

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE  
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA  
RECHERCHE SCIENTIFIQUE  
UNIVERSITÉ ABOU BEKR BELKAID TLEMCEM  
FACULTÉ DE TECHNOLOGIE  
DÉPARTEMENT DE TELECOMMUNICATIONS

**THÈSE**

Présentée pour l'obtention du grade de  
**DOCTEUR EN SCIENCES**

en Télécommunications

Spécialité : Télécommunications

Par

*M<sup>me</sup>* BENLALDJ Lamia

---

# Routage dans les réseaux corporels mobiles avec optimisation de la consommation énergétique

---

Thèse soutenue publiquement en 2025 devant le jury composé de :

Pr. Benaissa Mohammed	Université de Tlemcen	Président
Dr. Merzoug Mohammed	Université de Tlemcen	Examineur
Dr. Benchehima Miloud	Université USTO-Oran	Examineur
Dr. Souiki Sihem	Université Aïn-Temouchent	Examineur
Pr. Hadjila Mourad	Université de Tlemcen	Directeur de thèse
Dr. Hachemi Mohammed Hicham	Université USTO-Oran	Invité

Année universitaire 2025-2026

# Remerciements

Je tiens tout d'abord à remercier très sincèrement mon directeur de thèse, Mr Hadjila Mourad, pour sa confiance, sa rigueur scientifique, sa disponibilité et la qualité de son encadrement tout au long de ce travail. Ses conseils avisés et sa bienveillance ont grandement contribué à la qualité de ce travail.

Je remercie Monsieur Benaissa Mohammed, Professeur à l'Université Abou Bekr Belkaid de Tlemcen, qui a bien voulu me faire l'honneur de présider le jury de cette thèse.

Je remercie également les membres du jury, Dr Merzoug Mohammed, Dr. Benchehima Miloud et Dr. Souiki Sihem pour l'honneur qu'ils me font en acceptant d'évaluer ce travail et pour l'attention qu'ils ont portée et les remarques constructives qu'ils m'ont adressées. Je remercie très sincèrement Dr Hachemi Mohammed Hicham d'avoir bien voulu accepter notre invitation et d'avoir apporté par la qualité de son regard académique une contribution précieuse à notre travail.

Mes respectueux remerciements à tous le personnel de la faculté de Technologie qui a toujours contribué au bon déroulement de mon travail depuis plus de vingt ans sans oublier de remercier tous les membres du laboratoire de télécommunications STIC pour leur soutien et leurs encouragements.

A mon adorable famille, mes proches, mes collègues et mes amis, je vous remercie du fond du cœur. Merci pour votre amour, vos encouragements constants et votre soutien inconditionnel tout au long de cette thèse.

A ma famille

## Résumé

Les réseaux WBAN, évolution des WSN, sont conçus pour surveiller le corps humain dans des contextes médicaux, sportifs et militaires. Leur principal défi réside dans la gestion de l'énergie, en raison de la miniaturisation des capteurs, de la mobilité des noeuds et de la difficulté de remplacer les batteries, notamment pour les dispositifs implantés. Dans cette thèse, deux contributions majeures ont été développées. La première s'articule autour de l'optimisation de la durée de vie des réseaux WBAN par la conception de protocoles de regroupement (clustering) fondés sur l'algorithme Fuzzy C-Means (FCM). Trois variantes de cette approche ont été explorées, intégrant notamment les algorithmes de clustering k-means et k-medoids afin d'améliorer la sélection des têtes de cluster et d'assurer un équilibre énergétique optimal. Les performances des protocoles proposés ont été évaluées par simulation à travers des indicateurs clés tels que l'énergie résiduelle moyenne, la longévité du réseau et la stabilité des communications inter-noeuds. Une analyse comparative entre les protocoles CBFCM et Improved CBFCM a permis de démontrer les améliorations substantielles obtenues, notamment en termes de réduction de la consommation énergétique et d'augmentation de la stabilité du réseau. La seconde contribution concerne la conception d'un protocole de routage énergétique intelligent reposant sur des techniques d'apprentissage automatique (Machine Learning). Ce protocole mobilise plusieurs modèles supervisés, parmi lesquels l'arbre de décision (Decision Tree), les k-plus proches voisins (K-Nearest Neighbors, K-NN), la machine à vecteurs de support (Support Vector Machine, SVM) et la régression linéaire. Ces modèles ont été entraînés à prédire les trajectoires de communication les plus efficaces selon différents paramètres relatifs à la consommation énergétique, à la densité et à la topologie du réseau. L'évaluation comparative des modèles a permis d'identifier les approches les plus performantes et de mettre en évidence leur influence sur la durabilité et l'efficacité globale du réseau WBAN.

**Mots clés :** WBAN, durée de vie du réseau, efficacité énergétique, clustering, Fuzzy C-Means, K-Means, apprentissage automatique, arbre de décision (DT), k-plus proches voisins (KNN), machine à vecteurs de support (SVM), régression linéaire.

## Abstract

WBANs, an evolution of WSNs, are designed to monitor the human body in medical, sports, and military contexts. Their main challenge lies in energy management, due to sensor miniaturization, node mobility, and the difficulty of replacing batteries, particularly for implanted devices. In this thesis, two major contributions have been developed. The first focuses on optimizing the lifetime of WBANs through the design of clustering protocols based on the Fuzzy C-Means (FCM) algorithm. Three variants of this approach were explored, notably integrating k-means and k-medoids clustering algorithms to enhance cluster-head selection and ensure optimal energy balance. The performance of the proposed protocols was evaluated through simulations using key indicators such as average residual energy, network lifetime, and communication stability between nodes. A comparative analysis between CBFCM and Improved CBFCM protocols demonstrated significant improvements, particularly in reducing energy consumption and increasing network stability. The second contribution focuses on the design of an energy-efficient routing protocol based on Machine Learning techniques. This protocol employs several supervised models, including Decision Tree, K-Nearest Neighbors (K-NN), Support Vector Machine (SVM), and Linear Regression. These models were trained to predict the most efficient communication paths according to parameters related to energy consumption, node density, and network topology. The comparative evaluation of these models identified the most effective approaches and highlighted their impact on the overall durability and efficiency of the WBAN.

**Keywords:** WBAN, network lifetime, energy efficiency, clustering, Fuzzy C-Means, K-Means, Machine Learning, DT, KNN, SVM, Linear Regression.

## ملخص:

شبكات الاستشعار اللاسلكية الجسدية (WBANS)، وهي تطور لشبكات الاستشعار اللاسلكية (WSNs)، مصممة لمراقبة جسم الإنسان في السياقات الطبية والرياضية والعسكرية. يكمن التحدي الرئيسي لهذه الشبكات في إدارة الطاقة، نظرًا لتصغير حجم أجهزة الاستشعار، وقابلية تحرك العقد، وصعوبة استبدال البطاريات، خاصة في الأجهزة المزروعة. في هذه الأطروحة، تم تطوير مساهمتين رئيسيتين. تركز المساهمة الأولى على تحسين عمر شبكات WBANS من خلال تصميم بروتوكولات التجميع القائمة على خوارزمية التجميع الغامض (C-Means (FCM). تم استكشاف ثلاثة أنواع من هذا النهج، ولا سيما دمج خوارزميات التجميع k-means وk-medoids لتعزيز اختيار رؤوس المجموعات وضمان التوازن الأمثل للطاقة. تم تقييم أداء البروتوكولات المقترحة من خلال عمليات المحاكاة باستخدام مؤشرات رئيسية مثل متوسط الطاقة المتبقية، وعمر الشبكة، واستقرار الاتصال بين العقد. أظهر التحليل المقارن بين بروتوكولي CBFM وImproved CBFM تحسينات كبيرة، لا سيما في تقليل استهلاك الطاقة وزيادة استقرار الشبكة. تركز المساهمة الثانية على تصميم بروتوكول توجيه موفر للطاقة يعتمد على تقنيات التعلم الآلي. يستخدم هذا البروتوكول عدة نماذج تعلم خاضعة للإشراف، بما في ذلك شجرة القرار، وخوارزمية الجيران الأقرب (K-NN)، وآلة المتجهات الداعمة (SVM)، والانحدار الخطي. تم تدريب هذه النماذج للتعليق بمسارات الاتصال الأكثر كفاءة وفقًا للمعلومات المتعلقة باستهلاك الطاقة، وكثافة العقد، وهيكل الشبكة. حدد التقييم المقارن لهذه النماذج الأساليب الأكثر فعالية وسلط الضوء على تأثيرها على المتانة والكفاءة الكلية لشبكة WBAN.

## الكلمات المفتاحية:

شبكات الاستشعار اللاسلكية الجسدية (WBAN)، عمر الشبكة، كفاءة الطاقة، التجميع، خوارزمية التجميع الغامض C-Means، خوارزمية K-Means، التعلم الآلي، شجرة القرار، خوارزمية الجيران الأقرب (KNN)، آلة المتجهات الداعمة (SVM)، الانحدار الخطي.

# Table des matières

<b>Remerciements</b>	<b>i</b>
<b>Résumé</b>	<b>iii</b>
<b>Sommaire</b>	<b>vi</b>
<b>Table des figures</b>	<b>x</b>
<b>Liste des tableaux</b>	<b>xii</b>
<b>Introduction générale</b>	<b>1</b>
<b>1 Réseaux de capteurs corporels sans fil</b>	<b>5</b>
1.1 Introduction . . . . .	6
1.2 Les réseaux WBANs vs les réseaux WSNs . . . . .	7
1.2.1 Définition dun WSN . . . . .	7
1.2.2 Définition dun WBAN . . . . .	9
1.2.3 Comparaison entre les réseaux WBANs et les réseaux WSNs . . . . .	9
1.2.3.1 Portée, nombre et taille de nuds, fiabilité et le remplacement des nuds . . . . .	9
1.2.3.2 Topologie . . . . .	11
1.2.3.3 Compatibilité biologique, Technologies sans fil et standard . . . . .	11
1.2.4 Utilisation de capteurs pour le contrôle de la santé . . . . .	11
1.2.5 IoT Healthcare . . . . .	12
1.3 Architecture de communication des WBANs . . . . .	13
1.3.1 Topologie WBAN . . . . .	13
1.3.2 Architecture de communication des WBANs . . . . .	15
1.3.3 Fonctionnement du réseau de capteurs corporels . . . . .	16
1.4 Applications WBANs et leurs importance . . . . .	21
1.4.1 Domaine médical . . . . .	22

1.4.2	Domaine non médical . . . . .	23
1.4.2.1	Domaine militaire . . . . .	23
1.4.2.2	Entraînement sportif . . . . .	23
1.4.2.3	Applications de divertissement . . . . .	23
1.4.2.4	Urgences . . . . .	23
1.4.2.5	Authentification . . . . .	24
1.5	Technologies de communication WBAN . . . . .	24
1.5.1	Technologie ZigBee - IEEE 802.15.4 . . . . .	24
1.5.2	Technologie Bluetooth - IEEE 802.15.1 . . . . .	25
1.5.3	Technologie ultra-large bande (UWB) - IEEE 802.15.3 . . . . .	26
1.5.4	Wi-Fi IEEE 802.11 . . . . .	27
1.5.5	IEEE 802.15.6 . . . . .	28
1.5.5.1	Spécification de la couche PHY . . . . .	28
1.5.5.2	La couche MAC . . . . .	29
1.6	Recommandations d'implémentation d'un WBAN . . . . .	30
1.7	Défis et problèmes des WBANs . . . . .	30
1.7.1	Topologie du réseau . . . . .	30
1.7.2	Efficacité énergétique . . . . .	31
1.7.3	Environnement hétérogène . . . . .	31
1.7.4	Effets biologique . . . . .	31
1.7.5	QoS in WBAN . . . . .	32
1.8	Conclusion . . . . .	32
<b>2</b>	<b>Introduction au Machine Learning et ses Algorithmes</b>	<b>33</b>
2.1	Introduction au Machine Learning . . . . .	33
2.2	Types de Machine Learning . . . . .	34
2.2.1	Apprentissage supervisé . . . . .	34
2.2.2	Apprentissage non supervisé . . . . .	35
2.2.3	Apprentissage semi-supervisé . . . . .	35
2.2.4	Apprentissage par renforcement . . . . .	36
2.3	Algorithmes de l'apprentissage supervisé . . . . .	37
2.3.1	Régression Linéaire . . . . .	37
2.3.2	Régression Logistique . . . . .	39
2.3.3	k-Nearest Neighbors (k-NN) . . . . .	40
2.3.4	Support Vector Machines (SVM) . . . . .	42
2.3.5	Arbres de Décision . . . . .	44
2.3.6	Random Forest . . . . .	45
2.3.7	Réseaux de Neurones Artificiels (ANN) . . . . .	47
2.4	Algorithmes d'apprentissage non supervisé . . . . .	48
2.4.1	k-Means . . . . .	48
2.4.2	PCA (Principal Component Analysis) . . . . .	49

2.5	Algorithmes d'apprentissage par renforcement . . . . .	50
2.5.1	Q-Learning . . . . .	50
2.6	Conclusion . . . . .	51
<b>3</b>	<b>Optimisation de la durée de vie des WBAN via des protocoles de clustering</b>	<b>52</b>
3.1	Introduction . . . . .	53
3.2	Travaux récents . . . . .	54
3.3	Contributions et protocoles proposés . . . . .	55
3.4	Outils de simulation . . . . .	56
3.5	Modèle WBAN utilisé . . . . .	56
3.5.1	Déploiement des nuds . . . . .	56
3.5.2	Scénario de routage entre nuds . . . . .	58
3.5.3	Modèle énergétique . . . . .	59
3.6	Implémentation de protocoles . . . . .	60
3.6.1	Première contribution . . . . .	61
3.6.1.1	Première approche (tous les nuds sont concernés par le clustering) . . . . .	62
3.6.1.2	Deuxième approche . . . . .	64
3.6.2	Deuxième contribution . . . . .	67
3.6.2.1	K-Means . . . . .	67
3.6.2.2	K-Medoids . . . . .	67
3.6.2.3	Implémentation de CBK-Means et CBK-Medoids . . . . .	68
3.6.3	Troisième contribution (Improved CBFCM) . . . . .	72
3.7	Comparaison entre CBFCM et Improved CBFCM . . . . .	75
3.7.1	Energie résiduelle . . . . .	75
3.7.2	Durée de vie du réseau . . . . .	76
3.7.3	Stabilité du réseau . . . . .	76
3.8	Conclusion . . . . .	77
<b>4</b>	<b>Routage énergétique basé sur l'apprentissage automatique pour les WBAN</b>	<b>79</b>
4.1	Introduction . . . . .	79
4.2	Travaux liés . . . . .	81
4.3	Modèle de réseaux de capteurs . . . . .	84
4.3.1	Modèle de système . . . . .	84
4.3.2	Modèle énergétique . . . . .	85
4.4	Algorithmes du Machine Learning utilisés . . . . .	86
4.4.1	Machine Learning . . . . .	86
4.4.2	Algorithme "Decision tree" . . . . .	86
4.4.3	Algorithme "K-Nearest Neighbors" . . . . .	87

4.4.4	Algorithme "Support Vector Machine" . . . . .	87
4.4.5	Algorithme "Linear Regression" . . . . .	88
4.5	Résultats et discussions . . . . .	89
4.6	Etude comparative . . . . .	91
4.7	Conclusion . . . . .	95
	<b>Conclusion générale</b>	<b>96</b>
	<b>Liste des publications/communications</b>	<b>99</b>
	<b>Bibliographie</b>	<b>100</b>

# Table des figures

1	.....	v
1.1	Réseau de capteurs sans fil. ....	7
1.2	Domaines d'application des WSNs. ....	8
1.3	Topologie WBAN. ....	14
1.4	Architecture WBAN. ....	16
1.5	Exemple d'un réseau de capteur corporel. ....	17
1.6	La structure d'un biocapteur. ....	18
1.7	Structure d'une topologie composite en étoile dans laquelle les nuds sont connectés à un nud central. ....	19
1.8	Exemple de surveillance d'un patient dans un réseau corporel. ....	21
1.9	Domaines d'application des WBANs. ....	22
1.10	Technologie Bluetooth dans les WBAN. ....	26
1.11	Technologie UWB dans les WBAN. ....	27
2.1	Régression linéaire. ....	39
2.2	Régression logistique. ....	40
2.3	Algorithme KNN. ....	42
2.4	Algorithme SVM. ....	43
2.5	Les arbres de décision. ....	45
2.6	Random Forest. ....	46
2.7	Réseau de neurones artificiels. ....	48
2.8	Algorithme K-Means. ....	49
3.1	Localisation des nuds. ....	57
3.2	Répartition des nuds en 2 clusters. ....	62
3.3	Transmission par CBFCM. ....	63
3.4	Energie résiduelle consommée par CBFCM. ....	63
3.5	Nombre de nuds vivants avec le protocole CBFCM. ....	64
3.6	Transmission par CBFCM PN. ....	65
3.7	Energie résiduelle consommée par CBFCM PN. ....	66
3.8	Nombre de nuds vivants avec le protocole CBFCM PN. ....	66

3.9	Energie résiduelle consommée par CBKmeans. . . . .	69
3.10	Energie résiduelle consommée par CBKmeans. . . . .	70
3.11	Nombre de nuds vivants avec le protocole CBKmeans. . . . .	70
3.12	Energie résiduelle consommée par CBKmedoide. . . . .	71
3.13	Nombre de nuds vivants avec le protocole CBKmedoide. . . . .	72
3.14	Transmission par Improved CBFCM. . . . .	73
3.15	Energie résiduelle consommée par Improved CBFCM. . . . .	74
3.16	Nombre de nuds vivants avec le protocole Improved CBFCM. . . . .	74
3.17	Comparaison des énergies résiduelles consommées par les 2 méthodes. . . . .	75
3.18	Comparaison du nombre de nuds vivants pour les 2 méthodes. . . . .	76
3.19	Epuisement dénergie du premier et dernier nud de chaque protocole. . . . .	77
4.1	Structure de lalgorithme "Decision Tree". . . . .	86
4.2	K-Nearest Neighbors. . . . .	87
4.3	Classification des points de données utilisant lalgorithme SVM. . . . .	88
4.4	Algorithme "Linear Regression". . . . .	89
4.5	Residual Energy vs. Rounds. . . . .	90
4.6	Alive nodes vs. Rounds. . . . .	91
4.7	Approches traditionnelles et modèles basés sur la ML en termes de FND, LND et débit. . . . .	93
4.8	Énergie résiduelle aux différents rounds. . . . .	94

# Liste des tableaux

1.1	Comparaison entre les réseaux WSN et WBAN . . . . .	10
1.2	Différents capteurs médicaux placés sur le corps humain . . . . .	20
1.3	Bande de fréquence et bande passante des différentes couches PHY du IEEE 802.15.6 . . . . .	29
3.1	Positions des nuds selon les axes X et Y. . . . .	58
3.2	Paramètres de simulation. . . . .	61
4.1	Déploiement des nuds capteurs biologiques sur le corps humain. . . . .	85
4.2	Paramètres de simulation WBAN . . . . .	89
4.3	Évaluation comparative entre les approches traditionnelles et les modèles ML en termes de FND, LND et débit . . . . .	92
4.4	Comparaison des approches traditionnelles et des modèles ML selon l'énergie résiduelle (en Joules) . . . . .	94

# Introduction générale

Les réseaux de capteurs corporels sans fil (WBAN, pour Wireless Body Area Networks) sont des architectures spécialisées de réseaux de capteurs conçues pour surveiller en temps réel des paramètres physiologiques, biomécaniques ou environnementaux liés au corps humain. Ces réseaux se composent de petits capteurs et d'actionneurs sans fil, implantés à l'intérieur du corps (par exemple, des pacemakers intelligents), portés à sa surface (comme des bracelets ou patches médicaux) ou placés à proximité (comme des smartphones collectant des données). Les WBAN jouent un rôle crucial dans des domaines comme la e-santé, le sport, la télémédecine ou l'assistance aux personnes dépendantes, en permettant une surveillance continue et non invasive. Contrairement aux réseaux de capteurs traditionnels, les WBAN doivent répondre à des contraintes strictes en matière de consommation d'énergie (pour éviter des recharges fréquentes ou des interventions chirurgicales), de latence (pour les alertes médicales urgentes) et de sécurité (pour protéger des données sensibles).

Les défis techniques des WBAN incluent la gestion des interférences (notamment dans des environnements riches en dispositifs sans fil), la fiabilité des transmissions (car le corps humain atténue les signaux) et l'adaptabilité aux mouvements du patient. Les protocoles de communication (comme IEEE 802.15.6, spécialisé pour les WBAN) optimisent la qualité de liaison tout en minimisant l'énergie utilisée. Par ailleurs, l'intégration des WBAN avec l'Internet des Objets (IoT) ou les clouds médicaux ouvre des perspectives comme le diagnostic à distance ou l'analyse prédictive, mais soulève aussi des questions éthiques et légales sur la confidentialité des données. Ainsi, les WBAN représentent une convergence entre l'ingénierie, la médecine et l'informatique, avec un potentiel transformateur pour les systèmes de santé modernes.

Le routage dans les réseaux de capteurs sans fil (WSN) est un défi majeur en raison des contraintes spécifiques de ces réseaux, telles que la limitation d'énergie, la faible puissance de calcul et la dynamique topologique. Contrairement aux réseaux traditionnels, où les protocoles de routage privilégient la performance ou la qualité de service, les WSN nécessitent des approches optimisées pour prolonger la durée de vie du réseau et minimiser la consommation d'énergie. Les protocoles de routage dans les WSN se divisent généralement en trois catégories : les protocoles hiérarchiques

(comme LEACH ou PEGASIS), qui organisent les nuds en clusters pour réduire la surcharge de communication ; les protocoles basés sur la localisation (comme GEAR ou GPSR), qui utilisent les coordonnées géographiques pour acheminer les données ; et les protocoles à flux de données (comme Directed Diffusion), où les requêtes et les données sont diffusées de manière économe en énergie. De plus, des mécanismes comme le data aggregation (fusion des données) et la multihop communication (transmission par sauts) sont souvent intégrés pour réduire la redondance et la distance de transmission. Cependant, des défis persistent, notamment la gestion de la mobilité des nuds, l'équilibrage de charge énergétique et la robustesse face aux pannes, ce qui motive des recherches continues sur des protocoles hybrides ou bio-inspirés.

L'évolution des protocoles de routage tient également compte des applications variées des WSN, comme la surveillance environnementale, la santé connectée ou les villes intelligentes. Par exemple, dans les applications temps réel, les protocoles doivent garantir une faible latence, tandis que dans les environnements hostiles, la fiabilité devient critique. Les approches récentes exploitent l'intelligence artificielle pour adapter dynamiquement les routes en fonction des conditions du réseau (congestion, énergie résiduelle, etc.). Par ailleurs, l'intégration des WSN avec l'Internet des Objets (IoT) complexifie le routage en introduisant des passerelles hétérogènes et une échelle massive. Ainsi, le routage dans les WSN reste un domaine actif, où l'équilibre entre efficacité énergétique, robustesse et adaptabilité est au cur des innovations.

## 1. Motivation

Les réseaux de capteurs corporels sans fil (WBANs) jouent un rôle essentiel dans le domaine de la santé connectée en permettant une surveillance médicale continue et en temps réel de paramètres vitaux tels que le rythme cardiaque, la glycémie ou l'activité cérébrale. Cependant, leur efficacité est souvent limitée par des contraintes énergétiques, ce qui rend cruciale l'optimisation de leur durée de vie. En effet, une autonomie prolongée est nécessaire pour assurer une surveillance ininterrompue, particulièrement pour les patients atteints de maladies chroniques ou en situation critique, où toute interruption pourrait avoir des conséquences graves. Par ailleurs, de nombreux capteurs sont implantés ou portés en permanence, comme les pacemakers ou les patches médicaux, ce qui rend le remplacement fréquent des batteries à la fois coûteux, invasif et gênant pour les patients. Les nuds WBANs, caractérisés par des ressources limitées en termes de batterie et de puissance de calcul, doivent fonctionner de manière optimale pour éviter les pannes prématurées et garantir une transmission fiable des données, notamment dans des situations d'urgence où une défaillance pourrait compromettre la rapidité des interventions médicales. De plus, une meilleure gestion de l'énergie contribue à réduire les coûts pour les systèmes de santé et les patients, tout en limitant l'impact environnemental lié à la production et à l'élimination des batteries. Dans un contexte plus large, l'intégration des WBANs

dans les écosystèmes IoT et les réseaux 5G/6G nécessite une autonomie accrue pour assurer une interopérabilité efficace avec d'autres dispositifs connectés. C'est dans cette optique que cette thèse propose des solutions innovantes, telles que des protocoles de clustering intelligents basés sur des algorithmes comme le FCM ou le K-Means, des techniques de routage optimisées par apprentissage automatique (SVM, arbres de décision), et des modèles énergétiques adaptatifs prenant en compte la mobilité et les variations des canaux de transmission. Ces avancées visent à rendre les WBANs plus durables, fiables et économes en énergie, ouvrant ainsi la voie à des applications médicales plus performantes et à une santé connectée plus robuste, capable de sauver des vies tout en réduisant les contraintes techniques et financières.

## 2. Organisation de la thèse

Cette thèse est organisée en quatre chapitres comme suit :

- Le premier chapitre est consacré à une revue approfondie des réseaux WBAN, en les comparant aux réseaux de capteurs sans fil classiques (WSN). Après avoir défini les concepts fondamentaux des WSN et WBAN, l'auteur discute de leurs différences en termes de portée, de nombre et de taille des nœuds, de fiabilité, de remplaçabilité, de topologie, ainsi que de compatibilité biologique et de normes de communication. Ce chapitre met aussi en lumière l'utilisation des capteurs pour le suivi de la santé et l'intégration des WBAN dans le paradigme de l'Internet des objets médicaux (IoT Healthcare). Il se termine par une description de l'architecture de communication typique des WBANs, incluant les différents niveaux de topologie et les mécanismes de transmission de données.
- Le deuxième chapitre introduit les concepts fondamentaux du Machine Learning, qui constitue un axe méthodologique central dans la suite du travail. L'auteur y présente les différentes catégories d'apprentissage : supervisé, non supervisé, semi-supervisé et par renforcement. Ensuite, une revue détaillée des algorithmes est proposée, incluant la régression linéaire et logistique, les méthodes basées sur la distance comme k-NN, les classificateurs à marge comme SVM, les approches arborescentes (arbres de décision, forêts aléatoires), ainsi que les réseaux de neurones, le clustering (k-means), la réduction de dimension (PCA), et l'apprentissage par renforcement (Q-learning). Ce chapitre sert de socle théorique à l'application de ces algorithmes dans les protocoles de routage.
- Le troisième chapitre constitue une première contribution scientifique centrée sur l'optimisation de la durée de vie du réseau WBAN à travers des protocoles de regroupement (clustering) basés sur le Fuzzy C-Means (FCM). Après une revue des travaux récents, l'auteur propose plusieurs protocoles originaux de regroupement, détaillant les approches de déploiement des

nuds, le modèle énergétique utilisé, ainsi que la modélisation de la perte de propagation. Trois contributions sont présentées, incluant notamment l'intégration d'algorithmes de clustering comme k-means et k-medoids pour améliorer la sélection des têtes de cluster. Les performances de ces protocoles sont évaluées à l'aide de simulations, selon des indicateurs tels que l'énergie résiduelle, la durée de vie du réseau et la stabilité des communications. Une comparaison entre les protocoles CBFCM et Improved CBFCM permet de valider les gains apportés par les contributions proposées.

- Le quatrième chapitre constitue la deuxième contribution de la thèse, dans laquelle l'auteur propose un protocole de routage énergétique basé sur des algorithmes de Machine Learning. Un modèle de réseau WBAN est d'abord défini, incluant la description du système et le modèle de consommation énergétique. L'auteur applique ensuite plusieurs algorithmes supervisés tels que l'arbre de décision (Decision Tree), le k-plus proches voisins (K-NN), la machine à vecteurs de support (SVM) et la régression linéaire. Ces modèles sont entraînés pour prédire les routes de communication les plus efficaces en fonction de paramètres liés à la consommation énergétique et à la topologie du réseau. Les résultats sont discutés de manière comparative, montrant les performances relatives des différentes approches et leur impact sur la longévité du réseau.

La thèse se clôture par une conclusion générale qui récapitule les apports scientifiques majeurs des travaux. Elle met en évidence les gains en efficacité énergétique et en stabilité réseau obtenus grâce à l'intégration de protocoles de clustering intelligents et d'algorithmes d'apprentissage automatique. En outre, l'auteur suggère plusieurs perspectives de recherche, telles que l'exploration de techniques de Deep Learning, l'optimisation multi-objectifs ou encore l'expérimentation dans des environnements cliniques réalistes.

# Réseaux de capteurs corporels sans fil

## Sommaire

---

<b>1.1</b>	<b>Introduction</b>	<b>6</b>
<b>1.2</b>	<b>Les réseaux WBANs vs les réseaux WSNs</b>	<b>7</b>
1.2.1	Définition dun WSN	7
1.2.2	Définition dun WBAN	9
1.2.3	Comparaison entre les réseaux WBANs et les réseaux WSNs	9
1.2.3.1	Portée, nombre et taille de nuds, fiabilité et le remplacement des nuds	9
1.2.3.2	Topologie	11
1.2.3.3	Compatibilité biologique, Technologies sans fil et standard	11
1.2.4	Utilisation de capteurs pour le contrôle de la santé	11
1.2.5	IoT Healthcare	12
<b>1.3</b>	<b>Architecture de communication des WBANs</b>	<b>13</b>
1.3.1	Topologie WBAN	13
1.3.2	Architecture de communication des WBANs	15
1.3.3	Fonctionnement du réseau de capteurs corporels	16
<b>1.4</b>	<b>Applications WBANs et leurs importance</b>	<b>21</b>
1.4.1	Domaine médical	22
1.4.2	Domaine non médical	23
1.4.2.1	Domaine militaire	23
1.4.2.2	Entraînement sportif	23
1.4.2.3	Applications de divertissement	23
1.4.2.4	Urgences	23
1.4.2.5	Authentification	24
<b>1.5</b>	<b>Technologies de communication WBAN</b>	<b>24</b>
1.5.1	Technologie ZigBee - IEEE 802.15.4	24
1.5.2	Technologie Bluetooth - IEEE 802.15.1	25
1.5.3	Technologie ultra-large bande (UWB) - IEEE 802.15.3	26
1.5.4	Wi-Fi IEEE 802.11	27

1.5.5	IEEE 802.15.6 . . . . .	28
1.5.5.1	Spécification de la couche PHY . . . . .	28
1.5.5.2	La couche MAC . . . . .	29
<b>1.6</b>	<b>Recommandations dimplémentation dun WBAN . . . . .</b>	<b>30</b>
<b>1.7</b>	<b>Défis et problèmes des WBANs . . . . .</b>	<b>30</b>
1.7.1	Topologie du réseau . . . . .	30
1.7.2	Efficacité énergétique . . . . .	31
1.7.3	Environnement hétérogène . . . . .	31
1.7.4	Effets biologique . . . . .	31
1.7.5	QoS in WBAN . . . . .	32
<b>1.8</b>	<b>Conclusion . . . . .</b>	<b>32</b>

---

## 1.1 Introduction

Un réseau de capteurs sans fil (Wireless Sensor Network WSN) est constitué dun ensemble de capteurs miniaturisés communicants munis dune source dénergie très limitée qui nexige généralement aucune infrastructure.

Un réseau de capteurs corporels sans fil (Wireless Body Area Network WBAN) est un cas particulier des WSNs. Le WBAN a été présenté pour la première fois par T. G. Zimmerman dans un article datant de 1996, mais il a dabord appelé ces réseaux corporels nWireless Personal Area Network (WPAN) z pour réseaux personnels sans fil. Plus tard, PAN a été redéfini et le nom WBAN est apparu [1].

Le système WBAN peut être défini comme un ensemble de composants électroniques qui communiquent avec ou sans fil pour construire un système qui surveille en permanence les signaux vitaux de lêtre humain grâce aux capteurs placés sur son corps, qui considère le corps humain comme centre de communication [2].

Les progrès de la microélectronique et des circuits intégrés, de la conception de systèmes sur puce, de la communication sans fil et des capteurs intelligents faible-énergie ont favorisé le développement du WBAN. Le WBAN est considéré comme une évolution des réseaux de capteurs sans fil vers les technologies portables et implantées et représente un réseau avec des perspectives de plus en plus importantes. De ce fait Le WBAN est considéré comme une solution précieuse pour surveiller le corps humain à distance et de manière fluide [3].

