





**Comparaison de l'efficacité du deep learning et de l'apprentissage automatique classique pour la reconnaissance d'activités humaine dans les habitats intelligents.**

**par Tchamba Kuinze Brondon Styve**

**Mémoire présenté à l'Université du Québec à Chicoutimi en vue de l'obtention du grade de Maître ès sciences (M. Sc.) en informatique (recherche)**

Québec, Canada

© brondon styve, Tchamba Kuinze, 2024

## RÉSUMÉ

Ce mémoire se penche sur la comparaison de l'efficacité du Deep Learning (DL), tel qu'illustré dans la littérature existante, avec celle de l'apprentissage automatique classique (ML) que nous avons personnellement développé, dans le domaine de la reconnaissance d'activités humaines dans les habitats intelligents. L'étude se concentre sur l'analyse critique des performances des méthodes de deep learning, basée sur des recherches antérieures, et les compare avec les résultats obtenus par les techniques traditionnelles de machine learning que nous avons développé.

L'introduction présente un aperçu des principes fondamentaux de l'intelligence artificielle, l'évolution du ML et du DL, et leur application dans les habitats intelligents. Le mémoire aborde également les défis et enjeux associés à ces technologies, notamment en termes de complexité et de ressources nécessaires.

La méthodologie adoptée dans ce travail repose sur une revue approfondie de la littérature sur les applications du DL dans la reconnaissance d'activités humaines, ainsi que sur le développement et l'optimisation des modèles de ML classiques. Une attention particulière est accordée à l'optimisation des hyperparamètres pour améliorer la performance de ces modèles.

Cette analyse est axée sur la comparaison directe de l'efficacité des méthodes de deep learning, telles qu'elles sont documentées dans la littérature existante, avec celle des techniques d'apprentissage automatique classique que nous avons développées. L'objectif est de déterminer dans quelle mesure le deep learning, souvent perçu comme plus avancé, se distingue réellement en termes d'efficacité par rapport à l'apprentissage automatique classique, en se concentrant spécifiquement sur les applications dans les habitats intelligents. Cette approche vise à éclairer la question cruciale de savoir si l'adoption du deep learning est systématiquement justifiée, ou si, dans certains cas, les méthodes traditionnelles de machine learning peuvent s'avérer tout aussi efficaces.

Le mémoire conclut sur une synthèse des découvertes, mettant en lumière les forces et les faiblesses de chaque approche. Il offre également une perspective critique sur l'applicabilité du DL par rapport au ML classique dans les habitats intelligents et propose des recommandations pour des recherches futures, basées sur les résultats obtenus.

## ABSTRACT

This dissertation delves into comparing the efficacy of deep learning (DL), as illustrated in existing literature, with that of classical machine learning (ML) techniques that we have personally developed in the domain of human activity recognition in smart habitats. The study focuses on a critical analysis of the performance of DL methods, based on prior research, and compares them with the results obtained from traditional ML techniques that we have implemented.

The introduction presents an overview of the fundamental principles of AI, the evolution of ML and DL, and their application in smart habitats. The dissertation also addresses the challenges and issues associated with these technologies, particularly in terms of complexity and the resources required.

The methodology adopted in this work is based on an extensive review of the literature on DL applications in human activity recognition, as well as on the development and optimization of classical ML models. Special attention is paid to the optimization of hyperparameters to enhance the performance of these models.

This analysis is centered on a direct comparison of the efficacy of deep learning methods, as documented in the existing literature, with that of classical machine learning techniques that we have developed. The objective is to determine to what extent deep learning, often perceived as more advanced, truly stands out in terms of efficacy compared to classical machine learning, specifically focusing on applications in smart habitats. This approach aims to shed light on the crucial question of whether the adoption of deep learning is systematically justified, or if, in some cases, traditional machine learning methods can prove to be just as effective.

The dissertation concludes with a synthesis of the findings, highlighting the strengths and weaknesses of each approach. It also offers a critical perspective on the applicability of DL compared to classical ML in smart habitats and proposes recommendations for future research based on the results obtained.

## TABLE DES MATIÈRES

|   |             |
|---|-------------|
| <b>RÉSUMÉ</b> .....   | <b>ii</b>   |
| <b>ABSTRACT</b> .....   | <b>iii</b>  |
| <b>TABLE DES MATIÈRES</b> .....   | <b>iv</b>   |
| <b>LISTE DES TABLEAUX</b> .....   | <b>vii</b>  |
| <b>LISTE DES FIGURES</b> .....  | <b>viii</b> |
| <b>LISTE DES ABRÉVIATIONS</b> .....   | <b>ix</b>   |
| <b>DEDICACE</b> .....   | <b>x</b>    |
| <b>REMERCIEMENTS</b> .....  | <b>xi</b>   |
| <b>CHAPITRE 1 : INTRODUCTION</b> .....  | <b>1</b>    |
| <b>1.1. MISE EN CONTEXTE</b> .....  | <b>1</b>    |
| <b>1.2. PROBLEMATIQUE</b> .....   | <b>2</b>    |
| <b>1.3. OBJECTIFS ET QUESTIONS DE RECHERCHE</b> .....                             | <b>3</b>    |
| <b>1.4. METHODOLOGIE</b> .....  | <b>4</b>    |
| <b>CHAPITRE 2 : CADRE THÉORIQUE DE L'APPRENTISSAGE AUTOMATIQUE</b> .....          | <b>6</b>    |
| <b>2.1. INTRODUCTION AUX PRINCIPES DE BASE DE L'IA</b> .....                      | <b>6</b>    |
| <b>2.2. FONDAMENTAUX DE L'APPRENTISSAGE AUTOMATIQUE ET DU DEEP LEARNING</b> ..... | <b>7</b>    |
| 2.2.1. Concepts clés et historique.....   | 7           |
| 2.2.2. Évolution de l'apprentissage automatique .....                             | 10          |
| 2.2.3. Enjeux éthiques et défis liés à l'IA et au deep learning .....             | 10          |
| <b>2.3. MODELES EN MACHINE LEARNING CLASSIQUE</b> .....                           | <b>11</b>   |
| 2.3.1. Support Vector Machines (SVM) .....  | 12          |
| 2.3.2. Arbres de décision .....   | 14          |
| 2.3.3. K-Nearest Neighbors (KNN) .....  | 17          |
| 2.3.4. Random forest .....  | 19          |
| 2.3.5. Xgboost .....  | 21          |
| 2.3.6. Naive bayes.....   | 23          |
| <b>2.4. DEEP LEARNING : TECHNIQUES ET APPLICATIONS</b> .....                      | <b>25</b>   |
| 2.4.1. Réseaux de neurones convolutifs (CNN).....                                 | 26          |
| 2.4.2. Réseaux de neurones récurrents (RNN) .....                                 | 29          |
| 2.4.3. Optimisation et techniques avancées pour les RNN.....                      | 30          |
| 2.4.4. Applications des RNN.....  | 32          |
| 2.4.5. Applications du DL en habitats intelligents.....                           | 33          |
| <b>CHAPITRE 3 : MÉTHODOLOGIE DE RECHERCHE</b> .....                               | <b>35</b>   |
| <b>3.1. INTRODUCTION</b> .....  | <b>35</b>   |
| <b>3.2. REVUE DE LA LITTÉRATURE ET SELECTION DES ARTICLES</b> .....               | <b>35</b>   |

|   |   |           |
|---|---|-----------|
| 3.2.1.  | Objectif de la revue de littérature .....   | 35        |
| 3.2.2.  | Méthodologie de recherche bibliographique .....                                   | 37        |
| 3.2.3.  | Processus de sélection des articles.....  | 38        |
| 3.2.4.  | Synthèse des travaux clés .....   | 39        |
| 3.2.4.1.  | Résultats et performances .....   | 41        |
| 3.2.4.2.  | Défis et limitations .....  | 42        |
| 3.2.4.3.  | Orientation vers le machine learning classique .....                              | 43        |
| 3.2.5.  | Analyse critique de la littérature .....  | 43        |
| <b>3.3.</b>                                     | <b>DESCRIPTION ET ANALYSE DES JEUX DE DONNEES SELECTIONNES .....</b>              | <b>46</b> |
| <b>3.4.</b>                                     | <b>MISE EN ŒUVRE DE L'APPRENTISSAGE AUTOMATIQUE CLASSIQUE.....</b>                | <b>57</b> |
| 3.4.1.  | Prétraitements et traitements des données pour Aruba.....                         | 57        |
| 3.4.1.1.  | Sélection des Caractéristiques .....  | 58        |
| 3.4.1.2.  | Normalisation et prétraitement des données.....                                   | 60        |
| 3.4.1.3.  | Techniques de validation croisée utilisées pour évaluer les modèles. ....         | 61        |
| 3.4.2.  | Prétraitements et traitements des données pour le UCI-HAR.....                    | 61        |
| 3.4.3.  | Prétraitements et traitements des données pour ESC-50 ET KITCHEN 20.....          | 64        |
| <b>3.5.</b>                                     | <b>CHOIX ET PARAMETRAGE DES MODELES D'APPRENTISSAGE AUTOMATIQUE .....</b>         | <b>68</b> |
| 3.5.1.  | Sélection des modèles pour chaque jeu de données .....                            | 69        |
| 3.5.2.  | Configuration et optimisation des paramètres .....                                | 70        |
| 3.5.3.  | Optimisation des hyperparamètres .....  | 71        |
| <b>3.6.</b>                                     | <b>STRATEGIES D'ÉVALUATION DES MODELES .....</b>                                  | <b>72</b> |
| <b>CHAPITRE 4 : RÉSULTATS ET ANALYSES .....</b> | <b>74</b>   |           |
| <b>4.1.</b>                                     | <b>INTRODUCTION.....</b>  | <b>74</b> |
| <b>4.2.</b>                                     | <b>RESULTATS SUR LE JEU DE DONNÉES ARUBA.....</b>                                 | <b>75</b> |
| 4.2.1.  | Random forest sur le jeu de données Aruba .....                                   | 75        |
| 4.2.2.  | KNN sur le jeu de données Aruba .....   | 76        |
| 4.2.3.  | SVM sur le jeu de données Aruba.....  | 78        |
| 4.2.4.  | Arbre de décision sur le jeu de données Aruba .....                               | 78        |
| 4.2.5.  | Performance des autres modèles sur le jeu de données Aruba .....                  | 79        |
| 4.2.6.  | Comparaison et analyse critique des performances sur le jeu de données Aruba..... | 80        |
| <b>4.3.</b>                                     | <b>RESULTATS SUR LE JEU DE DONNEES UCI-HAR.....</b>                               | <b>82</b> |
| 4.3.1.  | KNN sur le jeu de données UCI-HAR.....  | 83        |
| 4.3.2.  | SVM sur le jeu de données UCI-HAR .....   | 84        |
| 4.3.3.  | Random forest sur le jeu de données UCI-HAR .....                                 | 86        |
| 4.3.4.  | Performance des autres modèles sur le jeu de données UCI-HAR .....                | 87        |
| 4.3.5.  | Discussion sur la pertinence des résultats du UCI-HAR .....                       | 88        |
| 4.3.6.  | Points forts et limitations des modèles sur le UCI-HAR .....                      | 89        |
| <b>4.4.</b>                                     | <b>RESULTATS SUR LE ESC-50 ET KITCHEN 20 JEU DE DONNÉES .....</b>                 | <b>90</b> |
| 4.4.1.  | Random forest sur le jeu de données ESC-50 et Kitchen 20.....                     | 90        |
| 4.4.2.  | SVM sur le jeu de données ESC-50 et Kitchen 20 .....                              | 92        |
| 4.4.3.  | KNN sur le jeu de données ESC-50 et Kitchen 20 .....                              | 92        |
| 4.4.4.  | Approche après collaboration avec les auteurs de X-CHAR .....                     | 93        |
| 4.4.5.  | Interprétation des résultats et leurs implications .....                          | 95        |
| <b>4.5.</b>                                     | <b>DISCUSSION SUR LA NECESSITE DU DEEP LEARNING .....</b>                         | <b>97</b> |

|  |   |            |
|--|---|------------|
| 4.5.1.   | Implications pour les habitats intelligents .....   | 98         |
| <b>4.6.</b>  | <b>COMPARAISON GLOBALE DES RESULTATS .....</b>  | <b>99</b>  |
| 4.6.1.   | Jeu de donnée Aruba .....   | 99         |
| 4.6.2.   | Jeu de données UCI-HAR .....  | 100        |
| 4.6.3.   | Jeu de données combiné ESC-50 ET KITCHEN 20 .....   | 102        |
| 4.6.4.   | Perspectives sur l'efficacité relative du machine learning classique vs deep learning ..... | 104        |
| 4.6.5.   | Recommandations pratiques basées sur les résultats .....                                    | 107        |
| <b>4.7.</b>  | <b>SYNTHESE ET CONCLUSION DU CHAPITRE .....</b>   | <b>108</b> |
| <b>CHAPITRE 5 : CONCLUSION ET PERSPECTIVES .....</b> |   | <b>110</b> |
| <b>5.1.</b>  | <b>SYNTHESE DES RESULTATS.....</b>  | <b>110</b> |
| <b>5.2.</b>  | <b>CONTRIBUTIONS DE LA RECHERCHE .....</b>  | <b>112</b> |
| <b>5.3.</b>  | <b>LIMITES ET DEFIS DE LA RECHERCHE.....</b>  | <b>114</b> |
| 5.3.1.   | Défis rencontres pendant la recherche.....  | 116        |
| <b>5.4.</b>  | <b>IMPLICATIONS PRATIQUES POUR LES HABITATS INTELLIGENTS .....</b>                          | <b>117</b> |
| 5.4.1.   | Application des résultats dans les habitats intelligents .....                              | 118        |
| <b>5.5.</b>  | <b>PERSPECTIVES ET RECOMMANDATIONS .....</b>  | <b>120</b> |
| 5.5.1.   | Directions de recherche future.....   | 121        |
| 5.5.2.   | Implications pratiques et théoriques .....  | 122        |
| <b>BIBLIOGRAPHIE .....</b>                           |   | <b>124</b> |

## LISTE DES TABLEAUX

|   |            |
|---|------------|
| <i>Tableau 1 : Récapitulation des résultats appliqués sur Aruba par random forest.....</i>  | <i>76</i>  |
| <i>Tableau 2 : Récapitulation des résultats appliqués sur Aruba par les KNN.....</i>  | <i>77</i>  |
| <i>Tableau 3 : Récapitulation des résultats appliqué sur Aruba par les arbres de décision.....</i>  | <i>79</i>  |
| <i>Tableau 5 : Récapitulation des résultats appliqué sur UCI-HAR par les KNN.....</i>   | <i>83</i>  |
| <i>Tableau 6 : Récapitulation des résultats appliqué sur UCI-HAR par les SVM.....</i>   | <i>85</i>  |
| <i>Tableau 7 : Récapitulation des résultats appliqué sur UCI-HAR par les Random Forest.....</i>   | <i>86</i>  |
| <i>Tableau 8 : Tableau de Comparaison des performances des modèles de ML et de DL sur le Jeu de données Aruba.....</i>                      | <i>99</i>  |
| <i>Tableau 9 : Tableau de Comparaison de performances des modèles de ML et de DL sur le jeu de données uci-har.....</i>                     | <i>101</i> |
| <i>Tableau 10 : Tableau de comparaison des performances des modèles ML et DL sur les jeux de données combinés ESC-50 et Kitchen 20.....</i> | <i>103</i> |



## LISTE DES FIGURES

|  |           |
|--|-----------|
| <i>Figure 1 : Structure Générale du modèle SVM.....</i>  | <i>12</i> |
| <i>Figure 2 : Représentation générale du plan de classification hyperplan de l'algorithme SVM. ....</i>                            | <i>13</i> |
| <i>Figure 3 : Exemple d'illustration d'un arbre de décision.....</i>   | <i>16</i> |
| <i>Figure 4 : illustration du fonctionnement de l'algorithme de KNN.....</i>   | <i>18</i> |
| <i>Figure 5 : illustration graphique de Random Forest.....</i>   | <i>20</i> |
| <i>Figure 6 : illustration graphique de l'algorithme de XgBoost. ....</i>  | <i>22</i> |
| <i>Figure 7 : Illustration du principe de fonctionnement du Naïve Bayes .....</i>  | <i>24</i> |
| <i>Figure 8 : illustration CNN.....</i>  | <i>28</i> |
| <i>Figure 9 : Illustration du fonctionnement des RNN.....</i>  | <i>30</i> |
| <i>Figure 10 : Format du jeu de données Aruba.....</i>   | <i>51</i> |
| <i>Figure 11: Représentation d'un audio du jeu de données en fonction de l'amplitude et du temps...</i>                            | <i>54</i> |
| <i>Figure 12 : Répartition des différentes catégories de notre jeu de données .....</i>  | <i>65</i> |
| <i>Figure 13 : Matrice de confusion du meilleur résultat de KNN sur Aruba.....</i>   | <i>77</i> |
| <i>Tableau 4 : Meilleures performances en termes de précision pour chaque modèle testé.....</i>                                    | <i>80</i> |
| <i>Figure 14 : Matrice de confusion du meilleur résultat de SVM sur UCI-HAR.....</i>   | <i>85</i> |
| <i>Figure 15 : Matrice de confusion du meilleur résultat des Random Forest sur ESC 50 et Kitchen 20 combiné.....</i>               | <i>91</i> |
| <i>Figure 16 : Matrice de confusion du résultat des Random Forest sur ESC 50 et Kitchen 20 combiné provenant des auteurs .....</i> | <i>94</i> |

## LISTE DES ABRÉVIATIONS

**ML:** Machine Learning

**DL:** Deep Learning

**AI:** Intelligence Artificielle

**HAR:** Human Activity Recognition

**UCI:** University of California Irvine

**ESC-50:** Environmental Sound Classification 50

**KNN:** K-Nearest Neighbors

**SVM:** Support Vector Machine

**PCA:** Principal Component Analysis

**RBF:** Radial Basis Function

**LSTM:** Long Short-Term Memory

**BLSTM:** Bidirectional Long Short-Term Memory

**RNN:** Recurrent Neural Network

**IoT:** Internet of Things

**BPTT :** Backpropagation Through Time

## DEDICACE

À mes chers parents,

Ce mémoire est le fruit d'un long parcours, un chemin parsemé d'apprentissages, de défis et de réalisations. Aujourd'hui, alors que je referme cette page significative de ma vie, je désire dédier ce travail à vous deux, mes piliers inébranlables et mes premiers guides dans la vie.

Vous m'avez enseigné la valeur de la persévérance, de l'humilité et du travail acharné. Vous avez nourri mes rêves et soutenu mes ambitions, même lorsque le chemin semblait incertain. Votre amour inconditionnel, votre soutien sans faille et votre foi indéfectible en mes capacités m'ont permis de me surpasser et d'atteindre cet accomplissement.

Chaque page de ce mémoire porte l'empreinte de votre amour et de votre sagesse et de vos encouragements. Votre exemple m'a inspiré à poursuivre mes objectifs avec détermination et intégrité. Vous m'avez appris que le savoir est une lumière qui éclaire le chemin de la vie, et grâce à vous, j'ai marché avec confiance vers cette lumière.

Avec toute ma gratitude et mon amour, je vous dédie ce mémoire, symbole de mon parcours et de votre présence indélébile à chaque étape.

## REMERCIEMENTS

La réalisation de ce mémoire représente l'aboutissement d'un parcours enrichissant et stimulant, rendu possible grâce à l'accompagnement et au soutien de plusieurs personnes. C'est avec une profonde gratitude que je souhaite exprimer ma reconnaissance envers celles et ceux qui ont contribué à ce travail.

Je tiens tout d'abord à adresser mes remerciements les plus sincères à mon directeur de mémoire, le professeur Kevin Bouchard. Sa patience, sa disponibilité et ses conseils avisés ont été des atouts précieux qui ont nourri ma réflexion et guidé mon travail. Son expertise et son encouragement ont été des éléments déterminants dans l'accomplissement de ce projet.

Je suis également reconnaissant envers le directeur du programme et les professeurs de l'Université du Québec à Chicoutimi (UQAC). Leurs enseignements et leur pédagogie m'ont permis d'acquérir les connaissances fondamentales et de développer les compétences nécessaires pour mener à bien cette recherche.

Un merci tout spécial à mon épouse, pour son soutien indéfectible, sa compréhension et sa présence constante à mes côtés malgré la distance. Sa force et son encouragement m'ont été d'un grand réconfort durant les moments de doute et de persévérance.

Ma famille mérite également toute ma reconnaissance. Votre soutien inconditionnel, votre confiance et vos encouragements ont été une source de motivation constante. Je vous dédie ce mémoire en gage de ma profonde gratitude et de mon affection.

Enfin, je souhaite exprimer ma gratitude envers mes amis et collègues. Votre soutien moral et intellectuel a été un pilier essentiel tout au long de mon parcours. Vos conseils, vos discussions stimulantes et votre solidarité ont grandement contribué à l'aboutissement de ce travail.

# CHAPITRE 1

## INTRODUCTION

### 1.1. MISE EN CONTEXTE

L'apprentissage automatique (ML), une composante essentielle de l'intelligence artificielle (IA), permet aux systèmes d'apprendre et de s'améliorer à partir des données sans être explicitement programmés [1]. Le ML s'appuie sur des algorithmes pour analyser et interpréter des données, afin de prendre des décisions ou de faire des prédictions basées sur ces informations. Des outils comme WEKA et Scikit-learn, sont essentiels pour le data mining et la mise en œuvre d'algorithmes d'apprentissage automatique [2] [3]. Par ailleurs, des bibliothèques comme TensorFlow et PyTorch fournissent des plateformes avancées pour le développement de modèles de deep learning (DL), gérant efficacement des réseaux de neurones complexes et des grands volumes de données [4].

Le DL, une branche avancée du ML, s'est imposé comme un élément crucial de l'IA, en particulier dans les domaines de la vision par ordinateur et du traitement automatique du langage naturel [5]. Sa capacité à traiter d'importantes quantités de données non structurées a ouvert des perspectives nouvelles dans la recherche et les applications industrielles [6] [7].

L'impact de l'IA et du ML est notable dans divers secteurs, notamment la santé, la finance et l'automobile. Dans la santé, l'IA contribue à des diagnostics plus précis [8], tandis que dans le secteur financier, elle est utilisée pour la prédiction des tendances du marché et la gestion des risques [9].

Un domaine d'application particulièrement prometteur de l'IA est celui des habitats intelligents. Ces environnements intègrent l'automatisation et l'IA pour améliorer de gestion des ressources, la réduction des déchets et la durabilité [10]. Les systèmes d'IA dans les habitats intelligents ajustent les paramètres tels que l'éclairage et la température en apprenant des habitudes des résidents, optimisant ainsi la qualité de vie et prédire les prochaines activités [11].

## **1.2. PROBLEMATIQUE**

Malgré l'essor et la popularité croissante du deep learning (DL), des questions cruciales émergent concernant son application systématique dans divers domaines. L'une des préoccupations majeures réside dans la nécessité et la complexité des méthodes de DL. Bien que puissants, ces modèles avancés sont souvent confrontés à des défis en termes de compréhension et d'explication de leur fonctionnement interne, ce qui soulève des questions d'interprétabilité et de transparence [12].

En outre, le DL, en raison de sa nature complexe et de sa dépendance à de grandes quantités de données, exige des ressources considérables, tant en termes de puissance de calcul que de stockage de données. Cette exigence entraîne des coûts élevés et une plus grande empreinte carbone, ce qui rend difficile son application dans des contextes à ressources limitées ou dans des environnements soucieux de leur impact écologique [13].

L'adoption généralisée du DL soulève également des inconvénients notables. La dépendance aux grandes quantités de données et la nécessité d'une puissance de calcul élevée

limitent son accessibilité et son efficacité dans des situations où de telles ressources ne sont pas disponibles [14]. De plus, la complexité des modèles de DL peut mener à des difficultés dans leur mise en œuvre et leur maintenance, en particulier pour les équipes avec une expertise limitée dans ce domaine spécifique rendant impossible l'atteinte de jalons de référence importants si les tendances actuelles se maintiennent [14].

Ces considérations soulignent la nécessité d'une évaluation critique et d'une comparaison avec des méthodes alternatives, telles que l'apprentissage automatique classique, qui peuvent offrir des solutions plus simples, moins coûteuses et plus explicables dans certaines applications. L'examen de ces alternatives devient d'autant plus pertinent dans le contexte des habitats intelligents, où l'efficacité, la simplicité d'usage et la durabilité sont des facteurs clés.

### **1.3. OBJECTIFS ET QUESTIONS DE RECHERCHE**

La progression fulgurante et l'intégration du deep learning (DL) dans diverses applications soulèvent des interrogations quant à son omniprésence par rapport aux méthodes traditionnelles d'apprentissage automatique (ML). Cette recherche vise donc à explorer la pertinence actuelle du DL, en questionnant son rôle et son impact dans les travaux contemporains. Elle s'interroge sur la nécessité de cette technologie avancée dans les contextes où des méthodes de ML classique pourraient s'avérer suffisantes ou même supérieures.

Un des objectifs clés de cette étude est d'évaluer la possibilité de reproduire ou de rivaliser avec les résultats obtenus par le DL en utilisant des techniques de ML classique. Cela implique le développement et l'optimisation de modèles ML classiques dans le but de

les comparer directement aux modèles de DL, particulièrement dans le contexte des habitats intelligents. Cette comparaison vise à déterminer si les méthodes de ML classique peuvent offrir des avantages significatifs, tels que la simplicité, la moindre consommation de ressources, ou une meilleure interprétabilité, tout en maintenant ou en améliorant les niveaux de performance.

Au travers de cette recherche, plusieurs hypothèses seront examinées. Parmi celles-ci, l'hypothèse selon laquelle les modèles de ML classique peuvent égaler ou même surpasser les modèles de DL dans certains scénarios d'application, notamment en termes d'efficacité et de facilité d'utilisation. En outre, l'étude vise à identifier les situations où l'adoption du DL est justifiée par rapport aux alternatives plus simples de ML, en prenant en compte des facteurs tels que la complexité des données, les exigences de performance et les contraintes de ressources.

L'objectif ultime est de fournir des recommandations éclairées et des directives pratiques pour le choix entre le DL et le ML classique dans le développement d'applications intelligentes, notamment dans les habitats intelligents. Cette étude aspire à contribuer au domaine de l'IA en offrant une perspective nuancée sur l'utilisation judicieuse de ces technologies puissantes.

#### **1.4. METHODOLOGIE**

L'approche méthodologique adoptée pour cette étude est conçue pour aborder de manière exhaustive les questions de recherche et tester les hypothèses formulées. La méthodologie repose sur une combinaison de revue systématique de la littérature existante et de recherche pratique. La revue de la littérature se concentre sur les études existantes concernant le DL et



ses applications, en particulier dans le contexte des habitats intelligents. Cette revue permet de comprendre le paysage actuel du DL, ses avancées, ses défis, ainsi que les domaines où il a été appliqué avec succès.

En parallèle, une série d'expérimentations pratiques sera menée pour mettre en œuvre et évaluer des modèles de ML classique. Ces expérimentations visent à reproduire ou à rivaliser avec les performances des modèles de DL documentés dans la littérature, en utilisant des jeux de données pertinents pour les habitats intelligents. L'analyse comparative des résultats obtenus à partir de ces modèles classiques face aux modèles de DL fournira des compréhensions précieuses sur leur efficacité relative.

La méthodologie choisie permettra également d'évaluer la facilité d'utilisation, la complexité de mise en œuvre, et l'efficacité des ressources des différentes approches. L'objectif est de déterminer non seulement quelle approche est la plus performante en termes de résultats, mais aussi laquelle est la plus pratique et durable dans une perspective d'application réelle.

En conclusion, cette recherche vise à apporter une contribution significative au domaine de l'IA en offrant une analyse comparative détaillée du DL et du ML classique. Les résultats de cette étude ont pour ambition d'informer les décideurs, les chercheurs et les praticiens sur le choix le plus judicieux des technologies d'IA dans le développement d'applications intelligentes, en mettant l'accent sur les habitats intelligents. Cette approche méthodologique rigoureuse garantit que les conclusions tirées seront fondées sur des données pratiques, solides et une analyse critique approfondie.

## **CHAPITRE 2**

### **CADRE THÉORIQUE DE L'APPRENTISSAGE AUTOMATIQUE**

#### **2.1. INTRODUCTION AUX PRINCIPES DE BASE DE L'IA**

L'intelligence artificielle (IA) constitue le fondement sur lequel repose l'apprentissage automatique (ML) et le deep learning (DL). Comprendre les principes de base de l'IA est essentiel pour appréhender la manière dont les machines peuvent simuler l'intelligence humaine. L'IA englobe un ensemble de techniques visant à doter les systèmes informatiques de la capacité d'effectuer des tâches qui exigeraient normalement l'intelligence humaine. Cela inclut la résolution de problèmes, la reconnaissance de motifs, et la prise de décisions. On distingue généralement deux catégories d'IA : l'IA faible (ou étroite) et l'IA forte (ou générale). L'IA faible se spécialise dans des tâches spécifiques, tandis que l'IA forte vise à égaler l'intelligence humaine dans tous les domaines [15], [16].

L'IA tire parti du ML pour permettre aux systèmes d'apprendre à partir de données et d'améliorer leurs performances au fil du temps. Le ML est le mécanisme par lequel les machines ajustent leurs actions en fonction de l'expérience acquise. Le DL, en tant que sous-domaine de l'IA, repose sur des réseaux de neurones profonds pour effectuer des tâches complexes telles que la reconnaissance d'images, la traduction automatique, et bien d'autres [17]. Cette approche s'inspire du fonctionnement du cerveau humain avec des couches de neurones interconnectées. Bien évidemment, l'intégration croissante de l'IA soulève des questions éthiques et sociétales. La transparence des décisions prises par les algorithmes, la

protection de la vie privée, et la prévention des biais algorithmiques sont des préoccupations cruciales [18].

## **2.2. FONDAMENTAUX DE L'APPRENTISSAGE AUTOMATIQUE ET DU DEEP LEARNING**

L'apprentissage automatique (ML) constitue le socle de l'intelligence artificielle (IA), permettant aux systèmes de développer des capacités d'analyse et de prise de décision à partir des données. Dans cette section, nous explorerons les principes fondamentaux du ML, mettant en lumière son évolution et son importance croissante dans divers domaines.

Le deep learning (DL), en tant que sous-domaine spécialisé du ML, sera également examiné en détail. À travers l'utilisation de réseaux de neurones profonds, le DL a révolutionné la capacité des machines à comprendre et à interpréter des données complexes, notamment dans des domaines tels que la vision par ordinateur et le traitement du langage naturel.

Cette exploration des fondamentaux jettera les bases nécessaires pour comprendre les implications de ces techniques dans le contexte spécifique des habitats intelligents.

### **2.2.1. Concepts clés et historique**

L'apprentissage automatique est un sous-domaine de l'intelligence artificielle qui se concentre sur le développement d'algorithmes capables d'apprendre à partir de données et de faire des prédictions ou des décisions sans être explicitement programmés pour chaque tâche spécifique [1]. Cela implique la création de modèles mathématiques qui traitent et interprètent efficacement les données complexes.

