

UNIVERSITÉ DU QUÉBEC

**OPTIMISATION AVANCÉE DES RÉSEAUX DE CAPTEURS INTELLIGENTS DANS
LES TECHNOLOGIES D'INTERNET DES OBJETS**

**DOCTORAT PRÉSENTÉ À
L'UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES
COMME EXIGENCE PARTIELLE DU**

**DOCTORAT EN INGÉNIERIE
CONCENTRATION (GÉNIE MÉCANIQUE)**

PAR

Yousra Mahmoudi

Janvier 2024

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire, de cette thèse ou de cet essai a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire, de sa thèse ou de son essai.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire, cette thèse ou cet essai. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire, de cette thèse et de son essai requiert son autorisation.

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES
DOCTORAT EN INGÉNIERIE (CONC. GÉNIE MÉCANIQUE) (2325)

Direction de recherche :

Pre. Nadjet Zioui Directrice de recherche

Jury d'évaluation

Pre. Marie Hébert Présidente de jury

Pre. Nadjet Zioui Directrice de recherche

Pr. Abdelmounaam Rezgui Évaluateur externe

Pr. Mohamed Tadjine Évaluateur externe

Thèse soutenue le 24 janvier 2024

DÉDICACE

Je dédie ce travail aux membres de ma précieuse famille qui alimentaient incessamment ma force et mes ambitions :

Omi el kabira et khalti Zohra,

Mes chers parents Fatma Djahida et Hocine,

Mon cher mari Abderrahmane et mon adorable fils Youssouf,

Ma sœur et fidèle amie Aicha,

Mes frères Abderrahmane et Lokmane,

Ma belle-sœur Naima,

À la mémoire de mes grands-parents Abi Djeddou, Aicha et Abderrahmane SNP.

Novembre 2023

REMERCIEMENTS

La réalisation de ce projet a été rendue possible grâce à l'aide de plusieurs personnes à qui je tiens à témoigner ma sincère gratitude.

Je tiens à exprimer toute ma reconnaissance à ma directrice de thèse, Madame Nadjat ZIOUI. Je la remercie pour son encadrement, orientation, aide et conseils judicieux.

J'adresse mes sincères remerciements aux professeurs Hacène BELBACHIR, Hanane DAGDOUGUI, Mohamed TADJINE, Abdelmounaam REZGUI et Said BENTOUBA qui ont contribué à la concrétisation d'une partie de ce projet en guidant mes réflexions par leurs conseils et critiques.

Finalement, je tiens à remercier le réseau québécois sur l'énergie intelligente pour la bourse RQEI 2020-2021 offerte dans le cadre du projet de recherche « Optimisation avancée des ressources énergétiques multiples dans un véhicule pour alimenter l'instrumentation embarquée » ainsi que l'UQTR pour la bourse PAIR 2020-2022 qu'elle m'a offert dans le cadre du projet de recherche « Optimisation avancée des ressources énergétiques multiples dans un véhicule pour alimenter l'instrumentation embarquée »

Novembre 2023

RÉSUMÉ

Les avancées spectaculaires dans les domaines des communications sans fil et de la microélectronique ont autorisé le développement de capteurs multifonctionnels à des coûts peu élevés. Ces progrès ont ouvert la voie à l'Internet des objets (IoT) qui est devenu une technologie essentielle dans de nombreux secteurs tels que le transport, la sécurité, l'industrie, l'agronomie, l'environnement, ... etc.

Les applications à base de technologies d'internet des objets comportent de nombreux défis dont les enjeux liés à la sécurité, à la qualité de service (QoS), la fiabilité, évolutivité, hétérogénéité, congestion, consommation et autonomie énergétique ainsi que le routage.

Dans ce travail, nous nous intéressons au problème de l'efficacité énergétique dans les réseaux IoT sans fil.

Nous décrivons, tout d'abord, un nouveau modèle mathématique complet basé sur le problème du p -médian, appelé (PMC), pour le problème de regroupement des nœuds efficace énergétiquement dans les réseaux IoT sans fil. Un ensemble de variables de décision est défini pour exprimer l'objectif de minimisation de la consommation d'énergie sous la forme d'une fonction mathématique à minimiser en tenant compte de l'énergie résiduelle des nœuds, ainsi que d'autres contraintes à satisfaire.

Par la suite, nous implémentons une approche d'optimisation basée sur la méthode Branch-and-Bound pour résoudre le modèle (PMC) décrit. Les résultats des tests de performance montrent que le modèle décrit est très pertinent, permettant une réduction significative de la consommation d'énergie de 12,52% et 19,36% dans les réseaux avec station de base centrale et périphérique, respectivement. Contrairement à la plupart des techniques proposées dans la littérature, l'approche proposée permet la détermination dynamique du nombre optimal " p " de clusters à former et de l'affectation des nœuds de capteurs à chaque cluster afin de diminuer et d'équilibrer la consommation d'énergie dans réseau, même lorsque la station de base est située en dehors du réseau. Toutefois, le temps d'exécution de la méthode proposée est d'au moins 60 minutes, ce qui ne peut être accepté dans les applications réelles de l'IoT.

Ce constat nous a conduits vers l'exploitation des concepts et des avantages de l'informatique quantique pour concevoir la métaheuristique d'inspiration quantique QIC afin de résoudre le modèle (PMC). Les tests de performance montrent que le QIC permet d'économiser 15,48 % de la consommation d'énergie dans les réseaux avec station de base centrale en un temps très raisonnable. En effet, QIC offre une accélération considérable du temps d'exécution comparée à la méthode précédemment utilisée, étant capable d'exécuter 100 itérations incluant l'exploration d'une population de 100 solutions réalisables sur un réseau de 100 nœuds en moins de 5 minutes. L'algorithme QIC est très intéressant pour le problème considéré, cependant il a été observé que les réductions offertes ne sont obtenues que lors des premières itérations.

Par la suite, dans le but de remédier à la convergence prématurée vers un optimum local observé dans l'approche QIC, nous décrivons une nouvelle variante de l'algorithme d'optimisation par essaim de particules PSO qui s'appuie sur les concepts de l'informatique quantique et exploite ses forces pour déterminer un clustering énergétiquement efficace des réseaux IoT avec des stations de base à des emplacements différents. Cette nouvelle méthode, appelée QIPSO, offre plusieurs améliorations en termes de modélisation de l'objectif de réduction de la consommation d'énergie, de sélection du schéma de routage, d'exploration de l'espace des solutions, de la qualité du clustering fourni, de vitesse de convergence et du temps d'exécution. Cette nouvelle méthode s'est avérée très efficace, offrant des réductions de la consommation d'énergie allant jusqu'à 19,77 % et 91 % pour les deux configurations de stations de base, dans un délai très court qui convient parfaitement aux applications du monde réel exigeant une prise de décision instantanée.

Novembre 2023

Mots Clés

Internet des Objets, Réseaux IoT sans fils, Optimisation, Métaheuristique, regroupement, Structure en grappes, Efficacité énergétique, problème du p-médian, Informatique quantique,

ABSTRACT

Spectacular advances in wireless communications and microelectronics have enabled the development of low-cost, multifunctional sensors. These advances have paved the way for the Internet of Things, which has become an essential and indispensable technology in many sectors such as transport, security, industry, agronomy, the environment, etc.

Applications based on Internet of Things (IoT) technologies face several challenges, including security, quality of service (QoS), reliability, scalability, heterogeneity, congestion, energy consumption and autonomy, and routing.

In this work, we address the problem of energy efficiency in wireless IoT networks.

We, first, describe a novel comprehensive p -median based mathematical model, named (PMC), for the wireless IoT network's clustering problem. A set of decision variables is defined to express the objective of minimizing the energy consumption as a mathematical function to be minimized taking into consideration the residual energy of the nodes, among other constraints to be satisfied.

Then to solve the described (PMC) model, we implement an optimization approach based on the Branch-and-Bound method. The experiments' results show that the model described is highly relevant, providing a significant reduction in energy consumption of 12,52% and 19,36% in networks with central and peripheral base station, respectively. Unlike most of the techniques proposed in the literature, this one is remarkably notable by being scalable to large sized networks with up to 90,000 nodes. Moreover, the proposed approach allows the dynamic determination of the optimal number “ p ” of clusters to be formed and the assignment of the sensor nodes to each cluster to decrease and balance energy consumption of the network even when the base station is located outside the network. However, the execution time of the proposed method is at least 60 minutes, which cannot be accepted in real dynamic applications.

This led us to leverage the concepts and advantages of quantum computing to design the quantum-inspired metaheuristic QIC to solve the (PMC) model. Performance tests show that QIC saves 15.48% of energy consumption in networks with central base station in a

very reasonable time. Indeed, QIC offers a considerable speed-up compared with the previously used method, being able to execute 100 iterations including the exploration of a population of 100 feasible solutions on a network of 100 nodes in less than 5 minutes. The QIC algorithm is highly interesting for the problem under consideration, but it has been observed that the reductions offered are achieved during the first iterations only.

Then, in order to overcome the premature convergence to a local optimum encountered in the QIC approach, we describe a new variant of the Particle Swarm Optimization PSO algorithm that draws on the concepts of quantum computing and harnesses its strengths to determine energy-efficient clustering of IoT networks with base stations in different locations. This new method, called QIPSOC, offers several improvements in terms of modeling the objective of reducing energy consumption, selection of the routing scheme, exploration of the solutions' space, quality of the provided clustering, convergence speed and execution time. This new method is proven to be highly effective, offering energy consumption reductions of up to 19.77% and 91% for both base station configurations, in a very short timeframe that is ideally suited to real-world applications requiring instantaneous decision-making.

November 2023

Key Words

Internet of Things, Wireless IoT Networks, Optimization, Metaheuristic, Clustering, Energy efficiency, p-median problem, Quantum Computing,

Table des Matières

| | |
|---|-----------|
| DÉDICACE | iii |
| REMERCIEMENTS | iiiv |
| RÉSUMÉ | v |
| Mots Clés | vi |
| ABSTRACT | vii |
| Key Words | vi |
| Table des Matières..... | ix |
| Liste des Tableaux | xiv |
| Liste des Figures..... | xv |
| Liste des acronymes..... | xvii |
| Liste des notations | xviii |
| Avant-propos | xxi |
| CHAPITRE 1 - INTRODUCTION GÉNÉRALE | 22 |
| 1.1 Mise en contexte..... | 22 |
| 1.2 Limitations | 22 |
| 1.3 Problématique..... | 23 |
| 1.4 Objectifs | 24 |
| 1.5 Hypothèses | 25 |
| 1.6 Contributions..... | 25 |

| | | |
|--|---|----|
| 1.7 | Méthodologie de recherche | 29 |
| 1.8 | Infrastructure de recherche..... | 30 |
| 1.9 | Structure de la thèse | 30 |
| CHAPITRE 2 - ETAT DE L'ART..... | | 32 |
| 2.1 | Introduction | 32 |
| 2.2 | Architecture des réseaux IoT..... | 32 |
| 2.3 | Caractéristiques des nœuds de capteursIoT | 36 |
| 2.4 | Applications des réseaux IoT | 38 |
| 2.5 | Défis et contraintes dans les réseaux IoT | 40 |
| 2.6 | Revue des techniques d'optimisation de la consommation de l'énergie dans les réseaux IoT | 42 |
| 2.7 | Conclusion..... | 46 |
| CHAPITRE 3 -TECHNIQUES DE L'OPTIMISATION MATHÉMATIQUE..... | | 48 |
| 3.1 | Introduction | 48 |
| 3.2 | Définition d'un problème..... | 48 |
| 3.3 | Modélisation mathématique du problème | 49 |
| 3.4 | Résolution du modèle mathématique | 51 |
| 3.4.1 | Méthodes exactes | 51 |
| 3.4.2 | Méthodes approchées | 55 |
| (i) | Les heuristiques | 56 |

| | |
|--|----|
| (ii) Les métaheuristiques | 56 |
| 3.5 Complexité d'un problème d'optimisation..... | 62 |
| 3.5.1 La complexité algorithmique | 62 |
| 3.4.1 La complexité d'un problème d'optimisation | 63 |
| 3.6 Conclusion..... | 63 |
| CHAPITRE 4 - CONTRIBUTION À L'OPTIMISATION DES RÉSEAUX IOT PAR UNE MÉTHODE CLASSIQUE DU P-MÉDIAN..... | |
| 4.1 Introduction | 65 |
| 4.2 Une nouvelle approche classique pour l'optimisation des réseaux IoT..... | 65 |
| 4.2.1 Définition du problème | 65 |
| 4.2.2 Evaluation de la consommation de l'énergie..... | 66 |
| 4.2.3 Modélisation mathématique | 67 |
| 4.2.4 Résolution | 69 |
| 4.2.5 Tests et résultats | 70 |
| 4.3 Conclusion..... | 76 |
| CHAPITRE 5 - CONTRIBUTION AU CALCUL QUANTIQUE POUR L'OPTIMISATION AVANCÉE DES RÉSEAUX IoT | |
| 5.1 Introduction | 77 |
| 5.2 Définition, principes de base et avantages de l'informatique quantiques... | 77 |
| 5.3 Revue des approches d'optimisation quantique..... | 80 |

| | | |
|--|--|-----|
| 5.3.1 | Méthodes d'optimisation quantiques et inspirées-quantiques | 81 |
| 5.3.2 | Recuits quantiques | 90 |
| 5.4 | Une nouvelle approche inspirée-quantique pour l'optimisation des réseaux IoT | 93 |
| 5.4.1 | Modélisation quantique..... | 94 |
| 5.4.2 | Algorithme pour la construction d'une solution binaire..... | 94 |
| 5.4.3 | Exploration de l'espace des solutions..... | 96 |
| 5.4.4 | L'algorithme QIC | 98 |
| 5.4.5 | Tests et résultats..... | 100 |
| 5.5 | Une nouvelle approche inspirée-quantique améliorée pour l'optimisation des réseaux IoT | 107 |
| 5.5.1 | Modélisation quantique..... | 108 |
| 5.5.2 | Nouvel algorithme pour la construction d'une solution binaire..... | 109 |
| 5.5.3 | Exploration de l'espace des solutions..... | 111 |
| 5.5.4 | L'algorithme QIPSOC | 112 |
| 5.5.5 | Tests et résultats..... | 113 |
| 5.6 | Conclusion..... | 120 |
| CHAPITRE 6 - CONCLUSION GÉNÉRALE | | 122 |
| 6.1 | Contributions..... | 122 |

| | |
|--|-----|
| 6.2 Perspectives et recommandations..... | 125 |
| RÉFÉRENCES BIBLIOGRAPHIQUES | 129 |

Liste des Tableaux

| | |
|---|-----|
| Tableau 3.1 Classification des problèmes d'optimisation | 50 |
| Tableau 4.1 Paramètres de simulation | 71 |
| Tableau 5.1 Classification des contributions dédiées à la résolution des problèmes d'optimisation en fonction de l'objectif principal de l'étude..... | 92 |
| Tableau 5.2 Paramètres de simulation relatifs à l'algorithme QIC | 101 |
| Tableau 5.3 Paramètres du mouvement FA | 101 |
| Tableau 5.4 Caractéristiques des réseaux IoT | 102 |
| Tableau 5.5 Sommaire des résultats des tests sur l'algorithme QIC | 102 |
| Tableau 5.6 Paramètres du mouvement PSO dans l'algorithme QIPSOC | 113 |
| Tableau 4.7 Résumé des résultats des tests sur les algorithmes QIPSOC, QIC et B&B..... | 114 |

Liste des Figures

| | | |
|------------|--|----|
| Figure 2.1 | Architecture de base d'un réseau IoT | 33 |
| Figure 2.2 | Topologie plate d'un réseau IoT | 34 |
| Figure 2.3 | Topologie hiérarchique d'un réseau IoT | 35 |
| Figure 2.4 | Topologie hierarchique d'un réseau IoT avec transmission multi-sauts | 35 |
| Figure 2.5 | Architecture générale d'un nœud de capteurs | 36 |
| Figure 2.6 | Le nœud de capteurs « Mighty Grecko EFR3MG12 » de silicone Lab | 38 |
| Figure 2.7 | Cinquante applications potentielles de l'Internet des Objets [2]..... | 40 |
| Figure 3.1 | Polyèdre réalisable, points extrêmes, et solution optimale du programme mathématique (PL)..... | 53 |
| Figure 4.1 | Clustering des nœuds de réseau sans fil autour d'une station de base centrale (nœuds situés dans une zone de $100 \times 100m^2$ avec la station de base située à l'intérieur de la zone)..... | 72 |
| Figure 4.2 | Clustering des nœuds de réseau sans fil reliés à une tation de base périphérique (nœuds situés dans une zone de $100 \times 100m^2$ avec la station de base située à l'extérieur de la zone) | 73 |
| Figure 4.3 | Energie consommée par les réseaux IoT sans fil autour d'une station de base centrale..... | 74 |
| Figure 4.4 | Energie consommée par les réseaux IoT sans fil autour d'une station de base périphérique | 74 |
| Figure 5.1 | La représentation d'un état de Qbit dans la sphère de Bloch | 78 |

| | | |
|-------------|---|-----|
| Figure 5.2 | Evolution du nombre de publications de recherche portant sur l'utilisation des outils mathématiques avancés dans l'informatique quantique [77]..... | 81 |
| Figure 5.3 | Economie d'énergie réalisée avec chaque configuration de paramètres (de gauche à droite : 1 à 7)..... | 103 |
| Figure 5.4 | Le temps d'exécution moyen par configuration de paramètres | 104 |
| Figure 5.5 | Consommation de l'énergie dans les réseaux IoT avec une station de base périphérique..... | 105 |
| Figure 5.6 | Consommation de l'énergie dans les réseaux IoT avec une station de base centrale..... | 105 |
| Figure 5.7 | Réduction de la consommation d'énergie par les réseaux en fonction du nombre d'itérations effectuées par l'algorithme QIC | 106 |
| Figure 5.8 | Consommation de l'énergie dans des réseaux IoT avec une station de base centrale..... | 115 |
| Figure 5.9 | Consommation de l'énergie dans des réseaux IoT avec une station de base périphérique..... | 115 |
| Figure 5.10 | La progression de la recherche de la meilleure solution dans le QIPSOC | 116 |
| Figure 5.11 | Dispersion des consommations d'énergie de 200 réseaux IoT dont les nœuds sont regroupés par clusters en utilisant QIPSOC..... | 117 |
| Figure 5.12 | Comparaison des temps d'exécution de B&B, QIC et QIPSOC sur cinq réseaux IoT de taille 100 avec station de base centrale | 118 |
| Figure 5.13 | Comparaison des temps d'exécution de B&B, QIC et QIPSOC sur cinq réseaux IoT de taille 100 avec station de base périphérique | 119 |

Liste des acronymes

| | |
|---------|---|
| B&B | Algorithme par séparation et évaluation (Branch and Bound) |
| NSGA-II | Algorithme génétique de tri non dominé II |
| FA | Algorithme des lucioles |
| PSO | Algorithme d'optimisation par essaim de particules |
| QIC | Algorithme de Clustering à Inspiration Quantique |
| QIPSOC | Algorithme PSO à Inspiration Quantique pour le clustering des réseaux IoT |
| CH | Tête de cluster |
| FNS | Fitness ou valeur de la fonction objectif |
| IoT | Internet des objets |
| NB-IoT | Internet des objets à bande étroite |

Liste des notations

| | |
|-----------------------------|--|
| d_0 | Le seuil de distance entre l'émetteur et le récepteur (m) |
| E_{elec} | Énergie consommée par le système électronique pour envoyer ou recevoir un bit (J/bit) |
| E_{DA} | Énergie consommée par l'agrégation des données (J/bit) |
| ε_{fs} | Énergie consommée pour la propagation en espace libre (J/bit/m ²) |
| ε_{mp} | Énergie consommée pour la propagation par chemins multiples (J/bit/m ⁴) |
| L | Taille des paquets de données (bit) |
| $E_{TX}(L, d)$ | Énergie consommée pour transmettre un message de L bits sur une distance d (J) |
| $E_{RX}(L)$ | Énergie consommée pour recevoir un message de L bits (J) |
| a_{ij} | La distance entre deux nœuds i et j |
| d_j | La distance entre le nœud j et la station de base |
| x_{ij} | Variable de décision, égale à 1 si et seulement si le nœud i transmet des données à la tête de cluster j . |
| y_j | Variable de décision, égale à 1 si et seulement si le nœud j est sélectionné tête de cluster. |
| E_j | Energie dans le nœud j |
| $ 0\rangle$ and $ 1\rangle$ | États de base orthonormaux |
| $ q\rangle$ | État du Qbit q |

| | |
|------------------------|--|
| \mathbb{C} | Ensemble des nombre complexes |
| QY | Solution quantique |
| BS | Solution binaire |
| n | Taille du réseau |
| θ | Angle de rotation du Qbit |
| t | Compteur des itérations de l'algorithme QIC |
| $nb_iterations$ | Nombre d'itérations de l'algorithme QIC |
| r_{ij} | Distance de Hamming normalisée entre les deux nœuds i et j |
| λ | Coefficient d'absorption de la lumière |
| β | Attractivité entre deux solution binaires BS_i et BS_j |
| β_0 | Attractivité entre deux solution binaires séparées par une distance nulle |
| α et ϵ | Paramètres aléatoires du mouvement FA |
| c_1 et c_2 | Facteurs d'apprentissage du mouvement PSO |
| ω | Poids d'inertie |
| $\Delta\theta_{ik}^t$ | Angle de rotation du $k^{\text{ème}}$ Qbit de la solution quantique QY_i à l'itération t |
| QYS | Population des solution quantiques |
| BSS | Population des solutions binaires |
| m | Taille de la population |
| bbs^t | La meilleure solution binaire à l'itération t |
| bqs^t | La meilleure solution quantique à l'itération t |

| | |
|--------|----------------------------------|
| BS_g | La meilleure solution binaire |
| QS_g | La meilleure solution quantique |
| χ | Facteur d'amortissement inertiel |

Avant-propos

Tous les appareils électroniques utilisés dans notre vie quotidienne sont ou deviendront très bientôt intelligents. Cela est encore plus vrai dans le cas des applications de l'Internet des objets (IoT). Cette technologie récente, en progrès permanent, est largement utilisée dans plusieurs domaines cruciaux tels que la santé, la gestion urbaine, la télécommunication, le transport, la sécurité, la gestion d'entreprise et les processus industriels.

