



HAL
open science

Détection de changement de comportement de vie chez la personne âgée par images de profondeur

Soumaya Msaad

► **To cite this version:**

Soumaya Msaad. Détection de changement de comportement de vie chez la personne âgée par images de profondeur. Traitement du signal et de l'image [eess.SP]. Université de Rennes 1, 2022. Français. NNT: . tel-03815836v1

HAL Id: tel-03815836

<https://theses.hal.science/tel-03815836v1>

Submitted on 14 Oct 2022 (v1), last revised 9 Dec 2022 (v2)

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.

THÈSE DE DOCTORAT DE

L'UNIVERSITÉ DE RENNES 1

ÉCOLE DOCTORALE N° 601
*Mathématiques et Sciences et Technologies
de l'Information et de la Communication*
Spécialité : *Signal, Image, Vision*

Par

Soumaya M'SAAD

**Détection de changement de comportement de vie chez la personne âgée
par images de profondeur**

Thèse présentée et soutenue à Rennes, le 15/06/2022
Unité de recherche : LTSI UMR INSERM 1099

Rapporteurs avant soutenance :

Farah CHEHADE Maître de conférences, HDR, Université de Technologie de Troyes
Norbert NOURY Professeur, INSA Lyon

Composition du Jury :

Président :	François CHARPILLET	Directeur de Recherche INRIA, INRIA Nancy Grand-Est, Nancy
Examineurs :	François CHARPILLET	Directeur de Recherche INRIA, INRIA Nancy Grand-Est, Nancy
	Farah CHEHADE	Maître de conférences, HDR, Université de Technologie de Troyes
	Vincent GAUTHIER	Directeur de Neotec Vision, Pacé
	Norbert NOURY	Professeur, INSA Lyon
Dir. de thèse :	Guy CARRAULT	Professeur, Université Rennes 1
Co-dir. de thèse :	Jean-Louis DILLENSEGER	Maître de conférences, HDR, Université de Rennes 1

Table des matières

Glossaire	5
Liste des figures	6
Liste des tableaux	10
Introduction Générale	13
1. Un bref état de l'art pour la surveillance des personnes âgées.....	16
Introduction.....	16
1.1. Vieillessement de la population	16
1.1.1. Définition du vieillissement.....	16
1.1.2. Données démographiques	17
1.1.3. Profil de la personne âgée.....	18
1.2. Chute de la personne âgée	20
1.2.1. Facteurs de risque de la chute	20
1.2.2. Conséquences de la chute.....	21
1.2.3. Évaluation du risque de la chute.....	22
1.3. Solutions pour le maintien à domicile des personnes âgées	23
1.3.1. Habitat intelligent	24
1.3.2. Principaux capteurs utilisés pour la surveillance	26
1.3.2.1. Les capteurs portés	26
1.3.2.2. Les capteurs ambiants.....	27
1.3.2.3. Système de vision.....	28
1.4. Comportement de la personne âgée	29
1.4.1. Relation entre les activités et la santé	29
1.4.2. Routine de la personne âgée	30
1.4.3. Types de changement de comportement.....	31
1.4.4. Détection de changement de comportement	32
Conclusion	33
2. Le projet PRuDENCE	35
Introduction.....	35
2.1. Contexte du projet PRuDENCE	35
2.2. Bases de données	39
2.2.1. Base de données Gladis	39
2.2.2. Base de données Symh	41
2.3. Métriques d'évaluation	46

2.3.1.	Métriques d'évaluation d'un modèle à deux classes	46
2.3.2.	Métriques d'évaluation d'un modèle à plus de deux classes	48
	Conclusion	49
3.	Détection de la chute et suivi du comportement de la personne âgée	50
	Introduction.....	50
3.1.	Approche proposée.....	50
3.2.	Acquisition des images et extraction des paramètres	51
3.3.	Classification des images.....	52
3.4.	Implémentation de la méthode	54
3.4.1.	La base de données.....	54
3.4.2.	Classification des images.....	56
3.4.2.1.	Classification avec K-NN.....	56
3.4.2.2.	Classification avec arbre de décision	56
3.4.2.3.	Classification avec forêt aléatoire	57
3.4.2.4.	Comparaison des performances des classifieurs	57
3.4.3	Suivi de la personne	57
	Conclusion	58
4.	Détection des chutes, des postures et de l'absence de la personne.....	61
	Introduction.....	61
4.1.	Reconnaissance des postures et des activités	61
4.1.1.	Choix de la reconnaissance des postures pour définir une activité.....	61
4.1.2.	Caractéristiques d'un réseau de neurones à convolution	66
4.2.	Implémentation d'un réseau de neurones à convolution pour la reconnaissance des postures.....	73
4.2.1.	Augmentation des données	73
4.2.2	Résultats de la classification	74
4.2.2.1.	Implémentation retenue.....	74
4.2.2.2.	Résultats de la classification sur la base Gladis	76
4.2.2.3.	Résultats de la classification sur la base Symh	77
4.2.2.4.	Résultats de la classification sur la base totale (Gladis et Symh)	79
4.2.2.5.	Résultats de la classification sur la combinaison 1 des bases Gladis et Symh.....	80
4.2.2.6.	Résultats de la classification sur la combinaison 2 des bases Gladis et Symh.....	81
	Conclusion	83
5.	Détection du changement de comportement de la personne âgée	84

Introduction.....	84
5.1. Détection du changement de comportement au moyen de la distance d'édition.....	85
5.1.1. Définition de la journée routine.....	85
5.1.2. Acquisition et classification des images.....	87
5.1.3. L'algorithme de la distance d'édition.....	87
5.1.4. Application de M-DME à la détection du changement de comportement.....	88
5.2. Détection du changement de comportement au moyen de la déformation temporelle dynamique.....	93
5.2.1. L'algorithme de la déformation temporelle dynamique.....	94
5.2.2. Application de la M-DTW à la détection du changement de comportement.....	95
5.3. Détection du changement de comportement par classification de la nature de la journée	100
5.3.1. Auto-apprentissage des classes des jours.....	100
5.3.1.1. Autoapprentissage : cas la journée décrite par une succession des postures	101
5.3.1.2. Autoapprentissage : La journée décrite par les indices du jour.....	106
5.3.2. Classification du type de la journée par une approche supervisée.....	110
5.3.3. Détection du changement de comportement.....	110
5.3.4. Application à la détection du changement de comportement.....	110
5.3.4.1. Personne A.....	111
5.3.4.2. Personne B.....	112
5.4. Détection du changement de comportement par une approche heuristique.....	114
Conclusion.....	116
6. Détection du changement de comportement sur des données simulées.....	118
Introduction.....	118
6.1. Les bases de données pour construire des simulations réalistes.....	119
6.1.1. Définition de la journée routine par une enquête.....	119
6.1.2. La base de données Symh.....	120
6.2. Simulateur de la routine et des activités de la personne.....	122
6.2.1. Modèles de Markov.....	122
6.2.1.1. Chaîne de Markov.....	122
6.2.1.2. Modèles de Markov cachés.....	122
6.2.1.3. Modèles Semi-Markovien cachés.....	123
6.2.2. Simulation de dégradations par HSMM.....	124
6.2.3. Simulation des indices du jour.....	126
6.2.4. Exemples de simulations du changement de comportement.....	128

6.2.4.1.	Simulation du changement progressif	128
6.2.4.2.	Simulation du changement récurrent	129
6.2.4.3.	Simulation du changement brusque	130
6.2.4.4.	Simulation du changement graduel	131
6.2.4.5.	Simulation du maintien de la routine	132
6.3.	Comparaison des méthodes sur des populations à comportement homogène	133
	Conclusion	139
A.	Détection des changements de comportement : progressive, récurrent et brusque	140
A.1.	Comportement lors d'un changement progressif	140
A.2.	Comportement lors d'un changement récurrent	143
A.3.	Comportement lors d'un changement brusque	146
	Conclusion générale et perspectives	149
	Résumé et contributions	149
	Perspectives	151
	Bibliographie.....	154

Glossaire

ANR	Agence Nationale de la Recherche
APA	Allocation Personnalisée d'Autonomie
ASH	Aide Sociale à l'Hébergement
AVQ	Activités de la Vie Quotidienne
BRL	Binary Regression Logistic
DT	Decision Trees
DTW	Dynamic Time Warping
EDHMM	Explicit Duration-Hidden Markov Model
EHPAD	Etablissements d'Hébergement Pour Personnes Agées Dépendantes
FC	Fully connected layer
FN	False Negative
FP	False Positive
HMM	Modèle de Markov Cachés
INSEE	Institut National de la Statistique et des Etudes Economique
K-NN	K-Nearest Neighbors <i>K-NN</i>
LL2A	Living Lab ActivAgeing
LTSI	Laboratoire de Traitement du Signal et de l'Image
M-CNJ	Méthode Classification Nature de la Journée
M-DME	Méthode Distance Minimale d'Édition
M-DTW	Méthode Déformation Temporelle Dynamique
OMS	Organisation Mondiale de la Santé
PRuDENCE	PRévention Et DEtectionN des ChutEs
RF	Random Forest
TN	True Négative
TP	True Positive
UTT	de Technologie de Troyes
WP	Work Package

Liste des figures

Figure 1-1 : Pyramides des âges en France en 2013 et 2070 selon une étude INSEE [9].	17
Figure 1-2 : Différents profils de la personne âgée.	18
Figure 1-3: Test « Get up and Go ».	23
Figure 1-4 : Exemple «Habitat Intelligent pour la Santé », à la faculté de médecine de Grenoble. L’habitat est équipé de : capteurs volumétriques disséminés dans chacune des pièces, capteur qui enregistre le poids, capteurs pour mesurer la pression artérielles, pouls, taux d’oxygénation, la température, l’hygrométrie, la luminosité et le niveau sonore [80].	25
Figure 1-5 : Catégories de capteurs pour la détection des activités de la personne âgée ou de sa chute.	26
Figure 1-6: Différents types de changements. a: Brusque, b: Récurrent, c: Graduel, d: Progressif [135].	32
Figure 2-1 : Vue synthétique de la thèse pour la détection du changement de comportement de la personne et de la chute.	38
Figure 2-2 : Dispositif Gladis.	39
Figure 2-3 : Images de profondeur personne B (a : la personne est par terre. b : La personne est absente. c : La personne est assise. d : la personne est allongée).	40
Figure 2-4 : Effectif des postures des deux personnes A et B enregistrées dans leurs chambres d’EHPAD.	40
Figure 2-5 : Appartement d’acquisition de la base Symh.	42
Figure 2-6 : Caméra KINECT V1.	42
Figure 2-7 : Images de profondeur. a : La personne est debout. b : La personne chute. c : La personne est absente d : La personne est assise.	44
Figure 2-8 : Effectif des classes de l’étude de la base Gladis (personne B) et la base Symh.	45
Figure 2-9 : Effectif des classes de la base de données composées de la base Gladis de la personne B et la base Symh.	45
Figure 3-1 : Schéma de la détection de la chute et suivi du comportement de la personne.	50
Figure 3-2 : Exemples des régions contenant une personne détectée dans les images profondeur/thermiques fusionnées et reportées sur les images de profondeur : images de la personne assise au bord du lit (a et b), images de la personne au sol (c et d) et images de la personne allongée sur le lit (e et f).	52
Figure 3-3 : Exemple d’un K-NN pour classer le point vert.	53
Figure 3-4 : Exemple d’un arbre de décision.	53
Figure 3-5 : Boxplots des paramètres des images en fonction de la localisation de la personne.	55
Figure 3-6 : Nombre de chutes par jour pendant une période d’enregistrement de 37 jours.	58
Figure 3-7 : Évolution du pourcentage du temps passé au lit par jour pendant une période d’observation de 37 jours.	58
Figure 3-8 : Exemple d’erreur de sélection de région dans l’image de profondeur : la personne par terre n’est pas sélectionnée.	59
Figure 3-9 : Exemple d’erreur de sélection de région dans l’image de profondeur : les deux personnes présentes dans la chambre sont sélectionnées.	59
Figure 3-10 : Exemple d’erreur de sélection de région dans l’image de profondeur : La personne est occultée par les aides-soignants présents dans la pièce.	59

Figure 3-11 : Séparation en deux régions de la personne observée.	59
Figure 4-1: Exemples de squelettes de corps. De gauche à droite : debout, penché, assis, marche, et accroupi [170].	64
Figure 4-2 : les articulations 3D définissant le squelette [170].....	64
Figure 4-3 : Exemple de la reconnaissance de l'activité manger avec HMM [173].....	65
Figure 4-4 : Architecture d'un réseau de neurones à convolution.	67
Figure 4-5 : les opérations principales de la couche convolutive.	67
Figure 4-6 : Présentation de l'opération de la convolution [180].....	68
Figure 4-7: Exemple de max pooling.	69
Figure 4-8 : Exemple de flattening.	69
Figure 4-9 : Couche entièrement connectée (x_i entrée et s_i sortie).....	70
Figure 4-10: Processus d'un réseau CNN.	71
Figure 4-11 : Architecture ResNet-18.....	72
Figure 4-12: Schéma de la classification des postures.	73
Figure 4-13 : Exemple d'augmentation de donnée.....	74
Figure 4-14 : Effectif des classes des bases de données apprentissage et test de la base Gladis.	76
Figure 4-15 : Matrice de confusion (a), matrice de confusion normalisée (b).	76
Figure 4-16 : Effectif des classes des bases de données apprentissage et test de la base Symh.	77
Figure 4-17 : Matrice de confusion (a), matrice de confusion normalisée (b).	78
Figure 4-18 : Effectif des classes des bases de données apprentissage et test de la base totale (Gladis +Symh).....	79
Figure 4-19 : Matrice de confusion (a), matrice de confusion normalisée (b).	79
Figure 4-20 : Effectif des classes des bases de données apprentissage et test de la base de la combinaison 1 des bases Gladis et Symh.....	80
Figure 4-21 : Matrice de confusion (a), matrice de confusion normalisée (b).	81
Figure 4-22 : Effectif des classes des bases de données apprentissage et test de la base de la combinaison 2 des bases Gladis et Symh.....	82
Figure 4-23 : Matrice de confusion (a), matrice de confusion normalisée (b).	82
Figure 5-1 : Schéma de la détection du changement de comportement au moyen de la distance d'édition.	85
Figure 5-2 : Exemple d'application de l'algorithme DME pour aligner la séquence 1 à la séquence 2. 88	
Figure 5-3 : Annotations (assis en couleur bleu, allongé en couleur mauve, absent en couleur rouge, debout en couleur blanche et chute en jaune) des images de la personne A durant la journée (axe des ordonnées) pour une durée de 85 jours (axe des abscisses). La ligne verticale sur la droite correspond à la journée routine de la personne.	88
Figure 5-4 : Annotations (assis en couleur bleu, allongé en couleur mauve, absent en couleur rouge, debout en couleur blanche et chute en jaune) des images de la personne B durant la journée (axe des ordonnées) pour une durée de 85 jours (axe des abscisses). La ligne verticale sur la droite correspond à la journée routine de la personne.	89
Figure 5-5 : Annotation des images de la personne A et la distance d'édition entre la journée routine et chaque jour enregistré. La ligne continue représente la moyenne mobile des distances de M-DME par intervalles de 7 jours.....	90
Figure 5-6 : Annotation des images de la personne B et la distance d'édition entre la journée routine et chaque jour enregistré. La ligne continue représente la moyenne mobile des distances de la M-DME par intervalles de 7 jours.	90

Figure 5-7 : Annotations des images par jour de la personne B, résultats des distances de la M-DME par jour, évolution de la moyenne mobile des distances et les boxplots des valeurs des distances pour chaque groupe.	91
Figure 5-8 : Boxplots des groupes routine et non-routine des distances de la M-DME de la personne B.....	92
Figure 5-9 : Résultat du test CUSUM appliqué aux distances de la M-DME du jour 1 au jour 79 de la personne B.	93
Figure 5-10 : Schéma de la détection du changement de comportement au moyen de la déformation temporelle dynamique.....	93
Figure 5-11 : Illustration d'un exemple de DTW entre deux séries X et Y [197].....	95
Figure 5-12 : Annotations des images de la personne A et les résultats de la distance de de la déformation temporelle dynamique entre la journée routine et chaque jour enregistré. La ligne continue représente la moyenne mobile des distances DTW par intervalle de 7 jours.....	96
Figure 5-13 : Annotations des images de la personne B et les distance de de la déformation temporelle dynamique entre la journée routine et chaque jour enregistré. La ligne continue représente la moyenne mobile des distances DTW par intervalle de 7 jours.	97
Figure 5-14 : Annotations des images par jour, résultats des distances DTW par jour et les boxplots de la DTW pour chaque groupe.	98
Figure 5-15 : Boxplots des groupes routines et non-routines des distances DTW de la personne B....	99
Figure 5-16 : Résultat du test CUSUM appliqué aux distances DTW du jour 1 au jour 79 de la personne B.....	99
Figure 5-17 : Schéma de la détection du changement de comportement par classification de la nature de la journée.	100
Figure 5-18 : Evolution de la somme de toutes les dissimilarités entre les clusters en fonction du nombre des clusters K pour la personne A.	102
Figure 5-19 : Classification des jours de la personne A (classes 1, 2, 3 et 4).	102
Figure 5-20 : Évolution de la somme de toutes les dissimilarités entre les clusters en fonction du nombre des clusters K pour la personne B.	103
Figure 5-21 : Classification des jours de la personne B (classes 1, 2, 3 et 4).	104
Figure 5-22 : Annotations des images des jours enregistrés selon le type de classes (assis en couleur bleue, allongé en couleur mauve, absent en couleur rouge, debout en couleur blanche et chute en jaune).....	104
Figure 5-23 : Boxplots des pourcentages des images en position chute, assise, allongée, et absent par jour selon les classes des jours.....	105
Figure 5-24 : Evolution de l'inertie en fonction du nombre des classes K de la personne A.	106
Figure 5-25 : Classification des jours de la personne A selon le nombre des classes (1, 2, 3 et 4).	107
Figure 5-26 : Boxplots pour les 4 classes de jours (resp. 1 à 4) des indices : pourcentage en temps allongé, pourcentage en temps assis, pourcentage en temps debout et pourcentage en temps absent de la personne A.....	107
Figure 5-27 : Evolution de l'inertie en fonction du nombre des classes K.....	108
Figure 5-28 : Classification des jours de la personne B selon le nombre des classes (1,2 et 3).	109
Figure 5-29 : Évolution de l'indice BI issu de la classification par des forêts aléatoires (RF) et de la vérité terrain de la personne A.	111
Figure 5-30 : Évolution de l'indice BI issu de la classification des jours par RF de la personne B.	113
Figure 5-31 : Évolution de l'indice BI issu de la classification des jours par RF de la personne B.	114

Figure 5-32 : Évolution de l'indice BI issu des annotations et de la base de données résultant de la détection des postures de l'absence et de la chute de la personne A.	115
Figure 5-33 : Évolution de l'indice BI issu des annotations et de la base de données résultant de la détection des postures de l'absence et de la chute de la personne B.	116
Figure 6-1 : Graphe d'états d'une journée d'une personne âgée.....	119
Figure 6-2 : Exemple d'une chaîne de Markov à 3 états.....	122
Figure 6-3 : Exemple d'un HMM à trois états.	123
Figure 6-4 : Exemple d'un HSMM.	124
Figure 6-5 : Enchaînement des états dans un modèle semi-Markovien caché.	125
Figure 6-6 : Exemple d'un HSMM dans chaque état <i>Si</i>	125
Figure 6-7 : Modèle proposé pour la simulation des journées (routines et non-routines).....	126
Figure 6-8 : Les intervalles des indices routines IR (pourcentage en temps allongée, pourcentage en temps assise, pourcentage en temps debout, pourcentage en temps absente) qui résultent de l'enquête et des enregistrements de plusieurs journées d'un scénario d'une journée compressée d'une personne âgée par 4 personnes.....	126
Figure 6-9 : Schéma de simulation des jours et des indices du jour.	128
Figure 6-10 : Évolution du type du jour (0 non-routine et 1 routine) et les indices du jour pour un exemple d'un changement progressif.	129
Figure 6-11 : Évolution du type du jour (0 non-routine et 1 routine) et les indices du jour pour un exemple d'un changement récurrent.	130
Figure 6-12 : Évolution du type du jour (0 non-routine et 1 routine) et les indices du jour pour un exemple d'un changement brusque.	131
Figure 6-13 : Évolution du type du jour (0 non-routine et 1 routine) et les indices du jour pour un exemple d'un comportement routinier.	132
Figure 6-14 : Schéma de la création de la base de données qui décrit l'évolution de la simulation des jours par HSMM où les journées sont des scénarios compressés de la journée d'une personne âgée.	133
Figure 6-15 : Évolution du type du jour dans le cas du maintien de la routine.	134
Figure 6-16 : Évolution du type du jour dans le cas de la dégradation progressif de la routine.	134
Figure 6-17 : Évolution du type du jour dans le cas de la perte récurrente de la routine.....	134
Figure 6-18 : Évolution du type du jour dans le cas de la perte brusque de la routine.....	134
Figure 6-19 : Évolution du BI moyen par jour des 100 simulations pour chaque comportement (couleur rouge) et les barres d'erreur (couleur bleue).	135
Figure 6-20 : Évolution de la moyenne des pourcentages des distances minimales d'édition par jour des 100 simulations pour chaque comportement (couleur rouge) et les barres d'erreur (couleur bleue).	136
Figure 6-21 : Évolution de la moyenne des pourcentages des distances (Dynamic Time Warping) par jour des 100 simulations pour chaque comportement (couleur rouge) et les barres d'erreur (couleur bleue).	137
Figure A-1: Évolution du pourcentage DME et évolution de la moyenne mobile du pourcentage DME. Évolution du pourcentage DTW et évolution de la moyenne mobile du pourcentage DTW. Évolution BI de la simulation et des indices BI après classification des jours par l'algorithme K-moyenne et K-modes. Évolution BI de la simulation et de l'indice BI après classification par forêts aléatoires. Évolution BI de la méthode heuristique dans le cas de la simulation de la dégradation progressif... 140	

Figure A-2 : Boxplots du pourcentage des distances DME et DTW selon les groupes des jours (A, B et C).	141
Figure A-3 : Résultats du test CUSUM appliqué aux pourcentages des distances DME et DTW.	141
Figure A-4 : Évolution du pourcentage DME et évolution de la moyenne mobile du pourcentage DME. Évolution du pourcentage DTW et évolution de la moyenne mobile du pourcentage DTW. Évolution BI de la simulation et des indices BI après classification des jours par l’algorithme K-moyenne et K-modes. Évolution BI de la simulation et de l’indice BI après classification par forêts aléatoires. Évolution BI de la méthode heuristique dans le cas de la simulation d’un changement récurrent....	143
Figure A-5 : Boxplots du pourcentage du résultat des distances de l’algorithme DME et DTW des groupes des jours (A, B, C, D et E).	144
Figure A-6 : Résultats du test CUSUM appliqué aux pourcentages des distances DME et DTW pour détecter le premier changement du comportement récurrent.	144
Figure A-7 : Résultats du test CUSUM appliqué aux pourcentages des distances DME et DTW pour détecter le deuxième changement du comportement récurrent.	145
Figure A-8 : Évolution du pourcentage DME et évolution de la moyenne mobile du pourcentage DME. Évolution du pourcentage DTW et évolution de la moyenne mobile du pourcentage DTW. Évolution BI de la simulation et des indices BI après classification des jours par l’algorithme K-moyenne et K-modes. Évolution BI de la simulation et de l’indice BI après classification par forêts aléatoires. Évolution BI de la méthode heuristique dans le cas de la simulation de la simulation d’un changement brusque.	146
Figure A-9 : Boxplots du pourcentage des résultats des distances de l’algorithme DME et l’algorithme DTW des groupes des jours (A, B).	147
Figure A-10 : Résultats du test CUSUM appliqué aux pourcentages des distances DME et DTW dans le cas de la simulation d’un changement brusque.	147

Liste des tableaux

Tableau 1-1 : Échelle des préférences de routinisation [134].	31
Tableau 2-1 : Scénario d’une journée de référence compressée pour l’acquisition des images de la base Symh [152].	43
Tableau 2-2 : Matrice de confusion.	47
Tableau 2-3 : Matrice de confusion.	48
Tableau 2-4 : Précision et score F1.	49
Tableau 3-1 : Effectif de chaque classe par localisation.	55
Tableau 3-2 : Matrice de confusion avec la classification K-NN.	56
Tableau 3-3 : Matrice de confusion avec la classification DT.	56
Tableau 3-4 : Matrice de confusion avec la classification RF.....	57
Tableau 3-5 : Comparaison des résultats des prédictions.	57
Tableau 4-1 : Différents types d’activités.	62
Tableau 4-2 : Exemple des activités de la personne représentées par des postures.....	63
Tableau 4-3 : Description de l’architecture de ResNet-18 utilisé pour la classification (k est le nombre de classes).	75
Tableau 4-4 : Répartition des 2 bases de données sur les phases d’apprentissage et de test pour chaque expérimentation.	75

Tableau 4-5 : Métriques d'évaluation	77
Tableau 4-6 : Métriques d'évaluation.....	78
Tableau 4-7 : Métriques d'évaluation.....	80
Tableau 4-8 : Métriques d'évaluation	81
Tableau 4-9 : Métriques d'évaluation.....	82
Tableau 5-1 : Exemple d'une journée routine avec indication de la posture qui correspond à chaque activité.....	86
Tableau 5-2 : Résultats du test Wilcoxon.....	92
Tableau 5-3 : Exemple d'application de l'algorithme DTW pour aligner la séquence A à la séquence B.	95
Tableau 5-4 : Résultats du test de Wilcoxon.....	98
Tableau 5-5 : Intervalles des indices de la journée routine (de la méthode K-modes et de la vérité terrain).....	103
Tableau 5-6 : Intervalles de la journée routine de la personne B (de la méthode K-modes et de la vérité terrain).	106
Tableau 5-7 : Intervalles des indices de la journée routine de la personne A.	108
Tableau 5-8 : Intervalles de routine de la personne B (de la méthode K-moyennes et de la vérité terrain).....	109
Tableau 5-9 : Performances de classification du type de la journée de la personne A.	111
Tableau 5-10 : Performances de classification du type de la journée de la personne B après avoir classé les jours avec l'algorithme K-modes.....	112
Tableau 5-11 : Performances de classification du type de la journée de la personne B après avoir classé les jours avec l'algorithme K-moyennes.....	113
Tableau 6-1 : Résultats de l'enquête.....	120
Tableau 6-2 : Séquences enregistrées dans la chambre pour la journée routine et journée non-routine.....	121
Tableau 6-3 : Les intervalles de routines IR des distances d'édition, de la DTW et du BI (de la classification de la nature de la journée).	137
Tableau 6-4 : Instant de changement de référence pour différents changements de comportement.	138
Tableau 6-5: Les intervalles interquartile du retard à la détection du changement de comportement des trois méthodes (M-DME, M-DTW et M-CNJ).....	138
Tableau 6-6: Pente moyenne en valeur absolue pour 7 et 14 jours des pourcentages des distances minimale d'édition DME, des distances DTW et du BI pour différents changements	139
Tableau A-1 : Résultats du test Wilcoxon (pour les résultats des distances de M-DME couleur noire et pour les résultats des distances M-DTW couleur bleue) dans le cas d'un changement progressif. ...	141
Tableau A-2 : Résultats du test Wilcoxon (pour les résultats des distances de M-DME couleur noire et pour les résultats des distances M-DTW couleur bleue) dans le cas d'un changement récurrent.	144

Introduction Générale

Le nombre des personnes âgées ne cessent d'augmenter dans le monde, il continuera à augmenter pour doubler d'ici 2050 pour atteindre 2 milliards¹. Par exemple en France, le nombre des personnes âgées de plus de 75 ans est estimé à 12 millions en 2050 contre 6 millions en 2020 selon l'institut national de la démographie². Dans ce contexte, même si des structures spécialisées ont été créés pour accueillir les personnes âgées, il est primordial de trouver des solutions pour le maintien des personnes âgées à domicile, le plus longtemps et avec une meilleure autonomie.

Dans ce cadre, la personne âgée doit être surveillée pour détecter la chute et pour détecter la fragilité. En effet, la chute et la fragilité présentent de réels enjeux sociétaux. La chute est une des premières causes de mortalité de la personne âgée après les maladies spécifiques aux individus âgés de plus de 75 ans [1]. La fragilité est un état de la personne qui précède la dépendance et qui doit être identifiée pour que la personne bénéficie des interventions et des préventions spécifiques afin qu'elle retrouve son état robuste. La fragilité est mesurée dans un cadre clinique ou par la mesure d'un score des réponses de la personne à un questionnaire sur ses capacités motrices, sensorielles et cognitives³. Les tests cliniques réalisés par des professionnels de santé et les réponses aux questionnaires ne décrivent pas tous les détails de la vie quotidienne d'une personne. De plus, la personne âgée ne consulte pas au bon moment le médecin pour l'évaluation de la fragilité. Pour une meilleure précision, l'observation directe et quasi continue reste l'approche la plus fiable pour évaluer l'état de santé de la personne âgée dans son milieu de vie. Pour cela les maisons intelligentes ont été créées pour répondre à cette problématique. Les maisons intelligentes sont des lieux de vie qui sont équipées de capteurs qui retournent des informations des événements spécifiques (absence, sommeil, température...). L'analyse des données enregistrées par les capteurs est un moyen pour alerter le corps médical ou l'entourage de la personne dans le cas de la chute ou la perte des capacités fonctionnelles de la personne.

Chaque individu a tendance à suivre une routine. Cette routine a été démontrée chez les personnes âgées [2] et par conséquent, on peut imaginer que les capteurs d'une maison intelligente retournent des informations sur cette routine. Le changement de ce comportement routinier à long terme, peut être un indice de prévention de la fragilité de la personne et permettre ainsi d'éviter que son état de santé se dégrade vers l'état de la dépendance [3].

Dans le cadre de notre recherche, les choix de capteurs de profondeur et thermiques purement passifs, qui enregistrent la personne en préservant son anonymat et qui permettent un fonctionnement de jour comme de nuit ont été faits par la société NeoThec-Vision. Cette solution a fait l'objet d'un projet ANR (Agence Nationale de la Recherche) : PRuDENCE « PRévention Et DETection des ChutEs, ANR-16-CE19-0015-01 » qui a offert le cadre de cette thèse. Le projet a été mené en collaboration avec différents organismes, la société NeoTec-Vision qui est spécialiste dans la vision par

¹ <https://www.unfpa.org/sites/default/files/pub-pdf/UNFPA-Exec-Summary.pdf>

² <https://www.ined.fr/fr/tout-savoir-population/chiffres/france/evolutionpopulation/projections/>

³ La grille profil de risque de la fragilité : https://reseaux-sante-ca.org/IMG/pdf/2018_grille_sega_validee_.pdf, <http://www.sngie.org/wp-content/uploads/sites/28/2019/02/GRILLE-SEGA.pdf>

ordinateur (coordinateur du projet), le Laboratoire de Traitement du Signal et de l'Image (LTSI, INSERM-U1099), l'Université de Technologie de Troyes (UTT) et l'école d'ingénieurs généralistes ECAM Rennes - Louis de Broglie.

Objectifs scientifiques

L'objectif principal de la thèse était de proposer et de développer des méthodes, basées sur l'apprentissage automatique, le deep learning et la modélisation des données issues des capteurs des maisons intelligentes, pour détecter la fragilité et ainsi faciliter un meilleur vieillissement de la personne âgée et un maintien à domicile.

Plus spécifiquement, l'objectif global de la thèse est réalisé par la combinaison de plusieurs sous objectifs :

- **Détecter et modéliser les activités de vie de la personne âgée au sein d'un habitat intelligent** : le comportement quotidien de la personne est décrit par une succession des activités, la réalisation des activités explique le niveau d'autonomie de la personne. On a proposé une modélisation des activités quotidiennes de la personne par une succession des postures (assise, allongée, debout) avec indication des chutes et des absences. Ainsi, des images de profondeur, les postures, l'absence et la chute sont détectées. L'approche proposée par NeoThec-Vision associant Capteurs de profondeur et images thermiques permet de préserver l'anonymat de la personne (car on n'a pas la description de la journée par des activités mais par des postures avec indication de l'absence).
- **Détecter le comportement irrégulier de la personne** : Partant du postulat que la personne âgée a tendance à maintenir une routine bien définie sur une longue durée, le changement du maintien de la routine peut être un indice de la dégradation de la santé de la personne. Le suivi de la routine est réalisé à long terme, au contraire de la chute qui est un comportement irrégulier de la personne et qu'on cherche à détecter quotidiennement. Ainsi, la détection de la chute et de la perte de la routine permettrait d'anticiper la prise en charge de la personne âgée.

Organisation du travail de la thèse

La thèse est constituée de six chapitres.

Le chapitre I propose la définition du contexte du vieillissement, de la chute qui est une des conséquences de vieillissement, des différents comportements de la personne âgée et une présentation des maisons intelligentes pour la surveillance de l'aîné.

Le chapitre II présente le contexte du projet PRuDENCE de la thèse qui suit les travaux de trois précédentes thèses. Aussi on présente les bases de données qui résultent de nos propres enregistrements dans le cadre du projet par des capteurs de profondeur de deux personnes âgées dans la chambre d'un EHPAD et de quatre adultes (deux femmes et deux hommes) dans un

appartement à plusieurs pièces (salon, cuisine, salle de bain, couloir d'entrée et chambre à coucher). Enfin, on définit les différentes métriques choisies pour l'analyse de nos différents résultats.

Le chapitre III présente une contribution pour la détection de la chute et le suivi du comportement de la personne à partir des images de profondeur et thermiques enregistrées. Tout d'abord les images thermiques et de profondeur sont fusionnées pour cibler une région de la personne. De la région d'intérêt, des caractéristiques de la silhouette sont extraites. Enfin les images sont classées en comparant les résultats de trois classificateurs (K plus proche voisin, arbre de décision et forêts aléatoires) pour la détection de la chute par emplacement de la personne au sol.

Le chapitre IV représente la continuité du chapitre précédent mais envisage simultanément la détection de la chute, des postures (assise, allongée et debout) et de l'absence de la personne par une approche de deep-learning (réseau de neurones ResNet-18). La détection des postures et de l'absence sont nécessaires pour caractériser les activités, chaque activité est modélisée par une succession de postures avec indication de l'absence. De la même façon, la détection de la chute est nécessaire pour la prise en charge rapide de la personne.

Le chapitre V consiste en la proposition de trois stratégies pour le suivi de comportement :

- La première compare la journée routine (décrite par la succession des postures avec l'indication de l'absence et de la chute) avec chaque journée enregistrée, d'une part par l'algorithme de la distance d'édition, et d'autre part par l'algorithme de la déformation temporelle dynamique. L'évolution des pourcentages des distances représente l'indice de détection du changement de comportement proposé sur lequel est appliqué l'algorithme du CUSUM test.
- La deuxième stratégie consiste à classer la nature de la journée en routine ou non routine et de suivre l'évolution moyenne par période de la nature du jour. Cette évolution moyenne représente l'indice du changement de comportement. Les méthodes de classification du type de la journée par les méthodes non supervisées (K-modes et K-moyennes) et par les méthodes de classification supervisée (régression binaire logistique, arbre de décision et les forêts aléatoires) ont été développées à cet effet. Les premières (les non supervisées) permettent de ne faire aucune hypothèse sur les classes et peuvent servir de base pour alimenter les secondes.
- La troisième stratégie est plus heuristique et montre comment on peut répondre aux limites de la seconde stratégie lorsqu'on n'a pas observé de journées *non-routines*.

Le chapitre VI présente l'application des méthodes précédentes sur des données d'un simulateur qu'on a proposé et qui est proche de la réalité. Le contexte lié à la pandémie COVID-19 ne nous a pas permis d'installer les capteurs dans les lieux de vie des personnes âgées vivants seuls. Pour évaluer quantitativement nos performances, une alternative pour simuler différentes évolutions du comportement, reportée dans la littérature, en se basant sur un modèle de Markov est proposé. La routine est simulée en se basant sur les données d'une enquête, menée sur 7 personnes âgées qui nous ont renseignés sur leurs intervalles *routines*. Nous avons également exploité des images réelles de 4 personnes qui ont été enregistrés en reproduisant un scénario compressé d'une journée d'une personne âgée reporté également dans la littérature. Le modèle proposé simule aussi pour chaque journée les indices du jour (pourcentage en temps assise, allongée, debout, absente et nombre de chutes).

1. Un bref état de l'art pour la surveillance des personnes âgées

Introduction

Notre travail s'inscrit dans une problématique industrielle où certains choix étaient déjà définis avant la thèse. Ces choix ont alors contraint certaines de nos solutions. Toutefois, il nous a paru important de situer nos travaux en regard de ceux traités dans la littérature. L'objet de ce chapitre est, dans un premier temps, de présenter la population concernée par notre étude. En effet, il existe plusieurs définitions de la personne âgée. Parmi ces définitions, nous en avons dégagé une par rapport à la population concernée par l'étude. Nous nous sommes ensuite intéressés à la problématique de la chute et de sa surveillance. En effet, la surveillance de la chute de la personne âgée est un vrai enjeu de santé publique. Cette surveillance nécessite alors d'utiliser des solutions technologiques intégrées dans des habitations « intelligentes ». Un bref rappel des différentes solutions sera décrit dans ce chapitre. Notre ambition est cependant d'aller plus loin dans cette surveillance de chute en essayant de détecter le changement de comportement de la personne qui est un indice de la fragilité de la personne âgée. En effet, si l'on est capable d'estimer, par la surveillance, la dégradation de l'état de santé ou l'apparition d'une fragilité chez la personne âgée, nos travaux auront alors un aspect prédictif sur son état futur. Pour cela, le lien entre les activités quotidiennes des personnes et leur état de fragilité est décrit dans ce chapitre. Nous allons montrer que l'activité normale présente des routines et que des modifications dans ces routines sont des signes d'apparition de fragilité.

1.1. Vieillessement de la population

1.1.1. Définition du vieillissement

Le vieillissement est une étape naturelle de la vie. Néanmoins, l'âge du début du vieillissement n'a pas été formellement défini par les chercheurs. Ainsi, il existe près de deux cents définitions du vieillissement avec des âges de début de vieillissement différents, reflétant ainsi la complexité de cette notion.

Le vieillissement est un processus complexe, dynamique et évolutif. Il résulte de l'influence de quatre facteurs, que sont la génétique, les comportements de vie, les influences sociales et l'environnement. Selon chaque individu, ces facteurs interviennent d'une manière différente dans leur processus de vieillissement [4]. La population âgée est vaste et hétérogène. Elle regroupe des individus différents tant pour ce qui concerne leur état de santé que leur état fonctionnel. Par conséquent, l'impact du vieillissement est variable d'une personne à l'autre. C'est ainsi que les conséquences du vieillissement peuvent être absentes pour certaines personnes et importantes ou très importantes pour d'autres [4]. L'OMS a tenté de définir l'âge de début de vieillissement à 65 ans, et qualifie ce dernier comme étant un processus progressif dans le temps et irréversible, de modifications des structures et des fonctions de l'organisme [5]. Quant au secteur de la gériatrie, il fixe l'âge moyen de vieillissement à une moyenne de 85 ans [6]. Dans l'environnement social, une personne est considérée

comme étant une personne âgée quand elle atteint l'âge de la retraite, ce qui correspond à un âge moyen compris entre 55 et 65 ans selon l'activité exercée par l'individu.

1.1.2. Données démographiques

Le vieillissement de la population française évolue en fonction des années. Ainsi les personnes âgées d'au moins 65 ans représentaient 18.8% du total de la population en 2016, 19.2% en 2017, 19.7% en 2018, 20.1% en 2019 et 20.5% en 2020. Ceci pour une population de l'ordre de 67 Millions d'habitants (chiffre de 2018). Selon les projections de population établies par l'Institut National de la Statistique et des Etudes Economique (INSEE), la France compterait 76.5 millions d'habitants en 2070. La quasi-totalité de la hausse de la population d'ici 2070 (Figure 1-1) concernerait les personnes âgées de 65 ans et plus. La hausse serait particulièrement forte pour la catégorie de personnes de 75 ans et plus [7]⁴. La population française continue de vieillir sous le double effet de l'avancée des nombreuses générations du baby-boom (nées entre 1946 et 1975) et de l'augmentation de l'espérance de vie. En effet, les statistiques montrent sur les dix dernières années que l'espérance de vie a augmenté de 1,2 ans pour les femmes et 2 ans pour les hommes. La conséquence est alors que, selon INSEE [8], en 2050, plus du tiers de la population en France sera âgée de plus de 60 ans, contre un cinquième en 2000. Dans la population totale en France, la proportion des personnes de moins de 20 ans sera inférieure à la proportion de la population âgée de plus de 60 ans.

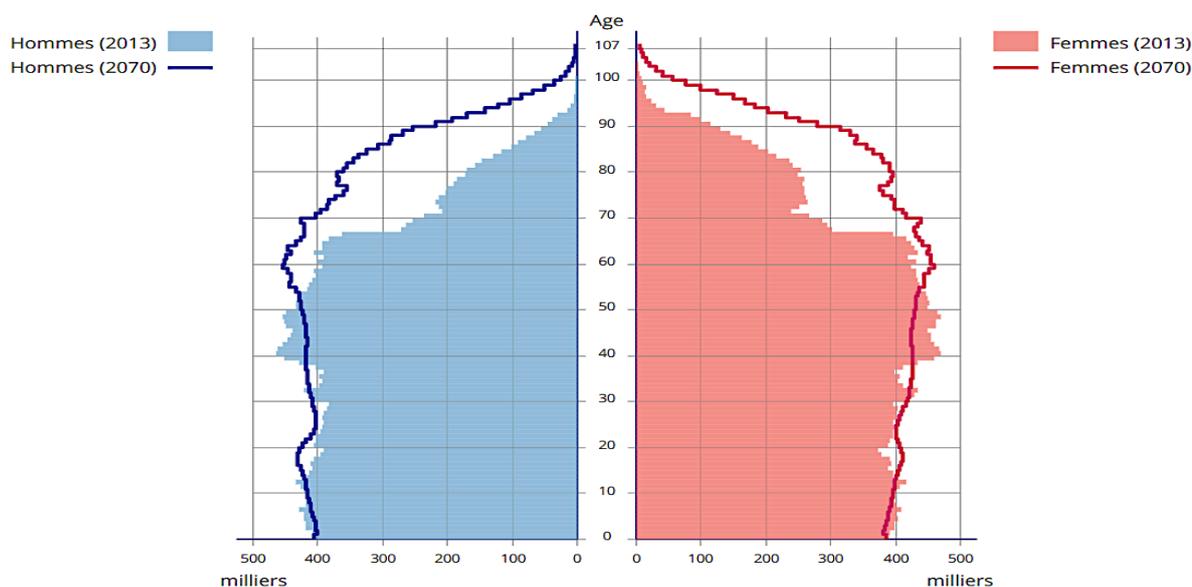


Figure 1-1 : Pyramides des âges en France en 2013 et 2070 selon une étude INSEE [9].

Le phénomène d'augmentation du nombre de personnes âgées est aussi observé dans le reste du monde [10]. La chute concomitante du taux de mortalité et du taux de natalité accélère la croissance de la proportion des personnes âgées. Selon le rapport de l'Organisations des Nations Unies

⁴ Les chiffres sont présentés sur les pyramides des âges (des années 2013 et 2070) publiés par l'INSEE [9] (Figure 1-1).

(ONU) [11], la population mondiale a augmenté de 48% entre 2000 et 2015⁵. Les prévisions tablent également sur une croissance qui se poursuit, avec des prévisions prévoyant 1,4 milliards de personnes âgées de plus de 65 ans en 2030 (+56% vs 2015) et 2.1 milliards en 2050 (soit presque le double comparé à 2015).

1.1.3. Profil de la personne âgée

Le processus du vieillissement n'est pas linéaire. Chaque individu âgé peut être classé dans l'un des trois profils dits robuste, fragile ou dépendant, en fonction de son état de santé, psychologique, social, de son environnement ainsi que de son activité socioprofessionnelle [12] (Figure 1-2).



Figure 1-2 : Différents profils de la personne âgée.

Une personne robuste est une personne qui a de bonnes performances physiques, avec une absence ou une atteinte très minime des fonctions physiologiques et une absence de pathologie. Il s'agit d'un individu complètement autonome et ne présentant aucune dépendance médicale et sociale.

Une personne fragile est une personne qui a subi une diminution des réserves physiologiques en-dessous d'un certain seuil de fonctionnalité [13]. Il existe plusieurs dimensions de la fragilité : sociale, physique, sensorielle, cognitive, nutritionnelle et fonctionnelle. De nombreux travaux ont été publiés concernant la détection de la fragilité [14]–[31]. À l'heure actuelle, deux modèles conceptuels font consensus et sont utilisés pour la détection de la fragilité :

1. Le modèle de Fried [14] : Fried a en particulier proposé un modèle fondé sur un phénotype « physique » qui évalue chez les personnes âgées de 65 ans ou plus la présence de cinq critères :
 - La perte de poids involontaire de plus de 4.5 kg (ou de plus de 5 % du poids) depuis 1 an ;
 - L'épuisement ressenti par le patient ;
 - La vitesse de marche ralentie, évaluée sur une distance de 4 mètres (seuil 0,8 m/s) ;
 - La baisse de la force musculaire ;
 - La sédentarité.

Les patients sont dits fragiles en présence d'au-moins trois des critères ci-dessus. Ils sont dits pré-fragiles si un ou deux critères sont présents. Si aucun critère n'est présent, ils sont considérés comme robustes.

⁵ D'après ONU, en 2015, la population mondiale comptait 901 millions de personnes de plus de 60 ans pour 1334 millions en 2000.

2. Le modèle de Rockwood [32]: Rockwood a proposé un autre modèle de fragilité multi-domaine intégrant cognition, humeur, motivation, motricité, équilibre, capacité pour les activités de la vie quotidienne, nutrition, conditions sociales et comorbidités. L'idée sous-jacente de Rockwood est de dire que « plus une personne a de déficits, plus elle est fragile ». Le nombre de déficits médico-psycho-sociaux à évaluer varie entre 20 et 70 rapportés par questionnaire. Le modèle de Rockwood calcule un index présenté comme un score entre 0 et 1, où 0 correspondant à aucun déficit et 1 à 100% des déficits.

L'état de fragilité est un état potentiellement réversible. Quand la fragilité est détectée, le corps médical propose des solutions pour tenter de faire basculer la personne de son état fragile vers l'état robuste [33]–[36]. Il s'agit donc d'une phase intermédiaire entre l'autonomie complète et la dépendance, en cas d'aggravation de l'état de santé [37].

Une personne dépendante est définie selon la loi du 24 janvier 1997 comme « L'état de la personne qui, nonobstant les soins qu'elle est susceptible de recevoir, a besoin d'être aidée pour l'accomplissement des actes essentiels de la vie ou requiert une surveillance régulière ». C'est une personne qui était auparavant fragile mais dont l'état de santé s'est dégradé, engendrant un besoin d'assistance ou d'aides afin d'accomplir les actes courants de la vie. Le nombre de personnes dépendantes tend à s'accroître avec l'âge et il est souvent irréversible [38]. Il existe également, par ailleurs, cette même double constatation avec les dimensions médicale et sociales de la dépendance. La commission de terminologie auprès du Secrétariat d'État des personnes âgées définit la dépendance suivant deux dimensions :

- 1- La dimension médicale : La situation d'une personne qui, en raison d'un déficit anatomique ou d'un trouble physiologique, ne peut remplir des fonctions ou effectuer des gestes essentiels à la vie quotidienne.
- 2- La dimension sociale : La subordination d'une personne à une autre personne ou à un groupe.

En France, les personnes dépendantes bénéficient de différentes aides sociales de l'État, comme les aides ménagères, l'aide sociale à l'hébergement (ASH) ou l'allocation personnalisée d'autonomie (APA).

Parmi ces trois profils, la personne âgée fragile est celle qui présente un intérêt particulier pour le travail réalisé dans ce mémoire. En particulier, le passage de la personne de l'état robuste à l'état fragile sera décrit par un changement de comportements qu'il sera possible de détecter. L'objectif visé étant qu'une détection précoce de la fragilité doit permettre d'intervenir en amont pour aider la personne à rester robuste et le cas échéant redevenir robuste, en lui apportant l'aide nécessaire après avoir ciblé la cause de sa fragilisation.

1.2. Chute de la personne âgée

Selon l'OMS, la chute est la deuxième cause de décès accidentels [39], avec 2 à 3 chutes par personne et par an qui sont comptabilisées dans les maisons de retraite [40]. C'est la raison pour laquelle les chutes des personnes âgées doivent faire l'objet d'une surveillance particulière. Ce contrôle accru doit s'exercer au niveau de la prévention et la détection des chutes. La prévention consisterait à analyser l'évolution de l'activité de la personne pour détecter les signes de fragilité.

Succinctement, 55% des chutes se produisent dans le logement, 22% loin du domicile, et 23% près du logement [41]. Gilles et al. [42] ont suivi, durant 3 ans, 1088 personnes vivant dans des logements sans escaliers. Leur étude a conclu que 10% des chutes se produisent dans les couloirs, 13% dans les salles de bains et/ou toilettes, 19% dans les cuisines, 30% dans les chambres à coucher et 31% dans les salles de séjour.

Les causes de la chute sont variées. Zecevic et al. [43] ont réalisé une enquête téléphonique sur 477 personnes âgées et 31 professionnels de santé ayant pour objectif de définir la chute et ses causes. Les personnes âgées ont exprimé que les causes des chutes étaient liées à l'équilibre, le climat (gel, ...), l'attention, les obstacles et les conditions médicales. Les réponses des professionnels de santé ont confirmé celles des personnes âgées. Les résultats de l'enquête montrent, comme on pouvait s'y attendre, que la chute est causée par différents facteurs.

La détection de la chute permet de secourir rapidement la personne afin de limiter au maximum les conséquences de cette chute. Il a en effet été montré que le temps passé au sol suite à une chute influe sur les conséquences dommageables qui peuvent conduire même au décès [44].

1.2.1. Facteurs de risque de la chute

Les facteurs de risque sont intrinsèques ou extrinsèques : Les facteurs de risque intrinsèques comprennent l'âge, les maladies (vertiges, démence et dépression) et la condition physique (équilibre, force musculaire, cognition et vision). Ils sont liés directement au vieillissement de la personne. Les facteurs extrinsèques comprennent entre-autres la prise de médicaments, le domicile (les marches d'escaliers, le sol glissant, le manque d'équipement, etc.) et les chaussures. Ces derniers facteurs sont liés à l'environnement de la personne âgée.

Ces différents facteurs intrinsèques et extrinsèques méritent d'être précisés :

- L'âge : l'âge est l'un des principaux facteurs qui explique la chute. Selon Bergen et al. [45], les personnes âgées sont susceptibles de chuter lors de la réalisation de leurs activités quotidiennes. Les résultats de leur enquête réalisée aux États-Unis en 2014 montrent que 28% des personnes âgées ont déclaré avoir eu au moins une chute au cours des 12 mois précédents. Fuller [46] indique dans ses travaux que le nombre de chutes augmente progressivement avec l'âge pour les deux sexes.
- L'équilibre : l'équilibre est aussi considéré comme un facteur de risque important de la chute. Chez la personne âgée la diminution des entrées sensorielles, combinée à une perte musculaire (nommée sarcopénie) [47], [31] et à des régressions neurologiques entraînent des perturbations de l'équilibre [49].

- La marche : Les capacités motrices tendent à diminuer avec l'âge [50]. L'étude de O'Loughlin [51] indique que 60% des chutes ont lieu le plus souvent dans l'espace de vie de la personne et surviennent surtout pendant la réalisation des Activités de la Vie Quotidiennes AVQ telles que la marche. Ainsi, 29% des chutes ont comme origine une glissade et 26% un trébuchement [50].
- La vision : La vision est essentielle pour le contrôle de l'équilibre et pour éviter les obstacles. Une bonne vision permet d'estimer avec précision la distance par rapport aux informations spatiales. La vision est une fonction importante pour planifier les déplacements, adapter la posture et s'orienter dans l'espace [52].
- La cognition : Les déficiences cognitives peuvent être le résultat d'atteintes neurologiques diverses. La marche est associée à la fonction exécutive, qui fait référence aux processus cognitifs supérieurs. Ces processus utilisent et modifient les informations provenant de nombreux systèmes sensoriels. Avec le vieillissement, la fonction exécutive se détériore et la capacité à effectuer des tâches diverses diminue [52], [36].
- Les médicaments : liés aux problèmes inhérents de santé, les aînés ont tendance à prendre de plus en plus des médicaments. Tinetti et al. [54] montrent que la poly médication peut augmenter le risque de chute. Les effets indésirables des médicaments, comme les étourdissements, l'incoordination musculaire et la somnolence, peuvent affecter directement l'équilibre et ainsi augmenter le risque de chute.
- La dépression : La dépression est la baisse du tonus neuropsychique associée à un sentiment de tristesse et à une réduction psychomotrice. Elle est aussi considérée comme un facteur de risque de la chute [55], [39].
- L'environnement : L'espace de vie de la personne peut contribuer à la chute : les obstacles, les encombrements, le sol glissant, l'absence d'appuis de sécurité, etc. Une évaluation du logement doit être menée pour étudier la sécurité de l'individu [57].
- Les maladies cardiovasculaires : L'hypotension touche 30 % des personnes âgées de plus de 65 ans et, surtout, 70 % des personnes vivant en maison de retraite [58]. Hausdorff et al. [59] ont montré qu'il existe un lien entre la pression artérielle et le risque de chute. Concernant la fibrillation auriculaire, Sanders et al. [60] ont réalisé des expériences sur 442 patients âgés de plus de 65 ans et ils ont analysé les risques accidentels et non accidentels de la chute. Ils ont trouvé une prévalence plus élevée de chutes non accidentelles chez les patients souffrant de fibrillation auriculaire.

1.2.2. Conséquences de la chute

Les chutes peuvent avoir des conséquences physiques, sociales, psychologiques, financières et médicales importantes, ainsi que des conséquences sur les coûts de santé. La

chute provoque des traumatismes physiques de degrés différents [61], souvent classés en trois catégories :

- Les traumatismes mineurs qui apparaissent au niveau de la peau tels que les hématomes sous cutanés ou les légères écorchures de la peau.
- Les traumatismes modérés correspondant à des fractures (des côtes ou/et des vertèbres) avec des symptômes légers et une douleur modérée.
- Les traumatismes sévères correspondant aux fractures fémorales, des hématomes cérébraux, des hématomes extra ou sous-duraux, des traumatismes crâniens et des déchirures cutanées de grande taille ou/et profondes. Cette catégorie de traumatismes conduit constamment à une hospitalisation et met en jeu le pronostic vital des personnes.

Des études ont montré que les conséquences de la chute s'aggravent avec le temps passé au sol, pouvant mener parfois au décès de la personne [62]–[64].

Une personne âgée peut développer, à la suite d'une chute, des complications psychologiques et créer une anxiété majeure. En effet, la personne perd confiance en elle, car elle est consciente de sa fragilité. Elle a peur de monter les escaliers, d'aborder le vide, et peut aller jusqu'à refuser de se verticaliser. L'anxiété et la peur de tomber contribuent à l'apparition d'un état dépressif [65] et l'évolution vers la perte de l'autonomie et l'indépendance.

Après une chute, la personne ayant besoin de soins permanents constitue un coût pour la société. Par exemple, les coûts directs des blessures liées aux chutes représentent à eux seuls 0,1 % de toutes les dépenses de santé aux États-Unis et jusqu'à 1,5 % des dépenses de santé dans les pays européens [66].

1.2.3. Évaluation du risque de la chute

Pour minimiser les conséquences de la chute, il existe des solutions pour évaluer le risque des chutes afin de les prévenir. Dans leurs cabinets, les médecins évaluent le risque de la chute par la réalisation de deux tests simples : Le test de Tinetti et le test « Get up and Go »

- Le test de Tinetti [67] évalue l'équilibre (en 9 items) et la marche (en 7 items). La durée du test est d'environ de 5 à 10 minutes. L'équilibre est évalué en combinant les passages de la position assise, se lever du sol, se lever d'un fauteuil, l'équilibre en rotation de 360°, en position debout, les yeux fermés, lors d'une poussée, et lorsque la personne s'assoit. Le score d'équilibre est noté sur 16. La seconde partie, notée sur 12, consiste à analyser et évaluer la marche. La somme des deux évaluations donne un score total qui est comparée au seuil du test de Tinetti (si le score total est inférieur à 20 alors le risque de chute est élevé).
- Le test « Get up and Go » [68] : durant ce test, la personne doit se lever de la chaise, marcher 3 mètres puis faire demi-tour et revenir s'asseoir en faisant le tour de sa

chaise (Figure 1-3). Le temps pour réaliser le test est chronométré, s'il est supérieur à 20 secondes alors le sujet présente un risque de chute accru.

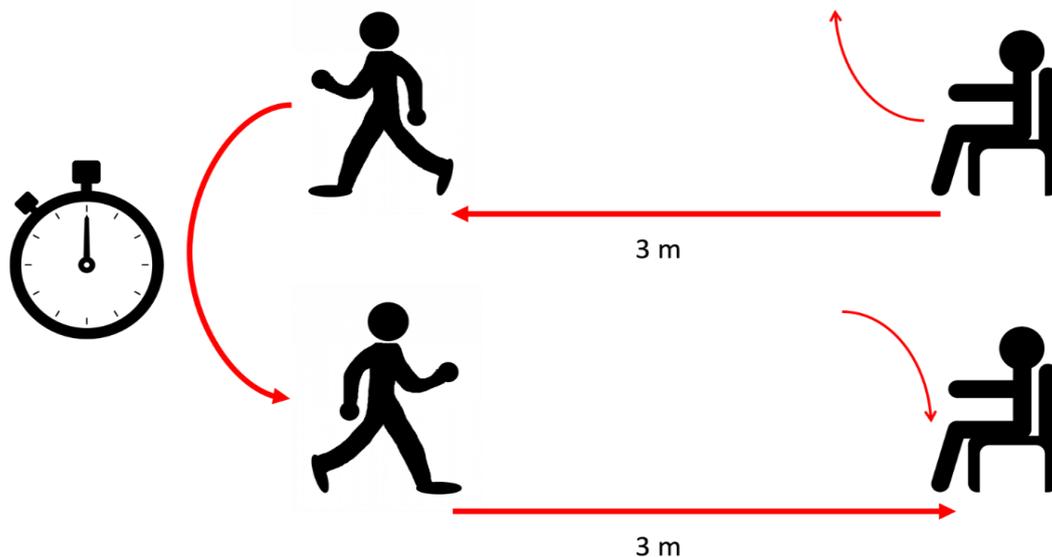


Figure 1-3: Test « Get up and Go ».

L'évaluation du risque des chutes peut être aussi étudiée en suivant le comportement de la personne dans son environnement. Ceci se traduit par le suivi de la routine de la personne. Par exemple, une diminution ou une absence de réalisation des activités de la vie quotidienne est un signe de fragilité et semble exposer la personne à la chute [69], [70]. Plusieurs systèmes de suivi de l'activité de la personne, de la prévention et de la détection de la chute sont détaillés dans la section qui suit. Les systèmes existants sont nécessaires pour envoyer des alarmes en cas d'urgence, secourir rapidement la personne, préserver le maintien de l'autonomie et augmenter ainsi les chances de survie.

1.3. Solutions pour le maintien à domicile des personnes âgées

Il devient primordial de disposer d'infrastructures adéquates pour veiller sur les personnes âgées qui font partie de la population davantage impactée par les chutes accidentelles. Malheureusement, le nombre d'hébergements disponibles dans les établissements pour les seniors n'est pas adapté à l'évolution rapide du nombre de personnes âgées sollicitant ce type d'hébergement. Pour résoudre ce problème, le maintien à domicile de la personne âgée semble être la solution privilégiée. Dans un contexte de recherche sur l'amélioration des conditions de vie, il conviendrait donc d'adapter les domiciles afin de permettre à la personne âgée de rester le plus longtemps possible dans son logement tout en lui offrant un maximum d'autonomie. Il s'agira donc de surveiller son état de santé via la détection d'une chute ou d'un accident cardio-vasculaire, via la détection de la fragilité, etc. L'installation de moyens technologiques pourra être d'une aide significative dans l'accomplissement des actes de la vie courante. Ces solutions sont souvent proposées dans les maisons intelligentes.

1.3.1. Habitat intelligent

Pour différentes et nombreuses raisons, les séniors préfèrent vieillir à domicile plutôt que dans des maisons de retraite. Selon l'INSEE, 83% d'entre eux préfèrent le maintien à domicile. La maison intelligente est une solution alternative intéressante, parmi les solutions proposées pour maintenir les personnes âgées à leur domicile le plus longtemps. Cette maison est aménagée de manière qu'elle soit adaptée aux besoins des personnes âgées pour le plus de confort possible, pour économiser de l'énergie, pour une sécurité optimale et /ou pour un suivi de leur santé.

Une maison intelligente ou smart home [71], [72] est un espace équipé de différents capteurs (de température, d'humidité, de son, au sol, etc.) permettant d'avoir des informations sur l'activité au sein de l'environnement équipé. Les données enregistrées par les capteurs sont traitées pour différents objectifs (détecter la chute, assurer la sécurité, économiser l'énergie, favoriser l'accessibilité et le maintien à domicile des seniors, etc.).

Des dispositifs technologiques ont été installés dans les lieux de vie des personnes âgées pour détecter la chute [73], déclencher l'alarme en cas de feu ou sécuriser le logement [74], allumer automatiquement la lumière dès la détection de la présence d'une personne, et aussi extraire des indices comme la vitesse de marche, la durée du sommeil, la fréquence d'utilisation des appareils électriques [75], etc.

La majorité des travaux publiés sur les maisons intelligentes est basée sur les habitats à un seul résident. Ces travaux montrent les limites de la détection des activités de plusieurs résidents dans le même espace de vie et il est difficile de discerner la diversité des activités humaines [76].

Plusieurs projets pour le suivi de la personne ont été réalisés en utilisant le principe de chambre ou habitat intelligent pour déclencher des alarmes en cas de comportement anormal.

Steenkeste et al. [77] ont réalisé le projet GARDIEN (Gérontologie Assistée par la Recherche et le Diagnostic des Incidents et des Errances Nocturnes) pour le suivi des patients Alzheimer en chambre intelligente. La chambre du patient est équipée de capteurs infrarouges passifs, qui détectent les mouvements de la personne dans des zones stratégiques (l'espace autour du lit, la porte de la chambre, et les toilettes). Les données enregistrées sont transmises à un ordinateur distant et traitées par des approches d'intelligence artificielle. Cette recherche a permis de mettre en évidence la possibilité de :

- i) alerter en cas de fugue ou de chute du résident ;
- ii) évaluer les effets des traitements médicamenteux sur le comportement moteur du patient ;
- iii) proposer une aide au diagnostic, grâce à l'étude du comportement et la détection des premiers symptômes d'une maladie.

Noury et al. [78] ont conduit le projet AILISA qui consiste à la réalisation des plateformes d'évaluations pour des technologies de télésurveillance médicale et d'assistance en gérontologie. Les plateformes sont équipées de différents capteurs comme un pèse-personne, des détecteurs

volumétriques infrarouges, d'un tensiomètre au poignet et d'un oxymètre de pouls. Le projet a pour objectif le maintien de la personne âgée en situation de dépendance. Il propose aussi de créer et de pérenniser des lieux de validation qui permettront d'accumuler l'expérience et d'augmenter la connaissance en toute sécurité. Le même groupe a également présenté un exemple de maison intelligente conçue par Noury et al. [79] au sein de la faculté de médecine de Grenoble Figure 1-4 [80]. La maison intelligente, dite « Habitat Intelligent pour la Santé », est câblée à un réseau domotique de type CAN, sur lequel sont connectés les capteurs. Les données récoltées sont transmises et traitées par un système d'information reposant sur les technologies du WEB et de JAVA.

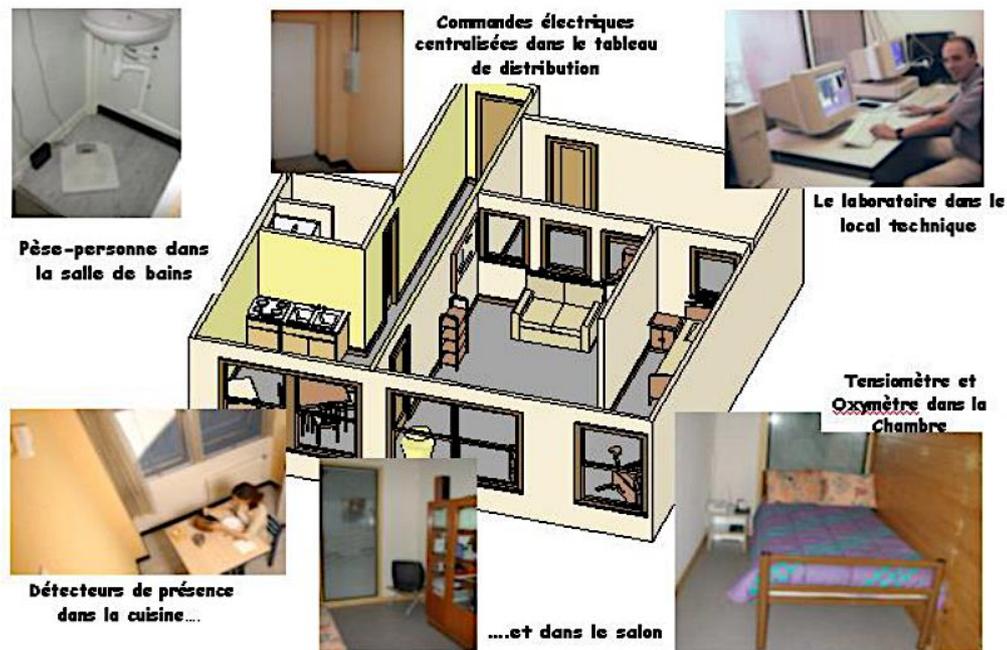


Figure 1-4 : Exemple "Habitat Intelligent pour la Santé", à la faculté de médecine de Grenoble. L'habitat est équipé de : capteurs volumétriques disséminés dans chacune des pièces, capteur qui enregistre le poids, capteurs pour mesurer la pression artérielle, pouls, taux d'oxygénation, la température, l'hygrométrie, la luminosité et le niveau sonore [80].