La base théorique de l'apprentissage automatique s'ancre dans des disciplines telles que les statistiques, la théorie de la probabilité, l'informatique, et l'optimisation. L'objectif est de construire des modèles qui peuvent généraliser à partir de données d'entraînement pour effectuer des tâches telles que la classification, la régression, ou la détection d'anomalies sur de nouvelles données non vues [19]. Contrairement à la programmation traditionnelle, où les règles et les logiques sont définies par les programmeurs, l'apprentissage automatique permet aux machines d'apprendre ces règles à partir des données. Cela se traduit par une capacité à traiter des problèmes complexes qui seraient difficiles, voire impossibles, à coder manuellement [20]. Au fil du temps, l'apprentissage automatique est devenu un pilier central de nombreux systèmes technologiques avancés, influençant des domaines allant de la reconnaissance d'image à la conduite autonome. Son impact continu sur la société et l'industrie souligne son importance croissante dans le monde moderne [21].

L'apprentissage automatique se situe à l'intersection de plusieurs disciplines scientifiques et mathématiques. Les statistiques fournissent des méthodes pour l'analyse et l'interprétation des données, tandis que la théorie de la probabilité offre un cadre pour comprendre et modéliser l'incertitude. L'informatique apporte des algorithmes et des techniques de calcul, et l'optimisation se concentre sur la recherche de solutions optimales dans des espaces de problèmes complexes. Dans l'univers de l'apprentissage automatique, il est essentiel de développer des modèles mathématiques qui captent les tendances ou les schémas dans les données. Ces modèles servent ensuite à tirer des conclusions, telles que la prédiction de résultats futurs ou le classement des données en différentes catégories [22]. Un enjeu clé en apprentissage automatique est l'équilibre entre l'ajustement aux données d'entraînement et la

capacité de généraliser à de nouvelles données. Le surajustement se produit lorsque les modèles apprennent trop bien les détails spécifiques des données d'entraînement au détriment de leur performance sur de nouvelles données. Des techniques comme la validation croisée et la régularisation sont utilisées pour atténuer ce problème [23].

L'apprentissage automatique comprend deux grandes catégories : supervisé et non supervisé. L'apprentissage supervisé utilise des données étiquetées pour entraîner des modèles, tandis que l'apprentissage non supervisé trouve des modèles ou des structures dans des données non étiquetées. Chaque catégorie a ses propres défis et approches [24]. L'apprentissage par renforcement est une autre branche importante de l'apprentissage automatique, qui se concentre sur la manière dont les agents devraient agir dans un environnement pour maximiser une notion de récompense cumulative. Contrairement à l'apprentissage supervisé et non supervisé, l'apprentissage par renforcement est caractérisé par une interaction entre l'agent d'apprentissage et son environnement, où l'agent apprend à atteindre un objectif en expérimentant et en adaptant ses actions en fonction des retours qu'il reçoit. Cette approche est particulièrement pertinente dans les domaines où la prise de décision séquentielle est cruciale, comme les jeux, la navigation des robots, ou certaines applications en finance. Les algorithmes d'apprentissage par renforcement ont connu des avancées significatives ces dernières années, notamment avec des succès notables dans des domaines complexes comme les jeux de stratégie et les véhicules autonomes [25].

Ces fondements théoriques forment la base sur laquelle repose l'apprentissage automatique moderne, offrant un cadre pour développer des solutions innovantes à des

problèmes complexes. La compréhension de ces principes est essentielle pour apprécier la portée et l'efficacité de l'apprentissage automatique dans divers contextes.

### **2.2.2. Évolution de l'apprentissage automatique**

L'évolution de l'apprentissage automatique est caractérisée par des avancées significatives et des changements paradigmatiques, marquant des transitions importantes dans le domaine de l'IA. Initialement, l'IA se concentrait plutôt sur la logique, où des règles symboliques étaient employées pour résoudre des problèmes. Cette approche a révélé ses limites face à la complexité des connaissances, incitant un virage vers le ML statistique qui privilégie l'apprentissage à partir de données sans règles explicites, avec des méthodes comme la régression linéaire et les machines à vecteurs de support [26], [27]. Le passage au DL, s'appuyant sur les réseaux de neurones profonds, a engendré des progrès notables, notamment dans la vision par ordinateur et le traitement du langage naturel, grâce à des architectures innovantes telles que les CNN et les RNN [26]. Toutefois, cette avancée a introduit des défis liés à la gestion des données massives nécessaires à l'entraînement de modèles complexes. Les tendances actuelles se concentrent sur l'amélioration de l'efficacité des modèles, l'augmentation de leur interprétabilité et la capacité d'apprendre avec des données limitées, aspects cruciaux pour optimiser les systèmes dans les habitats intelligents et améliorer le bien-être des résidents.

### **2.2.3. Enjeux éthiques et défis liés à l'IA et au deep learning**

L'IA et le DL présentent des enjeux éthiques significatifs, notamment la protection de la confidentialité avec l'exploitation massive des données. Il est crucial d'adopter des mesures rigoureuses pour sauvegarder la vie privée. Les biais dans l'IA posent problème, exigeant

des efforts pour les réduire et assurer une utilisation juste. La complexité des systèmes de DL requiert des explications claires sur leur fonctionnement et décisions. La responsabilité en cas d'erreurs des systèmes d'IA nécessite une attribution précise, soulignant l'importance d'une gestion éthique et transparente de ces technologies.

Outre les préoccupations morales, l'IA et le DL présentent des défis pratiques qui nécessitent une approche réfléchie pour une utilisation judicieuse de ces technologies. L'automatisation par l'IA peut avoir un impact significatif sur l'emploi et la société, nécessitant une révision des programmes de formation professionnelle et une gestion efficace des changements sociaux et économiques associés. La sécurité des systèmes d'IA est également une préoccupation majeure, car ces systèmes peuvent être vulnérables aux attaques. Il est donc essentiel de renforcer la sécurité de ces systèmes pour les utiliser en toute confiance et minimiser les risques liés à d'éventuelles intrusions. En outre, l'IA soulève des questions sociales et philosophiques profondes qui nécessitent une réflexion approfondie. Ces questions portent notamment sur la nature de l'intelligence, la possibilité pour une IA d'avoir une conscience, et les implications philosophiques de la création d'entités intelligentes [28].

### **2.3. MODELES EN MACHINE LEARNING CLASSIQUE**

Dans cette partie, il sera question de présenter les principaux modèles et algorithmes utilisés dans le cadre du machine learning traditionnel. En explorant cette section, nous présentons les bases du d'apprentissage automatique classique, y compris les modèles de régression, les méthodes d'apprentissage supervisé et non supervisé, ainsi que les techniques de classification et de clustering.

### 2.3.1. Support Vector Machines (SVM)

Les SVM, ou machine à vecteurs de support, sont un des modèles les plus robustes et polyvalents en ML classique. Nés dans les années 1990, les SVM ont gagné en popularité grâce à leur capacité à effectuer à la fois des classifications linéaires et non linéaires avec une grande précision. Ce modèle est particulièrement réputé pour sa capacité à gérer des espaces de caractéristiques de haute dimension et pour sa flexibilité dans le choix des fonctions de noyau, ce qui lui permet de s'adapter à une grande variété de données.

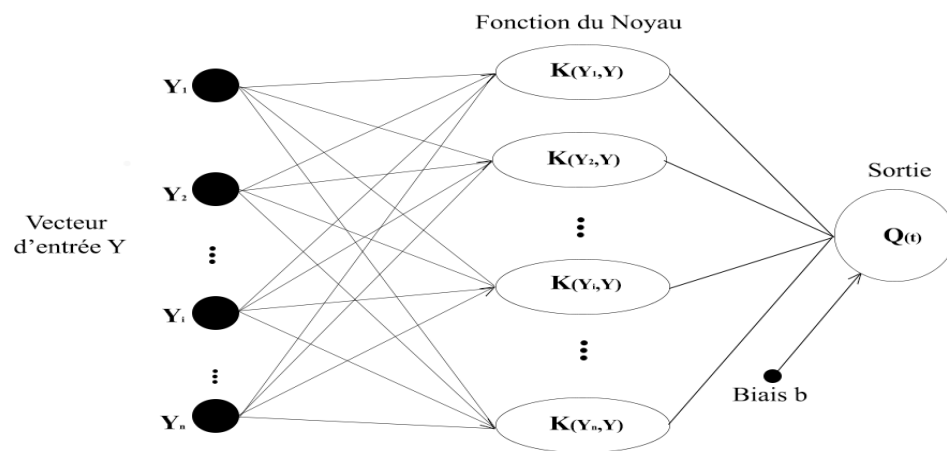


Figure 1 : Structure Générale du modèle SVM

©Brondon Styve, 2024.

Comme présenté sur la figure 1, SVM prend les données d'entrée, les transforme pour faciliter leur séparation à l'aide d'une fonction du noyau, puis utilise ces informations transformées pour déterminer à quelle classe chaque donnée appartient en trouvant l'hyperplan optimal de séparation. Les principes de base et le fonctionnement des SVM reposent sur la recherche d'un hyperplan optimal dans l'espace des caractéristiques, qui sépare de manière maximale les différentes classes de données comme mentionné dans la figure 2. Cet hyperplan vise à maximiser la marge entre les points de données les plus proches de chaque classe, connus sous le nom de vecteurs de support [29].



Les SVM sont des outils puissants pour la classification de données, capables de gérer à la fois les problèmes linéaires et non linéaires. Pour les problèmes linéaires, ils cherchent le meilleur hyperplan qui sépare les données. Pour les cas non linéaires, ils utilisent des fonctions de noyau comme linéaire, polynomial, ou RBF (Radial Basis Function) pour projeter les données dans un nouvel espace où elles peuvent être séparées linéairement. Le choix de la fonction du noyau est essentiel, influençant directement la performance du modèle en fonction de la complexité des données. Grâce à l'optimisation de la marge entre les catégories, les SVM sont particulièrement efficaces, même avec peu de données, en offrant des modèles robustes et précis adaptés à divers contextes complexes.

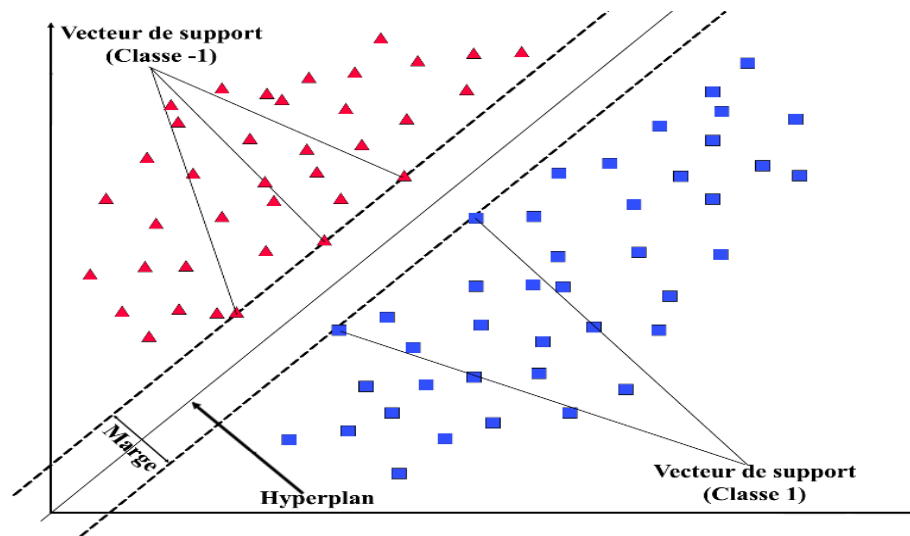


Figure 2 : Représentation générale du plan de classification hyperplan de l'algorithme SVM.

©Brondon Styve,2024.

Les SVM trouvent des applications variées grâce à leur polyvalence et efficacité, couvrant des secteurs tels que la reconnaissance d'images et de visages [30], le traitement du langage naturel pour la classification de textes et la reconnaissance vocale [31], la bio-informatique pour la classification de protéines et la prédiction de fonctions génétiques [32],

ainsi que la finance pour la prédiction de mouvements boursiers et le scoring de crédit [33]. Leur capacité à gérer des caractéristiques de haute dimension et à traiter efficacement le bruit dans les données les rend idéaux pour des tâches complexes, y compris la détection de fraude. Ces exemples illustrent l'aptitude des SVM à offrir des solutions précises et robustes dans divers domaines, soulignant leur importance en tant qu'outil d'analyse de données.

Les SVM présentent plusieurs avantages en apprentissage automatique. Ils sont efficaces dans les espaces de grande dimension, traitant ainsi des jeux de données complexes. Leur flexibilité à gérer des données non linéaires grâce aux fonctions noyau élargit leur applicabilité. De plus, les SVM sont stables et conservent une performance robuste, même en présence de dimensions élevées. Leur polyvalence les rend adaptés à la classification, la régression et la détection d'anomalies. Cependant, ils peuvent montrer une sensibilité à la taille des données et nécessitent un choix critique du noyau, ce qui peut limiter leur interprétabilité et augmenter la complexité computationnelle lors de l'entraînement sur de grands ensembles de données. Ces inconvénients soulignent l'importance d'une analyse approfondie avant leur utilisation en apprentissage automatique.

### **2.3.2. Arbres de décision**

Les arbres de décision sont parmi les algorithmes les plus intuitifs et accessibles en ML. Leur popularité repose sur leur simplicité et leur transparence : un arbre de décision modélise les décisions et leurs conséquences potentielles sous forme d'un arbre graphique. Un arbre de décision se présente comme une séquence hiérarchique de règles logiques construites automatiquement à partir d'un ensemble de données. L'élaboration de cet arbre implique l'utilisation de descripteurs pour subdiviser graduellement l'ensemble en sous-

groupes de plus en plus spécifiques. L'algorithme estime la probabilité qu'une observation se trouve dans le nœud  $t$  en utilisant la formule :

$$P(T) = \sum_{j \in T} W_j$$

Où  $W_j$  représente le poids des observations,  $T$  est l'ensemble de tous les indices d'observations du nœud  $t$ , et  $n$  est le nombre d'observations.

Les arbres de décision sont des modèles de classification basés sur l'apprentissage supervisé. Ils adoptent une structure arborescente composée de nœuds, de branches et de feuilles. La construction de ces arbres s'effectue à partir d'une base de données brute (vecteur des caractéristiques et classes) en utilisant des règles déterminantes pour une classification efficace des futures données. Chaque nœud de l'arbre représente une règle de classification déterminée de manière récursive[34]. La construction d'un arbre de décision débute avec le nœud racine, où les données sont divisées en sous-ensembles selon une caractéristique. Ce processus se répète de manière récursive pour former la structure arborescente comme sur figure 3. Les critères de division incluent l'indice de Gini, l'entropie et la réduction de variance. Pour éviter le surajustement, l'élagage est crucial, consistant à retirer les parties peu informatives de l'arbre. Les arbres de décision offrent une grande visibilité et sont facilement interprétables grâce à leur représentation graphique, ce qui en fait des outils puissants pour la classification et la régression, notamment lorsque la compréhension et l'explication du modèle sont essentielles.

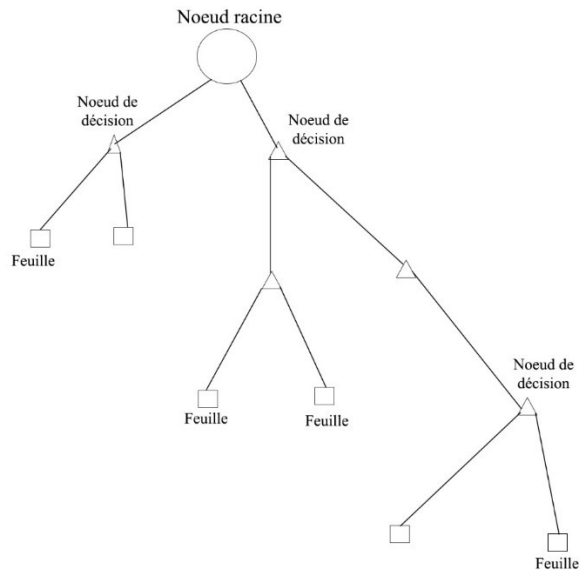


Figure 3 : Exemple d'illustration d'un arbre de décision

©Brondon Styve,2024.

Les arbres de décision sont des outils intuitifs et transparents, adaptés à ceux qui ne sont pas des experts en apprentissage automatique, car chaque nœud représente une règle de décision simple. Ils ne supposent aucune distribution spécifique des données et peuvent gérer à la fois des données numériques et catégorielles sans transformation préalable, offrant ainsi une grande flexibilité pour capturer des interactions non linéaires entre les caractéristiques. Cependant, ils ont tendance à s'adapter trop précisément aux données d'entraînement, ce qui peut entraîner un surajustement et une performance médiocre sur de nouvelles données. De plus, de petites variations dans les données peuvent entraîner des changements significatifs dans la structure de l'arbre, le rendant instable, et les décisions locales ne garantissent pas une solution globale optimale, ce qui peut conduire à un biais en faveur des classes majoritaires en présence de classes fortement déséquilibrées.

### 2.3.3. K-Nearest Neighbors (KNN)

Les KNN appelé K plus proches voisins sont l'un des algorithmes les plus simples et les plus intuitifs en apprentissage automatique. Né dans les premiers jours de l'intelligence artificielle, le KNN est demeuré une méthode de base pour la classification et la régression, grâce à sa simplicité et son efficacité. Le principe du KNN est direct. Il classe un nouvel échantillon en se basant sur la majorité des classes de ses voisins les plus proches. C'est comme demander à vos voisins les plus proches un conseil avant de prendre une décision : vous considérez les avis de ceux qui sont le plus près de vous. Cette méthode, basée sur la proximité et la similarité, a un charme certain : elle est facile à comprendre et à mettre en œuvre, ne nécessite pas un modèle complexe à construire, et s'adapte facilement à différents types de données. Cependant, sa simplicité vient avec des défis uniques, surtout en ce qui concerne la gestion des grands ensembles de données et la sensibilité aux données bruyantes ou irrégulières.

La méthode des k plus proches voisins (KNN) est une approche d'apprentissage automatique qui se fonde sur la proximité entre les points de données. L'idée principale de KNN est de prédire la classe d'un nouvel exemple en se basant sur la classe majoritaire parmi ses k voisins les plus proches dans l'espace des caractéristiques.

Mathématiquement, pour un nouvel exemple  $x$ , la prédiction de sa classe  $C$  s'obtient en calculant la classe majoritaire parmi ses voisins les plus proches :

$$C = \operatorname{argmax} \left( \sum_{i=1}^k I(y_i = c) \right)$$

Où  $y_i$  est la classe de chaque voisin,  $c$  représente une classe possible, et  $I(\cdot)$  est la fonction indicatrice. L'algorithme KNN est simple à comprendre et à mettre en œuvre. Cependant, il

peut être sensible aux valeurs aberrantes et nécessite un choix approprié de la distance (par exemple, la distance euclidienne). De plus, la performance de KNN peut être impactée par la dimensionnalité des données.

Dans le domaine de l'apprentissage automatique, KNN trouve des applications dans la classification, la régression, et la détection d'anomalies. Sa flexibilité en fait un choix populaire, mais il est essentiel de prendre en compte les paramètres tels que le nombre de voisins  $k$  pour optimiser les résultats. Ainsi, lorsqu'un nouvel exemple doit être classifié, l'algorithme mesure la distance entre ce point et tous les autres dans l'ensemble d'apprentissage. Les  $k$  voisins les plus proches sont ensuite identifiés, et la classe majoritaire parmi ces voisins est attribuée au nouvel exemple.

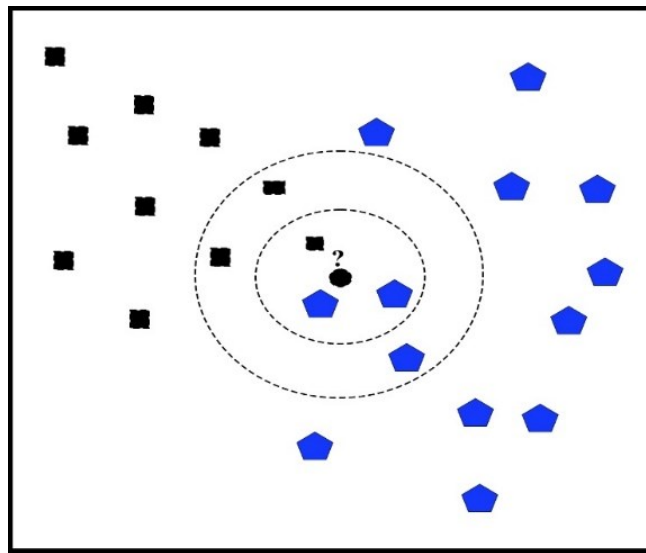


Figure 4 : illustration du fonctionnement de l'algorithme de KNN

©Brondon Styve,2024.

Comme illustré à la figure 4, pour prédire la catégorie d'un point de données, le KNN considère les 'k' points les plus proches dans l'espace des caractéristiques. Si la majorité de

ces voisins appartient à une catégorie spécifique, le point en question est classé dans cette même catégorie. Un aspect important à considérer avec KNN est le choix du nombre de voisins  $k$ . Un  $k$  trop faible peut conduire à une sensibilité excessive au bruit, tandis qu'un  $k$  trop élevé peut lisser les frontières de décision et ignorer les structures locales. Trouver la valeur optimale de  $k$  est donc crucial pour la performance de l'algorithme.

L'algorithme des  $k$  plus proches voisins (KNN) présente des avantages en termes de simplicité et de facilité d'implémentation, ainsi que de flexibilité, car il peut être appliqué à différents types de tâches d'apprentissage automatique et s'adapter aux données changeantes. Cependant, il est sensible aux valeurs aberrantes et aux données extrêmes, ce qui peut nuire à sa performance, surtout dans des ensembles de données bruités. De plus, il nécessite des calculs intensifs de distances entre chaque point de données, ce qui peut devenir coûteux en termes de calcul dans des ensembles de données volumineux, et il est affecté par la malédiction de la dimensionnalité, nécessitant parfois une réduction de la dimensionnalité des données. Enfin, la performance de KNN dépend fortement du choix approprié du nombre de voisins  $k$ , ce qui nécessite une validation attentive pour éviter des résultats moins efficaces.

#### **2.3.4. Random forest**

L'algorithme Random Forest appelé forêt aléatoire constitue une méthode avancée d'apprentissage automatique, reconnue pour sa puissance et sa robustesse. Son principe fondamental repose sur la création d'une "forêt" d'arbres de décision, chacun construit de manière indépendante en utilisant des échantillons aléatoires des données d'entraînement et des caractéristiques spécifiques. Cette diversité dans la construction des arbres contribue à

réduire le surajustement, permettant au modèle de généraliser efficacement sur de nouvelles données.

La forêt aléatoire construit simultanément plusieurs arbres de décision comme nous pouvons le rencontrer à la figure 5, chacun basé sur un échantillon aléatoire des données d'entraînement. La prédiction finale est obtenue par un vote majoritaire des prédictions de tous les arbres. Cette méthode offre des avantages comme la réduction du surajustement et une robustesse accrue face aux valeurs aberrantes, grâce au "bootstrap sampling" [35]. Chaque arbre contribue à la diversité de la forêt et les prédictions sont agrégées pour déterminer le résultat final, rendant la forêt aléatoire moins sujette au surajustement. En outre, elle évalue l'importance des caractéristiques, ce qui enrichit son pouvoir prédictif. La Random Forest est ainsi un modèle robuste et précis, adapté à divers problèmes de données.

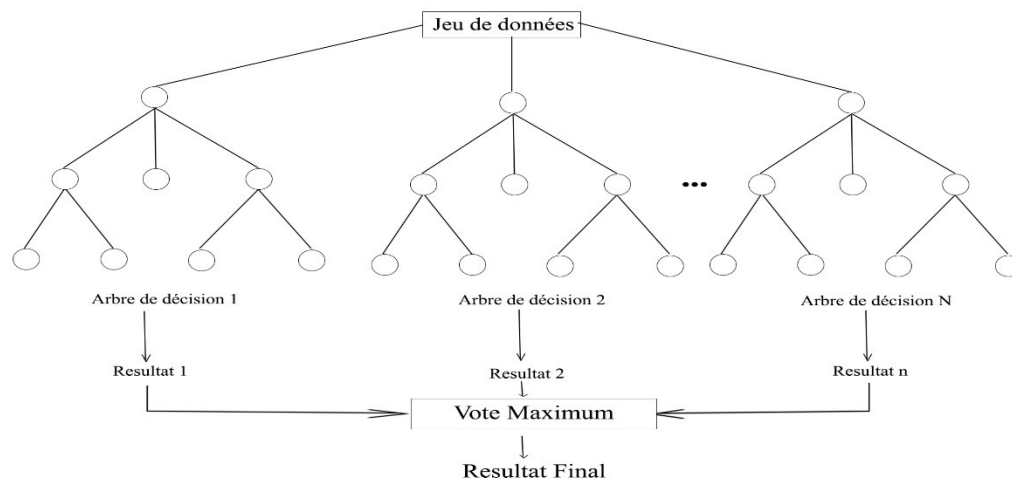


Figure 5 : illustration graphique de Random Forest

©Brondon Styve,2024.

Les forêts aléatoires présentent plusieurs avantages significatifs. Elles réduisent le surajustement en construisant de nombreux arbres de décision sur des échantillons aléatoires,



ce qui améliore la généralisation et offre des prédictions robustes sur de nouvelles données. De plus, leur robustesse aux valeurs aberrantes est notable car les différents échantillons utilisés minimisent l'impact des données atypiques, renforçant la stabilité du modèle. En outre, les forêts aléatoires traitent efficacement les ensembles de données complexes en explorant profondément l'espace des caractéristiques, ce qui favorise des performances élevées dans divers contextes. Cependant, ces modèles peuvent être complexes à interpréter en raison du grand nombre d'arbres, et leur construction et agrégation nécessitent des ressources computationnelles plus importantes, ce qui peut rendre le processus plus long, surtout pour de grands ensembles de données.

#### **2.3.5. Xgboost**

XGBoost, abréviation de "eXtreme Gradient Boosting", est un algorithme d'apprentissage automatique qui appartient à la famille des méthodes ensemblistes. Il est particulièrement réputé pour sa puissance et sa performance dans les compétitions de apprentissage automatique. L'algorithme combine les principes du boosting et utilise un modèle ensembliste basé sur des arbres de décision.

XGBoost est une implémentation avancée de la méthode de gradient boosting, fonctionnant en construisant séquentiellement des arbres de décision pour corriger les erreurs des précédents. Il utilise un processus itératif de descente de gradient pour minimiser la perte. Conçu pour être efficace en calcul et en mémoire, XGBoost utilise des algorithmes d'optimisation et une structure de données spéciale pour améliorer la vitesse et la performance, tout en gérant efficacement les données manquantes et en supportant la régularisation pour prévenir le surajustement. Avec une grande flexibilité de paramétrisation,

les utilisateurs peuvent ajuster divers paramètres pour optimiser les performances du modèle selon leur tâche spécifique. XGBoost permet également d'évaluer l'importance des caractéristiques pour comprendre les modèles dans les données et identifier les caractéristiques les plus significatives.

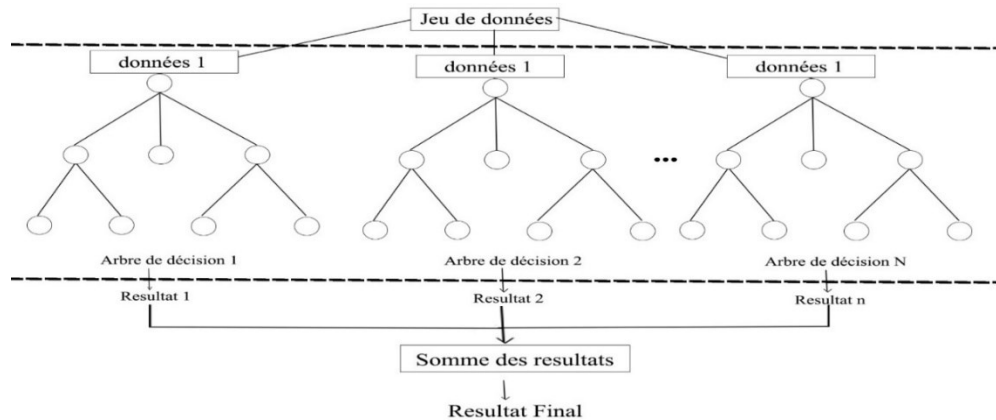


Figure 6 : illustration graphique de l'algorithme de XgBoost.

©Brondon Styve,2024.

La figure 6 accompagne la discussion sur XGBoost en affichant une série d'arbres de décision, chacun se construisant sur les leçons tirées des précédents. Visuellement, elle capte l'essence du boosting, avec des flèches qui guident le regard d'un arbre à l'autre, soulignant le processus itératif. Cette illustration concrétise l'idée de correction progressive des erreurs et d'optimisation continue, tout en mettant en lumière la capacité de XGBoost à s'adapter et à affiner ses prédictions au fur et à mesure que plus d'arbres sont ajoutés au modèle.

XGBoost présente plusieurs avantages significatifs, notamment sa haute performance reconnue dans des compétitions en ligne telles que Kaggle, sa capacité à produire des résultats précis sur diverses tâches, et son intégration de techniques de régularisation pour prévenir le surajustement et améliorer la généralisation du modèle. De plus, il gère

efficacement les valeurs manquantes dans les données, prend en charge la parallélisation pour accélérer l'entraînement et offre une flexibilité pour diverses tâches telles que la classification et la régression. Cependant, XGBoost présente également des inconvénients, notamment sa complexité en termes de configuration des hyperparamètres, le temps d'entraînement plus long par rapport à des modèles plus simples, et sa consommation significative de mémoire. De plus, son interprétation peut être complexe en raison de sa nature basée sur des ensembles d'arbres, et il peut être sensible aux valeurs aberrantes, affectant sa performance dans certaines situations.

### 2.3.6. Naive bayes

Le modèle Naïve Bayes est un algorithme d'apprentissage automatique basé sur le théorème de Bayes. Son approche repose sur la supposition "naïve" que les caractéristiques utilisées pour la classification sont conditionnellement indépendantes, ce qui simplifie considérablement le calcul des probabilités.

Le modèle Naïve Bayes repose sur deux principes fondamentaux qui guident son fonctionnement. Premièrement, le modèle utilise le Théorème de Bayes pour estimer la probabilité d'appartenance à une classe donnée ( $P(C|X)$ ) en fonction des caractéristiques observées ( $X$ ). Cette estimation se base sur les probabilités conditionnelles inversées, à savoir la probabilité des caractéristiques étant donné une certaine classe ( $P(X|C)$ ) et la probabilité a priori de la classe ( $P(C)$ ). La formule de Bayes  $P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)}$ , résume cette approche. Deuxièmement, le modèle repose sur l'hypothèse "naïve" d'indépendance conditionnelle. Cette hypothèse simplifie le calcul en considérant que les caractéristiques ( $X_1, X_2, \dots, X_n$ ) sont conditionnellement indépendantes étant donné la classe ( $C$ ). En

d'autres termes, la probabilité conjointe des caractéristiques dans une classe est le produit des probabilités individuelles :

$$P(X_1, X_2, \dots, X_n | C) = P(X_1 | C) \cdot P(X_2 | C) \cdot \dots \cdot P(X_n | C).$$

Ainsi, en combinant ces principes, le modèle Naïve Bayes peut rapidement estimer la probabilité d'appartenance à chaque classe pour de nouveaux exemples, en considérant la distribution conditionnelle des caractéristiques. Bien que cette approche soit "naïve" dans son hypothèse d'indépendance, elle se révèle souvent efficace dans des scénarios de classification, notamment dans le traitement de données textuelles comme la classification de courriels en "spam" ou "non spam".