L'IEEE 802 a créé un groupe de travail (Task Group) appelé IEEE 802.15.6 en novembre 2007 pour la normalisation du WBAN. L'objectif du groupe est d'établir une norme de communication à courte portée pour des applications à faible consommation d'énergie et à haute fiabilité sur, dans et autour du corps humain [4].

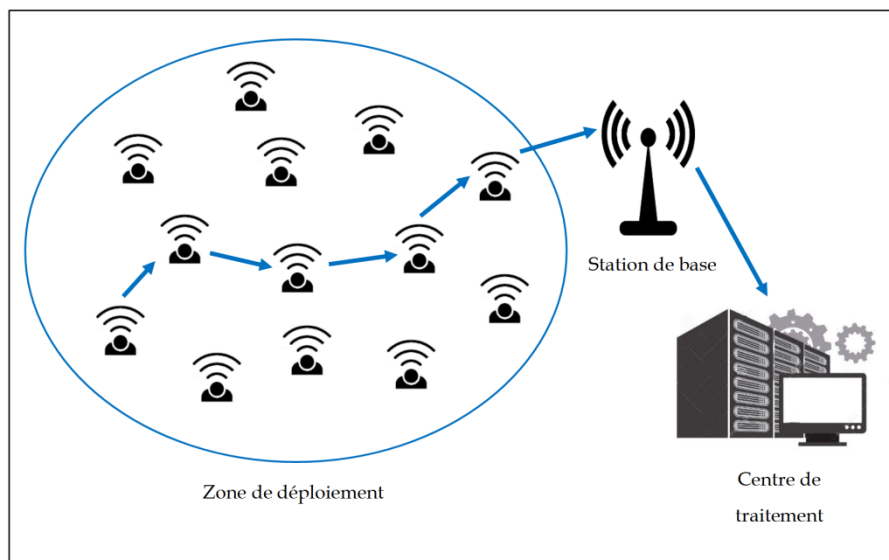
Il existe différentes annotations pour WBAN comme WBANS - Wireless Body Area Sensor Networks ou WBSN - Wearable Body Sensors Network [5].

Des définitions du WBAN, ses architectures, ses applications, et ses défis seront présentés au cours de ce chapitre.

## 1.2 Les réseaux WBANs vs les réseaux WSNs

### 1.2.1 Définition dun WSN

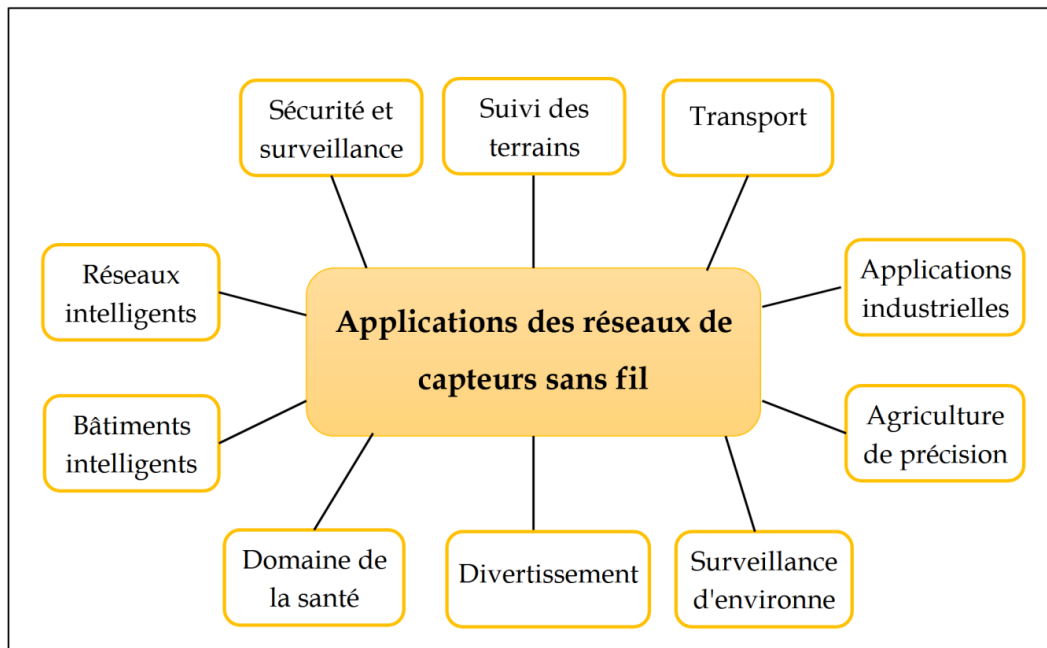
Les réseaux de capteurs sans fil (Wireless Sensor Network WSN) sont des réseaux basés sur la coopération de nuds de capteurs à faible consommation d'énergie, à faible coût et à communication sans fil. Un capteur est un dispositif qui détecte des événements ou des changements dans son environnement et envoie ces informations à un autre système électronique. Le nombre de capteurs peut varier entre quelques dizaines à des milliers. Ces capteurs sont de petite taille, ils sont dotés d'une source énergétique réduite. Un réseau de capteurs sans fil n'exige généralement aucune infrastructure, il est utilisé pour effectuer des tâches de collecte de données et de surveillance sur un terrain d'intérêt. Le déploiement des capteurs peut être d'une manière structurée ou d'une manière aléatoire dans une zone géographique appelée champ de captage ou zone de déploiement (voir Figure 1.1). Les données collectées par les capteurs seront envoyées à l'aide d'une connexion sans fil vers un (ou plusieurs) point de collecte appelé station de base. Les principales limites des réseaux de capteurs sont la capacité de mémoire, la puissance de calcul et l'énergie.



*Figure 1.1 – Réseau de capteurs sans fil.*

Toutefois, en raison de l'efficacité accrue de la collecte de données, le domaine d'application des WSNs est très large, il comprend le domaine de transports, de santé, d'agriculture de précision, les applications industrielles, la sécurité, la surveillance de

l'environnement, etc. [6,7]. La Figure 1.2 montre les domaines d'application des WSNs.



*Figure 1.2 – Domaines d'application des WSNs.*

Les applications des réseaux de capteurs sans fil (Wireless Sensor Networks, WSN) sont nombreuses et variées, allant de la surveillance environnementale à la détection de catastrophes naturelles, en passant par l'agriculture de précision, la domotique, la santé connectée et l'industrie. Ces usages, souvent critiques, exigent des performances optimales en matière de communication, ce qui impose la prise en compte de plusieurs paramètres de qualité de service (Quality of Service, QoS). Parmi les paramètres essentiels, on retrouve notamment la latence, la fiabilité, la bande passante et la sécurité, chacun jouant un rôle crucial selon le domaine d'application.

La latence, définie comme le temps de transmission d'un paquet entre un capteur et le destinataire final, est un critère déterminant pour les applications sensibles au temps réel, telles que les systèmes d'alerte ou les dispositifs médicaux embarqués. Une latence excessive peut compromettre la réactivité du système, avec des conséquences potentiellement graves dans les contextes médicaux ou industriels [8].

La fiabilité fait référence à la capacité du réseau à assurer une livraison correcte et sans perte des données transmises. Dans les environnements bruyants ou instables, typiques des milieux extérieurs ou industriels, garantir un taux élevé de livraison des paquets est un défi central. Des mécanismes de redondance, de retransmission, et de contrôle d'erreur sont donc souvent mis en œuvre pour améliorer la robustesse des communications [9].

La bande passante constitue également une contrainte majeure, particulièrement dans les WSN multi-sauts ou fortement peuplés. L'accès partagé au canal radio limite

la quantité de données pouvant être transmises simultanément, ce qui nécessite l'optimisation des protocoles de routage, de compression et d'agrégation des données afin d'éviter la congestion et les collisions [10].

Enfin, la sécurité représente un enjeu transversal, indispensable dans les applications impliquant des données sensibles comme les informations médicales ou militaires. Les WSN sont particulièrement vulnérables aux attaques en raison de la limitation des ressources en calcul et en énergie, ainsi que de leur déploiement dans des environnements ouverts. Des solutions légères de cryptographie, d'authentification, et de détection d'intrusion doivent donc être intégrées dès la conception du réseau [11].

Ainsi, la satisfaction simultanée de ces exigences de QoS nécessite une conception fine et équilibrée des protocoles de communication et des architectures réseau, adaptée aux contraintes matérielles des capteurs tout en répondant aux impératifs fonctionnels de l'application ciblée.

### 1.2.2 Définition d'un WBAN

Un réseau de capteurs corporels sans fil (Wireless Body Area Network WBAN) [12–14] est un cas particulier des WSNs, il est constitué d'un ensemble de capteurs miniaturisés portés ou implantés sur le corps humain. Ces capteurs sont capables de prendre des mesures sur les caractéristiques physiologiques du corps humain ou sur son environnement. Ces données captées seront enregistrées puis envoyées à l'aide d'une connexion sans fil vers un dispositif central de traitement appelé sink (puits). Le sink contrairement aux autres nœuds est connu pour ses capacités élevées sur le plan énergétique et puissance de calcul [15].

### 1.2.3 Comparaison entre les réseaux WBANs et les réseaux WSNs

Malgré les ressemblances qui existent entre les WBANs et WSNs, plusieurs différences peuvent être identifiées entre les deux réseaux, le Tableau 1.1 résume les principales différences [16].

#### 1.2.3.1 Portée, nombre et taille de nœuds, fiabilité et le remplacement des nœuds

Dans les WSNs, les nœuds sont de petite taille ; généralement, ils sont déployés d'une façon aléatoire dans des zones qui ne sont pas facilement accessibles (voire hostile). On place un nombre important de nœuds (densité élevée) pour assurer la redondance afin de contourner les problèmes de défaillance des nœuds vu que leur remplacement n'est pas facile. Cependant, pour le cas des WBANs, les nœuds sont placés sur le corps humain (ou implantés sous la peau) soigneusement dans des endroits étudiés. D'après le standard IEEE 802.15.6 [17], le nombre de nœuds dans un WBAN typique peut varier

*Tableau 1.1 – Comparaison entre les réseaux WSN et WBAN*

<b>Facteur</b>	<b>WSN</b>	<b>WBAN</b>
Portée / environnement dexploitation	Environnement externe (quelques mètres à plusieurs kilomètres)	Corps humain (centimètres à mètres)
Nombre de nuds	Grand nombre, couverture étendue	Petit nombre, espace restreint
Taille des nuds	Petite taille souhaitable mais pas impérative	Miniaturisation indispensable (capteurs portés ou implantés)
Fiabilité	Assurée par la redondance de nuds	Assurée par la robustesse individuelle des nuds
Remplacement des nuds	Facile, certains nuds peuvent être jetables	Difficile, surtout pour les nuds implantés
Topologie	Généralement peu changeante (souvent statique)	Très dynamique (mouvements corporels)
Compatibilité biologique	Peu ou pas considérée	Critère crucial (biocompatibilité, contraintes SAR)
Technologies sans fil typiques	ZigBee, Bluetooth, Wi-Fi, GPRS, etc.	UWB, MICS, Bluetooth Low Energy (très basse puissance)
Standard principal	IEEE 802.15.4	IEEE 802.15.6

entre 6 et 256. Un seul WBAN peut impliquer un seul coordinateur et au maximum 64 nuds. Etant donné que 2 à 4 WBANs peuvent coexister sur la même personne, un maximum de 256 nuds peut exister par personne. Dans les WBANs, la fiabilité est assurée par la robustesse des nuds ce qui exige une bonne gestion de leurs ressources. La défaillance d'un nud n'est pas tolérée, donc en cas de défaillance (ou épuisement d'énergie) on procède directement à son remplacement [15].

### 1.2.3.2 Topologie

Dans les WSNs, habituellement les nuds ne sont pas mobiles et ils sont considérés comme stationnaires. Pour cela, la topologie des WSNs est inchangeable. Par contre dans le cas des WBANs, les personnes portant des capteurs peuvent se déplacer (par exemple changement de posture des mains) et par conséquent les nuds capteurs sont des nuds mobiles.

### 1.2.3.3 Compatibilité biologique, Technologies sans fil et standard

La plupart des réseaux WSNs sont utilisés pour surveiller des événements, où la compatibilité biologique est très peu considérée. Les technologies sans fil utilisées pour les WSNs sont Bluetooth, ZigBee, GPRS, WLAN, etc. la norme standard pour les WSNs est le standard IEEE 802.15.4. Cependant, les WBANs sont utilisés pour mesurer des valeurs physiologiques de l'être humain, en d'autres termes, un WBAN est mis en place directement sur le corps humain, ce qui exige une forte compatibilité biologique. En outre, la technologie sans fil à utiliser doit être à faible puissance. La norme standard pour les WBANs est le standard IEEE 802.15.6 [15, 17].

## 1.2.4 Utilisation de capteurs pour le contrôle de la santé

Les cas d'utilisation de ces réseaux WBAN comprennent la collecte à distance de données physiologiques du corps humain, la détection des patients et des médecins dans un environnement médical et l'organisation des médicaments dans un hôpital. Grâce aux progrès significatifs de la technologie des réseaux de capteurs sans fil dans le secteur médical et à l'utilisation des données fournies par cette technologie en dehors de l'hôpital, il est possible pour les praticiens médicaux d'être alertés en cas d'urgence médicale, ce qui permet à l'équipe médicale de prendre des mesures en temps voulu. Les différents facteurs à prendre en compte pour la transmission des données dans les réseaux de télémédecine sont la disponibilité, la confidentialité, le respect de la vie privée, la fiabilité, la qualité du service et la mobilité (portabilité) [7, 18].

La plupart des patients consultent un médecin lorsqu'ils présentent des symptômes anormaux et, souvent, dans les cas graves, le patient doit être traité immédiatement. Dans de tels cas, le patient doit être traité rapidement et il peut être amené à dépenser beaucoup d'argent pour le traitement. Cependant, l'utilisation d'un réseau de

capteurs permet non seulement de maintenir le bien-être physique des individus, mais aussi d'identifier l'apparition d'une maladie, ce qui contribue à réduire les coûts et les risques supplémentaires tout au long du processus thérapeutique [19].

Les réseaux de capteurs seront largement utilisés dans les soins de santé à l'avenir. Des types de capteurs rudimentaires sont actuellement utilisés dans certains hôpitaux de pointe pour surveiller les données physiologiques des patients, suivre les traitements médicamenteux et surveiller les médecins et les patients dans l'hôpital.

L'une des applications des réseaux de capteurs dans ce domaine concerne les soins aux personnes âgées. À cette fin, des caméras sont utilisées pour détecter l'activité musculaire, ce qui crée un réseau complexe. Ce réseau surveille les personnes âgées et peut détecter les chutes, l'état d'inconscience, les signes vitaux, le régime alimentaire et l'exercice physique. Les experts estiment qu'à l'avenir, grâce aux progrès technologiques et à l'utilisation de la technologie à large bande, ces réseaux pourront être d'une grande utilité pour déterminer l'état de santé réel du corps. Les diagnostics de santé en temps réel utilisant cette technologie peuvent compenser les retards dans l'identification des maladies dégénératives, sauver des vies et, par conséquent, réduire les coûts de santé.

Dans certains cas, il est désormais possible de surveiller la santé à distance, mais les systèmes de surveillance à distance ne sont pas encore parfaits. Les capteurs de surveillance actuels décrits dans des travaux antérieurs utilisant la technologie à bande ultralarge sont très petits et portables, et ils reçoivent l'énergie dont ils ont besoin de la chaleur du corps. Malgré leur petite taille, ces dispositifs sont capables de transmettre de grandes quantités d'informations qui amélioreront considérablement les services médicaux et les soins de santé, réduiront les coûts de traitement et contribueront à la prévention des maladies. Pour ce type de mesure et de surveillance de la santé, un dispositif à bande ultra-large sera conçu, a déclaré Patrick Chiang, spécialiste de l'électronique sans fil et professeur adjoint de médecine à l'École de génie électrique et d'informatique (Oregon State University OSU). Il peut également collecter et transmettre des données sur la santé cardiaque, le volume osseux, la pression artérielle et les niveaux d'insuline dans le corps. En plus de surveiller la santé du patient, ce dispositif peut également prévenir les maladies; par exemple, il est possible de diagnostiquer une arythmie chez un patient et de prédire la survenue d'une crise cardiaque. Ce dispositif doit être bon marché et accessible à tous et doit également être capable de stocker et de fournir d'énormes quantités de données [20].

### 1.2.5 IoT Healthcare


L'internet des objets (IoT) est une technologie moderne impliquant des objets intelligents comprenant des composants physiques tels que des capteurs qui détectent l'état interne d'un événement ou d'un environnement externe et effectuent certaines actions sur la base des données collectées. Les données générées par les capteurs

des objets intelligents (smart) peuvent être analysées et des décisions peuvent être prises en conséquence. Ces objets intelligents sont dotés d'un logiciel intégré qui permet de contrôler les différents éléments et événements générés par ces objets. Le paradigme IoT combine les avantages de différentes branches informatiques telles que le Cloud ou le edge ainsi que l'automatisation, dans les technologies de communication afin de créer de nouveaux axes et opportunités dans divers domaines. En 2030, 75 billions de composants devraient être connectés par la technologie IoT d'après le dernier rapport d'état de l'IoT. Parmi les domaines concernés par l'IoT, citons les entreprises, les activités de fabrication, la santé, le commerce et la défense/sécurité. Il existe de nombreuses applications de l'IoT, notamment le stationnement intelligent, l'éclairage intelligent, la gestion des déchets, la détection des incendies de forêt, la détection des tremblements de terre, la gestion intelligente des récoltes et les soins à distance pour les personnes âgées [7, 21].

## 1.3 Architecture de communication des WBANs

### 1.3.1 Topologie WBAN

La norme IEEE 802.15.6 définit le réseau de capteurs corporels (BAN) comme un arrangement de nuds capteurs (Sensor Nodes, SNs) et d'un coordinateur ou nud central (hub, sink). L'ensemble adopte la topologie en étoile avec deux types de communications différentes : la topologie en étoile simple à un saut (one hop) et étendue à deux sauts (two-hop). Dans la topologie en étoile simple à un saut, les nuds échangent des trames directement avec le sink du BAN, tandis que dans la topologie étendue à deux sauts, un nud relais est introduit et les nuds peuvent communiquer directement avec le sink ou par l'intermédiaire d'un nud relais, comme l'illustre la figure 1.3. Cette topologie est facile à concevoir, implémenter et étendre. Il est nécessaire d'avoir un nud central suffisamment puissant car tout le trafic de données passe par ce nud central. Le principal inconvénient de cette topologie réside dans la vulnérabilité de ce nud ; si ce dernier tombe en panne, aucune connexion ne peut être établie [15]. Le nombre total de nuds dans un seul BAN est spécifié par la norme et a été fixé à 64 [22].



**Figure 1.3** – Topologie WBAN.

Les nuds du réseau BAN peuvent être classés en fonction de leur rôle en [22] :

- **Hub** : Le nud hub, le nud sink ou le coordinateur sont des noms différents pour le même type de nud. Le hub sert de passerelle vers un autre réseau BAN ou vers des réseaux externes. Il contrôle le réseau BAN et toutes les communications externes passent par lui. Il dispose de meilleures ressources comparé aux nuds normaux à l'intérieur du réseau BAN.
- **Nud relais** : Certains nuds ont la capacité de relayer les messages des nuds finaux vers le hub. Ils sont situés dans la zone de communication directe du hub. Le relais est nécessaire dans la topologie en étoile étendue du WBAN.
- **Nud terminal** : Les autres nuds du WBAN sont considérés comme des nuds terminaux. Ils sont conçus pour effectuer des tâches spécifiques et échanger des messages avec le hub directement s'ils sont dans la zone de communication directe ou via des nuds de relais s'ils sont en dehors de cette zone.

D'autres classifications sont disponibles dans la littérature, selon le lieu de déploiement

du nud, dans le corps (in body), ou sur le corps (on body), etc. et selon la fonctionnalité du nud (nuds capteurs ou nuds actionneurs, etc.).

### 1.3.2 Architecture de communication des WBANs

Si l'on considère l'ensemble de l'écosystème WBAN, la communication de données peut être divisée en différents niveaux de communication. Trois niveaux de communication sont reconnus dans la norme WBAN [18, 19, 23] comme suit :

- **Tier-1 communication Intra-BAN** : la communication de données au premier niveau comprend la communication entre les nuds capteurs eux-mêmes et entre les nuds capteurs et le hub. Dans ce niveau de communication l'émetteur et le récepteur sont tous deux situés dans la zone corporelle. Il s'agit de nuds capteurs à l'intérieur du corps (in body), sur le corps (on body) et hors du corps (off body).
- **Tier-2 communication Inter-BAN** : la communication Tier-2 comprend la communication entre deux BAN différents et la communication entre le hub et les points d'accès (APs).
- **Tier-3 communication Beyond BAN** : la communication Tier-3 représente toutes les communications qui ont lieu au-delà du BAN. Le niveau 3 comprend la communication entre les points d'accès et les serveurs médicaux via l'internet. Tous les protocoles de ce niveau de communication sont bien définis dans la pile TCP/IP.

La figure 1.4 décrit tous les niveaux de communication WBAN. Sur cette figure, deux BAN sont représentés au niveau Tier-1 de la communication, où les nuds sur le corps et les nuds implantés sont répartis sur tout le corps. Tous les nuds sont connectés au hub par communication directe ou par l'intermédiaire d'un nud relais [22]. La fonction principale de ce premier niveau est de collecter les données physiologiques sur le corps humain et de les transmettre au niveau 2 par le biais d'une connexion sans fil.

Dans le niveau Tier-2, on trouve des téléphones intelligents, des ordinateurs personnels ou d'autres appareils électroniques intelligents. Ce niveau joue le rôle d'un relais entre le premier niveau et le troisième niveau, il reçoit les données envoyées en mode sans fil par les capteurs et les transmet au centre médical via Internet. Le troisième niveau correspond au centre médical dans lequel se trouve l'équipe médicale chargée de rassembler et d'analyser les données reçues. Les données mesurées peuvent être sujet d'un diagnostic en temps réel. En cas de réception des données critiques, l'équipe médicale peut effectuer une intervention d'urgence, ce qui peut accélérer le traitement, et même sauver la vie du patient [15].

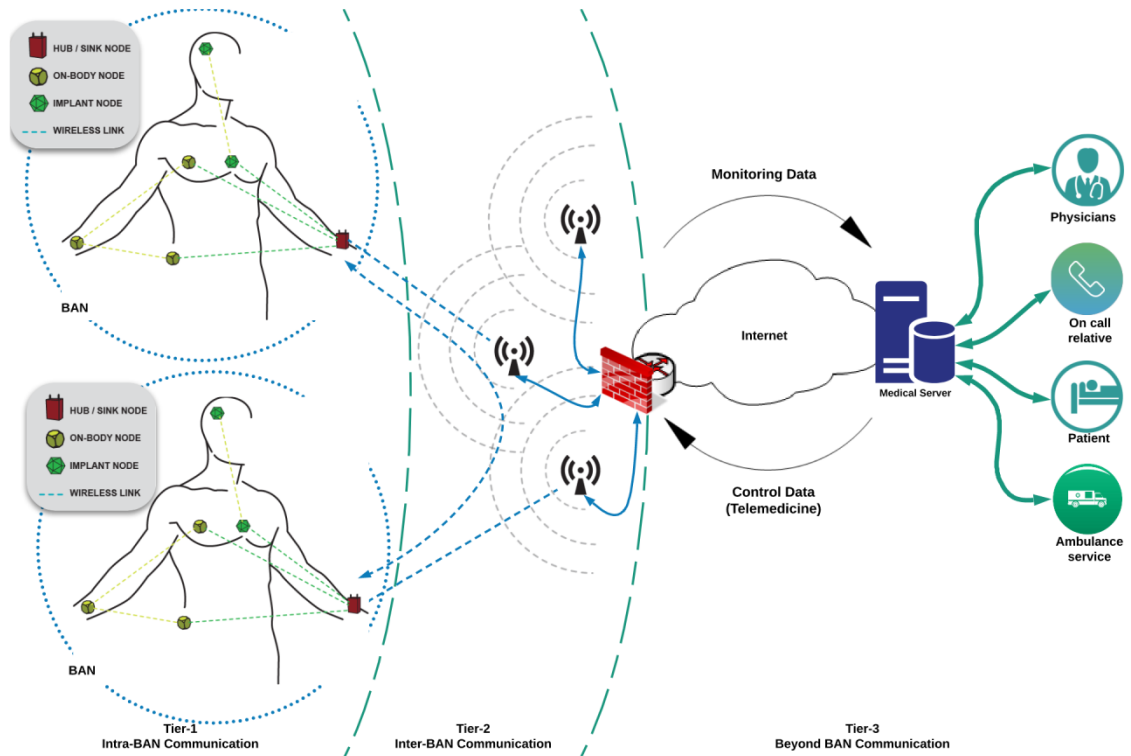


Figure 1.4 – Architecture WBAN.

### 1.3.3 Fonctionnement du réseau de capteurs corporels

Aujourd’hui, l’utilisation de réseaux de capteurs sans fil est une question importante pour améliorer le degré d’intelligence et de synchronisation des systèmes industriels ou environnementaux. L’une des principales utilisations des réseaux de capteurs sans fil dans les systèmes de santé humaine est le réseau de capteurs corporels sans fil.

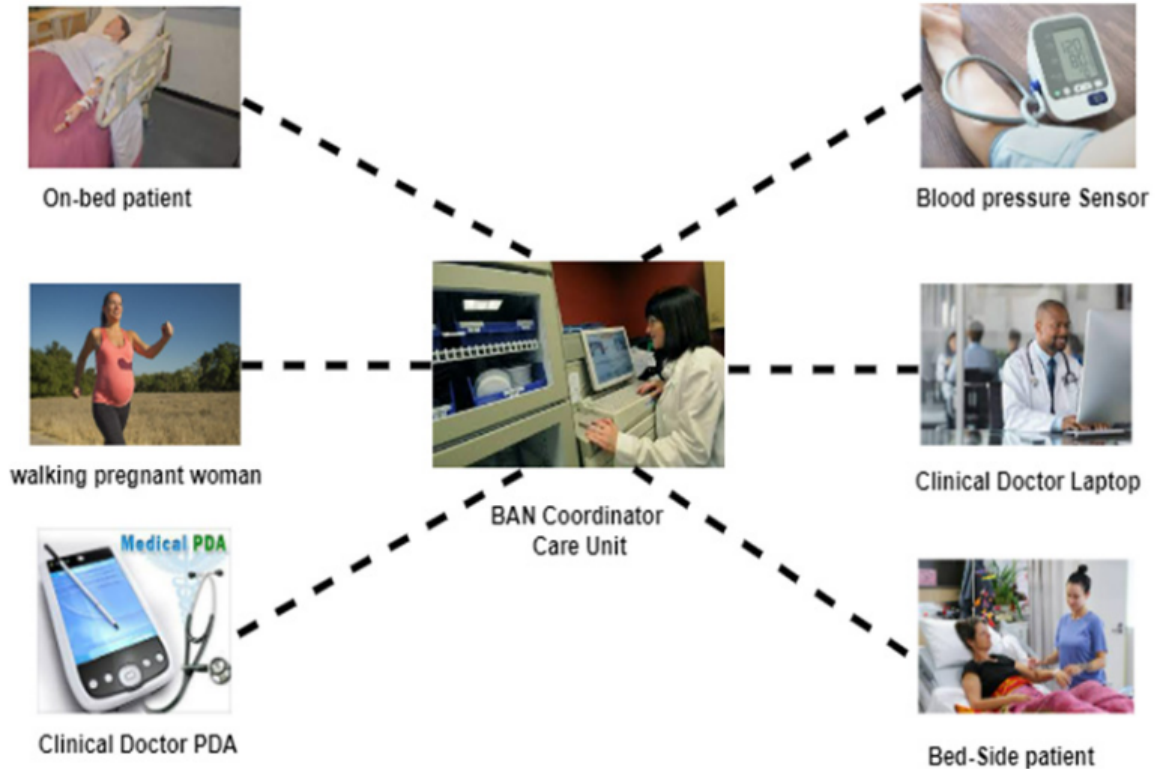
Ce réseau à base de biocapteurs s’intéresse à la surveillance des signes vitaux ; tels que la température corporelle, pression artérielle, transpiration de la peau, glycémie, rythme cardiaque, saturation en oxygène, électrocardiogramme (ECG), etc ; reçus des patients ou des personnes âgées aux centres de soins médicaux une fois que le patient est sorti de l’hôpital et a repris sa vie quotidienne [24, 25].

Cela permet aux médecins et aux centres d’urgence de surveiller l’état des patients en temps réel ou avec un léger retard, et de répondre à leurs besoins de traitement de manière précise et opportune.

Les capteurs corporels doivent être légers, consommer peu d’énergie et passer rapidement du mode veille au mode réveil pour économiser l’énergie. En outre, le matériau utilisé pour fabriquer les capteurs ne doit pas être nocif pour le corps humain [25].

La figure 1.5 présente un exemple de réseau de capteurs sans fil dans le système

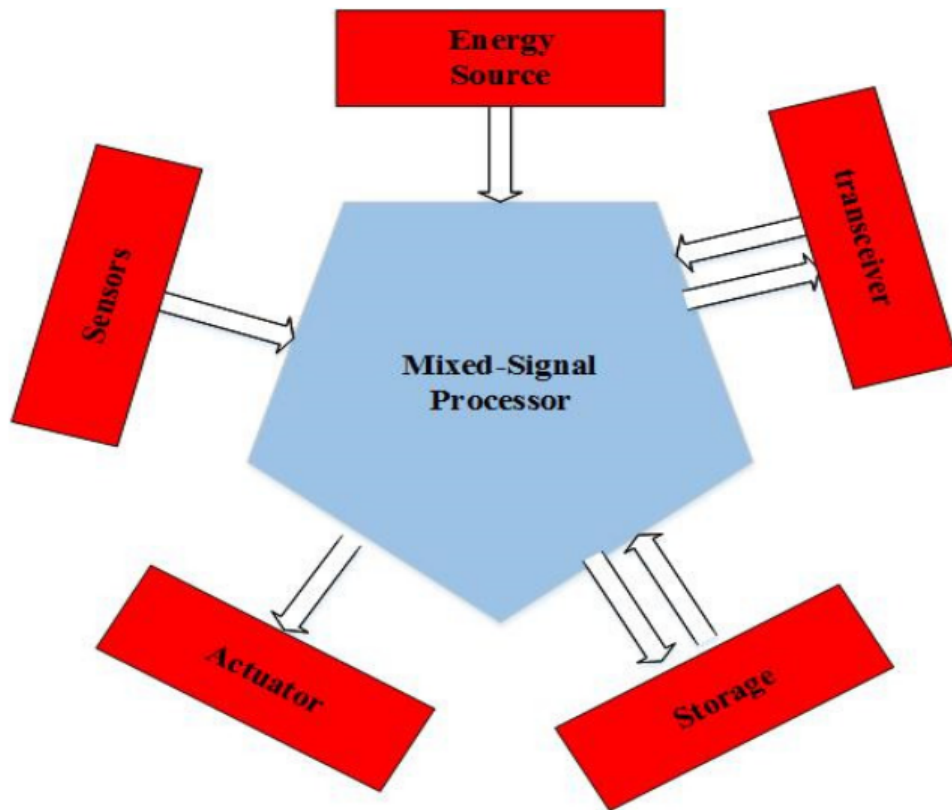
de soins de santé qui recueille les données physiologiques des patients dans différentes situations et les envoie à l'unité de coordination des soins médicaux. Ces informations sont transmises au médecin par le biais de diverses méthodes de communication [7].



*Figure 1.5 – Exemple dun réseau de capteur corporel.*


Les informations reçues des capteurs sont envoyées à l'unité de coordination BAN. Son rôle principal est d'aider à extraire les caractéristiques utiles de l'ensemble des données reçues du corps du patient et de fixer le moment de la transmission des données. Une autre partie de ce nud est l'unité de stockage. Les données retardées sont archivées dans cette unité et fournies au centre médical sur demande. Parfois, les données doivent être sauvegardées en raison des mauvaises conditions du canal.

