

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université 8 Mai 1945 – Guelma
Faculté des Sciences et de la Technologie
Département d'électronique et telecommunication

Réf:...../2020



MEMOIRE

Présenté pour l'obtention du **diplôme de MASTER Académique**

Domaine: Sciences et Technologie

Filière: Electronique

Spécialité: Instrumentation

Par: Khallef Houssam Eddine et Merouche Zakaria

Thème

*Reconnaissance de l'activité humaine en utilisant les
wearable sensors*

Soutenu publiquement, le 03/10 /2020 devant le jury composé de:

M. Abainia kheireddine
M. Boukaache abdour
M. Boudjahem djalil

Univ. Guelma
Univ. Guelma
Univ. Guelma

Président/Encadreur
Examineur
Examineur

Année Universitaire: 2019 /2020

Remerciements

Tout d'abord, je remercie le bon Dieu le tout puissant pour son aide et pour m'avoir guidé pour mener à bien ce travail.

Je tiens à remercier mon encadreur Mr. KHEIREDDINE ABANNA pour le suivi et les précieux conseils qu'il m'a fait part et pour la qualité de leur encadrement, patience, gentillesse et leur encouragement patient et bienveillant qui m'a permis de mener à bien ce travail.

Je tiens aussi à remercier les membres du jury d'avoir accepté d'évaluer le travail de recherche du présent mémoire, en espérant que leurs remarques, orientations et conseils me seront utiles pour la continuité de ma formation.

Je remercie tous ceux qui m'ont soutenu, qui m'ont supporté tout au long de ce travail.

En fin j'exprime mes vifs remerciements à ma famille et mes proches. Car ils n'ont cessé de me soutenir et de m'encourager pendant toute la période de ce travail.

Dédicace

Savoir que l'on sait ce que l'on sait, et savoir que l'on ne sait pas ce que l'on ne sait pas : voilà la véritable intelligence

Confucius.

Je ne sais comment exprimer ma gratitude à:

Mon père et ma mère qui m'ont toujours soutenu dans ma vie « Dieu les garde pour moi ».

*ma famille ; mes chers ce qui me donnent de l'amour et de la
solidarité.*

*À tous mes amis qui m'ont toujours encouragé et à qui je
souhaite plus de succès.*

À tous ce que j'aime.

HOUSSEM

Dédicaces

Je dédie ce modeste travail aux êtres lui me sont les plus chers :

*Mes parents qui m'ont accompagné tout au long de mes études
par leurs encouragements, soutiens,*

Et amour

Qu'ils trouvent toutes mes reconnaissances dans ce travail

*A mon frère et mes sœurs qui ont partagé avec moi tous
les moments difficiles lors de la réalisation de ce travail*

A l'âme de ma grand-mère A mon binôme Houssem

*A mes amis, mes proches, et à tous ceux qui me connaissent et
qui m'aiment*

Tables des matières

Remerciement

Dédicace

Résumé

INTRODUCTION GENERALE 1

Chapitre I Notion et conceptions

1.1. Introduction..... 3

1.2. Définition du capteur portable..... 3

1.3. Différents types de capteurs portables..... 4

1.3.1. Types selon le mode de fonctionnement..... 4

1.3.1.1. Capteur classique..... 4

1.3.1.2. Capteur intelligent 4

1.3.2. Types selon l'usage du capteur..... 5

1.3.2.1. Capteur implémenté à l'intérieur du corps 6

1.3.2.2. Capteur porte à l'extérieur 7

1.4. Différentes applications des capteurs portables..... 8

1.4.1. Domaine de fitness et sport..... 8

1.4.2. Différentes applications dans le domaine de la santé 10

1.4.2.1. Biocapteurs 11

1.4.3. Domaine militaire 11

1.4.4. Domaine de marketing 12

1.4.5. Domaine industriel et de robotique 13

1.4.5. Domaine des jeux vidéo et loisir..... 14

1.5. Différentes architectures de traitement de l'information 15

1.5.1. Traitement centralisé 15

1.5.2. Traitement décentralisé 15

1.6. Conclusion 16

Chapitre II Travaux effectués sur les capteurs portables

2.1 Introduction..... 18

2.2 Méthodes basées sur le traitement de signal 18

2.3 Méthodes basées sur machine learning 18

2.3.1 Méthodes supervisées..... 18

2.3.1.1. <i>K-Nearest Neighbors (K-NN)</i>	18
2.3.1.2. <i>Support Vector Machine (SVM)</i>	19
2.3.1.3. <i>Random Forests (RF)</i>	19
2.3.2 <i>Méthodes non supervisées</i>	20
2.3.2.1 <i>Modèles de Markov cachés (HMM)</i>	20
2.3.3 <i>méthode de clustering</i>	20
2.3.3.1 <i>k-Nearest Neighbors</i>	20
2.3.3.2. <i>K-Means</i> :.....	20
2.3.4 <i>Etude comparative</i>	21
2.4 <i>Méthodes basées sur deep learning</i>	21
2.4.1 <i>Réseaux de neurones profonds (DNN)</i>	21
2.4.2 <i>Réseaux de neurones convolutifs (CNN)</i>	22
2.4.3 <i>Réseaux de neurones récurrents (LSTM et BiLSTM)</i>	22
2.4.4. <i>Etudes comparatives</i>	23
2.5 <i>Travaux basé sur des algorithmes hybrides</i>	23
2.6 <i>Discussion</i>	24
2.7. <i>Conclusion</i>	25

Chapitre III Contribution

3.1. <i>Introduction</i>	27
3.2. <i>Réseaux de neurones convolutifs</i>	27
3.2.1. <i>Introduction</i>	27
3.2.2. <i>Le réseau neuronal</i>	27
3.2.2.1. <i>Filtre de convolution</i>	28
3.2.2.2. <i>Fonction d'activation</i>	29
3.2.2.3. <i>Filtre de pooling</i>	30
3.2.2.4. <i>Classification</i>	30
3.2.3. <i>Architecture CNN</i>	31
3.3. <i>Expérimentation et résultats</i>	33
3.3.1. <i>Base de données utilisée</i>	33
3.3.2. <i>Préparation de l'environnement du travail</i>	34
3.3.3. <i>Résultats et discussion</i>	35
3.3.3.1. <i>Exploration des données</i>	35
3.3.3.2. <i>Algorithmes et techniques</i>	36

<i>3.3.3.3. Prétraitement des données</i>	38
<i>3.3.3.4. Mise en œuvre et raffinement</i>	38
<i>3.3.3.5. Évaluation et validation du modèle</i>	40
<i>3.3.3.6. Justification et conclusion</i>	41
<i>3.6 Conclusion</i>	41
CONCLUSION GENERALE	43
<i>Bibliographie</i>	44

LISTE DES FIGURES

Figure 1.1. Différents modèles de wearable sensor	
Figure 1.2. Capteur classique (photodiode)	
Figure 1.3. Schéma d'un capteur intelligent.	
Figure 1.4. Capteur minuscule pour surveiller le corps de l'intérieur.....	
Figure 1.5. Puce ultra-fine inventé par des Japonais.....	
Figure 1.6. Vue d'ensemble des interactions des capteurs dans la maison intelligente.....	
Figure 1.7. Présentation générale du système de surveillance de la santé à distance	
Figure 1.8. Le développement des équipements VR.....	
Figure 3.1. Photo représente A. un neurone réel .B. un neurone artificiel.....	
Figure 3.2. Architecture du système proposé.....	
Figure 3.3. Le processus de filtre de convolution.	
Figure 3.4. La fonction Sigmoïde.	
Figure 3.5. Le processus de filtre de pooling.	
Figure.3.6. Schéma d'architecture du réseau CNN utilisé	
Figure 3.7. Human activity walking jogging.	
Figure 3.8. Le déséquilibre des classes.	
Figure 3.9. Les courbes de Scree Plot (%).	
Figure 3.10. La structure CNN utilisant la FA Softmax.	
Figure.3.11: Modèle SVC.....	
Figure.3.12: Comparaison entre les modèles (PCA103, SVC, CNN).	

Liste des Abbreviation

AI : Artificial Intelligence

ML : Machine learning

CNN : Convolutional Neural Network

RNN: Recurrent Neural Network

IoT : internet of thing

DNN : DEEP

INTRODUCTION GENERALE

Nous pensons généralement à la technologie comme quelque chose qui nous sépare de l'être humain, mais on se demande de penser à la technologie comme un moyen d'élargir notre humanité. Ce qui pourrait être possible si vous pouviez apprendre, des données que votre corps rayonne, comment tirer la meilleure partie de votre corps et votre esprit ? Que feriez-vous avec ce pouvoir ?

Grâce à la technologie, on utilise le matériel médical et des ordinateurs pour collecter et analyser nos activités. Nous portons les capteurs qui peuvent collecter et analyser ces activités en temps réel, ainsi regarder les données sur nos smartphones ou d'autre appareil.

La reconnaissance de l'activité humaine (HAR ou human activity recognition) joue un rôle important dans la vie quotidienne des gens à cause de sa robustesse à acquérir des connaissances approfondies sur l'activité humaine à partir d'entrées brutes de capteurs. Les applications HAR réussies comprennent l'analyse du comportement à domicile (Vepakomma et al., 2015), la vidéo surveillance (Qin et al., 2016), l'analyse de la marche (Hammerla et al., 2016) et la reconnaissance des gestes (Kim et Toomajian, 2016). Il existe principalement deux types de HAR: le HAR à base vidéo et le HAR à base de capteur (Cook et al., 2013), et sur ce dernier que nous conductons notre travail.

Chapitre I

Notion et conceptions

1.1. Introduction

L'objectif du présent chapitre est la présentation de différentes définitions, types et mode de fonctionnement et usage concernant les capteurs portable (wearable sensors), ainsi que les composants de ces capteurs et leurs utilités au niveau du corps humain.

1.2. Définition du capteur portable

En général, les capteurs sont définis comme des dispositifs capables de détecter et mesurer des types particuliers d'entrées (propriétés physiques et caractéristiques) de leur environnement, tout en offrant par conséquent une sortie qui peut être convertie en informations lisibles [1]. Les capteurs portables se réfèrent aux vêtements, accessoires ou chaussures fabriqués avec des textiles ou des matériaux dotés de capteurs, ou activés par des composants électroniques intégrés ou éléments de détection non électroniques [1].

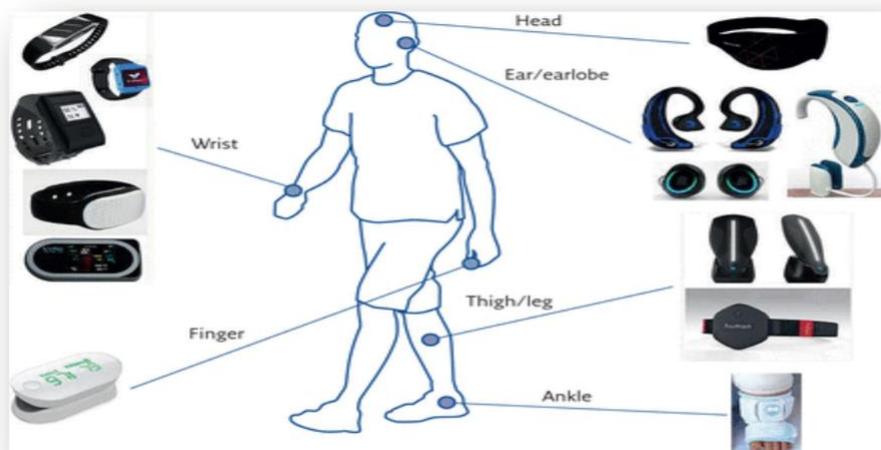


Figure 1.1. Différents modèles de capteurs portables.[2]

Ces appareils sont capables de détecter et de réagir dans un préprogrammée à une large gamme de stimulus. A la fois du porteur ou de l'environnement, afin de fournir une gamme de commentaires exploitables et peut être considéré comme une sous-catégorie de la technologie portable [1]. On trouve une vaste gamme de capteurs portables tels que les smartphones, ceintures, montres, patches adhésifs et électronique attachée aux vêtements ou textiles.[1]

1.3. Différents types de capteurs portables

Les appareils électroniques portables sont des petits appareils portés sur la tête, le cou, le bras, le torse ou les pieds. Il peuvent être classifié selon plusieurs critères, mais nous allons les catégoriser selon le mode de fonctionnement et l'usage.

1.3.1. Types selon le mode de fonctionnement

Nous pouvant identifier deux types selon le mode de fonctionnement pour les capteurs portables, des capteurs qui n'utilise pas un processeur, appeler capteurs classique, et il y a des capteurs intelligent qui utilise un processeur de mouvement numérique intégré.

1.3.1.1. Capteur classique

Un capteur de base est un capteur qui n'inclut pas un processeur de mouvement numérique intégré ou DMP. Celui-ci ne contient généralement que le capteur lui-même, tandis que tous les travaux de traitement et de calcul sont effectués par le fabricant. En utilisant un capteur de base, un profite d'un prix plus bas avec le composant et permet un contrôle total du processus de conception [3].



Figure 1.2. Capteur classique (photodiode). [4]

1.3.1.2. Capteur intelligent

Un capteur intelligent est un capteur qui contient un processeur de mouvement numérique (DMP) intégré. L'avantage de ceci est qu'il peut prendre des entrées de l'environnement physique et utilise des ressources de calcul intégrées pour exécuter des fonctions prédéfinies lors de la détection d'une entrée spécifique, puis traiter les données avant de les transmettre. Comme on l'imagine, le traitement des données capturées par le capteur est effectué sur le circuit intégré du capteur avec le DMP intégré. Les données traitées sont ensuite partagées avec le reste de l'appareil via une interface série [3].

Les capteurs intelligents permettent une collecte plus précise et automatisée des données environnementales avec moins de bruit parmi les informations enregistrées. Ces

dispositifs sont utilisés pour les mécanismes de surveillance et de contrôle dans une grande variété d'environnements, y compris les réseaux intelligents, la reconnaissance du champ de bataille, l'exploration et une variété d'applications scientifiques.

Le capteur intelligent est également une partie cruciale et intégrante de l'Internet des objets (IoT), l'environnement de plus en plus populaire dans lequel presque tout ce qui est imaginable peut recevoir un identifiant unique (UID) et la capacité de transmettre des données sur Internet ou un réseau similaire. Les capteurs intelligents sont notamment utilisés comme composants d'un réseau sans fil de capteurs et d'actionneurs (WSAN) dont les nœuds peuvent se compter par milliers, chacun d'eux étant connecté à un ou plusieurs autres capteurs et concentrateurs ainsi qu'à des actionneurs individuels.