En termes de fonctionnement, Le modèle est entraîné à partir d'un ensemble de données étiqueté, où les caractéristiques et les étiquettes de classe sont connues. Les probabilités conditionnelles  $P(X_i | C)$  et les probabilités a priori  $P(C)$  sont calculées à partir de ces données. Lorsqu'un nouvel exemple est présenté, les probabilités conditionnelles pour chaque classe sont calculées en utilisant le théorème de Bayes. La classe prédite est celle avec la probabilité la plus élevée.

$$\text{Classe prédite} = \underset{C}{\operatorname{argmax}} P(C | X)$$




Figure 7 : Illustration du principe de fonctionnement du Naïve Bayes

©Brondon Styve, 2024.

La Figure 7 montre clairement la séparation des caractéristiques en entités indépendantes, reflétant l'hypothèse d'indépendance du modèle [36]. À travers des diagrammes ou des graphiques, elle pourrait illustrer comment Naive Bayes calcule la probabilité de chaque classe en fonction des attributs d'entrée, conduisant à une prédiction finale. Cette visualisation aide à comprendre comment, malgré sa simplicité théorique, Naive Bayes parvient à des conclusions précises, soulignant son utilité dans les tâches de classification, même avec une grande dimensionnalité des données.

Le modèle Naïve Bayes présente plusieurs avantages, notamment sa simplicité et sa rapidité de mise en œuvre, ainsi que sa compétitivité dans de nombreuses tâches de classification, notamment dans les domaines de la classification de texte et de la catégorisation de documents. De plus, il est efficace avec des jeux de données de petite taille et moins sensible au surajustement par rapport à des modèles plus complexes, ce qui le rend robuste dans certaines situations. Cependant, le modèle comporte des limitations telles que son hypothèse d'indépendance conditionnelle pouvant être trop simpliste dans des situations de fortes corrélations entre les caractéristiques, des estimations de probabilité inexactes, l'assomption d'une distribution normale des données, et un biais potentiel vers la classe majoritaire en présence de données déséquilibrées.

#### **2.4. DEEP LEARNING : TECHNIQUES ET APPLICATIONS**

Le Deep Learning, une sous-branche de l'intelligence artificielle, a gagné une attention significative dans le milieu académique et industriel grâce à sa capacité à traiter des volumes massifs de données avec une précision impressionnante. Cette section se concentre sur les techniques et applications du deep learning, en explorant comment ces

technologies révolutionnaires transforment les industries et, en particulier, les habitats intelligents [37].

S'appuyant sur des réseaux de neurones à plusieurs couches, il permet l'extraction automatique de caractéristiques et la reconnaissance de patterns complexes. Cette capacité rend le deep learning particulièrement adapté pour des applications allant de la reconnaissance d'images à l'analyse de la langue naturelle. Dans les habitats intelligents, ces techniques ouvrent la porte à des innovations telles que la surveillance automatisée, la gestion de l'énergie, et les systèmes de recommandation personnalisés. Dans le domaine du Deep Learning, les architectures et les algorithmes jouent un rôle crucial dans la définition des performances et des capacités des modèles. Cette section explore les différentes approches architecturales et algorithmiques qui ont émergé, offrant un aperçu des méthodes clés utilisées pour résoudre des problèmes complexes. Des choix judicieux d'architectures et d'algorithmes sont essentiels pour adapter les modèles aux spécificités des tâches, tout en optimisant les performances et la généralisation.

#### **2.4.1. Réseaux de neurones convolutifs (CNN)**

Les CNN, ou Réseaux de Neurones Convolutifs, sont aujourd'hui l'une des pierres angulaires du monde fascinant du deep learning [38]. Ils se sont imposés comme des outils incontournables pour analyser les images, reconnaître des motifs et même comprendre des vidéos. Mais qu'est-ce qui les rend si spéciaux ? Ces réseaux ont commencé à gagner en popularité dans les années 2010, grâce à leur capacité à traiter les images de manière beaucoup plus efficace que les techniques traditionnelles. Avant leur arrivée, analyser des images ou des vidéos était une tâche ardue et souvent imprécise. Les CNN ont changé la donne en introduisant une manière innovante de 'voir' et de comprendre le contenu visuel.

Dans leur essence, les CNN imitent la manière dont l'œil humain perçoit les choses. Ils apprennent à reconnaître des formes, des couleurs et des textures pour comprendre une image dans son ensemble. Cette capacité à extraire et à analyser les caractéristiques visuelles les rend extrêmement utiles dans de nombreux domaines, et pas seulement en informatique. Que ce soit pour identifier des visages dans une foule, aider les voitures autonomes à 'voir' la route, ou même pour diagnostiquer des maladies à partir d'images médicales, les CNN sont partout.

Au cœur des CNN comme illustré dans la figure 8, on trouve les couches convolutives. Elles agissent comme des filtres qui scannent une image et en extraient des caractéristiques spécifiques, comme les bords, les angles ou les textures. Chaque couche convolutive apprend à reconnaître différents aspects d'une image, ce qui permet au réseau de comprendre et de décomposer l'image en éléments de base. Après la convolution vient généralement le pooling, une couche qui vise à réduire la dimensionnalité de l'image traitée. Le pooling résume les caractéristiques détectées dans les zones plus petites, rendant le réseau moins sensible à la position exacte des caractéristiques dans l'image. Cela aide à réduire la quantité de calculs nécessaires et à rendre le modèle plus généralisable. Enfin, après plusieurs couches de convolution et de pooling, les données sont acheminées vers des couches entièrement connectées. Ici, le réseau prend toutes les caractéristiques apprises et les utilise pour prendre une décision finale, comme identifier un objet dans une image.

Cette architecture en couches permet aux CNN de traiter les images de manière hiérarchique. Des caractéristiques simples dans les premières couches aux caractéristiques de plus en plus complexes et abstraites dans les couches supérieures. Cette méthode imite d'une certaine manière la façon dont le cerveau humain traite les informations visuelles, en

se concentrant d'abord sur les détails pour ensuite assembler une compréhension plus complète de l'image.

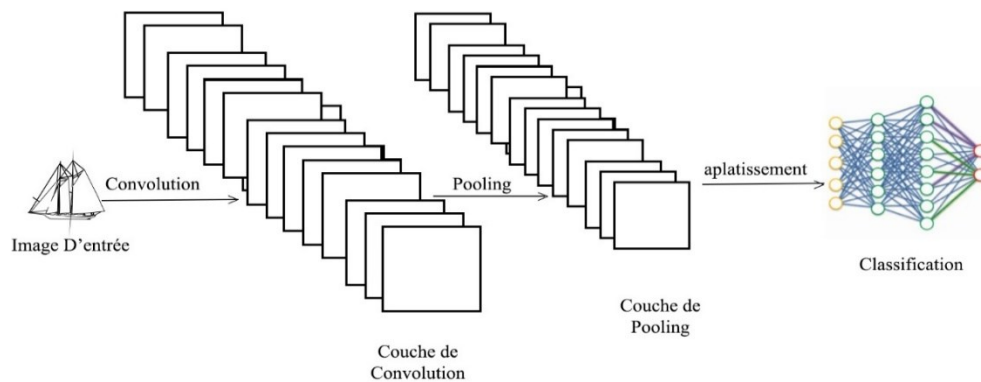


Figure 8 : illustration des CNN

©Brondon Styve,2024.

Les CNN, malgré quelques défis, offrent des avantages considérables dans le domaine de l'intelligence artificielle et du traitement d'images [39]. Ils se distinguent par leur haute précision dans la reconnaissance d'images, leur capacité à extraire automatiquement des caractéristiques pertinentes, leur polyvalence et leur adaptabilité à diverses tâches de traitement d'images. De plus, leur robustesse aux variations d'images mineures, leur évolutivité grâce aux avancées technologiques et leur intégration dans des systèmes complexes en font des outils précieux pour la perception et l'analyse visuelle. Cependant, ils doivent relever des défis tels que le besoin de grandes quantités de données d'entraînement, la complexité computationnelle, le risque de surajustement, le manque d'explicabilité, la sensibilité aux données de mauvaise qualité et la dépendance aux annotations de données.



Ces défis soulignent l'importance d'une utilisation réfléchie et d'une gestion prudente de ces modèles.

#### **2.4.2. Réseaux de neurones récurrents (RNN)**

Les RNN, ou Réseaux de Neurones Récurrents, sont une composante essentielle dans le paysage de l'intelligence artificielle, en particulier pour le traitement de données séquentielles telles que le texte ou les séries temporelles [40]. Ces réseaux se distinguent des modèles traditionnels par leur capacité à maintenir un 'état' ou une mémoire des entrées précédentes, ce qui les rend particulièrement efficaces pour comprendre des séquences où le contexte et l'ordre sont importants. Les RNN ont joué un rôle clé dans le progrès de domaines tels que le traitement du langage naturel et l'analyse de séries temporelles. Leur aptitude à traiter des séquences de données leur permet de 'comprendre' le flux d'informations d'une manière sophistiquée, ouvrant la voie à des applications avancées telles que les assistants vocaux intelligents, les systèmes de recommandation personnalisés et les prévisions météorologiques précises [41].

Les réseaux de neurones récurrents (RNN) sont bien adaptés au traitement de données séquentielles grâce à leur structure en boucle, où la sortie d'une couche devient une partie de l'entrée de la même couche au moment suivant [40], créant ainsi une mémoire séquentielle. Pour surmonter les limitations des RNN standard dans la gestion des dépendances temporelles à long terme, des variantes avancées telles que les LSTM (Long Short-Term Memory) et les GRU (Gated Recurrent Units) ont été développées. Cependant, l'entraînement efficace des RNN peut être difficile [42] en raison de problèmes tels que la disparition ou l'explosion du gradient, ce qui a stimulé la recherche de techniques

d'optimisation pour ces réseaux. Comprendre ces architectures, avec leurs forces et leurs limites, est crucial pour apprécier leur rôle dans le traitement séquentiel des données et leur application potentielle dans divers domaines.

Les réseaux de neurones récurrents (RNN) traitent les données séquentielles en séquences, en tenant compte à chaque étape non seulement de l'entrée actuelle mais aussi des informations précédemment reçues, ce qui leur permet de comprendre le contexte et la séquence dans les données. Leur capacité à capturer des dépendances temporelles à court et à long terme est une de leurs forces majeures, leur permettant de retenir des informations depuis le début de la séquence. Pour l'entraînement, les RNN utilisent une technique appelée rétropropagation à travers le temps (BPTT), ajustant les poids du réseau en tenant compte de l'erreur actuelle ainsi que de son influence sur les étapes précédentes et futures de la séquence. Ce fonctionnement est illustré par la figure 9.

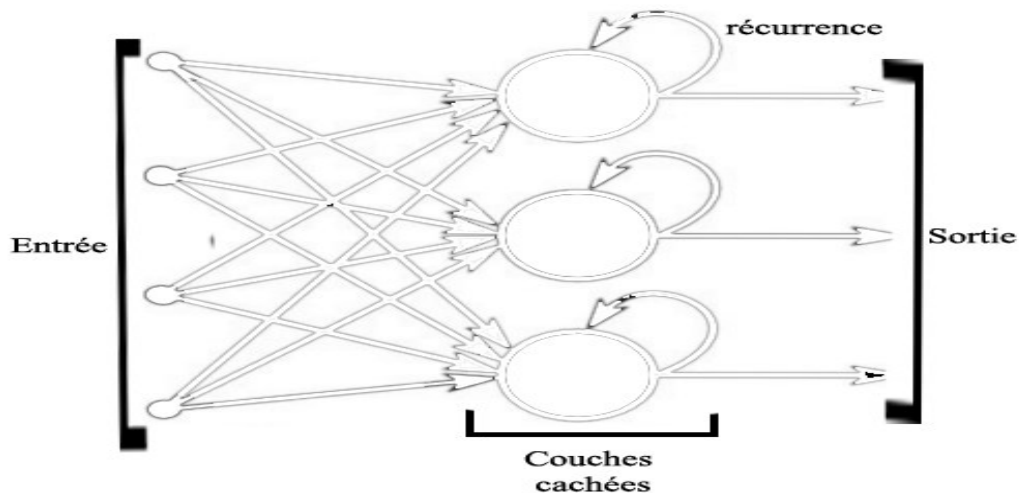


Figure 9 : Illustration du fonctionnement des RNN

©Brondon Styve,2024.

### 2.4.3. Optimisation et techniques avancées pour les RNN

L'optimisation des RNN est cruciale pour améliorer leur efficacité et leur performance dans le traitement de séquences de données. Les architectures de Long Short-Term Memory (LSTM) et les techniques de Backpropagation Through Time (BPTT) se présentent comme des avancées significatives pour surmonter les limites des RNN traditionnels [41]. Les réseaux LSTM sont une évolution clé des RNN traditionnels, conçus pour surmonter le problème de disparition du gradient, fréquent lors de l'apprentissage de dépendances à long terme. Les LSTM introduisent le concept de cellules mémoire, capables de maintenir l'information sur de longues périodes, et de portes (input, output, et forget gates) qui régulent le flux d'informations entrant et sortant de la cellule mémoire. Cette architecture permet une meilleure gestion des séquences de données temporelles, rendant les LSTM particulièrement adaptés pour les applications dans les habitats intelligents, comme la prédiction de consommation énergétique, où la compréhension des patterns sur de longues périodes est cruciale. D'autre part, La Backpropagation Through Time (BPTT) est une technique essentielle pour l'entraînement des RNN, permettant de prendre en compte les séquences temporelles dans l'ajustement des poids du réseau. Contrairement à la rétropropagation standard utilisée dans d'autres types de réseaux neuronaux, la BPTT étend ce processus à travers le temps en déroulant le réseau sur l'ensemble de la séquence temporelle. Cela signifie que l'erreur calculée à la sortie du réseau est rétropropagée non seulement à travers les couches, mais aussi à travers chaque étape temporelle, permettant au réseau d'apprendre des dépendances entre les événements séquentiels. Cependant, cette méthode peut entraîner des problèmes de disparition ou d'explosion du gradient, en raison de la multiplication répétée des gradients à travers les étapes temporelles. Pour gérer ces problèmes, des techniques comme la troncature du BPTT sont utilisées, où la rétropropagation est restreinte à un

nombre limité de pas temporels, afin de maintenir la stabilité de l'entraînement tout en capturant efficacement les dépendances temporelles.

#### **2.4.4. Applications des RNN**

Les réseaux de neurones récurrents (RNN) sont cruciaux pour le traitement des données séquentielles, trouvant des applications étendues dans les communications optiques pour analyser des séquences telles que les signaux numériques et le trafic réseau, comme illustré par [43]. Ils sont employés pour des tâches de prédistorsion et de post-compensation des signaux, prévision du trafic, et analyse des défaillances, offrant une approche de modélisation basée sur les données qui améliore l'apprentissage dans les systèmes de communication optique. En outre, les RNN bénéficient à divers autres domaines, notamment l'authentification biométrique, la reconnaissance des expressions, la détection d'anomalies et l'aviation, permettant l'utilisation de caractéristiques uniques pour l'authentification et l'analyse précise des émotions à partir d'images [44]. Ils détectent des anomalies dans des situations variées, y compris dans l'aviation pour identifier des conditions de vol anormales, soulignant leur potentiel pour résoudre des problèmes complexes et encourager des innovations dans des applications variées.

Les RNN dans leurs applications présente des avantages en se distinguant dans le traitement des données séquentielles grâce à leur capacité à gérer des séquences de données et à comprendre le contexte dans ces séquences, les rendant efficaces pour diverses applications, de la finance à la robotique. Les variantes comme les LSTM et les GRU améliorent cette performance en traitant les longues séquences et en capturant des dépendances complexes. Cependant, les RNN font face à des défis tels que la gestion des

dépendances à long terme, les problèmes d'explosion et de disparition du gradient, la complexité computationnelle élevée, et des difficultés de parallélisation, limitant leur vitesse d'entraînement et d'application, en particulier pour les longues séquences.

#### **2.4.5. Applications du DL en habitats intelligents**

L'application du deep learning dans les habitats intelligents révolutionne la manière dont nous interagissons avec notre environnement domestique. Ces technologies permettent non seulement une automatisation avancée et personnalisée des fonctions domestiques, mais elles contribuent également à une gestion énergétique plus efficace et à une amélioration significative de la sécurité résidentielle. Les études montrent que l'utilisation des CNN, RNN et LSTM dans ces contextes atteint une justesse remarquable, avec des taux de reconnaissance d'activité dépassant 95% dans certains cas, témoignant de leur capacité à s'adapter avec précision aux diverses situations domestiques [37]. Les modèles analysent les données des capteurs pour identifier des modèles de comportement, permettant aux systèmes domestiques de s'adapter de manière proactive aux besoins des occupants, que ce soit pour réguler la température, ajuster l'éclairage, ou encore optimiser la sécurité [45]. En outre, ces systèmes peuvent détecter des situations d'urgence, comme des chutes ou des anomalies dans les habitudes des résidents, et réagir en conséquence, déclenchant des alertes ou ajustant les paramètres de l'habitat pour assurer la sécurité et le confort. La reconnaissance vocale et gestuelle améliore également l'interaction utilisateur, rendant les commandes plus naturelles et intuitives. La capacité du DL à reconnaître des activités est essentielle, non seulement pour améliorer le confort mais aussi pour assurer la sécurité des occupants. Par exemple, en détectant les habitudes quotidiennes, le DL peut adapter l'éclairage et la température en fonction des préférences individuelles, tout en surveillant les activités anormales pour

garantir la sécurité. La détection de chutes par le DL est particulièrement cruciale pour les résidents vulnérables, permettant une intervention rapide en cas d'urgence, contribuant ainsi à un environnement domestique plus sûr. La reconnaissance vocale, une autre prouesse du DL, rend l'interaction avec les dispositifs domestiques plus naturelle et intuitive, ce qui est particulièrement bénéfique pour les personnes à mobilité réduite ou rencontrant des difficultés à utiliser les interfaces traditionnelles [37]. En outre, l'utilisation du DL pour la prédiction de la consommation d'énergie ouvre la voie à une gestion plus intelligente et durable des ressources, en optimisant l'utilisation de l'énergie pour réduire les coûts et l'impact environnemental. Ces avancées ne sont que quelques exemples de la façon dont le DL révolutionne les habitats intelligents, en les rendant plus confortables, sécurisés, accessibles et écologiques, tout en soulignant l'importance croissante de la technologie dans la gestion quotidienne des environnements domestiques.

## **CHAPITRE 3**

### **MÉTHODOLOGIE DE RECHERCHE**

#### **3.1. INTRODUCTION**

Ce chapitre présente la méthodologie adoptée pour notre étude comparative approfondie entre le deep learning (DL) et l'apprentissage automatique classique (ML) dans le domaine de la reconnaissance d'activités humaines au sein des habitats intelligents. L'objectif est de déterminer, à travers une approche méthodique et rigoureuse, si le DL offre effectivement toujours les meilleures performances en termes de justesse, d'efficacité et d'applicabilité dans des environnements domestiques intelligents. Nous commençons par une revue de la littérature, identifiant et analysant les travaux clés dans le domaine du DL appliqué à la reconnaissance d'activités humaines. Cette revue sert à établir un cadre de référence pour nos expérimentations et à identifier les lacunes et les opportunités de recherche. La sélection minutieuse des jeux de données est ensuite abordée, avec une attention particulière portée à leur pertinence pour la reconnaissance d'activités humaines. Chaque jeu de données sélectionné, comme UCI-HAR, Aruba, ESC-50 et Kitchen 20, est examiné en détail en termes de sources, caractéristiques et contexte d'utilisation.

#### **3.2. REVUE DE LA LITTÉRATURE ET SELECTION DES ARTICLES**

Dans cette sous-section, nous abordons le processus de revue de la littérature, un élément fondamental pour établir la base théorique et contextuelle de notre étude.

##### **3.2.1. Objectif de la revue de littérature**

Dans le cadre de notre recherche approfondie visant à explorer les avancées et les opportunités dans le domaine de la reconnaissance d'activités humaines au sein des habitats intelligents, la revue de la littérature constitue une étape primordiale. Cette section a pour objectif de fournir un fondement théorique solide pour notre étude et de situer notre recherche dans le contexte actuel des travaux scientifiques existants. Cette revue de la littérature est conçue pour établir une compréhension approfondie des applications du DL dans le domaine de la reconnaissance d'activités humaines au sein des habitats intelligents. L'accent est mis spécifiquement sur les études qui emploient des techniques de DL, afin de les comparer ultérieurement avec les approches de ML classique que nous développerons et mettrons en œuvre.

Notre premier objectif est d'examiner les dernières avancées dans l'utilisation du DL et du ML pour la reconnaissance d'activités humaines, en particulier dans les habitats intelligents. Cette analyse nous permettra d'identifier les tendances actuelles, les défis techniques, et les solutions innovantes proposées dans la littérature. En identifiant les lacunes dans les études existantes, nous visons à définir clairement comment notre recherche peut combler ces manques et contribuer à l'avancement du domaine.

La revue de la littérature nous aidera à établir des critères de comparaison entre les méthodologies de DL et de ML. Cela est essentiel pour structurer notre étude comparative, en nous permettant de sélectionner des approches et des techniques pertinentes pour notre analyse. Enfin, cette revue vise à orienter la direction de notre recherche future. En identifiant les approches prometteuses et les domaines sous-explorés, nous pourrions déterminer les aspects les plus pertinents pour notre étude et nos expérimentations futures.



### 3.2.2. Méthodologie de recherche bibliographique

Notre recherche bibliographique a débuté avec l'utilisation de la base de données Sofia, qui a fourni une première couche d'articles pertinents. Cependant, pour élargir notre champ de recherche et accéder à des articles plus spécialisés, nous avons également exploré d'autres bases de données académiques telles que IEEE Xplore, ACM Digital Library, Gale (Computer database), et Ebscohost. Ces bases de données ont été choisies pour leur richesse en publications scientifiques et techniques centrées sur le deep learning, l'apprentissage automatique, et les habitats intelligents. Les requêtes que nous avons utilisé étaient centrées sur des mots-clés pertinents à notre étude, tels que "Deep Learning" (Apprentissage profond), "Human Activity Recognition" (reconnaissance d'activités humaines), "Smart Homes" (habitats intelligents) et "Sensors" (capteurs).

Sur la plateforme Sofia nous avons appliqué des requêtes telles que :

- "Deep Learning" AND "reconnaissance activité humaine" AND ("habitats intelligents" OR "maisons intelligentes") AND ("capteurs ambiants" OR "capteurs portatifs" OR caméras OR "capteurs avancés").
- "Deep Learning" AND "reconnaissance activité humaine" AND "habitat intelligent".
- "Apprentissage profond" AND "activité humaine" AND "habitat intelligent".

Pour les autres bases de données, les mots-clés ont été adaptés en anglais pour accroître la pertinence des résultats. Les requêtes finales comprenaient des combinaisons telles que :

- ("Deep learning" OR "neural network" OR "DL" OR "CNN") AND ("human activity" OR "human behavior") AND ("smart home" OR "smart house" OR "intelligent house") AND ("sensor" OR "IOT").
- "Deep learning" OR "neural network" AND "human activity" AND ("smart home" OR "smart house" OR "intelligent house") AND "sensor".

Ces requêtes ont évolué au fil de la recherche, nous permettant d'affiner et de cibler notre collecte d'articles. Les filtres disponibles dans chaque base de données ont été exploités pour optimiser la pertinence et la qualité des résultats obtenus.

### **3.2.3. Processus de sélection des articles**

Dans le cadre de notre revue de littérature, nous avons obtenu un total de 54 articles. Ce processus rigoureux et méthodique a été structuré pour garantir la pertinence et la qualité des sources sélectionnées pour notre recherche. La pré-sélection des articles a été basée sur la lecture des titres, des résumés et, lorsque nécessaire, des introductions pour évaluer leur adéquation avec notre sujet de recherche. Les articles qui semblaient pertinents selon ces premières informations ont été conservés pour un examen plus détaillé. Cette étape de tri préliminaire a permis de réduire la liste à 54 articles pour une analyse plus détaillée. Pour gérer efficacement la sélection des articles, nous avons utilisé le logiciel EndNote. Cet outil nous a permis de conserver et d'organiser les références des articles trouvés lors de notre recherche initiale dans les différentes bases de données. EndNote a été un outil crucial pour suivre les articles pertinents avant la lecture approfondie. Les articles conservés ont ensuite fait l'objet d'une lecture attentive et complète. Cette étape impliquait une analyse en profondeur de la méthodologie, des résultats, et de leur contribution au domaine de la reconnaissance d'activités humaines dans les habitats intelligents. Chaque article a été évalué sur la base de critères stricts, y compris la rigueur méthodologique, la pertinence des résultats, la qualité de l'analyse, et l'adéquation avec les objectifs de notre étude. Sur la base de cette évaluation approfondie, une sélection finale des articles a été effectuée. Seuls les articles qui répondaient pleinement à nos critères de recherche et qui apportaient une contribution significative à notre étude ont été retenus pour la revue de littérature détaillée.

#### 3.2.4. Synthèse des travaux clés

Cette section présente une synthèse des 54 articles sélectionnés, mettant en lumière les contributions essentielles, les tendances, et les résultats clés de la recherche actuelle dans le domaine du deep learning appliqué à la reconnaissance d'activités humaines dans les habitats intelligents. Dans notre revue des travaux clés sur la reconnaissance d'activités humaines, nous avons observé une variété d'approches innovantes en deep learning. Les Réseaux de Neurones Convolutifs (CNN) ont été largement adoptés pour l'analyse de données de capteurs, avec des applications variées, allant de l'extraction de caractéristiques à partir de données d'inertie à la prédiction d'activités complexe [46]. Dans cette recherche, les auteurs ont mis au point un système innovant pour la reconnaissance en temps réel des activités humaines, en exploitant des données en continu issues de capteurs binaires. Leur approche se fonde sur une segmentation dynamique des données, suivie d'un encodage et d'une classification via un modèle spécifique de CNN2D, testé sur le jeu de données Aruba. Ce modèle CNN2D, qui se distingue par l'utilisation d'une couche de pooling moyenne globale pour prévenir le surajustement et par sa capacité à agréger les données spatiales, a démontré une justesse de classification notable de 81,6%, surpassant ainsi d'autres méthodes conventionnelles. Néanmoins, malgré ces résultats prometteurs, l'étude reconnaît certaines limites, notamment dans la méthode de segmentation dynamique qui a une F-mesure de 0,607, suggérant des opportunités d'optimisation. L'étude souligne également l'intérêt d'explorer d'autres architectures de réseaux neuronaux pour renforcer encore la performance du système de reconnaissance d'activités humaines.

D'autre part, les auteurs de l'article [47] ont introduit Kitchen20, un nouveau dataset audio brut dédié à la reconnaissance d'actions humaines en cuisine, répondant ainsi au besoin d'un ensemble de données ouvert et annoté spécifiquement pour ce contexte. Kitchen20,

combinable avec ESC-50 pour créer ESC-70, vise à enrichir la recherche en apprentissage automatique grâce à une meilleure compréhension des actions en cuisine à travers l'audio. Ils ont utilisé EnvNetV2, un réseau de neurones convolutif profond spécialisé dans le traitement de l'audio brut, optimisé par une stratégie d'apprentissage inter-classes et une augmentation des données, pour analyser les sons de Kitchen20. Les résultats, obtenus après une optimisation bayésienne de 200 étapes, ont révélé une justesse maximale de 79,1%, soulignant l'efficacité de Kitchen20 pour la classification audio des activités de cuisine. Cependant, le dataset pourrait être limité par sa diversité d'actions, sa taille et sa représentativité des environnements de cuisine réels, avec une reconnaissance basée uniquement sur l'audio qui pourrait omettre des informations visuelles cruciales pour la compréhension complète des activités humaines en cuisine.

L'approche de Deep Ensemble Learning, combinant plusieurs modèles CNN, a également été explorée pour améliorer la justesse de la reconnaissance des activités humaines, avec des résultats prometteurs. De même, l'utilisation de LSTM bidirectionnels résiduels a permis de tirer parti des connexions bidirectionnelles et résiduelles, offrant une amélioration significative dans la reconnaissance des activités humaines à partir de données de capteurs portables [48]. Les chercheurs ont introduit Res-Bidir-LSTM, un réseau de neurones avancé conçu pour la reconnaissance d'activités humaines à partir de données de capteurs portables, testé sur les ensembles de données UCI et Opportunity, couvrant des activités simples à complexes. Ce modèle innovant combine des connexions résiduelles et bidirectionnelles au sein des LSTM pour résoudre le problème de disparition du gradient et améliorer l'analyse temporelle, utilisant une fonction de perte sigmoïde et l'optimiseur Adam pour l'entraînement. Le Res-Bidir-LSTM a surpassé les modèles LSTM standards en atteignant une justesse jusqu'à 93,6% et un score F1 d'environ 0,9, prouvant une convergence

rapide et des performances élevées. Toutefois, malgré son efficacité, le modèle pourrait rencontrer des défis de généralisation et nécessiter un ajustement intensif des hyperparamètres, suggérant un potentiel d'amélioration dans la simplification de l'optimisation des paramètres pour de futures applications.

Dans l'étude [49], les auteurs ont développé un cadre de reconnaissance des activités humaines (HAR) basé sur des techniques avancées de deep learning, telles que CNN, diverses formes de LSTM, et GRU, évalué sur les jeux de données UCI HAR et WISDM utilisant des données de capteurs de smartphone. Ils ont exploré des architectures hybrides, y compris CNN-LSTM, CNN-LSTM-Dense, et GRU, pour analyser efficacement les informations spatiales et temporelles sans ingénierie manuelle des fonctionnalités. Les résultats ont révélé une haute justesse, avec le modèle GRU atteignant jusqu'à 96,83% sur UCI-HAR et 98% sur WISDM, démontrant la capacité des modèles proposés à reconnaître précisément les activités humaines. Cependant, l'étude reconnaît des défis en termes de généralisation à divers environnements et de l'efficacité des modèles dans des contextes en temps réel, suggérant la nécessité d'évaluations supplémentaires pour confirmer leur robustesse et leur applicabilité pratique. Ces avancées dans les techniques de deep learning reflètent la dynamique d'innovation dans le domaine de la reconnaissance d'activités humaines et ouvrent de nouvelles perspectives pour des recherches futures.

