

THÈSE / UNIVERSITÉ DE RENNES 1
sous le sceau de l'Université Bretagne Loire

En Cotutelle Internationale avec
La Tunisie

pour le grade de

DOCTEUR DE L'UNIVERSITÉ DE RENNES 1

Mention : Informatique

École doctorale Matisse

Zaineb Liouane

Préparée à l'unité de recherche IRISA – UMR6074
Institut de Recherche en Informatique et Systèmes Aléatoires

**Services e-santé basés
sur la reconnaissance et
la prédiction des
activités quotidiennes
dans les espaces
intelligents**

**Thèse soutenue à Monastir
Thèse soutenue à Monastir
le 30-06-2018**

Devant le jury composé de :

Christine VERDIER

Professeur UGA-LIG / Examinatrice

Rachedi ABDERREZAK

Maître de conférences(HDR) UPEM-LIGM /
Rapporteur

Mohamed Adel ALIMI

Professeur ENIS-REGIM / Rapporteur

Lotfi NABLI

Professeur ENIM-LARATSI / Examineur

Hassani MESSAOUD

Professeur ENIM-LARATSI / Directeur

Frédéric WEIS

Maître de Conférences(HDR) UR1-IRISA /
Directeur

Tayeb LEMLOUMA

Maître de Conférences UR1-IRISA / Co-directeur

Dédicace

À tous ceux qui me sont chers...
Je dédie ce travail et qu'il soit le témoin de ma reconnaissance la plus sincère.

Remerciements

Ce travail de recherche fait l'objet d'une convention en cotutelle entre l'École Nationale d'Ingénieurs de Monastir-Tunisie et l'Université de Rennes1-France. La présente étude a été réalisée au sein du Laboratoire Automatique, Traitement de Signal et Image (LARATSI) du coté Tunisien et à l'Institut de Recherche en Informatique et Systèmes Aléatoires (IRISA) du coté Français.

Je voudrais saisir cette occasion pour exprimer ma gratitude envers mes directeurs de thèse, Monsieur **Hassani Messaoud**, Professeur à l'ENIM-LARATSI et Monsieur **Frédéric Weis**, Maître de conférences (HDR) à l'UR1-IRISA qui m'ont accueilli au sein de leurs équipes de recherche et qui m'ont offert la possibilité d'évoluer dans mes travaux de recherche. Je les remercie pour la confiance et la liberté qu'ils m'ont témoignées durant ces années dans un climat convivial. Je les remercie pour le temps qu'ils m'ont consacré, pour leur encouragement, leur soutien et leur appui. Je remercie vivement mon co-directeur de thèse, Monsieur **Tayeb Lemlouma**, Maître de conférence à l'UR1-IRISA d'avoir assuré la codirection de ce travail, et de m'avoir apporté la rigueur scientifique nécessaire à son bon déroulement, je tiens également à le remercier de sa gentillesse et sa grande disponibilité. Je tiens particulièrement à exprimer mes plus vifs remerciements à Monsieur **Philippe Roose**, Professeur Associé à LIUPPA/T2I-UPPA mon co-encadreur de la thèse pour son aide très précieuse, son soutien et ses qualités humaines.

Je remercie vivement Monsieur **Rachedi Abderrezak**, Maître de conférences (HDR) à l'UPEM/ Laboratoire (LIGM) et Monsieur **Mohamed Adel Alimi**, Professeur à l'ENIS/ Laboratoire (REGIM), d'avoir accepté d'être les rapporteurs de cette thèse. Je leur exprime toute ma gratitude pour l'intérêt qu'ils ont manifesté à l'égard de ce travail et pour leurs appréciations. J'adresse mes remerciements à Madame **Verdier Christine**, Professeur à l'UGA/ Laboratoire (LIG), d'avoir acceptée de participer au jury de thèse comme examinatrice. Je tiens à remercier, Monsieur **Nabli Lotfi**, Professeur à l'ENIM, d'avoir participé à ce jury, en tant que examinateur.

Je remercie tous les membres de l'ENIM, du LARATSI, de l'IRISA et de l'UR1 avec qui j'ai eu le plaisir de travailler. Je suis reconnaissante envers mes amis et mes collègues du laboratoire LARATSI et de l'IRISA pour qui j'ai beaucoup d'amitié et de sympathie. Je les remercie pour leur amicale présence. Je tiens à remercier Madame **Lydie** pour sa sympathie et d'avoir rendu agréables mes séjours à Lannion.

Liste des publications

Journal Papers

Liouane, Z., Lemlouma, T., Roose, P., Weis, F., & Messaoud, H. An improved extreme learning machine model for the prediction of human scenarios in smart homes. *Applied Intelligence*,(2017), 1-14.

Conference Papers

Liouane, Z., Lemlouma, T., Roose, P., Weis, F., & Messaoud, H. An improved elman neural network for daily living activities recognition. In *International Conference on Intelligent Systems Design and Applications*, Springer. 14-16 December 2016, Porto-Portugal,(pp. 697-707).

Liouane, Z., Lemlouma, T., Roose, P., Weis, F., & Messaoud, H. A genetic neural network approach for unusual behavior prediction in smart home. In *International Conference on Intelligent Systems Design and Applications*, Springer. 14-16 December 2016, Porto-Portugal,(pp. 738-748).

Liouane, Z., Lemlouma, T., Roose, P., Weis, F., & Messaoud, H. A Genetic-based Localization Algorithm for Elderly People in Smart Cities. In *Proceedings of the 14th ACM International Symposium on Mobility Management and Wireless Access*. 13 - 17 November 2016,Malta-Malta,(pp. 83-89).

Liouane, Z., Lemlouma, T., Roose, P., Weis, F., & Hassani, M. A Markovian-based approach for daily living activities recognition. In *International Conference on Sensor Networks (SENSORNETS'16)*. 17 - 19 February, 2016,Rome-Italy.

Table des matières

Table des figures	VIII
Liste des tableaux	XI
Acronymes	XIV
Introduction Générale	1
1 Contexte du travail	1
2 Problématiques des surveillances à domicile	1
3 Objectifs	2
4 Contributions	3
4.1 Contribution 1	3
4.2 Contribution 2	4
4.3 Contribution 3	4
I Étude Bibliographique	6
1 Maison intelligente et services e-santé pour les personnes âgées	7
1.1 Introduction	8
1.2 Intelligence ambiante	9
1.2.1 Définition	9
1.2.2 AmI et IA	9
1.3 Vieillesse de la population	12
1.4 Environnement intelligent	13
1.4.1 Maison Intelligente	13
1.4.2 Maisons intelligentes pour la santé	14
1.4.2.1 La couche-maison	16
1.4.2.2 La couche communication	18
1.4.2.3 La couche services	21
1.5 Assistance à l'autonomie à domicile (AAD)	22

1.5.1	AAD basée sur la surveillance de comportement	23
1.5.2	AAD basée sur la détection des chutes	24
1.5.3	AAD basée sur la surveillance de la santé	26
1.6	Reconnaissance du comportement en fonction des connaissances médicales	28
1.6.1	Domaine gériatrique et échelles d'évaluation	28
1.6.2	Les modèles d'évaluation de l'autonomie	29
1.6.2.1	Description du modèle AGGIR	29
1.6.2.2	Description du modèle SMAF	32
1.7	Les fonctionnalités de surveillance	34
1.7.1	Reconnaissance des comportements et des activités quotidiennes	34
1.7.2	Détection des comportements anormaux	36
1.7.3	Prédiction du comportement de l'état de santé	37
1.8	Processus de raisonnement	37
1.9	Les techniques statistiques	38
1.9.1	Modèle de Markov Caché (MMC)	38
1.9.2	Réseau bayésien	39
1.9.3	Modèle de mélange gaussien	39
1.10	Les techniques d'intelligence computationnelle	39
1.10.1	Les réseaux de neurones	40
1.10.2	Support Vector Machines (SVM)	40
1.11	Autres techniques et modèles utilisés dans la reconnaissance du comportement	41
1.12	Conclusion	43
II	Contributions	44
2	Description et reconnaissance des activités quotidiennes des personnes âgées	45
2.1	Introduction	46
2.2	Activités de la vie quotidienne	46
2.3	Approche basée sur les langages naturels	47
2.3.1	La langue naturel	48
2.3.2	Elderly By Room Activities Description Language (EBRADL)	49
2.3.2.1	Objectif de EBRADL	49
2.3.2.2	Champ lexical de EBRADL	50
2.3.2.3	La syntaxe de EBRADL	51
2.3.2.3.1	Contrainte 1 : Endroit - Objet	52

2.3.2.3.2	Contrainte 2 : Endroit - Activité	52
2.3.2.3.3	Contrainte 3 : Activité – Temps	53
2.3.2.3.4	Contrainte 4 : Activité – Habitude	53
2.3.2.3.5	Contrainte 5 : Personne – Profil	54
2.3.2.4	Structure de EBRADL	55
2.4	Modélisation du comportement	57
2.4.1	Modèle de Markov Caché (HMM)	58
2.4.2	Modèle de reconnaissance hybride	59
2.4.2.1	Modèle de markov caché hiérarchique(HHMM)	59
2.4.2.2	Modèle semi-markovien caché (HSMM)	59
2.5	Temporal Hierarchical Hidden Markov Model (THHMM)	60
2.5.1	Principe du THHMM	61
2.5.2	Résultats des simulations	65
2.5.2.1	Reconnaissance du comportement	65
2.5.2.2	Prédiction du Comportement	68
2.6	Évaluations de performance	71
2.7	Conclusion	75
3	Une approche hybride pour l'application et l'évaluation des réseaux de neurones pour les services e-santé	77
3.1	Introduction	78
3.2	Description et présentation des données	78
3.2.1	Description des données	79
3.2.2	Présentation des données	81
3.3	Principe de reconnaissance et de prédiction du comportement	86
3.4	Modèles prédictifs	89
3.4.1	Réseau de neurones artificiels (RNA)	90
3.4.2	Apprentissage par les Algorithmes Évolutionnaires (AE)	92
3.4.2.1	Algorithmes Génétiques (AG)	92
3.4.2.2	Évolution Différentielle (ED)	93
3.5	Nouvelle approche hybride	95
3.5.1	Principe du RNA-AG	95
3.5.2	Principe du RNA-ED	96
3.5.3	Topologie des modèles proposés	96
3.5.3.1	Modèle ELMAN-NN	97
3.5.3.2	Modèle NARX	98
3.6	Mesure des performances	99
3.6.1	Reconnaissance et prédiction du comportement	100
3.6.2	Paramètres de simulation	103
3.6.3	Résultats de l'évaluation	104
3.7	Étude comparative	108

3.8	Conclusion	109
4	Nouveau modèle pour la prédiction et l'identification des comportements anormaux	110
4.1	Introduction	111
4.2	Les lacunes des réseaux de neurones artificiels	111
4.3	Modèle prédictif	112
4.3.1	Modèle ELM	112
4.3.2	Principe du ELM	112
4.4	Nouvelle approche	114
4.4.1	Recurrent Extreme Learning Machine (RELM)	115
4.4.1.1	Description du RELM	115
4.4.1.2	Fonctionnement du RELM	115
4.5	Évaluation des paramètres du modèle RELM	118
4.6	Résultats de simulation	121
4.6.1	Performances du RELM	121
4.6.2	Étude comparative	124
4.7	Système d'aide à la décision	125
4.8	Étude de cas : dépression chez les personnes âgées	125
4.8.1	La dépression	126
4.8.2	La dépression chez les personnes âgées	127
4.8.3	Les symptômes de la dépression chez les personnes âgées	128
4.9	Système d'évaluation du risque de dépression	129
4.9.1	Base de connaissance	130
4.9.1.1	Sélection des ADL-DS	130
4.9.1.2	Les ADL-DS habituel de la personne	131
4.9.2	Évaluation du taux de dépression	135
4.9.3	Prise de décision	142
4.10	Conclusion	144
	Conclusion et Perspectives	146
1.	Conclusion générale	146
2.	Perspectives	149
III	Annexes	151
	Bibliographie	161

Table des figures

1.1	La relation entre l'intelligence ambiante (AmI) et l'Intelligence Artificielle (IA)	11
1.2	Le pourcentage des personnes âgées de plus de 65 ans en 2008 et les prévision en 2040 en Europe.	12
1.3	L'évolution des personnes âgées à l'échelle mondiale	13
1.4	Un aperçu de la structure d'un système de surveillance à domicile.	15
1.5	La structure d'un système de surveillance par couche.	17
1.6	Un aperçu de la couche maison.	18
1.7	Un aperçu de la couche communication.	20
1.8	Un aperçu de la couche service.	22
1.9	Les 3 catégories d'un système de l'autonomie à domicile	24
1.10	Le fonctionnement du modèle AGGIR [1]	30
1.11	Le fonctionnement du modèle SMAF [2]	33
1.12	Les fonctionnalités de la maison intelligente	35
1.13	Processus de reconnaissance et de prédiction	36
2.1	Structure du modèle HHMM	60
2.2	Structure du modèle THHMM	61
2.3	Structure de EBRADL modélisé par THHMM	63
2.4	Processus de reconnaissance et de prédiction par THHMM.	65
2.5	Les états cachés du THHMM au niveau 2.	66
2.6	Observation des états cachés par THHMM au niveau 2.	67
2.7	Comportement de la personne par endroit.	67
2.8	Les états cachés des activités associées à l'état "cuisine" obtenues par THHMM au niveau 3.	69
2.9	Observation des activités associées à l'état "cuisine" obtenues par THHMM au niveau 3	69
2.10	Le comportement de la personne dans la cuisine.	70
2.11	Le comportement prédit et le comportement réel obtenu par THHMM au niveau 2.	70

2.12	Prédiction des activités associées à l'état "cuisine" obtenu par THHMM au niveau 3.	71
2.13	Le temps réel et le temps prédit pour chaque état (Salon, Cuisine, Salle de bain et chambre à coucher) obtenu par THHMM durant une journée.	72
2.14	Le temps réel et le temps prédit pour chaque état ("préparer le repas", "laver la vaisselle" et "utiliser objet") pour n=3.	72
2.15	Erreur de prédiction en fonction du temps.	73
2.16	Erreur de prédiction en fonction de l'état (niveau 2).	74
2.17	Erreur de prédiction en fonction de l'état (niveau3).	74
2.18	Temps de calcul de THHMM pendant différentes périodes.	75
3.1	Étape de prétraitement	83
3.2	les relations entre Qualité de prédiction (QP), Qualité de Service (QS) et Qualité de Vie (QV)	88
3.3	la relation entre les services internes et les services externes dans le cadre d'un système de surveillance.	89
3.4	Structure du modèle ELMAN-NN.	98
3.5	Structure du modèle NARX.	99
3.6	Processus de reconnaissance et de prédiction par RNN-AE.	100
3.7	Scénario de la personne-C1 durant 5 jours	101
3.8	Scénario de la personne-C2 durant 5 jours.	101
3.9	Comportement d'une personne autonome appartenant au profil SMAF <i>P1</i> avec une Personne moins autonome.	102
3.10	Résultats de prédiction des deux modèles NARX-AG et ELMAN-AG concernant la personne de profil SMAF <i>P1</i>	105
3.11	Résultats de prédiction des deux modèles NARX-DE et ELMAN-DE concernant la personne de profil SMAF <i>P1</i>	105
3.12	Résultat de prédiction des deux modèles NARX-AG et ELMAN-AG pour la personne-C2.	106
3.13	Résultat de prédiction des deux modèles NARX-DE et ELMAN-DE pour la personne-C2.	106
4.1	Structure du modèle ELM	113
4.2	Structure du modèle RELM	116
4.3	Processus de prédiction utilisé par RELM	118
4.4	Évaluation du RELM en fonction de RMSE basée sur le nombre de neurones cachés (HNN) et le nombre actuel de neurones récurrent (RNN)	120
4.5	Évaluation du temps d'apprentissage en fonction du nombre HNN	120

4.6	Comparaison des scénarios réels et prévus dans la phase d'apprentissage pendant 6 jours.	122
4.7	Processus de surveillance à domicile	126
4.8	Système de prise de décision pour l'évaluation de risque de dépression	130
4.9	La durée habituelle des activités de la vie quotidienne liées aux symptômes de dépression (DH-ADL-DS).	132
4.10	La fréquence habituelle des activités de la vie quotidienne liée aux symptômes de dépression (FH-ADL-SD).	133
4.11	Variable d'entrée/ activité «Sleeping »	137
4.12	Variable d'entrée/ activité «Eating »	138
4.13	Variable d'entrée/ activité «Reading»	138
4.14	Variable d'entrée/ activité «Watch-TV »	139
4.15	Variable d'entrée/ activité «GO-OUT »	139
4.16	La sortie de notre modèle « Risque de dépression»	140
4.17	Résultats d'évaluation du taux de dépression d'une personne non dépressive	141
4.18	Résultats d'évaluation du taux de dépression d'une personne avec un taux de dépression léger	141
4.19	Résultats d'évaluation du taux de dépression d'une personne avec un taux de dépression grave	142

Liste des tableaux

1.1	Caractéristiques de l’intelligence ambiante dans la littérature. . . .	10
1.2	Les différents types de capteurs utilisés dans la maison intelligente .	19
1.3	Les caractéristiques des technologies sans fil	21
1.4	Les fonctionnalités d’un AAD-SC.	24
1.5	les fonctionnalités d’un AAD-DC.	25
1.6	Les fonctionnalités d’un AAD-SS.	26
1.7	Les exigences des AADs	27
2.1	Les principaux travaux proposés dans la littérature pour la modéli- sation des activités	48
2.2	Les termes de base en fonction de leurs sous-termes.	50
2.3	Les objets par leur endroit.	53
2.4	Les activités de la personne par endroit.	53
2.5	Le niveau de description en fonction de (Age, SMAF profile, Maladies). .	55
2.6	Classification des Activités / Objets/ Slot de temps par endroit. . .	56
2.7	Les abréviations du modèle THHMM par niveau.	64
2.8	RMSE par jour	73
3.1	Les caractéristiques des deux cas proposés dans [3].	80
3.2	Les activités / actions de la vie quotidienne.	82
3.3	Un exemple de données collectées à partir d’une maison intelligente. .	82
3.4	Les paramètres des architectures NARX et ELMAN	104
3.5	RMSE des deux phases d’apprentissage et de validation pour les modèles ELMAN-(AG/ED) et NARX-(AG/ED) pour les deux cas personne autonome et personne avec changement de profile.	107
3.6	Temps d’apprentissage pour les modèles ELMAN-(AG/ED) et NARX- (AG/ED) pour les deux cas Personne autonome et Personne avec changement de profile.	107
3.7	Évaluation de l’RMSE pour les modèles de prédiction hybrides pro- posés : ELMAN-ED/AG, NARX-ED/AG avec les modèles clas- siques : SLFN-BP, ELMAN-BP, NARX-BP, SLFN-AG et SLFN-ED	108

4.1	Évaluation de la prédiction du RELM dans l'étape de test	123
4.2	Évaluation du RELM en fonction du temps d'apprentissage	123
4.3	Évaluation du RELM en fonction du temps de test/validation	123
4.4	Évaluation de l'RMSE pendant la phase d'apprentissage et de validation	124
4.5	Évaluation de temps d'apprentissage et de validation.	125
4.6	Les activités de la vie quotidienne liées aux symptômes de dépression	129
4.7	Durée moyenne maximale et minimale par mois pour chaque ADL-DS	134
8	Définition des paramètres du HHMM	156

Acronymes

3S	Systèmes de Soins de Santé.
AAD	Assistance à l'Autonomie à Domicile.
ACP	Analyse en Composantes Principales.
AE	Algorithmes Evolutionnistes.
AG	Algorithmes Génétiques.
AGGIR	Autonomie Gérontologique-Groupes Iso-Ressources.
AVQ	Activités de la Vie Quotidienne.
BPNN	Back-Propagation Neural Networks .
CARA	Context-Aware Real-time Assistant.
CML	Context Modeling Language.
DT	Decision Tree .
EBRADL	Elderly By Room Activities Description Language.
ECG	Electro-CardioGraphie.
ED	Evolution Différentielle.
EEG	Electro-Encéphalographie.
EI	Environnements Intelligents.
ELM	Extreme Learning Machine .
EMG	Electro-MyoGraphiques.
EOG	Electro-OculoGraphie.
EQM	Erreur Quadratique Moyenne.
ESN	Echo State Network .
FTDNN	Focused Time Delay Neural Networks.
GPS	Système de Positionnement Global.
GSOM	Growing Self-Organizing Maps.
IA	Intelligence Artificielle.
IAm	Intelligence Ambiante.
ICA	Independent Component Analysis.

LSTM	Long Short Term Memory.
LF	Logique Floue .
LR	Logistic Regression.
LRN	Layered Recurrent Neural Network.
MHMC	Modèle Hiérarchique de Markov Caché.
MI	Maisons Intelligentes.
MIS	maisons intelligentes pour la santé.
MMC	Modèles de Markov Cachés.
MMCC	Modèle de Markov Caché Couplé .
MMCCH	Modèle de Markov Caché au Contexte Hiérarchique.
MSMC	Modèle de Semi Markov Caché.
NARX	Non-linear AutoRegressive network with eXogenous.
NBC	Naïve Bayes Classifier.
NFS	Neuro-Fuzzy System.
ORM	Object-Role Modelling.
PM	Périphériques Multimédias.
RB	Réseaux Bayésiens .
RCC	Réseau des Capteurs Corporels.
RCP	Réseau des Capteurs Personnels.
RDF	Resource Description Framework.
RELM	Recurrent Extreme Learning Machine.
RMSE	Root Mean Square Error.
RN	Réseaux Neuronaux.
RNA	Réseaux de Neurones Artificiels.
RNR	Réseaux de Neurones Récurrents.
RNRT	Réseaux de Neurones à Retard de Temps.
RNS	Réseau de Neurones Stables.
SLFN	Single Layer Feedforward Neural Network .
SMAF	Système de Mesure de l'Autonomie Fonctionnelle.
SNF	Système Neuro-Flou.
SRN	Simple Recurrent Network .
SVM	Support Vector Machine.
THHMM	Temporal Hierarchic Hidden Markov Model.
TIC	Technologies de l'Information et de la Communication.
UML	Unified Modelling Language.

Introduction Générale

1 Contexte du travail

L'être humain est en constante évolution, avec l'âge, il acquiert en sagesse mais perd en compétences. Ainsi, les capacités psychologiques et physiques de l'individu se dégradent avec le temps. Par conséquent, une personne âgée reste sensible physiquement et moralement, avec des besoins d'attention particulière, de suivi et surtout de contrôle continu. A ce propos un suivi à long terme de l'état de santé des habitants âgés s'impose.

Ces dernières années, le nombre de personnes âgées a remarquablement augmenté dans le monde entier. Les dernières recherches statistiques sur la population mondiale révèlent une croissance très importante dans la population âgée [4], ce qui entraîne des problèmes de prise en charge vu le nombre limité des places dans les établissements de santé à savoir : les maisons de retraite, les foyers, les unités de soins dans les hôpitaux. Par ailleurs, la plupart, des personnes âgées préfèrent ne pas quitter leurs domicile dans la mesure où ils sentent plus confortable de rester chez elles tout en bénéficiant des moyens de contrôle et de surveillance médicales discrètes et imperceptibles. Ce qui leur assure à la fois le sentiment de sécurité, de respect de la vie privée et d'autonomie.

Cette dernière option laisse penser à l'habitat intelligent et la surveillance à domicile, ce qui permet d'améliorer le mode de vie des séniors en les maintenant dans l'environnement auquel ils sont habitués et en réduisant les coûts des soins médicaux. Ainsi c'est dans le cadre intitulé " Maintien à domicile des personnes âgées et surveillance à distance de leurs états de santé " que s'intègre les travaux objet de ce rapport.

2 Problématiques des surveillances à domicile

Avec l'âge, les personnes deviennent de moins en moins autonomes et par conséquent ils deviennent incapables d'assurer toutes seules certaines activités de

la vie quotidienne. De ce fait, un habitat intelligent est censé être un environnement adéquat qui fournit une surveillance à domicile pour suivre et améliorer de façon décisive la qualité de vie des personnes âgées.

Les réseaux de capteurs ont connu une grande expansion pour les systèmes de communication et les applications de surveillance. Un habitat intelligent est équipé de plusieurs types de capteurs qui peuvent être non invasifs (non portés par l'occupant), non intrusifs (ne dérange pas l'intimité de l'occupant) qui fonctionnent de façon passive (sans avoir besoin de l'intervention de l'occupant) et des capteurs visuels (par image ou par vidéo). Dans ce cadre, nous ne pouvons pas négliger le fait que les capteurs visuels nous permettent de suivre et d'observer le comportement quotidien des personnes en question avec un taux important de précision et de prudence. Toutefois, ces techniques peuvent déranger la vie privée de l'occupant et peuvent être insupportables (sensation d'être sous contrôle tout le temps). De plus, la plupart des patients préfèrent l'utilisation de capteurs non intrusifs pour se sentir plus à l'aise chez eux [5]. En partant de ce principe, un système de surveillance doit être implémenté et géré de façon transparente autant que possible dans le but de garder le maximum d'autonomie à nos seniors. De ce fait, ce travail de recherche tente de trouver une solution efficace, pertinente et fiable pour surveiller les personnes âgées vivant dans leurs propres foyers, de façon autonome et précise, en tenant compte des changements de profil de chaque personne (âge, maladies, niveau d'autonomie, etc).

Dans la suite, nous allons présenter dans un premier temps les objectifs à atteindre ainsi que les contributions proposées dans cette étude, dans le but d'avoir un système de surveillance à domicile performant et adaptable.

3 Objectifs

Les progrès de la technologie des capteurs et leur disponibilité ont permis de mesurer diverses propriétés et activités des habitants dans une maison intelligente. Cependant, l'obtention de connaissances significatives à partir d'une grande quantité d'informations collectées à partir d'un réseau de capteurs n'est pas une tâche simple. En raison de la complexité du comportement des habitants, l'extraction d'informations significatives et la prédiction précise des valeurs représentant les activités futures d'un occupant sont des défis de recherche [6].

L'objectif principal de notre travail de thèse est d'assurer une analyse efficace des données recueillies à partir des capteurs d'occupation dans une maison intelligente. A ce propos, ce travail se base sur la reconnaissance et l'évaluation des

activités quotidiennes d'une personne âgée dans le but d'observer, de prédire et de suivre l'évolution de son état de dépendance, de santé et de détecter par la même occasion, la présence d'une perte ou d'une perturbation de l'autonomie en temps réel.

Afin d'atteindre l'objectif principal de cette recherche, les objectifs suivants sont identifiés :

- Étudier différentes méthodes pour présenter et extraire l'énorme ensemble des données hétérogènes (bas niveau) détectées par les capteurs pour les adapter dans un format approprié, lisible (haut niveau) dans le but de reconnaître et de prédire le comportement de la personne.
- Suivre l'état de santé de l'habitant via son comportement quotidien et selon sa routine.
- Étudier les moyens appropriés d'exploration et de prédiction des comportements dans la maison intelligente pour extraire le modèle comportemental de la personne.
- Proposer un modèle de reconnaissance et de prédiction des activités quotidiennes adaptables à la personne, performant de terme de précision et de rapidité.
- Comparer les performances des différentes techniques de prédiction (les modèles proposés) pour évaluer la technique la plus appropriée pour les données collectées à partir d'un habitat intelligent.
- Examiner les différentes techniques de détection pour évaluer les informations importantes concernant les valeurs aberrantes et tout comportement anormal.
- Évaluer l'état de la santé de la personne à partir de son comportement quotidien, son profil et ses habitudes.

4 Contributions

Les principales contributions de cette thèse sont les suivantes :

4.1 Contribution 1

La première contribution consiste à la valorisation des données provenant des divers capteurs. En effet, la diversité des signaux recueillis et la complexité du comportement de l'occupant rendent l'extraction et l'obtention des informations significatives une tâche sensible et complexe pour le suivi du comportement de l'occupant.

Pour satisfaire cette contribution, nous avons proposé un langage descriptif sensible au contexte pour présenter les données relatives à l'habitat. Afin de simplifier et de bien représenter les données collectées par les capteurs (bas niveau) dans le but d'avoir une reconnaissance pertinente des données relatives aux personnes (haut niveau), nous développons une structuration des activités de la personne simples et significatives. Notre langage est basé sur plusieurs règles et contraintes. C'est un langage consacré à l'explication, l'exposition et la description des activités et du comportement humain. De ce fait pour décrire le comportement de la personne, nous définissons un nouveau langage descriptif intitulé : « Elderly By Room Activities Description Language (EBRADL) », qui permet d'assurer une surveillance basée sur des règles bien définies et précises. Par la suite, nous avons proposé un modèle markovien hybride adapté aux raisonnements de notre langage qui tient compte de la notion hiérarchique et de la notion temporelle, nommée « Temporal Hiérarchic Hidden Markov Model » dans le but de reconnaître et de prédire le comportement de la personne.

4.2 Contribution 2

Pour suivre le comportement et l'autonomie de la personne, une surveillance à long terme doit être de mise. La deuxième contribution consiste à l'élaboration d'un modèle de reconnaissance et de prédiction à long terme vue la sensibilité et la variation du comportement des personnes âgées au cours du temps.

Pour se faire nous avons opté en premier lieu pour les réseaux de neurones artificiels. L'étude approfondie des résultats obtenus nous permet de proposer des modèles de prédiction hybrides basés sur les algorithmes évolutionnaire plus pertinentes que les réseaux de neurones classiques. Pour évaluer et suivre les connaissances dans le but de prédire et modéliser le comportement des personnes âgées, il est nécessaire de gérer leurs scénarios quotidiens. Les données utilisées dans cette partie sont basées sur des données réelles représentant les activités de deux personnes, la première est totalement autonome et la deuxième dispose d'une perte partielle d'autonomie, proposés dans [3].

4.3 Contribution 3

La troisième contribution se résume à la proposition d'un modèle de prédiction en temps réel dans l'objectif d'intervenir à temps lors d'un comportement anormal ou dans le cas échéant. Ce modèle est une forme récurrente du modèle "Extreme Learning Machine (ELM)", dénommé "Recurrent Extreme Learning Machine (RELM)".

Ainsi, à partir des données comportementales et des activités de la vie quotidienne de la personne, le système peut évaluer leur état de santé et peut détecter l'apparition de plusieurs maladies telles qu'Alzheimer, Diabète, Dépression, etc. Dans ce cas, nous nous sommes intéressés à la maladie de la dépression chez les personnes âgées, puisque ils sont classés parmi les personnes les plus susceptibles à cette maladie et vu le danger de cette dernière si aucune mesure ou intervention n'est faite.

Partant de ce principe, un système approfondi de diagnostic de la dépression (taux) basé sur le comportement (les activités quotidiennes de la personne) sera proposé. En effet, une étude de différents symptômes de dépression chez les personnes âgées est effectuée afin d'identifier les activités quotidiennes liées à la dépression pour évaluer le taux de risque de dépression de notre occupant. De ce fait, un modèle de prise de décision basé sur la logique floue est proposé dans le but d'évaluer le taux de dépression et de détecter s'il y a un changement comportemental ou un comportement anormal.

Première partie
Étude Bibliographique

CHAPITRE 1

Maison intelligente et services e-santé pour les
personnes âgées

1.1 Introduction

Les progrès récents des technologies de l'intelligence ambiante, y compris la détection, la communication et la prise de décision, ont entraîné une émergence rapide de l'environnement intelligent. Parmi ces progrès on cite les maisons intelligentes (MI) (Smart Home SH)) et plus spécifiquement les maisons intelligentes pour la santé (MIS) (Health Smart Home (HSH)) qui constituent un système de surveillance de la santé à domicile sensible au contexte dans un environnement intelligent. Le domaine du MIS a suscité un intérêt considérable ces dernières années. En effet, il a émergé comme une solution prometteuse pour résoudre le problème du vieillissement croissant de la population avec la capacité de leur fournir des services de santé en ligne qui correspondent à leur contexte et à leurs besoins réels. A ce propos la surveillance de la santé des personnes âgées vivant seules chez elles, l'évaluation de leurs comportements, de l'état de santé et de leurs autonomies sont nécessaires afin de pouvoir assister et rendre service à ces personnes au moment opportun. Pour ce faire deux phases sont primordiales dans ce contexte. La première consiste à la mesure du degré de l'autonomie de la personne âgée ce qui permet de prendre connaissance de l'état de santé de la personne afin d'en adapter notre système de surveillance d'une part et de former une base de données basées sur l'évolution du niveau d'autonomie d'autre part. La deuxième phase concerne la reconnaissance et la prédiction des scénarios et du comportement de la personne âgée, ce qui aide à fournir des informations relatives à l'évolution du comportement médical en fonction des connaissances obtenues par le modèle de mesure de l'autonomie.

Ce chapitre est organisé comme suit : au début, nous donnons un aperçu sur l'émergence de l'intelligence ambiante et l'intelligence artificielle. Dans la section 1.3 nous mettons en avant statistiquement l'augmentation de la population âgée dans le monde. L'environnement intelligent, les maisons intelligentes et les maisons intelligentes pour la santé sont développés dans la section 1.4. Une étude sur les Systèmes d'Assistance à l'Autonomie à Domicile (AAD) est effectuée dans la section 1.5. Par la suite, dans la section 1.6 nous allons nous concentrer sur la reconnaissance du comportement en fonction des connaissances médicales (les modèles de mesure de l'autonomie). Dans la section 1.7 nous allons étudier les différentes fonctionnalités de surveillance à domicile. En fin nous allons présenter les différents modèles et algorithmes de prédiction et de reconnaissance utilisés dans les systèmes de surveillance à domicile.

1.2 Intelligence ambiante

1.2.1 Définition

L'intelligence ambiante est une discipline émergente qui apporte de l'intelligence à nos environnements quotidiens afin de les rendre sensibles au contexte. Cette thématique de recherche repose sur les progrès des capteurs, des réseaux de capteurs, de l'informatique omniprésente et de l'intelligence artificielle. Elle promet de révolutionner la vie humaine quotidienne en rendant l'environnement flexible et adaptable. L'intelligence ambiante (AmI) traite un nouveau monde où les dispositifs informatiques se propagent partout (ubiquité), ce qui permet à l'être humain d'interagir dans ces environnements de manière intelligente et transparente. Ces environnements doivent être conscients des besoins des personnes, doivent permettre de personnaliser les exigences et de prévoir les comportements.

Un système basé sur l'AmI doit être : *Sensible (S)*, *Réactif (R)*, *Adaptatif (A)*, *Transparent (T)*, *Omniprésent (O)* et *Intelligent (I)*. Le tableau 1.1 résume les différentes caractéristiques de l'intelligence ambiante par rapport à leur définition. À partir de ce tableau, nous pouvons distinguer la différence et la ressemblance de ce domaine (AmI) avec d'autres domaines tels que l'informatique omniprésente, l'informatique ubiquitaire et l'intelligence artificielle. Le fait que les systèmes AmI doivent être sensibles, réactifs et adaptatifs souligne la relation et la dépendance entre l'AmI et l'informatique contextuelle. Ainsi on peut définir un système d'intelligence ambiante comme «un environnement numérique qui, de manière proactive, mais sensible, prend en charge les personnes dans leur vie quotidienne» [7]. Elle a pour objectif de prendre des décisions et faire bénéficier aux utilisateurs des services dans leur environnement en fonction de l'information recueillie en temps réel et des données historiques accumulées [8, 9].

1.2.2 AmI et IA

Les systèmes intelligents ambiants utilisent les technologies opérationnelles que nous avons mentionnées précédemment au niveau de la couche opérationnelle (matériel, systèmes d'exploitation, communications, base de données, etc) et des techniques d'intelligence artificielle dans la couche intelligente (la connaissance, reconnaissance, logique, traitement, etc) comme le montre la figure 1.1. Nous pouvons conclure alors que l'intelligence ambiante et l'intelligence artificielle sont deux domaines indispensables pour développer un environnement intelligent. L'intelligence ambiante s'appuie sur un logiciel intelligent qui prend en charge les personnes dans leur vie quotidienne en les aidant en prenant en compte leur situation [7, 11, 18–20]. En fait, un environnement intelligent s'appuie sur plusieurs concepts

TABLE 1.1 – Caractéristiques de l’intelligence ambiante dans la littérature.

	(S)	(R)	(A)	(T)	(O)	(I)
Une technologie qui rendra notre environnement quotidien plus sensible à notre présence [10].	✓	✓				
Un avenir potentiel dans lequel nous serons entourés d’objets intelligents et dans lesquels l’environnement reconnaîtra la présence de personnes et répondra de manière indétectable [11].	✓	✓		✓	✓	
L’«intelligence ambiante» implique l’intelligence qui nous entoure [12].	✓	✓	✓			
La présence d’un environnement numérique sensible, adaptatif et réceptif à la présence de personnes [13].					✓	✓
Une vision de la vie quotidienne future. Contient l’hypothèse que la technologie intelligente devrait disparaître dans notre environnement pour amener les humains à une vie plus facile [14].		✓		✓	✓	
Un nouveau domaine de recherche pour les systèmes distribués, non intrusifs et intelligents [15].				✓		✓
Dans un environnement AmI, les personnes sont entourées de réseaux d’appareils intelligents intégrés qui peuvent détecter leur état, anticiper et peut-être s’adapter à leurs besoins [16].	✓		✓	✓	✓	✓
Un environnement numérique qui soutient les personnes dans leur vie quotidienne d’une manière non intrusive (Raffler) [17].				✓	✓	

(S) Sensible, (R) Réactive, (A) Adaptatif, (T) Transparent, (O) Omniprésent, (I) Intelligent

et vise à créer des systèmes qui intègrent l’intelligence artificielle avec l’intelligence ambiante et repose sur la disponibilité de services omniprésents / ubiquitaires [21].

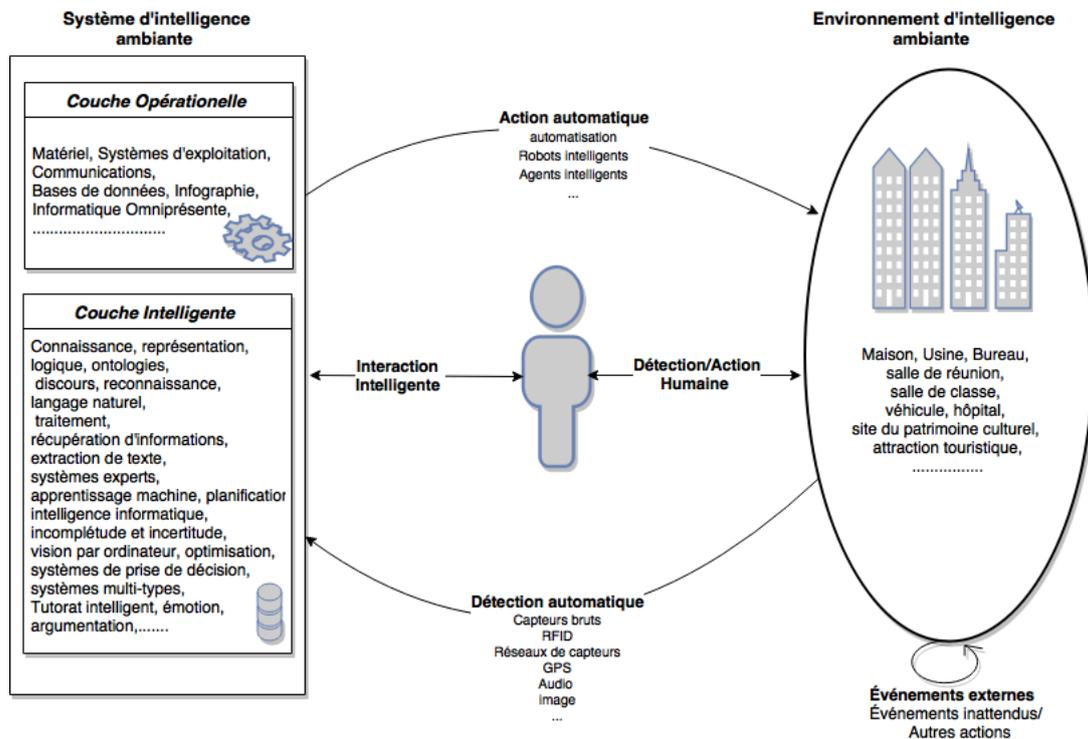


FIGURE 1.1 – La relation entre l'intelligence ambiante (AmI) et l'Intelligence Artificielle (IA)

Par conséquent, l'intelligence ambiante (AmI) est un nouveau domaine dans lequel les personnes sont surveillées par un environnement numérique où leurs activités quotidiennes ainsi que leurs besoins sont analysés par cet environnement [22]. Cela peut être réalisé en utilisant une connexion intelligente adaptative entre des systèmes et des services interconnectés personnalisés. Ainsi, l'omniprésence, l'intelligence et la conscience du contexte sont les principaux domaines informatiques impliqués dans une intelligence ambiante. Cette ubiquité forme une infrastructure omniprésente où l'utilisateur est intégré par un grand nombre de systèmes embarqués interconnectés. Les systèmes intelligents peuvent inclure des algorithmes d'apprentissage et des modèles de reconnaissance, des traducteurs de langues, des classificateurs des gestes et des modèles d'évaluation de la situation. Enfin, la sensibilité au contexte comprend le suivi et le positionnement de tous les objets et la relation entre ces objets et leurs environnements [22, 23].

1.3 Vieillesse de la population

Le pourcentage de la population âgée dans le monde entier augmente constamment au cours des dernières années. La figure 1.2 représente le pourcentage de la population âgée de 65 ans et plus en Europe pour les deux années 2008 et 2040. A partir ce figure on note une augmentation sensible du pourcentage des personnes âgées dans tous les pays de la communauté. De même à l'échelle mondiale, la population âgée augmente comme le montre la figure 1.3. Cette augmentation peut être le résultat des progrès de la technologie, de l'amélioration de la santé publique et de la nutrition, ainsi que de la médecine [24, 25]. L'augmentation de l'espérance de vie, la baisse des taux de natalité et la mortalité infantile continueront d'influencer ce changement significatif de la démographie dans le monde, bien qu'à des degrés et à des rythmes variables [26]. Les personnes de 60 ans et plus représentaient plus de 11,5% de la population mondiale en 2012. D'ici 2050, ce pourcentage devrait doubler pour atteindre 2 milliards.

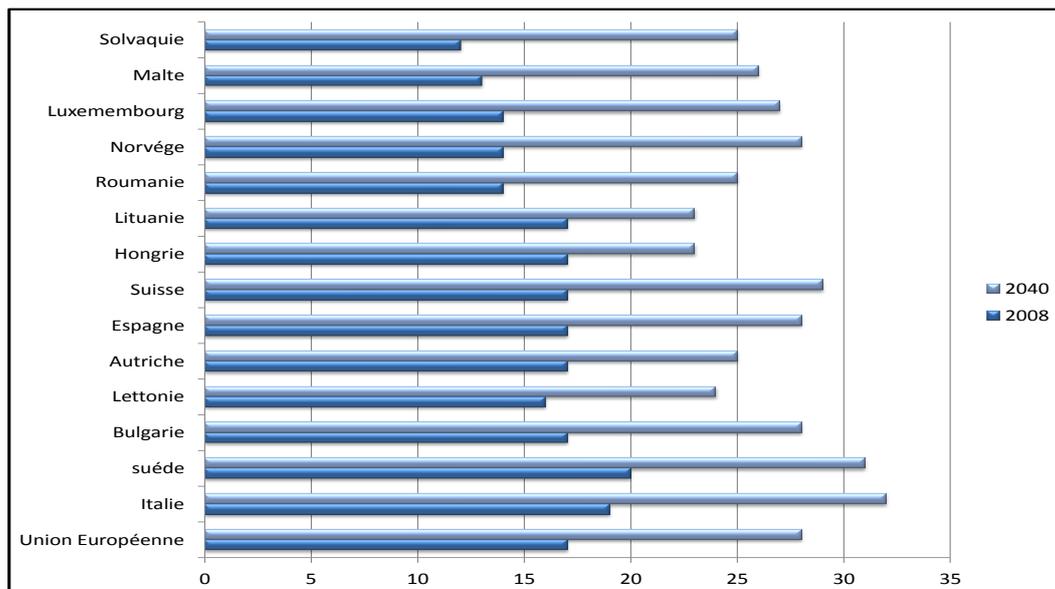


FIGURE 1.2 – Le pourcentage des personnes âgées de plus de 65 ans en 2008 et les prévision en 2040 en Europe.

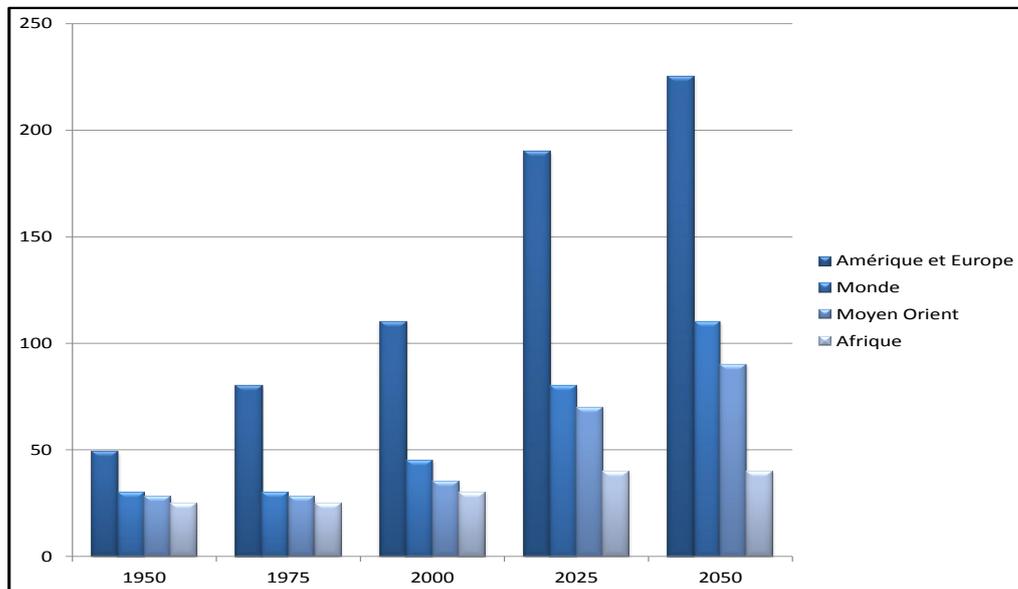


FIGURE 1.3 – L'évolution des personnes âgées à l'échelle mondiale

1.4 Environnement intelligent

Les Environnements Intelligents (EI) (Smart Environment (SE)) sont considérés comme une solution pour faciliter le suivi à long terme des activités et des maladies chroniques des personnes âgées. Ce sont des environnements capables de surveiller leur propre état et l'état de leurs habitants dans le but d'améliorer la vie quotidienne dans cet environnement [27]. Parmi les composantes de cet environnement, on tenons les maisons intelligentes et plus précisément les maisons intelligentes pour la santé.

1.4.1 Maison Intelligente

Le nombre des personnes âgées et handicapées physiques qui ont besoin d'aide dans leurs activités quotidiennes augmente rapidement, comme l'ont révélé les dernières statistiques sur la population mondiale [24]. Ces statistiques montrent une augmentation de population âgée de 65 ans et plus. Cela entraîne une série de problèmes de prise en charge. En outre, le modèle Européen de bien-être n'est pas suffisant pour satisfaire les besoins de la population en croissance et l'augmentation du nombre des fournisseurs de soin n'est pas une solution réaliste. Il est reconnu que l'utilisation de technologies actuelles telles que les environnements intelligents peuvent aider ces personnes. Les maisons intelligentes peuvent améliorer

le mode de vie des personnes âgées, préserver leur vie privée et les laisser vivre dans leur propre maison au lieu de maisons de soins ou d'hôpitaux. Ainsi, les coûts des soins médicaux sont réduits. En fait les environnements domestiques intelligents, et particulièrement les maisons intelligentes [28], sont devenus un sujet de recherche important ces dernières années. Les environnements domestiques intelligents nécessitent des systèmes capables **de détecter, de suivre et de reconnaître** le comportement quotidien des personnes dans leurs espaces. Les aspects suivants peuvent être identifiés par un environnement domestique intelligent [29].

- Le nombre de personnes qui occupent l'environnement,
- L'identité des occupants,
- L'activité physique des occupants,
- La localisation des occupants dans une zone.
- L'état de santé de la personne, etc.

Afin de satisfaire les besoins des occupants des maisons intelligentes et notamment pour assurer une haute qualité de soins, des systèmes de télésurveillance médicale qui reposent sur les techniques domotiques et les techniques de l'intelligence ambiante doivent être déployés [30]. A ce propos, les objets situés à l'intérieur de la maison tels que les appareils électroménagers, les objets domestiques et les systèmes de climatisation, peuvent être équipés de capteurs pour recueillir des informations sur leur utilisation et surveillés à distance [20, 31]. Toutefois la technologie utilisée ne doit pas entraver leur vie quotidienne. Ainsi, tous les appareils devraient fonctionner de manière autonome sans intervention humaine. On parle lors de maison intelligente pour la santé. Il existe de nombreux projets de recherche pour l'aide au maintien à domicile, tels que MavHome [28], DOMUS [32], HOMECARE [33], WISDOM [34], etc. Ils traitent principalement la perte d'autonomie des personnes âgées, développent des services numériques pour la santé et offrant un suivi à long terme.

1.4.2 Maisons intelligentes pour la santé

L'objectif principal des maisons intelligentes pour la santé (MIS) et des systèmes de surveillance des soins de santé (3S) est de fournir un système qui surveille et évalue le comportement quotidien et l'état de santé des personnes, et leur fournit des services de santé en temps réel. Pour atteindre cet objectif, il existe quatre fonctionnalités permettant de développer une maison intelligente pour la santé [35–37] :

- **La sensibilité** : Obtenir les données physiologiques, comportementales et environnementales de l'utilisateur.

- **La communication** : Les sources de données (capteurs) et les actionneurs sont connectés au système de traitement et de raisonnement qui, à son tour, peut être connecté à d'autres systèmes.
- **Le raisonnement** : Traiter et analyser les données issues des capteurs et extraire des connaissances (informations contextuelles). La technologie de raisonnement est la base des environnements intelligents et pourrait être implémentée dans les capteurs, les serveurs, etc.
- **L'action** : Informations, suggestions, conseils, alarme, etc. L'action peut être locale, à distance, soit instantanée (alarme en situation d'urgence) soit retardée (rappel, recommandations).

La figure 1.4 illustre la structure d'un système de surveillance à domicile. Le sys-

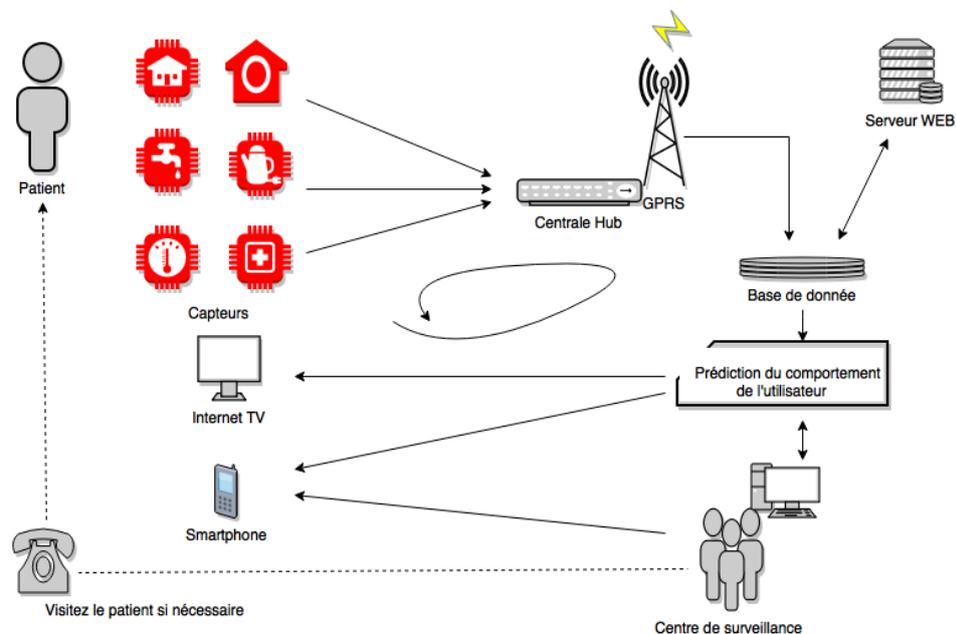


FIGURE 1.4 – Un aperçu de la structure d'un système de surveillance à domicile.

tème d'information organise la circulation des informations relatives au patient, de leur domicile jusqu'au centre de surveillance et inversement. L'acquisition de données est traitée par les différents types de capteurs déployés dans la maison, qui sont soit *des capteurs stationnaires* déployés dans les objets et l'environnement, soit *des capteurs portables* portés par la personne surveillée. Ces deux catégories de capteurs collectent les informations contextuelles de la personne de façon constante ou périodique. Ces capteurs transmettent les données via un point d'accès ou une station de base à un serveur domestique ou à des appareils portables en utilisant différentes technologies de réseaux disponibles. Le serveur domestique ou les pé-

riphériques portables agissent comme une passerelle. La passerelle est un élément commun utilisé dans MIS et 3S est considéré comme le coordinateur de réseau qui fournit un accès et un contrôle à distance et sert de lien entre le réseau local de la maison (Local Area Network (LAN)) et le réseau étendu (Wide Area Network (WAN)) tels que internet, les réseaux téléphoniques cellulaires ou fixes. Au niveau de l'application, les acteurs d'un système de surveillance (médecin, infirmière ou fournisseurs de soins de santé) utilisent une Interface Utilisateur Graphique (GUI). Selon la complexité du système, les interfaces graphiques peuvent être utilisées dans le suivi et l'évaluation de l'autonomie de la personne, et peuvent notifier les alertes aux soignants dans le cas d'une détection des activités anormales ou d'une situation d'urgence. Plusieurs données hétérogènes sont collectées avec plusieurs capteurs qui peuvent être détectés à partir de :

Les données d'environnement : la température, l'humidité, la détection du son, etc.

Les mouvements : les gestes, l'emplacement, etc.

Les signes vitaux : le rythme cardiaque, la saturation en oxygène, la pression sanguine, etc.

Ces données fournissent des connaissances de bas niveau (issues de données brutes) sur le comportement de la personne, son état de santé et son environnement. L'architecture du système, les capacités matérielles (détection, connexions et passerelles) et les méthodes de traitement des données utilisées, tout cela aident le système à obtenir des connaissances et des informations de haut niveau. Dans le cadre d'un système de surveillance à domicile, les connaissances, les informations et les données de haut niveau peuvent être obtenus en plusieurs étapes telles que l'acquisition, la détection, la communication et le traitement des données. La figure 1.5 montre la démarche générale d'un système de surveillance à domicile de la maison jusqu'au centre de surveillance et inversement. Ce système est composé de trois couches de base qui sont *la couche maison, la couche de communication et la couche de services*.

1.4.2.1 La couche-maison

Les systèmes de surveillance de santé doivent avoir une visibilité complète sur le contexte et l'environnement de la personne. L'acquisition des données est la première étape dans les systèmes de surveillance à domicile dans lesquels diverses sources sont utilisées pour collecter les informations relatives à l'état physique de la personne, son comportement, son environnement, ses activités réalisées, etc.

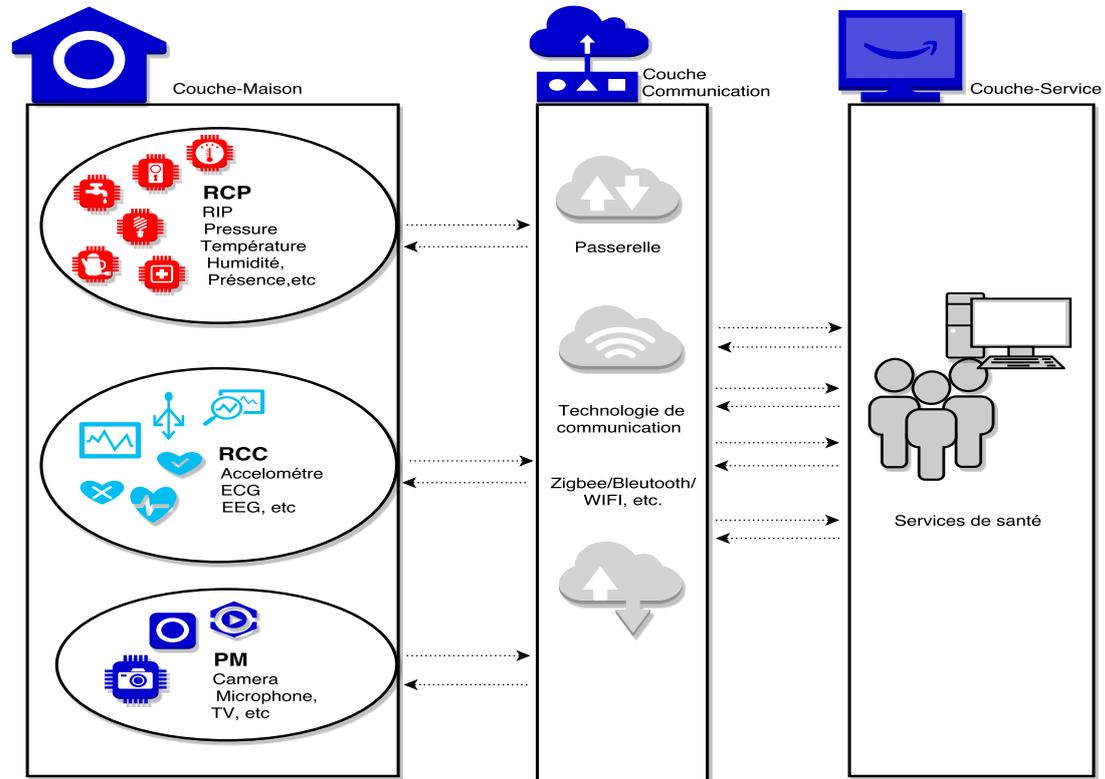


FIGURE 1.5 – La structure d’un système de surveillance par couche.

