

# Prédiction de l'activité humaine afin de réduire la consommation électrique de l'habitat

J. Gil-Quijano      C. Herpson      N. Sabouret  
gilquijano@poleia.lip6.fr      cedric.herpson@lip6.fr      nicolas.sabouret@lip6.fr

Laboratoire d'Informatique de Paris VI,  
Université Pierre et Marie Curie, 75016, Paris, France

## Résumé

Nous présentons dans cet article un mécanisme d'apprentissage du comportement des appareils électriques dans le contexte d'une maison intelligente. L'objectif de ce mécanisme est de réduire la consommation d'énergie des appareils à effet différé (par exemple le chauffage) tout en maximisant le confort des habitants. Notre approche utilise un modèle prédictif de l'activité d'une famille au sein de son logement. Ce modèle est construit à partir des informations locales perçues par les appareils électriques. Après avoir présenté en détail notre mécanisme, nous procédons à l'évaluation de celui-ci au sein de la plateforme de simulation SMACH. La qualité du modèle prédictif est évaluée par sa capacité à prévoir les déplacements d'une famille sur différents intervalles de temps. La stratégie apprise par les appareils électrique est quant-à-elle comparée au sein du simulateur à la stratégie proposée par notre partenaire EDF. Les résultats obtenus, bien que préliminaires, indiquent que notre approche est à même de réduire la consommation électrique tout en maintenant un bon niveau de confort des habitants.

**Mots-clés :** Simulation multi-agents, Intelligence ambiante, Apprentissage, Modèle prédictif du comportement

## Abstract

In this paper we propose a learning mechanism to build the behavior of electrical appliances in a smart home context. The aim of that mechanism is to reduce the consumption of appliances whose effect is delayed (for example the heating) while maximizing the inhabitants comfort. Our approach is based on a predictive model of home humans' activities. That model is built from local information sensed by the appliances. First we detail our mechanism, then we present its evaluation on the SMACH simulation platform. The accuracy of the model is evaluated on its ability to predict the displacements of a family. Evaluations are performed on several time frames. The strategy that is learned by the electrical appliances is compared with

*the one proposed by our partner EDF. Preliminary results show that our approach is able to reduce the electrical consumption without significantly lowering the comfort of inhabitants.*

**Keywords:** Multi-agent simulation, Ambient intelligence, Behaviour Learning, Human activity prediction

## 1 Introduction

La consommation électrique du secteur résidentiel représente aujourd'hui 29% de la consommation électrique Française [6]. La réduction de la dépense énergétique des foyers peut donc avoir un impact très important sur la consommation globale de l'habitat. Cependant, une stratégie de diminution de la consommation énergétique des logements ne prenant pas en compte le confort des habitants n'est pas envisageable. Pour être accepté, un tel plan de gestion de l'énergie doit donc marier réduction de la consommation d'énergie et confort des individus. Dans ce contexte, l'essor de l'informatique ubiquitaire offre de nombreuses perspectives. En effet, l'intégration d'objets communicants dans la vie quotidienne crée la possibilité d'adapter les comportements de ces derniers à leur environnement de manière proactive.

Dans le cadre de nos recherches menées en partenariat avec EDF, nous nous plaçons ainsi dans le contexte d'une maison intelligente. Nous modélisons les objets intelligents disponibles dans la maison comme des agents et faisons l'hypothèse que ceux-ci permettent de connaître la position et l'activité des membres de la famille. Notre objectif vise alors à permettre une adaptation adéquate des comportements énergétiques des appareils à effet différé (ie : le chauffage) en se basant sur un modèle prédictif des activités humaines.

Dans un contexte semblable, le projet ISES [4] propose un système multi-agent qui optimise l'utilisation des radiateurs et des lumières dans les locaux d'une entreprise. Le système se base

sur la négociation entre des agents-usagers qui essaient de maximiser leur niveau de confort et des agents-pièces qui essaient de minimiser la consommation d'électricité. Dans ISES, les agents-usagers déterminent leur activité à partir des agendas électroniques des humains qu'ils représentent. Les plannings étant toujours respectés, la notion d'imprévu n'existe pas. A l'inverse, nos recherches font l'hypothèse que le comportement humain est trop versatile pour envisager d'asservir les agents responsables des appareils électriques à un planning fixé *a priori*. Nous nous basons donc sur l'observation des humains pour détecter des "régularités" dans leurs comportements et tenter de prédire leur activité future. Dans un contexte également proche du notre, le travail [1] propose un mécanisme de coordination entre appareils producteurs (i.e. panneaux photovoltaïques) et appareils consommateurs d'énergie (i.e. appareils électroménagers) au sein d'une habitation. L'attribution de la ressource énergétique est basée sur un mécanisme d'anticipation qui considère l'offre et la demande sur une période donnée et privilégie les appareils qui ont un effet sur le confort des habitants. Dans cette étude, la demande énergétique de chaque appareil est connue *a priori* et la variabilité des comportements des habitants n'est pas prise en compte. Dans le cadre de nos recherches, le comportement des appareils est déterminé dynamiquement afin de s'adapter au mieux aux activités humaines. Nous n'utilisons pas d'informations relatives à la consommation *a priori* des appareils. Enfin, l'aspect production n'est pas considéré ici, l'énergie étant supposée disponible.