#### **3.2.4.1. Résultats et performances**

Les études analysées ont mis en évidence des résultats significatifs en termes de justesse, de fiabilité et d'efficacité des modèles de deep learning dans divers scénarios d'habitats intelligents. Par exemple, le modèle X-CHAR a démontré une capacité notable à prédire des activités complexes en se basant sur des concepts simples [50]. Les modèles

comme EnvNet et EnvNetV2 ont quant à eux prouvé leur efficacité dans la reconnaissance des sons environnementaux, surpassant les approches classiques d'apprentissage automatique dans le même article [47]. L'approche Deep Ensemble Learning a également montré des résultats prometteurs, en particulier en termes d'amélioration de la justesse de la reconnaissance d'activités humaines par une combinaison de CNN et BiLSTM allant jusqu'à 96,37% où les auteurs ont récapitulé un ensemble d'articles dans le domaine de reconnaissance d'activités humaines dans les habitats intelligents à travers le deep learning [51]. Ces résultats mettent en évidence non seulement les performances comparatives, mais aussi établissent de nouvelles normes de référence dans le domaine.

#### **3.2.4.2. Défis et limitations**

Notre analyse des travaux clés sur le deep learning appliqué à la reconnaissance d'activités humaines a mis en évidence divers défis et limitations inhérents à ces modèles [52]. Parmi eux, l'interprétabilité et l'explicabilité se démarquent comme des problèmes majeurs, étant donné la complexité des architectures profondes qui rend difficile la compréhension des décisions du modèle. Le surajustement est également une préoccupation significative, avec des modèles ayant tendance à mal se généraliser sur de nouvelles données. Du côté de la gestion des données, la qualité et le volume nécessaire pour entraîner efficacement ces modèles posent des défis en termes de coût et d'effort, sans oublier les risques de biais qui peuvent mener à des résultats erronés ou inéquitables. En termes de considérations éthiques, la protection de la vie privée et la nécessité d'un consentement et d'une transparence dans l'utilisation des données personnelles sont cruciales pour maintenir la confiance des utilisateurs. Ces défis soulignent non seulement les limites des modèles de deep learning mais aussi les opportunités d'amélioration, en particulier en développant des

modèles de machine learning plus simples qui offrent une meilleure interprétabilité, une gestion plus facile des données, et une meilleure conformité avec les préoccupations éthiques et de confidentialité.

#### **3.2.4.3. Orientation vers le machine learning classique**

Les tendances et résultats observés dans la littérature mettent en lumière l'opportunité d'utiliser des méthodes d'apprentissage automatique classique pour aborder ces défis. Notre recherche se concentrera sur l'élaboration et l'expérimentation de modèles de ML classique qui pourraient offrir une interprétabilité et une gestion des données plus aisée tout en maintenant une performance élevée. Nous comparons directement les performances de nos modèles de ML classique avec celles des modèles de deep learning établis, en mettant l'accent sur des aspects tels que la précision, l'efficacité et la facilité d'utilisation. Cela permet d'évaluer la viabilité des méthodes de ML classique dans des scénarios réels.

#### **3.2.5. Analyse critique de la littérature**

L'examen approfondi de la littérature révèle des tendances claires dans l'application du deep learning pour la reconnaissance d'activités humaines. Notamment, un accent accru est mis sur l'utilisation des CNN et des modèles LSTM pour traiter des données complexes issues de capteurs portables. Ces technologies sont de plus en plus privilégiées pour leur capacité à modéliser des séquences temporelles et à extraire des caractéristiques pertinentes de grandes quantités de données. Par ailleurs, nous constatons un intérêt croissant pour l'explicabilité des modèles de deep learning, un aspect crucial pour la compréhension et la confiance des utilisateurs finaux dans ces systèmes.

Malgré les avancées significatives, notre analyse a également mis en évidence des lacunes dans la recherche actuelle. Un domaine sous-exploré concerne l'optimisation de l'efficacité des modèles en termes de coûts computationnels et de temps de traitement, ce qui est essentiel pour les applications en temps réel dans les habitats intelligents. De plus, bien que des progrès aient été réalisés dans l'explicabilité des modèles, cette question reste un défi majeur, avec un besoin de recherches supplémentaires pour rendre les modèles de deep learning plus transparents et compréhensibles.

En examinant les méthodologies employées dans les études analysées, nous avons constaté une variété d'approches dans la conception et l'implémentation des modèles de deep learning. Cependant, certaines études ont révélé des limitations en termes de robustesse, en particulier en ce qui concerne la validation des modèles et la gestion des données déséquilibrées. La dépendance à des ensembles de données volumineux et spécifiques pose également des questions quant à la généralisabilité des modèles. Bien que de nombreuses études aient démontré des résultats prometteurs avec des taux de justesse élevés, il est crucial de considérer la pertinence et l'applicabilité de ces résultats dans des contextes réels. Certaines études manquent d'une évaluation approfondie de la performance des modèles dans des scénarios variés, ce qui est essentiel pour garantir la fiabilité et l'efficacité des solutions proposées dans les habitats intelligents [53].

Une préoccupation récurrente dans les études sur la reconnaissance d'activités humaines concerne les enjeux éthiques, notamment en matière de confidentialité des données. La collecte et l'utilisation de données sensibles, comme celles provenant de capteurs dans les habitats intelligents, nécessitent une attention particulière pour garantir le respect de la vie



privée des individus. Plusieurs études ont souligné la nécessité de développer des modèles de deep learning qui soient non seulement efficaces, mais aussi respectueux des normes éthiques et de confidentialité [54]. L'analyse des travaux actuels révèle également des interrogations sur l'applicabilité pratique des modèles de deep learning dans des environnements réels. Les défis liés à l'intégration de ces modèles dans des systèmes existants, ainsi que les coûts et les ressources nécessaires pour leur mise en œuvre, sont des aspects critiques qui doivent être pris en compte. Il est essentiel de veiller à ce que les solutions proposées soient réalisables et viables dans le contexte des habitats intelligents.

Les lacunes et défis identifiés dans les études actuelles ouvrent la voie à de nouvelles directions de recherche. En particulier, il existe un potentiel significatif pour le développement de méthodes de machine learning classique qui peuvent offrir des alternatives plus éthiques, moins coûteuses et plus faciles à intégrer. De plus, la recherche future devrait se concentrer sur l'amélioration de l'explicabilité et de la transparence des modèles de deep learning. Cette analyse souligne également le potentiel d'innovation dans le domaine de la reconnaissance d'activités humaines. Il existe des opportunités pour améliorer les approches existantes, notamment en traitant le biais des données et en augmentant la généralisabilité des modèles. L'exploration de nouvelles architectures de modèles et de techniques de traitement des données peut contribuer à l'avancement du domaine. La critique approfondie de la littérature actuelle révèle des opportunités significatives pour l'application et l'innovation dans le domaine du machine learning classique.

### **3.3. DESCRIPTION ET ANALYSE DES JEUX DE DONNEES SELECTIONNES**

Dans cette section, nous nous concentrons sur les jeux de données soigneusement sélectionnés, qui forment le fondement pratique de notre recherche en machine learning. Le choix judicieux de ces ensembles de données est crucial, car ils fournissent non seulement les informations nécessaires pour entraîner et tester nos modèles, mais influencent également de manière significative l'orientation et les résultats de notre analyse. Une compréhension approfondie de chaque jeu de données nous permettra d'exploiter au mieux leurs potentialités et de tirer des conclusions robustes et pertinentes. Nous débutons par examiner les critères qui ont guidé notre sélection, avant de plonger dans l'analyse détaillée de chaque ensemble de données.

#### **3.3.1. Critère de sélection des jeux de données**

La sélection des jeux de données pour notre étude en ML n'est pas anodine ; elle repose sur une série de critères essentiels qui garantissent la pertinence et l'efficacité des données pour nos objectifs de recherche. Ces critères servent à orienter notre choix vers des ensembles de données qui offrent non seulement une qualité et une variété de données adéquates, mais aussi une applicabilité directe à la reconnaissance d'activités humaines. Il est essentiel de préciser les critères qui ont guidé leur sélection. Nous nous sommes donc appuyés sur des critères comme :

- L'Adéquation avec le Domaine de Recherche : Les jeux de données doivent être étroitement liés au domaine de la reconnaissance d'activités humaines, offrant des scénarios et des exemples qui reflètent les situations réelles rencontrées dans les habitats intelligents.

- La diversité des Données : Une variété de types de données (comme les données issues de capteurs, audio, etc.) est recherchée pour assurer une compréhension complète des différentes facettes des activités humaines.
- La qualité des Données : La qualité des données est primordiale. Les jeux de données choisis doivent être fiables, précis et exempts d'erreurs qui pourraient fausser les résultats de nos analyses.
- La représentativité : Les ensembles de données doivent être représentatifs des populations et des scénarios qu'ils sont censés modéliser. Cela est crucial pour garantir que les conclusions tirées de notre recherche sont généralisables et applicables à une large gamme de situations.
- L'accessibilité des Données : L'accessibilité est un facteur clé ; les jeux de données doivent être disponibles et exploitables dans le cadre de notre recherche.
- La considérations Éthiques : Les ensembles de données doivent être sélectionnés en tenant compte des considérations éthiques, notamment en ce qui concerne la confidentialité et le consentement des individus dont les données sont utilisées.

Avec ces critères de sélection en tête, nous sommes maintenant bien positionnés pour explorer en détail les jeux de données spécifiques choisis pour notre recherche. Chacun de ces ensembles de données a été sélectionné non seulement pour sa conformité avec nos critères rigoureux, mais aussi pour son potentiel unique à enrichir et à informer notre étude.

Dans les sections suivantes, nous allons examiner de plus près les caractéristiques spécifiques, la provenance, la description et le contexte d'utilisation de chaque jeu de données, en commençant par le jeu de données UCI-HAR.

### 3.3.2. Jeu de données UCI-HAR

Le UCI-HAR représente un jalon important dans la recherche sur la reconnaissance d'activités humaines à l'aide de capteurs portables. Ce jeu de données, développé par l'Université de Californie, Irvine, est devenu une référence dans le domaine pour sa richesse et sa précision. Il a été spécifiquement conçu pour étudier les activités humaines quotidiennes à travers des données capturées par des smartphones. L'objectif principal de ce jeu de données est de fournir une base solide pour le développement et la validation de modèles de ML capables de reconnaître et de classifier les activités humaines à partir de données de capteurs. Les données du Jeu de données UCI-HAR sont issues d'expérimentations contrôlées, au cours desquelles des volontaires équipés de smartphones ont effectué un ensemble d'activités standardisées. Cette méthode de collecte assure non seulement la qualité et la fiabilité des données, mais fournit également une diversité d'informations essentielle pour l'entraînement de modèles de reconnaissance d'activités robustes et précis.

```
2.5717778e-001 -2.3285230e-002 -1.4653762e-002 -9.3840400e-001 -9.2009078e-001 -6.6768331e-001 -9.5250112e-001 -9.2524867e-001 -6.7430222e-001 -8.9408755e-001 -5.5457721e-001 -4.6622295e-001 7.1720847e-001 6.3550240e-001 7.8949666e-001 -8.7776423e-001 -9.9776606e-001 -9.9841381e-001 -9.3434525e-001 -9.7566897e-001 -9.4982365e-001 -8.3047780e-001 -1.6808416e-001 -3.7899553e-001 2.4621698e-001 5.2120364e-001 -4.8779311e-001 4.8228047e-001 -4.5462113e-002 2.1195505e-001 -1.3489443e-001 1.3085848e-001 -1.4176313e-002 -1.0597085e-001 7.3544013e-002 -1.7151642e-001 4.0062978e-002 7.6988933e-002 -4.9054573e-001 -7.0900265e-001 9.3648925e-001 -2.8271916e-001 1.1528825e-001 -9.2542727e-001 -9.3701413e-001 -5.
```

Figure 10 : Format du jeu de données UCI-HAR.

©Brandon Styve,2024.

Le Jeu de données UCI-HAR a été créé à partir d'une expérience où 30 volontaires ont été équipés de smartphones Samsung Galaxy S II sur la taille. Ces volontaires ont effectué six activités quotidiennes typiques : marcher, monter des escaliers, descendre des escaliers, s'asseoir, se tenir debout et s'allonger. Pendant ces activités, les smartphones ont enregistré les données via leur accéléromètre et gyroscope intégrés, fournissant des mesures détaillées des mouvements et orientations corporelles. Pour accéder à ce jeu de données, les chercheurs et les praticiens peuvent se rendre sur le site web de l'UCI Machine Learning Repository, une source reconnue pour les jeux de données académiques en ML. Le Jeu de données UCI-HAR y est disponible en téléchargement libre, offrant ainsi une facilité d'accès pour les utilisateurs souhaitant l'exploiter dans leurs propres recherches. Les données y sont structurées de manière à permettre une utilisation directe dans la plupart des environnements de développement de ML.

Plus spécifiquement, Le jeu de données contient des enregistrements des accélérations linéaires et angulaires tridimensionnelles, capturées à une fréquence de 50Hz. Ces données ont été prétraitées pour filtrer le bruit et ensuite segmentées en fenêtres de 2.56 secondes avec un chevauchement de 50%. Chaque fenêtre de données a été étiquetée avec l'activité correspondante, fournissant ainsi un ensemble de données clair et structuré pour l'analyse des activités humaines. Le jeu de données UCI-HAR se distingue par sa combinaison de données d'accélération et de vitesse angulaire, ce qui permet une analyse détaillée et complète des mouvements humains. De plus, le jeu de données a été largement utilisé et validé dans la communauté de recherche, ce qui en fait une référence fiable pour évaluer les performances des algorithmes de reconnaissance d'activités. Ce jeu de données est particulièrement adapté pour les études visant à développer ou à améliorer des algorithmes d'apprentissage automatique pour la reconnaissance d'activités humaines. Sa

structure détaillée et sa labellisation précise le rendent idéal pour tester à la fois la précision et l'efficacité des modèles de machine learning dans la classification des activités à partir de données de capteurs.

### **3.3.3. Jeu de données Aruba**

Le jeu de données Aruba est un autre ensemble de données crucial dans le domaine de la reconnaissance d'activités humaines, en particulier dans le contexte des habitats intelligents. Collecté dans le cadre d'un projet de recherche sur les habitats intelligents, ce jeu de données offre une perspective unique sur les comportements et les routines quotidiennes au sein d'un espace de vie réel. Ce jeu de données se distingue par sa collecte de données dans un environnement domestique sur une longue période, offrant ainsi une richesse de données sur les activités humaines naturelles et non scriptées. Les données d'Aruba sont particulièrement précieuses pour étudier comment les individus interagissent avec leur environnement domestique, ce qui est essentiel pour le développement de systèmes intelligents capables de s'adapter et de répondre aux besoins des utilisateurs.

Le Jeu de données Aruba est issu d'un projet de recherche mené dans le cadre du Center for Advanced Studies in Adaptive Systems (CASAS) pour les habitats intelligents [55]. La collecte des données a eu lieu dans une résidence intelligente, avec pour objectif d'étudier les comportements quotidiens d'un résident senior vivant seul. Dans cette étude, une multitude de capteurs ont été installés dans la maison pour enregistrer des données environnementales variées, y compris les mouvements, l'utilisation d'appareils, les ouvertures de portes et autres interactions domestiques. Ces données recueillies offrent une fenêtre précieuse sur les routines et les habitudes quotidiennes, fournissant des informations

clés pour comprendre le comportement humain dans un environnement domestique. Aruba est disponible publiquement via le site web du CASAS. Les chercheurs intéressés par l'analyse de comportements dans les habitats intelligents peuvent télécharger le jeu de données directement depuis cette plateforme. Sa disponibilité sur CASAS garantit un accès facile et permet une vaste utilisation dans des projets de recherche axés sur l'amélioration de la vie dans les espaces domestiques intelligents.

Ses données comprennent des informations sur les mouvements, la température, ainsi que l'ouverture et la fermeture de portes et fenêtres. Elles sont enregistrées de manière continue, fournissant ainsi une chronologie détaillée des activités quotidiennes au sein de la maison. La richesse des données du Jeu de données Aruba le rend particulièrement adapté pour l'analyse des schémas comportementaux dans les espaces domestiques, offrant des opportunités pour le développement de systèmes intelligents personnalisés et réactifs aux habitudes des utilisateurs. Les données recueillies sont essentielles pour comprendre non seulement les routines physiques, mais aussi les interactions avec l'environnement domestique, ce qui est crucial pour les applications en matière d'assistants domestiques intelligents et de systèmes de surveillance de santé à domicile.

```
2010-11-04 05:40:42.452746 M007 ON
2010-11-04 05:40:43.642664 M003 OFF Sleeping end
2010-11-04 05:40:44.223548 M003 ON
2010-11-04 05:40:45.939846 M005 ON
2010-11-04 05:40:46.310862 M003 OFF
2010-11-04 05:40:51.303739 M004 ON Bed_to_Toilet begin
2010-11-04 05:40:52.342105 M005 OFF
2010-11-04 05:40:57.176409 M007 OFF
2010-11-04 05:40:57.941486 M004 OFF
2010-11-04 05:43:24.021475 M004 ON
2010-11-04 05:43:26.273181 M004 OFF
2010-11-04 05:43:26.345503 M007 ON
2010-11-04 05:43:26.793102 M004 ON
2010-11-04 05:43:27.195347 M007 OFF
2010-11-04 05:43:27.787437 M007 ON
2010-11-04 05:43:29.711796 M005 ON
2010-11-04 05:43:30.279021 M004 OFF Bed_to_Toilet end
2010-11-04 05:43:34.261135 M005 OFF
2010-11-04 05:43:35.941892 M007 OFF
2010-11-04 05:43:40.821615 M007 ON
2010-11-04 05:43:45.619681 M007 OFF
2010-11-04 05:43:45.7324 M003 ON Sleeping begin
```

Figure 11 : Format du jeu de données Aruba, ©Brondon Styve,2024.

©Brondon Styve,2024.

La figure 10 présente un extrait de la structure du jeu de données Aruba qui est illustrée par une série d'enregistrements qui comprend des horodatages précis, associés à des identifiants de capteurs spécifiques et à des descriptions d'activités correspondantes. Chaque entrée détaille l'instant précis où une activité a été détectée, le type de capteur qui a enregistré l'événement, ainsi que l'activité observée, codifiée par un libellé. Aruba se distingue par ses caractéristiques uniques, rendant ce dernier extrêmement utile pour la recherche en habitats intelligents. Il se caractérise par sa multimodalité, intégrant divers types de capteurs pour une vision complète des activités domestiques. Sa granularité temporelle fine, grâce à une collecte de données en continu, permet une analyse précise des comportements quotidiens. La longue durée de suivi des données révèle des tendances à long terme et des variations saisonnières dans les comportements. Enfin, il offre une représentation réaliste des activités domestiques, essentielle pour le développement de systèmes intelligents adaptés aux habitudes et besoins des utilisateurs. Ces atouts font du Jeu de données Aruba une ressource précieuse pour l'exploration des dynamiques des habitats intelligents et la reconnaissance d'activités humaines. Il est particulièrement adapté au développement de systèmes domotiques intelligents qui apprennent et s'adaptent aux comportements des résidents pour améliorer leur confort et leur sécurité. Ce jeu de données est également utile pour les études sur la santé à domicile, permettant la surveillance des routines quotidiennes pour détecter des indicateurs de problèmes de santé. En outre, il offre des opportunités pour optimiser la consommation d'énergie dans les habitats intelligents et pour des études approfondies sur l'interaction humain-environnement. Ces utilisations diverses témoignent de la richesse des données recueillies et de leur pertinence pour améliorer la vie quotidienne et la technologie des habitats intelligents.



### 3.3.4. Jeux de données ESC-50 et Kitchen 20

Le ESC-50 et le Kitchen 20 sont des ensembles de données clés dans le domaine de la reconnaissance d'activités humaines, en particulier pour l'analyse des sons [47]. Le ESC-50, compile des enregistrements audios de différentes sources en ligne et est spécialement conçu pour la diversité et la représentativité des catégories de sons. Les échantillons sont reconvertis en un format unifié (44,1 kHz, mono, compression Ogg Vorbis à 192 kbit/s) [56], assurant une qualité et une cohérence sonore à travers le jeu de donnée. C'est un outil précieux pour la recherche en reconnaissance d'activités humaines grâce à sa riche collection de 2 000 clips audio environnementaux, répartis-en 50 catégories. Chaque catégorie, contenant 40 exemples de cinq secondes chacun, qui incluent des sons d'animaux (comme le chant des oiseaux ou le rugissement des lions), des bruits naturels (comme le tonnerre ou la pluie), des sons domestiques (comme une sonnerie de téléphone ou le bruit d'une machine à laver), ainsi que des bruits humains (comme des toux ou des applaudissements). Ce jeu de données est disponible sur la plateforme Kaggle. Kitchen 20, quant à lui, se distingue par sa composition spécifique et son application ciblée dans le domaine de la reconnaissance audio dans les environnements de cuisine. Composé de 800 échantillons sonores, Kitchen20 est organisé en 20 classes distinctes, réparties équitablement entre les sons produits par des appareils de cuisine et ceux liés aux manipulations humaines. Chaque catégorie est illustrée par 40 enregistrements audio de cinq secondes, soigneusement sélectionnés pour représenter de manière exhaustive les activités de cuisine typiques. Ces enregistrements ont été acquis avec une qualité sonore élevée, enregistrés à ou réduits à un taux d'échantillonnage de 44,1 KHz pour assurer une uniformité dans le traitement des données [47]. La diversité des sources des échantillons audio, combinée à une méthode de collecte minutieuse de 662 échantillons provenant de FreeSound et 138 capturés dans de véritables cuisines par des

individus utilisant des smartphones modernes [47]. La figure 11 présente un des fichier pris dans notre jeu de données plus précisément le fichier '0-101477-B-3\_cat-microwave\_fold-1.wav'.

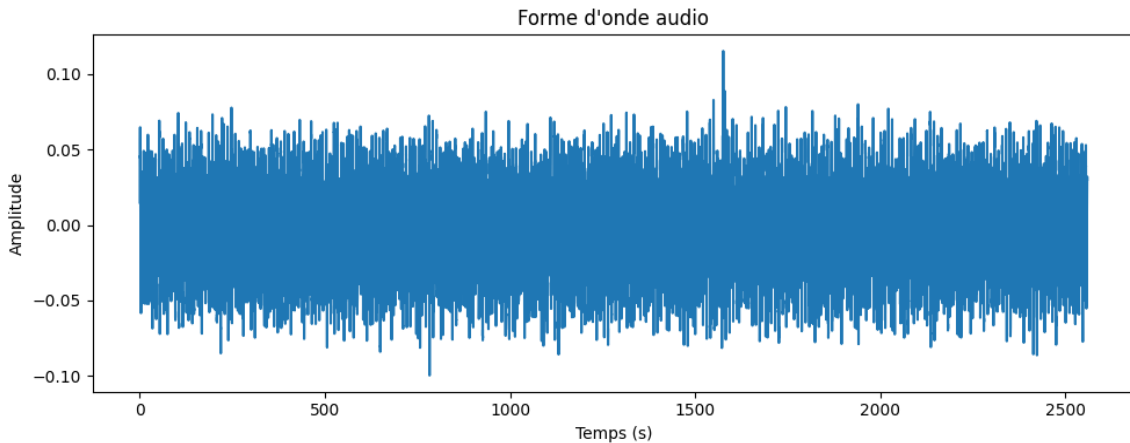


Figure 12: Représentation d'un audio du jeu de données en fonction de l'amplitude et du temps.

©Brondon Styve, 2024.

Le ESC-50 et le Kitchen 20 sont particulièrement utiles dans plusieurs domaines de recherche et d'applications pratiques. Le contexte d'utilisation pour ESC-50 est ancré dans la nécessité de reconnaître et de classifier efficacement les sons environnementaux dans diverses applications. Il revêt une importance significative dans des domaines tels que la recherche en intelligence artificielle, la technologie des assistants vocaux, la recherche en traitement du signal audio, et la récupération multimédia. Par exemple, dans le domaine de la récupération multimédia, ESC-50 peut être utilisée pour améliorer les performances des systèmes de recherche vidéo en exploitant au mieux la modalité audio. De plus, l'analyse automatisée des sons urbains, tels que les niveaux de bruit élevés, peut bénéficier de ESC-50 en offrant des informations détaillées. En outre, la classification des sons environnementaux a des applications potentielles dans des domaines tels que la surveillance

acoustique pour la détection précoce de situations d'urgence, la reconnaissance d'événements sonores dans les environnements urbains, et l'analyse des modèles sonores pour des applications de sécurité et de surveillance [57]. Ainsi, l'ESC-50 joue un rôle crucial dans la compréhension et l'exploitation des informations audio environnementales, ce qui en fait un domaine de recherche dynamique et en évolution constante. Pour Kitchen20, les domaines d'utilisation concrets englobent le développement d'assistants culinaires intelligents, l'automatisation de la cuisine, et l'amélioration de la sécurité domestique. Les échantillons audio spécifiques à la cuisine permettent aux chercheurs et aux développeurs de créer des systèmes capables d'identifier les activités de cuisine en temps réel, telles que la cuisson, le mixage, ou l'utilisation d'appareils électroménagers. Cela a des implications directes dans la conception d'appareils de cuisine intelligents qui peuvent réagir de manière autonome à des événements sonores, offrant une aide aux utilisateurs dans leurs tâches culinaires et améliorant l'expérience utilisateur par l'interaction sonore. De plus, dans un contexte de sécurité, Kitchen20 peut contribuer à la détection d'événements anormaux, comme un appareil laissé accidentellement allumé, renforçant ainsi la sécurité domestique par la surveillance acoustique.

### **3.3.5. Synthèse et implications pour la recherche**

La gestion de la complexité à chaque jeu de données constitue une étape cruciale pour l'affinement des modèles de ML dans notre étude de reconnaissance d'activités humaines. Cette complexité, reflétée par la diversité des activités enregistrées, les conditions variées sous lesquelles ces données ont été collectées, et leurs caractéristiques modales distinctes, nécessite une approche d'entraînement ciblée et spécifique à chaque ensemble. Pour UCI-HAR, cela signifie adapter les modèles pour distinguer avec précision entre les mouvements

physiques capturés par les capteurs, malgré la variabilité individuelle. Dans le cas d'Aruba, l'enjeu réside dans l'analyse des séquences comportementales au sein d'un habitat intelligent, où la détection des activités nécessite une interprétation contextuelle fine des données environnementales. Pour les ensembles de données audio ESC-50 et Kitchen 20, le défi est de traiter avec succès le bruit de fond et les variations acoustiques pour identifier correctement les sons spécifiques aux activités. En entraînant chaque jeu de données séparément, nous visons à développer des modèles hautement spécialisés, capables de naviguer dans la complexité spécifique à chaque type de données.

La quantité et la qualité des données constituent des axes fondamentaux influençant directement l'efficacité des modèles dans notre étude. Chaque jeu de données sélectionné porte en lui une variabilité significative tant en termes de volume de données que de qualité, ce qui impose des stratégies d'entraînement spécifiques pour chaque ensemble. L'UCI-HAR, avec ses données précises capturées par des capteurs d'accéléromètre et de gyroscope, et l'ESC-50, riche en enregistrements audio classifiés en catégories environnementales diverses, se caractérisent par leur haute qualité et leur structuration rigoureuse. Ces ensembles permettent d'entraîner des modèles avec une grande précision, facilitant la distinction entre des activités ou des sons spécifiques grâce à des données claires et bien définies. La précision de ces données soutient l'apprentissage des modèles, permettant une généralisation efficace à partir d'exemples limités mais pertinents. En contraste, Aruba et Kitchen 20, capturant respectivement des séquences d'activités domestiques et des sons de cuisine, offrent des volumes de données plus importants issus de scénarios réels et complexes. Cette abondance et cette variété dans les données réelles posent des défis uniques pour l'entraînement des modèles, notamment en termes de gestion du bruit de fond, de la

variabilité des situations, et de l'interprétation des séquences d'activités continues. Ces ensembles ouvrent des voies précieuses pour tester la robustesse et l'adaptabilité des modèles, en les confrontant à des conditions diverses et en évaluant leur capacité à reconnaître et à classifier des activités dans des contextes plus proches de la vie quotidienne.

### **3.4. MISE EN ŒUVRE DE L'APPRENTISSAGE AUTOMATIQUE CLASSIQUE**

Dans cette section, nous aborderons la mise en œuvre des méthodes d'apprentissage automatique classique (ML) pour la reconnaissance d'activités humaines, en utilisant les jeux de données précédemment décrits. Nous explorerons comment ces méthodes traditionnelles de ML peuvent être appliquées efficacement pour analyser les données variées issues de ces jeux de données, et évaluerons leur performance par rapport aux approches plus complexes de DL.

#### **3.4.1. Prétraitements et traitements des données pour Aruba**

L'approche méthodologique adoptée pour le prétraitement et le traitement des données issues du jeu de données Aruba est un élément clé de notre étude en apprentissage automatique classique. Cette phase critique vise à préparer les données de manière à maximiser l'efficacité des analyses subséquentes et la précision des modèles développés. L'accent est mis sur la personnalisation des techniques de prétraitement et de traitement pour adapter notre approche aux caractéristiques uniques de ce jeu de données, avec l'objectif de tirer le meilleur parti des données disponibles. Une approche méthodique et détaillée a été adoptée pour le prétraitement et le traitement des données du jeu de données Aruba. Le processus commence par la création d'un dictionnaire pour cartographier les étiquettes en chiffres, suivi de la lecture et de la structuration des données depuis un fichier. Des

techniques sophistiquées ont été utilisées pour gérer les valeurs manquantes et les caractéristiques de données. Plusieurs techniques ont été évaluées pour gérer les valeurs manquantes, telles que l'imputation (utilisation de la moyenne ou de la médiane), l'examen des valeurs mal enregistrées, ou l'utilisation d'algorithmes capables de gérer les données manquantes. Dans ce traitement, les valeurs manquantes ont été gérées de manière à préserver l'intégrité et la qualité des données. Lors de la lecture du fichier, les valeurs manquantes dans la colonne 'Libelle' ont été remplacées par zéro, et dans la colonne 'Timestamp', la méthode 'forward fill' de la bibliothèque Pandas a été utilisée. Cette technique consiste à remplacer les valeurs manquantes (NaN) dans la séquence temporelle par la dernière valeur valide connue. L'implémentation de cette méthode a été réalisée grâce à l'instruction `data['Timestamp'].fillna(method='ffill', inplace=True)` [58]. En pratique, cela signifie que si un enregistrement particulier dans la colonne 'Timestamp' était absent ou non valide, le système a automatiquement inséré la valeur de l'horodatage précédent valide, assurant ainsi une continuité dans les données temporelles. Cette approche assure que les données sont complètes et prêtes pour l'analyse. En remplaçant les valeurs manquantes par des valeurs neutres ou en utilisant des méthodes de remplissage, nous évitons d'introduire des biais dans les modèles de ML. Cela garantit que les modèles développés sont basés sur des données complètes et fiables, reflétant fidèlement les activités enregistrées dans le jeu de données car un traitement inadéquat des valeurs manquantes peut entraîner des biais dans les résultats ou affecter la performance des modèles. Par conséquent, l'impact de chaque technique sur la qualité et la fiabilité des modèles de ML a été évalué pour assurer une analyse précise et fiable des données.

