



**HAL**  
open science

# Analyse et modélisation des interactions des occupants avec les fenêtres dans les chambres des logements français durant l'été

Kevin Campagna, Aurélie Fouquier, Anaïs Machard, Dorothée Charlier,  
Monika Woloszyn

► **To cite this version:**

Kevin Campagna, Aurélie Fouquier, Anaïs Machard, Dorothée Charlier, Monika Woloszyn. Analyse et modélisation des interactions des occupants avec les fenêtres dans les chambres des logements français durant l'été. Conférence Francophone de l'International Building Performance Simulation Association, IBPSA France, May 2024, La Rochelle - Ile d'Oléron, France. pp.1-20. hal-04663949

**HAL Id: hal-04663949**

**<https://hal.science/hal-04663949v1>**

Submitted on 29 Jul 2024

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

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

# Analyse et modélisation des interactions des occupants avec les fenêtres dans les chambres des logements français durant l'été

Kevin Campagna<sup>1,2,3\*</sup>, Aurélie Fouquier<sup>3</sup>, Anaïs Machard<sup>2</sup>, Dorothée Charlier<sup>4</sup>, Monika Woloszyn<sup>1</sup>

<sup>1</sup>Université Savoie Mont-Blanc, CNRS, LOCIE, 73000 Chambéry, France

<sup>2</sup>Centre Scientifique et Technique du Bâtiment (CSTB), 24 Rue Joseph Fourier, 38400 Saint-Martin-d'Hères

<sup>3</sup>Univ. Grenoble Alpes, CEA, Liten, INES, 73375 Le Bourget-du-Lac, France

<sup>4</sup>Université Savoie Mont-Blanc, IREGE, 4 chemin de Bellevue, 74940 Annecy-le-Vieux, France

\*[kevin.campagna@cstb.fr](mailto:kevin.campagna@cstb.fr)

---

*RESUME. Lors des périodes de vagues de chaleurs l'occupant joue un rôle prépondérant sur la surchauffe de son logement et donc sur son confort thermique. Aujourd'hui, la diversité des comportements en période de fortes chaleurs est mal représentée dans les logiciels classiques de STD. A l'aide d'une base de données recueillie sur 76 appartements dans 3 régions de France durant l'été 2023, cette étude vise à mieux comprendre le comportement des occupants vis-à-vis des fenêtres de leurs chambres et les paramètres environnementaux et sociologiques les plus impactant. A l'aide d'un clustering des profils types lors d'une semaine chaude et froide, il a été possible d'analyser la diversité des comportements et de retrouver des comportements adaptatifs de ventilation nocturne. Grâce à la méthode SHAP (Shapley Additive exPlanations) d'IA explicable d'un modèle XgBoost (eXtreme Gradient Boosting) de prédiction de l'état des fenêtres, la température et l'humidité, ainsi, que la catégorie socio-professionnelle, le mois de l'année, l'heure, le bruit ont été déterminés comme les plus impactant.*

*MOTS-CLÉS : Comportement des occupants - Modèle de prédiction d'état des fenêtres – Surchauffe – Été.*

---

*ABSTRACT. During heatwave periods, the occupant plays a major role in its dwelling overheating and therefore its thermal comfort. Today, the diversity of behaviours encountered in real life during periods of extreme heat is poorly represented in Performance Building Simulation (PBS). Using a database collected from 76 dwellings in 3 regions of France during the summer of 2023, this study aims to gain a better understanding of occupants' behaviour towards their bedroom windows openings. It focuses on the environmental and sociological parameters that have the greatest impact. By clustering typical profiles during a hot and a colder summer week, it was possible to analyse the diversity of behaviours and identify adaptive night-time ventilation behaviours. Using explainable AI method SHAP (Shapley Additive exPlanations) on an XgBoost (eXtreme Gradient Boosting) model for predicting window state, the parameters with the greatest impact were identified as the temperature and humidity, as well as socio-professional category, month of the year, time of day and noise.*

*KEYWORDS: Occupant Behavior - Window state prediction model – Overheating - Summer*