Les applications de l'Internet des objets fonctionnent principalement grâce aux nœuds de capteurs placés dans des infrastructures physiques. Ces objets sont alimentés par des batteries limitées en énergie et ont pour tâches principales la collecte, l'émission et la réception des données spécifiques en réponse aux requêtes et besoins de l'utilisateur. La performance et la durabilité de ces applications sont fortement liées à l'efficacité énergétique des nœuds de capteurs.

Pour cela, nous faisons recours dans notre travail aux techniques d'optimisation de la recherche opérationnelle pour l'optimisation de la consommation de l'énergie des nœuds de capteurs et aux techniques avancées innovatives de traitement de l'information pour accélérer les calculs et permettre une optimisation instantanée adaptée aux applications réelles de l'IoT qui nécessitent une prise de décision rapide et efficace.

CHAPITRE 1 - INTRODUCTION GÉNÉRALE

1.1 Mise en contexte

L'internet des Objets (IoT) est une technologie récente qui permet de relier des objets physiques de différents types entre eux et à l'internet aussi. Cette technologie en progrès permanent et spectaculaire fait désormais partie de notre quotidien. En effet, tous les appareils électroniques utilisés dans notre vie sont ou deviendront très bientôt intelligents. L'IoT est largement utilisée et a des applications cruciales dans plusieurs domaines tels que la santé, la gestion urbaine, la télécommunication, le transport, la sécurité, la gestion d'entreprise et dans les processus industriels [1-3].

L'Internet des objets actuel fonctionne principalement grâce à des capteurs, des actionneurs et d'autres objets connectés placés dans des infrastructures ou des objets physiques. Ces objets recueillent, émettent et reçoivent des données spécifiques qui sont téléchargées via un réseau sans fil sur des plateformes IoT. Les données sont analysées et enrichies pour être utilisées afin de répondre à des requêtes émises par l'utilisateur et/ou pour optimiser l'utilisation des appareils inclus dans le réseau.

1.2 Limitations

Le nombre d'objets connectés aux réseaux IoT ne cessent de croître, actuellement nous comptons des millions d'objets connectés qui génèrent une immense quantité de données ce qui mènent vers beaucoup de problèmes liés au routage des données dans le réseau, la conservation de l'énergie, le contrôle de la congestion, l'hétérogénéité des données, l'évolutivité, la sécurité des données et la qualité de service [4-5].

L'un des défis majeurs de l'IoT est la conservation de l'énergie. En effet, les nœuds de capteurs sont de petits composants qui restent actifs pendant une durée limitée par la capacité de leurs sources d'énergie, principalement des batteries. Dans la plupart des applications, il est problématique, voire impossible, de recharger ou de changer la batterie [1]. Le nœud de capteurs finit par être retiré du réseau lorsque sa batterie est épuisée ce qui cause une interruption de ses services.

La désintégration simultanée des nœuds de capteurs entrainera une dégradation des performances du réseau et, au bout d'un certain temps rend le réseau obsolète.

Étant données les caractéristiques et les limitations des nœuds de capteurs, il est crucial d'optimiser l'utilisation des ressources énergétiques de ces derniers pour permettre la collecte et la transmission des données sans compromettre les performances globales du réseau.

De nombreux travaux de recherche ont été menés dans le contexte de la conservation de l'énergie dans le but de prolonger la durée de vie des réseaux IoT. Cependant, une bonne partie de ces travaux ne prend pas en considération la sécurité des données, la qualité du service, et l'évolutivité lors de l'élaboration des solutions de conservation de l'énergie. De plus, peu des techniques proposées sont applicables aux réseaux de grandes tailles et sont encore plus rares celles qui répondent aux objectifs lorsque la station de base est située en dehors du réseau.

1.3 Problématique

Les objets connectés aux réseaux IoT se comptent actuellement par millions et leur nombre devrait atteindre des milliards dans les années à venir [4-5]. Ceci entraînera la génération d'immenses quantités de données sans précédent. Il est, donc, impératif d'optimiser l'efficacité énergétique des réseaux IoT pour permettre la collection et la transmission de données sans compromettre les performances globales du réseau, notamment, la sécurité des données et l'évolutivité du réseau.

La question de recherche à laquelle nous répondons à travers les travaux présentés dans cette thèse est la suivante :

« Comment peut-on utiliser les techniques de la recherche opérationnelle et les nouvelles technologies de traitement de l'information pour optimiser la consommation de l'énergie dans les réseaux IoT? »

1.4 Objectifs

Dans ce travail, nous visons à proposer un schéma de clustering dynamique basé sur le problème p -médian pour minimiser l'énergie consommée par les nœuds de capteurs des réseaux IoT sans fil. Un tel clustering définira un schéma de routage qui va permettre d'atteindre plusieurs objectifs en même temps :

- (i) L'efficacité énergétique en effectuant d'une façon dynamique le choix des têtes des clusters et l'affectation des nœuds membres aux têtes de clusters de manière à minimiser la distance entre les nœuds membres et la station de base.
- (ii) La sécurité des données en adoptant des transmissions en un seul saut entre les nœuds membres et la tête du cluster et entre la tête du cluster et la station de base.
- (iii) L'évolutivité du réseau puisque le clustering permet une insertion fluide de nouveaux nœuds de capteurs.

Afin de décrire un schéma de clustering dynamique qui répond aux critères (i), (ii) et (iii) simultanément, nous avons fixé les objectifs suivants :

- (a) Étudier les réseaux IoT sans fil et déterminer les contraintes liées à la consommation de l'énergie dans les nœuds de capteurs.
- (b) Formuler le problème sous forme d'un programme mathématique prenant en considération toutes les contraintes liées à la consommation de l'énergie.
- (c) Résoudre le programme mathématique élaboré en un temps raisonnable adapté aux applications réelles de l'IoT avec des stations de bases centralisées ou périphériques.
- (d) Utiliser des technologies récentes très puissantes pour développer une approche d'optimisation avancée rapide et efficace.
- (e) Évaluer la performance de la méthode proposée et effectuer une étude comparative de l'approche proposée avec des méthodes de la littérature en termes de

plusieurs critères, la qualité de la solution fournie, la complexité algorithmique et le temps d'exécution.

1.5 Hypothèses

Pour atteindre les objectifs listés en haut, nous considérons des réseaux IoT comportant des nœuds capteurs et une station de base non mobiles dont les positions géographiques sont bien connues.

En termes de capacités énergétiques, la station de base est alimentée par une source d'énergie continue et illimitée, tandis que les nœuds de capteurs ont des ressources énergétiques restreintes non extensibles et non-échangeables.

En ce qui concerne la consommation de l'énergie, un nœud de capteurs utilise de l'énergie pour effectuer trois tâches principales : la collecte, le traitement et la communication. Dans notre étude nous considérons seulement l'énergie nécessaire pour la communication puisqu'elle constitue la plus grande part de l'énergie consommée par un nœud capteur.

De plus, les paquets de données ne peuvent pas être fractionnés mais doivent être transmis en entier depuis les nœuds de capteurs jusqu'à la station de base.

1.6 Contributions

Les principales contributions de notre travail sont les suivantes :

- i. Nous avons conçu un modèle mathématique linéaire détaillé et complet en nombres entiers basé sur le modèle p-médian pour modéliser le problème de clustering efficace énergétiquement dans les réseaux IoT sans fil. Compte tenu de l'énergie résiduelle des nœuds, des positions des nœuds, des distances nœud-nœud et nœud-station de base, la résolution du modèle mathématique proposé permet de déterminer le nombre idéal de clusters à former, de sélectionner le nœud le plus approprié de chaque cluster pour être tête de cluster, et d'affecter efficacement les nœuds aux clusters. Cette contribution originale permet d'établir un processus de

routage qui offre une réduction de l'énergie à consommer lors d'une transmission sécuritaire des données des capteurs la station de base.

- ii. Nous avons mis en œuvre une nouvelle approche de clustering des réseaux IoT basée sur la méthode Branch and Bound pour la résolution du modèle mathématique décrit. Nous avons mené une série de tests intensifs pour évaluer les performances de la méthode, et les résultats obtenus montrent qu'elle permet une réduction considérable de la consommation de l'énergie approchant les 20% pour les réseaux avec station de base centrale et même périphérique. Ce qui atteste également que le modèle mathématique décrit d'une façon appropriée le problème du clustering efficace énergétiquement dans les réseaux IoT sans fil avec localisation centrale et périphérique de la station de base. Le seul inconvénient de cette méthode est sa complexité algorithmique exponentielle, les résultats ont été obtenus après au moins 60 minutes de temps d'exécution ce qui ne permet pas de fournir un clustering instantané adapté aux applications réelles de l'IoT.
- iii. Exploitation des avantages de l'informatique quantique dans la résolution du problème de clustering efficace énergétiquement dans les réseaux IoT sans fil, notamment l'accélération des calculs.
- iv. Élaboration d'une nouvelle métaheuristique inspirée-quantique QIC basée sur l'algorithme des lucioles et sur l'algorithme d'optimisation par essaim de particules pour résoudre le problème de clustering efficace énergétiquement dans les réseaux IoT sans fil. Cette métaheuristique est puissante et efficace puisqu'elle combine les avantages de l'optimisation classique aux avantages de l'informatique quantique, notamment l'accélération des calculs. L'application de cette méthode sur des réseaux IoT sans fil avec une station de base centrale a permis une réduction de la consommation de l'énergie atteignant 15.48% et a offert une accélération très remarquable des calculs. En effet, le temps nécessaire pour l'exécution de 100 itérations incluant l'exploration d'une population de 100 solutions réalisables sur un réseau de 100 nœuds est d'au plus 5 minutes.
- v. Perfectionnement de la métaheuristique proposée QIC en n'adoptant que le mouvement de l'algorithme d'optimisation par essaim de particules avec adaptation dynamique du coefficient d'inertie à l'aide d'un facteur d'amortissement inertiel afin d'éviter la convergence prématurée vers un minimum local causée par

le mouvement de l'algorithme des lucioles, et d'améliorer la qualité de la solution fournie tout en accélérant les calculs. En conséquent, nous avons développé une nouvelle métaheuristique adaptative inspirée-quantique QIPSOC qui fournit un clustering meilleur qui offre une réduction supplémentaire de la consommation de l'énergie en un temps très réduit de l'ordre de 19 secondes. De ce fait, QIPSOC est très adéquate pour une résolution en temps réel du problème du clustering efficace énergétiquement dans les réseaux IoT.

- vi. Nous avons également mené une étude comparative des méthodes proposées avec des méthodes de la littérature en termes d'économie en énergie, de complexité algorithmique et de temps d'exécution.
- vii. Les contributions listées en haut ont été valorisées et démontrées à travers la rédaction de quatre articles scientifiques, dont trois ont été déjà publiés dans des revues scientifiques avec comité de lecture de calibre Q1, le quatrième étant sous révision par une revue avec comité de lecture, et de deux articles de communication dans des conférences internationales. De plus, nous avons eu l'opportunité de collaborer avec des chercheurs à l'international sur divers projets de recherche dans le contexte de l'optimisation et de l'informatique quantique et de contribuer à la rédaction et la publication de 5 articles de recherche.

La liste de ces articles suivante est la suivante :

Articles publiés dans des revues avec comités de lecture :

Yousra Mahmoudi, Nadjat Zioui, Hacène Belbachir, and Hanane Dagdougui. (2023) P-median based modelling-based optimization of energy consumption in smart wireless sensors networks in Internet of Things applications. *Operational Research in Engineering Sciences: Theory and Applications*, Vol. 66, n° 1.

Nadjat Zioui, Aicha Mahmoudi, **Yousra Mahmoudi**, and Mohamed Tadjine. (2023) Quantum computing based state domain equations and feedback control. *Results in Applied Mathematics*, Volume 19. doi :

<https://doi.org/10.1016/j.rinam.2023.100385>

Aicha Mahmoudi, **Yousra Mahmoudi**, Karima Benatchba, Abdelmounaam Rezgui, and Nadjat Zioui. (2023) Towards Optimal Frequency Plans a Survey of Frequency Assignment Strategies, Models and Methods. Disponible sur SSRN:

<https://ssrn.com/abstract=4535493>

or

<http://dx.doi.org/10.2139/ssrn.4535493>

Yousra Mahmoudi, Nadjat Zioui, Hacène Belbachir, Mohamed Tadjine, and Abdelmounaam Rezgui. (2022) A brief review on mathematical tools applicable to quantum computing for modelling and optimization problems in engineering. Emerging science Journal, Vol. 7, n° 1, pp. 289-312.

Yousra Mahmoudi, Nadjat Zioui, and Hacène Belbachir. (2022) A new quantum-inspired clustering method for reducing energy consumption in IoT networks. Internet of Things, Vol, 20. doi: <https://doi.org/10.1016/j.iot.2022.100622>

Mohamed El Amine Boudjoghra, Sid Ali Sofiane Daimellah, Nadjat Zioui, **Yousra Mahmoudi**, and Mohamed Tadjine. (2022) State-domain equations and their quantum computing solution based HHL algorithm. Mathematical Modelling of Engineering Problems, Vol. 9, n° 4, pp. 879-886. <https://doi.org/10.18280/mmep.090404>

Nadjat Zioui, **Yousra Mahmoudi**, Aicha Mahmoudi, Mohamed Tadjine, and Said Bentouba. (2021). A novel quantum-computing-based quaternions model for a robotic arm position. International Journal of Computational Intelligence in Control, Vol 13, n° 2, pp.71-77. <https://www.mukpublications.com/resources/ijcic%20v13-2-9.pdf>

Nadjet Zioui, Aicha Mahmoudi, **Yousra Mahmoudi**, and Abdelmounaam Rezgui. (2021) A comparative study of performances between the sliding modes and the trust control strategies for an articulated robotic arm position control. *International Journal of Mechanical & Mechatronics Engineering*, Vol. 21, n° 1. doi : <https://doi.org/10.22055/jacm.2021.37611.3048>

Articles sous révision par une revue avec comité de lecture :

Yousra Mahmoudi, Nadjet Zioui, and Hacène Belbachir. Quantum-inspired particle swarm optimization approach with damping factor to reduce energy consumption in IoT network.

Articles de conférences internationales avec comités de lecture :

Yousra Mahmoudi, Nadjet Zioui, and Hacène Belbachir. Comparison between conventional and quantum based p-median optimisation for energy consumption in IoT networks. *9th International Conference on engineering and Emerging Technologies (ICEET2023)*, 27 - 28 October 2023, Istanbul - Turkey.

Yousra Mahmoudi, Nadjet Zioui and Hacène Belbachir, "Quantum Optimization in Engineering: A Brief Review," *2023 International Conference on Decision Aid Sciences and Applications (DASA)*, Annaba, Algeria, 2023, pp. 23-27, doi: [10.1109/DASA59624.2023.10286779](https://doi.org/10.1109/DASA59624.2023.10286779).

1.7 Méthodologie de recherche

Dans la quête de la méthode et la solution optimales du problème du clustering efficace énergétiquement dans les réseaux IoT, nous faisons appel aux techniques de l'optimisation mathématique de la Recherche Opérationnelle, la discipline qui regroupe les techniques d'aide à la décision.

Nous avons adopté le processus d'optimisation mathématique de base constitué de quatre étapes principales : la première étape comprend la définition des contraintes liées au problème considéré et des objectifs à atteindre afin de définir un problème d'optimisation visant à maximiser et/ou minimiser chacun des critères tout en satisfaisant l'ensemble des contraintes. La deuxième étape consiste à exprimer le problème d'optimisation défini sous forme d'équations, d'inéquations et de fonctions mathématiques. Dans la troisième étape la complexité du problème d'optimisation défini est évaluée avant de passer à la quatrième et dernière étape de sélection et d'adaptation de la méthode de résolution dépendamment de la complexité du problème de l'optimisation et des préférences de l'utilisateur.

1.8 Infrastructure de recherche

Les méthodes d'optimisation proposées dans la présente thèse pour l'optimisation de la consommation de l'énergie dans les réseaux IoT sans fil sont implémentées sous Matlab R2021a.

L'évaluation de leurs performances ainsi que l'analyse de la qualité des solutions qu'elles fournissent en termes d'économie d'énergie et de temps d'exécution sont menées en exploitant un ordinateur portable équipé d'un processeur Intel(R) Core (TM) i5-1135G7 @ 2,40 GHz de 11e génération pour exécuter une série de tests intensifs sur des réseaux IoT comportant 100 nœuds de capteurs distribués aléatoirement sur une zone de 10000 m² et une unique station de base située soit au centre ou en dehors de la zone du réseau. Tous les nœuds de capteurs disposent d'une énergie initiale de 2J.

1.9 Structure de la thèse

Nous commençons cette thèse par le deuxième chapitre dédié à la définition des réseaux IoT, de leurs architectures de base, les caractéristiques de chacune de ses composantes, leurs domaines d'applications, les défis et les contraintes rencontrés dans ces réseaux, et à la présentation d'une revue des techniques de conservation de l'énergie.

Dans le troisième chapitre, nous définissons l'optimisation mathématique, ses notions de base et nous décrivons le processus général à suivre pour la résolution des différents problèmes d'optimisation.

Dans le quatrième chapitre, nous abordons le problème de l'optimisation de la consommation d'énergie dans les réseaux IoT. Nous décrivons une formulation mathématique détaillée et complète du problème à l'étude sous forme d'un programme linéaire en nombres entiers. Nous présentons l'approche classique que nous avons développé pour résoudre le modèle mathématique, les résultats obtenus lors des tests de performance, ainsi qu'une analyse et discussion de ces derniers.

Dans le cinquième chapitre, nous définissons les notions de base de l'informatique quantique, par la suite nous présentons ses avantages et ses forces à travers une revue des techniques d'optimisation basées ou inspirées de l'informatique quantique. Nous décrivons une métaheuristique inspirée-quantique QIC qui permet de déterminer un clustering des réseaux IoT qui offre une réduction significative de l'énergie à consommer. Puis nous présentons une autre nouvelle métaheuristique inspirée-quantique QIPSOC, qui est une version améliorée de QIC, qui offre des réductions supplémentaires de la consommation de l'énergie et du temps d'exécution de l'algorithme. Ceci est suivi par une étude extensive et d'une comparaison des résultats des tests de performances des méthodes proposées.

Finalement, cette thèse sera conclue dans le dernier chapitre, et des perspectives de travaux futurs seront proposées. La liste des références est présentée à la toute fin, suivant le style standard de l'institut des ingénieurs électriciens et électroniciens (IEEE).

CHAPITRE 2 – ÉTAT DE L'ART

2.1 Introduction

Ces dernières années, une nouvelle technologie est apparue en force dans notre vie. Presque tous les objets physiques de notre quotidien sont connectés à Internet grâce à l'Internet des Objets (IoT) qui est le fruit des progrès réalisés ces dernières décennies dans les domaines de la microélectronique, de la micromécanique, et des technologies de communication sans fil.

L'Internet des objets actuel permet de décrire un réseau qui fonctionne principalement grâce à des nœuds de capteurs placés dans des objets/infrastructures physiques de différentes natures. Ces nœuds de capteurs sont implémentés dans le but de collecter, émettre et de recevoir des données spécifiques à télécharger sur des plateformes IoT. Par la suite, ces données sont analysées et enrichies afin d'être utilisées pour répondre aux requêtes des utilisateurs et/ou pour optimiser l'utilisation des appareils inclus dans le réseau.

Ces réseaux sont désormais incontournables dans différents domaines tels que : l'environnement, la domotique, le médical, la logistique, et dans la sécurité et la surveillance des infrastructures critiques.

2.2 Architecture des réseaux IoT

Un réseau à technologie IoT est composée de trois structures de base :

1. **La structure de perception** qui est constituée d'un ensemble de nœuds de capteurs intégrés dans des objets physiques fixes ou mobiles, répartis dans une zone géographique bien définie. Ces nœuds de capteurs sont chargés de la détection, la mesure et le recueil de certains paramètres physiques de l'environnement tels que le taux d'humidité, la température, la présence de mouvements ou même l'identification d'autres objets intelligents dans l'environnement.

2. **La structure réseau** qui est chargée de relier et de connecter les éléments IoT à d'autres objets intelligents, à des périphériques réseau et à des serveurs. La connexion

établie peut être filaire ou non-filaire, à courte portée (wifi, Bluetooth, ...) ou à longue portée (3G, 4G, ...). Elle peut comprendre une ou plusieurs stations de bases responsables de la transmission et la réception des données fournies par les nœuds de capteurs du réseau.

3. **La structure logicielle** qui intègre, traite et analyse les données reçues, puis les utilise pour communiquer avec les capteurs et fournir des services spécifiques à l'utilisateur. Les services fournis dépendent du type de l'application dans laquelle l'internet des objets est déployé (maison intelligente, santé, industrie, ... etc.) et des besoins de l'utilisateur. La figure 2.1 représente l'architecture de base d'un réseau IoT.

