



HAL
open science

Système de détection et de suivi du comportement de personnes dans le cas des chutes basé sur l'analyse de la mobilité

Laura Maligne, Eric Campo, Adrien van den Bossche, Nadine Vigouroux, Frédéric Vella, Olivier Negro, Dan Istrate, Vincent Zalc, Pierre Rumeau

► **To cite this version:**

Laura Maligne, Eric Campo, Adrien van den Bossche, Nadine Vigouroux, Frédéric Vella, et al.. Système de détection et de suivi du comportement de personnes dans le cas des chutes basé sur l'analyse de la mobilité. Colloque en Télésanté et dispositifs biomédicaux, Université Paris 8, CNRS, Jun 2023, Paris Saint Denis, France. hal-04220667

HAL Id: hal-04220667

<https://hal.science/hal-04220667>

Submitted on 28 Sep 2023

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.

Système de détection et de suivi du comportement de personnes dans le cas des chutes basé sur l'analyse de la mobilité

Laura Maligne¹, Eric Campo^{1,3}, Adrien van den Bossche^{2,3}, Nadine Vigouroux², Frédéric Vella², Olivier Negro³, Dan Istrate⁴, Vincent Zalc⁴, Pierre Rumeau⁵

¹LAAS, UPR8011, CNRS, Toulouse, France

²IRIT, Université de Toulouse, CNRS, Toulouse INP, UT3, UT2J, Toulouse, France

³IUT de Blagnac, Université Toulouse Jean Jaurès, Toulouse, France

⁴Université de Technologie de Compiègne, CNRS, Biomechanics and Bioengineering, Centre de recherche Royallieu – Compiègne, France

⁵Laboratoire de Gérontechnologie La Grave, CHU Toulouse/CERPOP, Toulouse, France
eric.campo@univ-tlse2.fr

Abstract – L'article présente une étude menée au sein d'une maison partagée accueillant 12 personnes âgées autonomes. Chaque chambre des habitants ainsi que les deux zones communes ont été instrumentées par des capteurs permettant de relever les activités de mouvement et d'entrée/sortie. Une infrastructure matérielle et informatique complète a été conçue par une équipe de chercheurs pluridisciplinaires et testée préalablement au sein d'un appartement intelligent puis déployée au sein de la maison partagée. 9 mois de données ont été collectés et analysés mettant en évidence les modes d'activités habituels et les changements de ces comportements notamment lors de l'apparition d'une chute puis du retour au comportement habituel. Deux niveaux d'analyse ont été implémentés : la détection des écarts des indicateurs d'activités de chaque individu et la détection de la dérive des modèles de comportement au cours du temps. Les résultats obtenus mettent en exergue la relation entre les dérives de modèle constatées et des événements liés aux chutes et retours d'hospitalisation. Les performances des méthodes utilisées sont discutées ainsi que les premiers résultats de classification des activités.

Keywords: Capteurs de mouvement, modèle du comportement, chute, personnes âgées, habitats partagés.

I. INTRODUCTION

Le mode d'habiter des personnes âgées vivant seules est une des préoccupations majeures actuelles dans le champ de l'autonomie. Les habitats alternatifs aux structures de type EHPAD se caractérisent, à ce jour, par leur grande hétérogénéité. L'architecture des locaux, la situation géographique, le profil des habitants ou la structure juridique diffèrent d'un mode à un autre. Les béguinages, les résidences

intergénérationnelles, les habitats partagés, les habitats groupés, les domiciles communautaires ou les appartements collectifs sont autant de dénominations figurant cette nouvelle offre résidentielle destinée principalement aux plus de 60 ans [1]. La Maison Partagée (MP) est un mode d'habitat imaginé, après une longue expérience de terrain par des professionnels, sous la forme d'une nouvelle structure d'accueil et d'accompagnement pour des personnes âgées autonomes fragiles. Depuis 2009, cet habitat alternatif tente de répondre aux attentes de ces personnes, de vivre le plus longtemps possible au domicile sans être seules et isolées. Elles cohabitent avec quelques personnes et sont soutenues au quotidien par un professionnel. Les MP sont un concept décliné sous plusieurs formes en Europe [2]. Ce sont des lieux propices à la participation à la vie de la cité et à l'expression de la sociabilité. Cependant, même si l'habitat dispose d'un accompagnement présent 7J/7 de 9h à 17h, des risques n'en sont pas moins présents. Peu de recherches ont été jusqu'à présent consacrées à l'utilisation de dispositifs technologiques permettant l'observation du comportement d'une population âgée vivant dans ce type de structure.