---

## 1. INTRODUCTION

La prise en compte du comportement des occupants, avec sa stochasticité intrinsèque et sa grande diversité, demeure un défi non résolu et une source majeure d'incertitude de la simulation thermique dynamique (Clevenger et Haymaker 2006). Les scénarios fixes et les règles actuelles ne parviennent pas à intégrer pleinement la diversité et la stochasticité des comportements (D'Oca et al. 2019). Les approches probabilistes, telles que les modèles basés sur des régressions logistiques simples ou multiples et les chaînes de Markov, ont été proposées pour pallier à ces lacunes (Haldi et Robinson 2008). Récemment, l'utilisation du Machine Learning sur des données de campagnes de mesures a montré des performances supérieures avec des modèles tels que les arbres de décisions, les Support Vector Machine,

les réseaux de neurones, les forêts aléatoires et le XgBoost (eXtreme gradient Boosting) (Mo et al. 2019). Le dérèglement climatique amplifie les vagues de chaleur et leur impact sur la surchauffe des bâtiments, soulignant l'importance du comportement des occupants pour maintenir le confort thermique. Par exemple, la gestion des fenêtres, notamment la ventilation nocturne, joue un rôle crucial pendant les périodes chaudes (Gondian 2019). Il apparaît nécessaire d'approfondir la recherche sur le comportement des occupants en période estivale dans les bâtiments résidentiels, étant donné que la majorité des modèles de comportement se concentrent sur les périodes hivernales ou d'inter-saison et principalement dans des bâtiments tertiaires (Balvedi, Ghisi, et Lamberts 2018). Malgré quelques études, comme celle de Hostein et al. (2023) sur quatre logements à Lyon, la généralisation des résultats reste difficile en raison de la taille limitée de l'échantillon (Dong, Liu, et al. 2022). Pour améliorer cette généralisation, il est essentiel d'augmenter la taille des bases de données et d'incorporer des facteurs contextuels et sociologiques dans les modèles (Yan et al. 2015). Cette étude s'appuie sur une base de données collectée dans 76 logements durant l'été 2023 en Ile de France, Gironde et dans le sud-est de la France, et vise à identifier les paramètres explicatifs de l'ouverture des fenêtres par les occupants français en période estivale et caniculaire et à mettre en place un modèle de prédiction de l'état des fenêtres en été basé sur les données.

## 2. METHODOLOGIE

### 2.1. METHODOLOGIE GENERALE

La méthodologie générale mise en place au cours de cette étude peut être résumée de façon graphique dans la Figure 1, et est présentée dans les sections suivantes.