Ainsi, les maisons connectées rendent la vie plus facile à la personne âgée. En effet, avec le problème de la perte d'autonomie, il devient de plus en plus difficile pour le senior de s'occuper tout seul de la maison et de réaliser des tâches quotidiennes qui deviennent de plus en plus dures. Basé sur la reconnaissance du comportement de la personne, l'habitat intelligent s'adapte aux besoins et aux préférences de l'utilisateur. La maison peut par exemple allumer automatiquement la télévision pour regarder les informations, enclencher le chauffage et le réguler de façon autonome en prenant en compte l'historique de l'utilisation de la personne, allumer les lumières lorsqu'une présence est détectée dans la pièce, ouvrir automatiquement les stores lorsqu'on se lève le matin, ouvrir à distance la porte aux visiteurs, préparer automatiquement le café au réveil, déclencher une alarme pour le rappel des rendez-vous programmés... En synthèse, elles sont constituées de plusieurs automatismes qui peuvent rendre la vie quotidienne plus facile et agréable aux seniors.

1.3.2. Principaux capteurs utilisés pour la surveillance

Les capteurs jouent un rôle clé pour l'automatisation de l'habitat intelligent et également pour la surveillance de la personne âgée. Pour cette dernière tâche, il existe différents capteurs qui sont soit installés dans la maison intelligente, soit portés par la personne âgée. Ces capteurs permettent de recueillir les informations nécessaires avec un certain niveau de précision. En particulier, trois grandes catégories de capteurs peuvent être identifiées : les capteurs portés, les capteurs ambiants et les capteurs basés sur la vision (Figure 1-5).

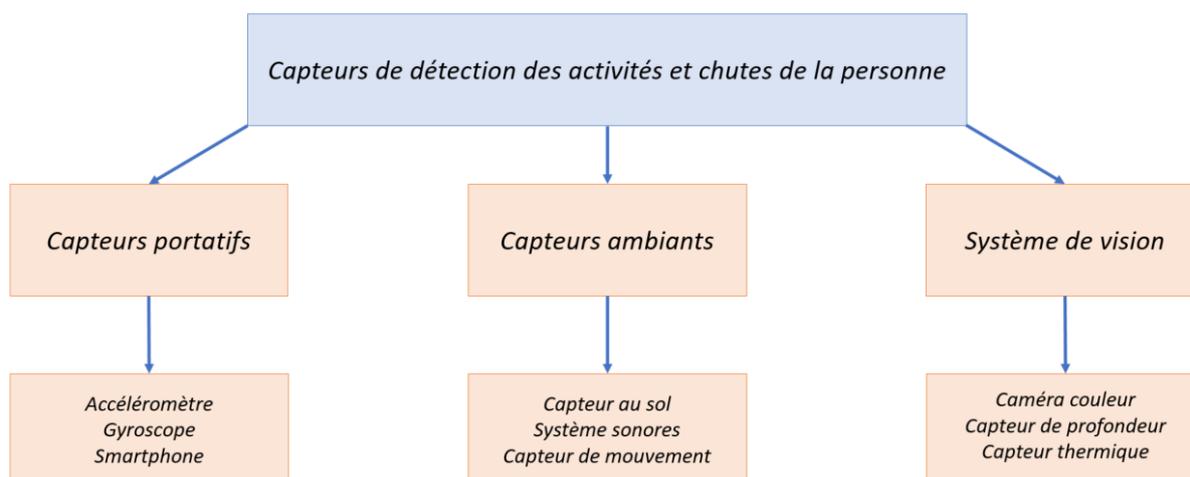


Figure 1-5 : Catégories de capteurs pour la détection des activités de la personne âgée ou de sa chute.

1.3.2.1. Les capteurs portés

Un capteur porté est un dispositif électronique placé sur la personne, par exemple comme au poignet, à la poitrine, au niveau de la taille ou sur la jambe. Un tel capteur est individualisé et permet d'éviter de confondre les personnes qui sont situées dans un même espace. Au début, de tels capteurs ont été utilisés pour le suivi de la température [81], ainsi que la tension de la personne [82], [83]. Plus récemment ces capteurs ont été perfectionnés par l'intégration d'un accéléromètre et/ou d'un gyroscope. Les accéléromètres sont parmi les capteurs portés les plus utilisés, ils permettent de fournir des indications sur la marche [84]–[86], de détecter les postures [87]–[89] et les chutes [90]–[95]. Cette avancée de l'utilisation d'accéléromètres vient de l'amélioration de la technologie des smartphones. Dans certains cas, le smartphone peut même remplacer le capteur. Ainsi, Dai et al. [96] ont été les premiers à utiliser un téléphone pour la détection de la chute.

En utilisant un accéléromètre triaxial, Bourke et al. [84] ont évalué une méthode pour détecter les chutes et déterminer le meilleur emplacement du capteur. Ils ont évalué leur méthode en plaçant le capteur sur la cuisse et sur le buste de 20 personnes d'âges différents (10 personnes âgées et 10 autres plus jeunes). Les personnes ont simulé des chutes suivant quatre directions : à gauche, à droite, en avant et en arrière. Les résultats ont montré que l'emplacement de l'accéléromètre sur la poitrine donne une meilleure détection de la chute.

Kangas et al. [97] ont également évalué le meilleur emplacement du capteur en comparant différentes positions (poignet, tête et autour de la taille) pour les mêmes types de chutes proposées dans la recherche [84]. Ils obtiennent de meilleurs résultats lorsque l'accéléromètre est placé sur la tête. Malheureusement cet emplacement n'est pas accepté par la majorité des personnes âgées.

Afin d'augmenter la précision d'un modèle, il est possible de combiner l'accéléromètre et le gyroscope [98]. Le gyroscope permet de calculer la vitesse angulaire avec comme conséquence, une meilleure précision pour la détection des postures.

L'inconvénient de ces capteurs est que la personne doit le porter en continu. Le deuxième inconvénient est qu'ils fonctionnent avec des piles ou des batteries et qu'il convient de les recharger. Des études ont montré que les personnes âgées ont une préférence pour les capteurs non portés [99].

1.3.2.2. Les capteurs ambiants

Cette catégorie de capteurs fonctionne à l'intérieur de l'espace de vie de la personne. Ces dispositifs ont l'avantage de fonctionner automatiquement sans l'intervention de la personne. Les données recueillies à partir des capteurs sont transmises directement à un dispositif pour être analysées. Ces capteurs jouent un rôle clef pour l'apprentissage du comportement de la personne. Grâce à de tels capteurs, il est possible de compter le nombre d'utilisation de la bouilloire par la personne, la durée par jour de son absence, le nombre de fois qu'elle prend une douche, etc. Des alarmes peuvent être déclenchées en cas d'anomalie comme dans le cas de chute de l'individu et que sa présence au sol se prolonge sur une longue durée, etc. Les capteurs ambiants sont classés en trois catégories : ceux qui enregistrent le son, ceux qui détectent le mouvement, et ceux qui sont placés au sol et qui enregistrent la pression.

Capteurs sonores

Ces dispositifs comprennent un réseau de microphones situés dans un espace silencieux. Le problème crucial à résoudre est la séparation des sons émis par la personne âgée de ceux issus d'une autre source.

Zigel et al. [100] ont proposé un détecteur de chute en se basant sur le son et les vibrations au sol. Les performances mesurées dans un environnement contraint sont excellentes avec une spécificité de 98,6% et une sensibilité de 97%. Cependant, le passage à l'échelle a montré que le principal inconvénient de ce dispositif est qu'il est sensible aux bruits extérieurs (si le logement n'est pas très bien isolé), des objets, des visiteurs, etc. Une simple chute de la chaise peut être considérée comme une chute de la personne.

Popescu et al. [101] ont proposé une méthode pour réduire le nombre des fausses alarmes. Ils localisent le son avec un capteur de son vertical et discriminent les sons situés à une hauteur supérieure approximativement à 60 cm. Pour distinguer les sons des animaux domestiques, ils intègrent dans leur dispositif un détecteur de mouvement. On trouve aussi des exemples d'utilisation des microphones en maison intelligente dans les recherches de Medjahed et al. [102] ou Karaman et al. [103].

Capteurs au sol

Les capteurs au sol, comme leur nom l'indique, sont des capteurs qui sont posés au sol et qui détectent les pressions plantaires exercées par les individus. Ainsi, il est possible de localiser la personne dans l'espace de vie, de détecter la chute, de calculer la vitesse de la marche, etc. Ce type de capteurs est très bien accepté car les personnes âgées ne se sentent pas surveillées par ces capteurs car ils sont passifs et dissimulés.

Comme la majorité des chutes se produisent au sol, de nombreux chercheurs proposent de détecter les chutes à l'aide de ces sols intelligents. A titre d'exemple, Chaccour et al. [104] obtiennent une spécificité de 94.9% et une sensibilité de 88.8% pour la détection de la chute avec des capteurs de pression différentielle. Rimminen et al. [105], [106] présentent une méthode pour suivre la personne et pour détecter sa chute. Tout en étant séduisant, ce système présente certains inconvénients. Le matériel et son installation sont coûteux. Il est réservé à des installations dans les Établissements d'Hébergement Pour Personnes Agées Dépendantes (EHPAD) ou à des constructions neuves. Les solutions algorithmiques pour la gestion de plusieurs personnes restent à démontrer.

Capteurs de mouvement

Les capteurs infrarouges passifs sont des capteurs de mouvement et de présence. Ces capteurs ne sont pas coûteux. Ils sont installés sur les murs et ne causent aucun dérangement à l'habitant. Ces capteurs fonctionnent de manière passive. Ils détectent et enregistrent les mouvements de l'occupant. Les données enregistrées par ces capteurs permettent de déterminer l'emplacement de l'occupant à un instant précis. Le et al. [107] proposent une solution pour la reconnaissance des activités de la personne âgée vivant seule dans un habitat en se basant sur les données des capteurs infrarouges et sur les informations fournies par la personne sur ses habitudes de vie. Barralon et al. [108] fusionnent les données d'un accéléromètre porté par la personne et les données des infrarouges passifs pour la classification de quatre activités de vie quotidienne (habillage, alimentation, transfert et aller aux toilettes). Ohta et al. [109] ont surveillé 8 personnes âgées vivant seules durant 80 mois où les appartements des personnes étaient équipés de capteurs infrarouges passifs. Ils ont constaté que chaque personne avait un modèle spécifique de déplacement.

1.3.2.3. Système de vision

Le système de vision comporte une ou plusieurs caméras optiques qui sont fixées généralement au mur ou au plafond. Les capteurs basés sur la vision couplés à des méthodes de traitement de l'image, permettent d'avoir un grand nombre d'informations (détecter l'inactivité, reconnaître des formes et des activités, analyser les mouvements de la tête) [110].

Charaoui et al. [111] ont présenté un état de l'art de la vision par ordinateur pour la détection des activités humaines. Des activités détectées dans la cuisine par des caméras d'un smart home sont décrites dans l'article de Thi et al. [112]. Thome et al. [113] détectent avec deux caméras les chutes avec une précision de 97,08%.

L'inconvénient des systèmes à base de caméras optiques est leur acceptabilité dans un environnement privé. En effet, ce type de capteur est extrêmement intrusif car il ne préserve pas l'anonymat de la personne. D'autres types de capteurs ont alors été proposés pour éviter d'atteindre à la vie privée de la personne : les capteurs thermiques et les capteurs de profondeur.

Les capteurs de profondeur, telle la caméra Kinect, sont utilisés pour déterminer la distance entre le capteur de profondeur et l'objet ciblé. Ils sont indépendants de l'éclairage de l'environnement et de son emplacement. Ainsi, Le et al. [114] ont proposé une solution de détection de la chute par le biais du capteur Kinect. Dubois et al. [115] ont utilisé les caméras de profondeur pour analyser la marche (la vitesse de la marche et la longueur des pas) de 11 personnes. Les résultats obtenus par le capteur sont proches des résultats obtenus pour la même expérience sur un tapis de pression.

Les capteurs thermiques collectent les radiations infrarouges émises par un matériau ou un humain dont la température est supérieure à zéro absolu. Tao et al. [116] proposent dans leurs travaux, une méthode de la reconnaissance des activités basées sur les capteurs infrarouges basse résolution (8× 8). Les travaux de Davis et al. [117] basés sur les séquences vidéos thermiques ont permis de détecter de manière robuste les personnes dans des environnements différents. Dans la littérature, plusieurs travaux reportent la détection de la chute avec les capteurs thermiques [118]–[121].

1.4. Comportement de la personne âgée

Si la détection de la chute a fait l'objet de nombreuses contributions, on s'est aussi rendu compte que l'étude du comportement de la personne était intéressante. Ce dernier est décrit par la succession de ses activités. La personne âgée a tendance à suivre une routine. Cette routine est exacerbée chez la personne âgée [2]. On considère qu'un changement de comportement est en lien direct avec le suivi de leur santé.

1.4.1. Relation entre les activités et la santé

Ce paragraphe a pour objectif d'expliquer le lien entre la santé et le comportement de la personne c'est à dire la succession des activités. Selon l'OMS, la santé est définie comme « un état complet de bien-être physique, mental et social, et ne consiste pas seulement en une absence de maladie ou d'infirmité ». Elle est associée à la notion de bien-être. Par ailleurs, la réalisation des activités de vie quotidienne (AVQ) pour prendre soin de soi comme se laver, se nourrir, s'habiller font partie du bien-être de la personne. Cette définition de la santé, permet de mesurer combien le bien-être physique et l'activité sont liés. En effet, l'état physique de la personne a un impact direct sur la réalisation des activités, car une personne qui a un bon état physique réalise sans difficulté les AVQ. Par contre, une personne avec un état physique dégradé réalisera avec difficulté les mêmes AVQ. Zulfiqar et al. [122] montrent que l'activité physique a une action positive sur l'état de santé fragile de la personne âgée. Blanchet et al. [123] montrent aussi que la pratique physique a de multiples avantages chez la personne âgée, comme la prévention de la chute, la diminution des maladies cardio-respiratoires, et favorise la santé mentale et cognitive [124].

Le bien-être mental défini par l'OMS est clairement relié aux AVQ par la notion de l'estime de soi. En effet, une personne qui réalise ses activités quotidiennes comme prendre sa douche, cuisiner, réaliser une activité physique aura un meilleur moral et une meilleure estime de soi qu'une personne dépendante [123]. Des études transversales et longitudinales ont montré que la réalisation des activités physiques réduisent le risque de développer des troubles cognitifs [124]. Blumenthal et al. [125] montrent que la pratique de l'activité physique améliore l'humeur de la personne. Enfin, une bonne santé de la personne âgée influe sur le maintien de ses relations sociales. Par exemple, une

personne âgée robuste peut recevoir chez elle des visites et peut aussi rendre visite aux personnes de son réseau social sans difficultés ou obstacles, contrairement à la personne dépendante ou fragile.

1.4.2. Routine de la personne âgée

Les personnes âgées ont généralement une routine bien définie dans le temps et dans l'espace. En effet, leur quotidien est organisé autour de routines fixes dans le comportement, les relations sociales et l'environnement. La routine est associée au concept d'habitude. Elle procure un sentiment de sécurité, de contrôle et de stabilité face à des événements stressants du quotidien [126]. Plus la personne vieillit, plus elle attache une importance à un rythme bien défini des journées, des semaines et des années. Elle a le sentiment que plus sa vie est prévisible, mieux elle est contrôlable.

Reich et al. [127] indiquent que l'élément central de la qualité de vie de la personne est d'avoir des rythmes journaliers et hebdomadaires bien établis. Kastenbaum [128] suggère que tout événement inconnu, donc non déjà vécu dans la vie de la personne, serait rejeté afin d'éviter toute anxiété. En résumé, chaque jour la personne âgée s'attache à une routine et évite toute perturbation [129]. La routine semble jouer un rôle important dans le maintien de l'autonomie. Buisson et al. [130], Buisson [131], et Bergua et al. [132] ont montré l'existence d'un lien entre la routinisation et la vulnérabilité psychologique. La préférence de la routinisation augmente non seulement avec l'âge, mais également en fonction de l'importance de l'anxiété et la dépression. Les résultats de l'étude PAQUID ont permis de mettre en évidence le lien entre la routinisation et la vulnérabilité cognitive [132]. La préférence d'avoir un comportement routinier est plus importante chez les personnes qui ont un déclin cognitif et non atteintes de démence. Bergua et al. [2] mettent aussi en évidence un lien entre la vulnérabilité fonctionnelle et la routinisation, ils décrivent une association de la routinisation à la présence d'incapacités fonctionnelles pour les activités instrumentales de la vie quotidiennes, où les activités instrumentales de la vie quotidienne correspondent aux activités réalisées sans aide humaine au niveau tâches simples et des tâches plus complexes en utilisant des instruments de la vie quotidienne (par exemple utiliser le téléphone, préparer des aliments ...) [133].

Afin de bien comprendre la routine quotidienne de la personne âgée, Buisson [134] propose une échelle (Tableau 1-1) pour déterminer si la personne est routinière. L'échelle consiste à questionner l'individu sur ses sentiments ou états (par exemple : « Je ne supporte pas qu'on change mes affaires de place ») ou sur son comportement quotidien (par exemple : « En général je fais les mêmes choses chaque jour »). Cette échelle permet de définir la routine des personnes âgées : comme le fait d'organiser sa vie quotidienne autour de routines fixes dans le comportement, les relations sociales et l'environnement [130].

Tableau 1-1 : Échelle des préférences de routinisation [134].

	Pas du tout vrai	Un peu vrai	Moyennem. vrai	Souvent vrai	Tout à fait vrai
1. En général, je fais les mêmes choses chaque jour.	<input type="checkbox"/>				
2. Je ne suis pas content(e) quand une personne que j'attends n'est pas à l'heure.	<input type="checkbox"/>				
3. Je ne supporte pas qu'on change mes affaires de place.	<input type="checkbox"/>				
4. J'aime les situations imprévues.	<input type="checkbox"/>				
5. Je n'aime pas attendre quand c'est l'heure du repas.	<input type="checkbox"/>				
6. J'aime bien bouger et changer d'activité.	<input type="checkbox"/>				
7. Je n'aime pas qu'on me prenne ma place pour manger ou regarder la télévision.	<input type="checkbox"/>				
8. Je préfère me lever et me coucher aux mêmes heures tous les jours.	<input type="checkbox"/>				
9. J'aime bien sortir pour rencontrer de nouvelles personnes.	<input type="checkbox"/>				
10. J'aime bien voir des émissions ou films nouveaux à la télévision.	<input type="checkbox"/>				

1.4.3. Types de changement de comportement

Le comportement est un processus qui évolue dans le temps, ce processus peut, soit suivre une évolution constante monotone, soit subir des changements brusques. Il est important de connaître les différents types de changement de comportement pour identifier les causes, proposer des solutions dans le cas d'une dégradation, et aussi pour déclencher des alarmes dans le cas d'urgence. Bose et al. [135] ont identifié quatre types de changements possibles au sein d'un processus opérationnel (un ensemble de tâches permettant de réaliser une activité). Ces changements sont présentés dans la Figure 1-6. On distingue :

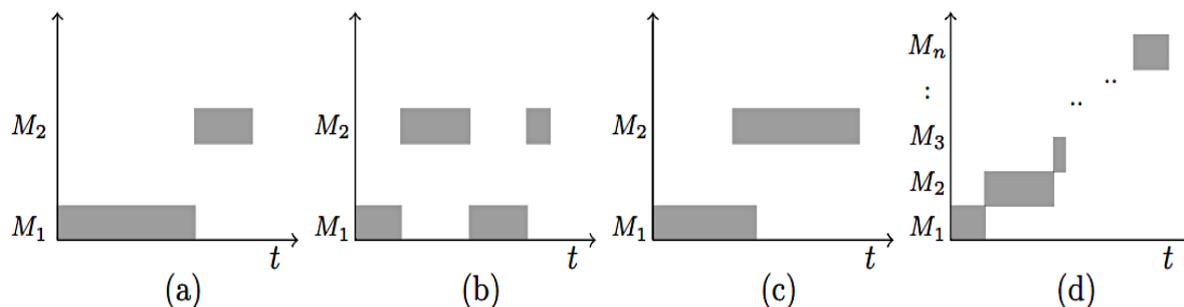


Figure 1-6: Différents types de changements. a: Brusque, b: Récurrent, c: Graduel, d: Progressif [135].

- a) Le changement brusque (Figure 1-6 (a)) : il correspond au remplacement soudain d'un comportement M_1 par un comportement M_2 . En d'autres termes, d'un jour à l'autre la personne perd sa routine. Ce type de changement est la conséquence de l'apparition d'un événement inattendu, par exemple suite à un accident, une hospitalisation, le décès d'un proche, etc.
- b) Le changement récurrent (Figure 1-6 (b)) : il correspond à la réapparition de certains événements après un certain temps. Parfois la durée de réapparition d'un événement est liée à sa nature. Par exemple, la personne tombe malade suite aux changements de saisons. Par conséquent, son comportement change d'une façon récurrente. Il existe aussi des maladies chroniques qui se traduisent par des changements récurrents.
- c) Le changement graduel (Figure 1-6 (c)) : il correspond à l'apparition d'un comportement M_2 qui chevauche avec le comportement précédent M_1 durant un intervalle de temps ; contrairement au changement brusque où les événements M_1 et M_2 sont disjoints. Par exemple, une personne âgée qui prend un nouveau médicament, continuera aussi de prendre l'ancien médicament pour finir son traitement.
- d) Le changement progressif (Figure 1-6 (d)) : il correspond au scénario où la personne passe par le comportement M_1 au comportement M_n en passant par plusieurs changements courts. Par exemple, ce changement peut être expliqué par une maladie qui réduit progressivement les capacités physiques de la personne, cela se reflètera par une réduction progressive des réalisations des activités.

1.4.4. Détection de changement de comportement

La détection du changement de comportement se résume dans la détection du changement dans la routine de la personne ou dans le changement de ses habitudes. Plusieurs recherches approfondies ont été réalisées dans des maisons intelligentes pour le suivi des résidents. Ces recherches ont permis de détecter les anomalies du quotidien, d'identifier le comportement et d'anticiper son changement. Les travaux sur la détection des changements du comportement à long terme dans les maisons intelligentes sont rares. Le comportement de la personne est décrit par ses

activités, on retrouve dans la littérature plusieurs travaux sur la détection des activités de la vie quotidienne.

Le et al. [136] proposent la reconnaissance du comportement d'une personne âgée vivant seule dans un habitat intelligent pour la santé en traitant les données provenant des capteurs infrarouges passifs. De cette façon on peut suivre les activités de la vie quotidienne et évaluer leurs régularités. Les capteurs détectent les séquences d'états mobiles et immobiles de l'occupant dans les différentes pièces du lieu de vie. À partir des séquences détectées, les auteurs utilisent les règles de reconnaissances pour définir certaines activités de la vie quotidienne (AVQ). Dans le même contexte, Wilson [137] utilise le modèle de Markov caché pour la reconnaissance des activités de la vie quotidienne de la personne. Barralon [138] propose la reconnaissance de quatre AVQ (Aller aux toilettes, s'habiller, s'alimenter, et se déplacer) en se basant sur les données enregistrées par des capteurs infrarouges passifs et un accéléromètre porté par la personne pour la détection du changement de comportement et ainsi évaluer la perte d'autonomie. Lotfi et al. [139] proposent une solution pour le suivi du comportement de la personne, la détection et la prédiction du comportement anormal, basée sur des capteurs tels que les détecteurs de mouvement, des capteurs d'entrée dans une pièce et des accéléromètres. Les données enregistrées par les capteurs sont analysées avec les réseaux neuronaux récurrents. Jain et al. [140] proposent dans leurs travaux l'identification des tendances du mode de vie, la détection des anomalies, et la conception d'un système d'assistance. Les activités anormales sont détectées en calculant un écart par rapport à une situation de référence (z-score). Dawadi et al. [141] proposent dans leurs travaux une méthode de la détection du changement de la routine en comparant les courbes d'activités quotidiennes. Les courbes d'activités sont définies en segmentant les données sur une période fixe (une semaine, un mois, etc.). Les données sont issues de 18 maisons intelligentes habitées par des personnes âgées. Les auteurs ont montré qu'il y a une corrélation entre la santé et le changement de comportement. Ils soulignent que le changement de comportement peut être détecté automatiquement par le biais des maisons intelligentes et de l'apprentissage automatique. Sprint et al. [142] ont également proposé une approche de détection du changement de comportement des personnes dans des maisons intelligentes. Les séquences d'activités sont segmentées par semaine. Chaque semaine est comparée à la semaine qui la précède et qui représente le comportement normal de la personne. La comparaison est réalisée par le biais d'arbre de décision. Cette méthode a été testée sur trois personnes âgées qui ont subi une dégradation de leur état de santé. Les travaux ont montré que l'état de santé a un impact sur plusieurs activités, notamment le sommeil, l'alimentation et l'absence du domicile.

Conclusion

Ce chapitre a permis de procéder à un tour d'horizon de différentes approches utilisées pour le suivi des personnes âgées. Fortement ancrés sur la détection de la chute à partir de capteurs différents (accéléromètre, gyroscope, caméra, caméra de profondeur, capteur thermique), les travaux se sont diversifiés vers l'habitat intelligent (capteurs d'ambiance) ou les sols intelligents et se sont progressivement tournés vers le suivi du comportement des personnes. L'intégration de ces solutions dans des « maisons intelligentes » facilite le quotidien des seniors, car elle leur assure une vie plus confortable, plus sécurisée. Par contre, des solutions robustes doivent encore être recherchées pour gérer la multiplicité des situations observables.

Le suivi du comportement représente, à la lecture de cet état de l'art, un véritable challenge. En effet, nous partons d'une hypothèse émise par de multiples professionnels de santé, qui stipule que des changements de comportement observés chez une personne âgée peuvent être des signes d'apparition de problèmes de santé. La dégradation de l'état de santé de la personne âgée robuste est un signe de fragilité. De plus, le changement des habitudes de vie peut indiquer l'apparition d'un trouble, comme la maladie d'Alzheimer. Étant donné que plus la personne avance dans l'âge, plus elle s'attache à une routine ou à des habitudes, la détection de changements dans le comportement routinier est similaire à la perte de la routine.

C'est dans ce contexte que la société NeoTec-Vision recherche et essaye de déployer depuis plusieurs années une solution qui combine des caméras de profondeur et des capteurs thermiques. Si des solutions ont pu être proposées [143]–[145] pour détecter des chutes et des activités, il convient maintenant de les stabiliser et de proposer une solution robuste sur la base de ces capteurs pour détecter les changements de comportement. C'est l'objet des prochains chapitres.

2. Le projet PRuDENCE

Introduction

Comme il a été mentionné dans le chapitre précédent, notre travail de thèse s’inscrit dans le cadre d’une collaboration menée lors d’un projet ANR, le projet PRuDENCE (PRévention et DEtection des ChutEs). Nous allons dans un premier temps présenter ce projet avec ses objectifs, ses partenaires et son organisation. Ceci permettra de mieux situer notre travail dans le flux des sous-projets. Ce projet est centré sur une nouvelle solution de données de surveillance (association d’un capteur de profondeur et d’un capteur thermique de faible résolution). L’inconvénient est qu’il n’existe pas de données publiques préalables au projet. De ce fait, nous avons donc dû constituer les différentes bases de données du projet PRuDENCE permettant la détection des chutes et la détection du changement de comportement. Ces bases de données seront décrites dans ce chapitre. De même, ce type de données nécessite également des méthodes d’évaluation à la fois sur les procédures de détection et sur les procédures de classification qui seront également décrites dans ce chapitre.

2.1. Contexte du projet PRuDENCE

Le projet PRuDENCE est un projet de recherche industriel financé par l’agence nationale de la recherche. Le projet, démarré en 2016, est le fruit de la collaboration entre le Laboratoire de Traitement du Signal et de l’Image de Université de Rennes I (LTSI), l’École Catholique d’Arts et Métiers de Rennes (l’ECAM), le Living Lab ActivAgeing (LL2A) de l’Université de Technologie de Troyes, l’équipe d’accueil EA2694 Santé Publique/épidémiologie et qualité des soins de l’Université de Lille et l’entreprise NeoTec-Vision. Son objectif principal était d’améliorer un dispositif de détection des chutes à bas coût (un projet antérieur mené par NeoTec-Vision nommé dispositif Gladis) à base de capteurs de profondeurs et/ou thermiques en y apportant de la robustesse dans la détection des chutes et en l’étendant vers la surveillance des personnes âgées pour la détection de la fragilité. Le choix initial de ces capteurs était motivé par le fait qu’ils permettent d’enregistrer des images en préservant l’anonymat des personnes observées et qu’ils fonctionnent de jour comme de nuit. Pour répondre à cet objectif, le projet PRuDENCE a été découpé en 5 WP (Work Package).

- Le premier, WP 1, concerne des travaux dans la continuité du projet Gladis (thèse CIFRE de Geoffroy CORMIER – NeoTec-Vision [146]) : utilisation d’un capteur de profondeur et d’un capteur thermique pour le suivi de la personne. Ces travaux ont été réalisés par l’ECAM Rennes principalement dans le cadre de la thèse d’Imen HALIMA [147]. Deux parties sont à distinguer : la première sur le suivi de la tête de la personne à partir d’un filtrage particulière avec ou sans fusion des capteurs, la seconde sur la reconnaissance de postures (*assise, debout, allongée sur le lit, allongée par terre*) par des techniques de Deep Learning.

- L'objectif du WP2 est de mettre en œuvre une solution de détection des chutes et de suivi des activités de la personne à partir d'une paire de caméras thermiques basse résolution. Ces travaux sont l'objet de la thèse de Yannick ZOETGNANDE au LTSI, Université de Rennes 1 [145].
- Le WP3, sur lequel portait ce travail de thèse, est focalisé sur la détection de la fragilisation de la personne âgée par l'utilisation de l'observation des activités de la personne. L'idée est, dans un premier temps, de détecter les routines de la personne par l'observation, puis de détecter la fragilité par l'observation des écarts à ces routines. Les données de l'observation utilisées par le WP3 sont les informations sur l'activité de la personne (posture, vitesse de déplacement, chute ...) estimées par les méthodes développées dans les WP1 et WP2.
- Le WP4 porte sur l'intégration logicielle et matérielle des différentes méthodes développées dans les autres WP. Cette partie était assurée par NeoTec-Vision. L'objectif était d'intégrer les algorithmes issus de WP1 et WP2 au fur et à mesure et de les adapter au temps réel (à une fréquence – nombre d'images par seconde – adaptée aux phénomènes à observer).
- Enfin, le WP5, réalisé par le Living Lab ActivAgeing de l'UTT, avait pour double objectif, d'une part, de réaliser des séquences en utilisant nos capteurs avec une vérité terrain (capture de mouvements par système Vicon), et, d'autre part, de définir en co-conception les fonctionnalités et les modes d'utilisation du futur dispositif.

Le projet PRUDENCE s'inscrit donc dans une approche sociétale complète où la prévention et la détection de la chute et l'estimation du degré de fragilité permettent de maintenir au maximum les personnes âgées à leur domicile, en favorisant au maximum leur autonomie.

Dans ce manuscrit, nous nous sommes donc concentrés sur les travaux à réaliser dans le contexte du WP3, c'est-à-dire la détection de la fragilisation de la personne âgée. Comme il a été dit plus haut, cela nécessite l'analyse de l'activité de la personne. Notre corollaire est qu'une activité peut être déduite d'une posture (*assis, allongé, debout*) ou par son *absence* du logement. Cela implique donc des outils de reconnaissance de ces postures, qui passe par une phase d'apprentissage. La particularité de notre projet est qu'il doit reconnaître et suivre l'activité d'une personne âgée dans son environnement quotidien. Peu de bases de données publiques proposent un tel contexte : lieu clos et habité, activités spécifiques à des personnes âgées, activités routinières, apparition de quelques accidents tels les chutes, etc. Nous avons donc dû élaborer nos propres bases de données pour l'apprentissage et la validation de nos méthodes. De même, nos travaux reposent sur la détection des postures. Pour cela, nous avons dû adapter certains des travaux réalisés dans le cadre des WP2 et WP1 à notre problématique. Ces adaptations nous ont permis d'élaborer des méthodes sur la détection de la chute [148] et du changement du comportement de la personne âgée, basée sur l'analyse de son activité [149]–[151].

Ceci nous a conduits à structurer ce travail sur la détection du changement de comportement des personnes âgées en deux axes associés à plusieurs étapes (Figure 2-1). Pour les deux axes de recherche, la première étape était commune :

- Cette première étape concernait la conception d'une base de données d'images. En effet, notre projet est particulier dans le sens qu'il essaye d'estimer des comportements (suites de postures) d'un public spécifique (personnes âgées) dans un lieu particulier (appartement ou chambre) à partir d'images de profondeur. Comme nous n'avons pas trouvé de données publiques traitant de cette problématique nous avons dû créer nos propres bases de données à partir d'enregistrements en EHPAD et en appartement. Ces bases de données sont décrites dans le chapitre II.

Premier axe de recherche : Extraction des paramètres de l'Image

- Après l'acquisition des données, la seconde étape consiste à extraire des paramètres des images de profondeur après avoir fusionné à chaque instant d'enregistrement l'image de profondeur et l'image thermique pour localiser une région dans l'image de profondeur.
- La troisième étape propose une méthode de détection de la chute basée sur la localisation de la personne, la localisation de la personne permet aussi de suivre le comportement de la personne. La méthode a été appliquée sur des données réelles d'une personne âgée vivant dans une maison de retraite.

Deuxième axe de recherche : Classification par Deep-learning

- Après l'acquisition des données, la seconde étape permet de classer les images de profondeur enregistrées par un réseau de neurones entraîné pour reconnaître les postures (*assise, allongé, debout*), la *chute* mais aussi l'*absence* de la personne. Nous avons choisi un réseau du type ResNet-18 car ce dernier présente l'avantage de ne pas être trop profond (sur-apprentissage), et contient relativement beaucoup de couches (sous-apprentissage). Ce réseau et son évaluation sont décrits dans le chapitre VI. La classification des images permet de définir la journée de la personne en succession de postures avec indication de l'absence et de la chute.
- La troisième étape propose quatre méthodes de détection de changement de comportement qui sont appliquées à des données réelles (chapitre V), et à des données simulées (chapitre VI).
 - La première méthode *M-DME*⁶ consiste à comparer la journée routine avec chaque journée enregistrée par le biais de l'algorithme distance d'édition. Le suivi des résultats des comparaisons permet de détecter le changement de comportement.
 - La seconde méthode *M-DTW*⁷ consiste à aligner chaque journée enregistrée à la journée routine. L'alignement est réalisé par l'algorithme de la déformation

⁶ *M-DME* : Méthode Distance Minimale d'Édition

⁷ *M-DTW* : Method par Dynamic Time Warping

temporelle dynamique. Le suivi des résultats permet de détecter le changement de comportement.

- La troisième méthode *M-CNJ*⁸ consiste à classer chaque journée enregistrée en journée routine ou journée non-routine par la classification supervisée (régression logistique binaire, arbre de décision et les forêts aléatoires) et non supervisée (les méthodes du clustering : K-modes et K-moyennes) selon les pourcentages des indices qui décrivent la journée (pourcentage en temps *assise*, pourcentage en temps *allongée*, pourcentage en temps *absente*, pourcentage en temps *debout* et le nombre de *chutes*). Le suivi de la nature de la journée sur une période d'enregistrement permet de détecter le changement de comportement.
- La quatrième méthode heuristique *M-H*, qui consiste à classer la journée de la personne en vérifiant si les indices du jour (pourcentage en temps *assise*, pourcentage en temps *allongée*, pourcentage en temps *absente*, pourcentage en temps *debout* et le nombre de *chutes*) appartiennent aux intervalles *routines* des indices. L'évolution de la classification du type du jour permet de détecter le changement de comportement.

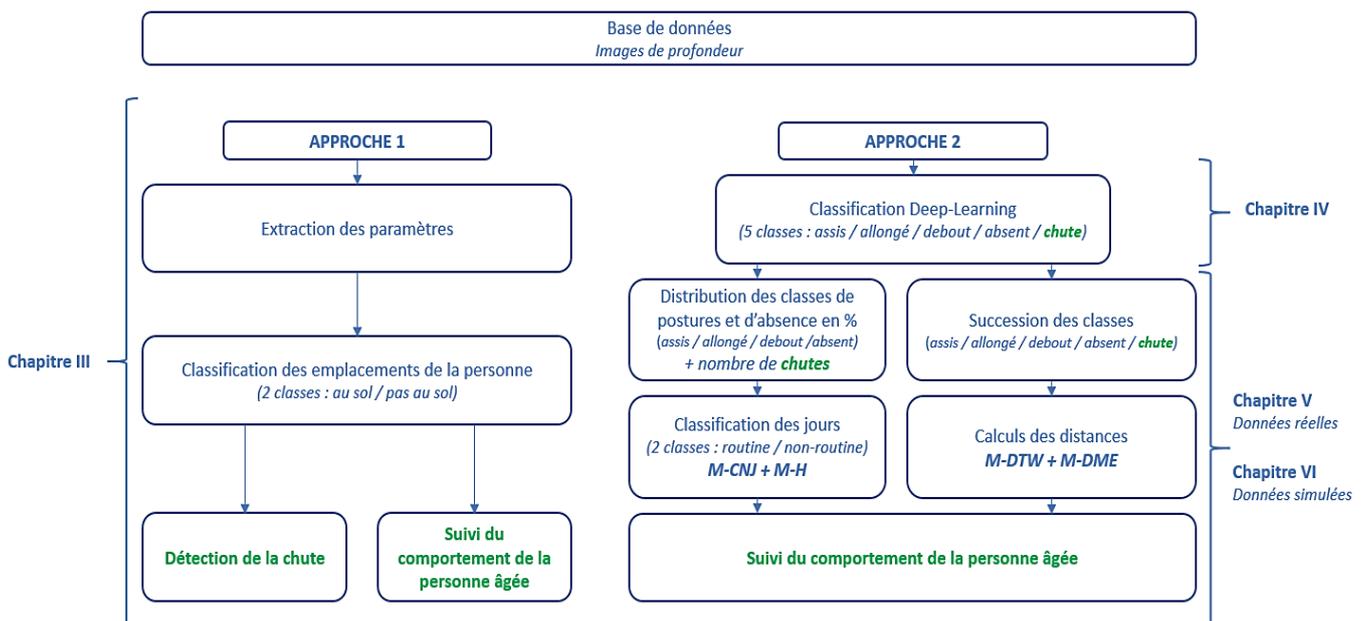


Figure 2-1 : Vue synthétique de la thèse pour la détection du changement de comportement de la personne et de la chute.

⁸ *M-CNJ* : Méthode par Classification de la Nature de la Journée

2.2. Bases de données

Suite à la première étude menée par Geoffroy Cormier [146], nous nous sommes focalisés sur l'utilisation de caméras de profondeur. Ceci a donné lieu à la réalisation par la société NeoTec-Vision d'un dispositif nommé Gladis, basé dans un premier temps sur une seule caméra de profondeur. Par la suite, une caméra thermique y a été associée. Pour confirmer ce choix, une étude menée par le Laboratoire Armoricaire Universitaire de Recherche en Psychologie Sociale de l'Université de Rennes 2, a montré l'acceptabilité psychosociale d'un tel dispositif basé sur des images de profondeurs. Cette étude a également montré que le dispositif proposé par NeoTec-Vision était acceptable tant pour les individus observés et leurs familles que pour les professionnels de santé et les établissements d'hébergement pour personnes âgées [146].

Lors de son étude, Cormier a voulu évaluer le dispositif Gladis dans une situation réelle. Ce dispositif a donc été placé en EHPAD, dans deux chambres de personnes âgées. Les images de cette étude composent donc notre première base de données. Par contre, cette situation de deux personnes en EHPAD ne répondait que partiellement à notre problématique de surveillance de personnes en situation d'autonomie. Nous avons donc dû créer une deuxième base de données présentant l'activité de 4 personnes adultes (deux femmes et deux hommes), dans différents lieux d'un appartement.

2.2.1. Base de données Gladis

Le dispositif Gladis élaboré par la société NeoTec-Vision est basé sur l'idée de « Sécuriser sans surveiller » [146]. En effet, la solution présente la particularité de ne pas utiliser de caméra vidéo et de ne pas obliger la personne âgée à porter de capteur(s). Dans sa première version, il était constitué d'un capteur de profondeur et d'une informatique embarquée, le tout intégré dans un boîtier pouvant être fixé au plafond (Figure 2-2). Ce dispositif était dédié à la seule détection des chutes des personnes âgées.

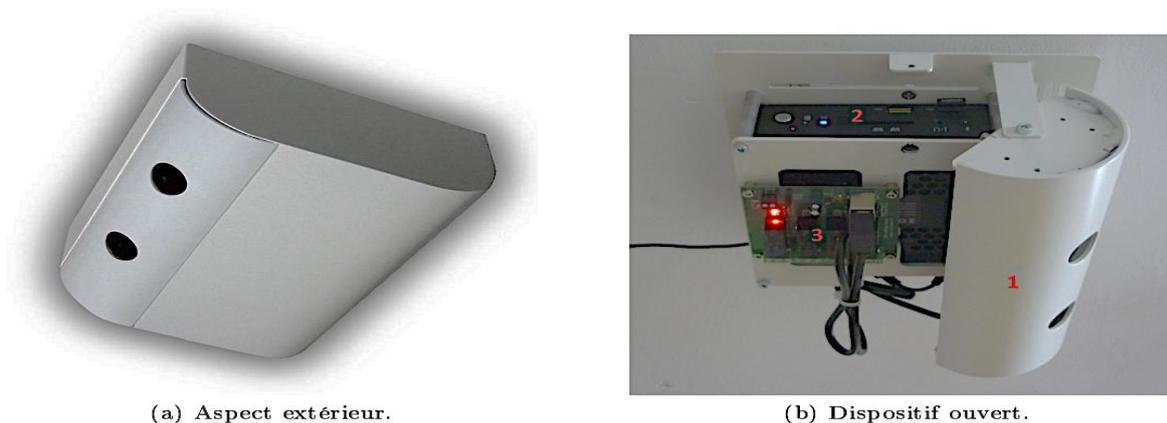


Figure 2-2 : Dispositif Gladis.

Lors de l'évaluation du dispositif pour la détection de la personne au sol, il a été placé dans deux chambres d'un centre d'hébergement de personnes âgées [146] après l'obtention de l'accord des deux personnes et de la direction de l'EHPAD. L'activité de ces deux personnes âgées, que nous

nommerons A et B, a été enregistrée par le dispositif Gladis toute la journée en continu, jour et nuit, durant 85 jours. Une image était enregistrée chaque 15 minutes. Ceci a donné un total de 8160 images pour chaque personne. La Figure 2-3 présente quelques images de profondeur de la personne B.

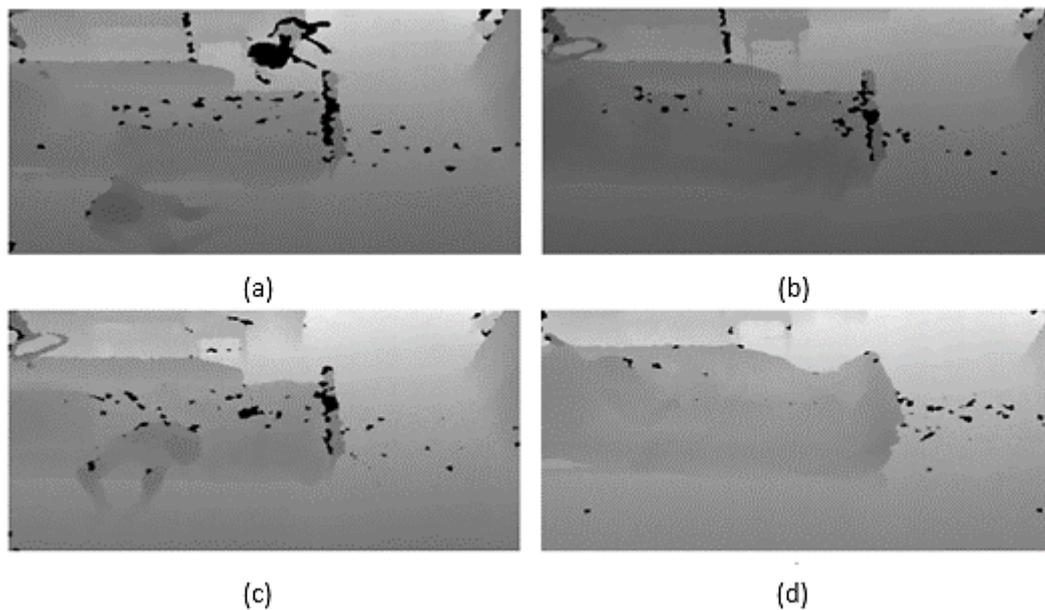


Figure 2-3 : Images de profondeur personne B (a : la personne est par terre. b : La personne est absente. c : La personne est assise. d : la personne est allongée)

Nous avons utilisé ces deux séquences pour établir notre première base de données appelée Gladis par la suite. Afin d'établir une vérité terrain, nous avons annoté chaque image en fonction de la posture de la personne. Les deux personnes étant des personnes dépendantes présentant des problèmes de mobilité seule les postures suivantes ont été identifiées et annotées : *allongée sur le lit*, *assise*, *au sol* à la suite d'une chute et *absente* (en effet une des deux personnes avait été hospitalisée une partie de la période d'acquisition). La Figure 2-4 présente l'effectif des postures des personnes A et B.

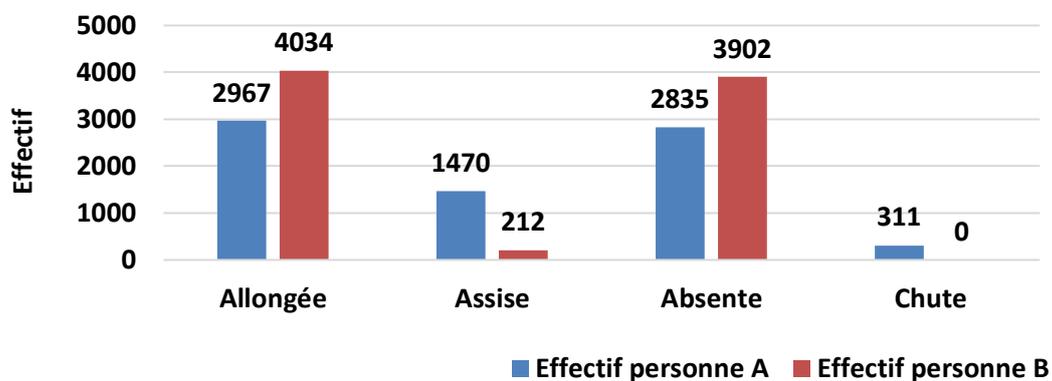


Figure 2-4 : Effectif des postures des deux personnes A et B enregistrées dans leurs chambres d'EHPAD.

On remarque que la personne A n'a jamais chuté, par contre la personne B présente des images de chute (personne au sol).

Cette base de données présente l'avantage d'être prise en condition réelle. Elle a aussi l'avantage de montrer de vrais cas de chutes, avec une fréquence supérieure au cas de personnes moins fragiles. Par contre, elle présente différents biais par rapport à notre objectif :

- Les deux personnes âgées étaient des personnes dépendantes, peu mobiles et non autonomes. Ceci explique les forts pourcentages des postures « assises » et « couchées » et la non présence de la posture « debout ».
- Les images ont été enregistrées à une fréquence très basse (1 image/15 min). Un suivi d'activité est difficile dans ces conditions.
- Les personnes étaient déjà dans un stade de fragilité avancée. Il n'y a donc pas de passage d'un stade robuste vers fragile et fragile vers dépendant.

2.2.2. Base de données Symh

Du fait de la faiblesse de la base de données Gladis, nous avons donc dû créer une base de données répondant à nos hypothèses de départ : routine dans les activités puis perturbations de ces routines indiquant un début de fragilité.

La seconde base, dénommée Symh, rassemble l'enregistrement d'une personne observée dans différents lieux d'un appartement tels que la cuisine, le salon, la chambre ou encore le couloir d'entrée (Figure 2-5). Comme nous ne disposions plus du système Gladis, un capteur de profondeur de type KINECT⁹ V1 (Figure 2-6) a été utilisé. Ce capteur a été placé sur un trépied à une hauteur de 240 cm afin de simuler une pose au plafond ou au haut des murs. Les images ont été enregistrées avec une fréquence de 2 Hz, cette fréquence est plus propice à un suivi d'activités.

⁹ C'est un dispositif développé pour la console Xbox 360 pour le suivi des mouvements humains.



Figure 2-5 : Appartement d'acquisition de la base Symh.

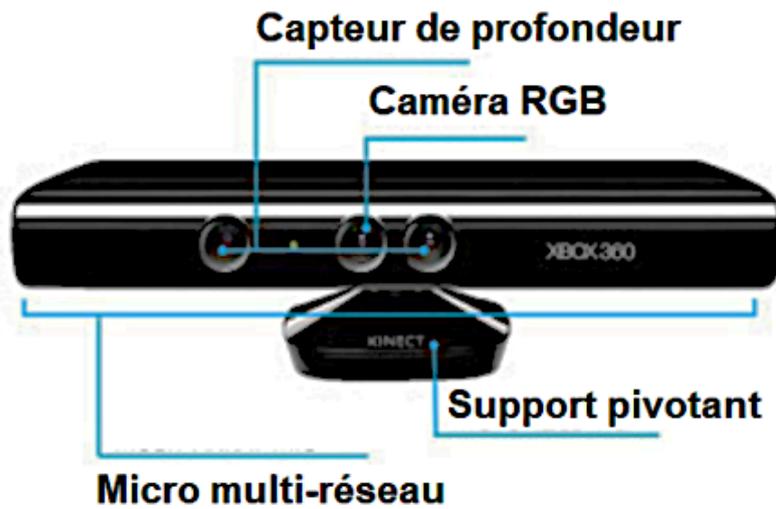


Figure 2-6 : Caméra KINECT V1.

Étant donné que l'enregistrement d'une personne en continu dans son logement durant toute la journée et sur une longue durée est difficile, nous avons proposé, pour l'acquisition de cette base de données de compresser une journée en de courtes séquences dans différents lieux, à l'instar de ce qu'a proposé Sevrin [152], en se basant sur le scénario décrit au Tableau 2-1 :

Tableau 2-1 : Scénario d'une journée de référence compressée pour l'acquisition des images de la base Symh [152].

Heure	Action/Activité	Localisation	Durée
07:00	Le sujet se réveille et se lève.	Chambre	1 min
07:05	Toilettes/douche	Salle de bain	10 s
07:45	Préparation du petit déjeuner	Cuisine	1 min
08:00	Petit déjeuner dans la cuisine	Cuisine	1 min
08:30	Salle de bain	Salle de bain	10 s
09:00	Il va faire les courses	Sortir de l'appartement	30 s
10:30	Retour dans l'appartement	Entrer dans l'appartement	30 s
10:35	Le sujet range	Cuisine	1 min
11:00	Lecture sur le canapé	Salon (Canapé)	1 min
11:30	Préparation du repas	Cuisine	1 min
12:15	Repas	Cuisine	1 min
12:45	Vaisselle/nettoyage	Cuisine	1 min
12:50	Toilettes	Salle de bain	10 s
13:00	Informations à la télé	Salon (Canapé)	1 min
14:00	Sieste	Chambre	1 min
14:30	Sortir de l'appartement (sport)	Sortir de l'appartement	30 s
16:30	Retour à l'appartement	Entrer dans l'appartement	30 s
16:35	Le sujet mange dans la cuisine	Cuisine	1 min
16:45	Le sujet prend une douche	Salle de bain	10 s
17:10	Préparer un café	Cuisine	1 min
17:20	Un invité frappe à la porte. Le sujet vient ouvrir	Entrée	30 s
17:30	Les deux personnes discutent	Salon	1 min
19:00	L'invité quitte l'appartement	Entrée	30 s
19:05	Toilettes	Salle de bain	10 s
19:10	Le sujet fait la cuisine	Cuisine	1 min
19:40	Le sujet mange à table	Cuisine	1 min
20:00	Télévision	Salon (Canapé)	1 min
20:40	Vaisselle	Cuisine	1 min
21:00	Le sujet se met à son bureau	Chambre	1 min
21:30	Le sujet se prépare pour la nuit	Salle de bain	10 s
22:00	Lecture dans le lit	Chambre	1 min
22:50	Prise de la tension	Chambre	1 min
23:00	Le sujet se couche	Chambre	1 min

Il convient de noter, comme cela pourrait être le cas dans un appartement réel, qu'il n'y a pas de capteurs installés dans la salle de bain et les toilettes. Par contre, son emplacement permet d'indiquer si la personne est entrée dans la salle de bain ou les toilettes.

Afin de créer une variabilité des jours enregistrés, différentes séquences par lieu ont été enregistrées en introduisant des perturbations dans le scénario précédent telles que la chute de la personne dans différents lieux, la personne ne reçoit pas d'invité, la personne fait une sieste dans le salon au lieu de la chambre, la vitesse de marche est différente, la personne saute un repas ou encore la personne ne sort pas, etc.

Les perturbations ainsi introduites permettent de définir plusieurs et différents jours compressés. Ces scénarios ont été joués par 4 personnes différentes afin de créer une variabilité dans les personnes et les activités. La Figure 2-7 présente quelques images de profondeur d'une personne de la base Symh. Au total, 139 séquences dans tout l'appartement et pour les quatre personnes ont été acquises pour un total de 4177 images de profondeur. Comme, les personnes jouaient un scénario, l'annotation des images pour la vérité terrain se faisait d'elle-même lors de l'acquisition des images. Pour le scénario décrit dans le Tableau 2-1 on trouve les images des *chutes* (15% des images), des postures suivantes : *debout* (36% des images), *assise* (19% des images), *allongée* (6% des images), et des images de l'*absence* de la personne (23% des images).

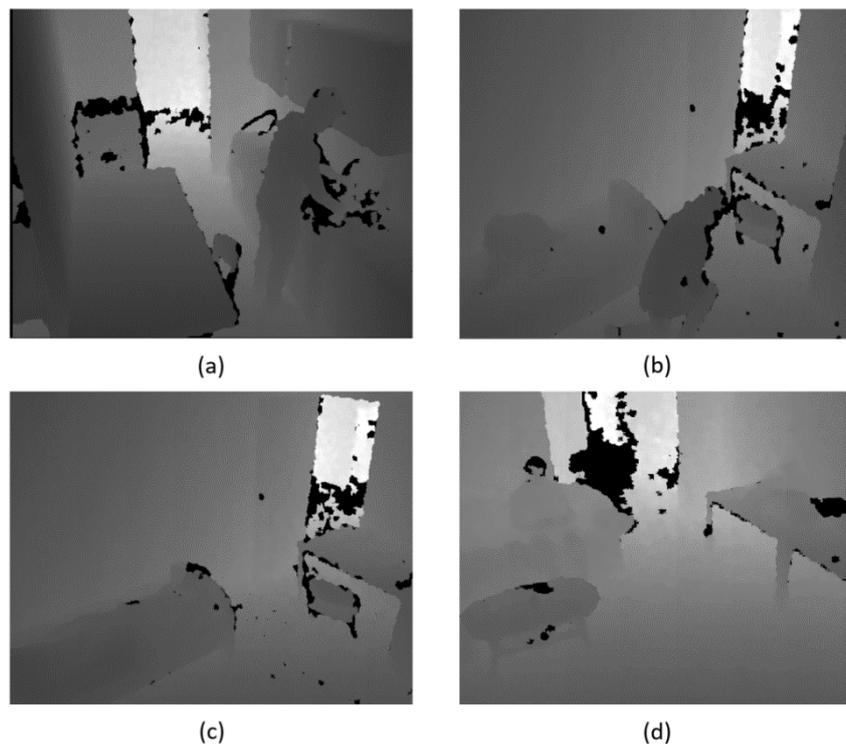


Figure 2-7 : Images de profondeur. a : La personne est debout. b : La personne chute. c : La personne est absente d : La personne est assise.

En résumé :

Notre base de données est composée des images de profondeur de la base Gladis (de la personne A (8160 images de profondeur), de la personne B (7582 images de profondeur)), et de la base Symh (4177 images de profondeur). La personne B de la base Gladis présente plus de variabilité que la personne A car la personne B chute souvent. Les effectifs des classes de la personne B et de Symh sont présentés dans la Figure 2-8 et la Figure 2-9.

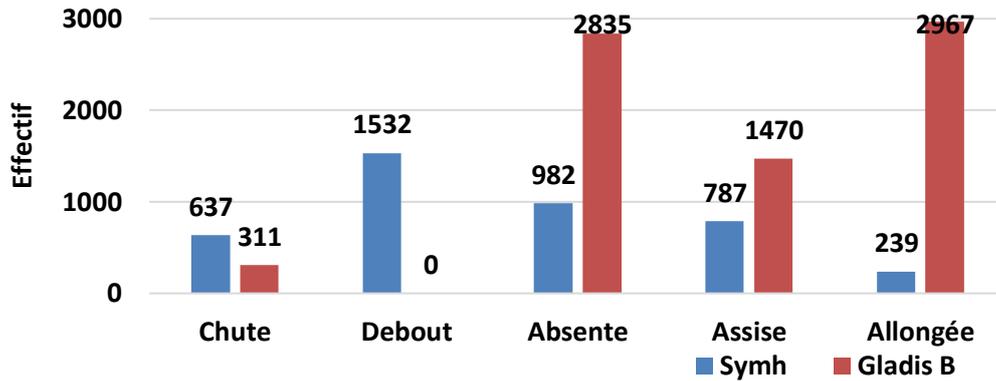


Figure 2-8 : Effectif des classes de l'étude de la base Gladis (personne B) et la base Symh.

Base de données totale

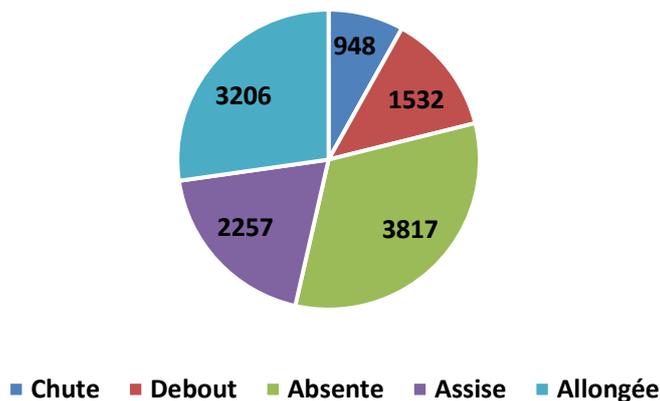


Figure 2-9 : Effectif des classes de la base de données composées de la base Gladis de la personne B et la base Symh.

L'effectif de la base Gladis de la personne B s'explique par le fait que la personne présentait des problèmes de mobilité et par conséquent n'a jamais été observée debout sur la période d'observation de 85 jours. De même, il y a eu une grande période d'absence du fait d'une hospitalisation (9 jours). Malgré ce déséquilibre nous avons voulu garder la base de données Gladis car

elle représente des acquisitions en conditions réelles. La base de données totale associant la base Gladis et Symh est ainsi plus équilibrée.

2.3. Métriques d'évaluation

Dans cette section, nous allons introduire les métriques utilisées pour mesurer les performances de nos algorithmes. Dans notre cas, la métrique doit être un moyen de mesurer et de quantifier le résultat d'une méthode de classification. Dans certains cas, nos méthodes font une classification en deux classes (chute/pas chute) et, dans d'autres, à plus de deux classes (debout/couché/absent...).

2.3.1. Métriques d'évaluation d'un modèle à deux classes

Dans un modèle à deux classes (modèle binaire) on définit un événement A et son événement contraire \bar{A} , ces deux événements présentent les deux classes. C'est le cas par exemple, de la détection de chutes de la personne, on définit alors l'événement A : chute et l'événement \bar{A} : pas de chute. Un autre exemple est la classification du type de la journée de la personne, on définit alors A : une journée suivant la routine et \bar{A} : une journée s'écartant de la routine.

Les métriques calculées sont basées sur les notions classiques suivantes :

- Vérité de terrain : elle présente l'ensemble des données étiquetées à la main en étiquette positive et étiquette négative.
- Prédiction : c'est le résultat du classifieur. La prédiction peut être positive ou négative.
- Vrai positif (TP : True Positive) : lorsque la prédiction et l'étiquette sont toutes deux positives.
- Vrai Négatif (TN : True Négative) : lorsque la prédiction et l'étiquette sont toutes deux négatives.
- Faux Positif (FP : False Positive) : lorsque la prédiction est positive alors que l'étiquette est négative.
- Faux Négatif (FN : False Negative) : lorsque la prédiction est négative alors que l'étiquette est positive.

Le modèle de classification appliqué aux données permet d'établir la matrice de confusion (Tableau 2-2) qui évalue les performances du modèle. La matrice de confusion facilite la lecture des résultats grâce à une visualisation simple et nette des données de prévisions. Chaque ligne de la matrice présente le nombre d'occurrences d'une classe réelle (vérité terrain), tandis que chaque colonne de la matrice présente le nombre d'occurrences d'une classe prédite. La diagonale de la matrice présente les données correctement prédites, tandis que les autres cellules correspondent aux erreurs de prédiction.

Tableau 2-2 : Matrice de confusion.

		Prédiction	
		Positif	Négatif
Réal	Positif	TP	FN
	Négatif	FP	TN

La matrice de confusion permet alors le calcul de la précision, la sensibilité, la spécificité, le score F1 et la justesse :

- La précision, également appelée valeur prédictive positive, permet de connaître le nombre de prédictions positives bien effectuées. En d'autres termes c'est le résultat du rapport de TP et la somme de TP et FP :

$$Précision = \frac{TP}{TP + FP}$$

La précision est comprise entre 0 et 1, plus elle est élevée plus le modèle minimise l'effectif de faux positifs (FP). Lorsque la précision est proche de 1, cela signifie que la majorité des prédictions positives du modèle sont des positifs correctement prédits.

- La spécificité également appelée le taux négatif réel, elle représente le taux de détection de l'événement contraire \bar{A} . C'est le résultat du rapport de TN et la somme de TN et FP :

$$Spécificité = \frac{TN}{TN + FP}$$

- La sensibilité aussi appelée le rappel, correspond à la proportion de l'événement A à être correctement détecté. En d'autres termes la sensibilité permet de savoir le pourcentage de positifs bien prédit par le modèle. Sous forme mathématique, on a :

$$Sensibilité = \frac{TP}{TP + FN}$$

- Le score F1 aussi appelé la moyenne harmonique permet d'effectuer une bonne évaluation de la performance du modèle dans le cas d'une base déséquilibrée. En effet, bien qu'elles soient utiles, ni la précision ni la sensibilité ne permettent d'évaluer entièrement le modèle. Les deux métriques, la précision et la sensibilité sont inutiles si le modèle prédit tout le temps « positif » (la sensibilité sera élevée), ou si au contraire le modèle ne prédit jamais « positif » (la précision sera élevée) car on aura des métriques qui montrent que le modèle est efficace alors qu'il est au contraire plus naïf qu'intelligent. Le score F1 combine la précision et la sensibilité sous la forme de leur moyenne harmonique. Il se calcule ainsi :

$$\text{score } F1 = 2 \times \frac{\text{Précision} \times \text{Sensibilité}}{\text{Précision} + \text{Sensibilité}} = \frac{2 TP}{2 TP + FN + FP}$$

Plus le score F1 est élevé, plus le modèle est performant.

- Justesse (accuracy) est la probabilité des prédictions correctes (à la fois vraies positives et vraies négatives) parmi le nombre total de cas examinés. Les données bien classées se trouvent sur la diagonale de la matrice. La justesse est le rapport de la somme TP et TN à l'effectif total de la base de données composée des données à classer. La justesse se calcule ainsi :

$$\text{Justesse} = \frac{TP + TN}{TP + FN + TN + FP}$$

2.3.2. Métriques d'évaluation d'un modèle à plus de deux classes

Le passage à plusieurs classes nécessite quelques adaptations des métriques précédentes. Pour simplifier, et ne pas rendre la présentation trop générale, nous avons préféré illustrer notre propos à l'aide d'un exemple. On suppose disposer d'une base de données composée de 30 images de paysages différentes (ciel, mer, désert). Chaque image est annotée en ciel ou mer ou désert. La matrice de confusion obtenue après avoir prédit les classes est reportée (Tableau 2-3).

Tableau 2-3 : Matrice de confusion.