Plusieurs travaux en domotique [5, 13] s'intéressent à l'étude de l'activité humaine. Ils se basent sur la classification de séquences de micro-événements provenant de différents capteurs (positionnés dans la pièce, sur les meubles et sur la personne) pour déterminer la tâche couramment effectuée par un individu. Bien qu'intéressants en terme d'analyse comportementale, ces travaux n'intègrent pas de modèle prédictif. La construction de modèles prédictifs du comportement humain a été et est encore étudiée dans de nombreux contextes. Cependant, ceux-ci se répartissent principalement entre la modélisation du comportement d'un unique individu [11, 9, 3] et la modélisation d'une foule [7, 10, 2]. Dans le cas d'une personne seule, les problèmes liés aux relations d'influences entre individus ne sont par définition pas considérés. Dans le cas du comportement des foules, les modélisations portant sur plusieurs milliers (ou

dizaines de milliers) d'individus [12] utilisent des mécanismes d'abstraction de très haut niveau (modélisation sous forme de fluides, de particules [7]) qui n'offrent pas un niveau de détail suffisant pour représenter le comportement d'un groupe réduit de manière précise. Or, dans notre contexte, la combinatoire décrivant l'ensemble des interactions qui influencent les décisions et les actions - coordonnées ou non - de chaque membre d'un groupe (ici d'une famille) est très importante. L'élaboration d'une stratégie de gestion de l'énergie efficace passe donc nécessairement par un modèle fiable de la dynamique du groupe permettant ainsi de prédire le comportement des individus avec précision. Nous proposons dans cet article une modélisation statistique de l'occupation des pièces de l'habitat des membres d'une famille en fonction de leurs activités. Ce modèle permet alors de définir une politique pour les appareils à effet différé (radiateurs).

Afin de disposer d'un volume de données suffisamment important pour générer un modèle probabiliste cohérent, les déplacements des individus ont été incorporés au sein d'un simulateur et intègrent une certaine variabilité. Ce simulateur (SMACH) est présenté dans la partie 2. Les stratégies de référence proposées par notre partenaire pour la diminution de la consommation électrique sont introduites dans la partie 3.1. Nous présentons ensuite le modèle qui sert de base à la prédiction des déplacements des individus (partie 3.2). Ce dernier est utilisé pour déterminer le temps qui va potentiellement s'écouler avant qu'une pièce devienne vide ou occupée. Ces intervalles de temps sont ensuite factorisés et utilisés pour l'apprentissage des comportements des différents appareils électriques de la maison (partie 3.2 A et B). Enfin, une évaluation de notre modèle prédictif et des stratégies afférentes des appareils électriques est proposée en partie 4 au travers d'un scénario simulant l'activité d'une famille.

## 2 Modélisation du système au sein de la plateforme SMACH

SMACH (Simulation Multi-Agent du Comportement Humain) est une plateforme de simulation développée de façon collaborative dans le cadre de ce projet. Son objectif est de permettre d'évaluer l'impact du comportement adaptatif de différents appareils électriques sur la consommation globale d'une maison. Pour cela, SMACH modélise les comportements des appa-

reils électriques ainsi que ceux des individus. Les comportements des individus sont modélisés à partir d'observations réalisées *in vivo* sur les habitudes de familles témoins. Nous avons adopté un modèle orienté tâches. Le comportement d'un appareil est quant à lui représenté par son état courant et par l'impact de celui-ci sur le confort des habitants. Nous avons donc 2 types d'agents : les *agents appareils* (pour lesquels nous essayons de définir un comportement intelligent en utilisant les méthodes décrites dans cet article) et les *agents humains* qui représentent les habitants de la maison.

## Définitions

Soit  $\mathcal{A}$  l'ensemble d'agents représentant les appareils électriques,  $\mathcal{H}$  l'ensemble d'agents représentant les humains,  $\mathcal{T}$  l'ensemble de toutes les tâches que les agents-humains peuvent réaliser et  $\mathcal{R}$  l'ensemble de pièces de la maison.

Soit  $<$  la relation de précédence entre les tâches dans  $\mathcal{T}$ .  $\tau_i < \tau_j$  signifie que  $\tau_j$  ne peut commencer qu'après la fin de l'exécution de  $\tau_i$ . La relation de précédence entre toutes les tâches dans  $\mathcal{T}$  est exprimée sous forme de *graphe des contraintes intertâches* (voir figure 1). Soit  $poss : \mathcal{H} \rightarrow 2^{\mathcal{T}}$  la fonction qui renvoie l'ensemble de tâches possibles pour un humain donné.  $\tau \in poss(h)$  signifie que  $\forall \tau' < \tau, h$  a terminé d'exécuter  $\tau'$ . Soit  $pref : \mathcal{H} \times \mathcal{T} \rightarrow \mathbb{R}^+$  la fonction qui calcule la préférence d'un humain pour l'exécution d'une tâche donnée. Soit  $loc : \mathcal{R} \rightarrow 2^{\mathcal{T}}$  la fonction qui renvoie la localisation d'une tâche.  $\tau \in loc(r)$  signifie que  $\tau$  peut être réalisée dans la pièce  $r$ .

Pour chaque pièce  $r \in \mathcal{R}$  nous notons  $\mathcal{EV}_r$  l'ensemble de variables associées à  $r$  (e.g. "température", "luminosité", etc). Pour chaque appareil  $a \in \mathcal{A}$ , nous notons  $room(a) \in \mathcal{R}$  la pièce dans laquelle  $a$  est localisée et  $V_a \in \mathcal{EV}_{room(a)}$  la variable environnementale qui est modifiée par  $a$  dans sa pièce (ex. un radiateur agit sur la température de sa pièce). Nous notons  $\mathcal{VALS}(V_a)$  l'espace de valeurs de  $V_a$  et  $V_a^t \in \mathcal{VALS}(V_a)$  sa valeur au temps  $t$ . Nous notons  $\mathcal{ST}_a$  l'espace d'états de  $a$  et  $st_a^t \in \mathcal{ST}_a$  l'état de  $a$  au temps  $t$ .