Un capteur intelligent peut également inclure un certain nombre d'autres composants en plus du capteur principal. Ces composants peuvent inclure des transducteurs, des amplificateurs, une commande d'excitation, des filtres analogiques et une compensation (Gain). Un capteur intelligent intègre également des éléments définis par logiciel qui exécutent des fonctions telles que la conversion de données, le traitement numérique et la communication avec des périphériques externes.

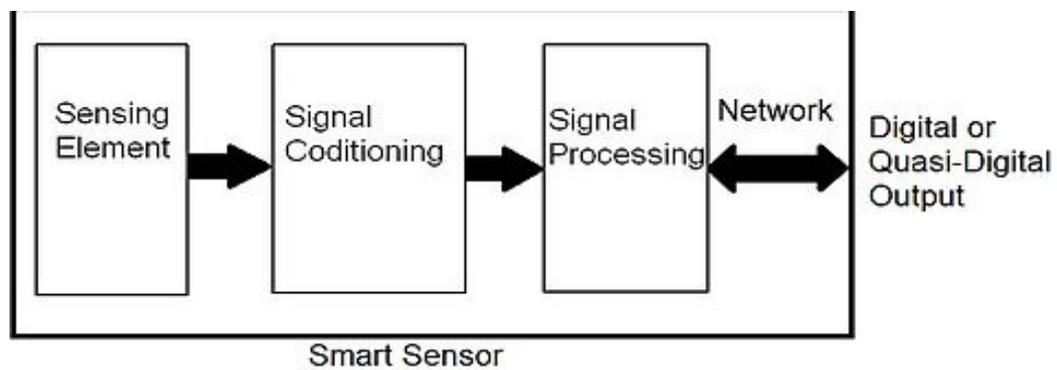


Figure 1.3. Schéma d'un capteur intelligent.[4]

1.3.2. Types selon l'usage du capteur

Selon l'usage du capteur, on trouve deux types principaux, il y a des capteurs implantés à l'intérieur du corps, soit minuscule ou ultra-fine. Autrement, il existe des capteurs portés à l'extérieur, sur le corps ou fait partie d'un système de Smart Home

1.3.2.1. Capteur implémenté à l'intérieur du corps

On peut identifier deux types de capteurs implémenté à l'intérieur du corps:

A. Un capteur minuscule

Des chercheurs de l'université Berkeley, en Californie, ont mis au point le premier capteur sans-fil, de la taille d'un grain de sable et implantable dans le corps. Il permet d'enregistrer et de transmettre l'activité des neurones en temps réel grâce aux ultrasons (5). L'invention a fait l'objet d'une publication au mois d'août (année) dans le journal scientifique *Neuron*. Selon les auteurs, le capteur testé sur des rats pourrait, à terme, offrir de nombreuses applications en santé humaine, notamment dans le traitement de l'épilepsie.[5]

L'échographie (signal neuronal) est envoyé à la poussière neurale, qui renvoie un signal avec des données sur l'activité électrique du nerf. Ces données analysées, révélant différents schémas électriques, qui dictent les mouvements correspondants pour une prothèse. Pour être implantés dans le cerveau, les ingénieurs ont conçu une poussière neuronale plus récente et plus petite [5]. Cette dernière utilise des matériaux qui pourraient durer toute une vie. La poussière neurale pourrait être utilisée pour d'autres applications de santé.

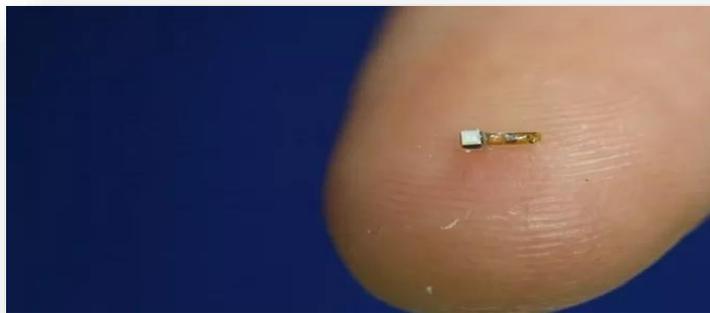


Figure 1.4. Capteur minuscule pour surveiller le corps de l'intérieur [5]

B. Une puce ultra-fine et flexible

Une équipe de chercheurs japonais a annoncé d'avoir conçu une puce électronique ultra-fine, légère et souple qui pourrait être posée sur la peau ou implantée dans le corps humain pour suivre les conditions physiques [6]. Ce circuit intégré se présente sous la forme d'un film ultra-

mince. Il a la particularité de continuer de fonctionner même après avoir été froissé ou étiré. Selon les professeurs de l'Université de Tokyo à l'origine de ce capteur, il pourrait être utilisé pour surveiller toutes sortes de données, telles que la température corporelle et la pression artérielle ainsi que les mouvements des muscles ou les battements du cœur [6].

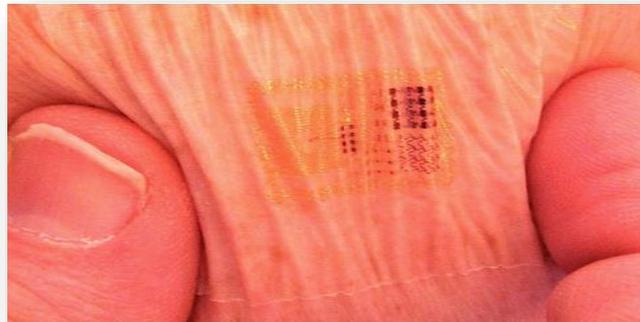


Figure 1.5. Puce ultra-fine inventé par des Japonais [6]

On pourrait aussi imaginer un tel capteur servant de zone de réception tactile pour permettre à des personnes d'activer un dispositif à partir de leur bouche, de leurs yeux ou de toute autre partie valide du corps afin de pallier un handicap physique. "Cette puce peut être fixée à toute sorte de surface et ne limite pas le mouvement de la personne qui la porte" [6].

1.3.2.2. Capteur porte à l'extérieur

On identifier deux types de capteurs implémenté à l'intérieur du corps:

A. Smart Home

Un vaste champ de recherche au sein de la communauté implique l'exploration du potentiel créé par le déploiement de capteurs intelligents, dans tout un appartement, pour l'analyse de vie quotidienne des habitants de la maison intelligente. Un autre sujet est la réalisation de divers types de capteurs sur le corps pour détecter des caractéristiques telles que le mouvement (activité), les données de biométrie (surveillance), localisation, etc. [7].

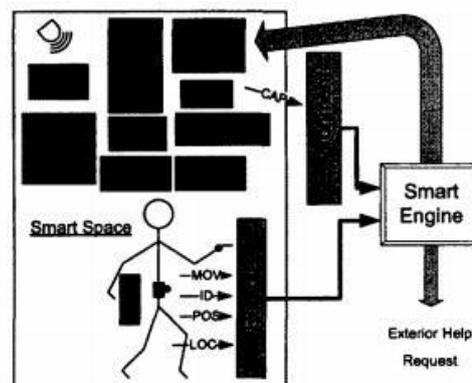


Figure 1.6. Vue d'ensemble des interactions des capteurs dans la maison intelligente [7]

B. Capteurs porté sur les vêtements et smart-watch

La montre connectée, aussi appelé «montre intelligente »ou en anglais smartwatch est une montre électronique qui intègre des fonctions de communication élaborées : réception-émission d'appels téléphoniques, notifications provenant d'un téléphone mobile, envoi et réception de messages, Ces instruments sont la plupart du temps équipés d'un écran tactile qui permet de personnaliser l'affichage en changeant le cadran ; en général, ils font office de compagnon pour les smartphones auxquels ils sont associé par liaison Bluetooth.[8]

Les chercheurs du MIT ont développé un moyen d'intégrer des capteurs électroniques dans les tissus extensibles, leur permettant de créer des chemises ou d'autres vêtements qui pourraient être utilisé pour surveiller les signes vitaux tels que la température, la respiration et la fréquence cardiaque.[9]

Les capteurs électroniques sont constitué de longues bandes flexibles qui sont enveloppées d'époxy et ensuite tissées en canaux étroits dans le tissu. Ces canaux ont de petites ouvertures qui permettent aux capteurs d'être exposés à la peau. Pour cette étude, les chercheurs ont conçu un prototype de chemise avec 30 capteurs de température et un accéléromètre qui peuvent mesurer le mouvement, la fréquence cardiaque et la fréquence respiratoire du porteur. Le vêtement peut ensuite transmettre ces données sans fil à un smartphone.[9]

1.4. Différentes applications des capteurs portables

1.4.1. Domaine de fitness et sport

Une variété de technologies de capteurs portables sont développées par un nombre toujours croissant d'entreprises et reçoivent une attention considérable de la communauté sportive. systématiquement installé sous le maillot de chaque joueur entre les omoplates.

Ces microcapteurs portables permettent d'enregistrer et de signaler les mouvements des joueurs en direct pendant le match, fournissant aux entraîneurs d'équipe des « mesures » de performance clés telles que la distance totale parcourue par un joueur en match, le nombre d'accélérations et de décélérations, et «l'impact» pendant toute contact ou tacle donné. On prétend que ces mesures de performance permettent aux entraîneurs d'équipe de suivre et de planifier la stratégie de jeux du match. L'évolution des règles et réglementations sportives a facilité l'utilisation de ces appareils. Par exemple, la règle de compétition 144 d de l'Association internationale des fédérations d'athlétisme (2018 à 2019) sur l'assistance autorise « des moniteurs de fréquence cardiaque ou de distance de vitesse ou des capteurs de foulée ou des dispositifs similaires transportés ou portés personnellement par les athlètes pendant un

événement, à condition que ce dispositif ne peut pas être utilisé pour communiquer avec une autre personne ». De telles règles encouragent l'utilisation de wearables dans le sport d'élite et encouragent les entreprises à développer ces outils pour faciliter les performances de haut niveau.

La technologie portable est apparue comme la principale tendance en matière de fitness dans une enquête mondiale menée récemment par l'American College of Sports Medicine (ACSM), prédisant des ventes de 1,5 à 2,5 milliards de dollars américains pour certains appareils et incitant à la déclaration qu'« il est imprévisible dans quelle mesure la technologie portable va avancer au cours de la prochaine décennie. Les avancées en matière d'innovations portables sont présentées par un nombre croissant d'entreprises lors de conférences internationales sur les technologies portables (par exemple, Medical Wearables 2018). La principale allégation de marketing étant des appareils portables à faible coût et faciles à utiliser qui permettent une surveillance non invasive ou minimalement invasive d'une variété de paramètres physiologiques et biomécaniques, qui dans le passé n'étaient tout simplement pas possibles, ou uniquement mesurables avec des méthodes sophistiquées, chronophages et procédures de laboratoire coûteuses. Par exemple, des lentilles de contact peuvent être utilisées pour surveiller en continu les niveaux de glucose, des chaussures de football peuvent améliorer la précision des coups de pied et des tissus peuvent être disponibles dans le commerce pour surveiller les signes vitaux tels que la fréquence respiratoire.

Malgré le potentiel révolutionnaire des wearables, il existe des inquiétudes fondées concernant l'industrie des wearables. Les principales critiques concernent le manque de preuves des effets bénéfiques de l'analyse d'un paramètre spécifique dans un contexte ou un isolement donné, la qualité du matériel et des données fournies, la surcharge d'informations, la sécurité des données et les allégations marketing exagérées. Pour ces raisons, les athlètes, les organismes de réglementation et les parties prenantes concernées deviennent de plus en plus sceptiques à l'égard des appareils portables. La réputation douteuse de certains appareils portables a un effet néfaste sur la réputation des appareils basés sur des preuves. Les allégations marketing agressives et exagérées et le lancement précipité de produits portables sans, ou seulement, des études de validation et de fiabilité internes, et aucune évaluation externe, sont très problématiques. Les dispositifs portables qui utilisent des données biologiques à des fins de santé devraient être soumis à une évaluation rigoureuse avant d'être lancés sur le marché, à l'instar du processus utilisé par les industries pharmaceutiques pour tester leurs produits. Soutenir les affirmations marketing des développeurs de technologies portables avec des

preuves scientifiques indépendantes aurait un impact positif sur le marché du sport, du fitness et de la santé. Ne pas le faire devrait être passible de sanctions financières et autres, comme cela s'est produit dans le passé. La technologie portable qui s'appuie sur une science de qualité sera plus rentable et durable à long terme, et les entreprises impliquées auront un retour sur investissement beaucoup plus élevé. [37]

1.4.2. Différentes applications dans le domaine de la santé

Les systèmes IoT (Internet of Things) appliqués aux soins de santé améliorent la technologie existante et la pratique générale du médicament. Ils augmentent à la fois l'exactitude et la taille des données médicales grâce à la collecte de données diverses du monde réel, ainsi ils améliorent également la précision de la prestation des soins médicaux grâce à l'intégration sophistiquée du système de santé [10].

Une grande partie de la recherche médicale actuelle repose sur des ressources dépourvues d'informations critiques du monde réel. Il utilise des environnements contrôlés, des bénévoles et essentiellement des restes pour un examen médical. IoT ouvre la porte à une mine d'informations précieuses grâce à des données de terrain en temps réel, à des analyses et essai [10].