		Prédiction		
		Ciel	Mer	Désert
Réal	Ciel	5	1	2
	Mer	1	10	3
	Désert	2	2	4

Les données de la diagonale de la matrice présentent le nombre des images correctement classées pour chaque classe (5 images du ciel bien classées, 10 images de la mer bien classées et 4 images du désert bien classées). Les autres cases de la matrice correspondent aux confusions des classes (par exemple 3 images de la mer ont été prédites en classe désert).

La précision pour chaque classe est calculée par le rapport du nombre de la classe correctement prédit à la somme totale des prédictions pour cette classe. Par exemple, la précision de la prédiction de la classe mer vaut : $10/(1 + 10 + 2) = 76,92 \%$

De même, la sensibilité pour chaque classe est calculée par le rapport du nombre de la classe correctement prédit à la somme totale des instances pour cette classe. Par exemple, la sensibilité de la prédiction de la classe mer vaut : $10/(1 + 10 + 3) = 71,42 \%$

Le score F1 se calcule par classe en reprenant la formule du cas à deux classes.

Sur notre exemple, le tableau suivant résume le calcul de la précision de la sensibilité et du score F1 en se basant sur les données de la matrice de confusion précédente (Tableau 2-3).

Tableau 2-4 : Précision et score F1.

	Précision	Sensibilité	Score F1
Ciel	62.50%	62.50%	62.50%
Mer	76.92%	71.42%	74.06%
Désert	44.44%	50.00%	47.05%

Pour toutes les classes, on obtient en moyenne une précision d'images bien classées de 63.33% $((5+10+4)/30)$.

En conclusion, dans ce travail, lorsque l'on veut évaluer un modèle à plus de deux classes, nous retiendrons la précision, la sensibilité et le score F1. En effet, la précision ne peut identifier le déséquilibre entre les classes, c'est pour cela que l'on calcule également le score F1 qui est défini comme une moyenne harmonique de la précision et la sensibilité.

Conclusion

Ce chapitre a permis de situer l'objectif de ce mémoire (les détections des chutes et les changements de comportement) en regard des autres travaux [145], [147] menés en parallèle dans le cadre du projet ANR PRuDENCE. Afin de clarifier, nous avons également présenté les deux bases de données à notre disposition, une base de données acquise en conditions réelles en EPHAD, nommée Gladis, l'autre dans un appartement nommé Symh. Enfin, les différentes métriques d'évaluation ont été présentées. L'objectif du chapitre suivant est de présenter les travaux réalisés pour la détection des chutes et des postures par l'approche associant l'extraction des paramètres.

3. Détection de la chute et suivi du comportement de la personne âgée

Introduction

La chute des personnes âgées de plus de 75 ans est la première cause de mortalité hors maladie [1], elle représente un réel enjeu sociétal. La détection précoce de la chute permet de porter rapidement secours à la personne et de limiter les conséquences de la chute qui s'aggravent avec le temps passé au sol, qui peut des fois mener au décès de la personne. Au-delà de ces conséquences, la fréquence des chutes est aussi un marqueur très important dans l'évolution d'une personne âgée vers la fragilisation.

Pour rappel, le projet PRUdENCE a été initié suite aux premiers travaux sur la détection des chutes à partir d'images de profondeur et thermiques menés par Geoffroy Cormier dans le cadre de sa thèse Cifre [146]. Il était naturel, dans un premier temps, de s'inscrire dans la continuité de ces travaux sur la détection des chutes en nous focalisant sur les aspects de classification des images. Nous avons aussi prolongé ces travaux en proposant une première approche du suivi du comportement de la personne dans la perspective d'estimer sa fragilité.

3.1. Approche proposée

Son organisation est décrite dans la Figure 3-1 :

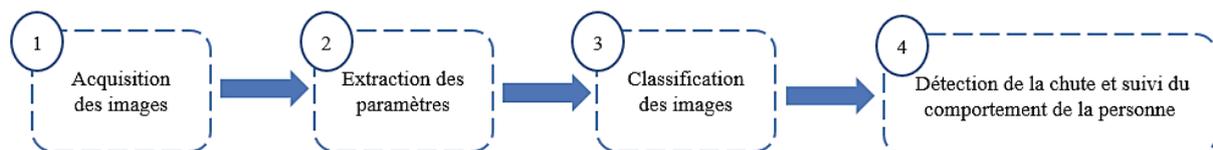


Figure 3-1 : Schéma de la détection de la chute et suivi du comportement de la personne.

A l'étape 1, les images sont enregistrées avec un capteur de profondeur et thermique comme décrit au chapitre précédent. En suivant la procédure présentée par G. Cormier [146], il est possible d'extraire automatiquement la silhouette de la personne à partir des images de profondeurs/thermique fusionnées. Le résultat en est une silhouette sur la carte de profondeur avec une information spatiale sur la personne.

L'étape 2 permet d'extraire des paramètres afin de caractériser la posture de la personne. Nous nous sommes également inspirés des descripteurs élaborés par G. Cormier dans sa thèse.

A l'étape 3, les images sont classées à partir des caractéristiques extraites. Trois approches ont été comparées : les K plus proches voisins (K-Nearest Neighbors *K-NN*), les arbres de décision (Decision Trees *DT*), et les forêts aléatoires (Random Forest *RF*).

Dans la quatrième et dernière étape, les résultats de la classification permettent de détecter la chute et de suivre le comportement de la personne. Pour tester cette approche, elle a été appliquée sur les images enregistrées dans la base de données Gladis durant 43 jours.

3.2. Acquisition des images et extraction des paramètres

On rappelle que le dispositif Gladis est composé d'un capteur de profondeur et d'un capteur thermique qui capturent au même instant t et pour la même zone spatiale, une image de profondeur et une image thermique. Comme mentionné précédemment, dans ce premier travail nous nous sommes appuyés sur les travaux de recherche de G. Cormier [146] sur la reconnaissance de la silhouette de la personne et sur l'extraction des paramètres permettant de caractériser la posture de la personne. Le principe de son approche consiste à :

- Estimer des régions où potentiellement la personne puisse être. Pour cela, une image de profondeur de la pièce vide est acquise et sert d'image de référence. Les régions d'intérêts sont celles où se trouvent de nouveaux objets par rapport à la scène de référence. Ces nouveaux objets sont soit des personnes soit des objets déplacés depuis la scène de référence.

La fusion de l'image thermique sur l'image de profondeur permet ensuite de sélectionner parmi ces régions, celle où se trouve la personne. Cela se fait en éliminant les régions qui ne présentent pas des points de chaleur et qui ne correspondent donc pas à la personne. La Figure 3-2 présente des exemples des régions sélectionnées lorsque la personne est assise au bord du lit (images a et b), est au sol (images c et d) ou est allongée sur le lit (images e et f).

- Grâce à l'image de profondeur, nous avons une information spatiale 3D pour chaque pixel de la région sélectionnée. Il est également possible d'estimer des mesures plus globales comme le centre de gravité de chaque région (croix sur les images de profondeur de la Figure 3-2). G. Cormier a également proposé une méthode d'estimation du plan du sol. Il est ainsi possible d'estimer, pour chaque pixel de la région sélectionnée sa hauteur par rapport au sol. Ces différentes informations permettent alors d'extraire des descripteurs de la posture de cette personne. Quatre descripteurs ont été retenus :
 - *Hcog* : la hauteur du centre de gravité par rapport au sol exprimée en cm ;
 - *Near* : la proportion de l'individu qui se trouve à moins d'une hauteur prédéfinie h du sol. Elle est donnée par le nombre de pixels de la région sélectionnée ayant une hauteur inférieure à h par rapport au nombre total de pixels de la région sélectionnée. *Near* est exprimée en %;
 - Les coordonnées X et Y du centre de gravité exprimées en cm.

Les paramètres *Hcog*, *Near*, X et Y sont extraits d'une région sélectionnée de l'image. La région est considérée comme un objet plan orthogonal à l'axe de visée du capteur.

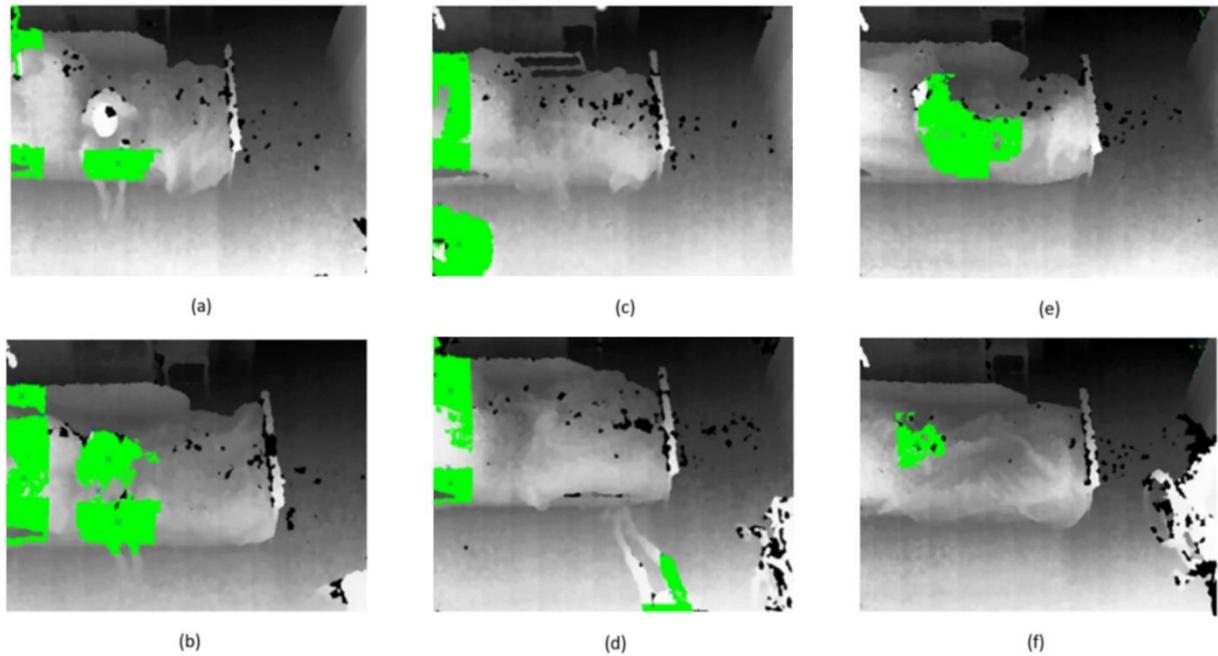


Figure 3-2 : Exemples des régions contenant une personne détectée dans les images profondeur/thermiques fusionnées et reportées sur les images de profondeur : images de la personne assise au bord du lit (a et b), images de la personne au sol (c et d) et images de la personne allongée sur le lit (e et f).

3.3. Classification des images

La prédiction de la localisation de la personne au sol ou non peut être vue comme un problème de classification basé sur les paramètres qui caractérisent la posture de la personne. Dans ce travail, trois classifieurs sont comparés : les K plus proches voisins (K -Nearest Neighbors K -NN), les arbres de décision (Decision Trees DT) et les forêts aléatoires (Random Forest RF).

K plus proches voisins

La méthode de classification par les K plus proches voisins K -NN [153] est une méthode d'apprentissage supervisé qui vise à construire des groupes de classes à partir d'un ensemble de données d'apprentissage. Les données de la base test sont classées en fonction de leur distance aux groupes (en utilisant la distance euclidienne ou une autre). Chaque donnée de la base test est associée à la classe majoritaire des K données voisines les plus proches. L'algorithme K -NN est un algorithme « non-paramétrique », seul K doit être fixé. L'avantage de cette méthode est qu'elle est très facile à mettre en œuvre.

La Figure 3-3 présente le principe du K -NN pour classer un point inconnu en vert sur la figure. Si $K=3$, le point vert est classé en triangle rouge (car l'effectif des triangles rouges est majoritaire) et, si $K=5$, le point vert est classé en carré bleu (car l'effectif des carrés bleus est majoritaire).

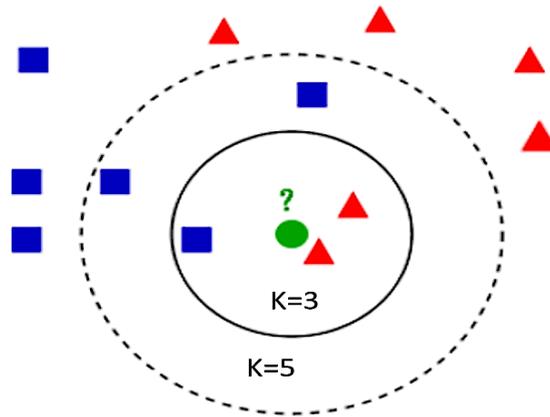


Figure 3-3 : Exemple d'un K-NN pour classer le point vert.

Arbre de décision

La méthode de classification par arbre de décision *DT* [154] permet de diviser une population d'individus en groupes homogènes selon un ensemble de critères. Les *DT* sont présentés sous la forme d'un arbre qui commence par un nœud (racine) d'où découlent plusieurs décisions (nœuds au bout des branches) selon différents critères. Chacune des nouvelles décisions peut être prise selon d'autres critères. Les nœuds finaux à l'extrémité de l'arbre (les feuilles) indiquent les classes de l'étude. Les arbres de décisions ont l'avantage d'être simples à interpréter et très rapides à entraîner.

La Figure 3-4 présente un exemple d'arbre de décision pour les différentes évolutions de l'état de la personne. Si la personne âgée a une diminution dans la capacité à effectuer ses soins personnels (réalisations des activités de la vie quotidienne comme s'habiller, se laver...) alors elle peut être diagnostiquée fragile. La bonne prise en charge de la personne âgée (des interventions thérapeutiques spécifiques) basculera son état vers la robustesse dans le cas échéant l'état de santé de la personne de la personne se dégrade pour atteindre la dépendance.

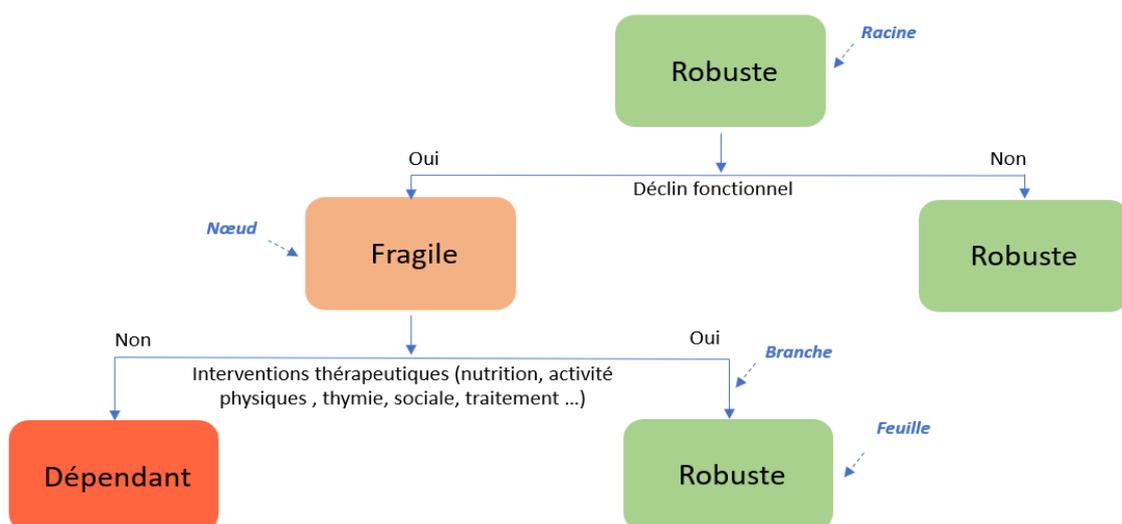


Figure 3-4 : Exemple d'un arbre de décision.

Forêts aléatoires

La méthode de classification par forêts aléatoires *RF* [155] effectue l'apprentissage sur plusieurs arbres de décision formés par des sous-ensembles de données différents. Le nombre d'arbres est ajusté par validation croisée. L'objectif de l'algorithme *RF* est de trouver la moyenne des prédictions de plusieurs modèles indépendants pour réduire la variance de l'erreur de prédiction. Les *RF* sont basés sur la méthode de bagging qui consiste à :

- Découper la base de données en plusieurs sous-ensembles aléatoires constitués d'échantillons (d'où le terme aléatoire dans « forêt aléatoire »).
- Entraîner un modèle sur chaque sous-ensemble (il y a autant de sous-ensembles que de modèles).
- Combiner les résultats des modèles (par exemple avec un système de vote) pour obtenir le modèle final.

L'expérience a montré qu'il est possible d'obtenir un modèle robuste à partir de plusieurs modèles qui ne sont pas nécessairement aussi performants. Les *RF* peuvent être utilisés en :

- Classification : lorsque la variable réponse est qualitative, l'algorithme *RF* permet de prédire l'appartenance des données à une classe d'une variable qualitative, sur la base de variables explicatives quantitatives et/ou qualitatives.
- Régression : Lorsque la variable réponse est continue, l'algorithme *RF* permet de prédire la donnée d'une variable quantitative dépendante, en fonction de variables explicatives et/ou qualitatives.

3.4. Implémentation de la méthode

3.4.1. La base de données

La méthode de détection de la chute a été implémentée et testée sur les images de profondeur de la personne B de la base Gladis pour une période d'enregistrement de 43 jours. Sur toute la période d'enregistrement, l'algorithme n'a produit qu'une seule image où la région qui correspond à la personne n'a pas été détectée (voir Figure 3-8 en fin de chapitre).

La base d'apprentissage est composée de 581 images de profondeur correspondant à une annotation en 3 classes : sur le lit (*Bed-B*), par terre (*Fall-F*) et Absent (*A*) sur 6 jours. Les classes des images par localisation et les effectifs des classes sont résumées dans le Tableau 3-1. La classe « Sur le lit » correspond aux situations où la personne est assise ou allongée sur le lit. La personne suivie étant une personne dépendante ayant des problèmes de mobilité, ceci explique que la personne n'a jamais été vue debout. Nous observons aussi qu'il existe un grand nombre d'images où la personne est absente. Cette classe n'est pas intéressante dans notre contexte puisque l'objectif est la détection de la présence au sol (chute) ou du suivi du comportement. Nous avons donc choisi d'écarter ces images dans cette première expérimentation. En conséquence, dans le cas de cette personne, le problème de classification est réduit à un problème de classification binaire « Sur le lit » et « Par terre ».

Tableau 3-1 : Effectif de chaque classe par localisation.

Classe	Localisation	Total
B	Sur le lit	273
F	Par terre	55
A	Absent	253

La base de données test pour la détection de la chute et du suivi du comportement de la personne est constituée des images enregistrées durant 37 jours consécutifs. Les images ont été également annotées pour l'évaluation des méthodes. Nous avons également écarté les images où la personne était absente. L'effectif de la base de test était alors de 3552 images.

Chaque image est décrite par les paramètres *Hcog*, *Near*, *X*, *Y* et par l'annotation de la localisation de la personne. La hauteur prédéfinie *h* pour le calcul de *Near* a été fixée à 30 cm. Cette valeur a été choisie par rapport à la hauteur du lit qui se trouve dans la chambre de la personne. La Figure 3-5 illustre l'influence de la localisation de la personne sur les paramètres.

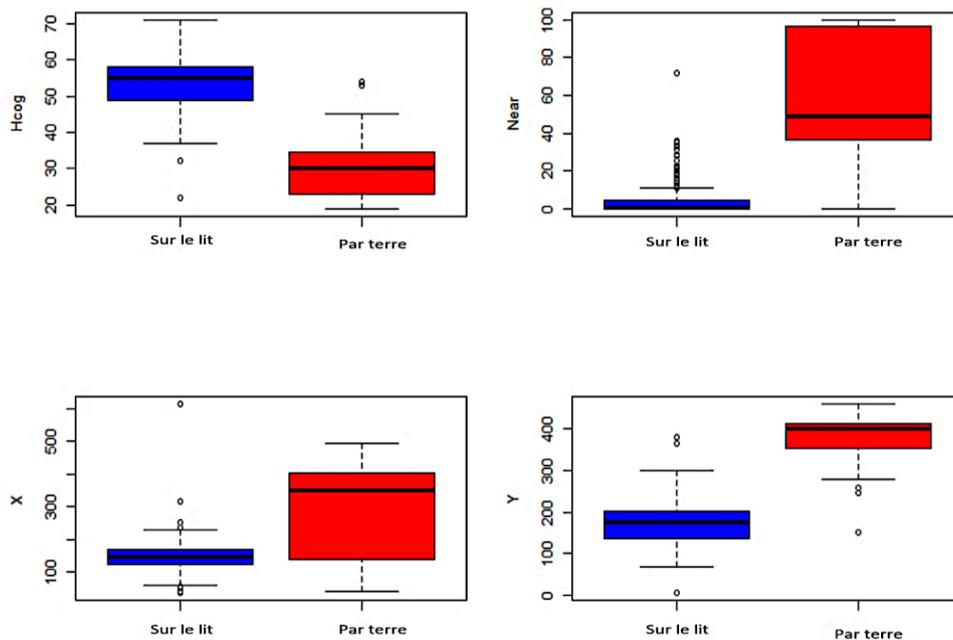


Figure 3-5 : Boxplots des paramètres des images en fonction de la localisation de la personne.

Plusieurs constats peuvent être tirés de la Figure 3-5 :

- Les médianes de la personne sur le lit et de la personne par terre sont clairement distinctes pour tous les paramètres calculés à partir de l'image.
- La variable *Near* est proche de zéro lorsque la personne est allongée sur son lit. Les valeurs non nulles de *Near* correspondent à la proportion de la personne détectée à moins de 30 cm du sol lorsque la personne est assise au bord du lit (en pourcentage).

- La médiane de la hauteur du centre de gravité H_{cog} relative au sol est plus petite lorsque la personne est sur le sol (cela a un sens car la personne est proche du sol).
- La personne sur le lit ou la personne sur le sol peuvent avoir des valeurs communes en X ou en Y . Ceci peut être expliqué par le fait que la personne tombe souvent près du lit.

Le test de Student a été appliqué pour accepter ou rejeter le fait que la moyenne du paramètre est différente pour chaque classe. Le test montre que les moyennes des deux classes sont différentes ($p < 0.001$) indépendamment des paramètres.

3.4.2. Classification des images

Pour évaluer les performances de classification des méthodes KNN , arbre de décision, nous avons créé aléatoirement 100 bases de données de la base d'apprentissage et 100 bases de données de la base test. Chaque base de données d'entraînement est composée de 246 images choisies aléatoirement, ce qui correspond à 75% de la taille de la base de données des six jours. La base de données test est composée de 82 images ce qui correspond à 25% de la taille de la base de données sans les images où la personne est absente.

3.4.2.1. Classification avec K-NN

Le nombre de voisins a été expérimentalement fixé à $k = 3$ après une étude exhaustive entre 1 et 30. Le Tableau 3-2 présente la matrice de confusion des prédictions pour chaque modalité des 100 tirages. Elle est donnée sous la forme de la médiane et interquartile $[Q1, Q3]$ des prédictions.

Tableau 3-2 : Matrice de confusion avec la classification K-NN.

		Valeurs réelles	
		<i>B</i>	<i>F</i>
Valeurs prédites	<i>B</i>	70, [66, 70]	1, [0, 1]
	<i>F</i>	1, [0, 1]	10, [11, 15]

Nous obtenons une précision de 97% d'images bien classées, une sensibilité de 90% et une spécificité de 98%.

3.4.2.2. Classification avec arbre de décision

Le Tableau 3-3 présente la matrice de confusion après prédiction sur les mêmes bases de test utilisées pour la prédiction par $K-NN$.

Tableau 3-3 : Matrice de confusion avec la classification DT.

		Valeurs réelles	
		<i>B</i>	<i>F</i>
Valeurs prédites	<i>B</i>	68, [65, 69]	1, [0, 2]
	<i>F</i>	1, [1, 2]	12, [11, 14]

On obtient une précision de 97% d'images bien classées, une sensibilité de 92% et une spécificité de 98%.

3.4.2.3. Classification avec forêt aléatoire

Comme nous avons peu de variables explicatives, nous avons utilisé un modèle avec 100 arbres et 2 variables par division pour réduire l'erreur de prédiction. Le Tableau 3-4 présente la matrice de confusion.

Tableau 3-4 : Matrice de confusion avec la classification RF.

		Valeurs réelles	
		<i>B</i>	<i>F</i>
Valeurs prédites	<i>B</i>	67	1
	<i>F</i>	0	14

Cette fois-ci, nous obtenons une précision de 99% d'images bien classées, une sensibilité de 93% et une spécificité de 100%.

3.4.2.4. Comparaison des performances des classifieurs

Le Tableau 3-5 résume les résultats de classification par les *K-NN*, les arbres de décision *DT* et les forêts aléatoires *RF*

Tableau 3-5 : Comparaison des résultats des prédictions.

	Sensibilité	Spécificité	Précision
<i>K-NN</i>	90%	98%	97%
<i>DT</i>	92%	98%	97%
<i>RF</i>	93%	100%	99%

L'analyse du tableau montre que de bonnes performances sont obtenues avec les trois méthodes de classification, avec une plus grande précision pour l'algorithme *RF* qui permet de détecter la chute avec une erreur inférieure à 1%.

3.4.3 Suivi de la personne

Dans la perspective d'identifier une trajectoire de fragilisation, le détecteur précédent a été testé pendant 37 jours dans la chambre de la personne âgée afin de suivre son comportement. Le nombre de chutes et le pourcentage de temps passé au lit sont représentés dans les figures suivantes :

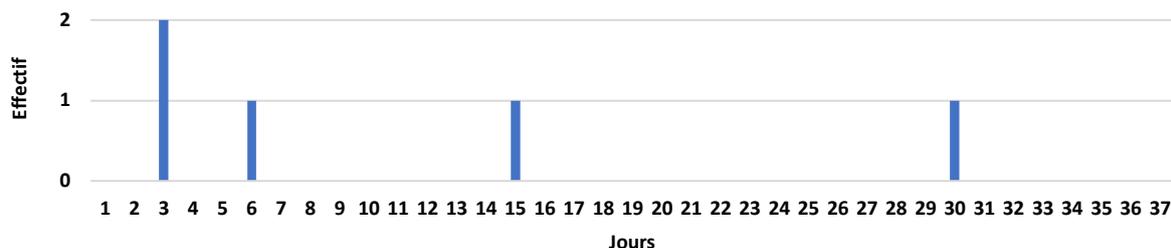


Figure 3-6 : Nombre de chutes par jour pendant une période d'enregistrement de 37 jours.

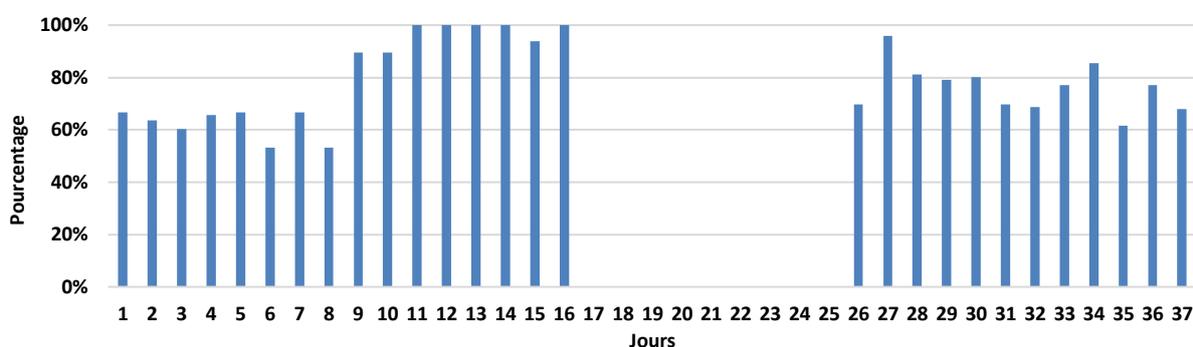


Figure 3-7 : Évolution du pourcentage du temps passé au lit par jour pendant une période d'observation de 37 jours.

Cette analyse qualitative, est intéressante et montre qu'après le 9^{ème} jour un changement s'opère dans le comportement de la personne et se traduit par une augmentation du pourcentage de temps passé au lit pendant 8 jours. Puis la personne est absente pendant 9 jours en raison d'une hospitalisation. Après le 25^{ème} jour, la personne revient avec moins de temps passé au lit qu'avant son absence. Ce bref exemple souligne l'intérêt de surveiller ces variables et suggère la possibilité de comprendre le comportement et d'anticiper tout changement soudain.

Conclusion

Dans ce chapitre, nous avons proposé la détection des chutes par la classification d'images de profondeur par K plus proches voisins, arbre de décision et forêts aléatoires. Le principe consiste à estimer la position de la personne à partir de capteurs de profondeur. Pour cela, les régions ayant subi un changement par rapport à une image statique de référence sont extraites dans l'image de profondeur. La fusion avec l'image thermique capturée au même instant que l'image de profondeur permet de distinguer la région dans laquelle se trouve la personne. Il a ensuite été montré qu'il était possible de détecter la chute à partir de variables explicatives extraites d'une région de l'image telles que les coordonnées du centre de gravité de la personne, la hauteur du centre de gravité et la proportion visible de l'individu à moins de 30 cm du sol. À partir des images de profondeur enregistrées

dans la chambre de la personne âgée, nos résultats ont montré qu'une chute pouvait être détectée par une méthode de classification avec une précision de 99%. Il est à noter que ces très bons scores sont obtenus en suivant les conseils du personnel soignant, en plus d'avoir limité l'analyse aux endroits autour du lit.

Dans un deuxième temps, un travail exploratoire nous a permis de vérifier que cette solution offrait la possibilité de surveiller les habitudes de la personne.

Toutefois, l'expérimentation en condition réelle et sur plusieurs jours a également montré que l'approche avait aussi quelques limites. En effet, en analysant les images de profondeur avec les régions sélectionnées, nous avons pu observer plusieurs erreurs qu'il convient de gérer. Certaines sont reportées ci-dessous et illustrées par les figures 3-8 à 3-11 :

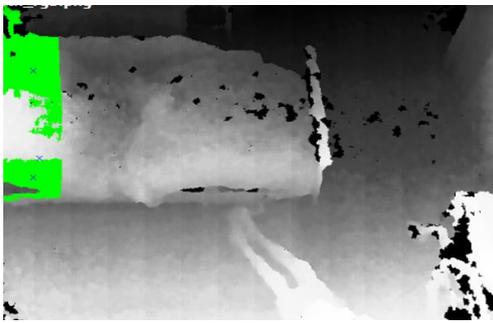


Figure 3-8 : Exemple d'erreur de sélection de région dans l'image de profondeur : la personne par terre n'est pas sélectionnée.

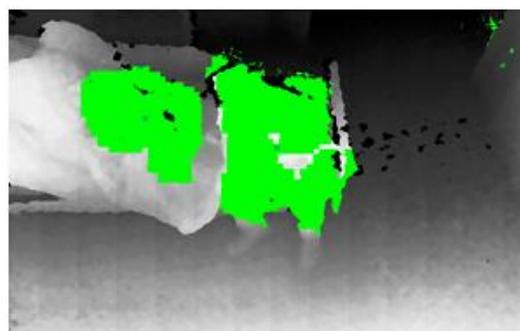


Figure 3-9 : Exemple d'erreur de sélection de région dans l'image de profondeur : les deux personnes présentes dans la chambre sont sélectionnées.



Figure 3-10 : Exemple d'erreur de sélection de région dans l'image de profondeur : La personne est occultée par les aides-soignants présents dans la pièce.

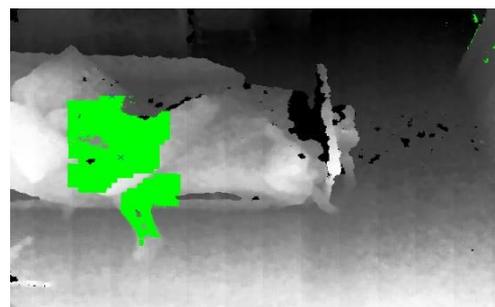


Figure 3-11 : Séparation en deux régions de la personne observée.

- 1- La Figure 3-8 montre un exemple où le système ne sélectionne pas la personne.

- 2- Le cas de présence de plusieurs personnes dans la chambre (personnel soignant ou membre de la famille) est illustré dans la Figure 3-9. Ces personnes sont alors aussi sélectionnées et il n'est alors plus possible de différencier la personne âgée des autres personnes présentes dans la pièce.
- 3- Le cas où la personne est présente derrière un élément du mobilier de la pièce ou derrière des personnes présentes dans la pièce (la personne est occultée), ou dans un angle mort du capteur. La personne est alors non détectée par le capteur (Figure 3-10). Ce problème peut être résolu grâce à un travail conduit en parallèle du nôtre dans le cadre du projet Prudence par Halima et al. [147]. Portant sur le suivi dynamique de la personne, ce travail pourrait être utilisé afin d'expliquer l'occlusion de la personne ou la sortie du champ du capteur.
- 4- Dans certains cas, une séparation de la personne en deux régions peut être observée (Figure 3-11). Cette séparation en une région supérieure et une région inférieure du corps peut être expliquée lorsque l'individu observé s'assied sur son lit. En effet, il peut s'enfoncer suffisamment pour que son giron se trouve en deçà du seuil de détection d'objets dans la carte de profondeur. Il convient alors soit de connecter ces deux régions à l'aide de l'information thermique, soit d'éliminer la région ayant la caractéristique *Near* la plus petite (la région qui correspond à la partie inférieure du corps) afin d'indiquer que la personne n'est pas au sol.

Les quelques limites et erreurs reportées en synthèse ci-dessus soulignent que la méthode ne peut être appliquée telle quelle. Ceci explique que dans le chapitre suivant, une alternative de détection de la chute et des postures est proposée. Pour cela, nous avons voulu nous appuyer sur les intéressants résultats obtenus par les approches basées sur le deep-learning reportés dans la littérature.

Cependant malgré ses limites, le travail décrit dans le présent chapitre a permis de montrer l'intérêt des capteurs de profondeur pour identifier et suivre les postures dans une perspective d'identification du changement du comportement d'une personne.

4. Détection des chutes, des postures et de l'absence de la personne

Introduction

Le principe de notre système de détection du comportement est basé sur l'extraction des différentes postures et sur le postulat que ces postures se répètent régulièrement chaque jour (moyennant bien sur quelques variations/déformations) pour signer un comportement régulier. Ce chapitre a donc pour objectif de présenter l'architecture que nous avons proposée pour la détection des postures et qui alimentera alors le processus de détection du changement de comportement de la personne âgée.

Après une définition des postures et de leur association avec des activités, ce chapitre présentera les différentes approches qui ont été proposées pour la reconnaissance des postures au travers d'un état de l'art. Puis nous détaillerons l'approche à base de réseau de neurones convolutifs que nous avons mise en œuvre pour la reconnaissance des postures. Bien que déjà largement exploitée dans le domaine du traitement d'images, une présentation décrivant les grandes étapes d'une méthode de deep-learning sera proposée permettant d'explicitier certaines définitions. Ensuite, l'implémentation que nous proposons sera détaillée. Elle reprendra succinctement la présentation de la base de données décrite au chapitre 2 et reportera les performances de reconnaissance des postures, des chutes et d'absence de la personne pour différentes conditions d'apprentissage. L'objectif étant de montrer la stabilité et la robustesse des résultats de la reconnaissance.

4.1. Reconnaissance des postures et des activités

4.1.1. Choix de la reconnaissance des postures pour définir une activité

La reconnaissance de l'activité est présente dans différents domaines tels que la production industrielle (la robotique) [156] , la surveillance visuelle [157]. Elle a cependant connu un essor important dans le suivi des personnes âgées [158] et en médecine [159]. La reconnaissance des postures qui lui est associée est donc fondamentale. En effet, la connaissance des postures est nécessaire pour caractériser certains comportements [160] comme la sédentarité. Cette dernière correspond à une activité physique faible ou nulle avec une dépense énergétique proche de zéro et le temps passé allongé sur le lit et/ou assis sur une chaise est un très bon indice de la sédentarité.

L'objectif principal de la reconnaissance de l'activité de la personne âgée consiste à fournir des informations sur le comportement de la personne afin de répondre au mieux aux besoins de la personne et/ou lui apporter l'aide nécessaire de manière proactive.

Une activité est une tâche réalisée par la personne durant un intervalle de temps. Dans la littérature, on distingue sept groupes d'activités (Tableau 4-1) [161]. Il est à noter que les groupes ne sont pas disjoints. Chaque activité peut être réalisée indépendamment des autres activités ou simultanément à une ou plusieurs activités, comme manger un sandwich et marcher.

Tableau 4-1 : Différents types d'activités.

Groupe	Activités
Déplacement	Marcher, courir, s'asseoir, debout, monter et descendre un escalier, s'allonger, prendre l'ascenseur, prendre l'escalier mécanique .
Transport	Monter dans un bus, faire du vélo, conduire.
Utilisation du téléphone	Envoyer un message , passer un appel.
Activités quotidiennes	Manger, boire, travailler sur l'ordinateur, regarder la télévision, lire, se brosser les dents, frotter, passer l'ordinateur, s'étirer.
Exercice physique	Faire de l'aviron, soulever des poids, tourner, marcher rapidement, faire des pompes.
Activités militaires	Ramper, s'agenouiller, évaluer la situation et ouvrir une porte.
Mouvement du haut du corps	Mâcher, parler, avaler, soupir et bouger la tête.

À un plus haut niveau, Aggarwal et al. [162] ont classé quatre catégories d'activités de la personne selon leur complexité :

- 1- Les gestes : Ils représentent les mouvements élémentaires du corps humain comme tourner la tête ou lever la main.
- 2- Les actions : Elles représentent les activités simples. Elles sont composées d'un ensemble de gestes réalisés durant un intervalle de temps (s'asseoir, s'allonger, marcher, ...).
- 3- Les interactions : Elles représentent des activités qui interagissent avec des personnes ou/et des objets. A titre d'exemple, deux personnes qui déplacent un bureau est une interaction qui implique un objet et deux personnes, et une personne qui joue au ballon est une interaction qui implique un objet et une personne.
- 4- Les activités de groupe : Elles représentent les activités réalisées par plusieurs individus et/ou objets (un groupe de jeunes qui jouent au football).

Dans notre travail, nous nous intéressons aux activités car elles décrivent bien le comportement de la personne âgée. Ceci explique pourquoi nous nous sommes centrés sur : i) la détection des activités par la détection des postures (*assis*, *allongée* et *debout*), ii) la détection de la *chute* et iii) la présence ou *absence* de la personne. En effet, lorsque la personne réalise une activité, elle s'approprie une certaine posture. Ceci peut être illustré par ces deux exemples triviaux : lorsque

la personne marche elle est *debout*, lorsqu'elle dort, elle est *allongée*. Chaque activité est alors traduite par une succession de posture. Comme la personne âgée suit une routine quotidienne des activités [163], et que les activités sont traduites par des postures, par conséquent la personne âgée suit une routine quotidienne des postures. Le Tableau 4-2 présente quelques exemples d'activités qui sont traduites par des postures. Il est important de rappeler ici que les postures *assis*, *allongé*, ou *debout* sont capturées par des caméras de profondeurs afin de préserver l'anonymat de la personne.

Tableau 4-2 : Exemple des activités de la personne représentées par des postures

Postures	Activités de la personne
Assis	Manger à table (assise sur la chaise pour prendre petite déjeuner, le déjeuner et le diner). Naviguer sur internet (assise sur la chaise du bureau). Regarder la télévision (assise sur le canapé). Lire (assise sur le canapé ou sur la chaise du bureau)
Allongée	Dormir (allongée sur le lit ou la canapé) Lire (allongé sur le lit ou le canapé)
Debout	Marcher Préparer à manger Passer l'aspirateur Ouvrir la porte Laver la vaisselle

La reconnaissance des postures est donc un des points clé de notre travail. L'état de l'art, nous montre qu'il existe plusieurs méthodes pour la reconnaissance des postures, certaines méthodes utilisent les capteurs portables [164], [165] tels les capteurs de pressions [166] ou les accéléromètres [167]. D'autres méthodes exploitent directement la vidéo, des images thermiques ou des images de profondeur [168].

En utilisant des capteurs de pression, Faubert et al. [166], obtiennent une précision de 100% pour la reconnaissance des postures allongée et assise avec un taux d'échec très faible pour les transitions posturales. Leur base de données est composée de participants jeunes et de personnes âgées en bonne santé mais aussi de personnes âgées souffrant des séquelles d'une fracture de la hanche et/ou encore après un accident vasculaire.

Dans leur étude, Babu et al. [167] ont utilisé des accéléromètres pour la détection de la chute, et des informations sur les postures et les activités. Ils ont obtenu des résultats avec une précision d'au moins 95%.

L'une des difficultés de la mise en œuvre des accéléromètres est liée à l'orientation du capteur et à son emplacement [169]. De plus, on ne sait pas si une position unique suffit pour capturer les mouvements humains pour définir les activités, ou si la combinaison de plusieurs capteurs placés dans des positions différentes est nécessaire. Ces constats rendent l'acceptabilité des accéléromètres encore difficile en particulier lorsque le nombre des dispositifs à porter augmente. S'ajoute également la complexité d'établir les lois de fusion de plusieurs types de capteurs provenant de positions différentes.

En ce qui concerne l'analyse des images, certaines recherches se basent sur l'analyse du squelette pour la reconnaissance des postures. Riahi et al. [170] proposent une méthode de reconnaissance des postures à partir des images de profondeur. Un modèle de squelette est estimé de l'image de profondeur et il est utilisé pour représenter les postures : *debout*, *penché*, *assis*, *marche*, et *accroupi* (Figure 4-1). La configuration du squelette humain est ensuite analysée dans l'espace 3D pour calculer les caractéristiques basées sur les articulations (Figure 4-2). Les cinq postures sont ensuite classées par SVM (Support Vector Machine). Sur une base de données composée de 10 personnes, des précisions de 86% sont obtenues pour la posture *debout*, 88% pour la posture *penchée*, 86% pour la posture *assise*, 87% pour la posture *marche* et 79% pour la posture *accroupie*. La difficulté de ce type d'approche est qu'il faut utiliser des algorithmes de traitement d'images pour extraire le squelette avant de reconnaître la posture. Ces algorithmes sont assez performants lorsque la personne est de face et assez proche de la caméra (dans le cas des jeux par exemple). Toutefois dans notre cas la caméra est placée au plafond et balaye toute une chambre.

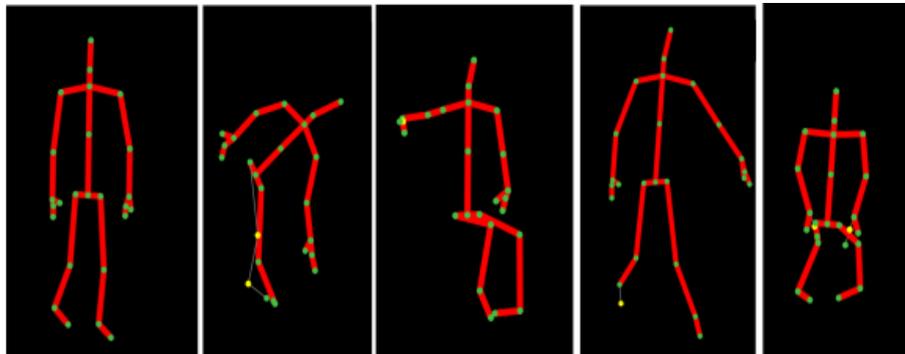


Figure 4-1: Exemples de squelettes de corps. De gauche à droite : debout, penché, assis, marche, et accroupi [170].

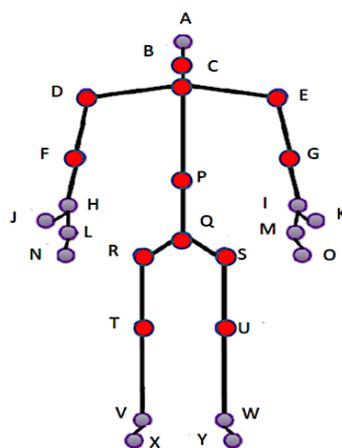


Figure 4-2 : les articulations 3D définissant le squelette [170].

Adhikari et al. [171] ont proposé un réseau de neurones convolutif pour la reconnaissance des postures (*debout*, *assise*, *allongée*, *penchée* et *ramper*) basées sur des images de profondeur. Les auteurs indiquent que l'identification des activités et leur succession est essentielle pour la détection de la chute. Par exemple, une séquence de postures qui se termine par une posture allongée peut être considérée comme une chute, alors que la séquence de postures dont la posture finale n'est pas la posture allongée peut être considérée comme un événement sans chute. La détection de la chute qui conduit souvent à une position allongée est différente de s'allonger sur le lit et dormir. La base de données de l'étude est composée de 21499 images acquises à la suite du suivi de 5 personnes dans 5 chambres différentes. Ils ont obtenu une précision globale de 74%, une sensibilité de 99% pour la position *allongée*, 80% pour la position *debout*, 53% pour la position *assise* et de très mauvais scores pour la position *penchée* (2%) et pour la position *ramper* (0%).

Yu et al. [172] ont également, dans leur recherche, un réseau de neurones convolutifs pour la reconnaissance des postures *debout*, *assise*, *allongée* mais sur des silhouettes de corps humain. La précision globale est de 96.88% sur une base de données composée de 804 images de personnes en position *debout*, 810 *allongées*, 833 *penchées*, 769 *assises*.

La détection de la *chute* et la reconnaissance des activités (s'asseoir, marcher, se lever, s'accroupir, s'allonger sur un canapé, tomber, se pencher et se coucher) à partir des images enregistrées par des capteurs de profondeur ont également été abordées par Dubois et al. [168]. La reconnaissance utilise un modèle de Markov cachés (HMM) pour la détection des chutes. Vingt-six personnes ont participé à cette étude. Les auteurs ont obtenu de bons résultats, sept de ces huit activités ont été correctement détectées (spécificité et sensibilité supérieures à 90%, dont la *chute* qui a été détectée sans faux positifs). Par contre ils ont obtenu une sensibilité de 0% et une spécificité de 100% pour l'activité « se pencher ».

Kimet al. [173] ont utilisé un HMM pour reconnaître l'activité « manger ». Un exemple des états cachés qui décrivent l'activité « manger » est présenté dans la Figure 4-3 (a). Chaque état génère une séquence d'observation. Sur cet exemple, l'activité « couper la viande » génère l'observation « couteau » (voir Figure 4-3 (b)).

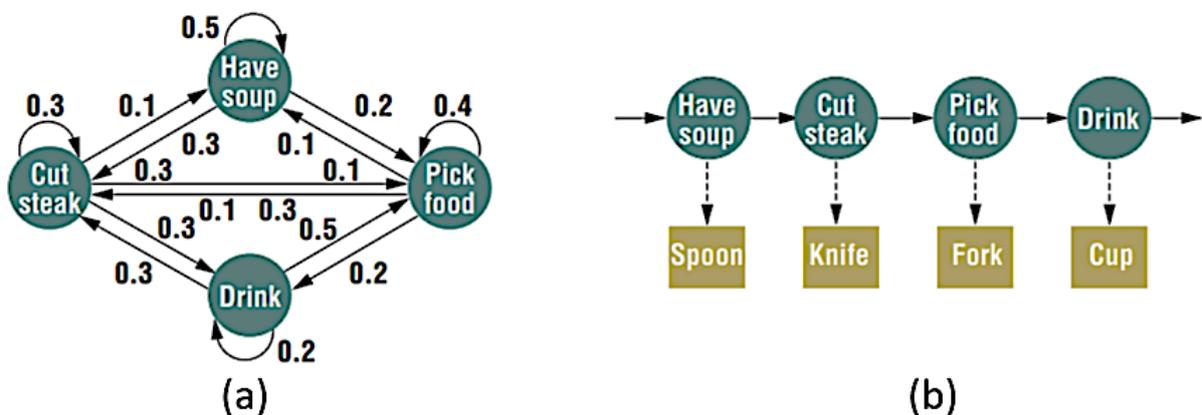


Figure 4-3 : Exemple de la reconnaissance de l'activité manger avec HMM [173].

Kolekar et al. [174] ont aussi proposé des modèles de Markov pour la reconnaissance de certaines activités dans des enregistrements de vidéos. Ils ont obtenu des performances très intéressantes. Un taux de reconnaissance de 100 % pour les activités de la « marche » et du « lever les mains », 90% pour l'activité « se pencher » et 84.61 % pour l'activité « courir ».

Enfin, dans le cadre du projet PRuDENCE, Halima et al.[147] ont classé et localisé les postures dans des images de profondeur et thermiques en utilisant des méthodes d'apprentissage profond supervisé sur le réseau SSD. Les postures à reconnaître étaient : *allongé par terre*, *allongé sur le lit*, *assis* et *debout*. Sur une base de données composée de 1297 couples d'images, l'association des deux types d'informations thermique et des profondeurs ont permis d'atteindre une précision supérieure à 98%.

Ces travaux présentés succinctement montrent que différents capteurs et différentes approches ont été développés pour reconnaître les postures. Certains se basent sur l'accélérométrie, d'autres sur les images de profondeur ou thermique. Dans notre étude, nous avons voulu mesurer l'apport des réseaux de neurones convolutifs pour la reconnaissance des postures (*assis*, *allongée*, *debout*), la détection de chute et la détection de l'absence de la personne dans la pièce. Ce réseau de neurones constitue donc la pierre angulaire de notre approche de reconnaissance des postures. Il est détaillé dans le paragraphe suivant.

4.1.2. Caractéristiques d'un réseau de neurones à convolution

L'apprentissage profond est un sous-ensemble de l'apprentissage automatique (machine learning). Il est constitué de réseaux de neurones comportant un certain nombre de couches. L'unité de base d'un réseau de neurones est le perceptron ou le neurone. Un neurone possédant N entrées est défini de la façon suivante :

$$Y = F\left(\sum_{i=0}^N w_i \cdot x_i + b\right)$$

Y représente la sortie du neurone, w_i est le poids d'une des entrées, x_i est l'entrée correspondante, b est un biais et F est la fonction d'activation qui est généralement non linéaire. La fonction d'activation F est une fonction qui s'applique avant la sortie du neurone. Cette unité de base est ensuite regroupée pour former différentes couches qui vont être empilées pour former l'architecture globale du réseau. Un réseau de neurones est donc composé de trois éléments :

- 1- Une couche d'entrée
- 2- Une ou plusieurs couches intermédiaires
- 3- Une couche de sortie

Le choix du type de couche est guidé par la tâche à résoudre. La couche pleinement connectée est parmi les premières couches proposées. Cette couche est composée d'un ensemble de neurones où chaque neurone prend en entrée toutes les sorties des neurones des couches précédentes.

Le réseau de neurones à convolution (on l'appellera directement CNN ou ConvNet par la suite) [175] est un algorithme d'apprentissage profond. Il est principalement utilisé pour l'analyse des images. L'intérêt du CNN est que le prétraitement requis est moins important que pour les autres réseaux de neurones. Le rôle du réseau est de réduire les images en une forme simple à traiter, en

préservant les caractéristiques identifiantes des motifs et des formes dans les images [176] afin de maximiser la précision de la prédiction.

L'architecture d'un CNN est inspirée de l'organisation du système visuel (plus particulièrement du fait que certains neurones de nos champs visuels ne réagissent qu'aux bordures verticales et d'autres aux bordures horizontales ou diagonales). L'architecture du CNN est composée de quatre couches principales (Figure 4-4) la couche convolutive, la couche de mise en commun (pooling), la couche d'aplatissement (flattening) et une couche entièrement connectée (fully-connected). Quelques couches peuvent se répéter avant la sortie du réseau. L'augmentation du nombre des couches rend le réseau plus profond. L'intérêt est que le réseau acquiert d'autres caractéristiques complexes de l'image d'entrée [177], [178]. À l'entrée du réseau, on place des images avec une résolution de 8 bits, chaque image est ainsi traduite par un tableau de valeurs comprises entre 0 et 255. À la sortie du réseau, on a une classe unique ou une probabilité d'appartenance à la classe qui caractérise l'image.

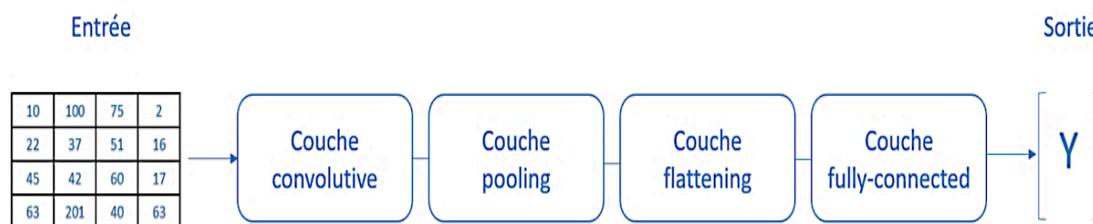


Figure 4-4 : Architecture d'un réseau de neurones à convolution.

La couche convolutive

Chaque couche convolutive subit trois opérations principales : la convolution, la normalisation spatiale par lot et une correction (Figure 4-5)

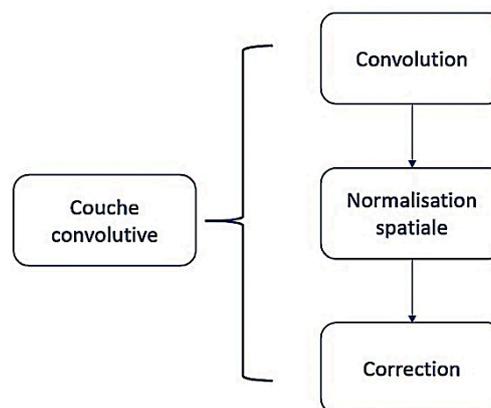


Figure 4-5 : les opérations principales de la couche convolutive.

La convolution d'une image est une opération qui consiste à faire glisser sur l'image un filtre d'une taille donnée en calculant à chaque position la somme du produit scalaire entre le vecteur de la valeur des entrées et le vecteur des poids associés du filtre. Les filtres peuvent avoir plusieurs dimensions et contenir des motifs différents pour définir les différentes caractéristiques de l'image [179]. La Figure 4-6 montre un exemple de cette opération ainsi que la sortie du filtre pour six positions

après avoir déplacé le filtre de 1 pixel [180]. A la fin de l'opération on obtient une carte de caractéristiques.

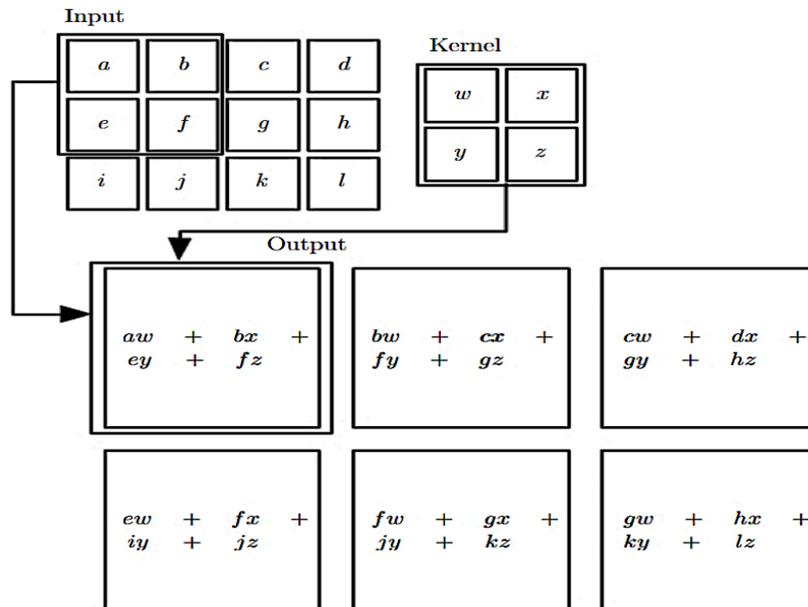


Figure 4-6 : Présentation de l'opération de la convolution [180].

La normalisation spatiale par lot est une opération appliquée après chaque convolution afin de normaliser les formats des images car les images peuvent avoir différentes dynamiques. La normalisation spatiale par lot consiste à calculer la moyenne μ et l'écart type σ d'un lot d'entrées d'images. Ensuite pour chaque valeur de la carte de caractéristiques, celle-ci est normalisée en fonction de μ et σ :

$$y = \frac{x - \mu}{\sigma + 0.001}$$

La valeur 0.001 est ajoutée à σ pour éviter le cas où σ est nul.

La correction est la dernière opération de la couche convolutive qui permet d'améliorer l'efficacité du traitement par le biais des fonctions d'activation. Ces fonctions sont utilisées pour introduire la non-linéarité dans le CNN dans le but d'obtenir des propriétés distinctes de l'entrée pour l'apprentissage. La correction ReLU (abréviation de Unité Linéaire Rectifiée) est l'opération la plus utilisée, elle est appliquée par pixel et consiste à remplacer toutes les valeurs négatives par zéro [181] :

$$F(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{sinon} \end{cases}$$

Ils existent d'autres fonctions d'activation, mais ReLU reste la plus populaire car elle est simple à calculer et donne d'excellents résultats.

La couche de pooling

Le pooling est une forme de sous-échantillonnage de l'image. Cette étape a pour objectif de regrouper et de réduire le nombre de paramètres, et aussi de réduire la taille spatiale du modèle et ainsi de contrôler le sur-apprentissage. Parmi les techniques couramment utilisées, on trouve le max pooling [182] qui consiste à conserver la valeur maximum à l'intérieur d'une fenêtre spatiale comme illustrée sur une fenêtre spatiale 2 x 2 dans la Figure 4-7:

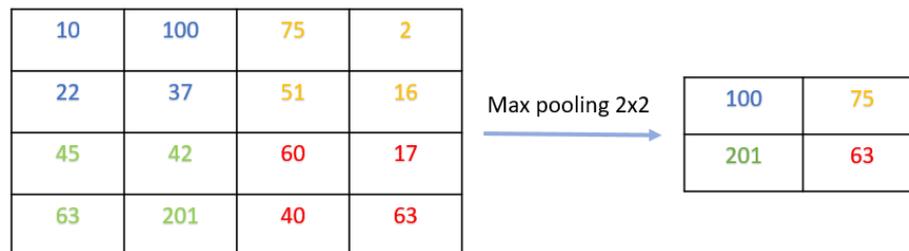


Figure 4-7: Exemple de max pooling.

Ils existent d'autres approches moins populaires que le « max pooling » telles que « l'average » et « la sum ». Suivant le même principe, « l'average pooling » consiste à calculer la moyenne des éléments et la « sum pooling » la somme des éléments de la fenêtre. Le pooling permet de rendre la présentation interne invariante aux petites translations des entrées. Le pooling est aussi utile pour gérer des entrées de taille variable. La réduction spatiale définie par le pooling réduit le nombre d'opérations nécessaires dans les couches suivantes et par conséquent accélère l'entraînement.

La couche de flattening

A cette étape tous les tableaux bidimensionnels sont convertis en un seul long vecteur aplati comme l'illustre la Figure 4-8. Cette étape sert de préparation des données à la couche fully connected

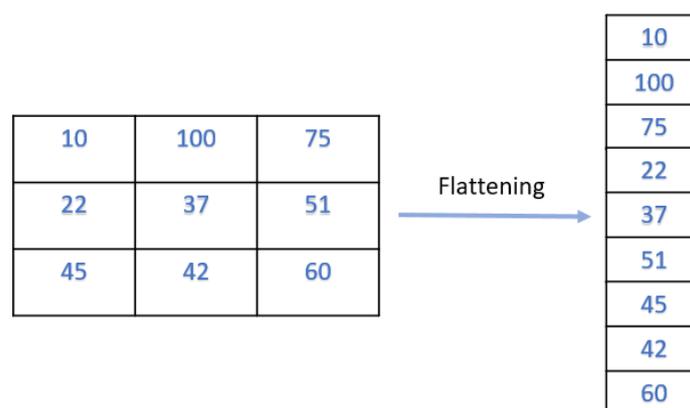


Figure 4-8 : Exemple de flattening.

La couche fully connected (FC)

La couche entièrement connectée « Fully connected layer, FC » est une couche composée d'un ensemble de neurones où chaque neurone prend en entrée toutes les sorties des neurones de la couche précédente (Figure 4-9). L'objectif de la couche entièrement connectée est d'utiliser les caractéristiques des couches convolutives et de pooling de l'image d'entrée dans différentes classes en fonction de la base d'apprentissage. Les caractéristiques présentées par les couches convolutives et pooling sont empilées dans la couche pleinement connectée. Ces caractéristiques sont toutes connectées à la sortie. Les couches entièrement connectées permettent d'extraire des caractéristiques plus complexes en utilisant plusieurs couches pleinement connectées. La fonction d'activation softmax est souvent utilisée sur la dernière couche de sortie pour prédire la classe d'appartenance de l'image. La fonction Softmax calcule la probabilité d'appartenance à une classe à partir des scores c de la couche entièrement connectée, soit :

$$\sigma_{c_i} = \frac{e^{c_i}}{\sum_i c_i}$$

Ensuite la vraisemblance (plus exactement le logarithme de la vraisemblance) est estimée à ces probabilités pour calculer la perte d'entropie croisée. La valeur maximale des probabilités représente l'étiquette de la classe de sortie [183].

L'apprentissage consiste alors à modifier les éléments constitutifs du réseau, tels que les poids et les cartes des caractéristiques, de manière répétée afin que le réseau atteigne les performances optimales qui lui permettront de classer les images avec la plus grande précision possible. Pour cela un optimiseur (classiquement l'optimiser Adam) modifie les différents éléments afin de minimiser une couche appelée couche de perte (loss) qui mesure la ressemblance entre la vérité terrain et la prédiction. Parmi les différentes fonctions utilisées pour mesurer la ressemblance de la perte par entropie croisée sigmoïde est une des plus utilisées.

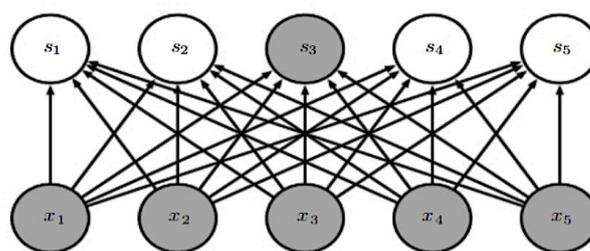


Figure 4-9 : Couche entièrement connectée (x_i entrée et s_i sortie).

Le réseau de neurones CNN représenté par la Figure 4-10 suivante synthétise les paragraphes précédents.

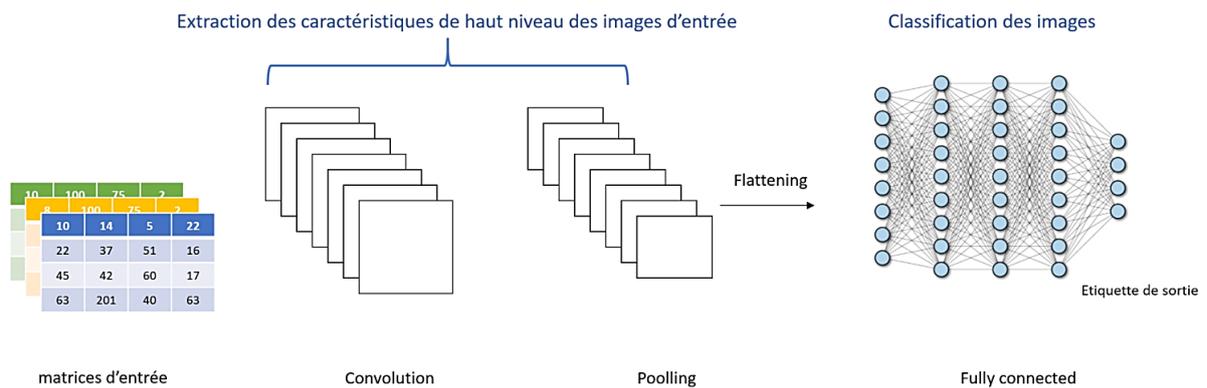


Figure 4-10: Processus d'un réseau CNN.

En 2012, le premier réseau de neurones convolutif proposé par Krizhevsky et al. [184] a remporté la compétition ImageNet¹⁰. L'architecture de ce réseau nommé AlexNet a révolutionné le monde de la vision. Brièvement, AlexNet est composée de 8 couches dont les 5 premières couches sont convolutives et les 3 restantes sont des couches entièrement connectées. La première couche convolutive utilise 96 filtres de dimensions 11 x 11 et un pas de 4 pixels. La deuxième couche qui prend en entrée la sortie de la première, comprend 256 filtres de dimensions 5 x 5 et utilise un pas de 1 pixel. La troisième et la quatrième couche exploitent 384 filtres de dimensions 3 x 3 et un pas de 1 pixel. La cinquième et la dernière couches convolutives comprennent 256 filtres de tailles 3 x 3 et utilisent un pas de 1 pixel. Concernant les couches entièrement connectées, la première et la deuxième ont chacune 4096 neurones et la dernière 1000 neurones. Le nombre de neurones de la dernière couche entièrement connectée est souvent modifié pour s'adapter au problème.

Plus récemment en 2015, a été proposée l'architecture ResNet (Residual Network), qui est plus performante que AlexNet. L'architecture ResNet [185] est devenue très populaire et très utilisée grâce aux très bonnes performances obtenues, ainsi qu'à la facilité d'entraîner ce type de réseau. En 2015, cette architecture a aussi remporté la compétition ImageNet et obtenu la première place dans la compétition proposée par ILSVRC¹¹. On a en effet constaté que pour le réseau AlexNet, plus le nombre de couches (c'est-à-dire plus il est profond) est élevé plus les performances s'améliorent. Cependant, il existe une limite à la profondeur et les performances tendent à se dégrader au-delà d'une certaine profondeur [185]. Ce problème a été résolu par les auteurs de ResNet en proposant des connexions par saut. La connexion par saut consiste à relier les différents niveaux du réseau par des connexions identitaires. Soit $F(x)$ une fonction qui présente la sortie d'une ou plusieurs couches successives. La connexion par saut recopie les valeurs d'entrée x , additionnées à la sortie de cette même couche :

$$F(x) = F(x) + x$$

¹⁰ ImageNet est une organisation qui possède une base de données (des images annotées) destinée aux travaux de recherche en vision par ordinateur.