L'évolution des systèmes numériques et technologiques de surveillance au sein de nouvelles structures et services dédiés aux personnes âgées est une aide pour la modélisation et la compréhension du mode de vie de ces personnes [3]. Elle pourrait prévenir certains risques dans le respect d'un choix local de mode de vie. L'étude décrite ici vise à présenter le système technique déployé au sein d'une maison partagée de l'association ASF [4] dans le Tarn (81) ainsi que l'analyse des données recueillies. Cette étape de faisabilité courant sur un an au total, concerne la mesure objective des comportements identifiés par la mobilité [5], la détection de la toux [6] dont une analyse combinée capteurs de mouvement/sons est

présenté dans un article, et l'utilisation d'une commande vocale et tactile [7]. Un des verrous étudiés est la combinaison de ces mesures hétérogènes et non synchronisées pour en dégager des habitudes, des signes inhabituels et des indicateurs d'un changement de comportement. Dans cet article, nous nous focalisons sur les premiers résultats obtenus sur la modélisation des habitudes de mobilité basés sur les capteurs de mouvement et entrée/sortie que nous avons mis en relation avec les annotations des accompagnants.

Nous nous intéresserons tout particulièrement au cas des chutes survenues durant la période d'observation. En effet, les conséquences d'une chute, au-delà d'une fragilité physique (fracture, inconfort), sont le risque d'une isolation involontaire due à une mobilité réduite [8]. Avant et suite à un évènement à risque, on cherche alors à détecter des changements grâce à l'observation de la mobilité au sein d'une pièce associée à un résident de la MP. Selon la modélisation des habitudes préalablement identifiées par des techniques d'apprentissage basée sur l'IA, on peut suivre l'évolution des comportements des habitants (on s'intéresse ici plus particulièrement à l'activité dans la chambre) et analyser les liens entre les évènements singuliers annotés par les personnels d'accompagnement et les évolutions des modèles. On construit finalement un capteur logiciel qui nous permettra de déterminer des changements notables et de lever le cas échéant une alerte.

L'article présente le processus méthodologique mis en place dans cette étude puis l'infrastructure matérielle et logicielle déployée, les mesures effectuées et les modèles de détection développés. Une conclusion permettra de rappeler les résultats obtenus et donnera quelques perspectives des travaux futurs.

II. MÉTHODOLOGIE

Le projet a suivi un processus méthodologique déjà éprouvé [9-10] par les chercheurs de l'étude et approuvé par le comité éthique de la recherche de Toulouse (2022-469). Il débute par une visite sur site pour rencontrer les résidents afin de leur présenter les objectifs du projet et procéder à la lecture et signature de la lettre d'information et du formulaire de consentement. Cette présentation est réalisée sous la forme d'un atelier participatif. On procède ensuite à l'installation des capteurs et à leurs tests de fonctionnement. Le système est déployé dans 14 pièces : 12 espaces individuels et 2 espaces communs. Les espaces individuels disposent d'une chambre et d'une salle de bain attenante, toutes deux équipées de capteurs. Les espaces communs comprennent une cuisine et une pièce de vie, équipées de capteurs de la même manière que les espaces individuels. La collecte et l'analyse des données s'étendent sur une période de 9 mois (22 avril 2022 – 22 janvier 2023) et se poursuivent à ce jour. L'étude prend en compte les 12 habitantes de l'habitat partagé étant toutes considérées comme autonomes avec un score ADL (Activities of Daily Life) de 6

et un score IADL (Instrumental Activities of Daily Life) de 7,09 ($\pm 1,38$). Nous ne disposons pas d'autres données médicales. La moyenne d'âge est 88 ans. Deux accompagnants sont présents quotidiennement à la MP et annotent sur un cahier d'observations les évènements singuliers qu'ils observent ou qui leur sont rapportés par les habitantes. Ces évènements peuvent être d'ordre individuel (personne qui s'isole, qui chute, qui s'absente, sort plus souvent, reçoit plus ou moins de visites...) ou d'ordre collectif (animations au sein de la MP, activités de cuisine, jeux...). Nous faisons l'hypothèse que ces informations peuvent permettre d'expliquer ou de valider les comportements observés et détectés par le système d'analyse.