D'autres éléments importants de ce réseau sont l'unité de communication et l'unité d'alimentation. En règle générale, un émetteur-récepteur doté de quatre canaux de radiofréquence entre 850 MHz et 2.4 GHz est utilisé pour coordonner les nuds et envoyer des données aux nuds suivants. L'énergie nécessaire est fournie par des batteries conçues avec de petites pièces portables. La figure 1.6 montre la structure d'un nud de capteurs corporels appelé TEMPO, développé par des chercheurs de l'université de Virginie, dont la taille est comparable à celle d'une pièce de monnaie [26].



*Figure 1.6 – La structure d'un biocapteur.*

Chacun de ces nuds capteurs corporels est connecté à un nud central selon une topologie en étoile. Dans cette topologie, tous les nuds du corps envoient des données à une unité de collecte. Dans la méthode hybride en étoile maillée, la communication est établie entre les unités de coordination de chaque groupe et, en cas de problème dans un nud, les autres nuds sont immédiatement informés. Cette topologie relie également des collecteurs et des passerelles pour se connecter à des réseaux plus vastes. La figure 1.7 illustre la topologie composite en étoile maillée [27].



*Figure 1.7 – Structure d’une topologie composite en étoile dans laquelle les nuds sont connectés à un nud central.*

Des exemples de différents types de capteurs, utilisés de diverses manières, sont présentés au tableau 1.2, notamment des électrodes cutanées et des bracelets [7, 28].


**Tableau 1.2** – Différents capteurs médicaux placés sur le corps humain

Capteur	Description
ECG	l'activité électrique du cur
Blood flow	Mesures des forces d'accélération dans l'espace tridimensionnel du corps
Blood pressure	la force appliquée par la circulation du sang sur les parois des vaisseaux sanguins
Body temperature	un indicateur de la capacité du corps à créer et à libérer de la chaleur
Respiration rate	nombre de mouvements d'inspiration et d'expiration par unité de temps
Oxygen level	indique l'oxygène qui circule dans le sang du patient
Heart rate	la fréquence du cycle cardiaque
Blood sugar	mesure la quantité de sucre (type, Source, énergie) dans le sang
Muscle signal	l'activité électrique des muscles (système nerveux et musculaire)
Electroencephalography	mesure l'activité cérébrale naturelle et d'autres capacités cérébrales

Comme le montre le tableau 1.2, différents capteurs sont placés sur le corps pour recueillir des données relatives aux symptômes du patient. Par exemple, la température corporelle est un facteur clé qui doit être mesuré pour déterminer l'état de santé du patient. Une température corporelle élevée est un signe de maladie, et une température corporelle basse, dans une certaine mesure, indique un risque accru de maladie. La pression artérielle peut être utilisée pour diagnostiquer un taux élevé de cholestérol, des artères obstruées ou un rythme cardiaque irrégulier. Le capteur de fréquence cardiaque peut également être utilisé pour indiquer le niveau de stress du patient. Lorsque la pression artérielle est mesurée sous l'influence du stress, elle n'est pas à son niveau normal, et la fréquence cardiaque et la température corporelle d'une personne sont directement liées à son niveau d'activité [7].

Un exemple de réseau WBAN médical utilisé pour la surveillance des patients est présenté à la figure 1.8 où plusieurs capteurs sont placés dans les vêtements, directement sur le corps ou sous la peau d'une personne. Parallèlement aux capteurs de mesure, le patient est équipé d'actionneurs qui permettent d'administrer des médicaments. Le médicament peut être administré à des moments prédéterminés, déclenché

par une source externe (c'est-à-dire un médecin qui analyse les données) ou immédiatement lorsqu'un capteur détecte un problème. Un exemple est la surveillance du niveau de glycémie dans le sang des diabétiques. Si le capteur détecte une chute soudaine du taux de glucose, un signal peut être envoyé à l'actionneur afin de commencer l'injection d'insuline. Ainsi, le patient subira moins de nuisances liées à sa maladie [16].

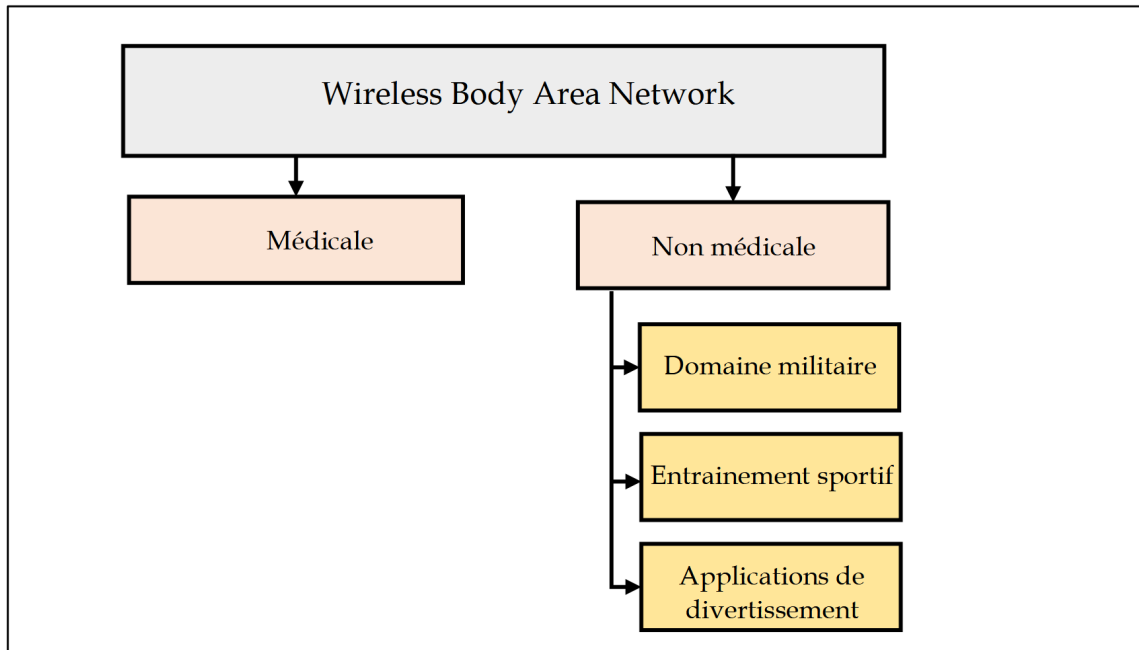


*Figure 1.8 – Exemple de surveillance d'un patient dans un réseau corporel.*

## 1.4 Applications WBANs et leurs importance

La facilité de mise en place d'un WBAN sur le corps humain et le coût de plus en plus faible des capteurs, ainsi que la diversité des capteurs disponibles ont permis au WBAN d'envahir plusieurs domaines d'application (Figure 1.9). On trouve les WBANs dans les soins médicaux omniprésents, l'armée, le sport, le divertissement et de nombreux autres domaines où les êtres humains sont impliqués. Nous pouvons

résumer les applications des WBANs dans les domaines suivants [6].



*Figure 1.9 – Domaines d'application des WBANs.*

### 1.4.1 Domaine médical

L'utilisation des WBANs dans le domaine médical englobe la détection précoce des maladies, la surveillance médicale, le retour d'information postopératoire et l'assistance médicale. Quelques exemples des applications courantes des WBANs dans les soins médicaux. Selon une étude de l'Organisation mondiale de la santé (OMS) [29], d'ici 2050, la population mondiale âgée de 60 ans ou plus serait d'environ 2,1 milliards. Cette augmentation du nombre de personnes âgées soulèvera davantage les problèmes de santé. Selon l'OMS, en 2021, 20,5 millions de personnes sont décédées des suites d'une maladie cardiovasculaire (MCV) un chiffre qui représente environ un tiers de l'ensemble des décès dans le monde et constitue une augmentation significative par rapport aux 12,1 millions de décès dus aux MCV enregistrés en 1990 [30]. De plus, selon l'OMS, plus de 422 millions de personnes souffrent de diabète. L'OMS estime que le diabète était la huitième cause de décès fin 2020 [31]. Les dégâts de ces maladies et d'autres (comme le cancer, Parkinson, l'asthme, etc.) peuvent être évités si elles sont détectées à temps. L'application de WBAN peut jouer un rôle très important dans la détection précoce de toutes ces maladies et par conséquent rendre les systèmes de soins de santé plus efficaces [15]. Aussi, un capteur ECG fixé sur une personne âgée peut détecter un rythme cardiaque inhabituel et envoyer cette information à un réseau social qui pourrait inclure les membres de sa famille, le médecin de famille, les services d'urgence, des amis, des collègues, etc. [32].

## 1.4.2 Domaine non médical

Au-delà du secteur médical, les WBANs se sont imposés dans différents domaines et les applications WBANs ont connu une large portée. On trouve les WBANs dans les domaines suivants [15, 32] :

### 1.4.2.1 Domaine militaire

L'utilisation des WBANs dans le domaine militaire peut être très bénéfique. Un soldat peut être affecté par l'épuisement physique ou psychologique, ainsi que par des blessures ; dans une telle situation, il n'est pas en mesure de conserver ses meilleures capacités physiques. Ces problèmes peuvent être évités en utilisant un WBAN pour observer les performances des soldats pendant l'entraînement ou sur les champs de bataille, et le cas échéant, on procède à leurs remplacements. Le WBAN peut être utilisé pour surveiller par exemple le niveau de substances toxiques dans l'air et avertir les soldats si un niveau mortel est détecté. Cela peut également être mis en œuvre lors des sessions de formation des forces de police, des pompiers et des équipes de gestion des catastrophes. En outre, à l'aide des capteurs de mouvement et des capteurs d'acide lactique, on peut mesurer les performances des individus. En se basant sur ces mesures, on peut offrir un répit à ceux qui sont épuisés en effectuant des remplacements, ce qui permet d'obtenir de meilleures performances.

### 1.4.2.2 Entraînement sportif

Les WBANs sont utilisés dans le domaine de l'entraînement sportif et ils ont contribué à obtenir de meilleurs résultats. Pendant les séances d'entraînement, on procède à l'enregistrement des performances des joueurs ou des athlètes, ces enregistrements seront utilisés pour déterminer les performances en établissant des profils pour chaque joueur. Ces profils seront utilisés pour aider les directeurs sportifs à choisir les bons joueurs ou athlètes selon les différentes situations.

### 1.4.2.3 Applications de divertissement

En plus des applications citées précédemment, un WBAN peut inclure des appareils tels qu'un lecteur MP3, un microphone, une caméra, des interfaces homme-machine avancées telles qu'une interface neuronale qui interagit avec le système nerveux etc. Le WBAN peut également être utilisé à des fins de jeu en réalité virtuelle où le contrôle de jeu est fait avec les gestes de la main et les mouvements corporels grâce aux capteurs de mouvement qui l'équipent.

### 1.4.2.4 Urgences

En cas d'incendie domestique, les détecteurs de fumée peuvent déclencher une alarme incendie. Cependant, une personne malentendante ne pourra pas entendre

cette alarme. Un capteur WBAN peut détecter la gravité de la situation et envoyer une alerte tactile pour avertir la personne du danger. Ceci est également utile dans les industries qui sont vulnérables aux incendies ou aux fuites de gaz toxiques où les capteurs WBAN (off body) peuvent jouer un rôle important en sauvant des vies sur le lieu de travail.

#### 1.4.2.5 Authentification

Une application WBAN peut être utilisée à des fins d'authentification sécurisée en utilisant des paramètres biométriques, tels que les empreintes digitales, la détection du visage, les empreintes de la paume de la main, la géométrie de la main, la reconnaissance de l'iris, la reconnaissance de la rétine et l'odeur. Les signaux biométriques, tels que l'ECG, l'EEG et l'activité électrodermale (EDA), fournissent des signatures biométriques uniques, difficiles à voler, à copier, à falsifier ou à perdre. Ce système est communément appelé *biométrie cognitive*.

## 1.5 Technologies de communication WBAN

Les réseaux sans fil ont suscité une attention accrue de la part des chercheurs. Bien que cette technologie semble bénéfique et qu'elle ait de nombreuses applications, l'étape la plus cruciale qui déterminera le degré de satisfaction à son égard est l'évaluation des besoins et des attentes des utilisateurs et leur comparaison avec les caractéristiques et les capacités de cette technologie. Si les besoins et les attentes de l'utilisateur ne sont pas pris en compte, les possibilités techniques et les applications de cette technologie se solderont par un échec et une insatisfaction. La technologie des réseaux de communication joue un rôle essentiel dans les réseaux de capteurs corporels en raison de la sensibilité des données sur les signes vitaux du corps pour surveiller l'état de santé de l'homme, et elle doit être exempte d'interférences dans les canaux de communication. La normalisation est alors nécessaire pour permettre d'harmoniser et de coordonner les WBAN. Dans ce qui suit, nous nous concentrons sur quelques-unes des technologies sans fil disponibles dans les réseaux de capteurs corporels à courte portée assurant l'échange de données entre les différents nœuds du réseau et la passerelle, elles sont utilisées dans les communications intra-WBAN. Concernant la communication entre la passerelle et le serveur, elle est assurée par les technologies de communication à longue portée comme : WiMax, LTE et LTE-Advance [7, 28].

### 1.5.1 Technologie ZigBee - IEEE 802.15.4

ZigBee est un réseau intelligent utilisé pour les protocoles de communication de haut niveau adoptés par des applications qui nécessitent un faible débit de données et une longue durée de vie de la batterie, ce qui le rend très utilisé pour les applications

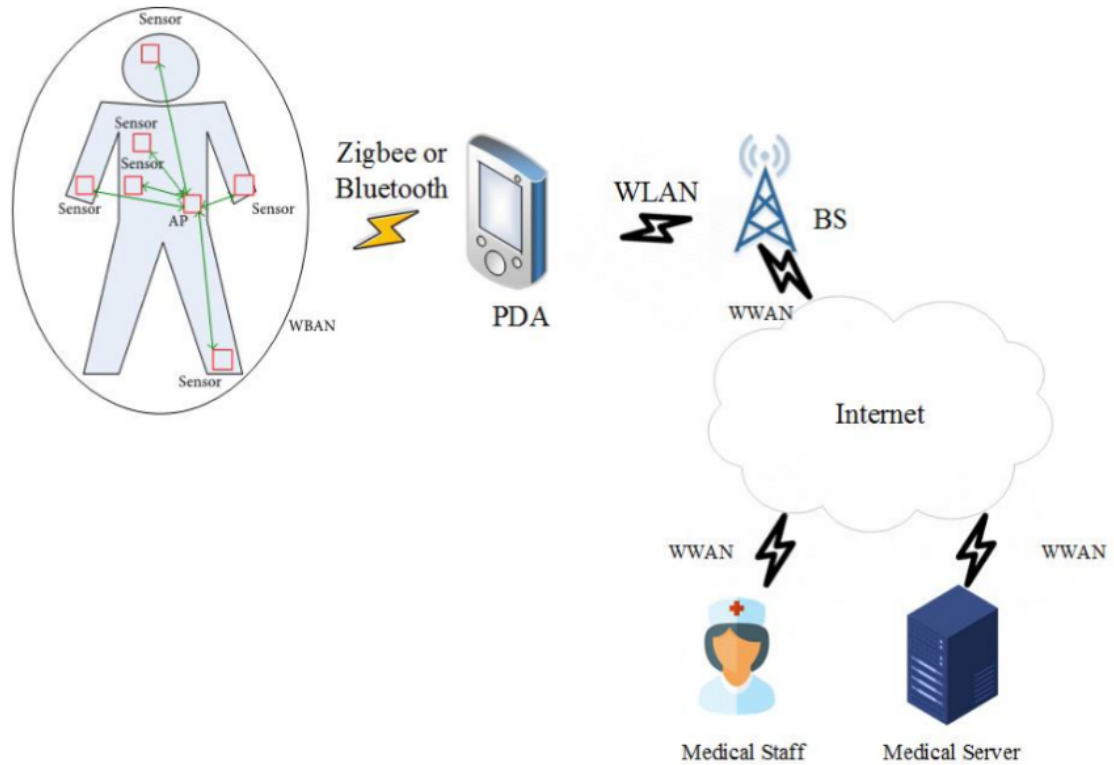
WBAN. Ce protocole est utilisé dans les réseaux personnels (PAN) (petits et de faible puissance), et sa technologie est basée sur la norme IEEE 802.15.4. Dans les réseaux de capteurs corporels, le protocole ZigBee est crypté avec des mots de passe de 128 bits. Ce système est pris en charge par les réseaux arborescents, étoilés et maillés. Chaque appareil doit être équipé d'un coordinateur. Sa fréquence de fonctionnement est de l'ordre de 2,4 GHz et sa vitesse de transmission est de 252 kbps [28].

ZigBee prend en charge un débit de données variable allant de 20 Kbps à 250 Kbps. Il fonctionne sur 16 canaux sur la bande ISM 2.4 GHz (250 Kbps), sur 10 canaux sur les bandes 915 MHz (40 Kbps) et sur un seul canal sur les bandes 868 MHz (20 Kbps). L'inconvénient majeur de ZigBee pour les applications WBAN est dû aux interférences avec la transmission WLAN, en particulier dans la bande 2,4 GHz, où de nombreux systèmes sans fil fonctionnent. Un autre inconvénient est lié à son faible débit de données, ce qui le rend inapproprié pour les applications WBAN en temps réel, en particulier dans les soins de santé.

### 1.5.2 Technologie Bluetooth - IEEE 802.15.1

Bluetooth est un protocole standardisé pour les communications à courte portée, à faible consommation d'énergie et à faible coût, sans nécessiter de câbles encombrants. Le fondement de la technologie Bluetooth est constitué d'ondes radio [28]. Il fonctionne dans la bande de fréquences 2,4 GHz et la plage de fonctionnement typique est de 10 à 100 m ce qui le rend un choix possible pour mettre en œuvre un WBAN, comme le montre la figure 1.10, lorsqu'une minuscule puce Bluetooth est installée dans les systèmes, elle crée un réseau sans fil personnel permettant la communication avec un autre appareil utilisateur à proximité.

La technologie Bluetooth fonctionne comme une topologie en étoile, où un maître et sept esclaves forment le réseau. Cette limitation implique que seulement sept esclaves peuvent être actifs à la fois, ce qui met un seuil sur le nombre maximum de nœuds à utiliser dans le réseau WBAN. De plus Bluetooth consomme beaucoup d'énergie, donc il n'est pas idéal pour les applications WBAN.




*Figure 1.10 – Technologie Bluetooth dans les WBAN.*

### 1.5.3 Technologie ultra-large bande (UWB) - IEEE 802.15.3

La technologie ultra-large bande est une technologie radio qui utilise un très faible niveau d'énergie pour les communications à courte portée et à large bande passant sur une grande partie du spectre radio de 3,1 à 10,6 GHz, ce qui est élevé. Bien que l'UWB soit censé avoir une faible puissance de transmission, sa fréquence de fonctionnement élevée entraîne une consommation d'énergie élevée. En novembre 2007, une équipe de recherche de l'IEEE a commencé à étudier les réseaux de capteurs corporels et a développé la technologie sans fil UWB. Comme le montre la figure 1.11, l'un des avantages de la technologie sans fil UWB réside dans sa portée de transmission de données, comprise entre 20 kbit/s et 850 Mbit/s, et dans sa capacité à observer simultanément de nombreux signaux physiologiques émis en permanence, tels que les ECC/EEG. Bien que cette norme accepte encore des instances pour le développement de réseaux de capteurs corporels, les concepteurs éprouvent des difficultés à concevoir de tels nuds UWB [28].

Cependant, la possibilité d'éviter une consommation d'énergie élevée d'un récepteur UWB est d'utiliser des réseaux à émetteur uniquement pour les réseaux à faible consommation comme le WBAN. Dans ce cas, un seul émetteur est utilisé pour envoyer des données et surveiller les paramètres physiologiques du corps d'un patient.

Un numéro d'identification unique de chaque capteur permet de distinguer chaque patient [33]. Selon [34], l'UWB est un choix intéressant pour plusieurs raisons. Par exemple, pour le suivi WBAN en intérieur, la technologie UWB peut fournir une localisation précise. Elle prend également en compte l'absorption d'énergie par les tissus humains, ce qui lui permet de réguler une faible puissance de transmission.



*Figure 1.11 – Technologie UWB dans les WBAN.*

#### 1.5.4 Wi-Fi IEEE 802.11

Le Wi-Fi est une norme IEEE 802.11 pour les réseaux locaux sans fil (WLAN). En général, la technologie Wi-Fi comporte quatre normes (802.11 a/b/g/n) qui fonctionnent sur les bandes ISM 2,4 et 5 GHz avec une couverture moyenne de 100 m. Le Wi-Fi permet aux utilisateurs de transférer des données à haut débit lorsqu'ils sont connectés à un point d'accès (AP) ou en mode temporaire. Le Wi-Fi est particulièrement adapté au transfert de grandes quantités de données via une connexion sans fil haut débit qui permet la visioconférence, les appels vocaux et le streaming vidéo. Un avantage majeur est que tous les smartphones, tablettes et ordinateurs portables intègrent le Wi-Fi. Cependant, le principal inconvénient de cette technologie est sa forte consommation d'énergie [7].

### 1.5.5 IEEE 802.15.6

La popularité, la demande et l'efficacité des systèmes de surveillance médicale en temps réel révolutionneront les futures technologies médicales. La norme IEEE 802 a créé un groupe de travail, IEEE 802.15.6, afin de normaliser le WBAN. L'objectif de cette norme est de prendre en charge les communications basse consommation pour les nuds corporels afin de transmettre les données physiologiques au point d'accès. Selon cette norme, le WBAN est classé en applications médicales et non médicales. Le groupe de travail IEEE 802.15.6 (WBAN) a défini de nouvelles couches physiques (PHY) et (MAC, Medium Access Control) pour les WBANs. Ces spécifications offrent une communication sans fil à faible complexité, à faible coût, à haute fiabilité, à très faible consommation d'énergie et à courte portée que ce soit à l'intérieur ou autour du corps humain [32].

#### 1.5.5.1 Spécification de la couche PHY

La norme IEEE 802.15.6 prend en charge trois couches PHY : i) la couche Narrowband (NB) PHY, ii) Ultra Wideband (UWB) PHY et iii) Human Body Communications (HBC) PHY. Ces couches physiques peuvent être résumées comme suit [22] :

- Narrowband (NB) PHY : Cette couche est responsable de la transmission/réception des données, de l'activation ou de la désactivation de l'émetteur-récepteur radio et de l'évaluation du bon fonctionnement du canal de communication. Elle prend en charge sept bandes de fréquences avec différents débits de données.
- Ultra Wideband (UWB) PHY : UWB est utilisé pour la communication entre les nœuds d'un même WBAN et pour la communication entre des nœuds placés sur le corps et ceux hors du corps. Cette couche prend en charge deux bandes de fréquences différentes, basse et haute, avec un nombre différent de canaux, tout en ayant la même bande passante. La conception de l'UWB PHY offre une implémentation durable avec une complexité et une consommation d'énergie réduites.
- Human Body Communications (HBC) PHY : HBC prend en charge une seule bande de fréquence basse centrée à 21 MHz, où la transmission de données est effectuée à travers le corps du patient à l'aide de la technologie de communication par champ électrique (Electric Field Communication, EFC) qui couvre la modulation, le préambule/le délimiteur de trame de départ (Start Frame Delimiter, SFD) et la structure des paquets.

Le tableau 1.3 résume les bandes de fréquences et les bandes passantes des canaux pour ces méthodes de propagation [23].

**Tableau 1.3** – Bande de fréquence et bande passante des différentes couches PHY du IEEE 802.15.6

<b>Human-Body Communication</b>		
Fréquence	Bandwidth	
16 MHz	4 MHz	
27 MHz	4 MHz	
<b>Narrowband Communication</b>		
Fréquence	Bandwidth	
402-405 MHz	300 kHz	
420-450 MHz	300 kHz	
863-870 MHz	400 kHz	
902-928 MHz	500 kHz	
956-956 MHz	400 kHz	
2360-2400 MHz	1 MHz	
2400-2438.5 MHz	1 MHz	
<b>UWB Communication</b>		
Fréquence	Bandwidth	
3.2-4.7 GHz	499 MHz	
6.2-10.3 GHz	499 MHz	

### 1.5.5.2 La couche MAC

Le groupe de travail IEEE 802.15.6 a défini une couche MAC au dessus de la couche PHY afin de gérer et contrôler l'accès au canal. Cette couche inclue le traitement de trame, le modèle d'accès, synchronisation d'horloge, gestion d'énergie, etc.

Il est crucial de concevoir des protocoles MAC efficaces en WBAN afin de prolonger la durée de vie du réseau et d'en garantir la fiabilité. Ces réseaux surveillent en permanence le corps humain et doivent envoyer à tout moment des données sensibles et importantes sur le corps humain aux équipes médicales. Cependant, plusieurs facteurs peuvent nuire à leur efficacité, notamment les collisions, les écoutes excessives, la surcharge des paquets de contrôle, les fluctuations de trafic ainsi que la coexistence entre WBAN et les autres systèmes sans fil [3].

## 1.6 Recommandations d'implémentation d'un WBAN

Les recommandations générales de la norme IEEE 802.15.6 sont les suivantes [35] :

- Récupérable en cas de défaillance d'un lien ou d'un nud.
- Capacité à prendre en charge une vaste gamme de débits de données allant de quelques dizaines de Kbps à environ 10 Mbps afin de répondre à toutes les applications potentielles.
- Mécanismes de consommation d'énergie efficaces qui permettent à la source d'énergie de durer plusieurs années.
- Assure une communication fiable avec des valeurs de gigue et de latence acceptables pour les applications médicales et non médicales.
- Supporte la coexistence de nuds de capteurs à l'intérieur et à l'extérieur du corps.
- Capacité à prendre en charge les mécanismes d'authentification, de cryptage et de sécurité de l'intégrité.
- Capacité à gérer l'ajout et le retrait de nuds dans un délai relativement court.
- Fonctionnement dans un environnement sans fil hétérogène.
- Conforme aux réglementations relatives au débit d'absorption spécifique (Specific Absorption Rate SAR).
- Prend en charge l'évolutivité jusqu'à 64 nuds [22].

## 1.7 Défis et problèmes des WBANs

Le WBAN est une technologie émergente qui hérite des défis et des problèmes des WSN lors de sa mise en application, en plus de contraintes plus spécifiques en raison de leur placement à l'intérieur et autour du corps humain. Dans la conception des réseaux WBAN, ces exigences nous imposent de donner la priorité à la santé du corps observé. Dans ce qui suit, les principaux défis des WBAN sont décrits de manière concise [36].

### 1.7.1 Topologie du réseau

La topologie du réseau décrit la manière dont les différents nuds communiquent entre eux. Il existe deux types principaux de topologie en fonction du nombre de sauts que les paquets doivent effectuer de la source à la destination : la topologie à saut unique (single-hop) et la topologie à sauts multiples (multi-hop). Dans la topologie à saut unique, chaque nud communique directement avec le nud de destination, tandis que dans la topologie à sauts multiples, les données transmises par les nuds sources

passent par un ou plusieurs nuds intermédiaires avant d'atteindre le nud de destination. Les études menées dans ce domaine montrent que la topologie multi-sauts est plus fiable en termes de nombre de paquets livrés à la destination que la topologie à saut unique [37]. En outre, les communications multi-sauts sont beaucoup plus résistantes aux changements fréquents de la topologie du réseau dus aux mouvements du corps humain et aux transmissions des nuds à courte portée.

### 1.7.2 Efficacité énergétique

Les WBAN sont composés de nuds de capteurs sans fil miniatures implantés à l'intérieur du corps humain, ce qui rend presque impossible le remplacement de leurs batteries. Dans un réseau sans fil, les communications sans fil consomment plus d'énergie que les opérations de capture et de traitement [36].

### 1.7.3 Environnement hétérogène

L'objectif des WBAN est de capturer et de surveiller les différents signes vitaux du corps humain. Selon la nature des paramètres à observer, plusieurs types de nuds sont utilisés. Les nuds peuvent se distinguer en termes de ressources informatiques, de capacité de stockage ou de consommation d'énergie [36]. La nature hétérogène des nuds pose d'autres problèmes.

### 1.7.4 Effets biologique

L'une des caractéristiques les plus remarquables des WBAN est que les nuds sont implantés à l'intérieur ou autour du corps humain. Cela nous oblige à prendre en compte les effets indésirables de ces réseaux sur la santé humaine. L'étude menée en [38] montre que la transmission et la réception de données sont les deux tâches distinctes qui provoquent le plus de chaleur à proximité d'un nud. Les tissus humains absorbent l'énergie du rayonnement et la convertissent en chaleur, ce qui entraîne une augmentation de la température. L'absorption du rayonnement est acceptable pour le corps humain tant qu'elle ne dépasse pas un seuil bien défini. Le paramètre le plus utilisé par les normes internationales relatives à la sécurité électromagnétique du corps humain est le Specific Absorption Rate (SAR). La norme IEEE recommande une valeur moyenne de 1,6 W/kg par gramme de tissu comme valeur SAR acceptable. Cette valeur est également adoptée par la FCC (Federal Communications Commission) [38]. Les effets des WBANs sur le corps humain peuvent être réduits en modifiant la conception des nuds et de leurs antennes, d'une part, et en adaptant la conception des protocoles de routage, d'autre part, afin d'obtenir un SAR sans danger.

### 1.7.5 QoS in WBAN

Dans de nombreuses applications WBAN, la qualité de service doit être prise en compte, car elles traitent les signes vitaux critiques du corps humain. Le trafic peut être classé en plusieurs catégories (données critiques, données ordinaires, etc.) en fonction du contexte de l'application et de la qualité de service requise. L'une des mesures de qualité de service les plus importantes dans les WBAN est la latence, qui est un paramètre critique [39]. En effet, dans certaines applications WBAN, le paquet doit être acheminé du nud source au nud de destination dans un temps limité, faute de quoi il devient inutile et obsolète.

## 1.8 Conclusion

Dans ce chapitre, nous avons présenté une vue d'ensemble des WBANs, de leur architecture et de leurs applications. Nous avons cité les technologies sans fil utilisées pour les communications dans ces réseaux, telles que IEEE 802.15.1, IEEE 802.15.4 et IEEE 802.15.6. Ensuite, nous avons présenté les principaux défis et problèmes liés aux WBAN, car ils ont des contraintes plus spécifiques en raison de leur placement dans et autour du corps humain.

# Introduction au Machine Learning et ses Algorithmes

## Sommaire

---

<b>2.1</b>	<b>Introduction au Machine Learning . . . . .</b>	<b>33</b>
<b>2.2</b>	<b>Types de Machine Learning . . . . .</b>	<b>34</b>
2.2.1	Apprentissage supervisé . . . . .	34
2.2.2	Apprentissage non supervisé . . . . .	35
2.2.3	Apprentissage semi-supervisé . . . . .	35
2.2.4	Apprentissage par renforcement . . . . .	36
<b>2.3</b>	<b>Algorithmes de l'apprentissage supervisé . . . . .</b>	<b>37</b>
2.3.1	Régression Linéaire . . . . .	37
2.3.2	Régression Logistique . . . . .	39
2.3.3	k-Nearest Neighbors (k-NN) . . . . .	40
2.3.4	Support Vector Machines (SVM) . . . . .	42
2.3.5	Arbres de Décision . . . . .	44
2.3.6	Random Forest . . . . .	45
2.3.7	Réseaux de Neurones Artificiels (ANN) . . . . .	47
<b>2.4</b>	<b>Algorithmes d'apprentissage non supervisé . . . . .</b>	<b>48</b>
2.4.1	k-Means . . . . .	48
2.4.2	PCA (Principal Component Analysis) . . . . .	49
<b>2.5</b>	<b>Algorithmes d'apprentissage par renforcement . . . . .</b>	<b>50</b>
2.5.1	Q-Learning . . . . .	50
<b>2.6</b>	<b>Conclusion . . . . .</b>	<b>51</b>

---

## 2.1 Introduction au Machine Learning

Le Machine Learning (apprentissage automatique) constitue aujourd'hui l'un des piliers essentiels de l'intelligence artificielle (IA) [40]. Il regroupe un ensemble de méthodes et d'algorithmes permettant aux systèmes informatiques d'acquérir de la

connaissance et de s'améliorer de manière autonome à partir de l'analyse de données, sans qu'une programmation explicite de l'ensemble des règles de décision ne soit nécessaire. Contrairement aux approches algorithmiques traditionnelles où les instructions sont définies à l'avance par le programmeur, le Machine Learning permet au système d'adapter son comportement en fonction des données qu'il observe et traite.