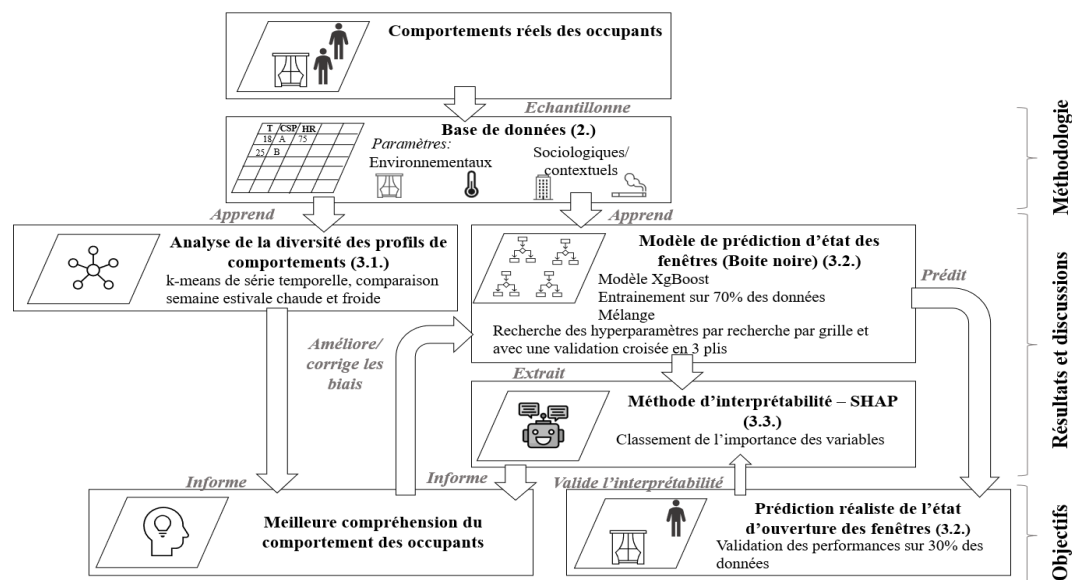


Figure 1 : Schéma explicatif de la méthodologie générale

### 2.2. DESCRIPTION DE LA BASE DE DONNEES

La base de données utilisée dans cette étude a été constituée dans le cadre du projet RENOPTIM copiloté par le CSTB (Centre Scientifique et Technique du Bâtiment) et l'USH (Union Sociale pour l'Habitat) qui vise à limiter le recours à la climatisation dans les logements français. Les 76 appartements ont été instrumentés de juin à fin septembre 2023, pour récolter la température et l'humidité à l'extérieur et à l'intérieur, l'état des fenêtres, ainsi que des informations sur les caractéristiques thermiques des

logements, sur les habitudes et le profil sociologique des occupants. Parmi les 19 résidences, les appartements ont été sectionnés pour essayer d'avoir un logement au rez-de-chaussée, à un étage intermédiaire et un sous les toits avec répartition de logements traversant et non-traversant de 60-40%. Le niveau de performance thermique des logements va de l'étiquette B à G avec une trentaine de logements ayant une étiquette C. La sociologie des occupants est variée, par exemple 26 occupants exercent une profession intellectuelle (CSP+), 18 sont retraités ou encore 22 occupants sont des employés. Dans cette étude, uniquement les données des chambres sont étudiées. La moitié des résidences étaient équipées d'une station météo sur le toit, pour celles non équipées, la météo de la résidence la plus proche leur a été associées. Un traitement des données a été effectué consistant à enlever les données incohérentes de capteurs (telles que des valeurs constantes, des valeurs physiquement impossibles ou des variations absurdes), à retirer les périodes d'absences longues, et à mettre toutes les données au même pas de temps de 10 minutes avec une interpolation linéaire entre deux pas de temps si nécessaire.

### 2.3. METHODOLOGIE DE L'ANALYSE DE LA DIVERSITE DES PROFILS DE COMPORTEMENT

Une comparaison des profils d'ouverture de fenêtres d'une période estivale dite « froide » et d'une dite « chaude » est réalisée avec une technique de clustering de K-means adaptée aux séries temporelles. Cette technique est utilisée à partir de la librairie `tslearn` de python et est utilisée avec le Dynamic time Warping Matching (DTW). Le nombre optimal de clusters est déterminé à l'aide du score de silhouette pour chaque période. Un test statistique du  $\chi^2$  (chi-2) est ensuite effectué pour expliquer la distribution des clusters à partir de paramètres sociologiques et contextuels.

### 2.4. MODELE DE PREDICTION D'ETAT DES FENETRES ET VALIDATION

Pour mieux comprendre le comportement des occupants vis-à-vis des fenêtres, un modèle capable de représenter des relations non-linéaires entre les variables avec une grande quantité de données a été construit. Pour cela, il est possible de construire deux types de modèles : un modèle d'état, prédisant si une fenêtre est ouverte ou fermée, et un modèle d'action, prédisant les changements d'état. Le modèle d'état est privilégié étant donné le faible nombre d'actions liées aux fenêtres durant l'été (Banihashemi et al. 2023). Un modèle XgBoost (eXtreme Gradient Boosting) est un algorithme gradient boosting qui est comparable à une forêt aléatoire, utilisant de nombreux arbres de décisions comme prédicteurs faibles. Contrairement à la forêt aléatoire l'erreur résiduelle de l'arbre de décision précédent est utilisée à chaque itération pour améliorer l'arbre de décision suivant. Ce type de modèle a été choisi pour ses performances, sa capacité à gérer automatiquement les données manquantes et sa capacité à gérer efficacement une grande quantité de données en évitant le sur-apprentissage. Concernant la méthodologie de construction de ce modèle de prédiction des états des fenêtres, les données sont mélangées en gardant la structure d'une journée, puis la base de données est divisée en 70% pour l'entraînement et la validation et 30% pour le test. Ensuite, une recherche par grille des hyperparamètres, correspondant aux paramètres intrinsèques du modèle, comme la profondeur des arbres ou le nombre d'arbres, est effectuée avec une validation croisée en 3 plis sur les 70% de la base de données. La validation croisée en 3 plis divise les données en trois ensembles, entraîne le modèle sur deux tiers et le valide sur le tiers restant, ce processus est répété trois fois pour améliorer l'estimation de la performance du modèle. Enfin, le modèle est testé sur 30% de données restantes en utilisant des métriques mathématiques et des métriques spécifiques au domaine tiré du travail de (Dong, Markovic, et al. 2022)).