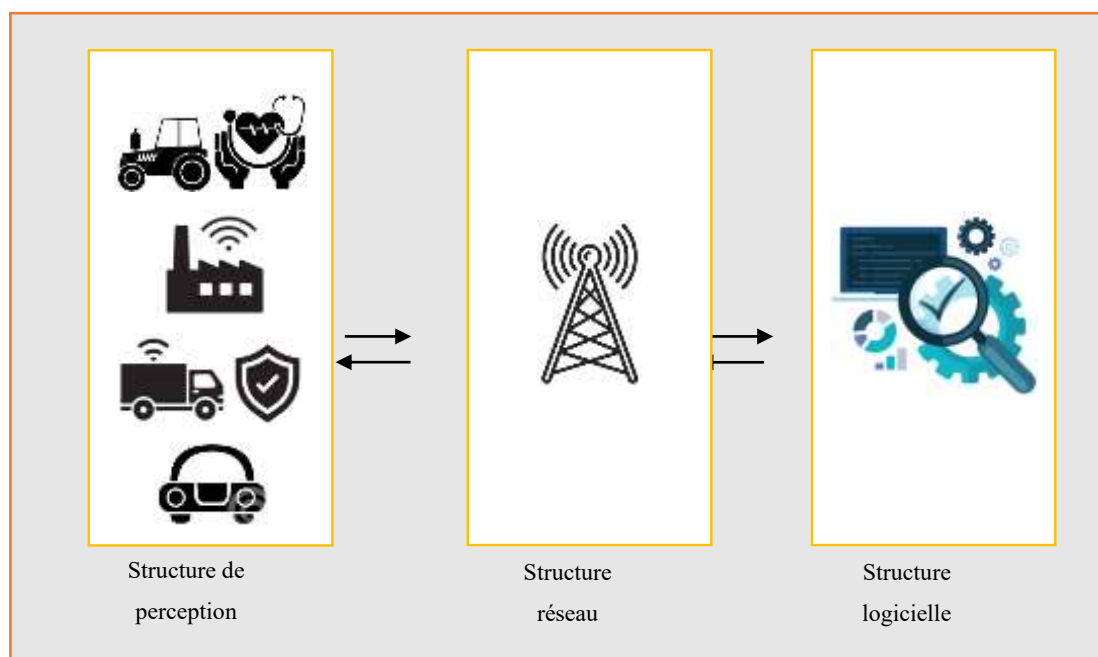


Figure 2.1 Architecture de base d'un réseau IoT.

Dans le cas le plus simple, tous les nœuds de capteurs du réseau se situent à proximité de la station de base pour que les données soient acheminées en un seul saut direct. Cependant, dans les plus grands réseaux, déployés sur une surface importante, de nombreux capteurs sont très distants de la station de base et leurs données ne peuvent pas être transmises directement mais doivent transiter par d'autres nœuds de capteurs. Ainsi, deux types de topologies peuvent être mises en

place pour assurer la transmission des données des nœuds de capteurs vers la station de base [1] :

1. **Topologie plate** : Un réseau de nœuds de capteurs sans fil plat (figure 2.2) est un réseau homogène. Tous ses nœuds de capteurs sont de caractéristiques identiques et disposent des mêmes ressources et fonctionnalités. Le routage des données entre les nœuds de capteurs et la station de base peut être basé sur des communications directes (en un seul saut) ou des communications multi-sauts, selon le service, le type et le nombre de nœuds de capteurs dans le réseau.




Figure 2.2 Topologie plate d'un réseau IoT.

L'un des plus grands inconvénients des topologies plates est le fait qu'elles ne soient pas évolutives. De plus, elles ne sont pas toujours efficaces énergétiquement ni sécuritaires surtout lorsque l'envoi de données d'un nœud de capteurs vers la station de base doit impliquer plusieurs nœuds intermédiaires.

2. **Topologie hiérarchique** : Les nœuds de capteurs d'un réseau hiérarchique sont regroupés en grappes ou clusters qui correspondent à différents niveaux de responsabilité. Chaque grappe est composée d'une tête de cluster (CH) et aussi d'un ensemble de nœuds de capteurs membres. Les têtes de clusters agissent comme des relais entre les nœuds de capteurs membres et la station de base. Les nœuds de capteurs membres acquièrent et envoient des données aux têtes de clusters, qui transmettent à leur tour les données vers la station de base directement ou via d'autres têtes de cluster, comme le montre la figure 2.3.




Figure 2.3 Topologie hiérarchique d'un réseau IoT.

Les architectures en grappes (clustering) améliorent l'efficacité énergétique, l'évolutivité du réseau tout en maintenant une hiérarchie dans le réseau et offrent en plus, des perspectives telles que l'agrégation et la sécurité des données collectées.

Dans la topologie hiérarchique, il est également possible d'utiliser une transmission multi-sauts (en chaîne) entre les nœuds membres des grappes comme illustré dans la figure 2.4.




Figure 2.4 Topologie hiérarchique d'un réseau IoT avec transmission multi-sauts.

Dans les différentes applications de l'internet des objets, les stations de base ainsi que la structure logicielle sont supposées avoir une grande capacité énergétique, de calcul et de stockage. Donc, elles n'ont pas de contraintes en termes d'énergie et de stockage contrairement aux nœuds de capteurs qui sont restreints en ressources. Dans

la section suivante nous allons explorer les composantes et décrire les caractéristiques générales des nœuds de capteurs.

2.3 Caractéristiques des nœuds de capteurs IoT

Les nœuds de capteurs qui constituent la base des réseau IoT sont des composantes électroniques miniaturisées conçues pour être intégrées dans des objets physiques dans le but de collecter des informations spécifiques et de les communiquer entre eux et/ou avec la station de base. Pour assurer ces tâches, chaque nœud de capteurs est doté de [1] :

- **Une unité d'acquisition** qui permet de mesurer des données physiques telles que l'humidité, la chaleur, la pression ...
- **Une unité de traitement** qui collecte, contrôle et conserve les données recueillies et les prépare pour la transmission. La capacité de stockage et de traitement, ainsi que la puissance de calcul de l'unité de traitement sont très limitées et ne sont pas extensibles.
- **Une unité de communication** composée d'un émetteur et d'un récepteur assurant la communication avec la station de base et les autres nœuds via une liaison radio filaire ou non-filaire. Les unités de communications ont une portée de transmission limitée, ce qui nécessite l'utilisation d'une antenne supplémentaire pour obtenir un signal plus puissant.
- **Une batterie** qui alimente toutes les unités du nœud de capteurs. Ce dernier reste actif et fonctionnel pendant une durée limitée par la capacité de sa batterie.

Dans certains modèles, un nœud de capteurs peut également comprendre :

- **Un système de localisation géographique** GPS ou un algorithme de localisation.

- **Une unité mobile** qui assure le déplacement du nœud de capteurs afin d'accomplir ses tâches. Cette unité vient toujours avec une alimentation énergétique séparée de celle du nœud de capteurs.

La figure 2.5 conceptualise l'architecture générale d'un nœud de capteurs.

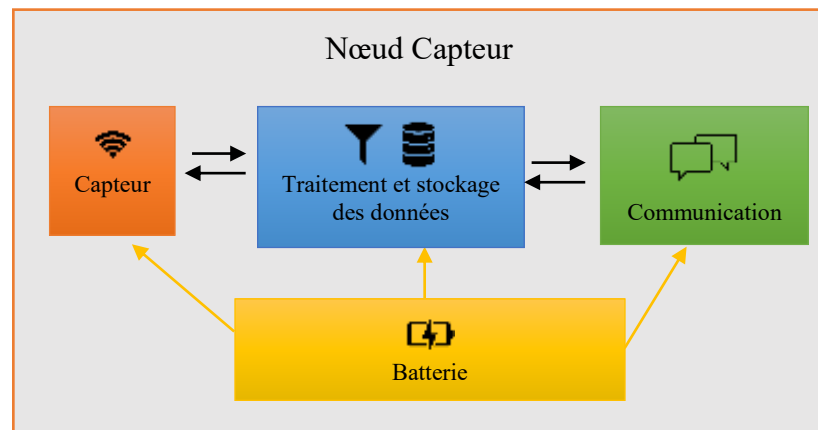


Figure 2.5 Architecture générale d'un nœud de capteurs.

En conséquent, les nœuds de capteurs sont caractérisés par [1]:

1. Une capacité de stockage et de traitement très restreinte.
2. Une courte portée de transmission liée aux limitations de la puissance du signal et de la capacité de rayonnement des antennes utilisées.
3. Une énergie limitée : En général, les batteries utilisées ont une capacité énergétique très limitée. De plus, dans la plupart des applications, il est problématique, voire impossible, de recharger ou de changer la batterie. Et lorsque cette dernière est épuisée, le nœud de capteurs ne peut fournir aucun service et il est considéré mort et il est instantanément retiré du réseau.

Par exemple, le nœud de capteurs « Mighty Grecko EFR3MG12 » de silicone Lab, présenté dans la figure 2.6, est composé d'un microcontrôleur 32 bits ARM® Cortex®-M4 avec une fréquence de fonctionnement maximale de 40MHz, 1Mo de mémoire et 256 Ko de RAM, et offre une puissance d'émission allant jusqu'à 19,5dBm pour les radios 2,4GHz et 20dBm pour les radios Sub-GHz.




Figure 2.6 Le nœud de capteurs «Mighty Grecko EFR3MG12» de silicone Lab.

Compte tenu des caractéristiques et des limitations des nœuds de capteurs, il est crucial d'optimiser l'utilisation des ressources énergétiques de ces derniers pour permettre la continuité de la collection et la transmission de données sans compromettre les performances globales du réseau.

2.4 Applications des réseaux IoT

La mise en œuvre de la technologie IoT a un impact économique et environnemental considérable sur les populations du monde entier. L'IoT a été déployée dans une large variété d'applications dans différents secteurs tels que l'habitation, gestion des villes, l'agronomie, la logistique, la santé, la sécurité, ...etc.

Dans [2], Libelium inventorie cinquante applications potentielles dans le domaine des nœuds de capteurs et de l'Internet des objets.

Parmi ces applications, nous citons [1-3] :

- **Applications domotiques** : Qui consistent à l'intégration des nœuds de capteurs dans des dispositifs à utilisation domestique tels que les appareils électroménagers, systèmes d'éclairage, aération, chauffage, climatiseurs, ... afin de permettre à l'utilisateur de les gérer et de les contrôler sur place, à distance voire d'une façon intelligente (auto-control).
- **Applications en agronomie** : le déploiement des nœuds de capteurs dans un champ de culture fournit à l'utilisateur des données réels sur le niveau d'humidité du sol et permet ainsi d'effectuer une irrigation sur mesure optimisée ce qui permet de préserver les ressources d'eau et de réduire les dépenses.

- **Applications médicales** : qui permettent la surveillance et le suivi de patients à distance. Les capteurs fixés sur le patient peuvent collecter en permanence, ou suivant un programme bien défini, des informations telles que la température, la pression, le taux du glucose, l'activité cardiaque, Ces informations sont partagées avec les personnes autorisées telles que les médecins et/ou les infirmiers pour suivre l'état de santé du patient et prendre les mesures nécessaires. Ainsi, l'état de santé du patient est surveillé en permanence et il n'a, donc, pas besoin de se déplacer physiquement à l'hôpital que dans les cas critiques.
- **Applications logistiques** : Les systèmes de transports intelligents permettent la rationalisation de la logistique puisque les données sont recueillies et reçues en temps réel. Ces systèmes effectuent l'évaluation de l'état des routes, la gestion des infrastructures de transport, le suivi des performances des véhicules et la réduction des temps d'arrêt et des retards.
- **Applications en surveillance et sécurité** : Les nœuds de capteurs déployés dans une zone de guerre peuvent fournir des informations précieuses dont le commandant peut avoir besoin pour affiner ses décisions. Les capteurs peuvent surveiller un champ de bataille en fournissant des alertes de présence des ennemis, et en les associant aux soldats, leurs positions, états physiologiques ainsi que l'état de leurs équipements peuvent être surveillés à tout instant.
- **Applications industrielles** : L'industrie intelligente exploite la technologie IoT dans les environnements de fabrication où chaque machine de chaque installation devient connectée pour fournir des données précieuses en temps réel. Ces données sont exploitées, par exemple, pour surveiller et optimiser le processus de production ce qui permet aux organisations d'automatiser les opérations et d'améliorer les performances de fabrication.
- **Applications environnementales** : Une application IoT peut prendre en charge, par exemple, la détection de substances nocives, de rejets chimiques, d'incendies et plus encore, permettant ainsi aux états et aux industries de préserver la propreté et la sûreté de notre planète.

La figure 2.7 regroupe l'ensemble des applications citées par Libelium [2].

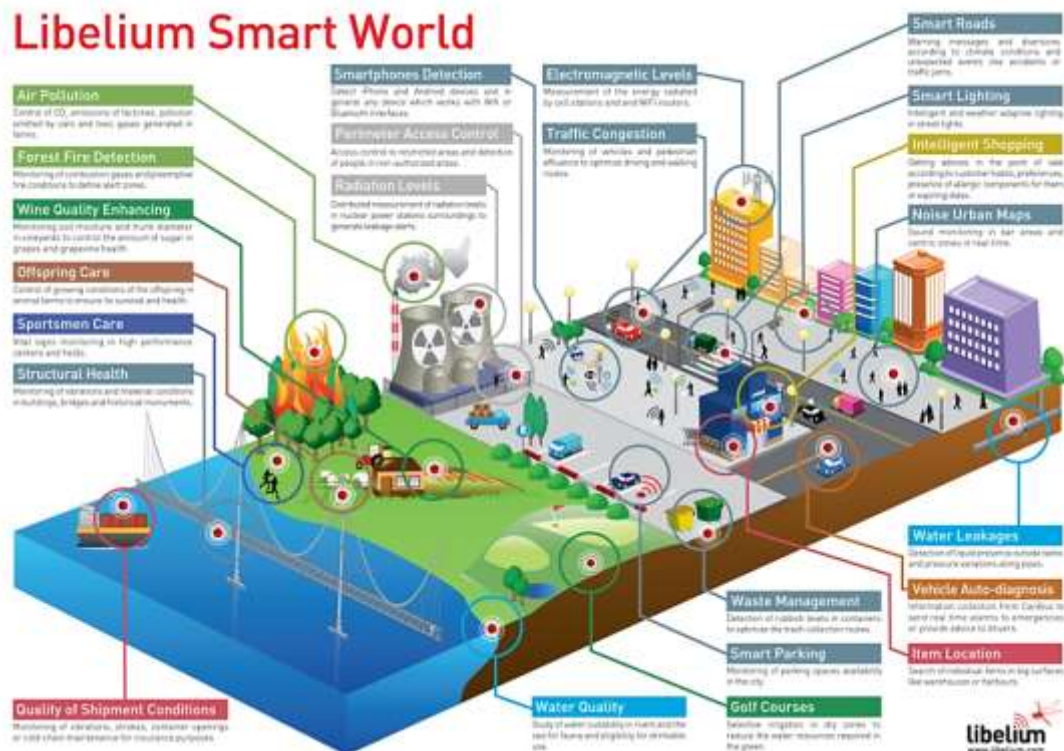


Figure 2.7 Cinquante applications potentielles de l'Internet des objets [2].

2.5 Défis et contraintes dans les réseaux IoT

Dans un futur proche, des milliards de dispositifs devraient être connectés aux réseaux IoT. Ceci entraînera une augmentation massive du trafic et la génération d'une quantité de données immense sans précédent [4]. Le trafic lourd généré aura un impact direct sur les différents services du réseau tels que le routage, les ressources énergétiques, les communications, la qualité de services, la sécurité...

Il est donc primordial de d'améliorer l'efficacité et la performance des réseaux IoT en développant et en adoptant des solutions aux divers problèmes rencontrés, notamment pour [5]:

- 1. Routage des données :** Le routage dans un réseau IoT doit être déterminé par un processus de sélection minutieuse du chemin suivant lequel les données sont acheminées à partir d'un point de départ vers un point de destination. Plusieurs critères peuvent être considérés pour la sélection du schéma de routage tels que la

durée du trajet, la longueur du chemin, l'énergie à consommer, la sécurité voire une combinaison de ces critères.

2. **Conservation de l'énergie** : Afin de bien exploiter les ressources énergétiques, consolider la performance et prolonger la durée de vie du réseau, des méthodes d'économie d'énergie ainsi que des techniques de programmation de périodes d'activités (sommeil-éveil) doivent être implémentées dans les applications IoT.

3. **Contrôle de la congestion** : La congestion dans les réseaux IoT est le résultat du nombre élevé de dispositifs de différents types connectés au réseau. Ceci entraîne une détérioration de la qualité des communications au sein du réseau ce qui compromet la sécurité des données et cause une augmentation des délais de transmission. De ce fait, l'implémentation d'un mécanisme de contrôle et de gestion efficace de la congestion est primordiale dans les réseaux IoT.

4. **Hétérogénéité** : Un réseau IoT peut comporter des objets et des nœuds de capteurs de différents types et caractéristiques générant des données de différentes natures. D'où la nécessité de la mise en place d'un système approprié de gestion et de traitement de données dans le réseau.

5. **Évolutivité** : Le nombre d'objets se connectant aux réseaux IoT est en constante augmentation. Ainsi, un des grands défis dans les réseaux IoT consiste à l'intégration fluide d'un objet supplémentaire dans le réseau tout en maintenant la stabilité et l'efficacité de ce dernier.

6. **Sécurité** : La protection des données est une exigence cruciale pour sécuriser le transport des messages dans le réseau, d'où la nécessité de mettre en place un outil performant pour protéger les données contre tout type de violation.

7. **Qualité de service (QoS)** : Les paramètres de QoS à améliorer dans un réseau IoT sont considérés sous différents angles et dimensions, tels que la gestion de la bande passante, de la latence, et des retards, la réduction du taux de perte de paquets, l'évitement des interférences et de la déstabilisation.

2.6 Revue des techniques d'optimisation de la consommation de l'énergie dans les réseaux IoT

Les techniques d'optimisation de l'efficacité énergétique dans les réseaux IoT peuvent être classées comme suit [3] :

- (i) **Techniques d'optimisation radio** : Ces techniques visent l'amélioration de la qualité du signal à travers la sélection dynamique des canaux et la réception/transmission coopérative. De telles techniques offrent une couverture réseau efficace et robuste.

Dans [6], Azari et Cavdar (2018) décrivent une méthode d'apprentissage distribuée pour le contrôle des opérations en technologie longue portée. La méthode proposée permet d'adapter les paramètres de communication des dispositifs à l'environnement afin de minimiser la consommation d'énergie et la collision des données transmises sur des canaux partagés.

D'une autre part, Alonso et al. (2018) ont étudié la possibilité d'utiliser la technologie IoT pour surveiller et améliorer l'efficacité énergétique et la maîtrise de l'utilisation du spectre des réseaux de radiodiffusion dans la bande des ultra-hautes fréquences [7]. Cette étude a abouti à la description d'une nouvelle architecture de réseau avec une boucle de rétroaction IoT et à la conception d'un algorithme à longue portée/NB-IoT. Cet algorithme est composé de 2 étapes principales, la première consiste à choisir le meilleur ensemble de stations de base afin de minimiser l'infrastructure, puis la deuxième optimise la consommation d'énergie en connectant les utilisateurs aux stations de base actives en empruntant le chemin qui réduit la puissance isotrope rayonnée effective tout en minimisant la perte des données. L'application de cette approche sur un radiodiffuseur de La Havana a permis de réduire la consommation de l'énergie de 15 à 16,3 % et ce en comparaison avec les réseaux de diffusion multimédia numérique terrestre actuels. De plus, l'efficacité de l'utilisation du spectre a été augmentée de 32 à 35 % et la disponibilité des canaux TVWS de 34 % pendant 90 % du temps.

Quelques mois après, Moreno et al. (2019) ont développé un algorithme basé sur le système L pour une fractale remplissant l'espace de Hilbert pour l'optimisation adaptative et dynamique d'un réseau IoT centralisé. L'algorithme proposé offre une portée de transmission Wi-Fi étendue avec partage des paramètres permettant ainsi d'augmenter l'efficacité énergétique d'une maison intelligente [8].

Chi et Radwan (2020) ont décrit un schéma d'attribution de petites cellules pour l'IoT dans une ville intelligente [9]. Le problème est formulé mathématiquement à l'aide d'un modèle mathématique à variables entières visant la maximisation de l'efficacité énergétique et du taux de transfert des données. De plus, un nouvel algorithme, basé sur la fusion de l'algorithme Branch-and-Bound (B&B) et de l'algorithme génétique de tri non dominé II (NSGA-II) [10], est conçu spécialement pour la résolution du programme mathématique élaboré.

Enfin, Ozturk et al. (2022) propose une nouvelle approche basée sur un algorithme d'apprentissage pour déterminer le type de connexion sans fil, l'unité de traitement des données et la quantité de données à télécharger afin de répondre aux objectifs de consommation d'énergie, de coût, de sécurité et de temps de réponse [11].

- (ii) **Techniques de réduction des données:** Ces techniques agissent sur la latence en minimisant la transmission des données et utilisent des mécanismes d'agrégation pour améliorer la qualité du service.

Dans [12], Gupta et al. (2017) fournissent une boîte à outils pour la modélisation et la simulation des techniques de gestion des ressources dans l'Internet des objets, l'informatique périphérique et les réseaux d'informatique en brouillard. Et dans le contexte de la nouvelle génération verte de la NB IoT, POPL et al. (2019) décrivent une technique économe en énergie, appelée analyse du modèle thermique zonal, pour l'utilisation productive de l'eau dans le domaine de l'agronomie. De plus, ils ont mis en place un système de surveillance de la santé économe en énergie (E2AHMS) assurant la distribution adaptative de la puissance de transmission nécessaire pour la surveillance des patients [13]. Dans [14],

Kumar Arun et al. (2020) utilisent l'algorithme d'optimisation de la baleine, inspirée de la méthode de chasse collective de la baleine à bosse, pour résoudre le problème de l'allocation des ressources dans l'informatique en nuage (cloud computing).