Dans 3S, les informations contextuelles peuvent être obtenues à l’aide de plusieurs types de sources disponibles pour fournir des données contextuelles pertinentes. De nos jours, les applications et les projets de surveillance de la santé s’appuient sur un ensemble de composants communs et utilisent des capteurs standards et commerciaux pour recueillir les données brutes afin de prendre connaissance de l’individu et de son environnement. A partir de la littérature, nous avons constaté qu’il existe trois classes principales de réseaux souvent utilisés dans les systèmes de surveillances à domicile qui sont : *le réseau des capteurs personnels (RCP)*[38], *le réseau des capteurs corporels (RCC)* [39–44, 44–46] et *les périphériques multimédias (PM)*[47–53]. Les RCP sont utilisés pour détecter les activités quotidiennes et mesurer les conditions de l’environnement de la personne. Les RCC sont utilisés pour surveiller les signes vitaux et l’état de santé en mesurant les paramètres physiologiques et en détectant les activités ambulatoires. Les informations contextuelles liées aux actions humaines sont collectées via *les périphériques multimédias (PM)* pour surveiller les mouvements, les changements environnementaux et pour augmenter l’inter-action entre la personne surveillée et la demande de santé en ligne. La couche maison est représentée dans la Figure 1.6, qui montre le type de

capteurs utilisés dans la maison intelligente, et le Tableau 1.2 décrit les trois catégories de réseaux en fonction du nom des capteurs les plus utilisés dans la maison, leurs fonctions et le type de données détectées.

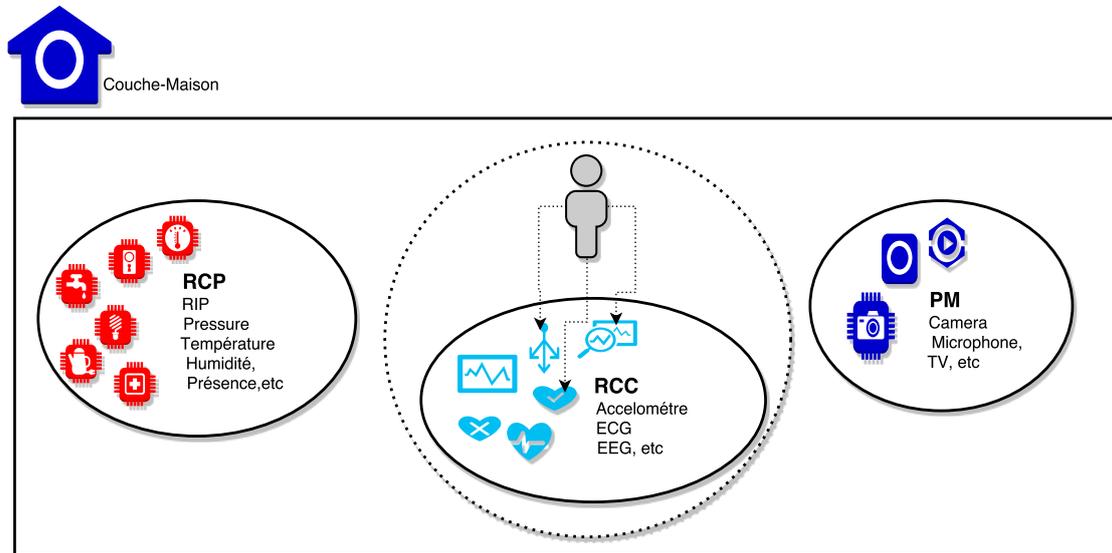


FIGURE 1.6 – Un aperçu de la couche maison.

1.4.2.2 La couche communication

Cette couche est la couche pivot du système constituée de différentes *API* (*Application Programming Interfaces*), de deux passerelles, d'un serveur web, internet, nuage (cloud), station de base, etc. Au début, le stockage en nuage stocke l'historique médical du patient ainsi que les enregistrements actuels des paramètres surveillés. Ce stockage joue un rôle central dans le système de réponse d'urgence et de surveillance hospitalière pour corréliser les données collectées des capteurs aux seuils stockés pour les valeurs paramétriques. Le stockage sur le nuage est essentiel pour analyser une situation d'urgence et déclarer l'état d'urgence du patient. Chaque fois qu'un patient est enregistré dans le système, une API crée le profil pour ce patient. Une autre API peut également être développée pour récupérer l'historique d'un patient qui utilise déjà le système et analyser son rapport médical. Ces API prennent en charge la création de profils, le stockage, les requêtes concernant l'historique du patient et d'autres rapports synchronisés avec l'ensemble du système. La passerelle est l'une des composantes principales utilisées dans les systèmes 3S et MIS. Ses principales fonctionnalités sont l'interconnexion du réseau,

TABLE 1.2 – Les différents types de capteurs utilisés dans la maison intelligente

Catégorie	Nom	Fonction	Type des données
RCP/PSN ¹	PIR	Détection de mouvement	Catégorique
	RFID	Détection de présence	Catégorique
	Pressure	Identification de l'emplacement	Numérique
	Température	Mesure de la température	Série Temporelle
	Humidité	Mesure de l'humidité	Série Temporelle
	Lumière	Détection de la lumière	Série Temporelle
	Énergie	Mesure de l'énergie consommée	Numérique
	Contacte	détection Open/Close	Catégorique
	Ultrasonique	Suivre l'emplacement et la posture	Numérique
RCC/BSN ²	Accéléromètre	Mesurer de l'accélération, la détection de chute, l'emplacement et la posture	Série Temporelle
	Gyroscope	Mesure de l'orientation, détection de mouvement	Série Temporelle
	ECG	Surveiller l'activité cardiaque	Signal analogique
	EEG	Mesure des ondes cérébrales	Signal analogique
	EOG	Surveiller le mouvement des yeux	Signal analogique
	EMG	Surveiller l'activité musculaire	Signal analogique
	Oxymètre de pouls PPG	Mesurer la saturation d'oxygène dans le sang Mesure de fréquence cardiaque et vitesse sanguine	Signal analogique Signal analogique
MD ³	Caméra	Surveillance et suivi	Image, video
	Microphone	Détection vocale	Audio
	Speakers	Alerts and instructions	Audio
	TV	Information visuelle	Audio, video

¹ Réseau de Capteurs Personnels, ² Réseau de Capteurs Corporels , ³ Périphériques Multimédias

une passerelle est responsable de la coordination entre les capteurs hétérogènes et le réseau. La passerelle peut être un appareil mobile comme un smartphone, une tablette ou un nœud de capteur intelligent local placé dans l'environnement. La station de base collecte les valeurs provenant des capteurs environnementaux, puis relaie les données vers la couche 2 (couche communication). Par conséquent, la station de base peut agir comme une passerelle pour le système entre la couche 1 (couche maison) et la couche 2 de l'architecture. L'utilisation de la station de base peut être rentable et mobile si un dispositif intelligent est utilisé en tant que passerelle transportée à tout moment par le patient. Les données des capteurs envoyées par la station de base au stockage en nuage (cloud) sont sous la forme d'un langage de balisage extensible (XML) qui facilite le partage des données. Dans un scénario global de la couche communication d'un 3S, la passerelle ou la station de base relie les données de la maison avec le centre de surveillance avec l'utilisation des technologies de communication tels que la téléphonie, le WiFi, les réseaux cellulaires et les réseaux satellites. Les technologies de réseau disponibles sont combinées pour servir les applications des soins de santé à domicile.

La figure 1.7 présente un aperçu de la couche communication. De nos jours,

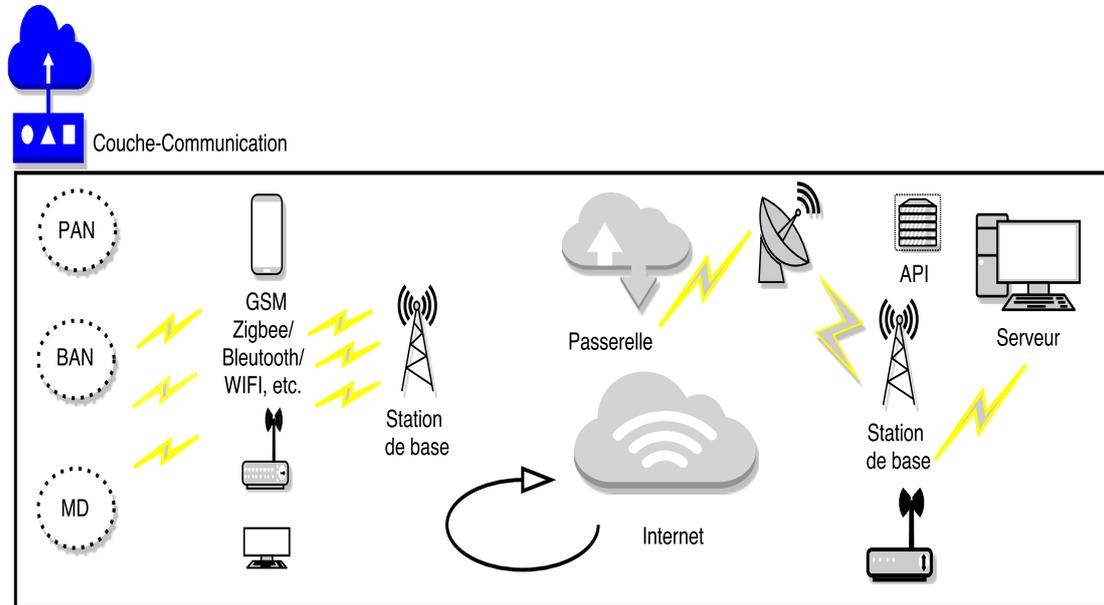


FIGURE 1.7 – Un aperçu de la couche communication.

diverses technologies de communication sans fil sont utilisées pour intégrer les applications de suivi médical et de santé à domicile avec le réseau, ainsi que pour diffuser et transmettre les données à partir des capteurs, les stations de base ou les passerelles afin d'améliorer les services de santé. En fait, chaque technologie sans fil a ses propres critères, définie par ses portées, ses débits et ses fréquences de communications. Il existe différentes catégories de réseaux sans fil ; les WWAN (Wireless Wide Area Networks), les WMAN (Wireless Metropolitan Area Network), les WLAN (Wireless Local Area Network) et les WPAN (Wireless Personal Area Network). Les technologies les plus populaires et les plus utilisées sont les protocoles sans fil à courte portée tels que Zigbee, Bluetooth, et WiFi [54, 55]. D'autres technologies sans fil sont sélectionnées pour des applications spécifiques telles que l'identification et le suivi des personnes et des objets, tels que le RFID, IrDA et UWB. Ces technologies sont utilisées avec des réseaux sans fil à grande échelle tels que la 3G/4G pour fournir des applications et des services avancés et omniprésents de maison intelligente comme par exemple le Wimax, le GSM, l'UTMs, LTE-Advanced, etc. La sélection et l'intégration des technologies de communication sont encore des problèmes ouverts et doivent être abordés dans le contexte des applications de la maison intelligente pour la santé. Fondamentalement, le type de réseau, la fréquence de transmission, le taux de couverture et le taux de données transmises sont les principaux aspects requis dans l'ensemble des

systèmes de surveillance à domicile. Le tableau 1.3 représente les caractéristiques des technologies de communication les plus utilisées dans le cadre d'un système de surveillance pour la santé. De la sorte, la couche communication, qu'on peut

TABLE 1.3 – Les caractéristiques des technologies sans fil

	Type de réseau	Norme IEEE	Génération	Couverture	Fréquence de transmission	Taux de données
Zigbee	PAN	802.15.14		≤10m	868Mhz,915Mhz et 2.5Ghz	20, 40, 250 kbit/s
Bluetooth	PAN	802.15.1		≤10m	868Mhz,915Mhz et 2.5Ghz	20, 40, 250 kbit/s
Wifi	LAN	802.11		≤1km	2.4 à 5 Ghz	11 à 54 Mbit/s
Wimax	MAN	808.16e		≤10km	2 à 66 Ghz	11 à 150 Mbit/s
GSM	WAN		2G	≤10km	85 Ghz à 190 Ghz	9,05 Kbit/s
UTMS	WAN		3G	≤10KM	90 Ghz à 200 Ghz	384 Kbit/s
LTE-ADVANCED	WAN		4G	≤10KM	260 Ghz	1 Gbit/s

aussi nommer couche réseau est l'intermédiaire entre la couche maison et la couche service.

1.4.2.3 La couche services

La troisième couche du système est la couche terminale offrant des services d'externalisation en fonction des données surveillées. Cette couche offre des services de conseil en santé électronique au patient. Ce processus consiste à prescrire des interventions, des médicaments ou à fournir des suggestions au patient en corrélation avec les valeurs des paramètres qui sont reçus par les capteurs. Sur la base des données issues des dossiers médicaux du patient, les services de santé à distance proposent des conseils comparant l'état normal et l'état détecté par les capteurs. Le système d'intervention informe les médecins et les soignants. En fonction du niveau d'urgence, l'équipe d'intervention prend les mesures nécessaires. Fournir des services contextuels est la partie la plus intéressante et la plus complexe dans cette couche. Les deux acteurs principaux qui sont directement impliqués dans les applications 3S sont : *les personnes surveillées* (les patients, les personnes âgées et les personnes handicapées) et *l'équipes de soins de santé* (les médecins, les infirmières et les bénévoles dans la couverture du réseau, famille, voisin, etc). La figure 1.8 montre un aperçu sur la couche service de la maison intelligente. Les applications de surveillance dépendent principalement de l'interaction entre ces deux catégories d'acteurs. Les services fournis sont définis par l'état de l'utilisateur et les services disponibles. Le système de traitements joue un rôle majeur dans ces applications où les données collectées doivent être pertinentes et ensuite elles sont gérées et interprétées. Les actions requises sont déclenchées pour fournir des services appropriés et personnalisés basés sur le contexte. En général, les services fournis par les systèmes de surveillance ont plusieurs définitions et caractéristiques proposées

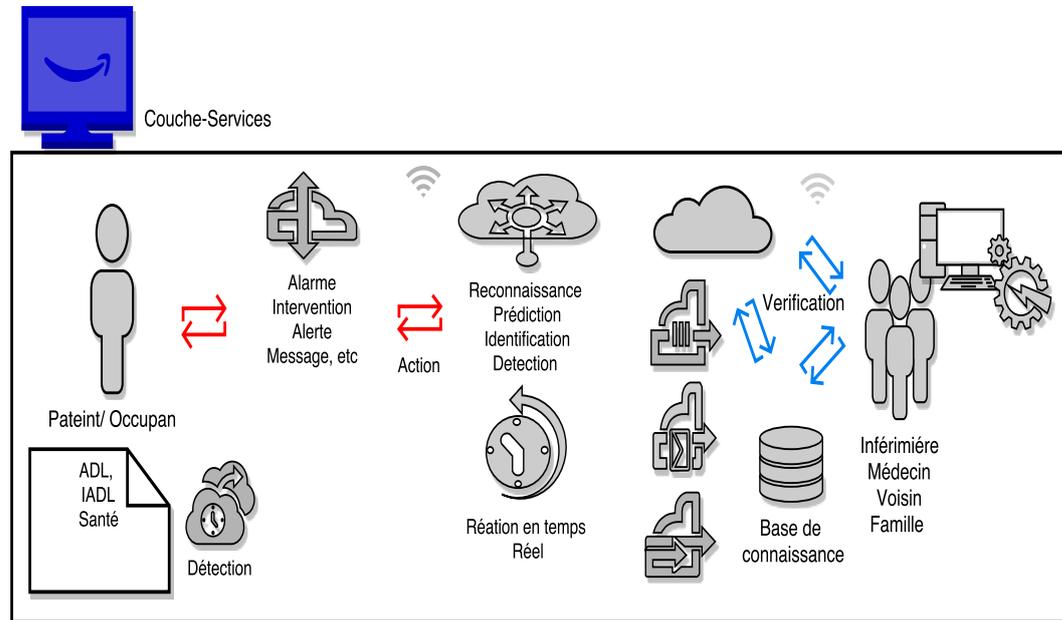


FIGURE 1.8 – Un aperçu de la couche service.

dans plusieurs études [56–59]. De plus, les services de soins fournis aux personnes en perte d'autonomie doivent s'adapter à l'état du patient, pour leur apporter le meilleur service médical. Dans la littérature il existe plusieurs systèmes et applications de surveillance à domicile pour les personnes en perte d'autonomie dans la partie suivante nous allons définir les systèmes et les applications les plus connus dans le domaine de surveillance de l'autonomie à domicile connu sous le nom : Assistance à l'Autonomie à domicile (AAD) (Ambient Assisted Living (AAL)).

1.5 Assistance à l'autonomie à domicile (AAD)

Cette assistance est devenue un sujet de recherche multidisciplinaire, visant à fournir des systèmes et des services logiciels qui aident les gens dépendants dans leurs activités quotidiennes. L'AAD est une initiative visant à prolonger le temps que les personnes âgées peuvent vivre dans leur environnement familial en augmentant leur autonomie et en les aidants à mener à bien leurs activités quotidiennes. Les systèmes AAD exploitent les technologies de l'information et de la communication (TIC) pour reconnaître les activités quotidiennes, surveiller l'autonomie de la personne et améliorer sa qualité de vie. Au cours de ces dernières décennies, de nombreux systèmes et applications ont été développés pour surveiller les personnes âgées et les patients handicapés à leur domicile, tels que, Auto-Dep, CA-

SIS, AICO, BADL Estimation, CARA, Wellness, ANGELAH, ITALH, COSAR, HS-Care, RFID-Track, RFID-behavior, M HMMR, EMUTEM, ETRI, HeartToGo, SPA, Dongle, AlarmNet, etc. Ces applications peuvent être divisées en 3 catégories (figure 1.9) selon la nature de surveillance qui sont :

- *AAD basé sur la surveillance de comportement (AAD-SC) / AAL-behavior monitoring* : Le système surveille et évalue une liste des activités quotidiennes de base, telles que ADL et IADL.
- *AAD basé sur la détection de chute (AAD-DC) / AAL-fall mouvement detection* : Le système peut suivre les activités ambulatoires, y compris les activités dynamiques, les postures statiques, le suivi des emplacements et les systèmes de chutes accidentelles.
- *AAD basé sur la surveillance de la santé (AAD-SS) / AAL-Health monitoring* : Ces systèmes utilisent des applications en temps réel dans le but de surveiller et de diagnostiquer les signes vitaux pour les personnes dépendantes et chroniquement malades telles que les personnes souffrant de diabète, d'hypertension et de maladies cardiovasculaires.

1.5.1 AAD basée sur la surveillance de comportement

AAD-SC représente des systèmes de surveillance de comportement à distance dans le cadre des environnements intelligents. Le système omniprésent et ubiquitaire dans *AAD-SC* peut exploiter des capteurs standards ou des capteurs spécifiques incorporés dans les objets d'usage quotidien tels qu'un lit, un canapé ou une table. La détection des activités quotidiennes et des comportements considérés comme normaux et anormaux de l'utilisateur peuvent être obtenus en fonction de l'interaction de l'utilisateur avec ces objets. Plusieurs systèmes et applications ont été développés pour surveiller et évaluer les activités spatio-temporelles et les activités quotidiennes des personnes dans leurs maisons et pour fournir des services d'assistance appropriés en temps opportun [60–62]. Ces systèmes traitent des divers procédés qui *classent les activités, reconnaissent les habitudes, détectent les comportements, prédisent les conditions de santé à partir de leur comportement, évaluent la dépendance de la personne, extraient les activités anormales et des situations à risque* et notifient automatiquement les soignants en cas d'urgence. Le tableau 1.4 présente quelques projets *AAD-SC* qui existent dans la littérature en fonction de leurs caractéristiques utilisées.

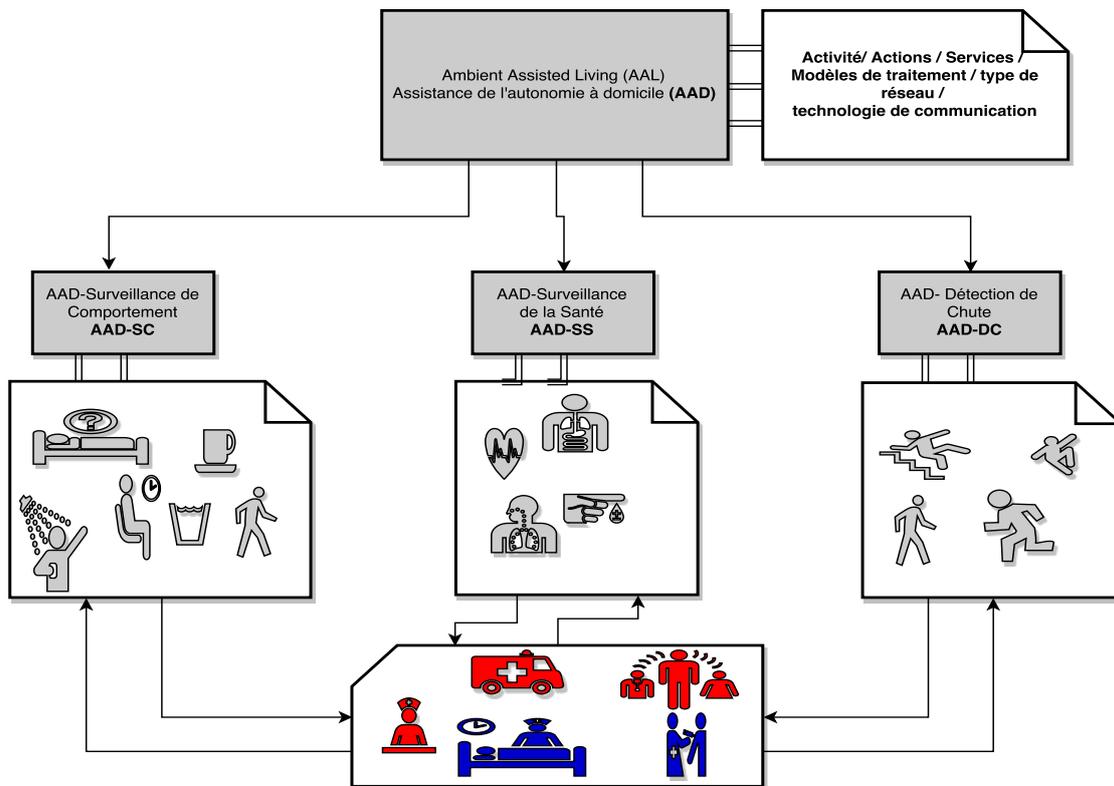


FIGURE 1.9 – Les 3 catégories d'un système de l'autonomie à domicile

TABLE 1.4 – Les fonctionnalités d'un AAD-SC.

Projets AAL-SC	Services	Activités	Actions	Modèles de Traitement	Type des capteurs	Technologie de communication
Auto-Dep [35]	Évaluation de dépendance	ADL, IADL, AMA, FM	Détection	AGGIR	PAN,BAN,MD	Bluetooth, Wi-Fi, Zigbee
CASIS [63]	Rappel	IADL	Détection	Règles	PAN, BAN,MD	
AICO [64]	Reconnaissance de l'emplacement	ADL, AMA	Reconnaissance	Réseau bayésien	PAN,MD	IEEE 802.15.4
BADL estimation [65]	Estimation ADL	ADL	Reconnaissance	Les Règles floue	BAN	Zigbee
CARA [66]	Soin de santé	ADL, IADL	Détection,Prédiction	les règles floues	PAN,BAN,MD	Bluetooth
Wellness [67, 68]	Rapport de bien-être	ADL, IADL	Prédiction	Modèle statistique	PAN	Zigbee

1.5.2 AAD basée sur la détection des chutes

Les chutes accidentelles sont des causes fréquentes de décès. Plusieurs projets ont porté sur la détection des chutes, des mouvements et de la localisation. Dans les systèmes de surveillances à domicile, une détection fiable et immédiate de chute est importante pour fournir des services appropriés. L'objectif principal

des projets et des recherches existants est de fournir des alertes aux soignants en cas d'accident et de permettre un suivi à distance pour faciliter une intervention rapide dans les situations d'urgence. Principalement, les AAD basées sur la détection des chutes visent les activités ambulatoires, y compris les activités dynamiques (p. ex., marche à l'intérieur, à l'extérieur, à la descente, et au jogging), stationnaires (ex. debout, assis et couché) et transitoires (ex. sit-to-stand et stand-to-sit, stand-to-walk), ainsi que le suivi de localisation et les chutes accidentelles. Différents types de systèmes de détection des chutes ont été développés et peuvent être classés en trois catégories, basés sur un dispositif portable, sur un capteur et sur la vision [69]. Les premières mesurent la posture et le mouvement à l'aide de capteurs tels que l'accéléromètre et le gyroscope [70, 71]. Les secondes reposent sur des capteurs tels que les capteurs PIR, les capteurs de pression, ainsi que sur la détection des vibrations au sol et l'analyse audio [72, 73]. Les systèmes basés sur la vision reposent sur des caractéristiques vidéo telles que le mouvement en 3-D, la forme et l'inactivité pour détecter les chutes [74, 75]. Dans [76], les auteurs décrivent une approche de détection des chutes dans un environnement AAD. Ils ont utilisé un tapis intelligent équipé par un ensemble d'étiquettes d'identification par radiofréquence (RFID) pour créer une zone de surveillance discrète et pour détecter les chutes parmi d'autres activités. Dans le travail de Klack et al. [77] plusieurs capteurs et microcontrôleurs sont intégrés dans le sol pour surveiller les mouvements et détecter les chutes. De même, Braun et al. [78] ont introduit un arrangement de capteurs capacitifs sur les tapis pour détecter quelqu'un qui glisse ou tombe sur le sol. Aud et al. [79] ont proposé l'utilisation de foils comme des capteurs pour détecter la présence d'un pied et développer un tapis intelligent. Le tableau 1.5 présente quelques projets AAD-DC qui existent dans la littérature en fonction de leurs caractéristiques utilisés.

TABLE 1.5 – les fonctionnalités d'un AAD-DC.

Projets AAL-DC	Services	Activités	Actions	Modèles de Traitement	Type des capteurs	Technologie de communication
ANGELAH [52]	Détection de chute	AMA	Détection	Raisonnement basé sur la vision, Gaussian Mixture	PAN, MD	Wi-Fi
ITALH [80, 81]	Détection de chute	AMA	Détection	fonction statistique	PAN, MD	Bluetooth, Zig-Bee
COSAR [82]	Reconnaissance basé sur la localisation	AMA	Reconnaissance	MLR et Ontologie	BAN	Bluetooth
HS-Care [83]	Détection de chute	AMA	Détection	Raisonnement basé sur la vision	PAN, MD	IEEE 802.15.4
RFID Track [84]	Suivi de l'emplacement	AMA	Reconnaissance	Algorithme génétique	PAN	RFID
RFID Behavior [85]	Suivi de mouvement, détection de chute	AMA, ADL	Détection	K-means clustering	PAN	RFID
M HMMR [86]	Reconnaissance des activités ambulatoire	AMA	Reconnaissance	HMM	BAN	Bluetooth,

1.5.3 AAD basée sur la surveillance de la santé

Les AAD basées sur la surveillance de santé ont émergé pour la surveillance à distance des activités physiologiques de la personne âgée. Ils acquièrent et transmettent des paramètres importants du signal vital et les transmettent vers le centre de soin de santé qui sont la fréquence cardiaque, la tension artérielle, la saturation artérielle de l’oxygène, la température corporelle et le taux de glycémie afin de fournir immédiatement les services requis. La surveillance continue des signes vitaux est un domaine d’application important. Divers capteurs portables et e-textiles ont été développés à cette fin. Par exemple, AMON est un système de surveillance de la santé portable développé à l’ETH Zurich University [87], HealthBuddy de Bosch [88], TeleStation de Philips [89], HealthGuide de Intel [90] et Genesis de Honeywell [91, 92] sont des exemples de dispositifs de e-santé disponibles dans le commerce. WEALTHY [93], BIOTEX [94] et MagIC [95] sont des exemples de projets d’e-textile. Le projet BIOTEX vise à intégrer des capteurs dans les textiles pour des applications telles que la surveillance endolorie basée sur la détection de changements de pH ou de concentrations de protéines inflammatoires [95]. Healthy Aims [96] est un autre projet qui prévoit de développer une gamme d’implants médicaux pour aider la population vieillissante. Certains chercheurs ont également mis au point d’autres techniques de surveillance de santé non intrusives. Par exemple, Masuda et al. [97] mesurent les fréquences cardiaques et respiratoires en utilisant un matelas rempli d’air et en mesurant les perturbations de la pression de l’air en exploitant les caractéristiques basses fréquences des fréquences cardiaques et respiratoires. De même, Andoh et al. [98] ont développé un matelas de surveillance du sommeil qui analyse la respiration, la fréquence cardiaque, le ronflement et les mouvements du corps. Le projet SELF [99] smart home surveille également la posture, les mouvements du corps, la respiration, l’oxygène dans le sang, le flux d’air dans la bouche et le nez et l’apnée, en utilisant des capteurs de pression, des caméras et des microphones. Le tableau 1.6 présente autres projets AAD-SS existants dans la littérature en fonction de leurs caractéristiques utilisées. À partir

TABLE 1.6 – Les fonctionnalités d’un AAD-SS.

Projets AAL-SS	Services	Activités	Actions	Modèles de Traitement	Type des capteurs	Technologie de communication
EMUTEM [100]	Surveillance de la santé	PHA	Détection	Logique floue	BAN, PAN	ZigBee
ETRI [44, 46]	Surveillance de la santé	PHA	Détection	Ontologie	BAN, PAN	ZigBee, Bluetooth
Heart ToGo [101]	Surveillance de la santé	PHA	Détection	Réseau de neurone artificiel	BAN,	Bluetooth
SPA [102]	Surveillance de la santé	PHA	Détection	Séries temporelle	BAN, PAN	Bluetooth, LAN
Dongle [103]	Surveillance de la santé	PHA	Détection	Méthode statistique	BAN, PAN	IEEE 802.15.4, GSM
Alarm Net [104]	Surveillance de la santé	PHA	Détection	Méthode statistique	BAN, PAN	Wi-Fi

de ces plusieurs études et travaux nous pouvons remarquer un lien solide entre les trois systèmes AAD-SC, AAD-DC et AAD-SS défini ci-dessus. Par conséquent, nous pouvons conclure que ces applications font face aux mêmes exigences telles que la fiabilité, la sécurité, la confidentialité, l'intégrité, l'adaptabilité, etc. Le tableau 1.7 présente quelques exigences défini par des travaux dans la littérature. La plupart de ces exigences seront discutées et traité en profondeur dans le reste de notre thèse.

TABLE 1.7 – Les exigences des AADs

Travaux	Les exigences des AALs
Suzuki et al [105]	Mesure, communication et analyse fiable des données
Rowe et al [106]	La communicabilité, la confidentialité, l'intégrité, la performance, la confidentialité, la fiabilité, la sécurité, la traçabilité
Mairiza et al [107]	La fiabilité, la disponibilité, l'efficacité et la confidentialité
Gresse et al [108]	La fonctionnalité, l'efficacité et la sécurité
Lee et al [109]	Qualité de soins de la santé, Satisfaction des patients
Halperin et al [110]	La convivialité, la fiabilité, l'exactitude des données, le coût, la sécurité et la confidentialité sont les principaux défis pour les systèmes AAL actuels
Fan et al [111]	Personnalisables, adaptatifs et anticipatifs. Ils doivent être non invasifs améliorant l'autonomie / l'indépendance, le confort, la sécurité, la sécurité, personnalisables, capacité d'adaptation, anticipation,
Al Ameen et al [112]	la fiabilité, la sécurité, la performance et la sécurité.
Aghazadeh et al [113]	Capacité de collecter des informations, agrégation, traitement et analyse des données, contrôle automatique
Akter et al [114]	La confiance
M Corchado et al [115]	La convivialité, la sécurité, la fiabilité et la précision.
Aguiar et al [116]	Améliorer la qualité de vie en fonction des besoins de l'utilisateurs, la convivialité et la faisabilité technique des produits.
Third EvAAL [117]	Fournir un cadre adaptatif et contextuel
Rashidi et al [118]	Sécurité et confidentialité

1.6 Reconnaissance du comportement en fonction des connaissances médicales

Pour la reconnaissance, l'identification et la prédiction des activités humaines, une connaissance médicale devrait être considérée afin de valider si le changement du comportement est en corrélation avec les changements d'état de santé de la personne. Les approches de surveillance qui existent dans la littérature ne tiennent pas compte du niveau d'autonomie de la personne âgée, ce qui peut mener à de mauvaises décisions [119]. Ainsi un lien étroit doit être maintenu entre les outils médicaux existants (modèle de mesure de l'autonomie, dossier du patient, historique médicale), d'une part, et les systèmes de surveillance à distance, d'autre part.

1.6.1 Domaine gériatrique et échelles d'évaluation

L'autonomie est définie par la capacité à se gouverner soi-même. Cette notion qui désigne l'indépendance présuppose la capacité de jugement, c'est-à-dire la capacité de prévoir et de choisir, et la liberté de pouvoir agir, accepter ou refuser en fonction de son jugement. Généralement, dans le domaine de la gériatrie, quatre types d'analyse sont utilisés pour évaluer le degré de l'autonomie des personnes âgées [120, 121] : *l'analyse physique*, *l'analyse mentale*, *l'analyse sociale* et *l'analyse fonctionnelle*.

Analyse physique : l'évaluation comprend généralement l'examen physique telles que marcher, bouger, tomber, etc.

Analyse mentale : l'évaluation de la santé mentale comprend une évaluation cognitive, pour déterminer le trouble mental (par exemple, démence ou délire).

Analyse sociale : ces échelles d'évaluation examinent la santé sociale de la personne, telles que les conditions économiques et la disponibilité des ressources de soins de santé (Ex. Soignants, famille et bénévoles).

Analyse fonctionnelle : cet aspect est une partie essentielle de la pratique clinique. La santé fonctionnelle implique la capacité du patient à effectuer les activités de la vie quotidienne (ADL) qui se réfèrent aux routines et aux tâches de base effectuées quotidiennement par les personnes, telles que manger et se laver. et les activités instrumentales de la vie quotidienne (IADL) qui se réfèrent aux tâches requises pour vivre dans une communauté, comme l'utilisation de médicaments et la budgétisation. Fondamentalement, les ADL sont axées sur les personnes les moins autonomes, tandis que les IADL évaluent le handicap plutôt que les per-

sonnes indépendantes.

Les troubles liés au vieillissement entraînent une perte d'indépendance. Une altération du statut de la personne liée à la santé fonctionnelle pourrait être le premier signe d'un processus pathologique. Par conséquent, la compréhension de l'état fonctionnel est un élément important pour les évaluations gériatriques. Dans ce domaine l'état de santé et du bien-être des personnes âgées est mesurés par les méthodes d'évaluation de la dépendance [122]. Dans la partie suivante nous allons nous intéresser à la définition des modèles de mesure de l'autonomie.

1.6.2 Les modèles d'évaluation de l'autonomie

Plusieurs outils d'évaluation ont été développés afin d'évaluer plus facilement le niveau de dépendance des personnes âgées [123]. Ces modèles sont basés sur l'évaluation des activités de base de la vie quotidienne (ADL) introduite par Katz [123] et les activités instrumentales de la vie quotidienne (IADL) de Lawton [61]. Ils sont très utiles dans les systèmes de surveillance de la santé des populations âgées qui souffrent de maladies liées à l'âge telles que les troubles cognitifs et les maladies chroniques, y compris le diabète, les maladies cardiovasculaires, la maladie d'Alzheimer, etc. Les activités quotidiennes et le comportement des personnes âgées sont influencés par leurs états de santé et par leurs maladies. Par exemple, les patients atteints de diabète peuvent avoir des comportements différents dans l'exécution de certaines activités telles que la consommation fréquente de l'eau, de toilette et de sommeil. Par conséquent, être en mesure de détecter les changements des comportements humains aide à identifier le contexte des personnes âgées, à diagnostiquer les maladies et à fournir des services appropriés. En fait, il existe plusieurs modèles de mesure de l'autonomie de la personne proposés dans la littérature tels que, Katz, Barthel, FIM, NPDS, AGGIR et SMAF. Dans ce chapitre nous allons nous concentrer sur l'explication des deux modèles les plus utilisés et les plus populaires dans le domaine de la gériatrie, le modèle SMAF et AGGIR.

1.6.2.1 Description du modèle AGGIR

Le modèle AGGIR (*Autonomie Gérontologique-Groupes Iso-Ressources*) est un modèle d'évaluation de dépendance utilisé en France [1]. Ce modèle utilise un algorithme complexe pour calculer la dépendance de la personne. Ce modèle considère 17 éléments décrivant les activités de la vie quotidienne. La grille AGGIR comporte deux types de variable : les variables discriminantes et les variables illustratives. Seules les dix variables discriminantes résumées dans la figure 1.10 sont utilisées pour la détermination du « groupe iso-ressources » (GIR) de l'individu. Six groupes sont définis, allant de GIR 1 (dépendance totale) à GIR 6 (autonomie

totale). Chaque variable se répartit en trois modalités de codage représentées par A, B et C.

Modalité A : la personne fait seule et spontanément, habituellement, totalement et correctement ;

Modalité B : la personne peut faire seule, mais ne le fait pas spontanément, ou/et correctement ou/et habituellement ou/et partiellement ;

Modalité C : la personne ne fait pas : il faut faire à sa place.

La figure 1.10 représente le principe de fonctionnement du modèle AGGIR. Sept autres variables sont également prises en compte dans l'évaluation à l'aide

VARIABLES DISCRIMINANTES *			A (bon)	B (partiel)	C (non)
1	COHERENCE	Converser et se comporter de façon sensée par rapport aux normes admises	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>
2	ORIENTATION	Se repérer dans le temps (jour et nuit, matin et soir), dans les lieux habituels ...	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>
3	TOILETTE	Faire seul, en entier, habituellement et correctement sa toilette du haut et du bas.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
		Il faut coter la toilette du haut (visage, tronc, membres supérieurs, rasage, coiffage) et du bas (régions intimes, membres inférieurs, pieds) puis de référer à : AA = A CC = C Autres = B	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>
4	HABILLAGE	S'habiller seul, totalement et correctement.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
		Il faut coter l'habillement du haut (bras, tête), du milieu (boutons, ceinture, bretelles..) et du bas (pantalon, chaussettes, bas, chaussures) puis se référer à : AAA = A CCC = C Autres = B	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>
5	ALIMENTATION	S'alimenter seul et correctement.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
		Il faut coter "se servir" (couper la viande, ouvrir un pot, se verser à boire, peler un fruit..) et manger et se référer à : AA = A CC = C BC = C CB = C Autres = B	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>
6	ELIMINATION	Assure seul et correctement l'hygiène de l'élimination urinaire et anale.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
		Il faut coter l'élimination urinaire et anale et se référer à : AA = A CC = C AC ou CA = C BC ou CB = C Autres = B	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>
7	TRANSFERTS	Se lève (du lit, du canapé, du sol), se couche et s'assoit seul	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>
8	DEPLACEMENTS INTERIEURS	Se déplace seul (éventuellement avec canne, déambulateur ou fauteuil roulant)	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>
9	DEPLACEMENTS EXTERIEURS	Dépasse seul le seuil de sa porte	ne modifie pas le GIR		
10	COMMUNICATION A DISTANCE	Utilise les moyens de communication à distance (cris, téléphone, alarme..)	ne modifie pas le GIR		
GIR			6	Reset	

FIGURE 1.10 – Le fonctionnement du modèle AGGIR [1]

du modèle AGGIR. Elles n'interviennent toutefois pas dans le calcul du GIR. Ces variables du modèle AGGIR sont dites illustratives et concernent les activités corporelles, domestiques et sociales :

- Gestion : gérer ses propres affaires, son budget, ses biens ;
- Cuisine : préparer ses repas et les servir ;
- Ménage : effectuer l'ensemble des travaux ménagers ;
- Transport : prendre ou commander un moyen de transport ;
- Achats : acquisition directe ou par correspondance ;
- Suivi du traitement : se conformer à l'ordonnance du médecin ;
- Activités pendant le temps libre : pratiquer des activités sportives, culturelles, sociales, de loisirs ou de passe-temps.

Pour identifier le classement du profil d'une personne, le modèle utilise huit fonctions de classification qui calculent les scores. Plus le score est faible, plus la personne est considérée comme étant fortement dépendante. Le degré d'autonomie sera par la suite déterminé par les six Groupes Iso-Ressources (GIR) tel que :

Le GIR 1 : correspond aux personnes âgées confinées au lit ayant perdu leur autonomie mentale, corporelle, locomotrice et sociale, et qui nécessitent une présence indispensable et continue d'intervenants. Dans ce groupe se trouvent également les personnes en fin de vie ;

Le GIR 2 : regroupe deux catégories :

- Les personnes confinées au lit ou au fauteuil dont les fonctions mentales ne sont pas totalement altérées et qui nécessitent une prise en charge pour la plupart des activités de la vie courante ;
- Celles dont les fonctions mentales sont altérées mais qui ont conservé leurs capacités motrices. Le déplacement à l'intérieur est possible mais la toilette et l'habillage ne sont pas faits ou partiellement.

Le GIR 3 : regroupe les personnes ayant leur autonomie mentale, partiellement leur autonomie locomotrice, mais qui nécessitent quotidiennement et plusieurs fois par jour des aides pour leur autonomie corporelle. La toilette et l'habillage ne sont pas faits ou partiellement. De plus, la majorité d'entre elles n'assument pas seule l'hygiène de l'élimination anale et urinaire.

Le GIR 4 : comprend deux catégories de personnes :

- Les personnes qui peuvent se déplacer à l'intérieur. Elles sont dépendantes pour la toilette et l'habillage.

- Celles n’ayant pas de problèmes locomoteurs, mais elles doivent être aidées pour les activités corporelles et pour les repas.

Le *GIR 5* est composé des personnes autonomes dans leurs déplacements chez elles, s’alimentant et s’habillant seules. Elles peuvent avoir besoin d’une aide ponctuelle pour la toilette, la préparation des repas et le ménage.

Le *GIR 6* regroupe les personnes qui n’ont pas perdu leur autonomie pour les actes discriminants de la vie quotidienne.

1.6.2.2 Description du modèle SMAF

Le système de mesure de l’autonomie fonctionnelle (SMAF) est une échelle de notation clinique utilisée au Canada qui mesure l’autonomie fonctionnelle des patients âgés [2]. Le modèle SMAF est utilisé pour évaluer l’indépendance et l’autonomie des individus en leur fournissant des soins et des services appropriés afin de réduire la perte d’autonomie des personnes âgées [124]. En fait, l’indépendance est la relation entre la perte d’autonomie et les ressources sociales ou matérielles disponibles, prises en compte pour atténuer le taux d’incapacité. La grille d’évaluation SMAF permet d’évaluer 29 activités nommées (items) regroupées en 5 dimensions :

- Activités de la vie quotidienne (ADL) : se compose de 7 items.
- Mobilité : se compose de 6 items.
- Communication : se compose de 3 items.
- Fonctions mentales : se compose de 5 items.
- Activités de la vie quotidienne instrumentales (IADL) : se compose de 8 items.

Comme le modèle AGGIR, le modèle SMAF est géré manuellement par un professionnel de la santé. L’expert utilise toutes les informations disponibles pour effectuer l’évaluation. La dépendance est évaluée en utilisant une échelle de 5 points : 0, -0.5, -1, -2 et -3 pour chacune des cinq dimensions qui sont évalués à l’aide d’un niveau de dépendance avec 0 : indépendant, -0,5 : indépendant mais avec difficulté -1 : besoin de surveillance ou de stimulation, -2 : besoin d’aide, et -3 : dépendant. Dix items de SMAF sont mesurés uniquement en utilisant 4 points (0, -1, -2 et -3), comme par exemple l’urine, l’intestin et la vision. La perte de l’autonomie est définie avec un score négatif maximal de -87. Un score plus élevé indique un niveau de dépendance plus élevé.

Le modèle SMAF inclut 14 profils de modèles de dépendance appelés profils iso-SMAF. En fonction de l’incapacité des groupes, chaque profil associe une quantité spécifique de soins infirmiers, le soutien des services, la supervision né-

cessaire et les coûts des services [125]. La figure 1.11 décrit chaque profil tel qu'il est présenté dans [126] et illustre l'association entre les profils, les scores d'invalidité et la classification des profils iso-SMAF. Le modèle SMAF détermine 14 profils Iso-SMAF de perte d'autonomie regroupés en 5 catégories. Il s'agit d'une classification en groupes homogènes de personnes établi selon les incapacités des personnes et leurs besoins. Les trois premiers groupes (Profils Iso-SMAF 1, 2 et 3) présentent des incapacités aux tâches domestiques seulement. Les Profils 4, 6 et 9 regroupent des individus avec des incapacités motrices progressives et préservation relative des fonctions mentales. Les Profils 5, 7, 8 et 10 décrivent des personnes avec des incapacités surtout mentales avec préservation relative des fonctions motrices. Ces profils s'appliquent surtout aux malades d'Alzheimer. Les Profils 11, 12, 13 et 14 représentent les personnes avec les incapacités les plus importantes. Dans le contexte des services de santé à domicile, les modèles d'évaluation de l'au-

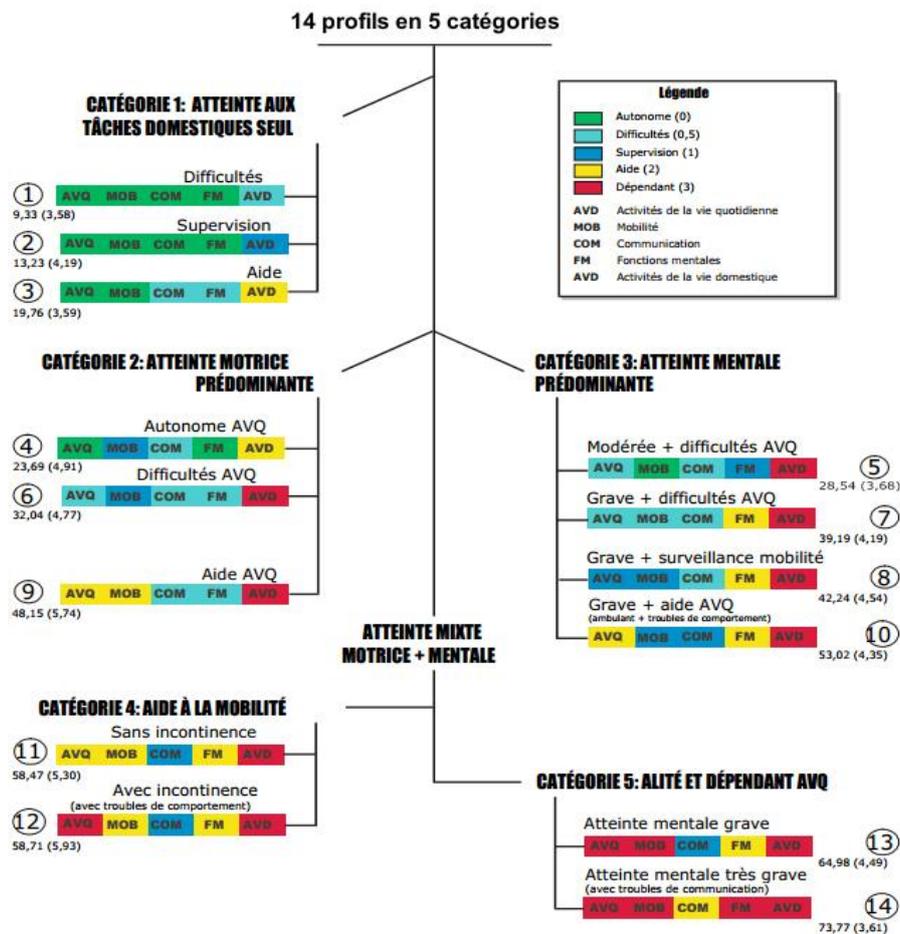


FIGURE 1.11 – Le fonctionnement du modèle SMAF [2]

tonomie servent à guider les professionnels pour prendre les bonnes décisions tout en fournissant des soins de santé adaptables. Dans la partie suivante nous allons nous concentrer sur les fonctionnalités de surveillance dans le cadre d'une maison intelligente pour la santé.

1.7 Les fonctionnalités de surveillance

Un défi majeur dans un système de santé intelligent est de sélectionner les méthodes et les techniques appropriées qui peuvent être en mesure de comprendre le comportement humain complexe et variable dans l'exécution des activités de la vie quotidienne (ADL) [127]. Plusieurs méthodes et recherches ont été menées pour le suivi et l'évaluation des capacités fonctionnelles des sujets et leurs caractéristiques physiologiques et comportementales ar conséquent, la détection des changements liés aux comportements aide à identifier le contexte du sujet, à diagnostiquer les maladies et à fournir des services appropriés. Dans cette partie, nous allons identifier trois fonctionnalités majeures des systèmes de surveillance de la santé qui sont *la reconnaissance des comportements et des activités* [64, 85], *la détection des activités anormales* [35, 128] et *la prédiction* [60, 129]. Ces fonctionnalités (figure 1.12) sont très importantes pour avoir un système aussi précis, efficace et sûr. En effet, une reconnaissance fiable du comportement habituel de la personne, une prédiction sûre et précise du comportement futur et une détection des comportements anormaux en temps réel sont des tâches aussi importantes qui influent directement sur la qualité de service ainsi ces fonctionnalités influent directement sur la qualité de vie fournie par le système.

1.7.1 Reconnaissance des comportements et des activités quotidiennes

La reconnaissance des activités est un processus bien connu dans un 3S qui vise à surveiller et à analyser le comportement des utilisateurs et leurs conditions environnementales pour déduire les activités en cours. La reconnaissance de l'activité est l'un des sujets de recherche les plus prometteurs pour les systèmes de surveillance médicale à domicile. L'objectif principal de la reconnaissance de l'activité est de détecter ou de reconnaître les activités et les comportements habituels de la personne dans sa vie quotidienne [130]. Les principaux défis liés à la nature des activités humaines ont été identifiés dans [130] sont :

- Reconnaître les activités simultanées : effectuer plusieurs activités en même temps.

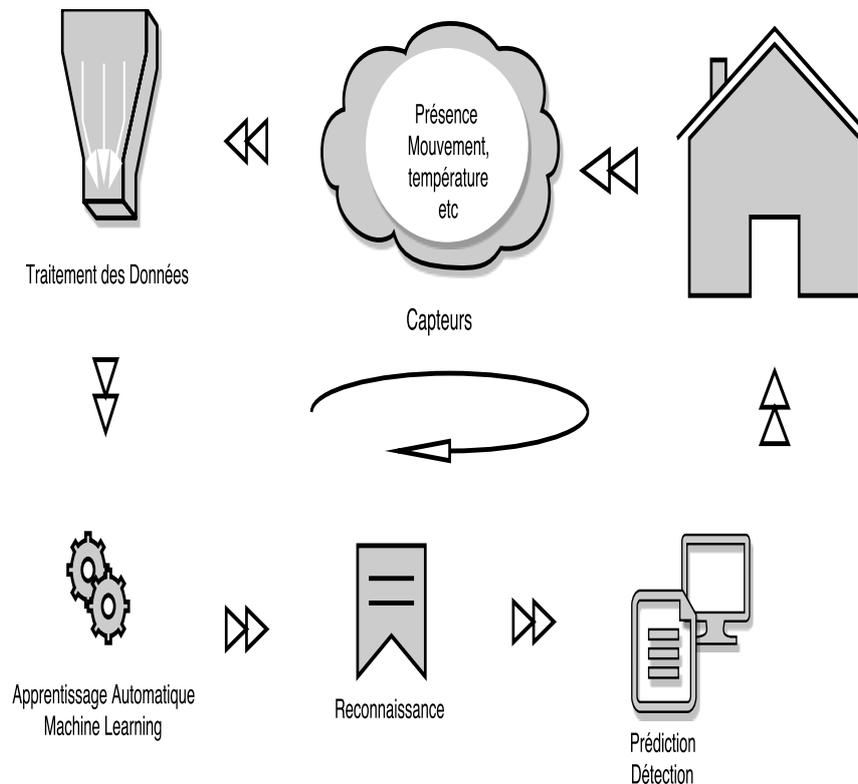


FIGURE 1.12 – Les fonctionnalités de la maison intelligente

- Reconnaître les activités entrelacées : activités qui se chevauchent avec les autres dans la vie réelle.
- L’ambiguïté de l’interprétation : des actions similaires peuvent être interprétées différemment selon le contexte.
- Soutenir plusieurs résidents : reconnaître les activités effectuées en parallèle par les occupants d’un groupe.

De nombreux efforts récents ont été faits sur la reconnaissance du comportement humain. Dans la littérature, différentes approches, méthodes et algorithmes ont été proposés et améliorés. Généralement, le champ de reconnaissance d’activité comprend de nombreux sujets différents tels que *la modélisation d’activité, le comportement, la surveillance de l’environnement, le traitement des données et la reconnaissance des formes*. Par conséquent, dans la pratique, *la reconnaissance des activités* peut être caractérisée par les quatre tâches de base suivantes : l’utilisation des capteurs appropriés dans l’environnement du résident pour surveiller et capturer le comportement ainsi que les changements de l’environnement, la collecte et le traitement de l’information perçue par l’agrégation et la fusion afin d’extraire des abstractions de haut niveau, la conception d’un modèle informatique d’activités

de manière à permettre aux systèmes et aux agents logiciels de mener des raisonnements et des manipulations, et la conception de méthodes et d’algorithmes pour prédire précisément les activités futures. La figure 1.13 présente la démarche d’un processus de reconnaissance et de prédiction.

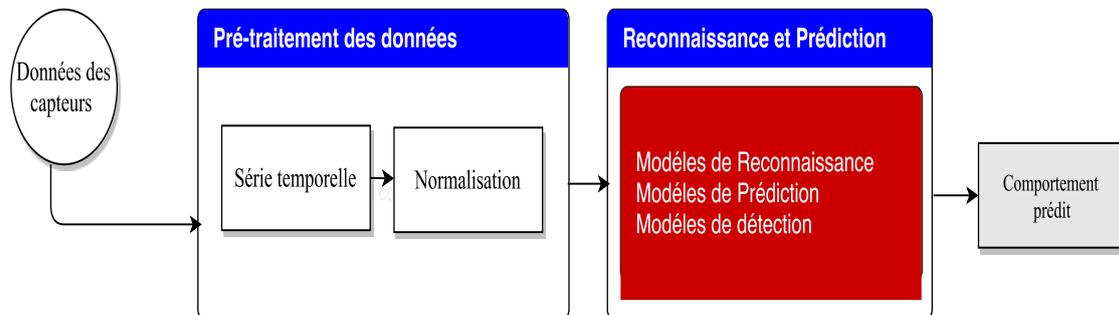


FIGURE 1.13 – Processus de reconnaissance et de prédiction

1.7.2 Détection des comportements anormaux

Détecter les changements et les perturbations du comportement humain à partir de leur comportement quotidien (les activités quotidiennes) est une autre tâche importante et difficile à réaliser. La détection des activités anormales, également appelée anomalies, est un sujet largement étudié qui a été appliqué dans plusieurs domaines d’application. Généralement, la définition de la détection des activités anormales se réfère à la recherche d’un modèle dans les données qui ne sont pas conformes au comportement normal ou prévu et les modèles non conformes sont souvent appelés anomalies ou valeurs aberrantes [131]. La détection d’anomalie est un processus complexe qui nécessite l’apprentissage des comportements normaux, puis la définition des hypothèses afin de distinguer entre un comportement normal et anormal. Ce processus est fortement influencé par les méthodes appliquées pour effectuer la détection, le choix des capteurs et l’extraction des caractéristiques. Les auteurs de [132] ont identifié les défis généraux auxquels sont confrontés les processus de détection des comportements anormaux par exemple :

- Par sa nature, les comportements humains sont irréguliers et changent constamment. Ainsi, un comportement normal actuel peut ne pas apparaître de manière similaire à l’avenir.
- Les comportements anormaux varient en fonction de la nature de la personne et du domaine d’application. Par exemple, certains signes comportementaux et vitaux peuvent être classés comme étant normal pour des personnes et anormal pour d’autres.

- Les méthodes appropriées utilisées dans la détection des comportements anormaux nécessitent d'apprendre tout sur la routine de la personne, ce qui est habituellement un problème majeur.
- Les données provenant des capteurs sont souvent incomplètes ou contiennent des bruits qui, dans certains cas, tendent à être similaires aux anomalies réelles, cela augmente la difficulté de la précision. Par conséquent, d'autres processus antérieurs sont nécessaires pour nettoyer les données, éliminer les valeurs manquantes et éliminer les valeurs aberrantes.

1.7.3 Prédiction du comportement de l'état de santé

Comme mentionné précédemment, l'interprétation des données du capteur permet de mieux comprendre le contexte de la personne. La connaissance acquise du contexte est utile pour évaluer l'état de santé des sujets en fonction de leur état actuel ou pour détecter les activités anormales dans des situations en cours. Afin de compléter ces fonctionnalités, il est important d'utiliser des données situationnelles à long terme pour prévoir les conditions de santé futures à l'avance et prendre les dispositions nécessaires de manière proactive. L'application de méthodes prédictives représente une autre tâche importante utilisée dans le 3S pour prédire l'évolution de l'état de santé de la personne. Cela peut être réalisé en fonction des données historiques disponibles du profil de la personne, y compris l'évaluation de la santé, la routine, l'état de la santé, etc. En fait, les méthodes et les modèles de prédiction et d'analyse permettent de fournir des connaissances plus approfondies sur l'évolution de la santé de l'utilisateur et d'avoir la possibilité d'informer les soignants s'il existe une probabilité de changement médicale ou de changement comportementale. Les modèles prédictions sont utiles pour automatiser l'apprentissage du comportement régulièrement et pour prévoir les activités anormales, les cas d'urgences et le changement comportemental à l'avance.

1.8 Processus de raisonnement

Dans un système intelligent il est impératif d'identifier les méthodes et les algorithmes appropriés qui peuvent interpréter efficacement les données détectées (*bas niveau*) et de créer de nouvelles abstractions (*haut niveau*) afin de comprendre le comportement complexe de la personne. La reconnaissance et le raisonnement comportemental, vise à déduire une nouvelle connaissance basée sur les données contextuelles disponibles [133]. Le raisonnement contextuel peut être composé de trois phases [134]

La phase de pré-traitement vise à traiter les valeurs manquantes, en nettoyant

les données collectées et en éliminant les valeurs aberrantes.

La fusion de données vise à intégrer des données à partir de sources multiples pour produire une vision plus complète et plus précise.