Ce paradigme repose sur la capacité des algorithmes à identifier des motifs sous-jacents, des relations statistiques ou des structures cachées dans les ensembles de données, même complexes et de grande dimension. Une fois ces régularités découvertes, le système est alors en mesure de réaliser des prédictions, de classer de nouvelles observations, de prendre des décisions optimisées, ou encore de formuler des recommandations dans des contextes variés. Cette faculté d'apprentissage évolutif confère au Machine Learning un large éventail d'applications allant de la reconnaissance d'images, du traitement du langage naturel, jusqu'à l'optimisation de systèmes complexes, le diagnostic médical assisté, ou encore la détection d'intrusions en cybersécurité [41–43].

## 2.2 Types de Machine Learning

### 2.2.1 Apprentissage supervisé

L'apprentissage supervisé constitue l'une des approches fondamentales du Machine Learning. Il repose sur l'utilisation d'un ensemble de données préalablement étiquetées, c'est-à-dire pour lesquelles les résultats ou classes attendues sont connus. Chaque observation de l'ensemble d'entraînement est constituée d'une paire formée de variables d'entrée (caractéristiques ou features) et de la sortie associée (étiquette ou label). Le modèle apprend ainsi à établir une relation fonctionnelle entre les variables explicatives et la variable cible à prédire [44].

Durant la phase d'apprentissage, l'algorithme ajuste ses paramètres internes en minimisant une fonction de coût qui mesure l'écart entre les prédictions du modèle et les sorties réelles des données d'entraînement. Une fois entraîné, le modèle est en mesure de généraliser ses connaissances afin de réaliser des prédictions ou classifications sur de nouvelles données inconnues.

L'apprentissage supervisé est particulièrement adapté aux tâches de classification (assignation à une catégorie) et de régression (prédiction d'une valeur continue). Parmi les principaux algorithmes représentatifs de cette approche, on distingue :

- Régression Linéaire [45]
- Régression Logistique [46, 47]
- k-Nearest Neighbors (k-NN) [48, 49]
- Support Vector Machines (SVM) [50, 51]
- Arbres de Décision [52, 53]
- Forêts Aléatoires (Random Forest) [54, 55]

- Réseaux de Neurones Artificiels (ANN) [56, 57]

Cette diversité d'algorithmes permet à l'apprentissage supervisé de s'adapter à un large éventail de domaines d'application, allant du diagnostic médical à la reconnaissance faciale, en passant par la prévision financière ou la détection de fraudes.

### 2.2.2 Apprentissage non supervisé

L'apprentissage non supervisé intervient lorsque l'ensemble des données ne comporte pas d'étiquettes associées aux observations, c'est-à-dire lorsque les sorties attendues ne sont pas connues au préalable [58, 59]. L'objectif de cette approche est alors d'explorer la structure intrinsèque des données afin d'y détecter des regroupements naturels, des schémas latents ou des relations sous-jacentes.

Dans ce cadre, les algorithmes d'apprentissage non supervisé visent principalement deux grandes familles de tâches :

Le clustering (regroupement), qui consiste à partitionner l'ensemble des observations en sous-groupes homogènes partageant des caractéristiques communes, sans connaissance préalable des catégories.

La réduction de dimensionnalité, qui permet de simplifier la représentation des données tout en conservant l'essentiel de l'information, facilitant ainsi la visualisation, l'interprétation ou la modélisation ultérieure.

Parmi les algorithmes emblématiques de l'apprentissage non supervisé, on distingue notamment :

- k-Means [60, 61]
- Hierarchical Clustering [62, 63]
- DBSCAN [64]
- Algorithmes de réduction de dimension (PCA, t-SNE) [65, 66]

L'apprentissage non supervisé est largement utilisé dans des domaines variés tels que la segmentation de clientèle, l'analyse exploratoire de données, la bioinformatique, ou encore la détection d'anomalies.

### 2.2.3 Apprentissage semi-supervisé

L'apprentissage semi-supervisé constitue une approche hybride combinant les principes de l'apprentissage supervisé et non supervisé. Il est particulièrement pertinent dans les situations où l'acquisition de données étiquetées est coûteuse, chronophage ou techniquement difficile, tandis qu'un grand volume de données non étiquetées est aisément disponible. En effet, dans de nombreux domaines tels que la médecine, la reconnaissance d'images ou le traitement automatique du langage, l'annotation manuelle des données requiert l'intervention d'experts et engendre des ressources importantes.

L'apprentissage semi-supervisé vise ainsi à exploiter pleinement l'information contenue dans les données non étiquetées afin de renforcer le processus d'apprentissage supervisé à partir d'un nombre limité d'exemples annotés [67, 68].

Dans ce cadre, le modèle est d'abord initialisé à partir des données étiquetées, puis il est progressivement affiné en tirant parti de la structure statistique présente dans l'ensemble plus large des données non étiquetées. Cette approche permet de généraliser les connaissances du modèle et de limiter le risque de surapprentissage dû à la faiblesse de l'échantillon supervisé. Différentes techniques sont utilisées pour intégrer l'information non étiquetée, parmi lesquelles on peut citer : l'auto-apprentissage (self-training), le co-apprentissage (co-training), les méthodes basées sur les graphes, les modèles génératifs, ainsi que les méthodes d'entropie minimale ou de régularisation par cohérence.

Par exemple, dans l'auto-apprentissage, le modèle utilise ses propres prédictions les plus confiantes sur les données non étiquetées comme pseudo-étiquettes pour continuer l'entraînement. Le co-apprentissage, quant à lui, exploite plusieurs classificateurs distincts s'entraînant mutuellement à partir de leurs prédictions croisées. Les approches à base de graphes cherchent à exploiter la proximité des instances dans un espace de similarité afin de propager l'information des étiquettes aux exemples voisins. Plus récemment, les architectures de deep learning ont intégré avec succès le semi-supervisé à travers des techniques avancées telles que les Generative Adversarial Networks (GANs) semi-supervisés ou encore les approches basées sur le consistency training.

L'apprentissage semi-supervisé s'est révélé particulièrement efficace dans des contextes réels où la labellisation complète des données est impraticable, permettant d'améliorer significativement les performances des modèles tout en réduisant les coûts liés à l'annotation.

## 2.2.4 Apprentissage par renforcement

L'apprentissage par renforcement constitue une branche spécifique et particulièrement dynamique du Machine Learning, inspirée des mécanismes d'apprentissage observés chez les êtres vivants. Contrairement aux approches supervisées et non supervisées, l'apprentissage par renforcement repose sur l'interaction d'un agent autonome avec un environnement dynamique. L'objectif de l'agent est d'apprendre à prendre des décisions optimales en maximisant une fonction de récompense cumulative sur le long terme. À chaque étape, l'agent observe l'état actuel de l'environnement, effectue une action, reçoit une récompense (ou une pénalité) associée à cette action, et observe le nouvel état résultant. Ce processus d'apprentissage repose sur l'exploration de l'espace des actions et l'exploitation des connaissances acquises afin de développer progressivement une stratégie ou politique de décision optimale [69].

Formellement, l'apprentissage par renforcement est souvent modélisé à travers le

cadre des processus de décision markoviens (Markov Decision Processes, MDP [70]), où l'objectif est de déterminer une politique  $\pi(s)$  qui maximise la valeur de retour espéré. Plusieurs algorithmes ont été développés pour résoudre ces problèmes, parmi lesquels on distingue les méthodes basées sur la fonction de valeur, telles que le Q-Learning, qui estime la valeur espérée de chaque couple état-action, ainsi que les méthodes d'approximation par réseaux de neurones profonds, comme les Deep Q-Networks (DQN). D'autres approches, telles que les méthodes d'acteur-critique et les policy gradients, apprennent directement la politique optimale en maximisant la récompense attendue via l'optimisation de gradients stochastiques.

L'apprentissage par renforcement présente l'avantage de pouvoir s'adapter à des environnements partiellement observables, évolutifs et stochastiques. Il est particulièrement adapté aux problèmes séquentiels complexes où l'évaluation immédiate de la qualité d'une action n'est pas toujours possible, mais où son impact doit être considéré sur plusieurs étapes futures. Ses domaines d'application sont vastes et variés, allant du contrôle de robots autonomes, de la gestion des ressources dans les réseaux de communication, de la planification de trajectoires, jusqu'au développement de systèmes de jeux stratégiques comme les célèbres succès d'AlphaGo et AlphaZero. Toutefois, l'apprentissage par renforcement soulève également des défis importants, notamment en matière de stabilité d'apprentissage, de compromis exploration-exploitation, ainsi que de coûts computationnels liés à l'entraînement dans des environnements simulés ou réels.

Parmi les algorithmes par renforcement, on cite :

- Q-Learning [71]
- Deep Q-Networks (DQN) [72]
- SARSA [73]
- Policy Gradient Methods [74]
- Actor-Critic Methods [75]

## 2.3 Algorithmes de l'apprentissage supervisé

### 2.3.1 Régression Linéaire

La régression linéaire représente l'une des méthodes les plus anciennes et fondamentales en apprentissage supervisé, largement utilisée pour modéliser les relations existant entre une variable dépendante continue et une ou plusieurs variables explicatives. Son principe repose sur l'hypothèse qu'il existe une dépendance linéaire entre la variable cible et les prédicteurs, de sorte que les variations de la cible peuvent être expliquées par une combinaison linéaire des variables d'entrée. La forme générale du modèle s'exprime par l'équation  $y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_px_p + \epsilon$ , où les  $\beta_i$  sont

les coefficients à estimer et  $\epsilon$  représente le terme d'erreur aléatoire, supposé suivre une distribution normale centrée réduite [45].

L'apprentissage du modèle consiste à déterminer les valeurs optimales des coefficients  $\beta_i$  de manière à minimiser l'écart entre les valeurs observées et les prédictions fournies par le modèle. Cette estimation est généralement réalisée par la méthode des moindres carrés ordinaires (Ordinary Least Squares, OLS), qui vise à minimiser la somme des carrés des résidus. Les coefficients ainsi obtenus permettent d'obtenir une fonction de prédiction capable de fournir des estimations continues sur de nouvelles observations.

La régression linéaire repose cependant sur plusieurs hypothèses importantes qui conditionnent la validité de ses résultats, notamment la linéarité de la relation entre variables, l'indépendance des résidus, l'homoscédasticité (variance constante des erreurs), et la normalité des erreurs. Lorsque ces hypothèses sont respectées, la régression linéaire fournit des prédictions fiables et des interprétations robustes des relations entre variables. Elle offre également une grande transparence sur l'influence relative de chaque variable grâce aux coefficients estimés.

L'évaluation de la performance du modèle s'appuie généralement sur des indicateurs tels que l'erreur quadratique moyenne (MSE), l'erreur absolue moyenne (MAE), ainsi que le coefficient de détermination  $R^2$ , qui mesure la proportion de variance expliquée par le modèle.


Bien que la régression linéaire soit simple à mettre en œuvre et facile à interpréter, elle présente certaines limitations. Elle est notamment inadaptée pour modéliser des relations non linéaires sans transformation préalable des variables, et reste sensible aux valeurs aberrantes qui peuvent influencer fortement l'ajustement des coefficients. Afin de pallier ces limites, plusieurs extensions de la régression linéaire ont été développées, telles que la régression polynomiale pour modéliser des relations non linéaires, ainsi que des variantes régularisées comme la régression ridge (L2) et la régression lasso (L1) qui permettent de limiter le surapprentissage et de réaliser une sélection automatique des variables pertinentes.

La régression linéaire constitue ainsi un outil de base incontournable en analyse de données et en modélisation statistique, souvent utilisé comme première approche exploratoire avant l'application de modèles plus complexes lorsque la structure des données le exige.

Modèle qui établit une relation linéaire entre une variable dépendante et une ou plusieurs variables indépendantes.

$$y = \beta_0 + \beta_1 x + \epsilon \tag{2.1}$$

La figure 2.1 montre le principe de la régression linéaire.



*Figure 2.1 – Régression linéaire.*

### 2.3.2 Régression Logistique

La régression logistique constitue un modèle fondamental de classification supervisée, principalement utilisé pour traiter les problèmes où la variable cible est qualitative, c'est-à-dire lorsque l'objectif est de prédire l'appartenance d'une observation à une ou plusieurs classes discrètes [46, 47]. Contrairement à la régression linéaire qui vise à estimer une variable continue, la régression logistique prédit une probabilité d'appartenance à une classe donnée en modélisant directement la fonction de probabilité conditionnelle. Le modèle repose sur la fonction sigmoïde (ou logistique), qui transforme une combinaison linéaire des variables explicatives en une probabilité bornée entre 0 et 1. La fonction de prédiction se exprime ainsi sous la forme :

$$P(y = 1|x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)}} \quad (2.2)$$

où les  $\beta_i$  représentent les coefficients du modèle à estimer.

L'apprentissage du modèle vise à déterminer ces coefficients en maximisant la vraisemblance des observations, plutôt qu'en minimisant une erreur quadratique comme en régression linéaire. Cette estimation repose sur la méthode de maximisation de la vraisemblance (Maximum Likelihood Estimation, MLE), qui permet d'identifier les paramètres rendant les données observées les plus probables sous le modèle. Ainsi, la régression logistique fournit une probabilité d'appartenance à chaque classe, permettant ensuite de définir une règle de décision en fixant un seuil (généralement 0.5) pour l'affectation des classes.


La régression logistique présente plusieurs avantages notables : sa simplicité d'interprétation grâce aux coefficients qui peuvent être directement interprétés en termes de *odds ratio*, sa robustesse à des distributions non normales des variables explicatives, ainsi que sa capacité à gérer efficacement les relations non parfaitement linéaires entre

les variables et la probabilité cible. Toutefois, elle repose sur l'hypothèse que la relation entre les variables explicatives et le logarithme du rapport des probabilités (log-odds) est linéaire, et qu'il n'existe pas de multicolinéarité importante entre les variables.

Outre la classification binaire classique, la régression logistique a été généralisée à des contextes multiclassse via la régression logistique multinomiale (ou softmax regression), et à des problèmes de classification multiple via la régression logistique ordinale. Son application est extrêmement répandue dans de nombreux domaines, notamment en médecine (diagnostic de maladies), en finance (évaluation du risque de défaut), en marketing (modélisation de la fidélité des clients), et dans les systèmes de détection d'intrusions et de filtrage de courriers indésirables.

Enfin, bien qu'elle constitue un modèle simple comparé aux méthodes modernes de machine learning, la régression logistique demeure souvent utilisée comme modèle de référence en raison de sa robustesse, de sa transparence et de sa facilité de mise en œuvre sur des jeux de données de taille modérée.

La figure 2.2 montre le principe de la régression logistique.



*Figure 2.2 – Régression logistique.*

### 2.3.3 k-Nearest Neighbors (k-NN)

L'algorithme des k plus proches voisins (k-Nearest Neighbors, k-NN) est une méthode d'apprentissage supervisé à la fois simple et efficace, applicable aussi bien aux problèmes de classification qu'à ceux de régression [48, 49]. Contrairement à de nombreux algorithmes qui reposent sur un modèle explicite construit à partir des données d'entraînement, k-NN est un algorithme non paramétrique et paresseux (lazy learner), car il ne réalise aucun apprentissage proprement dit lors de la phase d'entraînement. Au lieu de cela, l'ensemble des observations d'apprentissage est simplement stocké, et l'ensemble des calculs de prédiction est effectué au moment de la classification ou de la régression d'une nouvelle instance.

Le principe fondamental de k-NN repose sur l'idée que des observations similaires dans l'espace des caractéristiques ont de fortes chances de partager la même étiquette de sortie. Lorsqu'un nouvel échantillon doit être prédit, l'algorithme identifie les  $k$  instances d'entraînement les plus proches de cet échantillon selon une métrique de

distance spécifiée, généralement la distance euclidienne. La prédiction est ensuite effectuée à partir des étiquettes de ces voisins proches :

- En classification, l'étiquette majoritaire parmi les  $k$  voisins détermine la classe prédite (vote majoritaire).
- En régression, la valeur prédite est généralement la moyenne (ou parfois la médiane) des valeurs cibles des  $k$  voisins.

La valeur de  $k$  constitue un hyperparamètre crucial du modèle. Un choix trop faible (par exemple  $k = 1$ ) rend le modèle très sensible au bruit et aux valeurs aberrantes, menant à un surapprentissage (overfitting). À l'inverse, un  $k$  trop grand peut lisser excessivement les frontières de décision et engendrer un sous-apprentissage (underfitting). Le choix optimal de  $k$  est souvent déterminé empiriquement via validation croisée.

En termes de distance, si la distance euclidienne est la plus couramment utilisée, d'autres métriques peuvent être appliquées en fonction de la nature des données : distance de Manhattan, distance de Minkowski, distance de Mahalanobis, etc. Il est également important de normaliser ou standardiser les variables continues avant l'application de k-NN, afin d'éviter qu'une variable à forte amplitude ne crase l'influence des autres.

L'un des avantages majeurs de k-NN réside dans sa simplicité d'implémentation et son absence d'hypothèses fortes sur la distribution des données. De plus, il est naturellement adapté aux frontières de décision non linéaires complexes. En contrepartie, ses performances se dégradent rapidement en présence de données de très haute dimension en raison de la malédiction de la dimensionnalité (curse of dimensionality), qui rend la notion de voisinage de moins en moins pertinente.

Enfin, le coût computationnel de k-NN augmente significativement avec la taille du jeu de données, puisque chaque prédiction implique de parcourir l'ensemble des observations d'apprentissage. Pour des bases volumineuses, des techniques d'optimisation telles que les structures de recherche spatiale (arbres kd, ball trees) ou les méthodes approximatives peuvent être utilisées pour accélérer la recherche des voisins.

L'algorithme k-NN trouve de nombreuses applications dans divers domaines : reconnaissance de formes, systèmes de recommandation, détection d'anomalies, diagnostic médical, classification d'images ou de textes, entre autres.

La figure 2.3 montre le principe de l'algorithme KNN.




Figure 2.3 – Algorithm K-NN.

### 2.3.4 Support Vector Machines (SVM)

Les Support Vector Machines (SVM) représentent une classe d'algorithmes puissants et largement utilisés en apprentissage supervisé, principalement pour les tâches de classification binaire, bien qu'ils puissent également être adaptés aux problèmes de classification multiclassés et de régression [50, 51]. Le principe fondamental de SVM repose sur la recherche de l'hyperplan de séparation optimal qui maximise la marge entre les différentes classes dans l'espace des caractéristiques. Cette marge correspond à la distance entre l'hyperplan et les observations les plus proches appartenant à chaque classe, appelées vecteurs de support.

Dans le cas linéairement séparable, la recherche de l'hyperplan optimal se exprime sous la forme d'un problème d'optimisation quadratique visant à maximiser la marge tout en respectant les contraintes de séparation :

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad \text{tel que} \quad y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \quad \forall i \quad (2.3)$$

où :

$\mathbf{w}$  est le vecteur des poids,

$b$  est le biais,

$(\mathbf{x}_i, y_i)$  représentent les observations d'entraînement et leurs étiquettes.

Cependant, la plupart des problèmes de classification réels ne sont pas parfaitement séparables. Afin de gérer les données bruitées ou partiellement chevauchantes, les SVM introduisent la notion de marge souple (soft margin), en autorisant certaines violations de la séparation à travers l'introduction de variables d'écart  $\xi_i$ , pondérées par un paramètre de régularisation  $C$  qui contrôle le compromis entre maximisation de la marge et minimisation des erreurs de classification.

L'une des forces majeures des SVM réside dans leur capacité à traiter des problèmes non linéaires grâce à l'utilisation de la technique dite du noyau (kernel trick).

En projetant les données d'origine dans un espace de caractéristiques de dimension potentiellement infinie via une fonction noyau  $K(\mathbf{x}_i, \mathbf{x}_j)$ , les SVM peuvent trouver des frontières de décision non linéaires tout en conservant une complexité computationnelle raisonnable. Parmi les noyaux couramment utilisés, on distingue :


- Le noyau linéaire :  $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^\top \mathbf{x}_j$
- Le noyau polynomiale :  $K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^\top \mathbf{x}_j + c)^d$
- Le noyau gaussien RBF :  $K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma|\mathbf{x}_i - \mathbf{x}_j|^2)$
- Le noyau sigmoïde :  $K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\alpha \mathbf{x}_i^\top \mathbf{x}_j + c)$

Les hyperparamètres essentiels des SVM incluent le paramètre  $C$ , qui contrôle la pénalisation des erreurs de classification, et les paramètres du noyau (par exemple  $\gamma$  pour le noyau RBF), qui influencent la flexibilité de la frontière de décision.

Parmi les principaux avantages des SVM, on peut citer leur robustesse aux hautes dimensions, leur capacité à modéliser des frontières complexes avec relativement peu de données d'entraînement (grâce à l'exploitation des vecteurs de support uniquement), ainsi que leur bonne généralisation lorsque les hyperparamètres sont correctement choisis. En revanche, les SVM peuvent devenir coûteux en termes de temps de calcul sur des jeux de données très volumineux, et leur interprétation peut être moins intuitive que celle des modèles linéaires classiques.

Les SVM ont été appliqués avec succès dans de nombreux domaines tels que la reconnaissance de caractères, la bioinformatique (classification de gènes, détection de maladies), la détection d'intrusions, la reconnaissance faciale et le traitement du langage naturel.

La figure 2.4 montre le principe de l'algorithme "Support Vector Machine".



**Figure 2.4** – Algorithme SVM.

### 2.3.5 Arbres de Décision

Les arbres de décision constituent une méthode d'apprentissage supervisé à la fois intuitive, interprétable et flexible, utilisée aussi bien pour la classification que pour la régression [52, 53]. Leur principe repose sur la modélisation du processus de décision sous la forme d'une structure arborescente hiérarchique, dans laquelle chaque nœud interne représente un test sur une variable d'entrée, chaque branche correspond à un résultat possible de ce test, et chaque feuille assigne une prédiction de classe ou de valeur.

Le processus de construction d'un arbre consiste à partitionner récursivement l'espace des caractéristiques en sous-espaces homogènes selon un critère d'impureté. À chaque étape, l'algorithme sélectionne la variable et le seuil de coupure optimaux qui maximisent la séparation des données, c'est-à-dire qui produisent des sous-groupes aussi purs que possible. Plusieurs critères d'impureté sont utilisés pour mesurer la qualité des divisions :

- Indice de Gini (classification) :

$$G = 1 - \sum_{i=1}^C p_i^2 \quad (2.4)$$

où  $p_i$  est la proportion d'observations de la classe  $i$  dans un nœud.

- Entropie de Shannon (classification) :

$$H = - \sum_{i=1}^C p_i \log_2 p_i \quad (2.5)$$

- Variance (régression) :

$$\text{Var}(y) = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \quad (2.6)$$

La croissance de l'arbre se poursuit jusqu'à atteindre un critère d'arrêt défini : profondeur maximale, nombre minimal d'échantillons par feuille, ou absence de gain significatif d'impureté. Toutefois, un arbre construit sans contrainte a tendance à surajuster les données entraînant (overfitting), en apprenant des partitions trop spécifiques aux observations présentes. Pour limiter ce phénomène, des techniques de pruning (élagage) peuvent être utilisées afin de simplifier l'arbre a posteriori et améliorer sa capacité de généralisation.

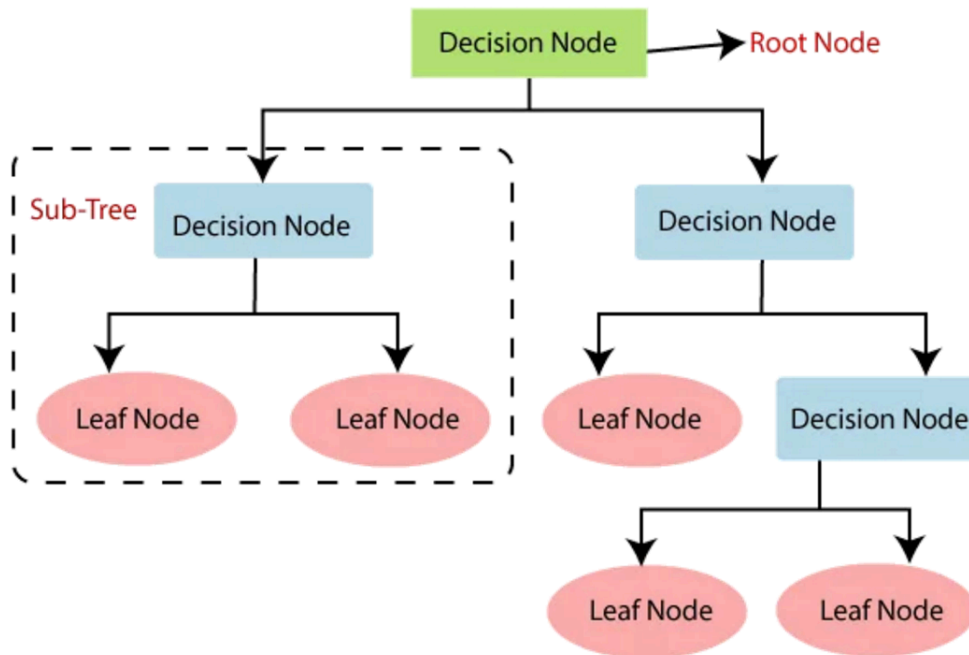
Les arbres de décision présentent plusieurs avantages notables : ils sont capables de gérer des variables qualitatives et quantitatives, peuvent modéliser des interactions complexes entre variables, et fournissent une représentation visuelle directe facilitant l'interprétation des règles de décision extraites. De plus, ils ne nécessitent pas de mise à l'échelle préalable des variables et sont robustes aux valeurs manquantes.

Cependant, les arbres isolés présentent certaines limitations. Ils sont souvent instables (sensibles aux variations des données entraînant) et peuvent manquer de

robustesse sur des jeux de données complexes ou de grande dimension. Ces limitations ont conduit au développement de méthodes d'agrégation d'arbres, telles que les forêts aléatoires et le boosting, qui améliorent substantiellement les performances en combinant plusieurs arbres de décision de manière collaborative.

Les arbres de décision sont utilisés dans de nombreux domaines d'application : analyse de risque, médecine, finance, diagnostic de panne, bioinformatique, et bien d'autres domaines nécessitant des systèmes décisionnels explicables.

La figure 2.5 montre le principe de l'algorithme "Decision Tree".



*Figure 2.5 – Les arbres de décision.*

### 2.3.6 Random Forest

Les forêts aléatoires (Random Forest) constituent une extension robuste et performante des arbres de décision traditionnels, reposant sur le principe de l'agrégation d'un grand nombre de modèles faibles (arbres de décision) afin de constituer un modèle global plus stable et précis. Cette approche s'inscrit dans la famille des méthodes dites d'ensemble (ensemble methods), dont l'objectif est de réduire la variance et le risque de surapprentissage inhérents aux arbres de décision isolés [54, 55].

Le fonctionnement de Random Forest repose sur deux mécanismes fondamentaux de diversification des arbres entraînés :

- **Le bootstrap (bagging)** Chaque arbre est entraîné sur un sous-échantillon aléatoire du jeu de données initial, obtenu par tirage aléatoire avec remise. Cette technique permet d'introduire une variabilité entre les arbres en leur présentant des sous-ensembles différents de données d'apprentissage.

- **La sélection aléatoire de caractéristiques (feature randomness)** Lors de la construction de chaque arbre, à chaque nud de décision, un sous-ensemble aléatoire de variables explicatives est sélectionné, parmi lesquelles la meilleure variable de séparation est choisie selon un critère d'impureté (Gini, entropie, variance). Ce mécanisme empêche les arbres de se ressembler trop fortement et favorise la diversité des partitions apprises.

Une fois la forêt constituée, la prédiction finale est obtenue par agrégation des prédictions individuelles des arbres :

En classification, par un vote majoritaire sur les classes prédites par chaque arbre.

En régression, par la moyenne des valeurs prédites.


L'introduction de cette double aléatorisation permet à Random Forest de réduire significativement la variance globale du modèle sans pour autant augmenter le biais, tout en le rendant beaucoup plus robuste face au surapprentissage. De plus, Random Forest conserve la capacité des arbres de décision à gérer des données mixtes (numériques et catégorielles), à modéliser des interactions complexes, et à s'adapter à des distributions de données non linéaires et bruitées.

Un autre atout majeur de Random Forest réside dans sa capacité à fournir des mesures d'importance des variables (feature importance), permettant d'identifier les caractéristiques les plus discriminantes dans la prédiction.

Cependant, malgré ses nombreux avantages, Random Forest présente certaines limitations : son interprétabilité est réduite par rapport aux arbres simples, et son coût computationnel devient important lorsque le nombre d'arbres ou la taille des données est très élevé.

Grâce à sa robustesse et ses excellentes performances sur un large éventail de jeux de données, Random Forest est devenu l'un des algorithmes de référence en machine learning supervisé, avec des applications variées dans des domaines tels que la bioinformatique, la finance, la médecine, la détection de fraudes, la reconnaissance de formes, et la cybersécurité.

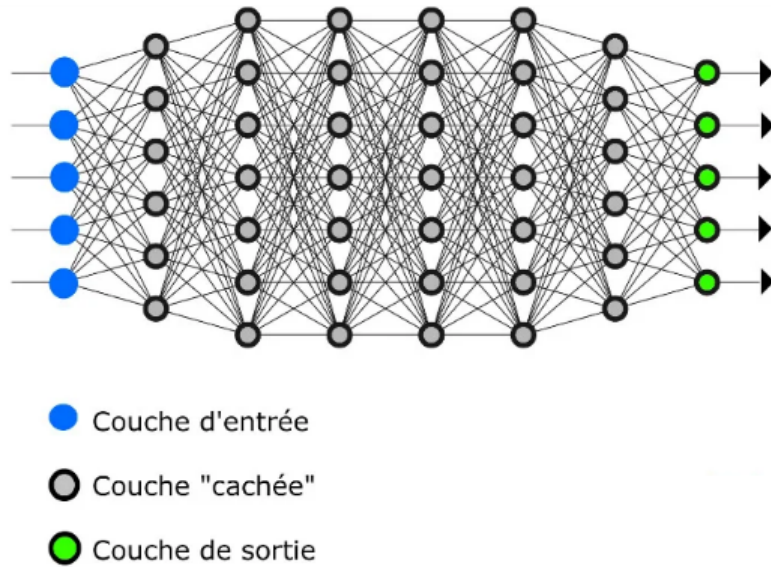
La figure 2.6 montre le principe de l'algorithme Random Forest.



*Figure 2.6 – Random Forest.*

### 2.3.7 Réseaux de Neurones Artificiels (ANN)

Les réseaux de neurones artificiels (RNA) constituent une classe de modèles d'apprentissage automatique inspirés du fonctionnement du cerveau humain [56,57]. Leur architecture repose sur l'interconnexion de nombreuses unités de calcul appelées neurones artificiels, organisées en couches successives (voir Figure 2.7) : la couche d'entrée, une ou plusieurs couches cachées et la couche de sortie. Chaque neurone effectue une opération de pondération sur les signaux reçus, applique une fonction d'activation non linéaire, et transmet le résultat aux neurones des couches suivantes. Cette organisation permet aux réseaux de neurones de modéliser des relations complexes et non linéaires entre les variables d'entrée et de sortie, rendant ces modèles particulièrement efficaces pour des tâches telles que la classification, la régression, la reconnaissance de formes, la détection d'anomalies et le traitement du langage naturel. L'apprentissage des réseaux de neurones repose généralement sur l'algorithme de rétropropagation de l'erreur, qui ajuste itérativement les poids des connexions à l'aide de méthodes d'optimisation, le plus souvent la descente de gradient et ses variantes. L'émergence des architectures profondes, appelées deep neural networks (DNN), qui comportent un grand nombre de couches cachées, a considérablement élargi les capacités des réseaux de neurones dans des domaines variés comme la vision par ordinateur, la traduction automatique et la conduite autonome. Toutefois, ces modèles présentent également certaines limites, notamment une forte dépendance à la quantité et à la qualité des données d'entraînement, une complexité computationnelle élevée et un risque de surapprentissage, nécessitant la mise en œuvre de techniques de régularisation, de normalisation et de validation croisée pour assurer leur robustesse et leur capacité de généralisation. De nombreux travaux de recherche continuent d'enrichir ce domaine en proposant des variantes d'architectures, telles que les réseaux convolutifs (CNN), les réseaux récurrents (RNN), les transformateurs, et en intégrant des mécanismes d'attention pour améliorer la performance et l'interprétabilité des modèles.