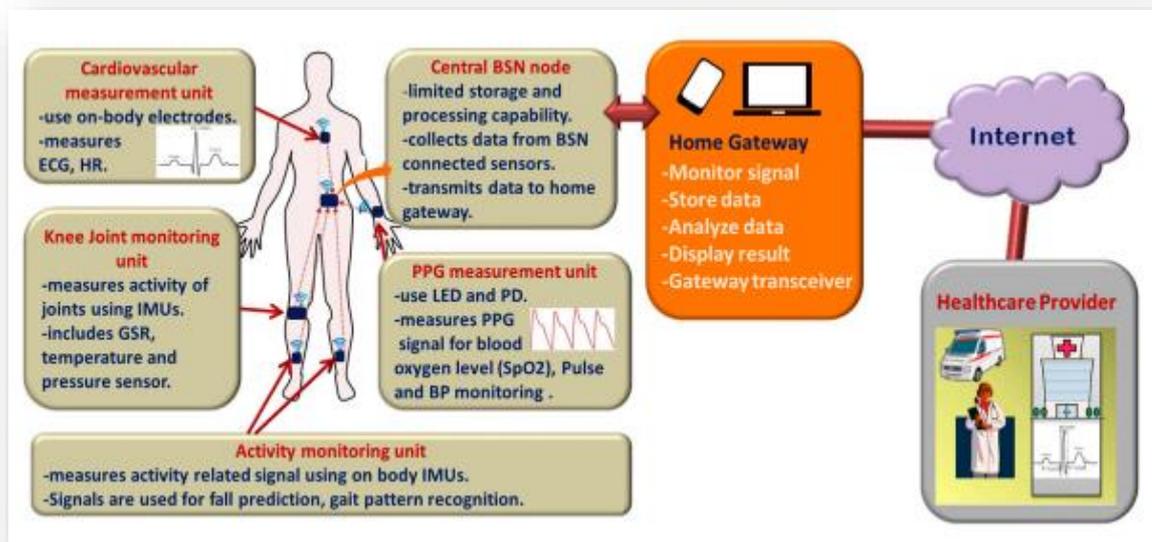


Figure 1.7. Présentation générale du système de surveillance de la santé à distance [11]

La température corporelle est l'un des signaux vitaux, qui est étroitement lié à divers types de maladies (e.g., coup de chaleur, insuffisance cardiaque congestive, infection, fièvre), à l'état physiologique et à l'état cognitif du corps humain. Elle doit être surveillée en temps réel avec une grande précision grâce aux capteurs portés [12].

1.4.2.1. Biocapteurs

Les biocapteurs sont des dispositifs médicaux portables en plein essor qui sont radicalement différents des trackers de poignet et des smartwatches. Le biocapteur portable de Philips est un patch auto-adhésif qui permet aux patients de se déplacer tout en collectant des données sur leurs mouvements, leur fréquence cardiaque, leur fréquence respiratoire et leur température. [13]

1.4.3. Domaine militaire

Des capteurs physiologiques portables peuvent permettre aux chefs de l'armée de surveiller l'état et le bien-être des soldats. L'objectif de ce projet de recherche était d'étudier les facteurs susceptibles d'avoir une incidence sur l'adoption de la technologie des capteurs portables et la conformité des soldats, notamment : le confort et la facilité d'utilisation de l'appareil; interférence de tâche; et les problèmes de sécurité et de confidentialité concernant les données. L'équipe de recherche était composée d'un membre du corps professoral de l'USMA affilié à l'Army Cyber Institute, le Dr Aryn Pyke, et de deux chercheurs cadets, Sydney Whitham et Trey Martin (maintenant 2LT), qui étaient des majors en psychologie de l'ingénierie du département des sciences du comportement et du leadership de West Point. Cette équipe de recherche a interrogé 226 futurs officiers de l'armée qui avaient utilisé des capteurs portables. Les expériences comprenaient quatre formats de capteurs : au poignet (54 %) ; sur la chaussure (37 %) ; et sur sangle de poitrine ou soutien-gorge de sport (9%). Les capteurs montés sur chaussures ont été les mieux notés en termes de confort, mais ne fournissent pas de données physiologiques clés (par exemple, la fréquence cardiaque et la température de la peau). Les capteurs de poignet et de poitrine/soutien-gorge fournissent de telles données, mais les capteurs de poignet ont reçu des notes de confort plus élevées (81/100 contre 57/100). Les capteurs de poignet ont également été jugés relativement faibles pour les interférences avec les tâches quotidiennes, les sports, l'entraînement militaire et le sommeil (note moyenne: 18/100). Cela dit, les utilisateurs ont évalué les interférences probables avec le combat à 32/100 et la volonté de porter un capteur de poignet au combat à seulement 61/100. L'une des préoccupations concernant l'utilisation des capteurs était liée à l'accès aux données et à la sécurité. Les personnes interrogées ont évalué à environ 60/100 leur niveau d'aisance vis-à-vis de la direction accédant à leurs données pour surveiller leur sécurité, diviser le travail et éclairer les évaluations de performance. Le confort avec des pairs ayant accès aux données a été évalué beaucoup plus bas, à 35/100, et le confort avec des adversaires pouvant accéder aux données a été évalué à 9/100. Si l'on pouvait garantir que les données sont protégées des

adversaires et que l'accès des pairs peut être restreint si désiré, cela pourrait améliorer l'attitude des soldats envers l'adoption de capteurs portables.

Un autre facteur qui faciliterait l'adoption et la conformité des capteurs est de fournir aux soldats eux-mêmes l'accès aux données qui les intéressent. Les types de données qui ont été jugés les plus intéressants par les répondants étaient les mesures du sommeil, le bien-être général et le niveau d'hydratation (note moyenne: 73/100). Celles-ci étaient suivies de mesures de la fatigue physique et mentale ou du stress et du rythme cardiaque (moyenne : 67/100). Il est intéressant de noter que la détection de l'exposition aux toxines a reçu une note inférieure aux mesures ci-dessus (57/100), peut-être parce qu'il était supposé qu'il s'agissait d'un événement rare. La température de la peau était la métrique la moins intéressante des options répertoriées (47/100). Quelques répondants ont également suggéré d'autres mesures qui pourraient intéresser les soldats, notamment : les calories brûlées, la composition corporelle, les niveaux d'oxygène et le VO₂ max. Ainsi, en plus de fournir des assurances sur la confidentialité et la sécurité des données, fournir aux soldats - plutôt qu'aux seuls dirigeants - un accès direct à leurs métriques de données d'intérêt devrait faciliter l'adoption et la conformité. Comment et quand ces informations sont mises à la disposition des soldats font l'objet de recherches en cours. Certains capteurs de poignet n'ont pas d'affichage des données, ce qui les rend probablement plus robustes sur le terrain et empêche le soldat d'être inutilement distrait par ces données. Cependant, certaines de ces données pourraient être précieuses pour le soldat en temps réel, donc l'accès à ces données sur demande - ou dans le cas où un seuil est déclenché - serait vraisemblablement utile. Cela peut être assuré par un affichage sur le poignet ou un autre appareil (par exemple, un téléphone portable ou un affichage tête haute). L'équipe de recherche souhaite remercier et exprimer notre appréciation pour les conseils et les informations fournis par Elizabeth Halford (soutien du contrat d'ingénierie des systèmes mondiaux pour CCDC), Bill Tharion (USAREIM), et Ed Argenta et le Dr Christian Whitchurch (DTRA). [36]

1.4.4. Domaine de marketing

Les capteurs portables (wearables) IoT ont été intensément développés entre 2006 et 2013, mais leur véritable essor s'est produit après 2014, lorsque la première Apple Watch est apparue. Les chercheurs [63] ont remarqué que, ces derniers temps, les appareils portables combinent plusieurs tendances technologiques clés, parmi lesquelles nous mentionnons « un canal de communication mobile, l'Internet des objets (IoT), la réalité augmentée (AR) et le Big Data ». Dans cette veine, dans une étude récente [64] a fait une analyse bibliométrique

complexe traitant des applications du analyse de données volumineuses dans les entreprises, l'accent étant mis sur la nécessité pour les entreprises de prendre des décisions stratégiques afin d'ajouter de la valeur à leur activité. et augmenter les avantages de l'analyse des mégadonnées. Selon leurs recherches, des stratégies d'entreprise supérieures peuvent être développées en matière de marketing, les auteurs citant plusieurs études qui étaient en faveur de ce résultat.

Ces études comprenaient celle d'Erevelles, Fukawa et Swayne (2016), selon laquelle « le déploiement des ressources de l'entreprise dans l'analyse des données des consommateurs développe stratégies marketing » [65], ainsi que les recherches de Xu, Frankwick et Ramirez 2016, selon lesquelles les mégadonnées aident à « réussir les nouveaux produits » [66]. Les wearables IoT représentent de petits ordinateurs qui ont de multiples fonctions [67]. Dans une autre définition, les wearables IoT représentent « des appareils intelligents qui peuvent être portés comme accessoires externes, intégrés dans des vêtements et des vêtements, implantés dans le corps, ou même collés ou tatoués sur la peau.

Ces appareils sont capables de se connecter à Internet afin de collecter, d'envoyer des données et de recevoir les informations pouvant être utilisées pour une prise de décision intelligente. Ces dispositifs portables deviennent une partie de plus en plus importante de la technologie IoT et leur développement passe de simples accessoires à des applications plus spécialisées et pratiques » [68]. Des études [69] ont également souligné que les caractéristiques les plus importantes des wearables résident en elles : non restrictives (elles intègrent la technologie mains libres, qui permet aux utilisateurs d'effectuer plusieurs activités en même temps) ; contrôlable (l'utilisateur a la possibilité de le contrôler toujours); attentif (technologies ayant différents capteurs et modes de fonctionnement) ; observable (donner la possibilité d'utiliser des alertes, des rappels ou des messages afin d'attirer l'intérêt de l'utilisateur); communicatif (offrant la possibilité d'échanger des informations via diverses options telles que Bluetooth et les réseaux sans fil) et démonopolisant (il y a plusieurs actions que l'utilisateur peut faire en même temps, une attention minimale étant nécessaire pour ces activités). [38]

1.4.5. Domaine industriel et de robotique

Avec les progrès rapides de la mécanique et de la robotique, les technologies de détection et de robotique portables ont été largement étudiées pour diverses applications, notamment les robots exosquelettes pour la rééducation, les robots exosquelettes pour soutenir la vie quotidienne des personnes âgées, et les dispositifs médicaux portables pour surveiller les signes vitaux, etc.

Cependant, certains défis technologiques clés doivent être relevés pour obtenir de meilleurs résultats de recherche, des démonstrateurs d'applications plus efficaces et une

commercialisation réaliste. La Conférence internationale sur les capteurs et robots portables (ICWSR 2015) [39] a réuni des universitaires, des chercheurs, des ingénieurs et des étudiants du monde entier pour se concentrer sur l'état de l'art de la technologie et pour en discuter et pour présenter les derniers résultats sur les différents aspects de capteurs portables et robots.

Quelques exemples d'utilisation de capteurs portables sont le dispositif d'évaluation de la fonction de la main de la conception du gant E basé sur la fusion de la vision et du toucher (Jing Guo et al. [39]), il y a aussi la mesure de la force de contact à trois axes d'un Les réseaux de capteurs tactiles flexibles pour les applications de saisie manuelle (Yancheng Wang et al. [39]) ont été discutés dans l'ICWSR 2015.

1.4.5. Domaine des jeux vidéo et loisir

En ce qui concerne les jeux, les capteurs portables se trouvent principalement dans les équipements VR, car le développement technologique des appareils portables a fortement contribué à l'avancement de la réalité virtuelle. La figure ci-dessous montre le développement des équipements VR :

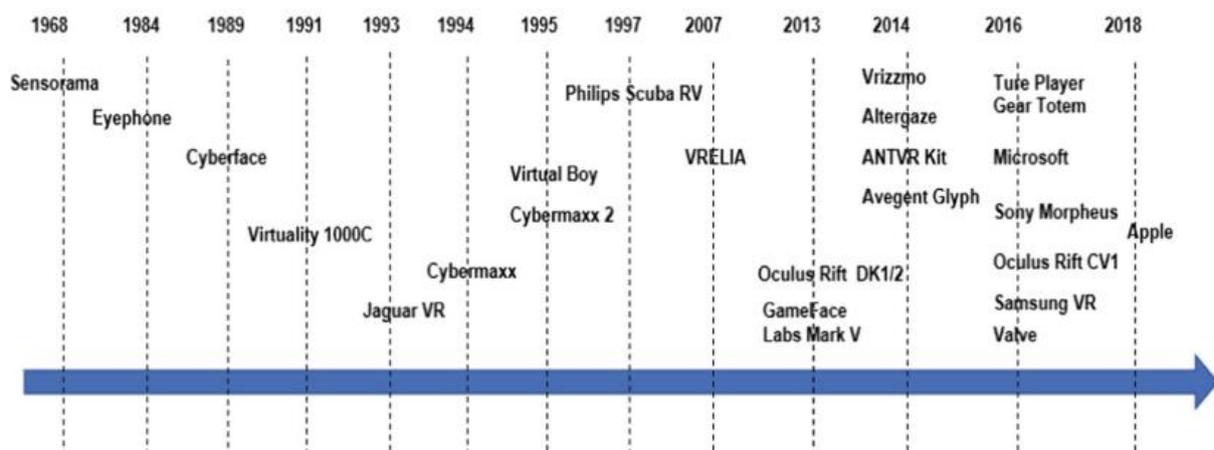


Figure 1.8: Le développement des équipements VR [40]

Il existe plusieurs capteurs utilisés en VR, chacun a un objectif, par exemple : pour assurer la sécurité du joueur, l'équipement aurait des capteurs de fréquence cardiaque, des capteurs de température, des capteurs de respiration, un équipement de capture de mouvement portable, un capteur d'inclinaison, etc. d'autres capteurs à utiliser pour permettre aux joueurs d'interagir les uns avec les autres tout en jouant en multijoueur comme des gants numériques, un capteur sonore, un équipement à retour de force, etc. Et enfin, il existe des capteurs utilisés pour estimer la taille et la stature du joueur à afficher dans le jeu, nous trouverions donc des capteurs physiologiques employés.

Donc, au final, la VR fournirait une perspective avancée et une sensation réaliste au jeu

lui-même, et permettrait également aux joueurs de communiquer et d'interagir beaucoup mieux par rapport aux moyens classiques, ce qui bien sûr ne serait pas possible sans l'utilisation de capteurs portables.

1.5. Différentes architectures de traitement de l'information

Il existe deux types d'architectures de traitement des informations fournis par un capteur portable, le traitement centralisé et décentralisé. Chaque architecture a ses avantages et inconvénients, nous allons les discuter si dessous.

1.5.1. Traitement centralisé

Un système centralisé c'est un système où tout le monde dépend d'une même autorité, un serveur à priori dans le cas informatique. Bien qu'un système centralisé soit beaucoup plus simple à faire sur le plan technique (facile de trouver des gens ou des informations quand ils sont tous au même endroit), il peut avoir ses propres inconvénients [15]. Un inconvénient majeur réside dans la lourde charge, où il est plus difficile d'absorber des données quand il n'y a qu'un centre de traitement, les tuyaux peuvent rapidement se trouver trop petits, etc. [15].

Avantages:

- La facilité d'accéder aux informations.
- Faible coût de maintenance comme il y a un seule serveur.

Inconvénients:

- Le système peut être encombré s'il y a beaucoup d'utilisateurs.