- (iii) **Techniques de sommeil et de réveil:** Ces techniques programment et contrôlent des périodes d'activité productive de l'IoT dans le but d'optimiser la consommation d'énergie, d'augmenter la durée de vie du réseau, de réduire la production, le stockage et la transmission de données inutiles, et de préserver la qualité des données.

Dans ce contexte, Tekin et al. (2020) ont modélisé à l'aide d'un graphe d'événements temporisés dans lequel les sommets correspondent à l'état des nœuds, les arcs représentent les liens entre les états et les poids des temps de transition d'un état à l'autre. Par la suite, ils ont utilisé l'algèbre dioïde Max-plus avec des dispositifs de réglage pour sélectionner les périodes d'activité et de sommeil afin d'éviter les réveils inutiles et de fournir des données en fonction des besoins anticipés des applications [15].

- (iv) **Routage économe en énergie :** Un bon schéma de routage des données, soit en regroupant les nœuds du réseau et en sélectionnant la tête de cluster de manière appropriée, soit en optant pour un autre protocole de transmission des données, joue un rôle majeur sur la consommation de l'énergie, l'évolutivité et la robustesse du réseau IoT. Praveen Kumar et Rajasekhara (2017) ont proposé l'algorithme de recherche gravitationnelle fractionnelle multi-objectif permettant de décrire un routage économe en énergie dans l'IoT [16]. En la première étape de l'algorithme, l'énergie de chaque nœud est estimée afin de délivrer les paquets suivant un routage efficace, puis l'algorithme détermine la tête de cluster de manière itérative. L'approche proposée prend en considérations plusieurs objectifs dont la distance, le délai, la durée de vie du lien et l'énergie. En parallèle, Dhumane et Prasad (2017) proposent une métaheuristique multi-objective pour le routage économe en énergie dans les réseaux IoT appelée la recherche gravitationnelle fractionnelle multi-objective [17]. Dans [18],

Alazab et al. (2021) introduisent un modèle d'optimisation multi-objectif pour la sélection de tête de cluster garantissant l'efficacité énergétique du réseau. L'algorithme prend en considération un ensemble de nœuds candidats à être des têtes de cluster, le ratio d'énergie résiduelle et le degré d'équilibre énergétique. Les performances de l'algorithme proposé en termes de délai, d'énergie normalisée, et de nœuds vivants par itération ont été vérifiées par une analyse comparative avec les méthodes les plus répandues telles que la méthode inspirée des colonies d'abeilles artificielles [19], l'algorithme génétique [20], l'optimisation par essaim de particules [21], la recherche gravitationnelle [22], l'optimisation par baleine [23], l'optimisation par flamme de papillon de nuit [24], l'optimisation par baleine auto-adaptative [25] et les algorithmes d'optimisation par cavalier [26]. Les résultats montrent l'efficacité supérieure du modèle de sélection des têtes de cluster proposé.

- (v) **Le problème de la composition de services:** étant fréquemment rencontré dans les réseaux IoT lorsqu'un utilisateur formule une demande compliquée à laquelle un dispositif ne peut pas répondre seul et qu'un service composite doit donc être créé. Dans des recherches connexes, un algorithme d'optimisation multi-objectif efficace basé sur l'essaim de fourmis chaotiques (CAS) a été développé dans [27]. Le CAS tire profit à la fois du comportement chaotique d'une fourmi unique et du comportement d'auto-organisation de la colonie de fourmis pour redéfinir les concepts de "voisins" et de règles de "sélection des voisins". De plus, une approche basée sur les archives y est incorporée pour permettre une convergence rapide vers le véritable front de Pareto avec un ensemble de solutions uniformément distribuées. La méthode proposée a été testée sur une panoplie de problèmes d'optimisation multi-objectifs bien connus, et a surpassé les algorithmes de pointe tels que l'algorithme d'optimisation par essaim de particules et l'algorithme génétique de tri non dominé, en termes de distance générationnelle, de taux d'erreur et d'espacement.

Alsaryrah et al. (2018) ont décrit et appliqué un modèle d'optimisation du plus court chemin bi-objectif pour la composition de services IoT. Le

modèle proposé répond aux exigences de l'IoT en matière de maximisation de la qualité de service (y compris le temps d'exécution, la latence du réseau et le coût) tout en minimisant la consommation d'énergie à l'aide d'un algorithme à impulsions avec quatre techniques d'élagage intégrées développées à cet effet [28]. De plus, Dans [29], Mehran et al. (2019) décrivent une nouvelle approche multi-objectif, appelée MAPO, pour résoudre les problèmes de fourniture de ressources et de placement d'applications IoT dans le brouillard. L'approche MAPO est basée sur un algorithme d'optimisation génétique multi-objectif qui prend en compte trois critères conflictuels, à savoir le temps d'exécution, la consommation d'énergie et le coût économique, et qui a comme but d'approcher l'ensemble de Pareto des placements optimisés des composants d'applications sur les dispositifs de brouillard disponibles. Cette méthode a été déclarée efficace après comparaison avec deux méthodes connexes de l'état de l'art [51,30] en termes de taille des données de communication, de charge de travail du CPU des composants, de qualité et d'évolutivité de l'algorithme.

Dans [31], Kashyap et al. (2020) ont exploré l'utilité de l'utilisation des métaheuristiques multi-objectifs, notamment le très populaire algorithme génétique de tri non-dominé, pour fournir une solution optimale au problème de composition de services.

Il est essentiel de souligner que dans le contexte de l'optimisation de la consommation d'énergie dans les réseaux IoT impliquant une architecture de clustering, aucun des travaux mentionnés ci-dessus n'a suivi un processus d'optimisation rigoureux en établissant une formulation mathématique complète basée sur une définition adéquate des variables de décision permettant ainsi de modéliser de manière appropriée les objectifs ainsi que toutes les contraintes.

2.7 Conclusion

Dans notre vie de tous les jours, l'internet des objets est présent partout. Cette technologie récente est en progrès permanent et est largement utilisée dans plusieurs

domaines tels que la santé, la gestion urbaine, la communication, le transport, la gestion d'entreprise et les processus industriels...

Cependant, les applications de l'IoT sont confrontées à des problèmes critiques liés au routage des données, consommation de l'énergie, contrôle de la congestion, gestion de l'hétérogénéité et de l'évolutivité dans le réseau, la sécurité et la qualité de service.

Dans la suite du document, nous nous concentrons sur le problème d'optimisation de la gestion des ressources énergétiques des nœuds de capteurs dans les réseaux IoT.

Dans le chapitre suivant, nous allons commencer par présenter les notions de base des techniques d'optimisation et nous décrivons les étapes constituant un processus d'optimisation mathématique classique. Ces étapes sont primordiales pour produire une solution d'une bonne qualité permettant d'atteindre les objectifs désirés.

CHAPITRE 3 – TECHNIQUES DE L’OPTIMISATION MATHÉMATIQUE

3.1 Introduction

En utilisant l'un des mots : minimum, minimiser, maximum, et/ou maximiser pour décrire une situation quelconque, cette dernière décrit un problème décisionnel et il devient possible de la formuler sous forme d'un problème d'optimisation mathématique.

La prise de la décision liée à la situation considérée reviendra à caractériser et à déterminer un optimum, qui est soit le maximum, soit le minimum ou même encore un compromis entre les deux selon les critères retenus, tout en respectant un ensemble de contraintes.

L'ensemble des techniques de l'optimisation mathématique regroupe les méthodes dédiées à l'analyse et à la résolution analytique des problèmes décisionnels qui consistent à optimiser (minimiser ou maximiser) un ensemble de critères sous condition de satisfaire un ensemble de contraintes.

Dans ce chapitre, nous décrivons les étapes générales des techniques de l'optimisation mathématique, soient : la définition du problème d'optimisation, la modélisation mathématique et la résolution.

3.2 Définition du problème

Étant donnée une situation nécessitant la prise d'une décision permettant l'optimisation d'un ou de plusieurs critères donnés. La première étape permettant d'établir une décision satisfaisante est la définition explicite du problème d'optimisation correspondant. Ça revient à bien identifier le ou les objectifs à atteindre et à déterminer, également, toutes les contraintes à satisfaire obligatoirement.

Pour pouvoir prendre une décision, le problème d'optimisation est modélisé mathématiquement comme décrit dans la section suivante.

3.3 Modélisation mathématique du problème

La modélisation consiste à abstraire le problème sous des formes quantitatives et/ou qualitatives. Plus particulièrement, la modélisation mathématique d'un problème d'optimisation consiste à la formulation des objectifs et des contraintes en termes de fonctions, équations et/ou inéquations.

Pour cela, un ensemble de variables de décision est défini. Ces variables de décisions sont reliées entre elles par des relations logiques, équations et/ou inéquations, représentant les contraintes du problème. De plus, le ou les objectifs du problème sont également modélisés par des fonctions, appelées fonctions objectifs, en les variables de décision. Les variables de décision prennent leurs valeurs parmi un ensemble fini de valeurs de manière à vérifier toutes les contraintes tout en offrant la meilleure valeur à la fonction objectif ou le meilleur compromis entre les fonctions objectifs si le problème est multi-objectif.

L'ensemble des variables de décision, les relations logiques représentant les contraintes et les fonctions objectifs forme le modèle ou le programme mathématique correspondant au problème d'optimisation considéré.

Le programme mathématique (P) présente la forme générale d'un programme mathématique de maximisation avec une seule fonction objectif:

$$(P) \left\{ \begin{array}{l} \text{maximiser } f(x) \\ \text{s. c,} \\ Ax \leq B \\ x \in X \end{array} \right. \quad (3.1)$$

Où,

x est un vecteur de variables de décision prenant ses valeurs dans le domaine X ,

$Ax \leq B$ représente l'ensemble des contraintes,

Et, $f(x)$ est la fonction objectif à maximiser.

Une solution du programme mathématique (P) est une affectation de valeurs de l'ensemble X aux variables du problème de façon à satisfaire toutes les contraintes.

Si un vecteur $x \in X$ satisfait toutes les contraintes de (P) , i.e. $Ax \leq B$, alors x est dit « solution réalisable » ou « solution admissible » de (P) . L'ensemble D regroupant toutes les solutions réalisables est appelé « ensemble de solutions » ou « polyèdre réalisable ». Si le polyèdre réalisable est fini, il est délimité par un ensemble de droites, plans ou hyperplans décrits par les contraintes du problème mathématique.

De plus, si $x^* \in X$ est une solution réalisable de (P) telle que pour toute solution réalisable $x \in X$ on a $f(x^*) \geq f(x)$, alors x^* est dite « solution optimale ».

En complément, si les éléments du vecteur solution x prennent leurs valeurs dans \mathbb{N} , le programme (P) est dit programme mathématique en nombres entiers.

Le programme mathématique (P) est dit linéaire si la fonction objectif ainsi que les contraintes s'écrivent comme des combinaisons linéaires des variables de décision.

Si les contraintes sont linéaires alors que la fonction objectif est quadratique, on dit que (P) est un programme quadratique.

Le tableau 3.1 illustre une classification des problèmes d'optimisation.

Tableau 3.1 Classification des problèmes d'optimisation.

| Caractéristiques du programme mathématique | | | Type du problème |
|--|--------|---------------------------|--------------------------------------|
| Variables de décision | Type | Nombres réels | Continu |
| | | Nombres entiers | <i>En nombres entiers ou discret</i> |
| Contraintes | Nombre | Pas de contraintes | <i>Non contraint</i> |
| | | Une/plusieurs contraintes | <i>Avec contraintes</i> |
| Fonction objectifs | Nombre | 1 | <i>Mono-objectif</i> |
| | | >1 | <i>Multi-objectif</i> |
| | Type | Linéaire | <i>Linéaire</i> |
| | | Non-linéaire | <i>Non-linéaire</i> |

Il est important de noter qu'on peut proposer plusieurs modèles mathématiques pour un même problème d'optimisation.

3.4 Résolution du modèle mathématique

Étant donné un modèle mathématique (P) formulant un problème d'optimisation.

La résolution de ce problème d'optimisation revient à trouver une solution $x^* \in D$ optimisant la valeur de $f(x)$. Elle se fait en appliquant une des techniques de l'optimisation mathématique ou sinon par la description d'une nouvelle méthode de résolution.

Les méthodes de résolution peuvent être classées principalement en deux catégories : méthodes exactes et méthodes approchées, suivant leur garantie sur la qualité de la solution qu'elles fournissent.

3.4.1 Méthodes exactes

Ces méthodes parcourent en général au complet l'ensemble des solutions réalisables d'une manière exhaustive et intelligente, et par conséquent, garantissent l'optimalité de la solution obtenue à la fin de l'exécution.

Ces méthodes se caractérisent par un temps d'exécution très élevé souvent exponentiel. De ce fait, leur application est efficace seulement sur des problèmes de petites tailles.

Les méthodes exactes peuvent être classifiées, suivant le processus utilisé pour l'exploration de l'ensemble des solutions, en : méthodes par séparation et évaluation, méthodes de programmation dynamique et méthodes de résolution analytique.

- (i) **Méthodes par séparation et évaluation ou arborescentes** : Ces méthodes procèdent par énumération implicite et intelligente de l'ensemble des solutions réalisables [32]. En effet, le principe ne consiste pas à énumérer toutes les solutions réalisables, mais à restreindre graduellement l'ensemble des solutions

réalisables en alternant une étape de séparation et une étape d'évaluation, et ce jusqu'à parvenir à la preuve de l'optimalité d'une solution.

Au cours de la phase de séparation, l'ensemble des solutions réalisables est divisé en plusieurs sous-ensembles. Ensuite, dans l'étape d'évaluation, chaque sous-problème correspondant au sous-ensemble généré par la séparation est résolu. Ainsi, elle calcule et fournit des bornes supérieures et inférieures de la valeur de la fonction objectif afin de déterminer si ce sous ensemble contient une solution. Si c'est bien le cas, l'exploration se poursuit, si non, la séparation suivant ce sous-ensemble s'arrête ce qui évite une exploration inutile.

Ce processus de séparation et évaluation peut être schématisé par une arborescence d'énumération, dont la racine correspond à l'ensemble des solutions réalisables du problème d'optimisation considéré, les nœuds représentent les sous-ensembles générés par la séparation et les feuilles correspondent aux sous-ensembles stérilisés par l'évaluation.

Ces méthodes présentent l'avantage d'être exploitables et adaptables à tous les problèmes d'optimisation combinatoire, leur seule exigence étant de disposer d'un ensemble fini de solutions.

- (ii) **Méthodes de programmation dynamique ou récursives** : Le principes de base des méthodes dynamiques et de diviser le problème initial en sous-problèmes indépendants, puis commencer la résolution récursive de ces sous-problèmes en commençant par le plus petit sous-problème jusqu'au plus grand tout en mémorisant à chaque étape les solutions et la valeur de la fonction objectif correspondante à chaque solution. Par la suite, les données de toutes les itérations sont utilisées pour construire une solution pour le problème initial [33-34].

Comme décrit dans le principe de l'optimalité de Bellman (1954), l'optimalité de la solution ainsi obtenue dépend fortement de l'existence d'une relation de récurrence permettant d'évaluer la valeur de la fonction objectif à une étape donnée en fonction de la valeur de la fonction objectif à l'étape précédente [35].

Ces méthodes peuvent être appliquées pour la résolution de n'importe quel problème d'optimisation, à condition de déterminer l'expression récursive de la solution en fonction de celle des sous-problèmes.

- (iii) **Méthodes analytiques de l'optimisation linéaire et non-linéaire** : Ces méthodes se basent sur l'utilisation du polyèdre des solutions réalisables, l'analyse mathématique vectorielle et du calcul matriciel pour déterminer une solution optimale. Elles sont justifiées par le théorème fondamental de l'optimisation linéaire qui atteste que si la valeur optimale de la fonction objectif d'un problème mathématique linéaire existe, alors elle est atteinte à au moins un des points extrêmes (sommets) du polyèdre réalisable [36].

Graphiquement, un point extrême correspond à une intersection des hyperplans correspondant aux contraintes qui délimitent le polytope réalisable.

À titre d'exemple, nous considérons le programme mathématique (PL) à deux variables de décision défini par :

$$(PL) \left\{ \begin{array}{l} \text{maximiser } x_1 + 2x_2 \\ \text{s. c,} \\ -\frac{1}{3}x_1 + x_2 \leq 3 \\ x_1 - 2x_2 \leq 3 \\ x_1 + x_2 \leq 6 \\ (x_1, x_2) \in [0, +\infty[\end{array} \right. \quad (3.2)$$

La figure 3.1 illustre la représentation graphique du polyèdre réalisable et des points extrêmes correspondant au programme mathématique (PL).

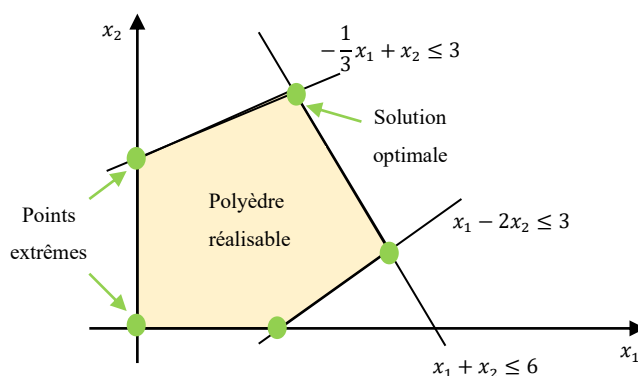


Figure 3.1 Polyèdre réalisable, points extrêmes, et solution optimale du programme mathématique (PL).

La première méthode proposée pour la résolution d'un problème linéaire avec contraintes d'inégalités est **la méthode du simplexe** décrite par George Bernard Dantzig en 1947 [37]. C'est une méthode de référence très connue et largement utilisée dans le domaine de l'optimisation mathématique linéaire. La méthode du simplexe démarre d'un point extrême quelconque puis exécute une série d'opérations de pivot qui effectue un déplacement d'un point extrême à un autre qui lui est adjacent. Ainsi, l'algorithme examine tous les points extrêmes et s'arrête lorsqu'il identifie un point extrême optimal correspondant à une solution optimale.

Bien que beaucoup de problèmes d'optimisation peuvent être formulés comme un programme mathématique linéaire, d'autres problèmes d'optimisation nécessitent une formulation mathématique sous la forme d'un problème linéaire en nombres entiers ou d'un problème non linéaire. Dans ces cas, il existe plusieurs autres méthodes exactes qui reposent sur le même principe de la structure polyédrale, de l'algèbre et du calcul matriciel telles que la méthode de la relaxation linéaire, la méthode de coupes et la méthode de génération de colonnes.

La méthode de relaxation linéaire consiste en la résolution du problème considéré en relâchant les contraintes d'intégralité sur les variables de décision puis résoudre le programme relaxé à l'aide d'une méthode d'optimisation linéaire telle que le simplexe [38]. Ceci permet de déterminer une borne supérieure et une borne inférieure sur la valeur optimale de la fonction objectif. Et lorsque ces deux bornes sont égales, la méthode fournit une solution optimale du problème.

La méthode de coupes repose sur le principe d'ajouter une ou plusieurs nouvelles contraintes, appelées coupes, pour éliminer une solution indésirable [39]. Cette méthode s'avère très efficace lorsqu'elle est introduite dans une méthode par séparation et évaluation, où à chaque étape de séparation une nouvelle coupe est intégrée dans le programme mathématique pour éliminer une solution non entière tout en relâchant les contraintes d'intégralité sur les variables de décision. L'évaluation peut se faire par l'exécution du simplexe par exemple.

La méthode de génération de colonnes est une technique très utilisée pour la résolution des problèmes linéaires de grande taille dont la résolution avec les méthodes précédemment présentées nécessite un temps d'exécution très important [40]. Le principe de la méthode consiste à résoudre itérativement une série de problèmes de tailles plus petites, dans le but d'obtenir une solution optimale au problème initial. Pour résoudre le problème initial dit aussi « maître », on considère un sous-ensemble de variables pour définir un "problème maître restreint" qui va être résout par la suite, et auquel on rajoute progressivement les variables non-encore considérées tout en exploitant la théorie de la dualité pour déterminer si une solution obtenue est optimale. Dans de nombreuses applications, la matrice A , définissant les contraintes, a une structure particulière qui peut être exploitée avantageusement pour choisir la variable à introduire à chaque itération. D'ailleurs, la seule difficulté liée à cette approche est le choix de la variable à introduire. C'est pourquoi on est amené à reformuler le programme mathématique de manière à présenter une structure adaptée à la résolution par génération de colonnes à travers l'utilisation de la méthode de décomposition de Dantzig-Wolfe [41].

3.4.2 Méthodes approchées

Le plus grand avantage offert par les méthodes exactes est la garantie de l'optimalité de la solution fournie. On est ainsi convaincu que ce serait la meilleure décision à prendre pour optimiser les critères considérés. Cependant, le temps nécessaire pour exécuter de telles méthodes augmente exponentiellement avec la taille du problème à résoudre. Ceci n'est pas toujours satisfaisant, surtout dans les situations réelles qui nécessitent une prise de décision instantanée. Pour cela, le décideur est amené, parfois, à faire recours aux méthodes d'optimisation approchées qui permettent de prendre une décision, pas nécessairement optimale, en un temps d'exécution réduit.

Dans la classe des méthodes approchées, nous distinguons deux types de méthodes : les heuristiques et les métaheuristiques.

- (i) **Les heuristiques :** Une heuristique est un algorithme approché qui s'appuie sur la structure et les caractéristiques du problème d'optimisation considéré, pour déterminer au moins une solution réalisable. En général, une heuristique est conçue pour un problème d'optimisation particulier et n'offre aucune garantie sur la qualité de la solution fournie.