III. INFRASTRUCTURE TECHNOLOGIQUE

L'infrastructure technologique a été conçue et testée dans un premier temps en environnement contrôlé au sein de la Maison Intelligente de Blagnac¹. Les 44 capteurs distribués recueillent les données d'activité dans les espaces privés et communs. Il s'agit de capteurs de mouvement infrarouge passif (IR) et de contacts d'ouverture de porte (CM) communicant selon le protocole sans fil Z-Wave associé au logiciel de gestion domotique libre Domoticz², le tout relié à un Raspberry Pi (RPi) par chambre. Les Raspberry Pi envoient leurs données journalières via le Wifi local (Figure 1) sur un serveur local, lui-même connecté à un serveur de données sécurisé SFTP localisé dans notre laboratoire. Les données sont transmises chaque nuit des Raspberry Pi au serveur local, puis du serveur local au serveur du laboratoire.




Figure 1. Architecture globale déployée au sein de la MP

¹ <http://mi.iut-blagnac.fr>

² <https://www.domoticz.com/wiki/Zwave>

En cas de coupure réseau, locale ou Internet, les données sont sauvegardées en attendant la nuit suivante. Les données recueillies sont incrémentées dans une base de données structurée *ad hoc* de type SQL. La récupération des données dans des tables et l'uniformisation des pas de temps ont été effectuées en langage Python. Enfin, des outils de monitoring de l'infrastructure ont été déployés sur le serveur local (collectd, smokeping) afin de vérifier le bon fonctionnement du système à distance et un portail web chiffré et protégé par mot de passe a été développé pour permettre aux chercheurs de se connecter simplement sur les outils de monitoring, comme sur les applications finales (Domoticz).

IV. DONNEES ET REPRESENTATION DES MODELES

A. RECUEIL DES DONNÉES

Seules les données issues des capteurs de mouvement IR et d'ouverture de porte sont exploitées ici. Le recueil des données est effectué dès changement d'état d'un capteur. Il alimente un fichier de données Domoticz au format .db. Ce fichier est envoyé quotidiennement sur le serveur sécurisé à partir duquel il peut être téléchargé et analysé. Le travail de requête, de restructuration et d'exploitation des données issues de notre base se fait en langage SQL. L'activité d'une pièce est quantifiée à la réception des données issues des capteurs de cette même pièce. Les données binaires reçues (« 1 » lorsque le capteur détecte un mouvement dans la pièce, immédiatement suivi d'un « 0 » pour signifier la fin de la détection) sont sommées sur des intervalles de 30 minutes. La somme des déclenchements décrit les périodes d'activité au sein d'une pièce pour une période de temps donnée. Les variations dans le signal de quantité de mouvement nous permettront par la suite de rechercher des patrons singuliers pouvant déterminer une décision de lancement d'alerte. Chaque lieu privatif est identifié par un numéro aléatoire et seulement connu des responsables scientifiques du projet.

B. PRÉPARATION DES DONNÉES

Nous avons en premier lieu procédé au pré-traitement des données issues des capteurs de mouvement et à leur uniformisation. On procède en deux étapes principales :

- L'uniformisation des pas de temps. Les détections de mouvements se faisant dès l'activation des capteurs, l'uniformisation nous permet de proposer des intervalles de temps réguliers et facilite le travail d'analyse par la suite. Pour ce faire, on considère des créneaux de 30 minutes. Pour chaque intervalle de temps, la valeur d'activité observée dans la pièce correspond à la somme des déclenchements du capteur de mouvement sur cet intervalle. Par exemple, le marqueur de temps 9h30 est associé aux relevés du capteur entre 9h et 9h30. Si le

capteur s'est déclenché 3 fois pendant ce temps, on associe au créneau 9h30 la valeur 3.

- La *data transformation* qui est l'étape de conversion des données dans un format adapté à leur traitement. En outre, nous intégrons ici le lissage des données ou réduction du bruit, qui se fait à travers le moyennage des données en appliquant notre modèle, et leur normalisation pour optimiser les temps de calcul en utilisant une échelle commune à toutes les données sans perdre d'informations sur la distribution générale. Nous appliquons une normalisation entre 0 et 1 à nos paramètres uniquement lors des phases de calcul avec des techniques de Machine Learning.

C. MODÈLES DE RÉFÉRENCE

L'observation du comportement se fait à travers l'analyse de modèles établis pour chacune des pièces de la MP chaque jour. Chaque modèle est construit dans le but de pouvoir détecter un comportement dit « anormal » en mettant en place différents niveaux de détection : le premier niveau permet, à l'aide de seuils calculés automatiquement, par exemple à partir d'un écart entre la valeur habituelle et la valeur mesurée à la tranche horaire instantanée, de mettre en avant des événements qui sortent des habitudes (ici nous avons retenu le nombre de déclenchements des capteurs de mouvement). Le second niveau considère les évolutions d'un modèle dynamique sur des périodes plus étendues et permet de rendre visible des changements progressifs.