Le raisonnement du comportement a pour objet de générer le contexte réel du sujet en fonction des données du capteur en utilisant plusieurs modèles d'apprentissage et mécanismes de raisonnement, de reconnaissance et de la prédiction.

En fait, il existe plusieurs types de modèles et d'algorithmes de prédiction proposées dans la littérature pour prédire et reconnaître le comportement des personnes. L'adoption de ces modèles a un impact décisif sur l'exactitude des résultats finaux. C'est la phase la plus indispensable de la réussite du système de surveillance. Dans la partie suivante, nous introduisons brièvement les méthodes et les techniques largement utilisées pour reconnaître les comportements humains, détecter les situations normales et anormales et prédire les conditions de santé futures.

1.9 Les techniques statistiques

1.9.1 Modèle de Markov Caché (MMC)

MMC est une technique statistique où le système utilise un processus de Markov avec des paramètres cachés (inconnus). Il désigne un certain nombre d'états cachés et d'observations utilisées pour modéliser un comportement donné. Les états cachés représentent les activités et les données du capteur représentent la sortie observable. Un MMC est défini par des matrices qui représentent les états et les probabilités d'observations. Les matrices de transition d'état décrivent la probabilité que le processus passe dans un nouvel état. Le HMM et ses extensions, telles que le Modèle de Markov Caché Couplé (CHMM) [135], Modèle de Markov caché hiérarchique HHMM [136, 137], Modèle de Markov caché au contexte hiérarchique (HCHMM) [138] et Modèle de Semi-Markov caché (S-HSMM) [139] ont été utilisés dans plusieurs fonctionnalités, y compris la reconnaissance des activités quotidiennes [135, 140, 141], la détection des anomalies [60, 138, 139] et la prédiction du comportement [137, 142, 143]. Le principal inconvénient de modèle HMM de base est le manque de hiérarchie dans la représentation du comportement humain [86]. Ce problème peut être résolu en utilisant le Modèle hiérarchique de Markov caché (HHMM) [104, 136, 137]. Le modèle HMM rencontre plusieurs difficultés dans le traitement de grandes données sensorielles de bas niveau (c'est-à-dire des données complexes temporelles provenant de différentes échelles de temps) [144]. En outre,

l'utilisation de HMM comme modèle de prédiction de séries temporelles nécessite un grand nombre de séquences temporelles.

1.9.2 Réseau bayésien

Les réseaux bayésiens (Bayesian Network BN) sont des outils statistiques qui fournissent un cadre plus général pour modéliser le comportement humain. Le problème principal des réseaux bayésiens est que le raisonnement probabiliste exact est intraitable [145]. Il existe plusieurs exemples d'utilisation de réseaux bayésiens pour la modélisation du comportement, le suivi et la détection des activités humaines [146–148]. Le classificateur Naïve Bayes (Naïve Bayes classifier NBC) représente les classificateurs probabilistes les plus simples possibles, basés sur le théorème de Bayes afin d'effectuer un raisonnement bayésien. Il a été utilisé avec des résultats prometteurs pour la reconnaissance d'activité dans [149, 150]. Cependant, le classificateur BN a besoin de grandes quantités de données pour fournir une bonne précision de reconnaissance. De plus, il ne modélise pas explicitement les informations temporelles, ce qui est généralement considéré comme étant important pour la reconnaissance de l'activité dans un espace intelligent. Contrairement à l'étude menée dans [151], une étude systématique a été menée dans [152] afin de comparer la performance de trois modèles de reconnaissance d'activité : modèle NBC, HMM et champs markoviens conditionnels (Conditional random fields (CRF)). Ils ont évalué ces modèles en utilisant l'ensemble de données combiné à partir du projet de maison intelligente CASAS pour reconnaître 11 activités de la vie quotidienne. Ces activités ont été analysées en utilisant des ensembles de données d'événements de capteurs collectés auprès de sept bancs d'essai physiques.

1.9.3 Modèle de mélange gaussien

Le modèle de mélange gaussien (Gaussian Mixture Model GMM) est un autre modèle probabiliste qui a été étudié dans la littérature pour apprendre le comportement normal dans l'exécution d'activités ADL et la détection d'anomalies dans un espace intelligent. GMM a été utilisé avec un raisonnement fondé sur des règles dans [153] et avec un raisonnement basé sur la vision dans [52] afin d'apprendre le comportement normal et de détecter des situations anormales.

1.10 Les techniques d'intelligence computationnelle

Les techniques d'intelligence computationnelle ont été largement utilisées dans la littérature comme une alternative aux méthodes statistiques. Ces techniques,

telles que les réseaux de neurones, les machines à vecteurs de soutien (SVM), l'exploration de données, l'arbre de décision et les systèmes flous, ont été utilisées pour reconnaître les activités, identifier les comportements normaux et anormaux et prédire le comportement humain et les conditions de santé.

1.10.1 Les réseaux de neurones

Les Réseaux de Neurones Artificiels (RNA) ont été largement utilisées dans les systèmes de surveillance de soins de santé à domicile. Un système de surveillance de la santé structurale basé sur les RNAs a été proposé dans [154]. Les résultats de simulation montrent une plus grande précision dans le traitement des données avec RNA par rapport à d'autres algorithmes de classification, y compris Support Vector Machine (SVM), Decision Tree (DT) et Logistic Regression (LR). Les RNAs ont également été utilisées pour détecter des modèles anormaux dans les signes vitaux détecté avec BSN [40], fournir un diagnostic pour la surveillance de la santé à domicile [155], et reconnaître les activités d'ambulation ainsi que les transitions entre les activités [156]. Le moteur de modélisation prédictive, proposé dans [157], a appliqué une extraction des données ADL à l'aide du RNA. Les auteurs de [158] ont utilisé le MLP (multilayer perceptron) comme technique de prédiction pour prédire le prochain mouvement de la personne. Les auteurs de [159] ont appliqué différents algorithmes d'apprentissage pour reconnaître les catégories d'âge et détecter les changements de l'état médical de l'individu en fonction des modèles de données de marche. Les algorithmes utilisés sont MLP, arbre de décision, support vectorial classifieur, Naive Bayes et Bayesnet. Dans leurs résultats expérimentaux, MLP a donné la plus grande précision dans la classification des catégories. Un système de réseau neuronal utilisé pour détecter l'activité de la personne a été discuté dans [160]. Les auteurs ont introduit une nouvelle couche qui aide à différencier les comportements normaux et anormaux en fonction des fréquences d'ADL.

1.10.2 Support Vector Machines (SVM)

Les SVM ont été largement utilisées pour la reconnaissance et la classification des modèles telles que la reconnaissance des activités ambulatoires et la détection des chutes [128, 142], la reconnaissance et la classification des ADL [161] et les situations d'apprentissage [127]. Dans [162], le modèle SVM a été utilisée avec HMM pour détecter les anomalies dans un comportement des personnes âgées où HMM a été appliqué pour former les ADL normales et ensuite, SVM a été utilisé pour classifier le comportement normal et anormal. Les auteurs de [163] ont appliqué le modèle SVM pour construire un modèle de classification de comportement et pour apprendre les habitudes d'utilisation liées à ADL dans le but de prédire et

d'identifier le comportement de l'occupant. Le modèle a réussi de prédire les activités quotidiennes de la maison telles que le toilettage, l'alimentation, le sommeil et le petit-déjeuner. Les résultats ont été limités à un ensemble réduit d'activités qui ont été réalisées uniquement au début de la matinée.

1.11 Autres techniques et modèles utilisés dans la reconnaissance du comportement

Les défis associés à la modélisation des séries chronologiques sont le manque de connaissances préalables, niveau de bruit élevé, la non-linéarité et non stationnaire. Une variété de techniques ont été proposées dans la littérature, étudiées et appliquées avec succès à la prédiction des séries chronologiques. Il existe plusieurs techniques qui peuvent être utilisées pour traiter les différents problèmes et la complexité d'un 3S contextuel. Par conséquent, ce qui a émergé dans la littérature est que la combinaison de ces modèles est une meilleure solution qui fournit une image complète du contexte de la personne dans un espace intelligent. Nous pouvons citer le modèle sensible au contexte proposé dans [60] utilisé pour la détection des changements, l'apprentissage par machine et des méthodes statistiques. Le modèle a utilisé une approche basée sur HMM pour détecter des anomalies dans une séquence d'activités quotidiennes. En outre, un processus statistique a été utilisé pour identifier l'irrégularité dans les comportements de routine (c.-à-d. Le changement de routine quotidienne) et un lissage exponentiel simple (en utilisant la méthode de tendance de liner Holt) a été utilisé pour prédire et détecter les changements dans les signes vitaux. Les résultats de ces techniques ont été combinés à un modèle à base de règles floues pour prendre la décision finale. Cependant, le problème principal avec ce système proposé est le coût de calcul élevé requis. L'utilisation d'une énorme quantité de données calculées avec HMM et une seule règle floue pour détecter les anomalies peut être inefficace. Différentes combinaisons de réseaux neuronaux artificiels (RNA) ont été utilisées afin d'apprendre les activités des occupants dans la maison intelligente. Par exemple, dans Zheng et al. [164], les auteurs utilisent un réseau neuronal auto-adaptatif basé sur Growing-Self Organizing Maps (GSOM) comme un algorithme d'apprentissage. Dans [164], le travail a présenté une approche d'exploration de données basée sur GSOM pour l'analyse par grappes des activités humaines dans l'environnement domestique intelligent. Hussein et al. [165] utilisent deux types de réseaux neuronaux (NN) : les réseaux neuronaux Feed-Forward et les réseaux neuronaux récurrents (RNN) afin d'aider les personnes handicapées dans leur vie quotidienne. Le travail a confirmé l'importance du NN dans la prédiction des activités dans une maison intelligente. En outre, les résultats des tests de NN ont montré que les données virtuelles sont

proches des données réelles avec les RNN. Fran et al. [166] utilisent un réseau de neurones de retro-propagation BPNN) avec une stratégie de feed forward au cours du processus d'apprentissage pour reconnaître les activités de la vie quotidienne (ADL) dans une maison intelligente. Ils révèlent que si le nombre de neurones cachés augmente, la précision du modèle augmente. Cependant, l'approche nécessitait un temps d'apprentissage plus important. Les résultats révèlent que le nombre de neurones dans la couche cachée affecte la précision du modèle [166]. Les auteurs déduisent que le BPNN obtient une bonne précision de reconnaissance. Liu et al. [167] développent un système d'assistance complexe pour prédire le comportement de la personne concernant l'activité humaine et le suivi de la santé. Les auteurs proposent un système de reconnaissance d'activité concernant la position du bras et du corps, tels que debout, Sitting, Walking, Falling-down. Les résultats montrent un bon taux de reconnaissance avec l'utilisation du modèle NN. Teich et al. [168] construisent un réseau de neurones stables (SNN) basé sur un réseau de neurones avancés dans la phase d'apprentissage. Les résultats montrent qu'un réseau neuronal supervisé avec de multiples couches cachées donne des résultats prometteurs après une courte période d'apprentissage. Dans le contexte de la reconnaissance de l'activité humaine à partir de séquences d'images, M. Zia et al. [169] a proposé une nouvelle méthode basée sur l'Independent Component Analysis (ICA) pour extraire les séquences d'image concernant les informations de forme d'activité. Ils ont utilisé le Hidden Markov Model (HMM) pour la reconnaissance des activités humaines. Dans [169], les auteurs montrent qu'une reconnaissance supérieure est obtenue par ICA basée sur HMM par rapport à l'analyse de composante principale (PCA) basée sur HMM. En ce qui concerne les applications de suivi de santé à domicile, le travail de [170] a étudié le problème des activités de reconnaissance dans la maison intelligente. Le travail [170] a porté sur le problème de la domination des activités majeures par rapport aux activités mineures dans une maison intelligente. Ils ont proposé un nouveau modèle d'ensemble évolutif (EEM) pour traiter indépendamment les activités mineures et principales. Le modèle EEM est basé sur un Algorithme Génétique (GA) pour gérer la nature non déterministe des activités. Les résultats de [170] montrent que le modèle EEM garantit de meilleures performances par rapport à HMM et l'approche de Jehad et al. [171] en termes de précision. Dans [172], nous avons proposé un modèle nommé "ELMAN-NN" amélioré pour la reconnaissance de l'activité de vie quotidienne concernant les personnes âgées dans une maison intelligente. L'utilisation de l'Algorithme d'Évolution Différentielle (DE) dans l'étape d'apprentissage de ELMAN-NN a été proposée afin d'améliorer la précision de la prédiction par rapport à l'algorithme conventionnel. Les résultats montrent que ELMAN-NN basé sur DE assure une meilleure performance du modèle ELMAN basé sur l'algorithme génétique par rapport au modèle ELMAN classique. Un réseau de neurone récurrent

basé sur l'algorithme génétique est proposé dans [173] dans le but d'améliorer la prédiction de comportement de la personne, et de fournir des services appropriés, alors dans [173] nous nous sommes concentrés sur l'amélioration de la qualité du système de surveillance à domicile de point de vue précision de prédiction.

1.12 Conclusion

Dans une première partie de ce chapitre, nous avons effectué une étude préliminaire sur la maison intelligente pour la santé et les systèmes d'assistance à l'autonomie à domicile. A ce propos, nous avons conclu que l'objectif principal d'un AAD est d'améliorer la qualité de vie de personnes dépendantes, tout en améliorant la qualité de reconnaissance, de prédiction et la qualité de service. Dans une deuxième partie, nous avons donné un aperçu sur les modèles de mesure de l'autonomie des personnes âgées utilisé dans le domaine de la gériatrie qui est une solution pour avoir des connaissances sur le niveau de l'autonomie de la personne. Dans le reste de ce chapitre nous avons présenté une étude bibliographique des différentes techniques utilisées pour la reconnaissance et la prédiction du comportement quotidien de la personne dans le cadre d'un système de surveillance à domicile. Dans le reste de notre manuscrit nous allons nous concentrer sur la qualité de reconnaissance, de prédiction et de décision dans le but d'améliorer le taux de précision et la rapidité de l'intervention. De plus, nous nous appuyons sur les activités quotidiennes ADL et IADL, la routine, le niveau d'autonomie de la personne et son état de santé pour offrir des services appropriés et pour améliorer la qualité de service afin d'avoir un système de surveillance à domicile pertinent, précis, adaptable et sûr.

Deuxième partie

Contributions

CHAPITRE 2

Description et reconnaissance des activités quotidiennes des personnes âgées

2.1 Introduction

Une maison intelligente est un environnement équipé de plusieurs types de capteurs responsables de suivre et de surveiller le comportement quotidien de la personne. Il vise à offrir des services adéquats aux besoins de la personne afin de gérer son environnement intelligent, d'améliorer sa qualité de vie, et de lui fournir le confort et l'assistance en fonction de ses besoins. Par conséquent, l'environnement intelligent se base essentiellement sur la connaissance des informations de la personne et de son environnement pour lui fournir un service adapté à son contexte dans le but de consolider l'adaptabilité et l'aide à la décision du système intelligent. Toutefois l'hétérogénéité des données recueillies dans ces environnements rendent la modélisation du système assez difficile. Dans le but de concevoir un système sensible au contexte, les informations doivent être bien définies, saisies et modélisées sous une forme adaptée et compatible.

En général dans le cadre d'une maison intelligente, les informations contextuelles provenant de différentes sources des capteurs liées à l'activité quotidienne ne sont pas formalisées de manière standard en raison de l'hétérogénéité de l'information. En effet, les données recueillies contiennent un volume important de données sensorielles complexes et hétérogènes. Pour élaborer un système efficace sensible au contexte dans le cadre d'une maison intelligente pour la santé, le contexte doit être bien défini et modélisé sous une forme qui favorise le partage de l'information. Notre objectif consiste à comprendre et à reconnaître le comportement de la personne à partir de ces données sensorielles. Cela pourrait être réalisé en utilisant des connaissances de bon sens par rapport aux activités quotidiennes de la personne. Dans ce chapitre nous nous focaliserons sur l'objectif de définir une modélisation basée sur une représentation significative, pertinente et utile des activités quotidiennes de la personne. De ce fait, pour reconnaître et prédire le comportement de la personne, nous proposons un nouveau langage de modélisation, inspiré des notions de base des langages naturels, qui concerne les activités, les scénarios et le comportement basés sur des règles et des critères bien définis. Par la suite nous proposons une approche Markovienne hybride basée sur la notion hiérarchique et la notion temporelle pour reconnaître et prédire le comportement de l'habitant.

2.2 Activités de la vie quotidienne

Les activités de la vie quotidienne sont les tâches réalisées par une personne pour accomplir un besoin donné comme celles relatives à l'alimentation, l'hygiène et l'élimination. Cependant, chaque personne développe ces activités en utilisant sa propre manière relative à son mode de vie, ses habitudes, son rythme de vie et ses

capacités. Afin de reconnaître et décrire les activités des personnes âgées dans un habitat intelligent, nous proposons un langage formel basé sur des règles et des critères dans le but de simplifier, raffiner et mettre en valeur notre description. Une bonne compréhension des activités cibles dans les MIs et de leurs caractéristiques spécifiques est essentielle pour la sélection correcte des capteurs et la conception du système intelligent. En outre, les connaissances précises sur le contexte des activités, telles que la localisation et les objets impliqués, si elles sont incluses dans la conceptualisation de l'activité, peuvent améliorer l'efficacité des systèmes de surveillance à domicile. Dans ce contexte plusieurs techniques de description ont été proposées dans la littérature tels que Key-value modelling, Markup scheme modelling, Graphical modelling, Object-oriented modelling, Logic-based modelling et Ontology-based modelling, le tableau 2.1 résume les avantages et les inconvénients de ces approches. À partir du tableau 2.1 on peut remarquer que malgré les avantages de ces approches il existe encore des limitations, par exemple, pour l'approche ontologique, la modélisation nécessite de solides compétences en ingénierie des connaissances ; il ne supporte pas le raisonnement lié au temps, les modèles sont généralement coûteux en termes de calcul de contexte et ils ont une capacité limitée à gérer le contexte incertain. Alors, dans le but de surmonter les inconvénients des méthodes de modélisation utilisées dans la littérature, nous proposons un nouveau langage spécifique dédié à la représentation et à la structuration du contexte des activités qui tient compte de plusieurs critères tels que le temps, l'emplacement, l'objet, etc. En outre, nous considérons aussi un autre critère très important dans la structuration des activités quotidiennes à savoir le profil de la personne contenant des informations contextuelles telles que les maladies, l'âge et le niveau de l'autonomie. La simplicité de notre langage est un atout qui permet de considérer les différentes catégories d'utilisateurs.

2.3 Approche basée sur les langages naturels

Pour simplifier, organiser, mettre en valeur, structurer et enlever l'ambiguïté des informations schématisées par un scénario nous nous focalisons sur la définition d'un langage de description qui concerne les personnes âgées vivant seul dans le cadre d'une maison intelligente. Notre langage nommé « *Elderly by Room Activities Description Language (EBRADL)* » est défini sur la base des termes, des règles, des contraintes et des relations bien examinées. Dans la suite, nous allons définir le langage naturel, nous décrivons l'objectif de EBRADL ainsi que son domaine de connaissance. En fin nous décrivons la syntaxe de EBRADL.

TABLE 2.1 – Les principaux travaux proposés dans la littérature pour la modélisation des activités

Type	Références	Avantages	Inconvénients
Key-value modelling	Aiello et al. [174], CC/PP [175], Tayeb [176]	Facile à gérer	Capacités limitées pour capturer des types de contextes sophistiqués
Markup scheme modelling	McDonald et al. [177], Gonçalves et al. [178]	Permet de définir des modèles d'interaction	Absence de critères de conception, uniquement disponible à une échelle limitée
Graphical modelling	Rialle et al. [179], Henricksen et al. [180]	Un support plus complet pour la capture d'informations imparfaites et l'historiques	Modèle d'information plat, limité en interopérabilité de soutien dans les systèmes contextuels
Object-oriented modelling	Zhang et al. [181]	Bonnes performances dans la représentation du contexte d'activité liée à un objet	Limitation de l'interopérabilité
Logic-based modelling	Bruno et al. [182], Chen et al. [183]	Sémantique claire et élégante dans la description de l'information contextuelle	Incapacité de représenter le contexte incertain et l'inflexibilité pour représenter les habitudes des utilisateurs
Ontology-based modelling	Okeyo et al. [184], Ye et al. [185], Perich et al. [186], Chen et al. [187]	Représente le contexte en termes d'hétérogénéité, d'interopérabilité et de convivialité avec une interface conviviale	Exige des compétences en ingénierie des connaissances bien construites, une capacité limitée face à un contexte incertain et changeant

2.3.1 La langue naturel

Les personnes utilisent essentiellement une langue pour communiquer entre eux. Une langue se caractérise par deux aspects : sa signification et sa structure. La signification d'une langue se matérialise par les idées qu'elle transmet et que l'on appelle son contenu sémantique. La structure d'une langue comporte les règles

grammaticales utilisées pour la construire et qui forment l'aspect syntaxique.

Lorsque l'on apprend une langue on doit maîtriser le vocabulaire, la grammaire et la sémantique :

- Le lexique : c'est le vocabulaire qui représente les mots du dictionnaire, les déclinaisons, etc.
- La syntaxe : c'est la grammaire ou comment composer des phrases correctes du point de vue forme et structure.
- La sémantique : c'est le sens des mots et des phrases. Généralement, cet apprentissage se fait en même temps que le vocabulaire et la grammaire : on apprend les mots corrects et leur sens et les constructions grammaticales et leur sens.

En se basant sur ces caractéristiques, nous allons définir, dans ce qui suit, les principes de base de notre langage de connaissance.

2.3.2 Elderly By Room Activities Description Language (EBRADL)

La reconnaissance des activités quotidiennes joue un rôle important dans les services e-santé. Un grand nombre de capteurs déployés dans la maison intelligente permet de fournir un environnement sûr et confortable. Cependant, la complexité de l'information détectée par les capteurs influence directement sur la précision du modèle de reconnaissance. Dans le but de simplifier la complexité de ces informations, nous proposons un langage descriptif afin de structurer et de classer la structure des activités des occupants et de la rendre moins complexe. Une compréhension et une caractérisation spécifique et claire des activités ciblées aux personnes âgées dans le cadre d'une maison intelligente est une tâche essentielle dans le but de définir des liens et des relations entre les différentes activités quotidiennes. La formalisation standard de l'information contextuelle définie dans le processus de conceptualisation est une étape primordiale pour permettre des conceptions efficaces.

2.3.2.1 Objectif de EBRADL

Compte tenu de la grande quantité d'information et des données descriptives des activités de la personne, la description du comportement de la personne d'une

façon adaptable et personnalisable est une tâche complexe et difficile qui nécessite une description et une modélisation précise de l’environnement ainsi de la personne. De ce fait, un langage descriptif performant et fiable est mis en considération pour caractériser l’activité en se basant sur leur concept et leur contexte. Un algorithme formel qui représente les instructions et l’enchaînement de base est utilisé pour construire notre langage est sera représenté par la suite.

Instructions de base du langage EBRADL :

- Identifier le domaine de connaissance,
- Identifier le champ lexical/ vocabulaire,
- Analyser le vocabulaire (les termes),
- Recenser les termes du vocabulaire et normaliser leurs sens,
- Identifier les concepts, les relations et les contraintes,
- Construire une structure/hiérarchie qui représente le langage.

En fait, une modélisation claire du comportement de l’habitant est une tâche essentielle pour une sélection adéquate des données collectées par les capteurs et pour une conception pertinente du système. La description de notre langage est discutée dans les sous-sections suivantes.

2.3.2.2 Champ lexical de EBRADL

Un champ lexical est un ensemble de mots et de termes qui se rapportent à un même contexte, c’est en fait le vocabulaire que nous allons utiliser dans notre langage. Ainsi, nous définissons les termes de notre langage [Terme : un mot de langage qui désigne un contexte]. En fait pour fixer et identifier les termes de EBRADL nous allons poser les questions suivantes : le langage va décrire quoi/ qui et où ?. Pour notre cas on définit les trois terme indiqués dans le tableau 2.2. Par conséquent, notre langage descriptif est spécifié par les termes appropriés : à la maison, à la personne et aux activités.

TABLE 2.2 – Les termes de base en fonction de leurs sous-termes.

Termes	Sous-Termes
Maison	surface, endroit (les chambres), nombre de chambres, Objets de chaque chambre, architecture.
Personne	nom, prénom, situation, autonomie, age, maladies
Activités	manger, se coucher, prendre une douche, s’habiller, préparer le repas, etc.

2.3.2.3 La syntaxe de EBRADL

La syntaxe est le fait de disposer des relations entre les termes basés sur des règles et de définir un sens aux termes. Le champ lexical du langage EBRADL est basé sur trois termes de base qui sont la maison, la personne et l'activité. De plus nous définissons les relations entre ces termes comme suit :

Relation 1 : Maison- Personne

Relation 1.1 : Personne-Endroit

Relation 1.2 : Personne-Objet

Relation 2 : Maison- Activité

Relation 2.1 : Activité -Endroit

Relation 2.2 : Activité – Objet

Relation 3 : Activité-Personne

Relation 3.1 : Personne-Activité

Relation 3.2 : Personne- Temps

A partir de ces relations, nous pouvons remarquer que chaque terme peut être en relation avec un autre terme. De plus, chaque relation définit un lien entre les termes. Définir des relations d'une manière générale n'est pas suffisant pour fournir une description adaptable et personnalisable. De ce fait, dans le reste de cette partie nous allons nous concentrer sur la définition des règles et des contraintes issues de la vie quotidienne.

Généralement, dans la vie quotidienne les personnes appliquent des règles apprises dès la naissance résultantes de certaines contraintes. Par exemple : des contraintes liées à l'objet, contraintes liées à l'endroit, contraintes liées aux temps, etc.

Dans un environnement domestique intelligent, il existe de nombreux types d'informations contextuelles pouvant être utilisés pour caractériser une activité, telles que l'interaction avec les objets, l'emplacement et le temps qui sont des concepts très utilisés pour décrire et distinguer les activités.

Un objet se réfère aux types d'activités, par exemple, si le téléviseur est l'objet, nous pouvons déduire qu'il s'agit d'une activité «*regarder la télévision*», tandis que le fait d'avoir un balai comme objet peut mener à l'activité «*balayer le plan-*

cher». De plus, l'emplacement est l'endroit spécifique où une activité se produise, par exemple, "*préparer le repas*" a lieu dans la cuisine et "*prendre une douche*" se produit dans la salle de bain. Par conséquent, l'emplacement peut aider à jeter certains objets en dehors de l'endroit cible. Le temps est une autre caractéristique clé dans la description de l'activité. En effet, l'utilisateur peut effectuer une activité à différents moments, mais certaines activités ne se produisent qu'à des moments précis de la journée. Par exemple, l'activité «préparer le petit-déjeuner» se produit habituellement le matin, «préparer le dîner» se produit généralement le soir et «prendre une douche» une ou deux fois par jour peut se produire après le réveil et/ou avant d'aller se coucher.

D'autres informations contextuelles sont utiles pour la caractérisation des activités comprennent le profil et l'habitude de la personne. Vu que notre langage est dédié aux personnes âgées et puisque ce type de population possède des autonomies parfois limitées (comme l'autonomie physique, autonomie mentale, etc.) en se basant sur les règles de la vie quotidienne nous allons définir des contraintes distinguées à la personne âgée dans le but d'améliorer la syntaxe de notre langage.

Dans ce cas, nous définissons quatre contraintes nommées :

- Contrainte 1 : Endroit - Objet
- Contrainte 2 : Endroit - Activité
- Contrainte 3 : Activité - Temps
- Contrainte 4 : Activité - Habitude
- Contrainte 5 : Personne - Profil

Dans la suite nous détaillons ces contraintes.

2.3.2.3.1 Contrainte 1 : Endroit - Objet

Cette contrainte représente toute la spécification de l'objet et le lien qui existe entre un endroit spécifique et les objets utilisés dans cet endroit. Chaque endroit de la maison est composé et équipé par des objets spécifiques. Nous pouvons donc dire que l'objet est relatif à l'endroit. Par exemple on ne peut pas utiliser les objets de la cuisine dans la salle de bain, de la même manière concernant la chambre à coucher et la cuisine. Le tableau 2.3 représente une classification des objets par leurs endroits en se basant sur la contrainte 1.

2.3.2.3.2 Contrainte 2 : Endroit - Activité

Cette contrainte représente la spécification de l'activité selon le type de l'endroit. Chaque activité de la vie quotidienne est relative a son endroit, c'est à dire que

TABLE 2.3 – Les objets par leur endroit.

Endroit	Objet
Cuisine	Four, micro-onde, lavabo, poêle, réfrigérateur, machine à laver, machine à café, table à manger.
Salle de bain	Toilette, lavabo, bain, miroir
Chambre à coucher	Lit, table de nuit, armoire, bureau
Salon	Canapé, télé, table, cheminée, téléphone

chaque activité est liée à son endroit et on ne peut pas la réaliser dans un autre endroit. Par exemple, on ne peut pas se coucher dans la cuisine, ou préparer le déjeuner dans la salle de bain. Le tableau 2.4 représente une classification des activités par endroit.

TABLE 2.4 – Les activités de la personne par endroit.

Endroit	Activité
Cuisine	Préparer le déjeuner/dîner, laver la vaisselle, etc.
Salle de bain	Se laver, prendre une douche/bain, faire sa toilette, etc.
Chambre à coucher	Se réveiller, se coucher, s'habiller, etc.
Salon	Regarder la télé, lire un livre, se reposer, etc.

2.3.2.3.3 Contrainte 3 : Activité – Temps

Cette contrainte représente la relation entre l'activité et le temps de réalisation. Chaque activité quotidienne est relative a un slot de temps spécifique, cela veut dire qu'une activité est limitée par un intervalle de temps qui peut être défini par des experts ou estimé en se basant sur le rythme de vie de la personne. Ainsi, il n'est pas logique de préparer un petit-déjeuner durant 5 heures, ou prendre une douche dans un slot de temps égal à 8 heures.

2.3.2.3.4 Contrainte 4 : Activité – Habitude

La contrainte Activité-Habitude est très importante dans la phase de reconnaissance qui facilite la détection des comportements anormaux de la personne en se basant sur leur habitude. Cette contrainte se compose de deux sous-contraintes qui sont : *la contrainte Habitude-temps des activités* et *la contrainte Habitude-ordre des activités*.

Habitude-temps : Cette contrainte est relative à la contrainte 3 (Activité – temps) qui dépend aussi de la routine de la personne. Nous considérons le temps habituel de la personne afin de définir une relation entre le temps nécessaire pour une activité dans le cadre général et le temps nécessaire pour une activité qui

concerne la personne à suivre (temps habituelles).

Habitude-ordre des activités : Cette contrainte concerne l'ordre des activités et l'habitude de la personne. Elle peut aider à structurer le comportement de la personne et à distinguer chaque changement du comportement. Par exemple si l'ordre des activités habituelles de la personne durant 3 mois est :

Se lever → prendre un douche → faire sa toilette → préparer son petit déjeuner → regarder la télé, si on distingue un changement dans l'ordre cela peut signaler un changement de comportement qui est du parfois à un changement d'état de la personne.

2.3.2.3.5 Contrainte 5 : Personne – Profil

Le sujet ciblé dans cette description est la personne âgée. Cette contrainte est basée sur le profil de la personne dans le but d'améliorer notre langage et d'avoir une description adaptable et personnalisable. Le profil de la personne se présente comme suit :

Profil = [Nom/Prénom – Age – Situation – Maladies - profil SMAF – poids - Hauteur].

Compte tenu du profil de la personne nous allons focaliser sur trois informations de base (*âge, maladies et profil SMAF*) qui sont les informations les plus significatives dans notre description. Le but de cette contrainte est de définir un lien spécifique entre ces termes et qui soit facile à interpréter afin d'avoir un niveau de description selon le profil de la personne.

Le terme « SMAF profil » indique le niveau d'autonomie de la personne. Comme nous l'avons expliqué dans le chapitre 3, SMAF est un système de mesure de l'autonomie très détaillé qui se compose de 14 profils. Dans notre travail, nous allons proposer de classer ces 14 profils en 3 catégories pour faciliter l'utilisation de ces informations. *Catégorie 1* se compose du profil p1, *catégorie 2* se compose du profil P2 et P3 et *catégorie 3* englobe les profils P4, P5, P6, P7, P8, P9, P10, P11, P12, P13 et P14.

Le terme « âge » est un critère aussi important pour les personnes âgées. Ce critère peut aider à déterminer le niveau des descriptions de notre langage.

Le terme « maladies » est un terme aussi significatif. Il aide aussi à améliorer notre manière de description.

A partir de ces trois termes nous allons proposer un niveau de description de notre langage qui prend en compte le profil de la personne ainsi que son niveau d'autonomie. Le principe de cette classification se présente comme suit :

Nous proposons 3 niveaux de description : description légère, description normale et description détaillée. Cette classification nous permet d'éliminer la présence d'informations inutiles dans notre description et d'éviter l'encombrement des informations si ce n'est pas nécessaire.

Niveau 1 : description légère qui concerne les personnes âgées $\in [50 \dots 70]$.

Niveau 2 : description normale qui concerne les personnes âgées $\in [70 \dots 80]$.

Niveau 3 : description détaillée qui concerne les personnes âgées $\in [80 \dots 90]$.

Le tableau 2.5 présente chaque niveau de description en fonction de (Age, SMAF profile, Maladies).

TABLE 2.5 – Le niveau de description en fonction de (Age, SMAF profile, Maladies).

	Niveau1	Niveau2	Niveau3
Maladies	La personne présente de simples maladies.		La personne souffre des maladies graves. Par exemple : Alzheimer, tension, maladies cardiaque .
SMAF	P1	P2, P3	P4, P5, P6, P7, P8, P9, P10, P11, P12, P13, P14
Age	[50...70]	[70...80]	[80...90]

Une évaluation du niveau de la personne est mise au début du suivi de la personne pour offrir une description adéquate. Ce niveau nécessite périodiquement un contrôle en fonction des données habituelles et en fonction de la contrainte 4. En outre, si le comportement de la personne subit un changement notable, le niveau d'autonomie défini au préalable sera mise à jour.

2.3.2.4 Structure de EBRADL

Après avoir défini le champ lexical et la syntaxe de notre langage, dans cette partie nous focalisons sur la désignation d'une structure adaptable et personnalisable en se basant sur les différentes contraintes proposées dans la partie syntaxe. Fondé sur *les contraintes 1, 2 et 3* nous pouvons conclure qu'une activité quotidienne

dépend de l'endroit, l'objet utilisé dans chaque activité est relatif aussi à l'endroit simultanément. Dans ce cas nous pouvons dire que l'endroit englobe l'activité et l'objet. Alors, la structure descriptive de notre langage prend en compte la notion de l'endroit comme une notion de base. Pour cette raison, nous allons proposer une classification basée sur le type de l'endroit de la maison. Nous pouvons donc ajouter une spécification à EBRADL et d'avoir une description simple, adaptable et pertinente. Le tableau 2.6 présente la notion de notre classification.

TABLE 2.6 – Classification des Activités / Objets/ Slot de temps par endroit.

	Endroit			
	Cuisine	Salle de Bain	Chambre à Cou- cher	Salon
Activités	Préparer le déjeuner/- diner, Préparer un café, Laver la vaisselle	Prendre sa toilette, Faire sa douche, Laver le visage/main	Se coucher, Se réveiller, S'habiller	Regarder la télé, Lire un livre
Objets	Poêle, lavabo, réfrigérateur, etc.	Lavabo, bain, douche, toilettes, etc.	Lit, Armoire, Table de chevet	Télé, canapé, Bibliothèque, etc.
Slot de Temps	Temps de début/ Temps de fin			

Après avoir fourni une classification pertinente et significative à nos termes et contraintes nous pouvons maintenant définir une structure bien organisée de notre langage. La description des activités quotidiennes de la personne prend la forme suivante :

Personne # est dans# un endroit # en train de # activité # avec l'utilisation de # objet [objet1... objetn] # à t = # temps de début.

Par exemple :

*Paul # est dans # la salle de bain # en train de
Faire sa toilette # avec l'utilisation de # [lavabo] # à t = # 9 :35h
Prendre sa douche #avec l'utilisation # [bain] # à t = # 9 :54h*

*Paul # est dans # la cuisine # en train de
préparer le déjeuner # avec l'utilisation de
#[poêle,réfrigérateur] #à t = # 10h*

En tenant compte de la contrainte 5 (Personne – Profile) nous allons définir trois structures de description en fonction du profil de la personne.

Niveau 1 (description légère) :

Personne # est dans # un endroit # en train de # activité.

Niveau 2 (description normale) :

*Personne # est dans # un endroit # en train de # activité # avec l'utilisation
objet[objet1... objetn] # à t = # temps de début.*

Niveau 3 (description détaillée) :

*Personne # est dans # un endroit # en train de # activité # avec l'utilisation
objet[objet1... objetn] # à td = # temps de début.
à tf = # temps de fin.*

Notre langage descriptif « EBRADL » est dédié aux personnes âgées et utilisé pour offrir une sélection adéquate des données collectées par les capteurs. Par la suite, il est crucial de modéliser et d'automatiser notre langage afin de reconnaître et de prédire le comportement de la personne suivie. De ce fait, une proposition d'un modèle de reconnaissance et de prédiction pertinent et adaptable au langage EBRADL sera détaillée dans la partie suivante.

2.4 Modélisation du comportement

Dans le cadre d'une maison intelligente pour la santé qui concerne les personnes âgées, l'un des principaux intérêts est de modéliser les activités quotidiennes de la personne dans son propre environnement. La reconnaissance de l'activité est utilisée pour modéliser le comportement humain dans un environnement intelligent. Elle devient un élément essentiel puisqu'elle peut être appliquée à de nombreuses applications réelles. La plupart des recherches qui ont été réalisées pour faire face à la reconnaissance et à la prédiction de l'activité comportementale, se font à l'aide des techniques statistiques utilisées pour déterminer la dépendance et les corrélations entre les données temporelles générées par les capteurs pour identifier le comportement d'un occupant. Les modèles probabilistes sont classés parmi les meilleures techniques utilisés pour identifier le comportement humain car ils sont capables de représenter des variables aléatoires, des dépendances et des variations temporelles dans les données [127].

Plusieurs algorithmes basés sur la probabilité ont été utilisés pour modéliser les

activités de la vie quotidienne des personnes âgées. Le modèle de Markov caché (HMM) et le modèle aléatoire conditionnel sont parmi les techniques les plus populaires [130]. Les modèles probabilistes tels que les réseaux de croyances bayésiens [150, 188] et les modèles markovien [139, 142, 143, 189, 190]. Dans cette partie, dans le but de modéliser et d'automatiser notre langage nous allons proposer un modèle markovien hybride. D'abord, nous allons définir en bref le modèle de Markov classique, par la suite nous allons proposer un modèle hybride efficace pour modéliser et décrire notre langage.

2.4.1 Modèle de Markov Caché (HMM)

Le *Modèle de Markov Caché (Hidden Markov Model-HMM)* est l'un des modèles statistiques dans lesquels un système utilise un processus de Markov avec des paramètres inconnus. Il se compose d'un certain nombre d'états cachés et d'observations (Figure). Le modèle de Markov caché est largement utilisé pour identifier les activités d'un utilisateur à partir des données de capteurs. Les états cachés représentent les activités et les données du capteur sont représentées par les observations. Il est un modèle efficace pour apprendre et reconnaître des activités séquentielles [191]. Cependant, lorsque l'ensemble des données devient de plus en plus complexe ou lorsque les activités exigent une forte dépendance temporelle la modélisation et le traitement des données deviennent une tâche difficile à réaliser. Notre but est d'automatiser notre langage descriptif proposé dans la partie précédente afin de reconnaître et prédire le comportement de la personne. Le langage exige d'appliquer et d'élaborer une structure spécifique, des règles, et des notions dans le processus de reconnaissance. Par conséquent, nous allons proposer un modèle markovien hybride en se basant sur les caractéristiques de notre langage proposé. Nous avons mentionné que notre langage se caractérise par deux notions de base à savoir, la notion hiérarchique (contrainte 1, contrainte 2, contrainte 3) et la notion temporelle (contrainte 4, contrainte 5), à cet effet nous proposons par la suite un modèle de reconnaissance hybride basé sur la notion hiérarchique et la notion temporelle permettant d'enrichir le modèle markovien classique et de s'adapter parfaitement à notre langage.

Dans la littérature, deux catégories d'extensions du HMM sont proposées qui tiennent compte du concept temporelle et de la notion hiérarchique.

- Une catégorie d'extension introduit la structure hiérarchique telle que Abstract HMM [191], hierarchical Hidden markov model [192] et layred hidden markov model [193].

- Une catégorie d’extension adopte la notion temporelle telle que Hidden Semi-Markov Model (HSMM) [194] qui introduit une variable ou un paramètre qui permet de calculer d’une manière explicite la durée passée dans chaque état.

2.4.2 Modèle de reconnaissance hybride

La structure et les contraintes de EBRADL imposent une modélisation particulière. En effet, EBRADL se caractérise par une structure hiérarchique, des contraintes bien définies qui représentent des relations robustes entre les termes et un aspect logique qui prend en considération le profil de la personne, l’architecture de la maison, etc. De ce fait, une modélisation pertinente nécessite un modèle qui répond aux besoins de notre langage. Ce modèle doit être efficace de point de vue reconnaissance et prédiction et doit prendre en considération la notion hiérarchique et la notion temporelle en même temps. A ce propos, nous proposons un modèle hybride nommé *Temporal Hierarchical Hidden Markov Model* (THHMM), basé sur une combinaison du modèle markovien caché hiérarchique (HHMM) et le modèle semi-markovien caché (HSMM).

2.4.2.1 Modèle de markov caché hiérarchique(HHMM)

Le modèle HHMM est une extension du modèle HMM standard [195]. Il a été inspiré par les langages réguliers qui sont modélisés à base d’automate à états finis et qui sont par la suite transformés en arbres hiérarchiques. HHMM est caractérisé par une hiérarchie à niveau où le niveau augmente du plus haut vers le plus bas. HHMM se compose de plusieurs séquences du HMM, chacune peut contenir une sous-séquence qui elle même peut être modélisée par un HMM ou par un HHMM. Un état parent au niveau n émet une suite de symboles pour stimuler un état fils au niveau $n + 1$. Ces états fils peuvent être aussi composés de HMM ou de HHMM. La structure hiérarchique de HHMM permet de lier les composantes qui se produisent à divers niveaux dans une séquence d’observations (Figure 2.1). Il existe deux types de transitions : une transition horizontale qui permet de relier les états de même niveau et une transition verticale qui permet de relier un état du niveau n aux états fils de niveau $n+1$. Le fonctionnement du HHMM est détaillé dans l’annexe A.

2.4.2.2 Modèle semi-markovien caché (HSMM)

Une loi semi-markovienne de la chaîne X peut être vue comme la loi marginale d’une chaîne de Markov du couple (X, U) , où le processus U gère le temps de

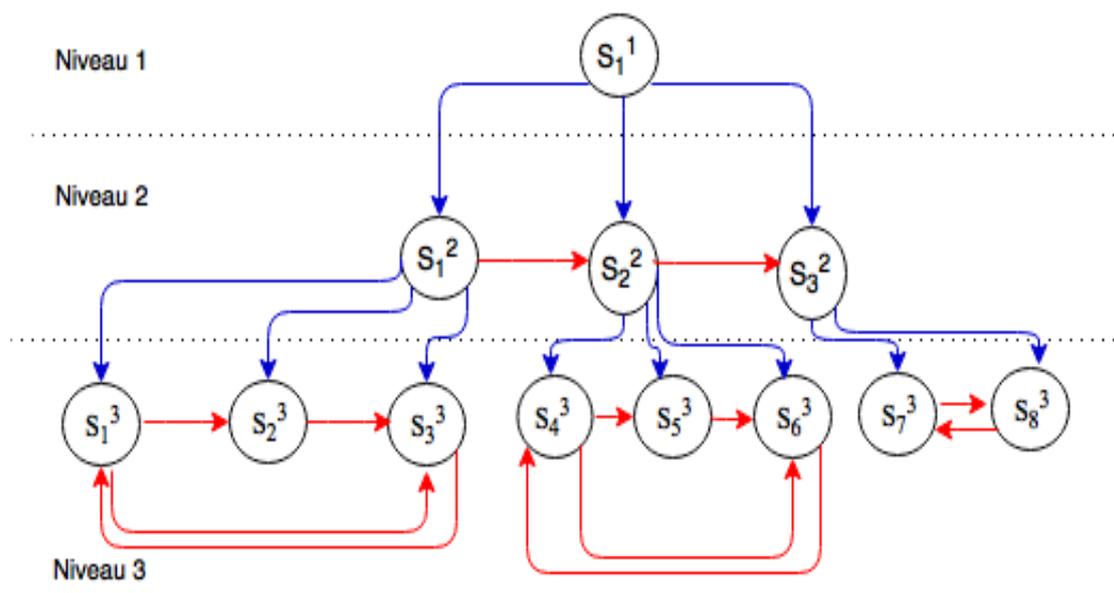


FIGURE 2.1 – Structure du modèle HHMM

séjour d'un état donné X_n [194]. Les modèles de Markov classiques et hiérarchiques ne tiennent pas compte de la notion temporelle pour chaque état, ce qui est très important dans les services e-santé pour la surveillance a domicile afin de discriminer la durée de chaque activité et par la suite de distinguer n'importe quel changement de routine de la personne. L'objectif est d'offrir une surveillance aussi pertinente pour l'autonomie et une description du comportement quotidien plus efficace. Par conséquent, nous allons introduire la notion temporelle du modèle semi-markovien dans notre modèle de reconnaissance. Le fonctionnement du Modèle semi-markovien caché est détaillé dans l'annexe A.

2.5 Temporal Hierarchical Hidden Markov Model (THHMM)

Le modèle THHMM que nous proposons pour modéliser notre langage dispose d'une architecture détaillée dans la figure 2.2. Il consiste à une incorporation de la notion temporelle et la notion hiérarchique. Le fonctionnement du THHMM est détaillé dans l'annexe A. Dans la suite, nous allons discuter le principe de EBRADL modélisé par THHMM, puis nous allons simuler et interpréter les résultats de reconnaissance et de prédiction obtenus par ce modèle.

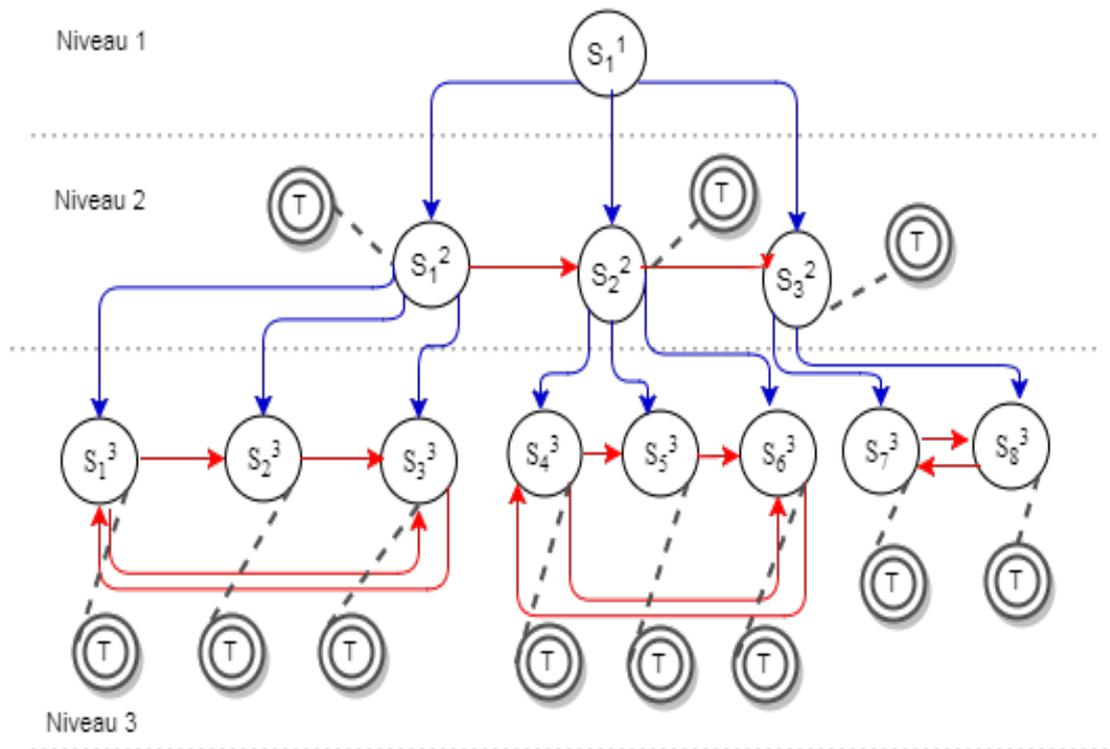


FIGURE 2.2 – Structure du modèle THHMM

2.5.1 Principe du THHMM

Nous appliquons notre modèle THHMM pour reconnaître et prédire le comportement de la personne âgée. D'abord, nous définissons la structure de la maison de la personne suivie. Dans notre étude, nous prenons comme exemple une maison composée de 4 chambres, la chambre à coucher (CC), le salon (S), la salle de bain (SB) et la cuisine (C). Chaque chambre est équipée de différents types de capteurs. Les connaissances préalables de l'environnement nous permettent de définir la structure du modèle et le nombre d'états.

Soit le modèle THHMM structuré par λ avec $\lambda = (A^s, B^s, \pi^s, S, T, N)$, où :

A^s représente la matrice de transition par niveau entre les états,

B^s désigne la matrice des observations par niveau,

π^s est l'état initial par niveau,

T indique le temps d'exécution du modèle au niveau d'un état,

N représente les états du modèle qui sont définis par l'ensemble $S_t^n = \{S_t^1, S_t^2, S_t^3\}$ où,

S_t^1 définit les pièces dans lesquelles se trouve l'occupant à l'instant t.

S_t^2 représente les activités effectuées par la personne à l'instant t.

S_t^3 représente les objets utilisés à l'instant t.

Pour tester le modèle THHMM, nous avons réalisé un scénario supervisé afin de simuler le comportement des activités de la vie quotidienne d'une personne âgée. Un THHMM peut être vu comme un ensemble discret de nœuds (ou d'états) et de transitions (ou d'arcs) reliant ces états entre eux. Le modèle THHMM est équivalent, en termes de capacité d'expression, à des HMM. Les états du modèle sont organisés hiérarchiquement avec un concept temporel. Nous avons développé une modélisation appropriée pour structurer le langage EBRADL par le modèle hybride THHMM. La figure 2.3 qui illustre la structure du langage EBRADL modélisée par THHMM, présente les activités de la personne en fonction des lieux et des objets d'une manière hiérarchique. Le niveau 1 représente l'environnement racine. Le niveau 2 représente l'environnement principal. Les niveaux 3 et 4 représentent les activités et les objets respectivement. Afin de reconnaître le comportement de l'habitant et pour automatiser notre langage EBRADL modélisé par THHMM, notre modèle est composé de 4 niveaux hiérarchiques qui sont le niveau Racine, le niveau Endroit, le niveau Activité et le niveau Objet. Nous décrivons par la suite chaque niveau avec « n » représente le niveau de la hiérarchie. Le Tableau 2.7 représente les abréviations utilisées dans la figure 2.3.

Au niveau « Racine » (avec n=1), le THHMM se compose d'un seul état noté S_1^1 . Cet état représente le début de la hiérarchie et est nommé « Couloir de passage » (CP) qui désigne un état de passage entre les chambres. Il indique aussi si la personne est à la maison ou non (la présence de la personne). Il est composé de 4 sous états relatif au deuxième niveau « le niveau endroit ». Les matrices de transition de l'état S_1^1 sont fixées à :

$$A^{S_1^1} = \begin{bmatrix} 0 & 0.4 & 0.2 & 0.4 \\ 0.5 & 0.5 & 0 & 0 \\ 0.5 & 0.4 & 0.1 & 0 \\ 0.5 & 0 & 0 & 0.5 \end{bmatrix}, \pi^{S_1^1} = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix}, V^{S_1^1} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

Au niveau « Endroit » (où n = 2), notre modèle de reconnaissance THHMM se

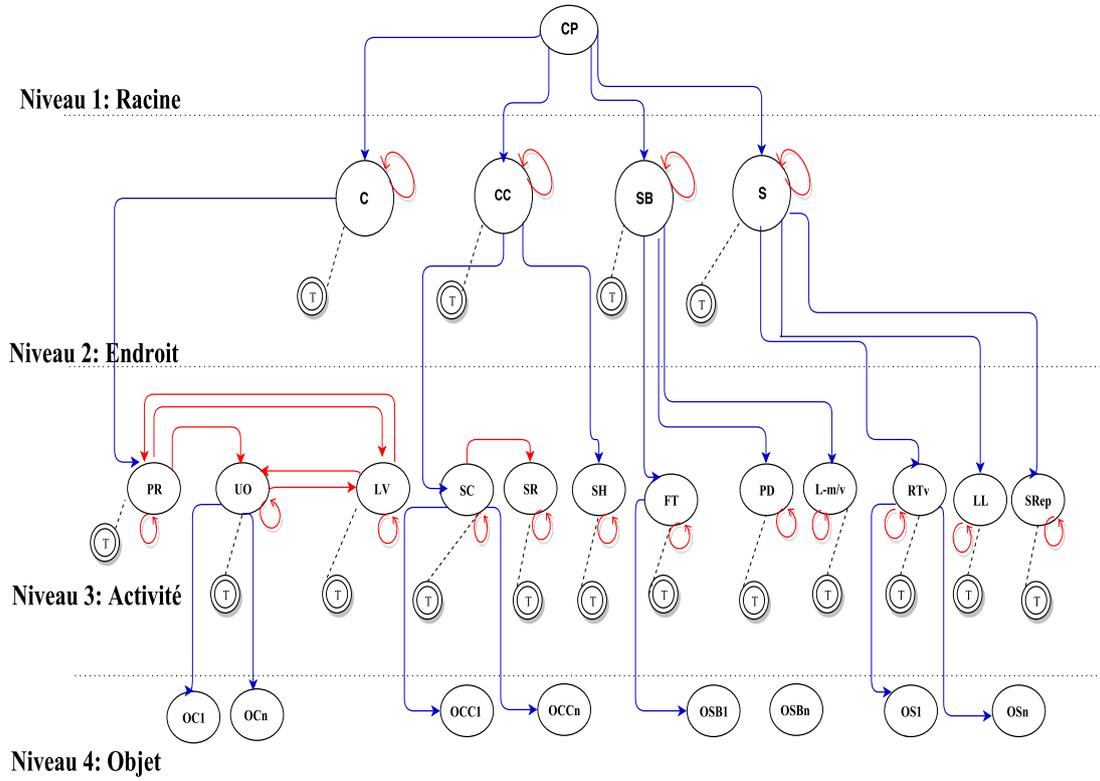


FIGURE 2.3 – Structure de EBRADL modélisé par THHMM

compose de quarts états noté $S_1^2, S_2^2, S_3^2, S_4^2$. Ces états représentent les chambres de la maison. L'état nommé « cuisine » (C) se compose de mc sous états où mc est le nombre d'activités à reconnaître qui concernent l'état cuisine. Nous prenons comme exemple $mc=3$ associé au niveau « *Activité* » qui sont : préparer le repas, laver la vaisselle et utiliser objet. De même, l'état S_2^2 nommé « chambre à coucher » (CC) est composé de mcc sous-états qui sont les activités à reconnaître dans la chambre à coucher. Nous prenons comme exemple $mcc=3$ avec les activités : se coucher, se réveiller, s'habiller. Pareillement pour les états S_3^2 nommé *salle de bain* se compose de msb sous états qui représentent les activités relatives à la salle de bain. Nous prenons comme exemple trois activités (sous états) qui sont : *faire sa toilette, prendre une douche, laver les mains/ visage*. Concernant S_4^2 il se compose de ms sous états où ms représente le nombre d'activités liées au salon. Nous proposons comme exemple $ms=3$ qui sont : *regarder la télé, lire un livre, se reposer*. Le temps passé par chaque état des différents niveaux est représenté par la probabilité $P(T)$.

Au niveau « *activité* » avec $n=3$, le THHMM se compose de 12 états modélisant les activités de la personne noté $S_1^3, S_2^3, S_3^3, S_4^3, S_5^3, S_6^3, S_7^3, S_8^3, S_9^3, S_{10}^3, S_{11}^3, S_{12}^3$.

TABLE 2.7 – Les abréviations du modèle THHMM par niveau.

Niveau		État	Abréviation
Niveau1		Couloir de passage	CP
Niveau2		Cuisine	C
		Chambre à coucher	CC
		Salle de bain	SB
		Salon	S
Niveau3	C	Préparer le repas	PR
		Laver la vaisselle	LV
		Utiliser Objet	UO
	CC	Se coucher	SC
		Se réveiller	SR
		S’habiller	SH
	SB	Faire sa toilette	FT
		Prendre une douche	PD
		Laver les mains/vi- sage	L-m/v
	S	Regarder la tété	RT
		Lire un livre	LL
		Se reposer	SRep
Niveau4	C	(ouvrir) Poêle	OC1
		(ouvrir) Réfrigérateur	OC2
		(utiliser) Tasse	OC3
		(utiliser) Casserole	OC4
	CC	Lit	OCC1
		Armoire	OCC2
		Coiffeuse	OCC3
		Table de chevet	OCC4
	SB	Lavabo	OSB1
		Bain	OSB2
		Toilette	OSB3
	S	Canapé	OS1
		TV	OS2
		Livre	OS3

. Les trois premiers états sont proportionnels à l’état « *cuisine* » du niveau précédent $n=2$ et sont interconnectés entre eux. Les états suivants sont liés entre eux et concernent *la chambre à coucher*. De plus, nous avons trois états qui concerne *la salle de bain*. Les trois derniers états sont liés entre eux et sont dédiés au *salon*.

Chaque état est associé aux objets utilisés dans l'activité en cours.

Au niveau « *Objet* » avec $n = 4$, notre modèle se compose de 4 ensembles d'état. Chaque ensemble est constitué de k états noté $S_1^4, S_2^4, \dots, S_k^4$ qui sont $[O_1.. O_k]$ avec k représente le nombre d'objets relatifs à l'activité ainsi que chaque ensemble d'objets est relatif à un endroit spécifique.