#### **3.4.1.1. Sélection des Caractéristiques**

Dans l'analyse du jeu de données Aruba, la sélection des caractéristiques a été une étape cruciale. Dans notre traitement du jeu de données Aruba, l'analyse en composantes principales (PCA) a été une étape cruciale pour gérer la dimensionnalité et réduire les caractéristiques. PCA est une technique statistique qui transforme les données initiales en un nouvel ensemble de variables, les composantes principales, qui sont non corrélées et qui capturent la majeure partie de la variance dans les données. En projetant les données sur les premières composantes principales, PCA permet de réduire la dimensionnalité tout en préservant les informations les plus importantes. Un certain nombre de composantes principales a été choisi pour capturer l'essentiel de la variance dans les données. Initialement, nous avons expérimenté avec un seuil de variance conservée de 0,80 pour la valeur de `n_components` dans PCA, visant à simplifier le modèle en réduisant le nombre de caractéristiques tout en retenant une quantité substantielle d'information. Cette approche a permis de réduire l'espace des caractéristiques de manière significative, toutefois, après une évaluation approfondie des performances des modèles et de la qualité de la représentation des données, il est apparu que l'augmentation de ce seuil à 0,95 offrait un équilibre optimal. En ajustant la valeur de `n_components` à 0,95, non seulement nous avons pu conserver une plus grande part de la variance des données, mais cela a également permis de capturer les aspects les plus significatifs des données sans compromettre la justesse des modèles. Cette modification a eu un impact direct sur la composition des caractéristiques utilisées pour l'entraînement des modèles. En passant d'un seuil de 0,80 à 0,95 pour `n_components`, le nombre de caractéristiques conservées après l'application de PCA a légèrement augmenté, mais chaque caractéristique retenue portait une quantité d'information beaucoup plus importante. La réduction de la dimensionnalité avec PCA diminue la complexité des données, ce qui se traduit par une accélération des calculs dans les modèles de ML.

### 3.4.1.2. Normalisation et prétraitement des données

La phase de normalisation et de prétraitement des données a joué un rôle crucial dans la préparation de notre jeu de données Aruba pour l'analyse via des modèles de ML. Cette étape a impliqué deux procédures principales : la standardisation des caractéristiques numériques et la conversion des valeurs catégorielles. Pour la standardisation, nous avons employé la méthode `StandardScaler` de la bibliothèque `scikit-learn`, qui réajuste les données pour qu'elles présentent une moyenne de zéro et un écart-type de un. Concrètement, après avoir isolé la colonne 'Valeur' qui contient les mesures numériques issues des capteurs, nous avons appliqué : `scaler = StandardScaler(); data[['Valeur']] = scaler.fit_transform(data[['Valeur']])`. Cette transformation a normalisé les valeurs des capteurs, rendant les mesures de différents capteurs comparables et prêtes pour l'analyse, malgré leurs échelles de mesure d'origine diverses. Quant à la conversion des données catégorielles, notamment la transformation des états des capteurs tels que "ON" et "OFF" en valeurs numériques, nous avons utilisé une approche directe et explicite dans le code de prétraitement. Cette conversion manuelle a permis de passer de valeurs textuelles à des représentations numériques, où, par exemple, "ON" et "OPEN" sont traités différemment des états "OFF" et "CLOSE", offrant ainsi aux algorithmes de machine learning la possibilité d'exploiter quantitativement ces informations. Enfin, la transformation des timestamps en valeurs numériques exploitables a été réalisée grâce à la méthode '`timestamp()`', transformant les dates et heures en nombres uniques représentant des moments spécifiques dans le temps. Ce choix méthodologique a été guidé par le désir d'exploiter les aspects temporels des données, cruciaux pour l'analyse des séquences d'activités dans le jeu de données Aruba. Ces étapes de prétraitement, allant de la standardisation des caractéristiques numériques à la



conversion des valeurs catégorielles et temporelles, ont non seulement harmonisé l'échelle des mesures des capteurs mais ont également assuré que toutes les variables, indépendamment de leur nature originale, contribuent de manière équilibrée et significative aux analyses menées par les modèles de machine learning.

#### **3.4.1.3. Techniques de validation croisée utilisées pour évaluer les modèles.**

Dans notre étude, pour évaluer la performance des modèles de machine learning appliqués au Jeu de données Aruba, nous avons utilisé la méthode de validation croisée à 10 plis. Cette technique consiste à diviser l'ensemble de données d'évaluation en dix parties égales. Pour chaque test, un de ces dix sous-ensembles est utilisé comme ensemble de test, et les neuf autres servent d'ensemble d'entraînement. Cette méthode, mise en œuvre via la fonction `KFold` de `scikit-learn`, permet de tester le modèle (dans notre cas, nous avons appliqué plusieurs modèles comme KNN, SVM, Random Forest, ...) sur différents sous-ensembles de données pour assurer une évaluation complète et équilibrée. Elle offre une mesure fiable de la justesse du modèle, indiquée par `scoring='accuracy'`, ce qui signifie que nous évaluons à quelle fréquence les prédictions du modèle correspondent aux étiquettes réelles. Cela aide à garantir que notre modèle fonctionne bien non seulement sur un ensemble de données spécifique, mais sur de multiples échantillons, reflétant ainsi sa capacité à généraliser à de nouvelles données.

#### **3.4.2. Prétraitements et traitements des données pour le UCI-HAR**

Dans le cadre de notre recherche, l'application des techniques de ML classique sur le jeu de données UCI-HAR a nécessité une approche de prétraitement et de traitement des données soigneusement élaborées. Cette approche est essentielle pour assurer la précision

des modèles prédictifs développés. Nous avons intégré PCA et la sélection de caractéristiques via un modèle SVM linéaire pour cibler les variables cruciales. Cette démarche a conduit à une simplification stratégique des données, où 300 composantes principales ont été retenues pour capturer l'essence de la variance, suivie d'une sélection rigoureuse basée sur l'importance attribuée par le modèle SVM. Cette optimisation a eu un impact notable sur la performance des modèles, offrant une justesse accrue par rapport à des configurations incluant un nombre supérieur de composantes. Lorsque nous avons expérimenté avec 450 composantes, atteignant ainsi une variance cumulée de 100%, l'augmentation marginale observée n'a pas compensé la complexité supplémentaire introduite. En effet, avec plus de 300 composantes, une tendance au surajustement et une baisse de l'efficacité globale du modèle ont été constatées, confirmant la pertinence de notre décision d'opter pour un seuil de 300 composantes. Cette limite s'est avérée être le point d'équilibre optimal, conservant une grande partie de l'information (97% de variance) tout en évitant les inconvénients d'une dimensionnalité excessive. En contraste, une réduction à seulement 100 composantes capturerait 94% de la variance, révélant une perte d'information plus significative, ce qui justifie notre choix de 300 composantes comme le compromis idéal entre simplification et préservation de l'intégrité des données. Nous avons utilisé le StandardScaler pour ajuster les échelles des différentes variables. Ces méthodes sont cruciales pour équilibrer l'influence des différentes caractéristiques sur le modèle et pour éviter que des variables avec de plus grands ordres de grandeur ne dominent le processus d'apprentissage.

Nous avons aussi examiné et résumer les méthodologies adoptées dans les études de référence sur le traitement des données du Jeu de données UCI-HAR. Cette analyse couvre

les différentes techniques de prétraitement et de traitement de données utilisées dans ces travaux, en mettant en lumière les stratégies clés, les outils et les approches spécifiques à chaque étude. Cela nous permettra de comprendre comment ces méthodes peuvent influencer ou être intégrées dans notre propre recherche. Les travaux de recherche analysés ont révélé des approches diversifiées en matière de prétraitement et de traitement des données pour la reconnaissance d'activités humaines. Dans une des études, l'accent a été mis sur l'évaluation de la qualité des données et la gestion des types de données incompatibles, soulignant l'importance du nettoyage et du formatage des données [59]. Dans certains, les auteurs ont appliqué des filtres de bruit et ont utilisé un échantillonnage en fenêtres coulissantes[53], tandis que d'autres ont mis en œuvre des méthodes de sélection de caractéristiques pour optimiser le traitement des données en appliquant deux techniques de sélection de caractéristiques pour simplifier les données et affiner les modèles de classification. La première s'appuie sur des arbres de décision pour identifier et retenir les caractéristiques clés selon leur impact sur la classification. La seconde utilise la régularisation L1 pour filtrer les caractéristiques en fonction de leur corrélation avec la variable cible, écartant celles jugées non pertinentes [59]. Enfin, [48] ont concentré leurs efforts sur l'ajustement des hyperparamètres dans les modèles de deep learning, où l'étude a utilisé une recherche en grille pour optimiser les hyperparamètres d'un modèle Deep Residual Bidir-LSTM dédié à la reconnaissance des activités humaines, améliorant significativement ses performances. En ajustant soigneusement des paramètres clés comme le taux d'apprentissage et le multiplicateur de dégradation L2, les chercheurs ont renforcé la précision et la généralisation du modèle sur divers ensembles de données parmi lesquels UCI-HAR, démontrant l'importance cruciale de l'ajustement des hyperparamètres dans l'amélioration de l'efficacité des modèles.

Dans l'évaluation critique des stratégies de traitement des données pour le Jeu de données UCI-HAR, nous constatons que chaque étude apporte des contributions uniques, mais aussi certaines limitations. Les techniques de prétraitement avancées, telles que l'utilisation de filtres de bruit et l'échantillonnage en fenêtres coulissantes adoptées par [60], sont efficaces pour nettoyer les données, mais peuvent introduire une complexité supplémentaire dans le traitement. La sélection de caractéristiques de [59] offre une réduction significative du temps de calcul, mais peut omettre des informations critiques. L'ajustement des hyperparamètres dans les modèles augmente la justesse [48], mais nécessite une expertise approfondie et du temps. Ces approches, bien que bénéfiques, doivent être soigneusement adaptées et équilibrées pour maximiser à la fois l'efficacité et la simplicité des modèles de machine learning.

### **3.4.3. Prétraitements et traitements des données pour ESC-50 ET KITCHEN 20**

Dans notre exploration des jeux de données ESC-50 et Kitchen 20, nous abordons le défi unique que représente le traitement de données audio. Ces jeux de données, composés de fichiers sonores, nécessitent des méthodes de prétraitement et de traitement distinctes, adaptées à leurs caractéristiques spécifiques. Notre objectif est de développer des techniques qui exploitent pleinement la nature audio de ces données, en mettant l'accent sur la reconnaissance précise et efficace des sons et des activités humaines. Ici, nous avons expérimenté sur deux ensembles de données pour former un seul comme dans les travaux sur lesquels nous nous sommes appuyés, et ensuite nous avons bénéficié d'un accès aux jeux de données qui nous a été fourni par un des auteurs d'une de nos revues de littérature. Nous avons commencé par charger les métadonnées de chaque jeu de données dans des

DataFrames pandas, ce qui a permis une manipulation aisée des informations relatives à chaque enregistrement audio. Pour chaque fichier audio, les détails tels que le nom du fichier, la catégorie de son, et le numéro de pli. Dans ce contexte, le "pli" indique un sous-ensemble spécifique au sein de l'ensemble de données, utilisé pour organiser les enregistrements audio en catégorie. Une étape cruciale a été la normalisation des chemins vers les fichiers audio et leur renommage pour refléter de manière cohérente leur catégorie et leur appartenance à un pli spécifique. Cette organisation a non seulement facilité la gestion des données mais a également permis une identification plus directe des fichiers lors des étapes de traitement ultérieures. Pour comprendre la distribution des catégories de sons dans les ensembles combinés, nous avons généré un diagramme à barres illustrant le nombre de fichiers audio par catégorie.

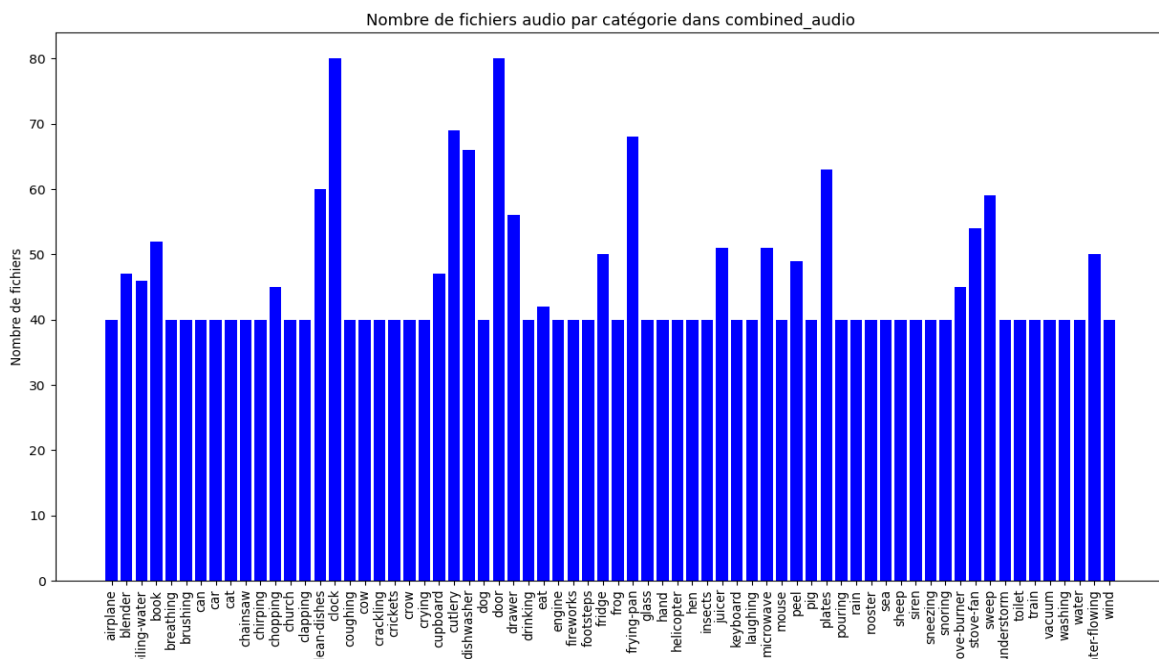


Figure 13 : Répartition des différentes catégories de notre jeu de données

©Brondon Styve,2024.

Cette analyse visuelle à la Figure 12 a aidé à identifier les catégories prédominantes et a orienté les décisions concernant les priorités d'analyse et d'entraînement des modèles. Un filtrage minutieux a été effectué pour sélectionner les enregistrements audio pertinents selon des catégories d'activités humaines prédéfinies. Ce processus a assuré que seuls les enregistrements liés aux actions humaines soient inclus dans l'analyse, optimisant ainsi la pertinence des données pour l'entraînement des modèles. Les fichiers audio sélectionnés ont été organisés dans un dossier commun, prêts pour les étapes d'extraction de caractéristiques et d'entraînement des modèles. Nous avons créé un DataFrame avec Pandas consolidé contenant les catégories et les chemins vers les fichiers audio filtrés, facilitant ainsi l'accès et le traitement ultérieur des données. Après avoir sélectionné les enregistrements audio pertinents, nous les avons centralisés dans un dossier unique nommé 'combined\_audio', pour simplifier l'accès lors des phases d'extraction de caractéristiques et d'entraînement des modèles. En parallèle, un DataFrame pandas a été créé, listant les catégories des sons et les chemins correspondants vers les fichiers audio dans ce dossier commun. Cette organisation méthodique a non seulement rationalisé la gestion des données audio mais a également optimisé le processus d'analyse en facilitant un accès direct et structuré aux fichiers, crucial pour l'extraction efficace des caractéristiques et l'entraînement précis des modèles sur les jeux de données ESC-50 et Kitchen 20.

Pour le prétraitement des jeux de données audio ESC-50 et Kitchen 20, nous avons intégré des techniques avancées comme la réduction du bruit et l'extraction de caractéristiques significatives. En utilisant Librosa [61], une bibliothèque puissante pour l'analyse audio, nous avons chargé les fichiers audio et extrait les coefficients cepstraux de fréquence de Mel (MFCCs), qui fournissent une représentation riche et condensée des

propriétés spectrales des sons [61]. Nous avons également appliqué un traitement pour réduire le bruit de fond, afin d'obtenir des données audio claires et précises pour une analyse plus efficace. Avant l'analyse, un traitement de réduction du bruit est appliqué aux enregistrements audio. Cette étape vise à supprimer les sons indésirables et les interférences, permettant une meilleure clarté et focalisation sur les sons pertinents.

Les coefficients cepstraux de fréquence de Mel (MFCCs) sont extraits en utilisant Librosa. Les MFCCs transforment le spectre de puissance d'un signal audio en une petite série de caractéristiques, qui capturent l'essence du son tout en réduisant la complexité des données. Chaque MFCC est un coefficient représentant une caractéristique spécifique du son, comme sa fréquence ou son timbre. Ensuite, nous calculons la moyenne de ces coefficients sur chaque fichier audio. Pour chaque enregistrement audio, nous calculons la moyenne des treize coefficients MFCC, ce qui donne lieu à un vecteur de caractéristiques de taille fixe. Par exemple, pour le fichier audio 1-26188-A-30\_cat-door\_wood\_knock\_fold-1.wav, le vecteur de caractéristiques MFCC résultant est le suivant : [-397.20822, 92.84853, 28.553719, 20.698265, 8.306844, 10.968207, 18.36738, 11.30198, 4.868713, 4.0529776, 6.530725, 7.9787064, 8.836627]. Ce vecteur représente une empreinte acoustique compacte du fichier, où chaque valeur reflète la moyenne d'un aspect spectral différent capturé sur l'ensemble de l'enregistrement. Grâce à cette réduction dimensionnelle, nous simplifions l'analyse en condensant les informations sonores complexes en un format succinct et gérable, tout en conservant les éléments essentiels nécessaires pour caractériser le profil sonore de l'enregistrement.

### **3.5. CHOIX ET PARAMETRAGE DES MODELES D'APPRENTISSAGE**

#### **AUTOMATIQUE**

Dans la partie précédente, nous avons minutieusement abordé les méthodes de prétraitement et de traitement des données pour divers jeux de données, notamment Aruba, UCI-HAR, ESC-50 et Kitchen 20. Ces étapes préparatoires essentielles ont jeté les bases nécessaires pour l'application efficace des modèles d'apprentissage automatique. À présent, dans cette section, nous nous concentrons sur le choix stratégique et le paramétrage méticuleux de ces modèles d'apprentissage automatique classique. La sélection des modèles appropriés pour chaque jeu de données est une démarche cruciale qui doit être effectuée en tenant compte des spécificités des données prétraitées. Chaque modèle possède des caractéristiques et des forces uniques, ce qui le rend plus ou moins adapté à certains types de données ou à certaines tâches. Ainsi, notre objectif ici est de déterminer quels modèles sont les plus appropriés pour maximiser la performance et la précision des prédictions sur chaque jeu de données spécifique. En parallèle, le paramétrage de ces modèles est tout aussi vital. Cette étape implique un ajustement fin des paramètres et des hyperparamètres de chaque modèle, une tâche qui requiert une compréhension approfondie non seulement des modèles eux-mêmes, mais aussi des caractéristiques des données sur lesquelles ils seront appliqués. L'optimisation des paramètres est un processus délicat et essentiel pour atteindre des performances optimales, éviter le surajustement et garantir la généralisation des modèles.

Dans les sous-sections suivantes, nous explorerons en détail la sélection et la configuration des modèles pour chaque jeu de données, en justifiant nos choix et en démontrant comment ces décisions s'appuient sur notre travail antérieur de prétraitement des données. Nous discuterons également des techniques utilisées pour l'optimisation des



hyperparamètres, en mettant l'accent sur la recherche par grille et la recherche aléatoire, et en évaluant leur efficacité dans le contexte de nos données et objectifs de recherche spécifiques.

### **3.5.1. Sélection des modèles pour chaque jeu de données**

Notre étude sur les jeux de données Aruba et UCI-HAR a impliqué l'utilisation d'une variété de modèles d'apprentissage automatique classique, sélectionnés pour leurs caractéristiques uniques et leur adaptabilité aux spécificités de ces ensembles de données. Nous avons opté pour le Random Forest en raison de sa robustesse et de sa capacité à gérer des données complexes et hétérogènes, idéal pour modéliser des interactions non linéaires sans surajuster. Le modèle KNN a été choisi pour son efficacité dans les contextes où les relations spatiales entre les données sont prédominantes, offrant une méthode de classification basée sur la proximité. Les SVM se distinguent par leur aptitude à établir des frontières de décision complexes dans des espaces de grande dimension, ce qui les rend utiles pour des jeux de données aux frontières de classes floues. Naive Bayes, reconnu pour sa rapidité et son efficacité, gère bien de vastes volumes de données malgré l'hypothèse simplificatrice d'indépendance des caractéristiques. La régression linéaire, malgré sa simplicité, sert de référence pour comprendre la complexité des relations dans les jeux de données. XGBoost a été sélectionné pour sa performance exceptionnelle en vitesse et précision, capable de traiter efficacement les déséquilibres et les caractéristiques de grande dimension. LightGBM, quant à lui, offre une solution rapide et puissante pour les grandes quantités de données, ce qui est essentiel pour les ensembles volumineux tels que Aruba et UCI-HAR. Pour le jeu de données combiné issu de Kitchen20 et ESC-50, qui se concentre sur la reconnaissance d'activités à partir de données audio, les modèles KNN, SVM,

XGBoost et Random Forest sont des modèles de machine que nous avons utilisés, chacun offrant des capacités uniques pour reconnaître des motifs complexes et gérer des données variées.

Cette diversité de modèles nous permet d'explorer une gamme de techniques et d'approches, augmentant ainsi nos chances de découvrir des insights pertinents et d'obtenir des résultats précis et fiables.

### **3.5.2. Configuration et optimisation des paramètres**

Après avoir sélectionné des modèles adaptés pour chaque jeu de données, il est essentiel de configurer et d'optimiser leurs paramètres pour maximiser leur efficacité. Cette étape est cruciale car elle influence directement la performance des modèles en termes de précision, de rapidité et de fiabilité.

Nous avons utilisé un `random_state` de 42 pour Random Forest et SVM sur tous les jeux de données, garantissant ainsi une cohérence des résultats. Le KNN a été réglé avec `n_neighbors=5`, équilibrant précision et robustesse. Pour les jeux de données Aruba et UCI-HAR, l'adoption des paramètres par défaut s'est avérée la plus efficace, reflétant une optimisation communautaire. Un kernel linéaire a été préféré pour le SVM sur ces jeux, tandis qu'un kernel RBF a été sélectionné pour ESC-50 et Kitchen 20, adaptant ainsi le modèle à la complexité des données audio. Le nombre d'arbres pour Random Forest a été fixé à 100, et le paramètre `gamma` du SVM a été ajusté sur 'scale', s'alignant sur les spécificités des données. Cette méthode adaptative illustre notre volonté d'exploiter au mieux les particularités de chaque jeu de données, visant une harmonie entre performance des

modèles et facilité d'implémentation, tout en étant prêts à ajuster les paramètres en réponse aux défis spécifiques des données audio et de reconnaissance d'activités.

### **3.5.3. Optimisation des hyperparamètres**

L'optimisation des hyperparamètres est une étape cruciale pour affiner la performance de nos modèles d'apprentissage automatique. Cette démarche consiste à ajuster les paramètres qui régissent le processus d'apprentissage des modèles pour maximiser leur efficacité. Dans notre étude, cette optimisation a été réalisée pour les modèles appliqués aux jeux de données Aruba, UCI-HAR, ESC-50 et Kitchen 20.

Nous avons employé deux approches principales pour l'optimisation des hyperparamètres. Premièrement la recherche par Grille qui est méthode systématique teste une combinaison de valeurs d'hyperparamètres prédéfinies. Elle est exhaustive mais peut être coûteuse en termes de temps et de ressources de calcul, surtout avec un grand nombre d'hyperparamètres. Et la recherche Aléatoire qui est plus flexible que la recherche par grille, cette approche sélectionne aléatoirement des combinaisons d'hyperparamètres dans une plage prédéfinie. Elle est souvent plus rapide et peut parfois aboutir à des résultats surprenants qui ne seraient pas découverts par une recherche par grille. Nous avons optimisé les hyperparamètres pour plusieurs modèles, ajustant des éléments clés comme le nombre d'arbres et la profondeur pour Random Forest, le nombre de voisins pour KNN, ainsi que le type de noyau et le paramètre de régularisation pour SVM, en plus des paramètres spécifiques à LightGBM et XGBoost. L'utilisation de la validation croisée a permis d'évaluer l'efficacité de ces ajustements, assurant une performance solide des modèles sur diverses subdivisions des données et leur capacité à bien généraliser. Cette optimisation, réalisée via

des méthodes comme la recherche par grille, vise à équilibrer précision, temps, et ressources de calcul, garantissant ainsi des modèles robustes et bien adaptés aux caractéristiques de chaque jeu de données.

### **3.6. STRATEGIES D'ÉVALUATION DES MODELES**

Après l'optimisation des hyperparamètres, il est essentiel de mettre en place des stratégies d'évaluation rigoureuses pour mesurer la performance de nos modèles d'apprentissage automatique. Cette évaluation joue un rôle crucial dans la validation de l'efficacité des modèles sur les jeux de données Aruba, UCI-HAR, ESC-50 et Kitchen 20. Voici les approches que nous avons adoptées pour cette phase critique dans la suite.

Nous avons utilisé la validation croisée à K-plis pour évaluer la robustesse de nos modèles. Cette technique divise le jeu de données en K sous-ensembles (ou plis) et utilise chaque sous-ensemble comme un ensemble de test, tandis que les autres sous-ensembles servent d'ensemble d'apprentissage. En plus de la validation croisée, nous avons réservé une partie du jeu de données comme ensemble de test indépendant. Cette méthode fournit une évaluation objective de la performance du modèle sur des données non vues lors de la phase d'apprentissage. Pour certains cas nous n'avons pas utilisé le K-Fold mais plutôt une approche directe en divisant les données en ensemble de validation et de test selon un certain pourcentage, ce qui permet une évaluation fiable des modèles sur des données inédites, assurant l'équilibre entre entraînement et test, la reproductibilité des résultats, et l'efficacité de l'utilisation des ressources. Ce choix stratégique vise à optimiser la performance du modèle tout en garantissant une répartition représentative et proportionnelle des données.

Pour évaluer l'efficacité de nos modèles, nous avons adopté une approche multi-métrique, incluant la justesse, le rappel, le F1-Score, et l'analyse via la matrice de confusion. La précision, indicateur essentiel de la justesse des classifications du modèle, est cruciale pour des jeux de données où les classes sont équilibrées [62]. Pour les jeux de données présentant un déséquilibre de classes, le rappel, qui quantifie la capacité du modèle à identifier tous les cas positifs, et le F1-Score, qui harmonise justesse et rappel, deviennent centraux [62]. La matrice de confusion offre une vue d'ensemble de la performance modèle, révélant les vrais positifs, faux positifs, vrais négatifs et faux négatifs [62], fournissant ainsi une analyse détaillée de la capacité discriminative du modèle au-delà des simples taux de succès.

## **CHAPITRE 4**

### **RÉSULTATS ET ANALYSES**

#### **4.1. INTRODUCTION**

Dans ce chapitre, nous nous penchons sur les résultats obtenus à la suite de l'application des modèles d'apprentissage automatique sur les jeux de données Aruba, UCI-HAR, ainsi que sur le jeu de données combiné ESC-50 et Kitchen 20. L'objectif ici est de fournir une analyse approfondie de ces résultats, en évaluant la performance des modèles et en explorant les implications pratiques et théoriques de nos découvertes.

Nos objectifs initiaux étaient de déterminer l'efficacité des modèles d'apprentissage automatique classiques dans des contextes variés et de comparer leur performance avec celle des techniques de deep learning. En particulier, nous avons cherché à comprendre comment ces modèles se comportent dans des scénarios de reconnaissance d'activités humaines, un domaine d'application de plus en plus pertinent dans l'ère actuelle de l'intelligence artificielle. Dans les sections suivantes, nous présentons les résultats détaillés pour chaque jeu de données, en fournissant une analyse comparative des performances des différents modèles. Nous discuterons également des points forts et des limitations observés, ainsi que de toute anomalie ou résultat inattendu et de son impact potentiel sur nos conclusions. Cette analyse nous permettra de tirer des conclusions éclairées sur l'efficacité des modèles d'apprentissage automatique dans divers contextes et de proposer des recommandations pour des recherches futures.

## 4.2. RESULTATS SUR LE JEU DE DONNÉES ARUBA

Dans cette sous-section, nous examinons en détail la performance des différents modèles d'apprentissage automatique que nous avons appliqués au jeu de données Aruba. Notre analyse se concentre sur des métriques clés de performance telles que la justesse, le rappel et le F1-Score. Ces métriques fournissent un aperçu complet de l'efficacité de chaque modèle dans la reconnaissance d'activités à partir de données issues de capteurs domestiques.

### 4.2.1. Random forest sur le jeu de données Aruba

Le modèle Random Forest a été initialisé avec des paramètres de base, notamment un `random_state` fixé à 42 pour assurer la reproductibilité. Cette première exécution a donné une justesse moyenne de 93%, indiquant une performance élevée dès le départ. Des champs temporels tels que l'année, le mois et le jour ont été ajoutés aux caractéristiques du modèle dans le but d'enrichir l'analyse de ces informations n'a pas significativement modifié la justesse, qui est passé de 93% à 94%. Par la suite, nous nous sommes inspirés de l'approche utilisée dans l'article [11]. Les transformations de Fourier discrète (DFT) et en ondelettes discrètes (DWT) ont été appliquées pour extraire des caractéristiques à partir des données brutes des capteurs. Ces techniques avancées de traitement des données ont légèrement augmenté la justesse, la portant à 93,55%. L'augmentation de la justesse à la suite de l'application des techniques DFT et DWT démontre l'importance d'une extraction de caractéristiques sophistiquée pour améliorer la reconnaissance d'activités dans les environnements d'habitats intelligents. La constance de la justesse, même après l'ajout de données temporelles, suggère que le modèle Random Forest était initialement bien paramétré pour ce type de données.

Tableau 1 : Récapitulation des résultats appliqués sur Aruba par random forest

| Étapes                                       | Justesse (%) | Rappel (%) | F1 Score (%) |
|--|--------------|------------|--------------|
| Random Forest par défaut                     | 93           | 93         | 93           |
| Random Forest + caractéristiques temporelles | 94           | 94         | 94           |
| Random Forest + DTW et DFT                   | 93,55        | 93         | 93           |

#### 4.2.2. KNN sur le jeu de données Aruba

Suivant la méthode décrite dans l'article [60] nous avons implémenté plusieurs étapes clés pour le traitement des données avant de les soumettre à l'algorithme KNN. Les données de capteurs continus ont été segmentées en fenêtres de 10 secondes avec un chevauchement de 50%, conformément à la méthode des auteurs. Des caractéristiques telles que la moyenne, l'écart-type, le maximum, le minimum, la pente et l'interquartile pour chaque capteur ont été extraites. Les caractéristiques de localisation, telles que le nombre de capteurs actifs par pièce et dans les pièces adjacentes, ont été ajoutées. L'application de cette approche a donné une justesse de 64%. En contraste avec l'approche précédente, nous avons simplifié le processus en exécutant le KNN standard avec l'ajout du jour et de l'heure comme caractéristiques supplémentaires. Cette simplification a considérablement amélioré la justesse, la portant à 97,31%, avec un rappel moyen de 81% et un F1-Score de 83%. La matrice de confusion obtenue pour le modèle KNN appliqué au jeu de données Aruba, illustrée à la figure 13, indique une prédominance de classifications correctes par le modèle. Par exemple, la catégorie 'Respirate' présente 543 instances correctement identifiées (vrais positifs) contre 20 instances incorrectement classées dans d'autres catégories.