## Comportement des agents

Le comportement des humains est gouverné par des objectifs globaux de la famille (e.g. respecter une limite de temps -partir à l'heure-, minimiser le coût de la consommation d'électricité -utiliser la machine à laver dans les périodes les

moins chères-, réaliser des activités sociales -manger en famille- et réaliser des tâches obligatoires -s'habiller avant de sortir-). La prochaine tâche  $t_n$  à être exécutée par un humain  $h$  est choisie à partir de l'ensemble  $poss(h)$ .  $t_n$  est la tâche qui maximise la *priorité*. Cette priorité dépend de la valeur de  $pref(h, t_n)$  et des objectifs globaux de la famille. Pour finir, la durée de  $t_n$  est également variable. Cette durée comprend deux composantes. D'une part le temps minimum pour que la tâche puisse être considérée comme réalisée (et donc que les tâches induites dans le graphe des contraintes intertâches puissent être déclenchées). D'autre part le temps "maximum" au delà duquel la priorité de la tâche est fortement diminuée pour permettre la sélection d'une nouvelle tâche. Un facteur aléatoire est également utilisé dans le calcul de la durée <sup>1</sup>.




FIG. 1 – Graphe des contraintes intertâches. Les tâches obligatoires sont grisées.

L'objective d'un agent- appareil  $a$  est double : maximiser le confort des humains et minimiser la consommation d'électricité. Le confort des humains dépend de la valeur  $V_a^t$ . Dans cet article, nous nous intéressons aux appareils qui nécessitent d'un temps relativement important pour produire un effet sur leur variable  $V_a$  associée (e.g. un radiateur). Nous appelons ce temps *période de transition* ( $\Delta_t$ ). Lorsque  $a$  influe sur la variable d'état  $ev_r$ , nous notons  $ev_r = map(st_a, \Delta_t)$  le fait que la valeur de  $ev_r$  soit obtenue après avoir maintenu  $st_a$  pendant un temps  $\Delta_t$ . Ainsi,  $lumineuse_r = map(ON_{lumiere}, 0)$  pour une lampe à incandescence et  $froide_r = map(OFF_{chauffage}, 30)$  (la pièce devient froide quand le chauffage est coupé pendant 30 minutes).

Pour maximiser le confort des humains dans une pièce  $r$  donnée, la valeur de  $\Delta_t$  doit être prise en compte pour déterminer le comportement de l'appareil  $a$ .

<sup>1</sup>il s'agit de la probabilité d'arrêter l'exécution de la tâche. Cette probabilité suit une distribution normale et prend sa valeur maximale lorsque la tâche atteint sa durée maximale

- Si  $r$  est vide,  $a$  doit la préparer de manière à ce que  $ev_r$  atteigne la valeur de confort avant l'arrivée de la première personne.
- $a$  doit maintenir les conditions de confort pendant le temps que la pièce est occupée.




FIG. 2 – Effet idéal souhaité d'un appareil  $a$  sur sa pièce  $r$ .  $r$  doit atteindre l'état confortable avant que quelqu'un y arrive,  $a$  doit maintenir cet état pendant que  $r$  est occupée et lorsque l'intervalle de temps avant que quelqu'un arrive est trop court. Dans les autres cas,  $a$  peut gagner un état moins consommateur d'électricité.

Pour minimiser la consommation d'électricité, après que le dernier humain ait quitté la pièce,  $a$  doit faire passer  $ev_r(a)$  à la valeur où l'on dépense le moins d'énergie. Cette dernière action ne doit être effectuée que si la pièce a le temps de regagner son état *confortable*, sous l'action de l'appareil, avant l'arrivée de nouvelles personnes. La stratégie idéale est présentée dans la figure 2.

**Exemple :** Dans cet article, nous considérons des radiateurs disposant de 3 états (*éteint* qui ne consomme pas ; *veille* qui consomme 3 unités ; et *marcheForcée* qui consomme 5 unités) associés à 3 états pour les pièces (*Froide*, *Fraiche*, *Confortable*) avec une période de transition  $\Delta_t = 5$ . Le comportement idéal d'un radiateur est d'assurer que la pièce soit dans l'état *Confortable* quand elle est occupée, *Fraiche* quand elle est vide et *Froide* quand il n'y a personne à la maison (cf. tableau 1).

TAB. 1 – Caractéristiques des radiateurs et des pièces. Les unités de consommation électrique (uce) sont fictives et ne servent qu'à comparer les résultats. Le temps de transition est exprimé en unité de temps (ut).

Radiateur		Pièce	
Etat	Dépense électrique	Temps de transition	Etat
Eteint	0	5	Froide
Veille	3.0	5	Fraiche
marcheForcée	5.0		Confortable

### 3 Amélioration du comportement des appareils électriques

Dans cette section, nous présentons plusieurs stratégies de comportements pour les appareils électriques. Nous présentons dans un premier temps les stratégies proposées par notre partenaire EDF. Nous introduisons ensuite notre approche qui repose sur l'observation du comportement des agents humains lors de l'exécution de  $N$  instances d'un scénario donné sur la plateforme de simulation. Un modèle probabiliste du comportement des différents individus est ainsi construit puis utilisé par les différents agents appareils pour prédire les déplacements des agents humains et adapter l'état des pièces en conséquence.

#### 3.1 Stratégies de référence

Dans la précédente version de la plateforme SMACH, les comportements des appareils électriques sont réactifs ou pseudo-réactifs.

**A) Stratégie réactive** Le comportement initialement proposé par EDF engendre un changement d'état des appareils électriques en fonction de la présence/de l'absence des gens dans une pièce donnée. Ce type de comportement n'est pas adapté aux appareils comme le chauffage du fait du temps de transition des pièces (ie : le passage d'une température ambiante de 18 à 20°C prend un certain temps).

**B) Stratégie rémanente** Pour palier aux limites de la stratégie réactive, EDF a donc proposé d'introduire un facteur de rémanence au sein des appareils à effet différé. Celui-ci permet de maintenir les valeurs de confort pendant un certain laps de temps  $\Delta_l$  après que la pièce se soit vidée de ses occupants. Cette rémanence est utilisée pour prévenir l'arrivée d'un individu dans la pièce. En fonction de la durée choisie, le taux de satisfaction peut ainsi être significativement amélioré. Cependant, la valeur de  $\Delta_l$  étant statique et déterminée *a priori*, cette stratégie a deux inconvénients majeurs. Elle engendre d'une part une perte d'énergie proportionnelle à la durée choisie dans le cas où personne n'entre dans la pièce, et ne représente d'autre part qu'un décalage du problème dans le cas où quelqu'un arrive après la période de rémanence (le nouvel arrivant étant insatisfait durant la période de transition).