Les heuristiques peuvent être classées suivant la procédure choisie pour le calcul de la solution réalisable en deux catégories : les heuristiques gloutonnes ou constructives et les heuristiques de recherche locale [42].

Les heuristiques gloutonnes partent d'une solution vide et génèrent de nouvelles solutions en ajoutant, itérativement, des composantes à la solution en cours de construction jusqu'à l'obtention d'une solution complète. Tandis que les heuristiques de recherche locale démarrent avec une ou plusieurs solutions initiales et cherchent à les améliorer dans un voisinage bien défini, telles que l'algorithme de la descente [43].

- (ii) **Les métaheuristiques :**

Le terme métaheuristique fait référence à une méthode d'optimisation approchée non-spécifique à un problème donné, mais qui peut être adaptée à divers problèmes.

Ces méthodes constituent une très bonne alternative aux méthodes exactes et aux méthodes heuristiques puisqu'elles permettent d'obtenir une solution réalisable, pas nécessairement optimale mais souvent de très bonne qualité, en un temps de résolution raisonnable sans nécessiter, en général, un espace de stockage important. Ainsi, elles sont plus adaptées à la résolution des problèmes d'optimisation de grandes tailles et aux situations réelles nécessitant une prise de décision rapide [16].

De plus, les métaheuristiques sont plus flexibles que les méthodes exactes et les méthodes heuristiques. Elles peuvent être adaptées pour répondre aux besoins de

la plupart des problèmes d'optimisation et n'imposent aucune exigence quant à la formulation mathématique du problème.

Elles s'inspirent, souvent, des phénomènes et des systèmes naturels tels que la théorie de l'évolution et des règles de la génétique, le comportement collectif dans les essaims et les règles d'interaction entre les individus, et même les processus de la physique et de la thermodynamique.

Les métaheuristiques peuvent être classées en trois catégories fondamentales suivant la manière utilisée pour manipuler les solutions [17-16] :

- **Les métaheuristiques de recherche locale ou de voisinage** partent d'une solution unique en lui apportant itérativement des modifications.

Étant donnée une solution s de l'ensemble réalisable D , une métaheuristique de recherche locale utilise une fonction de voisinage $V: D \rightarrow D$ pour générer un ensemble de solutions $V(s)$ obtenu en modifiant d'une façon élémentaire la solution s , puis choisir une solution de ce voisinage pour remplacer la solution courante s . Cette opération, dite « mouvement », est répétée jusqu'à la satisfaction d'un critère d'arrêt bien défini.

Le pseudo-code général des métaheuristiques de recherche locale est le suivant,

Métaheuristique de recherche locale

Générer une solution initiale $s \in D$;

Tant que le critère d'arrêt n'est pas satisfait ***faire***

Sélectionner s' dans le voisinage de s ($s' \in V(s)$) ;

Mettre à jour $s : s = s'$;

Retourner la meilleure solution rencontrée ;

Parmi ces métaheuristiques nous trouvons le recuit simulé, la marche aléatoire et la recherche taboue [44].

- **Les métaheuristiques basées sur une population de solutions** qui partent d'un ensemble de solutions réalisables de départ, dit aussi population de solutions initiales. Les solutions sont combinées et/ou manipulées itérativement pour en créer de nouvelles solutions qui viennent remplacer toutes ou quelques-unes des solutions courantes. Cette opération, dite « mouvement », est réitérée jusqu'à la satisfaction un critère d'arrêt bien défini.

Le pseudo-code général des métaheuristiques basées sur une population de solutions est,

Métaheuristique basée sur une population de solutions

Initialiser la population avec un ensemble de solutions réalisables ;

Tant que le critère d'arrêt n'est pas satisfait faire

Sélectionner des solutions de la population ;

Créer de nouvelles solutions en manipulant les solutions sélectionnées ;

Mettre à jour la population des solutions ;

Retourner la meilleure solution rencontrée ;

Parmi ces métaheuristiques nous trouvons la métaheuristique des lucioles et la métaheuristique d'optimisation par essaim de particules que nous présentons dans la suite.

L'algorithme d'optimisation par essaim de particules PSO est une métaheuristique basée sur une population de solutions définie par Kennedy et Eberhart en 1995 [45]. C'est une technique d'optimisation qui s'inspire du comportement collectif intelligent des nuées d'oiseaux. Les oiseaux se déplacent en tant que groupe cohésif, sans chef désigné, les individus restent à proximité des membres du groupe (attraction) et conservent en même temps une distance de sécurité pour éviter les collisions (répulsion). Lorsqu'un oiseau se déplace à la recherche de nourriture, le groupe le suit afin de conserver l'attraction et la répulsion globale du groupe. Le subtil compromis entre l'attraction globale du

groupe, la répulsion du voisinage local et l'attrait des ressources locales offre une efficacité particulière au processus de quête de nourriture.

L'algorithme PSO requiert une population de départ composée de solutions réalisables appelées particules. Ces particules examinent l'espace des solutions en tenant compte de leurs propres expériences et de celles des particules optimales actuelles.

En effet, l'algorithme PSO effectue un certain nombre d'itérations au cours desquelles chaque particule i de la population se déplace de sa position actuelle X_i^t vers une nouvelle position X_i^{t+1} suivant l'équation (3.5)

$$\begin{cases} X_i^{t+1} = X_i^t + V_i^{t+1} \\ V_i^{t+1} = \omega V_i^t + c_1 r_1 (best_i^t - X_i^t) + c_2 r_2 (Gbest^t - X_i^t) \end{cases} \quad (3.5)$$

Où, V_i^t et V_i^{t+1} représentent la vitesse de la particule i aux itérations t et $t + 1$ respectivement, ω est le coefficient d'inertie, c_1 et c_2 sont des facteurs d'apprentissage, r_1 et r_2 sont des paramètres aléatoires, $best_i^t$ est la meilleure position ultérieure de la particule i , et $Gbest^t$ la meilleure position dans la population à l'itération t .

Cet algorithme a fait l'objet de nombreuses améliorations au fil du temps, en optimisant ses paramètres de contrôle qui définissent la qualité de la solution fournie, notamment la taille de la population (m), le poids d'inertie ω et les facteurs d'apprentissage c_1 et c_2 [46,47,48]. Dans ce contexte, l'une des manières les plus efficaces consiste à ajuster la valeur du coefficient d'inertie ω à chaque itération t en utilisant une expression dynamique pour calculer la valeur du coefficient d'inertie, Coefficient de constriction ou un facteur d'amortissement inertiel de valeur fixe [49].

Le pseudo-code standard de l'algorithme d'optimisation par essaim de particules est donné par,

Métaheuristique PSO

Générer aléatoirement une population initiale de solutions réalisables ;

Enregistrer la meilleure position ultérieure de chaque particule, et la meilleure position dans la population ;

Tant que le critère d'arrêt n'est pas satisfait faire ;

Pour chaque solution i faire

Évaluer la vitesse V_i , et le coefficient d'inertie en utilisant les équations (3.5) et (3.6) ;

Mettre à jour la position de la solution i en utilisant l'équation (3.5) ;

Mettre à jour la meilleure position ultérieure de la particule i ;

Mettre à jour la position de la meilleure solution globale ;

Retourner la meilleure solution rencontrée ;

La métaheuristique des lucioles est une autre métaheuristique basée sur une population qui a été proposée par Yang en 2012 [50] qui s'inspire du comportement des lucioles qui sont des petits coléoptères ailés qui produisent une lumière clignotante pendant la nuit pour communiquer leurs positions aux autres lucioles. Les lucioles de faible lumière sont attirées par celles émettant une plus forte lumière.

Dans cette métaheuristique une luciole correspond à une solution du problème considéré. Elle se base sur trois règles principales :

- La luminosité d'une luciole (solution) correspond à la valeur de la fonction objective,
- L'attractivité entre les lucioles est proportionnelle à leurs luminosités et à la distance entre elles. Elle est définie par,

$$\beta(r) = \beta_0 e^{-\lambda r^2} \tag{3.3}$$

Où, r est la distance entre deux lucioles, β_0 est l'attractivité lorsque $r = 0$, et λ est une constante représentant le coefficient d'absorption de la lumière.

- Les lucioles sont unisexes, c'est-à-dire que n'importe quelle luciole i peut être attirée par n'importe quelle autre luciole plus brillante j et se déplacera vers elle suivant le mouvement défini par,

$$x_i = (1 - \beta_{ij})x_i + \beta_{ij}x_j + \alpha\epsilon \quad (3.4)$$

Où, x_i et x_j sont les positions des lucioles i et j respectivement, β_{ij} est l'attractivité entre les lucioles i et j , α est un paramètre aléatoire et ϵ est un vecteur de nombres aléatoires uniformément distribués dans $[0,1]$.

Ainsi, la métaheuristique des lucioles effectue une comparaison des luminosités de chaque couple de solutions (lucioles) de la population puis effectue un mouvement de chaque solution de faible luminosité vers une nouvelle luciole suivant le mouvement défini par l'équation (3.4). Ceci est répété jusqu'à satisfaire un critère d'arrêt, pour ensuite retourner la meilleure solution rencontrée.

Le pseudo-code général de la métaheuristique des lucioles est comme suit,

Métaheuristique des lucioles

Générer aléatoirement une population initiale de solutions réalisables ;

Tant que le critère d'arrêt n'est pas satisfait ***faire***

Évaluer la luminosité de chaque solution de la population ;

Déplacer chaque solution i vers d'autres solutions plus lumineuses en utilisant l'équation (2.4), si aucune autre solution est plus lumineuse, déplacer la solution i aléatoirement ;

Mettre à jour la population des solutions ;

Retourner la meilleure solution rencontrée ;

- **Les métaheuristiques hybrides** obtenues par combinaison des propriétés de deux ou plusieurs méthodes différentes, en tirant parti des avantages de chacune pour offrir des solutions de meilleure qualité. Une métaheuristique peut être hybridée avec diverses méthodes métaheuristiques et même exactes. Cette technique d'hybridation a démontré son efficacité sur de nombreux problèmes d'optimisation [51,52].

Les toutes premières métaheuristiques hybrides ont été proposées par Glover [53], Grefenstette [54] et Mühlenbein et al [55].

3.5 Complexité d'un problème d'optimisation

La complexité d'un problème d'optimisation est liée directement à celle de la méthode de résolution adoptée pour sa résolution. Pour cela, nous allons commencer par introduire la notion de la complexité algorithmique puis classifier les problèmes d'optimisation suivant leurs complexités.

3.5.1 La complexité algorithmique

Un algorithme est une suite finie d'opérations élémentaires (addition, soustraction, multiplication, division, comparaison, test, affectation, opération logique, ... etc.) permettant la résolution d'un problème donné.

La complexité d'un algorithme est caractérisée par le nombre d'opérations élémentaires requises pour l'exécuter. Ce nombre peut varier en fonction de la taille des données d'entrée, c'est-à-dire des paramètres donnés à l'algorithme.

Elle permet de mesurer l'efficacité d'un algorithme en fonction d'une expression mathématique qui indique le nombre d'opérations nécessaires pour exécuter l'algorithme en fonction de la taille des données d'entrée, dans le pire des cas.

Etant donné n la taille des données d'entrée nécessaires pour l'exécution d'un algorithme \mathcal{A} . Si le nombre total d'opérations élémentaires à exécuter par l'algorithme \mathcal{A} est majoré par un polynôme $P(n)$, on dit que l'algorithme \mathcal{A} est « polynomial » ou en $O(P(n))$. Sinon, l'algorithme \mathcal{A} est dit « exponentiel ».

En effet, un algorithme est dit « efficace » si et seulement s'il est polynomial.

3.5.2 La complexité d'un problème d'optimisation

On considère un problème d'optimisation qui consiste à

$$\text{Trouver } x^* \in X, \text{ tel que : } f(x^*) = \max_{x \in D} (f(x)) \quad (3.6)$$

S'il existe un algorithme polynomial pour le résoudre, on dit que c'est un problème « polynomial » et « facile ». La classe des problèmes polynomiaux est noté « P ».

Autrement, un problème d'optimisation non-polynomial est dit “difficile”.

Un problème d'optimisation est dit « non-déterministe polynomial », s'il est possible de vérifier, en un temps polynomial, si une solution x donnée est une solution réalisable du problème. La classe des problèmes non-déterministes polynomiaux est noté « NP ».

Parmi les problèmes de la classe NP, nous distinguons des problèmes qui sont plus difficiles à résoudre pour lesquels on ne connaît pas d'algorithme de résolution polynomial. Ces problèmes constituent la classe des problèmes « NP-complets » qui regroupe la plupart des problèmes d'optimisation tels que le problème du voyageur de commerce, le problème du sac à dos, le problème du p -médian, et les problèmes de la programmation linéaire en nombres entiers [16].

3.6 Conclusion

Dans ce chapitre nous avons présenté les notions de base de l'optimisation mathématique et nous avons décrit le processus général à suivre pour la résolution des problèmes d'optimisation.

Dans le chapitre suivant, nous abordons le problème de l'optimisation de la consommation d'énergie dans les réseaux IoT. Nous traitons le problème du regroupement ou clustering des réseaux IoT dans le but d'optimiser la consommation d'énergie en décrivant une modélisation mathématique détaillée et complète du problème à l'étude. Et en développant, par la suite, une approche classique pour

résoudre le modèle mathématique. Les résultats obtenus sont finalement analysés et discutés.

CHAPITRE 4 – CONTRIBUTION A L’OPTIMISATION DES RESEAUX IOT PAR UNE METHODE CLASSIQUE DU P- MEDIAN

4.1 Introduction

Dans un réseau IoT, contrairement aux stations de base et à la structure logicielle, les nœuds de capteurs ont des ressources en énergie très limitées. Les nœuds de capteurs sont alimentés principalement par des batteries souvent non rechargeables et non échangeables. Lorsque la batterie est épuisée, le nœud de capteurs ne peut fournir aucun service et il est considéré mort et donc retiré instantanément du réseau.

Il est crucial d'optimiser l'utilisation des ressources énergétiques de ces derniers pour permettre la collection, le traitement et la transmission des données sans compromettre les performances globales du réseau afin de prolonger au maximum sa durée de vie.

4.2 Une nouvelle approche classique pour l’optimisation des réseaux IoT

4.2.1 Définition du problème

Le clustering (hiérarchisation) des réseaux IoT est une topologie largement utilisée pour leur optimisation, puisqu’il permet une meilleure répartition de la consommation d’énergie et peut prendre en charge un très grand nombre de nœuds de capteurs. En effet, lorsque le routage des données est direct, les capteurs les plus éloignés s'épuisent plus rapidement. Et dans le cas de routage multi-sauts, les nœuds intermédiaires sont amenés à assurer des transmissions intermittentes en relayant des messages supplémentaires provenant d'autres nœuds, ce qui épuise leurs alimentations. Ainsi, le clustering offre une solution pertinente qui consiste à hiérarchiser les échanges en répartissant la collecte de données en grappes (clusters). Ceci permet de réduire la distance entre les nœuds de capteurs et la station de base, de limiter les interférences et d'améliorer la qualité des liaisons radio. Et donc, permet de réduire le nombre de retransmissions et de même diminuer la consommation de l'énergie. De plus en changeant fréquemment les têtes des clusters,

la puissance de la batterie des nœuds peut être maintenue plus longtemps et de manière presque égale pour tous les nœuds de capteurs.

4.2.2 Évaluation de la consommation de l'énergie

La consommation d'énergie des nœuds de capteurs peut être mesurée à l'aide du modèle radio dépendant de la distance entre les nœuds émetteurs et récepteurs. La valeur de cette distance décidera de l'utilisation soit du modèle d'espace libre ou celui des trajets [56].

L'énergie consommée par un nœud de capteurs qui envoie un message de longueur donnée L sur une distance donnée d peut être formulée comme suit [57] :

$$E_{TX}(L, d) = \begin{cases} E_{elec} * L + E_{AD} * L + \varepsilon_{fs} * L * d^2, & d \leq d_0 \\ E_{elec} * L + E_{AD} * L + \varepsilon_{amp} * L * d^4, & d > d_0 \end{cases} \quad (4.1)$$

Où :

E_{elec} est l'énergie consommée par bit envoyé ou reçu,

E_{AD} est l'énergie consommée pour l'agrégation des données,

ε_{fs} et ε_{amp} représentent la consommation d'énergie de la propagation en espace libre et de la propagation par trajets multiples, respectivement. Elles dépendent de la distance entre l'émetteur et le récepteur et du modèle d'amplification de l'émetteur. Si la distance d est supérieur à d_0 , le modèle à trajets multiples (d^4) est utilisé. Sinon, le modèle d'espace libre (d^2) est utilisé pour mesurer l'énergie dissipée [56].

$d_0 = \sqrt{\varepsilon_{fs}/\varepsilon_{mp}}$ est le seuil de distance entre le nœud émetteur et le nœud récepteur [58].

L'énergie consommée par un nœud recevant un message de longueur L bits est calculée par [58] :

$$E_{RX}(L) = E_{elec} * L \quad (4.2)$$

Il est clair que le coût énergétique de la communication entre deux nœuds de capteurs dépend fortement de la distance qui les sépare. En effet, plus cette distance est grande, l'énergie à consommer pour la transmission du paquet de données est grande surtout lorsque la distance dépasse le seuil de la distance du réseau. De ce fait, la minimisation de la consommation de l'énergie d'un réseau IoT revient à minimiser la distance totale entre les nœuds et les têtes de cluster et entre les têtes de cluster et la station de base.

4.2.3 Modélisation mathématique

Le problème p-médian est un problème de localisation particulier de l'optimisation combinatoire qui a été décrit et défini pour la première fois en 1964 par Hakimi [16].

Étant donné un graphe $G = (V, U)$ composé d'un ensemble V de n sommets reliés par les liaisons de l'ensemble E , avec $dist_{ij}$ la distance entre deux sommets i et j de V , le problème du p-médian consiste à sélectionner « p » sommets de V pour être « médians » et les « $n - p$ » sommets restants de V seront des « clients » à affecter aux médians. L'objectif est de minimiser la distance totale entre les médians et les clients.

Dans le problème du clustering, un réseau IoT peut être considéré comme un graphe G défini par l'ensemble V des nœuds de capteurs et l'ensemble E comprenant toutes les liaisons possibles entre les nœuds de capteurs de V ainsi que toutes les liaisons entre les nœuds de capteurs et la station de base. Ainsi, trouver un clustering minimisant la consommation de l'énergie dans un réseau IoT revient à résoudre le problème du p-médian sur le graphe G . Les médians sélectionnés correspondront aux têtes des clusters, tandis que l'affectation des clients aux médians représentera la formation des clusters i.e. détermination des nœuds membres de chaque cluster.

Un clustering ainsi obtenu constitue un schéma de routage qui minimise la consommation de l'énergie, réduit les interférences et améliore la qualité des liaisons radio en minimisant la distance totale à parcourir par l'ensemble des paquets. Il permet, également, de minimiser la perte de données en transmettant les paquets de

données en un seul saut entre les nœuds et les têtes des clusters et aussi entre les têtes des clusters et la station de base (pas de nœuds intermédiaires).

Sans perte de généralité, nous considérons un réseau qui contient une seule station de base qui dispose d'une alimentation électrique illimitée. Les nœuds de capteurs ainsi que la station de base ne sont pas mobiles et leurs positions géographiques sont bien connues. De plus, lorsqu'un nœud de capteurs transmet des données, le paquet de données ne peut pas être fractionné mais doit être transmis en entier.

Par conséquent, les variables de décision suivantes sont définies :

$$y_j = \begin{cases} 1 & , \text{Si le noeud } j \text{ est selectionné tête de cluster} \\ 0 & , \text{Si non} \end{cases} , j = \overline{1, n} \quad (4.3)$$

$$x_{ij} = \begin{cases} 1 & , \text{Si le noeud } i \text{ est associé à la tête de cluster } j \\ 0 & , \text{Si non} \end{cases} , i, j = \overline{1, n} \quad (4.4)$$

Il est clair qu'un nœud i ne peut être associé qu'à un nœud j déjà sélectionné tête de cluster, d'où :

$$x_{ij} \leq y_j, i, j = \overline{1, n} \quad (4.5)$$

De plus, Chaque nœud i doit être associé à une seule tête de cluster (un seul cluster). Alors,

$$\sum_{j=1}^n x_{ij} = 1, i = \overline{1, n} \quad (4.6)$$

D'un autre côté, chaque tête de cluster j doit disposer d'une énergie suffisante pour recevoir et transmettre ses données et celles de tous les nœuds qui lui sont associés.

Donc,

$$\sum_{\substack{i=1 \\ i \neq j}}^n x_{ij} \left(E_{RX}(L) + E_{TX}(L, d_j) \right) \leq y_j (E_j - E_{TX}(L, d_j)), j = \overline{1, n} \quad (4.7)$$

Où, E_j est l'énergie disponible dans le nœud j , et d_j est la distance entre le nœud j et la station de base.

Finalement, Le nombre de têtes de cluster à sélectionner doit être égal à p .

$$\sum_{j=1}^n y_j = p \quad (4.8)$$

L'objectif peut donc être formulé comme suit :

$$\text{Min } \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_{ij} + \sum_{j=1}^n d_j y_j \quad (4.9)$$

Avec, a_{ij} la distance entre les nœuds i et j .