*Figure 2.7 – Réseau de neurones artificiels.*


## 2.4 Algorithmes d'apprentissage non supervisé

### 2.4.1 k-Means

L'algorithme K-Means constitue l'une des méthodes de classification non supervisée les plus largement utilisées pour le partitionnement des données en groupes homogènes [60,61]. Son principe repose sur la minimisation de la variance intra-cluster, en cherchant à regrouper les observations autour de centres de gravité appelés centroïdes. L'algorithme commence par initialiser aléatoirement  $K$  centroïdes, où  $K$  représente le nombre de clusters défini à l'avance par l'utilisateur. À chaque itération, chaque donnée est affectée au centroïde le plus proche selon une mesure de distance, généralement la distance euclidienne. Ensuite, les centroïdes sont recalculés en prenant la moyenne des observations affectées à chaque groupe. Ce processus d'affectation et de mise à jour se poursuit jusqu'à convergence, c'est-à-dire lorsque les centroïdes ne se déplacent plus de manière significative ou qu'un critère d'arrêt prédéfini est atteint. K-Means présente l'avantage d'une mise en œuvre simple et rapide, même sur de larges ensembles de données, ce qui le rend particulièrement adapté à des problèmes de clustering exploratoire dans des contextes variés tels que la segmentation de clientèle, l'analyse d'image, la compression de données ou encore la bioinformatique. Cependant, il présente également certaines limitations importantes. Tout d'abord, le choix du nombre optimal de clusters  $K$  n'est pas trivial et nécessite souvent l'utilisation de méthodes complémentaires telles que l'indice de silhouette, la méthode du coude (Elbow Method) ou des critères d'information comme le BIC et l'AIC. De plus, K-Means est sensible aux valeurs aberrantes et aux variations d'échelle des variables, ce qui impose fréquemment un prétraitement rigoureux des données incluant la normalisation ou

la standardisation. Enfin, comme il repose sur des distances euclidiennes, K-Means tend à privilégier des clusters de forme sphérique et de taille comparable, ce qui peut poser problème dans le cas de structures de données plus complexes ou non convexes. Malgré ces limites, de nombreuses extensions ont été développées pour pallier ces insuffisances, notamment K-Medoids, Fuzzy C-Means et des variantes basées sur des noyaux, permettant ainsi délargir son domaine d'application tout en améliorant sa robustesse.

La figure 2.8 montre le principe de l'algorithme K-Means.



*Figure 2.8 – Algorithme K-Means.*

## 2.4.2 PCA (Principal Component Analysis)

L'Analyse en Composantes Principales (Principal Component Analysis en anglais) est une technique puissante de réduction de dimensionnalité largement utilisée en apprentissage automatique, analyse de données et statistiques pour simplifier des ensembles de données complexes tout en conservant leur structure essentielle. L'idée centrale de la méthode PCA est de transformer un jeu de données en haute dimension en un espace de plus faible dimension en identifiant les directions (appelées composantes principales) qui maximisent la variance des données. Ces composantes principales sont orthogonales entre elles et sont ordonnées selon la quantité de variance qu'elles expliquent : la première composante capture la plus grande part de variance, la seconde explique la variance suivante (tout en étant décorrélée de la première), et ainsi de suite. Mathématiquement, la méthode PCA consiste à calculer les vecteurs propres et valeurs propres de la matrice de covariance des données, ce qui permet de projeter les données originales dans un nouveau système de coordonnées défini par ces composantes principales. En ne conservant que les  $k$  premières composantes expliquant la majeure partie de la variance, la méthode PCA réduit efficacement le bruit, élimine les redondances et améliore l'efficacité des calculs sans perte significative d'informations. Cela en fait un outil particulièrement utile pour des tâches telles que la visualisation de données, l'extraction de caractéristiques ou la réduction du

bruit dans des domaines allant du traitement d'images et de la génomique à la finance et au traitement du langage naturel. Cependant, la méthode PCA suppose une linéarité dans les données et peut être sensible à la mise à l'échelle, ce qui implique souvent de standardiser les variables avant son application. Malgré ces limites, sa simplicité, son interprétabilité et son efficacité font de la méthode PCA un outil fondamental dans l'analyse exploratoire des données et les pipelines de prétraitement [76].

## 2.5 Algorithmes d'apprentissage par renforcement

### 2.5.1 Q-Learning

Le Q-Learning est un algorithme fondamental d'apprentissage par renforcement (Reinforcement Learning), appartenant à la famille des méthodes d'apprentissage hors modèle (model-free). Il permet à un agent autonome d'apprendre, par l'interaction avec son environnement, une politique optimale de décision sans nécessiter de connaissance préalable des dynamiques de transition de l'environnement [71]. Le principe du Q-Learning repose sur l'estimation itérative d'une fonction de valeur d'action, notée  $Q(s, a)$ , qui représente l'espérance du cumul des récompenses futures qu'un agent peut obtenir en choisissant une action  $a$  dans un état  $s$  donné, puis en suivant une politique optimale par la suite. À chaque interaction, l'agent met à jour sa fonction  $Q$  en appliquant l'équation de Bellman :

$$Q(s, a) \leftarrow Q(s, a) + \alpha[r + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad (2.7)$$

où  $\alpha$  est le taux d'apprentissage,  $\gamma$  est le facteur d'actualisation des récompenses futures,  $r$  est la récompense immédiate obtenue après la prise de l'action  $a$ , et  $s$  est l'état résultant. Au fil des épisodes, le Q-Learning converge théoriquement vers la fonction de valeur optimale sous certaines conditions de convergence, notamment une exploration suffisante de l'espace des états et un taux d'apprentissage décroissant. L'un de ses avantages majeurs réside dans sa simplicité de mise en œuvre et sa capacité à apprendre dans des environnements stochastiques et partiellement observables. Cependant, l'application du Q-Learning à des environnements à grand espace d'états ou d'actions souffre du problème d'explosion de la table  $Q$ , rendant le stockage et l'apprentissage inefficaces. Pour surmonter ces limitations, des variantes telles que le Deep Q-Learning (DQN) ont été développées, où la fonction  $Q$  est approximée par des réseaux de neurones profonds, permettant ainsi de généraliser l'algorithme à des espaces d'états continus ou de grande dimension. Le Q-Learning et ses extensions sont aujourd'hui largement utilisés dans des domaines variés tels que la robotique autonome, la gestion des ressources en réseaux de communication, les jeux stratégiques, la finance algorithmique et l'optimisation des systèmes complexes. Néanmoins, la stabilité de l'apprentissage, la gestion du compromis exploration/exploitation et la sensibilité aux

hyperparamètres demeurent des défis actifs de recherche dans le perfectionnement des algorithmes basés sur le Q-Learning.

## 2.6 Conclusion

Le Machine Learning constitue aujourd'hui un domaine clé de l'intelligence artificielle, offrant des méthodes adaptées à une grande variété de problèmes, allant de la simple régression à la conception de systèmes autonomes complexes. Grâce à la diversité de ses approches, il permet de traiter efficacement des données massives et hétérogènes dans des secteurs tels que la santé, la finance, l'industrie ou la cybersécurité. La compréhension des principaux paradigmes d'apprentissage supervisé, non supervisé et par renforcement, ainsi que la maîtrise des algorithmes tels que les réseaux de neurones, les arbres de décision, les SVM ou les méthodes d'ensemble, sont essentielles pour développer des modèles performants et fiables. Toutefois, la qualité des données, le choix des caractéristiques, l'ajustement des hyperparamètres et la gestion du surapprentissage jouent un rôle déterminant dans les performances obtenues. Par ailleurs, des défis liés à l'interprétabilité, à l'équité des algorithmes et à leur robustesse face aux données bruitées doivent être pris en compte afin d'assurer une utilisation responsable et efficace de ces technologies dans les applications réelles.

# Optimisation de la durée de vie des WBAN via des protocoles de clustering

## Sommaire

---

<b>3.1</b>	<b>Introduction</b>	<b>53</b>
<b>3.2</b>	<b>Travaux récents</b>	<b>54</b>
<b>3.3</b>	<b>Contributions et protocoles proposés</b>	<b>55</b>
<b>3.4</b>	<b>Outils de simulation</b>	<b>56</b>
<b>3.5</b>	<b>Modèle WBAN utilisé</b>	<b>56</b>
3.5.1	Déploiement des nuds	56
3.5.2	Scénario de routage entre nuds	58
3.5.3	Modèle énergétique	59
<b>3.6</b>	<b>Implémentation de protocoles</b>	<b>60</b>
3.6.1	Première contribution	61
3.6.1.1	Première approche (tous les nuds sont concernés par le clustering)	62
3.6.1.2	Deuxième approche	64
3.6.2	Deuxième contribution	67
3.6.2.1	K-Means	67
3.6.2.2	K-Medoids	67
3.6.2.3	Implémentation de CBK-Means et CBK-Medoids	68
3.6.3	Troisième contribution (Improved CBFCM)	72
<b>3.7</b>	<b>Comparaison entre CBFCM et Improved CBFCM</b>	<b>75</b>
3.7.1	Energie résiduelle	75
3.7.2	Durée de vie du réseau	76
3.7.3	Stabilité du réseau	76
<b>3.8</b>	<b>Conclusion</b>	<b>77</b>

---

### 3.1 Introduction

Les avancées dans le domaine de lélectronique ont ouvert la voie au développement de la technologie des systèmes micro-électromécaniques (MEMS), rendant les capteurs de plus en plus puissants et intelligents. Intrinsèquement, les capteurs MEMS sont de petits dispositifs capables de détecter l'environnement, de collecter, de traiter et de transmettre des données. Dans le but de tirer parti des progrès réalisés dans les communications sans fil, ces capteurs sont devenus capables de communiquer entre eux de manière autonome grâce à cette technologie, donnant ainsi naissance aux Réseaux de Capteurs Sans Fil (Wireless Sensor Networks), qui connaissent un développement croissant dans de nombreuses applications telles que les Réseaux de Capteurs Corporels Sans Fil (Wireless Body Sensor Networks) [77].

Le WBAN constitue un type particulier de réseau utilisé pour surveiller les paramètres de santé du corps humain sans perturber ses activités quotidiennes, répondant ainsi aux exigences des systèmes de soins de santé et des dispositifs médicaux. La structure du WBAN comprend de petits nuds capteurs (Sensor Nodes - SNs) déployés sur différentes parties du corps humain, permettant de mesurer divers paramètres physiologiques tels que la pression artérielle, la fréquence cardiaque, le taux de glucose, etc. Ces SNs collectent et traitent les données mesurées avant de les transmettre à une station de base ou à un nud collecteur (sink) [78]. Les données ainsi enregistrées sont ensuite dirigées vers un réseau externe ou stockées dans un environnement Cloud, accessible à divers professionnels de santé situés à distance afin qu'ils puissent entreprendre les actions nécessaires [79], [80].

Linconvénient majeur de ces SNs de petite taille réside dans leurs ressources limitées, notamment la capacité de la batterie, qui se décharge rapidement en raison des différentes opérations effectuées, principalement lors de la transmission des données [81–83]. Cette consommation énergétique accélérée entraîne la mort prématurée des SNs, affectant ainsi de manière significative la durée de vie du réseau [84]. En ce sens, le principal défi de conception auquel sont confrontés les WBANs est d'assurer une transmission fiable des données tout en prolongeant la durée de vie du réseau sous la contrainte d'une alimentation électrique restreinte et imposée.

Afin d'améliorer les performances des WBAN, les protocoles de routage doivent être conçus en tenant compte des limitations énergétiques des SNs dans le but de prolonger la durée de vie du réseau [85]. Les protocoles de routage fondés sur le mécanisme de clustering sont particulièrement appropriés aux applications WBAN. Dans l'approche de clustering, le réseau est divisé en plusieurs sous-réseaux logiques appelés clusters. Le chef de cluster (Cluster Head - CH) regroupe les données reçues en un seul paquet avant de les transmettre au sink [86]. Cette approche de clustering, associée à une sélection judicieuse du CH, permet de garantir une consommation

énergétique minimale.

Le reste du chapitre est organisé en plusieurs sections qui structurent la démarche de recherche. La deuxième section est consacrée à l'état de l'art et passe en revue les travaux récents. La troisième section présente les contributions principales, tandis que la quatrième décrit les outils de simulation utilisés. Les sections suivantes détaillent le modèle WBAN adopté, avec des sous-sections consacrées au déploiement des nuds et au modèle énergétique. Le cur méthodologique du chapitre se trouve dans les sections dédiées à l'implémentation des trois contributions, où chaque approche de clustering est systématiquement expliquée. Enfin, une section comparative analyse les performances des protocoles proposés, avant qu'une conclusion ne synthétise les principaux résultats. Cette organisation en sections permet de suivre clairement le développement logique de l'étude, depuis le cadre théorique jusqu'à l'évaluation des solutions proposées.

## 3.2 Travaux récents

Au cours de ces dernières années, de nombreux travaux ont été menés à travers le monde dans le domaine des réseaux de capteurs corporels sans fil (BAN), chaque étude s'efforçant de concevoir des mécanismes permettant d'optimiser la consommation énergétique des capteurs et de prolonger la durée de vie globale du réseau à travers diverses approches. Parmi ces travaux, une attention particulière est accordée aux protocoles de routage basés sur le clustering, qui constituent une solution prometteuse face aux contraintes énergétiques des WBAN.

Dans cette perspective, Anand et Sethi [87] ont réalisé une analyse comparative approfondie des différentes techniques de routage appliquées aux WBAN, en identifiant leurs principaux défis ainsi que leurs avantages et inconvénients respectifs. Leur étude recense plusieurs protocoles de routage existants, tels que ATTEMPT (Adaptive Threshold-based Thermal-aware Energy-efficient Multi-hop Protocol), SIMPLE (Stable Increased-throughput Multi-hop Protocol for Link Efficiency) et EERDT (Energy Efficient and Reliable Data Transfer), en évaluant leurs performances à l'aide de simulations réalisées sous l'environnement MATLAB.

Par ailleurs, Singh et Singh [88] ont proposé un protocole de routage adaptatif fondé sur une approche de clustering flou et économe en énergie. Ce protocole intègre une stratégie de transmission directe modulée selon la criticité et la localisation des nuds capteurs. Les simulations ont mis en évidence une amélioration significative de la période de stabilité et de la longévité du réseau, démontrant l'efficacité de cette méthode adaptative.

Dans un travail récent réalisé par Akash [89], les auteurs ont cherché à concevoir un réseau WBAN énergétiquement efficace, dans lequel un noeud passerelle est utilisé dans le chemin de routage entre les clusters corporels, selon le protocole GNCH (Ga-

teway Node-based Clustering Hierarchy). L'architecture WBAN adoptée dans cette étude comprend 16 noeuds capteurs et un noeud collecteur. Ce protocole a permis de minimiser la consommation énergétique et d'allonger ainsi la durée de vie du WBAN.

Dans un premier travail, Ullah et al. [90] ont développé le protocole DSCB (Dual Sink Clustering-Based), introduisant le concept d'une architecture à double puits de collecte associée à une technique de clustering. Cette approche vise à renforcer la stabilité du réseau tout en optimisant la consommation énergétique. Le protocole DSCB a été comparé aux protocoles existants SIMPLE et DARE (Distance-Aware Relaying Energy efficient), en s'appuyant sur une fonction de coût intégrant la distance nodale au puits, l'énergie résiduelle des nœuds et la puissance de transmission requise. Les résultats expérimentaux obtenus démontrent des performances supérieures en termes de stabilité du réseau et de réduction du délai de transmission de bout en bout.

Un autre travail présenté dans [91] par Ullah et al. consiste à utiliser un clustering fondé sur la connaissance préalable de l'énergie récupérée au niveau des noeuds, combiné à un protocole de routage coopératif pour WBAN, appelé E-HARP (Energy-efficient Harvested-Aware clustering and cooperative Routing Protocol). Le système WBAN proposé est constitué de 14 noeuds capteurs et de 2 noeuds collecteurs. Les résultats obtenus ont montré une amélioration significative des performances du protocole E-HARP en termes de stabilité et de durée de vie du réseau, de débit, de délai de bout en bout et de taux de livraison des paquets.

### 3.3 Contributions et protocoles proposés

Au regard des différentes études et des approches modernes de routage et de clustering, nous nous appuyerons sur l'ensemble des protocoles analysés afin de sélectionner la solution la plus adaptée répondant aux divers critères de performance requis pour les WBAN, en tenant compte des fortes contraintes imposées par la limitation des ressources énergétiques des capteurs.

Dans cette perspective, nous avons choisi d'adopter, dans le présent travail, la méthode Fuzzy C-means (FCM) pour la sélection du CH, en raison de sa simplicité, de sa facilité d'implémentation et de son efficacité sur l'énergie résiduelle consommée dans le réseau [92–96]. La méthode FCM introduit la notion d'ensemble flou dans la définition des clusters : chaque noeud dans la zone de déploiement appartient à chaque groupe avec un certain degré d'appartenance, et chaque cluster est caractérisé par son centre de gravité. La méthode FCM repose sur un critère visant à minimiser les distances intra-cluster et à maximiser les distances inter-cluster, tout en attribuant à chaque noeud un degré d'appartenance à chaque cluster.

Dans le cadre de notre première contribution, nous proposons la conception d'un protocole de routage basé sur le clustering utilisant la méthode FCM (Fuzzy C-

Means). Deux scénarios sont envisagés dans cette approche :

- l'algorithme Clustering Based Fuzzy C-Means CBFCM où l'ensemble des noeuds du réseau participe à l'opération de clustering ;
- et l'algorithme CBFCM-PN où les noeuds situés à proximité immédiate des puits de collecte (sinks) sont exclus du processus de clustering afin de limiter les surcharges inutiles.

De nombreuses simulations sont réalisées afin d'évaluer les performances des deux algorithmes.

La seconde contribution consiste à optimiser la position des puits de collecte dans le but d'accroître la durée de vie du réseau, en minimisant les distances de transmission et en équilibrant la consommation énergétique entre les nœuds. Ce protocole est nommé Improved-CBFCM.

L'évaluation des performances des algorithmes de routage proposés s'appuie sur les indicateurs suivants :

1. la durée de vie du réseau ;
2. la stabilité du réseau ;
3. l'énergie résiduelle des nœuds.

## 3.4 Outils de simulation


Divers outils de simulation sont disponibles pour modéliser les réseaux de capteurs sans fil en général, et les réseaux de capteurs corporels (WBAN) en particulier. Parmi les plus couramment utilisés figurent NS-3, Omnet++, Matlab et Castalia. Dans le cadre de ce travail, le choix s'est porté sur Matlab, qui constitue une plateforme de simulation largement répandue dans le domaine des réseaux de capteurs sans fil, en raison de sa grande flexibilité et de sa capacité de traitement avancée. Matlab offre une vaste bibliothèque de fonctions et de boîtes à outils permettant de modéliser efficacement les capteurs, les canaux de communication radio ainsi que divers algorithmes de clustering, notamment Fuzzy C-Means (FCM), K-Means, entre autres. Par ailleurs, son interface conviviale et sa facilité de prise en main font un environnement particulièrement adapté aussi bien pour les chercheurs expérimentés que pour les utilisateurs débutants.

## 3.5 Modèle WBAN utilisé

### 3.5.1 Déploiement des nœuds

Le système WBAN proposé est constitué de quatorze nœuds capteurs homogènes, caractérisés par des ressources matérielles limitées en raison de leurs dimensions ré-

duites. Ces capteurs sont déployés sur la face antérieure du corps humain, avec la présence de deux puits de collecte (sinks) stratégiquement positionnés, respectivement au niveau de la hanche droite et de la hanche gauche. Cette configuration permet de garantir une connectivité directe et efficace avec l'ensemble des nuds du réseau, quel que soit leur emplacement. Les deux puits de collecte se distinguent des autres nuds capteurs par leurs capacités matérielles supérieures, intégrant des ressources de calcul et de communication plus performantes. Leur positionnement respectif sur le corps humain est illustré dans la figure 3.1, tandis que leurs coordonnées détaillées sont présentées dans le tableau 3.1.



*Figure 3.1 – Localisation des nuds.*

**Tableau 3.1** – Positions des nuds selon les axes X et Y.

Nud	Axe X (m)	Axe Y (m)
1	0.32	1.77
2	0.35	1.37
3	0.22	1.35
4	0.36	1.01
5	0.35	0.01
6	0.08	1.45
7	0.06	0.98
8	0.37	1.27
9	0.40	1.01
10	0.22	0.91
11	0.45	0.45
12	0.15	0.50
13	0.15	0.45
14	0.25	0.17
Sink1	0.30	1.03
Sink2	0.09	1.05

### 3.5.2 Scénario de routage entre nuds

Les scénarios de communication utilisés dans ce schéma sont les communications à saut unique et à sauts multiples. La communication à saut unique est effectuée :

1. Si la donnée détectée est critique (différente des seuils supérieur et inférieur prédéfinis).
2. Si le nud de détection est plus proche du nud de réception.
3. Si le nud capteur est un CH sélectionné.

Si ce n'est pas le cas, le capteur transmet ses données au puits en utilisant un schéma multi-sauts, en les transmettant d'abord au CH. Une fois que le CH reçoit des données du SN, il les agrège puis les transmet au noeud récepteur. Le sink est chargé de choisir le CH en fonction du facteur de coût (CF) calculé. Les paramètres pour le calcul du CF sont estimés/calculés par les SN puis envoyés au noeud sink. La consommation d'énergie des SN pendant le traitement des données est ignorée car elle est beaucoup

plus faible par rapport à la consommation d'énergie pendant la transmission /réception des données.

### 3.5.3 Modèle énergétique

Afin de mettre en oeuvre les méthodes de routage, nous précisons tout d'abord les principes utilisés pour la modélisation des réseaux WBAN détaillés dans le modèle IEEE 802.15.6 [97].

#### 1. Calcul de la distance entre le SN et le Sink :

La distance est calculée à l'aide de la formule euclidienne :

$$D = \sqrt{(X_i - X_j)^2 + (Y_i - Y_j)^2} \quad (3.1)$$

où  $(X_i, Y_i)$  représentent les coordonnées du nud capteur (SN), et  $(X_j, Y_j)$  celles du Sink ou du Cluster-Head (CH).

#### 2. Modèle de propagation de perte de trajet : Le modèle de propagation avec atténuation ou perte de trajet sur le corps, exprimé en dB, est donné par la formule suivante :

$$PLoss = N + \alpha \cdot \log_{10}(D) + \beta \cdot \log_{10}(f) \quad (3.2)$$

où :

- $PLoss$  : perte de chemin (en dB),
- $D$  : distance entre le SN et le Sink,
- $f$  : fréquence de fonctionnement (2.4 GHz),
- $N = 158$  dB,
- $\alpha = -27.6$  et  $\beta = -46.5$ , coefficients linéaires ( $\alpha$  : coefficient de déclinaison, l'impact de la posture du corps humain, debout, assis, penché) sur la transmission,  $\beta$  : coefficient d'interception / constante d'interception).

#### 3. Consommation énergétique selon le modèle radio du premier ordre :

L'estimation/prédiction de la consommation d'énergie pendant la transmission, la réception et le traitement des données est effectuée selon le modèle radio du premier ordre [8]. L'équation 3.3 exprime la consommation d'énergie pendant la transmission de  $K$  bits de données vers le destinataire SN à la distance  $D$ .

- *Transmission* :

$$E_{Tx}(K, D) = K \cdot E_{Tx-elec} + K \cdot E_{Amp} \cdot D^n \quad (3.3)$$

- *Réception* : La consommation d'énergie lors de la réception des  $K$  bits de données est exprimée à l'aide de l'équation 3.4 :

$$E_{Rx}(K) = K \cdot E_{Rx-elec} \quad (3.4)$$

- *Agrégation des données (par le CH)* : L'équation 3.5 représente la consommation d'énergie pendant le processus d'agrégation des données effectué par le CH.

$$E_{Aggre}(K) = K \cdot E_{D-Aggre} \quad (3.5)$$

avec :

- $K$  : nombre de bits transmis,
- $E_{Tx-elec}$  : énergie de transmission par bit,
- $E_{Rx-elec}$  : énergie de réception par bit,
- $E_{Amp}$  : énergie de lamplificateur par bit et par distance,
- $E_{D-Aggre}$  : énergie d'agrégation par bit,
- $n$  : facteur d'atténuation lié au corps humain.

Toutes les énergies sont exprimées en (Joule/bit).

4. **Perte énergétique totale d'un membre de cluster** : L'énergie des SNs est consommée durant les différentes opérations de collecte, agrégation, traitement, ainsi que de transmission et réception des données. L'évaluation de la perte totale d'énergie de l'ensemble des membres d'un cluster peut être formulée en utilisant l'équation 3.6 :

$$E_{Loss-cluster}(i) = \sum_{i=1}^N [E_{Tx}(K, D) + E_{Rx}(K) + E_{Aggre}(K)] \quad (3.6)$$

5. **Perte énergétique estimée pour un candidat CH** : Afin d'estimer la consommation énergétique d'un candidat à devenir chef de cluster (CH), on ajoute à la perte énergétique du cluster l'énergie nécessaire à l'agrégation des données. Cette estimation est donnée par l'équation suivante :

$$E_{Loss-SN}(i) = E_{Loss-cluster}(i) + E_{D-Aggre} \quad (3.7)$$

6. **Perte énergétique totale du réseau pour un SN donné** : La perte énergétique totale du réseau pour un nud capteur (SN) donné est obtenue en sommant la perte du cluster et celle du nud candidat CH, comme exprimé dans l'équation ci-dessous :

$$E_{Total-loss}(i) = E_{Loss-cluster}(i) + E_{Loss-SN}(i) \quad (3.8)$$

## 3.6 Implémentation de protocoles

Afin de réaliser les expérimentations sur les protocoles de routage proposés dans ce travail et d'évaluer leurs performances respectives, différents programmes ont été développés et implémentés sous l'environnement de programmation Matlab. Les algorithmes de clustering utilisés incluent notamment Fuzzy C-Means (FCM), K-Means

et K-Medoids. L'ensemble des simulations a été réalisé en se basant sur un ensemble de paramètres spécifiques, parmi lesquels l'énergie initiale allouée à chaque nœud capteur, la taille de la zone de simulation, le nombre total de nœuds déployés ainsi que leurs positions respectives. Les détails complets des paramètres utilisés sont présentés dans le tableau 3.2.

**Tableau 3.2** – Paramètres de simulation.

Paramètres	Valeurs
Zone de simulation	1x2 $m^2$
Nombre de nœuds capteur	14
Nombre de sink	2
Positions des nœuds capteurs et des sink	indiquées dans le Tableau 3.1
Énergie initiale	0.5 J
$E_{Tx-lectronique}$	$16.7 \times 10^{-9}$ J/bit
$E_{Rx-lectronique}$	$36.1 \times 10^{-9}$ J/bit
$E_{Amplificateur}$	$1.98 \times 10^{-9}$ J/bit
$E_{aggregation}$	$5 \times 10^{-9}$ J/bit
Fréquence de travail	2.4 GHz
Nombre maximum de bits	3000

La simulation sera conduite selon trois contributions distinctes.

### 3.6.1 Première contribution


Pour la topologie du WBAN étudié, quatorze nœuds capteurs et deux sinks sont déployés, les positions de l'ensemble des nœuds étant répertoriées dans le tableau 3.1. Afin d'organiser efficacement le réseau, une stratégie de clustering est mise en œuvre. Cette technique permet de structurer le réseau en identifiant des sous-groupes de nœuds, chacun dirigé par un chef de cluster (Cluster Head, CH), chargé notamment de l'agrégation des données collectées par les membres de son groupe. La méthode de clustering adoptée repose sur l'algorithme Fuzzy C-Means (FCM), dont la fonction est directement accessible via la bibliothèque de Matlab, avec un paramétrage fixant le nombre de clusters à  $nc = 2$  (voir figure 3.2). L'algorithme FCM détermine les centres de chaque cluster (ici un premier cluster qui regroupe les SNs de la partie supérieure du corps et un deuxième pour les SNs de la partie inférieure), puis calcule les distances associées, permettant ainsi de représenter graphiquement les regroupements sous forme de cercles (voir Figure 3.3). Lors de la première itération, la sélection des

chefs de cluster est effectuée en fonction de la proximité géographique par rapport aux sinks. À partir de la seconde itération, le choix du CH est optimisé en tenant compte de l'énergie résiduelle des nuds au sein de chaque cluster, dans le but de prolonger la durée de vie globale du réseau.


### 3.6.1.1 Première approche (tous les nuds sont concernés par le clustering)

Dans cette approche, l'ensemble des nuds du réseau participe au processus de clustering, comme illustre la Figure 3.2. Le protocole développé dans ce cadre est désigné sous l'appellation CBFCM (Cluster-Based Fuzzy C-Means).

Une fois le CH choisi, les noeuds appartenant au même cluster doivent d'abord communiquer leurs informations au CH sélectionné. Ce dernier se chargera du traitement de ces données avant de les envoyer vers le sink le plus proche (voir Figure 3.3). Une communication à saut unique est adoptée.




*Figure 3.2 – Répartition des nuds en 2 clusters.*

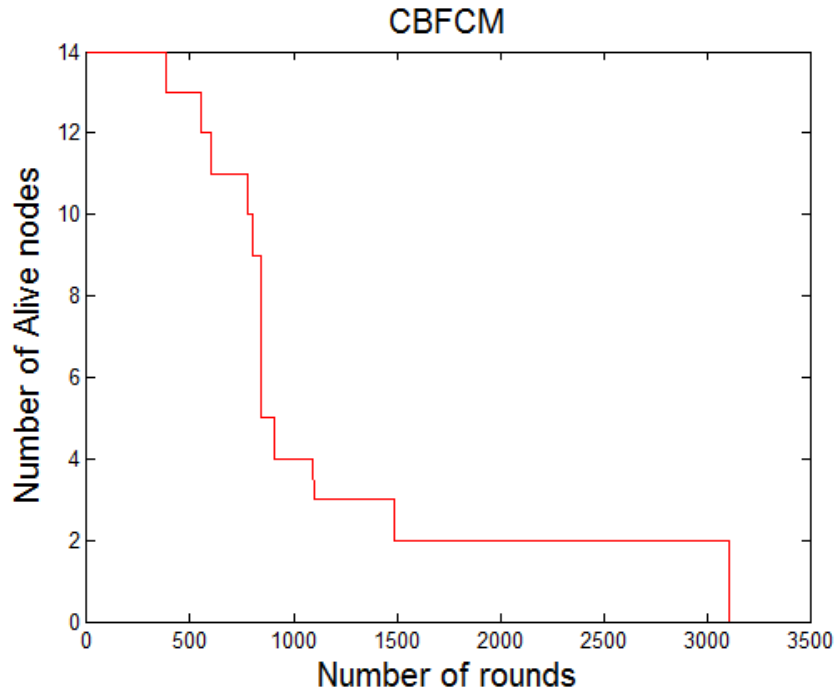


*Figure 3.3 – Transmission par CBFCM.*

Après la mise en uvre du protocole CBFCM, une évaluation de ses performances a été réalisée en sappuyant sur deux critères principaux : lénergie résiduelle consommée et le nombre de nuds encore opérationnels.



*Figure 3.4 – Energie résiduelle consommée par CBFCM.*



*Figure 3.5* – Nombre de nuds vivants avec le protocole CBFCM.

La Figure 3.4 illustre l'évolution de l'énergie résiduelle de l'ensemble des nuds en fonction du nombre d'itérations. On observe que l'énergie globale du réseau est entièrement épuisée à l'itération 3109, marquant ainsi la fin de vie énergétique du réseau.

La Figure 3.5 montre l'évolution décroissante du nombre de nuds actifs au fil des itérations. Progressivement, les nuds cessent de fonctionner à mesure que leur énergie est épuisée, jusqu'à l'extinction complète du réseau, qui intervient à l'itération 3109 lorsque le dernier nud devient inactif.