2.5.2 Résultats des simulations

Au début de ce chapitre, nous nous sommes focalisés sur l'élaboration d'un nouveau langage de description qui est structuré pour le traitement et la description des données hétérogènes provenant de différents types de capteurs en tenant compte du profil de la personne et de la structure de sa maison. Il s'agit d'un langage facile à interpréter, intelligible et caractérisé par son efficacité de point de vue harmonisation, classification et relation entre les données. Par la suite, nous allons nous concentrer sur la proposition d'un modèle de reconnaissance et de prédiction de données qui tient compte de la structure et les règles de notre langage. La figure 2.4 présente le processus de reconnaissance proposé.

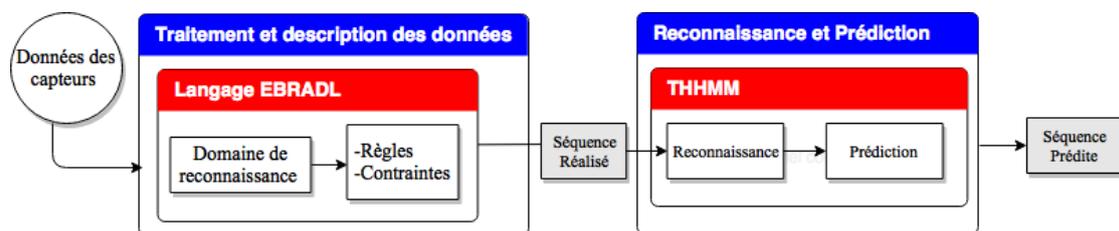


FIGURE 2.4 – Processus de reconnaissance et de prédiction par THHMM.

2.5.2.1 Reconnaissance du comportement

Dans ce travail, nous avons pris comme exemple une maison qui se compose de 4 chambres et un couloir de passage. Nous avons implémenté le modèle THHMM afin de suivre et reconnaître le comportement de la personne tout au long d'une journée. Les données détectées par les différents capteurs déployés dans la maison sont traités par notre langage.

Soient λ notre modèle Temporel Hiérarchique Markovien et O une séquence d'observations. La reconnaissance de cette séquence s'effectue en trouvant le modèle

λ qui maximise la probabilité $P(\lambda | O)$ (probabilité qu'un modèle λ génère une séquence de vecteurs acoustiques O) par niveau. Malheureusement, il n'est pas possible de calculer directement cette probabilité. Comme nous l'avons mentionné dans la définition du THHMM, nous allons appliquer les algorithmes spécifiques pour trouver le modèle λ qui maximise la probabilité $P(\lambda | O)$. Par conséquent, nous appliquons les algorithmes d'apprentissage et de reconnaissance du THHMM défini dans l'annexe A. Après la mise en œuvre de ces algorithmes (viterbi et back-propagation) nous obtiendrons le modèle λ le plus probable qui garantit d'obtenir la séquence d'observations la plus proche de la réalité.

Après avoir implémenté notre modèle de reconnaissance THHMM, la figure 2.5 montre les états cachés du comportement de la personne au niveau 2 obtenus par THHMM.

Les courbes 1, 2, 3 et 4 de la figure 2.5 représente l'état caché relatif au comportement de la personne âgée tout au long d'une journée dans la salle de bain, la cuisine, le salon et la chambre à coucher respectivement. Chaque courbe montre la présence de la personne marqué par "1" et "0" représente son absence en fonction du temps.

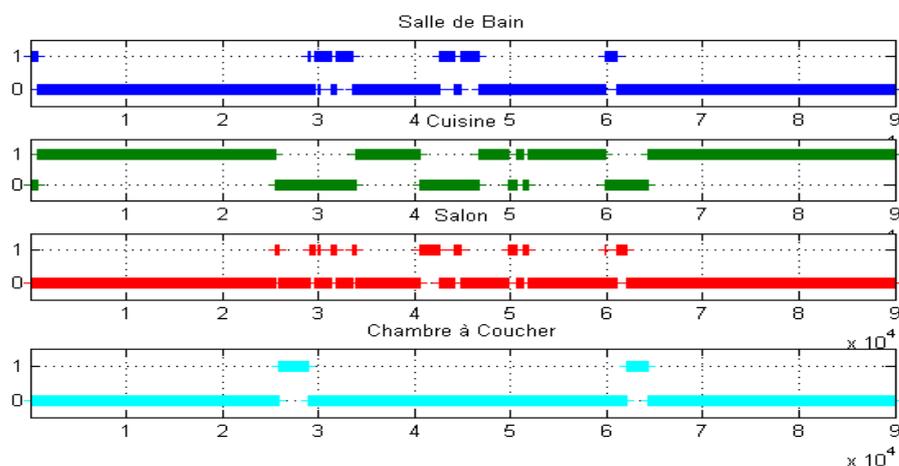


FIGURE 2.5 – Les états cachés du THHMM au niveau 2.

La figure 2.6 présente l'observation de ces états tout au long d'une journée ($\simeq 86400$ secondes). A l'aide de la séquence d'observation O , le comportement de la personne par endroit peut être estimé comme nous le montre la figure 2.7 en utilisant la matrice de transition A et la matrice initiale π . Afin de bien comprendre le processus de modélisation du langage EBRADL par le modèle THHMM, nous

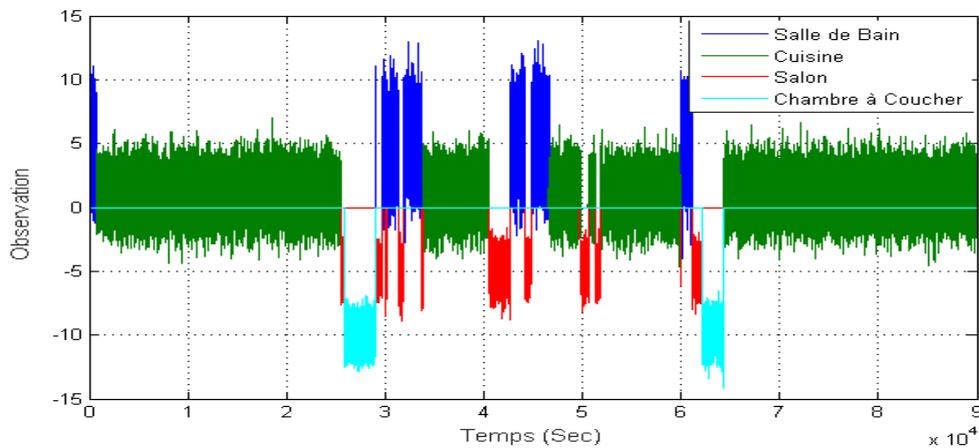


FIGURE 2.6 – Observation des états cachés par THHMM au niveau 2.

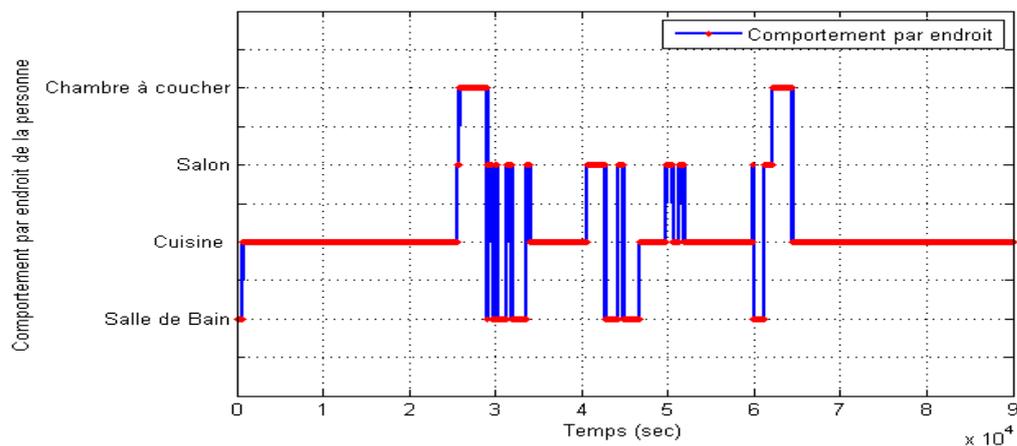


FIGURE 2.7 – Comportement de la personne par endroit.

allons prendre comme exemple de suivre une personne qui appartient à la catégorie 1 de notre langage et qui exige une description spécifique du scénario soit le niveau de description 1 qui est *# la personne # est dans l'endroit # entrain de faire l'activité #*.. Nous nous intéressons à l'endroit *cuisine* et nous souhaitons reconnaître et prédire le scénario qui correspond à l'état cuisine dans le niveau 2 de l'hierarchie du modèle THHMM. Comme indiqué dans la figure 2.3, il existe trois sous états qui représentent les activités de la cuisine dans le niveau 3 qui sont : préparer le repas, laver les vaisselles et Utiliser Objet. Un lien direct relie l'état de l'activité "préparer le repas" et l'état "cuisine". Concernant les deux autres états, ils sont liés à l'activité "préparer le repas" et sont exécutés par le déclenchement

de l'état "préparer le repas".

Le résultat de modélisation est représenté dans les figures 2.8, 2.9 et 2.10. La figure 2.8 montre les états cachés obtenues par le modèle THHMM associé à l'état cuisine. la première courbe présente l'activité nommée « Utiliser Objet », la courbe 2 présente l'activité « laver les vaisselles » et la courbe 3 présente l'activité « préparer le repas » en fonction du temps. La figure 2.9 présente l'observation de ces états dès l'exécution de l'activité « préparer le repas ». La figure 2.10 présente le scénario de l'activité « préparer le repas », ce qui nous permet de conclure le scénario suivant :

La personne entre à la cuisine pour préparer le repas, en premier temps l'activité "utiliser objet" est déclenchée (l'objet peut être l'un des objets listé dans le tableau 2.7). Par la suite, l'activité "préparer le repas" est exécutée, puis l'activité "utiliser objet" est déclenchée une autre fois, un retour à l'activité "préparer le repas" a lieu une deuxième fois. Enfin l'activité "laver la vaisselle" est exécutée.

Puisque la personne appartient à la catégorie 1 (niveau de description = niveau 1), notre modèle considère le résultat de reconnaissance suivante :

La personne # est dans la cuisine # en train de utiliser objet# à t=1#
#préparer le repas# à t= 2#
Utiliser Objet # à t= 3#
préparer le repas # à t= 4#
laver les vaisselles# à t= 5#.

2.5.2.2 Prédiction du Comportement

La prédiction de scénarios est une tâche très importante dans le cadre d'un système de surveillance à domicile. L'objectif est de prédire les activités à l'avance et d'intervenir en cas de changement de comportement ou en cas d'urgence. La prédiction permet également de mettre à jour les informations de profil de l'habitant dans le cas d'un changement notable. Dans la suite, nous évaluons la précision de la prédiction de notre modèle THHMM. La figure 2.11 et 2.12 présentent les résultats de la prédiction relative au comportement prédit par le modèle THHMM au niveau 2 (endroit) et au niveau 3 respectivement en fonction du comportement réel. La courbe en bleu présente le comportement réel et celle en rouge présente le comportement estimé par le modèle THHMM dans les deux figures 2.11 et 2.12. Les résultats de simulation pour l'interprétation du comportement de la personne en utilisant THHMM durant une journée (2.11) montre que le comportement es-

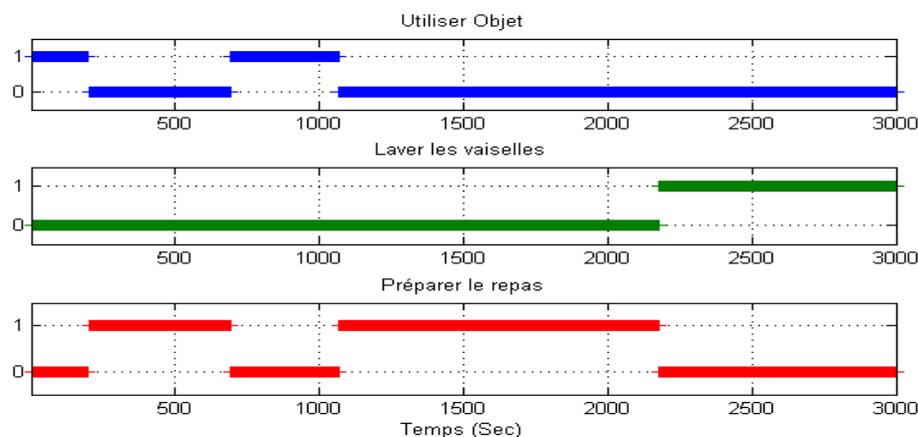


FIGURE 2.8 – Les états cachés des activités associées à l'état "cuisine" obtenues par THHMM au niveau 3.

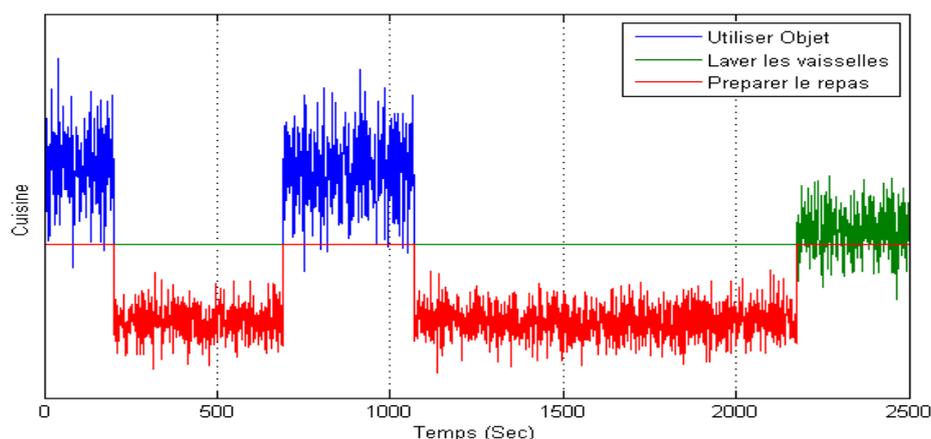


FIGURE 2.9 – Observation des activités associées à l'état "cuisine" obtenues par THHMM au niveau 3

timé par le modèle THHMM semble correspondre au comportement réel de la personne. La même constatation s'applique aux résultat de la figure 2.12.

Dans le cadre du maintien à domicile, le critère du temps est très important afin de détecter la présence d'un changement comportemental ou d'un état anormal, en particulier pour les personnes dépendantes. Le temps passé dans chaque espace ainsi que le temps passé pour réaliser une activité peut aider à modéliser des comportements qui concernent l'habitude de la personne et distinguer des chan-

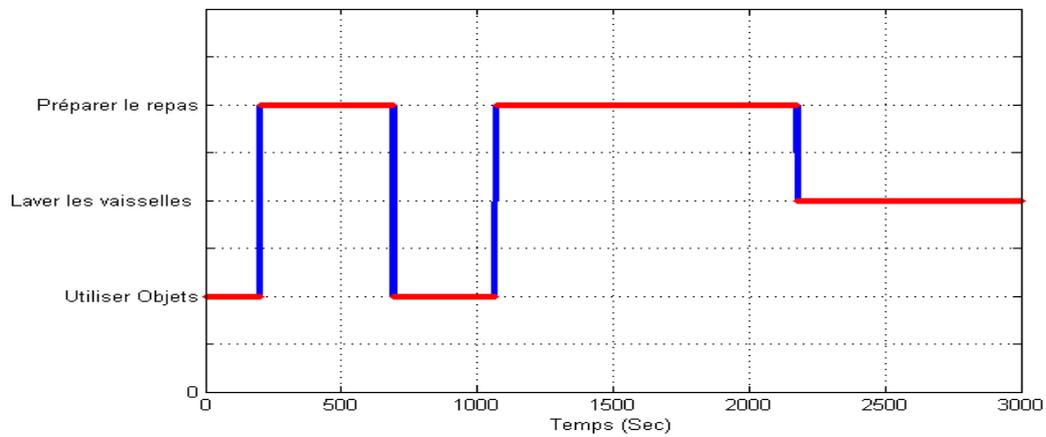


FIGURE 2.10 – Le comportement de la personne dans la cuisine.

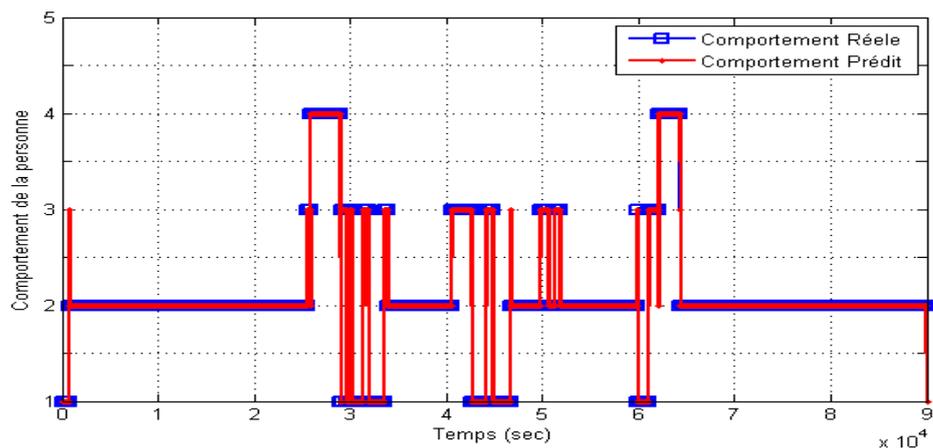


FIGURE 2.11 – Le comportement prédit et le comportement réel obtenu par THHMM au niveau 2.

gements en fonction de ces habitudes. Ces informations peuvent être utilisées à des fins médicales (par exemple pour le suivi de l'autonomie de la personne ou pour distinguer des maladies telles que Alzheimer, diabète, dépression, etc.). De ce fait, notre modèle comportemental THHMM est basé sur le critère temporel. La figure 2.13 présente les résultats de prédiction du temps passé dans chaque endroit obtenus par le modèle THHMM au niveau 2. Chaque courbe présente le temps réel ainsi que le temps estimé pour chaque état (Salon, Cuisine, Salle de bain, Chambre à coucher) tout au long d'une journée. La courbe bleue présente le temps réel, celle en rouge présente le temps estimé. Les résultats de simulation

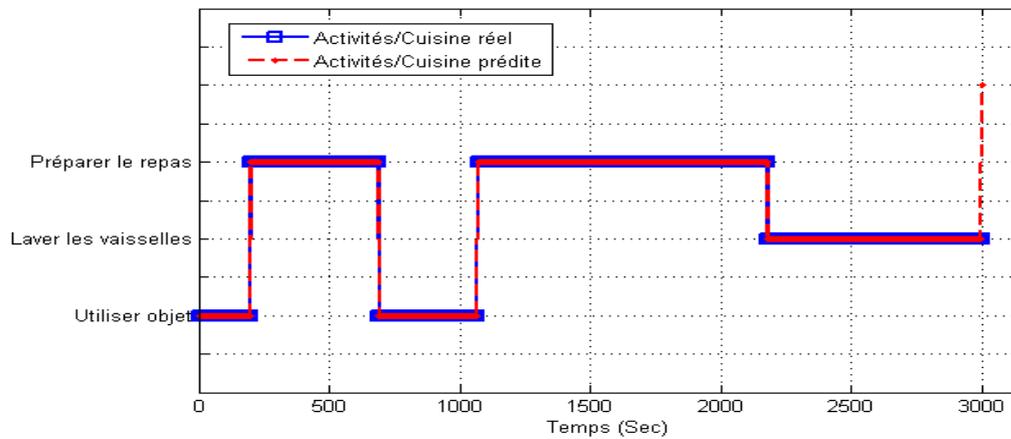


FIGURE 2.12 – Prédiction des activités associées à l'état "cuisine" obtenu par THHMM au niveau 3.

montrent que le temps estimé par le modèle THHMM pour chaque état semble correspondre au temps réel passé dans chaque endroit. La figure 2.14 présente les résultats de prédiction du temps passé pour exécuter chaque activité associée à l'état "cuisine" obtenue par THHMM au niveau 3. Elle présente trois courbes, chacune présente les activités de la cuisine qui sont : "utiliser objets", "laver la vaisselle" et "préparer le repas". La courbe bleue présente le temps réel, celle en rouge présente le temps estimé. Dans la figure 2.14, nous pouvons observer que le temps estimé par le modèle THHMM pour chaque état semble correspondre au temps réel passé pour chaque activité.

2.6 Évaluations de performance

Dans cette partie nous évaluons l'exactitude du modèle THHMM basé sur le langage EBRDAL. Notre objectif est d'identifier la capacité de THHMM en termes de précision de la prédiction et du temps de calcul. Nous allons évaluer l'erreur de prédiction, l'RMSE "Root Mean Square Error" et le pourcentage d'erreur par état au cours de la phase de prédiction afin d'évaluer les performances de notre modèle. La figure 2.15 présente l'erreur de prédiction en fonction du temps de notre modèle THHMM durant une journée. Les résultats d'évaluation montrent un taux minimal d'erreur. Cependant, cela n'est pas suffisant pour confirmer la précision de prédiction de notre modèle. Par conséquent, nous évaluons l'RMSE, le tableau 2.8 présente l'RMSE durant 10 jours ainsi que la moyenne. La moyenne de RMSE est environ $9.6392 \cdot 10^{-2}$ par jour ce qui confirme la précision du THHMM.

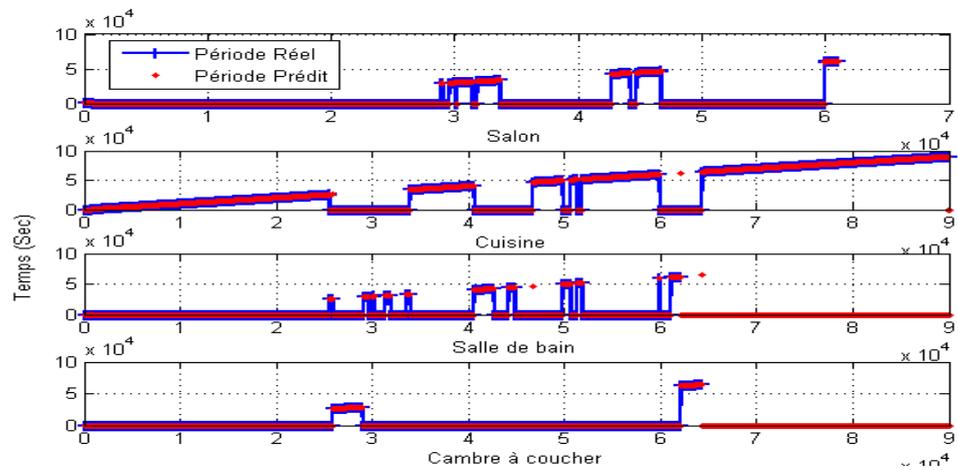


FIGURE 2.13 – Le temps réel et le temps prédit pour chaque état (Salon, Cuisine, Salle de bain et chambre à coucher) obtenu par THHMM durant une journée.

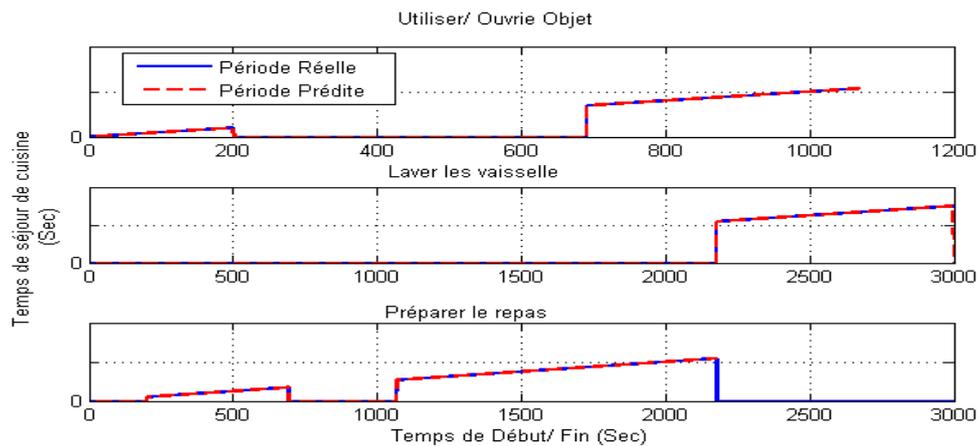


FIGURE 2.14 – Le temps réel et le temps prédit pour chaque état ("préparer le repas", "laver la vaisselle" et "utiliser objet") pour n=3.

Par la suite nous nous sommes intéressés à l'évaluation du pourcentage d'erreur de chaque état du « niveau 2 de la hiérarchie » qui sont "la chambre à coucher", "la salle de bain", "le salon" et "la cuisine". La figure 2.16 présente le pourcentage d'erreur pour chaque état appartenant au niveau 2 dans la phase de prédiction. Nous obtenons une valeur de 0.2 pour l'état "salle de bain", le pourcentage d'erreur est approximativement 0.5 pour la cuisine, 0.44 pour le salon et 0.31 pour la chambre à coucher. Concernant le niveau 3 de la hiérarchie (niveau activités) et

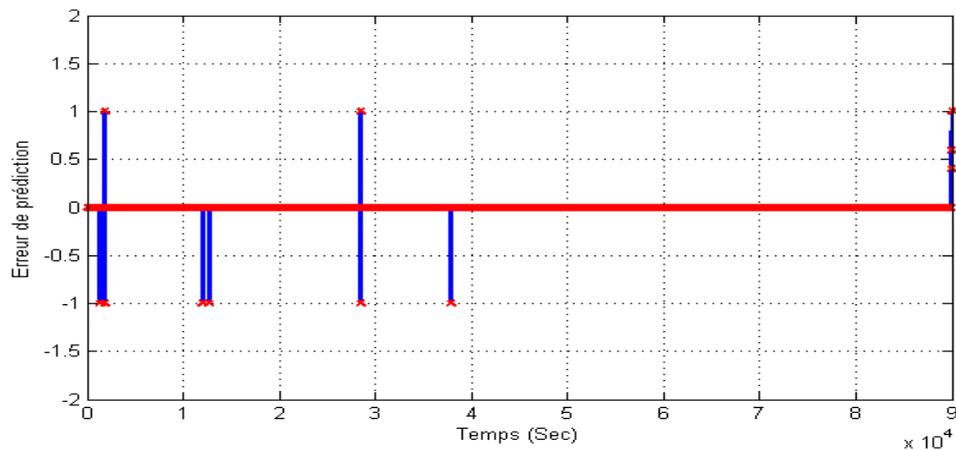


FIGURE 2.15 – Erreur de prédiction en fonction du temps.

TABLE 2.8 – RMSE par jour

Jour	RMSE
J1	$8.916 * 10^{-2}$
J2	$9.540 * 10^{-2}$
J3	$9.065 * 10^{-2}$
J4	$8.945 * 10^{-2}$
J5	$9.740 * 10^{-2}$
J6	$9.073 * 10^{-2}$
J7	$9.508 * 10^{-2}$
J8	$8.875 * 10^{-2}$
J9	$8.817 * 10^{-2}$
J10	$9.639 * 10^{-2}$
Moyenne	$9.2118 * 10^{-2}$

plus précisément les états associés à l'état cuisine, le pourcentage d'erreur est 0.03 pour l'état « Utiliser Objet », 0.06 pour l'état « laver les vaisselles » et 0.12 pour l'état « préparer le repas » (Figure 2.17).

Le temps de calcul est un critère aussi important pour la surveillance à distance. En effet, la rapidité du modèle de prédiction influence directement la qualité de service d'une application de surveillance. Partant de ce principe et vu qu'un système de surveillance exige un suivi à long terme nous évaluons le temps de calcul du modèle THHMM au cours de différentes périodes.

La figure 2.18 représente le temps de calcul de notre modèle pendant différentes

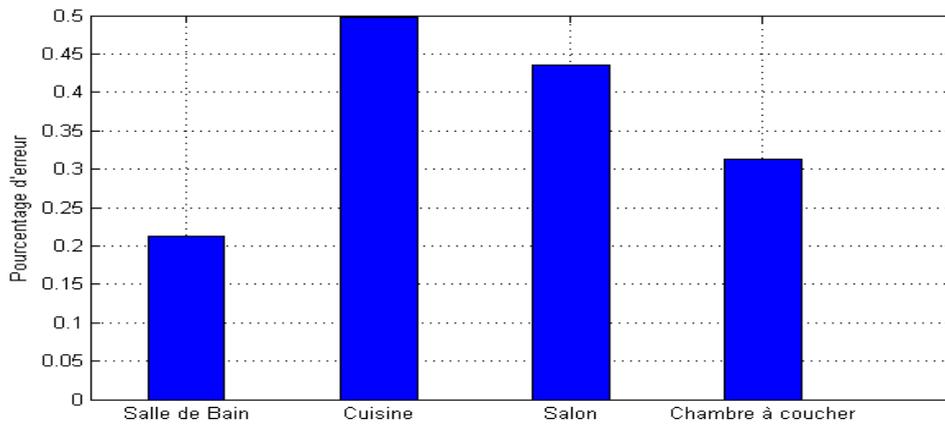


FIGURE 2.16 – Erreur de prédiction en fonction de l'état (niveau 2).

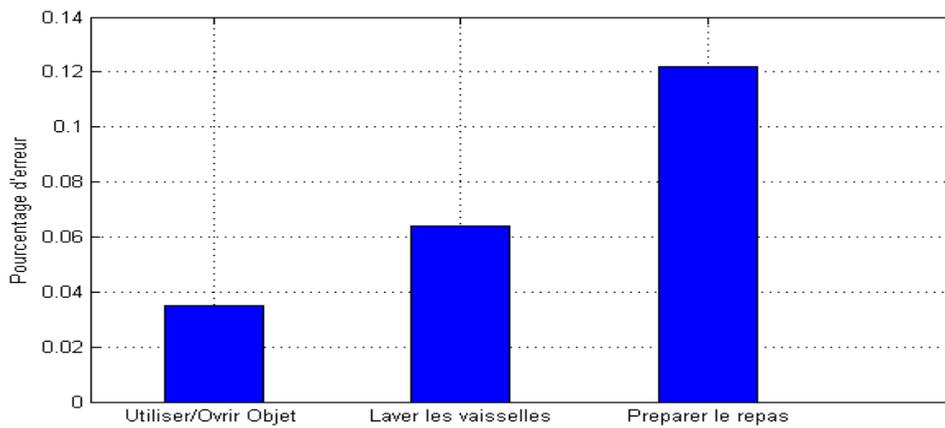


FIGURE 2.17 – Erreur de prédiction en fonction de l'état (niveau 3).

périodes, cette figure montre que le temps de calcul augmente d'une manière remarquable en fonction de la période de surveillance.

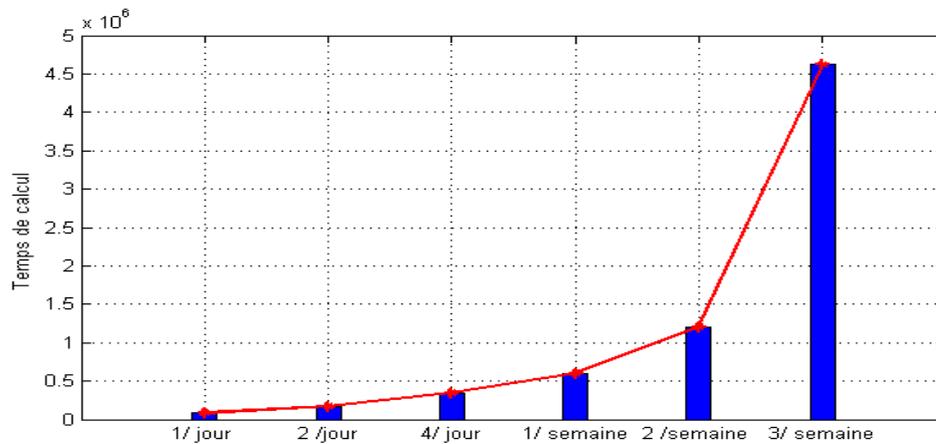


FIGURE 2.18 – Temps de calcul de THHMM pendant différentes périodes.

2.7 Conclusion

Dans ce chapitre, nous avons proposé un langage de reconnaissance nommé Elderly by Room Activities Description Language (EBRADL), basé sur les ADLs, les IADLs, le profil, les contraintes et les règles. Il est inspiré des notions de base des langages naturels, tout en respectant une logique entre la personne, l'espace et l'objet. EBRADL se compose de six instructions de base qui sont : *identifier le domaine de connaissance, identifier le champ lexical/ vocabulaire, analyser le vocabulaire (les termes), recenser les termes du vocabulaire et normaliser leurs sens, identifier les concepts, les relations et les contraintes, construire une structure/hierarchie qui représente le langage*. Notre objectif est d'avoir une reconnaissance appropriée et pertinente des activités quotidiennes de la personne dans son espace. En fait, notre langage sert à offrir une compréhension et une caractérisation spécifique et claire des activités quotidiennes selon le niveau d'autonomie de la personne. De plus, nous avons réussi à réaliser une formalisation standard de l'information contextuelle qui représente le comportement de la personne. Le langage EBRADL se caractérise par deux critères de base qui sont la structure hiérarchique et la notion temporelle, alors une modélisation pertinente nécessite un modèle qui répond aux besoins de ces caractéristiques. A ce propos nous avons proposé un modèle markovien, basé sur le modèle de markov hiérarchique (HHMM) et le modèle de semi-markovien (HSMM), intitulé "Temporal Hierarchical Hidden Markov Model (THHMM)". Ce modèle caractérisé par sa structure hiérarchique et par une notion temporelle qui tient compte de la durée passée dans chaque état. Les résultats de simulation montrent que le modèle proposé offre des résultats efficaces de point de vue précision comme le montrent les RMSE obtenues pendant 10 jours. Même si les

résultats de notre modèle THHMM semblent intéressants, il reste encore quelques lacunes à résoudre telles que :

- La difficulté du traitement des données sensorielles de bas niveau.
- Le nombre d'état devrait être connu à l'avance. Le modèle ne s'adapte pas aux données.
- La prédiction à long terme exige une complexité de calcul.

Pour surmonter ces défis et afin d'avoir un système de surveillance plus pertinent, plus efficace et plus rapide, nous proposons dans le chapitre suivant un modèle de prédiction basé sur les réseaux de neurones.

CHAPITRE 3

Une approche hybride pour l'application et
l'évaluation des réseaux de neurones pour les
services e-santé

3.1 Introduction

La sensibilité au contexte représenté par les activités quotidiennes aide à prédire les futurs comportements irréguliers à partir d'une routine quotidienne et l'absence inhabituelle d'une activité pendant une longue période [27]. Par conséquent, il est essentiel de concevoir un système robuste capable de surveiller les activités quotidiennes des personnes âgées. Vu que la surveillance de santé à domicile est un domaine sensible qui nécessite des connaissances précises, adéquate, et une exécution rapide des services, nous allons nous concentrer sur la proposition d'un modèle de prédiction pertinent qui tient compte du profil de la personne dans le but de surmonter les contraintes liées à la reconnaissance statistique basée sur le modèle Markovien et d'offrir une meilleure surveillance à long terme.

La reconnaissance des activités, mouvements, niveau de l'autonomie et de l'état de santé de la personne sert à améliorer la modélisation comportementale de l'habitant. Elle permet d'incorporer une différenciation du comportement à long terme, c'est-à-dire détecter le changement de routine, le changement d'habitude, de l'autonomie, de l'état de santé et d'assurer une surveillance efficace. En plus, la plus part de ces changements concernent des actions très importantes qui peuvent affecter la vie quotidienne de la personne (le confort, la confiance en soi, la joie de vivre, etc.). Par conséquent, il est crucial de modéliser le comportement habituel de la personne dans le but de reconnaître des situations anormales en temps réel (chute, vertige, etc.) et de prédire les changements comportementaux pour intervenir en temps opportun.

Dans ce chapitre, nous allons nous focaliser sur les modèles de l'intelligence computationnelle, dans ce cas nous allons proposer des approches hybrides basées sur les réseaux de neurones artificiels et les algorithmes méta-heuristiques pour améliorer la phase de prédiction du comportement. Au début de ce chapitre, nous allons présenter les données utilisées au fil de notre travail. Par la suite, nous allons définir la notion de la prédiction qui se base sur les approches de l'intelligence artificielle, puis nous allons examiner les problématiques et les défis des réseaux de neurones classique. Enfin, nous allons proposer une solution hybride dont le rôle est d'améliorer la qualité de prédiction pour offrir un service performant et approprié.

3.2 Description et présentation des données

Pour concevoir un système de surveillance capable de suivre avec précision les activités de la vie quotidiennes, reconnaître et prédire les changements comporte-

mentaux des personnes âgées, un modèle comportemental généré par le système qui représente ces activités est la base d'une surveillance adaptable et appropriée.

Un système de surveillance de santé à domicile se compose de trois parties : [196, 197] :

- Le réseau de capteurs pour la collection et l'envoi des données.
- L'évaluation des données : le pré-traitement, la reconnaissance et la prédiction.
- La réaction du système : les services fournis en fonction des informations obtenues (les besoins de l'habitant).

En outre, pour évaluer les informations détectées par les capteurs il est nécessaire de suivre des scénarios de manière réaliste pour être aussi proche que possible de la vie réelle. Par ailleurs, l'utilisation des scénarios réels pour une longue période permet d'évaluer la routine de la personne, le suivi à long terme, la reconnaissance des troubles de santé et la perte d'autonomie chez les personnes âgées. Dans les sous sections suivantes, nous allons nous intéresser à définir, à présenter et à traiter les données utilisées dans cette thèse.

3.2.1 Description des données

Une maison intelligente est un environnement intelligent équipé d'un grand nombre d'outils intelligents tels que les capteurs, les actionneurs et les composants informatiques pour suivre le comportement de la personne. De nombreux chercheurs qui utilisent un environnement réel dans leurs recherches ont remarqué que la gestion de tels environnement est difficile, compliquée et coûteuse. En effet, les plateformes réelles nécessitent des implémentations complexes y compris un nombre important de capteurs utilisés pour avoir une base de données riche des activités quotidiennes. En outre, nous avons besoin de grands échantillons de données afin de choisir et de justifier les meilleures techniques à des fins de prédiction dans un environnement intelligent. Ainsi, il serait préférable de simuler un environnement réel et de générer des données en réduisant les coûts de matériel [198]. La génération des scénarios simulés basés sur les activités de la vie quotidienne peut fournir suffisamment de données pour faciliter la conception et la validation des approches définies pour les maisons intelligentes et les systèmes de surveillances à domicile. Afin d'évaluer l'efficacité de notre système prédictif proposé, il faut l'expérimenter avec une série de scénarios riches et réalistes qui décrivent les activités de la vie quotidienne. A cette fin, dans ce manuscrit, les données utilisées pour appliquer et évaluer notre approche proposée sont les données générées dans [3], dans lesquelles le simulateur imite le comportement d'un occupant habite seul dans un environnement intelli-

gent en générant un signal comportemental.

Comme discuté dans [3], les ensembles de données générés repose sur un modèle markovien pseudo-variable. Les scénarios sont développés en utilisant l'environnement Matlab. Les ensembles de données décrivent le comportement de la personne surveillée, les scénarios générés incluant des séquences d'activités réalisées pendant une année entière par les personnes âgées ayant des niveaux de dépendance différents. Dans [3], les chercheurs ont proposé la simulation de deux types de scénarios :

Premier scénario : un scénario d'une personne autonome appartenant au profil P1 du modèle SMAF (Personne-Cas 1).

Deuxième scénario : un scénario d'une personne avec des changements de profil représentant la perte des capacités de la personne (Personne-Cas 2).

Le tableau 3.1 récapitule les deux cas en fonction du profil SMAF et des types des activités considérées.

TABLE 3.1 – Les caractéristiques des deux cas proposés dans [3].

	Profil de SMAF	Autonomie	Classe des Activités
Personne-Cas 1	P1 durant une année	Autonome	ADL, IADL, Mobilité
Personne-Cas 2	P1 pendant les 3 premiers mois	Non autonome	
	P3 du mois 4 jusqu'a 6		
	P6 du mois 7 jusqu'a 9		
	P9 jusqu'a la fin de l'année		

Plus précisément, les scénarios générés dans [3, 199] se composent de 22 activités de haut niveau, décrivant le comportement quotidien de la personne dont chacune peut être composée de différentes actions. Les activités et les actions envisagées représentent les trois classes de SMAF qui sont :

ADL : Manger, s'habiller, se laver, faire sa toilette (se laver les mains / visage, se sécher les cheveux et se maquillager).

IADL : Toilette, ménage, lessive/ linge, préparation des repas (cuisiner, préparer du thé, faire un sandwich, préparer de la nourriture chaude, déplacer le plat, laver la vaisselle, etc.).

Mobilité : Utiliser le téléphone, prendre des médicaments, marche/s'arrêter / sortir, regarder la télévision, lire et dormir.

Remarque : les autres classes d'activités de SMAF qui sont la communication et les fonctions mentales sont déduite en fonction de la capacité de la personne à réaliser les activités précédentes.

3.2.2 Présentation des données

Ce travail de recherche s'est déroulé dans le cadre d'une application de télésurveillance médicale ayant pour but de surveiller un habitant à travers l'utilisation de plusieurs types de capteurs. Les données hétérogènes issues de plusieurs capteurs peuvent fournir des informations volatiles, irrégulière et bruitées, elles peuvent posséder différents degrés d'imperfection. De ce fait, la modélisation des informations issues des capteurs est un problème à évaluer à des fins de prédictions. La prise en compte de l'imperfection présente dans les informations de notre système permet une modélisation plus réaliste du problème. Les informations recueillies à partir des capteurs dans un habitat intelligent sont considérées comme des séries temporelles (chronologiques). Généralement, la modélisation de ces séries exige la collecte des données, l'analyse des caractéristiques et leurs relations avec les séries en question pour produire un modèle efficace de point de vue prédiction.

Comme nous l'avons déjà mentionné, les données utilisées dans ce travail sont des données réellement recueillies à partir du projet "e-Health Monitoring Open Data project" [3], c'est un projet dédié aux personnes âgées dans le cadre d'une surveillance à domicile de la santé. Ce projet fournit un ensemble d'activités et d'actions réalisées par l'occupant dans l'ordre chronologique. Les données représentent les activités définies dans le modèle gériatrique SMAF[200]. Les données fournies décrivent des scénarios de la personne tout au long de l'année. Dans notre travail, nous allons nous baser sur ces informations pour implémenter et évaluer nos approches proposées. Un exemple des activités utilisées dans ce travail est résumé dans le tableau 3.2. Chaque activité est identifiée par son nom, les actions et un code spécifique.

Par la suite, nous allons traiter les scénarios habituels/quotidiens pour construire un modèle comportementale des personnes âgées qui sera utilisé pour prédire les activités futures. Les activités et les actions réalisées par l'habitant sont représentées sous forme d'une relation temporelle [jour, temps-début- temps-fin, code d'activité]. Le tableau 3.3 illustre un exemple de données recueillies utilisé dans notre thèse. Les données collectées sont traitées et transformées en un format de série temporelle continue.

TABLE 3.2 – Les activités / actions de la vie quotidienne.

Activité	Action	Code
Alimentation	Se nourrir	1
Habillage	S'habiller	2
Toilette	Se laver	3
Toiletage	Se laver les mains et le visage , Se sécher les cheveux, Déplacer le plat, Maquiller	4, 5, 34, 6
Élimination urinaire et fécale	fonction vésicale	7
Élimination urinaire et fécale	fonction anale	8
Élimination urinaire et fécale	faire sa toilette	9
Ménage	Entretenir la maison	10
Faire la lessive	avec la machine à laver	11
Préparer les repas	Laver les plats, Faire du café, Faire un thé , faire un sandwich, faire des aliments chauds	11, 13, 14, 15, 16
Téléphone	Utilisation du téléphone	17
Suivi du traitement	Prendre ses médicaments	18
Regarder la télévision	regarder la TV	19
Dormir	Sommeil	24
Sortir	Sortir	33
Lecture	lire un livre	35

TABLE 3.3 – Un exemple de données collectées à partir d'une maison intelligente.

Jour	Heure de Début	Heure de Fin	Code d'activité
01	08 : 03 : 32	08 : 22 : 40	3
01	08 : 23 : 46	08 : 26 : 53	5
01	08 : 28 : 50	08 : 38 : 39	2
01	08 : 40 : 37	08 : 50 : 24	9
01	08 : 52 : 12	08 : 55 : 38	4
01	08 : 57 : 36	09 : 05 : 53	13
01	09 : 07 : 38	09 : 12 : 52	4
01	09 : 13 : 57	09 : 21 : 10	15
01	09 : 23 : 08	09 : 43 : 11	1
01	09 : 46 : 00	09 : 55 : 21	14
01	09 : 56 : 45	10 : 03 : 03	9

Pré-traitement des données

La sensibilité d'un système de surveillance à domicile exige un traitement bien étudié des données utilisées pour suivre le comportement quotidien de la personne.

Cette phase, appelée « pré-traitement des données » est consacrée au traitement des données brutes collectées à partir de différentes sources existant dans l'environnement intelligent (la maison) afin de fournir une meilleure présentation des données. La phase de pré-traitement se compose de trois étapes principales qui sont : la collection des données, la conversion et la normalisation. La figure 3.1 présente le processus de pré-traitement des données.

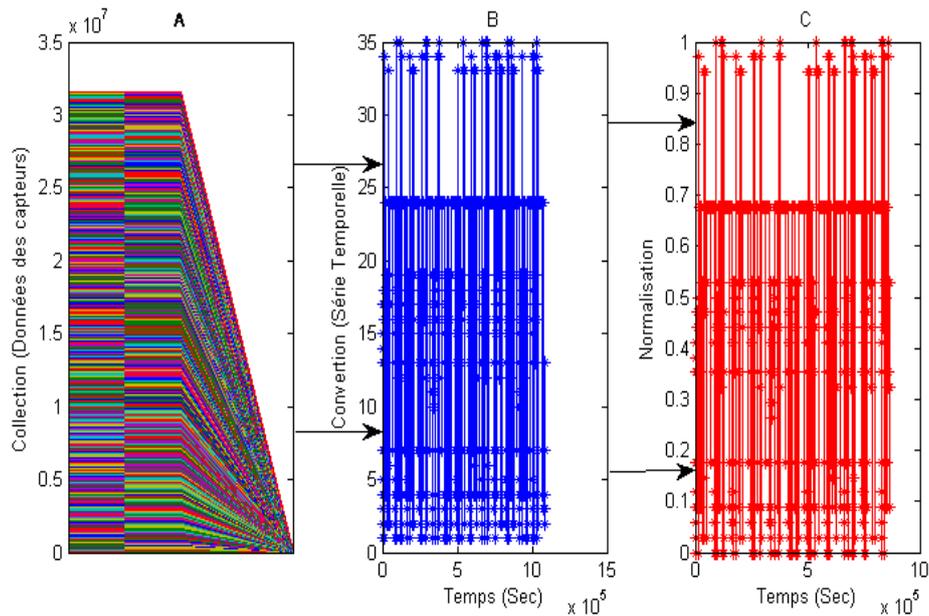


FIGURE 3.1 – Étape de prétraitement

Collection des données

Les capteurs placés dans une maison intelligente ont des niveaux différents d'intelligence. Au niveau le plus bas, les informations collectées sont transformées en signaux électriques, numérisés à partir des signaux analogiques et envoyés aux microcontrôleurs pour le traitement.

La figure 3.1.(A) montre la structure du signal collecté par les capteurs. Dans cette figure nous pouvons observer qu'à partir des mesures initiales collectées par les différents capteurs de comportement, il est difficile de comprendre (c.-à-d. identifier et extraire) le scénario réel et le comportement des personnes âgées. Pour cette raison, une structuration adéquate et claire des données est une étape nécessaire dans le processus de pré-traitement.

Conversion des données

La conversion des données réelles détectées par les capteurs en séries temporelles nous permet d'obtenir des observations intelligibles qui ont été capturées à des intervalles de temps réguliers. L'analyse des séries temporelles en question consiste à *prédire et à modéliser le comportement de la personne*. L'objectif de la prédiction est de prévoir avec précision l'évolution à court terme de séries temporelles. La modélisation vise aussi la détermination des caractéristiques du comportement à long terme. La caractérisation a comme but de déterminer les propriétés fondamentales d'une série temporelle. Formellement, une séquence de vecteurs en fonction du temps t est dénotée par :

$$x(t), \text{ avec } t = 0, 1, 2, \dots$$

Pour des raisons théoriques, x est présenté comme une fonction continue de la variable de temps t .

Typiquement, ces séries représentent les changements d'un objet mesuré dans un intervalle de temps connu dont la taille dépend habituellement du problème [201, 202]. Le but principal de l'analyse des séries temporelles est de développer certaines techniques de prédiction. En d'autres termes, le problème de la prédiction des séries chronologiques peut être énoncé comme suit : étant donné une suite $x(1), x(2), \dots, x(t)$ jusqu'au temps t , on doit déterminer la suite $[x(t+1), x(t+2), \dots]$. La caractéristique principale des séries temporelles est qu'elles peuvent être représentées sur la base de la séquence originale par des valeurs qui peuvent être répétées plusieurs fois sans maintenir aucune périodicité finie [203, 204]. Dans notre étude, une série temporelle est une succession d'événements (e_1, e_2, \dots, e_n) associés à une séquence temporelle (t_1, t_2, \dots, t_n) , voir figure 3.1.(B).

Pour convertir les mesures des capteurs sous forme d'une série temporelle, nous nous concentrons sur la détermination des durées d'activités. Tout d'abord, les données sont converties en fonction des valeurs de début et de fin de l'activité. L'algorithme 1 est proposé pour extraire les séries temporelles des données représentant les activités de la vie quotidienne.

Le principal défi est de savoir comment nous pouvons traiter ces données temporelles, reconnaître le comportement habituel de la personne et prédire les prochaines activités. Avant de passer à la phase de reconnaissance et de prédiction, une troisième étape de la phase de pré-traitement est détaillée dans la section suivante.

Algorithm 1 Extraction de la série temporelle

```

% act = current activity/basic action ;
% {code act1, ..., code actn} = list of predefined codes of activities/actions ;
% MXData : table of data [start time, end time, code of activity]
% DurTab : table of successive sequences (traces) for each activity
1. Begin
2. var k=1 ;
3.   For i=1 :length(MXData(i :1)) % process the ith line of MXData table
      % process the 3rd column of MXData i.e. "code of activity" :
4.     act = MXData(i, 3)
5.     Switch(act)
6.       Case{code act1}
7.         Duration = MXData(i, 2) - MXData(i, 1);
8.         For j=1 :Duration
9.           DurTab(k) = act;
10.          k = k + 1;
11.        End For
12.       Case{code act2}
      :
13.     End
14.   End For
15. End

```

La normalisation des données

Pour obtenir une meilleure représentation et pour faciliter la mémorisation des données en évitant la redondance et les problèmes sous-jacents de mise à jour, une normalisation est effectuée sur les séries temporelles qui représentent le comportement de la personne. Il existe plusieurs techniques de normalisation telles que la normalisation par la méthode Min-Max, par la méthode Z-Score, par une fonction quadratique-linéaire-quadratique (QLQ), par une fonction double sigmoïde, etc.

Dans notre travail nous allons utiliser la méthode Min-Max pour normaliser les entrées. La normalisation Min-Max conserve la distribution de données originales à un facteur d'échelle près et transforme toutes les données dans l'intervalle [0,1]. Les valeurs des données sont normalisées par l'équation (3.1).

$$x_n = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.1)$$

Avec x est la valeur actuelle ; $\max(x)$ est la plus grande valeur de l'ensemble d'entrée, et $\min(x)$ est la plus petite valeur de l'ensemble d'entrée. La figure 3.1.(C) présente les données normalisées qui représentent le comportement de la personne.

A partir de la phase du pré-traitement, les informations et les connaissances détectées par les capteurs sont désormais prêtes pour modéliser et évaluer le comportement de la personne. Typiquement, prévoir l'évolution et le changement de l'autonomie de la personne à partir de leurs routines et de leurs activités quotidiennes, nécessite des techniques et des outils robustes pour la reconnaissance et la prédiction de séries temporelles. Dans ce qui suit, nous allons effectuer une étude détaillée sur la reconnaissance et la prédiction du comportement de la personne dans le but de proposer une approche pertinente et efficace qui sert à améliorer la qualité de la prédiction dans le cadre d'une maison intelligente pour les services e-santé.

3.3 Principe de reconnaissance et de prédiction du comportement

Dans le cadre d'une maison intelligente pour l'e-santé, il est essentiel de développer une bonne compréhension du comportement normal et de distinguer les activités anormales et les changements notables de comportement. Le modèle de détection du comportement anormal devrait détecter le changement comportemental en fonction de la routine quotidienne de l'activité et du scénario en tenant compte des relations temporelles entre les activités.

Par exemple, dans une maison intelligente :

Si la porte du réfrigérateur n'a jamais été ouverte par l'occupant pendant toute une journée, ce comportement est considéré comme anormal (s'il ne reflète pas les habitudes de la personne) et une alarme pourrait être envoyée au soignant.

Si l'occupant ouvre le robinet de la salle de bain et ne le ferme pas avant de se coucher, le soignant devrait être informé. Si possible, le contrôleur intelligent à domicile devrait interférer et fermer le robinet.

Si l'occupant habituellement dort 7 heures pendant la nuit, et s'il ne le fait pas (il dort beaucoup moins), ce comportement peut être considéré comme un comportement anormal.

Le problème de la reconnaissance et de la prédiction des comportements anormaux / surprenants / nouveaux est très intéressant surtout quand nous parlons de systèmes de surveillance de santé à domicile pour les personnes âgées.

En surveillant les données des capteurs, des informations importantes concernant tout comportement irrégulier (ou anormal) peuvent être identifiées. Les scénarios anormaux correspondent à l'ensemble des reconnaissances qui ne suivent pas un comportement normal. Les activités anormales, les changements comportementaux et les changements de l'autonomie peuvent être reconnus en utilisant différentes techniques de reconnaissance et de prédiction.

Dans cette partie, nous allons nous concentrer sur l'amélioration de la qualité de surveillance qui concerne les personnes âgées dans le but de suivre leurs niveaux d'autonomies (état de santé), leurs comportements (concernant les ADLs et les IADLs) et de détecter la présence d'un cas urgent (chute, oublier le robinier ouvert, etc). En général, les systèmes de surveillance à domicile se basent sur trois caractéristiques qui sont :

- La qualité de prédiction (QP),
- La qualité de service (QS) et
- La qualité de vie de la personne (QV).

La qualité de prédiction précise la qualité de service du système et par conséquent la qualité de vie du patient. La figure 3.2 montre les liaisons verticales entre les trois caractéristiques de base d'un système de surveillance performant et réussi. Cette relation montre l'importance de la prédiction dans le cadre d'un système de surveillance à domicile.

L'interprétation des données nous aide à mieux comprendre les activités quotidiennes, suivre l'autonomie de la personne et détecter les comportements anormaux lorsqu'une activité anormale s'est produite. Cela serait également utile pour générer une base de connaissance basée sur les activités habituelles du patient pendant une longue période de temps. En générale, un système de surveillance à domicile se compose de deux processus de base qui sont le processus interne et le processus externe (voir figure 3.3).

Processus interne :

Le processus interne présente les tâches réalisées dans l'environnement (la maison/ les chambres) par le système (détection, extraction, identification, etc.) en tenant compte de l'état de l'environnement ainsi que l'état et le profil de la personne.

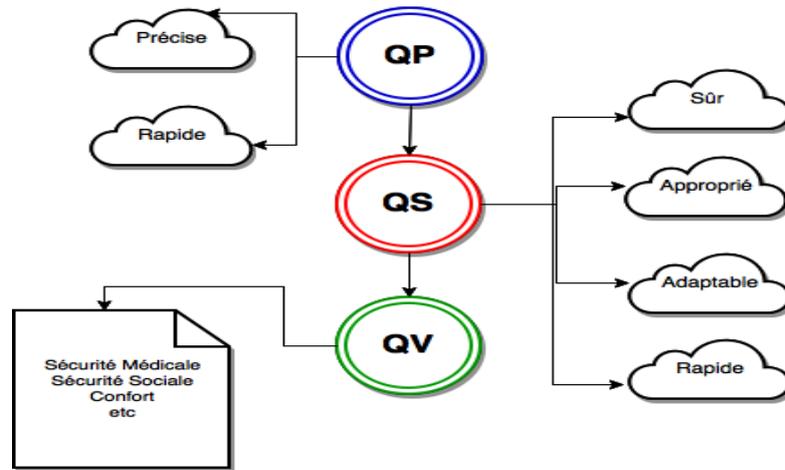


FIGURE 3.2 – les relations entre Qualité de prédiction (QP), Qualité de Service (QS) et Qualité de Vie (QV)

Processus externe :

Le processus externe présente les tâches réalisées par les observateurs concernant la personne et l'environnement (intervention/ alarme, etc) en tenant compte des informations et des reconnaissances détectées.

À partir de deux processus de base précédents, nous pouvons conclure que la qualité du service (service externe) du système de surveillance dépend d'une façon directe de la qualité du service du processus interne car c'est à base des connaissances détectées et prédites, que le processus externe réagit et fournit ces services. Un processus interne efficace et certain peut assurer une surveillance pertinente grâce à son impact sur les réactions et les services du système.

Par conséquent, pour améliorer la qualité du service d'un système de surveillance à domicile, une méthode prédictive pertinente est nécessaire pour prédire le comportement futur de la personne basée sur la base des connaissances historiques (routine/ habitude) et les informations personnelles de l'occupant disponibles et enregistrées dans la base de connaissance (profil/ état de santé/ âge).

En outre, à partir d'une prédiction précise du comportement habituel de l'habitant, nous pouvons suivre le mode de vie de la personne ainsi que son niveau d'autonomie et intervenir si nécessaire.