Les variables de décisions, les contraintes et les la fonction objectif décrites en haut permettent de décrire le modèle mathématique (PMC) suivant :

$$(PMC) \begin{cases} \text{Min } \sum_{i=1}^n \sum_{j=1}^n d_{ij} x_{ij} + \sum_{j=1}^n d_j y_j \\ \sum_{j=1}^n y_j = p \\ \sum_{j=1}^n x_{ij} = 1 & , i = \overline{1, n} \\ \sum_{i=1}^n x_{ij} (E_{RX}(L_i) + E_{TX}(L_i, d_j)) \leq y_j (E_j - E_{TX}(L_j, d_j)) & , j = \overline{1, n} \\ x_{ij} \leq y_j & , i, j = \overline{1, n} \\ x_{ij}, y_j \in \{0,1\} & , i, j = \overline{1, n} \end{cases} \quad (4.10)$$

L'étape prochaine consiste en la résolution du programme mathématique (PMC).

4.2.4 Résolution

Bien que le problème du p -médian soit amplement étudié en recherche opérationnelle, son polytope n'a pas encore été décrit complètement. Des descriptions partielles ont été proposées pour divers types d'arbres [59], des sous-classes de facettes dans le cas des graphes sans fourchettes [60]. De plus, dans [61], Zhao et al. ont proposé une formulation étendue avec deux ensembles supplémentaires de variables, qui a permis d'aboutir à une généralisation des facettes existantes et par conséquent une description complète du polytope lorsque $p = n - 2$.

Plusieurs méthodes exactes ont été proposées pour trouver des solutions optimales en utilisant principalement les algorithmes branch-and-bound, branch-and-cut et branch-and-price [62,63,64,65]. Puisque le problème p -médian est NP-dur sur un réseau général, les méthodes précédentes ne peuvent pas résoudre en un temps raisonnable

le problème du p -médian dans les réseaux de grandes tailles et/ou dans le cas où p est arbitraire [66]. En conséquent, plusieurs méthodes heuristiques et métaheuristiques ont été conçues pour générer des solutions de bonne qualité, légèrement inférieures aux solutions optimales, en beaucoup moins de temps de calcul que les méthodes exactes [68,67,68]. De plus, un algorithme de coupes et branchement basé sur la relaxation lagrangienne pour les grandes instances a été proposé dans [59].

Dans notre travail, Nous avons implémenté un programme basé sur le solveur de programmes linéaires en nombres entiers « intlinprog » sous l'environnement Matlab R2021a. Ce solveur effectue, dans l'ordre, les tâches suivantes jusqu'à ce que la solution optimale du problème soit obtenue [69] :

- 1) Réduire la taille du problème en utilisant le prétraitement du programme linéaire;
- 2) Résoudre le problème initial relaxé (relaxation des contraintes de l'intégrité) en utilisant la programmation linéaire ;
- 3) Renforcer la relaxation de la programmation linéaire du problème mixte en utilisant le prétraitement du programme mixte ;
- 4) Générer des coupes pour renforcer d'avantage le programme relaxé;
- 5) Rechercher des solutions réalisables à l'aide d'une heuristique ;
- 6) Exécuter un algorithme Branch and Bound pour rechercher systématiquement la solution optimale.

Le choix de ce solveur est motivé par le fait que les tests vont être effectués sur des instances de réseaux IoT comportant 100 nœuds et que les méthodes exactes basées sur un algorithme Branch and Bound peuvent être exécutées efficacement sur de telles instances et donner des solutions optimales en un temps raisonnable comme mentionné dans [70].

4.2.5 Tests et résultats

Pour évaluer la capacité du solveur intlinprog à résoudre efficacement le programme (PMC), nous avons réalisé des tests de performance sur des réseaux IoT sans fil

comportant une station de base et 100 nœuds de capteurs distribués de manière aléatoire sur une zone de 10 000 m². Tous les nœuds de capteurs disposent d'une énergie initiale de 2J. La station de base peut être située soit au centre du réseau ou en dehors de la zone du réseau. Les paramètres de simulation sont résumés dans le tableau 4.1.

Nous menons deux séries de tests différents :


Dans la **première série de tests**, nous considérons une première variante du modèle (PMC), intitulée (10-PMC), dans laquelle le nombre p de têtes de cluster a été fixé à 10 comme dans la plupart des travaux antérieurs.

Dans la **deuxième série de tests**, nous considérons une autre variante du modèle (PMC), notée (DV-PMC), dans laquelle le nombre p est considéré comme une variable de décision entière dont la valeur est à déterminer lors de la résolution du modèle (DV-PMC).


Tableau 4.1 Paramètres de simulation

| Paramètre | Valeur (unité) |
|--|---------------------------------|
| Surface | 10,000 (m ²) |
| Taille du réseau | 100 |
| Position de la station de base | (50, 50) or (50, 125) |
| Taille du paquet de données (L) | 500 (bits) |
| Energie initiale (E_0) | 2 (J) |
| Énergie consommée dans l'électronique (E_{elec}) | 50 (nJ/bit) |
| Dissipation d'énergie de l'amplificateur en espace libre (E_{fs}) | 10 (pJ/bit/m ²) |
| Dissipation d'énergie de l'amplificateur en cas de trajets multiples (E_{amp}) | 0.0013 (pJ/bit/m ⁴) |
| Énergie consommée lors de l'agrégation des données (E_{DA}) | 5 (nJ/bit) |
| Le seuil de distance (d_0) | 87 (m) |


Les figures 4.1 et 4.2 illustrent les solutions issues de la résolution de (10-PMC) et de (DV-PMC) sur deux réseaux ayant les caractéristiques énumérées dans le tableau 4.1. Dans la figure 4.1, nous avons considéré un réseau avec une station de base localisée au centre du réseau. Et dans la figure 4.2, Le réseau comprend une station de base localisée à l'extérieur de la zone déployée.



(a) Réseau sans clustering.




(b) clustering avec 10-PMC




(c) Clustering avec DV-PMC (18 CHs).

Figure 4.1 Clustering des nœuds de réseau sans fil autour d'une station de base centrale (nœuds situés dans une zone de 100x100 m² avec la station de base située à l'intérieur de la zone).


Pour les deux réseaux présentés, les meilleures économies d'énergie ont été obtenues par la résolution de (DV-PMC) avec un nombre de clusters différent de 10, étant $p = 18$ pour le réseau avec station de base centrale (figure 4.1) et $p = 15$ pour le réseau avec station de base périphérique (figure 4.2).



(a) Réseau sans clustering.



(b) Clustering avec 10-PMC



(c) Clustering avec DV-PMC (15 CHs).

Figure 4.2 Clustering des nœuds de réseau sans fil reliés à une station de base périphérique (nœuds situés dans une zone de 100x100 m² avec la station de base située à l'extérieur de la zone)

Les résultats obtenus, en termes de consommation d'énergie offerts par les clusterings déterminés par la résolution de (10-PMC) et de (DV-PMC), en utilisant le solveur intlinprog, sur 20 réseaux IoT sans fil différents ayant les caractéristiques énumérées dans le tableau 4.1, sont présentés et comparés dans les figures 4.3 et 4.4 dépendamment de la localisation de la station de base dans le réseau.





Figure 4.3. Consommation de l'énergie dans 10 réseaux IoT sans fil autour d'une station de base centrale.



Figur 4.4. Consommation de l'énergie dans 10 réseaux IoT sans fil avec une station de base périphérique.

Pour attester de l'efficacité de l'approche de clustering proposée à réduire la consommation de l'énergie dans un réseau IoT, nous mesurons les économies en énergie, i.e. les taux de réduction de la consommation de l'énergie, en utilisant l'équation (4.11) décrite comme suit :

$$\text{économie en énergie} = \frac{\text{énergie}_{\text{avec clustering}} - \text{énergie}_{\text{sans clustering}}}{\text{énergie}_{\text{sans clustering}}} \times 100 \quad (4.11)$$

Avec, $\text{énergie}_{\text{avec clustering}}$ est l'énergie consommée par le réseau dont les nœuds sont regroupés en clusters, Et, $\text{énergie}_{\text{sans clustering}}$ est l'énergie consommée par le réseau dont les nœuds ne sont pas regroupés en clusters.

Les résultats montrent que les deux variantes de l'approche p -médian pour le regroupement des nœuds ont permis de réduire l'énergie totale consommée par le réseau sans fil lorsque la station de base était située au centre. Les réductions étaient plus importantes lorsque le nombre de clusters était déterminé par le programme (DV-PMC). Les économies d'énergie variaient entre 1,45 et 8,2% avec les clusterings fournis par intlinprog sur (10-PMC) et entre 6,49 et 12,52% avec les clusterings fournis par intlinprog sur (DV-PMC).

Pour les réseaux avec station de base située en périphérie, (10-PMC) et (DV-PMC) ont fourni les mêmes résultats pour toutes les instances testées et le nombre p de clusters à former par la résolution de (DV-PMC) était toujours égale à 10. Les économies réalisées étaient très intéressantes et elles varient entre 14,02 % et 19,36%.

Étant donné que la majorité des méthodes de clustering proposées pour réduire la consommation d'énergie des réseaux IoT sans fil ont été conçues pour les réseaux avec des stations de base situées dans la zone couverte par les nœuds. Et lorsque utilisées dans des réseaux avec stations de base périphériques elles donnent de mauvais résultats. Les résultats offerts par (10-PMC) et plus particulièrement par (DV-PMC) sont donc très intéressants et montrent que le modèle proposé peut contribuer de manière significative à l'augmentation de l'efficacité énergétique des réseaux IoT sans fil indépendamment de sa configuration.

Le seul inconvénient lié à l'utilisation du solveur intlinprog est le temps exponentiel nécessaire pour résoudre (10-PMC) et (DV-PMC). En effet, Il est important de souligner que le temps nécessaire pour l'obtention des résultats discutés précédemment dépasse 3600s pour la plupart des instances. Ceci n'est pas satisfaisant voire inacceptable dans les applications de l'IoT étant donné que la transmission des données dans ses réseaux doit se faire rapidement pour permettre des services instantanés.

Dans la suite du document, nous ferons référence à la méthode élaborée à l'aide du solveur intlinprog utilisée dans ce chapitre pour la résolution du modèle (DV-PMC) par B&B.

4.3 Conclusion

Dans cette section, nous nous sommes concentrés sur le problème du clustering dans les réseaux IOT dans le but d'améliorer l'efficacité énergétique du réseau. Tout d'abord, nous avons décrit une formulation mathématique inédite, basée sur le problème du p -médian, du problème de regroupement des nœuds de capteurs dans les réseaux IoT sans fil. Le modèle est implémenté et résolu par un programme qui fait appel au solveur de programmation linéaire en nombres entiers mixtes "intlinprog" de l'environnement Matlab. Le solveur utilisé étant basé sur une méthode Branch-and-Bound, détermine le nombre optimal (p) de clusters à former et effectue une affectation optimale de tous les nœuds aux têtes des clusters sélectionnés.

Les tests de performance réalisés montrent que la méthode proposée est très efficace pour réduire la consommation d'énergie dans les réseaux IoT, et plus particulièrement lorsque le nombre de clusters à former est considéré comme une variable de décision (DV-PMC). La variante (DV-PMC) a permis d'obtenir de très bons résultats dans les deux configurations où la station de base était centrale et même lorsque la station de base était périphérique, et a offert une économie d'énergie atteignant 12,52% et 19,36% respectivement.

Cependant le temps de l'exécution était important et dépassait les 3600s pour la plupart des instances. Cet inconvénient sera traité et résolu dans le chapitre suivant en se servant de l'informatique quantique pour décrire des techniques d'optimisation avancées plus rapides et plus efficaces.

CHAPITRE 5 – CONTRIBUTION AU CALCUL QUANTIQUE POUR L'OPTIMISATION AVANCÉE DES RÉSEAUX IOT

5.1 Introduction

Compte tenu du nombre élevé de dispositifs connectés aux réseaux IoT, qui se comptent actuellement en millions et devraient atteindre des milliards dans les années à venir [6], très peu des techniques proposées pour l'optimisation de la consommation de l'énergie sont réalisables en raison de leurs grandes complexités et temps d'exécution inacceptable qu'elles requièrent. Une façon d'accélérer les calculs et donc de réduire le temps d'exécution est d'appliquer les concepts de l'informatique quantique, qui est une nouvelle technologie en plein essor qui résulte de l'intégration des principes de la mécanique quantique dans les processus informatiques.

Dans cette section, nous définissons quelques principes de base de l'informatique quantique qui sont nécessaires pour la compréhension de la suite du document. Nous passons en revue les différentes méthodes d'optimisation basées sur l'informatique quantique, puis nous proposons une nouvelle métaheuristique QIC inspirée de l'informatique quantique qui effectue un clustering en temps réel des réseaux IoT pour optimiser la consommation de l'énergie. Pour l'évaluation de la performance et de l'efficacité de la méthode proposée QIC, nous réalisons une étude paramétrique de l'approche puis nous conduisons une série de tests de simulation sur plusieurs réseaux IoT.

5.2 Définition, principes de base et avantages de l'informatique quantique

L'informatique quantique est un domaine en pleine expansion dans lequel les lois fondamentales de la mécanique quantique, telles que la superposition et l'intrication, sont joints aux outils mathématiques et informatiques pour accélérer les calculs et résoudre des problèmes complexes de la vie réelle dont la résolution dépasse les capacités des ordinateurs classiques tels que la gestion de la consommation énergétique dans les réseaux électriques, la logistique et le transport [16], la gestion

d'inventaire ainsi que la factorisation en nombres entiers [71] largement utilisée dans le domaine de la cryptographie.

Contrairement à un ordinateur classique, qui utilise des bits binaires ne pouvant prendre que les valeurs logiques 0 ou 1, un ordinateur quantique fonctionne avec des bits quantiques appelés Qbits, dont l'état repose sur le principe de superposition quantique dans lequel 0 et 1 sont superposables.

En effet, un Qbit est l'élément de base de l'information en informatique quantique. L'état d'un Qbit $|\varphi\rangle$ a une infinité de valeurs possibles, puisque son état est exprimé par une combinaison linéaire des états de base $|0\rangle$ et $|1\rangle$, comme représenté ci-dessous [72,73,74].

$$|\varphi\rangle = \alpha|0\rangle + \beta|1\rangle, \alpha, \beta \in \mathbb{C} \quad (5.1)$$

Les coefficients α et β sont les projections de l'état du Qbit $|\varphi\rangle$ sur les états propres $|0\rangle$ et $|1\rangle$ respectivement. Ce sont des nombres complexes vérifiant $|\alpha|^2 + |\beta|^2 = 1$. Les états de base des Qbits sont généralement représentés dans un espace vectoriel de deux dimensions (2D) par $|0\rangle = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ et $|1\rangle = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$.

L'état d'un Qbit est généralement représenté dans l'espace à trois dimensions (3D) à l'aide de la sphère de Bloch, illustrée à la figure 5.1.




Figure 5.1. La représentation d'un état de Qbit dans la sphère de Bloch.

Conformément à cette représentation, l'état d'un Qbit peut être exprimé comme suit [75]:

$$|q\rangle = \cos\frac{\theta}{2}|0\rangle + \sin\frac{\theta}{2}e^{i\varphi}|1\rangle = \begin{pmatrix} \cos\frac{\theta}{2} \\ \sin\frac{\theta}{2}e^{i\varphi} \end{pmatrix} \quad (5.2)$$

Avec, $\theta \in [0, \pi]$ et $\varphi \in [0, 2\pi[$

Les états des Qbits peuvent être manipulés à l'aide des portes ou des opérateurs quantiques. Ces opérateurs quantiques peuvent être exprimés à l'aide des quatre matrices hermitiennes de base connues sous le nom de matrices de Pauli σ_0 , σ_x , σ_y et σ_z , définies dans les équations (5.3) à (5.6) [76-77].

$$\sigma_0 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad (5.3)$$

$$\sigma_x = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} \quad (5.4)$$

$$\sigma_y = \begin{pmatrix} 0 & -i \\ i & 0 \end{pmatrix} \quad (5.5)$$

$$\sigma_z = \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix} \quad (5.6)$$

Les matrices de Pauli sont également connues sous le nom de portes d'identité X, Y et Z, respectivement.

Tout opérateur quantique peut être exprimé en fonction des portes de Pauli, y compris les opérateurs de rotations de base $R_x(\psi)$, $R_y(\theta)$ et $R_z(\varphi)$ autour des axes ox , oy et oz , respectivement. Ces rotations peuvent être exprimées comme suit :

$$R_x(\psi) = \cos\frac{\psi}{2}\sigma_0 - i\sigma_x\sin\frac{\psi}{2} = \begin{pmatrix} C\frac{\psi}{2} & -iS\frac{\psi}{2} \\ -iS\frac{\psi}{2} & C\frac{\psi}{2} \end{pmatrix} \quad (5.7)$$

$$R_y(\theta) = \cos\frac{\theta}{2}\sigma_0 - i\sigma_y\sin\frac{\theta}{2} = \begin{pmatrix} C\frac{\theta}{2} & -S\frac{\theta}{2} \\ S\frac{\theta}{2} & C\frac{\theta}{2} \end{pmatrix} \quad (5.8)$$

$$R_z(\varphi) = \cos\frac{\varphi}{2}\sigma_0 - i\sigma_z\sin\frac{\varphi}{2} = \begin{pmatrix} e^{-i\frac{\varphi}{2}} & 0 \\ 0 & e^{i\frac{\varphi}{2}} \end{pmatrix} \quad (5.9)$$

Avec, C et S le cosinus et le sinus des demi-angles, respectivement.

La succession des opérateurs quantiques définit un algorithme quantique à exécuter, exclusivement, sur un ordinateur quantique.

Actuellement, les ordinateurs quantiques rencontrent plusieurs limitations et défis liés à leur disponibilité pour la recherche et l'utilisation industrielle, la précision, la tolérance aux pannes et la fiabilité des Qbits. Ceci a incité beaucoup de chercheurs à développer des algorithmes inspirés-quantique qui exploitent les forces et les avantages de l'informatique quantique tout en s'exécutant sur des ordinateurs classiques.

5.3 Revue des approches de l'optimisation quantique

Depuis leurs apparitions, les outils mathématiques ont permis des avancées spectaculaires dans différents domaines. En particulier dans les sciences physiques, les progrès réalisés dans le domaine de la relativité et de la mécanique quantique sont spectaculaires et sont désormais exploitées pour stimuler le développement de l'informatique quantique, la conception d'ordinateurs quantiques et l'optimisation de leurs performances.

Bien qu'elle n'en soit qu'à ses débuts, l'informatique quantique suscite un intérêt croissant chez les scientifiques, étant donné qu'elle promet une rapidité, une performance et une efficacité supérieures à celles de l'informatique conventionnelle.

La figure 5.2 illustre l'évolution des travaux de recherches récemment publiés visant la définition et la description quantique de la transformée de Fourier, la transformée de Laplace et des méthodes d'optimisation, et aussi à la résolution quantique des

équations différentielles et des systèmes d'équations ainsi qu'à leurs applications concrètes dans le domaine de l'informatique quantique.




Figure 5.2. Évolution du nombre de publications de recherche portant sur l'utilisation des outils mathématiques avancés dans l'informatique quantique [78].

En particulier, ces dernières années, un nombre important de chercheurs se sont penchés sur l'exploitation des techniques d'optimisation pour le développement et l'amélioration des performances des ordinateurs quantiques, ainsi que sur la description et la conception de versions quantiques ou inspirées-quantique de ces techniques.

5.3.1 Méthodes d'optimisation quantiques et inspirées-quantiques

L'une des premières versions quantiques des algorithmes classiques d'optimisation est l'algorithme évolutionnaire d'inspiration quantique proposé par Han et Kim en 2002 [79]. Dans cet algorithme, un individu (solution) est représenté par un m-Q-bit pour une représentation probabiliste de ses états. Une porte quantique a également été introduite comme opérateur de variation pour guider les individus vers de meilleures solutions et éviter ainsi une convergence prématurée. La comparaison de l'algorithme proposé avec l'algorithme génétique conventionnel, a montré que l'algorithme proposé donne des résultats satisfaisants sans convergence précipitée.

Quelques années plus tard, Baritomba, Bulger et Wood (2005) ont introduit une méthode de calcul quantique stochastique réussie, appelée BBW, pour résoudre des problèmes d'optimisation globale sans contraintes à l'aide de l'algorithme de Grover [80]. Cette méthode a ensuite été revisitée par Liu et Gary J., Koehler (2010) dans la quête d'une solution optimale globale aux problèmes d'optimisation à variables discrètes [81]. L'algorithme original BBW a été remanié pour atteindre une augmentation significative de la vitesse et ainsi étendre l'ordonnancement statique de la BBW.

Dans [82], Jiao et al. (2008) ont décrit un algorithme clonal immunitaire d'inspiration quantique pour résoudre le problème d'optimisation globale. Dans l'approche proposée, les anticorps sont produits, organisés en groupes de sous-population, puis représentés par des Qbits génétiques à états multiples. Des portes de rotation quantique et un mécanisme d'ajustement dynamique des angles sont ensuite utilisés pour accélérer la convergence. De plus, la porte quantique NOT est appliquée pour assurer la mutation quantique et ainsi prévenir les convergences prématurées vers des optimums locaux. L'algorithme décrit converge en théorie vers l'optimum global, et les résultats expérimentaux montrent qu'il est bien plus performant que les autres algorithmes génétiques présents dans la littérature en termes de qualité de solution et de coût de calcul.

D'un autre côté, Zheng et Yamashiro (2010) ont inspecté l'intégration des opérateurs quantiques dans des algorithmes évolutionnaires, y compris l'utilisation de l'algorithme évolutionnaire de base d'inspiration quantique pour ensuite établir un algorithme évolutionnaire différentiel quantique pour le problème d'ordonnancement de l'atelier de flux de permutation [83]. Ce nouvel algorithme s'est montré plus efficace pour la résolution du problème que les algorithmes de référence. Dans [84], Zhisheng (2010) a examiné puis validé l'habileté de l'algorithme d'optimisation par essaim de particules à comportement quantique à résoudre le problème de répartition de la charge économique et celui d'équilibrage de la charge économique. Dans cette étude, une particule est décrite en fonction de plusieurs états de probabilité déterminés et l'opération de mise à jour de la particule est effectuée par les portes de

rotation quantiques. L'algorithme a démontré sa capacité à résoudre le problème de distribution économique efficacement, tout en surpassant l'algorithme d'optimisation par essaim de particules amélioré et d'autres algorithmes d'optimisation.