## 2.5. METHODE D'INTERPRETABILITE DU MODELE DE PREDICTION

Les méthodes d'interprétabilité permettent de répondre à plusieurs objectifs : 1) Augmenter la confiance que l'on a dans le modèle en comprenant mieux son fonctionnement ; 2) Détecter des biais d'apprentissage (pour les corriger ensuite) ; 3) Améliorer notre compréhension des mesures que les modèles de Machine Learning ont pu saisir. Il a été choisi d'utiliser la méthode SHAP (Shapley Additive exPlanations) qui détermine la moyenne pondérée de la contribution marginale de chaque paramètre, issue de la bibliothèque python homonyme (Lundberg et Lee 2017). Cette méthode est choisie parce qu'elle permet à la fois de faire une interprétabilité locale (impacts des paramètres sur une prédiction du modèle) et globale (impacts des paramètres sur le comportement général du modèle) et a une implémentation très performante pour les modèles basés sur les arbres comme le XgBoost. La méthode SHAP nous permettra dans ce travail d'identifier les paramètres les plus significatifs et leurs influences globales. Dans un travail futur, elle permettra la sélection des paramètres les plus importants et l'évaluation précise de l'impact des divers paramètres dans des contextes spécifiques, offrant par exemple une meilleure compréhension de l'effet des variables clés lors d'une période de canicule.

## 3. RESULTATS ET DISCUSSIONS

### 3.1. ANALYSE DE LA DIVERSITE DES PROFILS DE COMPORTEMENTS


Le lien entre la proportion de fenêtres ouvertes (FO), la température extérieure et le moment de la journée est analysé dans cette partie à l'aide de données d'une semaine estivale « froide » et « chaude » dont les caractéristiques sont résumées dans le Tableau 1.

**Tableau 1 : Résumé des températures moyennes durant les semaines estivales "froide" et "chaude"**

Région	Semaine estivale « froide »				Semaine estivale « chaude »			
	Période		Température moyenne [°C]		Période		Température moyenne [°C]	
	Début	Fin	[22-6h]	]6h-22[	Début	Fin	[22-6h]	]6h-22[
<b>GIR</b>	18/09/2023	24/09/23	15,8	19,4	17/08/2023	23/08/23	23,8	29,1
<b>IDF</b>	18/09/2023	24/09/23	15,1	17,4	03/09/2023	09/09/23	23,4	28,8
<b>SE</b>	18/09/2023	24/09/23	17,7	21,3	17/08/2023	23/08/23	24,5	32,3

Dans la partie gauche de la Figure 2, les courbes en pointillées mettent en évidence les différences de comportement moyen régional entre les semaines estivales « chaude » et « froide ». En semaine estivale « froide », la proportion de fenêtres ouvertes est plus élevée le matin et après 18h (55% de FO), avec des variations faibles entre les maximums et minimums en journée ainsi qu'entre les régions. En semaine estivale « chaude », la proportion de fenêtres ouvertes varie au cours de la journée, avec une forte ouverture durant la nuit et en de matinée, avec une nette réduction de 8h à 22h. Ce comportement est observé dans toutes les régions, avec quelques différences : il y a une ventilation nocturne plus importante dans le Sud-Est (90% de FO, contre 80% en Gironde et 60% en IDF), et une fermeture plus marquée en journée en Gironde (jusqu'à 40% de FO contre 60% dans le SE et 50% en IDF).

Pour analyser plus clairement la diversité des profils, une analyse par clustering de série temporelle k-means est réalisée, présenté dans la partie centrale de la Figure 2. Les scores de silhouette de la semaine estivale « froide » et « chaude » sont respectivement de 0,5 et 0,44. Pour rappel, un score de



**Figure 2 : Gauche : Profils moyen des comportements et moyennes régionales en pointiller. Milieu : Clusters des profils par k-means correspondant à la proportion de fenêtres ouvertes dans les chambres des logements de l'étude. Droite : Résultats du test de Chi2 à une significativité de  $p < 0,05$ .**