1.5.2. Traitement décentralisé

Le mot «dé-centralisé» veut dire qui n'a pas de centre, ni plus ni moins. L'idée pour un système de communication, c'est que toute entité (individu, association, organisation, etc) puisse être une partie d'un réseau qui n'a pas d'autorité principale, et que ces autorités puissent parler entre elles [15].

On essaye ainsi d'éviter les problèmes de la centralisation, mais on se retrouve avec tout un tas de nouveaux problèmes, techniques pour la plupart: il est beaucoup plus difficile de retrouver des données ou des entités en plusieurs endroits, et ça nécessite plus de matériel [15]. Par contre, le grand avantage de ce traitement est la rapidité du calcul, car chaque entité fait le calcul chez elle et communique seulement le résultat aux autres.

Avantages:

- Le système est plus efficace avec les charges lourds, comme chaque unité fait sa propre traitement.
- La vitesse de traitement des données très haute.

Inconvénients:

- Haute coût de maintenance et productions.
- Ce système est plus compliqué est difficile a utilisé quand comparé par un avec un traitement centralisé.

1.6. Conclusion

Dans ce chapitre on a présenté les notions importantes qui sont en relation avec Les capteurs portable (définition, Architectures...etc). Aussi qu'une vision générale sur Les domaines d'utilisation, en présentant leurs avantages dans chaque domaine. Finalement on a discuté les différents architectures de traitement des informations, avec les avantages et les inconvénients de chaque architecture. Alors nous allons discuter les travaux effectuer sur les capteurs portables dans le deuxième chapitre.

Chapitre II

Travaux effectués sur les capteurs portables

2.1 Introduction

Dans ce chapitre, nous exposons quelques travaux scientifiques effectués sur la reconnaissance de l'activité humaine en utilisant les wearables sensors. En particulier, les travaux sont organisés par des catégories telles que des méthodes basées sur le traitement du signal, des méthodes basées sur l'apprentissage automatique (machine learning) et des méthodes basées sur l'apprentissage profond (deep learning). En outre, nous présentons une petite comparaison de quelques algorithmes sur différentes bases de données.

2.2 Méthodes basées sur le traitement de signal

L'algorithme DTW (Dynamic Time Warping) a été appliqué à la reconnaissance de gestes après avoir fait ses preuves en matière de reconnaissance vocale dynamique. En 2013, Boukir et Cheneviere (2003) ont présenté un prototype complet et opérationnel intégrant la compression et la reconnaissance de gestes dansés issus d'un ballet contemporain, où ils l'ont fait à travers un système de capteur. On a trouvé que cette méthode est efficace lorsque le nombre de phénomènes à reconnaître est faible (les variations temporelles en rythme et durée sont prises en compte). D'autre part le principal problème de ces techniques reste la prise en compte du temps, où ce dernier est vu comme un mécanisme externe [16].

2.3 Méthodes basées sur machine learning

2.3.1 Méthodes supervisées

2.3.1.1. K-Nearest Neighbors (K-NN)

Le principe de cet algorithme est assez simple, en gros, l'exemple en main est classé en fonction de la classe de ses voisins les plus proches, il est généralement utile de prendre en compte plusieurs voisins. Étant donné que le processus de classification nécessite le chargement des exemples dans la mémoire, il est parfois appelé classification basée sur la mémoire. [43]

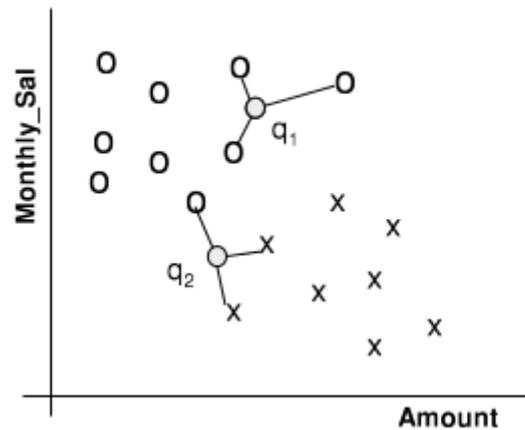


Figure. 2.1: Classification K-NN. [43]

2.3.1.2. Support Vector Machine (SVM)

En 2012, le problème de reconnaissance d'activité humaine a été déclaré comme résolu précédemment par Bravo et Hervéas (2012), et ceci grâce à la précision obtenue (89.3%). La base de données utilisée regroupe plusieurs activités humaines (six activités) faites par 30 volontaires ayant une tranche d'âge variant de 19 à 48 ans, où chaque candidat portait un smartphone sur la hanche. Les auteurs ont proposé une classification basée sur SVM multi-classes utilisant des paramètres entiers [18].

Huynh et Schiele ont combiné l'approche SVM et des espaces propres multiples afin d'améliorer le classifieur Bayes naïf standard avec un petit nombre de données d'apprentissage [18].

Krause et coll. (2005) ont examiné la reconnaissance de huit activités courantes utilisant le SVM, d'où ils ont observé une meilleure performance des fonctionnalités du domaine fréquentiel par rapport aux fonctionnalités du domaine temporel [18].

Doukas et al. (2005), ont appliqué des techniques SVM pour discriminer entre les chutes et les autres activités. Un microphone et un accéléromètre triaxial ont été utilisés pour identifier les chutes et deux activités (i.e. marcher et courir). Les taux de reconnaissance variaient entre 84% et 96% dépendant de la configuration de l'algorithme [18].

2.3.1.3. Random Forests (RF)

Bedogni et al. (2012) ont proposé une méthodologie de classification pour reconnaître, à l'aide de données d'accélération, différentes classes de mouvements, comme conduire une voiture, être dans un train et marcher, en comparant différentes techniques d'apprentissage

automatique (Random Forests, SVM et Naive Bayes). Les auteurs ont montré que l'algorithme Random Forest fournit la précision moyenne la plus élevée surpassant les SVM et les Naive Bayes (Bedogni et al., 2012) [19].

2.3.2 Méthodes non supervisées

2.3.2.1 Modèles de Markov cachés (HMM)

La modélisation de Markov peut être une arme importante dans notre arsenal de méthodes de calcul pour la classification de l'activité physique humaine. Et c'est ce qui le prouve Mannini et Sabatini (2010), en analysant un jeu de données d'accéléromètre des séries chronologiques. Le jeu de données est échantillonné à 76,25 Hz, et acquis à partir de cinq accéléromètres bi-axiaux, situé au niveau de la hanche, poignet, bras, cheville et cuisse. Le protocole d'origine était basé sur le test de 20 candidats, qui ont été invités à effectuer 20 Activités, Dans cet article, 13 candidats ont été sélectionnés au hasard pour une analyse plus approfondie, afin de faciliter le travail de développement, Les résultats étaient très bons (99.1% _ 92.2%) [20].

2.3.3 méthode de clustering

2.3.3.1 k-Nearest Neighbors

k-Nearest Neighbours (k-NN) est une technique de classification supervisée qui peut être considérée comme une méthode de classification directe, car elle ne nécessite pas de processus d'apprentissage. Foerster et al. (1999) ont été les premiers à appliquer la classification k-NN pour différencier neuf activités humaines utilisant des caractéristiques du domaine temporel obtenues à partir de trois accéléromètres uni-axiaux. Dans Foerster et Fahrenberg, (2000), les auteurs ont combiné k-NN avec une approche décisionnelle hiérarchique pour reconnaître neuf activités utilisant les fonctionnalités du domaine fréquentiel. Cette approche s'est avérée plus efficace, en termes de précision de classification, par rapport au k-NN [17]

2.3.3.2. K-Means :

K-means est une technique de classification non supervisée bien connue qui peut regrouper n objets en k classes. Le regroupement de K-means minimise la distorsion mesurée la variance intra-cluster totale en tant que fonction de coût, (Ferhat Atta et al en 2015) Ils ont fait un travail avec six sujets sains

Avec des profils différents (âge moyen : 26 ans, poids moyen: 65 kg) ont participé aux expériences. Les sujets ont reçu des instructions pour effectuer des activités à leur manière sans contraintes. Chaque sujet a mené un total de douze activités. Les auteurs observent que les taux de classification corrects obtenus avec différentes techniques sont tous supérieurs à 84%. L'algorithme k-Means donne les meilleurs résultats en termes de taux de classification global correct, de mesure F (96.53%) [19].

2.3.4 Etude comparative

Il existe plusieurs modèles de machine learning étudiés (supervisé or non supervisé), où certains auteurs ont mené une comparaison entre ces algorithmes. (Attal et al. (2015) ont étudié les techniques de classification supervisées à savoir, k-Nearest Neighbor (k-NN), Support Vector Machines (SVM), Gaussian Mixture Models (GMM) et Random Forest (RF) ainsi que trois techniques de classification non supervisées telles que K-means, les modèles de mélange gaussien (GMM) et le modèle de Markov caché (HMM). La comparaison a été faite en termes de taux de classification correct, de F-measure, de rappel, de précision et de spécificité (Attal et al, 2015). Les résultats obtenus montrent que le classifieur k-NN offre les meilleures performances par rapport aux autres algorithmes de classification, alors que le classifieur HMM est celui qui donne les meilleurs résultats parmi les algorithmes de classification non supervisé. Cette comparaison met en évidence quelle approche donne la meilleure performance dans des contextes supervisé et non supervisé [20].

2.4 Méthodes basées sur deep learning

2.4.1 Réseaux de neurones profonds (DNN)

Le réseau neuronal profond (DNN) est développé à partir d'un réseau neuronal artificiel (ANN) avec des améliorations dans l'apprentissage, afin de rendre la prédiction plus proche à celle de l'être humain. DNN a été utilisé en 2015, pour reconnaître l'activité humaine (Vepakomma et al., 2015), où les caractéristiques sont extraites à la main, puis soumise au réseau pour classifier le signal. Il a été également utilisé par Walse et al. (2016) en utilisant l'analyse des composantes principales pour extraire les caractéristiques [21].

Hammerla et al. (2016) ont utilisé un DNN à 5 couches cachées pour effectuer l'apprentissage automatique des fonctionnalités et classification avec des performances améliorées. Les expérimentations ont montré que plus les activités sont complexes et

multidimensionnelles plus l'augmentation du nombre de couches cachées aidera le modèle à bien s'entraîner [21].

2.4.2 Réseaux de neurones convolutifs (CNN)

Andrey a proposé une solution pour la reconnaissance de l'activité humaine indépendante de l'utilisateur, et qui est basée sur des réseaux de neurones convolutifs (CNN). Cette approche regroupe plusieurs caractéristiques statistiques qui sont en général 295 propriétés globales de la série chronologique de l'accéléromètre. L'évaluation a été faite sur deux bases de données populaires, i.e. WISDM et UCI HAR, et elle a montré que l'algorithme CNN surpasse considérablement les approches de base. L'avantage majeur de cette approche est qu'elle utilise des courtes intervalles dans la reconnaissance (allant jusqu'à une seconde), et ne nécessite aucune ingénierie de caractéristiques (intervention de l'humain). Elle a produit une précision de 97.63% dans la base de données WISDM, et 97.63% dans la base de données UCI HAR [22].

2.4.3 Réseaux de neurones récurrents (LSTM et BiLSTM)

Les modèles de réseau LSTM sont un type de réseau neuronal récurrent capable de apprendre et se souvenir sur de longues séquences des données d'entrée. En 2019 (Babak Moradi et al.), utilisant la reconnaissance de l'activité humaine Utilisation de l'ensemble de données des smartphones. Dans ce jeu de données, les expériences ont été réalisées avec un groupe de 30 bénévoles au sein d'une tranche d'âge de 19 à 48 ans. Chaque personne effectuait six activités, Les résultats obtenus sont une précision de 95%, les auteurs concluent que si la précision et le temps sont importants pour nous, le meilleur choix est LSTM.

(Babak Moradi et al.) utilisant aussi les LSTM bidirectionnels sont une extension des LSTM traditionnels qui peuvent améliorer les performances des modèles sur des problèmes de classification de séquences. Dans les problèmes où tous les pas de temps de la séquence d'entrée sont disponibles, les LSTM bidirectionnels entraînent deux LSTM au lieu d'un sur la séquence d'entrée. Le premier sur la séquence d'entrée telle qu'elle est et le second sur une copie inversée de la séquence d'entrée. Cela peut fournir un contexte supplémentaire au réseau et aboutir à un apprentissage plus rapide et encore plus complet du problème. [22]. Les résultats obtenus sont une précision de 97% [23].

2.4.4. Etudes comparatives

Il existe plusieurs modèles de deep learning étudiés, et on pose la question quel est le plus performant parmi tous pour la reconnaissance de l'activité humaine. Certains chercheurs ont mené une comparaison tel que (Hammerla et al., 2016), où les auteurs ont comparé DNN, CNN et RNN en conduisant 4000 expériences sur certaines bases de données publiques (dédiées pour la reconnaissance d'activité humaine). Les auteurs ont conclu que RNN (et LSTM également) sont recommandés pour reconnaître les activités courtes (i.e. s'asseoir, se lever, etc.), tandis que CNN est plus efficace pour reconnaître des activités répétitives à long terme. Plus précisément, RNN utilise la relation temporelle entre les lectures des capteurs, et CNN est plus capable d'apprendre fonctionnalités profondes contenues dans des modèles récurrents. Pour les signaux multimodaux, il est préférable d'utiliser CNN, car les fonctionnalités peuvent être intégrées via des convolutions multicanaux (Zheng et al., 2014 ; Ha et al., 2015) [24].

(Long et al. (2019) a proposé un nouveau réseau résiduel asymétrique pour la reconnaissance d'activité en utilisant les données des appareils portables, nommées ARN (abréviation de quoi), Pour améliorer la précision de la reconnaissance des activités. L'évaluation a été faite sur la base de données OPPORTUNITY comportant 17 activités de la vie quotidienne différentes (matinales) dans un environnement riche en capteurs. Cette approche a atteint une précision de plus de 98% et sont largement utilisées dans la vie des gens. La précision d'ARN ne peut pas répondre aux exigences des applications pratiques du domaine de la reconnaissance dans la société. Par conséquent, il reste encore beaucoup à faire [25].

2.5 Travaux basé sur des algorithmes hybrides

C'est évident que chaque méthode a une faiblesse dans la classification, d'où certains chercheurs s'orientent vers les modèles hybrides, i.e. combinaison d'algorithmes. A titre d'exemple, Moradi et al. (2019) ont combiné différentes combinaisons d'algorithmes, i.e. SVM avec noyau RBF, CNN, LSTM et BiLSTM, où ils ont comparé les performances en termes de précision et de temps d'exécution. La combinaison CNN_LSTM et LSTM_LSTM (BiLSTM) a apporté une précision de 97%, tandis que les algorithmes seuls produisaient une précision inférieure, e.g. LSTM 95%, CNN 91% et SVM-RBF 89% [26].