Bien que d'une efficacité *a priori* réduite du fait des critiques avancées ci-dessus, ces 2 stratégies

nous serviront d'élément de comparaison lors de la phase expérimentale. La section suivante présente les différentes stratégies envisagées pour améliorer les performances des différents appareils.

### 3.2 Prédire les déplacements des individus afin de déterminer le comportement adéquat des appareils électriques

Pour s'affranchir des limites des stratégies précédentes et adapter plus finement le comportement des appareils électriques aux habitudes des membres de la famille, nous proposons ici un modèle prédictif de l'activité humaine. L'objectif de ce modèle est de permettre aux appareils de prévoir les déplacements des agents humains afin de "préparer" les pièces à "recevoir" les membres de la famille dans les meilleures conditions. Dans la version présentée dans cet article, les graphes d'activités des membres de la famille sont appris hors-ligne puis transférés dans la mémoire de chaque appareil. Lors de la phase d'exploitation, les différents agents échangent continuellement les informations dont ils disposent localement. Ils maintiennent ainsi à jour leurs connaissances sur les activités courantes de la famille et sont ainsi en mesure de prédire leurs déplacements et d'adapter leur comportement en conséquence. Nous proposons deux stratégies pour la construction de ce comportement ; la première est une stratégie réactive et la seconde utilise l'apprentissage par renforcement.

#### Prédiction des déplacements des individus

Le modèle prédictif utilisé est un modèle statistique. Comme présenté en 2, les comportements des membres de la famille ont été incorporés à la plateforme SMACH en intégrant une certaine variabilité (sous la forme de probabilités). La conception du modèle prédictif repose donc sur l'observation des activités de la famille lors des simulations effectuées sur SMACH. A partir de différentes simulations, nous identifions les déplacements les plus probables ainsi que la durée de ceux-ci (temps avant de quitter ou de rejoindre une pièce donnée).

**Etape d'observation :** Lors de cette étape, nous construisons le graphe d'activité  $\mathcal{G}\mathcal{A}_h$  de chaque humain  $h$  à partir des résultats de l'analyse statistique des comportements de  $h$  sur un ensemble de simulations (un exemple de graphe est présenté sur la figure 3). Les noeuds d'un graphe d'activité  $\mathcal{G}\mathcal{A}_h$  sont les différentes

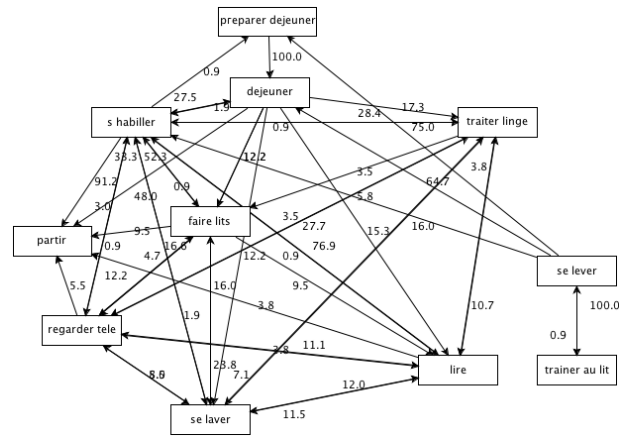


FIG. 3 – Exemple de graphe d'activité pour un adolescent établi à partir des résultats observés sur 100 instances d'un scénario. La valeur associée à un arc représente le pourcentage de chance de passer d'une tâche à l'autre.

tâches exécutables par l'humain  $h$ . Les arcs représentent des séquences d'exécution entre 2 tâches. On associe à chaque arc la probabilité d'exécution de cette séquence. Cette probabilité est le ratio entre le nombre de fois où la séquence a été exécuté par  $h$  divisé par le nombre de fois où  $h$  a réalisé la tâche de départ de ce même arc.

Pour 2 tâches  $\tau_k$  et  $\tau_l$  données, nous notons  $\mathcal{P}(\tau_l|\tau_k)$  la probabilité d'exécuter  $\tau_l$  immédiatement après  $\tau_k$  (cette probabilité est nulle lorsque l'arc est inexistant). Nous notons  $\tau_k <_{\mathcal{G}\mathcal{A}_h} \tau_l$  le fait que  $\tau_k$  précède strictement<sup>2</sup>  $\tau_l$  dans  $\mathcal{G}\mathcal{A}_h$ . On définit  $path_{\mathcal{G}\mathcal{A}_h}(A, B)$  l'ensemble des chemins tels que  $A <_{\mathcal{G}\mathcal{A}_h} B$ .

Comme chaque tâche ne peut être effectuée que dans certaines pièces, le graphe d'activité permet de prédire le prochain déplacement de  $h$  en fonction de la tâche en cours de réalisation (lorsque différentes pièces sont susceptibles d'accueillir une même tâche, on considère que chaque pièce a la même probabilité d'être retenue).

Soit  $c_h^t$  la tâche actuellement exécuté par l'individu  $h$ . Nous pouvons alors déterminer la probabilité qu'une tâche  $\tau$  puisse être exécutée dans le futur :

$$\mathcal{P}(h, \tau | c_h^t) = \sum_{\forall p \in path_{\mathcal{G}\mathcal{A}_h}(c_h^t, \tau)} \prod_{\forall \tau_i, \tau_{i-1} \in p} \mathcal{P}(\tau_i | \tau_{i-1})$$

<sup>2</sup>Le strictement écarte la possibilité pour 2 tâches à exécuter par un individu de se recouvrir même partiellement.