Pour chaque jour j de récolte de données, le modèle est calculé comme la moyenne des observations sur la semaine précédente (jour j inclus) par tranche horaire. Cette technique reprend les principes de la moyenne glissante et vise à supprimer les fluctuations les moins significatives pour se focaliser sur les évolutions sur le long terme. Nous avons choisi d'utiliser une pondération qui donne plus de poids aux données des trois derniers jours observés par rapport aux quatre autres jours considérés dans la moyenne. Nous avons fait l'hypothèse que cela permettrait de garder après lissage, des patrons fortement corrélés avec l'observation des données les plus récentes, tout en débruitant le signal reçu.

On illustre dans les Figures 2a et 2b un exemple des deux niveaux de détection.

Il est très important de distinguer ces deux niveaux de détection. Le premier niveau nous permet d'étudier les changements forts et soudains qui ne durent pas dans le temps (Figure 2a) tandis que le deuxième niveau est plus attentif aux diminutions ou augmentations graduelles qui ne seront pas détectables par un seuil quantitatif car pas assez importantes pour alerter immédiatement ce qui

correspond à une modification lente du patron « habituel » (Figure 2b).

Le modèle dynamique est analysé selon sa forme et son évolution tandis que les données unifiées sont surveillées par des seuils mis en place selon l'activité moyenne observable dans une pièce.

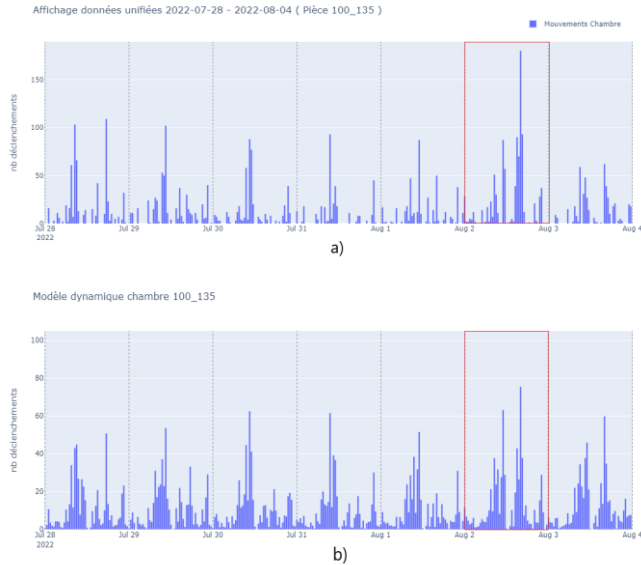


Figure 2. Observation d'un pic d'activité entre données relevées a) et modèle dynamique établi b) (Participante 135)

V. PRÉSENTATION DES RÉSULTATS

Pour illustrer les résultats obtenus, nous présentons pour exemple les résultats d'observation uniquement dans le cadre de trois chutes significatives survenues à la MP à différentes périodes et pour différentes habitantes. Nous nous intéressons dans un premier temps aux activités seules dans les pièces puis nous observerons les changements éventuels sur les modèles. Nous avons ensuite commencé à utiliser l'apprentissage non-supervisé pour extraire des patrons singuliers dans nos modèles représentatifs des chutes.

A. OBSERVATION DES COMPORTEMENTS D'ACTIVITES

Au cours de la période observée, 5 chutes ont été recensées concernant 4 habitantes de la maison.

Le profil de ces dernières est donné dans la Table 1. Il s'agit de 4 personnes autonomes (ADL=6 et IADL entre 7 et 8) ayant chuté au moins 1 fois. Cependant, nous présentons dans cet article, les observations de 3 chutes caractéristiques qui montrent des comportements différents selon les personnes lors de leur retour dans la MP, et selon le fait qu'elles ont été hospitalisées ou non.

TABLE 1 – Profil des participantes ayant subi une chute

ID Participant	Age/sexe	ADL	IADL	Durée de surveillance	Jours de chute
				Chambre	
135	96 ans/F	6	7	22/04/22 – 22/01/23	12/07/22 03/01/23
205	84 ans/F	6	8	22/04/22 – 05/12/23	13/11/22
232	91 ans/F	6	7	22/04/22 – 22/01/23	07/06/22
250	92 ans/F	6	8	22/04/22 – 22/01/23	16/05/22

B. OBSERVATION DES COMPORTEMENTS D'ACTIVITES

La Figure 3 montre un exemple de relevés de mouvements du capteur installé dans la chambre avant (3a) et après (3b) la chute de la participante de la pièce 135 le 3 Janvier 2023 dans la matinée (indiquée par une flèche rouge). Le nombre de déclenchement est plutôt faible habituellement. On détecte néanmoins une forte activité le lendemain après-midi qui s'explique par les visites nombreuses des autres participantes et des accompagnants de vie de la MP avec un retour à des activités plutôt habituelles.