Yao et al. (2017) ont fourni de bons exemples pour combiner CNN et RNN. Il est montré dans (Ordoñez et Roggen, 2016) que la performance de CNN + couches denses

récurrentes est meilleur que CNN + couches denses. Des résultats similaires sont également présentés dans (Singh et al., 2017). La raison est que CNN est capable de capturer la relation spatiale, tandis que RNN peut utiliser la relation temporelle. CNN et RNN pourraient améliorer la capacité de reconnaître différentes activités dont la durée et la distribution des signaux varient [26].

D'autres travaux ont combiné CNN avec des modèles tels que SAE (Zheng et al., 2016) et RBM (Liu et al., 2016). Dans ces travaux, CNN exécute l'extraction de caractéristiques et les modèles génératifs peuvent aider pour accélérer le processus de formation.

Uslu et al. (2013) a utilisé un modèle basé sur l'approche multi-capteurs-multi-classifieurs. En particulier, un classifieur hybride est utilisé, i.e. Naïve Bayes, HMM et SCD sont utilisés pour détecter les transitions entre les activités en temps réel. En phase d'entraînement, les tests sont répétés plusieurs fois et il a été observé que le modèle est rapide et précis (100% taux de réussite) à détecter les signaux de transition. Cependant, en raison du retard de traitement en temps réel une légère réduction de la détection des actions individuelles est observée [26].

2.6 Discussion

Il est clair que comparer les performances des algorithmes entre différentes études est une tâche difficile pour de nombreuses raisons. Cette difficulté est principalement liée à :

- (1) la variabilité des protocoles expérimentaux (le nombre de candidats recrutés, la nature et le nombre des activités reconnues - déambulation, le transport, les activités quotidiennes, l'exercice / la forme physique - la durée et l'ordre des différentes activités, etc.);
- (2) les objectifs applicatifs derrière la reconnaissance de l'activité humaine (surveillance, détection de chute, réadaptation à domicile, etc.);
- (3) le type de capteurs utilisé (accéléromètres, pression plantaire, gyroscopes, etc.) et leur fixation au corps (poignet, poitrine, hanche, cuisse, collier);
- (4) les critères d'évaluation des performances (exactitude, F-mesure, rappel, précision, spécificité, etc.);
- (5) la procédure de validation (pli P, omettre un, sous-échantillonnage aléatoire répété, bootstrap, etc.).

Dans [14,15,18,20,28,29], un accéléromètre a été utilisé pour reconnaître des activités telles que la position assise, debout, mentir, marcher, courir, froter, passer l'aspirateur, se brosser les dents, tomber, etc. Le classement moyen taux variait de 90,8% et 98,9% et a été obtenu en utilisant un accéléromètre placé à l'un ou l'autre au niveau de la taille [15, 18, 28] ou au

niveau du poignet [20, 29]. Dans [17,19,23,26], deux accéléromètres ont été utilisés pour reconnaître des activités telles que la marche lente, la marche rapide et l'aviron. Dans la plupart de ces études, le nombre d'activités ne dépasse pas dix activités. Un grand nombre d'activités ont été envisagées dans [27] (seize activités) et [7] (douze activités). Dans ces études, des taux de classification allant de 89% à 90,3% ont été obtenus. Dans d'autres études, trois accéléromètres ont été placés à la cuisse, sur un collier et au niveau du poignet.

Dans [8], les auteurs ont évalué l'utilisation d'un seul accéléromètre par rapport à un multi-accéléromètre pour reconnaître cinq activités (debout, assis, couché, marche et transition). Un taux de reconnaissance de 96,4% a été atteint avec l'utilisation de multi-accéléromètres placés au niveau de la poitrine, de la taille, des cuisses et des côtés. Dans [24], les capteurs IMU, y compris les accéléromètres et des gyroscopes, placés au niveau du tronc et de la tige, ont été utilisés pour reconnaître 14 activités quotidiennes des patients atteints de la maladie de Parkinson (MP). Une sensibilité de 83,8% a été obtenue chez les patients atteints de MP. Dans [30], les auteurs intègrent IMU et capteurs de pression pour améliorer le taux de reconnaissance des activités de la vie quotidienne des patients victimes d'un AVC. Un taux de classification de 90,4% a été atteint pour la reconnaissance des activités de base comme se coucher, s'asseoir, se tenir debout et marcher, ainsi que distinguer l'élévation du corps comme à plat, ascenseur vers le bas, ascenseur vers le haut, escalier vers le bas et escalier vers le haut [27].

2.7. Conclusion

Dans ce chapitre, nous avons exposé quelques travaux qui ont été entrepris dans le domaine de la reconnaissance de l'activité humaine, et utilisation de (capteur portable) dans ce domaine avec ses différentes techniques. Généralement, on a constaté que techniquement, il n'y a pas de modèle qui surpasse tous les autres dans toutes les situations. En outre, nous avons trouvé que le meilleur choix dans notre travail (capteur portable) est les algorithmes hybrides. Dans le chapitre suivant, nous présentons notre approche et expérimentation sur la base de données UCI-HAR.

Chapitre III
Contribution

3.1. Introduction

Après avoir présenté, les notions générale de humain activiy recognition (HAR) et les techniques de l'apprentissage profonde. Dans ce chapitre, nous présentons les outils utilisées dans de notre approche, l'implémentation et les résultats.

3.2. Réseaux de neurones convolutifs

Dans cette section, nous décrivons la structure des réseaux de neurones convolutionnels et les architectures du système proposée dans notre travail.

3.2.1. Introduction

Un réseau de neurones tente d'imiter le cerveau humain, un ordinateur utilise la mémoire pour stocker des données, la mémoire est divisée en sections, chacune a son adresse unique, un cerveau ne fonctionne cependant pas comme ça, il modifie plutôt l'association des neurones, un neurone n'a pas de capacité de stockage, il ne fait que transmettre des signaux à d'autres neurones.

3.2.2. Le réseau neuronal

Les réseaux neuronaux, aussi appelés ANN, sont des modèles de traitement de l'information qui simulent le fonctionnement d'un système nerveux biologique. C'est similaire à la façon dont le cerveau manipule l'information au niveau du fonctionnement. Tous les réseaux neuronaux sont constitués de neurones inter connectés qui sont organisés en couches [34].

Ce qui forme les réseaux de neurones, ce sont les neurones artificiels inspirés du vrai neurone qui existe dans notre cerveau. La figure 3.1 montre une représentation d'un neurone réel et d'un neurone artificiel.[34]

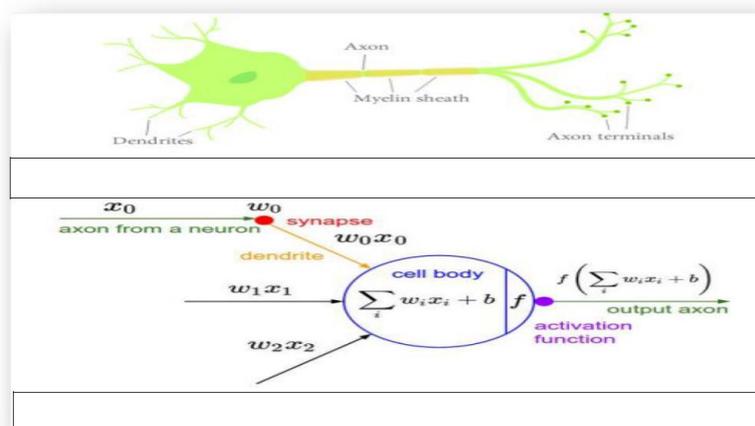


Figure 3.1. Photo représente A. un neurone réel .B. un neurone artificiel.[34]

Les X_i sont des valeurs numériques qui représentent soit les données d'entrée, soit les valeurs sorties d'autres neurones. Les poids W_i sont des valeurs numériques qui représentent soit la valeur de puissance des entrées, soit la valeur de puissance des connexions entre les neurones. Il existe des opérations qui se passent au niveau du neurone artificiel. Le neurone artificiel fera un produit entre le poids (w) et la valeur d'entrée (x), puis ajoutera un biais (b), le résultat est transmis à une fonction d'activation (f) qui ajoutera une certaine non-linéarité.[34]

Le réseau neuronal convolutif est un réseau neuronal profond utilisé dans la reconnaissance d'images, cette architecture imite le cortex visuel du cerveau et reconnaît les images. Il comporte un certain nombre de couches convolutives, où il apprend les filtres qui glissent le long des données d'entrée et appliqués à ses sous-régions [35]. Dans ce mémoire, nous proposons une architecture CNN qui est présentée dans la Figure 3.10.

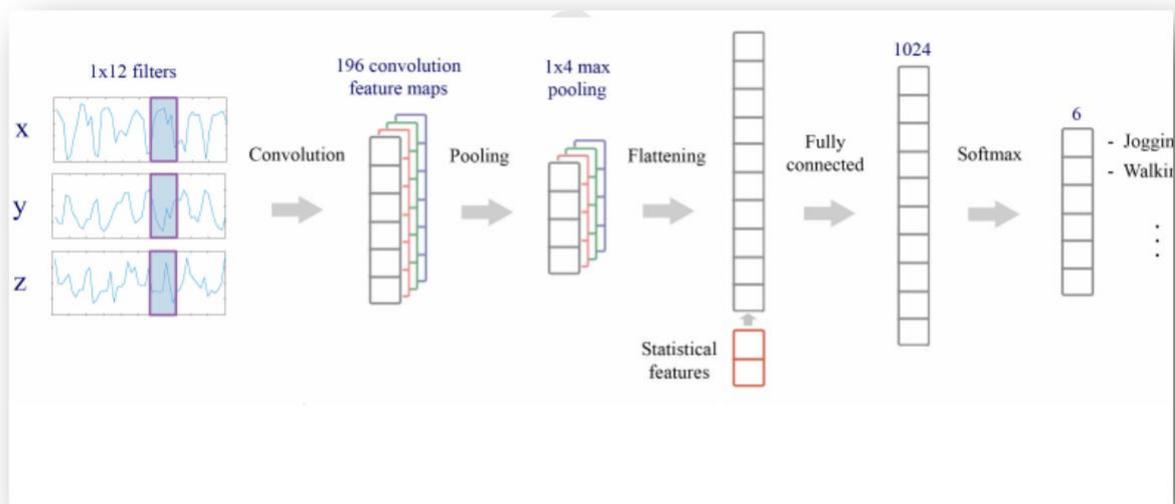


Figure 3.2. Architecture du système proposé.[35]

3.2.2.1. Filtre de convolution

La couche de convolution génère de nouvelles images appelées cartes de caractéristiques. La carte des caractéristiques accentue les caractéristiques uniques de l'image d'origine. La couche de convolution fonctionne de manière très différente par rapport aux autres couches du réseau de neurones. Cette couche n'utilise pas de poids de connexion ni de somme pondérée. Au lieu de cela, il contient des filtres qui convertissent les images. Nous appellerons ces filtres des filtres de convolution. Le processus de saisie de l'image à travers les filtres de convolution produit la carte des caractéristiques.

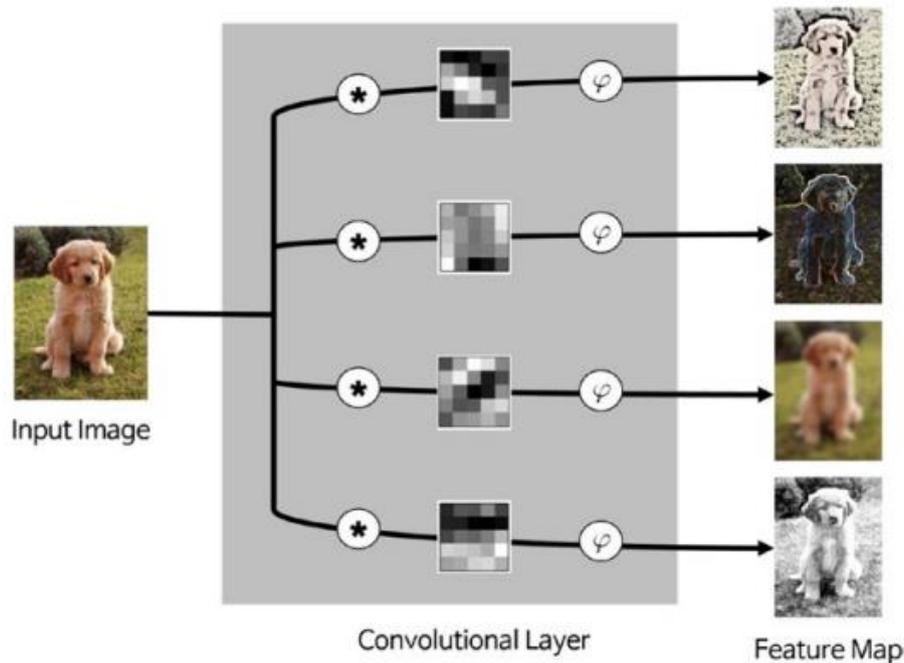


Figure 3.3. Le processus de filtre de convolution. [41]

Les filtres de la couche de convolution sont des matrices bidimensionnelles. Ils viennent généralement dans des matrices 5x5 ou 3x3, et même des filtres à convolution 1x1 ont été utilisés dans des applications récentes. [41]

3.2.2.2. Fonction d'activation

La fonction d'activation détermine le comportement du nœud, il existe plusieurs types de fonctions d'activation, l'une des plus utilisées est la fonction Sigmoidé illustrée dans la figure suivante:

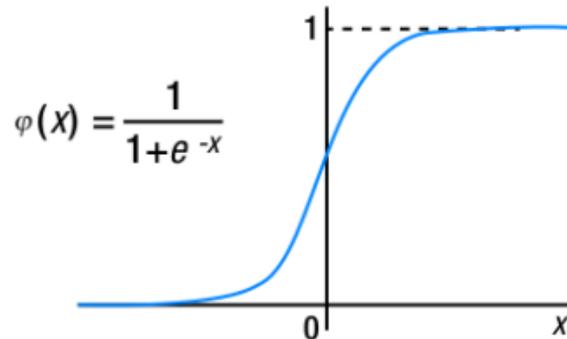


Figure 3.4. La fonction Sigmoidé. [41]

Il existe d'autres types, nous pouvons également utiliser une simple rampe pour plus de commodité dans certains exemples. [41]

3.2.2.3. Filtre de pooling

La couche pooling réduit la taille de l'image, car elle combine les pixels voisins d'une certaine zone de l'image en une seule valeur représentative. Le pooling est un technique typique que de nombreux autres schémas de traitement d'images ont déjà utilisé.