Dans [85], da Silva et Schirru (2011) se sont intéressés à l'optimisation du rechargement des assemblages combustibles du cœur du réacteur qui est une question de grand intérêt pour l'industrie nucléaire. L'étude effectuée a abouti à la description d'un algorithme quantique d'inspiration évolutionnaire, appelé QPBIL, combinant les concepts de base de l'apprentissage incrémental basé sur la population avec des bits quantiques et la superposition linéaire d'états. L'efficacité du QPBIL a été prouvée pour l'optimisation du cycle 7 d'Angra 1, surpassant les techniques actuellement disponibles basées sur l'intelligence artificielle. Et dans [86], Karimi et al. (2012) ont calculé les temps adiabatiques médians à partir de la déviation minimale pendant l'optimisation quantique d'une classe d'instances NP-difficiles du problème « Ising spin glass » avec un nombre maximal de 128 variables binaires. Dans ce contexte, si le temps de calcul est défini sur des échelles de temps adiabatiques (secondes), l'optimisation quantique est bien plus efficace que les solveurs classiques.

Par la suite, Layeb (2013) a appliqué avec succès un algorithme de recherche d'harmonie hybride d'inspiration quantique à des opérateurs d'inspiration quantique tels que la mesure et l'interférence [87]. Dans [88], Shang et al. (2014) ont proposé un algorithme de coévolution clonale immunitaire quantique (QICCA), basé sur un système immunitaire artificiel, un calcul évolutionnaire quantique et une stratégie de coévolution pour résoudre des problèmes d'optimisation multi-objectifs dynamiques. L'algorithme QICCA améliore la capacité de recherche en utilisant le clonage intégral et invoque la théorie quantique pour concevoir une mise à jour quantique. En outre, la stratégie de coévolution est intégrée dans l'opération holistique, et l'opération concurrentielle coévolutive et l'opération coopérative coévolutive sont conçues pour améliorer l'uniformité, la diversité et les performances de convergence des solutions. L'algorithme est efficace, avec une forte capacité à faire évoluer des fronts de Pareto convergents, diversifiés et uniformément distribués.

Un algorithme d'optimisation combinatoire quantique QAOA basé sur un circuit quantique de portes unitaires est conçu par Farhi, Goldstone et Gutmann (2014) pour produire des solutions approchées au problème MaxCut dans les graphes à degré borné [89]. Ce travail a été poursuivi en appliquant l'algorithme QAOA au problème combinatoire Max E3LIN2 à occurrence bornée [90]. Les solutions ainsi obtenues sont meilleures que celles fournies par deux algorithmes conventionnels de références. De plus, dans [91], une variante de QAOA qui considère une instance du problème de la 2-satisfiabilité maximale (MAX-2-SAT) a été développée pour générer avec précision un état très proche de l'état optimal.

Les recherches de Zouache, Nouioua et Moussaoui (2016) pour résoudre des problèmes d'optimisation discrète en adaptant l'algorithme des lucioles ont conduit à l'élaboration d'un nouvel algorithme appelé algorithme des lucioles d'inspiration quantique avec optimisation par essaim de particules [92]. Les deux concepts de base de l'informatique quantique utilisés dans cet algorithme pour améliorer le contrôle de la diversité des solutions sont les états de superposition du Qbit et la mesure quantique. Les lucioles sont représentées de manière discrète, et l'attraction entre elles est calculée par une variante de la distance de Hamming bien connue. Enfin, deux stratégies sont combinées pour assurer la coopération pendant l'exploration de l'espace de recherche. L'efficacité de l'algorithme proposé a été testée et validée sur plusieurs instances du problème du sac à dos multidimensionnel.

Dans une autre direction, Hen et Spedalieri (2016) ont proposé une nouvelle méthode pour encoder les problèmes d'optimisation avec contraintes sur des recycleurs quantiques dans le but d'éliminer le besoin de termes de pénalité et donc de réduire le nombre de coupleurs requis et de supprimer le besoin d'encastrement mineur [93]. Les auteurs affirment que leur approche réduit le nombre de Qbits physiques nécessaires pour mettre en œuvre des procédures d'optimisation sur des recycleurs quantiques et qu'elle est très utile pour le développement de l'informatique quantique. D'autre part, Ranjbar et al. (2016) ont reformulé le calcul des nombres de Ramsey généralisés sous la forme d'un problème d'optimisation combinatoire, puis ont fourni un algorithme quantique basé sur l'algorithme adiabatique pour résoudre le

problème [94]. Cette méthode permet de déterminer les nombres de Ramsey ($I-m, I-n$) décrits pour les arbres d'ordre $m, n = 6,7,8$, dont la plupart étaient auparavant inconnus.

Palittapongarnpim et al. (2017) ont utilisé l'algorithme d'évolution différentielle pour surmonter le problème de stagnation de l'optimisation non convexe [95]. La moyenne de la fonction objectif est considérée pour améliorer la fidélité du contrôle quantique pour un système bruyant, ainsi que des heuristiques pour la fin précoce des exécutions et pour la sélection adaptative des sous-espaces de recherche sont utilisées. Cette implémentation est massivement parallèle et vectorisée pour réduire davantage le temps d'exécution. Il a été démontré que l'algorithme proposé permet d'obtenir une fidélité et une évolutivité supérieures à celles obtenues avec les algorithmes gloutons. De plus, dans [96], le problème de répartition économique de l'énergie des générateurs avec de multiples options de carburant a été traité à l'aide d'une méthode basée sur l'optimisation par essaim de particules à comportement quantique avec mise à jour multiple. Il s'agit d'effectuer une recherche raffinée et d'éviter les déformations associées à la fonction de Lagrange augmentée (grâce à la mise à jour multiple) et d'assurer ainsi la convergence vers la solution optimale. De plus, le mouvement des particules est modélisé par une nouvelle approche du comportement quantique, basée sur l'équation de Schrödinger et la méthode de Monte Carlo [97]. La méthode proposée est déclarée très efficace pour la résolution du problème considéré.

Dans une autre étude, Sayed, Darwish et Hassanien (2019) ont combiné la représentation quantique de l'espace de recherche, les interférences et les opérateurs quantiques, avec l'algorithme d'optimisation multivers pour fournir un algorithme hybride appelé optimisation multivers quantique visant à trouver un compromis optimal entre l'exploration et l'extraction des ressources naturelles [98]. Lors de tests sur 50 fonctions de référence unimodales et multimodales, l'algorithme proposé s'est révélé supérieur aux algorithmes bien connus pour résoudre des problèmes d'optimisation numérique complexes.

L'une des applications importantes de l'informatique quantique concerne les algorithmes quantiques classiques pour les optimisations variationnelles hybrides. Des circuits quantiques ont été conçus pour mettre en œuvre deux algorithmes de ce type, dont l'un est variationnel, pour l'entraînement des réseaux neuronaux et censés permettre une augmentation exponentielle du nombre d'échantillons traitables et une augmentation polynomiale de la taille des échantillons par rapport aux algorithmes d'entraînement classiques [99]. Ces algorithmes permettent également d'obtenir les informations sur les poids de formation, de sorte que les résultats obtenus soient utilisés directement pour la résolution d'autres problèmes.

Dans [100], Ajagekar et You (2019) ont évoqué et décrit les étapes de l'application de l'informatique quantique aux problèmes d'optimisation des systèmes énergétiques, l'utilisation d'outils logiciels à code source ouvert, ainsi que les limites des ordinateurs quantiques les plus rencontrés récemment dans ce domaine. Dans une autre direction, Greplova (2020) s'est intéressé à l'un des défis majeurs de l'informatique quantique : la métallurgie, et a proposé une approche d'optimisation basée sur des stratégies de jeux (game theory) afin d'identifier les états de la matière ayant les propriétés requises [101].

L'une des contributions très marquantes est celle de Van Apeldoorn et al. (2020), dans laquelle les étapes à suivre pour accélérer la résolution de problèmes d'optimisation convexe ont été déterminées pour mettre en œuvre un oracle de séparation à l'aide de $\tilde{O}(1)$ requêtes quantiques à un oracle d'appartenance pour mettre en œuvre un oracle d'optimisation, offrant ainsi une augmentation exponentielle de la vitesse en comparaison avec les techniques classiques de requête d'appartenance $\Omega(n)$ [102]. Ce qui a permis de déterminer de multiples bornes inférieures. De plus, si un point intérieur de l'ensemble convexe est connu, l'algorithme nécessite $\Omega(\sqrt{n})$ requêtes d'appartenance, ou sinon $\Omega(\sqrt{n})$ requêtes de séparation.

Dans [103], un nouvel algorithme évolutionnaire d'inspiration quantique est proposé pour le problème de planification de la trajectoire d'un robot. Cet algorithme a été adapté, par la suite, à la résolution de problèmes d'optimisation à grande échelle pour

des environnements statiques et dynamiques complexes. Alexandru et al. (2020) fournit de nouveaux schémas quantiques qui accélèrent plusieurs méthodes d'optimisation numérique à usage général pour minimiser une fonction $f: \mathbb{R}^n \rightarrow \mathbb{R}$ [104]. Ceux-ci fournissent une accélération presque quadratique de nombreuses techniques d'optimisation globale sous une contrainte de Lipschitz, y compris la recherche backtracking, un élément non négligeable des algorithmes d'optimisation quasi-Newtonne.

De plus, pour éviter de stagner dans un optimum local comme dans les cas utilisant la version originale de l'algorithme évolutionnaire quantique, la combinaison de deux ou plusieurs méthodes peut conduire à de nouvelles approches avec des caractéristiques améliorées [105]. Dans [106], Zhen et al. (2020) décrivent un algorithme dans lequel un opérateur d'évolution mémétique basé sur le processus de brassage et un opérateur d'évolution quantique qui utilise un mécanisme de sélection adaptatif pour différents puits potentiels. Ces opérateurs sont conçus pour compléter l'équilibre entre la recherche globale et la recherche locale afin de résoudre les problèmes d'optimisation globale. De plus, l'incorporation de la loi de la gravité de Newton, du centre gravitationnel et du centre géométrique comme éléments essentiels dans l'algorithme proposé offre une amélioration de la diversité de la population. Testée sur plusieurs problèmes d'optimisation, la méthode proposée s'avère plus performante que les 11 algorithmes les plus performants de la littérature.

Un travail récent développe une version étendue de l'algorithme de recherche quantique de valeurs extrêmes (QEVSA), appelé le test de relation quantique à contraintes (CQRT) [107]. Le CQRT qui réduit considérablement la complexité, atteint une vitesse exponentielle maximale et une certitude classique et quantique élevée. D'une autre part, Khan et al. (2021) ont formulé une version quantique de l'algorithme d'optimisation métaheuristique connu sous le nom de recherche par antennes de scarabées (the beetle antenna search) et ils l'ont appelée QBAS. La QBAS a été appliquée pour l'optimisation de portefeuilles financiers en utilisant des données boursières réelles [108]. Le QBAS est réputé pour ses performances

supérieures à celles de l'algorithme d'optimisation par essaim de particules et de l'algorithme génétique.

Récemment, Warren (2021) a établi sept arguments démontrant que les problèmes symétriques du voyageur de commerce constituent un benchmark de référence pour la résolution quantique des problèmes d'optimisation combinatoire pour tous les types de machines quantiques [109]. Dans [110], Wang et Wang (2021) ont proposé un algorithme d'évolution différentielle d'inspiration quantique avec un optimiseur de type grey wolf pour améliorer la diversité et les performances de convergence dans des cas de haute dimension pour les problèmes de sac à dos à variables binaires, en se basant sur les portes quantiques et les états de superposition, entre autres principes. Des opérations de mutation par évolution différentielle adaptative, des opérations de croisement par évolution différentielle ainsi que l'observation quantique sont utilisées pour produire de nouvelles solutions comme individus de test. Des opérations de sélection sont employées pour déterminer la meilleure solution parmi les individus enregistrés et les individus tests créés par les opérations de mutation et de croisement. Dans le cas où les individus tests sont moins bons que les individus actuels, l'optimiseur adaptatif grey wolf et la porte de rotation quantique sont utilisés pour conserver la diversité de la population tout en accélérant la recherche de la solution optimale globale. Les résultats expérimentaux pour les problèmes de sac à dos à variables binaires confirment l'efficacité supérieure et la capacité de recherche globale de cet algorithme, en particulier pour les instances de grandes dimensions.

L'algorithme d'optimisation approximative quantique (QAOA) introduit par Farhi et al. [88-89] a été utilisé et amélioré dans plusieurs travaux, par exemple, pour permettre l'alternance entre des familles d'opérateurs plus générales et ainsi supporter la représentation d'un plus grand ensemble d'états [111]. Ceci pourrait avoir un impact important à long terme sur un large éventail de domaines d'application et serait particulièrement utile pour les problèmes d'optimisation approximative et exacte avec des contraintes dures. En plus de l'introduction de l'ansatz d'opérateur alternatif quantique, des critères de conception pour les opérateurs de mélange sont

établis, les mises en correspondance pour huit problèmes sont détaillées et un compendium avec de brèves descriptions des mises en correspondance d'un large éventail de problèmes est fourni. Dans [112], un algorithme d'optimisation approximative quantique à faible profondeur a été mis en œuvre à l'aide d'un simulateur quantique analogique pour estimer l'énergie de l'état fondamental du modèle d'Ising à champ transverse avec des interactions à longue portée et une portée acceptable, et pour optimiser le problème classique combinatoire correspondant en échantillonnant la sortie avec des mesures de Qbits individuels à haute-fidélité et à coup unique. Les performances résistent à l'augmentation d'échelle de manière adéquate, et le temps d'exécution est presque indépendant du nombre de Qbits.

Dans [113], un nouveau domaine de conception d'architectures de circuits quantiques pour les algorithmes d'optimisation approximative a été ouvert par Li et al. (2020), dans lequel la fonction objectif de Gibbs est définie et s'est avérée supérieure à la valeur d'espérance énergétique pour être utilisée comme fonction objectif dans le réglage variationnel des paramètres. Un algorithme de recherche d'architecture ansatz a ensuite été décrit pour étudier l'espace discret des architectures de circuits quantiques similaires. Avec le meilleur ansatz obtenu, l'application de ces modifications à un modèle d'Ising à graphe complet a donné une amélioration relative moyenne de 244,7 % de la probabilité de trouver un état à faible énergie tout en utilisant 33,3 % de portes à deux Qbits en moins. Dans le cas des modèles d'Ising sur une grille 2D, la probabilité a été améliorée moyennement de 44,4 % avec une réduction de 20,8 % du nombre de portes à deux Qbits.

Egger, Marecek et Woern (2021) ont analysé et étudié la manière d'initialiser l'optimisation quantique avec un état qui correspond à la solution d'une relaxation d'un problème d'optimisation combinatoire. Ils ont également examiné les caractéristiques requises de l'algorithme utilisé à cette fin [114]. L'algorithme quantique hérite idéalement des garanties des performances de l'algorithme classique. Ceci est illustré dans le contexte de l'optimisation de portefeuille, pour lequel les résultats révèlent que le démarrage à chaud de l'optimisation approximative est bénéfique. De même, l'algorithme récursif QAOA pour les problèmes de Max-Cut

présente une amélioration systématique de la taille de la coupe obtenue pour les graphes entièrement connectés avec des poids aléatoires lorsque l'arrondi aléatoire de Goemans-Williamson est utilisé dans un démarrage à chaud. Les auteurs affirment que cette technique peut être appliquée facilement à d'autres schémas d'arrondis aléatoires et même à d'autres problèmes d'optimisation.

Pour finir, l'application du processeur quantique Sycamore à Qbits supraconducteurs de Google à l'optimisation combinatoire approximative a été démontrée par Harrigan et al. (2021) récemment [115]. Ses performances ont été testées sur le graphe de connectivité planaire, avec le modèle de Sherrington-Kirkpatrick et Max-Cut, des problèmes non-natifs dont l'implémentation nécessite une compilation extensive. Les résultats montrent que dans le cas de problèmes non-natifs le taux d'approximation obtenu est indépendant de la taille du problème, et la performance s'améliore avec la profondeur du circuit. Pour les problèmes nécessitant une compilation, les performances diminuent avec la taille du problème. Cela suggère que pour les problèmes sur des graphes non natifs, les processeurs quantiques devraient être évalués en utilisant des algorithmes d'optimisation approximative.

5.3.2 Recuits quantiques

Les avancées récentes de la technologie quantique ont été suivies par le développement et la construction de recuits (annealers) quantiques programmables permettant de résoudre les problèmes d'optimisation quadratique binaire sans contraintes et, par conséquent, la résolution de nombreux problèmes d'optimisation combinatoire d'intérêt pratique beaucoup plus rapidement que leurs analogues classiques. Un avantage considérable du recuit quantique est la possibilité de résoudre des problèmes d'optimisation formulés avec des variables entières, tels que le problème du voyageur de commerce et le problème de la satisfiabilité. Parmi les premières applications du recuit quantique figure la méthode proposée par Finnila et al. (1993) qui permet de déterminer les extrema de fonctions multidimensionnelles [116]. Basée sur une extension du recuit simulé classique, cette approche permet d'éviter les minima locaux, et contrairement à certains de ses prédécesseurs, elle ne requiert pas l'approximation d'une fonction d'onde. La méthode proposée a été

appliquée avec succès au problème de la recherche des configurations les plus basses en énergie de clusters de Lennard-Jones comprenant jusqu'à 19 particules (environ 105 minima locaux). Cela a encouragé les chercheurs à considérer cette méthode comme un complément à la technique largement utilisée du recuit simulé et à l'appliquer et la développer dans d'autres contextes. Des décennies plus tard, Biswas et al. (2017) ont annoncé la programmation d'un recuit quantique et ont également exploré trois domaines d'application potentiels [117].

En mai 2018, Fujitsu a lancé son service Digital Annealer inspiré de l'informatique quantique. Une stratégie d'utilisation de ce service pour résoudre des problèmes d'optimisation combinatoire du monde réel pour les clients, qui consiste à formuler le problème pour une optimisation quadratique binaire sans contraintes, a été expliquée ultérieurement [118].

Dans [119], Vyskocil et Djidjev (2019) ont proposé une nouvelle approche de mise en œuvre des contraintes basée sur la conception combinatoire et la programmation linéaire en nombres entiers mixtes (MILP) pour obtenir une meilleure intégration des contraintes du type $\sum x_i = k$ pour les variables binaires x_i . Cette approche est évolutive pour tout nombre de variables et utilise un nombre linéaire de variables auxiliaires pour un k fixe.

Plus récemment, une approche innovante a été proposée par Ohzeki (2020), pour résoudre un problème d'optimisation à grande échelle sur le graphe de chimères en utilisant une méthode bien connue en mécanique statistique, à savoir la transformation de Hubbard-Stratonovich [120]. Cette méthode prend en charge un modèle d'Ising entièrement connecté sans encastrement sur le graphe chimère et fournit des résultats non triviaux. Son efficacité a été démontrée à travers des expériences sur plusieurs problèmes de partition impliquant la résolution d'équations linéaires et sur un problème réaliste d'optimisation du flux de trafic dans les villes japonaises de Sendai et Kyoto.

Dans [121], Abel, Blance et Spannowsky (2021) ont présenté une comparaison détaillée du recuit quantique aux techniques d'optimisation classiques, à savoir le

recuit thermique simulé, Nelder-Mead, et la descente de gradient. Cette étude montre que la méthode de recuit thermique simulé est légèrement plus efficace pour découvrir le minimum global, tandis que les méthodes de Nelder-Mead et de descente de gradient sont très susceptibles d'être coincées dans des minima locaux. Cependant, malgré leurs limites de taille actuelles, le recuit quantique est clairement la meilleure méthode pour minimiser les potentiels rapidement et efficacement.

Dans [122], le processeur de recuit quantique D-Wave 2000Q a été utilisé pour inspecter les propriétés thermiques diagonales du modèle canonique unidimensionnel d'Ising à champ transverse. Il a été constaté que le processeur quantique ne pouvait pas établir les valeurs d'espérance prédites correctement par la méthode de Monte Carlo quantique, ce qui en fait un candidat inadapté à l'échantillonnage thermique.

Le tableau 5.1 récapitule et catégorise les contributions dédiées à la résolution de problèmes d'optimisation qui ont été présentées dans cette section.

Tableau 5.1 Classification des contributions dédiées à la résolution des problèmes d'optimisation en fonction de l'objectif principal de l'étude.

| Références | Objectif d'étude |
|--|--|
| 96,99,110,112, | Implémentation de portes, circuits et oracles |
| 87,88,113,114, | Codage des contraintes |
| 97,98,111, | Résolution des problèmes associés aux algorithmes quantiques précédemment décrits |
| 76,77,78,79,80,82,83,85,86,87,88,92,93,95, | Méthodes quantiques pour l'optimisation |
| 84,89,94,96,100,101,103,104,105,106,107,108,109,110, | Méthodes inspirées de l'informatique quantique |
| 81,82,84,87,88,91,92,93,96,106,108,111,112,117, | Applications des algorithmes quantiques pour résoudre les problèmes d'optimisation |
| 115 | Implémentation de nouveaux recuits quantiques |
| 113,114,118,119, | Utilisation des recuits quantiques |
| 76,77,78,79,80,82,83,85,86,87,88,92,93,95, | Méthodes quantiques pour l'optimisation |

Les contributions consacrées à la mise en œuvre et le développement des algorithmes d'optimisation quantiques et inspirés-quantique, listées dans cette section, mettent en évidence l'importance et la puissance de l'informatique quantique pour résoudre des problèmes d'optimisation très complexes du monde réel avec une efficacité et une rapidité élevées.