### 3.6.1.2 Deuxième approche

La seconde approche, désignée sous l'appellation CBFCM-PN (Cluster-Based Fuzzy C-Means without Proximal Nodes), constitue une amélioration du protocole initial. Dans cette variante, les nuds situés à proximité immédiate des sinks sont exclus du processus de clustering, afin de limiter la surcharge énergétique associée à leur participation. L'implémentation de cette approche a été réalisée sous Matlab en vue d'évaluer ses performances. Le schéma de transmission des données pour les nuds exclus du clustering est défini comme suit (cf. Figure 3.6) :

- Le noeud 14 transmet ses données au noeud 12, qui assure ensuite la transmission vers le sink 1.
- Le noeud 13 transmet directement ses données au sink 2.

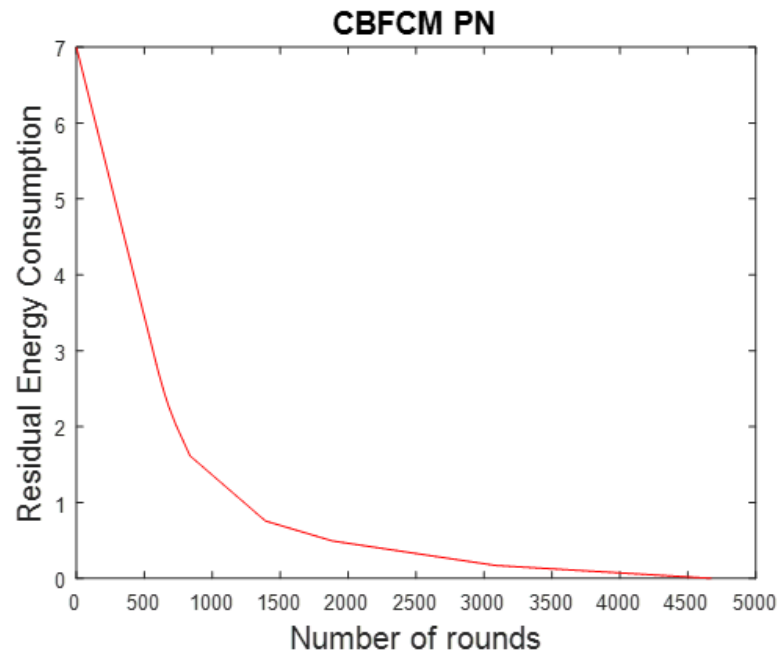
Sachant que l'ordre de numérotation des nuds a changé sur la figure 3.5 suite à l'exclusion des 3 nuds plus proches des deux sink.

En parallèle, les autres nuds du réseau continuent à fonctionner selon le principe du clustering : ils transmettent leurs données au chef de cluster (CH) sélectionné, lequel assure la régulation des données avant leur acheminement vers le sink correspondant (sink 1 ou sink 2).

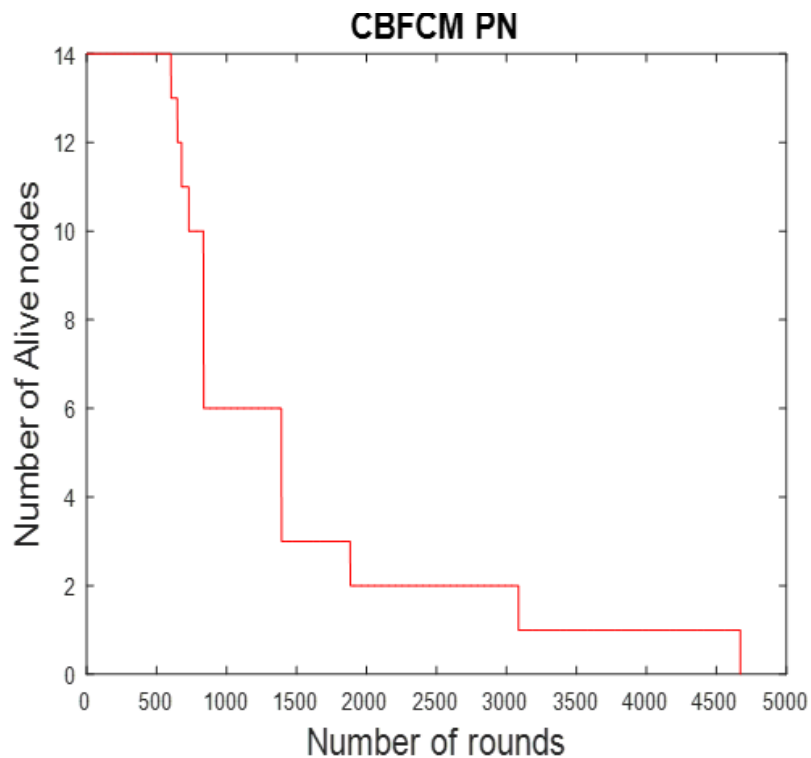


**Figure 3.6** – Transmission par CBFCM PN.

Après l'implémentation du protocole de routage CBFCM-PN, les mêmes indicateurs de performance ont été évalués. Les résultats obtenus sont présentés ci-après.



*Figure 3.7 – Energie résiduelle consommée par CBFCM PN.*



*Figure 3.8 – Nombre de nuds vivants avec le protocole CBFCM PN.*

La Figure 3.7 illustre l'évolution de l'énergie résiduelle tout au long du processus de simulation. Il est observé que l'énergie totale du réseau est entièrement consommée

au round 4672, marquant ainsi l'épuisement complet des ressources énergétiques.

La Figure 3.8 présente l'évolution du nombre de nuds encore opérationnels en fonction du nombre d'itérations. L'extinction complète du réseau intervient au round 4672, lorsque le dernier nud épuise à son tour son énergie.

### 3.6.2 Deuxième contribution

Dans cette partie, nous avons opté pour le remplacement de la méthode de clustering FCM, précédemment utilisée, par d'autres techniques de clustering.

#### 3.6.2.1 K-Means

Le K-Means constitue l'un des algorithmes de clustering non supervisés les plus largement utilisés dans les domaines de l'apprentissage automatique et de l'analyse de données. Son principe repose sur la partition d'un ensemble de données en un nombre prédéfini de groupes, appelés clusters, de manière à regrouper les éléments présentant des similarités. Chaque cluster est caractérisé par un centre de gravité appelé centroïde, représentant la moyenne des observations qui lui sont assignées.

L'objectif fondamental de l'algorithme K-Means est de minimiser la variance intra-cluster, c'est-à-dire de réduire la dispersion des points de données à l'intérieur de chaque groupe, tout en maximisant la variance inter-cluster, favorisant ainsi une séparation claire entre les différents groupes formés. Le processus d'optimisation est de nature itérative. À chaque itération, les étapes suivantes sont réalisées :

1. Affectation de chaque point de données au cluster dont le centroïde est le plus proche selon une métrique de distance, généralement la distance euclidienne.
2. Recalcul des centroïdes en prenant la moyenne des points actuellement assignés à chaque cluster.

Ce processus de réaffectation et de recalcul des centroïdes se poursuit jusqu'à convergence, c'est-à-dire lorsque les affectations de points aux clusters deviennent stables ou que la variation des centroïdes devient négligeable. Grâce à sa simplicité conceptuelle et à son efficacité computationnelle, l'algorithme K-Means s'avère particulièrement adapté à de nombreuses applications pratiques, notamment dans le traitement de grandes bases de données, la classification de signaux biomédicaux, l'analyse d'images ou encore la segmentation de réseaux de capteurs corporels.

#### 3.6.2.2 K-Medoids

Le K-Medoids est un algorithme de clustering non supervisé qui partage plusieurs similarités conceptuelles avec l'algorithme K-Means, dans la mesure où il cherche également à partitionner un ensemble de données en un nombre prédéfini de groupes ou clusters distincts. Toutefois, la différence essentielle entre les deux réside dans la manière dont sont choisis les représentants des clusters. Contrairement à K-Means

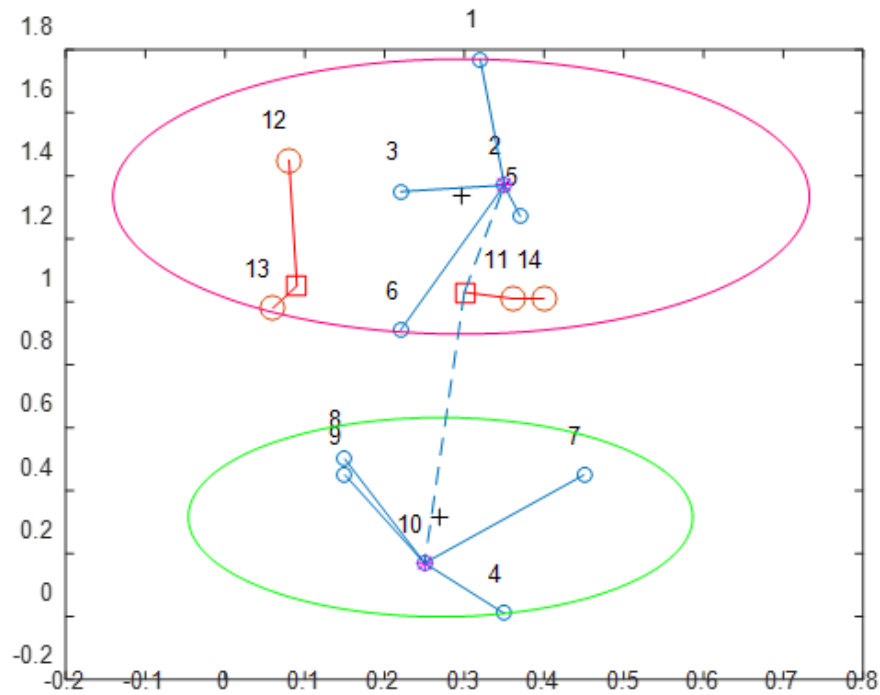
qui utilise les centroïdes (calculés comme la moyenne des points appartenant à chaque cluster), K-Medoids sélectionne parmi les observations réelles de l'ensemble de données des représentants appelés médoïdes. Chaque médoïde est un point de données concret qui minimise la distance moyenne (ou la somme des distances) entre lui-même et les autres points de son cluster. Ainsi, plutôt que de calculer des centres idéalisés susceptibles de ne pas correspondre à des données existantes, K-Medoids s'appuie uniquement sur des points observés dans l'espace de données. L'algorithme procède de manière itérative en suivant généralement les étapes suivantes :

1. Sélection initiale de  $k$  médoïdes aléatoires parmi l'ensemble des observations.
2. Affectation de chaque point de données au médoïde le plus proche selon une métrique de distance appropriée, souvent la distance de Manhattan ou la distance euclidienne.
3. Réévaluation de chaque médoïde par exploration des permutations possibles avec les autres points du cluster, en cherchant à minimiser la fonction coût définie comme la somme des distances entre chaque point et son médoïde respectif.
4. Répétition des étapes d'affectation et de mise à jour jusqu'à stabilisation des médoïdes, c'est-à-dire jusqu'à ce qu'aucune amélioration supplémentaire de la fonction coût ne soit possible.

L'une des forces majeures de K-Medoids réside dans sa robustesse face aux valeurs aberrantes et aux bruits. En effet, l'utilisation de points réels comme représentants rend l'algorithme moins sensible aux observations extrêmes ou aux distributions non convexes des données, là où K-Means peut être fortement perturbé. En raison de cette robustesse accrue, K-Medoids est particulièrement adapté aux applications impliquant des données hétérogènes, des formes de clusters complexes ou des jeux de données contenant des outliers, ce qui en fait un candidat pertinent dans le contexte du clustering de réseaux de capteurs corporels où les mesures peuvent parfois être bruitées ou irrégulières.

### 3.6.2.3 Implémentation de CBK-Means et CBK-Medoids

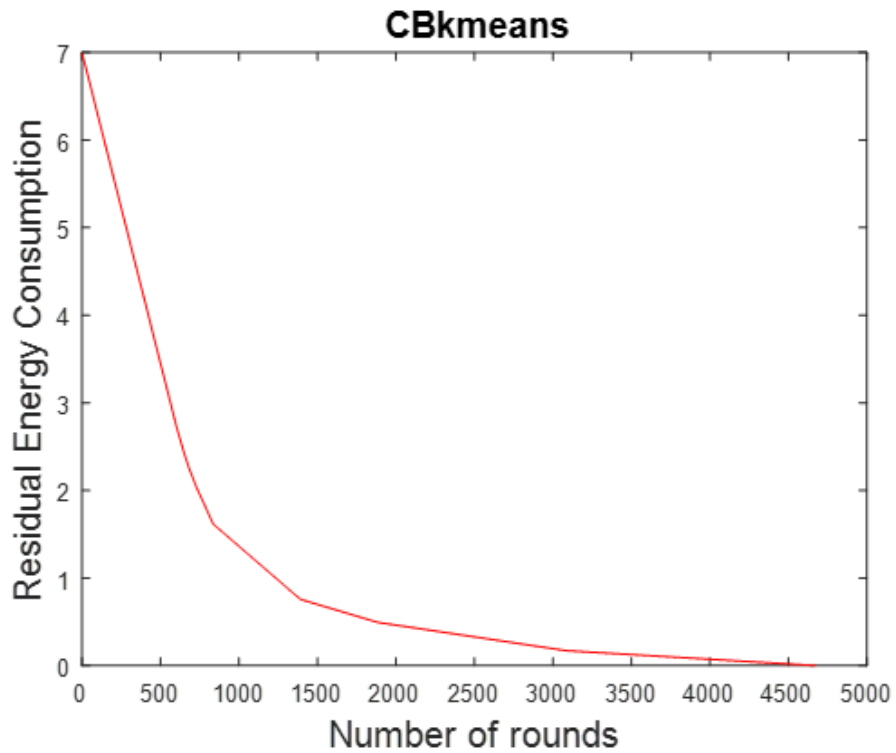
Les deux algorithmes K-Means et K-Medoids sont directement accessibles à travers la bibliothèque de fonctions intégrée dans l'environnement MATLAB, facilitant ainsi leur implémentation et leur exploitation dans les simulations. Après l'implémentation des protocoles CBK-Means et CBK-Medoids, une évaluation de leurs performances a été réalisée en se basant sur deux indicateurs principaux : l'énergie résiduelle consommée et le nombre de noeuds encore opérationnels. Les noeuds les plus proches des deux sinks sont exclus du clustering. Les résultats obtenus sont présentés ci-après.



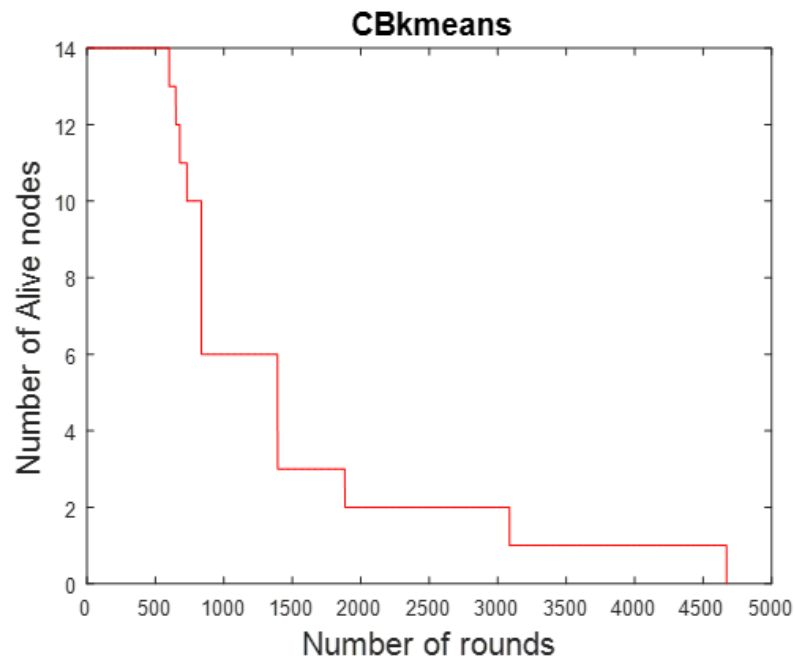
**Figure 3.9** – Energie résiduelle consommée par CBKmeans.

Sur la Figure 3.9 est présenté le protocole de routage CBK-means dans lequel la transmission de données est effectuée entre les différents noeuds d'un cluster et son centroïde déterminé par la méthode K-means.

Pour le protocole de routage CBK-Means, les mêmes indicateurs de performance ont été évalués. Les résultats correspondants sont présentés ci-après.




*Figure 3.10* – Energie résiduelle consommée par CBKmeans.



*Figure 3.11* – Nombre de nuds vivants avec le protocole CBKmeans.

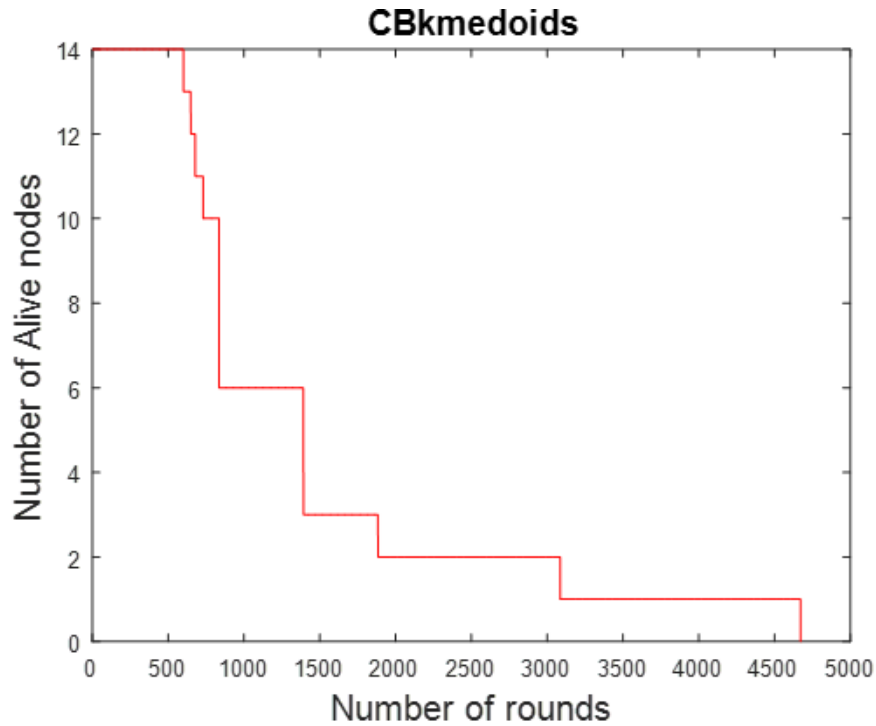
Dans les Figures 3.10 et 3.11, l'extinction complète du réseau intervient au round 4672.

Les indicateurs de performance pour le protocole de routage CBKmedoids ont été évalués et les résultats correspondants sont présentés ci-après.



*Figure 3.12 – Energie résiduelle consommée par CBKmedoide.*

La Figure 3.12 illustre l'évolution de l'énergie résiduelle tout au long du processus de simulation. Il est observé que l'énergie totale du réseau est entièrement consommée au round 4672, marquant l'épuisement complet des ressources énergétiques.



*Figure 3.13* – Nombre de nuds vivants avec le protocole CBKmedoide.


La Figure 3.13 présente l'évolution du nombre de nuds actifs durant la simulation. Le dernier nud épuise son énergie au round 4672, entraînant ainsi l'extinction complète du réseau.

En résumé, les algorithmes de clustering FCM, K-Means et K-Medoids se distinguent par leurs approches respectives en matière de partitionnement et de représentation des clusters. Chacun de ces algorithmes présente des avantages spécifiques qui peuvent les rendre plus adaptés à certains types de données ou de problématiques de clustering particulières. Lorsque le nombre de capteurs reste limité, les données sont souvent relativement simples, ce qui permet aux trois méthodes d'obtenir des performances comparables. Cependant, il convient de souligner que les performances de ces algorithmes peuvent être influencées par plusieurs facteurs, notamment le choix initial des centres de clusters, les paramètres propres à chaque algorithme, la présence de valeurs aberrantes (outliers), ainsi que le nombre total de nuds déployés dans le réseau. Ces paramètres doivent être soigneusement pris en compte lors du choix de l'algorithme de clustering le plus approprié pour une application donnée.

### 3.6.3 Troisième contribution (Improved CBFCM)

La position du sink exerce une influence significative sur les performances globales du système WBAN, notamment en matière de qualité de transmission, de consommation énergétique et de latence. En fonction de la topologie du réseau, de la portée


de communication des capteurs et des contraintes propres au système, le repositionnement du sink peut constituer une stratégie efficace pour optimiser la gestion énergétique du réseau. En rapprochant le sink des capteurs ou en l'alignant avec des sources d'alimentation externes, il est possible de diminuer la puissance nécessaire à la transmission des données, contribuant ainsi à prolonger la durée de vie des batteries des capteurs. Dans le cadre de cette étude, la position initiale du sink 2 ( $x = 0.09$ ;  $y = 1.05$ , voir Tableau 3.1) a été modifiée à plusieurs reprises. Une nouvelle position approximativement plus proche du deuxième cluster (localisé au niveau du genou gauche) a été adoptée, correspondant aux coordonnées  $x = 0.14$  et  $y = 0.5$ .




**Figure 3.14** – *Transmission par Improved CBFCM.*

Ce nouveau protocole (Figure. 3.14), simulé afin de pouvoir comparer les résultats obtenus auparavant, est basé sur la méthode FCM de clustering appliqué sur les 11 noeuds restants du réseau sachant que 3 des noeuds font leur transmission directement au sink 1 ou 2.

Une fois la mise en uvre du protocole "Improved CBFCM" terminée, nous avons testé ces performances du point de vue  $\acute{e}$ nergie résiduelle consommée  $\acute{z}$  et  $\acute{n}$  nombre de nuds vivants  $\acute{z}$ , voici ce que nous avons obtenus comme résultats :



*Figure 3.15 – Energie résiduelle consommée par Improved CBFCM.*



*Figure 3.16 – Nombre de nuds vivants avec le protocole Improved CBFCM.*

La figure 3.15 représente la courbe de l'énergie résiduelle consommée dans tout le réseau (en Joule/bit) en fonction du nombre de round par le protocole de routage "Improved CBFCM.

On constate que cette énergie devient nulle au round 6482, ce qui correspond aussi


au round du dernier nud qui épuise son énergie (Figure 3.16) ce qui provoque la fin de tout le réseau.

### 3.7 Comparaison entre CBFCM et Improved CBFCM

Le protocole Improved CBFCM proposé est comparé au protocole de référence CBFCM selon plusieurs critères de performance, à savoir la durée de vie du réseau, la consommation énergétique résiduelle totale et la stabilité du réseau. À cette fin, les courbes représentant l'évolution de l'énergie résiduelle ainsi que celles illustrant le nombre de nuds encore opérationnels ont été regroupées pour les deux protocoles, en fonction du nombre de rounds. Cette représentation comparative permet de mettre en évidence les améliorations obtenues grâce au protocole Improved CBFCM.

#### 3.7.1 Énergie résiduelle

L'énergie résiduelle totale du réseau correspond à la somme des énergies restantes de l'ensemble des nuds capteurs (SN) du réseau. Cette énergie décroît au fur et à mesure des opérations réalisées par les nuds, notamment les processus de transmission, de réception et de traitement des données, qui constituent les principales sources de consommation énergétique.



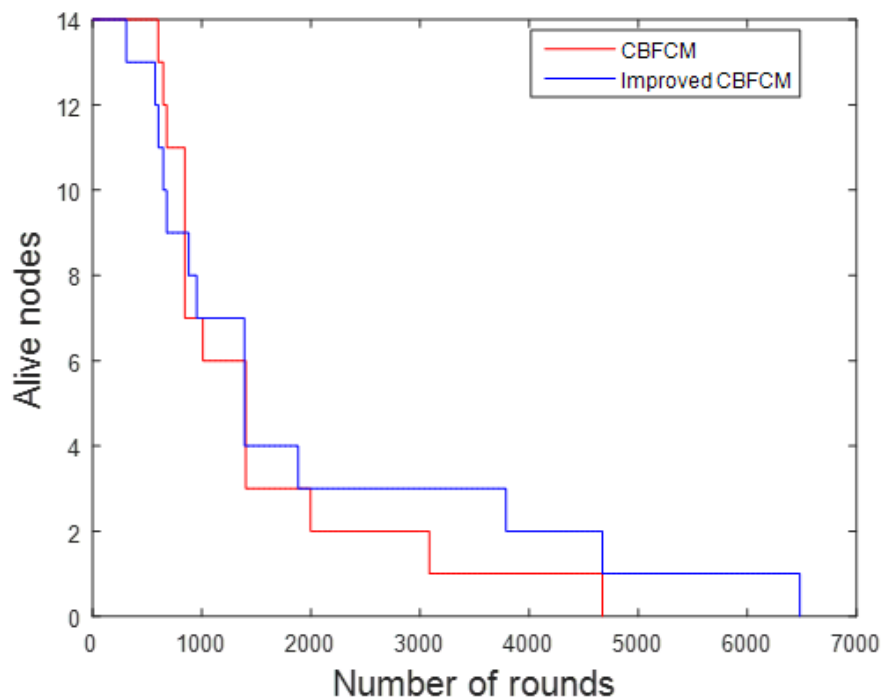
**Figure 3.17** – Comparaison des énergies résiduelles consommées par les 2 méthodes.

Comme illustre la Figure 3.17, l'énergie résiduelle enregistrée avec le protocole

Improved CBFCM demeure systématiquement supérieure à celle obtenue avec le protocole CBFCM, traduisant ainsi une meilleure efficacité énergétique du protocole proposé.

### 3.7.2 Durée de vie du réseau

La durée de vie d'un réseau désigne la période pendant laquelle le réseau demeure opérationnel, efficace et apte à satisfaire les exigences des utilisateurs. Elle englobe la capacité du réseau à assurer une connectivité fiable, à maintenir des performances satisfaisantes et à prendre en charge l'ensemble des applications et des services attendus.




*Figure 3.18* – Comparaison du nombre de nœuds vivants pour les 2 méthodes.

Il a été observé que, dans le cas du protocole CBFCM, le dernier nœud devient inactif à l'itération 4672. En revanche, le protocole Improved CBFCM permet une amélioration significative de la durée de vie du réseau, le dernier nœud n'épuisant son énergie qu'au round 6482 (voir Figure 3.18).

### 3.7.3 Stabilité du réseau

La période de stabilité correspond à l'intervalle de temps précédant la défaillance du premier nœud capteur du réseau. Un réseau présentant une période de stabilité plus longue permet aux nœuds de rester opérationnels durant une durée prolongée. Afin

dillustrer les résultats obtenus, un résumé sous forme d'histogramme est présenté, comparant les deux protocoles de routage étudiés en fonction du round au cours duquel le premier nœud devient inactif (First Node Died, FND), ainsi que celui où le dernier nœud épuise son énergie (Last Node Died, LND).



*Figure 3.19 – Epuisement d'énergie du premier et dernier nœud de chaque protocole.*

Selon la Figure 3.19, pour le protocole CBFCM, le premier nœud devient inactif à l'itération 600, tandis que le dernier nœud épuise son énergie à l'itération 4672. En comparaison, pour le protocole Improved CBFCM, le premier nœud cesse de fonctionner dès l'itération 309, alors que le dernier nœud reste actif jusqu'à l'itération 6482. Ces résultats indiquent que, bien que le protocole CBFCM présente une période de stabilité initiale plus longue, le protocole Improved CBFCM parvient à prolonger significativement la durée de vie globale du réseau. Cette amélioration des performances est essentiellement attribuée à l'optimisation de la position du sink.

### 3.8 Conclusion

Dans ce chapitre, une étude comparative a tout d'abord été menée entre les algorithmes de clustering FCM, K-Means et K-Medoids, permettant d'analyser leurs performances respectives dans le contexte des réseaux de capteurs corporels (WBAN). Par la suite, une évaluation des performances de deux protocoles de routage coopératif basés sur le clustering a été réalisée, à savoir les protocoles CBFCM et Improved CBFCM. Le protocole Improved CBFCM introduit deux mécanismes essentiels d'optimisation. D'une part, il adopte une sélection dynamique des Cluster-Heads (CHs)

parmi les membres des clusters en fonction de critères énergétiques. D'autre part, il permet aux nœuds situés à proximité des sinks de transmettre directement les données collectées, tout en optimisant la position du sink 2 afin de mieux équilibrer la consommation énergétique dans le réseau WBAN. Cette nouvelle approche à haut rendement permet ainsi de réduire la consommation énergétique globale, d'améliorer la stabilité du réseau et de prolonger significativement sa durée de vie opérationnelle.

# Routage énergétique basé sur l'apprentissage automatique pour les réseaux de capteurs corporels sans fil

## Sommaire

---

<b>4.1</b>	<b>Introduction</b>	<b>79</b>
<b>4.2</b>	<b>Travaux liés</b>	<b>81</b>
<b>4.3</b>	<b>Modèle de réseaux de capteurs</b>	<b>84</b>
4.3.1	Modèle de système	84
4.3.2	Modèle énergétique	85
<b>4.4</b>	<b>Algorithmes du Machine Learning utilisés</b>	<b>86</b>
4.4.1	Machine Learning	86
4.4.2	Algorithme "Decision tree"	86
4.4.3	Algorithme "K-Nearest Neighbors"	87
4.4.4	Algorithme "Support Vector Machine"	87
4.4.5	Algorithme "Linear Regression"	88
<b>4.5</b>	<b>Résultats et discussions</b>	<b>89</b>
<b>4.6</b>	<b>Etude comparative</b>	<b>91</b>
<b>4.7</b>	<b>Conclusion</b>	<b>95</b>

---

## 4.1 Introduction

Les réseaux corporels sans fil (Wireless Body Area Networks, WBAN) sont constitués de nuds capteurs à faible consommation déployés sur ou à l'intérieur du corps humain pour surveiller des paramètres physiologiques [25]. En raison des contraintes énergétiques propres aux WBAN, des mécanismes de routage efficaces sont essentiels pour prolonger la durée de vie du réseau tout en assurant une transmission fiable des données. Le routage conscient de l'énergie joue un rôle crucial dans l'optimisation de la consommation énergétique, la réduction des transmissions inutiles et l'équilibrage de l'utilisation de l'énergie entre les nuds. Contrairement aux réseaux sans fil

traditionnels [98], les nuds des WBAN évoluent dans des environnements hautement dynamiques, souvent confrontés à des défis de mobilité, des interférences dues au corps humain et des limitations énergétiques strictes. Pour faire face à ces défis, les protocoles de routage sensibles à l'énergie intègrent des stratégies telles que la communication multi-sauts [99], le contrôle adaptatif de la puissance de transmission [100] et la sélection intelligente des nuds relais [101], afin d'améliorer l'efficacité énergétique.

Les protocoles de routage traditionnels dans les WBAN sont conçus pour garantir une transmission efficace des données tout en minimisant la consommation d'énergie et en maintenant la stabilité du réseau. Ces protocoles se répartissent en plusieurs catégories : les approches sensibles à la température, économes en énergie, sensibles à la qualité de service (QoS), et basées sur le regroupement. Les protocoles sensibles à la température, tels que TARA (Thermal-Aware Routing Algorithm) [102] et HPR (Hotspot Preventing Routing) [103], visent à prévenir la surchauffe des capteurs en sélectionnant dynamiquement des chemins à faible élévation thermique. Les protocoles économes en énergie, comme LAEEBA (Link-Aware and Energy-Efficient Routing) [104] et M-ATTEMPT (Mobile Adaptive Threshold-based Thermal-aware Energy-efficient Multi-hop Protocol) [105], optimisent la consommation énergétique pour prolonger la durée de vie du réseau. Le routage sensible à la QoS assure une transmission fiable avec une faible latence, comme dans DMQoS (Dynamic Multihop QoS-Aware Routing) [106] ou les protocoles WBAN basés sur la priorité, qui prennent en compte l'urgence médicale. Le routage basé sur le regroupement organise les nuds en clusters afin de réduire les transmissions redondantes, à l'instar des protocoles ANYBODY (Adaptive Network for Body Area Networks) [107] et RE-ATTEMPT (Residual Energy Adaptive Thermal-aware Multi-hop Protocol) [108], qui équilibrent efficacement l'utilisation de l'énergie.