Figure 3. Données unifiées avant a) et après b) la chute (Participante 135)

Dans le cas présenté dans la Figure 4, nous regardons un autre exemple de relevés de mouvements dans la chambre de la participante 250 autour de la date de chute relevée (16 mai 2022 dans la matinée). Il est ici difficile de notifier un changement en amplitude de l'activité. On précise aussi que la résidente était absente de la MP du 12 mai (soir) au 15 mai (soir) ce qui explique la forte concentration d'activité pour la matinée du 12 mai (préparation du départ : observable pour l'ensemble des résidents avant une absence de la MP sur plusieurs jours).




Figure 4. Données unifiées avant a) et après b) la chute (Participant 250)

Le troisième exemple est illustré dans la Figure 5. Il retrace l'activité de la participante 232 sur la période du 2 juin au 12 juin 2022 avec une chute recensée le 7 juin.

Nous constatons une nette augmentation du nombre de mouvements dans la matinée et dans la soirée après la chute là où l'activité était relativement faible avant l'évènement. Dans ce cas précis, un changement significatif est observable sur les données de comportement d'activité brutes.




Figure 5. Données unifiées avant a) et après b) la chute (Participant 232)

C. OBSERVATION DES COMPORTEMENTS DES MODELES

Nous rappelons qu'à travers l'observation du modèle dynamique, nous nous intéressons au changement de forme dans le temps du signal affiché.



Figure 6. Evolution du modèle dynamique (Participant 250), avant la chute (a), après la chute et avant hospitalisation (b), retour d'hospitalisation (c) et retour à la normale (d)

La Figure 6 représente le modèle dynamique de la participante qui a chuté dans la matinée du 16 mai 2022 (Figure 6b). Elle est ensuite restée à la MP durant une quinzaine de jours avant d'être hospitalisée le 3 juin 2022 en raison d'une fracture au bassin. Son retour à la MP s'est effectué le 20 juin 2022. Nous remarquons que les changements sur le modèle sont observables dès le lendemain de la chute à la fois au niveau de

l'intensité des mouvements (amplitude < 50%) et de la forme du signal anormalement irrégulière. On ne retrouve notamment pas la forte activité matinale qui était observable avant l'évènement. Cela peut indiquer une difficulté dans les déplacements. On observe également dans la chambre une activité peu intense et régulière l'après-midi qui n'était pas remarquée avant la chute de la résidente. Le modèle des journées suivant son retour à la MP (Figure 6c) montre une reprise d'une activité régulière mais différente d'avant la chute avec une intensité matinale moins élevée et étalée dans la journée.

Plusieurs jours après son retour, le modèle de comportement retrouve peu à peu des valeurs conformes à son comportement habituel avant chute tant en intensité que sur la signature du signal (Figure 6d).

La Figure 7 présente le modèle dynamique de la participante 135 où l'on observe le même pic d'activité que sur les données unifiées dans l'après-midi du lendemain de la chute. Nous pouvons voir également que l'activité pour la fin de matinée suivant la chute est moindre comparée à ce qui est observable sur les jours précédents et suivants. Hormis ces singularités, l'activité du modèle est semblable avant et après la chute avec les trois mêmes centres d'activité remarquables pour chaque jour (milieu/fin de matinée, milieu d'après-midi et milieu de soirée). Nous pouvons donc considérer que l'évènement n'a pas entraîné de gêne dans la mobilité de la participante et donc n'a pas eu de conséquences sur les habitudes de la participante ce qui a été attesté par le cahier d'observation qui indique de plus qu'il n'y a pas eu d'hospitalisation de la participante.



Figure 7. Modèle dynamique avant a) et après b) la chute (Participante 135)

La Figure 8 montre le modèle dynamique dans la chambre de la participante 232 avant et après la chute survenue dans la matinée du 7 juin 2022.

Nous observons immédiatement une forte augmentation de l'activité dans la pièce, en particulier deux pics le matin et le soir et parfois en milieu d'après-midi. La participante s'est cassé le poignet et a été prise en charge au moment de la chute (pas de départ prolongé de la MP). D'après le cahier d'observation, elle reçoit une aide extérieure au moment du lever et du coucher ce qui expliquerait l'augmentation de l'activité matinale et l'activité du soir. Cette nouvelle forte activité dans la chambre prend fin autour du 10 septembre. Nous n'avons pas connaissance de la date de fin d'accompagnement extérieur de la participante.