Dans ce chapitre, nous évaluons la pertinence des techniques prédictives comme une solution à la prédiction des séries temporelles continues représentant les ac-

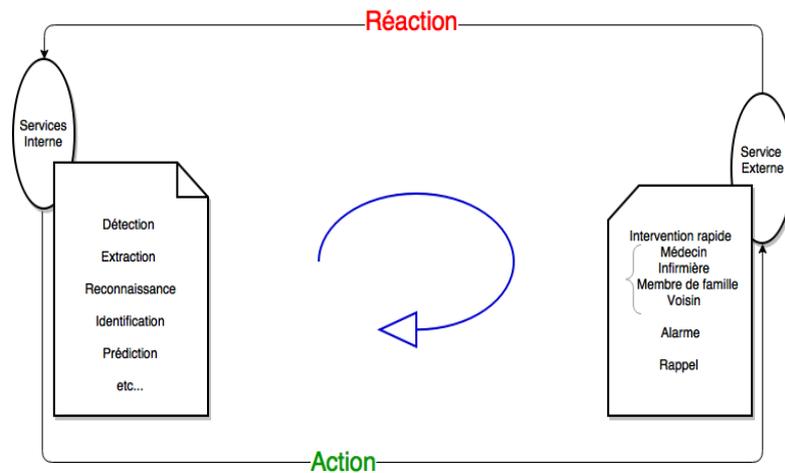


FIGURE 3.3 – la relation entre les services internes et les services externes dans le cadre d'un système de surveillance.

tivités quotidiennes d'une personne âgée dans une maison intelligente. Une large variété de techniques pour la prédiction des comportements et des ADL d'une personne existe dans la littérature. Dans la partie suivante, nous allons définir et examiner les modèles de prédiction utilisés dans la littérature, étudier leurs performances et leurs inconvénients. Par la suite, nous allons proposer un modèle de prédiction qui soit à la hauteur d'un système de surveillance de santé dans le but de surmonter les défis des modèles existants.

3.4 Modèles prédictifs

La prédiction est une tâche très sensible dans le domaine de e-santé. Elle sert à obtenir des informations relatives à l'évolution de l'état de santé de l'utilisateur et d'offrir au centre de surveillance la possibilité de prendre des mesures et des connaissances à l'avance.

De nombreuses techniques traditionnelles sont utilisées pour traiter les données de séries temporelles. Dans la plupart des cas, le signal est supposé être stationnaire et peut être décrit par un ensemble d'équations linéaires. Les modèles les plus connus sont : AR (autoregressive), ARX (AR with eXternal input series), VAR (vector autoregression), ARMA (AutoRegressive Moving Average), ARMAX (ARMA with eXternal input series), ARIMA (AutoRegressive Integrated Moving Average), ARIMAX (ARIMA with eXternal input series), et ARFIMA (AutoRegressive Fractionally Integrated Moving Average). Ces modèles de séries temporelles linéaires sont bien développés et largement utilisés. En outre, ils fournissent

une traçabilité et une facilité d'interprétation. En raison de la linéarité et de la simplicité des modèles existants, de nombreux problèmes complexes ne peuvent être mis en œuvre et de nombreuses caractéristiques des processus sous-jacents sont capturées sans succès. Cela conduit à des résultats insatisfaisants dans le cas d'une prédiction des problèmes complexes à long terme [205, 206].

Un nouveau domaine largement utilisé pour surmonter les défis des techniques traditionnelles est l'Intelligence Artificielle (IA). Ce domaine fournit la capacité humaine à effectuer des tâches telles que le raisonnement et l'apprentissage. Les recherches dans le domaine de l'IA sont concentrées sur la modélisation du contexte, la prédiction d'actions et l'extraction de fonctionnalités de mouvement à l'aide d'algorithmes d'apprentissage qui sont réalisés en utilisant des outils et des techniques de l'IA. L'apprentissage est une méthode utilisée par les applications omniprésentes afin de créer un environnement intelligent capable d'avoir des connaissances sur l'environnement et de réagir aux événements qui se produisent. Par conséquent, les systèmes intelligents représentent un bon candidat technologique pour résoudre les principaux problèmes d'un environnement intelligent. En effet, de nombreuses techniques d'apprentissage ont été utilisées pour prédire les activités quotidiennes humaines telles que les réseaux bayésiens, l'apprentissage flou, l'apprentissage par renforcement et les réseaux de neurones artificiels (ANN). Ce sont des modèles largement utilisés dans les systèmes de surveillance à domicile à fin de reconnaître, identifier et de prédire les données extraites par plusieurs capteurs [141, 164, 206–209]. Les résultats de ces recherches montrent que les réseaux de neurones semblent efficaces pour prédire les données à partir des données observées [210]. De la sorte, dans ce travail, nous proposerons d'utiliser un modèle basé sur les réseaux de neurones pour prédire le comportement de la personne âgée avec une excellente qualité de prédiction de point de vue précision et exactitude.

3.4.1 Réseau de neurones artificiels (RNA)

Les Réseaux de Neurones Artificiels (RNA) sont des méthodes non linéaires adaptées aux données et auto-adaptables qui ne nécessitent pas d'hypothèses spécifiques sur le modèle sous-jacent. Au lieu de mettre les données sous forme de modèle pré-spcifié, les réseaux neuronaux permettent aux données elles-mêmes de servir de preuve directe pour appuyer l'estimation du processus de génération sous-jacente par le modèle. Cette caractéristique non paramétrique les rend très souples dans la modélisation de phénomènes du monde réel où les observations sont généralement disponibles, mais la relation théorique n'est pas connue.

Un réseau de neurones (RNA) performant est un modèle qui peut modéliser un ensemble de données en entrée jusqu'à ce qu'il puisse garantir un certain nombre de critères afin d'obtenir une solution efficace et pertinente à un problème donné.

Par conséquent, pour obtenir un RNA similaire il faut appliquer les trois phases principaux qui sont : *l'initialisation, l'apprentissage et la validation*.

Dans notre travail, nous allons nous intéresser aux réseaux de neurones pour reconnaître et prédire le comportement de l'habitant. Plus précisément, nous allons nous baser sur la phase d'apprentissage du RNA, dans ce cas nous allons améliorer le fonctionnement de cette phase dans le but d'avoir une modélisation plus performante.

Dans la littérature, il existe plusieurs méthodes et algorithmes d'apprentissage utilisée souvent dans la phase d'entraînement/d'apprentissage. Ces algorithmes sont *déterministes* tels que l'algorithme de rétro-propagation qui à été proposé par Rumelhart, la règle de Hebb, la méthode Solis et Wets et l'algorithme de rétro-propagation du gradient.

Cependant, lorsque ces algorithmes d'apprentissage déterministes sont appliqués pour entrainer un réseau de neurones, plusieurs inconvénients sont rencontrés [211] :

- Le critère d'évaluation est une fonction différentiable ce qui engendre souvent un nombre important des solutions sous-optimales qui correspondent à des optimas locaux du critère d'évaluation du réseau.
- Optimiser de façon itérative le critère d'évaluation revient à apporter des modifications de faible amplitude aux paramètres dans la direction du gradient du critère d'évaluation par rapport à ces paramètres.

Par conséquent, les algorithmes de recherche déterministes sont parfois incapables de quitter un optimum local atteint et ne permettent donc pas d'assurer la poursuite et la complétude de la recherche.

Comme nous l'avons déjà mentionné, notre objectif principal est de proposer un modèle de prédiction efficace basé sur les réseaux de neurones pour prédire le comportement des personnes âgées. Afin de surmonter les problèmes des algorithmes déterministes une nouvelle approche basée sur les algorithmes évolutionnistes (AE) appelés aussi les algorithmes évolutionnaires (evolutionary computation en anglais) sera mise en considération dans la phase d'apprentissage. Les AEs sont des algorithmes d'apprentissage très intéressants lorsqu'il s'agit de l'amélioration des performances du RN tout en fournissant une meilleure diversité dans la population finale et répondant à un certains nombre de critères. Par conséquent, nous

allons proposer une approche hybride pour améliorer la qualité de prédiction dans le cadre d'un système de surveillance à domicile.

3.4.2 Apprentissage par les Algorithmes Évolutionnaires (AE)

Les algorithmes évolutifs sont des méthodes de recherche stochastiques fonctionnent sur une population de solutions potentielles (une population d'individus) en appliquant le principe de survie du plus apte à produire les meilleures approximations d'une solution. L'idée principale de ce type d'algorithmes est que les individus qui ont hérité des caractères bien adaptés et adéquats, ont plus de chance de survivre assez longtemps pour se reproduire, alors que les moins adaptés ont tendance à disparaître. Plusieurs types d'algorithmes évolutionnaires ont été proposés dans la littérature. Nous pouvons citer : les stratégies d'évolution, la programmation évolutionnaire [212, 213], les algorithmes génétiques [214], la programmation génétique [215, 216], et l'évolution différentielle [217, 218]. Dans ce qui suit, nous nous intéressons aux algorithmes génétiques (AG) et l'évolution différentielle (ED) afin d'améliorer principalement la qualité de prédiction.

3.4.2.1 Algorithmes Génétiques (AG)

Les AG se basent sur une population d'individus au lieu d'un seul individu. Tout d'abord, une population composée d'un certain nombre d'individus initialisés aléatoirement est créée. Durant une succession d'itérations la population évolue. Cette évolution constitue les différentes générations. Pour construire la population de la prochaine génération, une série d'opérations génétiques est appliquée aux individus appelés parents pour engendrer de nouveaux individus nommés enfants. Les opérateurs d'algorithme génétique continuent jusqu'à trouver une solution optimale. Un algorithme génétique dispose de trois principaux processus naturels qui sont : la sélection, le croisement et la mutation [219].

Sélection : les individus sont choisis en fonction de leur aptitude (fitness) à la production. Le principal objectif de l'opérateur de sélection dans une population est de souligner les bonnes solutions et d'éliminer les mauvaises tout en maintenant la taille de la population constante.

Croisement : les parents sont recombinaisonnés pour produire des enfants. Le « Crossover » est une opération qui échange des chromosomes partiels entre une paire d'individus parents avec une probabilité relativement élevée (probabilité de croisement) et qui produit deux nouveaux individus.

Mutation : tous les enfants sont transférés avec une certaine probabilité (probabilité de mutation). Cette opération permet d'introduire la nouveauté de la population. Cependant, rien ne garantit que la nouvelle génération obtenue produise de bonnes solutions.

Si le critère d'optimisation n'est pas satisfait, la création d'une nouvelle génération est entamée.

3.4.2.2 Évolution Différentielle (ED)

L'algorithme d'évolution différentielle (ED) est un algorithme stochastique inspiré des algorithmes évolutifs proposé par Storn et Price [217]. L'algorithme ED est classé parmi les algorithmes évolutionnaires les plus simples et les plus performants. Sa robustesse et son nombre faible d'hyper-paramètres en font un outil de choix pour la résolution des problèmes complexes. L'algorithme de l'évolution différentielle est inspiré des algorithmes génétiques et les stratégies évolutionnistes combinées avec une technique géométrique de recherche. Le concept principal est d'engendrer au hasard une population initiale. Par la suite, l'algorithme effectue une série de transformations sur les individus avec la mise en œuvre de trois opérations d'évolution génétique qui sont : *la mutation, le croisement et la sélection*.

Soit une population initiale générée au hasard avec N individus. Chaque individu $X_{i,G}$ est un ensemble $X_{i,G} = \{X_{1i,G}, X_{2i,G}, \dots, X_{Di,G}\}$ avec $i = 1, 2, \dots, N$.

A chaque génération, l'algorithme applique trois opérations pour produire un vecteur d'essai (en anglais trial vector).

$$T_{i,G+1} = (T_{1i,G+1}, T_{2i,G+1}, \dots, T_{Di,G+1}) \text{ Avec } i = 1, 2, \dots, N.$$

Par la suite, une opération de sélection permet de choisir les individus à conserver pour la nouvelle génération ($G + 1$).

Le processus d'évolution est généré comme suit :

i) Mutation :

Contrairement aux AG où la mutation est basée sur une "probabilité de mutation", la phase de mutation de l'algorithme ED consiste en la création d'un vecteur mutant $V_{i,G+1}$ pour chaque vecteur courant $X_{i,G}$ en utilisant l'une des stratégies de mutation suivantes :

$$Rand/1 : V_{i,G+1} = X_{r_1,G} + F.(X_{r_2,G} - X_{r_3,G})$$

$$Best/1 : V_{i,G+1} = X_{best,G} + F.(X_{r_1,G} - X_{r_2,G})$$

$$Current - to - best/1 : V_{i,G+1} = X_{i,G} + F.(X_{r_1,G} - X_{r_2,G}) + F.(X_{best,G} - X_{i,G})$$

$$Best/2 : V_{i,G+1} = X_{best,G} + F.(X_{r_1,G} - X_{r_2,G}) + F.(X_{r_3,G} - X_{r_4,G})$$

$$Rand/2 : V_{i,G+1} = X_{r_1,G} + F.(X_{r_2,G} - X_{r_3,G}) + F.(X_{r_4,G} - X_{r_5,G})$$

Les indices r_1, r_2, r_3, r_4 et $r_5 \in 1, 2, \dots, N$ sont des entiers aléatoires, tous différents et différents de l'indice courant i . $X_{best,G}$ est le meilleur individu à la g ème génération. $F \in [0, 2]$ est une valeur constante responsable du contrôle de l'amplification de la variation différentielle de $X_{r_i,G} - X_{r_j,G}$ appelée aussi differential weight.

ii) Croisement :

Lors de cette opération on forme le vecteur d'essai final $T_{i,G+1}$. Elle est mis en œuvre, selon le vecteur $X_{i,G}$ et le vecteur mutant correspondant $V_{i,G+1}$. Le croisement est appliqué pour augmenter la diversité des vecteurs des paramètres perturbés. Le nouveau vecteur $T_{i,G+1}$ est donné par la formule suivante :

$$T_{i,G+1} = \begin{cases} V_{i,G+1} & \text{si } randb(j) \leq CR \text{ ou } j = rnbr(i), \\ X_{j,i,G} & \text{si } randb(j) > CR \text{ et } j \neq rnbr(i) \text{ pour tout } j \in \{1, 2, \dots, D\}. \end{cases}$$

Avec $randb(j)$ est la j ème valeur représentant un nombre aléatoire uniforme appartenant à l'intervalle $[0, 1]$. CR est le coefficient de croisement qui appartient à l'intervalle $[0, 1]$ déterminé par l'utilisateur. $rnbr(i)$ est un indice choisi au hasard dans l'ensemble $1, 2, \dots, N$.

iii) Sélection :

Dans l'opération de sélection un vecteur parmi $T_{i,G+1}$ ou $X_{i,G}$, doit être choisi pour la génération $G+1$. Les deux vecteurs sont comparés à leur fonction de coût.

$$X_{i,G+1} = \begin{cases} T_{i,G+1} & \text{si } f(T_{i,G+1}) < f(X_{i,G}), \\ X_{i,G} & \text{si non.} \end{cases}$$

Le processus d'évolution génétique de ED est répété jusqu'à ce qu'une meilleure solution soit obtenue.

En général, un RNA est un modèle de prédiction caractérisé par plusieurs critères qui peuvent être optimisés dans la phase d'apprentissage pour avoir un modèle puissant, pertinent et une meilleure qualité de prédiction. Ces paramètres sont *Les poids synaptiques*, *Les Biais*, *Le nombre de couches de réseau* et *Le nombre de nœud par couche*. Dans la partie suivante, nous allons nous intéresser à optimiser les poids synaptiques et les biais des réseaux de neurones en utilisant les deux algorithmes évolutionnaires, l'algorithme génétique et l'algorithme de l'évolution différentielle dans la phase d'apprentissage.

3.5 Nouvelle approche hybride

Une nouvelle approche hybride est proposée pour améliorer la qualité de prédiction de notre système afin de prédire les séries temporelles des données représentant les mouvements et le comportement ainsi que l'état médical de la personne avec un taux important de précision. Nous proposons deux modèles hybrides prédictifs, le premier modèle est un réseau de neurones basé sur les algorithmes génétiques (RNA-AG), le deuxième est un réseau de neurones basé sur l'algorithme de l'évolution différentielle (RNA-ED).

3.5.1 Principe du RNA-AG

Pour former un modèle de prédiction amélioré RNA-AG, nous proposons d'utiliser l'algorithme génétique dans la phase d'apprentissage du réseau de neurones pour déterminer les valeurs optimales des poids et des biais du réseau.

Le processus du RNA-AG se compose de trois étapes :

Étape 1 : Déterminer la topologie RNA-AG (nombre de nœud des couches, nombre des couches, etc).

Étape 2 : Utiliser l'algorithme AG dans la phase d'apprentissage pour optimiser les poids et les biais du réseau. Une population initiale d'individus est créée au hasard et dont les individus représentent les poids et les biais du réseau. Les meilleurs individus qui représentent la meilleure valeur de poids et du biais sont calculés par les opérations de sélection, de croisement et de mutation. Une mesure d'adaptation (fonction objective) est calculée par la suite en fonction des paramètres obtenus, si la mesure est adéquate à la fonction objective, le processus d'apprentissage est terminé. Sinon, une mise à jour de la population est effectuée.

Étape 3 : dans la phase de validation, l'application du RNA optimisé par AG est effectuée pour prédire le comportement de la personne âgée avec précision.

3.5.2 Principe du RNA-ED

Dans ce cas, les poids et les biais du RNA sont optimisés lors de la phase d'apprentissage par l'algorithme ED. Le processus du RNA-ED dans la phase d'apprentissage suit les huit étapes suivantes :

Étape 1 : Générer aléatoirement une nouvelle population d'individus ;

Étape 2 : Choisir le vecteur cible de manière aléatoire avec les individus W_{best} et B_{best} (W_{best} et B_{best} sont considérés comme les meilleurs individus) ;

Étape 3 : Générer aléatoirement W_1, W_2 et B_1, B_2 ; avec $(W_1 \neq W_2)$ et $(B_1 \neq B_2)$.

Étape 4 : Créer le vecteur bruyant W_i et B_i pour chaque individu dans la population, avec $W_i = W_{best} + F.(W_1 - W_2)$ et $B_i = B_{best} + F.(B_1 - B_2)$;

Étape 5 : Rechercher le vecteur d'essai à l'aide d'un croisement entre W_{best} et W_i , et d'un croisement entre B_{best} et B_i ;

Étape 6 : Calculer le coût du vecteur cible et du vecteur d'essai ;

Étape 7 : Le vecteur qui comprend le coût le plus petit remplace le membre de la population dans la population initiale.

Étape 8 : Répéter les différentes étapes jusqu'à avoir le meilleur coût de la prédiction (erreur minimale).

Par conséquent, grâce à un apprentissage efficace, nous sommes en mesure d'identifier un meilleur modèle ayant les meilleurs paramètres (poids et biais) des réseaux qui influencent implicitement notre fonction objectif (minimisation du taux d'erreur entre les données prédites et souhaitées). En effet, après la phase d'apprentissage le modèle obtenu nous fournit un modèle général et nous offre une prédiction des mouvements de la personne surveillée en minimisant le coût des erreurs.

3.5.3 Topologie des modèles proposés

Vu que la reconnaissance et la prédiction de comportement quotidien de la personne nécessitent plusieurs dépendances temporelles entre les activités ainsi une mémorisation des données [220], la topologie *Feed-Forward* [221] ne correspond pas et ne répond pas à notre objectif. Par conséquent, nous nous sommes orienté vers l'utilisation d'autres topologies qui tiennent compte les besoins de notre système,

telles que :

Les Réseaux de Neurones Récurrents (RNN) : Recurrent Neural Network. Ces réseaux sont capables de maintenir des informations historiques connexes pour prédire l'évolution future de la série temporelle. Ainsi, le rapport temporel entre les données d'entrées et les observations à différents moments est traité[205, 222].

Les Réseaux de Neurones à Retard de Temps (TDNN) : Time Delay Neural Network. Ces réseaux s'appuient principalement sur un type particulier de mémoire appelée *ligne à retard* où les entrées les plus récentes sont mises en mémoire tampon à des étapes de temps différentes [201, 223]. Chaque topologie se compose de différents types de modèles.

Les Réseaux de Neurones Récurrents :

- Echo State Network (ESN)
- Long Short Term Memory (LSTM)
- Simple recurrent network
- ELMAN-NN

Les Réseaux de Neurones à Retard de Temps :

- Focused Time Delay Neural Network (FTDNN)
- Layered Recurrent Neural Network (LRN)
- Non-linear Autoregressive network with eXogenous (NARX)

Dans notre travail, nous allons nous concentrer sur le modèle ELMAN-NN comme un modèle de RNN et le modèle NARX comme un modèle de TDNN. Ces modèles seront améliorés et utilisés pour reconnaître et prédire le comportement de la personne âgée.

3.5.3.1 Modèle ELMAN-NN

Elman Neural Networks (Elman-NN) a été proposé par Elman en 1990 [224]. Son architecture illustrée par la figure 3.4, se caractérise par une couche d'entrée, une couche appelée couche de contexte (context units en anglais), une couche cachée et une couche de sortie. Le principal avantage d'Elman-NN est que les nœuds contextuels sont utilisés pour mémoriser les données précédentes des nœuds cachés, ce qui rend Elman-NN applicable dans les domaines de l'identification du système dynamique et de la prédiction [225].

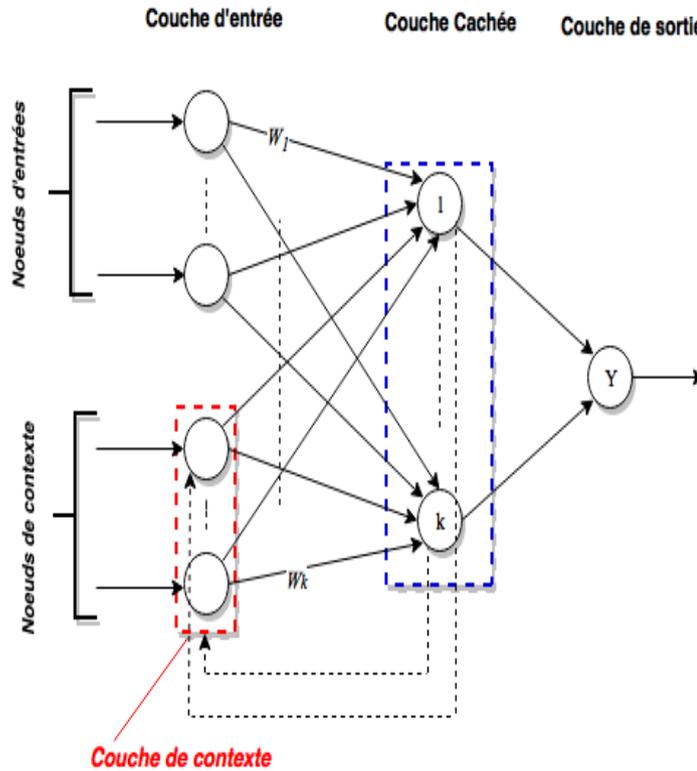


FIGURE 3.4 – Structure du modèle ELMAN-NN.

3.5.3.2 Modèle NARX

Le modèle NARX est un modèle non linéaire discret qui est démontré comme étant équivalent à la machine de Turing [226]. La figure 3.5 montre l'architecture typique du réseau NARX [227]. Dans ce modèle, le réseau de perceptron multicouche est utilisé pour approximer $y(t)$ exprimé comme suit :

$$y(t) = f(x(t-1); x(t-2) \dots x(t-Dx); y(t-1); y(t-2) \dots y(t-Dy))$$

où $x(t)$ et $y(t)$ sont respectivement l'entrée et la sortie du modèle à l'instant t , Dx et Dy sont les ordres de mémoire d'entrée et de sortie avec $Dy \geq Dx$. La fonction non linéaire de l'entrée et de la sortie du modèle est exprimée par f . La sortie prédite $y(t)$ est régressée sur la valeur d'entrée (exogène) $x(t-1)$ et la valeur de sortie $y(t-1)$.

Aussi bien ELMAN-NN que NARX sont améliorés par l'utilisation des algorithmes génétiques et les algorithmes de l'évolution différentielle on obtient ELMAN-AG,

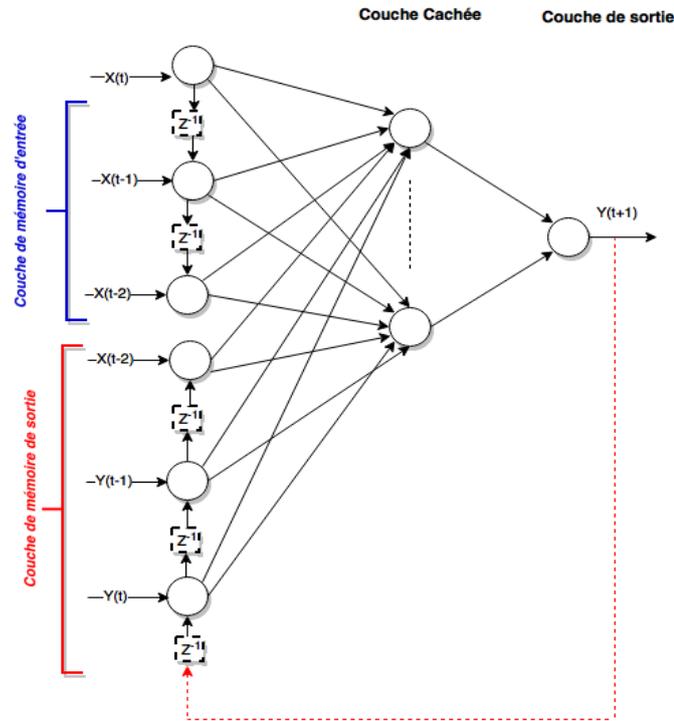


FIGURE 3.5 – Structure du modèle NARX.

ELMAN-ED, NARX-AG et NARX-ED. Les quatre modèles seront appliqués pour prédire le comportement de la personne en se basant sur les deux cas définis dans la section 5.2, en plus une mesure de leurs performances de point de vue précision de prédiction et temps de calcul sera effectuée.

3.6 Mesure des performances

L'interprétation des données comportementales nous aide à mieux comprendre les ADL et à distinguer les comportements anormaux lorsqu'une activité anormale se produit. Cela serait également utile pour générer des reconnaissances sur les activités habituelles du patient pendant une longue période de temps. En outre, cela peut aider également les soignants à suivre le comportement habituel et à prendre les dispositions nécessaires à l'avance. Pour améliorer la qualité du service fourni par le système de surveillance, une méthode prédictive précise est nécessaire pour prédire les activités futures de l'habitant. Dans cette section, nous allons évaluer les performances des techniques prédictives proposées ci-dessous.

3.6.1 Reconnaissance et prédiction du comportement

Les activités de la vie quotidienne telles que la toilette et la cuisine sont de bons indicateurs des capacités des personnes âgées. Ainsi, un système capable de surveiller les activités quotidiennes des personnes âgées peut jouer un rôle important afin de leurs permettre de vivre de manière autonome dans leur propre maison. Le système devrait reconnaître ces activités pour permettre un suivi automatique de la santé et donner de bonnes directives pour les soins infirmiers. Pour ces personnes, le système pourrait fournir un outil de rappel sur la façon dont les activités sont exécutées au cours du temps. Un système de surveillance d'activité est constitué de trois parties : un réseau de capteurs qui sert à collecter les données de l'environnement, une phase de pré-traitement des données et un modèle de reconnaissance permettant de reconnaître et de comprendre les comportements quotidiens de ces capteurs (Figure 3.6).

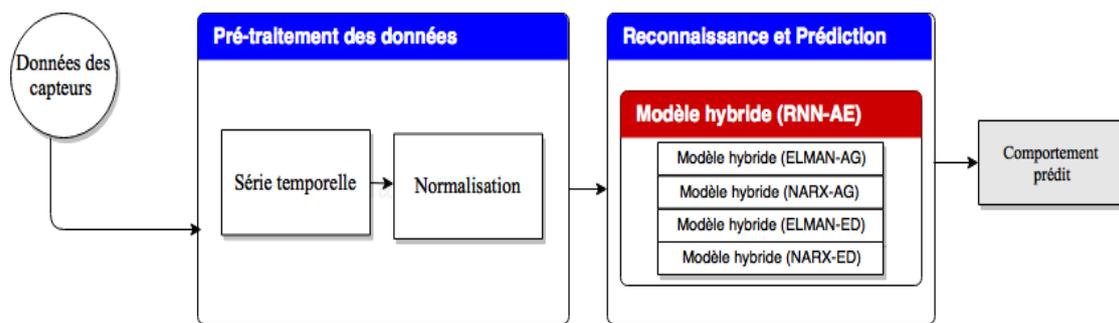


FIGURE 3.6 – Processus de reconnaissance et de prédiction par RNN-AE.

La reconnaissance d'un comportement normal/habituel d'une personne nous permet de prendre des informations sur la routine de la personne ce qui facilite par la suite la détection et la prédiction d'un changement. Ces connaissances pourront enrichir notre base de données et permettre aux responsables de surveillance (médecin, expert, etc.) d'avoir une vue plus détaillée sur le profil de la personne, son état de santé et ses routines quotidiennes. Ceci permet par la suite de prendre de meilleures prédictions, des décisions appropriées et de mettre à jour le comportement habituel de la personne si nécessaire. Les données utilisées dans cette partie sont les données sensorielles simulées recueillies à partir du projet "e-Health Monitoring Open Data project", qui représente deux différents cas qui sont :

Personne-C1 : le premier cas qui représente le comportement de la personne autonome.

Personne-C2 : le deuxième cas qui représente le comportement de la personne le moins autonome.

Les figures 3.7 et 3.8 illustrent le comportement habituel de la personne-C1 et de la personne-C2 respectivement durant 5 jours successifs. Dans les figures 3.7 et 3.8, des variations similaires sont repérées. Si nous prenons la variation du comportement de chaque jour, nous observons qu'il existe des jours où les variations sont presque les mêmes. Par exemple, sur la figure 3.7, les courbes du jour 1 et du jour 2 ont presque la même forme, ce qui exprime la routine de la personne.

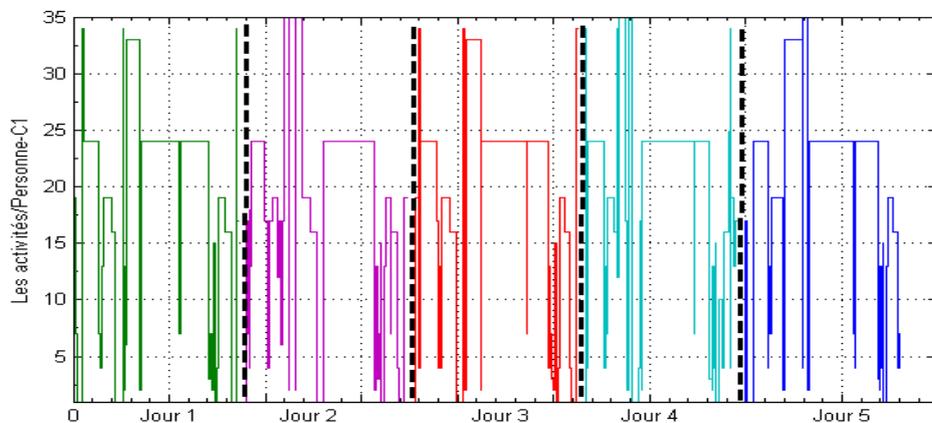


FIGURE 3.7 – Scénario de la personne-C1 durant 5 jours

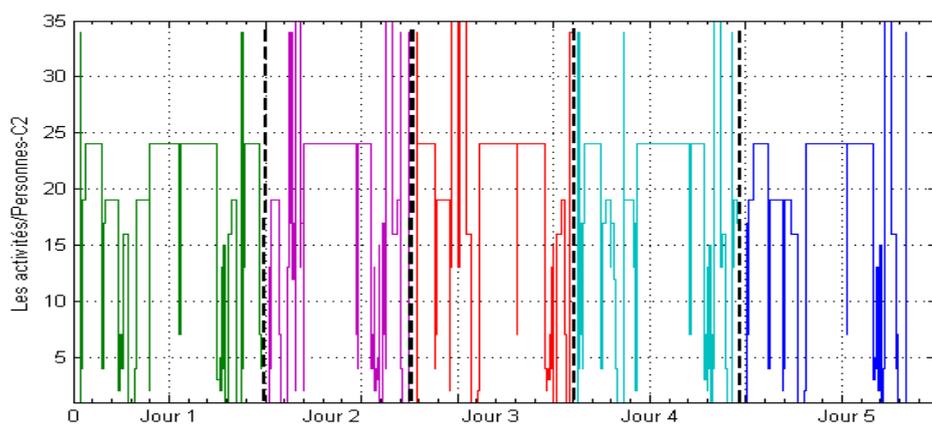


FIGURE 3.8 – Scénario de la personne-C2 durant 5 jours.

La figure 3.9 représente le comportement de la personne autonome et celle de la personne le moins autonome tout au long d'une journée pour distinguer la différence comportementale en cas de perte de l'autonomie. Dans la figure 3.9, nous pouvons remarquer un changement remarquable entre le comportement de la personne-C1 et le comportement de la personne-C2 qui confirme la relation entre le comportement quotidien et le niveau de l'autonomie de la personne. Par conséquent, une phase de prédiction est nécessaire pour détecter les changements comportementaux dans le but de détecter la présence d'un comportement ou d'une activité anormale à l'avance.

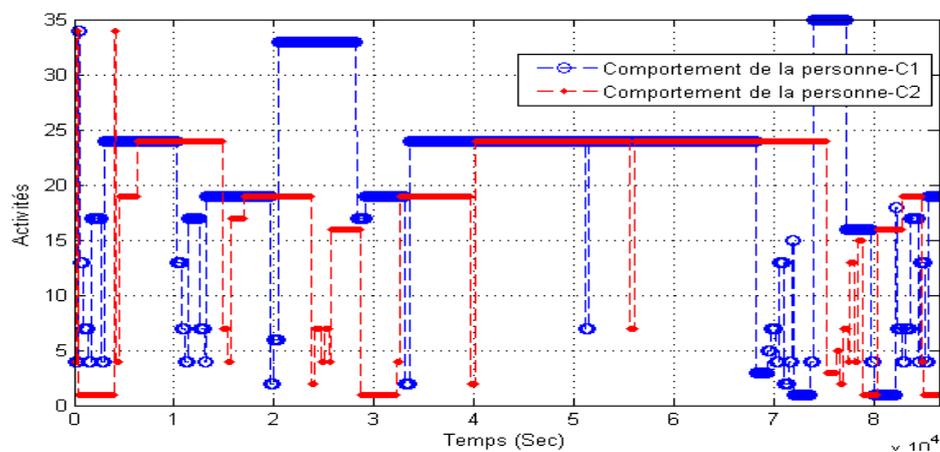


FIGURE 3.9 – Comportement d'une personne autonome appartenant au profil SMAF *P1* avec une Personne moins autonome.

Dans la partie suivante, nous évaluons les modèles de prédiction proposés auparavant afin d'identifier le meilleur modèle. Généralement, pour mesurer la qualité de précision d'un modèle de prédiction, il est important de choisir une mesure appropriée. De ce fait, la mesure d'erreur est la méthode la plus utilisée dans ces types d'études. Selon le type d'entrée du modèle (binaire ou continue), différentes mesures d'erreur peuvent être utilisées.

Pour les séries de données binaires : après le prétraitement des données des séries temporelles binaires, nous utilisons une mesure de similarité entre les deux séries (données réelles et prédites). Dans la littérature, les chercheurs proposent différentes méthodes de mesure de similarités comme le coefficient de Jaccard-Needham, Dice, Roger Tanmoto, etc [228, 229].

Pour les séries des données continues : il existe plusieurs mesures d'erreur utili-

sées pour calculer le taux d'erreur entre les données réelles et les données prédites. Par exemple, RMSE (Root Mean Square Error), la Somme des Carrés des Résidus (SCR ou Sum of Squared Errors), le Carré Moyen des Erreurs (MSE ou Mean Square Error), et l'Erreur Moyenne Absolue (MAE pour Mean Absolute Error).

L'entrée de notre modèle est une série temporelle continue et normalisé. Elle représente le comportement de notre habitant, de ce fait nous avons utilisé l'RMSE pour mesurer la performance des modèles proposés, donné par l'équation 3.2.

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3.2)$$

3.6.2 Paramètres de simulation

Les données issues des capteurs seront divisés en deux ensemble 2/3 pour l'apprentissage et 1/3 pour la validation. Alors, 9 mois de l'année, sont réservés pour l'apprentissage et trois mois pour la validation.

La distribution des données concernant les deux cas sont présentées comme suit :

Personne-C1 :

Données d'apprentissage du 28 Mars 2015 au 28 Décembre 2015.

Données de validation du 29 Décembre 2015 au 29 Mars 2016.

Personne-C2 :

Données d'apprentissage 29 Juin 2015 – 29 Mars 2016.

Données de validation 28 Mars 2015 – 28 Juin 2015.

Par la suite, nous allons définir l'architecture de chaque modèle proposé afin d'évaluer ses performances. Généralement, l'architecture est représentée par le nombre des couches cachées, le nombre des nœuds d'entrées, le nombre de nœuds cachés et le nombre de nœuds de sortie. En ce qui concerne nos modèles proposés (ELMAN et NARX), l'architecture des deux modèles se compose d'une seule couche cachée. Pour le modèle ELMAN, en plus des nœuds d'entrés, cachés et de sortie, le modèle se caractérise par le nombre des nœuds contexte qui se réfèrent à la couche contexte. Concernant NARX, le modèle se caractérise aussi par un autre type de nœuds qui sont *input memory orders* et *output memory orders*.

Après plusieurs expérimentations de l'architecture, un certain nombre de paramètres est utilisé pour former le réseau NARX et ELMAN. Le tableau 3.4 montre les paramètres de l'architecture qui minimisent l'erreur par rapport aux autres architectures. Ces paramètres sont utilisés dans le reste dans ce chapitre.

TABLE 3.4 – Les paramètres des architectures NARX et ELMAN

	NARX	ELMAN
Nœud d'entrée	16	16
Nœud Caché	12	12
Nœud de sortie	1	1
input memory orders	8	
output memory orders	9	
Nœud de contexte		9

3.6.3 Résultats de l'évaluation

Dans cette section, nous allons détailler les résultats des modèles ELMAN-ED, ELMAN-AG, NARX-ED et NARX-AG utilisés dans la phase de prédiction dans notre système de surveillance pour les deux cas en terme de précision et de temps de calcul. Le choix du meilleur modèle se fait en fonction du taux de précision de la prédiction. Les résultats de prédiction sont présentés dans la figure 3.10, 3.11, 3.12 et 3.13. Les figures concernent un échantillon de données où les valeurs réelles des capteurs sont désignées par une ligne bleue et les valeurs prédites sont désignées par une ligne rouge pointillée. La figure 3.10 présente les résultats de prédiction qui concernent la personne-C1 obtenus par ELMAN et NARX améliorés en utilisant l'algorithme AG. La figure 3.11 présente les résultats de prédiction obtenue par ELMAN et NARX amélioré en utilisant l'algorithme ED. Les figures 3.12 et 3.13 présentent les résultats de prédiction de la personne-C2 la moins autonome. La figure 3.12 montre les résultats de simulation de ELMAN et NARX basé sur l'algorithme d'apprentissage AG. La figure 3.13 montre les résultats de simulation obtenus par ELMAN et NARX améliorés par DE.

Dans la figure 3.10 et 3.11 nous pouvons observer que le scénario prédit suit clairement le scénario réel pour la personne-C1 avec les deux modèles NARX-ED et ELMAN-ED. La figure 3.12 montre la variation entre le scénario prédit et le scénario réel pour les deux modèles NARX-AG et ELMAN-AG. De même, les figures 3.12 et 3.13 qui concernent les deux modèles ELMAN et NARX améliorés par ED utilisés pour prédire le comportement de la personne-C2 montrent que le scénario prédit et le scénario réel sont entièrement conformes. Cependant, pour les deux

modèles améliorés par AG il existe encore un taux d'erreur.

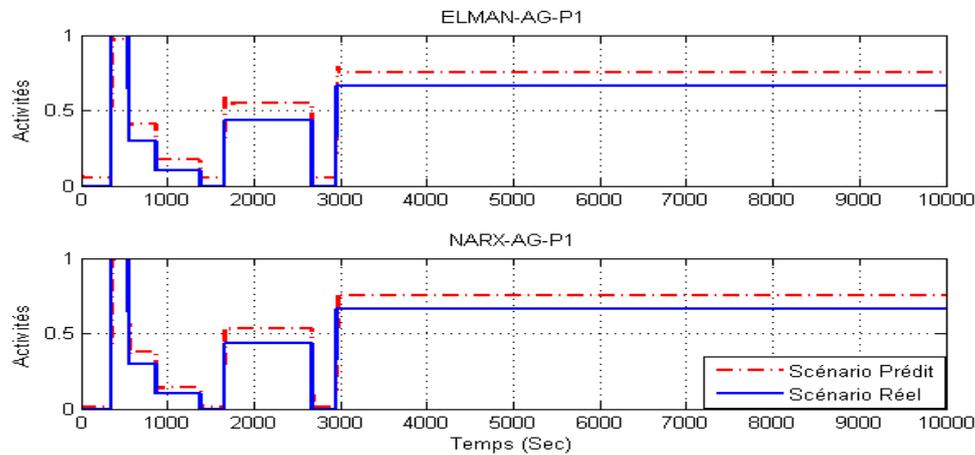


FIGURE 3.10 – Résultats de prédiction des deux modèles NARX-AG et ELMAN-AG concernant la personne de profil SMAF *P1*

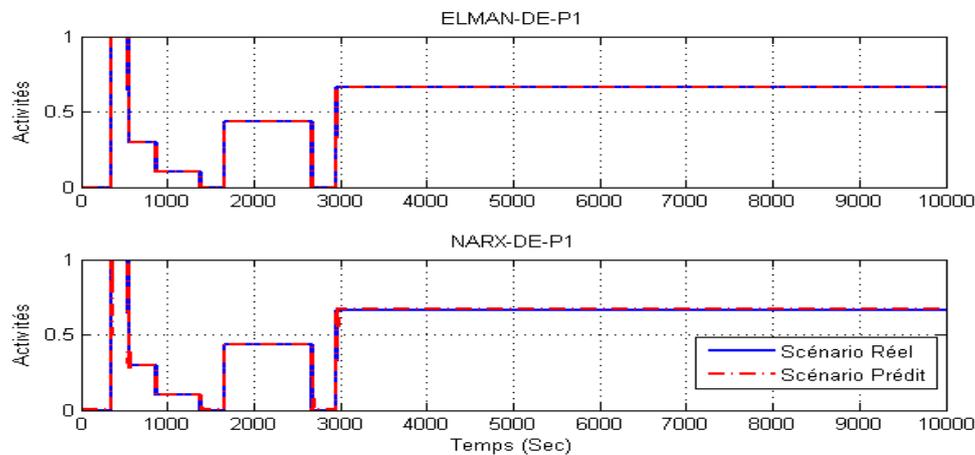


FIGURE 3.11 – Résultats de prédiction des deux modèles NARX-DE et ELMAN-DE concernant la personne de profil SMAF *P1*

Pour mesurer l'exactitude de la prédiction des modèles proposés, nous allons calculer l'erreur quadratique moyenne (RMSE) dans la phase d'apprentissage et dans la phase de validation de ELMAN-ED, ELMAN-AG, NARX-ED et NARX-AG. Le tableau 5.6 décrit les performances des réseaux ELMAN-ED, ELMAN-AG, NARX-ED et NARX-AG pour les deux cas personne-C1 et personne-C2 en termes d'apprentissage et de validation en utilisant RMSE. Dans le tableau 3.5, nous observons

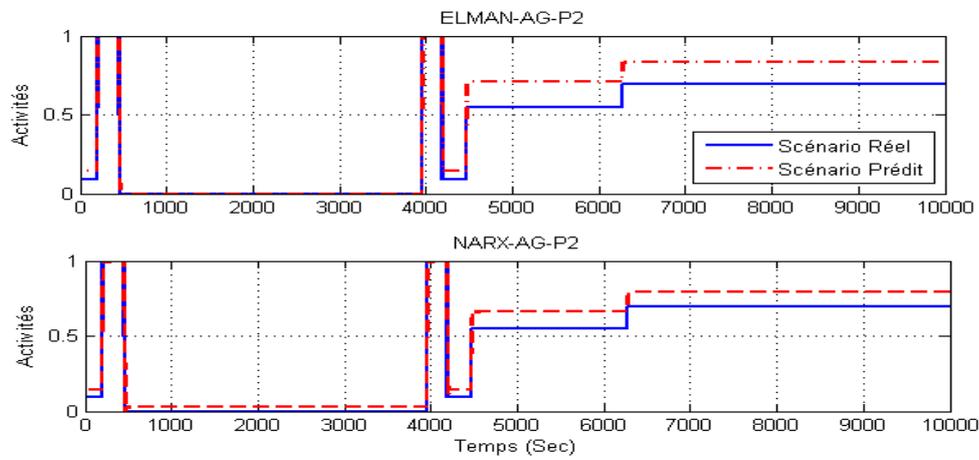


FIGURE 3.12 – Résultat de prédiction des deux modèles NARX-AG et ELMAN-AG pour la personne-C2.

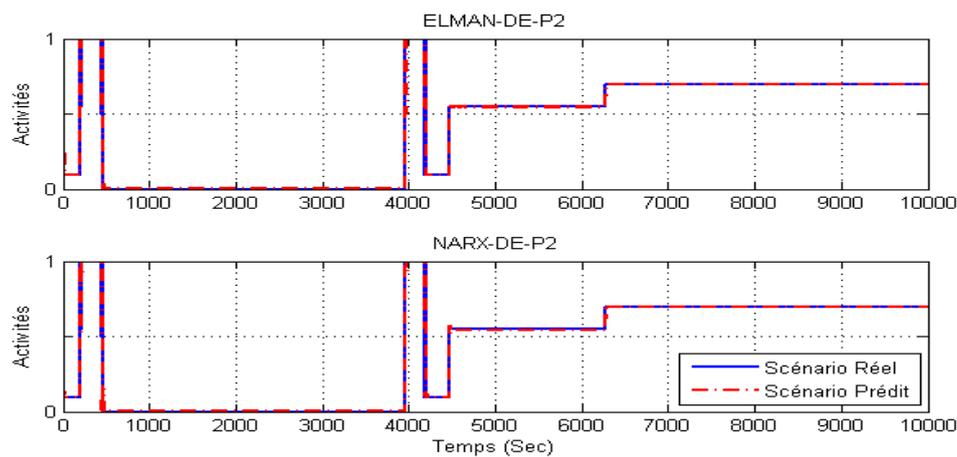


FIGURE 3.13 – Résultat de prédiction des deux modèles NARX-DE et ELMAN-DE pour la personne-C2.

que pour certains ensembles de données de capteurs, il y a une augmentation de la précision de prédiction lorsque ELAMN et NARX utilisent l'algorithme d'apprentissage DE par rapport à l'algorithme AG. A partir de ces résultats, nous pouvons conclure que les réseaux NARX-ED et ELMAN-ED sont plus performants que NARX-AG et ELMAN-AG en terme de précision de la prédiction.

Dans le cadre d'un système de surveillance à domicile, un autre facteur important est le temps d'apprentissage. Nous avons évalué le temps d'apprentissage des

TABLE 3.5 – RMSE des deux phases d'apprentissage et de validation pour les modèles ELMAN-(AG/ED) et NARX-(AG/ED) pour les deux cas personne autonome et personne avec changement de profile.

	Modèle	RMSE-APPRENTISSAGE	RMSE-VALIDATION
Personne-Cas 1	ELAMN-AG	0.0146	0.264
	NARX-AG	0.0201	0.0921
	ELAMN-ED	0.00014	0.0105
	NARX-ED	$2.1767 * 10^{-4}$	0.00254
Personne-Cas 2	ELAMN-AG	0.09582	0.3520
	NARX-AG	0.0890	0.1230
	ELAMN-ED	0.00564	0.1890
	NARX-ED	$2.6782 * 10^{-4}$	0.00125

modèles de prédiction proposés, ELMAN-AG, ELMAN-ED, NARX-AG et NARX-ED. Le tableau 3.6 illustre les résultats d'évaluation du temps d'apprentissage pour chaque modèle pour les deux cas Personne-C1 et Personne-C2.

TABLE 3.6 – Temps d'apprentissage pour les modèles ELMAN-(AG/ED) et NARX-(AG/ED) pour les deux cas Personne autonome et Personne avec changement de profile.

	Modèle de prédiction	Temps d'apprentissage (Sec)
Personne-Cas 1	ELAMN-AG	372
	NARX-AG	537
	ELAMN-ED	2990
	NARX-ED	5258
Personne-Cas 2	ELAMN-AG	417
	NARX-AG	534
	ELAMN-ED	3860
	NARX-ED	5243

Dans le tableau 3.6, nous observons que ELMAN-AG est plus rapide que les autres modèles. NARX-ED nécessite beaucoup plus de temps que les autres modèles avec 4721 sec de différence approximativement.

Les résultats obtenus ci-dessus montrent que les modèles NARX et ELMAN améliorés par DE sont performants de point de vue précision. Cependant, les résultats obtenus par les modèles NARX et ELMAN améliorés par AG sont plus performants de point de vue temps.

3.7 Étude comparative

Afin de confirmer la performance des modèles proposés, nous allons comparer les résultats obtenus par les modèles hybrides proposés (ELMAN-ED/AG et NARX-ED/AG) avec ceux obtenus par les réseaux de neurones classique (SLFN-BP, ELMAN-BP et NARX-BP). Cette comparaison est effectuée dans différents slots de temps (périodes). Pendant la phase de test, 10 périodes de temps seront prises en considération durant un mois. Le tableau 3.7 présente les résultats de comparaison. Nous pouvons observer que les modèles hybrides donnent de bons résultats de prédiction par rapport aux autres types de réseaux de neurones qui se basent sur l'algorithme déterministe « Back-propagation de l'erreur » (BP).

TABLE 3.7 – Évaluation de l'RMSE pour les modèles de prédiction hybrides proposés : ELMAN-ED/AG, NARX-ED/AG avec les modèles classiques : SLFN-BP, ELMAN-BP, NARX-BP, SLFN-AG et SLFN-ED

	SLFN-BP	NARX-BP	ELMAN-BP	SLFN-AG	NARX-AG	ELMAN-AG	SLFN-ED	NARX-ED	ELMAN-ED
P1	0.322	0.254	1.035	0.0028	0.0017	0.0102	0.0007	0.00001	0.0002
P2	0.122	0.956	1.152	0.0026	0.0017	0.0118	0.0008	0.00006	0.0006
P3	0.303	1.200	0.963	0.0028	0.0020	0.0065	0.0005	0.00008	0.0005
P4	0.985	0.115	0.900	0.0025	0.0020	0.0131	0.00066	0.00002	0.0001
P5	1.356	0.963	1.002	0.0025	0.0015	0.0095	0.0005	0.00003	0.0009
P6	0.369	1.300	0.978	0.0026	0.0018	0.0127	0.0004	0.00008	0.0008
P7	2.782	0.025	0.925	0.0028	0.0017	0.0102	0.00021	0.00012	0.00008
P8	1.654	0.823	1.741	0.0025	0.0018	0.0074	0.00012	0.00004	0.0001
P9	0.234	0.123	0.852	0.0025	0.0017	0.0120	0.00057	0.00006	0.00005
P10	0.899	1.852	0.925	0.0026	0.0017	0.0106	0.00020	0.00008	0.0004
Moy	0.902	0.761	1.047	0.0026	0.0017	0.0104	0.0004	0.000058	0.000373

A partir des résultats de comparaison obtenus, nous pouvons conclure que les résultats de prédiction des réseaux NARX-ED, ELMAN-ED et SLFN-ED sont meilleurs que les réseaux ELMAN, NARX et SLFN formés avec BP ou AG. Nos expérimentations ont montré que la convergence du réseau NARX est meilleure que le réseau ELAMN. Par exemple, la moyenne de l'RMSE dans la phase de test des données du réseau ELMAN-ED est de 0.000373. Cependant, la moyenne de

l'RMSE est seulement de 0.000058 pour former le réseau NARX-ED.

3.8 Conclusion

Dans ce chapitre, nous avons proposé un modèle de prédiction efficace de point de vue précision pour prédire le comportement d'une personne âgée dans une maison intelligente basée sur des informations sensorielles. Les données utilisées pour évaluer les approches proposées sont les données générées dans [3], dans lesquelles le simulateur imite le comportement d'un occupant habite seul dans un environnement intelligent en générant un signal comportemental. Les données fournies décrivent le comportement de la personne tout au d'une année. De plus, nous avons proposé de simuler deux types de scénarios, un scénario d'une personne autonome et un scénario d'une personne moins autonome avec des changements de profil. Nous sommes basés sur les réseaux de neurones pour prédire le comportement future de la personne. Vu que la prédiction est une tâche très sensible dans le cadre de la surveillance à domicile les algorithmes évolutionnaires ont été appliqués dans la phase d'apprentissage d'ANN pour améliorer la phase de prédiction. Selon la nature de notre application nous avons choisir deux topologies approprié qui répond au besoin de notre système. La prédiction de comportement future de la personne nécessite plusieurs critères tels que la dépendance temporelle entre les activités et la dépendance entre l'activité actuelle et l'activité précédente, pour cette raison nous avons choisi d'appliquer le modèle ELMAN-NN pour garantir le fonctionnement dynamique du système (notion du récurrence) et le modèle NARX pour garantir la dépendance temporelle entre les données. Afin de garantir un modèle de prédiction efficace de point de vue précision, nous avons proposé d'améliorer les deux types de réseau neurones proposée, les algorithmes évolutionnaires ont été appliqués dans la phase d'apprentissage de ELMAN et NARX pour améliorer la prédiction. Nous avons proposé d'appliquer deux types des algorithmes évolutionnaires qui sont l'algorithme génétique (AG) et l'évolution différentielle (ED). Par conséquent, les modèles ELMAN-AG, ELMAN-ED, NARX-AG et NARX-ED ont été proposés pour prédire le comportement future de la personne. Les résultats obtenus ont confirmé les performances de nos modèles pour les deux cas : une personne autonome et une personne avec un changement de niveaux d'autonomie. Notre modèle hybride a réussi à améliorer la qualité de prédiction. Malgré les bons résultats obtenus de point de vue précision de prédiction, le temps de calcul reste toujours un problème à résoudre vu que les systèmes de surveillance nécessitent une rapidité de prédiction pour offrir des services appropriés et en temps réel dans certains cas comme les cas d'urgence.

CHAPITRE 4

Nouveau modèle pour la prédiction et l'identification des comportements anormaux

4.1 Introduction

D'après les résultats obtenus dans le chapitre 3, il ressort que les modèles hybrides proposés pour la reconnaissance et la prédiction (ELMAN-ED, ELMAN-AG, NARX-AG et NARX-ED) sont très efficaces de point de vue précision de prédiction. Cependant, l'exécution basée sur ces modèles nécessite un temps de calcul important ce qui rend l'intervention faite en retard. De ce fait, pour permettre au système de réagir en moment opportun dans des situations anormales et d'urgence nous allons proposer un modèle de prédiction qui satisfait à la fois la précision de prédiction et la rapidité d'exécution. Le nouveau modèle proposé sera une amélioration du modèle ELM (Extreme Learning Machine) afin d'obtenir une version récurrente de celle-ci dénommée RELM (Recurrent Extreme Learning Machine) et qui sera adaptée pour la prédiction. Afin d'assurer un système de surveillance à domicile complet nous allons générer le processus de surveillance dès la collection des données jusqu'à la prise de décision. En outre nous utiliserons la logique floue comme un modèle de raisonnement logique pour la prise de décision. L'état de santé d'une personne peut être évalué à partir de son comportement, puisqu'il y a plusieurs symptômes des maladies relatives aux changements du comportement et des activités. Par conséquent, à partir des changements du comportement et des activités de la personne, on peut détecter son état de santé. Tenant compte de la relation entre les activités quotidiennes de la personne et les symptômes des maladies, une étude de cas relative à la dépression chez les personnes âgées sera mise au point à la fin de ce chapitre. Notre système de prise de décision sera mis en œuvre pour évaluer le taux de dépression des personnes âgées afin d'informer le centre de surveillance si nécessaire.

Au début de ce chapitre, nous allons étudier les lacunes du réseau de neurones. Par la suite, pour contourner ces inconvénients rappelle le modèle ELM de base, puis une transformation est apportée pour le rendre récurrent ce qui fait l'objet du nouveau modèle proposé. Enfin, nous allons proposer d'implémenter un système d'aide à la décision complet pour évaluer le risque de dépression chez les personnes âgées.

Les données de simulation utilisées sont celles utilisées dans le chapitre précédent. Toutefois uniquement le cas "Personne-C1" sera considéré.

4.2 Les lacunes des réseaux de neurones artificiels

Malgré les résultats satisfaisants obtenus par ELMAN-AG, ELMAN-ED, NARX-AG et NARX-ED proposés dans le chapitre précédent au niveau de la prédiction,

de la reconnaissance et du suivi des activités quotidiennes des personnes âgées, les ANNs présentent certains inconvénients citons :

- Le choix de la structure.
- Le choix du nombre de neurones (neurones d'entrée, cachées et de sortie).
- Le choix de l'algorithme d'apprentissage (dans la phase d'apprentissage).
- Le temps de calcul élevé.

Afin de surmonter ces inconvénients, Huang et al. [230] ont proposé un algorithme amélioré basé sur les ANN appelé Extreme Learning Machine (ELM). Le modèle ELM offre des avantages importants tels que la vitesse d'apprentissage, la précision de la prédiction et la facilité de sa mise en œuvre. En raison de son efficacité remarquable, de sa simplicité et de ses performances de généralisation, ELM a récemment été appliqué dans divers domaines tels que l'ingénierie biomédicale, la vision par ordinateur, l'identification du système, le contrôle et la robotique [231]. Dans ce chapitre on proposera un nouveau modèle basé sur le modèle ELM.

4.3 Modèle prédictif

Dans cette partie, nous allons nous intéresser au modèle de prédiction ELM pour assurer un système de surveillance à distance rapide et pour améliorer la capacité de réaction en temps réel.

4.3.1 Modèle ELM

Le modèle ELM proposé par Huang et al [230], il est identifié comme une technique d'apprentissage émergente qui offre une solution globalement optimale avec un apprentissage rapide et de bonnes performances de généralisation. Dans l'étape d'apprentissage, ELM sélectionne aléatoirement les poids d'entrée et les biais et il détermine, par la suite, les poids et les biais sans ajustement supplémentaire d'une façon analytique. ELM détermine les matrices de sortie de la couche cachée avec la notion Pseudo-Inverse [232].