Malgré leur efficacité, les protocoles de routage traditionnels des WBAN souffrent souvent d'une adaptabilité limitée face aux dynamiques du réseau en temps réel. Nombre d'entre eux reposent sur des règles prédéfinies plutôt que sur une prise de décision fondée sur l'apprentissage, ce qui peut entraîner une utilisation inefficace de l'énergie dans des conditions imprévisibles. Par ailleurs, les protocoles sensibles à la température peuvent entraîner des retards accrus dans la transmission des paquets, tandis que les protocoles économes en énergie peuvent compromettre la QoS dans les applications critiques.

Cependant, les avancées récentes en apprentissage automatique (Machine Learning, ML) et en apprentissage par renforcement (Reinforcement Learning, RL) ont permis le développement de stratégies de routage intelligentes, capables de s'adapter dynamiquement aux conditions du réseau. Les approches basées sur le ML, telles que les arbres de décision, les  $k$ -plus proches voisins ( $k$ -NN) et les machines à vecteurs de support (SVM), permettent de prédire la consommation énergétique de chaque transmission, facilitant ainsi un acheminement optimisé des paquets. Les techniques de RL, comme les réseaux de neurones profonds pour l'apprentissage Q (Deep Q-Networks,

DQN) [109] et l'optimisation proximale des politiques (Proximal Policy Optimization, PPO) [110], améliorent encore davantage le routage adaptatif en s'appuyant sur les retours environnementaux pour optimiser l'efficacité énergétique à long terme. En intégrant les techniques de routage sensibles à l'énergie avec des modèles ML et RL, les WBAN peuvent atteindre une efficacité accrue, une durée de vie opérationnelle prolongée et une fiabilité améliorée de la transmission, les rendant particulièrement adaptés à la surveillance continue de la santé.

Le présent travail propose une approche structurée visant à optimiser l'efficacité réseau dans les WBAN en s'appuyant sur des modèles d'apprentissage automatique pour prédire la consommation énergétique. En simulant la transmission de paquets à travers les nœuds capteurs et en utilisant des modèles décisionnels tels que les arbres de décision, les k-NN, les SVM et la régression linéaire, le système assure une utilisation énergétique efficace. La simulation permet de suivre des indicateurs clés tels que l'épuisement des nœuds, l'évolution de l'énergie et le débit, fournissant ainsi des informations précieuses sur la longévité et l'efficacité du réseau. La visualisation des résultats facilite par ailleurs l'analyse comparative de l'efficacité des différents modèles sur la prolongation de la durée de vie du réseau.

Le reste du chapitre est structuré comme suit : la section 2 présente un état de l'art des travaux existants. La section 3 décrit le modèle de réseau de capteurs, incluant le modèle système et le modèle énergétique. La section 4 propose une présentation synthétique des algorithmes d'apprentissage automatique utilisés. La section 5 expose les résultats et leur discussion, tandis que la section 6 propose une étude comparative avec la littérature existante. Enfin, la section 7 conclut l'étude et propose des perspectives de recherche.

## 4.2 Travaux liés

Cette section présente une revue synthétique des divers protocoles de routage proposés pour les réseaux corporels sans fil (Wireless Body Area Networks, WBAN), en mettant l'accent sur l'efficacité énergétique, considérée comme un axe de recherche majeur visant à prolonger la durée de vie du réseau tout en assurant une communication fiable. Plusieurs techniques ont été proposées, couvrant les protocoles de routage, les algorithmes d'optimisation, les méthodes de regroupement (clustering) et les approches basées sur l'apprentissage automatique. De nombreuses études ont exploré des protocoles de routage sensibles à l'énergie pour améliorer les performances des WBAN.

Goel et al. [111] ont introduit la technique EEART (Energy-Efficient Adaptive Routing Technique), qui combine agrégation adaptative, regroupement, planification coopérative inter-couches, et optimisation par intelligence collective. Le mécanisme de regroupement permet de simplifier la gestion du réseau, de réduire les communi-

cations directes et déquilibrer la charge entre les nuds, ce qui prévient la congestion et prolonge la durée de vie du réseau. Les résultats montrent que EEART améliore significativement l'efficacité énergétique et réduit la latence, avec une amélioration de l'ordre de 30 à 35 %, tout en dépassant les protocoles de routage existants en termes de débit et de taux de livraison de paquets (Packet Delivery Ratio, PDR).

Dans [112], les auteurs comparent deux algorithmes de clustering : CHSFL (Cluster Head Selection based on Fuzzy Logic) et sa version améliorée. Les deux utilisent la méthode FCM (Fuzzy C-Means) pour le regroupement des nuds, suivie d'une sélection du chef de cluster via un système d'inférence floue prenant en compte l'énergie résiduelle (RE) et la proximité du puits (sink) pour calculer la probabilité de sélection du chef de cluster (CHEP). Dans CHSFL, tous les nuds participent au clustering, tandis que la version améliorée exclut les nuds proches du puits afin d'optimiser l'efficacité. Les simulations indiquent une amélioration de 34 % de la durée de vie du réseau avec la version améliorée.

Sidhoum et al. [113] ont proposé une approche de routage en chaîne pour les WBAN, basée sur la formation de chaînes de nuds capteurs selon une matrice de distances. Trois variantes ont été développées : la première construit une chaîne unique via les distances minimales ; les deuxième et troisième repositionnent le puits en créant un cluster unique par la méthode FCM, dont le centre devient la nouvelle position du puits. La troisième approche, comparée à RE-ATTEMPT et PSOBAN, démontre des économies d'énergie substantielles.

Vyas et Gupta [114] ont proposé un système WBAN sécurisé pour le suivi de santé en continu, intégrant un cloud basé sur le machine learning qui s'adapte aux nouvelles données cliniques et assure un suivi en temps réel des patients, indépendamment de leur localisation. Akbar et al. [115] ont introduit le protocole REMR (Region-Based Energy-Efficient Multipath Routing), destiné à améliorer la longévité des capteurs dans un système de surveillance de la santé. Le réseau est segmenté en clusters, avec un nud désigné par région pour la transmission et l'agrégation. La consommation d'énergie est équilibrée entre les nuds afin de prévenir une décharge prématurée.

Liya et Arun [116] ont conçu un schéma d'agrégation de données économe en énergie fondé sur l'optimisation par essaim d'abeilles (Bee Swarm Optimization). Ce protocole sélectionne les chefs de cluster les plus adaptés parmi un ensemble de candidats aléatoires, réduisant les retransmissions et gérant la congestion.

Samarji et al. [117] ont développé ERQTM (Energy-Efficient Routing and QoS Traffic Management), basé sur un algorithme génétique pour sélectionner le chef de cluster optimal selon l'énergie résiduelle, la consommation, l'impact de l'atténuation du signal et la distance à la station de base. Ce protocole donne la priorité aux données d'urgence, minimisant ainsi les délais.

Hajiloovakil et al. [118] ont réduit la consommation d'énergie grâce à une méthode de compression de données fondée sur le codage de Huffman modifié. Par rapport à la méthode NIS, cette technique permet d'économiser 1770 unités d'énergie et d'aug-

menter de 11,8 % l'efficacité énergétique.

Shemim et U. Witkowski [119] ont évalué plusieurs protocoles énergétiquement efficaces sur des critères tels que le débit, le nombre de nuds vivants/morts et la durée de vie moyenne du réseau. Leur protocole montre des performances supérieures en matière de longévité et d'optimisation énergétique.

Dans [120], une technique d'optimisation a été développée pour remédier aux mauvaises conditions de canal, en corrélant le temps d'attente et la longueur des trames pour améliorer le taux de livraison et l'efficacité énergétique. Toutefois, des perfectionnements sont requis pour maximiser la QoS.

Les auteurs de [121] ont proposé une technique de regroupement pour prolonger la durée de vie des implants médicaux, fondée sur une version modifiée de LEACH. Les données critiques sont transmises immédiatement, tandis que les données non urgentes sont agrégées. L'étude ne prend cependant pas en compte certains paramètres de routage essentiels.

Bilandi et al. [122] ont introduit un protocole fondé sur l'optimisation par essaim particulière (PSO), tenant compte des distances et de l'énergie résiduelle pour optimiser la sélection des relais entre source et puits. Les résultats montrent une supériorité en matière d'énergie résiduelle.

Khanna et al. [123] ont développé M-SIMPLE (Modified SIMPLE), un protocole à niveaux multiples permettant les communications mono- et multi-sauts. Les nuds parents sont sélectionnés via une fonction de coût tenant compte de l'énergie et de la distance au puits.

Khan et al. [124] ont proposé ZE-QoS, un protocole sensible à l'énergie et à la QoS, sélectionnant des chemins optimaux selon le coût, le délai et la fiabilité. Dans un scénario hospitalier, ZE-QoS surpasse DM-QoS et noRouting.

Dans [104], LAEEBA a été introduit comme protocole sensible au lien et à l'énergie. Il combine communications mono- et multi-sauts, sélectionnant les nuds à forte énergie et proches du puits. Il réduit l'atténuation du signal et améliore la fiabilité.

Javaid et al. [105] ont développé M-ATTEMPT, un protocole thermique et économe en énergie, utilisant la communication directe pour les données critiques et la communication multi-sauts pour les autres. Un modèle d'optimisation linéaire est employé pour la gestion énergétique.

Razzaque et al. [106] ont introduit DM-QoS, un protocole de routage multi-objectif qui équilibre délai, fiabilité et efficacité énergétique via une optimisation lexicographique.

Bag et Bassiouni [103] ont développé HPR (Hotspot Preventing Routing), surpassant TARA et le routage à saut minimal en évitant les zones de surchauffe et en réduisant les délais.

Tang et al. [102] ont proposé un protocole thermique redirigeant les données hors des zones à haute température. Chaque nud estime la température de ses voisins et adapte son routage pour maintenir la charge thermique équilibrée.

Malgré ces avancées, il subsiste un besoin de solutions plus robustes pour prolonger la durée de vie du réseau, réduire le délai bout-en-bout et optimiser la consommation énergétique des WBAN.

### 4.3 Modèle de réseaux de capteurs

Dans le développement des WBAN (Wireless Body Area Networks), la durée de vie du réseau et la consommation énergétique représentent des défis majeurs, car le rechargement ou le remplacement des batteries des biocapteurs peut engendrer un inconfort physique pour les patients. La préservation de l'énergie constitue ainsi un enjeu essentiel, nécessitant une utilisation optimisée des batteries afin de prolonger la durée de fonctionnement du réseau. Les nuds biocapteurs transmettent les données vers le puits (sink) en passant par des nuds relais, en sélectionnant les routes qui minimisent à la fois la distance et la consommation énergétique.

Le présent travail propose une stratégie de transmission de données optimale et efficace, en s'appuyant sur un modèle énergétique pour calculer la consommation d'énergie et sur des modèles d'atténuation de signal (path loss) pour évaluer la dégradation du signal au cours de la transmission. Des algorithmes basés sur l'apprentissage automatique (Machine Learning) sont utilisés pour déterminer la meilleure route de transmission des données dans un environnement WBAN.

#### 4.3.1 Modèle de système

Le réseau WBAN est constitué de huit nuds capteurs biologiques et d'un nud collecteur. Chaque nud capte et transmet les données vers le collecteur en empruntant la route la plus courte. Tous les nuds capteurs biologiques reçoivent initialement une quantité égale d'énergie destinée à la communication réseau. Le déploiement des nuds capteurs sur le corps humain est présenté en détail dans le Tableau 4.1.

**Tableau 4.1** – Déploiement des nuds capteurs biologiques sur le corps humain.

Nud	Position (X, Y)
S1	(0.55, 1)
S2	(0.25, 1)
S3	(0.28, 0.2)
S4	(0.48, 0.25)
S5	(0.3, 0.5)
S6	(0.5, 0.5)
S7	(0.45, 0.13)
S8	(0.35, 0.9)
Sink	(0.4, 1.1)

### 4.3.2 Modèle énergétique

Le travail proposé utilise un modèle radio de premier ordre pour estimer l'énergie consommée par un nud lors de la transmission des données [81,125]. Selon ce modèle, l'énergie de transmission nécessaire à un nud pour relayer un paquet de données de  $W$  bits sur une distance  $D$  est calculée comme suit :

$$E_{\text{TX}}(W, D) = W \cdot E_{\text{TX-elec}} + W \cdot E_{\text{Amp}} \cdot D^{\text{PLI}} \quad (4.1)$$

Le modèle prend également en compte la consommation d'énergie des nuds lors de la réception d'un paquet de données de  $W$  bits, calculée comme suit :

$$E_{\text{RX}}(W) = W \cdot E_{\text{RX-elec}} \quad (4.2)$$

En utilisant le même modèle, l'énergie consommée par les nuds pour l'agrégation de  $W$  bits est calculée comme suit :

$$E_{\text{DA}}(W) = W \cdot E_{\text{DA}} \quad (4.3)$$

Ici,  $E_{\text{TX-elec}}$ ,  $E_{\text{RX-elec}}$  et  $E_{\text{Amp}}$  représentent respectivement la consommation d'énergie par bit dans les circuits de transmission, de réception et d'amplification du nud en fonctionnement.  $E_{\text{DA}}$  désigne la consommation d'énergie liée à l'agrégation des données par bit. L'indice d'atténuation de propagation (Path Loss Index) tient compte des pertes supplémentaires dues aux canaux de communication corporelle.

Dans l'approche proposée, les pertes d'énergie liées au traitement par le nud sont considérées comme négligeables par rapport à celles engendrées par la transmission des données, et sont donc ignorées [126].

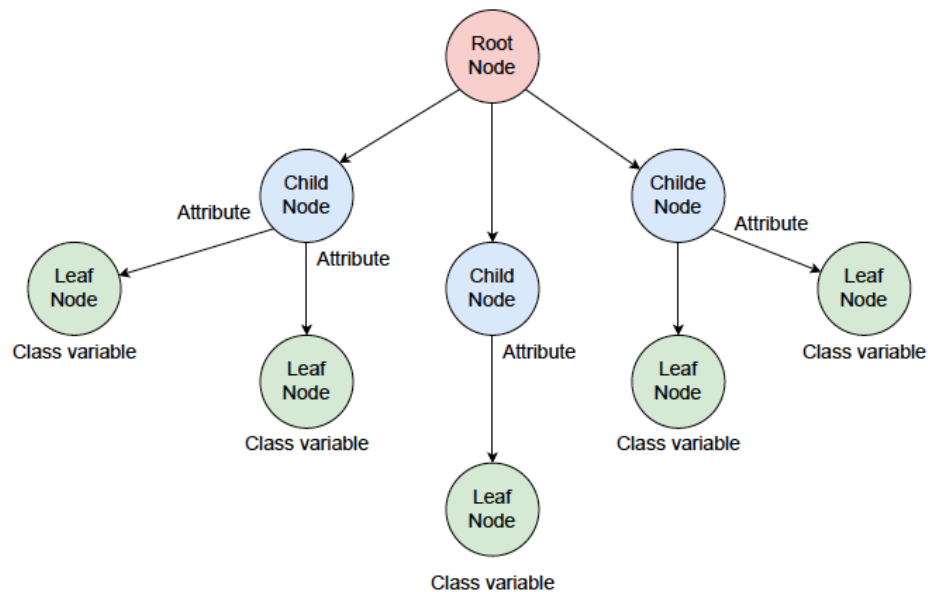
## 4.4 Algorithmes du Machine Learning utilisés

### 4.4.1 Machine Learning

L'apprentissage automatique (Machine Learning, ML) est un sous-domaine de l'intelligence artificielle (IA) qui permet aux systèmes d'apprendre des motifs à partir de données et de formuler des prédictions ou des décisions sans être explicitement programmés. Il englobe l'apprentissage supervisé (données étiquetées), l'apprentissage non supervisé (données non étiquetées) et l'apprentissage par renforcement (apprentissage basé sur un système de récompenses). Les algorithmes de ML, tels que les réseaux de neurones, les arbres de décision et les machines à vecteurs de support, améliorent leurs performances au fil du temps en s'adaptant à de nouvelles données.

### 4.4.2 Algorithme "Decision tree"

L'algorithme de l'arbre de décision [127] est une technique d'apprentissage supervisé utilisée pour la classification et la régression. Il divise les données en branches selon les valeurs des caractéristiques, formant ainsi une structure arborescente dans laquelle chaque nœud interne représente une décision, chaque branche correspond à un résultat possible, et chaque feuille représente une prédiction finale (voir Figure 4.1).




*Figure 4.1 – Structure de l'algorithme "Decision Tree".*

L'algorithme choisit les divisions à l'aide de critères tels que l'impureté de Gini ou l'entropie (gain d'information) pour la classification, et l'erreur quadratique moyenne (MSE) pour la régression. Il est simple, interprétable et efficace pour les données structurées, mais il est sujet au surapprentissage s'il n'est pas accompagné de tech-

niques délagage ou de régularisation. La Figure 4.1 illustre la structure dun arbre de décision.

### 4.4.3 Algorithme "K-Nearest Neighbors"

Lalgorithme des k plus proches voisins (K-Nearest Neighbors, KNN) [128] est une méthode d'apprentissage supervisé simple et non paramétrique, utilisée pour la classification et la régression. Il attribue une classe à un point de données en fonction de la majorité des classes parmi ses k plus proches voisins, ou prédit une valeur en calculant la moyenne de leurs sorties. La proximité entre les points est déterminée à laide de métriques de distance telles que les distances euclidiennes, de Manhattan ou de Minkowski. Bien que facile à mettre en uvre, le KNN peut savérer coûteux en calcul pour les ensembles de données volumineux.




*Figure 4.2 – K-Nearest Neighbors.*

### 4.4.4 Algorithme "Support Vector Machine"

Lalgorithme des machines à vecteurs de support (Support Vector Machine, SVM) [51] est une méthode d'apprentissage supervisé utilisée pour la classification et la régression. Il consiste à déterminer l'hyperplan optimal qui maximise la marge de séparation entre les différentes classes dans un espace de grande dimension.

Le SVM utilise des fonctions noyaux (kernels) telles que les noyaux linéaire, polynomial ou à base de fonctions radiales (RBF) pour traiter des distributions de données

complexes. Il est particulièrement efficace pour les ensembles de données de petite à moyenne taille, bien qu'il puisse devenir coûteux en ressources de calcul lorsqu'il est appliqué à de grandes bases de données.




*Figure 4.3 – Classification des points de données utilisant l'algorithme SVM.*

#### 4.4.5 Algorithme "Linear Regression"

La régression linéaire [45] est un algorithme d'apprentissage supervisé qui modélise la relation entre une variable dépendante continue et une ou plusieurs variables indépendantes à l'aide d'une équation linéaire. Elle vise à minimiser la somme des carrés des écarts entre les valeurs réelles et les valeurs prédites.

La régression linéaire simple ajuste une droite aux données, tandis que la régression linéaire multiple s'appuie sur un hyperplan. Elle est couramment utilisée dans des applications telles que la prévision de tendances ou la modélisation financière. Ses hypothèses incluent la linéarité des relations, une faible multicolinéarité entre les variables explicatives, ainsi qu'une distribution normale des résidus. Des techniques de régularisation telles que Lasso et Ridge permettent d'améliorer les performances du modèle et de limiter le surapprentissage.



*Figure 4.4 – Algorithme "Linear Regression".*


## 4.5 Résultats et discussions

Dans cette section, nous évaluons quatre approches fondées sur des modèles d'apprentissage automatique, à savoir l'arbre de décision (Decision Tree, DT), les k plus proches voisins (K-Nearest Neighbors, KNN), la machine à vecteurs de support (Support Vector Machine, SVM) et la régression linéaire (Linear Regression, LinReg), dans le contexte du routage écoénergétique au sein des WBAN.

L'analyse vise à prolonger la durée de vie du réseau en étudiant l'évolution de l'énergie résiduelle au cours du temps, le nombre de nuds vivants par cycle, ainsi que le nombre total de nuds encore actifs durant toute la simulation. Le Tableau 4.2 présente une synthèse des paramètres utilisés dans l'environnement de simulation, lequel a été implémenté et évalué à l'aide du langage Python.


*Tableau 4.2 – Paramètres de simulation WBAN*

N <sup>o</sup>	Paramètre	Description	Valeur (Unité)
1	Énergie initiale	Énergie initiale par nud	0.6 J
2	Nombre de nuds	Nombre total de nuds capteurs	8 nuds
3	Position du collecteur	Placé au centre du corps	1 nud
4	Taille des paquets	Nombre total de bits transmis	4000 bits
5	Nombre de cycles	Nombre total de rounds de simulation	10000 rounds



*Figure 4.5 – Residual Energy vs. Rounds.*

La Figure 4.5 présente la comparaison de l'énergie résiduelle au fil des cycles de simulation pour quatre modèles d'apprentissage automatique : Decision Tree (DT), k-Nearest Neighbors (KNN), Support Vector Machine (SVM) et Régression Linéaire (LinReg) appliqués au routage dans les WBAN. À mesure que la simulation progresse, tous les modèles affichent une tendance décroissante de l'énergie résiduelle, traduisant une consommation énergétique continue. Parmi eux, DT maintient l'énergie résiduelle la plus élevée tout au long de l'expérience, signe d'une efficacité énergétique supérieure. En revanche, SVM subit une déplétion plus rapide, révélant une utilisation moins efficace des ressources. KNN et LinReg offrent des performances intermédiaires, avec un rythme de déplétion plus lent que SVM, mais plus rapide que DT. La convergence finale de toutes les courbes atteste de l'épuisement complet de l'énergie à terme. Ces résultats suggèrent que, pour un routage économe en énergie dans les WBAN, DT constitue l'option la plus pertinente, tandis que SVM nécessite une optimisation supplémentaire afin d'améliorer sa durabilité énergétique.



*Figure 4.6 – Alive nodes vs. Rounds.*

La Figure 4.6 illustre l'évolution du nombre de nuds actifs au cours du temps pour différents modèles d'apprentissage automatique appliqués au routage dans les WBAN, à savoir Decision Tree (DT), K-Nearest Neighbors (KNN), Support Vector Machine (SVM) et Régression Linéaire (LinReg). Les résultats montrent que le modèle DT conserve l'ensemble des nuds actifs pendant la durée la plus longue, témoignant d'une efficacité énergétique supérieure. À l'inverse, le modèle SVM présente la chute la plus précoce du nombre de nuds actifs, ce qui suggère une mauvaise distribution de l'énergie.

Les modèles KNN et LinReg affichent une déplétion plus progressive, mais leur performance reste inférieure à celle de DT. Une fois la phase de déplétion amorcée, DT subit une chute rapide du nombre de nuds actifs ; néanmoins, sa capacité à maintenir tous les nuds en vie plus longtemps indique une gestion énergétique globale plus efficace. Ces résultats mettent en évidence la supériorité de DT pour maximiser la durée de vie du réseau, tandis que le modèle SVM, en l'état, apparaît inadapté à un routage sensible à l'énergie dans les WBAN, sauf en cas d'optimisations supplémentaires.

## 4.6 Etude comparative


Cette section présente une analyse comparative entre les approches traditionnelles PSOBAN, RE-ATTEMPT et la troisième méthode proposée par Sidhoum [113] et les modèles basés sur l'apprentissage automatique : Decision Tree (DT), K-Nearest

Neighbors (KNN), Support Vector Machine (SVM) et Régression Linéaire (LinReg). Les protocoles PSOBAN et RE-ATTEMPT sont décrits dans l'article de Bilandi [122], tandis que les auteurs de [113] proposent trois approches distinctes, la troisième étant une méthode en chaîne fondée sur le clustering flou (Fuzzy C-Means, FCM), qui a obtenu les meilleurs résultats.

La comparaison, présentée dans le Tableau 4.3, s'articule autour de trois indicateurs de performance clés : FND (First Node Died) représentant le tour de mort du premier nud, LND (Last Node Died) correspondant au tour de mort du dernier nud, et le débit mesuré en nombre de paquets reçus. Ces métriques permettent d'évaluer la longévité du réseau, son efficacité énergétique, ainsi que sa capacité de transmission, éléments cruciaux dans le contexte des WBAN.

**Tableau 4.3** – *Évaluation comparative entre les approches traditionnelles et les modèles ML en termes de FND, LND et débit*

Méthode	RE-ATTEMPT	PSOBAN	3 <sup>e</sup> ap-proche	DT	KNN	SVM	LinReg
FND (round)	2480	3800	6836	8488	8578	7759	8541
LND (round)	8912	8995	8930	9643	9213	7759	9150
Débit (paquets reçus)	21523	30900	37001	73595	71347	62064	71127




**Figure 4.7** – Approches traditionnelles et modèles basés sur la ML en termes de FND, LND et débit.

La comparaison des performances entre différentes techniques de routage dans les WBAN, présentée dans le Tableau 4.3 et la Figure 4.7, met en évidence la supériorité des modèles basés sur l'apprentissage automatique par rapport aux approches traditionnelles, en termes de longévité du réseau et de débit. Les tours correspondant à la mort du premier nud indiquent que les méthodes KNN (8578 tours) et la Régression Linéaire (8541 tours) surpassent largement les approches conventionnelles telles que RE-ATTEMPT (2480 tours) et PSOBAN (3800 tours), démontrant une efficacité énergétique nettement améliorée. De même, les tours de mort du dernier nud confirment cette tendance, avec le DT (9643 tours) assurant la durée de vie la plus longue du réseau. En ce qui concerne l'efficacité de la transmission des données, les valeurs de débit révèlent que les modèles d'apprentissage automatique, en particulier DT (73595 paquets), KNN (71347 paquets) et la Régression Linéaire (71127 paquets), traitent un nombre de paquets bien supérieur à celui des techniques traditionnelles telles que RE-ATTEMPT (21523 paquets). Ces résultats suggèrent que les approches fondées sur l'apprentissage automatique, en particulier le DT, sont particulièrement efficaces pour améliorer l'efficacité énergétique, la durée de vie du réseau et les performances de transmission des données dans les WBAN.

**Tableau 4.4** – Comparaison des approches traditionnelles et des modèles ML selon l'énergie résiduelle (en Joules)

Rounds	RE-ATTEMPT	PSOBAN	3 <sup>e</sup> approche	DT	KNN	SVM	LinReg
2000	2.6894	3.3661	3.4861	3.7545	3.7230	3.5627	3.7196
4000	1.6029	2.2095	2.1722	2.7090	2.6460	2.3254	2.6392
6000	0.9041	1.2652	0.8583	1.6635	1.5690	1.0880	1.5588
8000	0.3359	0.3990	0.1239	0.6180	0.4920	–	0.4785



**Figure 4.8** – Énergie résiduelle aux différents rounds.

Le Tableau 4.4 et la Figure 4.8 présentent une étude comparative parallèle de l'énergie résiduelle (en joules) pour différentes méthodes de routage dans les WBAN, mesurée aux 2000, 4000, 6000 et 8000 tours. Les résultats montrent que les algorithmes Decision Tree (DT), K-Nearest Neighbors (KNN) et Régression Linéaire conservent systématiquement l'énergie résiduelle la plus élevée à travers toutes les phases, avec une valeur atteignant 3,7545 J au tour 2000 pour DT et maintenant encore 0,6180 J au tour 8000. En revanche, la méthode Support Vector Machine (SVM) subit une chute brutale, ses valeurs étant absentes au 8000 tour, ce qui suggère une déplétion complète de l'énergie. La méthode de Sidhoum affiche une forte consommation énergétique, ne

conservant que 0,1239 J au terme du tour 8000. Par ailleurs, les approches PSOBAN et RE-ATTEMPT [122] présentent des performances modérées, mais restent inférieures à celles de DT, KNN et de la Régression Linéaire. Globalement, ces résultats désignent DT et KNN comme les méthodes les plus efficaces sur le plan énergétique pour le routage dans les WBAN, ce qui en fait des candidats prometteurs pour prolonger la durée de vie du réseau.

## 4.7 Conclusion

Ce chapitre examine l'application de divers algorithmes d'apprentissage automatique (ML) pour résoudre le problème de routage dans les réseaux WBAN. L'analyse évalue plusieurs modèles d'apprentissage supervisé en se basant sur trois critères essentiels : l'énergie résiduelle, la durée de vie du réseau et le débit de transmission. Parmi les modèles analysés, l'algorithme Decision Tree (DT) se distingue par une énergie résiduelle élevée tout au long de la simulation, traduisant une efficacité énergétique supérieure. À l'inverse, la méthode Support Vector Machine (SVM) présente une déplétion énergétique plus rapide, illustrant une gestion sous-optimale des ressources énergétiques.

Bien que DT consomme l'énergie plus lentement que SVM, il parvient à maintenir un équilibre favorable entre performance et efficacité énergétique. En termes de durée de vie du réseau, DT conserve le plus grand nombre de nuds actifs tout au long de la simulation, tandis que SVM est associé à une déplétion précoce, suggérant une faible capacité de gestion énergétique. Ces résultats confirment la supériorité des approches basées sur le ML, notamment DT, KNN et la Régression Linéaire (LinReg), pour améliorer l'efficacité énergétique, la longévité du réseau et les performances de transmission de données dans les WBAN.

La comparaison des performances souligne également que KNN (8578 tours) et LinReg (8541 tours) dépassent largement les méthodes classiques telles que RE-ATTEMPT et PSOBAN en ce qui concerne le tour de mort du premier nud, confirmant leur efficacité. De plus, l'analyse du débit révèle que DT traite un nombre de paquets nettement plus élevé, ce qui le rend particulièrement adapté aux exigences de transmission dans les environnements WBAN. Enfin, l'étude de l'énergie résiduelle aux différentes étapes de la simulation renforce la conclusion selon laquelle DT est le modèle le plus efficient énergétiquement, surpassant KNN, LinReg, SVM et les méthodes traditionnelles.

Pour les recherches futures, il serait pertinent d'explorer des modèles hybrides adaptatifs intégrant l'apprentissage par renforcement multi-agent, des fonctions de récompense sensibles à l'énergie et des mécanismes d'optimisation en temps réel, afin de renforcer la durabilité des WBAN.

# Conclusion générale

Les réseaux de capteurs corporels sans fil (WBAN) représentent une technologie émergente aux applications prometteuses, particulièrement dans le domaine médical et du bien-être. Ces réseaux spécialisés, composés de capteurs miniaturisés et intelligents implantés, portés ou placés à proximité du corps humain, permettent une surveillance continue et non invasive de paramètres physiologiques et environnementaux. Contrairement aux réseaux de capteurs traditionnels, les WBAN se distinguent par leurs exigences uniques en matière de fiabilité, de latence ultra-faible et d'efficacité énergétique, tout en devant s'adapter aux contraintes spécifiques liées à la mobilité du corps humain et à la sécurité des données sensibles. Leur capacité à transmettre des données vitales en temps réel tout en optimisant la consommation d'énergie ouvre la voie à de nouvelles possibilités en télémédecine, assistance personnalisée et diagnostic précoce, positionnant les WBAN comme une pierre angulaire des futures solutions de santé connectée et des systèmes médicaux intelligents.

Le routage dans les réseaux de capteurs corporels sans fil (WBAN) représente un domaine complexe et essentiel, où les protocoles doivent concilier efficacité énergétique, faible latence et fiabilité pour répondre aux exigences critiques des applications médicales et de surveillance en temps réel. Contrairement aux réseaux de capteurs traditionnels, les WBAN doivent s'adapter aux contraintes dynamiques liées aux mouvements du corps, aux interférences et à la sécurité des données, tout en garantissant une communication robuste entre les nœuds. Les approches de routage hiérarchique, géographique ou adaptatif, ainsi que l'intégration de techniques avancées comme l'intelligence artificielle, offrent des solutions prometteuses pour optimiser les performances du réseau. Cependant, des défis persistent, notamment en matière de dévolutivité, d'autonomie énergétique et de gestion des données sensibles, soulignant la nécessité de recherches futures pour des protocoles plus résilients et adaptatifs dans ce domaine en pleine expansion.

Les travaux de recherche approfondis réalisés dans le cadre de cette thèse ont permis d'élaborer deux contributions majeures dans le domaine du routage pour les réseaux de capteurs corporels sans fil (WBAN).

Dans le cadre de cette première contribution, une analyse comparative approfondie

a été effectuée entre trois algorithmes de regroupement, à savoir le Fuzzy C-Means (FCM), le K-Means et le K-Medoids, afin d'évaluer leurs performances respectives dans l'environnement spécifique des réseaux de capteurs corporels sans fil (WBAN). Cette étude a permis de mettre en évidence les forces et limites de chaque méthode de clustering dans des scénarios de déploiement réalistes. Par la suite, une évaluation des performances de deux protocoles de routage coopératif reposant sur des techniques de regroupement a été menée. Les protocoles considérés sont le CBFCM (Clustering-Based Fuzzy C-Means) et sa version améliorée, l'Improved CBFCM, dont l'efficacité énergétique et la stabilité du réseau ont été analysées de manière comparative.