On remarque néanmoins que le taux d'activité visible sur la Figure 8c reste supérieur à ce qui était observable avant la chute. Aussi, dans le cas de cet évènement, les changements sont plus notables en termes d'amplitude qu'en terme de forme : en effet, les périodes où l'activité est concentrée dans la pièce avant et après la chute restent les mêmes.

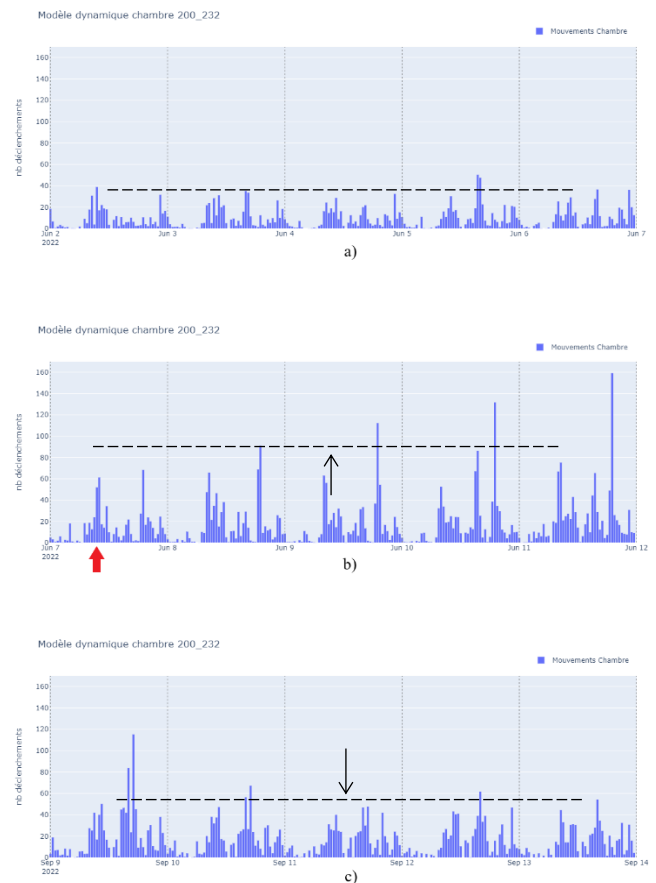


Figure 8. Evolution du modèle (Participante 232) avant la chute (a), après la chute (b) et retour à l'avant chute (c)

Le traitement des deux autres chutes survenues pendant la période de l'étude confirme également le fait que le suivi de l'évolution du modèle dynamique est beaucoup plus pertinent que le suivi des données journalières qui sont plus bruitées et plus sensibles par exemple à des événements extérieurs (activités de vie diverses dans la maison partagée...) et donc peuvent potentiellement causer des fausses détections.

D. CLASSIFICATION NON-SUPERVISÉE

Une autre phase de travail a été l'extraction de patrons singuliers dans nos modèles. Les techniques de classification utilisées reposent sur un apprentissage non-supervisé dans un premier temps, c'est-à-dire que nous ne disposons pas d'indicateur concernant le label réel des signaux étudiés. L'objectif de cet apprentissage est de classer les signaux journaliers des modèles associés à chacune des pièces dans différents groupes, afin de mettre en avant un ou des signaux présentant un patron différent du reste des observations. L'objectif visé à terme est d'intégrer la reconnaissance automatique de patrons dans le système pour pouvoir anticiper des événements à risque comme les chutes.

Il existe de nombreux algorithmes applicables pour le partitionnement non-supervisé [11]. Pour choisir, il est important de bien considérer les données en entrée. Dans notre cas, on travaille sur des signaux temporels et on cherche à mettre en avant les ressemblances de patrons et observer lesquels sont répétés ou exceptionnels.

Les méthodes de classification non-supervisée choisies ici sont le partitionnement en « k-means » et DBSCAN (« Density-Based Spatial Clustering of Applications with Noise »). Elles permettent respectivement de prendre en compte les décalages temporels entre les différents signaux (métrique « DTW (Dynamic Time Warping) » pour l'algorithme « k-means »), et de distinguer les endroits avec une forte densité d'observations de ceux moins denses, soit dans notre cas de discerner les clusters correspondant aux patrons habituels ou périodiques observables des clusters regroupant des signaux remarquables.