Afin de conduire les opérations dans la couche de mutualisation, il convient de déterminer comment sélectionner les pixels de regroupement de l'image et comment définir la valeur représentative. Les pixels voisins sont généralement sélectionnés à partir de la matrice carrée, et le nombre de pixels qui sont combinés diffère d'un problème à l'autre. La valeur représentative est généralement définie comme la moyenne ou le maximum des pixels sélectionnés. Un exemple de pooling in dans la figure suivante:

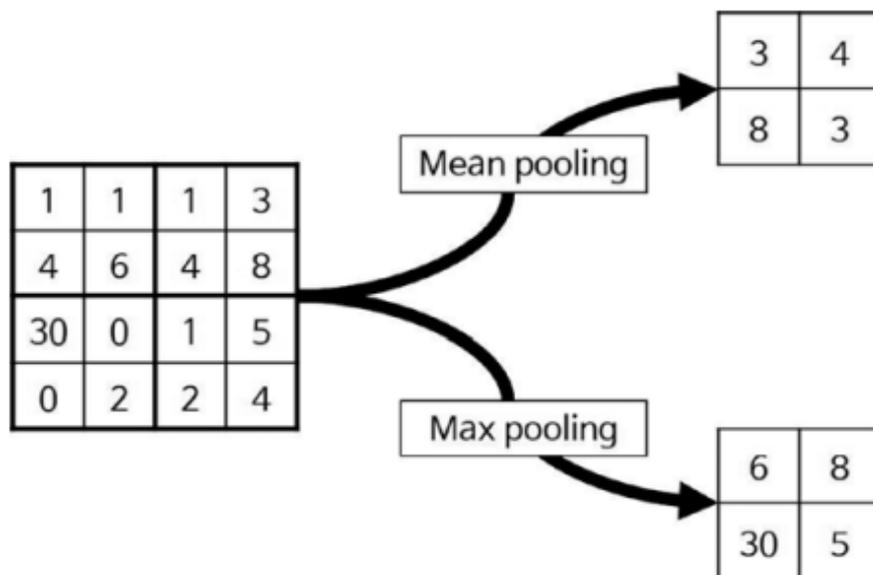


Figure 3.5. Le processus de filtre de pooling. [41]

3.2.2.4. Classification

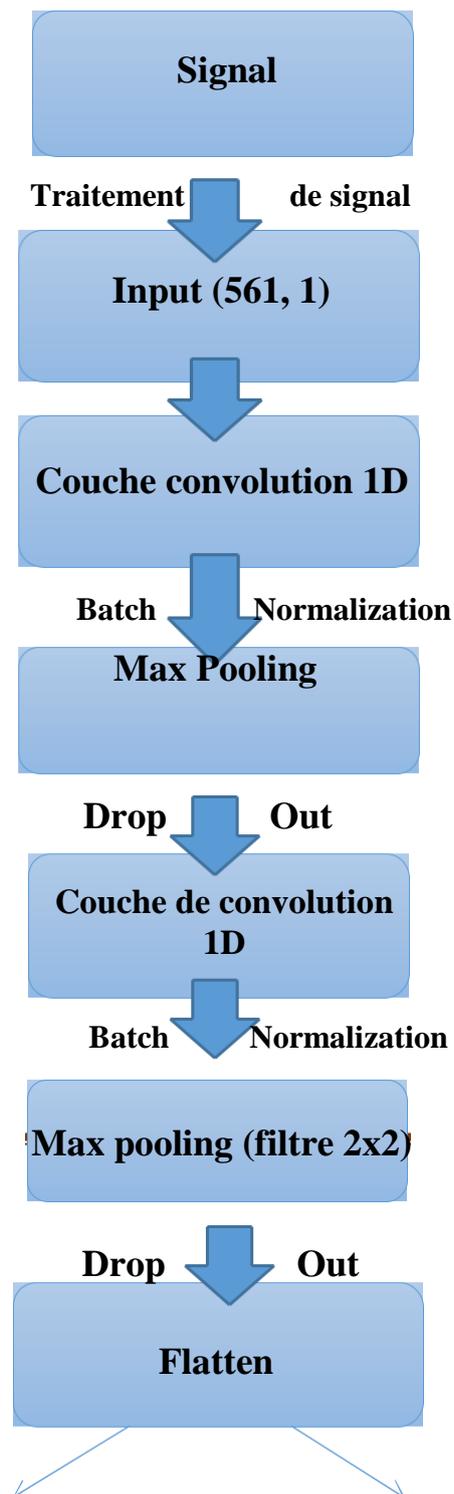
Dans l'application du réseau de neurones à la classification, la couche de sortie est généralement formulée différemment en fonction du nombre de groupes dans lesquels les données doivent être divisées. La sélection du nombre de nœuds et des fonctions d'activation appropriées pour la classification de deux groupes est différente lors de l'utilisation de plusieurs groupes. [41]

3.2.3. Architecture CNN

Notre réseau CNN est composé par deux parties, la première partie est dédiée pour l'extraction du vecteur caractéristique, elle est composée de deux couches de convolutions. La première couche est composée de 16 filtres de taille 6 , et la deuxième de 32 filtres de taille 3. Chaque couche de convolution est suivie par un batch normalization pour normaliser les sorties, puis une couche de max-pooling pour réduire la taille de la sortie et garder que l'information pertinente. A la fin une couche de drop out pour éviter le 'overfitting'.

Donc, notre architecture CNN a été utilisée dans laquelle les couches CNN sont utilisées pour l'extraction de caractéristiques sur les données d'entrée Les étapes de base de la construction du réseau neuronal CNN sont les suivantes :

1. Charger des données: Le chargement du jeu de données brutes en mémoire. Il y a trois signaux principaux dans les données brutes comme l'accélération totale, l'accélération corporelle et le gyroscope corporel et chacun a 3 axes de données comme x, y, z. Ainsi, il y a un total de neuf variables pour chaque pas de temps. En outre, chaque série de données a été partitionnée en fenêtres se chevauchant de 2,56 secondes de données ou 128 pas de temps. Par conséquent, chaque ligne de données contient $128 * 9$ ou 1152 éléments.
2. Ajuster et évaluer le modèle: La figure suivante illustre le processus de cette étape.



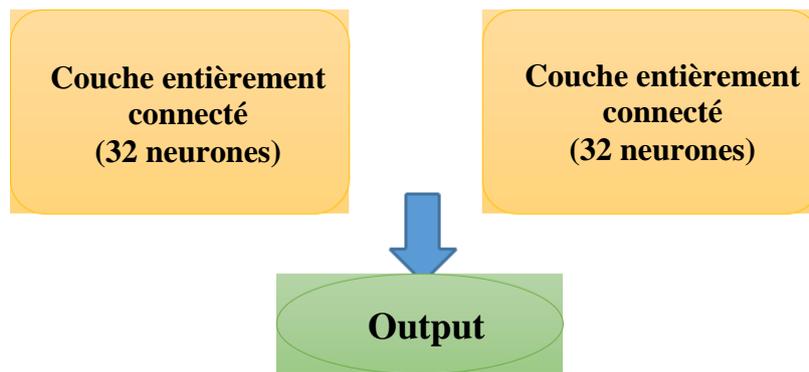


Figure 3.6: Schéma d'architecture du réseau CNN utilisé

Une couche flatten est-utilisé pour faire passer le vecteur caractéristique (qui représente la sortie de la première partie) à la deuxième partie qui est dédiée à la classification. Cette partie est composée de 3 couches de neurones. La première contient 64 neurones, la deuxième 32 neurones et la troisième 6 neurones qui représente le nombre d'activités.

3.3. Expérimentation et résultats

Dans la partie suivantes, on vas élaborées les étapes de notre expérimentation sur la base de données de reconnaissance de l'activité humaine (HAR), on doit aussi faire une comparaison entre les méthode de reconnaissance.

3.3.1. Base de données utilisée

L'ensemble de données utilisé dans le système est le jeu de données standard de reconnaissance de l'activité humaine (HAR) ou le jeu de données « Reconnaissance d'activité a l'aide de téléphones intelligents » qui a été rendu disponible en 2012. Il est disponible et peut être téléchargé à partir du référentiel d'apprentissage automatique de l'UCI. La taille de l'ensemble de données est de 10299. Les données ont été collectées auprès de 30 personnes âgées de 19 à 48 ans effectuant six activités standard à savoir marcher, monter les escaliers, descendre les escaliers, s'asseoir, se tenir debout et se coucher. Chaque personne a effectué cette séquence d'activités deux fois une fois avec l'appareil sur le côté gauche et une fois avec l'appareil sur le côté droit. Les capteurs utilisés étaient le capteur count-1 et le capteur de position de taille. Les données ont été collectées avec le téléphone mobile Samsung Galaxy SII. Ici, ils ont capturé les signaux bruts 3 axes de l'accéléromètre et du gyroscope avec tAcc-XYZ et tGyro-XYZ avec une fréquence de 50 Hz. Les expériences ont été enregistrées sur vidéo pour étiqueter les données manuellement. L'ensemble de données obtenu a été partitionné au hasard en deux ensembles, où 70% des volontaires ont été sélectionnés pour générer les données d'entraînement et 30% les données de test. Des expériences ont été

réalisées sur des ensembles de données UCI contenant données de séries chronologiques de l'accéléromètre obtenues à partir de smartphones Android.

3.3.2. Préparation de l'environnement du travail

Dans cette section, nous présentons la préparation de l'environnement afin de s'expérimenter dans la reconnaissance d'activité humaine. La principale expérimentation est basée sur une base de données existante (données acquises de smartphones),



Figure 3.7: human activity walking jogging[35]

A l'aide des logiciels **Anaconda** et **Jupyter**, nous avons utilisé le langage python pour développer notre algorithme (i.e. CNN).

Anaconda est une distribution libre et open source des langages de programmation Python et R appliqué au développement d'applications dédiées à la science des données et à l'apprentissage automatique (traitement de données à grande échelle, analyse prédictive, calcul scientifique), qui vise à simplifier la gestion des paquets et de déploiement [32].

Python est un langage de programmation, un des langages de niveau supérieur, caractérisé par une écriture et une lecture simples, facile à apprendre, utilisant un style de programmation ouvert, et évolutif [33].

3.3.3. Résultats et discussion

3.3.3.1. Exploration des données

L'ensemble de données utilisé pour cet article provient du référentiel d'apprentissage automatique de l'UCI intitulé "Smartphone-Based Recognition of Human Activities and Postural Transitions Data Set" (SBHAR). Les données ont été recueillies à partir d'expériences avec un groupe de 30 volontaires âgés de 19 à 48 ans portant un Samsung Galaxy SII à la taille. Les volontaires ont effectué un protocole d'activités comprenant six postures de base : trois statiques — debout, assis, couché et trois dynamiques — marcher, descendre et monter les escaliers. L'expérience comprenait également des postures de transition entre des postures statiques. Ce sont : debout pour s'asseoir, assis pour se tenir debout, assis pour mentir, couché pour s'asseoir, debout pour mentir et couché pour se tenir debout. Les signaux des capteurs ont été collectés à partir de l'accéléromètre et du gyroscope des smartphones, notamment une accélération linéaire sur 3 axes et une vitesse angulaire sur 3 axes à un taux de rafraîchissement constant de 50 Hz. Des données étiquetées manuellement ont également été ajoutées à la séquence vidéo de cette expérience [Note 1]. Le SBHAR a été divisé de manière aléatoire en ensembles de test et d'entraînement dans un rapport de 70:30. Après une série de prétraitements, l'ensemble de données final contient 561 vecteurs de caractéristiques par exemple dérivés de 17 modèles d'action et 17 fonctions sur 12 étiquettes d'activités.

Pour mieux comprendre l'ensemble de données, nous avons examiné le nombre d'activités enregistrées pour chacun des 12 groupes d'activités. L'ensemble de données présente un problème de déséquilibre, les activités en transit étant sous-représentées par rapport aux activités non en transit. La figure ci-dessous donne une image claire :

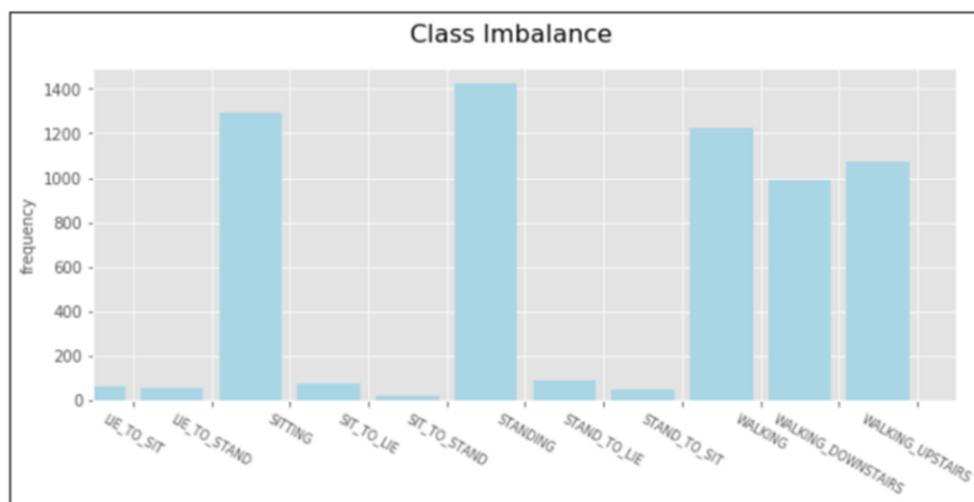


Figure.3.8: Le déséquilibre des classes.

Le déséquilibre des classes pourrait présenter des difficultés pour classer et prédire avec précision les données. Les ensembles de données avec un rapport disproportionné d'observations dans chaque classe peuvent compromettre la légitimité de l'utilisation de la précision comme mesure de la performance. C'est parce qu'un score de précision élevé pourrait être attribué à l'échantillonnage de la classe surreprésentée, mais des données très limitées de la classe sous-représentée ont été capturées. Pour résoudre ce problème, plusieurs méthodes pourraient être envisagées : le suréchantillonnage sous la classe de données représentée ; sous-échantillonnage sur la classe de données représentée ; en utilisant différents algorithmes ou mesures qui réduisent la dépendance du score de précision uniquement ou en remplissant les données pour augmenter la classe de données sous-représentée.