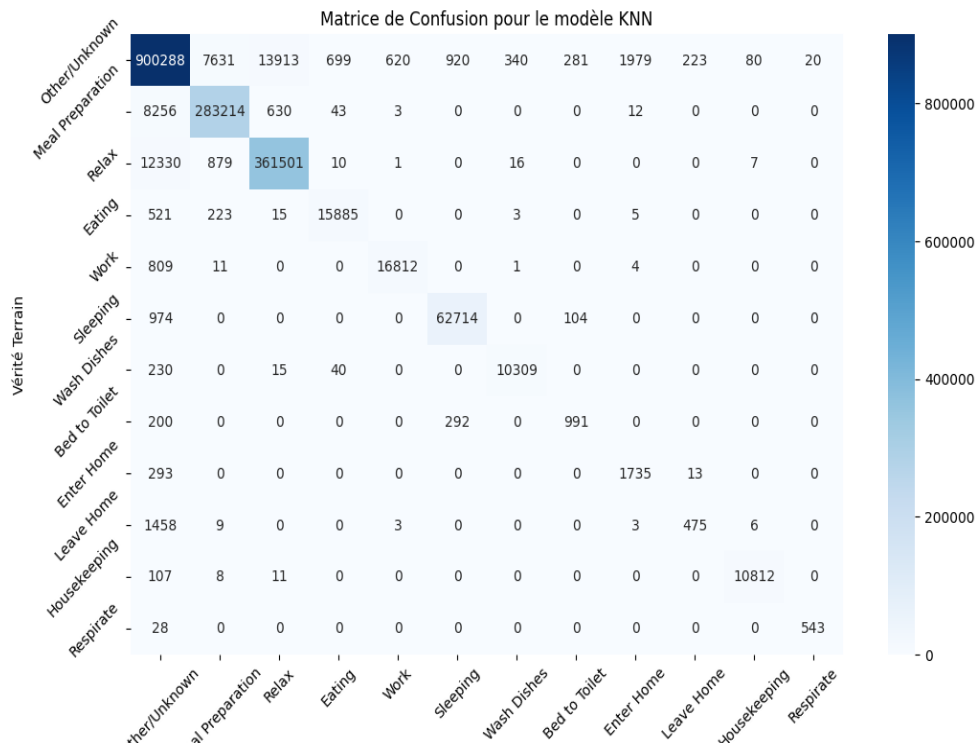


Figure 14 : Matrice de confusion du meilleur résultat de KNN sur Aruba

©Brondon Styve,2024.

Pour évaluer davantage la robustesse du modèle, une validation croisée à 10 plis a été utilisée. Cette technique a légèrement réduit la justesse à 96,63%, mais a amélioré le rappel moyen à 87% et le F1-Score moyen à 86%.

Tableau 2 : Récapitulation des résultats appliqués sur Aruba par les KNN

| Étapes                                     | Justesse (%) | Rappel (%) | F1-Score (%) |
|--|--------------|------------|--------------|
| KNN + DCR                                  | 64           | 65         | 63           |
| KNN + caractéristiques temporelles         | 97,31        | 81         | 83           |
| KNN + caractéristiques temporelles + kfold | 96,63        | 87         | 86           |

L'amélioration significative des performances en passant de l'approche DCR à une implémentation plus simplifiée souligne l'importance de la sélection et de la préparation des caractéristiques dans la reconnaissance d'activités.

Impact de la Validation Croisée : L'utilisation de la validation croisée a légèrement diminué la justesse mais a amélioré la généralisabilité du modèle, comme en témoigne l'augmentation du rappel et du F1-Score.

#### **4.2.3. SVM sur le jeu de données Aruba**

Le modèle SVM a été appliqué avec une stratégie standard, en utilisant un kernel 'rbf', un paramètre de régularisation C fixé à 1.0, un gamma 'scale', et un random\_state à 42 pour garantir la reproductibilité. Cette configuration initiale a permis d'atteindre une justesse moyenne de 74%, un rappel de 74% et un F1Score de 72%. Malgré l'utilisation des paramètres par défaut généralement efficaces, la performance du SVM dans ce contexte spécifique a été modeste. Cela pourrait être dû aux caractéristiques particulières du Jeu de données Aruba, qui peut présenter des défis tels que des dimensions élevées ou des frontières de décision complexes que le kernel RBF standard n'est pas en mesure de capturer efficacement.

#### **4.2.4. Arbre de décision sur le jeu de données Aruba**

L'arbre de décision a été déployé avec ses paramètres par défaut, sans modifications ou optimisations particulières. Cette approche initiale a produit une justesse de 95,64%, un rappel et un F1-Score de 95%. S'inspirant de l'article [63], nous avons appliqué une approche de fenêtrage pour extraire des caractéristiques spatio-temporelles. Cela se fait par l'utilisation d'une fenêtre glissante pour diviser les données de capteurs et par l'extraction de

caractéristiques statistiques pour chaque segment. Avec cette méthode, nous avons atteint une justesse moyenne de 95,88%, un rappel de 93% et un F1-Score de 95%. En ajoutant des variables telles que le jour de la semaine et l'heure du jour au modèle, cette modification a légèrement amélioré la justesse, la portant à 96,05%. Les résultats remarquables obtenus avec l'arbre de décision, même avec les configurations de base, démontrent son efficacité dans la gestion des données du jeu de données Aruba. L'application de la méthode de fenêtrage a fourni une légère amélioration, soulignant l'importance de l'extraction de caractéristiques adaptée pour la reconnaissance d'activités. L'intégration des informations temporelles a contribué à une amélioration marginale des performances, suggérant que ces variables peuvent fournir des indices contextuels utiles.

*Tableau 3 : Récapitulation des résultats appliqué sur Aruba par les arbres de décision*

| <b>Étapes</b>                                      | <b>Justesse (%)</b> | <b>Rappel (%)</b> | <b>F1-Score (%)</b> |
|--|---------------------|-------------------|---------------------|
| Arbre de décision par défaut                       | 95,64               | 95                | 95                  |
| Arbre de décision + Méthode de fenêtrage           | 95,88               | 93                | 95                  |
| Arbre de décision + ajout de variables temporelles | 96,05               | 87                | 86                  |

#### **4.2.5. Performance des autres modèles sur le jeu de données Aruba**

Dans l'évaluation des performances sur le jeu de données Aruba, LightGBM, XGBoost et Naive Bayes ont été testés avec leurs paramètres par défaut, aboutissant respectivement à des justesses de 67%, 75% et 54%. Ces résultats, inférieurs aux attentes, soulignent l'importance d'une personnalisation des paramètres et d'un prétraitement adapté. LightGBM et XGBoost, malgré leur efficacité générale en machine learning, indiquent le besoin

potentiel d'ajustements spécifiques pour ce contexte, tandis que la performance moindre du Naive Bayes reflète ses limites structurelles face à la complexité des données Aruba.

#### 4.2.6. Comparaison et analyse critique des performances sur le jeu de données Aruba

Tableau 4 : Meilleures performances en termes de justesse pour chaque modèle testé

| Modèle            | Justesse (%) | Rappel (%) | F1-Score (%) |
|-------------------|--------------|------------|--------------|
| Arbre de décision | 96,05        | 87         | 86           |
| KNN               | 97,31        | 87         | 86           |
| Random Forest     | 94           | 94         | 94           |
| SVM               | 74           | 74         | 72           |
| LightGBM          | 67           | 67         | 67           |
| XGBoost           | 75           | 75         | 74           |
| Naive Bayes       | 54           | 54         | 38           |

Après avoir examiné les performances individuelles de chaque modèle, il est crucial d'entreprendre une analyse comparative pour mettre en perspective ces résultats. Nous comparons les modèles en fonction de leurs scores de justesse, de rappel et de F1-Score. Cette comparaison révèle des observations importantes sur la capacité de chaque modèle à équilibrer la sensibilité et la spécificité. Les arbres de décision montrent une forte capacité de classification avec une justesse allant jusqu'à 96,05%, particulièrement lorsqu'ils sont couplés à l'ajout de variables temporelles, malgré une légère baisse du rappel et du F1-Score dans cette configuration. Le KNN a démontré une amélioration notable de la justesse (jusqu'à 97,31%) lorsque des ajustements spécifiques sont appliqués, bien que le rappel et le F1-Score soient moins élevés que la justesse dans certaines configurations. Le modèle Random Forest offre une performance stable avec une justesse et un F1-Score atteignant 94%,

spécialement avec l'intégration de caractéristiques temporelles. Cette méthode se distingue par sa robustesse et sa fiabilité, montrant une légère variation en présence de techniques avancées comme DTW et DFT. Cependant, le SVM présente des résultats plus modérés avec une justesse, un rappel et un F1-Score autour de 74%, suggérant que le modèle pourrait bénéficier d'un réglage fin des hyperparamètres ou d'un prétraitement des données pour améliorer son efficacité dans ce contexte spécifique. Quant aux autres modèles testés (LightGBM, XGBoost et Naive Bayes) avec des paramètres par défaut, ils ont montré des performances variables, avec XGBoost atteignant 75% de justesse, tandis que LightGBM et Naive Bayes affichent des résultats inférieurs, respectivement 67% et 54%. Ces écarts soulignent l'importance d'une adaptation et d'une optimisation minutieuses des modèles aux particularités du jeu de données Aruba pour maximiser leur performance.

L'optimisation des modèles de machine learning via Grid Search a entraîné des améliorations significatives dans la performance de divers algorithmes sur le jeu de données Aruba, révélant la variabilité dans la capacité de chaque modèle à gérer efficacement des tâches de classification complexes. Notamment, le Naive Bayes, qui était initialement le moins performant, a vu sa justesse augmenter considérablement à 68.70% grâce à l'ajustement fin de l'hyperparamètre alpha à 0.01. Cependant, malgré ces succès, l'optimisation a curieusement entraîné une baisse de la justesse pour le modèle KNN, dont la justesse est passée à 93.05% après optimisation avec les hyperparamètres {'metric': 'manhattan', 'n\_neighbors': 9, 'weights': 'uniform'}, contre une performance initialement supérieure. De son côté, XGBoost a bénéficié d'une optimisation menant à une justesse de 75.82%, avec des hyperparamètres clés {'learning\_rate': 0.5, 'max\_depth': 6, 'n\_estimators':

300}, et LightGBM a montré une justesse de 75.00% suite à l'optimisation, avec des paramètres {'learning\_rate': 0.01, 'n\_estimators': 300, 'num\_leaves': 124}.

Ces résultats, tout en soulignant l'impact de l'optimisation des hyperparamètres, révèlent aussi que LightGBM et XGBoost, malgré leur popularité, n'ont pas atteint des niveaux de performance particulièrement élevés pour ce jeu de données spécifique, soulignant ainsi l'importance d'une adaptation et d'une optimisation minutieuse des modèles en fonction des particularités du jeu de données traité. Cette nécessité est d'autant plus prononcée pour le modèle Naive Bayes, dont la faible performance initiale peut être attribuée à l'hypothèse d'indépendance des caractéristiques, souvent irréaliste dans des contextes complexes tels que celui d'Aruba. Par ailleurs, le modèle SVM, malgré l'utilisation d'un kernel 'rbf', n'a affiché qu'une performance modeste, ce qui indique des difficultés à traiter efficacement les caractéristiques uniques du jeu de données Aruba. Ces observations mettent en évidence non seulement l'importance de choisir et d'ajuster les hyperparamètres en fonction des spécificités de chaque modèle et du jeu de données, mais aussi la nécessité d'une analyse approfondie et d'une validation rigoureuse pour surmonter les défis spécifiques à chaque classe de prédictions et garantir des améliorations ciblées et efficaces.

Cette analyse souligne l'importance d'adapter les modèles aux spécificités du jeu de données. Les approches qui fonctionnent bien dans un contexte peuvent être moins efficaces dans un autre. Les résultats mettent en évidence le potentiel d'amélioration des modèles par des ajustements et des optimisations ciblés.

#### **4.3. RESULTATS SUR LE JEU DE DONNEES UCI-HAR**

Cette sous-section examine la performance de divers modèles d'apprentissage automatique appliqués au Jeu de données UCI-HAR, un ensemble de données centré sur la reconnaissance d'activités humaines à partir de données de capteurs de smartphones. Nous analysons les résultats obtenus en appliquant des configurations de base et des optimisations supplémentaires pour certains modèles. Dans cette sous-section, nous analyserons la performance de divers modèles appliqués au jeu de données UCI-HAR. Commençons par le modèle KNN.

#### 4.3.1. KNN sur le jeu de données UCI-HAR

En utilisant les paramètres de base du KNN, nous avons obtenu une justesse moyenne de 90,02%, avec un rappel et un F1-Score de 90%. Ces résultats suggèrent une capacité raisonnable du KNN à traiter les données du Jeu de données UCI-HAR dans sa configuration standard. Nous avons appliqué une recherche par grille avec les paramètres tels que : (**'n\_neighbors':range(1, 26), 'weights': ['uniform', 'distance']**). L'optimisation a conduit à une justesse moyenne de 90% et un rappel et F1-Score de 89%. Bien que l'optimisation n'ait pas significativement amélioré la justesse, elle a légèrement influencé le rappel et le F1-Score, indiquant un léger ajustement dans l'équilibre entre la sensibilité et la spécificité du modèle.

*Tableau 5 : Récapitulation des résultats appliqué sur UCI-HAR par les KNN*

| <b>Etapes</b>     | <b>Justesse (%)</b> | <b>Rappel (%)</b> | <b>F1-Score (%)</b> |
|-------------------|---------------------|-------------------|---------------------|
| KNN               | 90,02               | 90                | 90                  |
| KNN + Grid Search | 90                  | 89                | 89                  |

L'analyse du KNN sur le Jeu de données UCI-HAR révèle que, bien que les performances de base soient solides, les ajustements fins à travers la recherche par grille n'ont pas apporté d'améliorations significatives. Cela suggère que le modèle KNN, dans sa configuration standard, est déjà assez bien adapté aux caractéristiques de ce jeu de données particulier.

#### **4.3.2. SVM sur le jeu de données UCI-HAR**

Le SVM, connu pour sa robustesse dans divers scénarios de classification, a été évalué pour sa performance sur le Jeu de données UCI-HAR. Avec une configuration standard, le SVM a atteint une justesse moyenne impressionnante de 95,18%, accompagnée d'un rappel et d'un F1-Score équivalents de 95%. Ces résultats élevés indiquent que le SVM est particulièrement bien adapté pour traiter les données de capteurs complexes impliquées dans le Jeu de données UCI-HAR. Nous avons ensuite mis en œuvre une validation croisée K-Fold pour évaluer davantage la robustesse du modèle. Cette approche a légèrement amélioré les performances, avec une justesse, un rappel et un F1-Score de 96,40%. En s'inspirant de [59], nous avons appliqué des techniques avancées de traitement des données, telles que la PCA et la sélection de caractéristiques basée sur la régression logistique avec régularisation L1 (Lasso). Cette méthodologie a considérablement amélioré la justesse, le rappel et le F1-Score, atteignant un taux remarquable de 98,69%. L'application de cette méthode de sélection de caractéristiques avancées a démontré une augmentation significative des performances, soulignant l'importance de techniques de traitement de données adaptées pour la reconnaissance d'activités humaines.



Tableau 6 : Récapitulation des résultats appliqué sur UCI-HAR par les SVM

| Étapes       | Justesse (%) | Rappel (%) | F1-Score (%) |
|--------------|--------------|------------|--------------|
| SVM          | 95,18        | 95         | 95           |
| SVM + K-Fold | 96,40        | 96,40      | 96,39        |
| SVM + [59]   | 98,69        | 98,69      | 98,69        |

Les expériences avec le SVM sur le Jeu de données UCI-HAR révèlent que, bien que le modèle affiche des performances élevées dans sa configuration de base, l'application de techniques de traitement de données plus sophistiquées peut entraîner des améliorations significatives. Cela met en lumière le potentiel d'optimisation des modèles grâce à une sélection et un prétraitement judicieux des caractéristiques. Cette matrice de confusion illustre mieux les résultats que nous avons obtenu

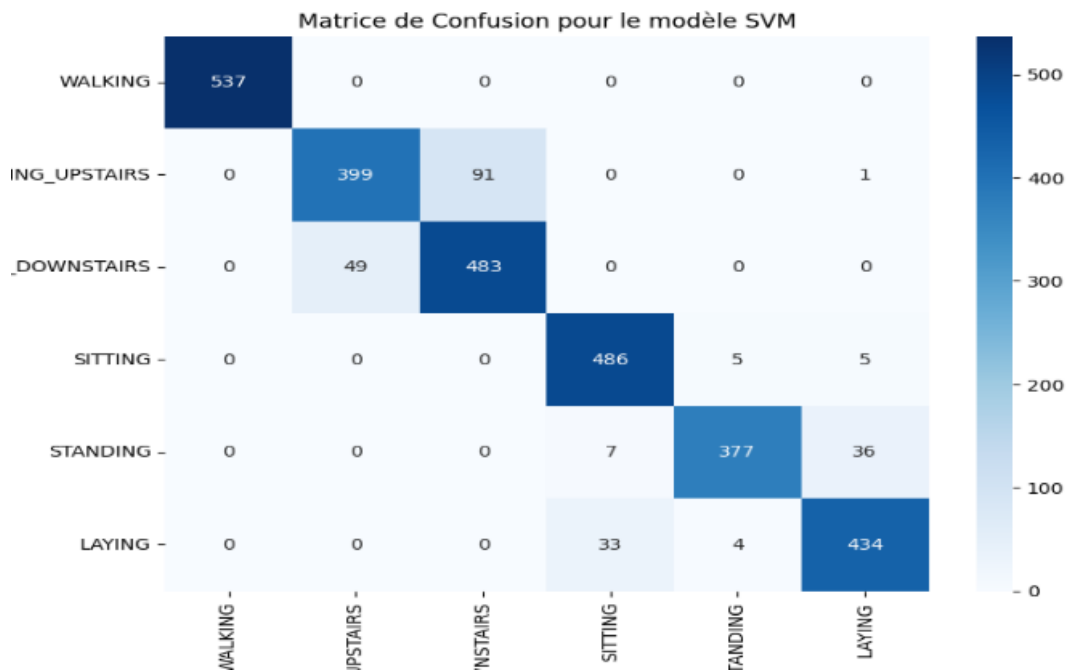


Figure 15 : Matrice de confusion du meilleur résultat de SVM sur UCI-HAR

©Brondon Styve, 2024.

La matrice de confusion pour le modèle SVM appliqué au jeu de données UCI-HAR, présentée à la figure 14, révèle une performance remarquable du modèle dans la classification des activités. Notamment, la catégorie 'Walking' enregistre 537 prédictions exactes (vrais positifs) sans aucune erreur (faux positifs ou faux négatifs), illustrant l'aptitude du SVM à identifier précisément cette activité. De même, pour la catégorie 'Standing', le modèle a correctement classé 377 instances, avec seulement 9 cas mal attribués à d'autres catégories, soulignant l'efficacité du SVM dans la distinction des différents types d'activités au sein du jeu de données UCI-HAR.

#### 4.3.3. Random forest sur le jeu de données UCI-HAR

Le Random Forest, un modèle apprécié pour sa capacité à gérer des ensembles de données complexes, a été évalué pour sa performance sur le Jeu de données UCI-HAR. En utilisant les paramètres de base du Random Forest, nous avons obtenu une justesse moyenne de 92,67%, avec un rappel moyen de 92% et un F1-Score de 93%. Ces résultats démontrent la forte capacité du Random Forest à traiter efficacement les données complexes, fournissant une bonne balance entre justesse et rappel. Une recherche par grille a été effectuée avec des paramètres variés, notamment 'n\_estimators', 'max\_depth', 'min\_samples\_split' et 'min\_samples\_leaf'. L'optimisation a abouti à une légère diminution de la justesse à 92,26%, avec un rappel de 92,26% et un F1-Score de 92,24% pour le meilleur résultat de la grille.

Tableau 7 : Récapitulation des résultats appliqué sur UCI-HAR par les Random Forest

| Étapes                      | Justesse (%) | Rappel (%) | F1-Score (%) |
|-----------------------------|--------------|------------|--------------|
| Random Forest               | 92,67        | 92         | 93           |
| Random Forest + Grid Search | 92,26        | 92,26      | 92,24        |

Bien que l'optimisation n'ait pas entraîné une amélioration significative des performances, elle a fourni des connaissances utiles sur la sensibilité du modèle aux différents paramètres. Le Random Forest s'est révélé être un modèle robuste pour le Jeu de données UCI-HAR, offrant des performances solides dès sa configuration de base. Les ajustements effectués par la recherche par grille n'ont pas considérablement modifié les résultats, ce qui peut indiquer que le modèle est relativement insensible à ces paramètres dans le contexte de ce jeu de données spécifique.

#### **4.3.4. Performance des autres modèles sur le jeu de données UCI-HAR**

Dans l'évaluation des performances sur le jeu de données UCI-HAR, l'arbre de décision, avec une configuration standard, a affiché une performance respectable, atteignant une justesse, un rappel, et un F1-Score d'environ 86,22%, légèrement en deçà des modèles plus avancés. XGBoost, en revanche, a démontré une performance robuste avec une justesse, un rappel, et un F1-Score avoisinant 95,01%, illustrant sa capacité à traiter efficacement les données complexes. La régression logistique s'est également révélée très performante, atteignant une justesse et un rappel de 95,49% ainsi qu'un F1-Score de 95,48%, ce qui met en évidence sa pertinence dans la reconnaissance d'activités humaines malgré une approche plus simple comparée à d'autres modèles. Ces modèles complémentaires ont montré une gamme de performances, mettant en évidence leur adaptabilité et leur efficacité dans le traitement des données du Jeu de données UCI-HAR. Chaque modèle présente des forces uniques, soulignant l'importance de choisir le bon outil en fonction des spécificités du problème et des données.

#### **4.3.5. Discussion sur la pertinence des résultats du UCI-HAR**

Dans cette section, nous discutons de la pertinence des résultats obtenus avec les différents modèles appliqués au Jeu de données UCI-HAR. Cette analyse prend en compte non seulement les performances des modèles mais aussi les caractéristiques spécifiques des données du UCI-HAR.

Nous avons observé une variété de performances à travers les différents modèles, allant de résultats moyens à exceptionnels. Cette variabilité souligne l'importance de l'adéquation entre le modèle et les spécificités du jeu de données pour une reconnaissance d'activités humaines efficace. L'application de méthodes de traitement des données avancées, comme dans le cas du SVM avec PCA et la sélection L1, a significativement amélioré les performances, indiquant l'utilité de telles techniques dans l'optimisation des modèles. Le Jeu de données UCI-HAR est reconnu pour sa structure bien organisée et son équilibre, avec des données clairement segmentées et étiquetées. Cette qualité des données a probablement contribué à la haute justesse du modèle et au bon équilibre entre rappel et justesse observés dans la plupart des modèles. La structure et l'équilibre des données ont facilité la tâche des modèles, leur permettant de mieux apprendre et de généraliser à partir des caractéristiques fournies. Cela a également aidé à réduire les cas de surajustement ou de biais, souvent rencontrés dans des jeux de données moins structurés ou déséquilibrés.

Les résultats obtenus sur le Jeu de données UCI-HAR reflètent l'efficacité des modèles dans un environnement de données idéal, où la qualité, la structure et l'équilibre des données jouent un rôle crucial dans la performance des modèles. Cette discussion met en lumière l'importance d'une bonne préparation des données dans les projets de reconnaissance

d'activités humaines et suggère que des résultats similaires pourraient être plus difficiles à obtenir dans des environnements avec des données moins structurées ou équilibrées.

#### **4.3.6. Points forts et limitations des modèles sur le UCI-HAR**

La compréhension des points forts et des limitations des différents modèles appliqués au jeu de données UCI-HAR est essentielle pour évaluer leur efficacité et identifier les domaines d'amélioration. Cette section détaille ces aspects pour chaque modèle testé. Plusieurs modèles, notamment la Régression Logistique et le SVM, ont montré une justesse élevée, ce qui est indicatif de leur bonne capacité à classifier correctement les activités humaines dans le jeu de données. Nous notons aussi le bon équilibre entre rappel et justesse observé dans la plupart des modèles suggère une capacité à détecter avec précision la majorité des activités pertinentes sans surclasser excessivement les activités non pertinentes. L'amélioration significative des performances avec des techniques avancées, comme dans le cas du SVM, souligne l'importance de l'ajustement et de l'optimisation des modèles. Cependant, nous avons aussi des modèles comme le Naive Bayes et LightGBM n'ont pas atteint le même niveau de performance que d'autres, ce qui pourrait indiquer des limites dans leur capacité à traiter ce type de données ou un besoin d'optimisation plus poussé. La performance élevée des modèles peut également refléter la qualité et l'équilibre du Jeu de données UCI-HAR. Cela soulève des questions sur la robustesse et l'adaptabilité de ces modèles dans des environnements aux données moins idéales.

Les modèles testés sur le Jeu de données UCI-HAR ont globalement montré de bonnes performances, mais leur efficacité peut être influencée par la qualité des données et leur complexité computationnelle. Ces résultats soulignent l'importance d'une sélection

judicieuse des modèles et des techniques de traitement des données adaptées aux spécificités des jeux de données de reconnaissance d'activités humaines.

#### **4.4. RESULTATS SUR LE ESC-50 ET KITCHEN 20 JEU DE DONNÉES**

Les résultats obtenus sur les jeux de données combinés ESC-50 et Kitchen 20 montrent des performances variables selon les modèles et les approches adoptées. Comme présenté plus haut nous avons fait premièrement une fusion de ces deux jeux de données en se concentrant sur les données liées directement à la reconnaissance d'activités humaine.

##### **4.4.1. Random forest sur le jeu de données ESC-50 et Kitchen 20**

Le modèle Random Forest, dans son approche initiale sur les jeux de données combinés ESC-50 et Kitchen 20, a enregistré une justesse moyenne de 57%, accompagnée d'un rappel de 54% et d'un F1-Score de 52%. Ces résultats indiquent une certaine difficulté du modèle à gérer la complexité et la variété des données audio de ces jeux de données. La modeste performance peut être attribuée à la diversité des sons et à la possible confusion entre différentes catégories d'activités. Ainsi, cette matrice de confusion présente les performances du modèle en termes de prédictions correctes et incorrectes pour chaque classe. Sur la figure 15, la matrice de confusion indique des défis dans la classification précise de certaines catégories sonores. Spécifiquement, pour la classe 'Crying', le modèle a réussi à identifier correctement 13 instances comme vrais positifs, mais a également mal classé 22 instances, attribuant incorrectement ces sons à d'autres catégories. Ce qui est le cas de presque toutes les autres classes. Ces résultats mettent en évidence les limites de l'approche initiale dans la gestion de la diversité et de la complexité des sons environnementaux et domestiques



précise des activités audio, suggérant la nécessité de réviser l'approche de traitement des données ou d'explorer d'autres modèles plus adaptés à ce type de tâches.

#### **4.4.2. SVM sur le jeu de données ESC-50 et Kitchen 20**

Le SVM, lors de sa première application sur les jeux de données combinés ESC-50 et Kitchen 20, a affiché une faible justesse de 21%. Ces résultats étaient cohérents en termes de rappel et de F1-Score, qui étaient également de 21% et 18%, respectivement. Ces faibles performances suggèrent que le SVM, dans sa configuration standard, avec le noyau RBF (`kernel='rbf'`), une valeur de régularisation  $C$  de 1.0, et un paramètre  $\gamma$  défini sur 'scale', a rencontré des difficultés à différencier efficacement entre les variétés complexes de données audio présentes dans ces jeux de données. En tentant d'améliorer ces résultats, des techniques comme la validation croisée K-Fold et l'Analyse en Composantes Principales (PCA) ont été appliquées, tout en conservant les paramètres par défaut du SVM. Malgré ces tentatives d'optimisation, les performances n'ont pas montré d'amélioration significative, confirmant les défis initiaux rencontrés par le SVM dans ce contexte particulier. Le SVM, bien que largement efficace dans de nombreux scénarios de classification, semble moins adapté à la complexité et à la diversité des données audio du ESC-50 et Kitchen 20. Cela met en évidence l'importance de choisir et d'optimiser les modèles en fonction des caractéristiques spécifiques des jeux de données.

#### **4.4.3. KNN sur le jeu de données ESC-50 et Kitchen 20**

L'application initiale du KNN sur les jeux de données combinés ESC-50 et Kitchen 20 a résulté en une justesse moyenne de 22%. De manière similaire, le rappel et le F1-Score se sont établis également autour de 22%. Ces résultats indiquent que le KNN, malgré sa



simplicité et son efficacité dans d'autres contextes, a éprouvé des difficultés à traiter avec précision les données audio complexes de ces jeux de données. Le modèle KNN, dans cet environnement de données audio, a montré ses limites, soulignant peut-être une inadéquation entre la méthode de classification basée sur les voisins les plus proches et la nature des données audio de ESC-50 et Kitchen 20. Cette observation suggère la nécessité d'explorer d'autres approches ou de modifier significativement la méthode de traitement des données pour ce type de tâche.

#### **4.4.4. Approche après collaboration avec les auteurs de X-CHAR**

Après avoir obtenu l'accès aux données spécifiques utilisées dans l'étude [50], des améliorations significatives des performances des modèles ont été observées. Cette étude se concentrait sur trois classes spécifiques au sein du jeu de données combiné ESC-50 et Kitchen 20, offrant une perspective plus ciblée. L'étude X-CHAR s'est focalisée sur les classes "office", "restroom" et "transport", réduisant la complexité et la diversité des données audio comparées à l'approche initiale qui englobait un spectre plus large d'activités. Cette concentration sur un nombre limité de classes a probablement contribué à simplifier le problème de classification, permettant aux modèles de mieux distinguer entre les différentes catégories d'activités. En se concentrant sur des catégories spécifiques, les modèles ont pu atteindre une plus grande précision dans la reconnaissance des sons et des activités pertinentes.

Une amélioration significative a été constatée avec le KNN, atteignant une justesse de 68%, un rappel de 68% et un F1-Score de 67%. Le Random Forest a montré une nette augmentation de performance, avec une justesse de 93%, un rappel de 89% et un F1-Score

de 90%. Et le SVM a également affiché une amélioration remarquable, atteignant 90% de justesse, environ 88% de rappel et un F1-Score d'environ 88%. A travers la matrice de confusion, nous remarquons la capacité du modèle à être assez précis.