¹¹ ILSVRC ImageNet Large Scale Visual Recognition Challenge est une compétition annuelle où les équipes de recherche évaluent leurs algorithmes de traitement d'images sur des données d'ImageNet.

Une hypothèse émise par les auteurs du réseau ResNet est de considérer la sortie $F(x)$ comme un résidu. L'idée est d'attribuer à ce résidu la valeur zéro par un algorithme d'apprentissage dans le cas où la connexion est identitaire. Le réseau évite ainsi d'apprendre une succession de couches non-linéaires comme dans le cas d'un réseau normal.

ResNet-18 [186] est une version de ResNet à 18 couches (Figure 4-11). C'est un réseau CNN composé exclusivement de couches convolutives (17 couches) et contient des connexions résiduelles toutes les 2 couches. Il associe :

- Des convolutions suivies de normalisations, de « pooling » et /ou d'unité linéaire rectifiée
- Des phases « dropout » dans lesquelles une partie aléatoire de neurones est désactivée pour forcer le réseau CNN à s'adapter à un manque d'informations.
- Des phases « sum » qui consistent à ajouter des données
- Une couche entièrement connectée (FC)
- Un algorithme Softmax qui normalise le vecteur de sortie pour calculer des probabilités dont la somme est un.

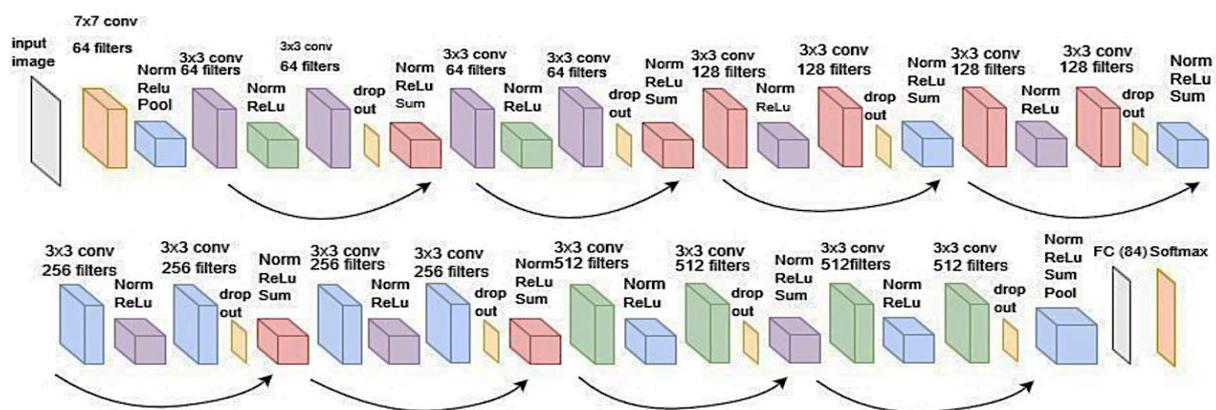


Figure 4-11 : Architecture ResNet-18.

Étant données les bonnes performances reportées dans la littérature par ce réseau, nous avons choisi cette architecture pour classer les images de profondeur de nos bases de données. L'objectif était donc de classer les postures *assise*, *allongée*, *debout*, *les chutes* et *l'absence*. Comme déjà mentionné, la prédiction de ces classes est indispensable pour rechercher les changements de comportement de la personne âgée.

4.2. Implémentation d'un réseau de neurones à convolution pour la reconnaissance des postures

Les étapes pour la reconnaissance des postures (assis, allongée, debout), de la chute et l'absence de la personne appliquées sur des images de profondeur sont décrites dans la Figure 4-12. La première étape consiste à acquérir une base de données composée de différentes postures (assis, allongée, debout), de chute et d'images où la personne est absente. La base de données a ensuite été divisée en deux parties, la base d'apprentissage et la base test. Pour répondre au problème lié à la taille des classes, la troisième étape procède à l'augmentation de la base de données par effet miroir, par occultation et par ajout d'un bruit blanc. La prédiction des images est ensuite réalisée par le réseau de neurones ResNet-18.

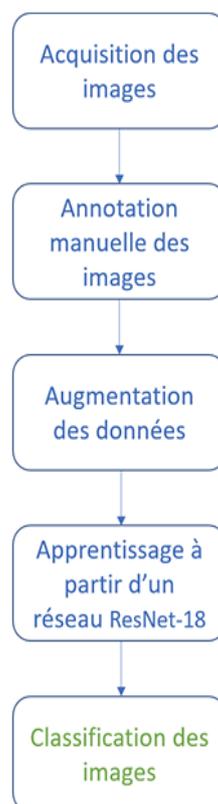


Figure 4-12: Schéma de la classification des postures.

4.2.1. Augmentation des données

Les bases de données ont été décrites dans le paragraphe 2.2. Les images ont une taille de 640x480. Avant d'introduire les images dans le modèle ResNet-18, elles sont redimensionnées 224x224. Par ailleurs, les images de 8 bits sont normalisées entre -1 et 1.

Afin de disposer de plus de données d'apprentissage et d'éviter le sur-apprentissage, nous avons procédé à l'augmentation des données. Cette méthode permet d'accroître artificiellement le nombre d'images en se basant sur les images de la base d'apprentissage déjà étiquetées. Des modifications sont introduites en appliquant : une occultation (un carré de taille aléatoire masque une partie de l'image), ou un effet miroir (l'image est inversée) ou encore en ajoutant du bruit gaussien aux images d'apprentissage. L'objectif est de permettre au modèle de détecter des comportements susceptibles d'apparaître dans l'ensemble des images de la base test. D'autres modifications pourraient être appliquées aux images comme : le retournement, une translation, un changement de la luminosité mais ces dernières n'ont pas été appliquées. La Figure 4-13 présente trois exemples de transformations respectivement l'occultation, l'effet miroir et l'ajout du bruit gaussien sur une image où la personne est debout. Bien qu'introduisant des transformations, la même posture (*debout*) reste identifiable à l'œil nu.

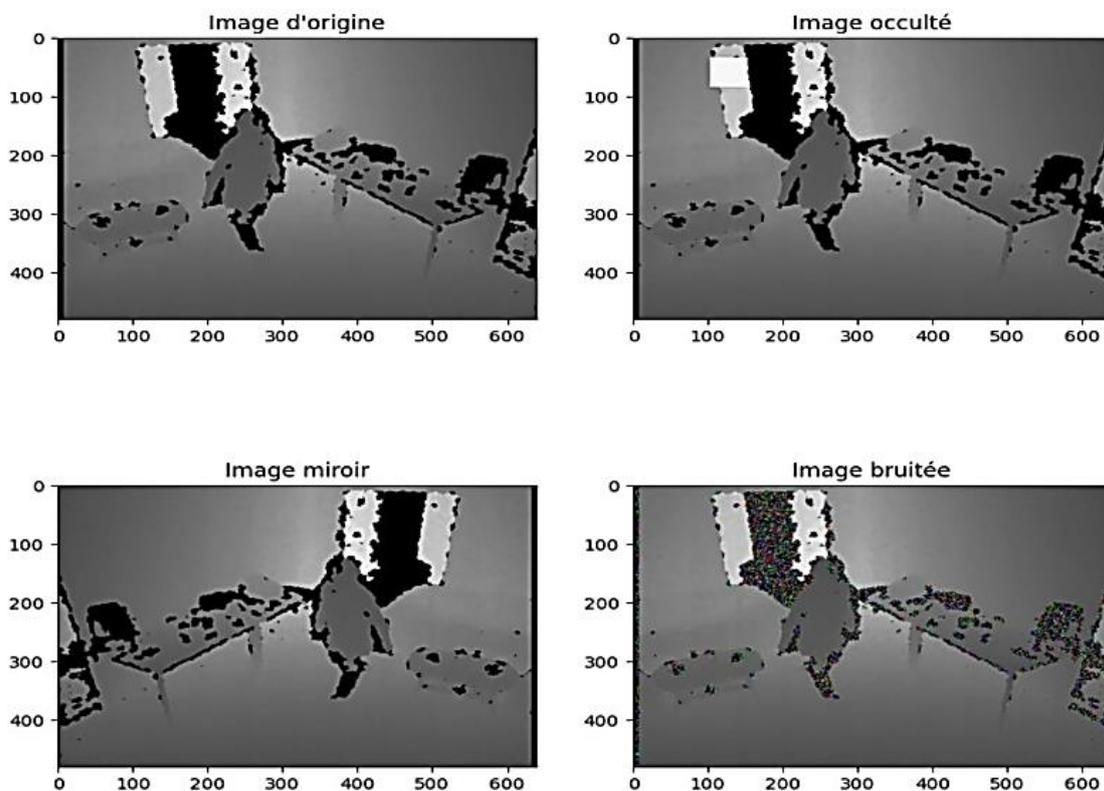


Figure 4-13 : Exemple d'augmentation de donnée.

4.2.2 Résultats de la classification

4.2.2.1. Implémentation retenue

L'architecture du réseau ResNet-18 utilisé pour la classification est reportée dans le Tableau 4-3. Les images de profondeurs sont placées à l'entrée du modèle et les prédictions sont données à la sortie du modèle. Le premier module extrait les caractéristiques peu profondes avec un noyau 7×7 , 64 filtres et un pas de 2. Les autres modules sont composés de couches convolutives avec un noyau 3×3 . Le dernier module $conv5_x$ est suivi par le pooling et la couche pleinement connectée FC. Les sorties du réseau de neurones sont des probabilités d'appartenance aux k classes prédites. Cette architecture

est la structure de base qui a été proposée pour le challenge ILSVRC 2015 [187]. De même, nous avons utilisé le modèle pré-entraîné sur l'ensemble des images exploité pour ce challenge. En ce qui concerne les calculs, Pytorch a été utilisé sur un GPU (Quadro RTX 3000). Le taux d'apprentissage initial a été fixé à 0.0001 et l'optimisation a été réalisée par l'optimiseur Adam avec une décroissance de poids de 0.00005. L'algorithme fait intervenir à chaque itération 8 images (Batch) pour moyenner les gradients et mette à jour les poids.

Tableau 4-3 : Description de l'architecture de ResNet-18 utilisé pour la classification (k est le nombre de classes).

Layer Name	Output Size	ResNet-18
<i>conv1</i>	112 × 112 × 64	7 × 7, 64, stride 2
<i>conv2_x</i>	56 × 56 × 64	3 × 3 max pooling, stride 2 $\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$
<i>conv3_x</i>	28 × 28 × 128	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$
<i>conv4_x</i>	14 × 14 × 256	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$
<i>conv5_x</i>	7 × 7 × 512	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$
average pooling	1 × 1 × 512	7 × 7 average pool
fully connected	κ	512 × κ fully connections
softmax	κ	

Nos tests ont été conduits en différenciant les deux bases de données et en les associant tant dans l'apprentissage que dans le test. Les prochains paragraphes décrivent les résultats de nos expérimentations sur la base de données Gladis (de la personne B seule), puis sur la base de données Symh et enfin sur la combinaison des deux bases Gladis et Symh selon 3 stratégies : « base totale » sans distinction des images, « combinaison 1 » privilégiant l'apprentissage sur la base Symh et « combinaison 2 », privilégiant l'apprentissage sur la base Gladis. Le Tableau 4-4 montre la répartition des images des 2 bases de données sur les phases d'apprentissage et de test pour chaque expérimentation.

Tableau 4-4 : Répartition des 2 bases de données sur les phases d'apprentissage et de test pour chaque expérimentation.

Expérimentation	Apprentissage	Test
<i>Gladis seule</i>	80%	20%
<i>Symh seule</i>	80 %	20%
<i>Bases totale</i>	80 % Gladis, 80 % Symh	20% Gladis, 20% Symh
<i>Combinaison 1</i>	30% Gladis, 100% Symh	70% Gladis
<i>Combinaison 2</i>	100% Gladis, 30% Symh	70% Symh

4.2.2. Résultats de la classification sur la base Gladis

La base d'apprentissage est composée de 80% de la base de Gladis et la base de test du reste des données de la base (20% de la base Gladis). L'effectif de chaque classe dans chaque base (apprentissage et test) est présenté dans la Figure 4-14.

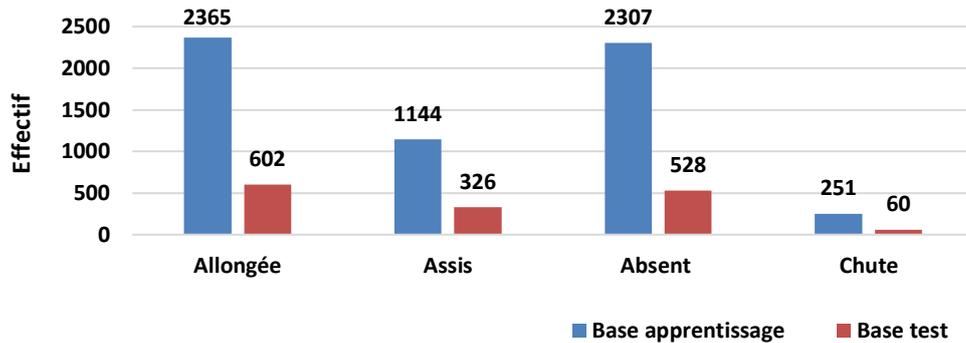


Figure 4-14 : Effectif des classes des bases de données apprentissage et test de la base Gladis.

La Figure 4-15 (a) présente les résultats sous la forme d'une matrice de confusion entre les classes. Les nombres indiqués sur la diagonale présentent les nombres d'images correctement prédites pour chaque classe et le reste présente la confusion du modèle. La Figure 4-15 (b), montre la matrice de confusion normalisée en calculant les taux des vraies prédictions et les erreurs de prédictions pour chaque classe de la base test. La précision, la sensibilité et le score F1 sont présentés dans le Tableau 4-5.

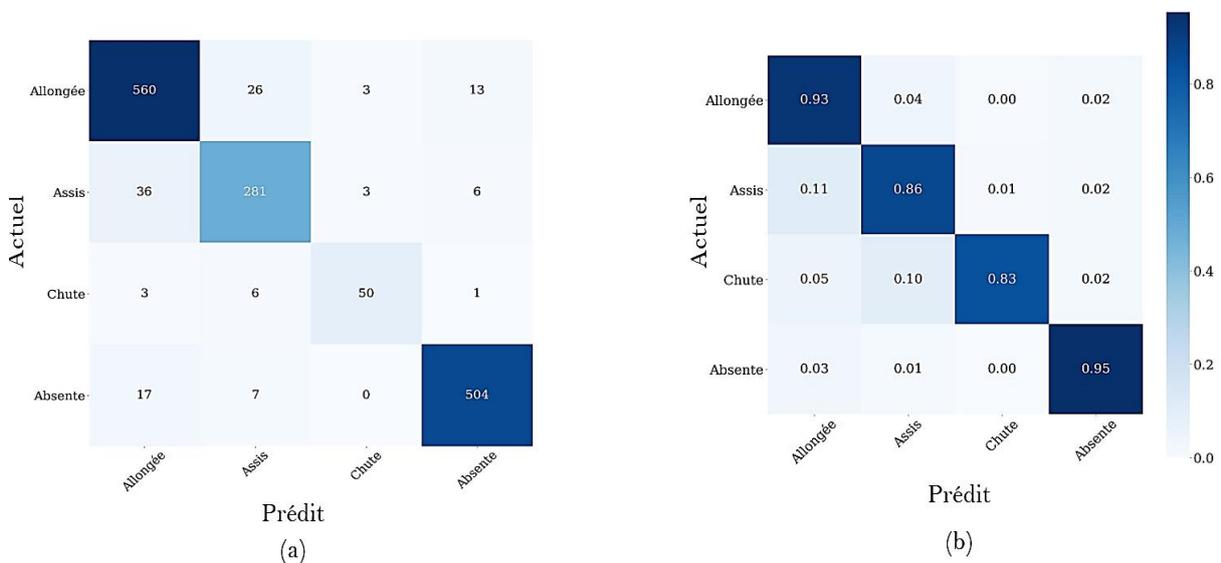


Figure 4-15 : Matrice de confusion (a), matrice de confusion normalisée (b).

Tableau 4-5 : Métriques d'évaluation

	Précision	Sensibilité	Score F1
Allongée	90.90%	93.48%	92.17%
Assis	87.81%	86.19%	86.99%
Chute	89.28%	83.33%	86.20%
Absente	96.18%	95.45%	95.81%

L'analyse des résultats montre que notre réseau obtient une précision de 92.02% des données bien classées et que pour chaque classe, les précisions de prédictions et les sensibilités sont supérieures à 83% ce qui reste très acceptable par rapport à l'objectif de détection du comportement que nous étudierons au chapitre VI.

4.2.2.3. Résultats de la classification sur la base Symh

La base d'apprentissage est une nouvelle fois composée de 80% de la base de Symh et la base test du reste des données de la base Symh. L'effectif de chaque classe dans chaque base (apprentissage et test) est présenté dans la Figure 4-16.

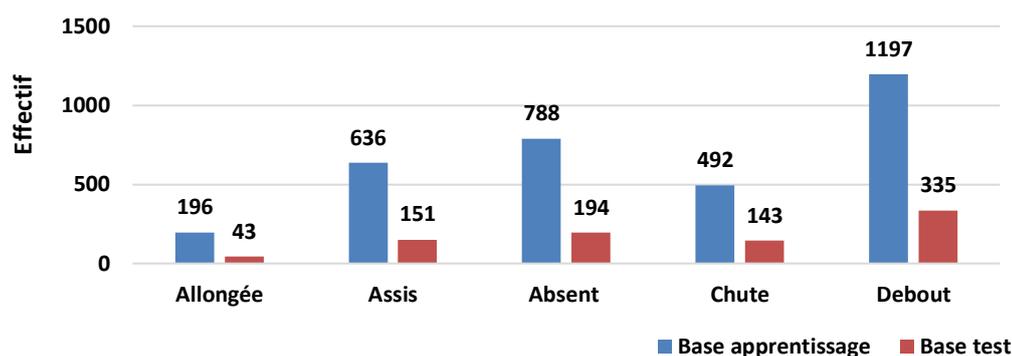


Figure 4-16 : Effectif des classes des bases de données apprentissage et test de la base Symh.

La Figure 4-17 (a) comme précédemment présente la matrice de confusion et la Figure 4-17 (b) la matrice de confusion normalisée. Les métriques d'évaluation sont présentées dans le Tableau 4-6.

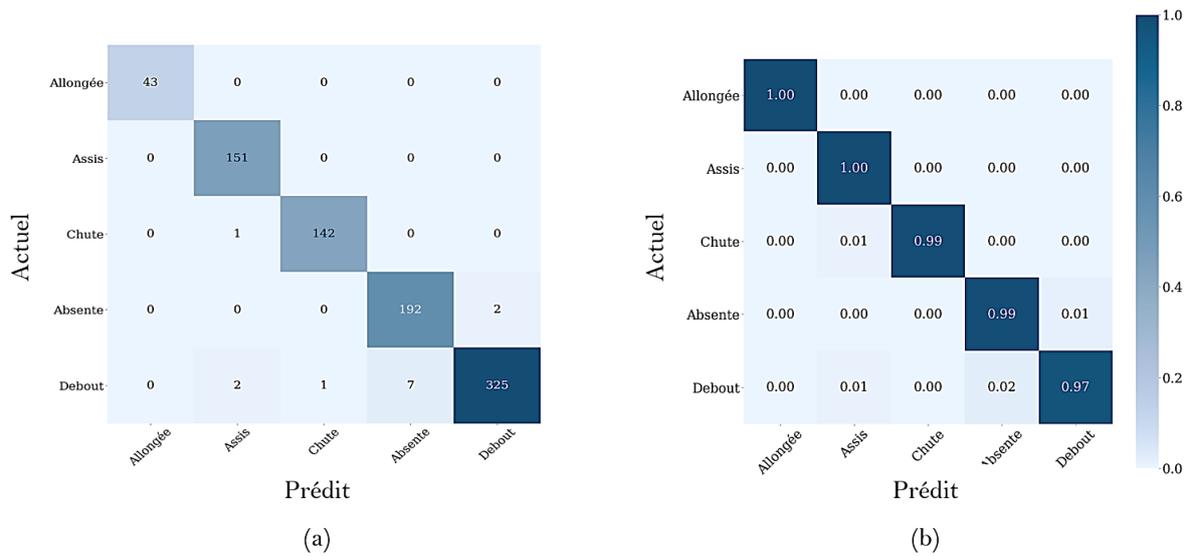


Figure 4-17 : Matrice de confusion (a), matrice de confusion normalisée (b).

Tableau 4-6 : Métriques d'évaluation.

	Précision	Sensibilité	Score F1
Allongée	100%	100%	100%
Assis	100%	100%	100%
Chute	99.30%	99.30%	99.30%
Absente	96.48%	98.96%	97.70%
Debout	99.38%	97.01%	98.18%

Une nouvelle fois et malgré la diversité des situations rencontrées (plus de pièces, emplacements différents des caméras dans les pièces, personnes différentes) de très bons résultats de prédiction sont observés. Ces résultats sont même supérieurs à ceux obtenus sur la base de données Gladis. En effet, une précision de 98.50% sur les postures bien classées est mesurée. Les différences s'expliquent par le fait que les données acquises dans cette base de données respectent un protocole parfaitement établi, avec des situations bien tranchées permettant de bien identifier les différentes postures. D'autre part, la qualité des enregistrements s'est améliorée au fil du temps pour la société Neotec-Vision permettant de recueillir des données de meilleures qualités lors des enregistrements de la base Symh.

4.2.2.4. Résultats de la classification sur la base totale (Gladis et Symh)

Afin d'évaluer, si une augmentation de la base de données Symh par des images réelles de la base Gladis permet d'accroître significativement les performances, un nouveau test a été réalisé où la base d'apprentissage est composée cette fois-ci de 80% de la base totale (Gladis +Symh) tandis que la base test rassemble le reste des données de la base totale. L'effectif de chaque classe dans chaque base (apprentissage et test) est présenté dans la Figure 4-18.

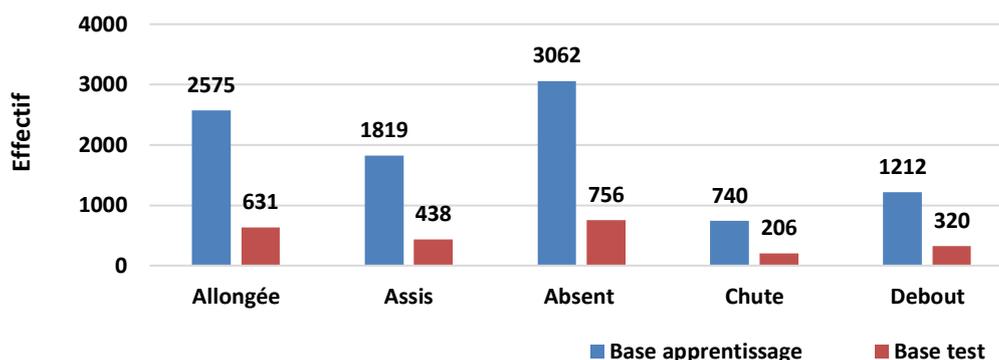


Figure 4-18 : Effectif des classes des bases de données apprentissage et test de la base totale (Gladis +Symh).

La Figure 4-19 (a) présente la matrice de confusion et la Figure 4-19 (b) la matrice de confusion normalisée.

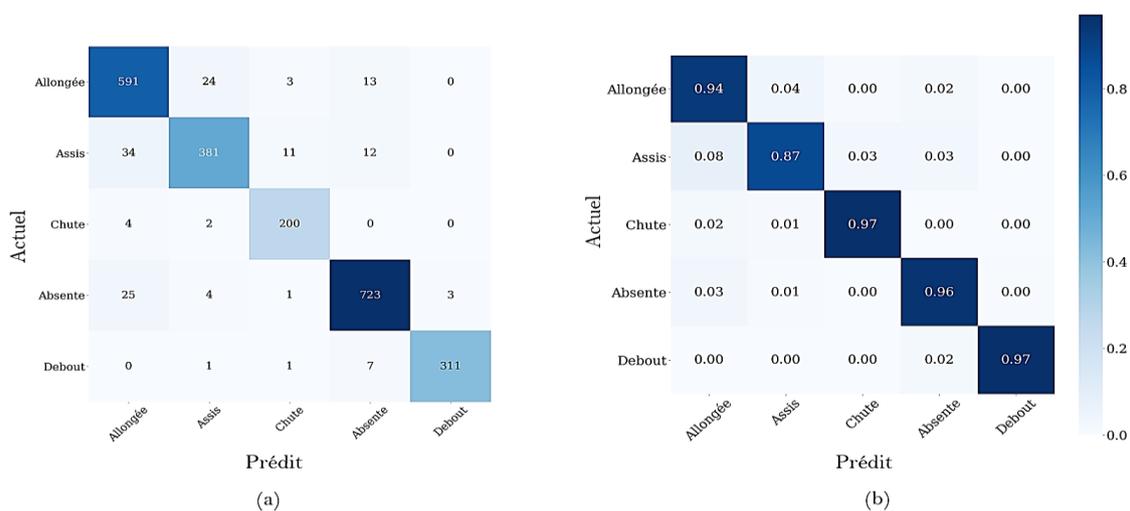


Figure 4-19 : Matrice de confusion (a), matrice de confusion normalisée (b).

Les métriques d'évaluations sont présentées dans le Tableau 4-7.

Tableau 4-7 : Métriques d'évaluation.

	Précision	Sensibilité	Score F1
Allongée	90.36%	93.66%	91.98%
Assis	92.47%	86.98%	89.64%
Chute	92.59%	97.05%	94.78%
Absente	95.76%	95.63%	95.69%
Debout	99.04%	97.18%	98.10%

L'examen de la matrice de confusion montre que l'on obtient une précision de 93.83% de données bien classées. Pour chaque classe la précision est supérieure à 90% et la sensibilité est supérieure à 86%. Les métriques sont meilleures que celles obtenues sur la base de données réelle Gladis, mais moins bonnes que celles obtenues sur la base de données simulée Symh. Il est difficile pour l'instant de tirer une conclusion mais le sentiment est que l'ajout de données provenant de situations différentes permet d'améliorer la robustesse globale. Une autre constatation est que le fait d'ajouter des données simulées à des données réelles permet d'améliorer la prédiction sur les données réelles.

4.2.2.5. Résultats de la classification sur la combinaison 1 des bases Gladis et Symh

Lors de l'analyse du résultat précédent sur toute la base, nous avons émis l'hypothèse que le fait d'ajouter des données simulées à des données réelles permettrait d'améliorer la prédiction sur données réelles. Afin de vérifier cela, il nous a semblé intéressant de préserver en test le maximum de données de la base Gladis. Dans cette expérimentation, nous avons volontairement restreint la base d'apprentissage à 30% de la base Gladis et utilisé la base complète Symh. La base test est alors composée de 70% d'images de la base Gladis. L'effectif de chaque classe dans chaque base (apprentissage et test) est présenté dans la Figure 4-20 . (a) présente les résultats de la matrice de confusion et (b) la matrice de confusion normalisée. Nous rappelons que la personne B de la base Gladis présente des problèmes de mobilités c'est pour cette raison que la personne n'est jamais debout.

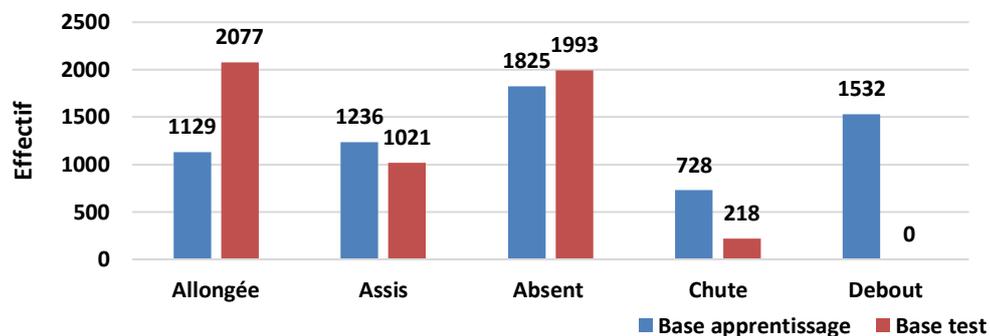


Figure 4-20 : Effectif des classes des bases de données apprentissage et test de la base de la combinaison 1 des bases Gladis et Symh.

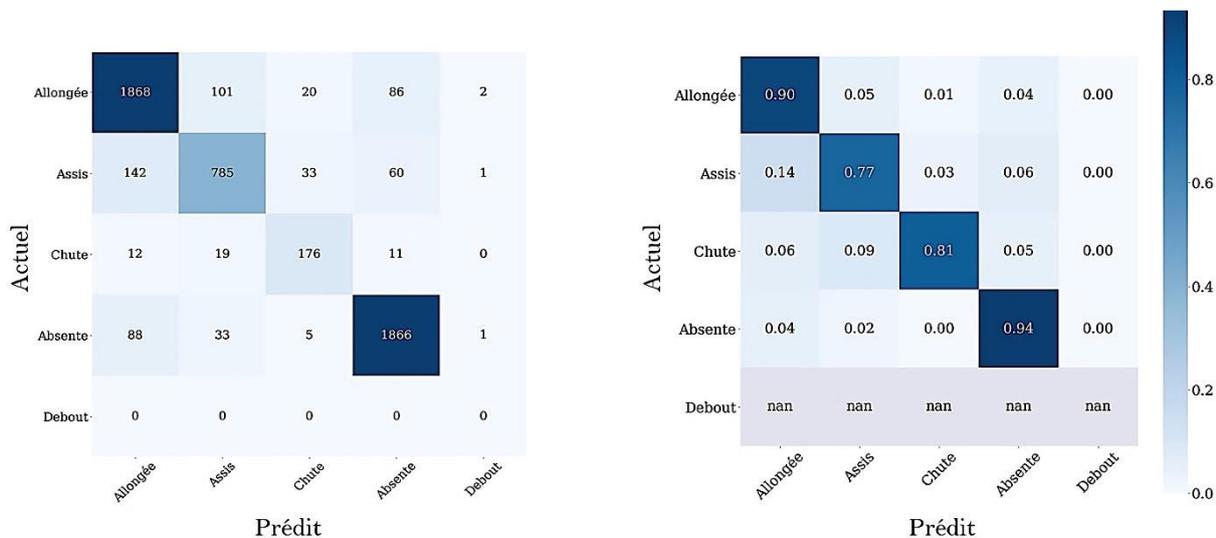


Figure 4-21 : Matrice de confusion (a), matrice de confusion normalisée (b).

Les métriques d'évaluations sont présentées dans le Tableau 4-8.

Tableau 4-8 : Métriques d'évaluation

	Précision	Sensibilité	Score F1
Allongée	89.85%	89.55%	89.70%
Assis	82.44%	81.88%	82.16%
Chute	77.78%	83.48%	80.53%
Absente	94.14%	93.52%	93.83%

Nous obtenons une précision de 89.32% d'images bien classées. Pour chaque classe la précision est supérieure à 77% et la sensibilité supérieure à 81%. Ces résultats sont moins bons que ceux obtenus sur la base Gladis seule. Plusieurs facteurs peuvent expliquer cette dégradation. L'apprentissage sur les deux bases de données est moins spécifique (moins spécialisé) à la base Gladis que lors du premier test. Une autre explication est aussi que nous essayons d'estimer une classe supplémentaire (la classe debout) que lors de l'étude sur Gladis seule. En effet, nous voyons qu'il y a 11 images où la prédiction est *debout* Dans tous les cas, et malgré le fait que dans l'apprentissage, il n'y avait que 30 % des images de la base Gladis, les performances sur la base test restent très satisfaisantes.

4.2.2.6. Résultats de la classification sur la combinaison 2 des bases Gladis et Symh

Comme nous l'avons dit dans la section 2.2, La base de données Gladis, même si elle recueille des cas réels, les personnes surveillées sont déjà en pertes d'autonomie. C'est pour cela que nous avons créé Symh, la base de cas simulés. Cependant, nous voulons voir si l'apprentissage de cas réels pouvait renforcer ou perturber les résultats sur la simulation. Pour cela, nous proposons dans cette section de construire une base d'apprentissage composée de 30% de la base Symh et de 100 % de la base Gladis, et de conserver, pour les scénarios que nous simulons, uniquement les images de la base

Symh en test (70% de la base Symh). L'effectif de chaque classe dans chaque base (apprentissage et test) est présenté dans la Figure 4-22.

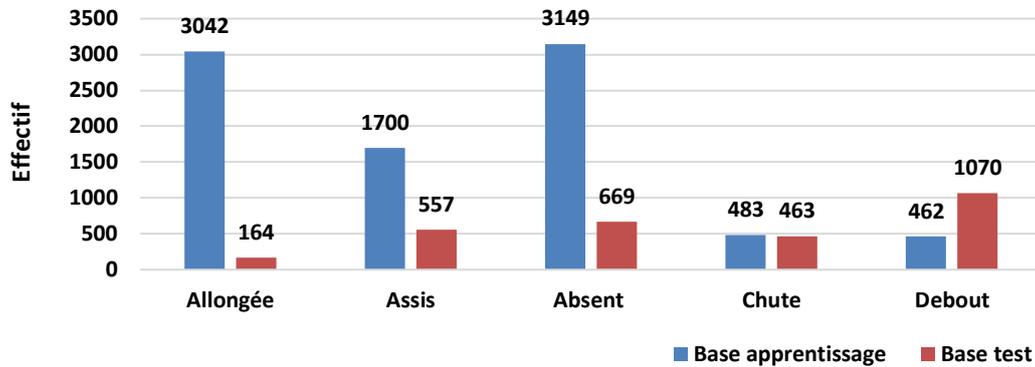


Figure 4-22 : Effectif des classes des bases de données apprentissage et test de la base de la combinaison 2 des bases Gladis et Symh.

La Figure 4-23 (a) présente la matrice de confusion et la Figure 4-23 (b) la matrice de confusion normalisée. Les métriques d'évaluations sont présentées dans le Tableau 4-9.

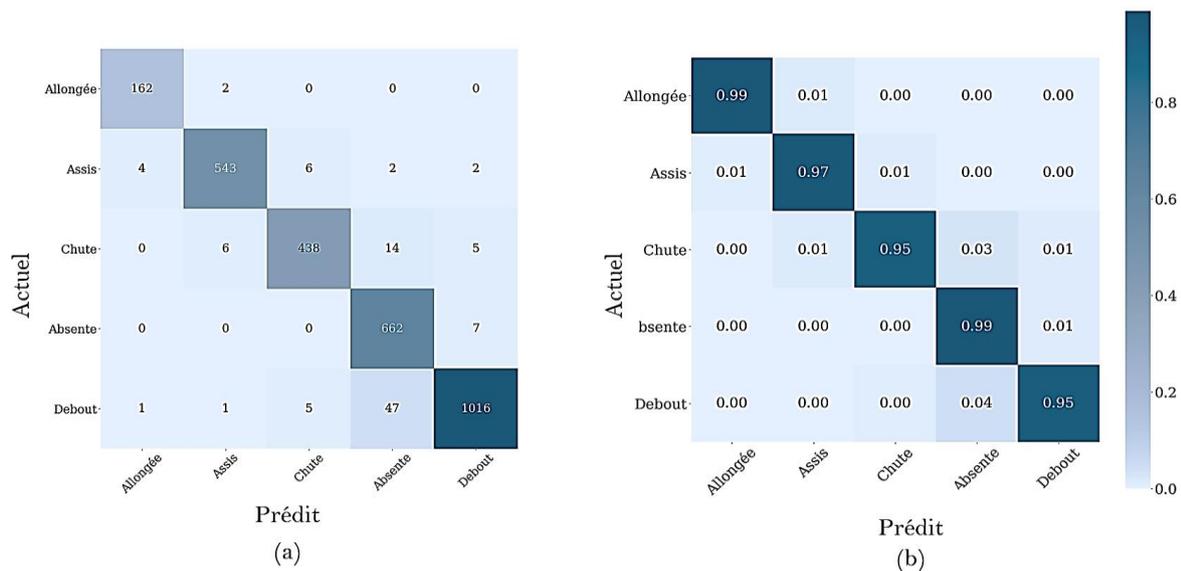


Figure 4-23 : Matrice de confusion (a), matrice de confusion normalisée (b).

Tableau 4-9 : Métriques d'évaluation.

	Précision	Sensibilité	Score F1
Allongée	97.05%	98.78%	97.91%
Assis	98.36%	97.48%	97.92%
Chute	97.55%	94.60%	96.05%
Absente	91.31%	98.95%	94.98%
Debout	98.35%	94.95%	96.62%

Nous obtenons une précision de 96.65% de données bien classées. Pour chaque classe, la précision est supérieure à 91% et la sensibilité est supérieure à 94%. Même si la base Gladis est distincte de la base Symh, elle apporte quand même une information suffisante pour la distinction des classes de la base Symh.

Conclusion

La détection des postures décrite dans ce chapitre constitue un des points clé de notre algorithme de détection de changement de comportement en établissant la prédiction des postures. À l'issue de cette expérimentation, nous observons que le modèle neuronal ResNet-18 permet de prédire les classes *assis*, *allongé*, *debout*, *l'absence* de la pièce et la *chute* avec de bonnes prédictions comprises entre 92.02% et 98.50%. Les deux bases utilisées couvrent différents participants en termes d'âge et de degré d'autonomie et différentes configurations de pièces et d'emplacements du capteur. Les tests reportés montrent une relative indépendance vis à vis de ces paramètres et les performances, comme montrées dans les sections précédentes, restent très satisfaisantes.

L'estimation de ces postures va permettre, comme nous allons le voir dans le chapitre V, d'établir quelques indicateurs pour la détection du comportement. L'objet du prochain chapitre est donc, de préciser plus amplement ces différentes méthodes.

5. Détection du changement de comportement de la personne âgée

Introduction

Une personne âgée a tendance à suivre une routine bien définie [2]. Cette routine permet à la personne de se repérer dans l'espace et le temps et donc d'avoir le sentiment d'un contrôle de son quotidien en évitant les événements inattendus qui sont sources de stress [163]. Le chapitre I a permis de mettre en évidence qu'un trouble de comportement peut être un indicateur clé de la fragilité de la personne. Par exemple, la maladie d'Alzheimer et la démence impactent le comportement de la personne (hausse d'apathie et désorientation) [188]. Dans la littérature, les travaux sur la détection du changement de comportement sur une longue durée d'une personne dans le cadre d'une maison intelligente sont rares. L'objectif de notre recherche est de proposer un outil qui permet aux professionnels de santé et aux familles des personnes âgées, de suivre l'évolution de la routine de la personne âgée vivant seule et aussi d'envoyer des alertes en cas de chute (ce dernier aspect a été étudié dans les chapitres précédents) et en cas de changement de comportement. L'outil proposé, comme indiqué dans les chapitres précédents, est basé sur des données enregistrées par des caméras de profondeurs. Nous y avons vu que chaque journée est décrite par le résultat d'une détection des postures (*assis*, *allongé* ou *debout*), de *l'absence* de la personne ou d'une détection de la *chute*. Dans le présent chapitre, cinq méthodes de détection du changement de comportements de la personne sont proposées. Le principe de base de toutes ces méthodes est de comparer une journée particulière avec une journée routine de référence.

- La première approche cherche à calculer une distance d'édition entre la journée observée et la journée routine prédéfinie.
- La deuxième méthode a pour objectif d'aligner chaque jour enregistré à la journée routine par le biais d'un algorithme de la déformation temporelle dynamique.
- Avec la troisième approche, on cherche à classer la nature de journée en *routine* et *non-routine*. L'objectif est d'apprendre les classes à partir des observations. Deux approches ont été testées l'une en exploitant les méthodes d'auto-apprentissage par K_moyennes l'autre par K_modes.
- La quatrième approche cherche simplement à tirer profit de l'approche précédente et à classifier la nature de la journée en *routine* et *non-routine* sur la base des pourcentages des postures (*assis*, *allongé* et *debout*) et de *l'absence* et du nombre des *chutes* par une approche supervisée.
- La dernière méthode classe la journée enregistrée avec une approche heuristique qui consiste à vérifier l'appartenance des valeurs des indices de chaque jour aux intervalles *routines*.

Dans tous les cas, on a fait le choix de présenter la méthode et l'évaluation objective des résultats sur la base de données Gladis de deux personnes âgées (cf chapitre II). Les données de la base

Symh seront exploitées dans le chapitre VI que nous dédierons à la mesure de performance et à la simulation.

5.1. Détection du changement de comportement au moyen de la distance d'édition

La Figure 5-1 présente le schéma de détection du changement de comportement en utilisant la Méthode qui calcule la Distance Minimale d'Édition (*M-DME*) :

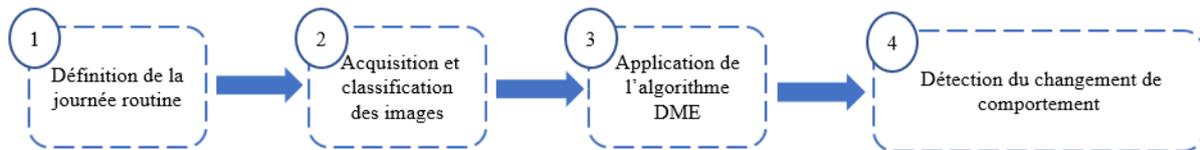


Figure 5-1 : Schéma de la détection du changement de comportement au moyen de la distance d'édition.

La *M-DME* est composée de 4 étapes présentées dans la figure précédente. La première étape consiste à définir la journée routine. La seconde étape consiste à acquérir sur une journée des images de profondeur et de les classer en postures (*allongé, assis, debout*) avec, le cas échéant, une indication de *l'absence* de la personne ou de sa *chute* au moyen des algorithmes décrits aux chapitres précédents. La troisième étape consiste à comparer chaque journée enregistrée avec la journée routine en calculant la distance d'édition. À la dernière étape, les résultats de comparaison permettent de repérer le changement de comportement de la personne.

5.1.1. Définition de la journée routine

Deux stratégies peuvent être retenues pour définir la journée routine. La première consiste à demander préalablement à la personne de décrire ses habitudes de vie en indiquant le type, l'heure et le lieu de la réalisation de l'activité. Ensuite, chaque activité est traduite par une posture. La journée routine est alors décrite par la succession des postures (*assis, allongé, debout*) avec indication de *l'absence* de la personne. Le Tableau 5-1 présente un exemple d'une journée routine avec l'indication de chaque posture correspondant à chaque activité. La stratégie d'apprentissage sera revue au cours du chapitre VI, où des scénarios réalistes seront construits.

Tableau 5-1 : Exemple d'une journée routine avec indication de la posture qui correspond à chaque activité.

Heure	Action/Activité	Localisation	Posture
07:00	Le sujet se réveille et se lève.	Chambre	Allongé
07:05	Toilettes/douche	Salle de bain	Absent
07:45	Préparation du petit déjeuner	Cuisine	Debout
08:00	Petit déjeuner dans la cuisine	Cuisine	Assis
08:30	Salle de bain	Salle de bain	Absent
09:00	Il va faire les courses	Sortir de l'appartement	Absent
10:30	Retour dans l'appartement	Entrer dans l'appartement	Debout
10:35	Le sujet range	Cuisine	Debout
11:00	Lecture sur le canapé	Salon (Canapé)	Assis
11:30	Préparation du repas	Cuisine	Debout
12:15	Repas	Cuisine	Assis
12:45	Vaisselle/nettoyage	Cuisine	Debout
12:50	Toilettes	Salle de bain	Absent
13:00	Informations à la télé	Salon (Canapé)	Assis
14:00	Sieste	Chambre	Allongé
14:30	Sortir de l'appartement (sport)	Sortir de l'appartement	Absent
16:30	Retour à l'appartement	Entrer dans l'appartement	Debout
16:35	Le sujet mange dans la cuisine	Cuisine	Assis
16:45	Le sujet prend une douche	Salle de bain	Absent
17:10	Préparer un café	Cuisine	Debout
17:20	La personne lit dans le salon	Salon (Canapé)	Assis
19:05	Toilettes	Salle de bain	Absent
19:10	Le sujet fait la cuisine	Cuisine	Debout
19:40	Le sujet mange à table	Cuisine	Assis
20:00	Télévision	Salon (Canapé)	Assis
20:40	Vaisselle	Cuisine	Debout
21:00	Le sujet se met à son bureau	Chambre	Assis
21:30	Le sujet se prépare pour la nuit	Salle de bain	Absent
22:00	Prise de la tension	Chambre	Assis
22:50	Le sujet se couche	Chambre	Allongé

La deuxième stratégie consiste à enregistrer la personne sur plusieurs jours. La journée *routine* est alors définie en choisissant, à un instant t sur la période d'enregistrement, la posture (*assis*, *allongé*, *debout*, *absent* et *chute*) la plus présente. Cette seconde approche relève de l'auto-apprentissage.

5.1.2. Acquisition et classification des images

Cette partie a été largement présentée dans les chapitres précédents. Pour mémoire, les caméras de profondeurs sont placées dans le logement de la personne ou dans des chambres d'établissements habilités. Ces caméras permettent d'enregistrer la personne jour et nuit en préservant son anonymat. Les images sont ensuite classées en postures (*assis*, *allongé*, *debout*) ou *absent* avec détection de la *chute* de la personne au moyen des méthodes décrites au chapitre IV.

5.1.3. L'algorithme de la distance d'édition

La classification des images enregistrées durant la journée permet de proposer une suite de symboles qui correspond à la succession des postures (*assis*, *allongé*, *debout*) et à l'indication de l'*absence* et de la *chute* de la personne. Le principe de *M-DME* est donc de calculer la distance d'édition en comparant la journée routine avec chaque journée enregistrée.

La distance d'édition est un moyen de comparer deux séquences temporelles qui ne synchronisent pas parfaitement. L'algorithme calcule la correspondance maximale entre deux séquences en estimant une distance qui correspond au minimum de changements réalisés pour aligner deux séries chronologiques.

La distance édition entre deux séquences [189] est le nombre minimum d'opérations nécessaires pour passer d'une séquence à une autre. Les opérations pour aligner deux séquences sont : « insérer », « changer » et « supprimer ». On peut fixer généralement un coût à chaque opération. Pour notre travail, nous avons retenu un coût unitaire [189], [190].

Soit $D(i, j)$ la distance d'édition entre deux séries $X(i)$ et $Y(j)$. On définit récursivement cette distance comme suit :

$$D(i, j) = \begin{cases} j & \text{si } i = 0 \\ i & \text{si } j = 0 \\ D(i-1, j-1) & \text{si } i, j > 0 \text{ et } X[i] = Y[j] \\ 1 + \min \begin{cases} D(i-1, j-1) \\ D(i-1, j) \\ D(i, j-1) \end{cases} & \text{sinon} \end{cases}$$

Pour appliquer la *M-DME* dans le présent cas, nous avons noté la classe assis « S », la classe allongé « L », la classe debout « D », la classe absent « A » et la classe chute « C ». La Figure 5-2 montre un exemple de calcul pour aligner la séquence 1 (L, C, S, D, L) à la séquence 2 (L, S, D, A, D).

<i>D</i>	4	4	4	3	3
<i>A</i>	3	3	3	2	2
<i>D</i>	2	2	2	1	2
<i>S</i>	1	1	1	2	3
<i>L</i>	0	1	2	3	4
	<i>L</i>	<i>C</i>	<i>S</i>	<i>D</i>	<i>L</i>

Figure 5-2 : Exemple d'application de l'algorithme DME pour aligner la séquence 1 à la séquence 2.

Dans cet exemple, l'algorithme retourne 3 opérations ($DME = 3$) nécessaires à effectuer pour aligner la séquence 1 (abscisses : *L, C, S, D, L*) à la séquence 2 (ordonnées : *L, S, D, A, D*). Les trois opérations sont : i) changer *L* par *D*, ii) insérer *A*, iii) supprimer *C*. Le chemin indiqué dans la figure précédente est le chemin optimal pour aligner les deux séquences.

5.1.4. Application de M-DME à la détection du changement de comportement

Cette approche de *M-DME* a été implémentée sur la base de données Gladis (cf chapitre II). La présentation graphique des résultats de l'algorithme permet d'apprécier d'une manière simple l'évolution du comportement sur une période d'enregistrement de la personne. Le calcul de la moyenne mobile par intervalle de 7 jours permet de visualiser d'une manière continue le changement du comportement.

La *M-DME* a donc été appliquée aux deux personnes âgées dépendantes (A et B) enregistrées avec des capteurs de profondeur dans leur maison de retraite durant une période de 85 jours (voir section 2.2.1 du manuscrit). Pour chaque personne, les images ont été annotées manuellement (assis en couleur bleu, allongé en couleur mauve, absent en couleur rouge, debout en couleur blanche et chute en jaune). Les images annotées des personnes ainsi que la journée routine pour chaque personne sont présentées dans la Figure 5-3 et la Figure 5-4.

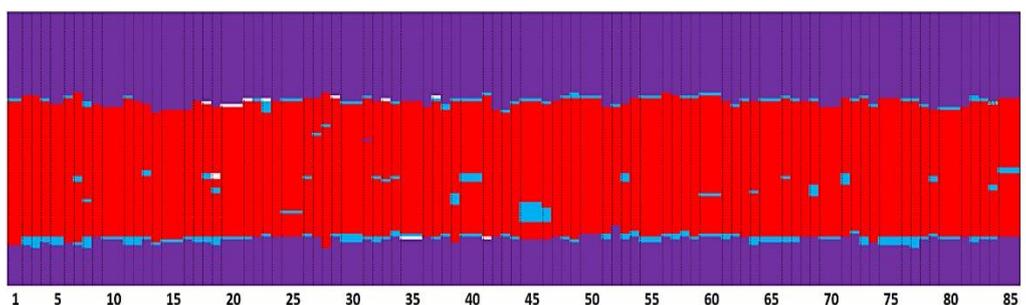


Figure 5-3 : Annotations (assis en couleur bleu, allongé en couleur mauve, absent en couleur rouge, debout en couleur blanche et chute en jaune) des images de la personne A durant la journée (axe des ordonnées) pour une durée de 85 jours (axe des abscisses). La ligne verticale sur la droite correspond à la journée routine de la personne.

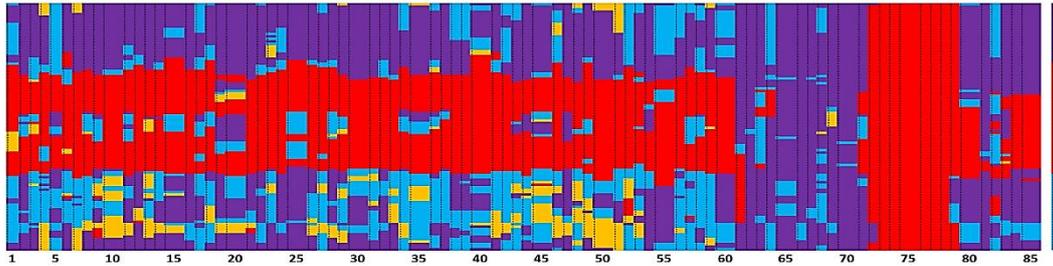


Figure 5-4 : Annotations (assis en couleur bleu, allongé en couleur mauve, absent en couleur rouge, debout en couleur blanche et chute en jaune) des images de la personne B durant la journée (axe des ordonnées) pour une durée de 85 jours (axe des abscisses). La ligne verticale sur la droite correspond à la journée routine de la personne.

De la Figure 5-3 et la Figure 5-4, les journées *routines* pour chaque personne ont été définies en reprenant la seconde stratégie décrite à la section 5.1.1. Sur les 10 premiers jours où les deux personnes présentent un comportement routinier, on sélectionne pour chaque instant t d'enregistrement la classe (*assis, allongé, debout, absent et chute*) la plus fréquente. La classe sélectionnée est attribuée à l'instant t à la journée routine. Cette dernière est reportée à l'extrémité du graphe.

Sur la durée d'enregistrement de 85 jours, on remarque que la personne A, a un comportement bien routinier avec une absence de chute. En revanche la personne B présente des changements de comportement avec présence de chute. Cette dernière personne suit un comportement routinier du premier jour au 60^{ème} jour. Durant 11 jours, une rupture brutale de la routine est observée ; elle est associée au fait que la personne est souvent allongée. Puis, la personne est absente pour une durée de 8 jours. Cette absence est expliquée par une hospitalisation. Sur les 6 derniers jours, la personne retrouve sa routine.

La *M-DME* appliquée sur toute la durée d'enregistrement de 85 jours pour chaque personne, le calcul de la moyenne mobile par intervalles de 7 jours et les annotations des postures sont reportées sur les Figure 5-5 et Figure 5-6 .

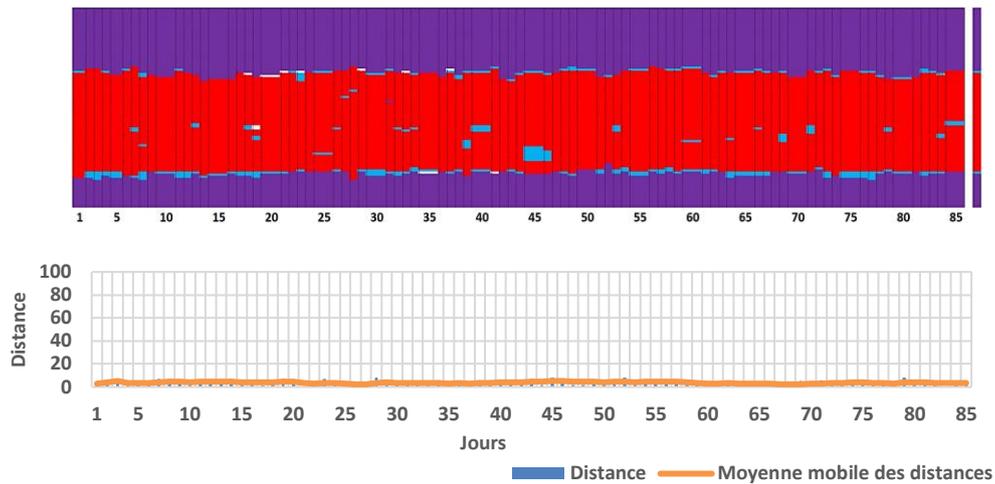


Figure 5-5 : Annotation des images de la personne A et la distance d'édition entre la journée routine et chaque jour enregistré. La ligne continue représente la moyenne mobile des distances de M-DME par intervalles de 7 jours.

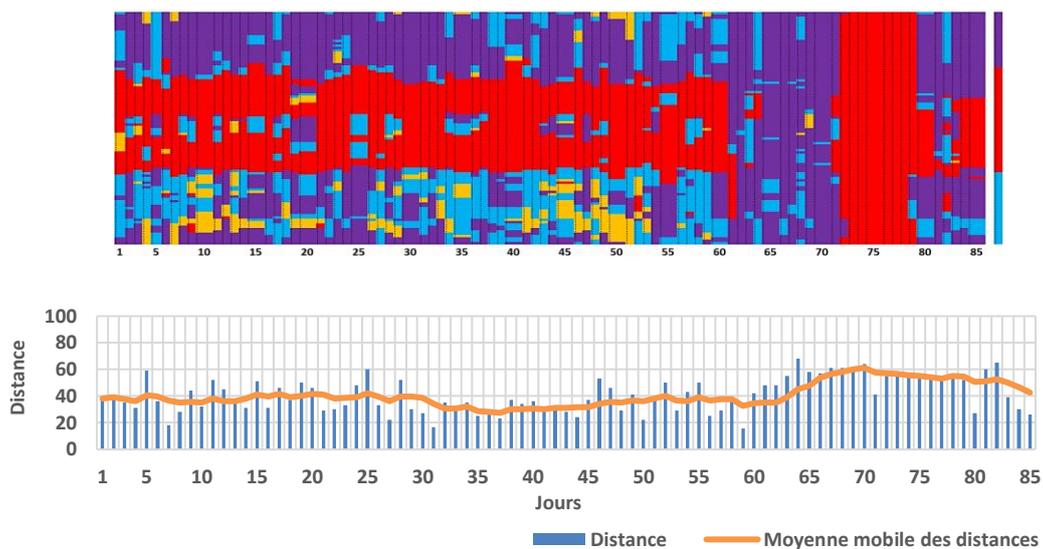


Figure 5-6 : Annotation des images de la personne B et la distance d'édition entre la journée routine et chaque jour enregistré. La ligne continue représente la moyenne mobile des distances de la M-DME par intervalles de 7 jours.

La Figure 5-5 montre que la M-DME a bien quantifié le mode de vie régulier de la personne A (les distances d'édition sont quasiment nulles). Pour la personne B (Figure 5-6), l'analyse montre que la personne présente des changements de comportement. En effet pour la personne B, on remarque, comme attendu, une augmentation du nombre de transformations après le jour 60 qui, pour mémoire, correspond au fait que la personne a été le plus souvent allongée puis absente. On note ensuite une diminution progressive de la distance d'édition qui correspond au retour de la personne B dans sa chambre.

Nous avons cherché à évaluer si ces changements pouvaient être considérés comme statistiquement significatifs. Après avoir annoté les images et observé la vérité terrain de la personne

B, la base de données a été divisée a priori en 7 groupes homogènes de journées (A, B, C, D, E, F et G). La Figure 5-7 présente les annotations des images par jour, les résultats de la M-DME par jour et les boxplots des distances d'édition pour chaque groupe.

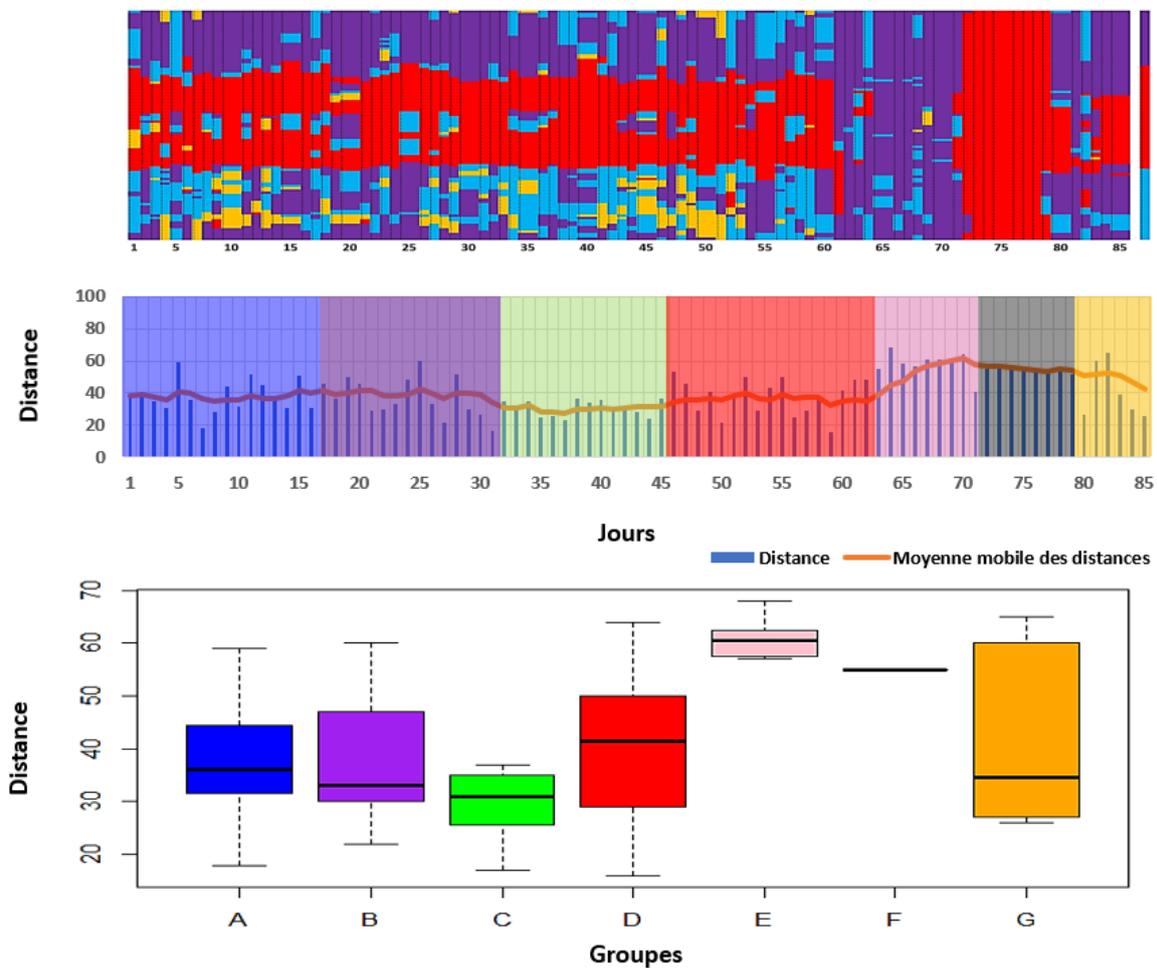


Figure 5-7 : Annotations des images par jour de la personne B, résultats des distances de la M-DME par jour, évolution de la moyenne mobile des distances et les boxplots des valeurs des distances pour chaque groupe.

Il ressort du graphe des boxplots que :

- Les distances d'édition des groupes A, B, C et D sont quasi similaires. Ce résultat s'explique par le fait que la personne a un comportement quasi routinier du premier au 60^{ème} jour.
- Les valeurs des médianes des groupes A, B, C, D sont clairement différentes des médianes des groupes E et F, du fait que la personne ne suit plus son comportement routinier durant les jours des groupes E et F.
- Les données du groupe G sont dispersées. Les valeurs de ce groupe qui sont communes avec celles des autres groupes s'expliquent par le retour progressif de la personne à sa routine après son retour de l'hôpital.

Afin d'identifier les groupes qui sont significativement différents, le test statistique de Wilcoxon [191] par paire de groupe pour tester l'hypothèse selon laquelle les distributions de chacun de deux groupes de données sont proches. Les résultats du test sont présentés dans le Tableau 5-2.

Tableau 5-2 : Résultats du test Wilcoxon.

	A	B	C	D	E	F
B	0.99					
C	0.09	0.28				
D	0.99	0.99	0.10			
E	0	0	0	0		
F	0	0	0	0	0.02	
G	0.99	1	0.42	0.99	0.16	0.42

On remarque d'une part, que les groupes A, B, C et D ne sont pas significativement différents ($p > 0.05$), et d'autre part qu'ils sont significativement différents des groupes E et F ($p < 0.05$). Aussi les groupes E et F sont significativement différents. Comme attendu, le groupe G n'est pas significativement différent des autres groupes.

En regroupant, les groupes A, B, C et D en un groupe *routine* et les groupes E et F en groupe *non-routine* et en notant *Med [Q25th, Q75th]* la médiane et l'intervalle interquartile des valeurs de la distance d'édition, on obtient pour le groupe *routine* 35 [29, 43] et pour le groupe *non-routine* 56 [55, 61]. La Figure 5-8 illustre ces résultats en présentant les boxplots du groupe *routine* R et du groupe *non-routine* NR.

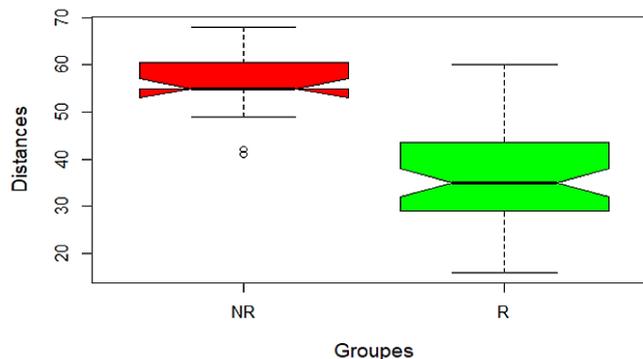


Figure 5-8 : Boxplots des groupes routine et non-routine des distances de la M-DME de la personne B.

Ceci est intéressant et permet d'envisager un test de décision statistique qui consiste à tester les deux hypothèses suivantes :

H_0 : La distance d'édition $y(n)$ suit une loi $P_{MDE0}(y(n), H_0)$ entre $n=0, \dots, N-1$

H_1 : La distance d'édition suit une

$P_{MDE0}(y(n), H_0)$ entre $n = 0, \dots, r-1$

$P_{MDE1}(y(n), H_1)$ entre $n = r, \dots, N-1$

Où y est la mesure de la distance d'édition au jour n et $P_{MDEi}(y, H_i)$ est la distribution de la distance d'édition sous l'hypothèse $i = 0$ (H_0 : aucun changement n'est observé) et sous l'hypothèse $i=1$ (H_1 :

un changement est observé) et r est le jour où le début de changement est observé. Le test CUSUM qui permet de détecter le changement de modèle dans des processus stochastiques répond à cette question. À chaque instant, l'algorithme CUSUM des sommes cumulées [192] compare la statistique de test au seuil.