Une autre observation sur l'ensemble de données est le nombre important de fonctionnalités, 561 au total, comme discuté dans la section ci-dessus. La haute dimensionnalité des données est souvent présentée comme la «malédiction de la dimensionnalité» dans l'apprentissage automatique, car elle pourrait potentiellement compliquer le processus d'apprentissage qu'un algorithme d'apprenant peut apprendre. Pour mieux comprendre l'ampleur de la dimensionnalité, une analyse en composantes principales (ACP) est utilisée. L'apprentissage en profondeur est également considéré comme une solution possible à la haute dimensionnalité [2], un réseau de neurones convolutifs est donc également appliqué pour résoudre ce problème. La section ci-dessous détaille les algorithmes et les techniques utilisés pour résoudre à la fois les problèmes de déséquilibre et de haute dimensionnalité observés dans l'ensemble de données.

3.3.3.2. Algorithmes et techniques

Comme discuté dans la section ci-dessus, les données SBHAR semblent présenter un déséquilibre de classe et des problèmes de dimensionnalité élevée. Pour résoudre le problème de haute dimensionnalité, l'ACP est appliquée pour tenter de réduire la dimensionnalité et sélectionner des caractéristiques. Une technique courante pour visualiser la relation entre le nombre de composantes principales et le pourcentage de variance expliqué par les composantes principales consiste à utiliser un scree plot. Cet article a d'abord tracé le scree plot pour examiner l'ensemble des données. Il semble que jusqu'à 90 % de la variance puisse s'expliquer par les 100 premières composantes principales. Un deuxième scree plot a ensuite été dessiné

pour zoomer sur les 100 premiers composants principaux afin d'examiner de plus près la relation. Le schéma ci-dessous présente les deux éboulis.

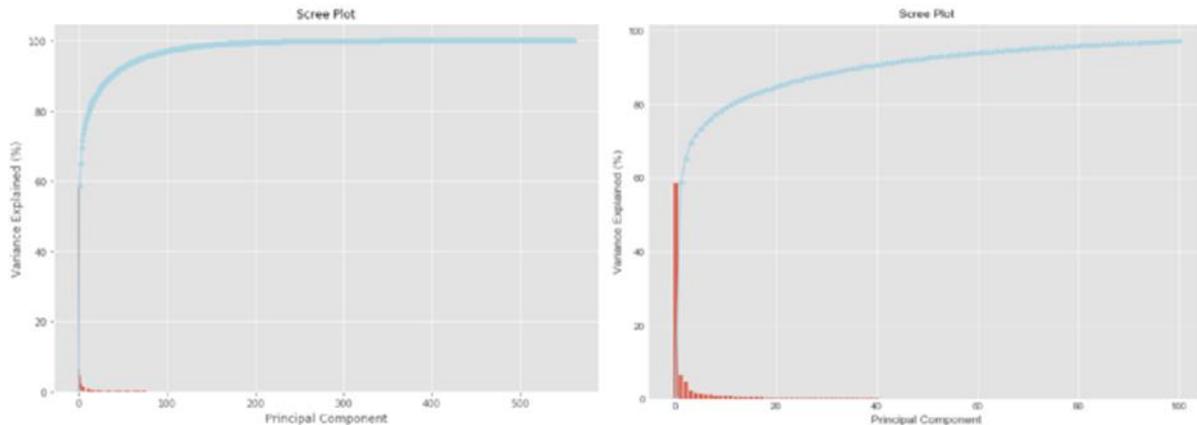


Figure.3.9: Les courbes de Scree Plot (%).

Un examen plus approfondi du scree plot montre que les trois premières composantes principales expliquent près de 70% des variances au sein de l'ensemble de données, tandis que les 100 premières composantes principales expliquent jusqu'à 97%. Cela signifie que les 561 dimensions pourraient être réduites à l'aide de la sélection d'entités et limitées à un sous-ensemble plus petit que l'ensemble de données.

Un certain nombre de classificateurs susceptibles de convenir au problème de classification actuel ont également été appliqués pour comparer le score de précision pouvant être atteint sans aucun réglage précis des hyper paramètres. En particulier, les classificateurs suivants sont utilisés, ainsi que les scores de précision obtenus individuellement.

Comme indiqué précédemment, étant donné la nature hautement dimensionnelle de l'ensemble de données, un modèle de réseau neuronal convolutif (CNN) a également été appliqué. Le CNN a été conçu pour avoir plusieurs couches convolutives et couches d'abandon avant de se connecter complètement à la fonction d'activation définie comme softmax. Le schéma ci-dessous illustre la structure de CNN.

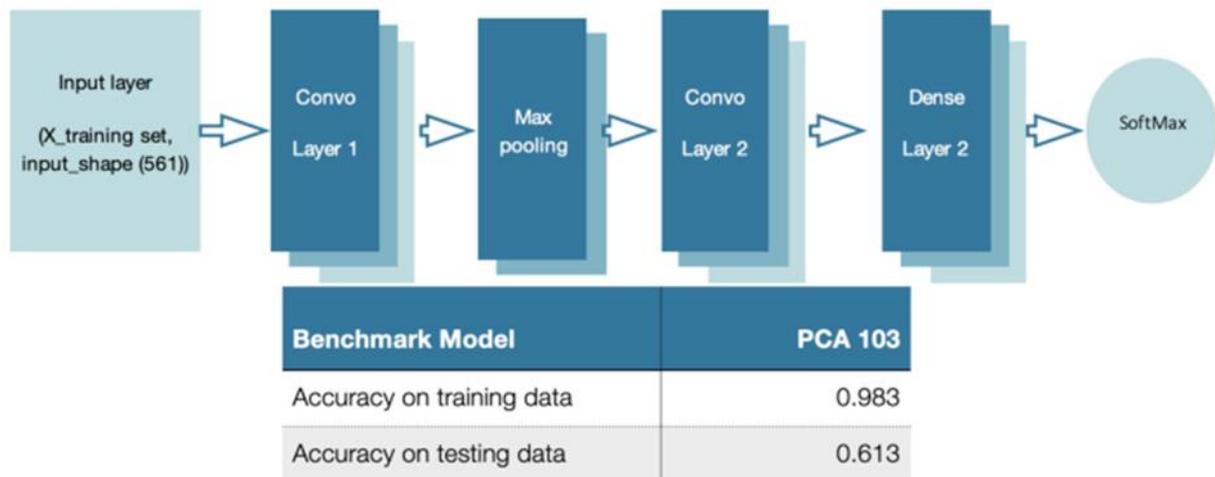


Figure.3.10: La structure CNN utilisant la FA Softmax.

3.3.3.3. Prétraitement des données

L'ensemble de données utilisé dans cet article avait déjà été pré-traité. En particulier, les données SBHAR ont généré environ 5 heures de données expérimentales [3], et ont également été pré-traitées avec des filtres de bruit échantillonnés par des fenêtres coulissantes à largeur fixe (2,56 s avec un chevauchement de 50%, soit 128 lectures/fenêtre). D'autres transformations de données ont également été appliquées, notamment le calcul des signaux Jerk à partir du temps, des informations sur l'accélération linéaire du corps et la vitesse angulaire; magnitude à l'aide de la norme euclidienne et les signaux du domaine fréquentiel à l'aide de la transformée de Fourier rapide (FFT). Le prétraitement effectué apparaît raisonnable et justifié. Une enquête sur des études similaires dans le domaine HAR indique également que le prétraitement était acceptable. L'analyse documentaire détaillée a été incluse dans la proposition de projet.

3.3.3.4. Mise en œuvre et raffinement

Suite aux discussions ci-dessus, les algorithmes d'apprentissage automatique SVC avec équilibrage de classe ont été implémentés. De plus, la mise en œuvre a été réalisée en ajustant finement les hyper paramètres du modèle SVC à l'aide de la recherche de grille. Plus précisément, nous avons examiné les trois hyper paramètres suivants : noyau, pénalité C et gamma. Ci-dessous, nous avons brièvement discuté des plages utilisées pour sélectionner le meilleur ensemble d'hyper paramètres à tour de rôle :

- Le noyau est par défaut rbf dans le package Scikit-Learn, le noyau linéaire a été ajouté pour fournir une extrapolation linéaire sur la limite de décision. Cependant, étant donné que

l'ensemble de données a une dimensionnalité élevée, ce noyau ne devait pas être sélectionné comme l'hyperparamètre optimal.

- Le paramètre de pénalité C punit une donnée mal classée et agit comme un outil de régularisation pour les données à biais élevé et à faible variance si défini petit, et vice versa si défini grand. Il affecte le modèle SVC en spécifiant dans quelle mesure nous pourrions tolérer une mauvaise classification de chaque classe dans l'ensemble de données. Le paramètre C de l'ordre de 1, 10, 100 et 1000 a donc été donné.
- Gamma est le paramètre hyper affectant la limite de classe des hyperplans non linéaires. Un gamma inférieur fournit une séparation plus douce entre les limites de classe tandis qu'un gamma plus élevé peut entraîner un problème de surapprentissage en créant des limites « d'îlot » pour chaque point de données. Étant donné que nous avons déjà observé un problème de surapprentissage potentiel en utilisant 103 composants principaux dans SVC, le gamma a été réglé à l'extrémité inférieure à 0,001 et 0,0001.

L'ensemble final de paramètres sélectionnés par la recherche de grille était {'C': 1000, 'gamma': 0,001, 'kernel': 'rbf'} et a été appliqué au modèle SVC sur l'ensemble de données pour surmonter davantage le déséquilibre de classe et le problème de surapprentissage. Le modèle SVC a été amélioré en conséquence, avec des scores de précision allant jusqu'à 0,995 pour l'ensemble d'apprentissage et 0,954 pour l'ensemble de test. Il indique le réglage fin effectué pour atténuer le problème de surapprentissage présenté dans le modèle d'analyse comparative.

Pour le modèle CNN, la structure du modèle, la fonction de perte et les optimiseurs ont tous été affinés à plusieurs reprises. La conception originale du modèle CNN comportait une couche d'entrée, deux couches denses avec une interruption temporelle entre les deux. L'ajout d'une couche dense supplémentaire avec un abandon supplémentaire semble avoir contribué au score de précision. De plus, au lieu d'utiliser l'entropie croisée catégorique comme fonction de perte, l'entropie croisée binaire semble améliorer les performances du modèle. Cela peut être dû à la rareté des matrices de prédiction. Enfin, un certain nombre d'optimiseurs ont été explorés, notamment Adam, Adamax, Adadelta, Adagrad et Rmsprop. Adam a semblé générer le meilleur score. Le CNN final a une couche d'entrée, trois couches denses avec trois fois l'abandon avant de se connecter complètement à la fonction d'activation softmax. Le modèle minimise l'entropie croisée binaire de la fonction de perte avec l'optimiseur Adam, obtenant un score de précision sur l'ensemble de données d'apprentissage à 0,997 et à 0,991 sur l'ensemble de données de test.

3.3.3.5. Évaluation et validation du modèle

Nous avons discuté plus tôt qu'en raison du déséquilibre des classes présenté dans les données, une méthodologie plus robuste consiste à examiner l'exactitude avec une matrice de confusion pour comprendre d'où venaient les erreurs. Cet article a spécifiquement examiné deux types de modèles pour prédire le HAR, un SVC affiné et un CNN. Vous trouverez ci-dessous les matrices de confusion pour chaque modèle sur les ensembles de données d'apprentissage et de test respectivement. Notez que les matrices de confusion sont normalisées pour faciliter la comparaison.

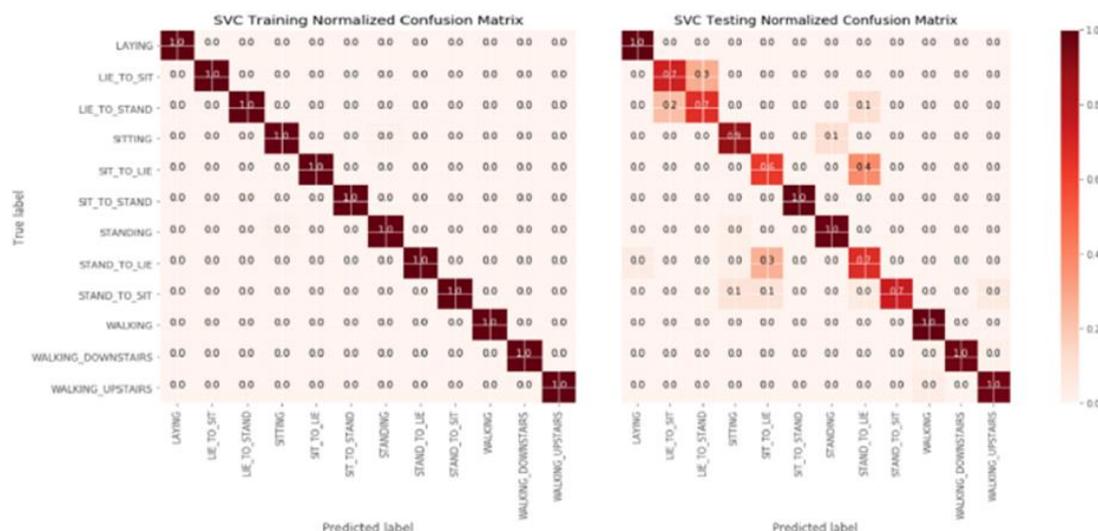


Figure.3.11: Modèle SVC.

Premièrement, la comparaison des matrices de confusion sur les performances du modèle SVC des données d'entraînement et de test.

La matrice de confusion SVC sur les données de test montre que la plupart des erreurs concernaient une mauvaise classification des activités de transition telles que mentir pour s'asseoir et mentir pour se tenir debout, ainsi que se tenir pour mentir et s'asseoir pour mentir. Ceux-ci sont compréhensibles car le mouvement et le mouvement entre les états de transit peuvent être trop subtils pour être détectés.

Ensuite, deux matrices de confusion présentent les performances du modèle CNN sur les données d'entraînement et de test respectivement. Étant donné que le modèle CNN fonctionnait mieux que le modèle SVC sur les deux ensembles de données respectivement, moins d'erreurs étaient attendues. Fait intéressant, CNN a commis des erreurs en classant principalement la marche et la marche en haut, ainsi que la marche en bas et la position debout pour s'asseoir.

3.3.3.6. Justification et conclusion

Le modèle SVC affiné et le CNN appliqués à l'ensemble de l'ensemble de données ont tous deux surpassé le modèle d'analyse comparative. Il n'y a pas de surprise étant donné que les modèles ont été exécutés sur de plus grands ensembles de données avec des hyperparamètres affinés pour optimiser les scores de précision.