**Haut : Durant la semaine estivale « froide ». Milieu : Evolution des profils de la semaine estivale « froide » à « chaude » Bas : Durant la semaine estivale « chaude ».**

silhouette supérieure à 0,7 est considéré comme "fort", une valeur supérieure à 0,5 comme "raisonnable" et une valeur inférieure à 0,25 comme "faible". Les clusters 0 des semaines estivales correspondent à un cluster où les fenêtres ont tendance à être fermées. On observe cependant, pour la semaine estivale « chaude » un fort pic d'ouverture entre 7h et 10h du matin. Le cluster 1 des deux semaines représente des profils qui ont tendance à garder leurs fenêtres toujours ouvertes. Le cluster 2 de la semaine estivale « froide » correspond à un profil moyen, qui a les fenêtres majoritairement fermées la nuit, et rassemble les profils qui n'ont pas pu être classés dans les deux autres clusters. Le cluster 2 de la semaine estivale « chaude » rassemble des profils qui font de la ventilation nocturne, qui a donc une ouverture des fenêtres durant la nuit et une fermeture de 8h à 21h.

Des tests du  $\chi^2$  (chi-2) ont été réalisés pour déterminer les paramètres contextuels et sociologiques qui pourraient expliquer l'appartenance des profils aux clusters en évaluant l'indépendance des paramètres par rapport aux clusters. Les résultats des tests se trouvent dans la partie droite de la Figure 2. Pour la semaine estivale « froide », les paramètres significativement influents ( $p < 0,05$ ) sont le genre, le nombre d'occupants dans le logement et la pratique de la ventilation nocturne. Par exemple, les personnes n'effectuant pas de ventilation nocturne sont significativement moins présentes dans le cluster 1, où les fenêtres ont tendance à rester ouvertes en permanence. Pour la semaine estivale « chaude », les paramètres influents sont la catégorie socioprofessionnelle (CSP1), la région, l'activité physique, le nombre d'occupants dans le logement, la sensibilité à la chaleur, le statut du logement (social ou non) et la pratique de la ventilation nocturne. Par exemple, les habitants d'Île-de-France sont significativement

moins présents dans le cluster chaud 2, indiquant que la ventilation nocturne y est moins pratiquée que dans les autres régions. De même, les personnes déclarant être sensibles à la chaleur sont significativement plus présentes dans les clusters chauds 1 et 2 que celles déclarant ne pas l'être. Certains paramètres testés, tels que le tabagisme, la présence de moustiquaires, le bruit ou l'étage ne se sont pas révélés significatifs. Avec un nombre élevé de transitions entre clusters (9 transitions), séparant les données en trop petits groupes, le test du  $\chi^2$  n'a pas pu être appliqué sur les transitions rendant impossible l'étude des raisons du changement de comportement entre les deux semaines.

### 3.2. MISE EN PLACE D'UN MODELE DE PREDICTION D'ETAT DES FENETRES

Pour compléter notre analyse du comportement des occupants, des paramètres l'influençant et pour prédire l'état des fenêtres, un modèle XgBoost est construit en utilisant les données de juin 2023 à fin septembre 2023. Les hyperparamètres du modèle sont sélectionnés et fixés comme suit : taux d'échantillonnage des colonnes par arbre de 0.6, régularisation (gamma) de 0, taux d'apprentissage de 0.08, profondeur maximale de l'arbre de 10, poids minimal des feuilles de 5 et nombre d'arbres de 50. Le modèle est entraîné et inclue 32 paramètres environnementaux, contextuels et sociologiques. Les résultats montrent que le modèle parvient à prédire correctement l'état des fenêtres dans 77% des cas. Cependant, il tend à surestimer la proportion globale de fenêtres ouvertes (60% de FO prédit contre 56% réel) et la fréquence d'ouverture par jour (1,28 ouverture par jour prédite contre 0,95 réel). On considère




Figure 3 : Gauche : Tableau récapitulatif du classement des 32 paramètres selon les valeurs moyennes SHAP du modèle XgBoost de prédiction de l'état des fenêtres. Droite : Sens de l'influence des 19 premiers paramètres sur le modèle XgBoost de prédiction de l'état des fenêtres.

dans ce travail que le modèle prédit (70% du jeu de données) avec une précision correcte l'état des fenêtres sur les données de test (30% du jeu de données). Dans un travail futur, il sera nécessaire d'explorer plus en détail, grâce à l'utilisation de l'interprétabilité locale de la méthode SHAP les raisons des 23% d'erreurs du modèle, et pouvoir pour corriger les biais d'apprentissage possibles et avoir un modèle qui est à la fois plus performant et représentatif des données et de la réalité des comportements.