Pour illustrer notre propos, le test a été appliqué pour détecter le plus rapidement possible le passage de l'hypothèse $H_0 = M(R)$ à l'hypothèse $H_1 = M(NR)$, où $M(R)$ est la valeur médiane des distances des jours du groupe *routine* (du jour 1 au jour 60 de la vérité terrain, ici 35) et $M(NR)$ est la valeur médiane des distances des jours du groupe *non-routine* (du jour 61 au jour 79 de la vérité terrain, ici 55). La Figure 5-9 suivante illustre le comportement de l'algorithme CUSUM sur les données des distances de la *M-DME* de la personne B sur une période de 79 jours. Le test de CUSUM met bien en évidence le changement au jour 61 comme ceci est indiqué dans les figures précédentes et cela correspond à la vérité terrain

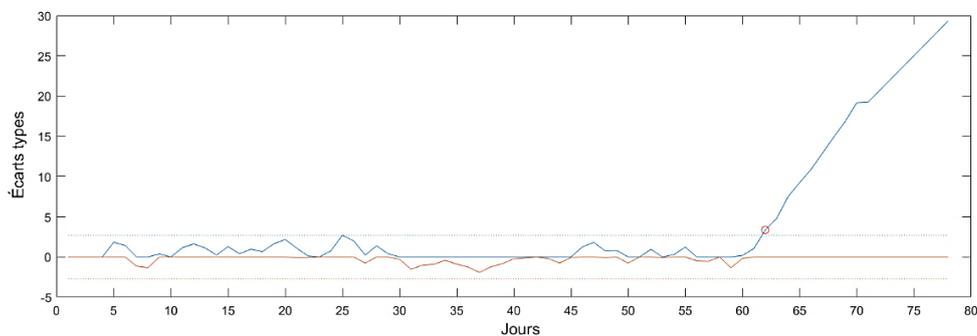


Figure 5-9 : Résultat du test CUSUM appliqué aux distances de la *M-DME* du jour 1 au jour 79 de la personne B.

5.2. Détection du changement de comportement au moyen de la déformation temporelle dynamique

La Figure 5-10 présente le schéma de détection du changement de comportement en utilisant la méthode qui calcule la distance de la déformation temporelle dynamique (*M-DTW*). Il reprend le principe décrit dans la Figure 5-1 mais où la distance d'édition est substituée par la déformation temporelle dynamique :



Figure 5-10 : Schéma de la détection du changement de comportement au moyen de la déformation temporelle dynamique.

La *M-DTW* est composée de 4 étapes. La première étape consiste à apprendre la journée *routine* qui est définie de la même manière que pour la détection du changement de comportement avec la méthode de distance d'édition (voir section 5.1.1). La seconde étape consiste à enregistrer les images de profondeur et à les classer. Ces dernières sont ensuite encodées par valeurs numériques en fonction de la posture (*allongé, assis, debout*), de l'*absence* de la personne et des *chutes*. La troisième étape consiste alors à aligner chaque journée enregistrée à la journée routine par le biais de l'algorithme de la transformation temporelle dynamique et de calculer la distance nécessaire pour l'alignement. À la dernière étape, le suivi des résultats des distances permet de repérer le changement de comportement de la personne.

5.2.1. L'algorithme de la déformation temporelle dynamique

La déformation temporelle dynamique (Dynamic Time Warping *DTW*) est inspirée de la distance de Levenshtein et constitue une extension de la distance d'édition aux séquences numériques. L'algorithme *DTW* permet d'aligner deux suites d'éléments évoluant au cours du temps [193]. Il est souvent utilisé dans le domaine de la reconnaissance de la parole où la vitesse d'élocution peut varier alors que la phrase prononcée reste la même. La *DTW* est aussi employée pour mesurer la similitude de séries temporelles dans le domaine de la fouille des données [194]–[196]. La déformation appliquée aux séries est réalisée par une transformation non linéaire de la variable temporelle afin de mesurer leur similarité indépendamment du temps. En effet, la *DTW* considère le temps comme non linéaire et élastique et permet de calculer la distance des séries en prenant en compte leurs décalages temporels contrairement à la distance euclidienne qui calcule la distance sans prendre en compte les différents décalages temporels.

L'algorithme *DTW* appliqué à deux séquences X et Y de longueurs respectives m et n :

$$X = x_1, x_2, \dots, x_m, Y = y_1, y_2, \dots, y_n$$

permet de construire la matrice de distance D de taille $(m \times n)$ où l'indice (i, j) correspond à la distance entre $(x(i), \dots, x(m))$ et $(y(j), \dots, y(n))$. Chaque valeur de la matrice D est calculée de façon récursive :

$$D(i, j) = \delta(x(i), y(j)) + \min\{D(i-1, j-1), D(i, j-1), D(i-1, j)\}$$

où δ est une distance entre les éléments des séquences.

On constate que par rapport à la distance d'édition, la *DTW* ne permet pas d'insérer ou de supprimer des éléments avec un coût fixe. L'algorithme *DTW* associe en effet chaque élément de chaque séquence à au moins un élément de l'autre séquence en minimisant les coûts d'association.

La Figure 5-11 suivante illustre un exemple de l'application de l'algorithme *DTW* entre deux séries X et Y .

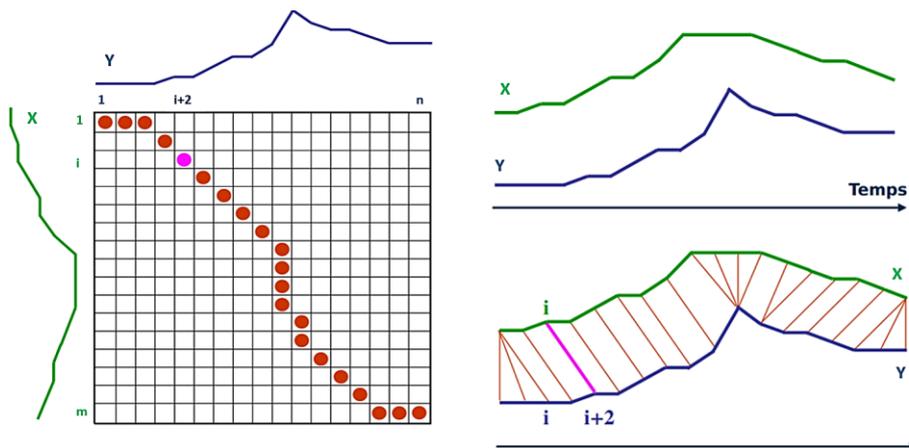


Figure 5-11 : Illustration d'un exemple de DTW entre deux séries X et Y [197].

L'algorithme *DTW* aligne les deux séries X et Y en appariant les éléments en fonction du chemin optimal représenté par des points dans la Figure 5-11-gauche. À droite de la figure nous pouvons constater (en rose) que le $i^{\text{ème}}$ élément de la série X est apparié au $i^{\text{ème}+2}$ de la série Y.

Pour renforcer notre propos, voici un exemple avec deux séquences $A = \langle 4,6,8,7,8 \rangle$ et $B = \langle 4,5,6,5,6,8,7 \rangle$. Le Tableau 5-3 illustre la matrice de distance D qui résulte de l'application de l'algorithme *DTW* pour aligner la séquence A à la séquence B en utilisant la fonction $\delta = |A(i) - B(j)|$.

Tableau 5-3 : Exemple d'application de l'algorithme DTW pour aligner la séquence A à la séquence B.

B/A	4	6	8	7	8
4	0	2	6	9	13
5	1	1	4	6	9
6	3	1	3	4	6
5	4	2	4	5	7
6	6	2	4	5	7
8	10	4	2	3	3
7	13	5	3	2	3

Le chemin en bleu dans le tableau précédent est le chemin minimal pour aligner la séquence A à la séquence B en appariant les éléments des deux séquences.

5.2.2. Application de la M-DTW à la détection du changement de comportement

Ce principe a donc été appliqué pour étudier la similarité entre la journée routine et chaque journée enregistrée. Comme précédemment pour la *M-DME*, la journée de la personne est décrite par une succession des postures avec indication de la chute ou de l'absence de la personne. L'algorithme *DTW* ne comparant pas les chaînes de caractères, il convient de proposer un codage numérique de la séquence. Après plusieurs expérimentations, il nous a semblé pertinent d'attribuer le poids le plus fort

aux positions les plus fréquentes de la journée et un poids moindre aux postures les moins fréquentes. Il importe de souligner qu'un codage inverse (poids forts aux événements rares) conduit exactement au même résultat.

Pour les deux personnes participant à notre étude, la chute est un événement qui n'apparaît pas dans la journée routine de la personne et reste un événement rare, elle a donc été encodée 0. Pour chaque personne dans la journée routine, la personne est plus souvent absente qu'allongée, et est plus souvent allongée qu'assise. Ces constats expliquent le choix suivant de l'annotation numérique des images :

Pour la personne A :

- Si la personne est debout « D », l'image est annotée 0
- Si la personne est assise « S », l'image est annotée 1
- Si la personne est allongée « L », l'image est annotée 2
- Si la personne est absente « A », l'image est annotée 3

Pour la personne B :

- Si la personne chute « C », l'image est annotée 0
- Si la personne est assise « S », l'image est annotée 1
- Si la personne est allongée « L », l'image est annotée 2
- Si la personne est absente « A », l'image est annotée 3

La *M-DTW* appliquée sur toute la durée d'enregistrement de 85 jours pour la personne A de la base Gladis et le calcul de la moyenne mobile par intervalles de 7 jours est reportée sur la Figure 5-12 qui montre que la *DTW* a bien quantifié le mode de vie régulier de la personne A (les distances sont quasiment nulles).

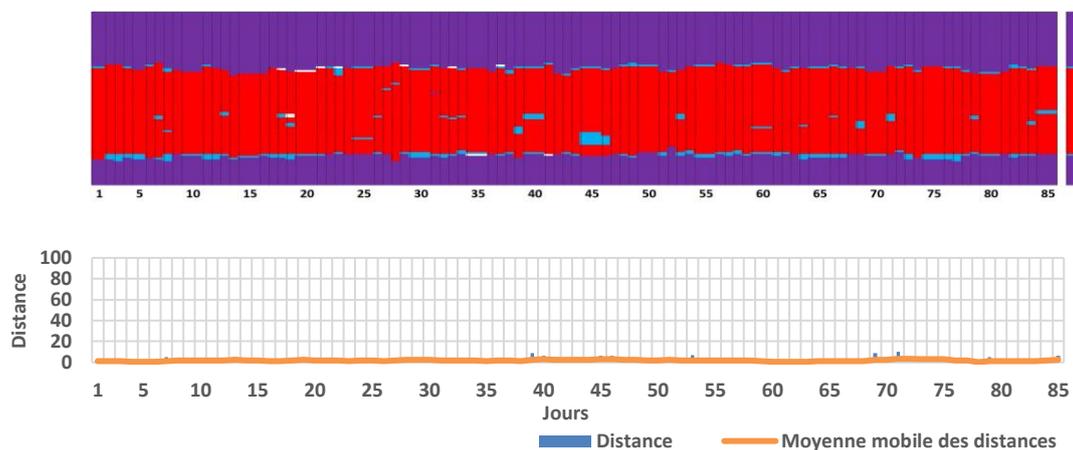


Figure 5-12 : Annotations des images de la personne A et les résultats de la distance de de la déformation temporelle dynamique entre la journée routine et chaque jour enregistré. La ligne continue représente la moyenne mobile des distances DTW par intervalle de 7 jours.

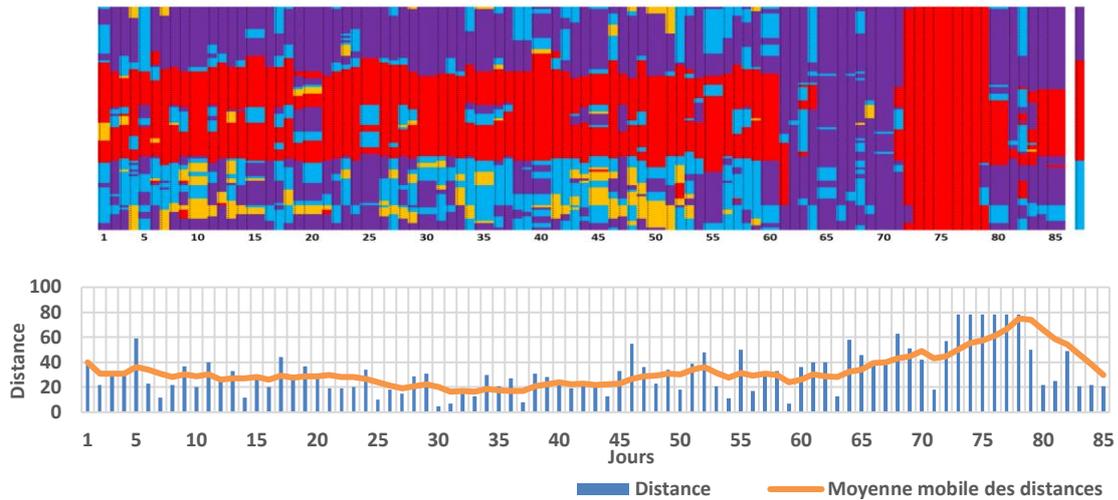


Figure 5-13 : Annotations des images de la personne B et les distance de de la déformation temporelle dynamique entre la journée routine et chaque jour enregistré. La ligne continue représente la moyenne mobile des distances DTW par intervalle de 7 jours.

Pour la personne B, l'analyse montre (Figure 5-13) une nouvelle fois que la personne présente des changements de comportement. En analysant la courbe de la moyenne mobile pour la personne B, on remarque une augmentation du nombre de transformations après le jour 62 (pour mémoire la personne est plus souvent allongée puis absente). On constate aussi la diminution de la *DTW* qui correspond au retour de la personne B à sa chambre. En synthèse, cette analyse globale est similaire à l'analyse décrite pour l'évolution de *DME* des personnes A et B. De la même manière que pour l'application de l'algorithme de la distance d'édition, la base de données a été divisée en 7 groupes homogènes de journées (A, B, C, D, E, F et G). La Figure 5-14 présente les annotations des images par jour, les résultats des distances de l'algorithme *DTW* par jour et les boxplots des distances dynamiques pour chaque groupe de la personne B.

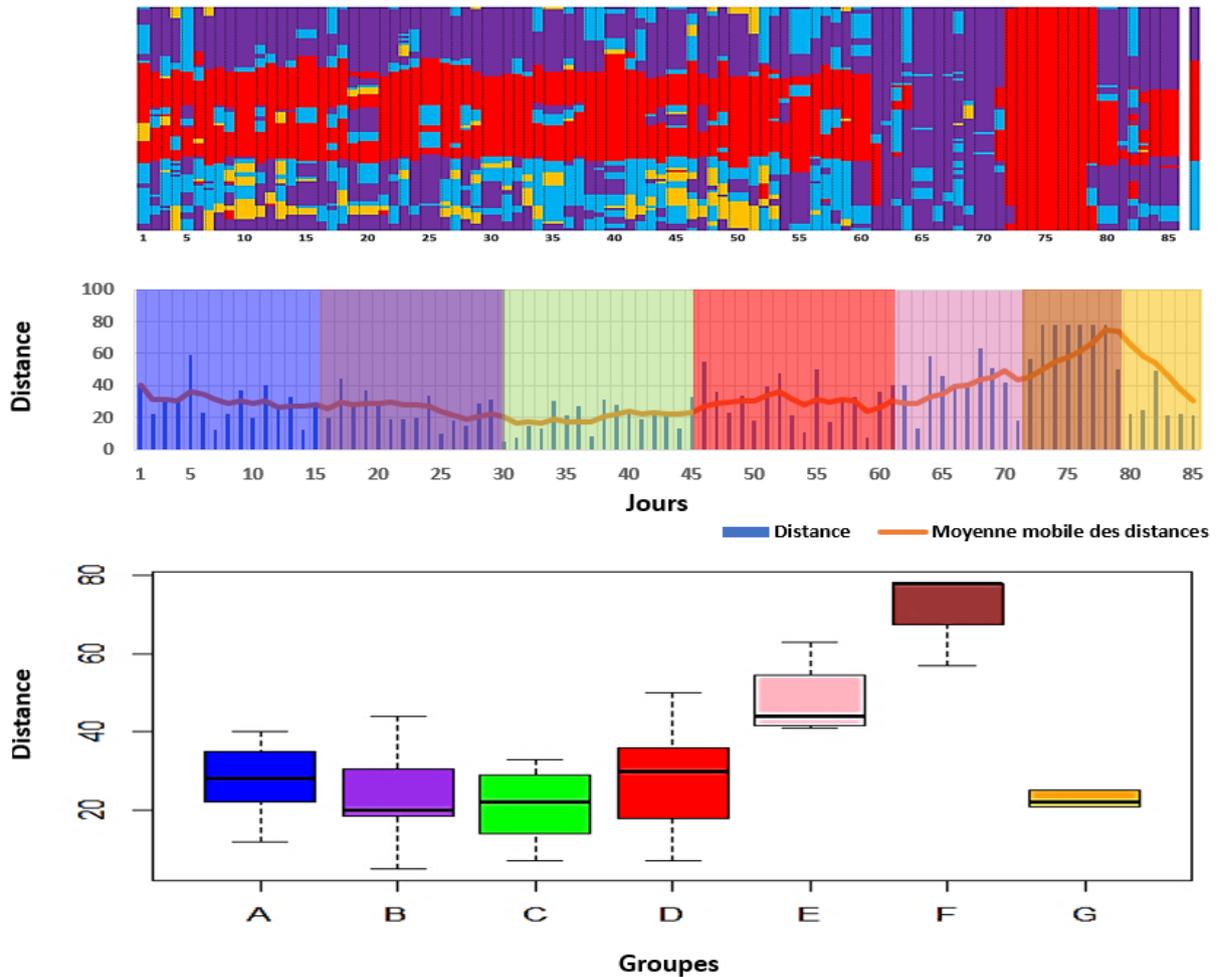


Figure 5-14 : Annotations des images par jour, résultats des distances DTW par jour et les boxplots de la DTW pour chaque groupe.

Les résultats du test statistique de Wilcoxon par pair de groupe sont présentés dans le Tableau 5-4.

Tableau 5-4 : Résultats du test de Wilcoxon.

	A	B	C	D	E	F
B	0.35					
C	0.21	0.78				
D	0.98	0.44	0.28			
E	0.01	0.01	0.01	0.01		
F	0	0	0	0	0	
G	0.54	0.56	0.73	0.78	0.15	0

On remarque d’une part que les groupes A, B, C et D ne sont pas significativement différents ($p > 0.05$), et d’autre part que les groupes A, B, C et D sont significativement différents des groupes E et F ($p < 0.05$). Ces deux derniers groupes sont aussi significativement différents. Cette différence s’explique en partie par la stratégie de codage que nous avons retenue favorisant les postures ou situations les plus fréquentes (ici l’absence de la personne). Le groupe G n’est pas significativement

différent des groupes A, B, C, D et E. Le groupe G est significativement différent de F. En observant le box-plot, on constate même une bonne ressemblance entre ces groupes. La *M-DTW* semble capturer mieux le retour à la routine de la personne que la *M-DME*. Ceci est confirmé par la Figure 5-15 qui synthétise ces résultats en présentant les boxplots du groupe routine R (regroupement des groupes A, B, C, et D) et du groupe non-routine NR (association des groupes E et F). Ces boxplots, nous permet de comparer les résultats obtenus par *M-DTW* (Figure 5-15) et ceux obtenues par *M-DME* (Figure 5-8), en notant une nouvelle fois, Med [Q25th, Q75th] la médiane et l'intervalle interquartile. Pour le groupe *routine* nous obtenons 25 [19, 33] avec *M-DTW* et 35[29, 43] avec *M-DME* et pour le groupe *non-routine* 51 [41, 78] avec *M-DTW* et 56 [55, 61] avec *M-DME*. Les deux groupes semblent être mieux séparés en utilisant la *M-DTW*.

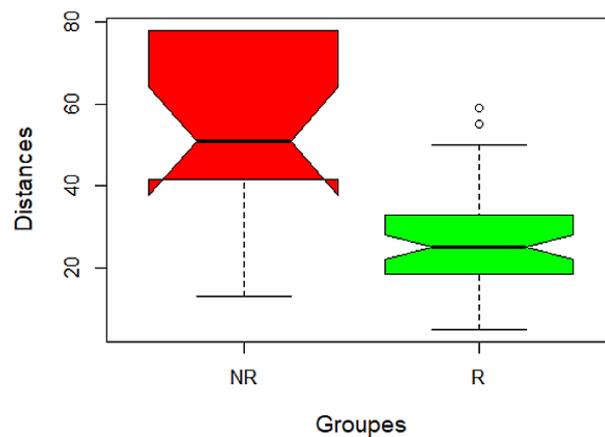


Figure 5-15 : Boxplots des groupes routines et non-routines des distances DTW de la personne B.

Le test de CUSUM appliqué pour estimer le changement de comportement est reporté sur la figure suivante et illustre les résultats du test. Le test montre une détection du changement au 65^{ème} jour ce qui présente un léger retard par rapport à la vérité terrain, étant donné que la personne change de comportement à partir du 61^{ème} jour.

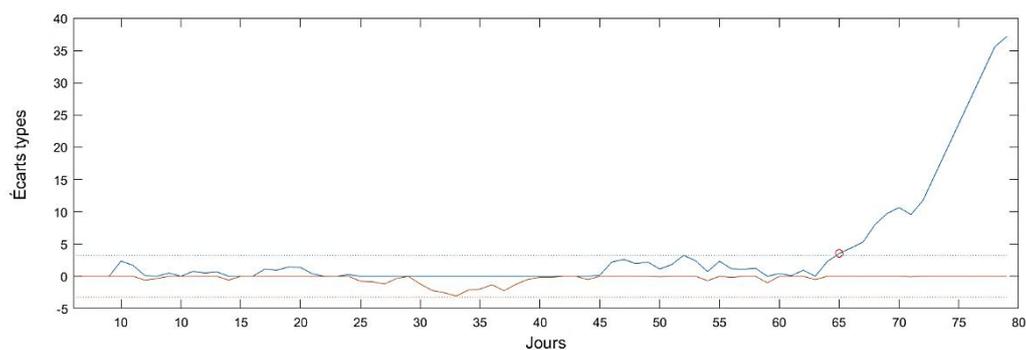


Figure 5-16 : Résultat du test CUSUM appliqué aux distances DTW du jour 1 au jour 79 de la personne B.

5.3. Détection du changement de comportement par classification de la nature de la journée

Les approches précédentes cherchent à caractériser les modifications tout au long de la journée. Il était aussi important de regarder le changement de comportement au jour le jour mais de manière globale. La Figure 5-17 présente le schéma de détection du changement de comportement de cette nouvelle approche :



Figure 5-17 : Schéma de la détection du changement de comportement par classification de la nature de la journée.

La méthode de détection du changement de comportement par Classification de la Nature de la Journée (*M-CNJ*) est composée de 3 étapes. La première étape consiste à enregistrer la personne avec des caméras de profondeurs et de classer les images en posture (*allongé, assis, debout*), en *absence* ou en position *chute*. Chaque journée est alors décrite, dans un premier temps, par une succession des postures avec indication de l'absence et de la chute de la personne, et dans un deuxième temps, la journée est définie par les cinq indices suivants : le pourcentage de temps en position *assise*, le pourcentage de temps en position *debout*, le pourcentage de temps en position *allongée*, le pourcentage de temps d'*absence* de la personne et du nombre de *chutes*.

Deux études ont alors été envisagées : i) la première où nous cherchons à apprendre les classes à partir des observations, ceci relève d'une approche non supervisée, ii) la deuxième où nous supposons connaître les classes afin de mettre en œuvre une approche supervisée. Ces deux approches pouvant d'ailleurs être complémentaires.

La classification du type de la journée permet ensuite de détecter les journées *routines* et les journées *non-routines*. À la dernière étape, le monitoring des résultats de la classification du type de la journée permet de repérer le changement de comportement de la personne.

5.3.1. Auto-apprentissage des classes des jours

La classification des images enregistrées pour chaque jour, par le biais du réseau de neurones ResNet-18 (voir section 4.2), permet de calculer pour la journée les valeurs des indices suivants : pourcentage en temps *assis*, pourcentage en temps *allongé*, pourcentage en temps *debout*, pourcentage en temps *absent* et le nombre de *chutes*. Dans cette section, une approche permettant de construire automatiquement les classes est proposée. Elle s'appuie sur les méthodes de clustering qui ont comme avantage de ne faire aucune hypothèse sur le nombre de classes observées mais cherche au contraire à les identifier.

Nous avons considéré deux cas de figure où chaque journée est décrite par :

- 1- Une succession des postures (*allongée, debout, assise*) avec indication de l'*absence* et de la *chute* de la personne ;
- 2- Les valeurs des indices du jour (pourcentage en temps allongé, pourcentage en temps assis, pourcentage en temps debout, pourcentage en temps absent et nombre des chutes).

Dans le cas où la journée est décrite par les valeurs des indices du jour, l'algorithme de clustering par K-moyennes [198] a été retenu. Cet algorithme analyse un ensemble de données où chaque donnée est caractérisée par un ensemble de descripteurs et regroupe les données similaires en K clusters (groupes) autour d'un centre de gravité (centroïde).

Le principe de l'algorithme K-moyennes peut être résumé ainsi :

- 1- Choisir au hasard K points (une ligne de la matrice des données). Ces K points sont les centres des clusters (centres de gravité).
- 2- Affecter chaque élément de l'ensemble des données au groupe dont le centre de gravité est le plus proche.
- 3- Recalculer le centre de gravité de chaque groupe et modifier le centroïde jusqu'à la convergence ou la stabilisation de l'inertie totale de l'ensemble des données.

Dans le cas où la journée est décrite par une succession des postures, l'algorithme K-modes [199] a été retenu car les données sont catégorielles. La méthode K-modes est similaire à la méthode de K-moyennes où le centre du cluster est calculé en fonction des fréquences des modalités majoritaires présentes dans ce cluster.

5.3.1.1. Autoapprentissage : cas la journée décrite par une succession des postures

Lorsque la journée est décrite par une succession des postures (*assise, allongée, chute*) avec indication de l'*absence* de la personne, on classe les jours des personnes A et B de la base Gladis par l'algorithme K-modes.

5.3.1.1.1 Classification des jours de la personne A

La Figure 5-18 suivante présente l'évolution de la somme de toutes les dissimilarités entre les clusters selon le nombre de groupes (notées le coût) après avoir appliqué l'algorithme K-modes en fonction du nombre prédéfini de clusters K. Nous pouvons remarquer que le taux de discrimination entre classes évolue peu lorsque le nombre de classes a priori augmente. Nous pouvons toutefois voir une rupture entre 4 et 5 classes ceci nous incite à fixer $K = 4$.

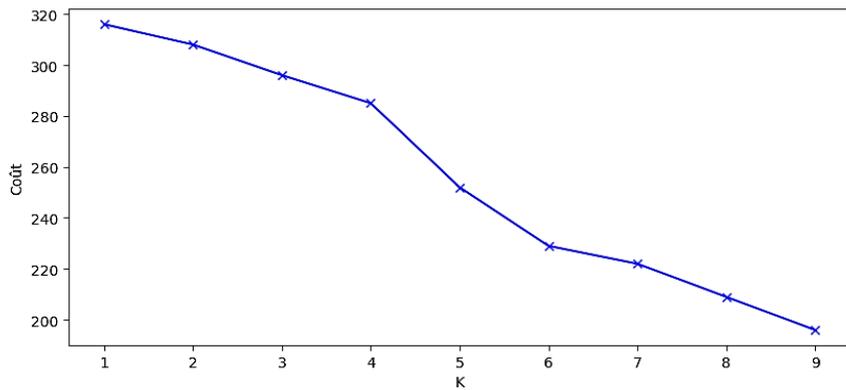


Figure 5-18 : Evolution de la somme de toutes les dissimilitudes entre les clusters en fonction du nombre des clusters K pour la personne A.

La Figure 5-19 montre l'évolution de la classification de la journée pour le nombre des classes K égal à 4 avec un rappel de la figure d'annotation des images de la personne A.

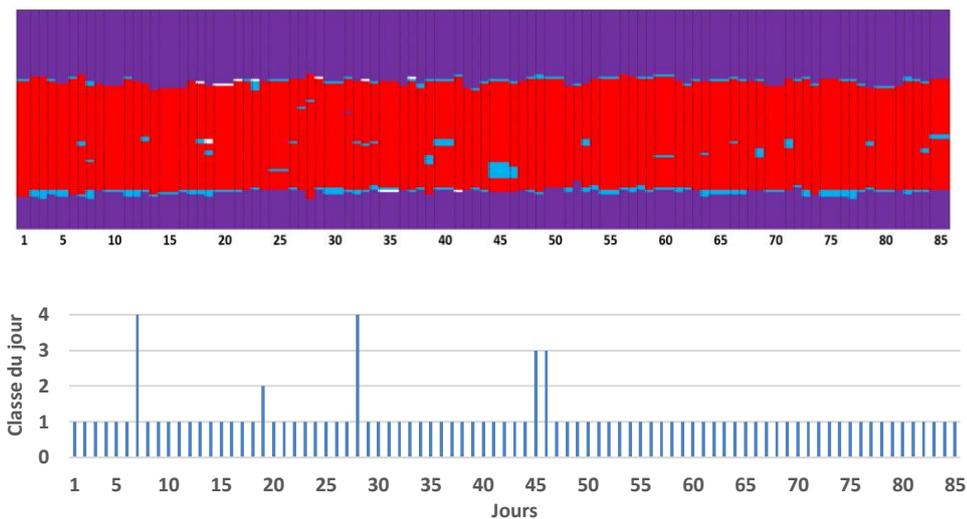


Figure 5-19 : Classification des jours de la personne A (classes 1, 2, 3 et 4).

On voit clairement ici que sans aucun a priori, on est capable d'identifier le caractère routinier de la personne A (la majorité des observations sont affectées à la classe 1 qui représente la routine de la personne). L'analyse de la vérité terrain montre que durant les journées 7 et 28 qui sont classées en classe 4 la personne est un peu plus absente que les autres jours. La journée 19 montre que durant cette journée, à la différence des autres jours, la personne a été enregistrée deux fois en posture debout. On rappelle que la personne enregistrée présente un problème de mobilité et est très rarement enregistrée en position debout. Les jours 45 et 46 sont classés en classe 3, car la personne est détectée plus souvent assise durant ces jours. Pour chaque journée on compte le pourcentage en temps *assise*, le pourcentage en temps *allongé*, le pourcentage en temps *debout*, le pourcentage en temps *absente* et le nombre des *chutes*.

Les résultats de classification permettent alors de construire automatiquement les intervalles [minimum du pourcentage des jours de la classe i , maximum des jours de la classe i]. Le tableau suivant présente les intervalles des indices de la journée routine par la classification K-modes et par l'annotation de la vérité terrain des types du jour (La vérité terrain est basée sur l'annotation du type du jour après avoir analysé les images enregistrées) :

Tableau 5-5 : Intervalles des indices de la journée routine (de la méthode K-modes et de la vérité terrain).

	Intervalles de la journée routine	
	K-modes	Vérité terrain
Nombre de CHUTES	[0, 0]	[0, 0]
Pourcentage ASSISE	[0%, 7%]	[0%, 8%]
Pourcentage ALLONGÉE	[45%, 56%]	[44%, 56%]
Pourcentage ABSENTE	[43%, 52%]	[43%, 55%]
Pourcentage DEBOUT	[0%, 1%]	[0%, 2%]

Nous remarquons que les intervalles des indices des jours routines issues de la méthode de classification K-modes et de la vérité terrain sont quasiment égaux.

5.3.1.1.2. Classification des jours de la personne B

La Figure 5-20 présente l'évolution de la somme de toutes les dissimilarités entre les clusters selon le nombre de groupes. Une nouvelle fois une rupture de cet indice se dégage pour 4 classes.

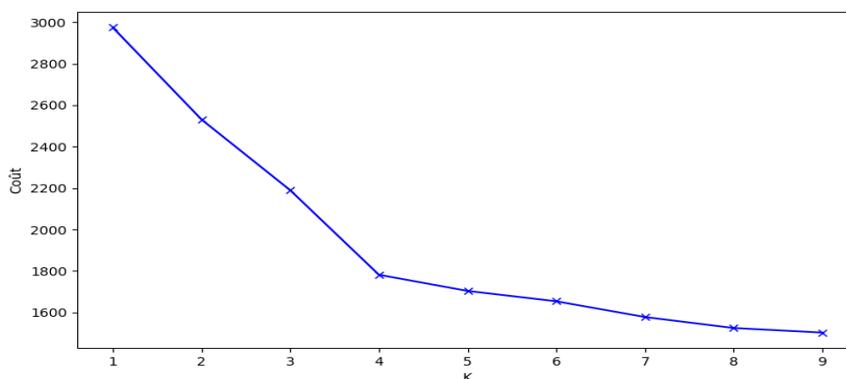


Figure 5-20 : Évolution de la somme de toutes les dissimilarités entre les clusters en fonction du nombre des clusters K pour la personne B.

La Figure 5-21 présente la classification des 85 jours enregistrés de la personne B pour le nombre des classes K égal à 4 avec un rappel de la figure d'annotation des images de la personne B.

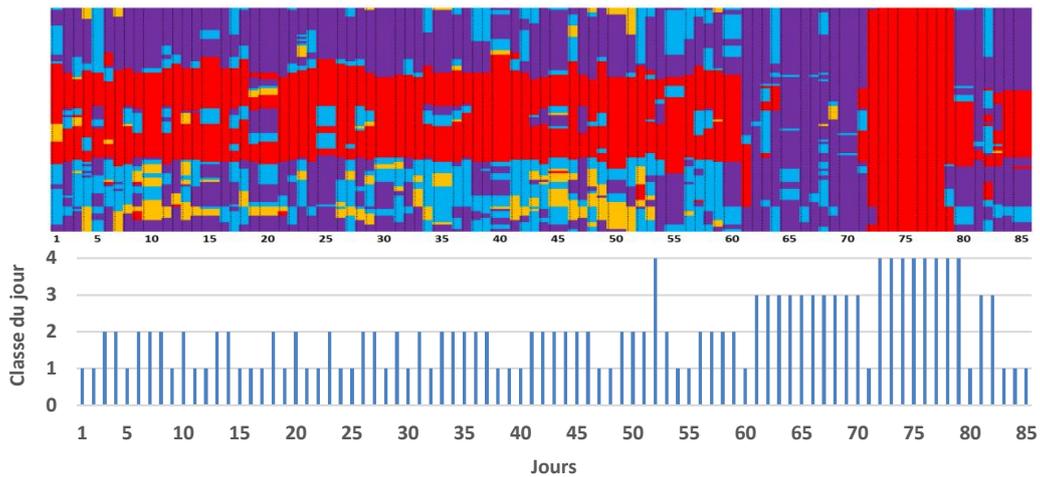


Figure 5-21 : Classification des jours de la personne B (classes 1, 2, 3 et 4).

De la figure précédente, nous pouvons remarquer que, du premier jour au 60^{ème} jour, la majorité des jours sont classés en classes 1 et 2. Suivi de 10 jours classés en 3 et suivi d’une journée classée 1 et puis 8 jours classés en classe 4. Enfin lors des 6 derniers jours, il y a un mélange des classes 1 et 3.

La Figure 5-22 illustre les annotations des images des jours groupés selon les classes de l’algorithme K-modes.

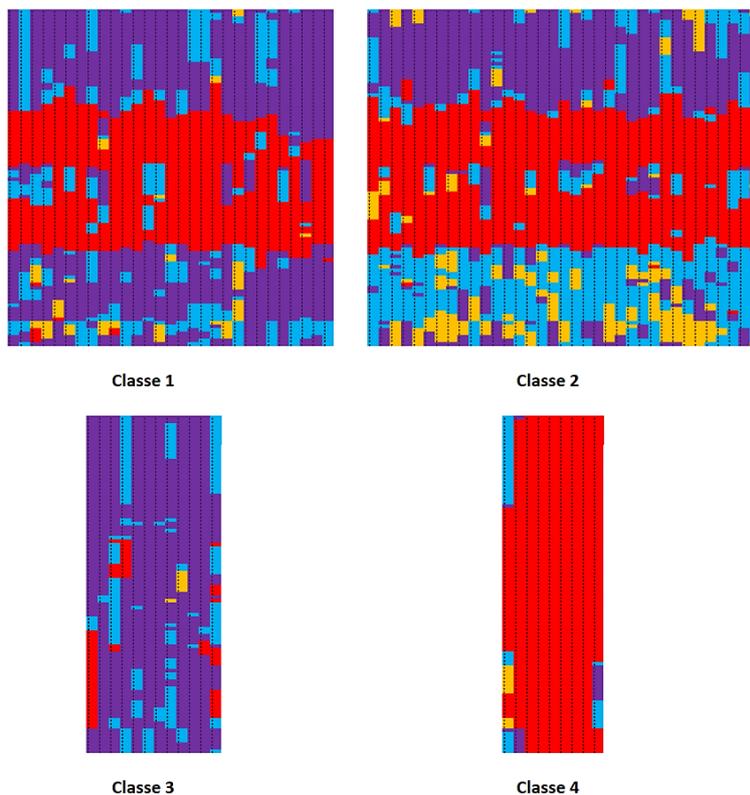


Figure 5-22 : Annotations des images des jours enregistrés selon le type de classes (assis en couleur bleue, allongé en couleur mauve, absent en couleur rouge, debout en couleur blanche et chute en jaune).

La vérité terrain montre que la classe 4 correspond à l'absence de la personne, la classe 3 décrit les jours où la personne est plus souvent allongée durant la journée. L'algorithme a également détecté deux types (classes 3 et 4) de jours anormaux et non-routine de la personne. Les classes 1 et 2 décrivent deux types de comportements de journée routine. En effet, les jours classés 1 ont un rythme différent des jours classés 2. La personne dans les jours du groupe 2 est plus souvent assise (couleur bleu) après son retour à la chambre par rapport à la classe 1. Nous pouvons également constater que dans le groupe 2, la personne a été plus enregistrée au sol (couleur jaune). Les boxplots des pourcentages des images en fonction de la classe de la journée confirment cette analyse (Figure 5-23).

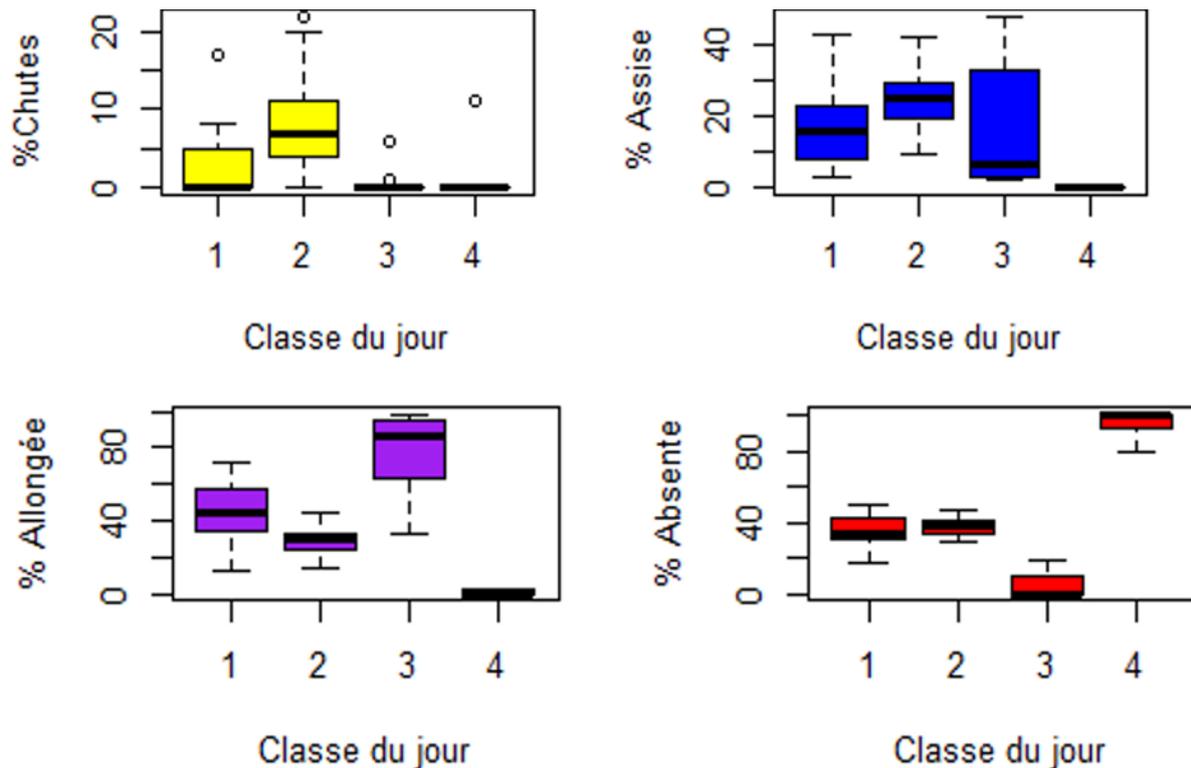


Figure 5-23 : Boxplots des pourcentages des images en position chute, assise, allongée, et absent par jour selon les classes des jours.

La classification des jours de la personne B par l'algorithme K-modes a permis de différencier les jours de la routine (du jour 1 au jour 60) puis la perte de la routine (du jour 61 au jour 79) en distinguant deux catégories de journées anormales (les classes 3 et 4) et, pour terminer, le retour progressif à la routine durant les six derniers jours (présence des classes 1 et 3). La personne B chute souvent car c'est une personne dépendante qui a des problèmes de mobilités, par conséquent la chute fait partie de sa routine. L'algorithme K-modes ne prend pas en compte le nombre des chutes mais la fréquence des images en position chute.

Le Tableau 5-6 présente les intervalles des indices de la journée routine (indices pourcentage en temps *debout*, pourcentage en temps *allongé*, pourcentage en temps *assis*, pourcentage en temps *absente* et le nombre des *chutes*) par la méthode K-mode et de la vérité terrain :

Tableau 5-6 : Intervalles de la journée routine de la personne B (de la méthode K-modes et de la vérité terrain).

	Intervalles de la journée routine	
	K-modes	Vérité terrain
Nombre de CHUTES	[0, 4]	[0, 4]
Pourcentage ASSISE	[3%, 49%]	[3%, 49%]
Pourcentage ALLONGÉE	[13%, 73%]	[13%, 72%]
Pourcentage ABSENTE	[18%, 56%]	[17%, 50%]
Pourcentage DEBOUT	[0%, 0%]	[0%, 0%]

Nous pouvons remarquer que les intervalles des indices des jours routines issues de la méthode de classification K-modes et de la vérité terrain sont quasiment égaux.

L'algorithme a inclus la chute dans le comportement *routine* de la personne car cette personne chutait souvent auprès de son lit. Il importe de souligner cependant qu'une alarme est générée pour chaque chute.

5.3.1.2. Autoapprentissage : La journée décrite par les indices du jour

L'algorithme K-moyenne est cette fois-ci appliqué aux jours enregistrés des personnes A et B où chaque jour est défini par le pourcentage en temps *allongé*, le pourcentage en temps *assis*, le pourcentage en temps *debout*, le pourcentage en temps *absent* et le nombre des *chutes*.

5.3.1.2.1. Classification des jours de la personne A

La Figure 5-24 présente l'évolution de l'inertie (l'inertie est la somme des distances au carré des échantillons par rapport à leur centre du groupe le plus proche) en fonction des nombres des classes *K*.

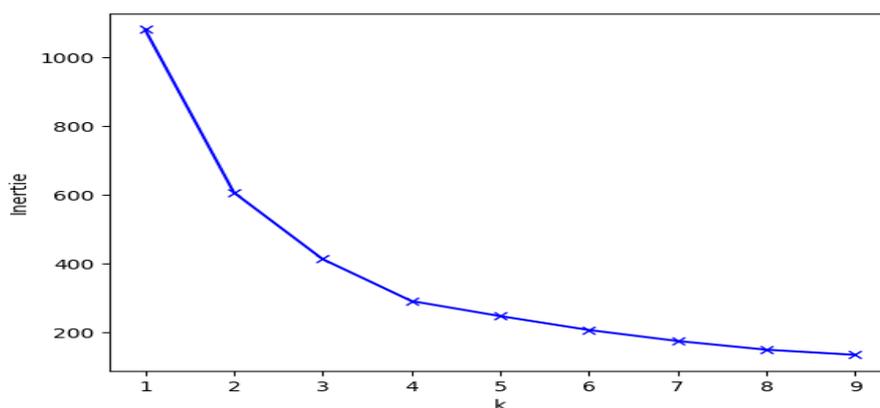


Figure 5-24 : Evolution de l'inertie en fonction du nombre des classes *K* de la personne A.

On voit que l'inertie chute brutalement entre $K = 1$ et $K = 3$. On se rend compte qu'un coude apparaît à $K = 4$ et l'inertie décroît ensuite légèrement. Nous considérons donc que $K = 4$ permet de bien discriminer les différents types de journées.

La Figure 5-25 présente les résultats de classification des jours selon le nombre des classes K égal à 4 et rappelle l'annotation des images des jours de la personne A.

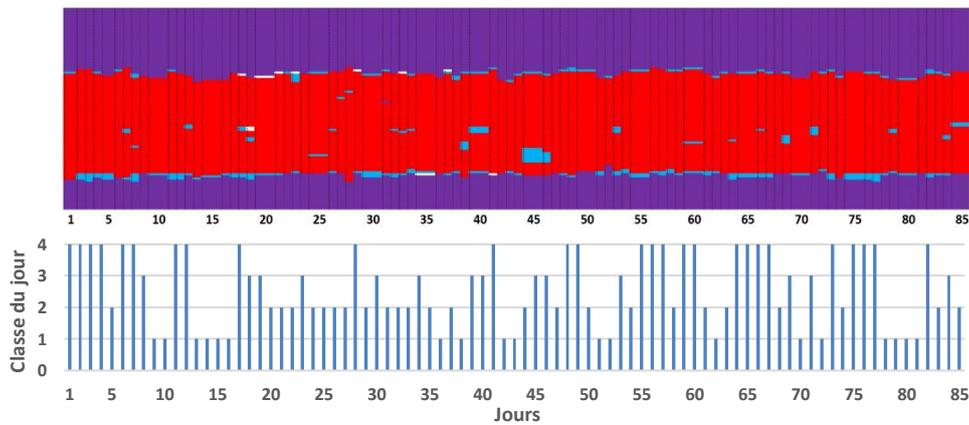


Figure 5-25 : Classification des jours de la personne A selon le nombre des classes (1, 2, 3 et 4).

Afin de mettre en évidence la différence entre les 4 classes des jours, la Figure 5-26 présente les boxplots des indices du jour (% allongée, % assise, % debout et % absente). Nous rappelons que la personne A ne chute jamais et par conséquent le graphe des chutes n'est pas présenté.

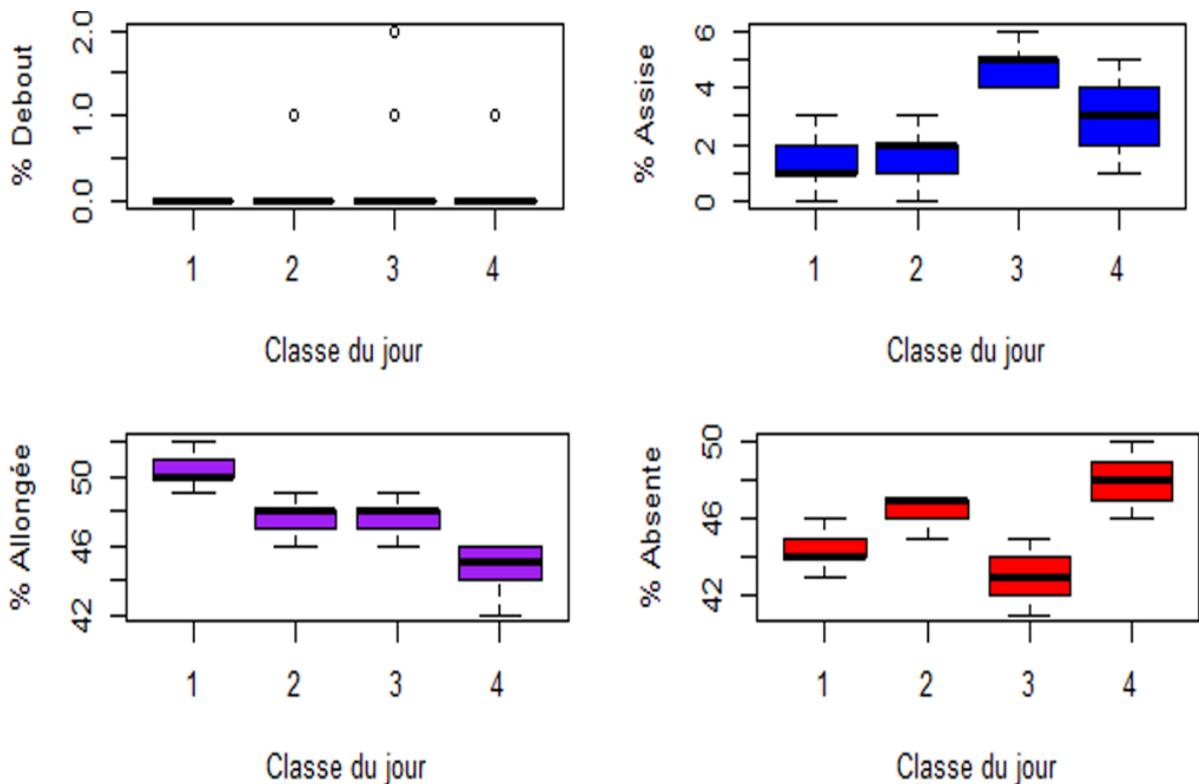


Figure 5-26 : Boxplots pour les 4 classes de jours (resp. 1 à 4) des indices : pourcentage en temps allongé, pourcentage en temps assis, pourcentage en temps debout et pourcentage en temps absent de la personne A.

L'indice pourcentage *debout* durant la journée n'est pas significatif pour la répartition des jours car la personne est une personne dépendante et rarement enregistrée en position debout. Pour les autres indices, on remarque que la différence de pourcentages des quatre classes est petite. L'algorithme K-moyennes a classé les jours en prenant en compte la différence minimale entre les indices des jours. La classe 3 correspond aux jours (14 jours) où la personne est enregistrée le plus souvent assise. La classe 1 correspond aux jours (19 jours) où la personne est un peu plus allongée. La classe 4 caractérisent les jours où la personne est plus absente (27). Les indices des 25 jours de la classe 2 se chevauchent avec les indices des autres classes.

La classification par la K-moyennes a permis de repérer le comportement routinier de la personne A et de définir quatre niveaux de routine de la personne. En exploitant notre connaissance a priori, nous avons décidé de fusionner ces quatre classes, par conséquent les intervalles des indices de la journée routine sont égaux aux intervalles *routines* de la vérité terrain car la personne a en réalité un comportement routinier sur toute la période d'enregistrement. Le Tableau 5-7 présente les intervalles des indices de la journée routine de la personne A.

Tableau 5-7 : Intervalles des indices de la journée routine de la personne A.

	<i>Intervalles de la journée routine</i>
Nombre de CHUTES	[0, 0]
Pourcentage ASSIS	[0%, 8%]
Pourcentage ALLONGÉ	[44%, 56%]
Pourcentage ABSENTE	[44%, 56%]
Pourcentage DEBOUT	[0%, 2%]

Il importe de remarquer que les intervalles de la journée routine des indices par la méthode d'apprentissage K-moyenne sont similaires aux intervalles des indices de la journée routine par la méthode d'apprentissage K-modes vue à la section précédente (Tableau 5-5).

5.3.1.2.2. Classification des jours de la personne B

La Figure 5-27 suivante présente l'évolution de l'inertie en fonction des nombres des classes K

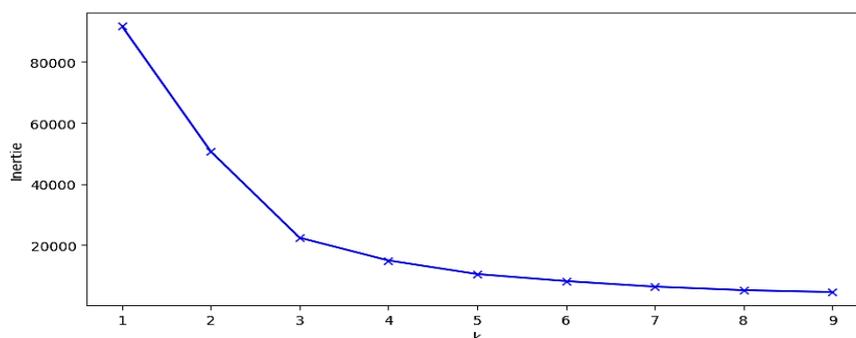


Figure 5-27 : Evolution de l'inertie en fonction du nombre des classes K.

Pour la personne B, le coude dans l'évolution de l'inertie apparaît pour $K = 3$. La figure suivante présente la classification des jours pour K égal à 3 avec le rappel de la figure d'annotation des images de la personne B.

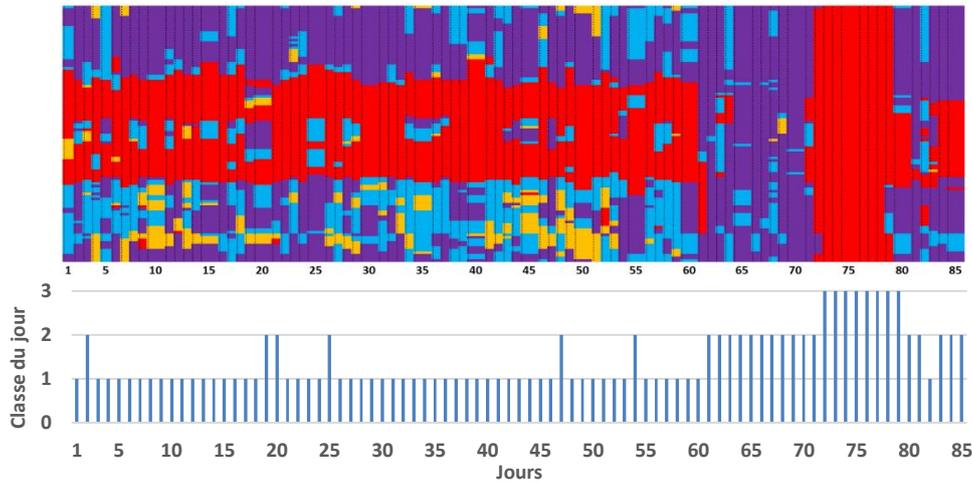


Figure 5-28 : Classification des jours de la personne B selon le nombre des classes (1,2 et 3).

La classe 2 correspond à la situation où la personne est allongée plus de 50% du temps durant la journée. La classe 3 est la classe des jours où la personne est absente. La classe 1 correspond à la routine de la personne. On constate que l'algorithme a détecté le comportement *routine* du premier jour au 60^{ème} avec la présence de 6 jours où la personne est plus allongée durant la journée. Il a également détecté le comportement anormal de la personne du jour 61 au jour 79 où la personne est la plus souvent allongée (la classe 2) puis absente (classe 3). Durant les 6 derniers jours, on retrouve 5 journées *non-routines* avec la présence d'une journée *routine* qui correspond au retour progressif à la routine.

Le Tableau 5-8 présente les intervalles minimum et maximum de chaque indice des jours de la classe 1 et des indices de la vérité terrain de la journée routine :

Tableau 5-8 : Intervalles de routine de la personne B (de la méthode K-moyennes et de la vérité terrain).

	Intervalles de la journée routine	
	K-moyennes	Vérité terrain
Nombre de CHUTES	[0, 4]	[0, 4]
Pourcentage ASSIS	[4%, 49%]	[3%, 49%]
Pourcentage ALLONGÉ	[13%, 52%]	[13%, 72%]
Pourcentage ABSENTE	[19%, 56%]	[17%, 50%]
Pourcentage DEBOUT	[0%, 0%]	[0%, 0%]

On remarque que les intervalles de la journée routine sont similaires aux intervalles de la journée routine de la vérité terrains sauf pour l'indice pourcentage allongée (le maximum est de 73% versus 52% de la classification par l'algorithme K-moyennes).

5.3.2. Classification du type de la journée par une approche supervisée

L'auto apprentissage de la section précédente a permis de définir les intervalles de la journée routine. Nous postulons dans cette section qu'une journée qui n'est pas *routine* est une journée *non-routine*. Cette remarque consiste à fusionner les classes précédentes des journées *non-routines*. Ceci a aussi comme implication de retenir des approches de classification capables d'appréhender des classes séparées non linéairement.

La classification en journée *routine* ou *non-routine* peut être vue alors comme un problème de classification/prédiction basé sur les paramètres qui caractérisent cette journée (pourcentage en temps *assis*, pourcentage en temps *allongé*, pourcentage en temps *debout*, pourcentage en temps *absent* et le nombre de *chutes*). Trois approches ont été comparées :

1. La régression binaire logistique [200] (*BRL* : Binary Regression Logistic) : la *BRL* a été choisie parce que le problème de classification est réduit à un problème de classification binaire et qu'il s'agit d'une approche standard.
2. L'arbre de décision (*DT* : Decision Tree) [154] : le *DT* a été retenu car il fournit des règles de décision interprétables.
3. La forêt aléatoire (*RF* : Random Forest) [155] : Le *RF* sont reconnues comme robustes. Elles effectuent un entraînement sur plusieurs arbres de décision à partir de différents sous-ensembles de données.

Dans cette étude, nous sommes dans le cas d'un modèle binaire à deux classes : la classe positive (journée *routine*) et une classe négative (journée *non-routine*). Les mesures de performance ont donc été évaluées de manière classique en calculant la précision, la spécificité et la sensibilité de chaque méthode de classification (cf. chapitre II). Les jours de *routine* et *non-routine* sont définis suivant l'apprentissage réalisé par classification au moyen des algorithmes K-modes et K-moyennes.

5.3.3. Détection du changement de comportement

Le principe de détection des changements de comportement consiste à attribuer la valeur 1 à un jour n ($J(n) = 1$) s'il suit la routine quotidienne de la personne et la valeur 0 ($J(n) = 0$) s'il ne la suit pas. Ce principe est basé sur le calcul récursif de l'indice de comportement noté *BI* (Behaviour Index) sur une fenêtre temporelle Pt :

$$BI(n) = BI(n - 1) + \frac{J(n) - J(n - Pt)}{Pt}$$

BI reflète le pourcentage des jours de routine sur la période Pt . Ce n'est rien d'autre que l'estimation récursive d'une moyenne mobile sur une période Pt . Le résultat de l'évolution du *BI* pendant la période de N jours décrit l'évolution du maintien de la routine de manière continue sur une période glissante Pt .

5.3.4. Application à la détection du changement de comportement

La *M-CNJ* a été appliquée de nouveau aux deux personnes âgées dépendantes (A et B) enregistrée avec des capteurs de profondeur dans leur chambre de maison de retraite durant une

période de 85 jours (voir section 2.2.1 du manuscrit). La classification des jours par les algorithmes K-modes et K-moyennes a permis d'apprendre, comme précisé ci-dessus, les journées *routines* et les journées *non-routines par fusion des classes apprises*. Chaque jour est décrit par les indices pourcentage en temps *allongé, assis, debout, absent* et le nombre des *chutes*. La régression logistique binaire (*BRL*), l'arbre de décision (*DT*) et les forêts aléatoires (*RF*) ont été utilisés pour classer le type de jour avec une méthode de validation croisée "Leave-One-Out" [201]. L'index *BI* est ensuite calculé sur la base de cette classification comme indiqué dans la formule précédente.

5.3.4.1. Personne A

Dans le cas de la classification des jours en *routine* et *non-routine* suite à la classification par l'algorithme K-modes, les performances des trois approches d'apprentissage automatique pour la base de données résultant des images annotées en posture (*allongé, assis, debout*), et en *absence* de la personne A sont présentées dans le Tableau 5-9 .

Tableau 5-9 : Performances de classification du type de la journée de la personne A.

	<i>Precision</i>	<i>Spécificité</i>	<i>Sensibilité</i>
<i>BRL</i>	93%	98%	0%
<i>DT</i>	94%	100%	0%
<i>RF</i>	100%	100%	100%

Parmi les jours de la personne A, seulement cinq jours sont *non-routine*. Les jours *non-routine* ne sont pas détectés par la classification régression logistique binaire et les arbres de décision. Les résultats de prédiction du type de la journée montrent que les forêts aléatoires affichent les meilleurs résultats de prédiction.

La Figure 5-30 montre l'évolution de l'indice de comportement *BI* pendant 85 jours sur une période glissante de 7 jours (c'est-à-dire $Pt = 7$) en utilisant i) l'annotation de vérité terrain du type du jour et ii) la sortie de la méthode de classification *RF* de la base de données résultant de la détection des postures de l'absence et de la chute.

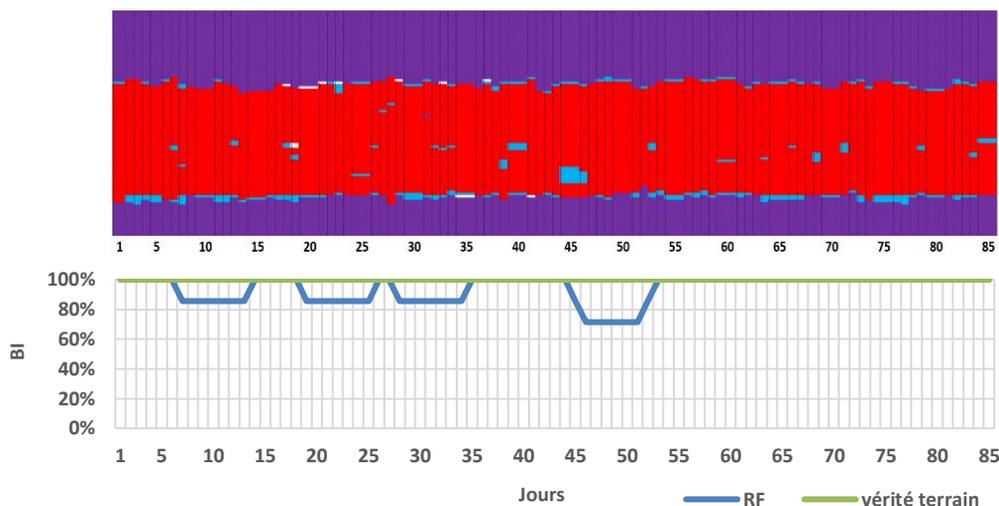


Figure 5-29 : Évolution de l'indice BI issu de la classification par des forêts aléatoires (RF) et de la vérité terrain de la personne A.

Nous pouvons observer que la personne A maintient sa routine sur toute la période d'enregistrement (*BI* supérieur à 70%) dans les deux cas.

L'analyse de nos résultats sur la personne A a montré que nous mettions en évidence seulement une seule classe. Ce constat montre que les approches supervisées ne sont pas directement applicables pour prédire le type de la journée et souligne une des limitations de cette approche.

5.3.4.2. Personne B

Nous avons procédé comme précédemment et les journées sont classées en journée *routine* et *non-routine* suite à la répartition des jours par la méthode de K-modes et en fusionnant les classes *routine* d'une part et les classes *non-routine* d'autre part. Pour la personne B, nous trouvons 21 journées *non-routines* et 64 journées *routines*.

Le Tableau 5-10 présente les performances des trois approches d'apprentissage automatique pour la base de données résultant des images annotées en posture (*allongé, assis, debout*), en *absence* et en nombre de *chutes* de la personne B.

Tableau 5-10 : Performances de classification du type de la journée de la personne B après avoir classé les jours avec l'algorithme K-modes.

	<i>Precision</i>	<i>Spécificité</i>	<i>Sensibilité</i>
<i>BRL</i>	81%	96%	50%
<i>DT</i>	94%	98%	81%
<i>RF</i>	100%	100%	100%

Les résultats de prédiction du type de la journée montrent que pour la personne B également, les forêts aléatoires affichent les meilleurs résultats de prédiction.

La Figure 5-30 montre l'évolution de l'indice de comportement *BI* pendant 85 jours sur une période glissante de 7 jours (c'est-à-dire $Pt = 7$) en utilisant : i) l'annotation de vérité terrain et ii) la sortie de la méthode de classification *RF* de la base de données résultant de la détection des postures de l'absence et de la chute de la personne B.

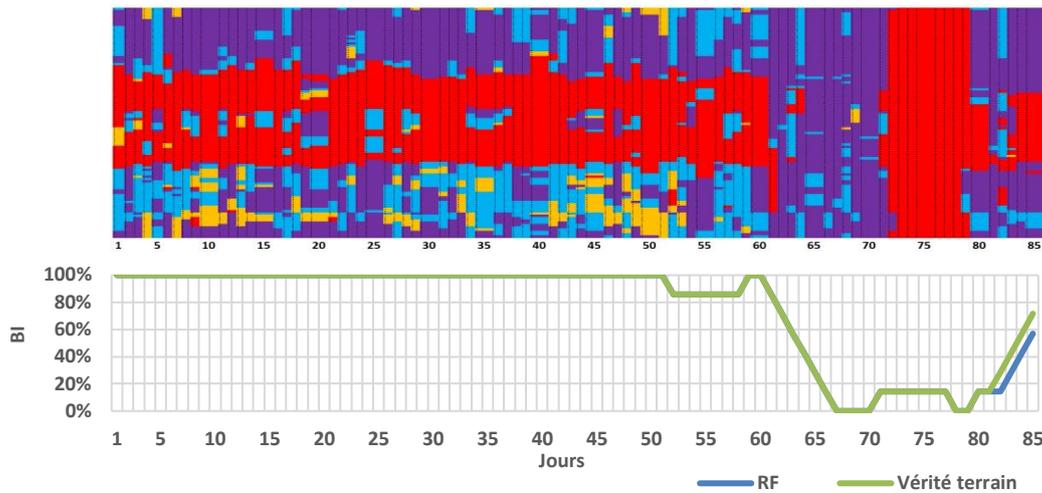


Figure 5-30 : Évolution de l'indice BI issu de la classification des jours par RF de la personne B.