4.3.2 Principe du ELM

La structure du modèle ELM est une structure simple de type SLFN qui se compose d'une couche d'entrée, d'une couche cachée et d'une couche de sortie. Chaque neurone est lié à l'aide d'une connexion pondérée appelée poids (w). D'autres paramètres sont également utilisés qui sont : le biais (b) fournissant des paramètres ajustables supplémentaires du modèle et la fonction de transfert (f) qui calcule la

sortie (y). La fonction de transfert f peut être logarithmique, linéaire, hyperbolique Tang, base radiale ou fonctions sigmoïdes. Nous pouvons donc décrire le réseau en utilisant le triplet (w, b, f) . La figure 4.1 présente la structure du modèle ELM. Stratégie de ELM : Pour N échantillons distincts x_i , avec $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n$

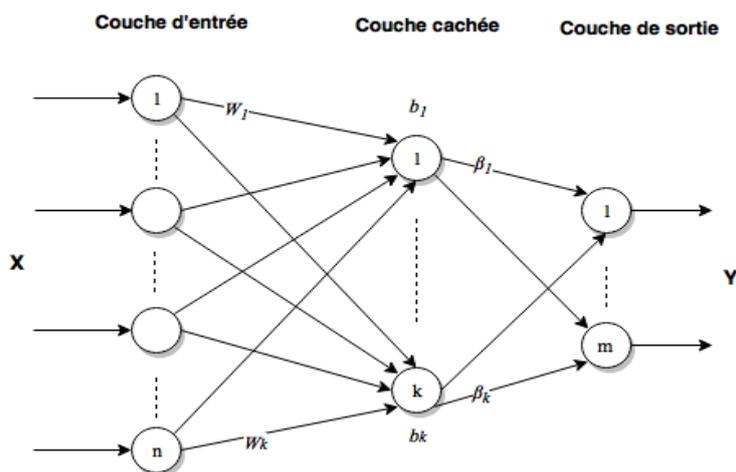


FIGURE 4.1 – Structure du modèle ELM

\mathbb{R}^n le vecteur des entrées et $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in \mathbb{R}^m$, le vecteurs des sorties. La sortie y_i de ELM est données par :

$$y_i = \sum_{j=1}^k \beta_j f(w_j \cdot x_i + b_j), \quad i = 1, \dots, N \quad (4.1)$$

Où $w_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T \in \mathbb{R}^n$ représente le vecteur des poids reliant les couches d'entrée et les j^{th} nœuds cachés, $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jm}]^T \in \mathbb{R}^m$ représente le vecteur de poids qui relie les nœuds de sortie et les j^{th} nœuds cachés, et $w_j \cdot x_i$ indique le produit scalaire de w_j et x_i et f présente la fonction de transfert/activation. L'équation ci-dessus (4.2) peut être écrite sous la forme matricielle suivante :

$$H\beta = y \quad (4.2)$$

Où H représente la matrice de sortie de la couche cachée du réseau :

$$H = \begin{bmatrix} f(w_1 \cdot x_1 + b_1) & \dots & f(w_k \cdot x_1 + b_k) \\ \vdots & & \vdots \\ f(w_1 \cdot x_N + b_1) & \dots & f(w_k \cdot x_N + b_k) \end{bmatrix}_{N \times k} \quad (4.3)$$

$$\text{avec } \beta = \begin{pmatrix} \beta_1^T \\ \vdots \\ \beta_k^T \end{pmatrix}_{k \times m} \quad \text{et} \quad y = \begin{pmatrix} y_1^T \\ \vdots \\ y_k^T \end{pmatrix}_{N \times m}$$

Les poids d'entrées et les biais de couches cachées sont déterminés aléatoirement selon la matrice de sortie H . Ainsi, l'apprentissage de ELM est tout simplement équivalent à trouver la dernière solution des moindres carrés β comme suit :

$$\beta = H^+ y \tag{4.4}$$

Où H^+ est donnée par :

$$H^+ = (H^T H)^{-1} . H^T \tag{4.5}$$

Généralement, β contient la solution optimale du ELM, qui peut fournir une généralisation optimale des poids et des biais de sortie de notre réseau, β est unique, donc cela peut éviter de produire une solution optimale locale. En fonction de β l'erreur de l'apprentissage peut être améliorée. l'algorithme ELM est resumé comme suit :

Algorithm 2 Pseudo code de ELM

1. Début

2. Choisir les valeurs de **poids** w_i et de **biais** b_i aléatoirement, avec $i = 1, \dots, k$;
avec $\# k$ est le nombre de neurones de couche cachés
3. Calculer **output matrix** de la couche cachée ;
4. Calculer **output weight** en utilisant *Equation (4.4)* ;

5. Fin

4.4 Nouvelle approche

Comme notre application est dédiée à la surveillance des personnes âgées et des personnes en perte d'autonomie. Ces personnes sont très sensible en terme d'autonomie, les centres de surveillance sont tenus à offrir des services fiables et robuste à ces patients et à éviter toute forme de défaillance. Pour cette raison, nous allons nous concentrer sur l'amélioration du modèle ELM connu par sa rapidité. Toutefois, ELM est insuffisant de prédire les séries temporelles qui nécessitent des capacités de stockage importantes [233], afin d'atteindre un taux important de précision et de rapidité de prédiction nous proposons d'intégrer la notion de récurrence dans le modèle ELM classique. La nouvelle forme assure une relation temporelle entre les données d'entrée et les observations précédentes. Le nouveau

modèle utilise des connexions de retour à la couche d'entrée à partir de la couche de sortie ce qui permet d'inclure la sortie précédente dans la nouvelle prédiction à long terme. Un réseau dynamique récurrent, avec des connexions de retour de la sortie du réseau, est proposé pour prédire les activités futures de l'habitant [207, 234]. Cette approche récurrente a été appliquée pour assurer principalement les avantages suivants :

- Une forte capacité dans la modélisation des applications qui nécessite des dépendances temporelles entre les sorties et les entrées,
- Une prédiction et une identification efficace des problèmes complexes qui nécessitent l'évaluation d'une quantité importante de données,
- De meilleurs résultats de prédiction pour les systèmes dynamiques et de contrôle,
- Une amélioration du taux d'exactitude avec la prise en considération des données antérieures dans la prédiction des données actuelles.

4.4.1 Reccurent Extreme Learning Machine (RELM)

4.4.1.1 Description du RELM

Dans cette partie, nous allons définir le modèle de prédiction proposé dénommé RELM "Reccurent Extreme Learning Machine". Il s'agit d'un modèle récurrent qui permet l'intégration de la sortie précédente dans la prédiction actuelle du comportement. Notre modèle garantit une caractéristique dynamique en fournissant une relation temporelle entre les observations à des moments différents. Par conséquent, grâce aux connexions de rétroaction, notre modèle devient capable de traiter les relations temporelles entre les données d'entrée et les données de sorties. La figure 4.2 montre l'architecture du modèle RELM proposé.

4.4.1.2 Fonctionnement du RELM

Nous cherchons à trouver une approximation de la fonction suivante :

$$y(t+1) = f[x(t), x(t-1), \dots, x(t-N_x), y(t), y(t-1), \dots, y(t-N_y)] \quad (4.6)$$

où $y(t+1)$ désigne la sortie prédite à l'instant $t+1$, $x(t)$ est l'entrée du modèle au moment t , f est la fonction d'activation, N_x et N_y représentent l'ordre de la mémoire d'entrée et de sortie respectivement. La sortie prédite $y(t+1)$ est une régression de la valeur d'entrée $x(t+1)$. La relation (4.7) peut être réécrite comme suit :

$$y(t+1) = \sum_{j=1}^k \beta_j f(w_j \sum_{i=1}^{N_x} x(i) + b_j) + \sum_{j=1}^k \beta_j f(w_j \sum_{m=1}^{N_y} y(m) + b_j) \quad (4.7)$$

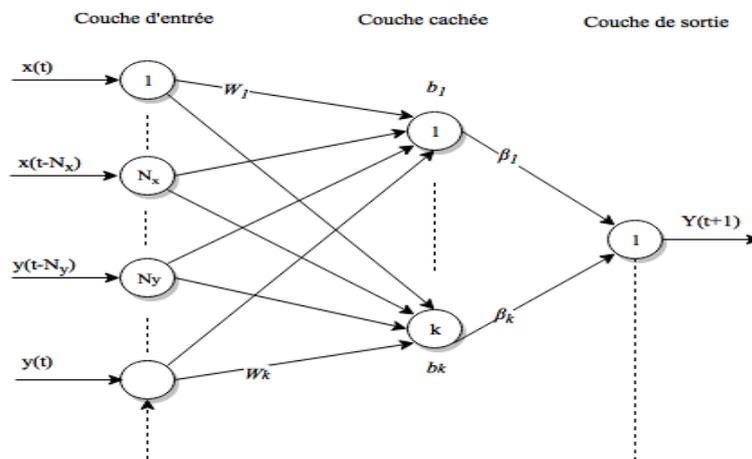


FIGURE 4.2 – Structure du modèle RELM

Avec,
 $X = [x(t), x(t-1), \dots, x(t-N_x)]$, $Y = [y(t), y(t-1), \dots, y(t-N_y)]$,
 $w_j = [w_{j1}, w_{j2}, \dots, w_{j(N_x+N_y)}]^T$ est le vecteur des poids qui connecte la couche d'entrée avec la j^{eme} neurone de la couche cachée, $\beta = [\beta_1, \dots, \beta_k]^T$ est le vecteur de poids qui relie la couche de sortie et la j^{eme} neurone de la couche cachée, β_i représente le biais de b_j neurone de la couche cachée.

Puisque les poids d'entrée et les biais de couche cachée sont déterminés aléatoirement selon la matrice de sortie $H(t)$, l'apprentissage de notre réseau revient à trouver la dernière (last square) solution de β avec l'équation suivante :

$$\beta = (H(t)^+) \cdot y(t+1) \quad (4.8)$$

Avec $H(t)^+$ est la pseudo inverse de la matrice $H(t)$. L'équation (4.8) peut être simplifiée comme suit :

$$H(t) \cdot \beta = y(t+1) \quad (4.9)$$

$$\text{Avec, } H(t) = \left[\begin{array}{c} \text{feedforward} \\ \text{matrix} \end{array} \right] \begin{array}{c} \rangle \\ N_x+1 \times k \end{array}, \\
 \left[\begin{array}{c} \text{backforward} \\ \text{matrix} \end{array} \right] \begin{array}{c} \langle \\ N_y+1 \times k \end{array}$$

$$H(t) = \left[\begin{array}{c} \left\{ \begin{array}{ccc} \xrightarrow{\text{Forward}} & \rightarrow & \rightarrow \\ f(w_1.x(t) + b_1) & \dots & \dots \\ \vdots & & \\ \vdots & & \\ f(w_1.x(t - N_x) + b_1) & \dots & \dots \\ \end{array} \right\} & \dots & \dots & \left\{ \begin{array}{ccc} \xrightarrow{\text{Forward}} \\ f(w_k.x(t) + b_k) \\ \vdots \\ \vdots \\ f(w_k.x(t - N_x) + b_k) \end{array} \right\} \\ \left\{ \begin{array}{ccc} \xleftarrow{\text{Backward}} & \leftarrow & \leftarrow \\ f(w_1.y(t) + b_1) & \dots & \dots \\ \vdots & & \\ \vdots & & \\ f(w_1.y(t - N_y) + b_1) & \dots & \dots \\ \end{array} \right\} & \dots & \dots & \left\{ \begin{array}{ccc} \xleftarrow{\text{Backward}} \\ f(w_k.y(t) + b_k) \\ \vdots \\ \vdots \\ f(w_k.y(t - N_y) + b_k) \end{array} \right\} \end{array} \right]_{(N_x+N_y+2) \times k} \tag{4.10}$$

Dans notre modèle, la matrice de sortie de la couche cachée se compose de deux sous-matrices à savoir la matrice *feed-forward* et la matrice *back-forward* de retour. La matrice *feed-forward* représente la même matrice de sortie du modèle ELM classique. Elle indique au début le produit scalaire de W_j et x en ajoutant les valeurs des biais associés au neurone b_j de la couche cachée. Cette matrice est calculée enfin avec la fonction d'activation f . La matrice *back-forward* de retour contient toutes les sorties précédentes. Elle indique en premier lieu le produit scalaire de W_j et x en ajoutant les valeurs des biais des neurones b_j de la couche cachées avec x et y comme présenté précédemment. Par conséquent, nous pouvons conclure que la prédiction obtenue par le nouveau ELM récurrent est plus précise que celle obtenue par ELM classique, car la valeur prédite $y(t + 1)$ du RELM est toujours composée de la valeur d'entrée $x(t)$ et de sortie $y(t)$. L'algorithme 3 représente le pseudo-code du modèle RELM.

Algorithm 3 Pseudo code du RELM

1. **Début**
2. **Pour** chaque séquence de l'ensemble d'apprentissage
3. Choisissez aléatoirement les valeurs du **pooids** w_i et du **biais** b_i
 pour $(N_x + 1 \times k)$ **forward matrix** ;
 % avec $i \in \{1, \dots, k\}$ est l'indice du neurone de la couche cachée
4. Choisissez aléatoirement les valeurs du **pooids** w_i et du **biais** b_i
 pour $(N_y + 1 \times k)$ **backward matrix** ;
 % avec $i \in \{1, \dots, k\}$ est l'indice du neurone de la couche cachée
5. Calculer $H(t)$ **output matrix** de la couche cachée donnée par (4.10) ;
6. Calculer β **output weight** selon (4.8) ;
7. **Fin Pour**
8. **Fin**

La figure 4.3 présente le processus de la prédiction en utilisant le modèle RELM. Comme nous l'avons déjà mentionné les principales étapes du modèle de prédiction sont : le prétraitement des données, la sélection de l'ensemble d'apprentissage et enfin la reconnaissance et la prédiction. Dans la partie suivante, nous allons

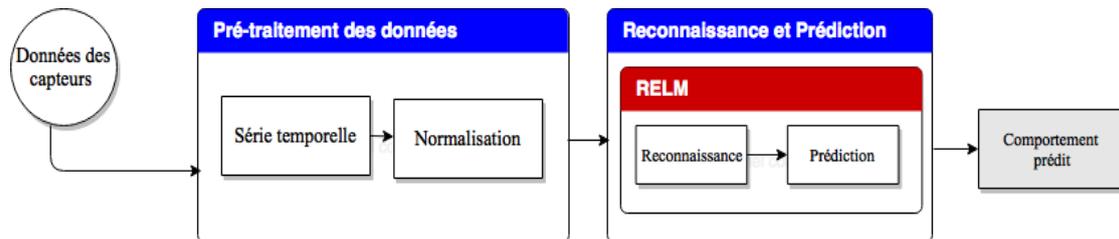


FIGURE 4.3 – Processus de prédiction utilisé par RELM

nous intéresser d'appliquer le modèle RELM pour reconnaître et pour prédire les activités quotidiennes de la personne et d'étudier leurs performances en termes de précision et rapidité de prédiction.

4.5 Évaluation des paramètres du modèle RELM

Afin d'améliorer considérablement l'efficacité de notre modèle proposé RELM, il est important de déterminer les paramètres qui sont appropriés pour notre réseau. Il convient de souligner que le réglage du RELM n'est pas très compliqué puisqu'il n'y a que trois paramètres à définir, à savoir le nombre de neurones cachés, le nombre de neurones de sortie récurrents et la fonction d'activation. Le nombre

de neurones cachés (Hidden Neuron Number-HNN) et le nombre de neurones récurrents (Recurrent Neuron Number-RNN) ont un impact important sur les performances du modèle RELM en termes de temps d'apprentissage et de taux de prédiction. De ce fait, pour construire un modèle optimal, un paramétrage raisonnable devrait être identifié pour HNN et RNN. Par conséquent, de nombreux tests doivent être effectués afin de sélectionner les paramètres optimaux. Pour atteindre cet objectif, nous allons analyser tout d'abord la relation entre HNN et RNN en termes d'erreur de prédiction. Ici nous choisissons d'évaluer l'RMSE (figure 4.4). Par la suite, nous allons étudier l'impact du nombre de neurones cachés(HNN) sur le temps d'apprentissage (figure 4.5). Le nombre de paramètres utilisés dans notre évaluation est :

HNN = [1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 15, 20, 25, 30, 35, 40, 50, 100]

et

RNN = [1, 2, 3, 4, 5].

La figure 4.4 illustre l'impact du nombre de neurones cachés (HNN) et le nombre de neurones récurrents (RNN) sur le taux de précision du modèle. La figure 4.4 montre que lorsque le nombre de nœuds cachés est entre 1 et 5 et le nombre de nœuds récurrents est entre 1 et 3, le taux d'erreur du modèle n'est pas suffisamment petit, par conséquent le modèle RELM n'est pas prêt pour avoir une meilleure prédiction. Lorsque $HNN > 5$ et RNN est compris entre 1 et 3, nous observons que le taux d'erreur commence à être stabilisé mais pas assez par rapport au cas lorsque $RNN \geq 4$. En effet, RELM atteint la précision maximale lorsque $HNN \geq 5$ et $RNN \geq 4$. De plus, lorsque $HNN > 5$ et $RNN > 4$ le RMSE est presque stable. La figure 4.5 illustre l'impact de HNN sur le temps d'apprentissage du RELM. Nous pouvons constater que le temps d'apprentissage augmente progressivement lorsque le nombre de neurones cachés augmente. Concernant le troisième paramètre du modèle RELM (la fonction de transfert), un choix pertinent de la fonction de transfert est très important car il affecte le comportement des neurones. Tenant compte des travaux existants dans la littérature, la fonction sigmoïde est parmi les fonctions de transfert les plus utilisées dans les problèmes de prédiction des séries chronologiques ou temporelles [235, 236]. Dans notre modèle, nous proposons d'utiliser la fonction sigmoïde comme une fonction d'activation afin d'effectuer une approximation globale et continue de l'intégralité des données d'entrée. De nombreuses expérimentations effectuées lors du réglage de modèle RELM nous ont permis de déterminer le meilleur comportement de RELM en fonction des paramètres HNN, RNN et la fonction de transfert. Ainsi, notre modèle RELM se caractérise par 5 neurones cachés 4 neurones récurrents et la fonction sigmoïde comme une fonction d'activation.

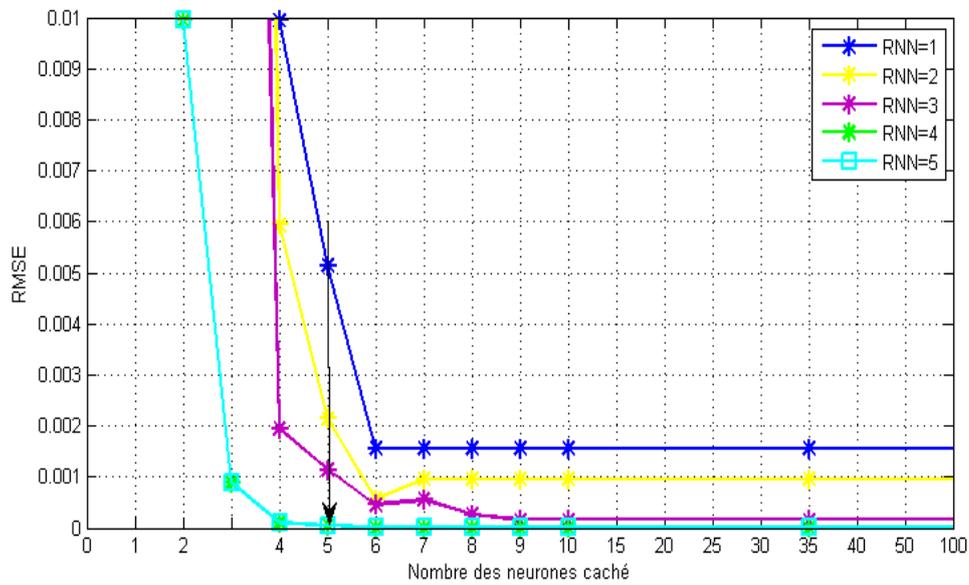


FIGURE 4.4 – Évaluation du RELM en fonction de RMSE basée sur le nombre de neurones cachés (HNN) et le nombre actuel de neurones récurrent (RNN)

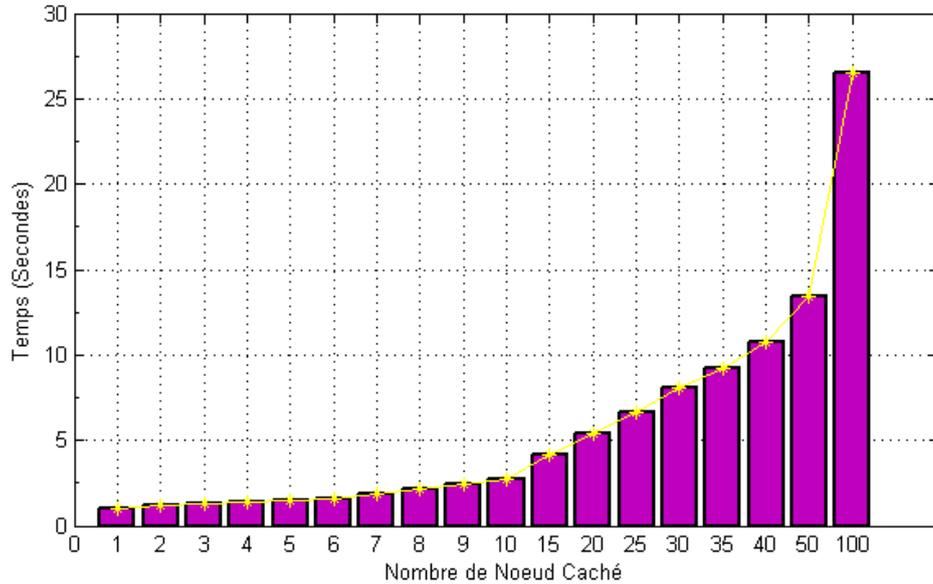


FIGURE 4.5 – Évaluation du temps d'apprentissage en fonction du nombre HNN

4.6 Résultats de simulation

Afin d'appliquer notre modèle RELM pour reconnaître et prédire le comportement et les activités quotidiennes de la personne, il est nécessaire de suivre le processus de prédiction présenté dans la figure 4.3. L'ensemble des données utilisées et qui représentent le comportement de la personne sont celles utilisées dans le chapitre 3 (sections 2) après l'application du processus de prétraitement. Une fois la phase de prétraitement des données est terminée, le modèle RELM est appliqué pour prédire le comportement futur des personnes âgées. Le modèle RELM est similaire à un réseau de neurones. Par conséquent, afin d'effectuer une prédiction efficace, un nombre suffisant d'échantillons d'apprentissage et de validation est nécessaire. Il est donc important de sélectionner les ensembles de données d'apprentissage et celles de validation dans le but de satisfaire les exigences du RELM. A cet effet, il est crucial de diviser les données réelles d'entrée en deux parties : un ensemble d'apprentissage qui représente les activités durant trois semaines, qui sera utilisé pour construire et former notre modèle, et un ensemble de test élaboré sur neuf semaines, qui sera utilisé pour évaluer notre modèle sur un échantillon de données différent de celui utilisé dans l'étape d'apprentissage.

4.6.1 Performances du RELM

Dans la phase d'apprentissage, nous estimons les paramètres du modèle et nous évaluons l'erreur de prédiction au cours des trois premières semaines de l'ensemble de données d'entrée. Nous allons nous concentrer d'abord sur l'évaluation des résultats obtenus dans la phase d'apprentissage. Les valeurs prédites sont comparées avec les valeurs réelles. Dans la figure 4.6, nous montrons un échantillon de six jours du résultat de prédiction du scénario qui représente les activités des personnes âgées prédites par rapport aux données réelles dans la phase d'apprentissage. La ligne pointillée en bleue représente les données réelles et la ligne pointillée en rouge représente les données prédites pour chaque jour. La figure 4.6 montre que les données prévues correspondent parfaitement aux données réelles fournies par les capteurs pendant les 6 jours. Les résultats de la phase d'apprentissage promettent de bonnes prédictions dans la phase de test en utilisant les paramètres formés. La prochaine étape de notre évaluation est l'analyse des résultats de la prédiction obtenus par RELM dans la phase de validation. Au cours de la phase de validation nous allons appliquer le modèle RELM basé sur les paramètres obtenus dans la phase d'apprentissage afin de prédire les scénarios futurs des personnes âgées. Pour ce faire, nous allons utiliser les données de test et évaluer les performances du RELM en utilisant les trois mesures suivants : l'RMSE (Root Mean Square

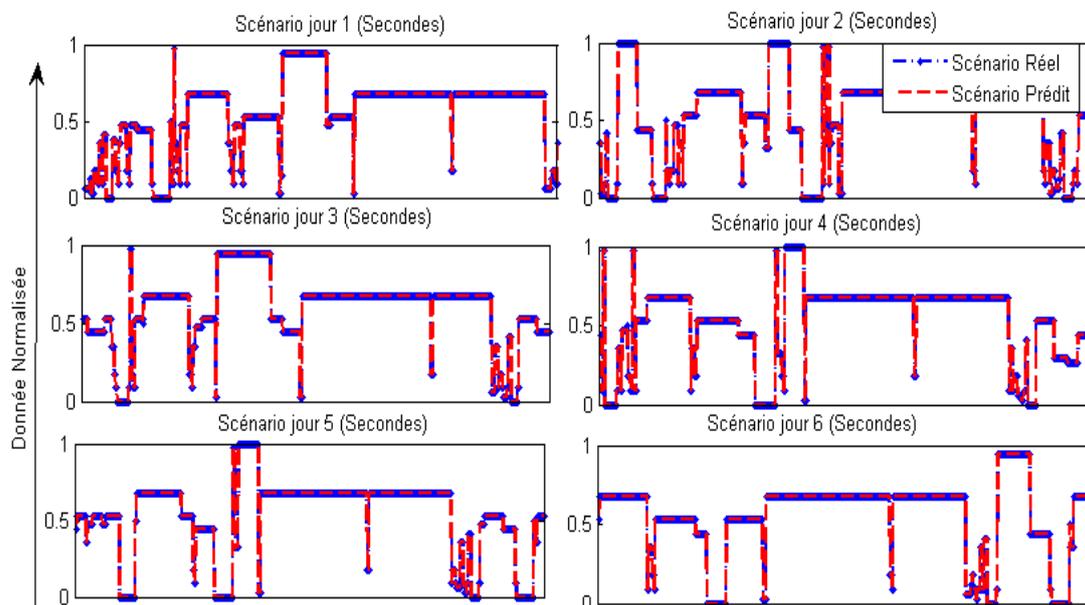


FIGURE 4.6 – Comparaison des scénarios réels et prévus dans la phase d'apprentissage pendant 6 jours.

Error)(4.11), la Similarité cosinus (4.12) et le pourcentage de l'erreur (PE)(4.13).

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4.11)$$

$$Similarity = \frac{y - \hat{y}}{\|y\| \times \|\hat{y}\|} \quad (4.12)$$

$$PE = 100 \cdot \frac{|y - \hat{y}|}{y} \quad (4.13)$$

Où N est le nombre des données, y représente les données réelles et \hat{y} est les données prédites.

Pour évaluer la précision de la prédiction du RELM, l'évaluation est effectuée pendant neuf différentes périodes. En outre, nous allons évaluer la similarité, l'RMSE, le pourcentage d'erreur (PE) et le pourcentage de similarité (PS). Chaque intervalle du temps de test dure un jour. Le tableau 4.1 illustre les résultats d'évaluation obtenus. Ces résultats fournissent de bonnes performances concernant la précision de la prédiction des scénarios dans la phase de validation. En effet, à partir du tableau 4.1 nous pouvons observer que le RMSE dans l'étape du test est délimité par 2.2146×10^{-4} et 2.3457×10^{-4} avec un taux de similarité élevée variant de 0,9978 à 0,9993. Le pourcentage d'erreur observé est faible et varie de 8,11% à 12,10%

alors que le pourcentage de similarité est au maximum 87,90% et peut atteindre 91,90%. A titre d'exemple pour la période 3, les mesures de performances obtenues sont : PS = 91.1521%, RMSE = 2.2630×10^{-4} , similarité = 0.9978 et un PE de 8.8479%. Dans le domaine de l'e-santé, le temps d'apprentissage est d'une impor-

TABLE 4.1 – Évaluation de la prédiction du RELM dans l'étape de test

	RMSE	Similarité	PE(%)	PS(%)
<i>Periode</i> ₁	2.2776×10^{-4}	0.9982	9.7757	90.2243
<i>Periode</i> ₂	2.2818×10^{-4}	0.9981	9.0219	90.9781
<i>Periode</i> ₃	2.2630×10^{-4}	0.9978	8.8479	91.1521
<i>Periode</i> ₄	2.2911×10^{-4}	0.9981	9.3887	90.6113
<i>Periode</i> ₅	2.3236×10^{-4}	0.9984	10.0653	89.9347
<i>Periode</i> ₆	2.3230×10^{-4}	0.9983	10.0648	89.9352
<i>Periode</i> ₇	2.2146×10^{-4}	0.9979	8.1065	91.8935
<i>Periode</i> ₈	2.2860×10^{-4}	0.9982	8.9060	91.0940
<i>Periode</i> ₉	2.3457×10^{-4}	0.9993	12.0979	87.9021

tance primordiale pour la prédiction des changements comportementales et des situations d'urgence. Nous allons évaluer le modèle RELM en fonction du temps de calcul, en fait nous allons nous concentrer sur le temps d'apprentissage et celui de la validation. De ce fait, nous allons considérer 10 simulations afin d'identifier la valeur moyenne du temps requis. Le tableau 4.2 illustre les résultats d'évaluation. Les résultats obtenus montrent un temps moyen efficace d'apprentissage qui est de 1.492 secondes. Les résultats confirment la rapidité de notre modèle dans la

TABLE 4.2 – Évaluation du RELM en fonction du temps d'apprentissage

Nombre de simulation	1	2	3	4	5	6	7	8	9	10	Moyenne
Temps d'apprentissage (Sec)	1.389	1.597	1.493	1.543	1.587	2.645	1.816	1.494	1.463	1.439	1.492

phase d'apprentissage. Le tableau 4.3 montre les résultats d'évaluations similaires appliquées dans la phase de validation. Le temps du test du RELM a été évalué au cours des 10 simulations. Les résultats obtenus durant cette phase de validation montrent que la moyenne du temps de calcul est de 0,0493 secondes, ce qui confirme à son tour la rapidité de notre modèle dans la phase de validation. En se

TABLE 4.3 – Évaluation du RELM en fonction du temps de test/validation

Nombre de simulation	1	2	3	4	5	6	7	8	9	10	Moyenne
Temps de validation(Sec)	0.050	0.044	0.044	0.043	0.039	0.065	0.061	0.044	0.059	0.044	0.0493

basant sur les résultats obtenus précédemment concernant le taux de précision et

la rapidité du modèle RELM, nous pouvons conclure que notre modèle assure une prédiction précise et rapide au cours du processus de prédiction.

4.6.2 Étude comparative

Afin de confirmer la suprématie de notre modèle proposé, nous effectuons une étude comparative, nous allons comparer notre modèle proposé (RELM) avec les modèles suivants : ELM, SLFN-DE, Elman-NN-DE, Sa-ELM et ELM-GA. Les mesures de performances utilisées sont : RMSE, le temps d'apprentissage et le temps de validation. Le tableau 4.4 résume les valeurs de l'RMSE obtenues au cours de la phase d'apprentissage et la phase de validation pour tous les modèles mentionnés. On note une meilleure performance du RELM liée à la précision de la prédiction avec une petite valeur de l'RMSE par rapport aux modèles existants. Dans le tableau 4.5, nous allons comparer le temps d'apprentissage et de validation pour tous les modèles de prédiction sur-cités. Les résultats révèlent que même si les résultats obtenus par le modèle ELM classique dans la phase d'apprentissage et de validation sont meilleurs que ceux obtenus avec RELM, la différence n'est pas significative par rapport aux autres modèles. En effet, les deux résultats de temps de RELM sont beaucoup plus petits que ceux obtenus avec SLFN-DE, Elman-NN-DE, Sa-ELM et ELM-GA en particulier concernant l'étape d'apprentissage où la différence observée est très significative. Les résultats d'évaluation et de compa-

TABLE 4.4 – Évaluation de l'RMSE pendant la phase d'apprentissage et de validation

Modèles	RMSE	
	Apprentissage	Validation
RELM	1.5625×10^{-6}	2.2818×10^{-4}
Classic ELM	0.3872	0.073
Sa-ELM	1.0147×10^{-3}	9.0701×10^{-2}
ELM-GA	1.6263×10^{-3}	1.5909×10^{-1}
SLFN-DE	8.9167×10^{-5}	0.0518
Elman-NN-DE	6.1813×10^{-4}	0.0852

raison obtenus confirment les performances de notre modèle proposé RELM en termes de précision et rapidité de prédiction. Cela nous encourage à modéliser un système de prise de décision complet dans le cadre d'une surveillance de la santé à domicile. La partie suivante est dédiée à une étude de cas qui évalue « le taux de dépression chez les personnes âgées ». Une surveillance à domicile de l'état de santé et du comportement d'une personne âgée aide à distinguer les changements de l'autonomie, du comportement et la déstabilisation de l'état de santé. Chez les personnes âgées, le changement du comportement indique généralement une perturbation de l'état de santé ou du niveau d'autonomie. Plusieurs activités de

TABLE 4.5 – Évaluation de temps d'apprentissage et de validation.

Modèles	Temps(seconds)	
	Apprentissage	Validation
RELM	3.1996	0.060300
Classic ELM	0.0583821	0.044905
Sa-ELM	308.816570	0.085641
ELM-GA	83.179903	0.065465
SLFN-DE	3469.728034	0.394624
Elman-NN-DE	578.255760	0.895468

la vie quotidienne peuvent être des symptômes de maladies chroniques telles que le diabète, la tension artérielle ou des maladies psychiques telles que l'Alzheimer, la dépression, etc. En général, les premiers symptômes deviennent perceptibles et compréhensibles à partir du comportement de la personne. Les symptômes de la maladie apparaissent parfois par un changement du comportement quotidien. Alors, le système peut détecter les symptômes des maladies à partir des changements d'activités ou du changement de comportement par rapport à la norme.

4.7 Système d'aide à la décision

Le processus de surveillance à domicile peut être représenté par un système circulaire fermé, comme le montre la figure 4.7.

La prise de décision dans les systèmes de surveillance de santé à domicile est un processus cognitif complexe visant la sélection d'un type d'actions parmi différentes alternatives. Ce processus est théoriquement basé sur des critères de choix et sur des analyses logiques. Le résultat peut être une action ou une mise à jour des connaissances. Le décideur peut être un soignant, un conseiller, un médecin, ou une entité multiple (famille, voisins, soignants). Partant de ce principe, nous allons dans la suite nous intéresser à l'implémentation d'un système de prise de décision adéquat pour les personnes âgées dans le contexte d'une surveillance à domicile de la santé. Nous allons nous focaliser sur le cas de la « dépression chez les personnes âgées ».

4.8 Étude de cas : dépression chez les personnes âgées

Dans le reste de ce chapitre, nous allons examiner une étude de cas relative à l'évaluation du taux de dépression chez les personnes âgées. Ce choix a été dicté par les conséquences que peut avoir cette maladie et la difficulté d'être diagnostiqué

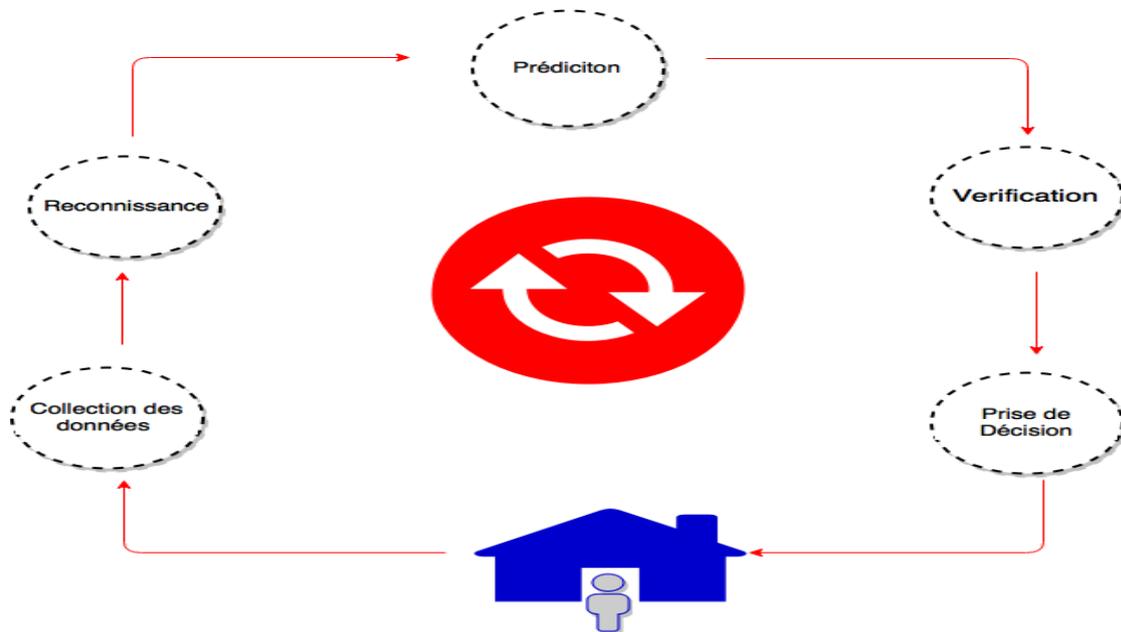


FIGURE 4.7 – Processus de surveillance à domicile

par des médecins et à distance. On commence par définir la dépression en général et en particulier chez les personnes âgées.

4.8.1 La dépression

La dépression (ou trouble dépressif) est une maladie psychique qui affecte principalement l'humeur de la personne. En fait, c'est un état de trouble et de mauvaise humeur qui perturbe fortement la vie quotidienne de l'être humain.

Toutes les personnes dépressives ont généralement une aversion envers les activités physiques. Cela peut affecter les pensées, le comportement, les émotions et le sentiment du bien-être [237, 238]. Les personnes souffrant d'humeur dépressive peuvent être particulièrement tristes, anxieuses ou vides. Elles peuvent également se sentir particulièrement désespérées, impuissantes, abattues ou sans valeur. D'autres symptômes exprimés peuvent inclure des sentiments de culpabilité, d'irritabilité ou de colère [239, 240] ou un sentiment de honte ou une inquiétude exprimée. Les personnes dépressives risquent notamment de ne plus s'intéresser à des activités quotidiennes, ou qu'elles éprouvent une perte d'appétit ou un excès de repas mais aussi une perturbation de sommeil. La maladie stimule également des facteurs notables chez les individus tels que les problèmes liés à la concentration, à des complications de prendre des décisions ou à avoir des difficultés relationnelles avec l'entourage et peuvent également entraîner une tentative de suicide. En plus de

tous les facteurs susmentionnés, l'insomnie exprimée, le sommeil excessif, la fatigue, les douleurs et les problèmes digestifs peuvent également être présents chez les personnes souffrant de dépression [241].

4.8.2 La dépression chez les personnes âgées

Les personnes âgées font partie des personnes les plus susceptibles d'être atteintes par les maladies dépressives. Selon les dernières enquêtes réalisées en France, environ 33 % des résidents d'un EHPAD (établissement d'hébergement pour les personnes âgées et dépendantes) souffriraient de dépression (Drees, ministère de la Santé, 2006). Les symptômes dépressifs se développent entre 18 à 37% chez les personnes âgées [242] et augmentent avec l'âge [243]. De plus, il existe un important afflux annuel de nouveaux cas [244]. La dépression est un problème fréquent chez les personnes âgées de multiples facteurs stimulent leur apparition et augmentent le risque d'être déprimés. Par exemple :

- La solitude et l'isolement,
- Le processus normal de vieillissement,
- Le départ à la retraite,
- Le changement et le sentiment de ne plus être utile,
- Les problèmes de santé comme par exemple les démences, les maladies cardiovasculaires ou l'Alzheimer qui impacte la mobilité et l'état physique général,
- Les médicaments,
- Les angoisses avec la peur de mourir ou la peur des problèmes financiers, le décès du conjoint ou des proches.

Les études effectuées sur les patients ayant des maladies physiques, ont montré que la dépression augmente considérablement la probabilité d'être attaqué par d'autres maladies telles que les maladies cardiaques, l'obésité, etc. Pour cette raison, il est important de suivre quotidiennement l'état de santé de la personne âgée afin de détecter la présence d'un changement comportemental et de s'assurer qu'une personne est traitée même si la dépression est légère. De plus, la prévention de la dépression chez les personnes âgées est un problème majeur de santé publique [245]. Il est donc important de bien identifier les signes et les symptômes de la dépression afin d'évaluer le taux de dépression chez la personne, d'agir et d'intervenir dans le temps nécessaire.

4.8.3 Les symptômes de la dépression chez les personnes âgées

Il existe plusieurs symptômes dépressifs souvent attribués au vieillissement. Ils sont variés de point de vue type. Pour cette raison, nous allons proposer de les classer en deux catégories :

Les symptômes liés au changement des sentiments : tels que l'humeur dépressive, la tristesse, la perte d'intérêt, le ralentissement ou l'agitation psychomotrice, le sentiment d'infériorité, la perte de l'estime de soi, le sentiment de culpabilité et les difficultés de concentration, etc.

Les symptômes liés au changement du comportement : tels que la fatigue ou la perte d'énergie, les troubles de l'appétit (diminution ou augmentation), les troubles du sommeil (diminution ou augmentation), perturbation dans l'entretien ménager (désordre et hygiène), diminution d'activités de loisirs (TV, lecture, sortir, etc.), etc.

La reconnaissance des symptômes de la dépression chez les personnes âgées est une étape cruciale et nécessaire avant le traitement et l'évaluation de cette maladie [246]. Une étude des travaux qui ont été effectués pour l'identification des signes et des symptômes de la dépression chez les personnes âgées peut améliorer la compréhension et faciliter la découverte des symptômes dépressifs comportementaux. La compréhension des symptômes permet de faciliter la découverte des symptômes dépressifs chez les personnes âgées [247]. Par conséquent, une connaissance approfondie de ces symptômes conduit à un traitement approprié et opportun qui pourrait entraîner une diminution du nombre de cas de suicide des personnes âgées [248]. Les auteurs de [249] ont déterminé que les connaissances des symptômes dépressifs, l'intervention précoce et l'évaluation sont particulièrement nécessaires pour les personnes âgées. On s'intéresse dans notre étude à la deuxième catégorie. En effet, il existe plusieurs symptômes de dépression liés aux activités quotidiennes et qui stimulent un changement de routine quotidienne de la personne. Plusieurs chercheurs ont montré la présence d'un lien fort entre les signes de dépression et les activités quotidiennes. Tenant compte de ces recherches effectuées dans le domaine médical et psychologique, nous allons examiner les symptômes dépressifs chez les personnes âgées et nous allons nous focaliser sur les symptômes de dépression relatifs aux activités de la vie quotidienne nommées (*Activities Of Daily Living-Depression symptoms (ADL-DS)*). En outre, chaque perturbation ou changement de routine liée aux ADL-DS peut nous aider à identifier si le sujet est menacé par des signes de dépression ou non. Le tableau 4.6 présente les ADL-DS proposés dans la littérature. Après avoir défini et reconnu les ADL-DS, nous allons nous focaliser

TABLE 4.6 – Les activités de la vie quotidienne liées aux symptômes de dépression

References	Activités	Action
[250]	Limitation des activités de loisirs	Lire des journaux/ des livres/ Regarder la TV
		Se promener
[251, 252]	Trouble du sommeil	Dormir trop
		Dormir trop peu
[253, 254]	Trouble de l'alimentation	Manger trop
		Manger trop peu

sur l'implémentation de notre système qui sert à évaluer et à identifier le risque de dépression chez les personnes âgées en se basant sur leur comportement quotidien.

4.9 Système d'évaluation du risque de dépression

Dans notre étude, nous allons proposer un système de prise de décision pour évaluer d'une manière précise le risque de dépression et pour intervenir dans le temps nécessaire. Notre système est un système hybride qui sert à reconnaître, prédire le comportement de la personne et à évaluer le risque de dépression. La figure 4.8 présente notre modèle hybride, qui se compose de 5 phases :

- Phase 1 : Prétraitement des données collectées par les capteurs,
- Phase 2 : Reconnaissance et prédiction des activités,
- Phase 3 : Génération d'une base de connaissance appropriée aux symptômes dépressifs basée sur la sélection des ADL-DS,
- Phase 4 : Évaluation du risque de dépression chez la personne en utilisant la logique floue),
- Phase 5 : Prise de décision.

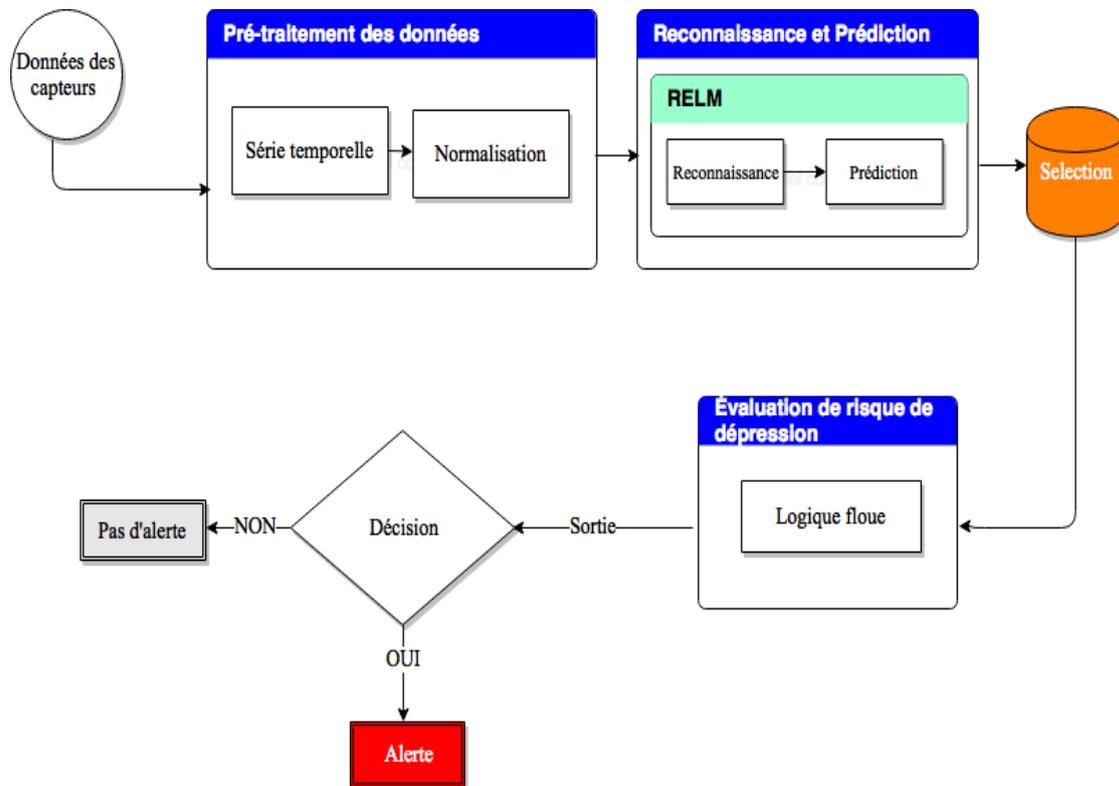


FIGURE 4.8 – Système de prise de décision pour l'évaluation de risque de dépression

Les deux premières phases ont été déjà détaillées dans la première partie de ce chapitre. Dans ce qui suit, nous allons nous intéresser à examiner le principe d'évaluation qui concerne le risque de dépression chez les personnes âgées.

4.9.1 Base de connaissance

Vu que les symptômes de la dépression changent d'une personne à une autre, nous intégrons une base de connaissances basée sur les activités quotidiennes relatives aux symptômes de dépression en se basant sur la routine et sur le profil de la personne. L'objectif est d'assurer une évaluation du risque de dépression efficace qui correspond à la nature de la personne (profil, routine et comportement).

4.9.1.1 Sélection des ADL-DS

La phase qui suit la reconnaissance des activités quotidiennes de la personne est la sélection des activités liées au symptôme dépressif. Dans cette phase nous proposons un algorithme de sélection qui sert à identifier tous les ADL-DS pour avoir par la suite une évaluation pertinente du risque de dépression. Notre algorithme

de sélection est nommé sélection des activités de la vie quotidienne liée aux symptômes de dépression (Selection of Activities of Daily Living-Depression Symptoms (S-ADL-DS)). Le principe de notre algorithme est comme suit : À partir d'une base de données importante des activités quotidiennes de la personne, nous allons sélectionner les ADL-DS qui sont : les activités de loisirs, le sommeil et d'alimentation. Le pseudo code suivant présente le principe de notre algorithme.

Algorithm 4 Pseudo code de S-ADL-DS

```
%C-ADL : Code des ADL
%C-ADL-DS : Code des ADL-DS
%T-ADL : tableau qui contient toutes les activités quotidiennes.
%N : taille du tableau T-ADL.
%T-ADL-DS : tableau qui contient les activités quotidiennes relatives aux symp-
tômes de dépression.
1.Début
2. k=1;
3. For i=1 :N
4.   act = T-ADL(i,3);
5.   Switch(act)
6.     Case(C-ADL)
7.       If C-ADL-DS==C-ADL Then
8.          $T - ADL - DS(k) \leftarrow C - ADL - DS$ 
9.         k=k+1;
10.      End if
11.    End
12.  End for
13.Fin
```

4.9.1.2 Les ADL-DS habituel de la personne

La maladie dépressive est fortement liée au comportement de la personne. Par conséquent, un changement significatif du comportement et de la routine de la personne indique un état anormal. Vu que notre étude est consacrée à l'évaluation des risques dépressifs chez les PAs une étude bien détaillée et profonde sur la routine des ADL-DS de la personne doit être mise en œuvre. Réellement, il existe deux critères principaux indispensables pour construire une base de connaissance qui décrit la routine des ADL-DS des personnes âgées. ces critères sont :

- La durée habituelle des ADL-DS,
- La fréquence habituelle des ADL-DS.

La durée habituelle des activités de la vie quotidienne liée aux symptômes de dépression (DH-ADL-DS) : Concerne la routine de la personne de point de vue du temps consacré pour chaque ADL-DS. Ce critère est utilisé dans le but de distinguer le minimum et le maximum de temps écoulé pour chaque activité dans une période de temps précise. La figure 4.9 montre la routine ADL-DS d'une personne saine/normale par semaine durant un mois.

La fréquence habituelle des activités de la vie quotidienne liées aux symptômes de

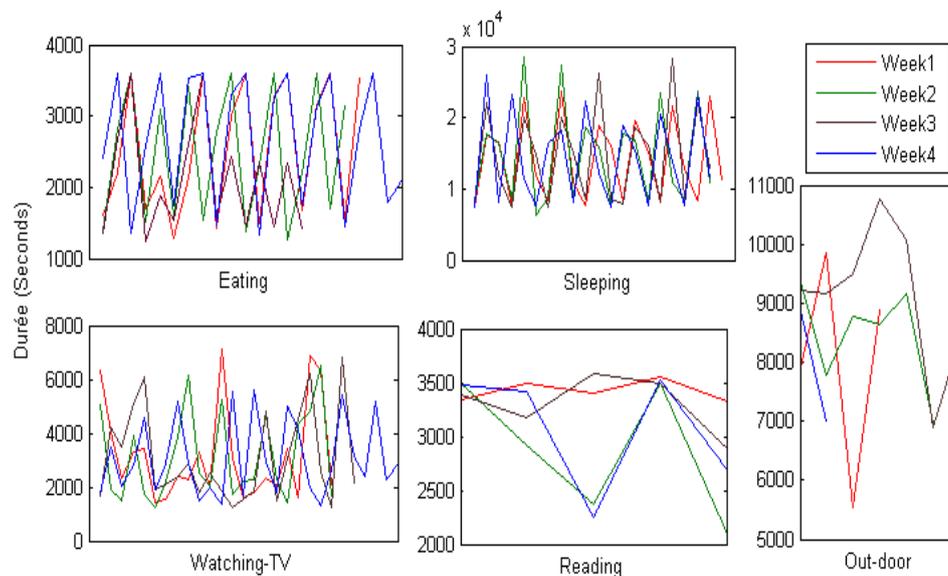


FIGURE 4.9 – La durée habituelle des activités de la vie quotidienne liées aux symptômes de dépression (DH-ADL-DS).

dépression (FH-ADL-SD) : La fréquence habituelle des activités quotidiennes est considérée comme étant un paramètre qui définit le nombre de fois requis pour réaliser une activité dans une période spécifique. Le but est d'avoir une connaissance sur la routine comportementale de la personne. La figure 4.10 présente la fréquence de chaque ADL-DS par semaine pendant un mois. Les deux paramètres DH-ADL-DS et FH-ADL-SD sont très importants pour pouvoir construire une base de connaissances détaillée et expressive de la routine quotidienne de la personne. Ces paramètres sont utilisés par la suite afin d'évaluer l'état dépressif de la personne suivie.

Le deuxième critère FH-ADL-DS est un indicateurs de changement important. Cependant, sa valeur peut être parfois imprécise et contradictoire. Par exemple dans le cas où la fréquence de l'activité reste constante mais avec une durée de réalisation

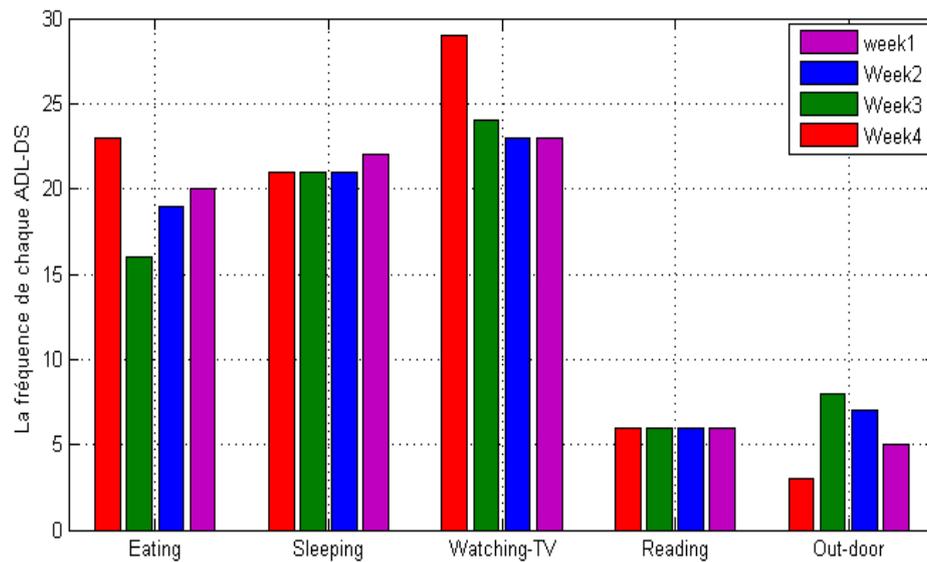


FIGURE 4.10 – La fréquence habituelle des activités de la vie quotidienne liée aux symptômes de dépression (FH-ADL-SD).

qui change. Par conséquent, dans notre travail, nous allons nous baser seulement sur le critère DH-ADL-DS dans la phase d'évaluation des risques dépressif vu la sensibilité de notre étude. L'avantage de se concentrer sur un seul indicateur puissant de point de vu des informations utiles sert à diminuer le taux d'incertitude et le taux de données contradictoires. De la sorte, nous proposons un nouvel algorithme qui calcule la durée habituelle des ADL-DS durant un mois. L'objectif de cet algorithme est de connaître la durée habituelle de chaque activité liée aux symptômes de dépression (ADL-DS) pendant 4 semaines. La plupart des symptômes dépressifs sont définis par une diminution ou une augmentation de la durée habituelle des ADL-DS. À cette fin, il est crucial d'examiner la durée de la routine des activités liées aux symptômes de dépression pendant une longue période pour évaluer le risque de dépression de la personne. Le but est d'extraire par la suite la durée habituelle minimale et maximale pour chaque ADL-DS. Par conséquent, nous allons étudier la durée habituelle de chaque ADL-DS de sorte que la durée habituelle des activités nous renseigne sur les symptômes de dépression. Notre algorithme est consacré au calcul de la durée habituelle de chaque activité par une semaine dans le but d'acquérir des connaissances utiles sur le comportement de la peronne. L'algorithme suivant présente le pseudo code de notre algorithme nommé Min/Max ADL-DS. Les résultats de notre algorithme sont illustrés dans le tableau 4.7.

Algorithm 5 Pseudo code de Min/Max ADL-DS

```

% C-ADL-DS : Code des ADL-DS
% T-ADL
% T-ADL-DS
k=1;
1. Début
2. For s = 1 : 4
3. For j = 1 : 7
4. For i = 1 : length(jour(i : 1))
5. Act = jour (i, 3);
6. Switch(act)
7. Case (code act)
8. Duration-act(k) = jour (i, 2) - jour (i, 1);
9. k = k + 1;
10. End
11. End for
12. Duration-jour (j) ← sum(Duration-act(k)/k);
13. End for
14. Max-duration-S(S) ← max(Duration-jour);
15. Min-duration-S(S) ← min(Duration-jour);
16. End for
17. Max-duration-Mois ← sum (max-duration-S/4);
18. Min-duration-Mois ← sum (min-duration-S/4);
19. Fin

```

En fait, les perturbations comportementales relatives aux symptômes de dépres-

TABLE 4.7 – Durée moyenne maximale et minimale par mois pour chaque ADL-DS

	Eating		Sleeping		Watch-TV		Read		Out-door	
	Min(sec)	Max(sec)								
Durée moyenne/Mois	1283	3600	7087	26579	1299	6512	2638	3537	6597	9725

sion sont définies soit par une augmentation ou une diminution de la durée d'une activité par rapport au comportement habituel. Dans le but d'identifier l'état dépressif de la personne nous proposons de déterminer un seuil de la durée habituelle maximale et la durée habituelle minimale pour chaque ADL-DS. Vu que les profils des personnes âgées sont très hétérogènes de point de vue de l'autonomie, de la maladie, de la dépendance, de l'âge, etc, il est impossible de définir une règle d'évaluation unique pour les changements comportementaux des personnes âgées. De plus, les symptômes de la dépression peuvent varier d'une personne à une autre.