Nous pouvons également estimer le temps qui va s'écouler, en moyenne, avant le démarrage de la tâche  $\tau$ .

$$time_{to\_start}(h, \tau | c_h^t) = \frac{time_{to\_finish}(c_h^t) + time_{for}(mpp(\mathcal{GA}_h, c_h^t, \tau))}{2}$$

avec :

$mpp(\mathcal{GA}_h, c_h^t, \tau)$  : chemin le plus probable jusqu'à  $\tau$ .  
 $time_{for}(path)$  : temps moyen d'exécution du chemin.

**Remarque** : L'utilisation de la fonction  $mpp$  doit s'effectuer avec précautions. Le fait de retourner le chemin le plus probable peut en effet, dans le cas général, engendrer de nombreuses erreurs. A titre d'exemple, si  $P(A|B) = 0.49$  et  $P(C|B) = 0.51$  avec  $time_{for}(A) = 10 * time_{for}(C)$  alors, le temps moyen pris en compte sera très proche du cas C alors que le cas A sera presque aussi fréquent. Dans notre problème, l'homogénéité des durées des différentes tâches et la mise à jour des différentes équations à chaque décision prise par les membres de la famille permet d'utiliser cette approximation. Dans un contexte plus général, l'utilisation de mécanismes du domaine de l'*optimisation robuste* [8] (à partir des différents scénarios connus a priori) s'avérerait nécessaire.

La probabilité qu'un individu aille dans une pièce  $r$  donnée est égale à la somme des probabilités des différentes tâches qu'il peut effectuer dans  $r$  après la tâche actuelle. De là, la probabilité qu'un individu quitte la pièce où il se trouve est égale à la somme des probabilités associées aux tâches qu'il peut effectuer après la tâche courante et situées dans d'autres pièces. A partir de ces informations, nous sommes donc en mesure d'estimer le temps moyen avant qu'une pièce ne se vide ainsi que l'intervalle de temps minimal avant qu'une pièce ne se remplisse.

Soient  $\mathcal{H}_{out}(r)$  et  $\mathcal{H}_{in}(r)$  2 ensembles représentant respectivement les individus situés hors et dans la pièce  $r$ .  $\mathcal{T}_{out}(h, r)$  et  $\mathcal{T}_{in}(h, r)$  représentent - pour une pièce et un individu donné - l'ensemble des tâches que peut réaliser  $h$  après la fin de sa tâche courante et qui nécessitent de respectivement quitter et venir dans la pièce  $r$ . Ainsi,

$$\mathcal{T}_{out}(h, r) = \{\tau | c_h^t \in \mathcal{GA}_h, \tau \wedge h \in \mathcal{H}_{in}(r) \wedge r \notin room(\tau)\}$$

**Estimation du temps restant avant qu'une pièce ne se vide** : On appelle  $time_{empty}$  le temps restant avant qu'une pièce occupée ( $H_{in} \neq \emptyset$ ) ne se

vide.

$$time_{empty}(r) = \begin{cases} 0 & \text{if } \mathcal{H}_{in}(r) = \phi \\ \infty & \text{if } \exists h \in \mathcal{H}_{in}(r) | \mathcal{T}_{out}(h, r) = \phi \\ T_p(r) & \text{otherwise} \end{cases}$$

où :  $T_p(r) =$

$$\frac{\sum_{h \in \mathcal{H}_{in}(r)} \sum_{\tau \in \mathcal{T}_{out}(h, r)} \mathcal{P}(h, \tau | c_h^t) \times time_{to\_start}(h, \tau | c_h^t)}{\sum_{h \in \mathcal{H}_{in}(r)} \sum_{\tau \in \mathcal{T}_{out}(h, r)} \mathcal{P}(h, \tau | c_h^t)}$$

Moins formellement,  $T_p(r)$  tient compte du nombre d'individus présents dans la pièce et de l'ensemble des tâches qu'ils sont susceptibles d'effectuer hors de celle-ci (compte tenu de leur tâche courante) pour estimer le temps restant avant que la pièce ne se vide.

**Estimation du temps restant avant qu'une pièce ne se remplisse** :

Pour un individu et une pièce vide donnés ( $H_{in}(r) = \emptyset$ ), on a :

$$time_{to\_arrive}(h, r) = \min_{\forall \tau, \tau \in \mathcal{T}_{in}(h, r)} (time_{to\_start}(h, \tau | c_h^t))$$

Ce qui nous conduit finalement à obtenir pour une pièce vide donnée :

$$time_{in}(r) = \min_{\forall h, h \in \mathcal{H}_{out}(r)} (time_{to\_arrive}(h, r))$$

**Taille de l'espace d'états** : Sans précautions spécifiques, la taille de l'espace d'états que l'on doit considérer pour construire le comportement des appareils peut s'avérer très importante. Soit :

- $nbAi$  : nombre d'actions/individu
- $nbI$  : nombre d'individus
- $nbEa$  : nombre d'états par appareil
- $nbA$  : nombre d'appareils
- $nbEp$  : nombre d'états par pièce
- $nbP$  : nombre de pièces

La taille de l'espace d'états est donc de l'ordre de  $nbAi^{nbI} * nbEa^{nbA} * nbEp^{nbP}$  ; et ce même si les différentes contraintes (notamment séquentielles) réduisent la taille de l'espace considéré au court du temps.

Afin de faciliter la détermination du comportement des agents-appareils, il nous est donc paru nécessaire d'effectuer une réduction de l'espace d'états à manipuler. Pour cela, on définit  $MTT_{r,a}$  le maximum entre le temps de transition de l'état courant à l'état confort et le temps de transition de l'état courant à l'état qui lui est

immédiatement inférieur en terme de consommation énergétique. A partir des estimations  $time_{empty}(r)$  et  $time_{in}(r)$  introduites dans le modèle prédictif, il est alors possible de définir les différents états d'occupation d'une pièce en fonction de la valeur de  $MTT_{r,a}$  : le tableau 2 ci-après représente ce calcul.

TAB. 2 – Le temps avant arrivé est représenté par la variable (I), le temps avant inoccupation par la variable (E) et l'état de la pièce par (S).