### 3.3. ETUDE DE L'IMPORTANCE DES DIFFERENTS PARAMETRES

Pour déterminer les paramètres les plus impactant, la méthode d'interprétabilité SHAP est utilisée sur le modèle XgBoost construit. Il est nécessaire de garder à l'esprit que les effets des différents paramètres sont représentatifs du modèle qui est, d'après l'évaluation, lui-même sensé être représentatif des données. Cependant, dans l'état actuel du modèle, celui-ci peut être sujet à des biais d'apprentissage, qui seront détectés et corrigés dans le futur à partir de la meilleure compréhension du modèle acquise à partir de l'analyse SHAP actuelle et future (voir Figure 1).

Dans le tableau à gauche de la Figure 3 se trouve le classement des 32 paramètres par ordre d'importance et à droite sont représentés l'influence (état fermé ou ouvert) des paramètres les plus importants. Voici un exemple d'interprétation des résultats : une température extérieure basse, représentée par du bleu, a une valeur SHAP négative, indiquant une prédiction plus encline à des fenêtres fermées, tandis qu'une température élevée représentée par du rouge a tendance à favoriser la prédiction des fenêtres ouvertes. La température, l'humidité extérieure et intérieure font partie des paramètres les plus importants, alors que l'irradiance globale horizontale semble beaucoup moins influente contrairement à ce qui avait été trouvé par Hostein et al. (2023). Cependant, ces résultats seraient sûrement différents si l'irradiance incidente à la fenêtre était considérée, sachant que de nombreuses études ont mis en évidence que l'orientation de la fenêtre était un paramètre important.

La catégorie socioprofessionnelle (CSP1) exerce une influence significative sur les prédictions du modèle. Les catégories intellectuelles (cadres, chefs d'entreprise...) ont un impact négatif (tendance à prédire des fenêtres fermées), tandis que les catégories associées dans le modèle à une valeur moyenne et faible, représenté par une couleur respectivement violette et bleu (resp. Ouvriers/artisans et retraités/chômeurs) ont un impact neutre ou positif sur le modèle (tendance à prédire des fenêtres ouvertes). Des hypothèses possibles sont que les catégories socioprofessionnelles induisent une différence d'occupation des logements, que les CSP sont corrélés à un type de logement, ou qu'ils impliquent des comportements différents. D'autres paramètres contextuels influencent également les prédictions du modèle, tels que l'heure de la journée, le mois de l'année, la ventilation nocturne et le bruit. Des paramètres comme la région et le bruit font partie des paramètres influents, mais ne sont pas dans le haut du classement, il serait intéressant d'étudier ces paramètres en se focalisant sur une période de forte chaleur ou la nuit avec l'explicabilité locale des valeurs SHAP.

## 4. CONCLUSION ET PERSPECTIVES

Les températures et l'humidité intérieures et extérieures influent sur le comportement des occupants vis-à-vis des fenêtres, notamment avec l'adoption de comportements adaptatifs tels que la ventilation nocturne en période de fortes chaleurs, absente en période plus fraîche au cours de l'été. D'après notre connaissance de la littérature du comportement des occupants vis-à-vis des fenêtres, notre étude est certainement celle considérant le plus de paramètres contextuels et sociologiques. Cela a permis de



confirmer le résultat d'études de la littérature indiquant que le mois, l'heure et l'âge étaient des paramètres influençant le comportement des occupants. Cela a aussi permis de déterminer des paramètres sociologiques et contextuels comme la catégorie socio-professionnelle ou le bruit comme des paramètres influençant significativement les comportements. L'identification de ces paramètres est un premier pas vers la généralisation des modèles de comportement des occupants.