De plus, étant donné que les modèles SVC et CNN ont atteint une précision de plus de 99% sur les ensembles de données de test, il est considéré comme une solution appropriée pour résoudre le problème HAR de manière adéquate. Le diagramme ci-dessous fournit une visualisation pour illustrer les performances du modèle entre le modèle de référence, SVC et CNN sur les données d'entraînement et les données de test.

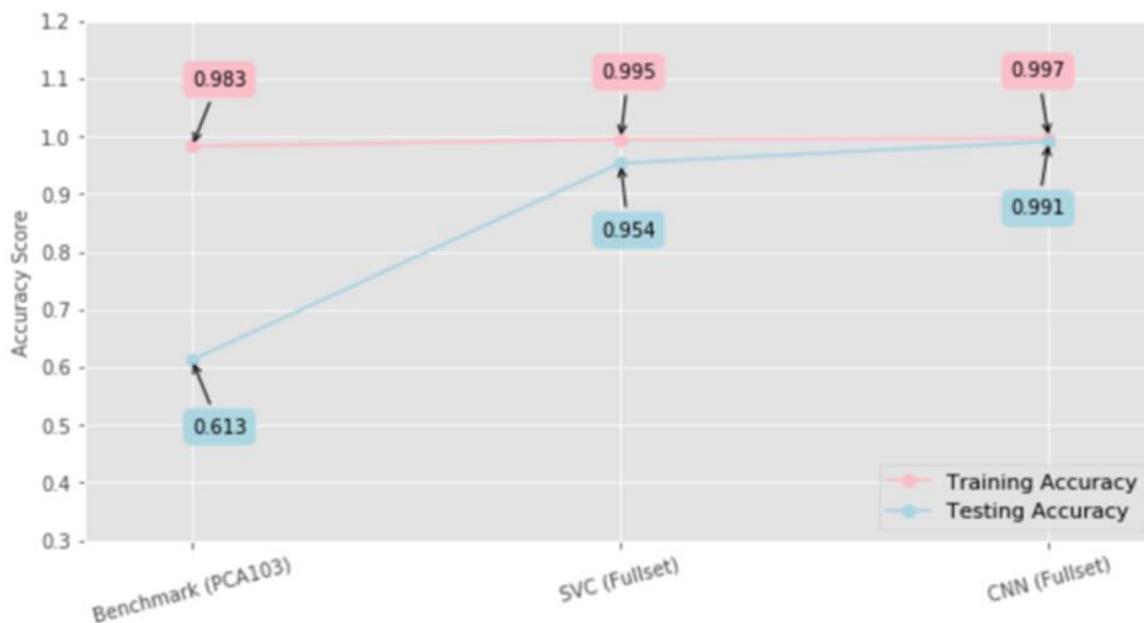


Figure.3.12: Comparaison entre les modèles (PCA103, SVC, CNN).

3.6 Conclusion

Dans ce chapitre, nous avons proposé une solution au problème de reconnaissance d'activités humaines indépendantes de l'utilisateur, et qui est basée sur des réseaux de neurones convolutifs (ou CNN). L'algorithme est augmenté de fonctionnalités statistiques qui englobent 295 propriétés globales de la série chronologique de l'accéléromètre. Il a les avantages d'utiliser la reconnaissance à courte intervalle de taille allant jusqu'à 1 seconde et ne nécessitant pratiquement aucune ingénierie des fonctionnalités et aucun prétraitement des

données. En raison d'une architecture relativement peu profonde, l'algorithme proposé a un temps d'exécution réduit et peut être exécuté efficacement sur les appareils mobiles en temps réel. Pour évaluer les performances de l'approche considérée, nous l'avons testée sur la base de données universelle *UCI-HAR*. Les résultats obtenus montrent que le modèle proposé basé sur CNN donne des résultats considérables et un taux de précision élevé (95.8%).

CONCLUSION GENERALE

La reconnaissance de l'activité humaine est un sujet de recherche important en reconnaissance de formes et en informatique omniprésente. Dans ce mémoire, nous passons en revue les progrès récents des capteurs portable pour la reconnaissance d'activités humaines. Par rapport aux méthodes traditionnelles de reconnaissance, les capteurs réduit la dépendance à l'égard de l'extraction de caractéristiques fabriquées par l'homme et obtient de meilleures performances en apprenant automatiquement des représentations de haut niveau des données. Nous soulignons les progrès récents dans trois catégories importantes : la modalité du capteur, le modèle profond et l'application. Par la suite, nous résumons et discutons en détail la recherche étudiée. Enfin, plusieurs grands défis et solutions réalisables sont présentés pour de futures recherches.

Bibliographie

- [1].<https://www.himss.org/resources/wearable-technology-applications-healthcare-literature->
- [2].<https://breathe.ersjournals.com/content/breathe/13/2/e27/F3.medium.gif>
- [3] <https://www.semiconductorstore.com/blog/2018/Smart-Sensor-vs-Base-Sensor-Whats-the-Difference-Symmetry-Blog/3538/#:~:text=A%20smart%20sensor%20is%20a,data%20before%20passing%20it%20on>
- [4] <https://www.inventelectronics.com/product/photodiode-5mm/>
- [5]<https://sante.lefigaro.fr/actualite/2016/09/12/25381-capteur-minuscule-pour-surveiller-corps-linterieur>
- [6]<https://www.lemondeinformatique.fr/actualites/lire-un-capteur-flexible-capable-de-realiser-un-bilan-medical->
- [7] <https://fr.slideshare.net/userADgents/ioteatime-3-smart-home-de-la-maison-connecte-la-maison-intelligente>
- [8]<https://www.futura-sciences.com/tech/definitions/montre-intelligente-montre-connectee-15456/>
- [9]<https://www.modeintextile.fr/capteurs-tisses-chemise-peuvent-surveiller-signes-vitaux/>
- [10]https://www.tutorialspoint.com/internet_of_things/internet_of_things_healthcare_application
- [11] Wearable Sensors for Remote Health Monitoring, Sumit Majumder 1 , Tapas Mondal 2 and M. Jamal Deen 1,* Published: 12 January 2017 Academic Editors: Stephane Evoy and Baris Fidan Department of Electrical and Computer Engineering, McMaster University, Hamilton, ON L8S 4L8, Canada; majums3@mcmaster.ca 2 Department of Pediatrics, McMaster University, Hamilton, ON L8S 4L8, Canada
- [12] <https://onlinelibrary.wiley.com/doi/full/10.1002/adhm.201700889>
- [13] <https://www.businessinsider.com/wearable-technology-healthcare-medical-devices?IR=T>
- [14]<https://waytolearnx.com/2018/11/difference-entre-microprocesseur-et-microcontrolleur.html>
- [15] https://www.goffi.org/b/S%C3%A0T_DOTCLEAR_IMPORT_BLOG_default_goff
- [15.16] Ref S. Boukir, F. Chenevière, Conception d'un système de reconnaissance de gestes

- danse [DTW], Université de La Rochelle, Avenue Michel Crépeau , le 2 septembre 2003 ,
200 traitement du signal 2004_volume 21_numéro 3
- [17] Ferhat Attal , Samer Mohammed , Mariam Dedabrishvili , Faicel Chamroukhi , Latifa Oukhellou and Yacine Amirat, Physical Human Activity Recognition Using Wearable Sensors, Academic Editor: Vittorio M.N. Passaro, Published: 11 December 2015, pp 31322-31323
- [18] -Krause, A.; Ihmig, M.; Rankin, E.; Leong, D.; Gupta, S.; Siewiorek, D.; Smailagic, A.; Deisher, M.; Sengupta, U. Trading off prediction accuracy and power consumption for context-aware wearable computing. In Proceedings of the 2005 Ninth IEEE International Symposium on Wearable Computers, Osaka, Japan, 18--21 October 2005; pp. 20–26.
- [1.19] Ferhat Attal , Samer Mohammed , Mariam Dedabrishvili , Faicel Chamroukhi , Latifa Oukhellou and Yacine Amirat, Physical Human Activity Recognition Using Wearable Sensors, Academic Editor: Vittorio M.N. Passaro, Published: 11 December 2015, pp 31323-31324
- [1.20] Ferhat Attal , Physical Human Activity Recognition Using Wearable Sensors, Received Editor: Vittorio M.N. Passaro, 11 September 2015; Accepted: 8 December 2015; Published: 11 December 2015 Academic Editor: Vittorio M.N. Passaro { **Etude comparative** }
- [1.21] Jindong Wang, Yiqiang Chen , Shuji Hao, Xiaohui Peng, Lisha Hu, Deep Learning for Sensor-based Activity Recognition: A Survey , Edison , Beijing, China, pp; 3-4
- [1.22] Ignatov Andrey, Title: Real-time human activity recognition from accelerometer data using Convolutional Neural Networks, , (2017), <http://dx.doi.org/10.1016/j.asoc.2017.09.27>
- [23] Babak Moradi, Mohammad Aghapour, Afshin Shirbandi, Compare of Machine Learning And Deep Learning Approaches for Human Activity Recognition, September 12, 2019
- [23.24]-Jindong Wang, Yiqiang Chen , Shuji Hao, Xiaohui Peng, Lisha Hu, Deep Learning for Sensor-based Activity Recognition: A Survey , Edison , Beijing, China,
- [23.25] Frédéric Li , Kimiaki Shirahama, Muhammad Adeel Nisar , Lukas Köping and Marcin Grzegorzek , Article Comparison of Feature Learning Methods for Human Activity Recognition Using Wearable Sensors , Department of Knowledge Engineering, University of Economics in Katowice, Bogucicka 3, 40-226 Katowice, Poland , Published: 24 February 2018
- [26] -Babak Moradi, Mohammad Aghapour, Afshin Shirbandi, Compare of Machine Learning And Deep Learning Approaches for Human Activity Recognition, September 12, 2019
- [27] ferhat attal physical human activity recognition using wearable sensors MDPI 11
Septembre 2015
- [28] <https://www.theengineeringprojects.com/?s=ARDUINO+mini+pro>
- [29] Ref img <https://electropeak.com/learn/wireless-communication-w-arduino-and-nrf24l01/>

- [30] MPU 6050 - Best IMU Sensor Tutorial - DIY Hacking <https://diyhacking.com/arduino-mpu-6050-imu-sensor-tutorial/>
- [31] <https://create.arduino.cc/projecthub/muhammad-aqib/nrf24l01-interfacing-with-arduino-wireless-communication-0c13d4>
- [32] la classification des images satellitaires par l'apprentissage profonde (deep learning), HABBA et Omar ISHAK ? Université Ahmed Draia – Adrar, 2019
- [33] <https://prograide.com/pregunta/48557/comment-mettre--jour-anaconda>
- [34] l'analyse du sentiment utilisant le deep learning, Medjdoubi Abdelkader, juin 2019, université of saida.
- [35] Real-time human activity recognition from accelerometer data using Convolutional Neural Networks, Ignatov Andrey, Applied Soft Computing,
- [36] United States Military Academy, West Point. (30/09/2021)
<https://www.westpoint.edu/ausa/helping-the-army-win/wearable-physiological-sensors>
- [37] Current Sports Medicine Reports. (30/09/2021)
https://journals.lww.com/acsm-csmr/fulltext/2018/06000/necessary_steps_to_accelerate_the_integration_of.4.aspx?utm_content=151381695&utm_medium=social&utm_source=facebook&hss_channel=fbp-164757956875283
- [38] I. Maiorescu, M. Bucur et al., Social Media and IOT Wearables in Developing Marketing Strategies. Do SMEs Dier From Large Enterprises?
- [39] C. Yang , G.S. Virk et al., Wearable Sensors and Robots Proceedings of International Conference on Wearable Sensors and Robots 2015.
- [40] Cao, Mingliang & Xie, Tianhua & Chen, Zebin. (2019). Wearable Sensors and Equipment in VR Games: A Review. 10.1007/978-3-662-59351-6_1.
- [41] MATLAB Deep Learning with Machine Learning, Neural Networks and Artificial Intelligence by Phil Kim.
- [42] Davide Anguita, Alessandro Ghio, Luca Oneto, Xavier Parra and Jorge L. Reyes-Ortiz. A Public Domain Dataset for Human Activity Recognition Using Smartphones. 21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2013. Bruges, Belgium 24–26 April 2013.
- [43] P. Cunningham, S. J. Delany . “k-Nearest neighbour classifiers”, Mult Classif Syst. Springer; (2007) 34: 1–17.
- [61] Ching, K.W.; Singh, M.M. Wearable Technology Devices Security and Privacy Vulnerability Analysis. Int. J. Netw. Secur. Its Appl. **2016**, *8*, 19–30.

- [62] Tarabasz, A.; Poddar, G. Factors influencing adoption of wearable devices in Dubai. *J. Econ. Manag.* **2019**, *36*, 123–143.
- [63] Chuah, S.H.W.; Rauschnabel, P.A.; Krey, N.; Nguyen, B.; Ramayah, T.; Lade, S. Wearable technologies: The role of usefulness and visibility in smartwatch adoption. *Comput. Hum. Behav.* **2016**, *65*, 276–284.
- [64] Khanra, S.; Dhir, A.; Mäntymäki, M. Big data analytics and enterprises: A bibliometric synthesis of the literature. *Enterp. Inform. Syst.* **2020**, *14*, 737–768.
- [65] Erevelles, S.; Fukawa, N.; Swayne, L. Big Data Consumer Analytics and the Transformation of Marketing. *J. Bus. Res.* **2016**, *69*, 897–904.
- [66] Xu, Z.; Frankwick, G.L.; Ramirez, E. Effects of Big Data Analytics and Traditional Marketing Analytics on New Product Success: A Knowledge Fusion Perspective. *J. Bus. Res.* **2016**, *69*, 1562–1566.
- [67] Dian, F.J.; Vahidnia, R.; Rahmati, A. Wearables and the Internet of Things (IoT), Applications, Opportunities, and Challenges: A Survey. *IEEE Access* **2020**, *8*, 69200–69211.
- [68] Page, T. A forecast of the adoption of wearable technology. In *Wearable Technologies: Concepts, Methodologies, Tools, and Applications*; IGI Global: Hershey, PA, USA, 2018; pp. 1370–1388.
- [69] Moon, N.W.; Baker, P.M.; Goughnour, K. Designing wearable technologies for users with disabilities: Accessibility, usability, and connectivity factors. *J. Rehabil. Assist. Technol. Eng.* **2019**, *6*.