(I)	(E)	(S)
$I > MTT_{r,a}$	$E = 0$	Vide
$I \leq MTT_{r,a}$	$E = 0$	Bientôt occupée
$I > MTT_{r,a}$	$0 < E \leq MTT_{r,a}$	Bientôt vide
$I \leq MTT_{r,a}$	$0 < E \leq MTT_{r,a}$	Occupée
$\forall I$	$E > MTT_{r,a}$	Occupée

Dès lors, l'espace d'états à prendre en considération a une complexité de l'ordre de  $nbP * nbEp^{nbEa}$  (le comportement des pièces étant décorrélé).

A partir des résultats du modèle prédictif, et compte tenu de la réduction de l'espace d'états réalisé ci-dessus, nous avons considéré 2 solutions pour la construction de comportements efficaces de la part des agents appareils. La première revient à déterminer directement le comportement des différents appareils à partir des résultats de la prédiction. La seconde fait l'hypothèse que l'utilisation d'un algorithme d'apprentissage par renforcement permettra de mieux supporter la variabilité des comportements des individus et les éventuelles erreurs de prédiction du modèle prédictif.

#### A) Un comportement réactif basé sur les prédictions

A partir de l'état d'occupation d'une pièce (cf. tableau 2), il est possible de modéliser le comportement des appareils sous la forme de règles de transitions. Nous définissons ainsi deux règles :

- Si le prochain état prédit pour la pièce  $r$  correspond à une pièce *Occupée* ou *Bientôt Occupée*, l'appareil doit passer dans l'état qui permet d'atteindre le niveau de confort sur la variable d'environnement  $ev_r$  associée.
- Si le prochain état prédit pour la pièce est *Vide* ou *Bientôt Vide*, l'appareil doit passer dans l'état immédiatement inférieur (en termes de consommation électrique) à son état courant.

#### B) Apprentissage du comportements des appareils électriques par l'algorithme du Q-learning

L'algorithme de Q-learning [14] permet d'apprendre une politique visant à maximiser la récompense globale de l'appareil en fonction de son but : maximisation du confort et minimisation de la consommation. Cet algorithme itératif considère, à chaque étape, la récompense immédiate associée au couple courant  $\langle \text{état de la pièce, état de l'appareil} \rangle$ . Le travail de l'algorithme d'apprentissage se restreint donc à apprendre pour chaque appareil et pour chaque état de la pièce, l'action qui maximise la fonction de récompense ci-après.

**Fonction de récompense :** Soit  $r$  la pièce où l'appareil  $a$  est disposé. La récompense obtenue par  $a$  lorsqu'il change son état courant pour l'état  $s$  est :

$$Reward(a, s) = Satisf(\mathcal{H}_{in(r)}, map(s, \Delta_t)) - consumption(a, s)$$

avec :

$$Satisf(\mathcal{H}_{in(r)}, v) = \frac{\sum_{h \in \mathcal{H}_{in(r)}} satisf(h, v)}{|\mathcal{H}_{in(r)}|}$$

$$\text{où : } satisf(h, v) \in \{-1, 1\}$$

et  $consumption(a, s)$  : consommation de l'appareil  $a$  dans l'état  $s$  (en pourcentage par rapport à sa consommation maximale).

A un instant  $t$ , la récompense est donc égale à la satisfaction des individus présents dans la pièce compte-tenu de l'état de celle-ci (en % du nombre total d'individus) moins la consommation électrique de l'appareil .

## 4 Expérimentations

Pour évaluer les différentes stratégies proposées dans cet article, nous avons conçu un scénario représentant l'activité d'une famille de cinq personnes (le père, la mère, un adolescent et deux enfants). Nous considérons une maison composée de 6 pièces (la chambre des parents, la chambre de l'adolescent, la chambre des enfants, la salle de bain, le salon, la cuisine) auxquelles s'ajoute l'extérieur de la maison.

Chaque pièce dispose d'un radiateur. Les différents états atteignables et les contraintes en terme de temps de transition sont présentées dans le tableau 1 ci-dessus. Le temps de transition entre 2 états consécutifs est immédiat pour un radiateur mais son impact sur la pièce est différé de 5 unités de temps (ut) par changement d'état. Si un radiateur passe de l'état *Eteint* à l'état *marcheForcée* dans une pièce *Froide*, le

radiateur va consommer 5 unités de consommation électrique par unité de temps et la pièce va mettre 10ut à atteindre l'état *Confortable*.

L'ensemble des tâches considérées pour les expérimentations est présenté sur le tableau 3 ci-dessous.

TAB. 3 – Ensemble des tâches possibles pour chaque occupant. Seule la tâche *partir* est obligatoire. Par le jeu des préconditions et des préférences individuelles, seul un sous-ensemble de ces tâches sera réalisé chaque matin par les occupants de la maison.

Tâche	Pièce	Père	Mère	Ado.	Enf.
Traîner au lit	Chbrs	✓	✓	✓	✓
Se lever	Chbrs	✓	✓	✓	✓
S'habiller	Chbrs	✓	✓	✓	✓
Faire lits	Chbrs	✓	✓	✓	✓
Se laver	SdB	✓	✓	✓	✓
Reg. télé	Salon			✓	✓
Lire	Salon	✓	✓	✓	✓
Traiter linge	Cuisine	✓	✓	✓	
Prép. pet. déj'	Cuisine	✓	✓	✓	
Prendre pet. déj'	Cuisine	✓	✓	✓	✓
Partir	Salon	✓	✓	✓	✓

Le graphe des contraintes inter-tâches associé est présenté sur la figure 1.

La durée d'une simulation est fixée à 120 unités de temps (1unité = 1minute). Nous avons généré le graphe d'activité de chaque individu à partir de 100 instances du scénario. A titre d'exemple, le graphe d'activité de l'"adolescent" est présenté sur la figure 3.