Par conséquent, pour évaluer le changement des ADL-DS il faut tenir compte du profil de la personne. Nous introduisons un paramètre d'ajustement qui tient compte de la situation de la personne. Ce paramètre précise le seuil de la durée de routine maximale (SDR-Max) et le seuil de la durée de la routine minimale (SDR-Min) et ceci pour chaque activité selon le profil de la personne. Le choix de ce paramètre, nommé « ajustement logique », est généralement effectué par un expert dans le domaine médical ou un médecin. Il est calculé en fonction de l'âge, des maladies et du niveau de l'autonomie de la personne afin d'assurer une surveillance adaptée.

Les deux équations ci-dessous présentes la méthode de calcul des SDR-Max et SDR-Min.

Le seuil de la durée de routine maximale (SDR-Max) :

$$\frac{\sum_{i=1}^n \max(\text{durée d'activité})}{n} + \text{ajustement logique} \quad (4.14)$$

Le seuil de la durée de routine minimale (SDR-Min) :

$$\frac{\sum_{i=1}^n \min(\text{durée d'activité})}{n} + \text{ajustement logique} \quad (4.15)$$

En utilisons (4.14) et (4.15) nous pouvons fixer un seuil bien défini pour chaque activité ADL-DS qui est indispensable à l'évaluation du risque de dépression chez la personne en utilisant la logique floue. Nous considérons trois critères de base qui résument notre base de connaissances :

- Les activités liées aux symptômes de dépressions,
- La durée de routine de chaque ADL-DS (maximale et minimale),
- Les seuils de chaque ADL-DS qui se rapporte aux profils de la personne (le seuil maximal et le seuil minimal),

À partir de cette base de connaissance, nous allons appliquer, par la suite, la phase d'évaluation.

4.9.2 Évaluation du taux de dépression

Afin d'identifier le risque de dépression chez les personnes âgées isolés, nous proposons d'utiliser un système basé sur la logique floue qui tient compte de notre base de connaissances. La logique floue est une théorie très utilisée dans le cadre des systèmes de prise de la décision. Il a été proposé par Lotfi Zadeh en 1965 [255, 256]. C'est un modèle efficace pour obtenir un raisonnement automatisé et compréhensible par ceux qui ne sont pas des spécialistes en informatique/mathématique. Dans ce qui suit, nous allons gérer la quatrième phase de notre système.

Cette phase est consacrée au traitement et à l'évaluation du risque de dépression à partir des activités et du comportement habituel. A cet effet, nous adoptons la logique floue comme un modèle d'évaluation de dépression à partir des données significatives appartenant à notre base de connaissances. Elles sont utilisées afin d'étudier les états dépressifs de la personne et d'évaluer par la suite le risque de dépression.

i) Fuzzification des ADL-DS :

Dans la partie fuzzification de la logique floue, nous exploitons les sorties des algorithmes proposés ci-dessus pour évaluer les ADL-DS dans le but d'extraire des résultats pertinent. La fuzzification est une phase très importante qui sert à définir les entrées et les sorties du modèle ainsi de définir les sous ensembles floue utilisés. Pour cette raison, nous allons nous intéresser en premier lieu à la définition des entrées/sorties de notre modèle. Chaque variable linguistique (chaque ADL-DS) correspond au triplet : V : la variable, X : la plage des valeurs et T_v : les sous ensemble floue. Les entrées de notre modèle se sont les ADL-DS, la sortie représente le taux de risque de dépression, la plage des valeurs est la durée d'une activité avec trois sous ensembles qui sont : Anormale-, Normale, Anormale++. Chaque activité est représentée par un sous ensemble et une fonction d'appartenance :

Input1 : sleeping avec le sous ensemble [Anormale-, Normale, Anormale ++],
Input2 : eating avec le sous ensemble [Anormale-, Normale, Anormale++],
Input3 : Reading avec le sous ensemble [Anormale-, Normale],
Input4 : watching-TV avec le sous ensemble [Anormale-, Normale],
Input5 : going-out avec le sous ensemble [Anormale-, Normale].

Chaque sous ensemble qui concerne les entrées est défini comme suit :

Anormale- : la durée de la réalisation d'une ADL-DS est anormale dans le sens négatif, c-à-d l'activité prend un slot de temps plus petit que le seuil de la durée de routine minimale (SDR-Min).

Normale : la durée de réalisation d'une ADL-DS est dans les normes habituelles.

Anormale++ : la durée de réalisation d'une ADL-DS est anormale dans le sens positif, c-à-d l'activité prend un slot de temps plus grand que le seuil de la durée de routine maximale (SDR-Max).

L'évaluation de risque de dépression dépend des symptômes de dépression des ac-

tivités (partie antérieure). Elle représente la sortie du modèle et se compose des trois sous ensembles suivants :

Output : Risque de dépression avec le sous ensemble [Faible, Élevé, Très élevé]

Faible (low) : Un petit changement comportemental concernant les ADL-DS.

Élevé (high) : un changement au niveau des ADL-DS avec au moins 2 ou 3 symptômes constatés tous les jours pendant une semaine,

Très élevé (Very high) : un changement au niveau des ADL-DS avec au moins 4 ou 5 symptômes constatés tout les jours pendant une semaine.

Les ensembles flous sont donnés dans les figures 4.11-4.15 et la sortie du système est représentée par la figure 4.16. Le changement (l'existence des symptômes dépressifs) est représenté si la durée de l'activité est hors norme que se soit en plus ou en moins. Par exemple, concernant l'activité « Eating », la personne âgée a une durée normale d'alimentation entre [1253, 3630].

Après avoir défini les entrées et les sorties de notre modèle dans la phase de

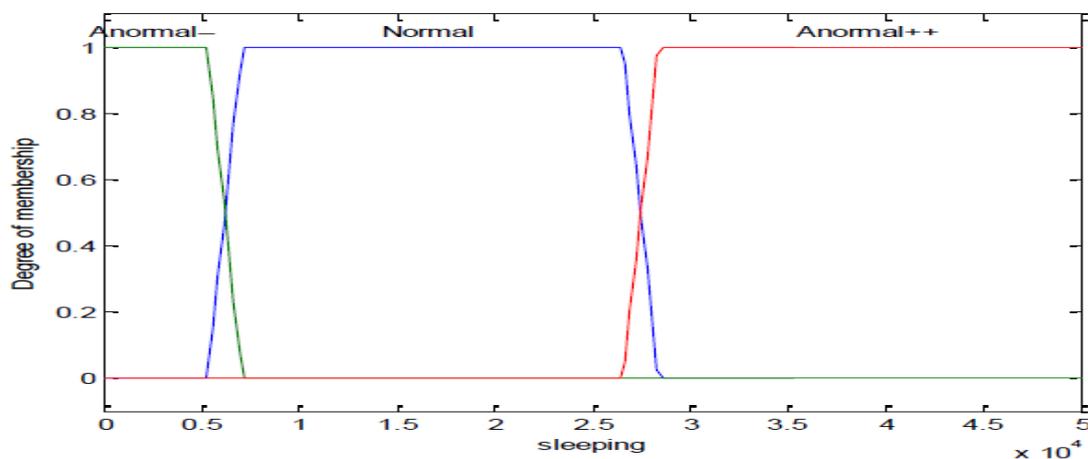


FIGURE 4.11 – Variable d'entrée/ activité «Sleeping »

fuzzification, nous allons, dans la phase suivante définir les règles utilisées pour le raisonnement flou également appelé raisonnement approximatif. Ces règles sont exprimées en langage naturel en utilisant les variables linguistiques prédéfinies précédemment.

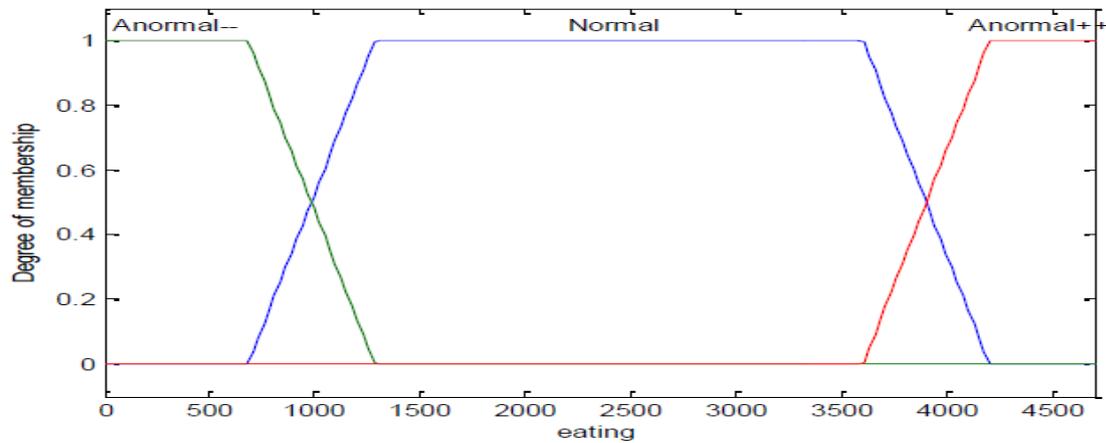


FIGURE 4.12 – Variable d'entrée/ activité «Eating »

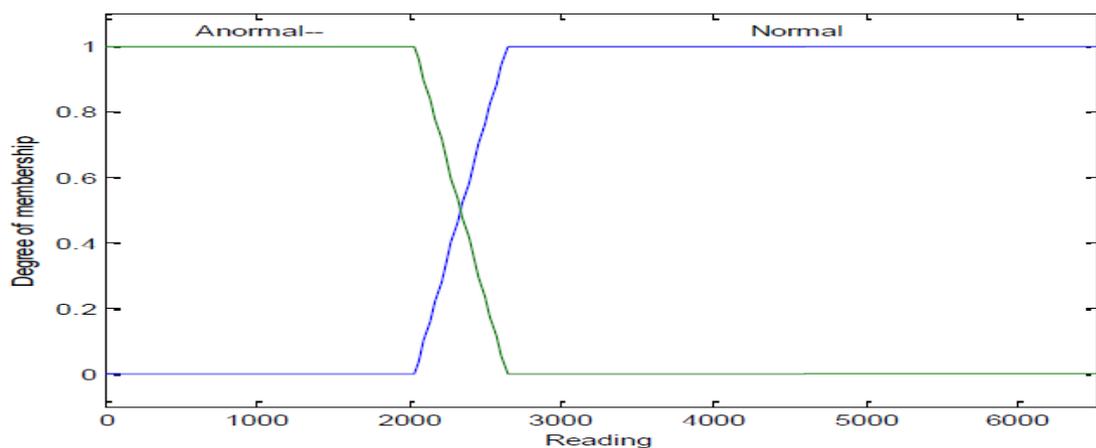


FIGURE 4.13 – Variable d'entrée/ activité «Reading»

ii) Les règles de raisonnement floue :

Notre décision qui concerne le taux de risque de dépression repose sur des règles bien définies. En effet, les maladies dépressives sont classées selon la durée, la sévérité et la nature des symptômes. Par conséquent, plus il y a de symptômes et plus ils sont intenses, plus la dépression est sévère et les conséquences sont importantes. Ainsi, le taux de dépression peut s'identifier par le nombre de symptômes. A partir des sous-ensembles du risque de dépression (sorite du système) qui sont *Faible*, *Élevé*, *Très élevé*, une base de règles est construite pour identifier la variable de sortie. Dans notre cas, la décision de sortie est l'identification du taux de dépres-

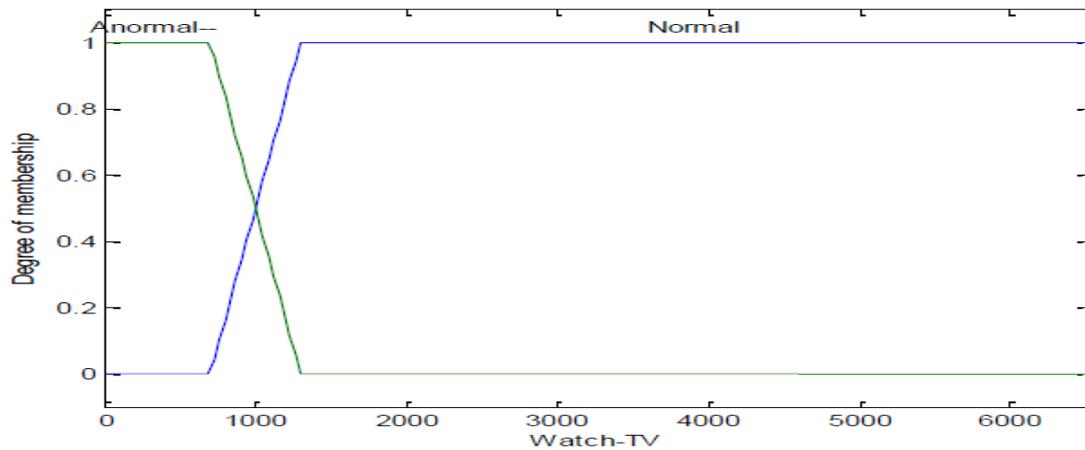


FIGURE 4.14 – Variable d'entrée/ activité «Watch-TV »

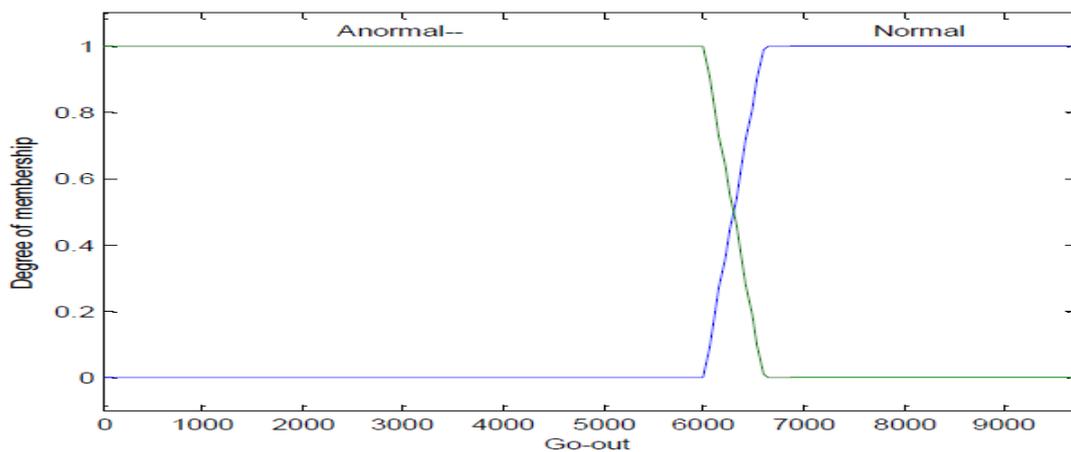


FIGURE 4.15 – Variable d'entrée/ activité «GO-OUT »

sion des personnes âgées. Il est recommandé que ces règles soient définies par des experts ou des professionnels de santé. Dans notre travail, les règles floues utilisées pour identifier le risque de dépression sont basées sur les connaissances inspirées de plusieurs études existantes avec des relations logiques entre les symptômes de la dépression (entrée) et le taux de risque de dépression (sortie). Ainsi, les règles sont extraites à partir de ces données en corrélant les symptômes et leur gravité. Les règles se composent de deux parties : une partie antérieure et une partie qui représente la conséquence. Nous présentons, dans ce qui suit, quelques règles utilisées dans notre travail :

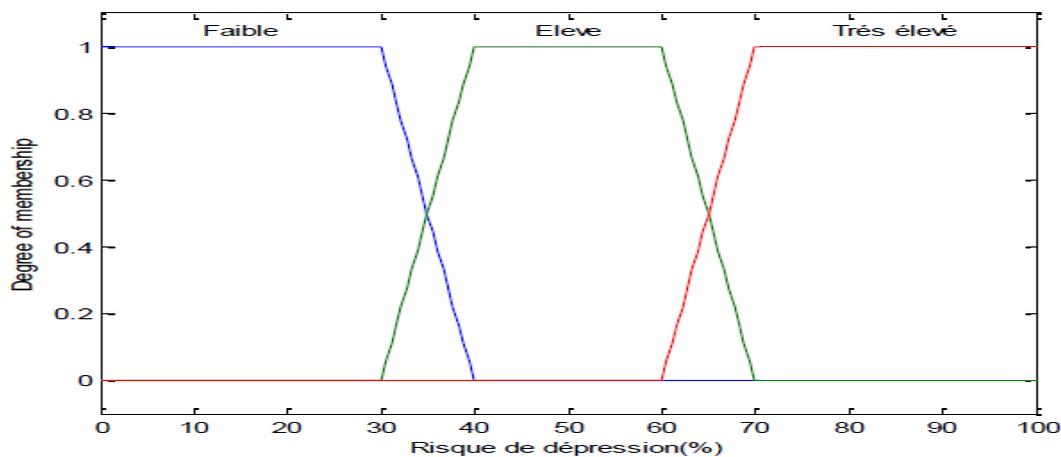


FIGURE 4.16 – La sortie de notre modèle « Risque de depression»

*If eating is Normal and sleeping is Normal and reading is Normal and watching is Normal **Then** depression risk is low.*

*If eating is low and sleeping is low and reading is low and watching is low **Then** depression risk is Very high.*

*If eating is low and sleeping is High and reading is low and watching is low **Then** depression risk is Very high.*

*If eating is High and sleeping is low and reading is low and watching is low **Then** depression risk is Very high.*

*If eating is low and sleeping is low **Then** depression risk is Very high.*

*If eating is low or sleeping is low **Then** depression risk is high.*

*If eating is low and sleeping is high **Then** depression risk is Very high.*

Afin d'évaluer les règles en fonction des entrées obtenues, nous appliquons les opérateurs flous correspondants pour combiner les règles. Si une règle a plusieurs antécédents, un opérateur flou est utilisé pour obtenir un seul chiffre qui représente le résultat pour cette règle. Les résultats sont ensuite appliqués à la fonction d'appartenance de la conséquence. Le résultat final est obtenu par la suite dans la phase défuzzification.

iii) Défuzzification des ADL-DS :

La défuzzification est le processus de convertir une valeur floue en (linguistique) à une valeur certaine. Dans notre cas, la sortie est le pourcentage de risque de la dépression. Plusieurs méthodes peuvent être utilisées comme l'appartenance maximale, la méthode du centroïde, et la méthode des moyennes pondérées. Nous

utilisons la méthode centroïde vu qu'elle est la plus utilisée dans la littérature.

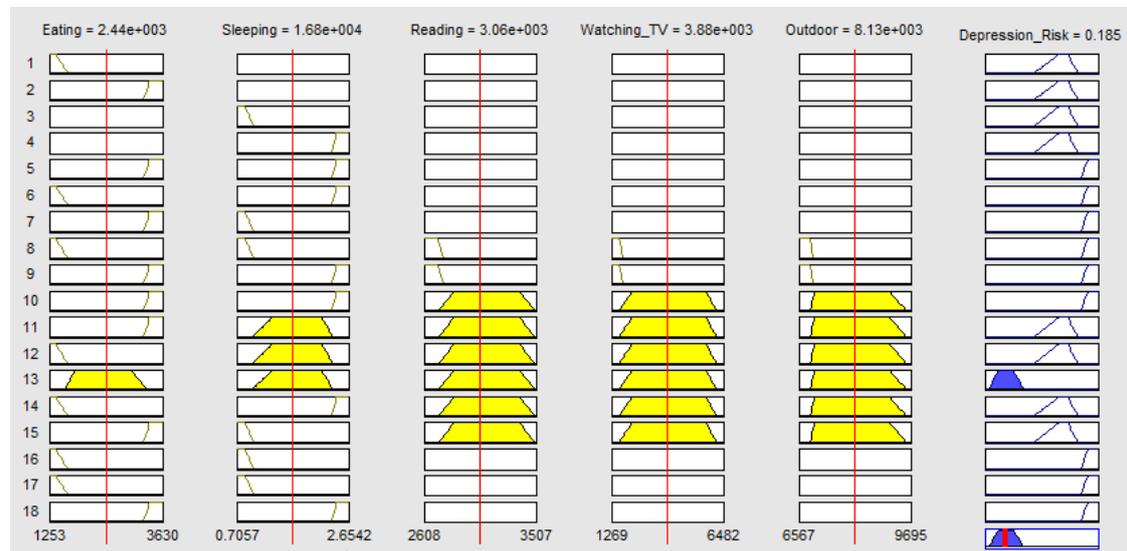


FIGURE 4.17 – Résultats d'évaluation du taux de dépression d'une personne non dépressive

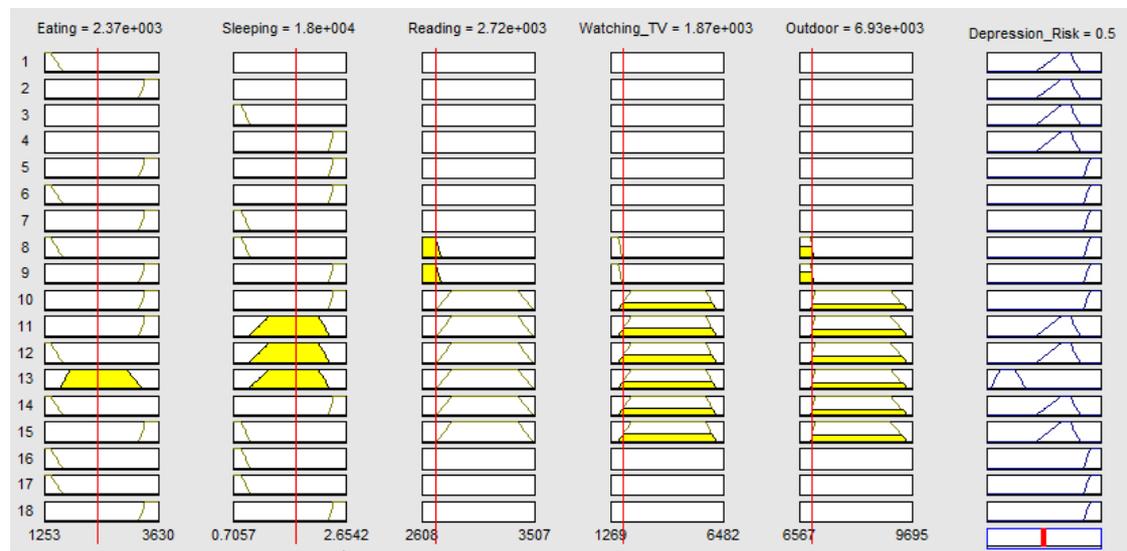


FIGURE 4.18 – Résultats d'évaluation du taux de dépression d'une personne avec un taux de dépression léger

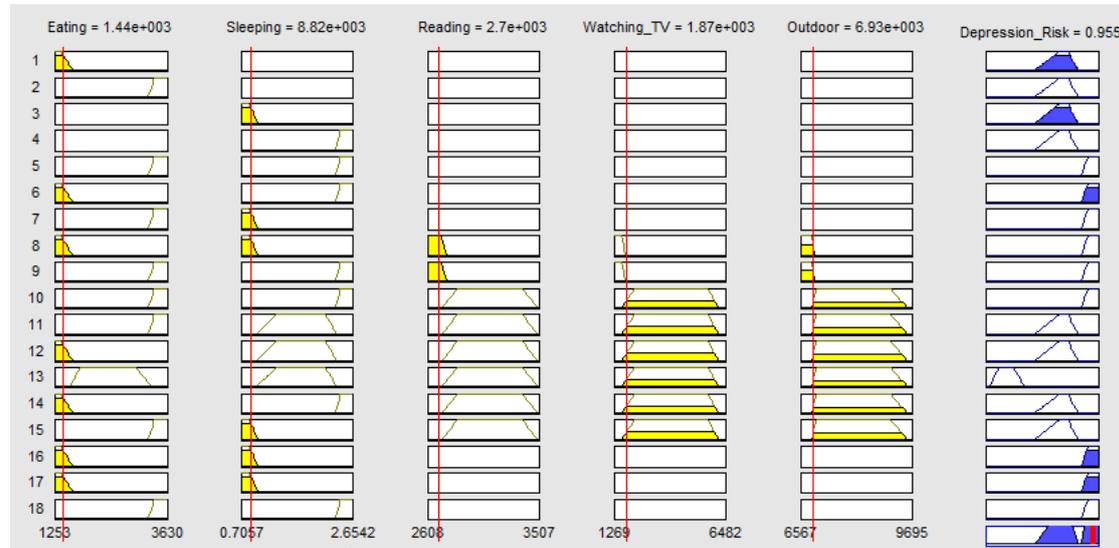


FIGURE 4.19 – Résultats d'évaluation du taux de dépression d'une personne avec un taux de dépression grave

Les résultats obtenus à partir de la phase de déffuzification sont présentés dans les figures 4.17-4.19 dans différents situations, une personne autonome non dépressive (figure 4.17), une personne avec un taux de dépression léger (figure 4.18) et une personne avec un taux de dépression grave (figure 4.19). Afin de calculer le pourcentage de risque de dépression de chaque situation il suffit de multiplier le résultat de risque de dépression par 100.

4.9.3 Prise de décision

L'état dépressif chez les PAs peut s'aggraver rapidement ou lentement en fonction du temps et du type de dépression. Plusieurs chercheurs dans le domaine médical ont montré qu'il existe deux types de dépression : une dépression majeure et une dépression mineure, la dépression majeure est définie par un changement brusque du comportement. La dépression mineure engendre un changement de l'état habituel de façon progressive. Le résultat obtenu par la logique floue représente le pourcentage de risque de dépression chez la personne suivie. Par conséquent, le système peut maintenant prendre une décision selon le pourcentage de taux de dépression (Rate Depression-RD) avec la prise en considération des deux niveaux de dépression. La partie prise de décision est une tâche très importante dans un système de surveillance. Dans cette partie, nous considérons deux facteurs : la période de surveillance et le pourcentage déterminé par notre modèle. Un algorithme de prise de décision sera proposé. En outre, l'évaluation du risque de la dépression est effectuée chaque semaine. Cela veut dire que chaque semaine une décision est

prise et transmise vers le centre de surveillance. Le principe de notre algorithme est comme suit :

Algorithm 6 Prise de décision

% Pourcentage de Risque de dépression "PRD" entier ;

% Variable de vérification "V" entier ; V=0 ;

1. **Début**

2. **Switch**(Sortie)

3. **Case**(PRD%)

4. **For**j=1 :7

5. **If** PRD \in [0 30] {

6. Comportment \leftarrow Comportment normal

7. Alerte \leftarrow 0 }

8. **Else if** PRD \in [30 50] {

9. Comportment \leftarrow Comportment dépressif

10. Alerte \leftarrow Dépression mineur

11. V=V+1 ;}

12. **Else if** PRD \in [50 80] {

13. Comportment \leftarrow Comportment dépressif

14. Alerte \leftarrow Dépression Majeur }

15. **Else if** PRD \in [80 100] {

16. Comportment \leftarrow Comportment dépressif

17. Alerte \leftarrow Dépression majeur/ besoin d'une intervention rapide }

18. **End**

19. **Fin**

% dans la semaine suivante, si l'alerte est une dépression mineur et si le variable de vérification v = 0, l'alerte prendre la valeur « dépression mineur » sinon si v = 1, l'alerte prendre la valeur « dépression majeur »

D'abord, selon le taux de risque de dépression, le système détermine la décision à déclencher en classant le pourcentage du taux de dépression sous forme d'intervalles. À partir de ces pourcentages, une décision appropriée est définie. Notre algorithme est basé sur trois décisions qui sont les suivantes : Si la personne est dans l'état normal et il n'y a pas de changements remarquables en ce qui concerne les activités liées aux symptômes de dépression, dans ce cas il n'y a pas d'alerte. Sinon, si le taux de dépression est moyen, dans ce cas nous pouvons distinguer une dépression mineure (une alerte nommée « dépression mineure » sera déclenchée). Une variable de vérification est utilisée pour enregistrer cet état dépressif afin de mettre en considération ces informations dans la semaine suivante. Si la situation

persiste la semaine suivante, nous allons déclencher une alerte « dépression majeure ». Enfin, si le pourcentage de taux de dépression est important, une alerte qui nécessite une intervention rapide sera déclenchée. Le pseudo-code Algorithme 6 présente le principe de l'algorithme de la prise de décision.

La maladie de dépression peut s'aggraver lentement ou rapidement selon la situation de la personne et les causes de la dépression. Par conséquent, un suivi complet, rapide et approprié est nécessaire. Grâce à notre système de prise de décision le centre de surveillance peut évaluer l'état de la personne et réagir si nécessaire.

4.10 Conclusion

Dans le contexte d'une maison intelligente dédiée à la surveillance des populations fragiles telles que les personnes âgées et les personnes dépendantes, l'un des principaux intérêts est de modéliser le comportement de l'habitant dans son propre environnement. Par conséquent, la modélisation du comportement permet de concevoir de nouveaux modèles et systèmes intelligents qui fournissent continuellement des services contextuels adaptés au profil de la personne et aux besoins réels. Dans ce domaine, l'un des objectifs primordiaux de cette modélisation est d'anticiper et de prédire les risques, les détériorations, les situations d'urgence et de fournir l'assistance et l'aide nécessaires. Dans ce chapitre, nous avons proposé une version améliorée du modèle ELM qui assure une prédiction précise et rapide du comportement des personnes âgées. Le modèle proposé, appelé RELM, est une forme récurrente du modèle ELM. Les résultats obtenus par RELM montrent une excellente performance concernant la précision avec une RMSE de 1.5625×10^{-6} pendant l'étape d'apprentissage et 2.2818×10^{-4} au cours de l'étape de validation. En ce qui concerne la rapidité de l'apprentissage, RELM a rapidement réussi à exécuter cette phase avec un temps moyen raisonnable de 3.1996 secondes et un temps de validation de 0.06030 secondes ce qui confirme l'efficacité de notre modèle. Nous avons fourni une évaluation comparative du modèle proposé avec certains modèles existants dans la littérature qui sont : ELM classique, SLFN-ED, Elman-NN-ED, Sa-ELM et ELM-GA.

Cette évaluation a confirmé la supériorité de RELM en termes de précision de la prédiction et de la rapidité d'apprentissage. Par conséquent, le modèle RELM peut être utilisé pour prédire les valeurs futures représentant les activités et les actions attendues pour une personne surveillée avec une grande confiance et une grande rapidité d'apprentissage. Dans un deuxième lieu, dans le but d'assurer une surveillance complète, nous avons proposé d'étudier le cas de dépression chez les personnes âgées. Dans le domaine de la gériatrie, ont estimé que 65% des personnes âgées vivant à leur domicile souffrent d'une dépression dans le cadre de longs sé-

jours. En fait, la dépression chez les personnes âgées est une maladie grave qui peut aller jusqu'au « syndrome de glissement » ou au suicide. Cependant, cette maladie reste très difficile à diagnostiquer car les personnes dépressives peuvent être en apparence joyeuses (dépression masquée). Si aucune mesure ou intervention n'est prise, cette maladie peut s'aggraver avec le temps et la personne peut être en danger. Cependant, une intervention rapide peut prévenir la personne et éviter la présence des situations anormales ou des situations dangereuses. Partant de ce principe, dans le cadre d'une surveillance à domicile des personnes âgées, nous avons proposé un système approfondi de diagnostic de la dépression basé sur les activités de la vie quotidienne. En effet, une étude des différents symptômes de dépression chez les personnes âgées est effectuée afin d'identifier les activités quotidiennes liées à la dépression et d'évaluer le taux de risque de dépression de notre occupant. Notre système d'évaluation est basé sur le comportement, le profil et la routine de la personne. Nous avons utilisé la logique floue dans la phase d'évaluation et nous avons proposé un algorithme qui est responsable de la prise de décision à base d'alertes. En conclusion, le système de la prise de décision proposé assure un suivi pertinent de la dépression chez les personnes âgées afin de diagnostiquer leurs états dépressifs et pour empêcher les habitants d'être attaqués par cette maladie en plus d'assurer une intervention rapide si nécessaire.

Conclusion et Perspectives

1. Conclusion générale

Dans cette thèse, nous avons conçu un système de surveillance et de maintien à domicile, qui cible les personnes âgées et les personnes dépendantes vivant seules chez eux. En fait, pour faire face à la demande croissante des services de surveillance d'e-santé, la conception d'un système de surveillance à distance adaptatif, précis, efficace et performant est une tâche primordiale et délicate qui nécessite la prise en compte de plusieurs facteurs tels que l'environnement, le profil de la personne, la routine, etc.

À cette fin, l'objectif de cette recherche était d'évaluer la performance des systèmes de surveillance à domicile de santé dans un environnement intelligent et de développer des approches efficaces qui offrent des services appropriés à long terme tout en gardant un lien étroit avec les connaissances médicales existantes, le profil de la personne et leur comportement quotidien. En fait, un système de surveillance performant est celui qui assure une surveillance pertinente du comportement et des activités de la vie quotidienne en temps réel et qui fournisse rapidement l'aide et l'intervention en cas des situations dangereuses et anormales.

Cette thèse tente de fournir une analyse de reconnaissance et de prédiction des comportements normaux et anormaux de la vie quotidienne des personnes âgées résidant dans les maisons intelligentes. Les trois contributions apportées dans cette thèse sont présentées ci-dessous.

La proposition d'un nouveau langage de comportement afin de structurer et de classer les activités quotidiennes en fonction du profil de la personne. Nommée «Elderly by Room Activities Description Language (EBRADL)». La motivation de cette contribution émane du fait que les données provenant de la maison intelligente sont hétérogènes et complexes, par suite elle ne sont pas formalisés d'une manière standard, compréhensible et adéquate. En fait, nous avons proposé une représentation de haut niveau, significative, pertinente et utile des activités quoti-

diennes de notre habitant. Le principe de notre langage est inspiré des notions de base des langages naturels, il est basé sur des règles et des contraintes bien étudiées.

Pour modéliser et décrire notre langage proposé afin de reconnaître et de prédire le comportement de la personne d'une manière souple et pertinente et par suite de suivre la personne en question, une approche Markovienne hybride a été proposée nommée Temporal Hierarchical Hidden Markov Model (THHMM) pour assurer à la fois la structure hiérarchique de EBRADL et la notion temporelle. Les résultats de prédiction obtenus par THHMM ont montré une prédiction précise et satisfaisante des activités quotidiennes de la personne.

Bien que le modèle proposé donne de bon résultat, celui devient conservatif lorsque l'ensemble des données recueillis devient énorme, ainsi une prédiction à long terme exige une complexité de calcul.

Notre responsabilité primordiale est d'assurer une surveillance aussi pertinente et précise pour améliorer les services des systèmes de surveillance à domicile.

De ce fait, de nouveaux modèles hybrides ont été proposés, ils ont basé sur les modèles computationnels. Plus précisément, différentes techniques basées sur les réseaux de neurones artificielles ont été appliquées pour la reconnaissance et la prédiction, ces techniques sont basées sur deux catégories différentes qui sont : Les *Réseaux de Neurones Récurrents (RNR) / (Récurrent Neural Network (RNN)* et *Les Réseaux de Neurones à Retard de Temps (RNRT) / (Time Delay Neural Network (TDNN))*. Afin d'améliorer la précision de la prédiction de RNN et TDNN, deux méta-heuristiques ont utilisés pendant la phase d'apprentissage soit les algorithmes génétiques (AG) et l'évolution différentielle (ED). Alors, les nouveaux modèles hybrides proposés pour la prédiction nommé ELMAN-DE, ELMAN-AG, NARX-DE et NARX-AG.

Les résultats obtenus avec ces modèles hybrides ont été évalués et comparés pour montrer leurs capacités et leurs performances, à partir cette comparaison on peut retenir les conclusions suivantes :

- Les modèles de prédiction de l'intelligence artificielle sont plus performants que les méthodes de prédiction statistiques.
- Les modèles de réseau de neurones hybrides proposés ont montré une amélioration remarquable de point de vue du taux de prédiction par rapport aux réseaux de neurones classiques.

- Les modèles proposés sont dotés d’une précision très satisfaisantes.
- Les résultats obtenus par les modèles NARX et ELMAN amélioré par ED sont performants de point de vue de la précision, par contre les résultats obtenus par les modèles NARX et ELMAN amélioré par AG sont performants de point de vue du temps.
- Certains compromis dans les deux modèles sont à signaler en terme de précision et temps d’apprentissage. Ainsi, l’utilisation de l’évolution différentielle révèle une meilleure précision comparé au algorithmes génétiques qui permettent un apprentissage plus rapide.

Les données utilisées pour l’apprentissage et la validation des modèles proposés sont les données sensorielles simulées et recueillies à partir du projet “e-Health Monitoring Open Data project”, qui représente deux différents cas. Ces deux cas nommés :

Personne-C1 : le premier cas qui représente le comportement de la personne autonome.

Personne-C2 : le deuxième cas qui représente le comportement de la personne le moins autonome.

Malgré les résultats adéquates obtenus par les modèles proposées, le compromis entre le taux du prédiction et le temps du calcul reste un problème à résoudre pour offrir un modèle de prédiction plus performant dans le cadre d’une surveillance à domicile des personnes âgées.

Dans le but d’améliorer de plus en plus notre système de surveillance vu son importance dans le domaine médical, afin de suivre, d’identifier, de reconnaître le comportement de la santé de la personne âgée / dépendante, de prédire, aussi, de détecter la présence d’un changement quelque soit sa gravité il est nécessaire d’implémenter un modèle performant qui assure à la fois une prédiction précise et un temps de calcul rapide.

A ce propos, un nouveau modèle de prédiction recurrent intitulé RELM (Recurrent Extreme Learning Machine) a été proposé. Ce modèle transforme le modèle de base du ELM existant en une nouvelle forme récurrente, l’amélioration de ce modèle est effectuée afin d’améliorer la précision de prédiction du ELM ainsi de profiter de leur rapidité d’apprentissage.

Les résultats obtenus confirment l'efficacité de notre modèle proposé RELM en terme de temps de calcul et de précision de la prédiction. Pour confirmer la suprématie du modèle proposé une étude comparative avec les modèles existants a été mise au points et les résultat étaient réconfortants. Ces résultats nous encouragent à appliquer notre modèle pour construire un système de prise de décision complet.

A ce propos, un système de surveillance de santé complet à base du modèle RELM avec l'utilisation de la logique floue pour le raisonnement et pour la prise de décision a été conçu.

En fait, les personnes âgées sont classées parmi les personnes les moins autonomes qui sont très sensibles d'être attaquées par des maladies telles que : Alzheimer, Cardio-vasculaire, Diabète, Dépression. A cet effet, comme application, une étude de cas a été réalisée pour évaluer le taux de dépression chez les personnes âgées vu l'impact de cette pathologie sur le comportement et par suite la vie de la personne âgée.

De ce fait nous avons proposé un système d'évaluation de taux de dépression qui est basé sur le comportement, le profil et la routine de la personne. Ainsi, nous avons utilisé la logique floue dans la phase d'évaluation par la suite nous avons proposé un algorithme qui est responsable de la prise de décision à base des alertes.

Notre solution est intéressante, et applicable pour les personnes âgées ou dépendantes. Elle est précise du point de vue de la prédiction et de la rapidité, aide à comprendre le comportement et l'état de santé et assure une détection des changements comportementaux, des perturbations de l'état de santé (à court terme ou à long terme) et des situations dangereuses.

2. Perspectives

L'aide au maintien à domicile est devenue une thématique majeure de nos jours, nous souhaitons poursuivre à contribuer dans ce domaine. Certaines améliorations peuvent être apportées aux méthodes proposées. Elles se résument a :

- L'application de notre système proposé dans le cadre réel.
- Reconnaître et prédire un comportement humain plus complexe.

- La conception d'un système d'interface utilisateur convivial pour permettre un suivi adaptable et performant.
- L'extension du système de surveillance complet conçu pour la dépression pour diagnostiquer et évaluer d'autres pathologie comme l'Alzheimer, le diabète, la démence et d'autres maladies à distance à partir du comportement et du profil de la personne.
- L'extension des travaux pour une situation d'occupation multiple, au cas de présence des visiteurs, des animaux de compagnie, etc.

Troisième partie

Annexes

Notion de base des modèles Markovien

A.1. Fonctionnement du MMC

Le modèle de Markov Caché est un modèle probabiliste permet de modéliser les données séquentielles. Dans MMC une séquence des données est considérée comme une série temporelle gérée par les états cachés qui sont des états inobservables. Une nouvelle séquence d'événement est analysée à chaque instant. La structure de MMC est composée par un ensemble d'états cachés, un ensemble d'observation, de transition et de distribution des probabilités entre les transitions. Trois algorithmes classiques bien connus des MMC issus des problèmes principaux qui sont l'apprentissage, l'évaluation et l'explication utilisés pour l'apprentissage des paramètres et la reconnaissance.

A.1.1. Les Algorithmes classiques du MMC

Le modèle HMM est représenté par $\lambda = (N, O, A, B, \pi)$, avec $O = O_1, O_2, \dots, O_T$ une séquence d'observations et $S = S_1, S_2, \dots, S_T$ une séquence d'états. La probabilité d'observer la séquence O pour une séquence d'état S est :

$$P(O | S, \lambda) = b_{S_1}(O_1) \cdot b_{S_2}(O_2) \cdot \dots \cdot b_{S_T}(O_T)$$

Avec, la probabilité de la séquence S est représentée par la forme suivante :

$$P(S | \lambda) = \pi_{S_1} a_{S_1, S_2} a_{S_2, S_3} \dots a_{S_{T-1}, S_T}$$

La probabilité conjointe du chemin S et des observation O est :

$$P(O, S | \lambda) = P(S | \lambda) \cdot P(O | S, \lambda)$$

La probabilité des observations O sachant λ est obtenue par :

$$P(O, \lambda) = \sum_S P(O | S, \lambda) \quad (16)$$

$$P(O, \lambda) = \sum_{S_1, S_2, \dots, S_T} \pi_{S_1} b_{S_1}(O_1) a_{S_1, S_2} b_{S_2}(O_2) \dots a_{S_{T-1}, S_T} b_{S_T}(O_T) \quad (17)$$

En fait, pour un modèle de N états, ce calcul nécessite $(2T-1)*N^T$ multiplications et N^{T-1} additions, ce qui implique la complexité de calcul et de l'implémentation.

L'algorithme Forward-Backward est une solution efficace pour mener ce calcul.

Sachant le modèle λ , la probabilité d'observer la séquence O_1, O_2, \dots, O_t et d'être à l'état i à l'instant t , nommée la probabilité en avant est écrite sous la forme :

$$\alpha_t(i) = P(O_1, O_2, \dots, O_t, S_t = i | \lambda), \quad (18)$$

L'algorithme Forward calcul cette probabilité d'une manière récursive (Algorithme 7).

Algorithm 7 Algorithme Forward

1. **Initialisation :** $\alpha_1(i) = \pi_i b_i(O_1) \quad 1 \leq i \leq N$
 2. Récurrence : $\alpha_{t+1}(j) = \sum_{i=1}^N [\alpha_t(i) a_{ij}] b_j(O_{t+1}), \quad t \in 1, 2, \dots, T-1$ et $1 \leq j \leq N$;
 3. Terminaison : $P(O | \lambda) = \sum_{i=1}^N \alpha_T(i)$
-

De même manière pour l'algorithme Backward, soit la probabilité arrière $\beta_t(j)$, c'est la probabilité d'observer la séquence $O_{(t+1)}, O_{(t+2)}, \dots, O_T$ sachant qu'on est dans l'état i au temps t et définie par :

$$\beta_t(j) = P(O_{t+1}, O_{t+2}, \dots, O_T | S_t = j, \lambda), \quad (19)$$

L'algorithme récursive Backward (Algorithme 8) est implémenté de la manière suivante :

Algorithm 8 Algorithme Backward

1. **Initialisation :** $\beta_T(i) = 1 \quad 1 \leq i \leq N$
 2. Récurrence : $\beta_t(i) = \sum_{j=1}^N \beta_{t+1}(j) a_{ij} b_j(O_{t+1}), \quad t \in T-1, T-2, \dots, 1$ et $1 \leq i \leq N$;
 3. Terminaison : $P(O | \lambda) = \sum_{i=1}^N \alpha_T(i) = \sum_{i=1}^N [\pi_i b_i(O_1)] \beta_1(i) = \sum_{i=1}^N \alpha_t(i) \beta_t(i)$
-

Sachant que λ représente le modèle HMM, le problème de décodage est basé à la recherche d'une séquence d'état optimale. Pour résoudre ce problème une variable γ est définie par :

$$\gamma_t(i) = P(S_t = i | O, \lambda) = \frac{\alpha_t(i)\beta_t(i)}{\sum_{i=1}^N \alpha_t(i)\beta_t(i)} = \frac{\alpha_t(i)\beta_t(i)}{P(O | \lambda)} \quad (20)$$

La variable $\gamma_t(i)$ représente la probabilité d'être à l'état i au temps t , avec O est la séquence d'observation. L'état optimale à l'instant t est définie par :

$$S_t = \arg_i \max[\gamma_t(i)] \quad (21)$$

En fait, cette méthode peut aboutir à des erreurs. En outre, le critère le plus utilisé est celui qui trouve la séquence optimale d'un état globale « le meilleur chemin », c'est-à-dire on cherche à maximiser $P(S, O | \lambda)$. L'algorithme viterbi est une solution pour résoudre ce problème. Alors, pour trouver la meilleur séquence S , à partir d'une séquence d'observations O , il s'agit de définir la quantité $\delta_t(i)$.

$$\delta_t(i) = \max_{S_1, S_2, \dots, S_{t-1}} P(S_1, S_2, \dots, S_t = i, O_1, O_2, \dots, O_t | \lambda) \quad (22)$$

$\delta_t(i)$ présente la meilleur résultat selon un chemin donnée, ce chemin se compose de t premier observations et se termine à l'état i . la valeur $\delta_t(i)$ est déterminé par l'algorithme récursive viterbi (Algorithme 9) avec :

$$\delta_{t+1}(j) = \max_{1 \leq i \leq N} [\delta_t(i)a_{ij}]b_j(O_{t+1}) \quad (23)$$

Algorithm 9 Algorithme Viterbi

1. Initialisation : $\delta_1(i) = \pi_i b_i(O_1) \quad 1 \leq i \leq N$

$\phi_1(i) = 0$

2. Récurrence : $\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i)a_{ij}]b_j(O_t), \quad 2 \leq t \leq T, \quad 1 \leq j \leq N$

$\phi_t(j) = \arg_{1 \leq i \leq N} \max[\delta_{t-1}(i)a_{ij}]$

3. Terminaison : $P^* = \max_{1 \leq i \leq N} [\delta_T(i)]$

$\phi_T^* = \arg_{1 \leq i \leq N} \max[\delta_T(i)]$

4. Recherche : $S_t^* = \phi_{t+1}(S_{t+1}^*), \quad t = T-1, T-2, \dots, 1$

Pour déterminer la séquence optimale d'état, il est important de garder la trace de l'indice i qui aide à maximiser la séquence précédente, et même pour tout t et j , alors ceci est fait à partir un tableau $\phi(j)$. Concernant le problème d'apprentissage qui sert à trouver une méthode pour ajuster les paramètres du modèle dans le but de maximiser la probabilité d'une séquence d'observation O , nous avons choisir d'utiliser l'algorithme Baum-Welch en se basant sur une méthode itérative. En

fait, pour décrire comment re-estimer les paramètres du modèle HMM, la probabilité d'être à l'état i au temps t et de faire une transition à l'état j au temps $t + 1$, on va définir la probabilité $\epsilon_t(i, j)$.

$$\epsilon_t(i, j) = \frac{\alpha_t(i)a_{ij}b_j(O_{t+1})\beta_{t+1}(j)}{P(O|\lambda)} \quad (24)$$

Étant donnée $\gamma_t(i)$ défini précédemment, qui présente la probabilité d'être à l'état i au temps t . Dans ce cas nous pouvons relier $\gamma_t(i)$ et $\epsilon_t(i, j)$ cette relation est représenté comme suit :

$$\gamma_t(i) = \sum_{j=1}^N \epsilon_t(i, j) \quad (25)$$

L'algorithme **Baum-Welch** estime les nouveaux paramètres du modèle de Markov par :

$$\bar{\pi}_i = \gamma_1(i), 1 \leq i \leq N \quad (26)$$

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \epsilon_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(j)}, 1 \leq i \leq N, 1 \leq j \leq N \quad (27)$$

$$\bar{b}_j(k) = \frac{\sum_{t=1, O_t=k}^T \gamma_t(j)}{\sum_{t=1}^T \gamma_t(j)} \quad 1 \leq j \leq N \quad (28)$$

La ré-estimation de la probabilité d'être à l'état i au temps $t = 1$ est représenté par la ré-estimation de π_i .

La ré-estimation du rapport entre le nombre de transitions de l'état i vers l'état j sur le nombre de transition à partir de l'état i est représenté par la formule de ré-estimation de a_{ij} .

Le rapport du nombre de fois d'être à l'état i en observant l'état k sur le nombre de fois étant l'état i est ré-estimé par $b_j(k)$.

A.2. Fonctionnement du HHMM

A.2.1. Initialisation des paramètres

HHMM est une extension du modèle HMM qui introduit la notion hiérarchique dans le modèle classique. En fait, la notion hiérarchique est mise en considération

pour assurer la dépendance séquentielle à long terme via les couches supplémentaires. Un modèle HHMM est un modèle noté par λ^n où $n \in [1..N]$ avec n représente le niveau de la hiérarchie.

S_i^n représente un état (émetteur interne) avec i représente l'indice de l'état, n le niveau de la hiérarchie.

λ^n est définie par $\lambda^n \{ S = S_i^n, A^{S^n} = a_{i,j}^{S^n}, B = B^{S^n}, \pi = \pi^{S^n} \}$ le tableau 8 présente la définition de chaque paramètre.

TABLE 8 – Définition des paramètres du HHMM

Définition	Interprétation Mathématique
S : un ensemble d'état N et n le niveau de l'hiérarchie.	$S = S_i^n = S_1^n, S_2^n, \dots, S_N^n$
A : la probabilité des transition entre les états internes.	$A^{S^n} = a_{i,j}^{S^n}, \text{ ou } a_{i,j}^{S^n} = P(S_j^{n+1} S_i^{n+1})$
B : la probabilité des observations (d'émission), O : l'ensemble de M symbole du vecteur d'observation, avec $O = O_1, O_2, \dots, O_M$	$B = B^{S^n} = b^{S^n}(k) \text{ ou } b^{S^n} = P(O_k S^n), k \in [1..M]$ avec M nombre d'état d'émission
π : la probabilité d'état initiale, π^{S^n} : la probabilité de transition verticale entre S^n et S^{n+1}	$\pi = \pi^{S^n} = \pi^n(S_i^{n+1}) = P(S_i^{n+1} S_i^n)$

A.2.2. Ré-estimation des paramètres d'un HHMM

Dans ce cas les paramètres d'estimation du modèle HMM sont reformulés pour prendre en considération la notion hiérarchique de HHMM.

Les variables de forward-backward α et β sont :

$$\alpha_t(j) = P(O_1, O_2, O_3, \dots, O_t, S_j \text{ fin à } t/\lambda) \quad (29)$$

$$\beta_t(j) = P(O_{(t+1)}, O_{(t+2)}, O_{(t+3)}, \dots, O_T/S_j \text{ fin à } t, \lambda) \quad (30)$$

Avec $O_1, O_2, \dots, O_{t-1}, O_T$ la séquence d'observation au court du temps t tel que $1 \leq t \leq T$ et $O_t \in V$ où V représente l'ensemble de symboles d'observation avec $V = V_1, V_2, \dots, V_M$.

Les paramètres de ré-estimation de HHMM prennent les valeurs suivantes :

$$\alpha_t^*(j) = P(O_1, O_2, O_3, \dots, O_t, S_j \text{ début à } t + 1/\lambda) \quad (31)$$

$$\beta_t^*(j) = P(O_{t+1}, O_{t+2}, O_{t+3}, \dots, O_T / S_i \text{ début à } t + 1, \lambda) \quad (32)$$

$$\pi_i^* = \frac{\beta_0^*(i)\pi_i}{P(O | \lambda)} \quad (33)$$

$$a_{i,j}^* = \frac{\sum_{t=1}^N \alpha_t(i) \cdot a_{i,j} \cdot \beta_t^*(j)}{\sum_{j=1}^N \sum_{t=1}^T \alpha_t(i) \cdot a_{i,j} \cdot \beta_t^*(j)} \quad (34)$$

A.3. Fonctionnement du MSMC

Pour une description plus fine le MSMC est proposé comme une extension du MMC classique, afin de trouver une modélisation explicite du modèle et pour estimer la quantité du temps dans un état donnée. Le paramétrage de temps effectuer par un modèle de Markov classique est comme suit :

Soit i un état du système et a_{ii} représente la probabilité auto-transition de cet état, alors la probabilité de resté dans l'état i pour une période consécutif de temps " d ", est représenté par :

$$a_{ii}^{d-1} * (1 - a_{ii}) \quad (35)$$

Le paramétrage explicite de la durée d'état développé par MSMC est défini par l'estimation d'un paramètre de type probabiliste :

$P_i(d)$ avec $1 \leq d \leq D$, avec D représente le durée maximale (limite) dans un état.

P_i représente un vecteur de probabilités de durée discrète tel que :

$$\sum_{d=1}^D P_i(d) = 1 \quad (36)$$

Deux classes de distribution peuvent être utilisées qui sont :

La distribution discrète de la durée d'état et la distribution continue de la durée d'état.

A.3.1. La distribution discrète de la durée d'état

En fait, une distribution de poisson à été proposée pour modéliser la durée d'état dans un HMM. Dans ce cas l'équation suivante représente la probabilité de la durée dans l'état j :

$$P_j(d) = e^{-l_j} * \frac{(l_j)^d}{d!} \quad (37)$$

Avec d est la durée passé dans l'état j et l_j est le paramètre de loi de poisson qui représente l'espérance de d .

En fait, l'estimation de l_j est calculée par le calcul de l'espérance de la durée de l'état divisé par l'espérance de l'occurrence de cet état. L'équation utiliser pour estimer le paramètre l_j et $x_{t_0,t_1}(j)$ obtenu par l'équation :

$$l_j = \frac{\sum_{t_0=1}^T \sum_{t_1=t_0}^T x_{t_0,t_1}(j) + (t_1 - t_0 + 1)}{\sum_{t_0=1}^T \sum_{t_1=t_0}^T x_{t_0,t_1}(j)} \quad (38)$$

Avec,

$$x_{t_0,t_1}(j) = \frac{\sum_{i=1}^N \alpha_{t_0,t_1}(j) \times a_{ij} \prod_{s=t_0}^{t_1} b_j(O_s) \times P_j(t_1 - t_0 + 1) \times \beta_{t_1}(j)}{p(O | \lambda)} \quad (39)$$

A.3.2. La distribution continue de la durée d'état

Pour modéliser explicitement la durée dans le modèle de Markov, deux distributions continues sont proposée qui sont : La distribution gamma et la distribution gaussienne.

La distribution gamma qui modélise la densité de durée d'état est présentée par l'équation :

$$P_j(d) = \frac{\eta_j^{v_j} \cdot d^{v_j-1} e^{-\eta_j d}}{\tau(v_j)} \quad (40)$$

Les paramètres η_j , v_j et $\eta_j v_j^{-1}$ représentent la moyenne et $\sigma_j^2 = v_j \eta_j^{-2}$ représente la variance.

L'équation suivante permet d'estimer la variance ou le paramètre ξ_j est obtenu en utilisant l'équation A.26.

$$\sigma_j = \frac{\sum_{t_0=1}^T \sum_{t_1=t_0}^T x_{t_0,t_1}(j) * (t_1 - t_0 + 1)^2}{\sum_{t_0=1}^T \sum_{t_1=t_0}^T x_{t_0,t_1}(j)} - (\bar{\xi}_j)^2 \quad (41)$$

$$\xi_j = \frac{\sum_{t_0=1}^T \sum_{t_1=t_0}^T x_{t_0,t_1}(j) * (t_1 - t_0 + 1)}{\sum_{t_0=1}^T \sum_{t_1=t_0}^T x_{t_0,t_1}(j)} \quad (42)$$

La distribution gaussienne qui modélise la densité de durée d'état est présenter par l'équation :

$$P_j(d) = \frac{1}{\sigma_j (2\pi)^{1/2}} * e^{\frac{-(d-m_j)^2}{2\sigma_j^2}} \quad (43)$$

Avec m_j est la moyenne de la loi gaussienne et σ_j la variance de la loi gaussienne.

A.4. Fonctionnement du THHMM

Le modèle THHMM proposé, permet une reconnaissance par niveau et introduit aussi la possibilité d'estimer les temps passés dans un état donnée. Le modèle THHMM est représenté par $\lambda = (A^S, B^S, \pi^S, P_S(d), N)$

$P_S(d)$ représente la probabilité que le modèle reste dans un état pendant une durée d .

Dans ce cadre, les algorithmes de reconnaissance et d'apprentissage de base (Baum-Welch et forward-Backward) subit une re-formulation afin d'appliquer la structure hiérarchique et la notion temporelle de THHMM.