Nous observons la même évolution du *BI* de la vérité terrain et des jours prédits par RF : du premier au 61^{ème} jour que le *BI* est quasi-constant ($BI \in [82\%, 100\%]$) et traduit que la routine est maintenue. Puis pendant 19 jours, la personne ne suit plus sa routine quotidienne. Puis le *BI* augmente à nouveau et un retour progressif à la routine est observé. Cet exemple montre que l'indice *BI* proposé met en évidence les changements dans la routine quotidienne et pourrait aider à anticiper les changements de comportement de la personne âgée.

Dans le cas où les journées sont classées en journées *routines* et *non-routines* suite à la répartition des jours par la méthode de K-moyennes et en fusionnant les classes *non-routine* de la personne B, nous trouvons 30 journées *non-routines* et 55 journées *routines*.

Le tableau suivant présente les performances des trois approches d'apprentissage automatique pour la base de données résultant des images annotées en posture (*allongé, assis, debout*), en *absence* et en *chute* de la personne B.

Tableau 5-11 : Performances de classification du type de la journée de la personne B après avoir classé les jours avec l'algorithme K-moyennes.

	<i>Précision</i>	<i>Spécificité</i>	<i>Sensibilité</i>
BRL	85%	82%	90%
DT	94%	98%	81%
RF	100%	100%	100%

Les résultats de prédiction du type de la journée montrent que les forêts aléatoires affichent les meilleurs résultats de prédiction. La Figure 5-31 montre l'évolution de l'indice de comportement *BI* pendant 85 jours sur une période glissante de 7 jours (c'est-à-dire $Pt = 7$) en utilisant la sortie de la méthode de classification *RF* de la base de données résultant de la détection des postures de l'absence et de la chute de la personne B.

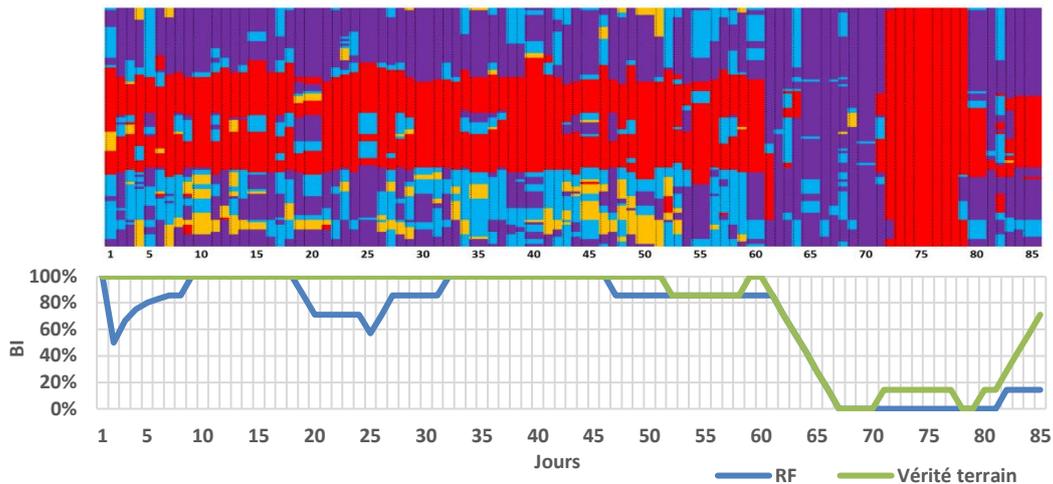


Figure 5-31 : Évolution de l'indice BI issu de la classification des jours par RF de la personne B.

Même si il existe une différence d'évolution du *BI* de la vérité terrain et du *BI* qui résulte de la prédiction de jours par RF, nous trouvons les mêmes interprétations du premier jour au 79^{ème} jour. En effet du premier au 61^{ème} jour le *BI* du RF est quasi-constant ($BI \in [50\%, 100\%]$) et traduit que la routine est maintenue. Puis pendant 19 jours, la personne ne suit plus sa routine quotidienne. Les six derniers jours de retour progressif à la routine dans la réalité est moins présente dans le cas *BI* issu du RF. On observe un retour progressif plus long à la routine, cette différence est vraisemblablement expliquée par la définition des intervalles de la journée routine.

La méthode précédente que nous avons évaluée pour des personnes dépendantes est intéressante mais nécessite une base d'apprentissage composée de journées *routines* et de journées *non-routines* pour classer le type de la journée. Nous avons proposé une stratégie qui permet d'apprendre automatiquement ces classes par des approches non-supervisées. Cependant, nous avons vu aussi les difficultés de mise en œuvre lorsque la personne ne présente pas de journée non-routine. La section suivante propose donc une autre méthode qui ne nécessite pas la présence d'une base d'apprentissage mais s'appuie sur l'observation du quotidien et s'inscrit plutôt sur une démarche heuristique.

5.4. Détection du changement de comportement par une approche heuristique

Cette méthode consiste à classer un jour en « journée *routine* » selon les valeurs des indices du jour (l'indice pourcentage en temps *allongé*, l'indice pourcentage en temps *assis*, l'indice pourcentage en temps *debout*, l'indice pourcentage en temps *absent*). En effet les intervalles des indices de la journée *routine* sont définis suite aux réponses de la personne âgée aux questions suivantes :

- Quelles sont les durées minimum et maximum du temps *allongé* (dormir, sieste) ?
- Quelles sont les durées minimum et maximum du temps *assis* (à table, sur le canapé, au bureau) ?

- Quelles sont les durées du minimum et du maximum du temps *absent* (absente de la maison, dans la salle de bains et toilettes) ?

L'intervalle de l'indice routine debout durant la journée est déduit des réponses précédentes, car la somme des durées des temps des différentes classes *absente*, *assise*, *debout* et *allongée* englobent la durée totale de la journée.

La journée sera classée *routine* si : « Chaque valeur de l'indice appartient à l'intervalle de routine de l'indice ». La journée sera classée *non-routine* si : « Au moins une valeur des indices n'appartient pas à l'intervalle routine ».

Dans le cas de présence de chute pour une personne robuste (la chute ne fait pas partie de sa routine) une alerte est déclenchée et la journée est classée alors *non-routine*.

Les personnes A et B sont des personnes dépendantes enregistrées dans leur chambre d'EHPAD, par conséquent nous n'avons pas à notre disposition les enquêtes. Notre idée a été de se baser sur les annotations de la vérité terrain du type du jour de chaque personne selon les intervalles de la journée routine.

La Figure 5-32 et la Figure 5-33 présente la moyenne mobile de l'évolution de l'indice *BI* des personnes A et la personne B (par période de 7 jours) après la vérification d'appartenance des valeurs des indices de chaque jour enregistré aux intervalles *routines*.

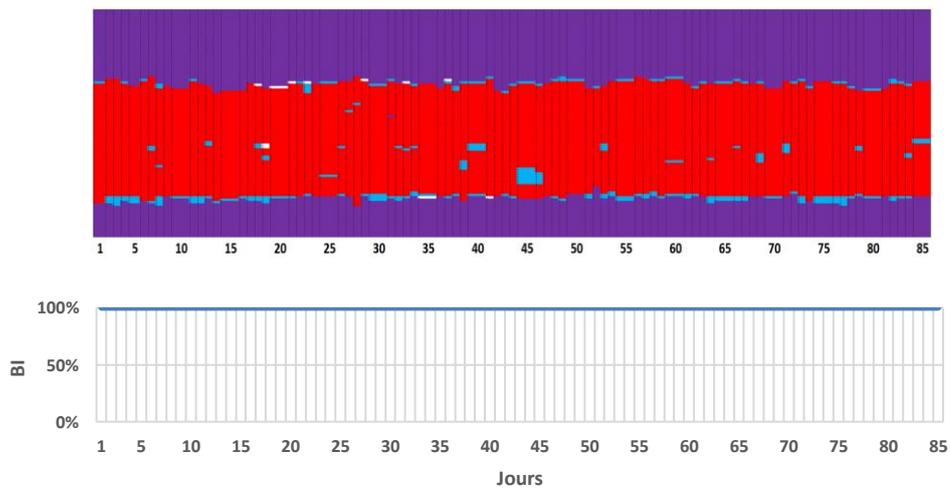


Figure 5-32 : Évolution de l'indice BI issu des annotations et de la base de données résultant de la détection des postures de l'absence et de la chute de la personne A.

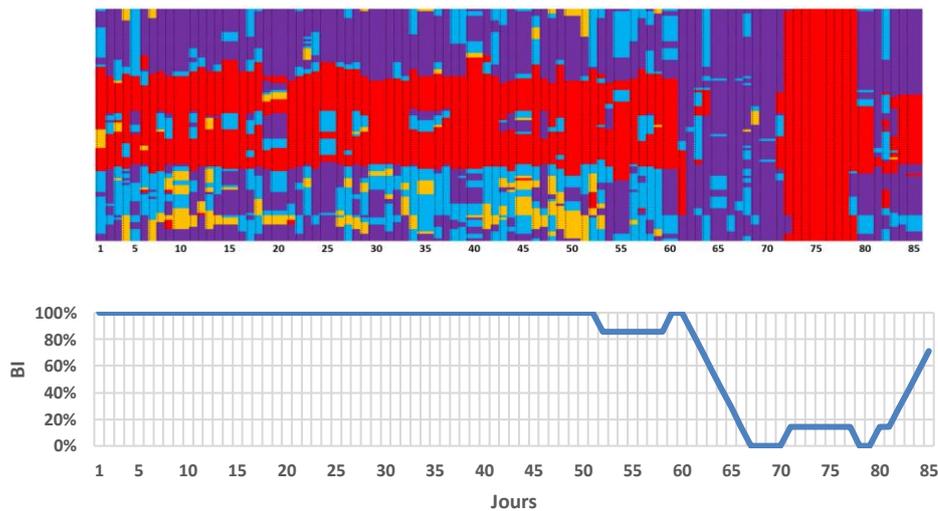


Figure 5-33 : Évolution de l'indice BI issu des annotations et de la base de données résultant de la détection des postures de l'absence et de la chute de la personne B.

Cette méthode permet de suivre la personne et de classer d'une manière simple le type de la journée. Elle peut aussi être exploitée pour construire progressivement les journées *non-routines* et ainsi alimenter la méthode de détection du changement de comportement par classification de la nature de la journée.

Conclusion

Trois stratégies pour détecter le changement de comportement de la personne en vue de prédire la fragilisation ont été proposées dans ce chapitre.

La première respecte la chronologie des activités de la journée en se basant sur le fait que la personne âgée suit une routine bien définie dans le temps et l'espace. Nous avons étudié deux variantes qui calculent respectivement la distance minimale d'édition (*M-DME*) et la déformation temporelle dynamique (*M-DTW*) par rapport à une journée dite routine. Nous avons constaté que la *M-DME* met bien en évidence les petits changements dans la routine et que la *M-DTW* capture mieux les changements durables. Associé à l'algorithme du CUSUM appliqué directement sur les distances (*DME* ou *DTW*) évaluées par jour, nous avons montré expérimentalement qu'il était possible de détecter des changements de comportement. Cette approche nécessite cependant l'apprentissage d'une journée routine. Deux stratégies d'apprentissage ont été proposées pour définir la journée routine. L'une participative demandant à la personne de répondre à un questionnaire, l'autre observationnelle où la personne est enregistrée sur plusieurs jours et la journée *routine* est définie par les postures les plus fréquentes à un instant *t*.

La seconde stratégie classe la nature de la journée selon les valeurs des indices de la journée et propose ainsi un aperçu global du comportement journalier de la personne dans le temps sans regarder la succession des activités. Notre étude révèle qu'une analyse qui mixte i) les méthodes non supervisées de clustering pour apprendre les classes au jour le jour et l'identification des intervalles des indices de la journée routine et ii) une classification supervisée pour classer automatiquement la journée en « *routine* » et « *non-routine* », était bien adaptée pour le suivi du changement de comportement.

La troisième stratégie plus heuristique classe la journée selon la vérification de l'appartenance des valeurs des indices aux intervalles *routines* des indices.

6. Détection du changement de comportement sur des données simulées

Introduction

Les chapitres précédents ont permis de présenter une méthode d'analyse complète englobant la détection de postures par des approches de deep-learning et la détection du changement de comportement suivant trois stratégies. Il est bien sûr, regrettable que cette approche n'ait pas pu être évaluée sur une plus grande base de données. Le contexte de cette thèse en plein confinement a fait que notre partenaire n'a pas souhaité poursuivre les expérimentations qui auraient permis de stabiliser et valider quantitativement nos résultats. Ces constats ont conduit à proposer un simulateur capable de reproduire différentes évolutions du type de la journée. Ce simulateur devra permettre de produire différentes évolutions de la routine et de spécifier des périodes de temps variables où des dégradations sont introduites. Dans la littérature, les modèles de Markov ont fait leur preuve pour modéliser le comportement humain [202]–[205]. Ceci explique que nous avons favorisé une approche par modèle semi-Markovien caché car le vieillissement décrit différents comportements des personnes âgées selon l'évolution de leur état de santé. La personne peut rester robuste, ou bien son état de santé peut se dégrader brutalement ou lentement. La variabilité de l'évolution de l'état de santé de la personne explique la variabilité du changement de comportement, par exemple une personne atteinte d'une dépression n'aura pas le même comportement qu'une personne atteinte de l'insomnie.

La première partie du chapitre définit la base de données qui a servi de support pour la simulation de scénarios réalistes. Elle est constituée *i)* d'une enquête sur 7 personnes âgées qui ont décrit leur journée routine et *ii)* d'images de profondeur enregistrées lors de différents scénarios d'une journée compressée (*cf.* la base Symh, voir section 2.2.2).

La deuxième partie du chapitre présente en premier le modèle de Markov caché et le modèle semi-Markovien caché qui sont utilisés pour définir le simulateur, puis propose une définition du simulateur des jours et des indices des jours, et enfin, décrit différentes trajectoires. Cette deuxième partie est clôturée par une conclusion sur le simulateur et des propositions sur d'autres utilisations pour décrire le comportement de la personne.

Dans la troisième partie, il nous a semblé aussi important de quantifier l'impact des mauvaises classifications des méthodes proposées aux chapitres précédents. Nous avons cherché à mettre en évidence l'efficacité des méthodes *M-DTW*, *M-DME*, *M-CNJ* et de la méthode heuristique pour la détection des différents changements de comportement en s'appuyant sur la simulation du type de la journée et sur les images enregistrées par les caméras de profondeur des scénarios des journées compressées de quatre personnes.

6.1. Les bases de données pour construire des simulations réalistes

6.1.1. Définition de la journée routine par une enquête

Afin de proposer des simulations réalistes de journées *routines*, une enquête a été réalisée dans le cadre du projet ANR ACCORD mené en parallèle à ce projet. La journée routine de la personne peut être décrite par une succession d'activités dans le temps que l'on peut représenter sous la forme d'un graphe d'états tel que représenté sur la Figure 6-1 suivante :

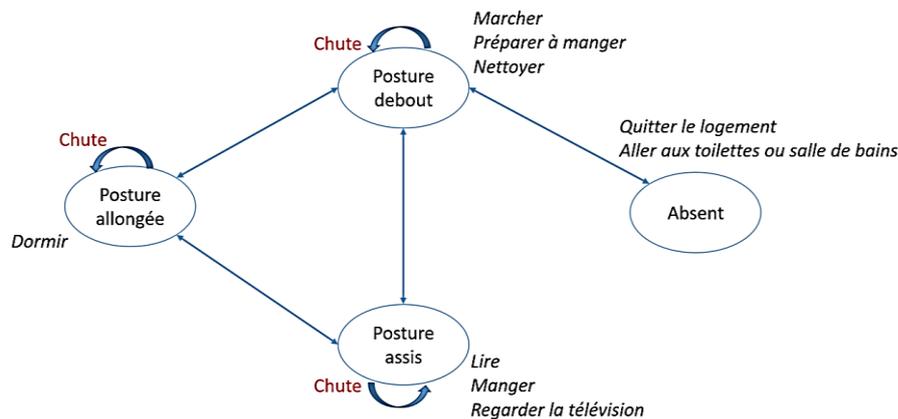


Figure 6-1 : Graphe d'états d'une journée d'une personne âgée.

Chaque journée est décrite par une succession d'activités qui sont traduites par des postures que nous sommes capables d'extraire automatiquement (cf chapitres précédents). Sept personnes âgées ont été questionnées sur leur routine quotidienne. Les personnes ont répondu aux questions suivantes :

1. Quel âge avez-vous ?
2. Quelle est la durée minimale et maximale de votre sommeil ?
3. Quelle est la durée minimale et maximale de votre sieste ?
4. Quelle est la durée minimale et maximale en position allongée sur le canapé ?
5. Quelle est la durée minimale et maximale en position assise sur la table à manger ?
6. Quelle est la durée minimale et maximale en position assise sur la chaise du bureau ?
7. Quelle est la durée minimale et maximale en position assise sur le canapé ?
8. Quelle est la durée minimale et maximale en position assise sur le lit ?
9. Quelle est la durée minimale et maximale de vos sorties du logement ?
10. Quelle est la durée minimale et maximale de vos toilettes (en salle de bains et aux toilettes) ?
11. Quel est le nombre de chutes par jour ?

Les réponses aux questions 2,3 et 4 permettent de définir l'intervalle routine du pourcentage en position allongée de la personne durant la journée routine. L'intervalle routine du pourcentage en position assise durant la journée résulte des réponses aux questions 5, 6, 7 et 8. L'intervalle routine de la durée d'absence par jour est défini à la suite des réponses aux questions 9 et 10. L'intervalle routine du pourcentage en temps debout correspond au pourcentage de la durée de temps restante

de la journée après avoir soustrait la durée en temps assise, allongée et absente. La réponse à la question 11 définit le nombre de chutes de la personne par jour.

Les résultats de l'enquête sont présentés dans le Tableau 6-1. Les réponses sont données sous forme d'intervalles et les indices (pourcentage en temps allongée, pourcentage en temps assise, pourcentage en temps debout, pourcentage en temps absente et nombre de chutes) dit routine sont calculés.

Tableau 6-1 : Résultats de l'enquête.

		Age	%Allongée	%Assise	%Absente	%Debout	Chutes
Personnes	1	67	[31%, 35%]	[15%, 17%]	[20%, 23%]	[25%, 34%]	0
	2	69	[33%, 37%]	[19%, 21%]	[19%, 21%]	[21%, 29%]	0
	3	73	[33%, 37%]	[23%, 30%]	[5%, 15%]	[18%, 39%]	0
	4	82	[46%, 48%]	[27%, 30%]	[0%, 4%]	[18%, 27%]	0
	5	84	[39%, 42%]	[27%, 32%]	[9%, 11%]	[15%, 25%]	0
	6	86	[45%, 49%]	[19%, 27%]	[12%, 15%]	[9%, 24%]	0
	7	93	[39%, 44%]	[37%, 40%]	[10%, 16%]	[0%, 14%]	0

Les résultats de l'enquête montrent la variabilité du comportement des personnes âgées, et justifient, s'il le fallait, d'une part, le besoin de développer une approche spécifique à une personne, et, d'autre part, l'intérêt des méthodes d'auto-apprentissage proposées dans le chapitre précédent.

6.1.2. La base de données Symh

Cette base de données a déjà été présentée au chapitre 2 (section 2.2.2). Dans ce chapitre, nous avons voulu préciser les caractéristiques clés qui ont été exploitées dans le cadre de la simulation. Nous avons demandé (et nous avons enregistré à l'aide de caméra de profondeur) à quatre personnes de simuler selon certains scénarii les activités d'une journée compressée dans le temps dans un vrai appartement composé d'une chambre, d'un salon, d'une cuisine, d'un couloir d'entrée et d'une salle de bain/toilette. Pour l'enregistrement de la journée routine et dans chaque pièce, différentes séquences ont été enregistrées où la personne réalise l'activité qui est programmée à cet endroit. Le capteur a été positionné de manière à enregistrer l'entrée et la sortie de la personne dans la pièce d'enregistrement.

Pour définir la journée non-routine, d'autres séquences ont été enregistrées. On a introduit aux scénarios de la journée routine des modifications comme : la personne chute, est plus souvent allongée ou assise, ne mange pas ou ne sort pas. Le tableau 2.1 du chapitre 2 rappelle le scénario de simulation qui a été réalisé. À titre de comparaison, le tableau suivant précise les séquences enregistrées dans la chambre pour la journée routine et pour la journée non-routine :

Tableau 6-2 : Séquences enregistrées dans la chambre pour la journée routine et journée non-routine.

Routine				
Séquence 0				
	07:00	Le sujet se réveille et se lève.	Chambre	1 min
		Aller aux toilettes		
Séquence 1				
		Venir du salon		
	14:00	Sieste	Chambre	1 min
		Sortir de l appartement		
Séquence 2				
		venir de la cuisine		
	21:00	Le sujet se met à son bureau	Chambre	1 min
		Aller à la salle de bain		
Séquence 3				
		venir de la salle de bain		
	22:00	Lecture dans le lit	Chambre	1 min
		rester sur le lit		
Séquence 4				
		sur le lit		
	22:00	Prise de la tension et dort	Chambre	1 min
	22:50	Le sujet se couche	Chambre	1 min
Non-routine				
Séquence 0				
	07:00	Le sujet se réveille et se lève chute du lit	Chambre	1 min
		Aller aux toilettes		
Séquence 1				
		venir de la cuisine		
	21:00	Le sujet se met à son bureau et chute de la chaise	Chambre	1 min
		Aller à la salle de bain		
Séquence 3				
	12:00	Le sujet se réveille et se lève.	Chambre	1 min
		Aller aux toilettes		

L'exemple de la journée routine de référence pour les enregistrements des séquences est décrite dans le Tableau 5-1. Afin d'introduire de la variabilité, des modifications sont introduites à la journée routine comme par exemple la personne dort plus, se couche plus tard ou rentre à la maison après ou avant l'heure fixée du Tableau 5-1 ainsi de suite. Pour cela certaines séquences d'images sont dupliquées pour décrire les allongements du temps ou éliminées pour décrire une activité qui a duré moins de temps. Plusieurs journées *routines* qui présentent tout de même des variabilités sont ainsi simulées. Les journées *non-routines* sont définies en remplaçant au moins une séquence de la journée *routine* par une séquence non-routine.

La modélisation par graphe d'états reportée sur la Figure 6-1 justifie qu'un modèle de Markov est adapté pour la modélisation de la routine. L'état n'est pas directement observé mais seulement les indices de la journée qui fluctuent en fonction du temps et des instants de la journée. Ainsi, les modèles semi-Markovien nous ont semblé bien adaptés pour le problème considéré. Ils sont d'autres parts souvent utilisés pour présenter des processus bayésiens à plusieurs états et probabilités conditionnelles associées.

6.2. Simulateur de la routine et des activités de la personne

6.2.1. Modèles de Markov

6.2.1.1. Chaîne de Markov

La chaîne de Markov est une suite de variables aléatoires (X_n) , $n \in N$. Les variables (X_n) , $n \in N$ appartiennent à un ensemble E appelé espace d'état. Le processus de Markov est un processus stochastique qui possède la propriété de Markov :

$$P(X_{n+1} | X_0, \dots, X_n) = P(X_{n+1} | X_n)$$

C'est un processus sans mémoire, cela signifie que le futur ne dépend que de l'état présent.

Une chaîne de Markov est présentée par un graphe d'états où les transitions entre les états sont régies par les probabilités de transitions. A un instant i , la transition s'effectue d'un état S_i à un autre état S_j (avec une probabilité de transition $a_{i,j}$), ou l'état initial est maintenu (avec une probabilité $a_{i,i}$ nommée auto-transition). La Figure 6-2 présente un exemple de chaîne de Markov à trois états, avec l'indication des probabilités de transition :

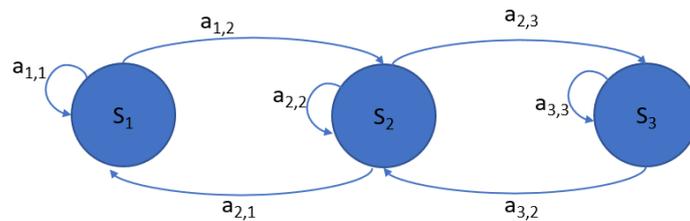


Figure 6-2 : Exemple d'une chaîne de Markov à 3 états.

Dans un modèle semi-Markovien, il est possible de rester un intervalle de temps aléatoire dans chaque état (S_i) entre chaque transition. Dans ce cas, on reste à l'état i une durée de temps t à $t + \alpha$, où α est une variable aléatoire.

6.2.1.2. Modèles de Markov cachés

Les modèles de Markov cachés (Hidden Markov Model HMM) sont très utilisés pour modéliser les états d'un système dynamique dans le cas où ces états ne sont pas directement observables [206]. A chaque pas de temps dans un état S_i , une observation o est émise dont la probabilité dépend de l'état courant du système S_i : $b_{S_i}(o_i) = P(O = o_i | S_t = S_i)$. Un HMM est défini par trois paramètres de base qui sont Π , A , B :

- Π est l'ensemble des fonctions de probabilités Π_n telles que Π_i est la probabilité que l'état S_i soit l'état initial.

$$\Pi_i = P(S_1 = S_i)$$

- A est l'ensemble des fonctions de probabilités de transitions $A = \{a_{i,j}\}$ telles que $a_{i,j}$ est la probabilité de la transition de l'état S_i à l'état S_j :

$$a_{i,j} = P(S_{t+1} = S_j | S_t = S_i)$$

- B est l'ensemble des fonctions de probabilités telles que $b_{S_i}(o_i)$ est la probabilité que l'observation o_i soit produite dans l'état S_i .

Dans un modèle HMM, l'état S_{t+1} ne dépend que de l'état S_t et l'observation o_t ne dépend que de l'état S_t . La Figure 6-3 illustre un exemple d'architecture d'un modèle de Markov caché à trois états $\{S_1, S_2, S_3\}$ et trois observations $\{o_1, o_2, o_3\}$:

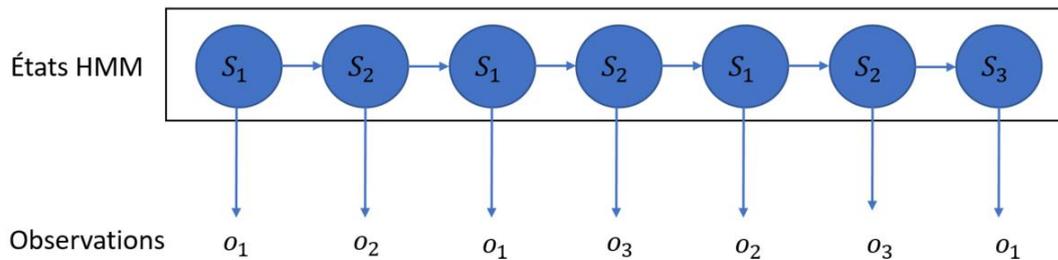


Figure 6-3 : Exemple d'un HMM à trois états.

L'observation ou l'émission de chaque état n'est pas déterministe. Chaque état peut produire de manière aléatoire une observation parmi l'ensemble des observations possibles. Les HMM sont très efficaces pour la classification des séquences temporelles, en particulier lorsque les scénarios sont définis sur une suite d'événements avec une granularité temporelle fixe. Dans la littérature, plusieurs travaux de cas d'application des chaînes de Markov cachés pour la reconnaissance de l'activité la plus probable de la personne dans une maison intelligente [207]–[210] ont été reportés.

6.2.1.3. Modèles Semi-Markovien cachés

Le modèle semi-Markovien caché (Hidden Semi-Markov Model HSMM) est un variant du HMM où un nombre de temps aléatoire présente la durée dans un état donné [211], [212]. Un modèle semi-Markov caché suit le même principe qu'un modèle Markov caché sauf que la chaîne cachée est semi-Markovienne. Cela signifie que chaque état émet une série d'observations et non une seule. Le modèle semi-Markovien caché est également appelé modèle de Markov caché à durée explicite (Explicit Duration-Hidden Markov Model EDHMM). Dans le cas d'un HMM l'estimation de la durée de l'état est implicite. Elle est liée à la probabilité d'auto-transition ($a_{i,i}$) d'un état du modèle (S_i). Le HSMM a été développé pour permettre le paramétrage explicite de la durée de l'état qui impacte directement la distribution de la durée de l'état [213], [214]. Le modèle est basé sur l'estimation du paramètre $P_i(d)$ qui présente la probabilité de rester à l'état S_i avec d qui présente une durée $1 \leq d \leq D$ et où D est la durée maximum d'occupation d'un état S_i . P_i est un vecteur de probabilités tel que $\sum_{d=1}^D P_i(d) = 1$.

Un HSMM est défini par quatre paramètres de base Π, A, B et D où Π, A, B sont équivalents à ceux d'un HMM, sauf que dans un HSMM les probabilités d'auto-transition $a_{i,i} = 0$. En effet, la durée de stationnement dans un état modélisé par le paramètre D permet de modéliser de manière plus explicite et précise les auto-transitions. La Figure 6-4 représente un exemple d'un HSMM à N états $\{S_1, S_2, \dots, S_N\}$ et trois observations $\{o_1, o_2, o_3\}$:

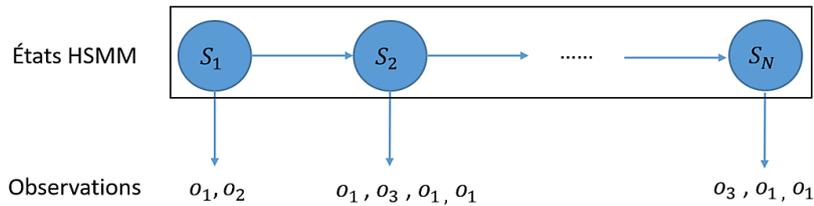


Figure 6-4 : Exemple d'un HSMM.

Les HSMM ont été utilisés avec succès dans la reconnaissance vocale [215], [216], la reconnaissance des activités [112], [217], ou bien encore la discrimination des différents événements d'une scène vidéo [218]. La section suivante montre comment les modèles semi-Markovien cachés ont été adaptés pour la simulation des jours *routines* et *non-routines*. On illustre aussi comment les indices du jour peuvent être simulés à partir de nos bases de données.

6.2.2. Simulation de dégradations par HSMM

Le type de la journée est noté 1 pour une journée *routine* et 0 pour une journée *non-routine*. Le type des journées est simulé durant N jours. Le but de ce simulateur est de spécifier des intervalles de dégradations qui sont composés de nombre de jours variables où des dégradations sont introduites d'un intervalle à un autre. Ces dégradations correspondent à l'introduction des journées *non-routines*.

Le modèle semi-Markovien caché permet de générer les jours de routine et non-routine. Les probabilités de transition ont été définies manuellement, car nous ne disposons pas de données représentatives des enchaînements possibles des situations que nous voulons reconnaître. Chaque état S_i à une durée variable d_{S_i} qui présente le nombre de jours dans cet état S_i , et chaque état produit d_{S_i} observations booléennes : $O_t = 1$ (*routine*) ou $O_t = 0$ (*non-routine*). Cette stratégie permet de présenter les différentes évolutions du type de la journée d'une personne âgée sur une période N de jours. La durée de l'état d_{S_i} est une variable aléatoire et prend une valeur entière dans l'ensemble $d = \{1, 2, \dots, d_{max}\}$ où d_{max} est la taille maximum d'un intervalle de dégradation. La variable aléatoire d_{S_i} est tirée selon une loi uniforme dans l'intervalle $[1, d_{max}]$.

Pour fixer les idées, la chaîne de la Figure 6-5 présente une chaîne de dégradation où le premier état S_1 (état initial) de durée d_{S_1} , produit d_{S_1} observations : $O_t = 1$ (*routine*) ou $O_t = 0$ (*non-routine*) selon la probabilité d'émission $b_{S_1}(O_t)$. L'état S_1 est transmis selon la probabilité de transmission $a_{1,2}$ (resp. $a_{1,1}$) à l'état S_2 (resp. S_1). L'état S_2 dure pendant d_{S_2} unités de temps qui produisent d_{S_2} observations (0 ou 1). Ensuite, de S_2 soit on reste dans l'état S_2 ou on transite à l'état S_3 , ou on revient à l'état S_1 en fonction des probabilités de transitions respectives $a_{2,2}$, $a_{2,3}$ et $a_{2,1}$. Ce processus est itératif jusqu'à l'état final S_M .

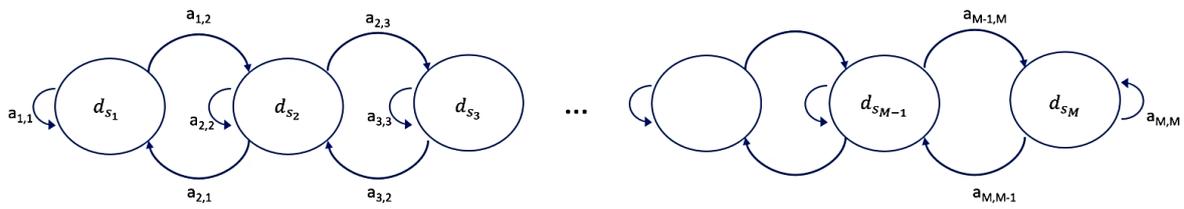


Figure 6-5 : Enchaînement des états dans un modèle semi-Markovien caché.

En synthèse, dans chaque état S_i de durée d_{S_i} , on trouve d_{S_i} états où chaque état émet une observation O_t (soit $O_t = 1$ ou soit $O_t = 0$) selon la probabilité d'émission $b_{1S_i}(O_t)$. Les probabilités de transition d'un état à autre sont égales à 1 (Figure 6-6) :

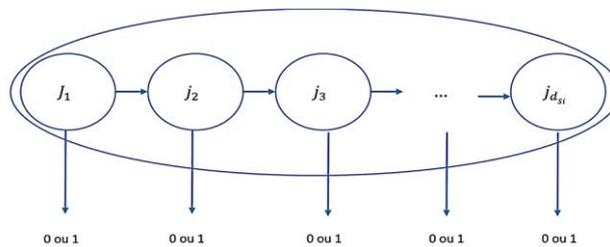


Figure 6-6 : Exemple d'un HSMM dans chaque état S_i .

Pour chaque état, la probabilité d'observation d'une journée anormale augmente de 0.1 sauf à l'état 1. Ce choix explique que la simulation de la dégradation dispose de 11 états $\{S_1, \dots, S_{11}\}$. Plus concrètement, on choisit dans l'état S_1 la probabilité d'avoir une journée anormale $b_{S_1}(O_t) = 0.05$, $t \in [1, d_{S_1}]$ et dans l'état S_2 , $b_{S_2}(O_t) = 0.1$, $t \in [1, d_{S_2}]$. D'un état à un autre (de S_i à S_{i+1} avec $i > 2$), la probabilité d'émission d'une journée anormale augmente d'un pas $\alpha_i = 0.1$, et ainsi de suite jusqu'à l'état S_M où $b_{S_M}(O_t) = 1$ et pour $t \in [1, d_{S_M}]$. La probabilité 1 de se trouver à l'état S_1 est attribuée car on se base sur l'hypothèse que la personne initialement suit une routine bien définie dans le temps. De plus à l'état S_1 , on trouve la plus faible probabilité d'obtenir une journée anormale. La durée de séjour dans un état S_i est définie aléatoirement par la probabilité de l'auto-transition et aussi par la durée de l'état d_{S_i} . Les transitions entre les états expriment le fait qu'on veut introduire progressivement des dégradations. Les différentes probabilités de transition d'un état S_i à un état S_{i+1} évoluent avec un pas de 0.05 comme le montre la Figure 6-7 :

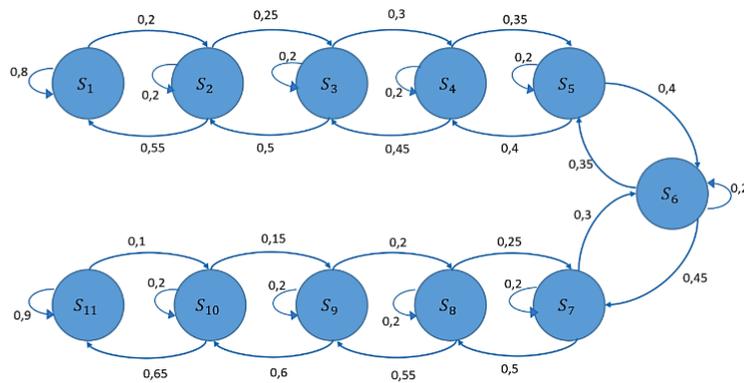


Figure 6-7 : Modèle proposé pour la simulation des journées (routines et non-routines)

Le résultat du simulateur est un vecteur $O = [O_1, O_2, \dots, O_N]$ de valeurs de 0 ou 1, où la valeur 0 correspond à une journée non-routine et la valeur 1 à une journée routine.

6.2.3. Simulation des indices du jour

Pour simuler les indices du jour (pourcentage en temps assise, pourcentage en temps allongée, pourcentage en temps debout, pourcentage en temps absente et le nombre des chutes) il convient de définir en premier les intervalles *routines* des indices de la journée routine IR. Les intervalles de routine des indices sont définis de deux manières (Figure 6-8).

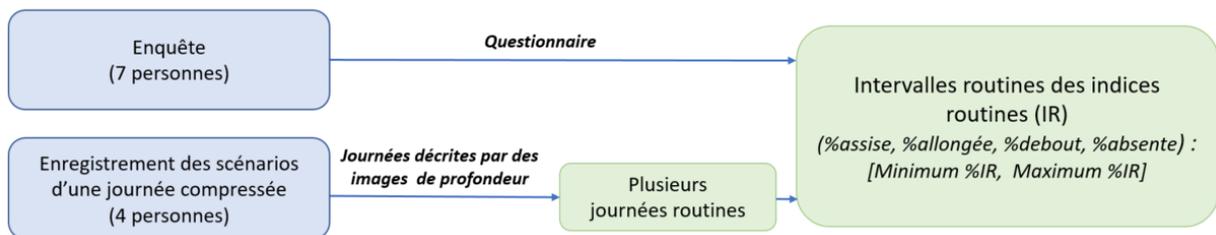


Figure 6-8 : Les intervalles des indices routines IR (pourcentage en temps allongée, pourcentage en temps assise, pourcentage en temps debout, pourcentage en temps absente) qui résultent de l'enquête et des enregistrements de plusieurs journées d'un scénario d'une journée compressée d'une personne âgée par 4 personnes.

- 1- Par la réalisation d'une enquête, les intervalles *routines* des indices sont définis par les réponses de la personne âgée à un questionnaire (voir section 6.1.1.1).
- 2- Par l'enregistrement de la personne par des caméras de profondeur sur la base de données Symh. Plusieurs journées *routines* ont été définies en introduisant des perturbations à la valeur du pourcentage de l'indice routine. Des images enregistrées de chaque journée routine, les indices *routines* IR des postures et absence sont calculées avec la formule suivante :

$$\text{Indice routine}(\text{posture ou absence}) = \frac{\text{Effectif de détection de la classe (position ou absence)}}{\text{Effectif total des images enregistrées} - \text{Effectif des images de la chute}} \times 100$$

Dans le cas d'une personne robuste, le nombre des chutes d'une journée *routine* est nul.

Des indices calculés, les intervalles *routines* du pourcentage en temps posture (assise, allongée, debout) et du pourcentage de temps absent sont définis. L'intervalle de *routine* pour chaque indice et pour chaque journée *routine* est calculé, chaque intervalle est défini par le minimum et maximum des valeurs pour chaque indice :

$$\text{Intervalle de routine de IR} = [\text{Minimum IR}, \text{Maximum IR}]$$

En l'absence de chute, la somme des indices pourcentage en temps en position assise, pourcentage en temps en position allongée, pourcentage en temps debout, pourcentage en temps assise et pourcentage en temps absente est égale à 100%. En présence de chute, la personne peut rester au sol durant un certain temps de la journée. Cette durée est tirée suivant une loi uniforme discrète dans l'intervalle [10 min, 60 min]. Une loi uniforme discrète est retenue pour l'équiprobabilité du choix de la durée de l'intervalle de la durée en position chute. Le pourcentage en temps en position chute sur la journée est donc de [0.69%, 4.16%]. Dans le cas de la chute, les indices des postures (assise, allongé et debout) et de l'absence sont calculés en prenant en compte le pourcentage en position chute durant la journée. La somme des pourcentages (assis, allongée, debout, absente et chute) est égale à 100%.

Les intervalles *non-routines* sont les intervalles complémentaires des intervalles *routines*. Lorsque la journée est une journée *non-routine* alors au moins un des indices est tiré aléatoirement des intervalles *non-routines* en respectant la condition que la somme du pourcentage en temps assise, allongée, debout, absente et position chute égale à 100%.

Les indices de la journée sont tirés aléatoirement des intervalles *routines* ou *non-routines* selon des lois de probabilités différentes :

- Les indices pourcentage en temps en position assise, allongée, debout et absente sont tirés pour chaque jour selon une loi uniforme. La loi uniforme a été choisie pour rendre la durée de ces événements équiprobable sur un intervalle [a, b]. La densité de probabilité de la loi uniforme continue est présentée par l'équation suivante :

$$f(x) = \begin{cases} \frac{1}{b-a} & \text{si } x \in [a, b] \\ 0 & \text{sinon} \end{cases}$$

- La chute est un évènement rare, le nombre de chutes est tiré aléatoirement selon une loi de Poisson de paramètre $\lambda > 0$. La probabilité d'obtenir k chutes est décrite dans la formule suivante :

$$P(X = k) = \frac{e^{-\lambda} \lambda^k}{k!}, k = 0, 1, 2, 3, \dots$$

En se basant sur les travaux de Khan et al. [40] qui indiquent que dans les maisons de retraite on comptabilise 2 à 3 chutes par personne, le paramètre λ a été fixé à 0.68% où λ est égale à la moyenne annuelle des chutes dans les maisons de retraite divisée par le nombre de jours de l'année.

6.2.4. Exemples de simulations du changement de comportement

Le principe de la simulation est reporté sur la Figure 6-9.

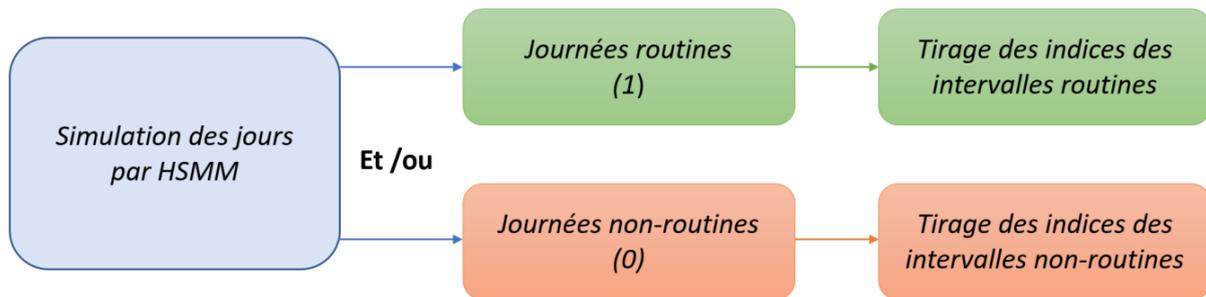


Figure 6-9 : Schéma de simulation des jours et des indices du jour.

Le simulateur retourne l'évolution du type du jour en *routine* et *non-routine* et chaque jour est décrit par les indices du jour (pourcentage en temps *assise*, *debout*, *allongée*, *absente* et le nombre des *chutes*).

Le chapitre I (section 1.4.3), présente les différents types de comportement au sein d'un processus opérationnel qui évolue dans le temps d'une personne âgée. Les changements qui se présentent sont : progressif, récurrent, brusque, graduel et bien sur le maintien de la routine (*i.e* aucun changement). On a donc souhaité montrer que le modèle proposé était capable de reproduire ces comportements. En se basant sur les données de l'enquête de la personne 1, cent jours sont chaque fois simulés, mais des périodes plus longues peuvent aussi être représentées.

6.2.4.1. Simulation du changement progressif

On rappelle que le changement progressif décrit un processus de passage d'un comportement existant à un autre nouveau comportement en passant par plusieurs changements courts (Figure 1-6 (d)). Dans notre cas d'étude, le changement progressif correspond au passage d'un comportement routine à la perte de la routine à travers le passage de la perte progressive de la routine (introduction progressive des journées *non-routines*). La Figure 6-10 présente l'évolution du type du jour et des indices du jour dans le cas d'une perte progressive de la routine.

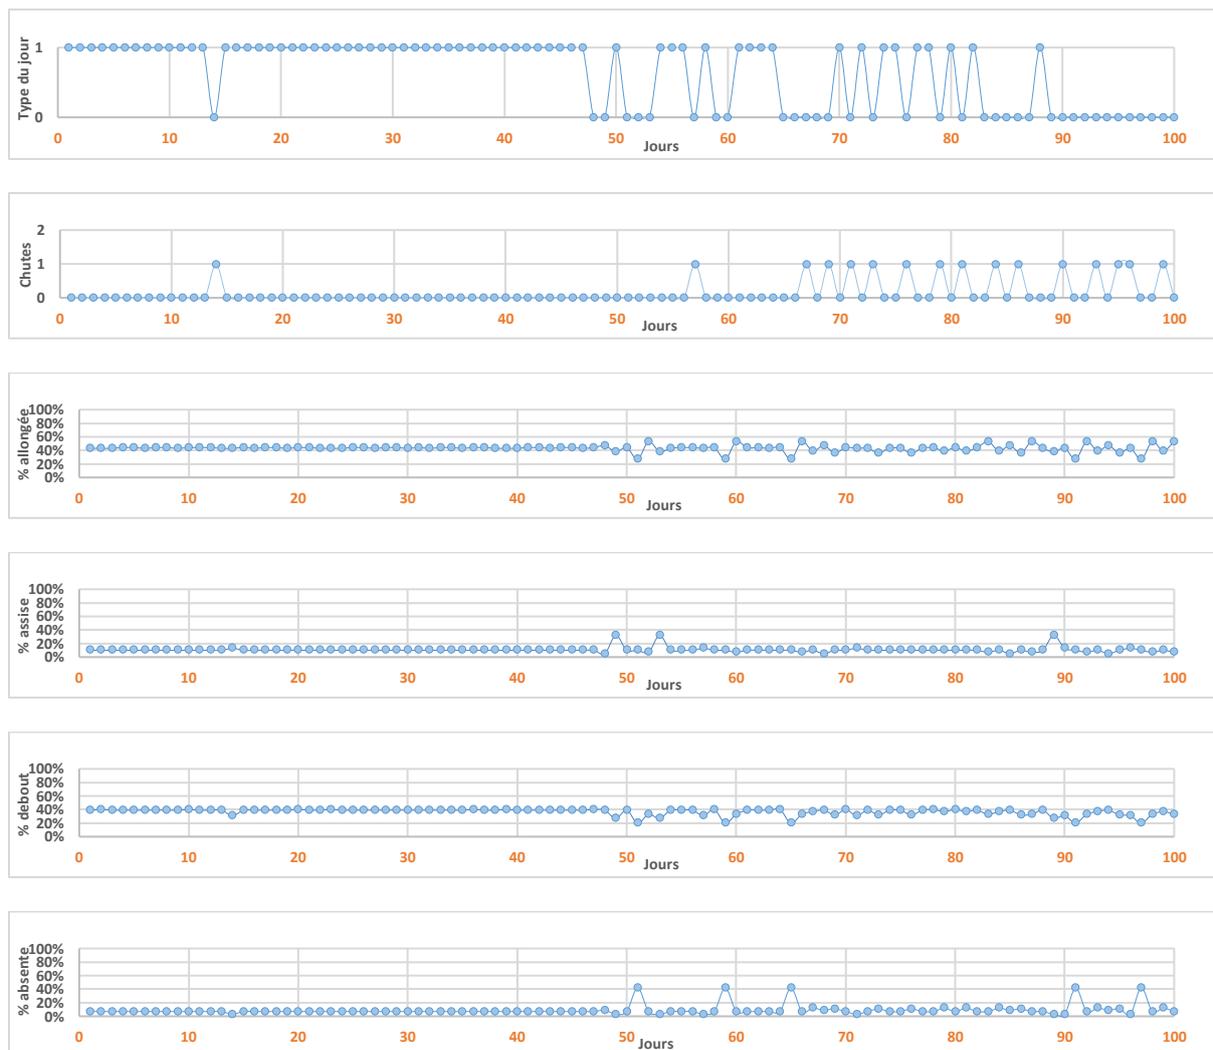


Figure 6-10 : Évolution du type du jour (0 non-routine et 1 routine) et les indices du jour pour un exemple d'un changement progressif.

Chaque journée classée *non-routine* est expliquée par l'analyse des valeurs des indices du jour. Dans le cas où la personne a l'habitude de quitter son logement durant la journée, le 70^{ème} jour la personne n'est pas sortie de son habitat, alors la journée est classée *non-routine*.

6.2.4.2. Simulation du changement récurrent

Le changement récurrent correspond à la réapparition de certains événements après un certain temps. Par exemple, l'exemple d'une personne âgée qui a une maladie chronique qui impacte sa routine, ou l'exemple de l'impact du changement des saisons sur le comportement de la personne. La Figure 6-11 présente l'évolution du type du jour et des indices du jour dans le cas d'un changement récurrent de la routine.

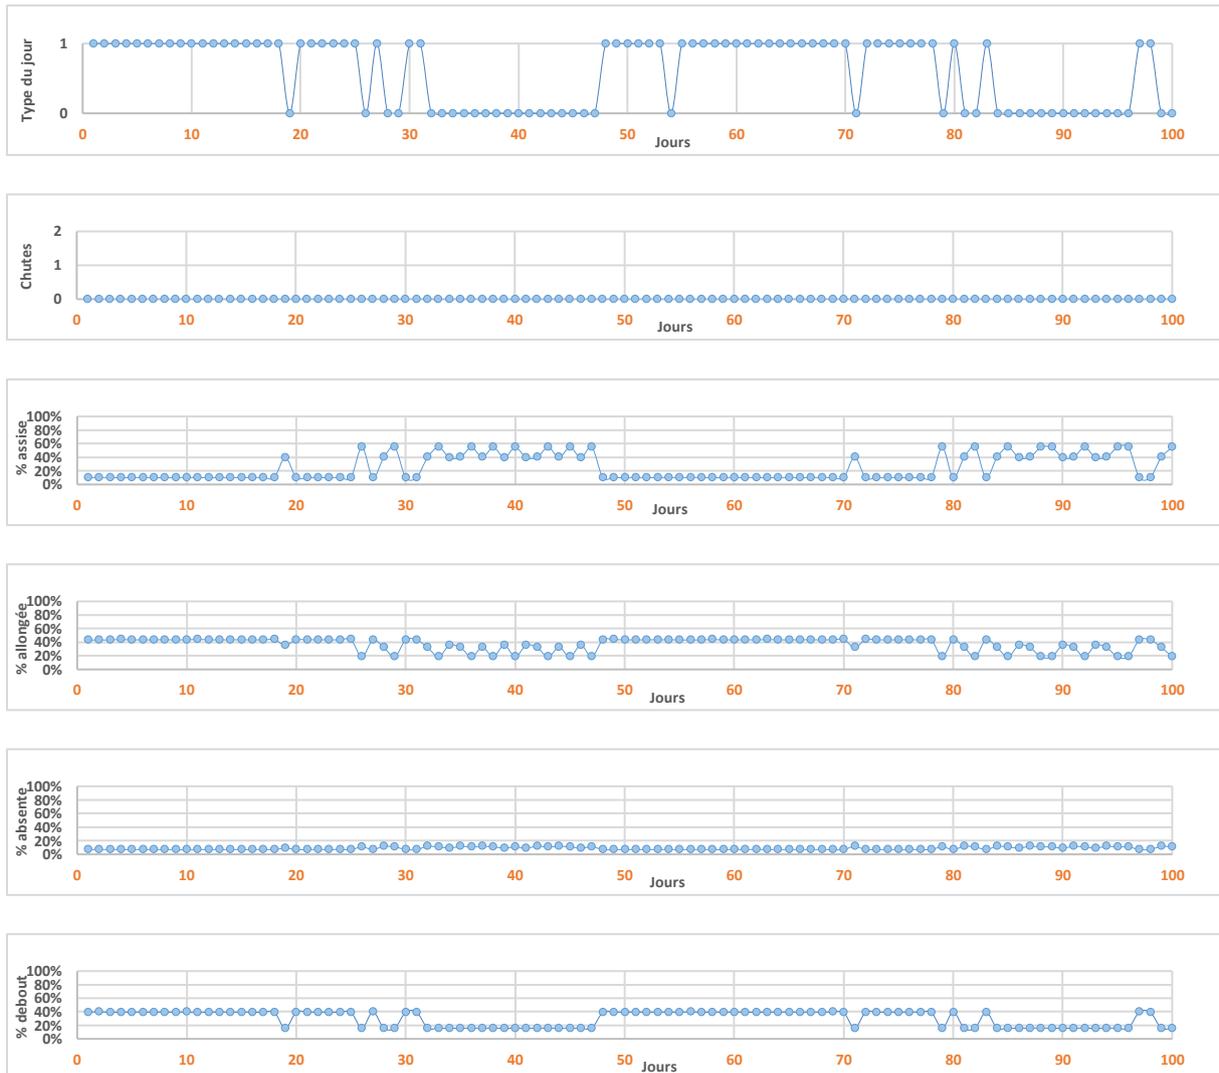


Figure 6-11 : Évolution du type du jour (0 non-routine et 1 routine) et les indices du jour pour un exemple d'un changement récurrent.

En analysant l'évolution du type de la journée et en liant les résultats à un comportement de la personne, on remarque que la personne suit une routine durant les 25 premiers jours (avec présence de 1 journée *non-routine* qui tient compte des aléas de la vie), suivie d'une perte de la routine durant 16 jours. Ensuite la personne retrouve sa routine durant 31 jours, suivie d'une perte de la routine les derniers jours. Le comportement des jours est expliqué par le comportement récurrent illustré par l'évolution des indices.

6.2.4.3. Simulation du changement brusque

Le changement brusque de comportement est expliqué par la substitution d'un comportement par un autre comportement. Dans ce cas, d'un jour à l'autre la personne change brusquement son comportement. On peut retrouver ce type de changement lors d'un événement non attendu comme un accident grave, un décès d'un proche qui conduit à une forte dépression, une hospitalisation La Figure 6-12 présente un exemple d'évolution de la routine et des indices de la routine.

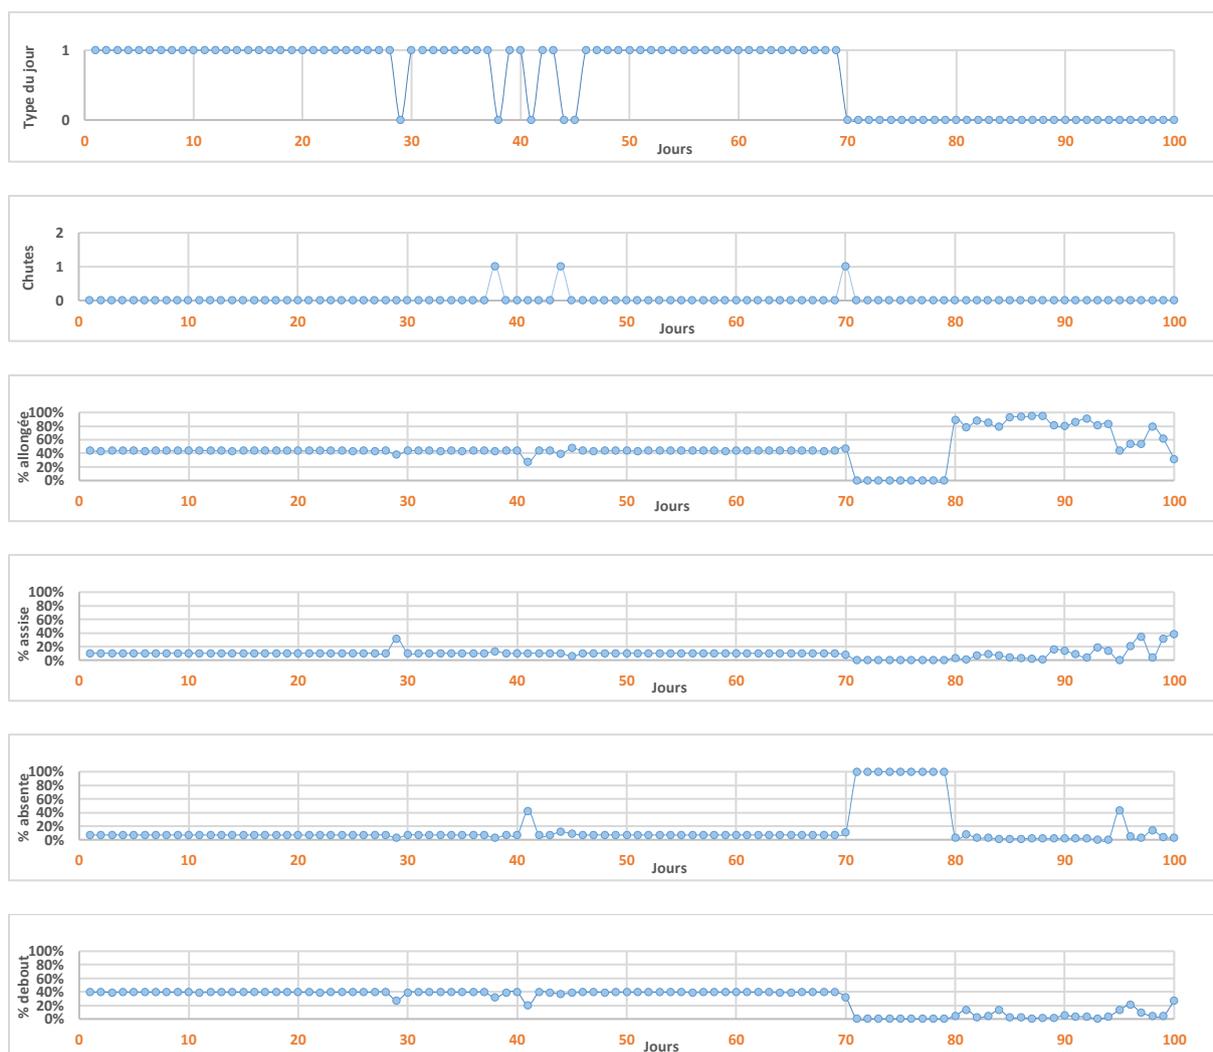


Figure 6-12 : Évolution du type du jour (0 non-routine et 1 routine) et les indices du jour pour un exemple d'un changement brusque.

L'évolution de la routine est maintenue pendant les 69 premiers jours, suivie d'une perte brusque de la routine. En analysant les valeurs des indices du jour, la perte de la routine est successive à la chute de la personne au 70^{ème} jour. Suite à la chute, une absence durant 10 jours est observée suivi d'un retour où on remarque durant les derniers jours des pourcentages élevés pour la position allongée. Cette simulation est intéressante car elle reproduit l'exemple de la personne B du chapitre précédent.

6.2.4.4. Simulation du changement graduel

Le changement graduel est un processus dans lequel un comportement courant est remplacé par un nouveau comportement. Le changement graduel est différent du comportement brusque car les deux comportements coexistent pendant une période de transition. Par exemple, la personne âgée garde son petit-fils qui est un nouvel événement introduit dans sa routine. La personne continue à maintenir sa routine en gardant son petit-fils. Il importe de souligner que dans notre étude, on s'intéresse uniquement à la personne qui vit seule dans son logement. Dans le cas d'un nouvel

événement qui fait intervenir d'autres personnes dans l'habitat, les méthodes développées dans le cadre du projet prudence [145], [147] ne sont pas directement transposables, mais doivent être adaptées. Ainsi, le nouveau comportement oblige la personne âgée à modifier sa routine, la journée *routine* doit être redéfinie. Ce constat explique que la détection du changement graduel a été jugée en dehors du périmètre de nos travaux.

6.2.4.5. Simulation du maintien de la routine

La vie d'une personne âgée est beaucoup plus axée autour de sa routine qui est expliquée par le maintien de la réalisation de ses habitudes de vie quotidienne dans le temps et l'espace. La Figure 6-13 présente un exemple d'une simulation d'un maintien de la routine sur une période de 100 jours avec la simulation des indices du jour :

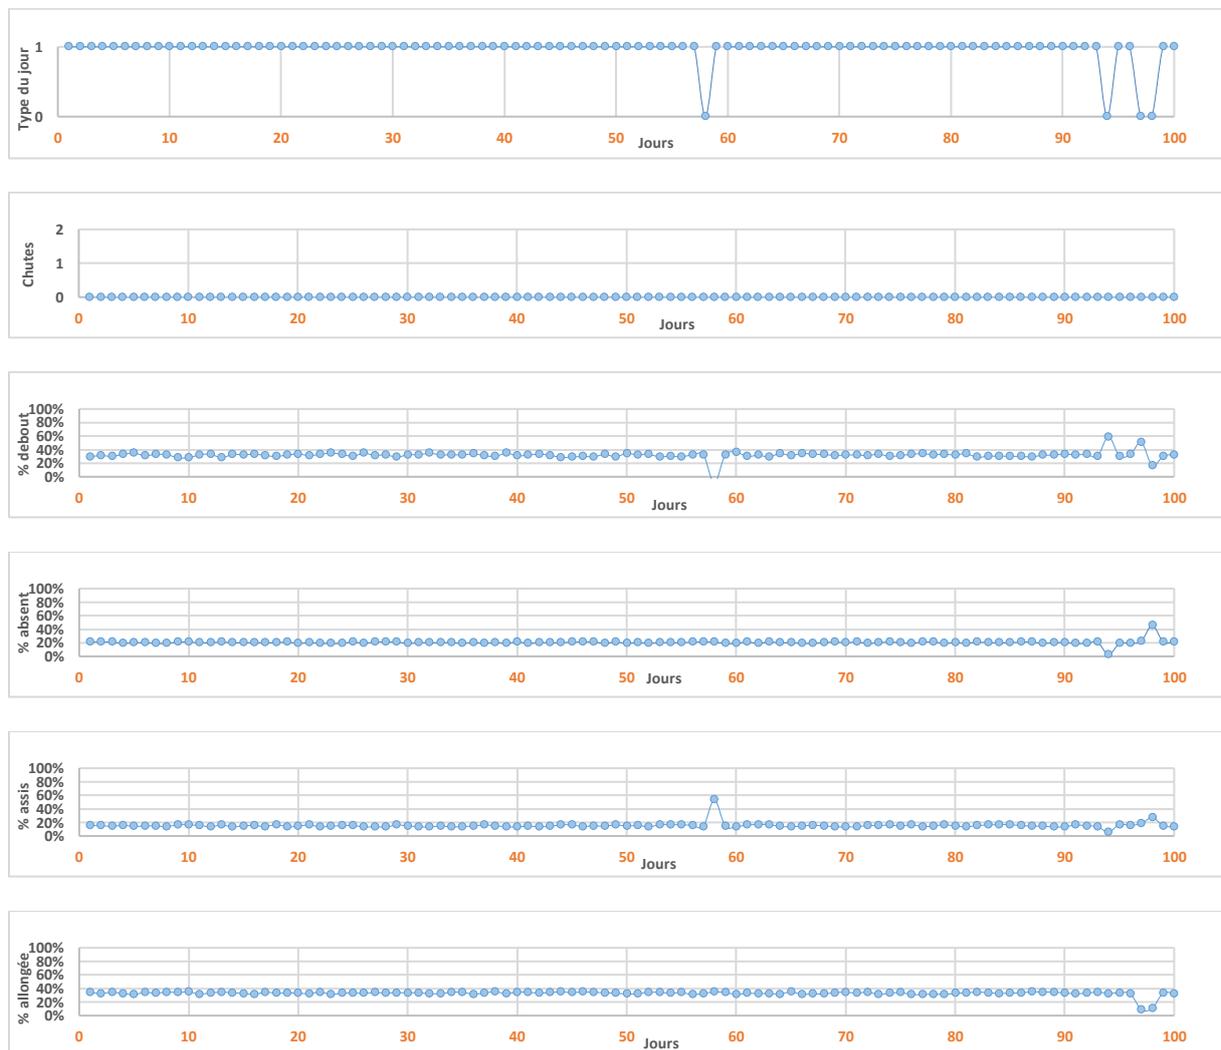


Figure 6-13 : Évolution du type du jour (0 non-routine et 1 routine) et les indices du jour pour un exemple d'un comportement routinier.

Cette simulation présente un maintien de la routine sur toute la période de 100 jours avec la présence de quelques jours *non-routines* liés à des événements exceptionnels du quotidien.

Le modèle proposé permet donc de reproduire différents scénarios : dégradation progressive, changements récurrent et brusque et le maintien de la routine. Il est donc maintenant intéressant de vérifier si les indices proposés au chapitre précédent sont capables de capturer ces modifications. Ainsi, il est proposé, ci-après, une étude objective et quantitative en simulant le comportement d'une population sur ces différents scénarios de rupture.