L'objectif de ce travail de classification sur le long terme serait de pouvoir superviser une partie de l'apprentissage à l'aide des annotations fournies par les accompagnants de la MP.

On présente dans la Figure 10 les résultats de la classification pour une des pièces de la MP et dans la Figure 11 la répartition en nombre des signaux au sein des 6 clusters établis.

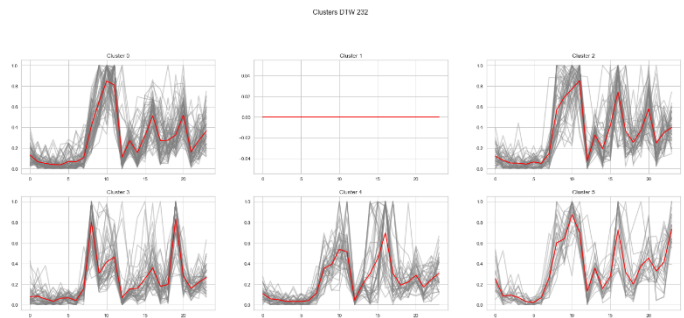


Figure 10. Classification de sous-séquences du modèle dynamique (Participant 232) (Algorithme K-Means métrique DTW)




Figure 11. Répartition en nombre des signaux au sein des 6 clusters établis (Participant 232)

Les signaux d'entrée sont les observations journalières du modèle dynamique dans la chambre 232 calculées sur des créneaux de 1h et non 30 minutes afin d'optimiser les coûts de calcul et de débruiter les signaux sans perdre d'informations. Ces signaux sont ensuite normalisés, c'est-à-dire que nous avons procédé à un ajustement des valeurs mesurées sur une échelle commune sans changer leur distribution.

Le nombre k de clusters est défini au préalable algorithmiquement selon la « méthode du coude » (*elbow method* en anglais) [12].

Les clusters 0, 2 et 5 (Figure 10) présentent des grandes similitudes : en rouge, les barycentres (moyenne des signaux partitionnés au sein d'un même cluster) ont la même forme. Le cluster 1 est caractéristique de l'absence d'activité du modèle sur les périodes où le résident n'est pas à la MP et/ou les capteurs de la pièce sont inactifs.

Au sein du cluster 3, nous retrouvons les signaux caractéristiques observables du modèle suite à la chute du 7 juin 2022 de la participante de la pièce. Les signaux classifiés dans ce cluster se suivent et correspondent à la période continue entre le 7 juin et le 21 juillet, à quelques exceptions près. Le dernier cluster 4 est atypique cependant les entrées associées à celui-ci ne se suivent pas dans le temps c'est-à-dire que l'on ne distingue pas de reproductibilité du signal sur plusieurs jours d'affilé.

D'après les résultats obtenus, nous pouvons dire que la fiabilité de la classification obtenue pour ces deux méthodes dépend

fortement de la régularité et la périodicité observables dans nos signaux d'entrée : plus ils sont réguliers, plus les groupes sont homogènes et donc plus l'interprétation semble pertinente.

Par la suite, on peut corrélérer les résultats obtenus après le partitionnement de données avec les informations partagées par les accompagnants vivant auprès des résidents. Deux cas posent un problème d'interprétation : A/ des patrons singuliers mis en avant par la classification correspondent effectivement à une période où l'habitant a modifié ses habitudes, dû à des difficultés de mobilité suite à un évènement, mais ils peuvent être confondus dans une classe avec des patrons que l'on peut qualifier de normaux (qui ne se traduisent pas en anomalies de comportement) ; B/ des formes singulières sont distribuées dans plusieurs groupes (i.e. on n'observe pas de signaux qui se suivent dans le temps au sein de nos classes) et par conséquent, l'interprétation et l'identification de forme est en échec.

VI. CONCLUSION ET PERSPECTIVES

Après le développement et la validation de l'infrastructure technologique en environnement contrôlé, nous l'avons déployée en environnement réel au sein d'une maison partagée par 12 résidents. Plusieurs capteurs ont été installés dont 2 capteurs de mouvement IR par pièce et 1 capteur de contact de porte. Cet article a pris pour objectif principal la détection de chutes. Les données recueillies sur 8 mois nous ont permis de modéliser le comportement habituel de chaque résident et de montrer des changements notables par l'évolution des modèles d'activité lors des chutes. La détection a été validée par les annotations du personnel d'accompagnement servant de standard, sur les jours et les créneaux horaires où sont intervenues les chutes.