La probabilité de vraisemblance $P(O | \lambda)$, peut être calculée par l'algorithme

Algorithm 10 Procédure temporelle hiérarchique forward

1. Initialisation du niveau de la hiérarchie (n)

2. Pour i allant de 1 à N faire

$$\alpha_1^n(i) = \pi_i b_i(O_1) P_1(1)$$

3. Fin pour

4. Pour t de 1 à $T-1$ faire

5. Pour i de 1 à N faire

$$\alpha_{t+1}^n(i) = [\sum \alpha_t(j) \cdot a_{ji}] b_i(O_{t+1})$$

6. Fin pour

7. Fin pour

8. Calculer : $P(O | \lambda) = \sum_{i=1}^N \alpha_t(i)$

9. Fin

forward-backward à partir de l'équation A.29.

$$P(O | \lambda) = \sum_{i=1}^N \sum_{i=1, i \neq j}^N \sum_{d=1}^t \alpha_{t-d}(i) a_{ij} P_j(d) \prod_{s=t-d+1}^t b_j(O_s) \beta_t(j) \quad (44)$$

Algorithm 11 Procédure temporelle hiérarchique backward

1. Initialisation du niveau de la hiérarchie (n)

2. Pour i allant de 1 à N faire
 3. $\beta_t(i) = 1$
 3. Fin pour
 4. Pour t de 1 à T-1 faire
 5. Pour i de 1 à N faire
 6. $\beta_t(i) = \sum a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)$
 6. Fin pour
 7. Fin pour
 8. Calculer $P(O | \lambda) = \sum_{i=1}^N \pi_i b_i(o_1) \beta_1(i)$
 9. Fin
-

Algorithm 12 Algorithme hiérarchique temporelle Baum-Welch

1. Initialisation des paramètres

2. Répéter
 3. À un niveau n de l'hiérarchie, pour chaque séquence observée
 4. Calculer $\alpha(S_j^n)$ avec l'algorithme hiérarchique temporel Forward
 5. Calculer $\beta(S_j^n)$ avec l'algorithme hiérarchique temporel Backward
 6. Calculer $\xi(S_j^n)$
 7. Calculer $\gamma(S_j^n)$
 8. Fin pour
 9. Ré-estimer les paramètres du THHMM jusqu'à ce qu'ils deviennent stable
-

Bibliographie

- [1] Vincent Coutton. Évaluer la dépendance à l'aide de groupes iso-ressources (gir) : une tentative en france avec la grille aggir. *Gérontologie et société*, 24(4) :111–129, 2001.
- [2] R Hébert, R Carrier, and A Bilodeau. The functional autonomy measurement system (smaf) : description and validation of an instrument for the measurement of handicaps. *Age and ageing*, 17(5) :293–302, 1988.
- [3] Haider Hasan Mshali. *Services e-santé sensibles au contexte dans les espaces intelligents*. PhD thesis, Bordeaux, 2017.
- [4] Guido Bertucci. United nations department of economic and social affairs, 2007.
- [5] Roberto Casas, Rubén Blasco Marín, Alexia Robinet, Armando Roy Delgado, Armando Roy Yarza, John Mcginn, Richard Picking, and Vic Grout. User modelling in ambient intelligence for elderly and disabled people. In *International Conference on Computers for Handicapped Persons*, pages 114–122. Springer, 2008.
- [6] Anders Gustavsson, Linus Jönsson, Rupert McShane, Mercè Boada, Anders Wimo, and Arthur S Zbrozek. Willingness-to-pay for reductions in care need : estimating the value of informal care in alzheimer’s disease. *International journal of geriatric psychiatry*, 25(6) :622–632, 2010.
- [7] Juan Carlos Augusto. Ambient intelligence : the confluence of ubiquitous/-pervasive computing and artificial intelligence. *Intelligent Computing Everywhere*, pages 213–234, 2007.
- [8] George Papamathaiakis, George C Polyzos, and George Xylomenos. Monitoring and modeling simple everyday activities of the elderly at home. In *Consumer Communications and Networking Conference (CCNC), 2010 7th IEEE*, pages 1–5. IEEE, 2010.

- [9] Juan Carlos Augusto. Ambient intelligence : Basic concepts and applications. In *International Conference on Software and Data Technologies*, pages 16–26. Springer, 2006.
- [10] Emile Aarts, Panos Markopoulos, and Boris De Ruyter. The persuasiveness of ambient intelligence. In *Security, privacy, and trust in modern data management*, pages 367–381. Springer, 2007.
- [11] Ken Ducatel, Marc Bogdanowicz, Fabiana Scapolo, Jos Leijten, and Jean-Claude Burgelman. *Scenarios for ambient intelligence in 2010*. Office for official publications of the European Communities Luxembourg, 2001.
- [12] Eisaku Maeda and Yasuhiro Minami. Steps toward ambient intelligence. *NIT Technical Review*, 4(1), 2006.
- [13] Ambient intelligence : Changing lives for the better, 2007.
- [14] Cecile KM Crutzen. Invisibility and the meaning of ambient intelligence. *International Review of Information Ethics*, 6(12) :52–62, 2006.
- [15] Jörg Rech and Klaus-Dieter Althoff. Artificial intelligence and software engineering : Status and future trends. *KI*, 18(3) :5–11, 2004.
- [16] Athanasios Vasilakos and Witold Pedrycz. *Ambient intelligence, wireless networking, and ubiquitous computing*. Artech House, Inc, 2006.
- [17] Emile Aarts and Boris De Ruyter. New research perspectives on ambient intelligence. *Journal of Ambient Intelligence and Smart Environments*, 1(1) :5–14, 2009.
- [18] Peter J Denning. *The Invisible future : the seamless integration of technology into everyday life*. McGraw-Hill, Inc., 2001.
- [19] Emile Aarts and Stefano Marzano. The new everyday : Visions of ambient intelligence, 010 publishing. *Rotterdam, The Netherlands*, 116, 2003.
- [20] Diane J Cook, Juan C Augusto, and Vikramaditya R Jakkula. Ambient intelligence : Technologies, applications, and opportunities. *Pervasive and Mobile Computing*, 5(4) :277–298, 2009.
- [21] Juan C Augusto, Vic Callaghan, Diane Cook, Achilles Kameas, and Ichiro Satoh. *Intelligent environments : a manifesto*. 2013.

- [22] Faiyaz Doctor, Hani Hagaras, and Victor Callaghan. A fuzzy embedded agent-based approach for realizing ambient intelligence in intelligent inhabited environments. *IEEE Transactions on Systems, Man, and Cybernetics-Part A : Systems and Humans*, 35(1) :55–65, 2005.
- [23] Parisa Rashidi, Diane J Cook, Lawrence B Holder, and Maureen Schmitter-Edgecombe. Discovering activities to recognize and track in a smart environment. *IEEE transactions on knowledge and data engineering*, 23(4) :527–539, 2011.
- [24] John Beard, Simon Biggs, David Bloom, Linda Fried, Paul Hogan, Re Kalache, and Jay Olshansky. Global population ageing : Peril or promise? 2012.
- [25] IA Aytac, JB McKinlay, RJ Krane, et al. The likely worldwide increase in erectile dysfunction between 1995 and 2025 and some possible policy consequences. *BJU international*, 84 :50–56, 1999.
- [26] United Nations. World population ageing 2013. *Department of Economic and Social Affairs PD*, 2013.
- [27] Taketoshi Mori, Akinori Fujii, Masamichi Shimosaka, Hiroshi Noguchi, and Tomomasa Sato. Typical behavior patterns extraction and anomaly detection algorithm based on accumulated home sensor data. In *Future generation communication and networking (FGCN 2007)*, volume 2, pages 12–18. IEEE, 2007.
- [28] Diane J Cook, Michael Youngblood, Edwin O Heierman, Karthik Gopalratnam, Sira Rao, Andrey Litvin, and Farhan Khawaja. Mavhome : An agent-based smart home. In *Pervasive Computing and Communications, 2003.(PerCom 2003). Proceedings of the First IEEE International Conference on*, pages 521–524. IEEE, 2003.
- [29] B Ivanov, H Ruser, and M Kellner. Presence detection and person identification in smart homes.
- [30] Thomas Kleinberger, Martin Becker, Eric Ras, Andreas Holzinger, and Paul Müller. Ambient intelligence in assisted living : enable elderly people to handle future interfaces. In *International Conference on Universal Access in Human-Computer Interaction*, pages 103–112. Springer, 2007.
- [31] Diane Cook and Sajal Kumar Das. *Smart environments : Technology, protocols and applications*, volume 43. John Wiley & Sons, 2004.

- [32] DOMUS. Laboratoire domus, 2012. <http://www.usherbrooke.ca>.
- [33] HOMECARE. Laas : projet homecare, 2014. <http://projects.laas.fr/HOMECARE/>.
- [34] WISDOM. Centre interdisciplinaire de recherche travail etat et société., 2014. <http://www.uclouvain.be/470227.html>.
- [35] Ger van den Broek, Filippo Cavallo, and Christian Wehrmann. *AALLIANCE ambient assisted living roadmap*, volume 6. IOS press, 2010.
- [36] Dave Randall. Living inside a smart home : A case study. In *Inside the smart home*, pages 227–246. Springer, 2003.
- [37] Nathalie Bricon-Souf and Conrad R Newman. Context awareness in health care : A review. *international journal of medical informatics*, 76(1) :2–12, 2007.
- [38] Mathieu Gallissot. *Modéliser le concept de confort dans un habitat intelligent : du multisensoriel au comportement*. PhD thesis, Grenoble, 2012.
- [39] John Paul Varkey, Dario Pompili, and Theodore A Walls. Human motion recognition using a wireless sensor-based wearable system. *Personal and Ubiquitous Computing*, 16(7) :897–910, 2012.
- [40] Lih-Jen Kau and Chih-Sheng Chen. A smart phone-based pocket fall accident detection, positioning, and rescue system. *IEEE journal of biomedical and health informatics*, 19(1) :44–56, 2015.
- [41] Daniel Ashbrook and Thad Starner. Using gps to learn significant locations and predict movement across multiple users. *Personal and Ubiquitous computing*, 7(5) :275–286, 2003.
- [42] Lin Liao, Donald J Patterson, Dieter Fox, and Henry Kautz. Learning and inferring transportation routines. *Artificial Intelligence*, 171(5-6) :311–331, 2007.
- [43] Adam T Barth, Mark A Hanson, Harry C Powell Jr, and John Lach. Tempo 3.1 : A body area sensor network platform for continuous movement assessment. In *Wearable and Implantable Body Sensor Networks, 2009. BSN 2009. Sixth International Workshop on*, pages 71–76. IEEE, 2009.
- [44] Dong-Oh Kang, Hyung-Jik Lee, Eun-Jung Ko, Kyuchang Kang, and Jeun-woo Lee. A wearable context aware system for ubiquitous healthcare. In *Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE*, pages 5192–5195. IEEE, 2006.

- [45] Young-Dong Lee and Wan-Young Chung. Wireless sensor network based wearable smart shirt for ubiquitous health and activity monitoring. *Sensors and Actuators B : Chemical*, 140(2) :390–395, 2009.
- [46] Dong-oh Kang, Kyuchang Kang, Hyung-jik Lee, Eun-jung Ko, and Jeunwoo Lee. A systematic design tool of context aware system for ubiquitous healthcare service in a smart home. In *Future generation communication and networking (fgcn 2007)*, volume 2, pages 49–54. IEEE, 2007.
- [47] Tayeb Lemlouma and Mohamed Aymen Chalouf. Smart media services through tv sets for elderly and dependent persons. In *International Conference on Wireless Mobile Communication and Healthcare*, pages 30–40. Springer, 2012.
- [48] Michel Vacher, Dan Istrate, François Portet, Thierry Joubert, Thierry Chevalier, Serge Smidtas, Brigitte Meillon, Benjamin Lecouteux, Mohamed Sehilli, Pedro Chahuara, et al. The sweet-home project : Audio technology in smart homes to improve well-being and reliance. In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, pages 5291–5294. IEEE, 2011.
- [49] Anthony Fleury, Norbert Noury, Michel Vacher, Hubert Glasson, and J-F Seri. Sound and speech detection and classification in a health smart home. In *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, pages 4644–4647. IEEE, 2008.
- [50] Damien Brulin, Yannick Benezeth, and Estelle Courtial. Posture recognition based on fuzzy logic for home monitoring of the elderly. *IEEE transactions on information technology in biomedicine*, 16(5) :974–982, 2012.
- [51] Bernt Schiele, Mykhaylo Andriluka, Nikodem Majer, Stefan Roth, and Christian Wojek. Visual people detection : Different models, comparison and discussion. In *Proceedings of the IEEE ICRA Workshop on People Detection and Tracking*, 2009.
- [52] Tarik Taleb, Dario Bottazzi, Mohsen Guizani, and Hammadi Nait-Charif. Angelah : a framework for assisting elders at home. *IEEE Journal on Selected Areas in Communications*, 27(4), 2009.
- [53] Guillaume Sacco, Véronique Joumier, Nelly Darmon, Arnaud Dechamps, Alexandre Derreumaux, Ji-Hyun Lee, Julie Piano, Nathalie Bordone, Alexandra König, Bernard Teboul, et al. Detection of activities of daily living impairment in alzheimer’s disease and mild cognitive impairment using

- information and communication technology. *Clinical interventions in aging*, 7 :539, 2012.
- [54] Zhonghai Wang and Xiaoya Xu. Smart home m2m networks architecture. In *Mobile Ad-hoc and Sensor Networks (MSN), 2013 IEEE Ninth International Conference on*, pages 294–299. IEEE, 2013.
- [55] Yao-lin Zhu, Rong Li, Xue-bin Liu, and Xu Jian. Wireless communication technology in family health monitoring system. In *Business Management and Electronic Information (BMEI), 2011 International Conference on*, volume 3, pages 64–67. IEEE, 2011.
- [56] Jason Pascoe. Adding generic contextual capabilities to wearable computers. In *Wearable Computers, 1998. Digest of Papers. Second International Symposium on*, pages 92–99. IEEE, 1998.
- [57] Bill Schilit, Norman Adams, and Roy Want. Context-aware computing applications. In *Mobile Computing Systems and Applications, 1994. WMCSA 1994. First Workshop on*, pages 85–90. IEEE, 1994.
- [58] Gregory Abowd, Anind Dey, Peter Brown, Nigel Davies, Mark Smith, and Pete Steggle. Towards a better understanding of context and context-awareness. In *Handheld and ubiquitous computing*, pages 304–307. Springer, 1999.
- [59] Sangkeun Lee, Juno Chang, and Sang-goo Lee. Survey and trend analysis of context-aware systems. *Information-An International Interdisciplinary Journal*, 14(2) :527–548, 2011.
- [60] Nagender Kumar Suryadevara, Subhas C Mukhopadhyay, Ruili Wang, and RK Rayudu. Forecasting the behavior of an elderly using wireless sensors data in a smart home. *Engineering Applications of Artificial Intelligence*, 26(10) :2641–2652, 2013.
- [61] Sidney Katz. Assessing self-maintenance : activities of daily living, mobility, and instrumental activities of daily living. *Journal of the American Geriatrics Society*, 31(12) :721–727, 1983.
- [62] Laurence G Branch and Alan M Jette. A prospective study of long-term care institutionalization among the aged. *American Journal of Public Health*, 72(12) :1373–1379, 1982.
- [63] Tayeb Lemlouma, Sébastien Laborie, and Philippe Roose. Toward a context-aware and automatic evaluation of elderly dependency in smart homes and

- cities. In *World of Wireless, Mobile and Multimedia Networks (WoWMoM), 2013 IEEE 14th International Symposium and Workshops on a*, pages 1–6. IEEE, 2013.
- [64] Wan-rong Jih, Jane Yung-jen Hsu, Chao-Lin Wu, Chun-Feng Liao, and Shao-you Cheng. A multi-agent service framework for context-aware elder care. In *In AAMAS*, 2006.
- [65] Ching-Hu Lu and Li-Chen Fu. Robust location-aware activity recognition using wireless sensor network in an attentive home. *IEEE Transactions on Automation Science and Engineering*, 6(4) :598–609, 2009.
- [66] Eri Shimokawara, Tetsuya Kaneko, Toru Yamaguchi, Makoto Mizukawa, and Nobuto Matsuhira. Estimation of basic activities of daily living using zigbee 3d accelerometer sensor network. In *Biometrics and Kansei Engineering (ICBAKE), 2013 International Conference on*, pages 251–256. IEEE, 2013.
- [67] Bingchuan Yuan and John Herbert. Context-aware hybrid reasoning framework for pervasive healthcare. *Personal and ubiquitous computing*, 18(4) :865–881, 2014.
- [68] Nagender Kumar Suryadevara and Subhas Chandra Mukhopadhyay. Wireless sensor network based home monitoring system for wellness determination of elderly. *IEEE Sensors Journal*, 12(6) :1965–1972, 2012.
- [69] Muhammad Mubashir, Ling Shao, and Luke Seed. A survey on fall detection : Principles and approaches. *Neurocomputing*, 100 :144–152, 2013.
- [70] GE Wu and Shuwan Xue. Portable preimpact fall detector with inertial sensors. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 16(2) :178–183, 2008.
- [71] Chin-Feng Lai, Sung-Yen Chang, Han-Chieh Chao, and Yueh-Min Huang. Detection of cognitive injured body region using multiple triaxial accelerometers for elderly falling. *IEEE Sensors Journal*, 11(3) :763–770, 2011.
- [72] Xiaodan Zhuang, Jing Huang, Gerasimos Potamianos, and Mark Hasegawa-Johnson. Acoustic fall detection using gaussian mixture models and gmm supervectors. In *Acoustics, Speech and Signal Processing, 2009. ICASSP 2009. IEEE International Conference on*, pages 69–72. IEEE, 2009.
- [73] Majd Alwan, Prabhu Jude Rajendran, Steve Kell, David Mack, Siddharth Dalal, Matt Wolfe, and Robin Felder. A smart and passive floor-vibration based fall detector for elderly. In *Information and Communication Technologies, 2006. ICTTA'06. 2nd*, volume 1, pages 1003–1007. IEEE, 2006.

- [74] Homa Foroughi, Aabed Naseri, Alireza Saberi, and Hadi Sadoghi Yazdi. An eigenspace-based approach for human fall detection using integrated time motion image and neural network. In *Signal Processing, 2008. ICSP 2008. 9th International Conference on*, pages 1499–1503. IEEE, 2008.
- [75] Guangyi Shi, Cheung Shing Chan, Wen Jung Li, Kwok-Sui Leung, Yuexian Zou, and Yufeng Jin. Mobile human airbag system for fall protection using mems sensors and embedded svm classifier. *IEEE Sensors Journal*, 9(5) :495–503, 2009.
- [76] Asanga Wickramasinghe, Roberto Luis Shinmoto Torres, and Damith C Ranasinghe. Recognition of falls using dense sensing in an ambient assisted living environment. *Pervasive and mobile computing*, 34 :14–24, 2017.
- [77] Lars Klack, Christian Möllering, Martina Ziefle, and Thomas Schmitz-Rode. Future care floor : a sensitive floor for movement monitoring and fall detection in home environments. In *International Conference on Wireless Mobile Communication and Healthcare*, pages 211–218. Springer, 2010.
- [78] Andreas Braun, Henning Heggen, and Reiner Wichert. Capfloor—a flexible capacitive indoor localization system. In *International Competition on Evaluating AAL Systems through Competitive Benchmarking*, pages 26–35. Springer, 2011.
- [79] Myra A Aud, Carmen C Abbott, Harry W Tyrer, Rohan VasanthaNeelgund, Uday G Shriniwar, Ashrafuddin Mohammed, and Krishna KishorDevarakonda. Smart carpet : Developing a sensor system to detect falls and summon assistance. *Journal of gerontological nursing*, 36(7) :8, 2010.
- [80] J Mikael Eklund, J Sprinkle, Shankar Sastry, and TR Hansen. Information technology for assisted living at home : building a wireless infrastructure for assisted living. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, pages 3931–3934. IEEE, 2006.
- [81] Thomas Riisgaard Hansen, J Mikael Eklund, Jonthan Sprinkle, Ruzena Bajcsy, and Shankar Sastry. Using smart sensors and a camera phone to detect and verify the fall of elderly persons. In *European Medicine, Biology and Engineering Conference*, volume 20, page 2486, 2005.
- [82] Daniele Riboni and Claudio Bettini. Cosar : hybrid reasoning for context-aware activity recognition. *Personal and Ubiquitous Computing*, 15(3) :271–289, 2011.

- [83] Ali Maleki Tabar, Arezou Keshavarz, and Hamid Aghajan. Smart home care network using sensor fusion and distributed vision-based reasoning. In *Proceedings of the 4th ACM international workshop on Video surveillance and sensor networks*, pages 145–154. ACM, 2006.
- [84] Chien-Chang Hsu and Jun-Hao Chen. A novel sensor-assisted rfid-based indoor tracking system for the elderly living alone. *Sensors*, 11(11) :10094–10113, 2011.
- [85] Hui-Huang Hsu and Chien-Chen Chen. Rfid-based human behavior modeling and anomaly detection for elderly care. *Mobile Information Systems*, 6(4) :341–354, 2010.
- [86] Dorra Trabelsi, Samer Mohammed, Faicel Chamroukhi, Latifa Oukhellou, and Yacine Amirat. An unsupervised approach for automatic activity recognition based on hidden markov model regression. *IEEE Transactions on Automation Science and Engineering*, 10(3) :829–835, 2013.
- [87] Urs Anliker, Jamie A Ward, Paul Lukowicz, Gerhard Troster, Francois Dolveck, Michel Baer, Fatou Keita, Eran B Schenker, Fabrizio Catarsi, Luca Coluccini, et al. Amon : a wearable multiparameter medical monitoring and alert system. *IEEE Transactions on information technology in Biomedicine*, 8(4) :415–427, 2004.
- [88] Bosch. Healthbuddy, 2010. www.bosch-telehealth.com.
- [89] Philips. Telestation, 2011. www.healthcare.philips.com.
- [90] Intel. Healthguide, 2011. www.intel.com.
- [91] Toshiro Suzuki, Sumio Murase, Tomoyuki Tanaka, and Takako Okazawa. New approach for the early detection of dementia by recording in-house activities. *Telemedicine and e-Health*, 13(1) :41–44, 2007.
- [92] Honeywell. Genesis dm, 2011. <http://hommed.com/>.
- [93] Rita Paradiso, Giannicola Loriga, and Nicola Taccini. A wearable health care system based on knitted integrated sensors. *IEEE transactions on Information Technology in biomedicine*, 9(3) :337–344, 2005.
- [94] Stéphanie Pasche, Silvia Angeloni, Réal Ischer, Martha Liley, Jean Luprano, and Guy Voirin. Wearable biosensors for monitoring wound healing. In *Advances in Science and Technology*, volume 57, pages 80–87. Trans Tech Publ, 2008.

- [95] Marco Di Rienzo, Francesco Rizzo, Gianfranco Parati, Gabriella Brambilla, Maurizio Ferratini, and Paolo Castiglioni. Magic system : A new textile-based wearable device for biological signal monitoring. applicability in daily life and clinical setting. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, pages 7167–7169. IEEE, 2005.
- [96] Diana Hodgins, Arnaud Bertsch, Nils Post, Manfred Frischholz, Bart Volckaerts, John Spensley, JM Wasikiewicz, Henry Higgins, Felix Von Stetten, and Laurence Kenney. Healthy aims : Developing new medical implants and diagnostic equipment. *IEEE Pervasive Computing*, 7(1) :14–21, 2008.
- [97] Yasushi Masuda, Mitsuyoshi Sekimoto, Masayuki Nambu, Yuji Higashi, Toshirou Fujimoto, Kunihiro Chihara, and Y Tamura. An unconstrained monitoring system for home rehabilitation. *IEEE engineering in medicine and biology magazine*, 24(4) :43–47, 2005.
- [98] Hisanori Andoh, Takayuki Ishikawa, Keita Kobayashi, K Watanabe, and T Nakamura. Home health monitoring system in the sleep. In *SICE 2003 Annual Conference*, volume 2, pages 1223–1226. IEEE, 2003.
- [99] Yoshifumi Nishida, Toshio Hori, Takashi Suehiro, and Shigeoki Hirai. Sensorized environment for self-communication based on observation of daily human behavior. In *Intelligent Robots and Systems, 2000.(IROS 2000). Proceedings. 2000 IEEE/RSJ International Conference on*, volume 2, pages 1364–1372. IEEE, 2000.
- [100] Hamid Medjahed, Dan Istrate, Jerome Boudy, Jean-Louis Baldinger, and Bernadette Dorizzi. A pervasive multi-sensor data fusion for smart home healthcare monitoring. In *Fuzzy Systems (FUZZ), 2011 IEEE International Conference on*, pages 1466–1473. IEEE, 2011.
- [101] Zhanpeng Jin, Joseph Oresko, Shimeng Huang, and Allen C Cheng. Hearttogo : a personalized medicine technology for cardiovascular disease prevention and detection. In *Life Science Systems and Applications Workshop, 2009. LiSSA 2009. IEEE/NIH*, pages 80–83. IEEE, 2009.
- [102] Kewei Sha, Guoxing Zhan, Weisong Shi, Mark Lumley, Clairry Wiholm, and Bengt Arnetz. Spa : a smart phone assisted chronic illness self-management system with participatory sensing. In *Proceedings of the 2nd International Workshop on Systems and Networking Support for Health Care and Assisted Living Environments*, page 5. ACM, 2008.

- [103] Wan-Young Chung, Chiew-Lian Yau, Kwang-Sig Shin, and Risto Myllyla. A cell phone based health monitoring system with self analysis processor using wireless sensor network technology. In *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*, pages 3705–3708. IEEE, 2007.
- [104] Anthony D Wood, John A Stankovic, Gilles Virone, Leo Selavo, Zhimin He, Qiuhua Cao, Thao Doan, Yafeng Wu, Lei Fang, and Radu Stoleru. Context-aware wireless sensor networks for assisted living and residential monitoring. *IEEE network*, 22(4), 2008.
- [105] Mizue Suzuki, Naomi Ohyama, Kiyomi Yamada, and Masao Kanamori. The relationship between fear of falling, activities of daily living and quality of life among elderly individuals. *Nursing & health sciences*, 4(4) :155–161, 2002.
- [106] Meredith Rowe, Stephen Lane, and Chad Phipps. Carewatch : a home monitoring system for use in homes of persons with cognitive impairment. *Topics in geriatric rehabilitation*, 23(1) :3, 2007.
- [107] Dewi Mairiza, Didar Zowghi, and Nurie Nurmuliani. An investigation into the notion of non-functional requirements. In *Proceedings of the 2010 ACM Symposium on Applied Computing*, pages 311–317. ACM, 2010.
- [108] Christiane Gresse von Wangenheim, Aldo von Wangenheim, Fergal McCaffery, Jean Carlo R Hauck, and Luigi Buglione. Tailoring software process capability/maturity models for the health domain. *Health and Technology*, 3(1) :11–28, 2013.
- [109] Hyun Lee, Kyungseo Park, Byoungyong Lee, Jaesung Choi, and Ramez Elmasri. Issues in data fusion for healthcare monitoring. In *Proceedings of the 1st international conference on Pervasive Technologies Related to Assistive Environments*, page 3. ACM, 2008.
- [110] Daniel Halperin, Thomas S Heydt-Benjamin, Kevin Fu, Tadayoshi Kohno, and William H Maisel. Security and privacy for implantable medical devices. *IEEE pervasive computing*, 7(1), 2008.
- [111] Xiaohu Fan, Qubo Xie, Xuebin Li, Hao Huang, Jian Wang, Si Chen, Changsheng Xie, and Jiajing Chen. Activity recognition as a service for smart home : Ambient assisted living application via sensing home. In *AI & Mobile Services (AIMS), 2017 IEEE International Conference on*, pages 54–61. IEEE, 2017.

- [112] Moshaddique Al Ameen, Jingwei Liu, and Kyungsup Kwak. Security and privacy issues in wireless sensor networks for healthcare applications. *Journal of medical systems*, 36(1) :93–101, 2012.
- [113] Sakineh Aghazadeh, Habibollah Pirnejad, Alvosat Aliev, and Alireza Moradkhani. Evaluating the effect of software quality characteristics on health care quality indicators. *Journal of Health Management and Informatics*, 2(3) :67–73, 2015.
- [114] Shahriar Akter, John D’Ambra, and Pradeep Ray. Service quality of mhealth platforms : development and validation of a hierarchical model using pls. *Electronic Markets*, 20(3-4) :209–227, 2010.
- [115] Juan M Corchado, Javier Bajo, Dante I Tapia, and Ajith Abraham. Using heterogeneous wireless sensor networks in a telemonitoring system for healthcare. *IEEE transactions on information technology in biomedicine*, 14(2) :234–240, 2010.
- [116] Alexandra Aguiar, J Sérgio Filho, Felipe G Magalhães, Thiago D Casagrande, and Fabiano Hessel. Hellfire : A design framework for critical embedded systems’ applications. In *Quality Electronic Design (ISQED), 2010 11th International Symposium on*, pages 730–737. IEEE, 2010.
- [117] Third EvAAL Competition. Evaluating aal systems through competitive benchmarking. *Journal of Ambient Intelligence and Smart Environments*, 5 :143–144, 2013.
- [118] Parisa Rashidi and Alex Mihailidis. A survey on ambient-assisted living tools for older adults. *IEEE journal of biomedical and health informatics*, 17(3) :579–590, 2013.
- [119] Haider Mshali, Tayeb Lemlouma, and Damien Magoni. Analysis of dependency evaluation models for ehealth services. In *Global Communications Conference (GLOBECOM), 2014 IEEE*, pages 2429–2435. IEEE, 2014.
- [120] Ken Dychtwald. *Healthy aging : Challenges and solutions*. Jones & Bartlett Learning, 1999.
- [121] Abhaya Gupta. *Measurement scales used in elderly care*. Radcliffe Publishing, 2008.
- [122] Gunes Arik, Hacer Dogan Varan, Burcu Balam Yavuz, Erdem Karabulut, Ozgur Kara, Mustafa Kemal Kilic, Muhammet Cemal Kizilarlanoglu, Fatih Sumer, Mehmet Emin Kuyumcu, Yusuf Yesil, et al. Validation of katz index

- of independence in activities of daily living in turkish older adults. *Archives of gerontology and geriatrics*, 61(3) :344–350, 2015.
- [123] Sidney Katz, Amasa B Ford, Roland W Moskowitz, Beverly A Jackson, and Marjorie W Jaffe. Studies of illness in the aged : the index of adl : a standardized measure of biological and psychosocial function. *Jama*, 185(12) :914–919, 1963.
- [124] Johanne Desrosiers, Annie Rochette, Luc Noreau, Gina Bravo, Réjean Hébert, and Catherine Boutin. Comparison of two functional independence scales with a participation measure in post-stroke rehabilitation. *Archives of gerontology and geriatrics*, 37(2) :157–172, 2003.
- [125] Nicole Dubuc, Réjean Hébert, Johanne Desrosiers, Martin Buteau, and Lise Trottier. Disability-based classification system for older people in integrated long-term care services : the iso-smaf profiles. *Archives of gerontology and geriatrics*, 42(2) :191–206, 2006.
- [126] Michel Raïche, Réjean Hébert, Marie-France Dubois, Nicole Dubuc, et al. Yearly transitions of disability profiles in older people living at home. *Archives of Gerontology and Geriatrics*, 55(2) :399–405, 2012.
- [127] Louis Atallah and Guang-Zhong Yang. The use of pervasive sensing for behaviour profiling—a survey. *Pervasive and Mobile Computing*, 5(5) :447–464, 2009.
- [128] Oliver Brdiczka, James L Crowley, and Patrick Reignier. Learning situation models in a smart home. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 39(1) :56–63, 2009.
- [129] Abdur Rahim Mohammad Forkan, Ibrahim Khalil, Zahir Tari, Sebti Fofou, and Abdelaziz Bouras. A context-aware approach for long-term behavioural change detection and abnormality prediction in ambient assisted living. *Pattern Recognition*, 48(3) :628–641, 2015.
- [130] Eunju Kim, Sumi Helal, and Diane Cook. Human activity recognition and pattern discovery. *IEEE Pervasive Computing*, 9(1), 2010.
- [131] Li Ye, Zhi-Guang Qin, Juan Wang, and Jing Jin. Anomaly event detection in temporal sensor network data of intelligent environments. In *Computer Engineering and Technology (ICCET), 2010 2nd International Conference on*, volume 7, pages V7–414. IEEE, 2010.

- [132] Varun Chandola, Arindam Banerjee, and Vipin Kumar. Anomaly detection : A survey. *ACM computing surveys (CSUR)*, 41(3) :15, 2009.
- [133] Antonis Bikakis, Theodore Patkos, Grigoris Antoniou, and Dimitris Plexousakis. A survey of semantics-based approaches for context reasoning in ambient intelligence. In *European Conference on Ambient Intelligence*, pages 14–23. Springer, 2007.
- [134] Petteri Nurmi and Patrik Floréen. Reasoning in context-aware systems. *Helsinki Institute for Information Technology, Position paper*, 2004.
- [135] Liang Wang, Tao Gu, Xianping Tao, Hanhua Chen, and Jian Lu. Recognizing multi-user activities using wearable sensors in a smart home. *Pervasive and Mobile Computing*, 7(3) :287–298, 2011.
- [136] Nam Thanh Nguyen, Dinh Q Phung, Svetha Venkatesh, and Hung Bui. Learning and detecting activities from movement trajectories using the hierarchical hidden markov model. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 2, pages 955–960. IEEE, 2005.
- [137] Wonjoon Kang, Dongkyoo Shin, and Dongil Shin. Detecting and predicting of abnormal behavior using hierarchical markov model in smart home network. In *Industrial Engineering and Engineering Management (IE&EM), 2010 IEEE 17Th International Conference on*, pages 410–414. IEEE, 2010.
- [138] Pau-Choo Chung and Chin-De Liu. A daily behavior enabled hidden markov model for human behavior understanding. *Pattern Recognition*, 41(5) :1572–1580, 2008.
- [139] Thi V Duong, Hung Hai Bui, Dinh Q Phung, and Svetha Venkatesh. Activity recognition and abnormality detection with the switching hidden semi-markov model. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1, pages 838–845. IEEE, 2005.
- [140] Norbert Noury and Tareq Hadidi. Computer simulation of the activity of the elderly person living independently in a health smart home. *Computer methods and programs in biomedicine*, 108(3) :1216–1228, 2012.
- [141] Zaineb Liouane, Tayeb Lemlouma, Philippe Roose, Frédéric Weis, and Messaoud Hassani. A markovian-based approach for daily living activities recognition. *arXiv preprint arXiv :1603.03251*, 2016.

- [142] Arpad Gellert and Lucian Vintan. Person movement prediction using hidden markov models. *Studies in Informatics and control*, 15(1) :17, 2006.
- [143] Sira Panduranga Rao and Diane J Cook. Predicting inhabitant action using action and task models with application to smart homes. *International Journal on Artificial Intelligence Tools*, 13(01) :81–99, 2004.
- [144] Geetika Singla, Diane J Cook, and Maureen Schmitter-Edgecombe. Recognizing independent and joint activities among multiple residents in smart environments. *Journal of ambient intelligence and humanized computing*, 1(1) :57–63, 2010.
- [145] Giuseppe Fenza, Domenico Furno, and Vincenzo Loia. Enhanced health-care environment by means of proactive context aware service discovery. In *Advanced Information Networking and Applications (AINA), 2011 IEEE International Conference on*, pages 625–632. IEEE, 2011.
- [146] Han-Saem Park, Keunhyun Oh, and Sung-Bae Cho. Bayesian network-based high-level context recognition for mobile context sharing in cyber-physical system. *International Journal of Distributed Sensor Networks*, 7(1) :650387, 2011.
- [147] Jin-Hyuk Hong, Sung-Ihk Yang, and Sung-Bae Cho. Conamsn : A context-aware messenger using dynamic bayesian networks with wearable sensors. *Expert Systems with Applications*, 37(6) :4680–4686, 2010.
- [148] Youtian Du, Feng Chen, Wenli Xu, and Yongbin Li. Recognizing interaction activities using dynamic bayesian network. In *Pattern Recognition, 2006. ICPR 2006. 18th International Conference on*, volume 1, pages 618–621. IEEE, 2006.
- [149] Diane J Cook and Maureen Schmitter-Edgecombe. Assessing the quality of activities in a smart environment. *Methods of information in medicine*, 48(5) :480, 2009.
- [150] Emmanuel Munguia Tapia, Stephen S Intille, and Kent Larson. Activity recognition in the home using simple and ubiquitous sensors. In *Pervasive*, volume 4, pages 158–175. Springer, 2004.
- [151] Douglas L Vail, Manuela M Veloso, and John D Lafferty. Conditional random fields for activity recognition. In *Proceedings of the 6th international joint conference on Autonomous agents and multiagent systems*, page 235. ACM, 2007.

- [152] Diane J Cook. Learning setting-generalized activity models for smart spaces. *IEEE intelligent systems*, 27(1) :32–38, 2012.
- [153] Fabien Cardinaux, Simon Brownsell, Mark Hawley, and David Bradley. Modelling of behavioural patterns for abnormality detection in the context of lifestyle reassurance. In *Iberoamerican Congress on Pattern Recognition*, pages 243–251. Springer, 2008.
- [154] Xiaobo Xie, Junqi Guo, Hongyang Zhang, Tao Jiang, Rongfang Bie, and Yunchuan Sun. Neural-network based structural health monitoring with wireless sensor networks. In *Natural Computation (ICNC), 2013 Ninth International Conference on*, pages 163–167. IEEE, 2013.
- [155] Alexandros Pantelopoulos and Nikolaos Bourbakis. A health prognosis wearable system with learning capabilities using nns. In *Tools with Artificial Intelligence, 2009. ICTAI'09. 21st International Conference on*, pages 243–247. IEEE, 2009.
- [156] Adil Mehmood Khan, Young-Koo Lee, Sungyoung Y Lee, and Tae-Seong Kim. A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer. *IEEE transactions on information technology in biomedicine*, 14(5) :1166–1172, 2010.
- [157] Samir Chatterjee, Qi Xie, and Kaushik Dutta. A predictive modeling engine using neural networks : Diabetes management from sensor and activity data. In *e-Health Networking, Applications and Services (Healthcom), 2012 IEEE 14th International Conference on*, pages 230–237. IEEE, 2012.
- [158] Lucian Vintan, Arpad Gellert, Jan Petzold, and Theo Ungerer. Person movement prediction using neural networks. 2006.
- [159] Chiu-Che Tseng and Diane Cook. Mining from time series human movement data. In *Systems, Man and Cybernetics, 2006. SMC'06. IEEE International Conference on*, volume 4, pages 3241–3243. IEEE, 2006.
- [160] Hui Li, Qingfan Zhang, and Peiyong Duan. A novel one-pass neural network approach for activities recognition in intelligent environments. In *Intelligent Control and Automation, 2008. WCICA 2008. 7th World Congress on*, pages 50–54. IEEE, 2008.
- [161] Anthony Fleury, Michel Vacher, and Norbert Noury. Svm-based multimodal classification of activities of daily living in health smart homes : sensors, algorithms, and first experimental results. *IEEE transactions on information technology in biomedicine*, 14(2) :274–283, 2010.

- [162] Ya-Xuan Hung, Chih-Yen Chiang, Steen Hsu, and Chia-Tai Chan. Abnormality detection for improving elder's daily life independent. *Aging Friendly Technology for Health and Independence*, pages 186–194, 2010.
- [163] Rachid Kadouche, H el ene Pigot, Bessam Abdulrazak, and Sylvain Giroux. User's behavior classification model for smart houses occupant prediction. *Activity Recognition in Pervasive Intelligent Environments*, 4(7) :149–164, 2011.
- [164] Huiru Zheng, Haiying Wang, and Norman Black. Human activity detection in smart home environment with self-adaptive neural networks. In *Networking, Sensing and Control, 2008. ICNSC 2008. IEEE International Conference on*, pages 1505–1510. IEEE, 2008.
- [165] Ali Hussein, Mehdi Adda, Mirna Atieh, and Walid Fahs. Smart home design for disabled people based on neural networks. *Procedia Computer Science*, 37 :117–126, 2014.
- [166] Hongqing Fang and Lei He. Bp neural network for human activity recognition in smart home. In *Computer Science & Service System (CSSS), 2012 International Conference on*, pages 1034–1037. IEEE, 2012.
- [167] Zhigang Liu, Yanan Song, Ye Shang, and Jinkuan Wang. Posture recognition algorithm for the elderly based on bp neural networks. In *Control and Decision Conference (CCDC), 2015 27th Chinese*, pages 1446–1449. IEEE, 2015.
- [168] Tobias Teich, Falko Roessler, Daniel Kretz, and Susan Franke. Design of a prototype neural network for smart homes and energy efficiency. *Procedia Engineering*, 69 :603–608, 2014.
- [169] M Zia Uddin, JJ Lee, and T-S Kim. Independent shape component-based human activity recognition via hidden markov model. *Applied Intelligence*, 33(2) :193–206, 2010.
- [170] Muhammad Fahim, Iram Fatima, Sungyoung Lee, and Young-Koo Lee. Eem : evolutionary ensembles model for activity recognition in smart homes. *Applied intelligence*, 38(1) :88–98, 2013.
- [171] AM Jehad Sarkar, Young-Koo Lee, and Sungyoung Lee. A smoothed naive bayes-based classifier for activity recognition. *IETE Technical Review*, 27(2) :107–119, 2010.

- [172] Zaineb Liouane, Tayeb Lemlouma, Philippe Roose, Frédéric Weis, and Hasani Messaoud. An improved elman neural network for daily living activities recognition. In *International Conference on Intelligent Systems Design and Applications*, pages 697–707. Springer, 2016.
- [173] Zaineb Liouane, Tayeb Lemlouma, Philippe Roose, Frédéric Weis, and Hasani Messaoud. A genetic neural network approach for unusual behavior prediction in smart home. In *International Conference on Intelligent Systems Design and Applications*, pages 738–748. Springer, 2016.
- [174] Francesco Aiello, Giancarlo Fortino, Raffaele Gravina, and Antonio Guerrieri. A java-based agent platform for programming wireless sensor networks. *The Computer Journal*, 54(3) :439–454, 2010.
- [175] World Wide Web Consortium et al. Composite capability/preference profiles (cc/pp) : Structure and vocabularies 1.0. *W3C Recommendation*, 15, 2004.
- [176] Tayeb Lemlouma. *Multimedia services negotiation and adaptation architecture in heterogeneous environments*. PhD thesis.
- [177] Heather McDonald, Chris D Nugent, Dewar D Finlay, George Moore, William Burns, and Josef Hallberg. Assessing the impact of the homeml format and the homeml suite within the research community. *J. UCS*, 19(17) :2559–2576, 2013.
- [178] Bernardo Gonçalves, José Gonçalves Pereira Filho, and Rodrigo Varejão Andreão. Ecgware : an ecg markup language for ambulatory telemonitoring and decision making support. In *HEALTHINF (2)*, pages 37–43, 2008.
- [179] Vincent Rialle, Jean-Baptiste Lamy, Norbert Noury, and Lionel Bajolle. Telemonitoring of patients at home : a software agent approach. *Computer Methods and programs in Biomedicine*, 72(3) :257–268, 2003.
- [180] Karen Henriksen and Jadwiga Indulska. A software engineering framework for context-aware pervasive computing. In *Pervasive Computing and Communications, 2004. PerCom 2004. Proceedings of the Second IEEE Annual Conference on*, pages 77–86. IEEE, 2004.
- [181] Daqing Zhang, Tao Gu, and Xiaohang Wang. Enabling context-aware smart home with semantic web technologies. *International Journal of Human-friendly Welfare Robotic Systems*, 6(4) :12–20, 2005.
- [182] Bruno Bouchard, Sylvain Giroux, and Abdenour Bouzouane. A smart home agent for plan recognition of cognitively-impaired patients. *JCP*, 1(5) :53–62, 2006.

- [183] Liming Chen, Chris Nugent, Maurice Mulvenna, Dewar Finlay, Xin Hong, and Michael Poland. Using event calculus for behaviour reasoning and assistance in a smart home. *Smart homes and health telematics*, pages 81–89, 2008.
- [184] George Okeyo, Liming Chen, and Hui Wang. Combining ontological and temporal formalisms for composite activity modelling and recognition in smart homes. *Future Generation Computer Systems*, 39 :29–43, 2014.
- [185] Harry Chen, Filip Perich, Tim Finin, and Anupam Joshi. Soupa : Standard ontology for ubiquitous and pervasive applications. In *Mobile and Ubiquitous Systems : Networking and Services, 2004. MOBIQUITOUS 2004. The First Annual International Conference on*, pages 258–267. IEEE, 2004.
- [186] Juan Ye, Graeme Stevenson, and Simon Dobson. Usmart : An unsupervised semantic mining activity recognition technique. *ACM Transactions on Interactive Intelligent Systems (TiiS)*, 4(4) :16, 2015.
- [187] Liming Chen, Chris D Nugent, and Hui Wang. A knowledge-driven approach to activity recognition in smart homes. *IEEE Transactions on Knowledge and Data Engineering*, 24(6) :961–974, 2012.
- [188] Fahd Albinali, Nigel Davies, and Adrian Friday. Structural learning of activities from sparse datasets. In *Pervasive Computing and Communications, 2007. PerCom'07. Fifth Annual IEEE International Conference on*, pages 221–228. IEEE, 2007.
- [189] Sebastian Luhr, Hung Hai Bui, Svetha Venkatesh, and Geoff AW West. Recognition of human activity through hierarchical stochastic learning. In *Pervasive Computing and Communications, 2003.(PerCom 2003). Proceedings of the First IEEE International Conference on*, pages 416–422. IEEE, 2003.
- [190] Lawrence R Rabiner. A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2) :257–286, 1989.
- [191] Hung H Bui, Svetha Venkatesh, and Geoff West. Tracking and surveillance in wide-area spatial environments using the abstract hidden markov model. *International Journal of Pattern Recognition and Artificial Intelligence*, 15(01) :177–196, 2001.
- [192] Shai Fine, Yoram Singer, and Naftali Tishby. The hierarchical hidden markov model : Analysis and applications. *Machine learning*, 32(1) :41–62, 1998.

- [193] Nuria Oliver, Eric Horvitz, and Ashutosh Garg. Layered representations for human activity recognition. In *Proceedings of the 4th IEEE International Conference on Multimodal Interfaces*, page 3. IEEE Computer Society, 2002.
- [194] Ming Dong and David He. A segmental hidden semi-markov model (hsmm)-based diagnostics and prognostics framework and methodology. *Mechanical systems and signal processing*, 21(5) :2248–2266, 2007.
- [195] Chris Pal and Mike Hu. Methodologies for constructing and training large hierarchical hidden markov models for sequence analysis. *RECOMB'01*, 2001.
- [196] Anh Dinh, Daniel Teng, Li Chen, Yang Shi, Carl McCrosky, Jenny Basran, and Vanina Del Bello-Hass. Implementation of a physical activity monitoring system for the elderly people with built-in vital sign and fall detection. In *Information Technology : New Generations, 2009. ITNG'09. Sixth International Conference on*, pages 1226–1231. IEEE, 2009.
- [197] TLM Van Kasteren, Gwenn Englebienne, and Ben JA Kröse. An activity monitoring system for elderly care using generative and discriminative models. *Personal and ubiquitous computing*, 14(6) :489–498, 2010.
- [198] Samir Bouaziz, Michel Fan, Roger Reynaud, and Thierry Maurin. Multi-sensors and environment simulator for collision avoidance applications. In *Computer Architectures for Machine Perception, 2000. Proceedings. Fifth IEEE International Workshop on*, pages 127–130. IEEE, 2000.
- [199] Haider Mshali, Tayeb Lemlouma, and Damien Magoni. ehealth monitoring open data project. website, 2015.
- [200] Haider Hasan Mshali, Tayeb Lemlouma, and Damien Magoni. Context-aware adaptive framework for e-health monitoring. In *Data Science and Data Intensive Systems (DSDIS), 2015 IEEE International Conference on*, pages 276–283. IEEE, 2015.
- [201] Georg Dorffner. Neural networks for time series processing. In *Neural network world*. Citeseer, 1996.
- [202] Michael Falk, Frank Marohn, René Michel, Daniel Hofmann, Maria Macke, Bernward Tewes, and Peter Dinges. A first course on time series analysis : examples with sas. 2006.
- [203] Ajoy K Palit and Dobrivoje Popovic. Computational intelligence in time series forecasting, 2006.

- [204] Eric A Wan. Time series prediction by using a connectionist network with internal delay lines. In *SANTA FE INSTITUTE STUDIES IN THE SCIENCES OF COMPLEXITY-PROCEEDINGS VOLUME-*, volume 15, pages 195–195. Addison-Wesley publishing co, 1993.
- [205] Yu Hen Hu and Jeng-Neng Hwang. Handbook of neural network signal processing, 2002.
- [206] Tze Leung Lai and Samuel Po-Shing Wong. Stochastic neural networks with applications to nonlinear time series. *Journal of the American Statistical Association*, 96(455) :968–981, 2001.
- [207] M Sawsan, L Ahmad, and L Caroline. Behavioral pattern identification and prediction in intelligent environments. *J. Applied Soft Computing*, 12(4) :1812–1822, 2013.
- [208] Stefan Oniga and Jozsef Suto. Human activity recognition using neural networks. In *Control Conference (ICCC), 2014 15th International Carpathian*, pages 403–406. IEEE, 2014.
- [209] Stefan Oniga and Jozsef Suto. Activity recognition in adaptive assistive systems using artificial neural networks. *Elektronika ir Elektrotechnika*, 22(1) :68–72, 2016.
- [210] V Callaghan et al. Echo state network for occupancy prediction and pattern mining in intelligent environments. In *5th International Conference on Intelligent Environments, Barcelona*, page 474, 2009.
- [211] Mihail Crucianu. Algorithmes d'évolution pour les réseaux de neurones. *Rapport de recherche*, 187, 1997.
- [212] Lawrence J Fogel. Autonomous automata. *Industrial research*, 4(2) :14–19, 1962.
- [213] Lawrence J Fogel, Alvin J Owens, and Michael J Walsh. Artificial intelligence through simulated evolution. 1966.
- [214] John H Holland. Adaptation in natural and artificial systems. 1975. *Ann Arbor, MI : University of Michigan Press and*, 1992.
- [215] John R Koza. Hierarchical genetic algorithms operating on populations of computer programs. In *IJCAI*, pages 768–774, 1989.

- [216] John R Koza. Genetically breeding populations of computer programs to solve problems in artificial intelligence. In *Tools for Artificial Intelligence, 1990., Proceedings of the 2nd International IEEE Conference on*, pages 819–827. IEEE, 1990.
- [217] Rainer Storn and Kenneth Price. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11(4) :341–359, 1997.
- [218] Kenneth Price, Rainer M Storn, and Jouni A Lampinen. *Differential evolution : a practical approach to global optimization*. Springer Science & Business Media, 2006.
- [219] Darrell Whitley. A genetic algorithm tutorial. *Statistics and computing*, 4(2) :65–85, 1994.
- [220] M Javad Akhlaghinia, Ahmad Lotfi, Caroline Langensiepen, and Nasser Sherkat. Occupant behaviour prediction in ambient intelligence computing environment. *Journal of Uncertain Systems*, 2(2) :85–100, 2008.
- [221] Ray J Frank, Neil Davey, and Stephen P Hunt. Time series prediction and neural networks. *Journal of Intelligent & Robotic Systems*, 31(1) :91–103, 2001.
- [222] Romuald Boné, Mohammad Assaad, and Michael Crucianu. Boosting recurrent neural networks for time series prediction. In *Artificial neural nets and genetic algorithms*, pages 18–22. Springer, 2003.
- [223] FD Marques, L de F Souza, DC Rebolho, AS Caporali, EM Belo, and RL Ortolan. Application of time-delay neural and recurrent neural networks for the identification of a hingeless helicopter blade flapping and torsion motions. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 27(2) :97–103, 2005.
- [224] Jeffrey L Elman. Finding structure in time. *Cognitive science*, 14(2) :179–211, 1990.
- [225] Liang Yongchun. Application of elman neural network in short-term load forecasting. In *Artificial Intelligence and Computational Intelligence (AICI), 2010 International Conference on*, volume 2, pages 141–144. IEEE, 2010.
- [226] José Maria P Menezes and Guilherme A Barreto. Long-term time series prediction with the narx network : An empirical evaluation. *Neurocomputing*, 71(16) :3335–3343, 2008.

- [227] JPF Sum, W-K Kan, and Gilbert H Young. A note on the equivalence of narx and rnn. *Neural computing & applications*, 8(1) :33–39, 1999.
- [228] Sung-Hyuk Cha, Sungsoo Yoon, and Charles C Tappert. On binary similarity measures for handwritten character recognition. In *Document Analysis and Recognition, 2005. Proceedings. Eighth International Conference on*, pages 4–8. IEEE, 2005.
- [229] Holmes Finch. Comparison of distance measures in cluster analysis with dichotomous data. *Journal of Data Science*, 3(1) :85–100, 2005.
- [230] Guang-Bin Huang, Qin-Yu Zhu, and Chee-Kheong Siew. Extreme learning machine : theory and applications. *Neurocomputing*, 70(1) :489–501, 2006.
- [231] Gao Huang, Guang-Bin Huang, Shiji Song, and Keyou You. Trends in extreme learning machines : A review. *Neural Networks*, 61 :32–48, 2015.
- [232] João Carlos Alves Barata and Mahir Saleh Hussein. The moore–penrose pseudoinverse : A tutorial review of the theory. *Brazilian Journal of Physics*, 42(1-2) :146–165, 2012.
- [233] S Ortín, Miguel C Soriano, L Pesquera, Daniel Brunner, D San-Martín, Ingo Fischer, CR Mirasso, and JM Gutiérrez. A unified framework for reservoir computing and extreme learning machines based on a single time-delayed neuron. *Scientific reports*, 5, 2015.
- [234] Sharat C Prasad and Piyush Prasad. Deep recurrent neural networks for time series prediction. *arXiv preprint arXiv :1407.5949*, 2014.
- [235] Ahmad Lotfi, Caroline Langensiepen, Sawsan M Mahmoud, and Mohammad Javad Akhlaghinia. Smart homes for the elderly dementia sufferers : identification and prediction of abnormal behaviour. *Journal of ambient intelligence and humanized computing*, 3(3) :205–218, 2012.
- [236] A Patra, S Das, SN Mishra, and Manas Ranjan Senapati. An adaptive local linear optimized radial basis functional neural network model for financial time series prediction. *Neural Computing and Applications*, 28(1) :101–110, 2017.
- [237] Sandra Salmans. *Depression : questions you have-answers you need*. Peoples Medical Society, 1995.
- [238] American Psychiatric Association et al. *Diagnostic and statistical manual of mental disorders (DSM-5®)*. American Psychiatric Pub, 2013.

- [239] Lewis L Judd, Pamela J Schettler, William Coryell, Hagop S Akiskal, and Jess G Fiedorowicz. Overt irritability/anger in unipolar major depressive episodes : past and current characteristics and implications for long-term course. *JAMA psychiatry*, 70(11) :1171–1180, 2013.
- [240] Judith Swan and Persis Mary Hamilton. Depressive disorders. 2014.
- [241] T Scott Stroup, Joseph P McEvoy, Marvin S Swartz, Matthew J Byerly, Ira D Glick, Jose M Canive, Mark F McGee, George M Simpson, Michael C Stevens, and Jeffrey A Lieberman. The national institute of mental health clinical antipsychotic trials of intervention effectiveness (catie) project : schizophrenia trial design and protocol development. *Schizophrenia bulletin*, 29(1) :15, 2003.
- [242] Keren Ladin. Risk of late-life depression across 10 european union countries : deconstructing the education effect. *Journal of aging and health*, 20(6) :653–670, 2008.
- [243] Nilufar Mossaheb, Silvia Weissgram, Sonja Zehetmayer, Susanne Jungwirth, Michael Rainer, Karl-Heinz Tragl, and Peter Fischer. Late-onset depression in elderly subjects from the vienna transdanube aging (vita) study. *The Journal of clinical psychiatry*, 70(4) :500–508, 2009.
- [244] Filip Smit, Agnieska Ederveen, Pim Cuijpers, Dorly Deeg, and Aartjan Beekman. Opportunities for cost-effective prevention of late-life depression : an epidemiological approach. *Archives of General Psychiatry*, 63(3) :290–296, 2006.
- [245] Meryl A Butters, Jeffrey B Young, Oscar Lopez, Howard J Aizenstein, Benoit H Mulsant, Charles F Reynolds III, Steven T DeKosky, and James T Becker. Pathways linking late-life depression to persistent cognitive impairment and dementia. *Dialogues in clinical neuroscience*, 10(3) :345, 2008.
- [246] Amy Fiske, Julie Loebach Wetherell, and Margaret Gatz. Depression in older adults. *Annual review of clinical psychology*, 5 :363–389, 2009.
- [247] John Clabby and David Howarth. Managing chf and depression in an elderly patient : Being open to collaborative care. *Families, Systems, & Health*, 25(4) :457, 2007.
- [248] Bob Lingard and Sotiria Grek. The oecd, indicators and pisa : an exploration of events and theoretical perspectives. *ESRC/ESF Research Project on Fabricating Quality in Education Working paper*, 2, 2007.

- [249] Kaarin J Anstey, Chwee von Sanden, Kerry Sargent-Cox, and Mary A Luszcz. Prevalence and risk factors for depression in a longitudinal, population-based study including individuals in the community and residential care. *The American journal of geriatric psychiatry*, 15(6) :497–505, 2007.
- [250] Chun-Te Lee, Chih-Jung Yeh, Meng-Chih Lee, Hui-Sheng Lin, Vincent Chin-Hung Chen, Ming-Hong Hsieh, Chi-Hua Yen, and Te-Jen Lai. Leisure activity, mobility limitation and stress as modifiable risk factors for depressive symptoms in the elderly : results of a national longitudinal study. *Archives of gerontology and geriatrics*, 54(2) :e221–e229, 2012.
- [251] Hisayoshi Okamura, Akira Tsuda, Jumpei Yajima, Hamer Mark, Satoshi Horiuchi, Natsuki Toyoshima, and Toyojirou Matsuishi. Short sleeping time and psychobiological responses to acute stress. *International Journal of Psychophysiology*, 78(3) :209–214, 2010.
- [252] Peter Meerlo, Andrea Sgoifo, and Deborah Suchecki. Restricted and disrupted sleep : effects on autonomic function, neuroendocrine stress systems and stress responsivity. *Sleep medicine reviews*, 12(3) :197–210, 2008.
- [253] Julia Reichenberger, Peter Kuppens, Michael Liedlgruber, Frank H Wilhelm, Martin Tiefengrabner, Simon Ginzinger, and Jens Blechert. No haste, more taste : An emma study of the effects of stress, negative and positive emotions on eating behavior. *Biological psychology*, 2016.
- [254] Lisa M Groesz, Shannon McCoy, Jenna Carl, Laura Saslow, Judith Stewart, Nancy Adler, Barbara Laraia, and Elissa Epel. What is eating you? stress and the drive to eat. *Appetite*, 58(2) :717–721, 2012.
- [255] George Klir and Bo Yuan. *Fuzzy sets and fuzzy logic*, volume 4. Prentice hall New Jersey, 1995.
- [256] Jerry M Mendel. Fuzzy logic systems for engineering : a tutorial. *Proceedings of the IEEE*, 83(3) :345–377, 1995.