Figure 17 : Matrice de confusion du résultat des Random Forest sur ESC 50 et Kitchen 20 combiné provenant des auteurs

©Brondon Styve,2024.

L'accès aux données ciblées de l'étude X-CHAR et la concentration sur un nombre restreint de classes ont clairement démontré leur impact positif sur la performance des modèles. Cela souligne l'importance d'une sélection judicieuse des données et des classes pour la reconnaissance d'activités basée sur l'audio, en particulier dans des contextes où la justesse et la spécificité sont cruciales. La matrice de confusion de la figure 16 illustre une amélioration notable. Notamment, pour la catégorie 'Restroom', le modèle a précisément

classé 55 instances, avec seulement 6 classifications incorrectes. Cette amélioration s'étend à la majorité des catégories.

#### **4.4.5. Interprétation des résultats et leurs implications**

Après avoir observé une amélioration notable des performances des modèles avec l'accès aux données spécifiques de l'étude X-CHAR, il est important de réfléchir aux implications de ces résultats et de comprendre les leçons tirées de cette expérience. L'accent mis sur un nombre restreint de classes dans l'étude X-CHAR [50] montre combien la sélection ciblée des données peut influencer positivement les performances des modèles. Cela suggère que pour des tâches spécifiques de reconnaissance audio, une approche plus concentrée peut être plus efficace. Les améliorations observées indiquent que les modèles comme le KNN, Random Forest et SVM sont suffisamment flexibles pour s'adapter à des changements dans la structure des données. Cette adaptabilité est cruciale dans le domaine de l'apprentissage automatique, où les données peuvent varier considérablement d'un projet à l'autre. La concentration sur des classes spécifiques a réduit la complexité du problème de classification, ce qui a probablement facilité la distinction plus précise entre les activités par les modèles.

Les résultats initiaux avec une gamme plus large de classes ont montré que les modèles luttent pour gérer la diversité et la complexité des données audio. Cela met en lumière le défi de travailler avec des jeux de données audio variés et souligne la nécessité de stratégies de prétraitement et de sélection des données bien pensées. La collaboration avec les auteurs de l'étude X-CHAR [50] et l'accès à leurs données ont été cruciaux pour améliorer les

performances des modèles. Cela souligne l'importance du partage des connaissances et des ressources dans la communauté scientifique pour faire avancer la recherche.

Les modèles ont initialement eu du mal à gérer la large gamme de sons et d'activités présents dans les jeux de données combinés, menant à des performances inférieures. Cette complexité souligne le défi de classifier avec précision des sons variés qui peuvent se chevaucher ou être similaires. La combinaison des jeux de données ESC-50 et Kitchen 20 a introduit des complications en termes de cohérence et d'équilibre des données. La gestion de cette fusion nécessite une attention particulière pour maintenir l'intégrité et la qualité des données. Comme le montre l'expérience avec les données X-CHAR [50], se concentrer sur un nombre limité de classes peut simplifier le problème de classification et améliorer les performances. Une approche plus ciblée, centrée sur des classes spécifiques d'activités ou de sons, peut permettre une classification plus précise. Encourager la collaboration entre chercheurs et le partage des jeux de données et des méthodologies, comme l'exemple de la collaboration avec les auteurs de l'étude X-CHAR [50]. Le partage des ressources peut accélérer le développement de solutions plus robustes et efficaces dans le domaine de la reconnaissance audio. Les défis rencontrés avec les jeux de données ESC-50 et Kitchen 20 mettent en lumière l'importance d'une sélection minutieuse des données, de techniques de prétraitement sophistiquées, et de la collaboration dans la recherche. En adoptant ces solutions, il est possible d'améliorer significativement la reconnaissance d'activités basée sur l'audio, ouvrant la voie à des applications plus précises et fiables dans des domaines variés.

En concluant notre analyse des performances sur les jeux de données ESC-50 et Kitchen 20, plusieurs points clés émergent. Premièrement, l'importance cruciale d'une

sélection et d'un prétraitement adéquats des données est mise en évidence. En ciblant des classes spécifiques et en appliquant des méthodes de traitement des données appropriées, nous avons constaté, sans surprise, une amélioration significative des performances des modèles. De plus, cette étude a démontré l'adaptabilité des modèles d'apprentissage automatique, qui ont réussi à s'ajuster à des données modifiées et plus ciblées, notamment avec les améliorations observées grâce aux données fournies par l'étude X-CHAR [50]. Ces conclusions offrent des perspectives précieuses pour les futurs travaux dans le domaine de la reconnaissance d'activités basée sur l'audio et soulignent l'importance d'une démarche méthodique et collaborative dans la recherche en apprentissage automatique.

#### **4.5. DISCUSSION SUR LA NECESSITE DU DEEP LEARNING**

Le DL une branche avancée de l'intelligence artificielle, a révolutionné de nombreux domaines de la technologie et de la recherche dans les dernières années. Dans cette section, nous discutons de son importance en comparaison avec le ML classique, en évaluant ses avantages et inconvénients, ainsi que ses implications dans des contextes spécifiques comme les habitats intelligents par rapport à nos travaux.

Le DL excelle dans l'analyse de grandes quantités de données complexes, comme les images, les sons, et les textes, grâce à sa capacité à apprendre des caractéristiques de haut niveau à partir des données brutes. Souvent, il offre une précision supérieure dans les tâches de classification et de prédiction comparé aux techniques de machine learning classiques. Mais il nécessite généralement d'importantes ressources computationnelles, notamment en termes de puissance de calcul (GPU) et de quantité de données. Les modèles de deep

learning peuvent être difficiles à interpréter, ce qui pose des problèmes de transparence et d'explicabilité.

#### **4.5.1. Implications pour les habitats intelligents**

L'utilisation du deep learning dans les habitats intelligents ouvre des perspectives fascinantes en termes de reconnaissance d'activités, de sécurité, et de personnalisation des services. Le deep learning peut traiter efficacement les données issues de multiples capteurs pour offrir une compréhension plus profonde des comportements et des préférences des utilisateurs. De la reconnaissance vocale à la détection des anomalies, le deep learning peut améliorer la sécurité et le confort dans les environnements domestiques.

L'examen des études réalisées sur les jeux de données UCI-HAR, Aruba, ESC-50 et Kitchen 20 révèle des domaines où le deep learning pourrait apporter une valeur ajoutée significative. Les capacités du deep learning à traiter des ensembles de données complexes et à en extraire des caractéristiques pertinentes seraient particulièrement utiles pour les défis observés dans ces études. Dans des domaines comme la reconnaissance audio, le deep learning pourrait potentiellement surclasser les approches de machine learning classiques en termes de précision et de capacité de généralisation. Bien que le deep learning présente des défis en termes de complexité et de ressources nécessaires, ses avantages en font une approche incontournable dans les applications avancées d'intelligence artificielle, notamment dans les habitats intelligents et dans des domaines nécessitant une analyse approfondie de données complexes comme l'analyse des sons.

## 4.6. COMPARAISON GLOBALE DES RESULTATS

Ces comparaisons sont basées sur les données des meilleurs résultats obtenus pour nos modèles de ML.

### 4.6.1. Jeu de donnée Aruba

Tableau 8 : Tableau de Comparaison des performances des modèles de ML et de DL sur le Jeu de données Aruba

| <b>Modèle / Étude</b>             | <b>Performances</b> |                   |                     |
|-----------------------------------|---------------------|-------------------|---------------------|
| <b>Modèle du Machine learning</b> | <b>Justesse (%)</b> | <b>Rappel (%)</b> | <b>F1-Score (%)</b> |
| Random Forest                     | 93                  | 93                | 93                  |
| <b>KNN</b>                        | <b>97,31</b>        | <b>81</b>         | <b>83</b>           |
| SVM                               | 74                  | 74                | 74                  |
| Arbre de Décision                 | 96,05               | 93                | 95                  |
| LightGBM                          | 67                  | 67                | 67                  |
| XGBoost                           | 75                  | 75                | 75                  |
| Naive Bayes                       | 54                  | 54                | 54                  |
| <b>Modèle du deep learning</b>    |                     |                   |                     |
| DNN [11]                          | 94,5                | 94.5              | 94.5                |
| Transformer-based approach [64]   | 95,9                | 96.9              | 96.4                |
| <b>LSTM [65]</b>                  | <b>96,61</b>        | <b>86.35</b>      | <b>85.88</b>        |
| DCR [60]                          | 82,23               | 68,57             | 80,28               |

L'un des résultats les plus notables de notre étude est la performance exceptionnelle du modèle KNN (K-nearest neighbors) dans l'approche de apprentissage automatique classique, avec une justesse de 97,31%. Cette performance est d'autant plus remarquable lorsqu'elle est mise en parallèle avec les modèles de deep learning. En effet, KNN est l'un des modèles d'apprentissage automatique les plus simples à mettre en œuvre, même parmi les approches d'apprentissage classiques. Elle démontre que, malgré la complexité croissante

et la popularité des méthodes de deep learning, les techniques d'apprentissage automatique classiques, lorsqu'elles sont bien appliquées et optimisées, peuvent rivaliser efficacement en termes de justesse. En comparant ces résultats avec ceux obtenus par les modèles de deep learning dans les études de référence, nous observons que, bien que les modèles DL comme ceux présentés dans les travaux [11] et l'approche basée sur le Transformer [64] affichent des performances élevées, le modèle KNN en ML classique peut surpasser ces approches en termes d'exactitude. Cette observation suggère que la complexité accrue des modèles de deep learning n'est pas toujours synonyme de meilleures performances et que les modèles plus simples peuvent être plus adaptés pour certaines tâches.

Ce résultat a des implications importantes pour le déploiement de technologies d'intelligence artificielle dans les habitats intelligents. Elle met en lumière l'importance de l'évaluation rigoureuse des besoins et des contraintes spécifiques de chaque application avant de choisir entre des modèles ML classiques et des modèles DL plus complexes. En particulier, pour les tâches où la justesse est primordiale et où les ressources computationnelles peuvent être limitées, comme c'est souvent le cas dans les applications domestiques, les modèles ML classiques comme le KNN pourraient être préférables. Cette constatation ouvre la voie à une exploration plus approfondie des capacités et des applications potentielles des modèles ML classiques dans les habitats intelligents, en parallèle avec les développements continus dans le domaine du deep learning.

#### **4.6.2. Jeu de données UCI-HAR**



Tableau 9 : Tableau de Comparaison de performances des modèles de ML et de DL sur le jeu de données UCI-HAR

| Étude / Modèle                        | Performances |            |              |
|---------------------------------------|--------------|------------|--------------|
|                                       | Justesse (%) | Rappel (%) | F1-Score (%) |
| <b>Modèle du Machine learning</b>     |              |            |              |
| KNN                                   | 90.00        | 89         | 89           |
| SVM                                   | 98.69        | 98.69      | 98.69        |
| Random Forest                         | 92.67        | 92         | 93           |
| Arbre de Décision                     | 86.22        | 86.22      | 86.17        |
| XGBoost                               | 95.01        | 95.01      | 95           |
| Régression Logistique                 | 95.49        | 95.49      | 95.48        |
| <b>Modèle de Deep learning</b>        |              |            |              |
| HDL [53]                              | 97.95        | -          | -            |
| BLSTM [53]                            | 95.70        | -          | -            |
| DBLSTM [53]                           | 96.75        | -          | -            |
| RNN-LSTM [59]                         | 90.19        | -          | -            |
| Réseaux de Neurones Artificielle [59] | 94.77        | -          | -            |
| CNN et LSTM [49]                      | 96.83        | -          | -            |
| CNN et BiLSTM [51]                    | 96.37        | 96.31      | -            |
| CNN [48]                              | 85.1         | -          | -            |
| Baseline LSTM [48]                    | 88.2         | -          | -            |
| Bidir-LSTM [48]                       | 89.2         | -          | -            |
| Res-LSTM [48]                         | 90.2         | -          | -            |
| Res-Bidir-LSTM [48]                   | 90.5         | -          | -            |

Ce tableau offre une comparaison directe des performances des modèles ML et DL sur le Jeu de données UCI-HAR. Vous pouvez maintenant procéder à une analyse comparative, en examinant les performances des différents modèles et en considérant leurs

implications dans le contexte de la reconnaissance d'activités humaines à l'aide de capteurs portables.

Dans notre étude sur le Jeu de données UCI-HAR, des résultats notables ont été observés avec les modèles d'apprentissage automatique classique. Notamment, le modèle SVM, après l'application de techniques avancées de traitement des données, a atteint une justesse impressionnante de 98,69%. En comparant ces résultats avec ceux obtenus par les modèles de deep learning, il est évident que, bien que les modèles DL tels que le HDL et le DBLSTM [53] présentent de hautes performances tandis que les modèles de Machine Learning classiques tels que le SVM et la Régression Logistique ont démontré une capacité équivalente, voire supérieure, en termes de justesse. Cette observation souligne que la sophistication des modèles de deep learning n'est pas toujours nécessaire pour atteindre des niveaux élevés de performance, et que les méthodes de Machine Learning classiques, lorsqu'elles sont optimisées efficacement, peuvent être extrêmement compétitives.

#### **4.6.3. Jeu de données combiné ESC-50 ET KITCHEN 20**

Ici, concernant les résultats de ML, nous avons présenté les résultats sur les données que nous avons combiné nous-même selon comme lu dans les articles de notre revue et par la suite, nous avons présenté avec ceux des données reçu des auteurs de l'article ayant utilisé l'approche X-CHAR [50]. Ceci est mieux expliqué plus haut où nous présentons les données utilisées

Tableau 10 : Tableau de comparaison des performances des modèles ML et DL sur les jeux de données combinés ESC-50 et Kitchen 20

| Étude / Modèle                      | Performances |            |              |
|-------------------------------------|--------------|------------|--------------|
|                                     | Justesse (%) | Rappel (%) | F1-Score (%) |
| <b>Modèle du machine learning</b>   |              |            |              |
| Random Forest (Avant Collaboration) | 57           | 54         | 52           |
| SVM (Avant Collaboration)           | 21           | 21         | 18           |
| KNN (Avant Collaboration)           | 22           | 22         | 22           |
| Random Forest (Après Collaboration) | 93           | 89         | 90           |
| SVM (Après Collaboration)           | 90           | 86         | 88           |
| KNN (Après Collaboration)           | 68           | 68         | 67           |
| <b>Modèle du deep learning</b>      |              |            |              |
| ENVNET [47]                         | 71.3         | -          | -            |
| ENVNET2 [47]                        | 78.1         | -          | -            |
| CONV LSTM + TCN [50]                | -            | -          | 90.80        |
| AROMA [50]                          | 86.40        | -          | 95.76        |
| CBM [50]                            | 94.58        | -          | 90.32        |
| X-CHAR [50]                         | 98.86        | -          | 98.86        |

Les résultats initiaux des modèles ML classiques sur les jeux de données ESC-50 et Kitchen 20 ont montré des performances relativement modestes. Cette observation est particulièrement significative lorsqu'on considère le grand nombre de classes et la diversité des données dans ces jeux de données. Bien que ces modèles aient montré une amélioration notable sur un sous-ensemble de classes spécifiques après la collaboration avec les auteurs

de l'étude "X-CHAR" [50] pour avoir accès au jeu de données qu'ils ont utilisés, cette performance est limitée à un contexte beaucoup moins diversifié. En comparaison, les modèles de deep learning tels que X-CHAR, CBM et les variantes d'ENVNET ont démontré des performances exceptionnelles sur l'ensemble combiné ESC-50 et Kitchen 20. Ces modèles DL ont maintenu une haute justesse et des scores F1 élevés même en traitant un plus grand nombre de classes, indiquant une meilleure adaptabilité et efficacité pour la reconnaissance d'activités basées sur l'audio dans un contexte plus général et diversifié. Cette comparaison met en lumière l'importance de la spécificité des tâches et de la sélection des données pour l'efficacité des modèles de reconnaissance d'activités. Les modèles ML classiques peuvent être optimisés pour des tâches spécifiques avec des données ciblées, mais leur applicabilité peut être limitée dans des contextes plus larges et diversifiés, contrairement aux modèles DL qui semblent mieux équipés pour gérer la variété et la complexité des données audio.

En conclusion, cette analyse suggère que bien que les modèles ML classiques aient un potentiel dans des scénarios spécifiques et bien définis, les modèles de deep learning offrent une plus grande flexibilité et une meilleure performance globale pour la reconnaissance d'activités dans des environnements audio variés et complexes. Ces conclusions fournissent des orientations importantes pour le choix des modèles dans le développement d'applications de reconnaissance audio, en particulier dans les domaines des habitats intelligents où la diversité des données et la justesse des prédictions sont cruciales.

#### **4.6.4. Perspectives sur l'efficacité relative du machine learning classique vs deep learning**

Dans cette section, nous allons approfondir l'analyse comparative de l'efficacité du Machine Learning classique (ML) par rapport au Deep Learning (DL), en se basant sur les résultats obtenus à partir des jeux de données Aruba, UCI-HAR, ESC-50 et Kitchen 20. Cette analyse vise à dégager une compréhension nuancée des forces et faiblesses de chaque approche dans divers contextes de reconnaissance d'activités. Nous examinerons des aspects tels que la précision, la capacité à généraliser, la complexité des modèles et les exigences en termes de ressources. Cette exploration offre des perspectives précieuses pour orienter le choix entre ML classique et DL dans le développement d'applications dans les domaines variés des habitats intelligents et de la santé mobile, en soulignant les implications pratiques et théoriques de chaque approche.

Les modèles de ML classiques et ceux de DL montrent une divergence notable en termes d'adaptabilité et de performance sur divers jeux de données. Les modèles ML classiques, tels que KNN, SVM, et Random Forest, exhibent une efficacité remarquable dans des contextes spécifiques, avec le SVM se distinguant particulièrement sur le jeu de données UCI-HAR après l'application de techniques de traitement avancées. Néanmoins, leur capacité de généralisation sur des ensembles divers est restreinte, comme illustré par leur performance sur les jeux combinés ESC-50 et Kitchen 20, avant l'application des approches développées dans l'étude "X-CHAR" [50]. En contraste, les modèles DL, incluant X-CHAR, CBM, et ENVNET, démontrent une supériorité dans le traitement de la diversité et la complexité des données, affirmant leur adaptabilité à une large gamme de tâches. Ce contraste met en lumière l'importance de sélectionner la technologie adéquate selon la spécificité des données et les objectifs visés, les modèles DL étant préférables pour des scénarios plus complexes et variés. L'évaluation comparative des modèles de Machine

Learning (ML) classiques face au Deep Learning (DL) met en exergue des distinctions essentielles concernant leur complexité, leurs besoins en ressources et leurs performances globales. Les modèles ML, avec le SVM sur l'UCI-HAR atteignant une justesse de 98,69%, sont hautement efficaces dans des contextes spécifiques et requièrent moins de ressources, les rendant idéaux pour les contextes à ressources limitées. Toutefois, leur capacité à généraliser à des ensembles de données divers est limitée, contrairement aux modèles DL qui, à travers des exemples comme X-CHAR et CBM, démontrent une performance robuste et une meilleure généralisation face à la diversité et la complexité des données de ESC-50 et Kitchen 20. Cette analyse révèle que le choix entre ML et DL devrait être guidé par les exigences spécifiques de l'application, notamment les contraintes de ressources et la nécessité de traiter des données variées, où les modèles ML sont préférables pour des tâches bien définies et les modèles DL pour des scénarios demandant une adaptabilité accrue.

Les implications pour le développement futur des modèles de Machine Learning (ML) et Deep Learning (DL) suggèrent des axes d'amélioration spécifiques pour chaque catégorie. Pour le ML classique, l'accent devrait être mis sur l'augmentation de la capacité de généralisation pour mieux traiter une diversité de données plus large, tout en optimisant l'utilisation des ressources. Cela peut permettre une efficacité accrue sans compromettre les performances. Concernant le DL, les efforts devraient viser à réduire la complexité et à améliorer l'interprétabilité, rendant ces modèles plus adaptés à une gamme étendue d'applications, en particulier celles limitées par les ressources. L'adaptabilité et la personnalisation sont également clés pour le DL, exploitant sa flexibilité pour répondre aux besoins spécifiques des différentes applications. L'approche future devrait envisager un équilibre entre ML et DL, choisissant la méthode appropriée basée sur les contraintes de

ressources, la diversité des données, et les objectifs de performance, pour maximiser les avantages de chaque technologie tout en minimisant leurs limitations.

#### **4.6.5. Recommandations pratiques basées sur les résultats**

À la lumière des résultats obtenus et des analyses effectuées, voici des recommandations pratiques pour l'utilisation des modèles de Machine Learning classique et de Deep Learning dans des contextes applicatifs spécifiques.

Pour des données structurées et bien définies, privilégiez les modèles ML classiques pour des tâches où les données sont structurées, moins volumineuses et bien définies. Par exemple, dans des applications d'habitats intelligents ciblant des tâches spécifiques comme la détection de mouvements ou la surveillance de paramètres environnementaux précis. Mais pour des données non structurées et complexes, utilisez des modèles DL pour analyser des données non structurées ou complexes, comme la reconnaissance d'activités humaines à partir d'enregistrements audio, où la variété et l'ampleur des données nécessitent une capacité d'abstraction et de généralisation plus élevée. Dans des contextes où les ressources de calcul ou les contraintes budgétaires sont un facteur limitant, comme dans certains dispositifs médicaux portables ou des applications IoT, les modèles ML classiques peuvent offrir une solution efficace et économique. Dans des situations où les ressources ne sont pas une contrainte majeure, comme dans des systèmes d'analyse de données centralisés ou des applications nécessitant une grande précision, les modèles DL sont plus appropriés. Adaptez le choix du modèle ML ou DL en fonction de la nature spécifique de l'application, en considérant des facteurs tels que la vitesse de traitement requise, la nécessité d'interprétabilité, et l'importance de la précision par rapport à la généralité. Et pour des systèmes devant évoluer et s'adapter au fil du temps, envisagez des modèles DL pour leur

capacité à apprendre et à s'adapter continuellement. Pour des applications nécessitant une maintenance minimale et une grande stabilité, les modèles ML classiques peuvent être plus appropriés.

#### **4.7. SYNTHÈSE ET CONCLUSION DU CHAPITRE**

Ce chapitre a offert une analyse approfondie et systématique des performances de divers modèles d'apprentissage automatique classiques et de deep learning appliqués aux jeux de données Aruba, UCI-HAR, ESC-50, et Kitchen 20. Nos investigations ont révélé des nuances importantes dans l'efficacité de ces modèles en fonction du type et de la complexité des données traitées.

Nous avons constaté que les modèles d'apprentissage automatique classiques, tels que le SVM et le KNN, démontrent une efficacité remarquable dans des contextes spécifiques, en particulier là où les ensembles de données sont bien structurés et moins complexes, comme dans le cas du jeu de données UCI-HAR. Leur performance exceptionnelle, associée à une moindre demande en ressources computationnelles, les rend particulièrement adaptés à des applications dans des environnements à ressources limitées, comme certains dispositifs d'habitats intelligents ou d'applications de santé mobile.

Par ailleurs, nos résultats indiquent que les modèles de deep learning excellent dans le traitement de données plus diversifiées et complexes, comme celles des jeux de données combinés ESC-50 et Kitchen 20. Leur capacité à extraire des caractéristiques de haut niveau à partir de données brutes et à généraliser sur de vastes ensembles de données les rend idéaux pour des applications nécessitant une grande flexibilité et une précision élevée.



Cette étude souligne donc l'importance cruciale de choisir le bon modèle d'apprentissage automatique en fonction des spécificités de chaque jeu de données et de chaque application. Dans les habitats intelligents et les applications de santé mobile, où les besoins varient grandement, une telle sélection stratégique est indispensable pour optimiser l'efficacité et la rentabilité des solutions basées sur l'intelligence artificielle.

Nos découvertes offrent des perspectives précieuses pour le développement futur de technologies d'IA adaptées. Elles encouragent une approche équilibrée, tenant compte à la fois des capacités des modèles d'apprentissage automatique et des exigences spécifiques des applications ciblées. Ces résultats contribuent significativement à la compréhension des forces et des limites des approches ML classiques et de deep learning, et ouvrent la voie à des recherches et développements futurs dans le domaine de l'intelligence artificielle appliqué.

## **CHAPITRE 5**

### **CONCLUSION ET PERSPECTIVES**

Alors que nous clôturons le cinquième chapitre de notre étude, il est crucial de prendre un moment pour réfléchir sur le parcours accompli et sur les connaissances acquises. Ce chapitre, agissant comme le pivot central de notre recherche, a non seulement consolidé les résultats de nos investigations rigoureuses mais a aussi ouvert des avenues pour des questionnements futurs et des explorations plus poussées. En se concentrant sur la comparaison entre le Deep Learning (DL) et le Machine Learning (ML) classique dans le cadre spécifique de la reconnaissance d'activités humaines dans les habitats intelligents, ce chapitre s'est efforcé de dégager des perspectives nuancées, en mettant en lumière les forces et faiblesses de chaque approche.

En abordant ce chapitre, il est essentiel de garder à l'esprit que notre objectif a toujours été de fournir une analyse équilibrée et basée sur des données probantes, pour orienter de manière éclairée le choix des technologies dans le domaine des habitats intelligents. Cette conclusion vise donc à résumer les principales découvertes et à souligner les implications pratiques et théoriques de nos recherches, tout en ouvrant la porte à des directions prometteuses pour les études futures.

#### **5.1. SYNTHÈSE DES RESULTATS**

Notre recherche, centrée sur l'évaluation comparative de l'efficacité du Machine Learning classique (ML) et du Deep Learning (DL) dans la reconnaissance d'activités humaines au sein des habitats intelligents, a révélé des révélations fascinantes. À travers

l'analyse de divers jeux de données tels que Aruba, UCI-HAR, ESC-50 et Kitchen 20, nous avons pu établir des conclusions clés qui éclairent non seulement le domaine académique mais aussi les applications pratiques. La première conclusion majeure est que, bien que le Deep Learning soit souvent perçu comme un outil plus puissant pour le traitement de données complexes, nos résultats ont démontré que les techniques de Machine Learning classiques ne doivent pas être sous-estimées. Par exemple, dans le cas des jeux de données Aruba et UCI-HAR, les modèles KNN et SVM en ML classique ont surpassés plusieurs modèles de deep learning en termes de justesse, révélant ainsi l'efficacité potentiellement équivalente, voire supérieure, de ces méthodes plus traditionnelles dans certains scénarios. En revanche, les modèles DL ont prouvé leur supériorité dans le traitement de données plus diversifiées et complexes, notamment dans le contexte audio du jeu de données combiné ESC-50 et Kitchen 20.

Notre analyse a révélé que, tandis que les modèles de deep learning montrent une adaptabilité remarquable dans la gestion de jeux de données divers et complexes (comme démontré par les études sur les jeux de données ESC-50 et Kitchen 20), les techniques de ML classiques peuvent exceller dans des contextes plus spécifiques et bien définis, en particulier lorsqu'il s'agit de jeux de données structurés et moins volumineux. Comme le jeu de données CRAA des auteurs de [X char] qui contenait moins de classes que les classes d'activités humaines obtenues en combinant les données de EXC 50 et Kitchen 20. Dans le domaine des habitats intelligents, cette découverte implique la nécessité d'une évaluation rigoureuse des exigences spécifiques de chaque application avant de choisir entre les approches de ML classiques et de DL. Dans certains cas, l'utilisation de modèles ML classiques peut non seulement être suffisante mais aussi préférable en raison de leur moindre

complexité et de leur demande plus faible en ressources de calcul. Les résultats ont souligné l'importance de trouver un équilibre entre la performance des modèles et les ressources disponibles. Alors que les modèles de deep learning exigent des capacités de calcul plus importantes, les modèles de ML classiques se sont révélés efficaces avec des ressources plus limitées, offrant ainsi une solution viable dans des contextes où la disponibilité des ressources est une préoccupation majeure.

Cette synthèse des résultats nous permet de conclure que la sélection entre le Machine Learning classique et le Deep Learning ne doit pas être basée sur une supériorité perçue de l'une ou l'autre technologie, mais plutôt sur une compréhension approfondie des spécificités de chaque projet, des exigences en termes de données, et des ressources disponibles. Ces conclusions fournissent une base solide pour orienter les futures recherches et le développement de solutions pratiques dans le domaine de la reconnaissance d'activités humaines, en particulier dans les contextes des habitats intelligents.

## **5.2. CONTRIBUTIONS DE LA RECHERCHE**

La recherche présentée dans ce mémoire apporte plusieurs contributions significatives tant au niveau académique que pratique, en enrichissant la compréhension de l'efficacité relative du ML et du DL dans le domaine de la reconnaissance d'activités humaines, spécifiquement dans les habitats intelligents. Notre étude se distingue par une évaluation comparative approfondie entre les modèles ML et DL sur divers jeux de données, notamment Aruba, UCI-HAR, ESC-50 et Kitchen 20. Cette analyse fournit des insights précieux sur les performances relatives de ces approches dans différents contextes de reconnaissance

d'activités, offrant une base solide pour de futures recherches et applications. Nous avons clairement identifié les scénarios dans lesquels les modèles ML classiques surpassent les modèles DL, et vice versa. Cette distinction aide à orienter les décisions concernant le choix du modèle le plus approprié en fonction des exigences spécifiques des applications d'habitats intelligents. Les résultats de notre recherche ont des implications directes pour la conception et le déploiement de solutions technologiques dans les habitats intelligents. En particulier, ils offrent des orientations sur le choix des modèles pour optimiser la précision, l'efficacité et la capacité de généralisation dans diverses applications, de la surveillance domestique à l'assistance aux personnes âgées. Notre travail contribue à la littérature existante en fournissant une comparaison détaillée et actualisée entre le ML et le DL dans le contexte de la reconnaissance d'activités humaines, un domaine en pleine expansion. Cette étude ouvre la voie à de futures recherches, en particulier en ce qui concerne l'amélioration de la généralisation des modèles ML et l'optimisation des modèles DL pour des applications avec des contraintes de ressources. Enfin, notre recherche met en lumière l'importance d'adopter une approche hybride et personnalisée dans le développement de technologies pour les habitats intelligents. Cette perspective encourage l'utilisation combinée de ML et DL pour tirer parti de leurs forces respectives dans des scénarios spécifiques.

En somme, cette recherche enrichit de manière significative le corpus de connaissances dans le domaine de l'intelligence artificielle appliquée aux habitats intelligents, tout en fournissant des recommandations pratiques pour le développement et l'implémentation de technologies de reconnaissance d'activités plus efficaces et adaptées.

### 5.3. LIMITES ET DEFIS DE LA RECHERCHE

Cette recherche, bien qu'approfondie et informative, a rencontré certaines limites et défis qui sont importants à reconnaître pour une compréhension complète de ses implications et pour guider les recherches futures.