#### 4.1 Evaluation du mécanisme de prédiction

Afin d'évaluer la précision de la prédiction, nous avons mesuré le nombre de bonnes prédictions engendrées. Nous avons calculé cette mesure pour différentes valeurs de temps de transitions. Une prédiction est bonne si pour un temps de transition donné, l'état prédit correspond à celui de la simulation. Par exemple, si la prédiction pour l'état d'une pièce donnée est *Vide*, la pièce doit rester vide à partir de l'instant prévu par la prédiction et pour une durée au moins égale au temps de transition. Dans nos expérimentations, nous avons considéré des temps de transitions allant de 5 à 45 ut. Pour chaque valeur de temps de transition, 100 simulations ont été effectuées. Enfin, pour chaque ensemble de simulations, nous avons calculé le pourcentage de bonnes prédictions. Les résultats obtenus sont présentés sur la figure 4 ci-après.

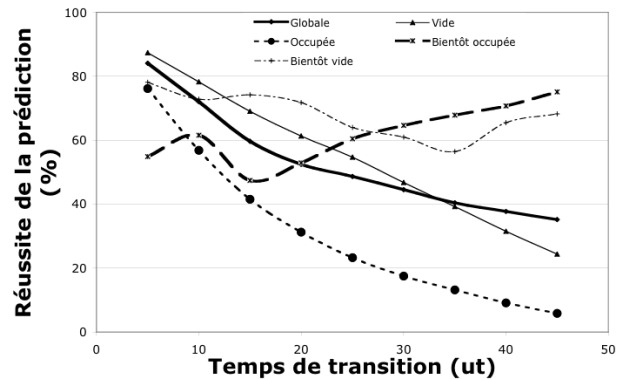


FIG. 4 – Taux de bonne prédiction en fonction du temps de transition d'une pièce d'un état à l'autre.

Les taux de bonnes prédictions les plus élevés ( $\cong 80\%$ ) sont obtenus pour des intervalles de transitions faibles (5 unités de temps). Leur nombre diminue avec l'augmentation de la durée des transitions. En effet, la durée moyenne d'une tâche dans notre scénario est de 10ut. Pour un temps de transition de 5ut, le mécanisme de prédiction doit donc prévoir les activités de la famille sur une horizon de 1 à 2 tâches. Dans le cas d'une période de transition de 45ut (et donc 90ut pour qu'une pièce passe de l'état *froide* à *confortable*), il faut être capable de prévoir la position des individus après une séquence de 9 tâches. Compte tenu de la combinatoire, cela s'avère beaucoup plus difficile. Néanmoins, le degré global de précision reste supérieur à 50% pour des temps de transition allant jusqu'à 25 ut.

#### 4.2 Evaluation des différentes stratégies

Afin d'évaluer nos différentes stratégies par rapport aux stratégies proposées par notre partenaire, nous avons effectué 100 simulations pour chacune d'elles. L'intervalle de temps  $\Delta_l$  correspondant au délai avant coupure de la stratégie rémanente a été fixé à 15 unités de temps. Cette valeur a été retenue après différentes expérimentations, celle-ci donnant les meilleurs résultats pour cette stratégie. Nous avons ensuite calculé la satisfaction et la consommation moyenne de chaque stratégie. Les figures 5 et 6 synthétisent ces informations. Comme nous pouvons le constater sur la figure 5, les valeurs de satisfaction obtenues suivant les stratégies prédictives sont légèrement plus faibles (- 7% par rapport à la stratégie réactive de référence). La stra-



tégie la plus mauvaise en terme de satisfaction se révélant être l'approche prédictive avec apprentissage.

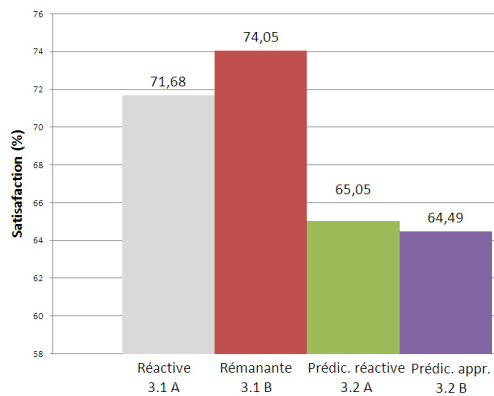


FIG. 5 – Taux de satisfaction moyen, pour chaque stratégie, établi sur 100 exécutions du scénario.




FIG. 6 – Consommation électrique moyenne obtenue après 100 exécutions du scénario pour chaque stratégie.

A l'inverse, et comme le montre la figure 6, la stratégie rémanente, bien que légèrement plus performante en terme de satisfaction utilisateur, engendre un accroissement de la consommation énergétique de 20% par rapport à la stratégie réactive. Suivant ce second critère, les résultats obtenus par l'approche prédictive montrent une nette diminution de la dépense énergétique qu'elle soit ou non combinée avec un mécanisme d'apprentissage. Ainsi, notre algorithme permet une économie d'énergie de 50% par rapport à la stratégie de référence (réactive). Ces derniers résultats confirment notre intuition sur les inconvénients de l'approche rémanente comparativement à la modélisation plus complexe, mais plus précise, que représente l'approche prédictive. A l'inverse, et contrairement à nos attentes, nos 2 stratégies prédictives obtiennent des performances équivalentes. L'ap-

prentissage a donc réussi à dégager des comportements adaptés pour les agent-appareils, mais celui-ci ne semble pas en mesure d'améliorer plus avant les résultats, ce qui invalide l'hypothèse faite en 3.2. Celle-ci supposait l'apprentissage à même d'absorber certaines des erreurs du modèle prédictif (celui-ci faisant 20% d'erreur dans le meilleur des cas).

## 5 Conclusion

Nous avons présenté un mécanisme de gestion de l'énergie qui, bien que relativement simple, permet une diminution de la consommation d'énergie de 50% par rapport à la stratégie de référence d'EDF sans que le confort des usagers ne soit trop altéré. Ce mécanisme fonctionne en 2 étapes : la prédiction des déplacements des individus et l'apprentissage des comportements des appareils électriques. Le modèle prédictif proposé s'avère bien adapté à l'estimation des comportements de plusieurs individus sur une période donnée. De plus, la taille de l'espace de recherche obtenu après factorisation facilite la détermination des comportements des appareils et permet d'envisager l'utilisation de cette approche sur des environnements plus complexes que ceux considérés dans cet article.