6.3. Comparaison des méthodes sur des populations à comportement homogène

La première partie du chapitre VI a permis de montrer que le modèle était bien adapté pour construire des scénarios réalistes en lien avec les comportements qui ont été décrits dans la littérature. La Figure 6-14 illustre la méthodologie proposée pour la création d'une base de données simulée :

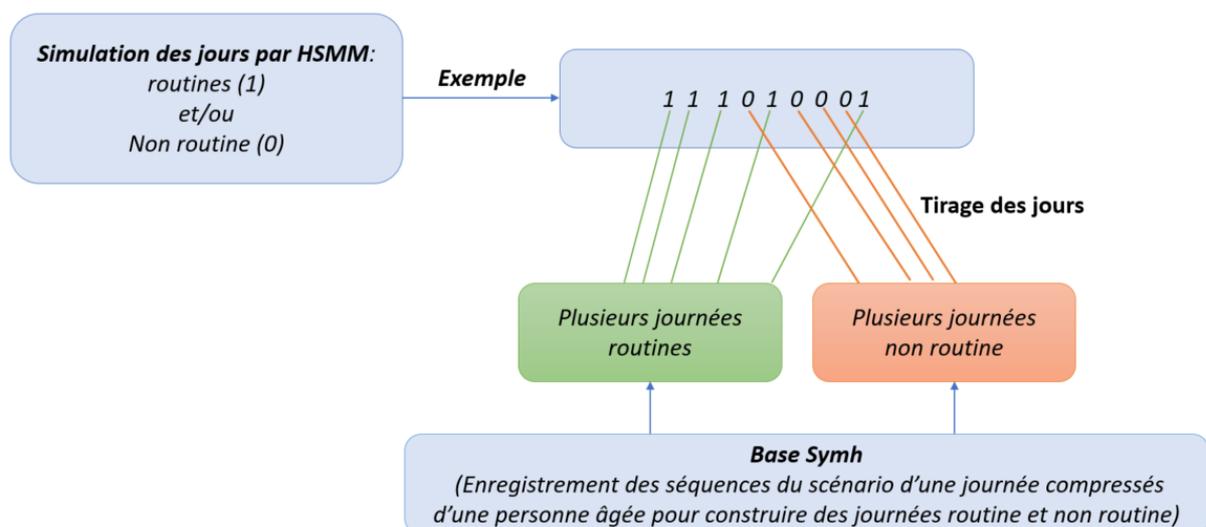


Figure 6-14 : Schéma de la création de la base de données qui décrit l'évolution de la simulation des jours par HSMM où les journées sont des scénarios compressés de la journée d'une personne âgée.

Chaque jour est décrit par la succession des images de profondeur des postures (assise, allongée et debout) avec indication de l'absence et de la chute. Des images de chaque jour, les indices du jour (pourcentage en temps assise, debout, allongée, absente et le nombre des chutes) sont calculés. Les entrées des méthodes de détection de changement sont les résultats de la classification des images obtenues à partir de la base Symh (cf chapitre IV). Ceci permet de juger l'impact des erreurs de classification. Ainsi aux trois types de changement de comportement (progressif, récurrent et brusque), a été appliquée :

- La méthode *M-DME* : l'algorithme *distance minimale d'édition* compare la journée routine aux jours issus du simulateur où chaque jour est décrit par une succession des postures en indiquant l'absence de la personne et la chute. Pour cette méthode, sont calculées l'évolution du pourcentage des résultats de l'algorithme DME sur toute la période de simulation ainsi que la moyenne mobile du pourcentage DME par période glissante de 7 jours.

- La méthode *M-DTW* : l'algorithme *Dynamic Time Warping* calcule la distance qui résulte de l'alignement de chaque journée enregistrée à la journée *routine*. Pour appliquer l'algorithme *DTW*, comme précédemment et après une recherche exhaustive des meilleurs poids, le poids le plus fort est attribué aux positions les plus fréquentes de la journée et le poids le moins fort est attribué aux postures les moins fréquentes. Pour cette méthode, les résultats des pourcentages des distances calculées et la moyenne mobile des pourcentages des distances *DTW* par période glissante de 7 jours sont calculées.
- La méthode de détection du changement de comportement *M-CNJ* par classification de la nature de la journée. Ici, les journées étant déjà générées par le simulateur, on présente pour cette méthode l'évolution de l'indice du comportement *BI* après classification non supervisée des jours par l'algorithme K-modes, K-moyennes, - et par la classification supervisée par forêts aléatoires.

Afin de ne pas alourdir la présentation de ce chapitre, la faisabilité de ces approches à capturer les trois changements étudiés sont reportés en annexe A. On y reporte pour chaque changement le comportement des méthodes *DME*, *DTW*, celles basées sur la classification de la journée et enfin la méthode heuristique. En synthèse, les résultats montrent que les méthodes *M-DTW*, *M-DME*, *M-CNJ* et la méthode heuristique mettent en exergue le changement de comportement progressif, récurrent et brusque. Les résultats décrits dans l'annexe A reproduisent le comportement d'une personne et l'étape finale est d'étudier le comportement d'une population ayant des caractéristiques communes. Quatre exemples de simulations des différents comportements sur une période de 180 jours sont présentés dans les figures suivantes (Figure 6-15, Figure 6-16, Figure 6-17 et Figure 6-18) :

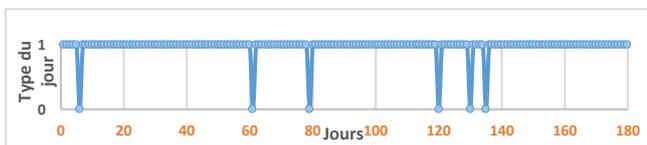


Figure 6-15 : Évolution du type du jour dans le cas du maintien de la routine.

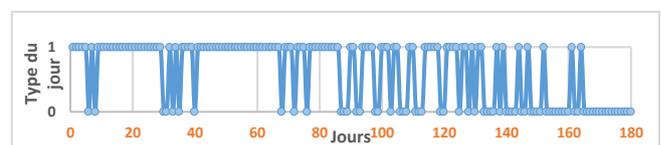


Figure 6-16 : Évolution du type du jour dans le cas de la dégradation progressive de la routine.

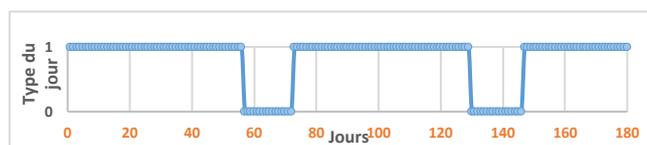


Figure 6-17 : Évolution du type du jour dans le cas de la perte récurrente de la routine.



Figure 6-18 : Évolution du type du jour dans le cas de la perte brusque de la routine

Pour chaque exemple, le modèle simule l'évolution du type de jour et les probabilités de la chaîne de Markov liées à ce tirage. Les probabilités de la chaîne de Markov extraites sont fixées pour simuler 100 changements de type de la journée (*routine* ou *non-routine*) sur la période de simulation (180 jours). Le type de jour (*routine* ou *non-routine*) est décrit par une succession des postures avec indication de l'absence ou de la chute après avoir lié chaque type de jour par une journée tirée aléatoirement parmi les journées *routines* ou parmi les journées *non-routines* (voir Figure 6-14). La Figure 6-19 décrit le

comportement de l'indice BI (cf. section 5.3.3) pour les quatre types de changements, déduit de la classification heuristique. Ce choix a été fait dans ce paragraphe au vu des résultats reportés dans l'annexe A où a été observé un comportement similaire pour les trois approches de classification de la nature de la journée (CNJ). Cette figure représente le comportement moyen de l'indice BI et les barres d'erreur des BI des 100 simulations. Les Figure 6-20 et Figure 6-21 représentent l'évolution de la moyennes en pourcentage et les barres d'erreur des distances d'édition et la distance DTW respectivement des 100 simulations.

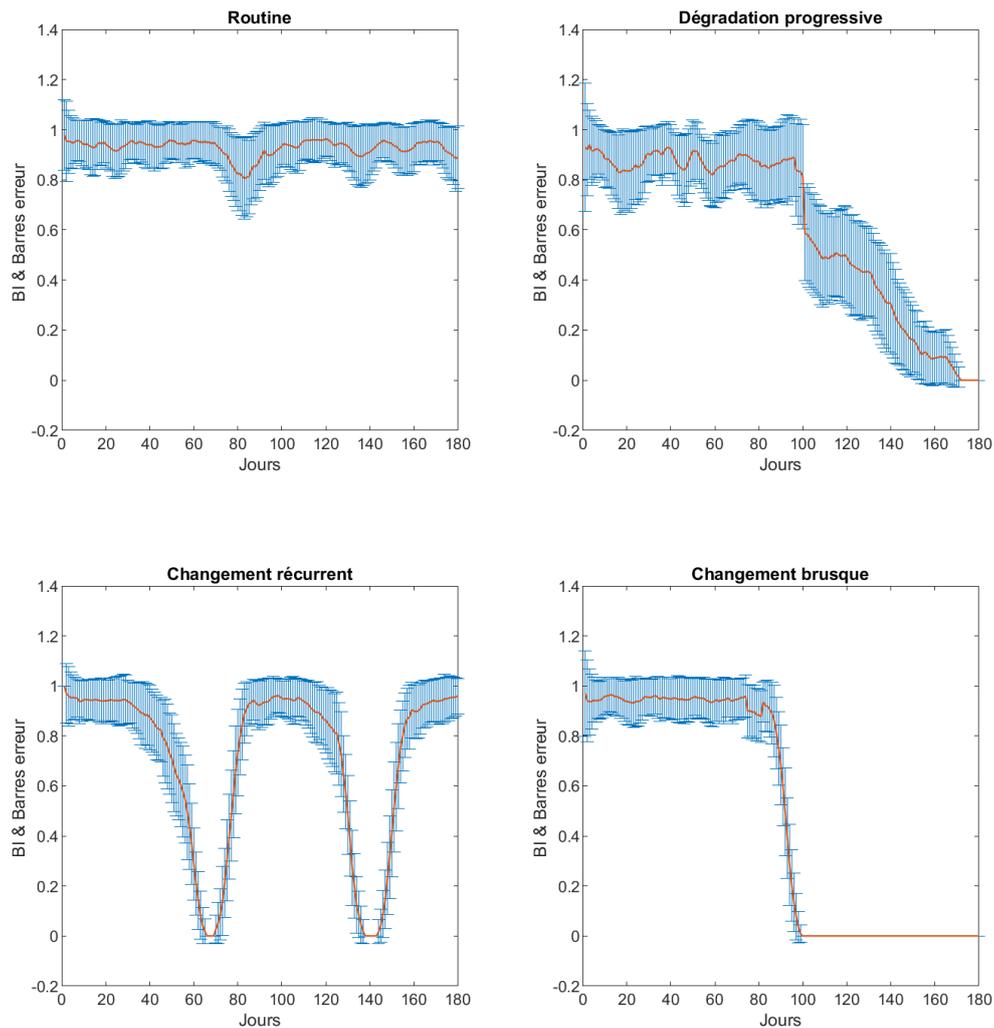


Figure 6-19 : Évolution du BI moyen par jour des 100 simulations pour chaque comportement (couleur rouge) et les barres d'erreur (couleur bleue).

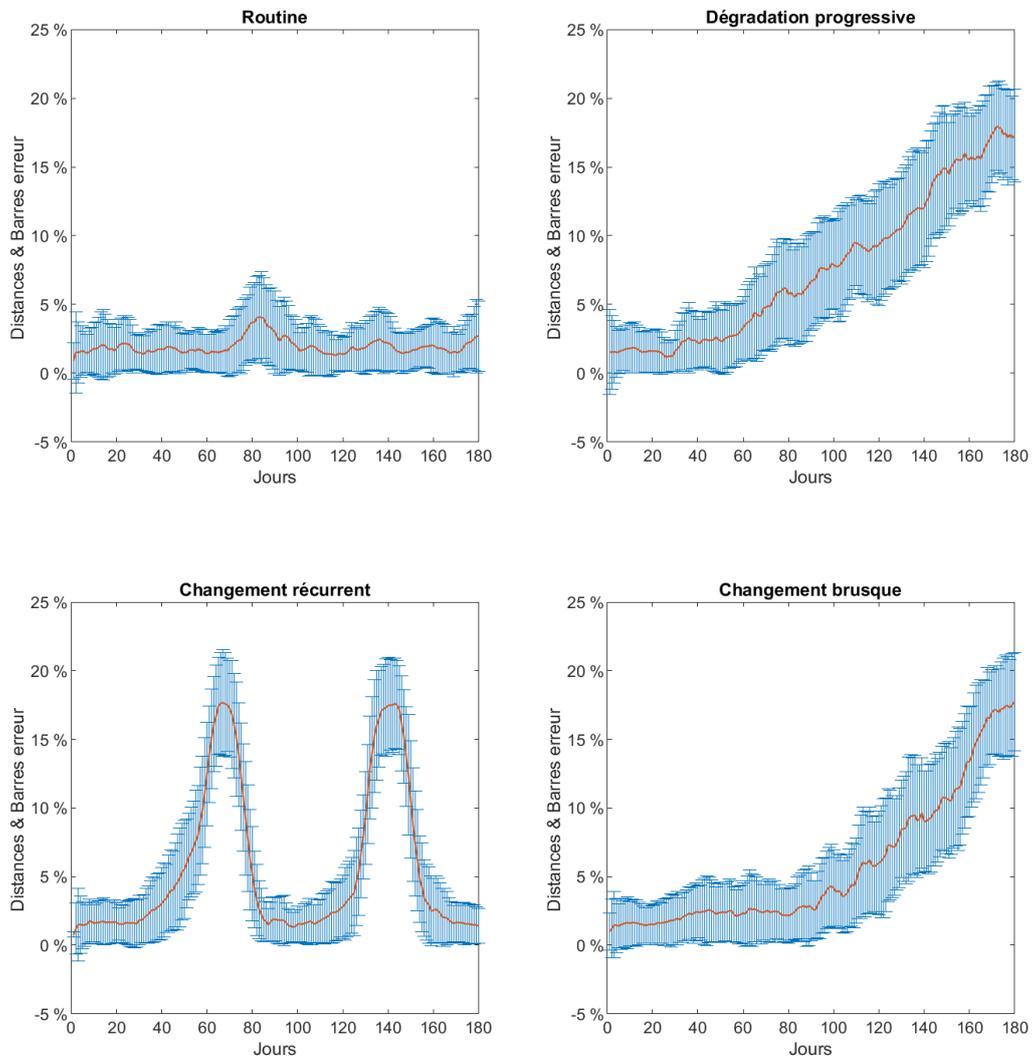


Figure 6-20 : Évolution de la moyenne des pourcentages des distances minimales d'édition par jour des 100 simulations pour chaque comportement (couleur rouge) et les barres d'erreur (couleur bleue).

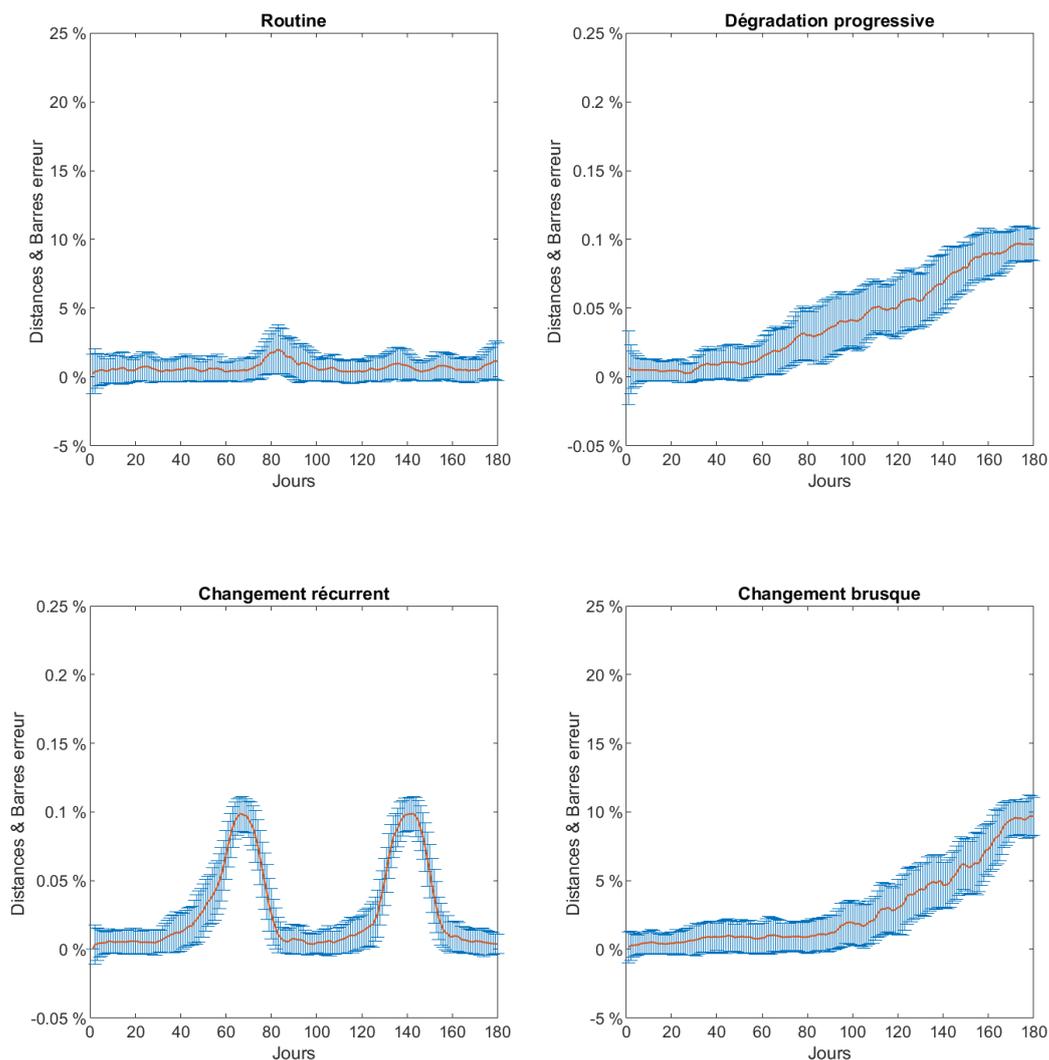


Figure 6-21 : Évolution de la moyenne des pourcentages des distances (Dynamic Time Warping) par jour des 100 simulations pour chaque comportement (couleur rouge) et les barres d'erreur (couleur bleue).

L'analyse de ces figures montre qu'un intervalle de routine (IR) peut-être établi pour les périodes stationnaires pour les trois approches proposées (DME, DTW, CNJ). Ceux-ci sont reportés dans le Tableau 6-3.

Tableau 6-3 : Les intervalles de routines IR des distances d'édition, de la DTW et du BI (de la classification de la nature de la journée).

IR distance d'édition	IR DTW	IR du BI
[0, 0.8%]	[0, 0.5%]	[68%, 117%]

Ces différentes réalisations permettent également de mesurer pour les trois types de changement étudiés : i) l'intervalle interquartile du retard (noté $[Q1, Q3]$) à la détection du changement des trois méthodes (*M-DME*, *M-DTW* et *M-CNJ*)¹² et ii) la pente moyenne de dégradations des trois mesures ($\% DME$, $\% DTW$ et *BI-CNJ*). Pour mesurer ces performances, nous nous sommes appuyés sur le comportement moyen (courbe rouge de la Figure 6-19) et nous avons fixé heuristiquement le jour de début de changement de comportement (voir Tableau 6-4) nommé instant de changement de référence *ICR* après avoir appliqué le test CUSUM sur le *BI* moyen de la classification de la nature du jour des 100 simulations. Les résultats des performances pour chaque type de comportement sont présentés dans le Tableau 6-5.

Tableau 6-4 : Instant de changement de référence pour différents changements de comportement.

Type de changement	Instant de changement de référence ICR
Progressif	102
Récurrent	57 et 130
Brusque	91

Tableau 6-5: Les intervalles interquartile du retard à la détection du changement de comportement des trois méthodes (*M-DME*, *M-DTW* et *M-CNJ*).

		$[Q1, Q3]$		
		% distances d'édition	% distances DTW	BI
Changement progressif		$[-3, 4]$	$[-4, 6]$	$[-1, 2]$
Changement récurrent	Premier	$[-2, 2]$	$[-3, 1]$	$[-1, 1]$
	Second	$[-2, 1]$	$[-3, 0]$	$[-2, 1]$
Changement brusque		$[-8, 1]$	$[-6, 5]$	$[-3, -1]$

En dépit des variations, les changements sont repérés par les trois indices proposés et ceci quel que soit le comportement de la population. Des tableaux précédents, on remarque que :

- 1- L'intervalle de routine (*IR*) des *BI* est faible sur les jours de routine,
- 2- Les intervalles interquartiles du temps de retard à la détection est plus faible pour la méthode basée sur la classification de la journée et ceci quel que soit la nature du comportement de la population.

D'autre part, l'analyse des évolutions (Figure 6-19, Figure 6-20 et Figure 6-21) montre que la méthode basée sur la classification de la nature de la journée semble mieux capturer les changements de comportement. L'index proposé apparaît en effet évoluer beaucoup rapidement après le changement. De la même façon, on observe que la méthode basée sur la distance minimale d'édition semble plus sensible que la méthode *DTW* au changement de comportement. Pour illustrer quantitativement ces analyses qualitatives, le Tableau 6-6 présente les résultats des pentes moyennes (ajustées au sens des

¹² Ce choix s'explique car on ne connaît pas avec exactitude l'instant réel de changement.

moindres carrés) des trois mesures (%DME, %DTW et BI-CNJ) normalisées afin de rendre comparable ces pentes, calculées sur une période de 7 et 14 jours après ICR.

Tableau 6-6: Pente moyenne en valeur absolue pour 7 et 14 jours des pourcentages des distances minimale d'édition DME, des distances DTW et du BI pour différents changements

	Brusque		1 ^{er} changement récurrent		Progressif	
	7 jours	14 jours	7 jours	14 jours	7 jours	14 jours
% DME	1.68 %	0.66 %	14.23 %	7.94 %	2.26 %	1.05 %
%DTW	1.48 %	0.57 %	13.82 %	7.77 %	2.62 %	1.33%
BI	23.58 %	11.88 %	13.50 %	7.71 %	3.29 %	1.62 %

L'expérimentation montre que le BI est dans les 7 premiers jours le plus sensible à repérer un changement et ceci quel que soit la nature du changement. Ceci est d'autant plus vrai que le changement est brutal. Dans ce dernier cas, la DME apparaît également plus sensible que la DTW. Les pentes du comportement récurrent du premier et du second changement ont été estimées quasi identiques et nous avons donc choisi d'en reporter une seule. Dans le cas de ce changement, les méthodes ont un comportement sensiblement identique. Pour le changement progressif, les pentes mesurées sont plus faibles traduisant ainsi l'évolution plus lente de la dégradation.

Conclusion

Dans ce chapitre, un simulateur des jours et des indices de chaque jour (pourcentage en temps *assise*, pourcentage en temps *allongée*, pourcentage en temps *debout*, pourcentage en temps *absente* et nombre de *chutes*) est proposé comme alternative à la difficulté d'acquérir une base de données. Le simulateur, basé sur un modèle semi-Markovien, est capable de reproduire différentes évolutions du comportement (brusque, progressive et récurrente). Afin de rendre le simulateur le plus réaliste possible, la journée *routine* est définie à partir d'une enquête de terrain où des personnes âgées ont décrit leur routine quotidienne d'une part et d'autre part des scénarios d'une journée compressée enregistrée chez 4 personnes.

L'application des méthodes de détection du chapitre V (*M-DTW*, *M-DME* et *M-CNJ*) ont montré leur efficacité et leur complémentarité sur 100 réalisations de dégradations progressive, récurrente et brusque. Sur un plan quantitatif et pour différents comportements, les simulations ont montré que le CUSUM appliqué au *M-DME*, *M-DTW* et *M-CNJ* présente un intervalle interquartile raisonnable à la détection de changement. Des intervalles de la routine ont pu être établis pour chaque indice proposé et les méthodes ont montré leur robustesse en régime stationnaire. L'approche qui associe la classification de la nature de la journée semble plus sensible aux changements de comportement en particulier brutaux. Cependant, les méthodes *M-DME* et *M-DTW* ne doivent pas être écartées et semblent apporter une information complémentaire intéressante. La première retourne le pourcentage du maintien des enchaînements des activités de la personne et traduit les aléas de la vie où certaines activités sont décalées ou supprimées. La *M-DTW* estime les pourcentages des distances nécessaires pour aligner la journée enregistrée à la journée *routine*. Ces informations sont importantes à nos yeux pour interpréter la nature du changement et devront être étudiées lors d'expérimentations ultérieures sur le terrain.

A. Détection des changements de comportement : progressive, récurrent et brusque

A.1. Comportement lors d'un changement progressif

La Figure A-1 présente l'évolution du type du jour et les résultats des méthodes.

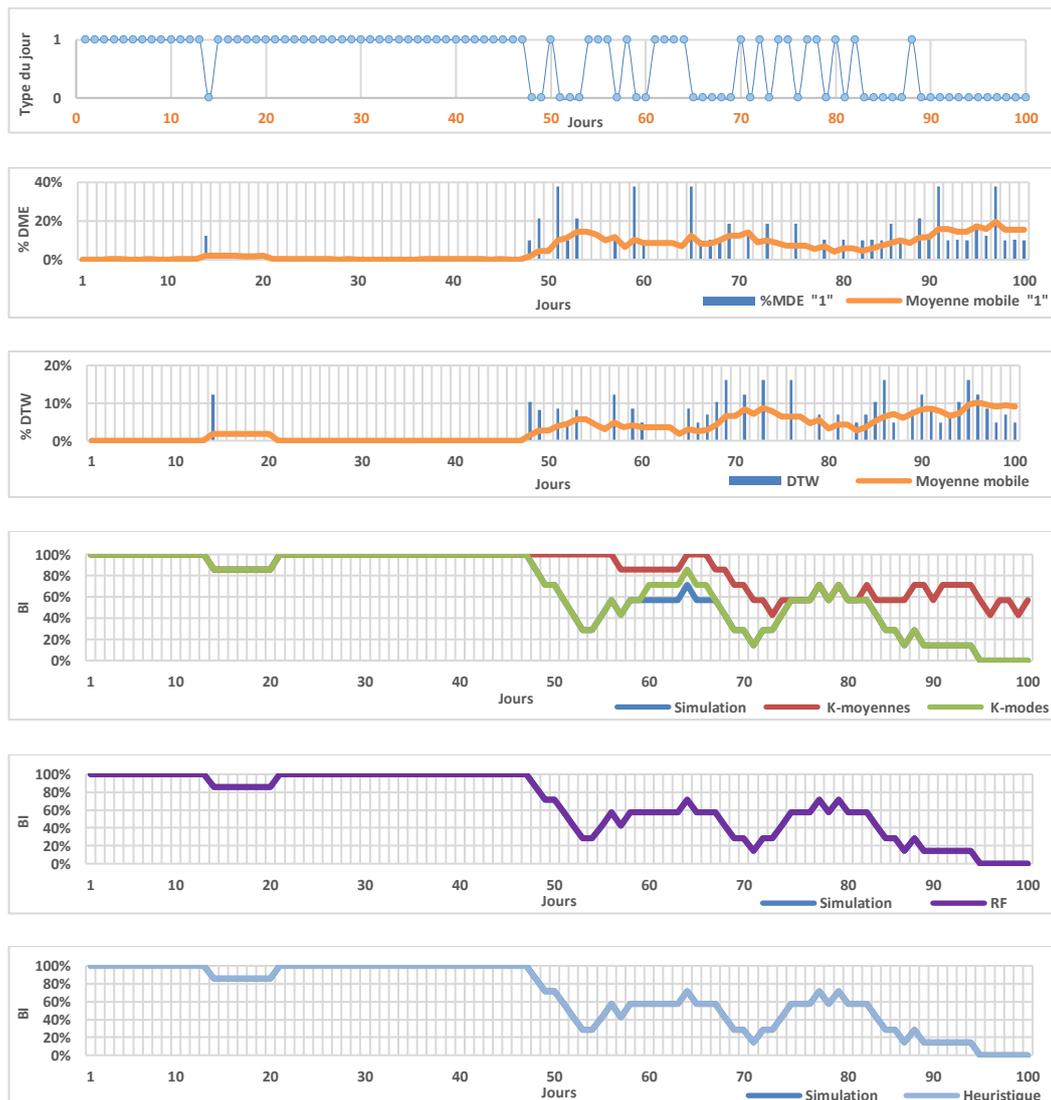


Figure A-1: Évolution du pourcentage DME et évolution de la moyenne mobile du pourcentage DME. Évolution du pourcentage DTW et évolution de la moyenne mobile du pourcentage DTW. Évolution BI de la simulation et des indices BI après classification des jours par l'algorithme K-moyenne et K-modes. Évolution BI de la simulation et de l'indice BI après classification par forêts aléatoires. Évolution BI de la méthode heuristique dans le cas de la simulation de la dégradation progressive.

Les résultats décrivent sensiblement le même comportement de la personne et capture le changement de comportement. On observe que l'évolution du *BI* semble moins sensible après classification des jours avec l'algorithme K-moyennes.

Etudes spécifiques de la M-DME et la M-DTW

Comme au chapitre précédent, de l'évolution du type du jour, trois groupes de jours ont été définis. Le groupe A regroupe la routine bien maintenue sur les 48 premiers jours. Le groupe B qui décrit une dégradation rapide expliquée par la présence des journées *non-routines* jusqu'au 89^{ème} jour. Et enfin le groupe C avec la perte totale de la routine. La Figure A-2 présente les boxplots du pourcentage des résultats de l'algorithme *DME* et *DTW* des groupes A, B et C. Le test statistique de Wilcoxon par pair de groupe a été appliqué pour montrer que les groupes sont significativement différents. Le Tableau A-1 présente les résultats du test en se basant sur les pourcentages des distances *DME* et *DTW* par groupe. Il ressort des résultats du test statistique que les groupes A, B, C sont significativement différents ($p < 0.05$).

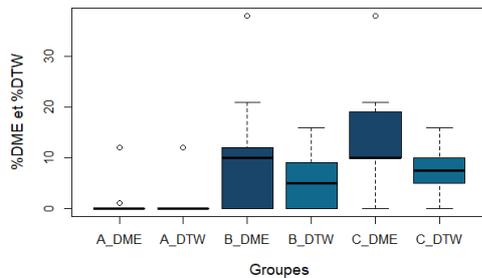


Tableau A-1 : Résultats du test Wilcoxon (pour les résultats des distances de M-DME couleur noire et pour les résultats des distances M-DTW couleur bleue) dans le cas d'un changement progressif.

	<i>A</i>	<i>B</i>
<i>B</i>	0.01/0.00	
<i>C</i>	0.00/0.00	0.03/0.02

Figure A-2 : Boxplots du pourcentage des distances DME et DTW selon les groupes des jours (A, B et C).

La figure A-3 présente le test de CUSUM utilisé pour détecter le jour du changement de comportement en se basant sur les pourcentages des distances (*DTW* ou *DME*). Le test montre une détection du changement au 49^{ème} jour qui correspond au jour du changement de la simulation du type du jour.

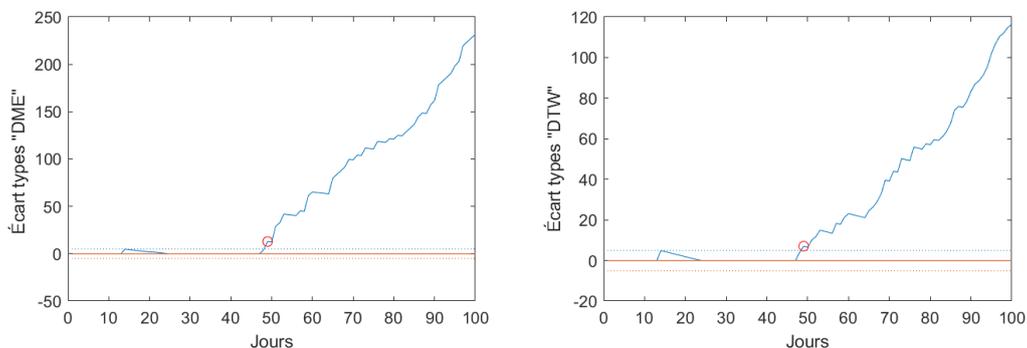


Figure A-3 : Résultats du test CUSUM appliqué aux pourcentages des distances DME et DTW.

Etudes spécifiques de la M-CNJ

L'évolution du *BI*, issu de la classification des jours par l'algorithme K-modes, a une tendance quasi identique à l'évolution du *BI* de la simulation. L'algorithme classe les jours en 8 clusters. Connaissant la journée *routine*, les clusters sont fusionnés en un groupe *routine* et un groupe *non-routine* et conduisent à une précision de 99%, une spécificité de 100% et une sensibilité de 97.22%.

L'algorithme K-moyennes a fait apparaître 2 groupes. L'évolution du *BI* qui résulte de la classification du type du jour avec la méthode K-moyennes n'a pas la même tendance que l'évolution du *BI* de la simulation sur certaines périodes de la simulation. Cela s'explique par la différence des largeurs des intervalles des indices *routines* définie par l'algorithme K-moyennes. La classification du type du jour par la classification K-moyennes nous donne une précision de 88%, une sensibilité de 44.44%, et une spécificité de 100%.

L'évolution du *BI* qui résulte de la classification du type par la méthode de validation croisée " Leave-one-out " avec la classification forêts aléatoires est identique à l'évolution du *BI* de la simulation.

Analyse des résultats de la méthode heuristique

La méthode heuristique classe les jours en *routine* si tous les indices appartiennent aux intervalles de routines, et non-routines si au moins un des indices n'appartient pas aux intervalles *routines*. Le simulateur reprend ce principe et cela explique que le résultat de l'évolution du *BI* de la méthode heuristique est identique à l'évolution du *BI* issu des jours simulés. L'évolution de *BI* reflète une dégradation progressive de la routine.

A.2. Comportement lors d'un changement récurrent

La Figure A-2 illustre les résultats du changement de comportement par différentes méthodes de détection du changement de comportement (*M-DME*, *M-DTW*, *M-CNJ* et la méthode heuristique) dans le cas du changement récurrent.

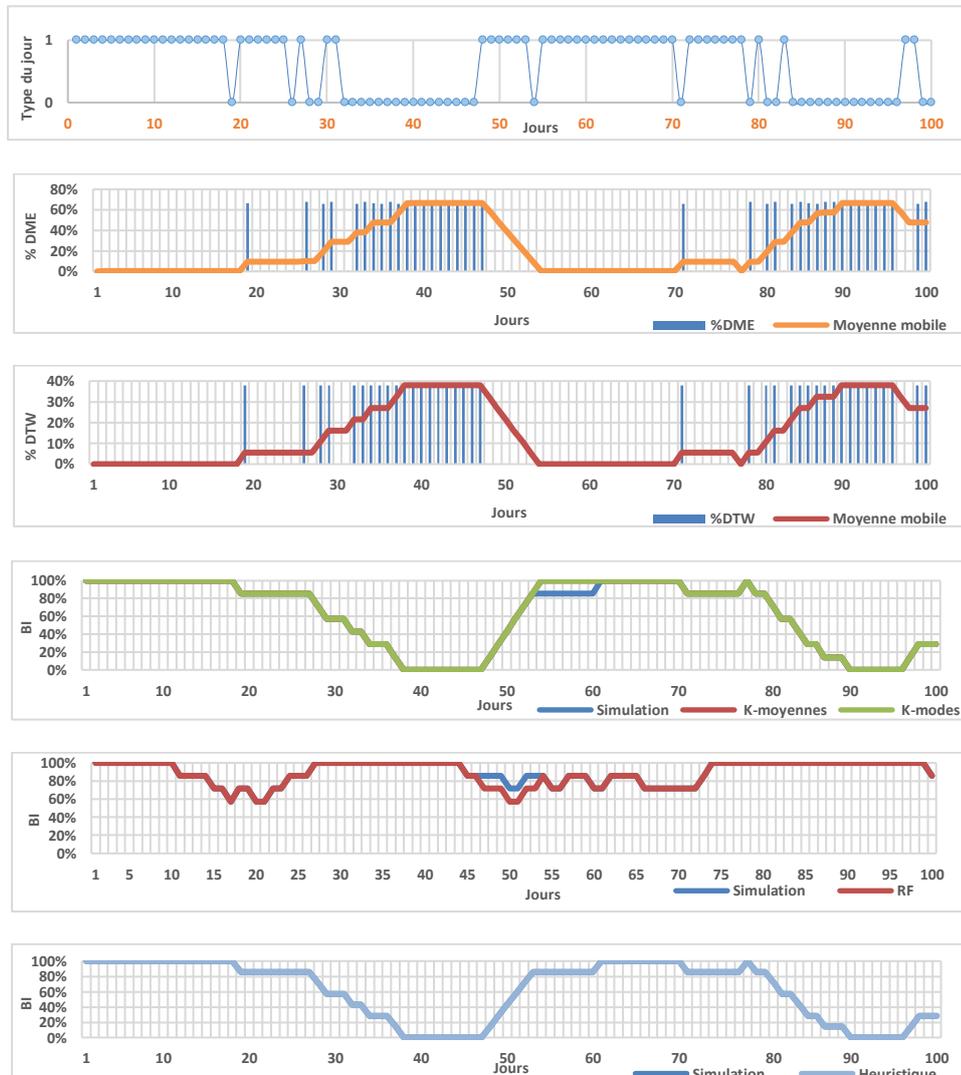


Figure A-4 : Évolution du pourcentage DME et évolution de la moyenne mobile du pourcentage DME. Évolution du pourcentage DTW et évolution de la moyenne mobile du pourcentage DTW. Évolution BI de la simulation et des indices BI après classification des jours par l'algorithme K-moyenne et K-modes. Évolution BI de la simulation et de l'indice BI après classification par forêts aléatoires. Évolution BI de la méthode heuristique dans le cas de la simulation d'un changement récurrent.

Les résultats des méthodes mettent en évidence le changement récurrent.

Études spécifiques de la *M-DME* et la *M-DTW*

Pour juger du potentiel des approches, les jours de la simulation ont été divisés en 5 groupes : le groupe A (du jour 11^{ème} au 25^{ème} jour), le groupe B (du 26^{ème} jour au 47^{ème} jour), le groupe C (du 48^{ème} jour au 78^{ème} jour) et le groupe D (Le reste des jours de la simulation). La Figure A-5 illustre les boxplots

du pourcentage du résultat des distances de l'algorithme *DME* et *DTW* par groupes des jours et le Tableau A-2 présente les résultats du test statistique Wilcoxon par pair de groupe.

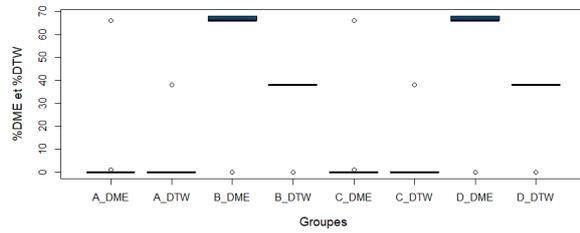


Figure A-5 : Boxplots du pourcentage du résultat des distances de l'algorithme *DME* et *DTW* des groupes des jours (A, B, C, D et E).

Tableau A-2 : Résultats du test Wilcoxon (pour les résultats des distances de *M-DME* couleur noire et pour les résultats des distances *M-DTW* couleur bleue) dans le cas d'un changement récurrent.

	A	B	C
B	0.00/0.00		
C	0.88/0.90	0.00/0.00	
D	0.00/0.00	0.88/0.84	0.00/0.00

Les résultats du test statistique montrent i) que les groupes A et C ne sont pas significativement différents et que les groupes B et D ne sont pas significativement différents ($p > 0.05$), et ii) que les groupes A et C sont significativement différents des groupes B et D ($p < 0.05$).

Simulant un changement récurrent, deux débuts de changement sont observés : le premier au jour 26 et le deuxième au jour 79. Les Figure A-6 et Figure A-7 montrent que le test de CUSUM a détecté les jours du changement de comportement qui correspondent aux premiers jours des périodes de récurrence de la perte de la routine pour les distances de la *M-DME*. Le test CUSUM appliqué aux distances de la *DTW* montre que le test de CUSUM a détecté les jours du changement de comportement qui correspondent aux premiers jours des périodes de récurrence de la perte de la routine. Afin d'établir une représentation facile et pour montrer l'évolution du CUSUM, la somme cumulée n'a pas été réinitialisée, même après la première détection.

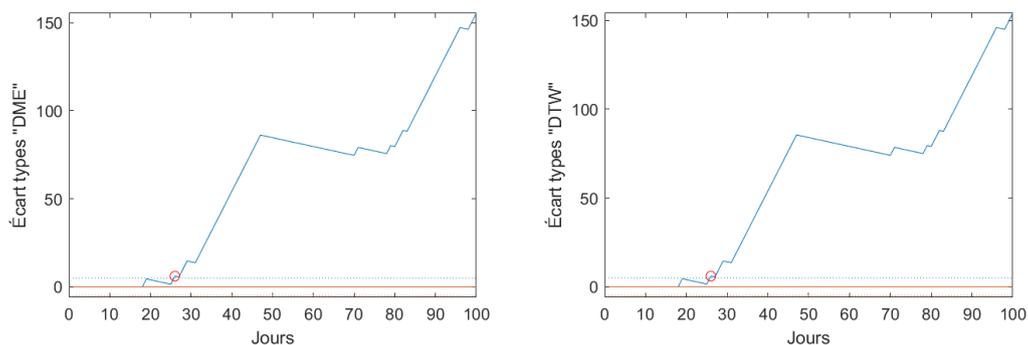


Figure A-6 : Résultats du test CUSUM appliqué aux pourcentages des distances *DME* et *DTW* pour détecter le premier changement du comportement récurrent.

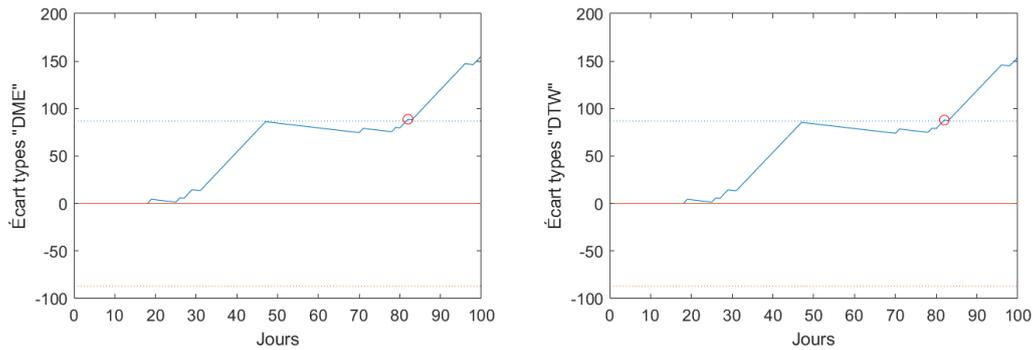


Figure A-7 : Résultats du test CUSUM appliqué aux pourcentages des distances DME et DTW pour détecter le deuxième changement du comportement récurrent.

Etudes spécifiques de la M-CNJ

Les jours sont classés en deux classes avec l'algorithme K-moyennes et en 4 classes avec l'algorithme K-modes. De la fusion des classes pour obtenir deux classes *routine* et *non-routine* pour chaque méthode de classification, on remarque que l'évolution de l'indice *BI* issu de la classification du type de la journée est quasi identique à l'évolution du *BI* qui résulte de la simulation. Pour la classification du type du jour (en *routine* et *non-routine*) la précision est de 99%, la sensibilité est de 97.50% et la spécificité est de 99%.

La classification du type de la journée par la méthode de validation croisée "Leave-one-out" avec la classification *RF* retourne 99% de précision, 100% de spécificité et 97.50% de sensibilité. Il est remarquable que l'indice *BI* dérivé de *RF* a un comportement comparable à l'indice *BI* dérivé de la simulation. L'évolution de l'indice *BI* met bien en évidence le comportement récurrent.

Analyse des résultats de la méthode heuristique

L'évolution de *BI* qui résulte de la classification des jours par la méthode heuristique reflète le comportement récurrent sur la période de la simulation.

A.3. Comportement lors d'un changement brusque

La Figure A-8 présente les résultats des méthodes (*M-DME*, *M-DTW*, *M-CNJ* et la méthode heuristique) dans le cas de la simulation du changement brusque.

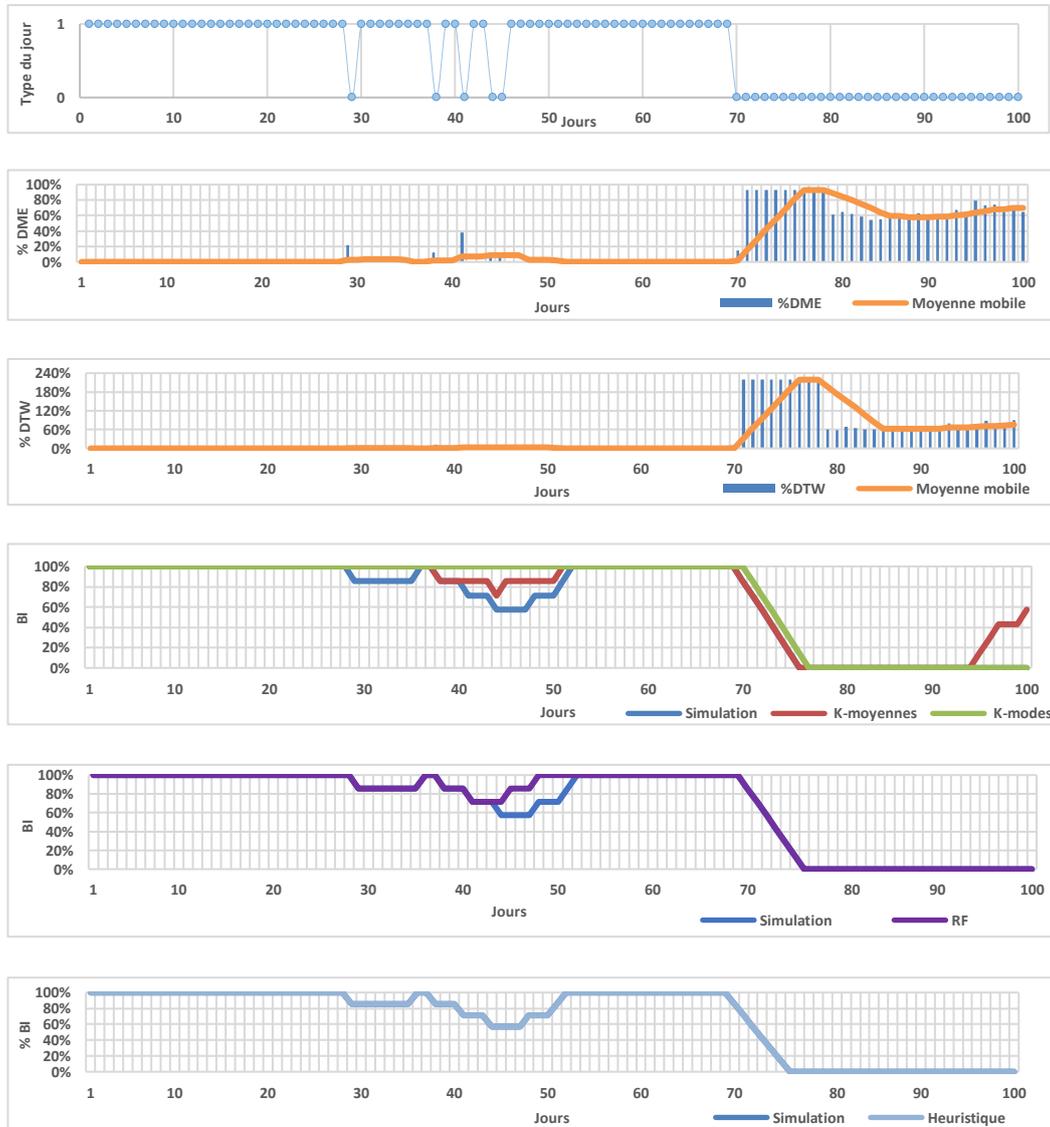


Figure A-8 : Évolution du pourcentage DME et évolution de la moyenne mobile du pourcentage DME. Évolution du pourcentage DTW et évolution de la moyenne mobile du pourcentage DTW. Évolution BI de la simulation et des indices BI après classification des jours par l’algorithme K-moyenne et K-modes. Évolution BI de la simulation et de l’indice BI après classification par forêts aléatoires. Évolution BI de la méthode heuristique dans le cas de la simulation de la simulation d’un changement brusque.

Les résultats de la figure précédente mettent en évidence la détection du changement brusque.

Etudes spécifiques de la M-DME et la M-DTW

La période de simulation est séparée en deux groupes : le groupe A (du jour 1 au 69^{ème} jour), le groupe B (du jour 70^{ème} au 100^{ème} jour). La Figure A-9 illustre les boxplots du pourcentage des distances calculées par l'application de l'algorithme DME et l'algorithme DTW par groupes des jours.

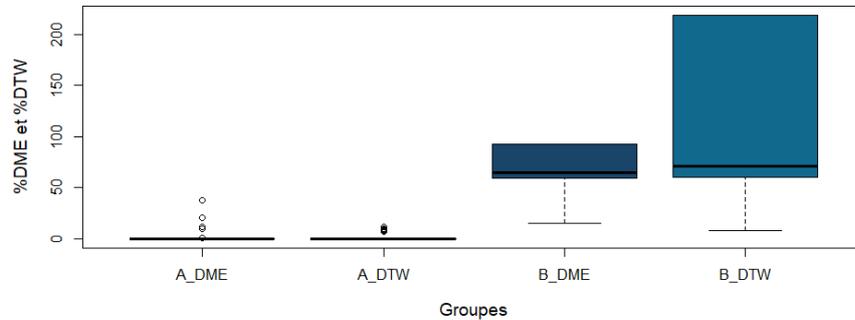


Figure A-9 : Boxplots du pourcentage des résultats des distances de l'algorithme DME et l'algorithme DTW des groupes des jours (A, B).

Les médianes des deux groupes, pour les deux distances (DME et DTW), sont très clairement distinctes. Le test de Student dans le cas de comparaison des pourcentages des distances des groupes A et B pour les deux cas des distances propose une p-value du test largement inférieur à 0.05. Le pourcentage des distances du groupe A est significativement différent du groupe B.

La Figure A-10 montre que le test de CUSUM affiche un changement de comportement le 70^{ème} jour en se basant sur les données des pourcentages des deux distances (DME et DTW).

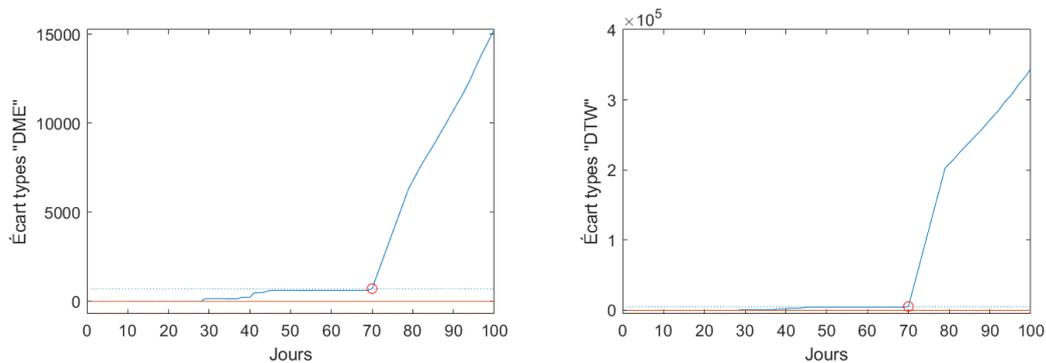


Figure A-10 : Résultats du test CUSUM appliqué aux pourcentages des distances DME et DTW dans le cas de la simulation d'un changement brusque.

En conclusion, les méthodes M-DME et M-DTW ont détecté le changement de comportement brusque présenté par le cas de la simulation d'un changement brusque.

Etudes spécifiques de la M-CNJ

Les jours sont classés en deux classes avec l'algorithme K-moyennes et en 4 classes avec l'algorithme K-modes. Les deux évolutions du BI issues de la classification des jours par l'algorithme K-modes et par l'algorithme K-moyennes suivent l'évolution du BI de la simulation et traduisent le

maintien ou la perte de la routine selon des pourcentages des intervalles *BI*. Les résultats se présentent comme suit : une précision de 93%, une spécificité de 100% et une sensibilité de 80.56% de la classification du type du jour par la classification K-moyennes. La classification des jours par la méthode K-modes propose une précision de 84%, une sensibilité de 55.56%, et une spécificité de 100%. Les erreurs détectées par la méthode K-moyennes s'expliquent par le choix des intervalles des indices que l'algorithme a fixé pour définir la journée *routine*.

La classification du type de la journée avec la méthode de validation croisée " Leave-one-out" de la classification *RF* a donné 98% de précision, 94% de spécificité et 100% de sensibilité. Une nouvelle fois, l'évolution des *BI* issue de la classification *RF* est quasi identique à l'évolution *BI* qui résulte de la simulation.

Analyse des résultats de la méthode heuristique

On rappelle que les résultats du type du jour de la simulation sont identiques aux résultats à la classification des jours par la méthode heuristique. L'évolution de *BI* qui résulte de la classification des jours par la méthode heuristique reflète le comportement brusque sur la période de la simulation.

Conclusion générale et perspectives

Résumé et contributions

La croissance du nombre des personnes âgées est un enjeu majeur de santé publique les prochaines années. Le maintien à domicile reste une solution adéquate avec la condition de sécuriser la personne âgée par son suivi en préservant son anonymat. On entend souvent par sécuriser la personne le fait de détecter i) la chute et ii) la fragilité. La détection de la chute et de la fragilité sont essentielles pour éviter la perte de l'autonomie. En effet, l'alerte de la chute permet une intervention rapide et par conséquent évite ou réduit les conséquences physiques (handicap ou incapacités locomotrices) et psychologiques (peur de rechuter et réduction des déplacements). La détection de la fragilité permet de prendre les mesures nécessaires pour faire basculer l'état de la personne vers l'état robuste, et de stopper l'évolution de la fragilité vers la dépendance.

Le vieillissement se caractérise par la réduction des capacités fonctionnelles et par l'augmentation de l'incidence des maladies liées à l'âge. Cela impacte le maintien de la routine sachant que la routine est exacerbée chez les personnes âgées. La détection du changement de comportement marqué par la perte ou la réduction des réalisations des activités de vie quotidiennes causées par la perte des capacités fonctionnelles, peut donc être un indicateur de la détection précoce de la fragilité dans le cas des personnes robustes.

Le travail présenté dans cette thèse s'inscrit dans cette logique du maintien et du suivi de la personne âgée dans une maison intelligente. En particulier, il se focalise sur la détection de la chute et de la perte de la routine de la personne âgée après avoir prédit ses habitudes de vie dans son habitat intelligent. Dans le cadre de cette recherche, la personne est suivie par des caméras de profondeur et thermique qui permettent d'enregistrer la personne en préservant son anonymat jour et nuit. Plusieurs contributions ont pu être développées tout au long de ce travail :

- 1- **La détection de la chute** : Nous avons proposé la détection de la chute par deux méthodes différentes :
 - La première qui fusionne les images de profondeurs et les images thermiques pour sélectionner une région de l'image où on détecte la personne. De la région sélectionnée, des paramètres sont extraits pour spécifier l'emplacement de la personne en position allongée sur le sol. En comparant les méthodes d'apprentissage les K plus proches voisins, les arbres de décision, et les forêts aléatoires [148], des bonnes performances (99% de précision, 100% de spécificité et 93% de sensibilité) ont été obtenues avec la classification par forêts aléatoires sur des images d'une personne âgée enregistrée dans sa chambre durant 43 jours.
 - Cependant, nous avons mis en exergue quelques défaillances qu'ils convenaient de corriger dans la première méthode. Une approche globale à base de deep-learning (réseau de neurones ResNet-18) qui permet de détecter la chute parmi les postures (assise, allongée, debout) et l'absence a dû être développée. En ce qui concerne la chute, des précisions sur les bases de données acquises allant de 77.78% à 99.30% ont été observées.

- 2- **La détection des activités** : Les activités de la personne sont traduites par des postures (par exemple, l'activité la personne *dormir* est traduite par la posture allongée ...). La classification, par le biais du réseau de neurones ResNet-18 des images de profondeur, des postures (*assise, absente, allongée*), de l'*absence* et de la *chute* a permis d'obtenir des précisions sur les bases de données acquises entre 89.32% et 98.50%.
- 3- **La Détection du changement de comportement** : La détection du changement de comportement a pour objectif de repérer la fragilité et consiste à suivre l'évolution du maintien d'une routine. La détection du changement de comportement est basée sur la détection des activités qui permet de décrire une journée. La journée est représentée par une succession de postures ou par les indices du jour (pourcentage en temps assise, allongée, debout, absente et le nombre de chutes). Trois stratégies ont été proposées pour la détection du changement du comportement.
- La première stratégie qui est liée au domaine de la programmation dynamique est composée de deux méthodes (*M-DME* et *M-DTW*). La méthode *M-DME* de détection du changement de comportement [219] calcule une distance d'édition et permet de suivre l'évolution de la moyenne glissante du pourcentage de cette distance. Cette distance correspond aux nombres des modifications nécessaires (suppression, insertion et substitution) pour réorganiser chaque journée enregistrée afin de retrouver la journée *routine* de la personne. L'algorithme de la transformation temporelle dynamique pour la méthode *M-DTW* aligne chaque journée enregistrée - décrite par la succession des postures (assise, allongée, debout, avec indication de l'absence et la chute) à la journée *routine* et calcule une distance. L'évolution de la moyenne glissante du pourcentage de cette distance représente un indice du changement de comportement. Le test de CUSUM appliqué aux distances *DME* et *DTW* permet de détecter le jour du début de la perte de la routine.
 - La deuxième stratégie a pour objet de classer la nature (*routine/non-routine*) de la journée (*M-CNJ*) [150], [151]. Cette méthode est appliquée après apprentissage des classes par des méthodes de classification non supervisées (K-modes et K-moyennes). Connaissant la description de la journée *routine*, les clusters identifiés sont regroupés pour définir deux classes (*routine* et *non-routine*) qui sont exploitées par une classification supervisée (forêts aléatoires) de la nature de la journée. Les taux de classification (précision) observée de la nature de la journée sont de 96% et permettent de construire un index *BI* qui consiste à calculer la moyenne mobile de la nature de la journée sur un intervalle temporel donné, traduisant le changement de comportement.
 - La troisième stratégie s'inspire du constat que les deux méthodes précédentes ont une limite d'application lorsque la personne ne présente que des journées *routines*. Dans ce cas, une méthode heuristique a été proposée qui consiste à vérifier si les indices de chaque jour enregistrés appartiennent aux intervalles de la routine des indices de la personne.

Les méthodes *M-DTW*, *M-DME*, et *M-CNJ* sont complémentaires pour une analyse de la journée du comportement de la personne. En effet, les résultats de la *M-CNJ* présentent d'une manière simple et globale l'évolution de la routine. Les résultats des *M-DME* et *M-DTW* expliquent la distance nécessaire pour le respect de la succession des activités et illustrent les pourcentages des distances pour aligner une journée enregistrée à la journée *routine*. L'application des méthodes sur les images enregistrées de deux personnes âgées dans leur chambre de la maison de retraite durant 85 jours ont montré leur efficacité pour la détection du changement du comportement.

- 4- **Proposition d'un simulateur** : Enfin, afin d'évaluer nos propositions sur différentes évolutions de la routine reportées dans la littérature et d'évaluer objectivement nos performances, un simulateur basé sur un modèle de Markov semi-Markovien caché a été proposé. Outre que le simulateur est capable de reproduire 4 types de changements reportés dans la littérature (Brusque, récurrent, progressif, routine), nous avons montré qu'il est possible d'évaluer la robustesse des approches proposées lorsque la routine est maintenue, en dépit de variation aléatoire et de mesurer objectivement les performances des méthodes de détection sur les types de comportements. La simulation a permis de montrer que la *M-CNJ* était plus sensible aux changements brusques que les deux autres approches (*M-DME*, *M-DTW*). Cependant, et comme mentionné au chapitre VI, il est intéressant d'exploiter la complémentarité des trois stratégies.

Perspectives

A travers les travaux proposés, nous avons fait face à une variété de défis scientifiques et en particulier la difficulté d'obtenir une base de données regroupant de l'enregistrement de plusieurs personnes âgées. Mais un bon nombre de ces difficultés ont pu être levées à l'aide de méthodes dédiées. A l'issue de ce travail, plusieurs perspectives peuvent être dégagées :

Concernant l'acquisition des données, nous avons fait état tout au long de ce mémoire de la difficulté d'obtenir une base de données conséquente. Ceci constitue bien évidemment la première perspective à ce travail au travers d'un protocole qu'il conviendra de présenter devant un comité éthique.

Concernant la détection du changement de comportement, il est possible d'envisager d'adopter des mêmes méthodes, mais à différentes périodes de la journée (le matin, l'après-midi et le soir). Cette stratégie permettrait d'obtenir une analyse plus fine de la journée et de mieux mettre en évidence les points de rupture de changements dans la journée.

Une étape importante serait aussi de synthétiser le comportement des indices mesurés (*DME*, *DTW*, *BI*) en état stable, transitoire ou évolution lente. Des approches telles que celle reportée dans Bosnjak et al. [220] représente une prolongation intéressante.

La classification des images de profondeur a permis de décrire la journée en succession de postures (assise, allongée, debout) avec indication de l'absence et la chute. Nous n'avons pas intégré la dimension temporelle dans nos analyses, d'une part dans l'enchaînement des postures et activités et d'autre part dans l'estimation de la durée de l'activité. Cette perspective devrait améliorer la description de la journée et de fait une meilleure précision sur l'évolution du maintien de la routine.

Sur un plan plus technique, nous n'avons pas étudié les caractéristiques de la marche qui pourraient être analysées à partir des images de profondeur. Des études de la littérature montrent que les modifications de la marche sont aussi des éléments caractéristiques de la fragilisation. On pourrait aussi imaginer à partir des images de profondeur de calculer la vitesse moyenne entre deux points de la pièce.

L'approche décrite dans cette recherche est une brique dans le domaine de l'évaluation de la fragilité et ne doit nullement exclure les approches plus classiques tels que le test de Fried (test de l'évaluation de la fragilité) chez le médecin. L'objectif des travaux futurs pourrait être triple :

- i) Démontrer que nos méthodes permettent la détection précoce de la fragilité à distance ;
- ii) Corréler les indices (Nombre de chutes, pourcentage de temps assis, debout, allongé et absente) aux mesures de Fried (cf page 20) et ainsi identifier les variables clefs les plus corrélées à la fragilité définie selon Fried (au moins trois des critères non respectés) ou préfragile (si un ou deux critères sont présents)
- iii) Confirmer les premières alertes émises par un test de Fried. Cette stratégie devrait permettre d'effectuer de manière anticipée le test de Fried chez le médecin et accélérer une prise en charge plus adaptée.

Les travaux menés dans cette thèse sont aussi complémentaires de ceux qui sont menés avec les objets connectés tels i) qu'un pèse-personne pour le suivi de l'évolution du poids de la personne, ii) que des capteurs au sol ou iii) qu'un appareil dédié à mesurer la force du poignet qui permet d'envoyer d'une manière continue les mesures prises par la personne âgée. L'ensemble de ces stratégies doivent être évaluées mais rajoutent des capteurs et posent indirectement le problème de leur utilisation en termes d'acceptabilité, d'acceptation et d'usage.

Sans ajout de capteurs, Il apparaît pertinent d'étudier le comportement de la personne par l'utilisation des appareils électriques (micro-ondes, sèche-cheveux, ordinateur, télévision et interrupteurs). Shimada et al. [221] ont rapporté de telles méthodes dans la littérature pour étudier le comportement irrégulier de la personne en se basant sur les données ('on' allumer/ 'off' éteindre) des appareils électriques. L'utilisation des appareils électriques s'inscrit indirectement dans la routine de la personne. Les méthodes développées dans le cadre de cette thèse sont suffisamment génériques et pourraient être appliquées à cet ensemble de mesures, extraits de l'utilisation des appareils électriques.

Publications

Revue internationale

Soumaya Msaad, Yannick Zoetgnande, Jean-Louis Dillenseger, Guy Carrault "Two propositions for detecting changes in the elderly senior routine", Accepté pour publication dans Measurement: Sensors. 2022.

Conférences avec comité de lecture et article long

1. Soumaya Msaad, Jean-Louis Dillenseger, Guy Carrault , "Interest of the dynamic time warping to detect behavior change of the elderly person", 43 ième conférence IEEE-EMBS, Mexique, Novembre 2021.
2. Soumaya Msaad, Jean-Louis Dillenseger, Guy Carrault, "Detection of changes in the behaviour of the elderly person", 43 ième conférence IEEE-EMBS, Mexique, Novembre 2021.
3. Soumaya Msaad, Yannick Zoetgnande, Geoffroy Cormier, Joaquim Prud'homme, Guy Carrault "Frailty detection in the elderly by monitoring their daily routine", 20 ième conférence IEEE-BIBE, USA, Octobre 2020.
4. Soumaya Msaad, Geoffroy Cormier, Guy Carrault , "Detecting falls and estimation of daily habits with depth images using machine learning algorithms", 42 ième conférence IEEE-EMBS, Montréal, Juillet 2020.