Un travail en cours porte sur l'utilisation des algorithmes de classification non-supervisées K-means et DBSCAN à l'identification automatique des déviations en amplitude ou rythme chronologique pour prédire cette fois ci les risques d'évènements. Les capteurs utilisés remontent également les données de luminosité et de température que nous souhaitons également utiliser pour analyser les changements de comportements et renforcer cette prédiction.

L'étape suivante sera d'approfondir ce travail de validation de classification automatique par les annotations « terrains » et de développer un système autonome capable, à partir d'un apprentissage supervisé des habitudes de comportement d'un résident, de détecter les changements ou mieux, de les anticiper.

REMERCIEMENTS

Les auteurs expriment leur gratitude à l'association ASF pour le financement du matériel, aux habitants et accompagnants de la MP de Brens (81) pour leur participation au projet ainsi qu'au CHU de Toulouse pour le co-financement de l'étude.

REFERENCES

- [1] Argoud, D. 2014. Les nouvelles formes d'habitat pour personnes âgées : approche socio-historique d'une innovation. In Nowik, L., & Thalineau, A. (Eds.), *Vieillir chez soi : Les nouvelles formes du maintien à domicile*. Presses universitaires de Rennes. [https://doi :10.4000/books.pur.69153](https://doi.org/10.4000/books.pur.69153)
- [2] A. Labit. *Habiter et vieillir en citoyens actifs : regards croisés France-Suède*. La doc. Française, 65, 2013, p. 101-120
- [3] J.P Aquino, M. Bourquin, *Les innovations numériques et technologiques dans les établissements et services pour personnes âgées*. Rapport de la filière Silver économie, 2019.
- [4] M. Buso, J. Ancilotto. *La Maison Partagée: Association Ages Sans Frontières (TARN 81)*. *Pour*, 233, 103-108, 2018. <https://doi.org/10.3917/pour.233.0103>
- [5] D. Brulin, E. Campo, C. Lejeune, D. Estève. *Time slot modeling of life habits in the elderly for decision-making support*. *Intelligence Artificielle appliquée à l'E-Santé et à l'autonomie*, IRBM Journal 2020. Elsevier Juillet 2020. <https://doi.org/10.1016/j.irbm.2020.06.012>.
- [6] M. Diniz, V. Zalc, D. Istrate. *Cough sound recognition for COVID-19 risk detection*. *JETSAN 2021 - Colloque en Télésanté et dispositifs biomédicaux - 8ème édition*, Mai 2021, Toulouse, Blagnac, France.
- [7] N. Vigouroux, F. Vella, G. Lepage, E. Campo. *Usability study of tactile and voice interaction modes by people with disabilities for home automation controls*. *ICCHP-AAATE 2022. Lecture Notes in Computer Science, Computers Helping People with Special Needs*, vol 13342, pp. 139-147, Lecco, Italy, July 11-15, 2022, Springer, Cham. https://doi.org/10.1007/978-3-031-08645-8_17.
- [8] A. F. Ambrose, P. Geet Paul, J. M. Hausdorff. *Risk factors for falls among older adults: A review of the literature*. *Maturitas*, Vol. 75, Issue 1, 51-61, 2013, ISSN 0378-5122, <https://doi.org/10.1016/j.maturitas.2013.02.009>.
- [9] N. Vigouroux, F. Vella, D. Istrate, E. Campo, L. Caroux, N. Lompre, P. Gorce, J. Jacquier-Bret, N. Pinede, M. Sacher, A. Serpa, A. Van den Bossche, *Multimodal observation method of digital accessibility for elderly people*, *IRBM*, 42(3), 2021, p. 135-145.
- [10] P. Rumeau, N. Vigouroux, E. Campo, E. Bougeois, F. Vella, A. Van Den Bossche, T. Val, J. Ancilotto, *Technological Services in Shared Housing: Needs Elicitation Method from Home to Living Lab*, *IRBM*, 42(2), 2021, p. 73-82
- [11] D. Greene, P. Cunningham, R. Mayer. *Unsupervised Learning and Clustering*. In: Cord, M., Cunningham, P. (eds) *Machine Learning Techniques for Multimedia*. Cognitive Technologies. Springer, Berlin, Heidelberg. 2008. https://doi.org/10.1007/978-3-540-75171-7_3
- [12] D. Marutho, S. Hendra Handaka, E. Wijaya and Muljono, "The Determination of Cluster Number at k-Mean Using Elbow Method and Purity Evaluation on Headline News," *2018 International Seminar on Application for Technology of Information and Communication*, Semarang, Indonesia, 2018, pp. 533-538, doi: 10.1109/ISEMANTIC.2018.8549751.