Pour approfondir la recherche des paramètres influençant le comportement des occupants vis à vis des fenêtres et construire un modèle de prédiction de comportement des occupants avec les fenêtres généralisable, il sera important d'incorporer plus de paramètres concernant la physique du bâtiment comme le niveau d'isolation ou le caractère traversant des logements. Il est aussi nécessaire d'explorer l'influence locale de chaque paramètre sur une unique prédiction ou un groupe de prédiction (région, nuit/jour, périodes de chaleurs...) en utilisant les valeurs de Shapley. Ensuite, pour améliorer la performance du modèle de prédiction il serait intéressant d'utiliser et de comparer d'autres méthodes de modélisation, telles que les modèles d'action, ainsi que d'autres types d'algorithmes et les modèles actuellement utilisés en STD. De plus, poursuivre l'analyse de clustering des profils d'ouverture et comprendre l'évolution des clusters au fil du temps serait pertinent. Enfin, incorporer d'autres actions adaptatives comme la gestion des protections solaires ou l'utilisation des brasseurs d'air et d'étudier leur impact sur le confort thermique des occupants, permettrait de mieux comprendre la diversité des comportements adaptatifs mis en place pour lutter contre les fortes chaleurs.

## 5. REMERCIEMENT

Ce travail a bénéficié d'une aide de l'État gérée par l'Agence Nationale de la Recherche au titre du programme d'Investissements d'Avenir (réf. ANR-18-EURE-0016 – Solar Academy).

## 6. BIBLIOGRAPHIE

- Balvedi, Bruna Faitão, Enedir Ghisi, et Roberto Lamberts. 2018. « A review of occupant behaviour in residential buildings ». *Energy and Buildings* 174 (septembre): 495-505. <https://doi.org/10.1016/j.enbuild.2018.06.049>.
- Banihashemi, Farzan, Manuel Weber, et al. 2023. « Window state or action modeling? An explainable AI approach in offices ». *Energy and Buildings* 298 (novembre): 113546. <https://doi.org/10.1016/j.enbuild.2023.113546>.
- Berndt, Donald J, et James Clifford. 1994. « Using Dynamic Time Warping to Find Patterns in Time Series ». *AAAI Technical Report*.
- Clevenger, Caroline M, et John Haymaker. 2006. « The Impact of the Building Occupant on Energy Modeling Simulations ». *Joint International Conference on Computing and Decision Making in Civil and Building Engineering*, 1-10.
- D'Oca, Simona, H Burak Gunay, Sara Gilani, et William O'Brien. 2019. « Critical Review and Illustrative Examples of Office Occupant Modelling Formalisms ». *Building Services Engineering Research and Technology* 40 (6): 732-57. <https://doi.org/10.1177/0143624419827468>.
- Dong, Bing, Yapan Liu, Wei Mu, Zixin Jiang, Pratik Pandey, Tianzhen Hong, Bjarne Olesen, et al. 2022. « A Global Building Occupant Behavior Database ». *Scientific Data* 9 (juin). <https://doi.org/10.1038/s41597-022-01475-3>.
- Dong, Bing, Romana Markovic, et al. 2022. « A guideline to document occupant behavior models for advanced building controls ». *Building and Environment* 219 (juillet): 109195. <https://doi.org/10.1016/j.buildenv.2022.109195>.
- Gondian, Léa. 2019. « Application de l'analyse de sensibilité temporelle pour la description de la réponse thermique d'un bâtiment aux actions des habitants. » Chambéry: Université Savoie Mont Blanc.
- Haldi, Frédéric, et Darren Robinson. 2008. « Stochastic / Probabilistic Modelling of Multiple Adaptive Processes: Some Subtle Complexities » 5th IBPSA-Canada Conference.
- Hostein, Mathilde, Bassam Moujalled, Marjorie Musy, et Mohamed El. 2023. « A Study of Indoor Environment and Window Use in French Dwellings Monitored during a Summer with Heatwaves ».
- Lundberg, Scott, et Su-In Lee. 2017. « A Unified Approach to Interpreting Model Predictions ». arXiv. <http://arxiv.org/abs/1705.07874>.
- Mo, Hao, Hejiang Sun, Junjie Liu, et Shen Wei. 2019. « Developing window behavior models for residential buildings using XGBoost algorithm ». *Energy and Buildings* 205: 109564. <https://doi.org/10.1016/j.enbuild.2019.109564>.
- Yan, Da, William O'Brien, et al. 2015. « Occupant behavior modeling for building performance simulation: Current state and future challenges ». *Energy and Buildings* 107 (novembre): 264-78. <https://doi.org/10.1016/j.enbuild.2015.08.032>.