Conférences nationales et internationales avec comité de lecture et résumé

1. Soumaya Msaad, Yannick Zoetgnande, Geoffroy Cormier, Joaquim Prud'homme, Guy Carrault "détection de la fragilité chez les personnes âgées par suivi des activités de la vie quotidienne", 41 ième congrès Journées Annuelle De la Société Française De Gériatrie et Gérontologie, Novembre 2021.
2. Soumaya Msaad, Geoffroy Cormier, Guy Carrault "Detection of frailty of an elderly person by monitoring activities of daily living ", 10 ième conférence ICFSR, Toulouse, Mars 2020.
3. Soumaya Msaad, Geoffroy Cormier, Guy Carrault "Detection de la fragilisation d'une personne âgée par monitoring des habitudes de la vie", 8ème Congrès Francophone Fragilité du Sujet Agé, Toulouse, Mars 2020.

Bibliographie

- [1] S. Abbate, M. Avvenuti, P. Corsini, J. Light, and A. Vecchio, "Monitoring of Human Movements for Fall Detection and Activities Recognition in Elderly Care Using Wireless Sensor Network: a Survey," *Wirel. Sens. Networks Appl. Des.*, Dec. 2010, doi: 10.5772/13802.
- [2] V. Bergua *et al.*, "Restriction in instrumental activities of daily living in older persons: Association with preferences for routines and psychological vulnerability," *Int. J. Aging Hum. Dev.*, vol. 77, no. 4, pp. 309–329, Jan. 2013, doi: 10.2190/AG.77.4.c.
- [3] M. P. Lawton and E. M. Brody, "Assessment of Older People: Self-Maintaining and Instrumental Activities of Daily Living," *Gerontologist*, vol. 9, no. 3_Part_1, pp. 179–186, Oct. 1969, doi: 10.1093/GERONT/9.3_PART_1.179.
- [4] C. Jeandel, "Les différents parcours du vieillissement," *Trib. la Sante*, vol. 7, no. 2, pp. 25–35, 2005, doi: 10.3917/SEVE.007.35.
- [5] L. Wang, G. Van Belle, W. B. Kukull, and E. B. Larson, "Predictors of Functional Change: A Longitudinal Study of Nondemented People Aged 65 and Older," *J. Am. Geriatr. Soc.*, vol. 50, no. 9, pp. 1525–1534, Sep. 2002, doi: 10.1046/J.1532-5415.2002.50408.X.
- [6] P. Lutzler, M. Khoualene, K. Bekov, N. Lapalus, V. Carlier, and P. Hutzler, "Les mécanismes du vieillissement," *Phytotherapie*, vol. 3, no. 2, pp. 53–56, Apr. 2005, doi: 10.1007/S10298-005-0069-Y.
- [7] "Population par âge – Tableaux de l'économie française | Insee," Accessed: Oct. 17, 2019. [Online]. Available: <https://www.insee.fr/fr/statistiques/3676587?sommaire=3696937>.
- [8] "La population de la France métropolitaine en 2050 : un vieillissement inéluctable – Économie et Statistique n° 355-356 - 2002 | Insee." <https://www.insee.fr/fr/statistiques/1375921?sommaire=1375935> (accessed Sep. 22, 2021).
- [9] "Projections de population à l'horizon 2070 - Insee Première - 1619." <https://www.insee.fr/fr/statistiques/2496228> (accessed Oct. 01, 2021).
- [10] R. Lee, "The Demographic Transition: Three Centuries of Fundamental Change," *J. Econ. Perspect.*, vol. 17, no. 4, pp. 167–190, Sep. 2003, doi: 10.1257/089533003772034943.
- [11] "World Population Ageing United Nations."
- [12] N. Sirven, Y. Bourgueil, Laboratoire interdisciplinaire de recherche appliquée en économie de la santé (Paris), Institut de recherche et documentation en économie de la santé (France), and Impr. TCH réalisation), "La prévention de la perte d' autonomie : la fragilité en questions. Apports, limites et perspectives. Actes du séminaire des 6 et 7 mars 2014 organisé à Paris par le Liraes (EA4470), Université Paris Descartes, en partenariat avec l'Irdes," *Rapp. Irdes*, no. 563, Jan. 2016, Accessed: Dec. 30, 2021. [Online]. Available: www.irdes.fr/recherche/rapports/563-la-prevention-de-la-perte-d-autonomie-la-fragilite-en-questions.pdf.
- [13] P. Chassagne, Y. Rolland, and B. J. (Bruno J. . Vellas, "La personne âgée fragile," p. 196, 2009.
- [14] L. P. Fried *et al.*, "Frailty in Older Adults: Evidence for a Phenotype," *Journals Gerontol. Ser. A Biol. Sci. Med. Sci.*, vol. 56, no. 3, pp. M146–M157, Mar. 2001, doi: 10.1093/gerona/56.3.M146.

- [15] K. Rockwood *et al.*, "A global clinical measure of fitness and frailty in elderly people," *CMAJ*, vol. 173, no. 5, pp. 489–495, Aug. 2005, doi: 10.1503/CMAJ.050051.
- [16] R. J. J. Gobbens, M. A. L. M. van Assen, K. G. Luijckx, M. T. Wijnen-Sponselee, and J. M. G. A. Schols, "The Tilburg Frailty Indicator: Psychometric Properties," *J. Am. Med. Dir. Assoc.*, vol. 11, no. 5, pp. 344–355, Jun. 2010, doi: 10.1016/J.JAMDA.2009.11.003.
- [17] T. M. Gill, "Geriatric medicine: it's more than caring for old people," *Am. J. Med.*, vol. 113, no. 1, pp. 85–90, Jul. 2002, doi: 10.1016/S0002-9343(02)01187-7.
- [18] F. Nourhashemi, S. Andrieu, S. Gillette-Guyonnet, B. Vellas, J. L. Albarede, and H. Grandjean, "Instrumental Activities of Daily Living as a Potential Marker of Frailty: A Study of 7364 Community-Dwelling Elderly Women (the EPIDOS Study)," *Journals Gerontol. Ser. A Biol. Sci. Med. Sci.*, vol. 56, no. 7, pp. M448–M453, Jul. 2001, doi: 10.1093/gerona/56.7.M448.
- [19] P. G. Jarrett, K. Rockwood, D. Carver, P. Stolee, and S. Cosway, "Illness Presentation in Elderly Patients," *Arch. Intern. Med.*, vol. 155, no. 10, pp. 1060–1064, May 1995, doi: 10.1001/ARCHINTE.1995.00430100086010.
- [20] H. Syddall, C. Cooper, F. Martin, R. Briggs, and A. A. Sayer, "Is grip strength a useful single marker of frailty?," *Age Ageing*, vol. 32, no. 6, pp. 650–656, Nov. 2003, doi: 10.1093/AGEING/AFG111.
- [21] M. Montero-Odasso *et al.*, "Gait Velocity as a Single Predictor of Adverse Events in Healthy Seniors Aged 75 Years and Older," *Journals Gerontol. Ser. A*, vol. 60, no. 10, pp. 1304–1309, Oct. 2005, doi: 10.1093/GERONA/60.10.1304.
- [22] D. Hamerman, "Toward an understanding of frailty," *Ann. Intern. Med.*, vol. 130, no. 11, pp. 945–950, Jun. 1999, doi: 10.7326/0003-4819-130-11-199906010-00022.
- [23] J. W. Faller, D. do Nascimento Pereira, S. de Souza, F. K. Nampo, F. de Souza Orlandi, and S. Matumoto, "Instruments for the detection of frailty syndrome in older adults: A systematic review," *PLoS One*, vol. 14, no. 4, p. e0216166, Apr. 2019, doi: 10.1371/JOURNAL.PONE.0216166.
- [24] M. D. Rothman, L. Leo-Summers, and T. M. Gill, "Prognostic Significance of Potential Frailty Criteria," *J. Am. Geriatr. Soc.*, vol. 56, no. 12, pp. 2211–2216, Dec. 2008, doi: 10.1111/j.1532-5415.2008.02008.x.
- [25] K. E. Ensrud *et al.*, "Comparison of 2 Frailty Indexes for Prediction of Falls, Disability, Fractures, and Death in Older Women," *Arch. Intern. Med.*, vol. 168, no. 4, pp. 382–389, Feb. 2008, doi: 10.1001/ARCHINTERNMED.2007.113.
- [26] S. Studenski *et al.*, "Physical Performance Measures in the Clinical Setting," *J. Am. Geriatr. Soc.*, vol. 51, no. 3, pp. 314–322, Mar. 2003, doi: 10.1046/j.1532-5415.2003.51104.x.
- [27] S. Studenski *et al.*, "Clinical global impression of change in physical frailty: Development of a measure based on clinical judgment," *Journal of the American Geriatrics Society*, vol. 52, no. 9, pp. 1560–1566, Sep. 2004, doi: 10.1111/j.1532-5415.2004.52423.x.
- [28] D. M. Jones, X. Song, and K. Rockwood, "Operationalizing a Frailty Index from a Standardized Comprehensive Geriatric Assessment," *J. Am. Geriatr. Soc.*, vol. 52, no. 11, pp. 1929–1933, Nov. 2004, doi: 10.1111/j.1532-5415.2004.52521.x.
- [29] M. J. M. C. A Paw, J. M. Dekker, E. J. M. Feskens, E. G. Schouten, and D. Kromhout, "How to select a frail elderly population? A comparison of three working definitions," *J. Clin. Epidemiol.*, vol. 52, no. 11, pp. 1015–1021, Nov. 1999, doi: 10.1016/S0895-4356(99)00077-3.

- [30] D. B. Rolfson, S. R. Majumdar, R. T. Tsuyuki, A. Tahir, and K. Rockwood, "Validity and reliability of the Edmonton Frail Scale," *Age Ageing*, vol. 35, no. 5, pp. 526–529, Sep. 2006, doi: 10.1093/AGEING/AFL041.
- [31] H. Schuurmans, N. Steverink, S. Lindenberg, N. Frieswijk, and J. P. J. Slaets, "Old or Frail: What Tells Us More?," *Journals Gerontol. Ser. A Biol. Sci. Med. Sci.*, vol. 59, no. 9, pp. M962–M965, Sep. 2004, doi: 10.1093/gerona/59.9.M962.
- [32] K. Rockwood, K. Stadnyk, C. MacKnight, I. McDowell, R. Hébert, and D. B. Hogan, "A brief clinical instrument to classify frailty in elderly people," *Lancet*, vol. 353, no. 9148, pp. 205–206, Jan. 1999, doi: 10.1016/S0140-6736(98)04402-X.
- [33] Y. Rolland *et al.*, "La fragilité de la personne âgée : un consensus bref de la Société française de gériatrie et gérontologie," *Gériatrie Psychol. Neuropsychiatr. du Vieil.*, vol. 9, no. 4, pp. 387–390, Dec. 2011, doi: 10.1684/PNV.2011.0311.
- [34] A. J. Cruz-Jentoft *et al.*, "Prevalence of and interventions for sarcopenia in ageing adults: A systematic review. Report of the International Sarcopenia Initiative (EWGSOP and IWGS)," *Age Ageing*, vol. 43, no. 6, pp. 48–759, Nov. 2014, doi: 10.1093/ageing/afu115.
- [35] E. F. Binder *et al.*, "Effects of exercise training on frailty in community-dwelling older adults: Results of a randomized, controlled trial," *J. Am. Geriatr. Soc.*, vol. 50, no. 12, pp. 1921–1928, Dec. 2002, doi: 10.1046/j.1532-5415.2002.50601.x.
- [36] H. K. Kim *et al.*, "Effects of exercise and amino acid supplementation on body composition and physical function in community-dwelling elderly Japanese sarcopenic women: a randomized controlled trial," *J. Am. Geriatr. Soc.*, vol. 60, no. 1, pp. 16–23, Jan. 2012, doi: 10.1111/j.1532-5415.2011.03776.x.
- [37] A. J. Campbell and D. M. Buchner, "Unstable disability and the fluctuations of frailty," *Age Ageing*, vol. 26, no. 4, pp. 315–318, Jul. 1997, doi: 10.1093/AGEING/26.4.315.
- [38] P.-O. Lang, J.-P. Michel, and D. Zekry, "Frailty syndrome: a transitional state in a dynamic process.," *Gerontology*, vol. 55, no. 5, pp. 539–49, 2009, doi: 10.1159/000211949.
- [39] "Vieillesse et santé." <https://www.who.int/fr/news-room/fact-sheets/detail/ageing-and-health> (accessed Oct. 03, 2021).
- [40] S. S. Khan and J. Hoey, "Review of fall detection techniques: A data availability perspective," *Med. Eng. Phys.*, vol. 39, pp. 12–22, Jan. 2017, doi: 10.1016/J.MEDENGGPHY.2016.10.014.
- [41] A. Kochera, "Falls among older persons and the role of the home: an analysis of cost, incidence, and potential savings from home modification.," *undefined*, 2002.
- [42] T. M. Gill, C. S. Williams, and M. E. Tinetti, "Environmental hazards and the risk of nonsyncopal falls in the homes of community-living older persons," *Med. Care*, vol. 38, no. 12, pp. 1174–1183, 2000, doi: 10.1097/00005650-200012000-00004.
- [43] A. A. Zecevic, A. W. Salmoni, M. Speechley, and A. A. Vandervoort, "Defining a Fall and Reasons for Falling: Comparisons Among the Views of Seniors, Health Care Providers, and the Research Literature," vol. 46, no. 3, pp. 367–376, 2006, Accessed: Jan. 08, 2022. [Online]. Available: <https://academic.oup.com/gerontologist/article/46/3/367/565294>.
- [44] F. Bloch, "Les complications non traumatiques des chutes : des conséquences trop souvent négligées chez la personne âgée," *NPG Neurol. - Psychiatr. - Gériatrie*, vol. 15, no. 88, pp. 188–190, Aug. 2015, doi: 10.1016/J.NPG.2015.02.001.
- [45] G. Bergen, "Falls and Fall Injuries Among Adults Aged ≥65 Years — United States, 2014,"

- MMWR. Morb. Mortal. Wkly. Rep.*, vol. 65, no. 37, pp. 993–998, Sep. 2019, doi: 10.15585/MMWR.MM6537A2.
- [46] G. F. Fuller, “Falls in the Elderly,” *Am. Fam. Physician*, vol. 61, no. 7, p. 2159, Apr. 2000.
- [47] D. R. Kenshalo, “Somesthetic sensitivity in young and elderly humans,” *J. Gerontol.*, vol. 41, no. 6, pp. 732–742, 1986, doi: 10.1093/GERONJ/41.6.732.
- [48] D. K.-J. Gerontol and undefined 1986, “Somasthetic sensitivity in young and elderly humans,” *ci.nii.ac.jp*, Accessed: Apr. 09, 2022. [Online]. Available: <https://ci.nii.ac.jp/naid/10005170337/>.
- [49] G. E. Stelmach, H. N. Zelaznik, and D. Lowe, “The influence of aging and attentional demands on recovery from postural instability,” *Aging (Milano)*, vol. 2, no. 2, pp. 155–161, 1990, doi: 10.1007/BF03323910.
- [50] B. E. Maki, M. A. Edmondstone, and W. E. McIlroy, “Age-Related Differences in Laterally Directed Compensatory Stepping Behavior,” *Journals Gerontol. Ser. A*, vol. 55, no. 5, pp. M270–M277, May 2000, doi: 10.1093/GERONA/55.5.M270.
- [51] J. L. O’loughlin, Y. Robitaille, J. F. Boivin, and S. Suissa, “Incidence of and risk factors for falls and injurious falls among the community-dwelling elderly,” *Am. J. Epidemiol.*, vol. 137, no. 3, pp. 342–354, Feb. 1993, doi: 10.1093/OXFORDJOURNALS.AJE.A116681.
- [52] J. K. Startzell, D. A. Owens, L. M. Mulfinger, and P. R. Cavanagh, “Stair negotiation in older people: A review,” *J. Am. Geriatr. Soc.*, vol. 48, no. 5, pp. 567–580, 2000, doi: 10.1111/J.1532-5415.2000.TB05006.X.
- [53] G. Yogev-Seligmann, J. M. Hausdorff, and N. Giladi, “The Role of Executive Function and Attention in Gait,” *Mov. Disord.*, vol. 23, no. 3, p. 329, Feb. 2008, doi: 10.1002/MDS.21720.
- [54] M. E. Tinetti, M. Speechley, and S. F. Ginter, “Risk Factors for Falls among Elderly Persons Living in the Community,” <http://dx.doi.org/10.1056/NEJM198812293192604>, vol. 319, no. 26, pp. 1701–1707, Jan. 2010, doi: 10.1056/NEJM198812293192604.
- [55] D. Paleacu, A. Shutzman, N. Giladi, T. Herman, E. S. Simon, and J. M. Hausdorff, “Effects of pharmacological therapy on gait and cognitive function in depressed patients,” *Clin. Neuropharmacol.*, vol. 30, no. 2, pp. 63–71, Mar. 2007, doi: 10.1097/01.WNF.0000240949.41691.95.
- [56] W. YC *et al.*, “Depression as a predictor of falls amongst institutionalized elders,” *Aging Ment. Health*, vol. 16, no. 6, pp. 763–770, Aug. 2012, doi: 10.1080/13607863.2012.678479.
- [57] “Soins infirmiers en gériatrie: vieillissement normal et pathologique - Mickey Stanley, Patricia Gauntlett Beare - Google Livres.” .
- [58] A. F. Ambrose, G. Paul, and J. M. Hausdorff, “Risk factors for falls among older adults: a review of the literature,” *Maturitas*, vol. 75, no. 1, pp. 51–61, May 2013, doi: 10.1016/J.MATURITAS.2013.02.009.
- [59] J. M. Hausdorff, T. Herman, R. Baltadjieva, T. Gurevich, and N. Giladi, “Balance and gait in older adults with systemic hypertension,” *Am. J. Cardiol.*, vol. 91, no. 5, pp. 643–645, Mar. 2003, doi: 10.1016/S0002-9149(02)03332-5.
- [60] N. A. Sanders *et al.*, “Atrial fibrillation: an independent risk factor for nonaccidental falls in older patients,” *Pacing Clin. Electrophysiol.*, vol. 35, no. 8, pp. 973–979, Aug. 2012, doi: 10.1111/J.1540-8159.2012.03443.X.

- [61] S. E. Lamb, E. C. Jørstad-Stein, K. Hauer, and C. Becker, "Development of a common outcome data set for fall injury prevention trials: the Prevention of Falls Network Europe consensus," *J. Am. Geriatr. Soc.*, vol. 53, no. 9, pp. 1618–1622, Sep. 2005, doi: 10.1111/J.1532-5415.2005.53455.X.
- [62] F. Bloch *et al.*, "Can metabolic abnormalities after a fall predict short term mortality in elderly patients?," *Eur. J. Epidemiol.*, vol. 24, no. 7, pp. 357–362, Jul. 2009, doi: 10.1007/S10654-009-9342-Y.
- [63] J. Fleming and C. Brayne, "Inability to get up after falling, subsequent time on floor, and summoning help: prospective cohort study in people over 90," *BMJ*, vol. 337, no. 7681, pp. 1279–1282, Nov. 2008, doi: 10.1136/BMJ.A2227.
- [64] R. J. Gurley, N. Lum, M. Sande, B. Lo, and M. H. Katz, "Persons found in their homes helpless or dead," *N. Engl. J. Med.*, vol. 334, no. 26, pp. 1710–1716, Jun. 1996, doi: 10.1056/NEJM199606273342606.
- [65] S. R. Lord, J. A. Ward, P. Williams, and K. J. Anstey, "Physiological Factors Associated with Falls in Older Community-Dwelling Women," *J. Am. Geriatr. Soc.*, vol. 42, no. 10, pp. 1110–1117, Oct. 1994, doi: 10.1111/J.1532-5415.1994.TB06218.X.
- [66] S. Heinrich, K. Rapp, U. Rissmann, C. Becker, and H. H. König, "Cost of falls in old age: a systematic review," *Osteoporos. Int.*, vol. 21, no. 6, pp. 891–902, Jun. 2010, doi: 10.1007/S00198-009-1100-1.
- [67] M. E. Tinetti, "Performance-oriented assessment of mobility problems in elderly patients," *J. Am. Geriatr. Soc.*, vol. 34, no. 2, pp. 119–126, 1986, doi: 10.1111/J.1532-5415.1986.TB05480.X.
- [68] S. Mathias, U. S. L. Nayak, and B. Isaacs, "Balance in elderly patients: the 'get-up and go' test.," *Arch. Phys. Med. Rehabil.*, vol. 67, no. 6, pp. 387–389, Jun. 1986, Accessed: Apr. 09, 2022. [Online]. Available: <https://europepmc.org/article/med/3487300>.
- [69] P. DARGENT, "Epidémiologie des chutes et des traumatismes liés aux chutes chez les personnes âgées.," *Rev. Epidemiol. Sante Publique*, 1995.
- [70] B. Leblanc, "Les chutes," *Orthopédie-traumatologie la Pers. âgée fragile*, pp. 55–65, 2013, doi: 10.1007/978-2-8178-0377-7_5.
- [71] D. S. C., MorikawaChamin, and P. M., "State of the art of smart homes," *Eng. Appl. Artif. Intell.*, vol. 25, no. 7, pp. 1313–1321, Oct. 2012, doi: 10.1016/J.ENGAPPAL.2012.05.002.
- [72] M. Chan, D. Estève, C. Escriba, and E. Campo, "A review of smart homes-Present state and future challenges," *Comput. Methods Programs Biomed.*, vol. 91, no. 1, pp. 55–81, Jul. 2008, doi: 10.1016/J.CMPB.2008.02.001.
- [73] M. Mubashir, L. Shao, and L. Seed, "A survey on fall detection: Principles and approaches," *Neurocomputing*, vol. 100, pp. 144–152, Jan. 2013, doi: 10.1016/J.NEUCOM.2011.09.037.
- [74] T. Xiang and S. Gong, "Video Behaviour Profiling and Abnormality Detection without Manual Labelling," 2005.
- [75] Y. Shimada, T. Matsumoto, and S. Kawaji, "DEVELOPMENT OF HUMAN DAILY BEHAVIOR MODEL AND IT'S APPLICATION."
- [76] A. BENMANSOUR, A. BOUCHACHIA, and M. FEHAM, "Multioccupant Activity Recognition in Pervasive Smart Home Environments," *scholar.archive.org*, vol. 48, no. 3, Dec. 2015, doi: 10.1145/2835372.

- [77] F. Steenkeste, H. Bocquet, M. Chan, and E. Campo, "La mise en place d'une technologie pour observer le comportement nocturne des personnes âgées en institution," *ITBM-RBM*, vol. 22, no. 1, pp. 25–30, Feb. 2001, doi: 10.1016/S1297-9562(01)90043-9.
- [78] N. Noury, "Ailisa: Assessment units for medical monitoring and assistance technologies in gerontology," *Gerontol. Soc.*, vol. 113, no. 2, pp. 97–119, Jun. 2005, doi: 10.3917/GS.113.0097.
- [79] N. Noury *et al.*, "Monitoring behavior in home using a smart fall sensor and position sensors," *1st Annu. Int. IEEE-EMBS Spec. Top. Conf. Microtechnologies Med. Biol. - Proc.*, pp. 607–610, 2000, doi: 10.1109/MMB.2000.893857.
- [80] N. Noury, G. Virone, P. Barralon, V. Rialle, and J. Demongeot, "Maisons intelligentes pour personnes âgées : technologies de l'information intégrées au service des soins à domicile," *J3eA*, vol. 3, p. 020, 2004, doi: 10.1051/BIB-J3EA:2004620.
- [81] V. Leonov, "Thermoelectric energy harvesting of human body heat for wearable sensors," *IEEE Sens. J.*, vol. 13, no. 6, pp. 2284–2291, 2013, doi: 10.1109/JSEN.2013.2252526.
- [82] T. Tamura, Y. Maeda, M. Sekine, and M. Yoshida, "Wearable Photoplethysmographic Sensors—Past and Present," *Electron. 2014, Vol. 3, Pages 282-302*, vol. 3, no. 2, pp. 282–302, Apr. 2014, doi: 10.3390/ELECTRONICS3020282.
- [83] T. T. Zhang *et al.*, "Sound based heart rate monitoring for wearable systems," *2010 Int. Conf. Body Sens. Networks, BSN 2010*, pp. 139–143, 2010, doi: 10.1109/BSN.2010.25.
- [84] A. K. Bourke, J. V. O'Brien, and G. M. Lyons, "Evaluation of a threshold-based tri-axial accelerometer fall detection algorithm," *Gait Posture*, vol. 26, no. 2, pp. 194–199, Jul. 2007, doi: 10.1016/J.GAITPOST.2006.09.012.
- [85] G. Wu, "Distinguishing fall activities from normal activities by velocity characteristics," *J. Biomech.*, vol. 33, no. 11, pp. 1497–1500, Nov. 2000, doi: 10.1016/S0021-9290(00)00117-2.
- [86] M. Silva, E. F. Shepherd, W. O. Jackson, F. J. Dorey, and T. P. Schmalzried, "Average patient walking activity approaches 2 million cycles per year: pedometers under-record walking activity," *J. Arthroplasty*, vol. 17, no. 6, pp. 693–697, 2002, doi: 10.1054/ARTH.2002.32699.
- [87] C. Ranhotigimage, "Human activities & posture recognition : innovative algorithm for highly accurate detection rate : a thesis submitted in fulfilment of the requirements for the degree of Master of Engineering in Electronics & Computer Systems Engineering at Massey University, Palmerston North, New Zealand," 2013, Accessed: Sep. 20, 2021. [Online]. Available: <https://mro.massey.ac.nz/handle/10179/4339>.
- [88] T. Shany, S. J. Redmond, M. R. Narayanan, and N. H. Lovell, "Sensors-based wearable systems for monitoring of human movement and falls," *IEEE Sens. J.*, vol. 12, no. 3, pp. 658–670, 2012, doi: 10.1109/JSEN.2011.2146246.
- [89] Y. Chuo *et al.*, "Mechanically flexible wireless multisensor platform for human physical activity and vitals monitoring," *IEEE Trans. Biomed. Circuits Syst.*, vol. 4, no. 5, pp. 281–294, Oct. 2010, doi: 10.1109/TBCAS.2010.2052616.
- [90] M. Saleh and R. L. B. Jeannes, "Elderly Fall Detection Using Wearable Sensors: A Low Cost Highly Accurate Algorithm," *IEEE Sens. J.*, vol. 19, no. 8, pp. 3156–3164, Apr. 2019, doi: 10.1109/JSEN.2019.2891128.
- [91] F. Chamroukhi, S. Mohammed, D. Trabelsi, L. Oukhellou, and Y. Amirat, "Joint segmentation of multivariate time series with hidden process regression for human activity recognition,"

- Neurocomputing*, vol. 120, pp. 633–644, Nov. 2013, doi: 10.1016/J.NEUCOM.2013.04.003.
- [92] N. Noury *et al.*, “Fall detection - Principles and methods,” in *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, 2007, pp. 1663–1666, doi: 10.1109/IEMBS.2007.4352627.
- [93] A. K. Bourke, P. W. J. Van De Ven, A. E. Chaya, G. M. ÓLaighin, and J. Nelson, “Testing of a long-term fall detection system incorporated into a custom vest for the elderly,” in *Proceedings of the 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS’08 - “Personalized Healthcare through Technology,”* 2008, pp. 2844–2847, doi: 10.1109/iembs.2008.4649795.
- [94] G. Wu and S. Xue, “Portable preimpact fall detector with inertial sensors,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 16, no. 2, pp. 178–183, Apr. 2008, doi: 10.1109/TNSRE.2007.916282.
- [95] M. Abbas, D. Somme, and R. Le Bouquin Jeannes, “Machine Learning-Based Physical Activity Tracking with a view to Frailty Analysis,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Jul. 2020, vol. 2020-July, pp. 3917–3920, doi: 10.1109/EMBC44109.2020.9175589.
- [96] J. Dai, X. Bai, Z. Yang, Z. Shen, and D. Xuan, “Mobile phone-based pervasive fall detection,” *Pers. Ubiquitous Comput.*, vol. 14, no. 7, pp. 633–643, Oct. 2010, doi: 10.1007/S00779-010-0292-X.
- [97] M. Kangas, A. Konttila, P. Lindgren, I. Winblad, and T. Jämsä, “Comparison of low-complexity fall detection algorithms for body attached accelerometers,” *Gait Posture*, vol. 28, no. 2, pp. 285–291, Aug. 2008, doi: 10.1016/J.GAITPOST.2008.01.003.
- [98] Q. Li, J. A. Stankovic, M. Hanson, A. Barth, J. Lach, and G. Zhou, “Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information.”
- [99] G. Demiris *et al.*, “Older adults’ attitudes towards and perceptions of ‘smart home’ technologies: A pilot study,” *Med. Inform. Internet Med.*, vol. 29, no. 2, pp. 87–94, Jun. 2004, doi: 10.1080/14639230410001684387.
- [100] Y. Zigel, D. Litvak, and I. Gannot, “A method for automatic fall detection of elderly people using floor vibrations and soundProof of concept on human mimicking doll falls,” *IEEE Trans. Biomed. Eng.*, vol. 56, no. 12, pp. 2858–2867, Dec. 2009, doi: 10.1109/TBME.2009.2030171.
- [101] M. Popescu, Y. Li, M. Skubic, and M. Rantz, “An acoustic fall detector system that uses sound height information to reduce the false alarm rate,” *Proc. 30th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS’08 - “Personalized Healthc. through Technol.*, pp. 4628–4631, 2008, doi: 10.1109/IEMBS.2008.4650244.
- [102] H. Medjahed *et al.*, “A pervasive multi-sensor data fusion for smart home healthcare monitoring A Pervasive Multi-sensors Data Fusion for Smart Home Healthcare Monitoring,” pp. 1466–1473, 2011, doi: 10.1109/FUZZY.2011.6007636i.
- [103] S. Karaman *et al.*, “Hierarchical Hidden Markov Model in Detecting Activities of Daily Living in Wearable Videos for Studies of Dementia,” vol. 69, no. 3, pp. 743–771, 2014, doi: 10.1007/s11042-012-1117-xi.
- [104] K. Chaccour, R. Darazi, A. Hajjam El Hassans, and E. Andres, “Smart carpet using differential piezoresistive pressure sensors for elderly fall detection,” *2015 IEEE 11th Int. Conf. Wirel. Mob. Comput. Netw. Commun. WiMob 2015*, pp. 225–229, Dec. 2015, doi: 10.1109/WIMOB.2015.7347965.

- [105] H. Rimminen, J. Lindström, M. Linnavuo, and R. Sepponen, "Detection of falls among the elderly by a floor sensor using the electric near field," *IEEE Trans. Inf. Technol. Biomed.*, vol. 14, no. 6, pp. 1475–1476, Nov. 2010, doi: 10.1109/TITB.2010.2051956.
- [106] H. Rimminen, J. Lindström, and R. Sepponen, "POSITIONING ACCURACY AND MULTI-TARGET SEPARATION WITH A HUMAN TRACKING SYSTEM USING NEAR FIELD IMAGING," *Int. J. Smart Sens. Intell. Syst.*, vol. 2, no. 1, pp. 156–175, 2009, doi: 10.21307/IJSSIS-2017-343.
- [107] U. Joseph Fourier -grenoble, X. LE Hoa Binh, and M. M. Alain FRANCO Président Eric CAMPO Rapporteur M Alain GUINET Rapporteur M Norbert NOURY Examineur, "RECONNAISSANCE DES COMPORTEMENTS D'UNE PERSONNE AGEÉ VIVANT SEULE DANS UN HABITAT INTELLIGENT POUR LA SANTE," Dec. 2008, Accessed: Jan. 08, 2022. [Online]. Available: <https://tel.archives-ouvertes.fr/tel-00580747>.
- [108] P. Barralon, "Classification et Fusion de Données Actimétriques pour la Télévigilance Médicale : Elaboration et Validation Expérimentale chez la Personne Jeune et Agée."
- [109] S. Ohta, H. Nakamoto, Y. Shinagawa, and T. Tanikawa, "A health monitoring system for elderly people living alone," *J. Telemed. Telecare*, vol. 8, no. 3, pp. 151–156, Nov. 2002, doi: 10.1177/1357633x0200800305.
- [110] D. Ayers and M. Shah, "Monitoring human behavior from video taken in an office environment," *Image Vis. Comput.*, vol. 19, no. 12, pp. 833–846, Oct. 2001, doi: 10.1016/S0262-8856(01)00047-6.
- [111] A. A. Charaoui, P. Climent-Pérez, and F. Flórez-Revuelta, "A review on vision techniques applied to Human Behaviour Analysis for Ambient-Assisted Living," *Expert Syst. Appl.*, vol. 39, no. 12, pp. 10873–10888, Accessed: Sep. 21, 2021. [Online]. Available: https://www.academia.edu/3269437/A_review_on_vision_techniques_applied_to_Human_Behaviour_Analysis_for_Ambient_Assisted_Living.
- [112] T. V. Duong, H. H. Bui, D. Q. Phung, and S. Venkatesh, "Activity recognition and abnormality detection with the switching hidden semi-Markov model," *Proc. - 2005 IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognition, CVPR 2005*, vol. 1, pp. 838–845, 2005, doi: 10.1109/CVPR.2005.61.
- [113] N. Thome, S. Miguët, and S. Ambellouis, "A Real-Time, Multi-View Fall Detection System: a LHMM-Based Approach," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 18, no. 11, pp. 1522–1532, Nov. 2008, doi: 10.1109/TCSVT.2008.2005606.
- [114] T. T. H. Tran, T. L. Le, and J. Morel, "An analysis on human fall detection using skeleton from Microsoft kinect," *2014 IEEE 5th Int. Conf. Commun. Electron. IEEE ICCE 2014*, pp. 484–489, Oct. 2014, doi: 10.1109/CCE.2014.6916752.
- [115] A. Dubois and F. Charpillet, "A gait analysis method based on a depth camera for fall prevention," *Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. IEEE Eng. Med. Biol. Soc. Annu. Int. Conf.*, vol. 2014, pp. 4515–4518, Nov. 2014, doi: 10.1109/EMBC.2014.6944627.
- [116] L. Tao, T. Volonakis, B. Tan, Y. Jing, K. Chetty, and M. Smith, "Home Activity Monitoring using Low Resolution Infrared Sensor," Nov. 2018, Accessed: Sep. 21, 2021. [Online]. Available: <https://arxiv.org/abs/1811.05416v1>.
- [117] J. W. Davis and V. Sharma, "Robust detection of people in thermal imagery," *Proc. - Int. Conf. Pattern Recognit.*, vol. 4, pp. 713–716, 2004, doi: 10.1109/ICPR.2004.1333872.
- [118] J. Rafferty, J. Synnott, C. Nugent, G. Morrison, and E. Tamburini, "Fall Detection Through Thermal Vision Sensing," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell.*

- Lect. Notes Bioinformatics*), vol. 10070 LNCS, pp. 84–90, 2016, doi: 10.1007/978-3-319-48799-1_10.
- [119] J. Quero, M. Burns, M. Razzaq, C. Nugent, and M. Espinilla, “Detection of Falls from Non-Invasive Thermal Vision Sensors Using Convolutional Neural Networks,” *Proceedings*, vol. 2, no. 19, p. 1236, Oct. 2018, doi: 10.3390/PROCEEDINGS2191236.
- [120] S. Vadivelu, S. Ganesan, O. V. R. Murthy, and A. Dhall, “Thermal imaging based elderly fall detection,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 10118 LNCS, pp. 541–553, 2017, doi: 10.1007/978-3-319-54526-4_40.
- [121] A. Hayashida, V. Moshnyaga, and K. Hashimoto, “The use of thermal IR array sensor for indoor fall detection,” *2017 IEEE Int. Conf. Syst. Man, Cybern. SMC 2017*, vol. 2017-Janua, pp. 594–599, Nov. 2017, doi: 10.1109/SMC.2017.8122671.
- [122] A. A. Zulfikar, N. Lorenzo-Villalba, A. Peixoto, J. Rio, and A. Gillibert, “Étude de la fragilité de la personne âgée et de l’activité physique en médecine générale : à propos d’une étude prospective,” *Rev. Epidemiol. Sante Publique*, vol. 68, no. 5, pp. 282–287, Sep. 2020, doi: 10.1016/J.RESPE.2020.06.006.
- [123] D. B. Maltais, “The benefits of physical activities on cognitive and mental health in healthy and pathological aging Article in Geriatrie et Psychologie Neuropsychiatrie du Vieillessement .,” 2018, doi: 10.1684/pnv.2018.0734.
- [124] C. Daskalopoulou, B. Stubbs, C. Kralj, A. Koukounari, M. Prince, and A. M. Prina, “Physical activity and healthy ageing: A systematic review and meta-analysis of longitudinal cohort studies,” *Ageing Res. Rev.*, vol. 38, pp. 6–17, Sep. 2017, doi: 10.1016/J.ARR.2017.06.003.
- [125] B. JA *et al.*, “Effects of exercise training on older patients with major depression,” *Arch. Intern. Med.*, vol. 159, no. 19, pp. 2349–2356, Oct. 1999, doi: 10.1001/ARCHINTE.159.19.2349.
- [126] S. de Beauvoir, *La vieillesse*. 1970.
- [127] P. Binswanger *et al.*, “François Höpflinger et Astrid Stuckelberger Alter Anziani Vieillesse Principaux résultats et perspectives du Programme National de Recherche PNR32,” 1999.
- [128] R. J. Kastenbaum, “Habituation as a Model of Human Aging.,” <http://dx.doi.org/10.2190/BR5F-H8B7-2B9X-53U8>, vol. 12, no. 3, pp. 159–170, Jan. 1995, doi: 10.2190/BR5F-H8B7-2B9X-53U8.
- [129] J. W. Reich and A. J. Zautra, “Analyzing the trait of routinization in older adults.,” *Int. J. Aging Hum. Dev.*, vol. 32, no. 3, pp. 161–80, 1991, doi: 10.2190/4PKR-F87M-UXEQ-R5J2.
- [130] J. Bouisson and J. Swendsen, “Routinization and Emotional Well-Being: An Experience Sampling Investigation in an Elderly French Sample,” *Journals Gerontol. Ser. B*, vol. 58, no. 5, pp. P280–P282, Sep. 2003, doi: 10.1093/GERONB/58.5.P280.
- [131] J. Bouisson, “Routinization preferences, anxiety, and depression in an elderly French sample,” *J. Aging Stud.*, vol. 16, no. 3, pp. 295–302, 2002, doi: 10.1016/S0890-4065(02)00051-8.
- [132] V. Bergua, C. Fabrigoule, P. Barberger-Gateau, J.-F. Dartigues, J. Swendsen, and J. Bouisson, “Preferences for routines in older people: associations with cognitive and psychological vulnerability,” *Int. J. Geriatr. Psychiatry*, vol. 21, no. 10, pp. 990–998, Oct. 2006, doi: 10.1002/GPS.1597.
- [133] P. Chassagne, “Gériatrie Évaluation de la dépendance,” 2018.
- [134] J. Bouisson, “Vieillesse, vulnérabilité perçue et routinisation,” *Retraite Soc.*, vol. 52, no. 3,

- pp. 107–128, Oct. 2007, doi: 10.3917/RS.052.0107.
- [135] P. Bose, J. Van Der Aalst, M. Žliobaite, and Pechenizkiy, “Handling Concept Drift in Process Mining,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 6741 LNCS, pp. 391–405, 2011, doi: 10.1007/978-3-642-21640-4_30.
- [136] X. H. B. Le, M. Di Mascolo, A. Gouin, and N. Noury, “Health smart home for elders - A tool for automatic recognition of activities of daily living,” *Proc. 30th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS’08 - “Personalized Healthc. through Technol.*, pp. 3316–3319, 2008, doi: 10.1109/IEMBS.2008.4649914.
- [137] D. Wilson, “Assistive intelligent environments for automatic health monitoring,” 2005, Accessed: Sep. 30, 2021. [Online]. Available: <https://search.proquest.com/openview/de3c844c74e741ce8f027d118e30f861/1?pq-origsite=gscholar&cbl=18750&diss=y>.
- [138] P. Barralon, “Classification et Fusion de Données Actimétriques pour la Télévigilance Médicale : Elaboration et Validation Expérimentale chez la Personne Jeune et Agée,” Accessed: Sep. 30, 2021. [Online]. Available: <https://tel.archives-ouvertes.fr/tel-00011106>.
- [139] A. Lotfi, C. Langensiepen, S. M. Mahmoud, and M. J. Akhlaghinia, “Smart homes for the elderly dementia sufferers: identification and prediction of abnormal behaviour,” *J. Ambient Intell. Humaniz. Comput. 2011 33*, vol. 3, no. 3, pp. 205–218, Jan. 2011, doi: 10.1007/S12652-010-0043-X.
- [140] G. Jain, D. J. Cook, and V. Jakkula, “Monitoring Health by Detecting Drifts and Outliers for a Smart Environment Inhabitant 1,” 2003.
- [141] P. N. Dawadi, D. J. Cook, and M. Schmitter-Edgecombe, “Modeling patterns of activities using activity curves,” *Pervasive Mob. Comput.*, vol. 28, pp. 51–68, Jun. 2016, doi: 10.1016/J.PMCJ.2015.09.007.
- [142] G. Sprint, D. Cook, R. Fritz, and M. Schmitter-Edgecombe, “Detecting Health and Behavior Change by Analyzing Smart Home Sensor Data,” *2016 IEEE Int. Conf. Smart Comput. SMARTCOMP 2016*, Jun. 2016, doi: 10.1109/SMARTCOMP.2016.7501687.
- [143] G. Cormier, “Analyse statique et dynamique de cartes de profondeurs : application au suivi des personnes à risque sur leur lieu de vie,” <http://www.theses.fr>, Nov. 2015, Accessed: Oct. 30, 2021. [Online]. Available: <http://www.theses.fr/2015REN1S146>.
- [144] I. Halima, “Suivi de l’activité d’une personne à partir de capteurs multi-modalités préservant l’anonymat dans un cadre de détection et prévention des chutes chez les personnes âgées,” Mar. 2021, Accessed: Oct. 30, 2021. [Online]. Available: <https://tel.archives-ouvertes.fr/tel-03212630>.
- [145] Y. Zoetgnandé, “Fall detection and activity recognition using stereo low-resolution thermal imaging,” <http://www.theses.fr>, Dec. 2020, Accessed: Oct. 30, 2021. [Online]. Available: <http://www.theses.fr/2020REN1S073>.
- [146] G. Cormier, “Analyse statique et dynamique de cartes de profondeurs : application au suivi des personnes à risque sur leur lieu de vie,” <http://www.theses.fr>, Nov. 2015.
- [147] I. Halima, “Suivi de l’activité d’une personne à partir de capteurs multi-modalité préservant l’anonymat dans un cadre de détection et prévention des chutes chez les personnes âgées,” <http://www.theses.fr>, Mar. 2021.
- [148] S. Msaad, G. Cormier, and G. Carrault, “Detecting falls and estimation of daily habits with

- depth images using machine learning algorithms,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Jul. 2020, vol. 2020-July, pp. 2163–2166, doi: 10.1109/EMBC44109.2020.9175601.
- [149] S. Msaad, J. L. Dillenseger, and G. Carrault, “Interest of the minimum edit distance to detect behaviour change of the elderly person,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 7377–7380, 2021, doi: 10.1109/EMBC46164.2021.9629665.
- [150] S. Msaad, J.-L. Dillenseger, G. Cormier, and G. Carrault, “Detection of changes in the behaviour of the elderly person,” p. 3425495, 2021, Accessed: Dec. 02, 2021. [Online]. Available: <https://hal.archives-ouvertes.fr/hal-03425495>.
- [151] S. Msaad, Y. Zoetgnande, J. Prud’homme, G. Cormier, and G. Carrault, “Frailty detection of older adults by monitoring their daily routine,” *Proc. - IEEE 20th Int. Conf. Bioinforma. Bioeng. BIBE 2020*, pp. 701–704, Oct. 2020, doi: 10.1109/BIBE50027.2020.00118.
- [152] L. Sevrin, “Mesure et suivi d’activité de plusieurs personnes dans un Living Lab en vue de l’extraction d’indicateurs de santé et de bien-être,” <http://www.theses.fr>, Sep. 2016, Accessed: Dec. 03, 2021. [Online]. Available: <http://www.theses.fr/2016LYSE1162>.
- [153] Z. Zhang, “Introduction to machine learning: K-nearest neighbors,” *Ann. Transl. Med.*, vol. 4, no. 11, Jun. 2016, doi: 10.21037/atm.2016.03.37.
- [154] L. A. Breslow and D. W. Aha, “Simplifying decision trees: A survey,” *Knowledge Engineering Review*, vol. 12, no. 1. Cambridge University Press, pp. 1–40, 1997, doi: 10.1017/S0269888997000015.
- [155] L. Breiman, “Random forests,” *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [156] A. Roitberg, N. Somani, A. Perzylo, M. Rickert, and A. Knoll, “Multimodal human activity recognition for industrial manufacturing processes in robotic workcells,” *ICMI 2015 - Proc. 2015 ACM Int. Conf. Multimodal Interact.*, pp. 259–266, Nov. 2015, doi: 10.1145/2818346.2820738.
- [157] W. Lin, M. T. Sun, R. Poovandran, and Z. Zhang, “Human activity recognition for video surveillance,” *Proc. - IEEE Int. Symp. Circuits Syst.*, pp. 2737–2740, 2008, doi: 10.1109/ISCAS.2008.4542023.
- [158] G. Sebestyen, I. Stoica, and A. Hangan, “Human activity recognition and monitoring for elderly people,” *Proc. - 2016 IEEE 12th Int. Conf. Intell. Comput. Commun. Process. ICCP 2016*, pp. 341–347, Nov. 2016, doi: 10.1109/ICCP.2016.7737171.
- [159] E. de Maria, T. l’Yvonne, S. Moisan, and J.-P. Rigault, “Probabilistic Activity Recognition For Serious Games With Applications In Medicine,” Nov. 2019, Accessed: Oct. 20, 2021. [Online]. Available: <https://hal.inria.fr/hal-02341600>.
- [160] J. L. Miles-Chan and A. G. Dulloo, “Posture Allocation Revisited: Breaking the Sedentary Threshold of Energy Expenditure for Obesity Management,” *Front. Physiol.*, vol. 0, no. JUN, p. 420, 2017, doi: 10.3389/FPHYS.2017.00420.
- [161] Ó. D. Lara and M. A. Labrador, “A survey on human activity recognition using wearable sensors,” *IEEE Commun. Surv. Tutorials*, vol. 15, no. 3, pp. 1192–1209, 2013, doi: 10.1109/SURV.2012.110112.00192.
- [162] J. K. Aggarwal and M. S. Ryoo, “Human Activity Analysis: A Review,” *ACM Comput. Surv.*
- [163] V. Rie Bergua and J. Bouisson, “Vieillesse et routinisation : une revue de la question Aging and

- routinization: a review," *Psychol NeuroPsychiatr Vieil*, vol. 6, no. 4, pp. 235–278, 2008, doi: 10.1684/pnv.2008.0144.
- [164] J. Wang *et al.*, "Wearable sensor based human posture recognition," *Proc. - 2016 IEEE Int. Conf. Big Data, Big Data 2016*, pp. 3432–3438, 2016, doi: 10.1109/BIGDATA.2016.7841004.
- [165] G. De Leonardis *et al.*, "Human Activity Recognition by Wearable Sensors : Comparison of different classifiers for real-time applications," *MeMeA 2018 - 2018 IEEE Int. Symp. Med. Meas. Appl. Proc.*, Aug. 2018, doi: 10.1109/MEMEA.2018.8438750.
- [166] N. Foubert, A. M. McKee, R. A. Goubran, and F. Knoefel, "Lying and sitting posture recognition and transition detection using a pressure sensor array," *MeMeA 2012 - 2012 IEEE Symp. Med. Meas. Appl. Proc.*, pp. 65–70, 2012, doi: 10.1109/MEMEA.2012.6226630.
- [167] A. Babu, K. Dube, S. Mukhopadhyay, H. Ghayvat, and M. V. Jithin Kumar, "Accelerometer based human activities and posture recognition," *Proc. 2016 Int. Conf. Data Min. Adv. Comput. SAPIENCE 2016*, pp. 367–373, Oct. 2016, doi: 10.1109/SAPIENCE.2016.7684120.
- [168] A. Dubois and F. Charpillet, "Human Activities Recognition with RGB-Depth Camera using HMM," 2013, doi: 10.1109/EMBC.2013.6610588i.
- [169] L. Atallah, B. Lo, R. King, and G. Z. Yang, "Sensor positioning for activity recognition using wearable accelerometers," *IEEE Trans. Biomed. Circuits Syst.*, vol. 5, no. 4, pp. 320–329, Aug. 2011, doi: 10.1109/TBCAS.2011.2160540.
- [170] D. Riahi, W. Bouachir, Y. Ouakrim, and N. Mezghani, "Depth imaging system for human posture recognition," *Middle East Conf. Biomed. Eng. MECBME*, vol. 2018-March, pp. 177–181, Jul. 2018, doi: 10.1109/MECBME.2018.8402429.
- [171] K. Adhikari, H. Bouchachia, and H. Nait-Charif, "Activity recognition for indoor fall detection using convolutional neural network," *Proc. 15th IAPR Int. Conf. Mach. Vis. Appl. MVA 2017*, pp. 81–84, Jul. 2017, doi: 10.23919/MVA.2017.7986795.
- [172] M. Yu, L. Gong, and S. Kollias, "Computer vision based fall detection by a convolutional neural network," *ICMI 2017 - Proc. 19th ACM Int. Conf. Multimodal Interact.*, vol. 2017-January, pp. 416–420, Nov. 2017, doi: 10.1145/3136755.3136802.
- [173] E. Kim, S. Helal, and D. Cook, "Human Activity Recognition and Pattern Discovery," *IEEE Pervasive Comput.*, vol. 9, no. 1, p. 48, Jan. 2010, doi: 10.1109/MPRV.2010.7.
- [174] M. H. Kolekar and D. P. Dash, "Hidden Markov Model based human activity recognition using shape and optical flow based features," *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, pp. 393–397, Feb. 2017, doi: 10.1109/TENCON.2016.7848028.
- [175] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," Accessed: Oct. 23, 2021. [Online]. Available: <http://code.google.com/p/cuda-convnet/>.
- [176] W. Rawat and Z. Wang, "Deep convolutional neural networks for image classification: A comprehensive review," *Neural Comput.*, vol. 29, no. 9, pp. 2352–2449, Sep. 2017, doi: 10.1162/NECO_A_00990.
- [177] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," *Proc. 2017 Int. Conf. Eng. Technol. ICET 2017*, vol. 2018-January, pp. 1–6, Mar. 2018, doi: 10.1109/ICENGTECHNOL.2017.8308186.
- [178] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, "Deep Learning for Computer Vision: A Brief Review," *Comput. Intell. Neurosci.*, vol. 2018, 2018, doi:

10.1155/2018/7068349.

- [179] R. Chityala and S. Pudipeddi, "Image Processing and Acquisition using Python," *Image Process. Acquis. using Python*, Jun. 2020, doi: 10.1201/9780429243370.
- [180] I. Goodfellow, Y. Bengio, and A. Courville, "Deep learning," 2016, Accessed: Oct. 23, 2021. [Online]. Available: https://books.google.fr/books?hl=fr&lr=&id=omivDQAAQBAJ&oi=fnd&pg=PR5&dq=Goodfellow,+I.,+Y.+Bengio+et+A.+Courville.+2016,+Deep+Learning,+MIT+Press.+http://www.+deeplearningbook.org.&ots=MNP39unBUY&sig=Mh8_mhxunitS58_RpjMfZbV7Lqc.
- [181] V. Nair and G. E. Hinton, "Rectified Linear Units Improve Restricted Boltzmann Machines," *undefined*, 2010.
- [182] Y. T. Zhou, R. Chellappa, A. Vaid, and B. K. Jenkins, "Image Restoration Using a Neural Network," *IEEE Trans. Acoust.*, vol. 36, no. 7, pp. 1141–1151, 1988, doi: 10.1109/29.1641.
- [183] X. Zhu, L. Yun, F. Cheng, and C. Zhang, "LFN: Based on the convolutional neural network of gait recognition method," *J. Phys. Conf. Ser.*, vol. 1650, no. 3, Oct. 2020, doi: 10.1088/1742-6596/1650/3/032075.
- [184] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Adv. Neural Inf. Process. Syst.*, vol. 25, 2012, Accessed: Oct. 23, 2021. [Online]. Available: <http://code.google.com/p/cuda-convnet/>.
- [185] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition." pp. 770–778, 2016, Accessed: Oct. 23, 2021. [Online]. Available: <http://image-net.org/challenges/LSVRC/2015/>.
- [186] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Dec. 2016, vol. 2016-December, pp. 770–778, doi: 10.1109/CVPR.2016.90.
- [187] O. Russakovsky *et al.*, "ImageNet Large Scale Visual Recognition Challenge," *Int. J. Comput. Vis. 2015 1153*, vol. 115, no. 3, pp. 211–252, Apr. 2015, doi: 10.1007/S11263-015-0816-Y.
- [188] M. Benoit, P. H. Robert, P. Staccini, and P. Brocker, "One-year longitudinal evaluation of neuropsychiatric symptoms in Alzheimer's disease. The REAL.FR Study Personally Assisted Living INRIA View project Programme MobiQual View project," *Artic. J. Nutr. Heal. Aging*, 2005, Accessed: Sep. 30, 2021. [Online]. Available: <https://www.researchgate.net/publication/7945231>.
- [189] M. Crochemore and W. Rytter, "Text algorithms," p. 412pp., 1994, Accessed: Nov. 04, 2021. [Online]. Available: <https://hal-upec-upem.archives-ouvertes.fr/hal-00619796>.
- [190] T. Bozkaya, N. Yazdani, and M. Ozsoyoglu, "Matching and indexing sequences of different lengths," *Int. Conf. Inf. Knowl. Manag. Proc.*, pp. 128–135, 1997, doi: 10.1145/266714.266880.
- [191] B. Rosner, R. J. Glynn, and M. L. T. Lee, "The Wilcoxon Signed Rank Test for Paired Comparisons of Clustered Data," *Biometrics*, vol. 62, no. 1, pp. 185–192, Mar. 2006, doi: 10.1111/J.1541-0420.2005.00389.X.
- [192] M. Basseville and I. Nikiforov, "Detection of abrupt changes: theory and application," 1993, Accessed: Feb. 28, 2022. [Online]. Available: <https://scholar.google.fr/ftp://ftp.irisa.fr/local/as/mb/k11.pdf>.
- [193] H. Sakoe and S. Chiba, "Dynamic Programming Algorithm Optimization for Spoken Word Recognition," *IEEE Trans. Acoust.*, vol. 26, no. 1, pp. 43–49, 1978, doi:

10.1109/TASSP.1978.1163055.

- [194] D. J. Bemdt and J. Clifford, "Using Dynamic Time Warping to Find Patterns in Time Series," 1994, Accessed: Jan. 24, 2022. [Online]. Available: www.aaai.org.
- [195] E. J. Keogh and M. J. Pazzani, "Scaling up dynamic time warping for datamining applications," *Proceeding Sixth ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, pp. 285–289, 2000, doi: 10.1145/347090.347153.
- [196] S. Park, W. W. Chu, J. Yoon, and C. Hsu, "Efficient searches for similar subsequences of different lengths in sequence databases," *Proc. - Int. Conf. Data Eng.*, pp. 23–32, 2000, doi: 10.1109/ICDE.2000.839384.
- [197] L. Etienne, "Motifs spatio-temporels de trajectoires d'objets mobiles, de l'extraction à la détection de comportements inhabituels. Application au trafic maritime.," Dec. 2011, Accessed: Feb. 10, 2022. [Online]. Available: <https://tel.archives-ouvertes.fr/tel-00667953>.
- [198] J. MacQueen, "SOME METHODS FOR CLASSIFICATION AND ANALYSIS OF MULTIVARIATE OBSERVATIONS," 1966, Accessed: Apr. 09, 2022. [Online]. Available: <https://apps.dtic.mil/sti/citations/AD0632526>.
- [199] A. Chaturvedi, K. Foods, P. E. Green, and J. D. Carroll, "K-modes Clustering," *J. Classif.* 2001 181, vol. 18, no. 1, pp. 35–55, Jul. 2014, doi: 10.1007/S00357-001-0004-3.
- [200] D. R. Cox, "Two Further Applications of a Model for Binary Regression," *Biometrika*, vol. 45, no. 3/4, p. 562, Dec. 1958, doi: 10.2307/2333203.
- [201] T. T. Wong, "Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation," *Pattern Recognit.*, vol. 48, no. 9, pp. 2839–2846, Sep. 2015, doi: 10.1016/J.PATCOG.2015.03.009.
- [202] N. Noury and T. Hadidi, "Computer simulation of the activity of the elderly person living independently in a Health Smart Home," *Comput. Methods Programs Biomed.*, vol. 108, no. 3, pp. 1216–1228, Dec. 2012, doi: 10.1016/J.CMPB.2012.07.004.
- [203] S. Wu *et al.*, "Survey on Prediction Algorithms in Smart Homes," *IEEE Internet Things J.*, vol. 4, no. 3, pp. 636–644, Jun. 2017, doi: 10.1109/JIOT.2017.2668061.
- [204] A. Paris, S. Arbaoui, N. Cislo, A. El-Amraoui, and N. Ramdani, "Modélisation du comportement habituel de la personne en smarthome," *jetsan2015.bmbi.utc.fr*, Accessed: Mar. 18, 2022. [Online]. Available: http://jetsan2015.bmbi.utc.fr/files/Publications/paper_7.pdf.
- [205] C. Azefack *et al.*, "Data-Driven Modeling and Simulation of Daily Activity Patterns of Elderlies Living in a Smart Home," *Proc. - Winter Simul. Conf.*, vol. 2019-December, pp. 594–605, Dec. 2019, doi: 10.1109/WSC40007.2019.9004910.
- [206] L. E. Baum, "An Inequality and Associated Maximization Technique in Statistical Estimation for Probabilistic Functions of Markov Processes."
- [207] O. Brdiczka, M. Langet, J. Maisonnasse, and J. L. Crowley, "Detecting human behavior models from multimodal observation in a smart home," *IEEE Trans. Autom. Sci. Eng.*, vol. 6, no. 4, pp. 588–597, Oct. 2009, doi: 10.1109/TASE.2008.2004965.
- [208] P. Chung, C. L.-P. Recognition, and undefined 2008, "A daily behavior enabled hidden Markov model for human behavior understanding," *Elsevier*, vol. 41, pp. 1572–1580, 2008, doi: 10.1016/j.patcog.2007.10.022.
- [209] S. Karaman *et al.*, "Hierarchical Hidden Markov Model in detecting activities of daily living in

- wearable videos for studies of dementia,” *Springer*, vol. 69, no. 3, pp. 743–771, 2014, doi: 10.1007/s11042-012-1117-x.
- [210] C. Zhang, L. Z.-I. J. of S. Home, and undefined 2013, “Activity recognition in smart homes based on second-order hidden markov model,” *gvpress.com*, vol. 7, no. 6, pp. 237–244, 2013, doi: 10.14257/ijsh.2013.7.6.23.
- [211] M. Dong and D. He, “A segmental hidden semi-Markov model (HSMM)-based diagnostics and prognostics framework and methodology,” *Mech. Syst. Signal Process.*, vol. 21, no. 5, pp. 2248–2266, Jul. 2007, doi: 10.1016/J.YMSSP.2006.10.001.
- [212] K. P. Murphy, “Hidden semi-Markov models (HSMMs) 1 Segment models 1.1 Representation,” 2002, Accessed: Dec. 06, 2021. [Online]. Available: www.ai.mit.edu/~murphyk.
- [213] T. Duong, D. Phung, H. Bui, and S. Venkatesh, “Efficient duration and hierarchical modeling for human activity recognition,” *Artif. Intell.*, vol. 173, no. 7–8, pp. 830–856, May 2009, doi: 10.1016/J.ARTINT.2008.12.005.
- [214] S. Lühr, S. Venkatesh, G. West, and H. H. Bui, “Explicit State Duration HMM for Abnormality Detection in Sequences of Human Activity,” *Lect. Notes Artif. Intell. (Subseries Lect. Notes Comput. Sci.)*, vol. 3157, pp. 983–984, 2004, doi: 10.1007/978-3-540-28633-2_125.
- [215] B. Logan and P. Moreno, “Factorial HMMs for acoustic modeling,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, vol. 2, pp. 813–816, 1998, doi: 10.1109/ICASSP.1998.675389.
- [216] M. J. Russell and R. K. Moore, “EXPLICIT MODELLING OF STATE OCCUPANCY IN HIDDEN MARKOV MODELS FOR AUTOMATIC SPEECH RECOGNITION.,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process. - Proc.*, pp. 5–8, 1985, doi: 10.1109/ICASSP.1985.1168477.
- [217] T. Duong, D. Phung, H. Bui, S. V.-A. intelligence, and undefined 2009, “Efficient duration and hierarchical modeling for human activity recognition,” *Elsevier*, Accessed: Dec. 06, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0004370208002142>.
- [218] K. Altun, B. Barshan, and O. Tunçel, “Comparative study on classifying human activities with miniature inertial and magnetic sensors,” *Pattern Recognit.*, vol. 43, no. 10, pp. 3605–3620, Oct. 2010, doi: 10.1016/J.PATCOG.2010.04.019.
- [219] S. Msaad, J.-L. Dillenseger, and G. Carrault, “Interest of the minimum edit distance to detect behaviour change of the elderly person,” 2021, Accessed: Dec. 02, 2021. [Online]. Available: <https://hal.archives-ouvertes.fr/hal-03425499>.
- [220] A. Bosnjak, G. Bevilacqua, G. Passariello, F. Mora, B. Sansó, and G. Carrault, “An approach to intelligent ischaemia monitoring,” *Med. Biol. Eng. Comput.*, vol. 33, no. 6, pp. 749–756, Nov. 1995, doi: 10.1007/BF02523005.
- [221] Y. Shimada, T. Matsumoto, and S. Kawaji, “DEVELOPMENT OF HUMAN DAILY BEHAVIOR MODEL AND IT’S APPLICATION,” *IFAC Proc. Vol.*, vol. 38, no. 1, pp. 36–41, Jan. 2005, doi: 10.3182/20050703-6-CZ-1902.01408.

Titre: Détection de changement de comportement de vie chez la personne âgée par images de profondeur.

Mot clés: Capteur de profondeur, Deep learning, Reconnaissance des activités, Détection de chute, Simulation par chaînes de Markov, Fragilité.

Résumé : Le nombre des personnes âgées ne cesse d'augmenter dans le monde d'où l'enjeu de les aider à continuer de vivre chez eux et de vieillir en bonne santé. Cette thèse s'inscrit dans cette problématique de santé publique et propose la détection du changement de comportement de la personne en se basant sur l'enregistrement des activités au domicile par des capteurs de profondeur à bas coût qui garantissent l'anonymat et qui fonctionnent de façon autonome de jour comme de nuit. Après une étude initiale associant la classification des images par des approches de machine learning, une méthode basée sur les réseaux de neurones profonds ResNet-18 a été proposée pour la détection de la chute et la détection des postures. Cette approche a donné des résultats satisfaisants avec une précision globale de 93,44% et une sensibilité globale de 93,24%. La détection des postures permet de suivre les changements de comportement qui sont synonymes de la perte de la rou-

tine. Deux stratégies ont été déployées pour le suivi du maintien de la routine. La première examine la succession des activités dans la journée en établissant une distance d'édition ou une déformation dynamique de la journée, l'autre consiste à classer la journée en routine et non-routine en associant des approches supervisées (k-moyennes et k-modes), non supervisées (Random Forest) ou les connaissances a priori sur la journée routine de la personne. Ces stratégies ont été évaluées à la fois sur des données réelles enregistrées en EHPAD chez deux personnes fragiles et à la fois sur des données simulées créées pour combler le manque de données réelles. Elles ont montré la possibilité de détecter différents scénarios de changement de comportement (brusque, progressif, récurrent) et prouvent que les capteurs de profondeur peuvent être utilisés en EHPAD ou dans l'habitat d'une personne âgée.

Title: Detection of life behavior change in the elderly by depth images.

Keywords: Depth sensor, Deep learning, Activity recognition, Fall detection, Markov chain simulation, Frailty.

Abstract: Abstract: The number of elderly people in the world is constantly increasing, hence the challenge of helping them to continue to live at home and ageing in good health. This PhD takes part in this public health issue and proposes the detection of the person behavior change based on the recording of activities in the home by low-cost depth sensors that guarantee anonymity and that operate autonomously day and night. After an initial study combining image classification by machine learning approaches, a method based on Resnet-18 deep neural networks was proposed for fall and posture position detection. This approach gave good results with a global accuracy of 93.44% and a global sensitivity of 93.24%. The detection of postures makes possible to follow the state of the person and in particular the behavior changes which

are assumed to be the routine loss. Two strategies were deployed to monitor the routine. The first one examines the succession of activities in the day by computing an edit distance or a dynamic deformation of the day, the other one consists in classifying the day into routine and non-routine by combining supervised (k-means and k-modes), unsupervised (Random Forest) or a priori knowledge about the person's routine. These strategies were evaluated both on real data recorded in EHPAD in two frail people and on simulated data created to fill the lack of real data. They have shown the possibility to detect different behavioral change scenarios (abrupt, progressive, recurrent) and prove that depth sensors can be used in EHPAD or in the home of an elderly person.