Cette recherche, axée principalement sur l'application du Machine Learning dans la reconnaissance d'activités humaines dans les habitats intelligents, a révélé certaines limites méthodologiques et de données. Ces limites sont essentielles pour interpréter nos résultats et orienter les futures études. Bien que notre étude ait fourni des aperçus précieux sur l'utilisation du Machine Learning, elle s'est principalement appuyée sur cette méthode, avec des comparaisons au Deep Learning basées sur des études existantes. Cette approche pourrait limiter la compréhension complète de la performance relative du Deep Learning dans des scénarios similaires. Comme illustré par notre analyse approfondie du modèle KNN sur le Jeu de données Aruba, où nous avons atteint une justesse de 97,31%. Toutefois, cette approche a limité notre exploration directe des capacités du Deep Learning, se référant principalement à des études existantes pour la comparaison. Les jeux de données utilisés (Aruba, UCI-HAR, etc.) ont été choisis pour leur pertinence, mais ils représentent des contextes spécifiques. Il est possible que ces jeux de données ne capturent pas toutes les nuances des activités humaines ou ne soient pas entièrement représentatifs de tous les environnements d'habitats intelligents. Par exemple, les résultats obtenus avec le SVM sur le Jeu de données UCI-HAR, bien que hautement précis, pourraient ne pas être généralisables à tous les environnements d'habitats intelligents. Tous les jeux de données peuvent contenir des biais, qui peuvent influencer les résultats de l'apprentissage des

modèles. Cela est particulièrement vrai pour les modèles de Machine Learning qui dépendent fortement des caractéristiques des données sur lesquelles ils sont entraînés. Les résultats obtenus dépendent fortement des méthodes de prétraitement appliquées aux données. Cette dépendance peut influencer la performance des modèles de Machine Learning et leur comparaison avec les modèles de Deep Learning mentionnés dans la littérature. Par exemple, l'amélioration de la justesse du modèle SVM sur le Jeu de données UCI-HAR après l'application de PCA et de sélection L1 souligne cette dépendance.

Les comparaisons avec les modèles de Deep Learning, provenant de sources externes, peuvent avoir des limitations en termes de cohérence méthodologique et de contexte d'application, affectant la comparabilité directe avec nos modèles de Machine Learning. Nos comparaisons avec les modèles de Deep Learning, comme le modèle X-CHAR pour ESC-50 et Kitchen 20, sont basées sur des études externes et pourraient manquer de cohérence méthodologique directe avec nos approches ML. Les modèles de Deep Learning, bien qu'efficaces, nécessitent souvent des ressources computationnelles significatives, ce qui peut limiter leur applicabilité dans certains contextes d'habitats intelligents où les ressources sont limitées. La nécessité de ressources computationnelles élevées pour le Deep Learning, comme dans les modèles de l'étude "X-CHAR" [50], contraste avec les exigences plus modestes de nos modèles de ML, ce qui pourrait limiter l'applicabilité des modèles DL dans des contextes d'habitats intelligents à ressources limitées.

En reconnaissant ces limites, notre recherche met en lumière les domaines nécessitant une attention accrue et des améliorations méthodologiques dans les futures études sur la reconnaissance d'activités humaines, en particulier en ce qui concerne l'équilibrage des

approches de Machine Learning et de Deep Learning et l'expansion des jeux de données pour une représentativité accrue.

### **5.3.1. Défis rencontrés pendant la recherche**

Dans cette section, nous abordons les défis techniques et logistiques rencontrés tout au long de notre recherche. Ces défis comprennent les obstacles liés à la collecte, au traitement et à l'analyse des données, ainsi qu'aux aspects logistiques tels que l'accès aux ressources et la gestion du temps.

La diversité et la complexité des jeux de données utilisés (Aruba, UCI-HAR, ESC-50 et Kitchen 20) ont posé des défis importants. Par exemple, le traitement et l'analyse de grandes quantités de données issues de capteurs divers nécessitaient une attention méticuleuse et souvent, des ajustements techniques significatifs. L'accès limité à des outils de pointe, en particulier pour le deep learning, a restreint notre capacité à explorer certaines avenues de recherche. Cette limitation a été particulièrement perceptible dans la comparaison des performances entre les modèles d'apprentissage automatique classique et les techniques de deep learning avancées. La gestion du temps a été un défi, notamment dans l'optimisation des modèles et l'analyse des résultats. Le processus d'ajustement fin des modèles ML pour atteindre des performances optimales a été chronophage, ce qui a limité notre capacité à explorer des approches alternatives. Notre recherche dépendait fortement de données provenant de sources extérieures, notamment de la littérature existante. Cette dépendance a parfois entravé notre capacité à réaliser des comparaisons directes ou à vérifier l'exactitude des données de référence. La gestion du temps et des ressources a été un aspect critique de notre projet. Trouver le juste équilibre entre la qualité de la recherche et le respect des délais



imposés a été un défi constant. Cela a été particulièrement pertinent dans la phase de test et de validation des modèles, où le temps nécessaire pour une évaluation approfondie devait être équilibré avec les contraintes de calendrier, ainsi que la répartition efficace des ressources limitées, telles que le temps de calcul et l'accès à des logiciels spécialisés, a nécessité une planification et une gestion stratégique.

Ces défis techniques, logistiques, et de gestion du temps et des ressources ont joué un rôle crucial dans la conduite et les résultats de notre recherche. Ils ont non seulement influencé notre méthodologie et nos conclusions, mais ont également offert des leçons précieuses pour des recherches futures dans ce domaine.

#### **5.4. IMPLICATIONS PRATIQUES POUR LES HABITATS INTELLIGENTS**

Notre recherche a mis en lumière les implications pratiques significatives de l'utilisation de l'apprentissage automatique classique et du deep learning dans la reconnaissance d'activités humaines, particulièrement dans le contexte des habitats intelligents. L'un des aspects fondamentaux révélés par l'étude est la nécessité d'un choix stratégique entre les technologies de ML classique et de DL, en fonction des exigences spécifiques des habitats intelligents. Par exemple, dans des situations où la justesse et la vitesse sont primordiales, et où les ressources sont limitées, les méthodes de ML classique peuvent se révéler plus adaptées. Un autre point clé est l'optimisation des ressources. Nos découvertes indiquent que l'emploi de méthodes moins exigeantes en ressources pour des tâches spécifiques peut conduire à une utilisation plus efficace et économe en énergie. Cela est particulièrement pertinent dans les applications où la limitation des ressources est un

facteur crucial. De plus, la personnalisation et l'adaptabilité se sont révélées être des éléments essentiels dans les habitats intelligents. Les modèles spécifiques, adaptés aux caractéristiques uniques de chaque environnement et utilisateur, peuvent offrir une expérience plus personnalisée et efficace. Les modèles de DL, avec leur flexibilité et leur capacité d'adaptation à des environnements dynamiques, sont particulièrement aptes à répondre à ces exigences. L'interactivité et l'apprentissage continu constituent également un aspect important. L'intégration de modèles capables d'évoluer et de s'adapter au fil du temps peut améliorer significativement l'interactivité et la réactivité des systèmes d'habitats intelligents. Cette approche permet aux systèmes de s'ajuster aux comportements changeants des utilisateurs, offrant ainsi une expérience utilisateur améliorée et plus intuitive. Enfin, la sécurité et la confidentialité des données dans les habitats intelligents sont des préoccupations majeures soulevées par notre étude. Il est impératif de développer des systèmes qui garantissent non seulement une reconnaissance efficace des activités humaines, mais qui le fassent de manière sécurisée, en protégeant la confidentialité et la vie privée des utilisateurs.

En somme, les implications pratiques de notre recherche pour les habitats intelligents sont vastes, englobant des considérations allant de l'efficacité énergétique et de l'optimisation des ressources à la personnalisation, l'adaptabilité, la sécurité et la confidentialité. Ces éléments sont cruciaux pour le développement de technologies intelligentes plus avancées, adaptées et sécurisées dans les environnements domestiques.

#### **5.4.1. Application des résultats dans les habitats intelligents**

L'application des résultats de notre recherche dans les habitats intelligents revêt une importance cruciale pour l'avancement de cette technologie. L'étude a démontré que les modèles d'apprentissage automatique classique, lorsqu'ils sont optimisés et appliqués de manière ciblée, peuvent offrir des performances comparables à celles du deep learning, tout en étant potentiellement plus accessibles et moins gourmands en ressources. Cette découverte suggère des applications pratiques diverses et significatives dans les habitats intelligents.

Un domaine d'application clé est la reconnaissance et la prédiction des activités quotidiennes. Par exemple, l'utilisation de modèles ML classiques tels que le KNN et le SVM peut permettre de détecter efficacement des activités telles que la cuisine, le repos, ou l'exercice physique, en utilisant des données issues de capteurs simples. Cette approche peut contribuer à créer des environnements plus réactifs et adaptatifs, améliorant le confort et la sécurité des utilisateurs.

La gestion de l'énergie est une autre application pertinente. Les résultats obtenus avec des modèles ML classiques pourraient être utilisés pour optimiser la consommation d'énergie en fonction des habitudes et des comportements des résidents. Par exemple, en anticipant les périodes d'activité et de repos, le système pourrait ajuster automatiquement le chauffage, l'éclairage et d'autres appareils électroménagers pour maximiser l'efficacité énergétique.

Dans le domaine de la santé et du bien-être, l'application des modèles ML classiques peut jouer un rôle important dans la surveillance à distance et la prévention des risques. Les systèmes d'habitats intelligents équipés de ces modèles peuvent surveiller les signes vitaux, détecter des anomalies dans les routines quotidiennes, et alerter en cas de situations potentiellement dangereuses, comme des chutes ou des comportements inhabituels.

En outre, les résultats de cette recherche peuvent être intégrés dans des systèmes de contrôle et d'automatisation domestique pour une meilleure personnalisation. Les modèles peuvent apprendre et s'adapter aux préférences individuelles, permettant aux systèmes de régler automatiquement les paramètres environnementaux selon les habitudes et les besoins des utilisateurs.

Enfin, la reconnaissance des activités par le ML dans les habitats intelligents ouvre la voie à une interaction plus naturelle et intuitive avec les technologies domestiques. Les utilisateurs peuvent bénéficier d'une expérience utilisateur améliorée, où les commandes vocales ou gestuelles sont interprétées plus efficacement, rendant la technologie plus accessible et conviviale.

Les applications des résultats de cette recherche dans les habitats intelligents sont diverses et portent la promesse d'améliorer significativement la qualité de vie, l'efficacité énergétique, et la sécurité des utilisateurs. Ces applications démontrent l'énorme potentiel des modèles d'apprentissage automatique classique dans la concrétisation des habitats intelligents du futur.

## **5.5. PERSPECTIVES ET RECOMMANDATIONS**

Dans ce dernier segment, nous abordons les perspectives et recommandations découlant de notre étude comparative sur l'efficacité de l'apprentissage automatique classique (ML) et du deep learning (DL) dans la reconnaissance d'activités humaines, en particulier dans le contexte des habitats intelligents. Cette section vise non seulement à esquisser les directions futures de la recherche dans ce domaine en pleine évolution, mais aussi à proposer des recommandations pratiques pour l'application de ces technologies. Nous

explorons comment les compréhensions approfondies tirées de notre étude peuvent éclairer les développements futurs, tout en tenant compte des implications éthiques, pratiques et théoriques. Ces perspectives et recommandations visent à guider les chercheurs, les praticiens et les décideurs dans la navigation des défis et des opportunités que présente l'intégration de l'intelligence artificielle dans nos environnements de vie et de travail.

#### **5.5.1. Directions de recherche future**

L'exploration de la reconnaissance d'activités humaines dans les habitats intelligents à travers le prisme de l'apprentissage automatique classique (ML) et du deep learning (DL) ouvre des avenues prometteuses pour la recherche future. Cette étude, en mettant en lumière les capacités comparatives du ML et du DL, suggère plusieurs directions potentielles pour approfondir notre compréhension et améliorer l'application de ces technologies.

Premièrement, une exploration plus approfondie des modèles hybrides, combinant les forces du ML classique et du DL, pourrait offrir un équilibre optimal entre précision, efficacité et flexibilité. Ces modèles hybrides pourraient tirer parti de la capacité du ML à traiter efficacement des tâches spécifiques tout en utilisant la puissance du DL pour gérer la complexité et la variabilité des données. Deuxièmement, l'accentuation de l'interprétabilité et de la transparence des modèles DL constitue un domaine de recherche crucial. Cela améliorerait non seulement la confiance des utilisateurs mais aussi la facilité d'intégration dans des contextes sensibles, tels que la santé et la sécurité dans les habitats intelligents. Troisièmement, une étude plus détaillée sur l'optimisation des ressources et la réduction de la complexité computationnelle des modèles DL est nécessaire. Cela permettrait une intégration plus large et plus économique de ces technologies dans divers environnements, y compris ceux avec des contraintes matérielles. En outre, l'exploration de nouvelles sources

de données et de capteurs innovants pour améliorer la précision et la diversité des informations collectées pour la reconnaissance d'activités est une direction prometteuse. Cela pourrait inclure l'utilisation de capteurs biométriques ou environnementaux avancés, enrichissant ainsi les données disponibles pour l'analyse. Enfin, une attention particulière devrait être accordée à l'impact éthique et social de l'intégration du ML et du DL dans les habitats intelligents. La recherche future devrait explorer les implications de la vie privée, de la sécurité des données et de l'inclusivité, assurant que ces technologies bénéficient à tous les utilisateurs de manière équitable et respectueuse.

Les directions de recherche future dans ce domaine sont vastes et variées, offrant des opportunités significatives pour améliorer et élargir l'application du ML et du DL dans la reconnaissance d'activités humaines, en particulier dans le contexte évolutif et interdisciplinaire des habitats intelligents.

### **5.5.2. Implications pratiques et théoriques**

La comparaison entre le ML classique et le DL dans la reconnaissance d'activités humaines offre des implications pratiques et théoriques significatives, particulièrement pour les habitats intelligents. D'un point de vue pratique, nos résultats soulignent l'importance de choisir la bonne approche en fonction des spécificités de l'application. Par exemple, dans des scénarios où la précision et l'efficacité sont prioritaires avec des contraintes de ressources limitées, le ML classique pourrait être préférable. En revanche, pour des tâches impliquant une grande variété de données et une complexité accrue, le DL présente un avantage distinct. Théoriquement, cette étude met en évidence la nécessité d'une compréhension plus nuancée des forces et des limites de chaque approche. Elle encourage une exploration plus approfondie de la façon dont des modèles hybrides peuvent combiner les avantages du ML

classique et du DL pour maximiser l'efficacité et la précision. D'un point de vue applicatif, les résultats de cette étude encouragent l'intégration de solutions ML et DL dans des dispositifs intelligents, offrant ainsi des services plus personnalisés, efficaces et sûrs aux utilisateurs. Cela inclut l'amélioration de la surveillance de la santé, la gestion de l'énergie, la sécurité domestique, et la personnalisation des interactions avec les habitants. Enfin, cette recherche soulève des questions éthiques et sociales importantes liées à l'utilisation de l'IA dans les habitats intelligents. Elle appelle à une réflexion approfondie sur les implications de la vie privée, de la sécurité des données et de l'équité dans l'accès aux technologies avancées.

Nous avons mis en lumière des découvertes essentielles sur l'efficacité relative de l'apprentissage automatique classique et du deep learning dans la reconnaissance d'activités humaines dans les habitats intelligents. Notre recherche a non seulement apporté des contributions significatives à la compréhension théorique dans ce domaine, mais a également ouvert des perspectives pratiques pour l'application de ces technologies. En examinant les limites, les défis, et les opportunités, nous avons tracé des voies pour des recherches futures, en soulignant l'importance d'une approche équilibrée et adaptée pour le développement de solutions intelligentes et efficaces. Nos conclusions offrent ainsi des directions stratégiques pour l'avancement de l'intelligence artificielle dans le cadre de la vie quotidienne, soulignant l'impact potentiel de notre travail dans l'amélioration des habitats intelligents et dans la promotion d'un avenir technologique plus inclusif et accessible.

## BIBLIOGRAPHIE

- [1] B. Mahesh, *Machine Learning Algorithms -A Review*, 2019.
- [2] G. Varoquaux, L. Buitinck, G. Louppe, O. Grisel, F. Pedregosa, et A. Mueller, "Scikit-learn: Machine Learning Without Learning the Machinery," *GetMobile: Mobile Computing and Communications*, vol. 19, pp. 29-33, 06/01 2015. doi: 10.1145/2786984.2786995.
- [3] Susanto, D. Stiawan, M. A. S. Arifin, M. Y. Idris, et R. Budiarto, "IoT Botnet Malware Classification Using Weka Tool and Scikit-learn Machine Learning," Dans *2020 7th International Conference on Electrical Engineering, Computer Sciences and Informatics (EECSI)*, 2020, pp. 15-20.
- [4] P. Tomasz, L. Jaejun, et M. Lenin, *Production-Ready Applied Deep Learning: Learn how to construct and deploy complex models in PyTorch and TensorFlow deep learning frameworks*: Packt Publishing, 2022.
- [5] Z. Li, Y. Wang, Y. Ji, et W. Yang, "A Survey of the Development of Artificial Intelligence Technology," Dans *2020 3rd International Conference on Unmanned Systems (ICUS)*, 2020, pp. 1126-1129.
- [6] L. Yang et M. Zhu, "Review on the Status and Development Trend of AI Industry," Dans *2019 IEEE 4th International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*, 2019, pp. 89-93.
- [7] Y. Lu et R. Parthasarathy, "Applying Artificial Intelligence Technology in China's Intelligent Manufacturing Industry," Dans *2023 8th International Conference on Business and Industrial Research (ICBIR)*, 2023, pp. 573-577.
- [8] A. Kumar et S. Joshi, "Applications of AI in Healthcare Sector for Enhancement of Medical Decision Making and Quality of Service," Dans *2022 International Conference on Decision Aid Sciences and Applications (DASA)*, 2022, pp. 37-41.
- [9] G. N. Mandala, D. Buddhi, M. Arumugam, S. Harbola, B. Othman, et H. A. Almashaqbeh, "A Critical Review of Applications of Artificial Intelligence (AI) and its Powered Technologies in the Financial Industry," Dans *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, 2022, pp. 2362-2365.
- [10] J. N. A. Kumar et S. Chimmani, "Proposal of smart home resource management for waste reduction and sustainability using AI and ML," Dans *2019 International Conference on Communication and Electronics Systems (ICES)*, 2019, pp. 992-998.
- [11] K. A. Alaghbari, M. H. Md. Saad, A. Hussain, et M. R. Alam, "Activities Recognition, Anomaly Detection and Next Activity Prediction Based on Neural Networks in Smart Homes," *IEEE Access*, vol. 10, 2022. doi: 10.1109/ACCESS.2022.3157726.



- [12] O. Sharma, "Deep Challenges Associated with Deep Learning," Dans *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*, 2019, pp. 72-75.
- [13] V. Miele, S. Dray, et O. Gimenez, O., "Images, ecology and deep learning  
Images, écologie et deep learning," *Regards sur la biodiversité*, 2021-02-22 2021. [En ligne].  
Disponible: <https://hal.science/hal-03142486>
- [14] N. Thompson, K. Greenewald, K. Lee, et G. Manso, *The Computational Limits of Deep Learning*, 2020.
- [15] M. Jordan, "Artificial Intelligence—The Revolution Hasn't Happened Yet," *Harvard Data Science Review*, 06/23 2019. doi: 10.1162/99608f92.f06c6e61.
- [16] A. Strong, "Applications of artificial intelligence & associated technologies," *Science [ETEBMS-2016]*, vol. 5, no. 6, 2016.
- [17] J. Heaton, "Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning," *Genetic Programming and Evolvable Machines*, vol. 19, no. 1, pp. 305-307, 2018/06/01 2018. doi: 10.1007/s10710-017-9314-z.
- [18] J.-P. Damiano, "Réflexions sur les enjeux de l'IA et les questions d'éthique," *Bulletin de l'IESF Côte d'Azur*, 2019.
- [19] A. Gaikwad, *The Fundamentals of Machine Learning*, 2023.
- [20] A. Alassadi et T. Ivanauskas, "Classification Performance Between Machine Learning and Traditional Programming in Java," Independent thesis Basic level (degree of Bachelor) Student thesis, 2019. [En ligne]. Disponible: <http://urn.kb.se/resolve?urn=urn:nbn:se:hkr:diva-20009>
- [21] R. K. Varshney, S. P. S. Chauhan, et V. Sharma, "Perspectives on the Impact of Artificial Intelligence & Machine Learning on Processes & Structures Engineering," Dans *2022 4th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)*, 2022, pp. 747-752.
- [22] P. Bhattacharya, "Artificial Intelligence in the Boardroom: Enabling 'Machines' to 'Learn' to Make Strategic Business Decisions," Dans *2018 Fifth HCT Information Technology Trends (ITT)*, 2018, pp. 170-174.
- [23] Y. Zhigang, S. Shenmin, D. Guangren, P. Run, et C. Wenjun, "The Design of RBF Neural Networks for Solving Overfitting Problem," Dans *2006 6th World Congress on Intelligent Control and Automation*, 2006, vol. 1, pp. 2752-2756.
- [24] A. Buhot, "Etude de propriétés d'apprentissage supervisé et non supervisé par des méthodes de Physique Statistique," Université Joseph-Fourier - Grenoble I, 1999. [En ligne]. Disponible: <https://theses.hal.science/tel-00001642>
- [25] M. Zimmer, "Developmental reinforcement learning  
Apprentissage par renforcement développemental," Université de Lorraine, 2018LORR0008, 2018. [En ligne]. Disponible: <https://theses.hal.science/tel-01735202>

- [26] A. Telikani, A. Tahmassebi, W. Banzhaf, et A. H. Gandomi, "Evolutionary Machine Learning: A Survey," *ACM Comput. Surv.*, vol. 54, no. 8, p. Article 161, 2021. doi: 10.1145/3467477.
- [27] K. Lu, S. Cvijic, D. Dewhurst, J. Gorman, R. Hyland, et J. Templin, "Democratizing AI for Condition-Based Maintenance Leveraging Probabilistic Programming for Symbolic Reasoning," Dans *2023 Annual Reliability and Maintainability Symposium (RAMS)*, 2023, pp. 1-6.
- [28] A. Sloman, "Interactions between philosophy and artificial intelligence: The role of intuition and non-logical reasoning in intelligence," *Artificial Intelligence*, vol. 2, no. 3, pp. 209-225, 1971. doi: 10.1016/0004-3702(71)90011-7.
- [29] C. Cortes et V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273-297, 1995/09/01 1995. doi: 10.1007/BF00994018.
- [30] M. M. Javier et M. Alberto, "Support Vector Machines with Applications," *Statistical Science*, vol. 21, no. 3, pp. 322-336, 8/1 2006. doi: 10.1214/088342306000000493.
- [31] C. Tan, Y. Sun, G. F. Li, G. Z. Jiang, J. Y. Kong, et B. Tao, "Research On Image Segmentation Based On Support Vector Machine," Dans *2018 International Conference on Machine Learning and Cybernetics (ICMLC)*, 2018, vol. 2, pp. 650-655.
- [32] A. Ganapathiraju, J. E. Hamaker, et J. Picone, "Applications of support vector machines to speech recognition," *IEEE Transactions on Signal Processing*, vol. 52, no. 8, pp. 2348-2355, 2004. doi: 10.1109/TSP.2004.831018.
- [33] Z. R. Yang, "Biological applications of support vector machines," *Briefings in Bioinformatics*, vol. 5, no. 4, pp. 328-338, 2004. doi: 10.1093/bib/5.4.328.
- [34] G. Audemard, S. Bellart, L. Bounia, F. Koriche, J.-M. Lagniez, et P. Marquis, "Sur le pouvoir explicatif des arbres de décision," Dans *Extraction et Gestion des Connaissances, EGC*, Blois, France, 2022, vol. E-38, pp. 147-158: Editions RNTI, <https://hal.science/hal-03699542/document>  
[https://hal.science/hal-03699542/file/DT\\_EGC\\_2022-final.pdf](https://hal.science/hal-03699542/file/DT_EGC_2022-final.pdf).
- [35] S. J. Rigatti, "Random Forest," *Journal of Insurance Medicine*, vol. 47, no. 1, pp. 31-39, 2017. doi: 10.17849/inm-47-01-31-39.1.
- [36] H. Hilali, "Application de la classification textuelle pour l'extraction des règles d'association maximales," Université du Québec à Trois-Rivières, 2009.
- [37] J. Yu, A. de Antonio, et E. Villalba-Mora, "Deep learning (CNN, RNN) applications for smart homes: a systematic review," *Computers*, vol. 11, no. 2, p. 26, 2022.
- [38] R. Wason, "Deep learning: Evolution and expansion," *Cognitive Systems Research*, vol. 52, pp. 701-708, 2018.
- [39] M. Browne et S. S. Ghidary, "Convolutional neural networks for image processing: an application in robot vision," Dans *Australasian Joint Conference on Artificial Intelligence*, 2003, pp. 641-652: Springer.

- [40] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network," *Physica D: Nonlinear Phenomena*, vol. 404, p. 132306, 2020/03/01/ 2020. doi: <https://doi.org/10.1016/j.physd.2019.132306>.
- [41] L. R. Medsker et L. Jain, "Recurrent neural networks," *Design and Applications*, vol. 5, no. 64-67, p. 2, 2001.
- [42] G. Serpen et Y. Xu, "Simultaneous recurrent neural network trained with non-recurrent backpropagation algorithm for static optimisation," *Neural Computing & Applications*, vol. 12, no. 1, pp. 1-9, 2003/09/01 2003. doi: 10.1007/s00521-003-0365-0.
- [43] D. Wang et M. Zhang, "Artificial Intelligence in Optical Communications: From Machine Learning to Deep Learning," *Frontiers in Communications and Networks*, vol. 2, 03/31 2021. doi: 10.3389/frcmn.2021.656786.
- [44] J. M. Ackerson, R. Dave, et N. Seliya, "Applications of recurrent neural network for biometric authentication & anomaly detection," *Information*, vol. 12, no. 7, p. 272, 2021.
- [45] A. Diallo et C. Diallo, "Human Activity Recognition in Smart Home using Deep Learning Models," Dans *2021 International Conference on Computational Science and Computational Intelligence (CSCI)*, 2021, pp. 1511-1515.
- [46] H. Najeh, C. Lohr, et B. Leduc, "Convolutional Neural Network Bootstrapped by Dynamic Segmentation and Stigmergy-Based Encoding for Real-Time Human Activity Recognition in Smart Homes," *Sensors (14248220)*, vol. 23, no. 4, p. 1969, 2023. doi: 10.3390/s23041969.
- [47] M. Moreaux, M. G. Ortiz, I. Ferrané, et F. Lerasle, "Benchmark for Kitchen20, a daily life dataset for audio-based human action recognition," Dans *2019 International Conference on Content-Based Multimedia Indexing (CBMI)*, 2019, pp. 1-6.
- [48] Y. Zhao, R. Yang, G. Chevalier, X. Xu, et Z. Zhang, "Deep Residual Bidir-LSTM for Human Activity Recognition Using Wearable Sensors," *Mathematical Problems in Engineering*, vol. 2018, p. 7316954, 2018/12/30 2018. doi: 10.1155/2018/7316954.
- [49] R. Kolkar et V. Geetha, "Human Activity Recognition in Smart Home using Deep Learning Techniques," Dans *2021 13th International Conference on Information & Communication Technology and System (ICTS)*, 2021, pp. 230-234.
- [50] J. V. Jeyakumar, A. Sarker, L. A. Garcia, et M. Srivastava, "X-CHAR: A Concept-based Explainable Complex Human Activity Recognition Model," *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, vol. 7, no. 1, p. Article 17, 2023. doi: 10.1145/3580804.
- [51] S. Zhang et al., "Deep Learning in Human Activity Recognition with Wearable Sensors: A Review on Advances," *Sensors*, vol. 22, no. 4 2022. doi: 10.3390/s22041476.
- [52] P. Angelov et A. Sperduti, "Challenges in Deep Learning," Dans *ESANN*, 2016.
- [53] T. Su, H. Sun, C. Ma, L. Jiang, et T. Xu, "HDL: Hierarchical Deep Learning Model based Human Activity Recognition using Smartphone Sensors," Dans *2019 International Joint Conference on Neural Networks (IJCNN)*, 2019, pp. 1-8.
- [54] W. Li, P. Meng, Y. Hong, et X. Cui, "Using deep learning to preserve data confidentiality," *Applied Intelligence*, vol. 50, pp. 341-353, 2020.

- [55] N. Sarma, S. Chakraborty, et D. S. Banerjee, "Activity Recognition through Feature Learning and Annotations using LSTM," Dans *2019 11th International Conference on Communication Systems & Networks (COMSNETS)*, 2019, pp. 444-447.
- [56] K. J. Piczak, "ESC: Dataset for Environmental Sound Classification," présenté à Proceedings of the 23rd ACM international conference on Multimedia, Brisbane, Australia, 2015, pp. 1015–1018. doi: 10.1145/2733373.2806390.
- [57] A. Guzhov, F. Raue, J. Hees, et A. Dengel, "ESResNet: Environmental Sound Classification Based on Visual Domain Models," présenté à 2020 25th International Conference on Pattern Recognition (ICPR), 2021, pp. 4933-4940. doi: 10.1109/icpr48806.2021.9413035.
- [58] W. McKinney, "pandas: a foundational Python library for data analysis and statistics," *Python for high performance and scientific computing*, vol. 14, no. 9, pp. 1-9, 2011.
- [59] T. M. Boiro, "Reconnaissance des activités humaines à travers les téléphones intelligents," 2022. [En ligne]. Disponible: <https://depot-e.uqtr.ca/id/eprint/10771/1/eprint10771.pdf>
- [60] A. Jarraya, A. Bouzeghoub, A. Borgi, et K. Arour, "DCR: A new distributed model for human activity recognition in smart homes," *Expert Systems with Applications*, vol. 140, p. 112849, 2020/02/01/ 2020. doi: <https://doi.org/10.1016/j.eswa.2019.112849>.
- [61] B. McFee *et al.*, "librosa: Audio and music signal analysis in python," Dans *Proceedings of the 14th python in science conference*, 2015, vol. 8, pp. 18-25.
- [62] R. Yacouby et D. Axman, "Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models," Dans *Proceedings of the first workshop on evaluation and comparison of NLP systems*, 2020, pp. 79-91.
- [63] F. A. Machot et H. C. Mayr, "Improving Human Activity Recognition by Smart Windowing and Spatio-Temporal Feature Analysis," présenté à Proceedings of the 9th ACM International Conference on Pervasive Technologies Related to Assistive Environments, Corfu, Island, Greece, 2016, p. Article 56. doi: 10.1145/2910674.2910697.
- [64] X. Huang et S. Zhang, "Human Activity Recognition based on Transformer in Smart Home," présenté à Proceedings of the 2023 2nd Asia Conference on Algorithms, Computing and Machine Learning, Shanghai, China, 2023, pp. 520–525. doi: 10.1145/3590003.3590100.
- [65] D. Bouchabou, S. M. Nguyen, C. Lohr, B. LeDuc, et I. Kanellos, "Using Language Model to Bootstrap Human Activity Recognition Ambient Sensors Based in Smart Homes," *Electronics*, vol. 10, no. 20 2021. doi: 10.3390/electronics10202498.