Cependant, ces résultats préliminaires doivent être nuancés. En effet, les différentes stratégies ont jusqu'à présent été uniquement testées en simulation. Or, la capacité d'identifier l'activité de chaque individu à chaque instant est une hypothèse très forte. Dans le cadre d'un déploiement en environnement réel - et si l'on écarte les dispositifs trop intrusifs de type implants ou caméras - les différents membres de la famille ne pourraient être aussi aisément discriminés. Les différents graphes d'activités devraient donc être fusionnés afin de représenter les activités du méta-individu *k-ubique* observé par les appareils domotiques (avec *k* le nombre d'individu réels composants le méta-individu). Cette perte d'information augmenterait la difficulté de l'apprentissage et l'on peut en conséquence s'attendre à une diminution des performances.

Une seconde limite à notre travail tient au fait que l'impact de l'environnement sur le comportement des appareils n'est pour l'instant pas considéré. A titre d'exemple, faire passer la température d'une pièce de 18° à 20° nécessite plus de temps la nuit que le jour du fait d'une déperdition d'énergie plus importante en l'absence de soleil. Une prochaine étape de notre travail vise donc à remplacer la linéarisation du com-

portement des appareils effectué ici lorsque l'on fixe les temps de transition *a priori*, par une détermination dynamique (et donc contextuelle) de ces derniers. A court terme, notre prochain objectif est donc de confronter nos stratégies à des données réelles afin de confirmer les résultats obtenus jusqu'à présent. L'intégration des données actuellement en cours de collecte par EDF nous permettra ainsi d'obtenir les temps de transitions réels des variables environnementales (i.e variation de températures des pièces en fonction de l'état du chauffage et de l'environnement) ainsi que le comportement de différentes familles.

Enfin, l'évaluation de nos stratégies en environnement réel n'est actuellement pas envisageable. En effet, cela nécessiterait de disposer d'un environnement domotique aisément modulable (nombre et disposition des pièces, des appareils) et un investissement trop important de la part des familles. Pour ces raisons, une seconde étape de nos travaux vise à intégrer les actions d'utilisateurs interagissant en temps réel avec notre système par le biais d'une simulation participative. S'agissant du cadre d'une simulation, nous disposerons d'une plus grande souplesse dans la définition des scénarii, de la capture et du traitement des comportements observés (utilisateurs de la simulation et *agents-appareils*). Dans la mesure où une personne ne va jouer son rôle qu'un nombre réduit de fois, il sera nécessaire d'envisager des solutions alternatives au fonctionnement actuel pour la construction du graphe d'activité. Une possibilité serait de combiner les observations issues des simulations participatives avec les simulations générées automatiquement en pondérant leurs importances respectives.

## Références

- [1] S. Abras, S. Pesty, S. Ploix, and M. Jacomino. Apport d'une approche multi-agents pour la résolution d'un problème de gestion de l'énergie dans l'habitat. In *Actes des Journées Francophones des Systèmes Multi-Agents*, 2009.
- [2] D.C. Brogan and J.K. Hodgins. Group behaviors for systems with significant dynamics. *Autonomous Robots*, 4(1) :137–153, 1997.
- [3] S. K. Das and D. J. Cook. Designing smart environments : A paradigm based on learning and prediction. *Lecture notes in computer science*, 3776 :81–90, 2005.
- [4] Paul Davidsson and Magnus Boman. Distributed monitoring and control of office buildings by embedded agents. *Inf. Sci.*, 171(4) :293–307, 2005.
- [5] Anthony Fleury, Norbert Noury, and Michel Vacher. Application des svm à la classification automatique des activités de la vie quotidienne d'une personne à partir des capteurs d'un habitat intelligent pour la santé. In *XVIèmes Rencontres de la Société Francophone de Classification*, page 4p, Grenoble, France, Sep. 2-4 2009.
- [6] N. Fontaine. Livre blanc sur les énergies. débat national sur les énergies. Technical report, Ministère de l'économie, des finances et de l'industrie, France, 2003.
- [7] D. Helbing, I. Farkas, and T. Vicsek. Simulating dynamical features of escape panic. *Nature*, 407(6803) :487–490, 2000.
- [8] P. Kouvelis and G. Yu. *Robust discrete optimization and its applications*. Kluwer Academic Pub, 1997.
- [9] M.C. Mozer. Lessons from an adaptive house. In D. Cook and S. Das, editors, *Smart environments : Technologies, protocols, and applications*. J. Wiley & Sons, Chichester, 2004.
- [10] S.G. Paris, S. Donikian, and N. Bonvalet. Vers une architecture pour la simulation microscopique de foule. *Revue Electronique Francophone d'Informatique Graphique*, 1(1), 2007.
- [11] Jung-Eun Park and Kyung-Whan Oh. Human behavior analysis for human-robot interaction in indoor environments. In Mehmet A. Orgun and John Thornton, editors, *Australian Conference on Artificial Intelligence*, volume 4830 of *Lecture Notes in Computer Science*, pages 762–768. Springer, 2007.
- [12] N. Pelechano, JM Allbeck, and NI Badler. Controlling individual agents in high-density crowd simulation. In *Proceedings of the 2007 ACM SIGGRAPH/Eurographics symposium on Computer animation*, page 108. Eurographics Association, 2007.
- [13] S.P. Rao and D.J. Cook. Predicting inhabitant actions using action and task models with application to smart homes. *International Journal of Artificial Intelligence Tools*, 13 :81–100, 2004.
- [14] R.S. Sutton and A.G. Barto. *Reinforcement learning : An introduction*. MIT Press, Cambridge, 1998.