Le protocole Improved CBFCM intègre deux mécanismes clés d'optimisation visant à renforcer l'efficacité énergétique du réseau. D'une part, il met en œuvre une sélection dynamique des nœuds Cluster-Heads (CHs) fondée sur des critères liés à la réserve énergétique des membres au sein de chaque cluster, assurant ainsi une rotation équitable des responsabilités. D'autre part, il autorise les nœuds situés à proximité des sinks à effectuer une transmission directe des données, réduisant ainsi le nombre de sauts intermédiaires. Par ailleurs, la position du second sink est ajustée de manière stratégique afin de mieux répartir la charge de communication et d'équilibrer la consommation énergétique à l'échelle du réseau WBAN.

Cette approche optimisée à haut rendement contribue de manière significative à la réduction de la consommation énergétique globale, à l'amélioration de la stabilité du réseau, ainsi qu'à l'extension substantielle de sa durée de vie opérationnelle, répondant ainsi aux exigences critiques des environnements WBAN.

La seconde contribution s'intéresse à l'exploitation d'algorithmes d'apprentissage automatique (Machine Learning, ML) pour aborder la problématique du routage dans les réseaux de capteurs corporels sans fil (WBAN). L'étude repose sur l'évaluation comparative de plusieurs modèles d'apprentissage supervisé, en s'appuyant sur trois indicateurs de performance majeurs : l'énergie résiduelle, la durée de vie du réseau et le débit de transmission. Parmi les approches examinées, l'algorithme Decision Tree (DT) se distingue par une capacité à maintenir un niveau d'énergie résiduelle élevé tout au long des simulations, attestant d'une meilleure efficacité énergétique. En revanche, le modèle Support Vector Machine (SVM) présente une déplétion plus rapide de l'énergie, révélant une gestion moins efficace des ressources énergétiques dans le contexte du routage WBAN.

Bien que l'algorithme Decision Tree (DT) présente une consommation énergétique plus modérée que la technique Support Vector Machine (SVM), il parvient simultanément à préserver un équilibre optimal entre performances opérationnelles et efficacité énergétique. Du point de vue de la longévité du réseau, DT maintient la proportion la plus élevée de nœuds actifs tout au long des simulations, alors que SVM se caractérise par une déplétion précoce des ressources, révélatrice d'une capacité réduite de gestion énergétique. Ces observations confirment la pertinence des approches fondées sur l'apprentissage automatique en particulier DT, KNN et la Régression Linéaire

pour accroître l'efficacité énergétique, prolonger la durée de vie du réseau et optimiser les performances de transmission de données dans les environnements WBAN.

La comparaison des performances met en évidence la supériorité des modèles DT, KNN et LinReg en matière de durabilité du réseau. En effet, le tour de mort du premier nœud atteint respectivement 8578, 8541 et 8488 tours pour KNN, LinReg et DT, ce qui surpasse de manière significative les protocoles classiques tels que RE-ATTEMPT et PSOBAN, soulignant ainsi leur robustesse énergétique. Par ailleurs, l'analyse du débit de transmission révèle que ces trois modèles sont capables de traiter un volume de paquets nettement plus élevé, répondant ainsi aux contraintes de transmission intensive dans les environnements WBAN. Enfin, l'étude détaillée de l'évolution de l'énergie résiduelle au cours des différentes phases de la simulation confirme que DT, KNN et LinReg présentent les meilleures performances énergétiques, surpassant la méthode SVM et les approches conventionnelles en matière de préservation de l'énergie.

Dans le cadre des perspectives de recherche, il serait judicieux d'explorer le développement de modèles hybrides adaptatifs combinant l'apprentissage par renforcement multi-agent, l'intégration de fonctions de récompense sensibles à la consommation énergétique, ainsi que l'implémentation de mécanismes d'optimisation en temps réel. Une telle approche permettrait de renforcer significativement la durabilité, la résilience et l'efficacité opérationnelle des réseaux WBAN face aux contraintes dynamiques de leur environnement d'exploitation.

# Liste des publications/communications

- [1] Lamia Benlaldj, Mohammed Hicham Hachemi, Mohammed Mhamedi, Mourad Hadjila, and Amina Bekkouche ; " Machine Learning-based Energy-Aware Routing for Wireless Body Area Network", Engineering, Technology & Applied Science Research, Vol. 15, No. 4, Pages : 24472-24477, August 2025, [https ://doi.org/10.48084/etasr.11137](https://doi.org/10.48084/etasr.11137)

# Bibliographie

- [1] S. Kaur and J. Malhotra, “Survey on empirical channel models for wban,” *Int. J. Future Gener. Commun. Netw*, vol. 8, no. 2, pp. 399–410, 2015.
- [2] I. Al-Barazanchi, H. R. Abdulshaheed, and M. S. B. Sidek, “A survey : Issues and challenges of communication technologies in wban,” *Sustainable Engineering and Innovation*, vol. 1, no. 2, dec 2019.
- [3] W. Badreddine, “Communication protocols in wireless body area networks (wban),” 2020.
- [4] K. S. Kwak, S. Ullah, and N. Ullah, “An overview of ieee 802.15.6 standard,” in *2010 3rd International Symposium on Applied Sciences in Biomedical and Communication Technologies (ISABEL 2010)*, Roma, Italy, nov 2010, pp. 1–6.
- [5] E. Ben Hamida, M. M. Alam, M. Maman, and B. Denis, “Short-term link quality estimation for opportunistic and mobility aware routing in wearable body sensors networks,” in *2014 IEEE 10th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, Larnaca, Cyprus, oct 2014, pp. 519–526.
- [6] R. A. Khan and A.-S. K. Pathan, “The state-of-the-art wireless body area sensor networks : A survey,” *International Journal of Distributed Sensor Networks*, vol. 14, no. 4, p. 155014771876899, apr 2018.
- [7] M. Yaghoubi, K. Ahmed, and Y. Miao, “Wireless body area network (wban) : A survey on architecture, technologies, energy consumption, and security challenges,” *Journal of Sensor and Actuator Networks*, vol. 11, no. 4, dec 2022.
- [8] K. Akkaya and M. Younis, “A survey on routing protocols for wireless sensor networks,” *Ad Hoc Networks*, vol. 3, no. 3, pp. 325–349, 2005.
- [9] J. Yick, B. Mukherjee, and D. Ghosal, “Wireless sensor network survey,” *Computer Networks*, vol. 52, no. 12, pp. 2292–2330, 2008.
- [10] O. B. Akan and I. F. Akyildiz, “Event-to-sink reliable transport in wireless sensor networks,” *IEEE/ACM Transactions on Networking*, vol. 13, no. 5, pp. 1003–1016, 2005.

- [11] A. Perrig, R. Szewczyk, V. Wen, D. E. Culler, and J. D. Tygar, “Spins : Security protocols for sensor networks,” *Wireless Networks*, vol. 8, no. 5, pp. 521–534, 2002.
- [12] K. Hasan, K. Biswas, K. Ahmed, N. S. Nafi, and M. S. Islam, “A comprehensive review of wireless body area network,” *Journal of Network and Computer Applications*, vol. 143, pp. 178–198, oct 2019.
- [13] F. T. Zuhra, K. A. Bakar, A. Ahmed, and M. A. Tunio, “Routing protocols in wireless body sensor networks : A comprehensive survey,” *Journal of Network and Computer Applications*, vol. 99, pp. 73–97, dec 2017.
- [14] J. H. Kurunathan, “Study and overview on wban under ieee 802.15.6,” *U.Porto Journal of Engineering*, vol. 1, no. 1, oct 2015.
- [15] S. Bouldjadj, “Sureté de fonctionnement des réseaux de capteurs médicaux,” 2020, unpublished. [Online]. Available : <https://rgdoi.net/10.13140/RG.2.2.20860.62084>
- [16] B. Latré, B. Braem, I. Moerman, C. Blondia, and P. Demeester, “A survey on wireless body area networks,” *Wireless Networks*, vol. 17, no. 1, pp. 1–18, jan 2011.
- [17] *IEEE Standard for Local and metropolitan area networks - Part 15.6 : Wireless Body Area Networks*, Std., 2012.
- [18] V. Mainanwal, M. Gupta, and S. K. Upadhayay, “A survey on wireless body area network : Security technology and its design methodology issue,” in *2015 International Conference on Innovations in Information, Embedded and Communication Systems (ICIECS)*, Coimbatore, India, mar 2015, pp. 1–5.
- [19] “A survey of routing protocols in wireless body sensor networks,” 2015. [Online]. Available : <https://www.mdpi.com/1424-8220/14/1/1322>
- [20] N. Javaid, N. A. Khan, M. Shakir, M. A. Khan, S. H. Bouk, and Z. A. Khan, “Ubiquitous healthcare in wireless body area networks - a survey,” 2012.
- [21] V. S. Naresh, S. S. Pericherla, P. S. R. Murty, and S. Reddi, “Internet of things in healthcare : Architecture, applications, challenges, and solutions,” *Computer Systems Science and Engineering*, vol. 35, no. 6, pp. 411–421, 2020.
- [22] M. S. Hajar, M. O. Al-Kadri, and H. K. Kalutarage, “A survey on wireless body area networks : architecture, security challenges and research opportunities,” *Computers Security*, vol. 104, p. 102211, may 2021.
- [23] S. Movassaghi, M. Abolhasan, J. Lipman, D. Smith, and A. Jamalipour, “Wireless body area networks : A survey,” *IEEE Communications Surveys Tutorials*, vol. 16, no. 3, pp. 1658–1686, 2014.
- [24] D. Dias and J. P. S. Cunha, “Wearable health devices—vital sign monitoring, systems and technologies,” *Sensors*, vol. 18, no. 8, p. 2414, jul 2018.

- [25] D. S. Bhatti *et al.*, “A survey on wireless wearable body area networks : A perspective of technology and economy,” *Sensors*, vol. 22, no. 20, p. 7722, oct 2022.
- [26] J. Lopez Dino, “Structural design of biosensor : A review,” *Instituto de Ingeniería y Tecnología*, 2023.
- [27] D. Vera, N. Costa, L. Roda-Sanchez, T. Olivares, A. Fernández-Caballero, and A. Pereira, “Body area networks in healthcare : A brief state of the art,” *Applied Sciences*, vol. 9, no. 16, p. 3248, aug 2019.
- [28] L. Zhong *et al.*, “Technological requirements and challenges in wireless body area networks for health monitoring : A comprehensive survey,” *Sensors*, vol. 22, no. 9, p. 3539, may 2022.
- [29] World Health Organization, “Ageing and health (who),” oct 2024. [Online]. Available : <https://www.who.int/news-room/fact-sheets/detail/ageing-and-health>
- [30] C. J. L. Murray, “Confronting the world’s number one killer,” oct 2022. [Online]. Available : <https://www.nature.com/articles/s41591-022-01990-1>
- [31] World Health Organization, “Les 10 principales causes de mortalité,” 2025. [Online]. Available : <https://www.who.int/fr/news-room/fact-sheets/detail/the-top-10-causes-of-death>
- [32] K. Hasan, “A secure and efficient communication framework for software-defined wireless body area network,” Ph.D. dissertation, Griffith University, jun 2020.
- [33] H. C. Keong and M. R. Yuce, “Analysis of a multi-access scheme and asynchronous transmit-only uwb for wireless body area networks,” in *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Minneapolis, MN : IEEE, sep 2009, pp. 6906–6909.
- [34] M. Chen, S. Gonzalez, A. Vasilakos, H. Cao, and V. C. M. Leung, “Body area networks : A survey,” *Mobile Networks and Applications*, vol. 16, no. 2, pp. 171–193, apr 2011.
- [35] “Ieee std 802.15.6-2012, ieee standard for local and metropolitan area networks-part 15.6 : Wireless body area networks,” IEEE, Tech. Rep., 2012.
- [36] T. Benmansour, “Contrôle et surveillance par les réseaux de capteurs corporels sans fil (wban),” 2020.
- [37] A. Natarajan, B. De Silva, K.-K. Yap, and M. Motani, “To hop or not to hop : Network architecture for body sensor networks,” in *2009 6th Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks*. Rome, Italy : IEEE, jun 2009, pp. 1–9.
- [38] G. Lazzi, “Thermal effects of bioimplants,” *IEEE Engineering in Medicine and Biology Magazine*, vol. 24, no. 5, pp. 75–81, sep 2005.

- [39] A. Salam, A. Nadeem, K. Ahsan, M. Sarim, and K. Rizwan, “A class based qos model for wireless body area sensor networks,” 2014.
- [40] J. M. Helm, A. M. Swiergosz, H. S. Haeberle, J. M. Karnuta, J. L. Schaffer, V. E. Krebs, A. I. Spitzer, and P. N. Ramkumar, “Machine learning and artificial intelligence : definitions, applications, and future directions,” *Current reviews in musculoskeletal medicine*, vol. 13, no. 1, pp. 69–76, 2020.
- [41] Y. Baştanlar and M. Özuysal, “Introduction to machine learning,” *miRNomics : MicroRNA biology and computational analysis*, pp. 105–128, 2013.
- [42] S. Badillo, B. Banfai, F. Birzele, I. I. Davydov, L. Hutchinson, T. Kam-Thong, J. Siebourg-Polster, B. Steiert, and J. D. Zhang, “An introduction to machine learning,” *Clinical pharmacology & therapeutics*, vol. 107, no. 4, pp. 871–885, 2020.
- [43] G. Rebala, A. Ravi, and S. Churiwala, *An introduction to machine learning*. Springer, 2019.
- [44] R. Saravanan and P. Sujatha, “A state of art techniques on machine learning algorithms : a perspective of supervised learning approaches in data classification,” in *2018 Second international conference on intelligent computing and control systems (ICICCS)*. IEEE, 2018, pp. 945–949.
- [45] D. Maulud and A. M. Abdulazeez, “A review on linear regression comprehensive in machine learning,” *Journal of applied science and technology trends*, vol. 1, no. 2, pp. 140–147, 2020.
- [46] E. Bisong, “Logistic regression,” in *Building machine learning and deep learning models on google cloud platform : A comprehensive guide for beginners*. Springer, 2019, pp. 243–250.
- [47] X. Zou, Y. Hu, Z. Tian, and K. Shen, “Logistic regression model optimization and case analysis,” in *2019 IEEE 7th international conference on computer science and network technology (ICCSNT)*. IEEE, 2019, pp. 135–139.
- [48] K. Taunk, S. De, S. Verma, and A. Swetapadma, “A brief review of nearest neighbor algorithm for learning and classification,” in *2019 international conference on intelligent computing and control systems (ICCS)*. IEEE, 2019, pp. 1255–1260.
- [49] Z. Zhang, “Introduction to machine learning : k-nearest neighbors,” *Annals of translational medicine*, vol. 4, no. 11, p. 218, 2016.
- [50] Q. Wang, “Support vector machine algorithm in machine learning,” in *2022 IEEE international conference on artificial intelligence and computer applications (ICAICA)*. IEEE, 2022, pp. 750–756.
- [51] S. Suthaharan, “Support vector machine,” in *Machine learning models and algorithms for big data classification : thinking with examples for effective learning*. Springer, 2016, pp. 207–235.

- [52] B. Charbuty and A. Abdulazeez, “Classification based on decision tree algorithm for machine learning,” *Journal of applied science and technology trends*, vol. 2, no. 01, pp. 20–28, 2021.
- [53] Y. Lu, T. Ye, and J. Zheng, “Decision tree algorithm in machine learning,” in *2022 IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA)*. IEEE, 2022, pp. 1014–1017.
- [54] H. A. Salman, A. Kalakech, and A. Steiti, “Random forest algorithm overview,” *Babylonian Journal of Machine Learning*, vol. 2024, pp. 69–79, 2024.
- [55] Y. Liu, Y. Wang, and J. Zhang, “New machine learning algorithm : Random forest,” in *International conference on information computing and applications*. Springer, 2012, pp. 246–252.
- [56] Y.-c. Wu and J.-w. Feng, “Development and application of artificial neural network,” *Wireless Personal Communications*, vol. 102, no. 2, pp. 1645–1656, 2018.
- [57] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, and H. Arshad, “State-of-the-art in artificial neural network applications : A survey,” *Heliyon*, vol. 4, no. 11, 2018.
- [58] G. James, D. Witten, T. Hastie, R. Tibshirani, and J. Taylor, “Unsupervised learning,” in *An introduction to statistical learning : with applications in Python*. Springer, 2023, pp. 503–556.
- [59] H. U. Dike, Y. Zhou, K. K. Deveerasetty, and Q. Wu, “Unsupervised learning based on artificial neural network : A review,” in *2018 IEEE International Conference on Cyborg and Bionic Systems (CBS)*. IEEE, 2018, pp. 322–327.
- [60] M. Ahmed, R. Seraj, and S. M. S. Islam, “The k-means algorithm : A comprehensive survey and performance evaluation,” *Electronics*, vol. 9, no. 8, p. 1295, 2020.
- [61] K. P. Sinaga and M.-S. Yang, “Unsupervised k-means clustering algorithm,” *IEEE access*, vol. 8, pp. 80 716–80 727, 2020.
- [62] F. Nielsen, “Hierarchical clustering,” in *Introduction to HPC with MPI for Data Science*. Springer, 2016, pp. 195–211.
- [63] F. Murtagh and P. Contreras, “Algorithms for hierarchical clustering : an overview, ii,” *Wiley Interdisciplinary Reviews : Data Mining and Knowledge Discovery*, vol. 7, no. 6, p. e1219, 2017.
- [64] D. Deng, “DbSCAN clustering algorithm based on density,” in *2020 7th international forum on electrical engineering and automation (IFEEA)*. IEEE, 2020, pp. 949–953.
- [65] W. Jia, M. Sun, J. Lian, and S. Hou, “Feature dimensionality reduction : a review,” *Complex & Intelligent Systems*, vol. 8, no. 3, pp. 2663–2693, 2022.

- [66] S. Velliangiri, S. Alagumuthukrishnan *et al.*, “A review of dimensionality reduction techniques for efficient computation,” *Procedia computer science*, vol. 165, pp. 104–111, 2019.
- [67] X. J. Zhu, “Semi-supervised learning literature survey,” 2005.
- [68] J. E. Van Engelen and H. H. Hoos, “A survey on semi-supervised learning,” *Machine learning*, vol. 109, no. 2, pp. 373–440, 2020.
- [69] L. P. Kaelbling, M. L. Littman, and A. W. Moore, “Reinforcement learning : A survey,” *Journal of artificial intelligence research*, vol. 4, pp. 237–285, 1996.
- [70] F. Garcia and E. Rachelson, “Markov decision processes,” *Markov Decision Processes in Artificial Intelligence*, pp. 1–38, 2013.
- [71] J. Clifton and E. Laber, “Q-learning : Theory and applications,” *Annual Review of Statistics and Its Application*, vol. 7, no. 1, pp. 279–301, 2020.
- [72] F. Tan, P. Yan, and X. Guan, “Deep reinforcement learning : From q-learning to deep q-learning,” in *International Conference on Neural Information Processing*. Springer, 2017, pp. 475–483.
- [73] D. Zhao, H. Wang, K. Shao, and Y. Zhu, “Deep reinforcement learning with experience replay based on sarsa,” in *2016 IEEE symposium series on computational intelligence (SSCI)*. IEEE, 2016, pp. 1–6.
- [74] Y. Wang and S. Zou, “Policy gradient method for robust reinforcement learning,” in *International conference on machine learning*. PMLR, 2022, pp. 23 484–23 526.
- [75] C.-L. Liu, C.-C. Chang, and C.-J. Tseng, “Actor-critic deep reinforcement learning for solving job shop scheduling problems,” *Ieee Access*, vol. 8, pp. 71 752–71 762, 2020.
- [76] M. Greenacre, P. J. Groenen, T. Hastie, A. I. dEnza, A. Markos, and E. Tuzhulina, “Principal component analysis,” *Nature Reviews Methods Primers*, vol. 2, no. 1, p. 100, 2022.
- [77] B. Abidi, A. Jilbab, and E. H. Mohamed, “Wireless body area networks : a comprehensive survey,” *Journal of Medical Engineering & Technology*, vol. 44, no. 3, pp. 97–107, 2020.
- [78] A. R. Bhangwar *et al.*, “Wetrp : Weight based energy & temperature aware routing protocol for wireless body sensor networks,” *IEEE Access*, vol. 7, pp. 87 987–87 995, 2019.
- [79] Y. Qu, G. Zheng, H. Ma *et al.*, “A survey of routing protocols in wban for healthcare applications,” *Sensors*, vol. 19, no. 7, p. 1638, 2019.
- [80] H. Taleb, A. Nasser, G. Andrieux *et al.*, “Wireless technologies, medical applications and future challenges in wban : A survey,” *Wireless Networks*, vol. 27, no. 8, pp. 5271–5295, 2021.

- [81] W. R. Heinzelman, A. Chandrakasan, and H. Balakrishnan, “Energy-efficient communication protocol for wireless microsensor networks,” in *Proceedings of the 33rd Annual Hawaii International Conference on System Sciences*, 2000, p. 10 pp. vol. 2.
- [82] A. Bengag, A. Bengag, and O. Moussaoui, “Intrusion detection based on fuzzy logic for wireless body area networks : review and proposition,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 26, no. 2, pp. 1091–1102, 2022.
- [83] M. Boumaiz, M. E. Ghazi, M. Fattah, A. Bouayad, and M. E. Bekkali, “Energy consumption study of channel access modes and modulation schemes of the 2.4 ghz narrowband ieee 802.15.6,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 22, no. 3, pp. 1505–1512, 2021.
- [84] B. Shunmugapriya, B. Paramasivan, S. Ananthakumaran *et al.*, “Wireless body area networks : Survey of recent research trends on energy efficient routing protocols and guidelines,” *Wireless Personal Communications*, pp. 1–32, 2021.
- [85] M. Roy, C. Chowdhury, and N. Aslam, “Designing an energy efficient wban routing protocol,” in *2017 9th International Conference on Communication Systems and Networks (COMSNETS)*. IEEE, 2017, pp. 298–305.
- [86] K. Kour *et al.*, “An energy efficient routing algorithm for wban,” *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, vol. 12, no. 10, pp. 7174–7180, 2021.
- [87] Anand and D. Sethi, “Comparative analysis of energy efficient routing in wban,” in *2017 3rd International Conference on Computational Intelligence & Communication Technology (CICT)*. IEEE, Feb. 2017, pp. 1–6.
- [88] K. Singh and R. K. Singh, “An energy efficient fuzzy based adaptive routing protocol for wireless body area network,” in *2015 IEEE UP Section Conference on Electrical Computer and Electronics (UPCON)*. IEEE, Dec. 2015, pp. 1–6.
- [89] A. R. Akash, M. Hossen, M. Hassan *et al.*, “Gateway node-based clustering hierarchy for improving energy efficiency of wireless body area networks,” in *2019 5th International Conference on Advances in Electrical Engineering (ICAEE)*. IEEE, 2019, pp. 668–672.
- [90] Z. Ullah, I. Ahmed, K. Razzaq, M. K. Naseer, and N. Ahmed, “Dscb : Dual sink approach using clustering in body area network,” *Peer-to-Peer Networking and Applications*, vol. 12, no. 2, pp. 357–370, 2019.
- [91] Z. Ullah, I. Ahmed, F. Khan *et al.*, “Energy-efficient harvested-aware clustering and cooperative routing protocol for wban (e-harp),” *IEEE Access*, vol. 7, pp. 100 036–100 050, 2019.

- [92] N. R. Pal, K. Pal, J. M. Keller, and J. C. Bezdek, "A possibilistic fuzzy c-means clustering algorithm," *IEEE Transactions on Fuzzy Systems*, vol. 13, no. 4, pp. 517–530, 2005.
- [93] M.-S. Yang, "A survey of fuzzy clustering," *Mathematical and Computer Modelling*, vol. 18, no. 11, pp. 1–16, 1993.
- [94] Y. Hu and R. J. Hathaway, "On efficiency of optimization in fuzzy c-means," *NEURAL PARALLEL AND SCIENTIFIC COMPUTATIONS*, vol. 10, no. 2, pp. 141–156, 2002.
- [95] M. Alata, M. Molhim, and A. Ramini, "Optimizing of fuzzy c-means clustering algorithm using ga," *World Academy of Science, Engineering and Technology*, vol. 1, no. 5, 2008.
- [96] H. Izakian, A. Abraham, and V. Snasel, "Fuzzy clustering using hybrid fuzzy c-means and fuzzy particle swarm optimization," in *World Congress on Nature & Biologically Inspired Computing (NaBIC 2009)*. IEEE, 2009, pp. 1690–1694.
- [97] F. Martelli, C. Buratti, and R. Verdone, "On the performance of an iee 802.15.6 wireless body area network," in *17th European Wireless 2011-Sustainable Wireless Technologies*. VDE, 2011, pp. 1–6.
- [98] J. Yick, B. Mukherjee, and D. Ghosal, "Wireless sensor network survey," *Computer Networks*, vol. 52, no. 12, pp. 2292–2330, 2008.
- [99] A. A. Ibrahim, O. Bayat, O. N. Ucan, and S. Salisu, "Weighted energy and qos based multi-hop transmission routing algorithm for wban," in *2020 6th International Engineering Conference "Sustainable Technology and Development" (IEC)*. IEEE, 2020, pp. 191–195.
- [100] A. Arghavani, H. Zhang, Z. Huang, and Y. Chen, "Power-adaptive communication with channel-aware transmission scheduling in wbans," *IEEE Internet of Things Journal*, vol. 11, no. 9, pp. 16 087–16 102, 2024.
- [101] B. Shunmugapriya and B. Paramasivan, "Fuzzy based relay node selection for achieving efficient energy and reliability in wireless body area network," *Wireless Personal Communications*, vol. 122, no. 3, pp. 2723–2743, 2022.
- [102] Q. Tang, N. Tummala, S. K. Gupta, and L. Schwiebert, "Tara : Thermal-aware routing algorithm for implanted sensor networks," in *International Conference on Distributed Computing in Sensor Systems*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2005, pp. 206–217.
- [103] A. Bag and M. A. Bassiouni, "Hotspot preventing routing algorithm for delay-sensitive applications of in vivo biomedical sensor networks," *Information Fusion*, vol. 9, no. 3, pp. 389–398, 2008.
- [104] S. Ahmed, N. Javaid, M. Akbar, A. Iqbal, Z. A. Khan, and U. Qasim, "Laeeba : Link aware and energy efficient scheme for body area networks," in *2014 IEEE*

- 28th International Conference on Advanced Information Networking and Applications*. IEEE, 2014, pp. 435–440.
- [105] N. Javaid, Z. Abbas, M. S. Fareed, Z. A. Khan, and N. Alrajeh, “M-attempt : A new energy-efficient routing protocol for wireless body area sensor networks,” *Procedia Computer Science*, vol. 19, pp. 224–231, 2013.
- [106] M. A. Razzaque, C. S. Hong, and S. Lee, “Data-centric multiobjective qos-aware routing protocol for body sensor networks,” *Sensors*, vol. 11, no. 1, pp. 917–937, 2011.
- [107] T. Watteyne, I. Augé-Blum, M. Dohler, and D. Barthel, “Anybody : A self-organization protocol for body area networks,” *BODYNETS*, vol. 6, 2007.
- [108] A. Ahmad, N. Javaid, U. Qasim, M. Ishfaq, Z. A. Khan, and T. A. Alghamdi, “Re-attempt : A new energy-efficient routing protocol for wireless body area sensor networks,” *International Journal of Distributed Sensor Networks*, vol. 10, no. 4, p. 464010, 2014.
- [109] Y. Huang, “Deep q-networks,” in *Deep Reinforcement Learning : Fundamentals, Research and Applications*, 2020, pp. 135–160.
- [110] J. Schulman, F. Wolski, P. Dhariwal, A. Radford, and O. Klimov, “Proximal policy optimization algorithms,” *arXiv preprint arXiv :1707.06347*, 2017.
- [111] S. Goel, K. Guleria, S. N. Panda *et al.*, “An improved routing technique for energy optimization and delay reduction for wireless body area networks,” *Egyptian Informatics Journal*, vol. 29, p. 100630, 2025.
- [112] L. Sidhoum, M. Hadjila, and R. Merzougui, “Cluster head election algorithm based on fuzzy logic to improve lifespan in wban,” in *2024 2nd International Conference on Electrical Engineering and Automatic Control (ICEEAC)*. IEEE, 2024, pp. 1–6.
- [113] —, “Chain based routing approach to improve lifespan in wireless body area networks,” *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 22, no. 2, pp. 427–434, 2024.
- [114] S. Vyas and S. Gupta, “Wban-based remote monitoring system utilising machine learning for healthcare services,” *International Journal of System of Systems Engineering*, vol. 13, no. 1, pp. 100–108, 2023.
- [115] S. Akbar, M. M. Mehdi, M. H. Jamal *et al.*, “Multipath routing in wireless body area sensor network for healthcare monitoring,” *Healthcare*, p. 2297, 2022.
- [116] B. S. Liya and S. Arun, “Energy efficient data aggregation in wireless ban area network using bee swarm optimisation,” in *2022 IEEE 7th International Conference for Convergence in Technology (I2CT)*. IEEE, 2022, pp. 1–6.
- [117] N. Samarji and M. Salamah, “Erqtm : Energy-efficient routing and qos-supported traffic management scheme for sdwbans,” *IEEE Sensors Journal*, vol. 21, no. 14, pp. 16 328–16 339, 2021.

- [118] M. Hajiloovakil, M. J. Khani, and Z. Shirmohammadi, “An efficient compression method to improve energy consumption in wbans,” in *2021 7th International Conference on Web Research (ICWR)*. IEEE, 2021, pp. 301–305.
- [119] K. S. F. Shemim and U. Witkowski, “Energy efficient clustering protocols for wsn : Performance analysis of fl-ee-nc with leach, k means-leach, leach-fl and fl-ee/d using ns-2,” in *2020 32nd International Conference on Microelectronics (ICM)*. IEEE, 2020, pp. 1–5.
- [120] G. Sun, L. Luo, K. Wang *et al.*, “Toward improving qos and energy efficiency in wireless body area networks,” *IEEE Systems Journal*, vol. 15, no. 1, pp. 865–876, 2020.
- [121] M. Usman, M. Qaraqe, M. R. Asghar *et al.*, “Energy efficient wireless body area networks : Proximity-based clustering in medical implants,” in *2020 IEEE Eighth International Conference on Communications and Networking (Com-Net)*. IEEE, 2020, pp. 1–5.
- [122] N. Bilandi, H. K. Verma, and R. Dhir, “Psoban : A novel particle swarm optimization based protocol for wireless body area networks,” *SN Applied Sciences*, vol. 1, no. 11, pp. 1–14, 2019.
- [123] A. Khanna, V. Chaudhary, and S. H. Gupta, “Design and analysis of energy efficient wireless body area network (wban) for health monitoring,” in *Transactions on Computational Science XXXIII*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2018, pp. 25–39.
- [124] Z. A. Khan, S. Sivakumar, W. Phillips, and B. Robertson, “Zeqos : A new energy and qos-aware routing protocol for communication of sensor devices in healthcare system,” *International Journal of Distributed Sensor Networks*, vol. 10, no. 6, p. 627689, 2014.
- [125] S. Ahmed, N. Javaid, S. Yousaf, A. Ahmad, M. M. Sandhu, M. Imran *et al.*, “Co-laeeba : Cooperative link aware and energy efficient protocol for wireless body area networks,” *Computers in Human Behavior*, vol. 51, no. 1, pp. 1205–1215, 2015.
- [126] I. F. Akyildiz, W. Su, Y. S. Subramaniam, and E. Cayirci, “Wireless sensor networks : A survey,” *Computer Networks*, vol. 38, pp. 393–422, 2002.
- [127] A. Navada, A. N. Ansari, S. Patil, and B. A. Sonkamble, “Overview of use of decision tree algorithms in machine learning,” in *2011 IEEE control and system graduate research colloquium*. IEEE, 2011, pp. 37–42.
- [128] A. Kataria and M. Singh, “A review of data classification using k-nearest neighbour algorithm,” *International Journal of Emerging Technology and Advanced Engineering*, vol. 3, no. 6, pp. 354–360, 2013.