Nous croyons que cette synthèse, que nous avons publié dans [78], ouvre des directions et des opportunités de développement majeures dans ce domaine. De plus, elle constitue une base de référence précieuse pour les chercheurs dans les domaines de l'ingénierie qui sont prêts à s'appuyer sur l'informatique quantique pour trouver des solutions.

5.4 Une nouvelle approche inspirée-quantique pour l'optimisation des réseaux IoT

Étant donné la complexité du problème du p-médian ainsi que la complexité algorithmique de ses méthodes de résolution, notamment la méthode par séparation et évaluation, L'utilisation de l'informatique quantique semble intéressante et attrayante vu les forces et les avantages qu'elle offre malgré ses limitations actuelles.

De ce fait, dans cette section, nous décrivons notre algorithme inspiré-quantique pour la détermination d'un clustering optimisant la consommation de l'énergie dans un réseau IoT sans fil. Il est constitué de quatre étapes principales dont la première consiste en la génération d'une population initiale de solutions quantiques. Dans la deuxième étape, l'algorithme "Construct_Binary_Solution" est exécuté pour générer une population de solutions réalisables binaires correspondant aux solutions quantiques précédemment générées. La troisième étape est consacrée à l'évaluation de la fitness FNS (valeur de la fonction objectif) de chaque solution réalisable binaire pour effectuer, par la suite, une comparaison de chaque couple des solutions réalisables binaires. Le mouvement de l'algorithme des lucioles (FA) [91,123] ou le mouvement de l'algorithme d'optimisation par essaim de particules (PSO) [115,124,125] est donc utilisé pour déplacer la mauvaise solution actuelle vers une nouvelle solution. Il est essentiel de souligner que ces mouvements ne sont pas

effectués sur les solutions binaires, mais plutôt sur les solutions quantiques correspondantes ce qui va mener à une nouvelle solution quantique à laquelle on définit la solution réalisable binaire dans la dernière étape.

5.4.1 Modélisation quantique

Pour un réseau constitué de n nœuds de capteurs, une solution quantique QY représente le choix des têtes de clusters et est exprimée sous forme d'un n-Qbit. Elle est définie par :

$$QY = \begin{bmatrix} \cos(\theta_1) & \cos(\theta_2) & \dots & \cos(\theta_n) \\ \sin(\theta_1) & \sin(\theta_2) & \dots & \sin(\theta_n) \end{bmatrix} \quad (5.10)$$

Où, $\forall j \in \{1, \dots, n\}$:

- $\theta_j \in \left[0, \frac{\pi}{2}\right]$,
- $|\cos(\theta_j)|^2$ représente la probabilité de ne pas choisir le nœud j comme tête de cluster.
- $|\sin(\theta_j)|^2$ représente la probabilité de choisir le nœud j comme tête de cluster.

À chaque solution quantique correspond une solution binaire qui constitue une solution réalisable pour le programme mathématique (PMC).

La sous-section suivante présente l'algorithme « Construct_Binary_Solution » que nous avons élaborée pour construire une telle solution réalisable binaire à chaque solution quantique considéré.

5.4.2 Algorithme pour la construction d'une solution binaire

L'algorithme « Construct_Binary_Solution » est essentiel dans notre approche. C'est un algorithme glouton conçu pour la construction d'une solution réalisable binaire à partir d'une solution quantique.

Une solution binaire est définie par une $(n \times n)$ -matrice $X = (x_{ij})_{i,j=1,\dots,n}$, telle que $x_{ij} \in \{0,1\}, \forall i, j \in \{1, \dots, n\}$.

Elle correspond à un clustering des nœuds du réseau, i.e. une sélection des têtes des clusters et une affectation des nœuds à ces têtes de cluster tout en satisfaisant les contraintes (4.5), (4.6), (4.7) et (4.8).

L'algorithme démarre avec une solution réalisable binaire vide ($x_{ij} = 0, \forall i, j \in \{1, \dots, n\}$). La première étape de la construction de la solution réalisable X revient à sélectionner les têtes des clusters en se basant sur les composantes de la solution quantique QY considérée. Dans la deuxième étape s'effectue la formation des clusters en affectant les nœuds aux têtes de clusters qui vérifient les contraintes (4.5), (4.6), (4.7) et (4.8), et minimisent, en même temps, la distance entre les nœuds membres et la station de base. Un nœud non-affecté sera considéré comme une tête de cluster. La troisième et dernière étape consiste en l'amélioration de la qualité de la solution fournie en considérant le nouvel ensemble de têtes de cluster et en effectuant une réaffectation (si nécessaire) des nœuds du réseau.

Le pseudo-code de l'algorithme « Construct_Binary_Solution » est le suivant,

Algorithme Construct_Binary_Solution

Entrée: Une solution quantique QY

Sortie: Une solution binaire x

1. Créer une solution binaire nulle x ;
2. Créer un ensemble CH de têtes de clusters, et l'initialiser à $CH = \emptyset$;
3. Générer un nombre aléatoire $r \in [0,1]$;
4. Pour chaque nœud i faire

Si $|\sin(\theta_i)|^2 \geq r$, alors le nœud i est sélectionné tête de cluster: $x_{ii} = 1$
et $CH = CH \cup \{i\}$;

FinSi;

FinPour;

5. Pour chaque nœud non encore affecté j

Assigner le nœud j à la tête de cluster i correspondant à $\min(d_j + d_k + a_{ik})_{k \in CH}$ et vérifiant les contraintes (4.7), i.e. $x_{ij} = 1$;

Si aucune tête de cluster ne vérifie la contraintes (4.7), alors le nœud j est défini tête de cluster, $x_{jj} = 1$ et $CH = CH \cup \{j\}$;

FinSi;

FinPour;

6. *Pour chaque tête de cluster i telle que $\sum_{j=1}^n x_{ji} = 1$*

S'il existe une tête de cluster r vérifiant $d_j \geq a_{rj} + d_r$ ainsi que les contraintes (4.7), alors j n'est plus tête de cluster et il est assigné à la tête de cluster r , i.e. $x_{jj} = 0$ et $x_{jr} = 1$

FinSi;

FinPour;

7. *Retourner la solution binaire x .*

L'algorithme « Construct_Binary_Solution » est un algorithme polynomial efficace.

En effet, l'étape de la création de la solution binaire x , de l'ensemble des têtes de clusters et de la génération du nombre aléatoire se font en $o(n)$ opérations. L'étape de la sélection des têtes de clusters nécessitent l'exécution de $o(3n)$ opérations au maximum et l'étape de l'affectation des nœuds membres aux têtes des clusters nécessitent au maximum $o(3n)$ opérations. L'étape de l'amélioration de la solution s'exécute en un maximum de $o(4n)$ opérations. Finalement, retourner la solution binaire en exécutant 1 seule opération d'affichage.

5.4.3 Exploration de l'espace des solutions

Notre approche utilise deux mouvements complémentaires pour explorer l'espace des solutions, à savoir le mouvement quantique de l'algorithme des lucioles (FA) et le mouvement quantique de l'algorithme d'optimisation par essaim de particules (PSO). Les mouvements quantiques ainsi que la variante de la distance de Hamming utilisés dans notre approche ont été définis et développés par Zouache et al. (2016) dans [91].

Considérons deux solutions binaires BS_i et BS_j , et soient QY_i et QY_j les solutions quantiques correspondantes.

1. Si la fitness de BS_i est supérieure à celle de BS_j , alors QY_i se déplacera vers une nouvelle position suivant la stratégie de l'algorithme des lucioles définie comme suit :

$$\theta_{ik}^{t+1} = \begin{cases} \theta_{ik}^t + \beta_0 e^{-\lambda r_{ij}^2} (\theta_{jk}^t - \theta_{ik}^t) + \alpha_t \epsilon_i^t, & \text{if } BS_{ik}^t \neq BS_{jk}^t \\ \theta_{ik}^t, & \text{otherwise} \end{cases} \quad (5.11)$$

Où,

- θ_{ik}^t and θ_{ik}^{t+1} sont les angles de rotation du $k^{\text{ème}}$ Qbit de la solution quantique QY_i aux itérations t et $t+1$ respectivement.
- r_{ij} représente la distance normalisée de Hamming entre deux solutions binaires BS_i et BS_j . Elle est définie par :

$$r_{ij} = \frac{\sum_{k=1}^n d(BS_{ik}, BS_{jk})}{2n - (\sum_{k=1}^n BS_{ik} + \sum_{k=1}^n BS_{jk})} \quad (5.12)$$

Telle que,

$$d(BS_{ik}, BS_{jk}) = \begin{cases} 1, & \text{if } BS_{ik} \neq BS_{jk} \\ 0, & \text{otherwise} \end{cases} \quad (5.13)$$

- α_t est un paramètre de valeur aléatoire de l'intervalle $[0,1]$.
 - ϵ^t est un vecteur de n composantes aléatoire de l'intervalle $[0,1]$.
 - $\beta_0 e^{-\lambda r_{ij}^2}$ représente l'attractivité entre deux solutions binaires BS_i et BS_j , avec, β_0 est l'attractivité entre deux solutions séparées par une distance nulle,
 - λ est le coefficient d'absorption de la lumière dont la valeur est constante.
2. Si en revanche, la fitness de BS_i est inférieure à celle de BS_j , alors le mouvement de QY_i est déterminé par celui décrit dans l'algorithme d'optimisation par essaim de particules comme suit :

$$\theta_{ik}^{t+1} = \begin{cases} \theta_{ik}^t + V_{ik}^{t+1} & , \text{ if } BS_{ik} \neq BSg_{kk} \text{ or } BF_{ik} \neq bbs_{ii}^t \\ \theta_{ik}^t & , \text{ otherwise} \end{cases} \quad (5.14)$$

Telle que,

- V_{ik}^t et V_{ik}^{t+1} sont les vitesses des angles de rotation du $k^{\text{ème}}$ Qbit de la solution quantique QY_i aux itérations t et $t+1$ respectivement, avec $V_{ik}^0 = 0, \forall i = \overline{1, m}, \forall k = \overline{1, n}$. Elles sont calculées par :

$$V_{ik}^{t+1} = \begin{cases} \omega V_{ik}^t + c_1 r_1 (\theta b_{ik}^t - \theta_{ik}^t) + c_2 r_2 (\theta g_k^t - \theta_{ik}^t) & , \text{ if } t \geq 1 \\ 0 & , \text{ if } t = 0 \end{cases} \quad (5.15)$$

- BSg est l'actuelle meilleure solution binaire,
- bbs^t est la meilleure solution binaire à l'itération t .
- θb_{ik}^t est l'angle de rotation du $k^{\text{ème}}$ Qbit de la meilleure solution quantique actuelle QS_g ,
- θg_k^t est l'angle de rotation du $k^{\text{ème}}$ Qbit de la meilleure solution quantique bqs^t à l'itération t ,
- r_1 et r_2 sont des nombre aléatoires dans $[0,1]$,
- ω est le poids d'inertie,
- c_1 et c_2 sont les facteurs d'apprentissage.

La nouvelle solution quantique QY_i^{t+1} ainsi obtenue est donnée par :

$$QY_i^{t+1} = \begin{bmatrix} \cos(\theta_{i1}^{t+1}) & \cos(\theta_{i2}^{t+1}) & \dots & \cos(\theta_{in}^{t+1}) \\ \sin(\theta_{i1}^{t+1}) & \sin(\theta_{i2}^{t+1}) & \dots & \sin(\theta_{in}^{t+1}) \end{bmatrix} \quad (5.16)$$

Maintenant que tous les éléments nécessaires de notre approche ont été définies, nous décrivons l'algorithme QIC dans la sous-section suivante.

5.4.4 L'algorithme QIC

Notre algorithme de clustering est inspiré de l'algorithme d'optimisation par essaim de particules et des lucioles d'inspiration quantique proposé précédemment par Zouache et al. (2016) pour résoudre le problème du sac à dos avec un objectif de

maximisation du profit [91]. Dans la présente approche, l'algorithme lucioles/PSO a été mis à niveau pour l'adapter à la résolution du problème de sélection des têtes de cluster dans les réseaux IoT et d'affectation des nœuds en vue de minimiser la consommation d'énergie.

Algorithme Quantum-inspired clustering QIC

Entrées : La taille de la population des solutions m , le nombre d'itérations $nb_iterations$.

Sortie : La meilleure solution réalisable binaire BS_g .

1. Initialiser les paramètres de l'algorithme ;
2. Générer la population initiale de m solutions quantiques, soit $QYS(0) = \{QY_1^0, QY_2^0, \dots, QY_m^0\}$;
3. Construire la population $BSS(0) = \{BS_1^0, BS_2^0, \dots, BS_m^0\}$ des solutions réalisables binaires correspondantes aux solutions quantiques de $QYS(0)$ en utilisant l'algorithme "Construct_Binary_Solution" ;
4. Evaluer la fitnessse FNS de chaque solution binaire de $BSS(0)$;
5. Enregistrer la meilleure solution binaire et la meilleure solution quantique correspondante dans $BBS(0) = \{bbs_1^0, bbs_2^0, \dots, bbs_m^0\}$ and $BQS(0) = \{bqs_1^0, bqs_2^0, \dots, bqs_m^0\}$, respectivement ;
6. Enregistrer la meilleure solution binaire courante dans BS_g et la meilleure solution quantique courante dans QS_g
7. Initialiser le compteur de la boucle à $t = 1$;
8. Tant que ($t \leq nb_iterations$) faire
 - Pour $i = 1$ à m faire
 - Pour $j = 1$ à m faire
 - Si ($FNS(BS_i^t) > FNS(BS_j^t)$)
 - Evaluer la distance discrète et l'attractivité entre les deux solutions binaires BS_i^t et BS_j^t ;
 - Déterminer la position de la nouvelle solution quantique QY_i^{t+1} suivant le mouvement FA (équation (5.11))
 - Sinon
 - Déterminer la position de la nouvelle solution quantique QY_i^{t+1} suivant le mouvement PSO (équation (5.14))
 - FinSi

Construire la nouvelle solution réalisable binaire BS_i^{t+1} correspondant à la nouvelle solution quantique QY_i^{t+1} en utilisant l'algorithme "Construct_Binary_Solution" ;

Evaluer la fitnessse FNS de la nouvelle solution binaire BS_i^{t+1} ;

Enregistrer la meilleure solution binaire \mathbf{bbs}_i^t et la meilleure solution quantique \mathbf{bqs}_i^t ;

Mettre à jour la meilleure solution binaire \mathbf{BS}_g ainsi que la meilleure solution quantique actuelle \mathbf{QS}_g ;

FinPour ;

FinPour ;

Incrémenter le compteur de la boucle $\mathbf{t} = \mathbf{t} + \mathbf{1}$;

FinTantque ;

9. Retourner la meilleure solution réalisable binaire \mathbf{BS}_g .

Pour évaluer la complexité de l'algorithme QIC, nous avons à déterminer le nombre d'opérations à exécuter lors des étapes d'initialisation, exploration et l'étape finale. En effet et compte tenu de la complexité de l'algorithme "Construct_Binary_Solution", l'étape de l'initialisation se fait en $o(n)$ opérations, l'étape de l'exploration se fait en $o(n)$ opérations et retourner la solution se fait avec une opération d'affichage.

Alors, l'algorithme QIC est une métaheuristique efficace qui permet de déterminer un clustering des nœuds des réseaux IoT en un temps polynomial.

5.4.5 Tests et résultats

Pour vérifier l'efficacité et les performances de notre algorithme d'inspiration quantique pour le clustering économe en énergie des réseaux IoT sans fil, et pour évaluer la qualité de la solution fournie en termes d'économie d'énergie, l'algorithme QIC a été implémenté sous Matlab R2021a et exécuté sur un ordinateur portable équipé d'un processeur Intel(R) Core (TM) i5-1135G7 @ 2,40 GHz de 11e génération.

Les paramètres de l'algorithme QIC en liaison avec la taille de la population des solutions, le nombre d'itérations ainsi que les paramètres du mouvement PSO sont fixés dans le tableau 5.2.

Tableau 5.2 Paramètres de simulation relatifs à l'algorithme QIC

| Paramètre | Valeur |
|------------------|--------------|
| m | 100 |
| $nb_itérations$ | 100 |
| r_1 | 1 |
| r_2 | 1 |
| c_1 | 1 |
| c_2 | 1 |
| ω | 0.9 |
| ϵ | $rand - 0.5$ |

De plus, pour déterminer les valeurs des paramètres liés au mouvement FA, nous avons mené une étude paramétrique prenant en considération plusieurs configurations de ces paramètres, comme indiqué dans le tableau 5.3, dans le but de déterminer la configuration de paramètres la plus adéquate permettant d'atteindre au mieux l'objectif de l'optimisation de l'énergie.

Tableau 5.3 Paramètres du mouvement FA

| Configuration de paramètres | Valeurs |
|-----------------------------|---|
| Set 1 | $\beta_0 = 1, \lambda = 0.1, \alpha = 0.2$ |
| Set 2 | $\beta_0 = 1, \lambda = 0.1, \alpha = rand$ |
| Set 3 | $\beta_0 = 1, \lambda = 0.01, \alpha = 0.1$ |
| Set 4 | $\beta_0 = 1, \lambda = 0.1, \alpha = 0.25$ |
| Set 5 | $\beta_0 = 1, \lambda = 1, \alpha = 0.5$ |
| Set 6 | $\beta_0 = 2, \lambda = 1, \alpha = 0.2$ |
| Set 7 | $\beta_0 = 0.2, \lambda = 1, \alpha = 0.5$ |

Cette étude paramétrique est menée à travers une série de simulations réalisées sur plus de 200 réseaux IoT dont la taille varie de 10, 50 à 100 nœuds, ayant tous une énergie initiale égale à $2J$ et devant transmettre des paquets de 1000 *bits*. Tous les réseaux comportent une seule station de base localisée au centre ou à l'extérieur de la zone déployée. Le tableau 5.4 récapitule les caractéristiques de ces réseaux.

Tableau 5.4 caractéristiques des réseaux IoT

| Caractéristique | Valeur |
|--|------------------------------|
| Taille de la zone | 10,000 m ² |
| Nombre de nœuds (n) | 10/50/100 |
| Localisation de la station de base | (50, 50),(50,125) |
| Taille des paquets de données (L) | 500 bits |
| Énergie initiale (E_0) | 2 J |
| Énergie consommée dans l'électronique (E_{elec}) | 50 nJ/bit |
| Dissipation d'énergie de l'amplificateur en espace libre (E_{fs}) | 10 pJ/bit/m ² |
| Dissipation d'énergie de l'amplificateur en cas de trajets multiples (E_{amp}) | 0.0013 pJ/bit/m ⁴ |
| Énergie consommée lors de l'agrégation des données (E_{DA}) | 5 nJ/bit |
| Le seuil de distance (d_0) | 87 m |

L'algorithme QIC a été exécuté en considérant les différentes configurations sur les mêmes réseaux IoT ayant les caractéristiques listées dans le tableau 5.4. Les résultats obtenus en termes d'économies d'énergie et de temps d'exécution par configuration de l'algorithme QIC, sont résumés dans le tableau 5.5 et présentées dans la figure 5.3.

Tableau 5.5 Sommaire des résultats des tests sur l'algorithme QIC

| Configuration | Économie maximale en énergie (%) | Temps d'exécution moyen (secondes) | | |
|---------------|----------------------------------|------------------------------------|----------|-----------|
| | | $n = 10$ | $n = 50$ | $n = 100$ |
| Set 1 | 7.09 | 46.86 | 213.19 | 427.31 |
| Set 2 | 12.37 | 38.19 | 1356 | 2134.9 |
| Set 3 | 15.48 | 59.95 | 176.13 | 359.68 |
| Set 4 | 10.52 | 107.92 | 2488 | 752.33 |
| Set 5 | 8.82 | 114.37 | 394.78 | 16026 |
| Set 6 | 11.25 | 65.70 | 270.78 | 505.49 |
| Set 7 | 13.02 | 174.66 | 3612 | 18683 |




Figure 5.3 Économie d'énergie réalisée avec chaque configuration de paramètres (de gauche à droite : 1 à 7)

Les résultats obtenus indiquent que l'algorithme peut regrouper les nœuds du réseau de manière à offrir des économies d'énergie atteignant les 15,48 %. Le temps d'exécution (en seconds) nécessaire pour effectuer 100 itérations et en explorant une population comprenant 100 solutions réalisables varie entre 38.19s et 174.66s pour les réseaux de 10 nœuds, varie entre 176.13s et 3612s pour les réseaux de 50 nœuds, et varie entre 359,68s et 18683s pour les réseaux de 100 nœuds.

La figure 5.4 représente une comparaison du temps d'exécution moyen (en seconds) de l'algorithme, par configuration, sur des réseaux de tailles 10, 50 et 100 respectivement.

Le résumé des résultats expérimentaux du tableau 5.5 montre que la configuration 3 fournit les meilleures économies d'énergie et le meilleur temps d'exécution pour les réseaux de 50 et 100 nœuds et offre un bon compromis entre l'énergie et le temps d'exécution pour les réseaux de 10 nœuds. De plus, le temps d'exécution avec cette configuration des paramètres est très raisonnable, il est d'environ 1 minute pour les réseaux de 10 nœuds et d'environ 5 min pour les réseaux de 100 nœuds.




Figure 5.4 Le temps d'exécution moyen par configuration de paramètres

En effet, l'algorithme QIC avec la configuration de paramètres n° 3, décrit des clusterings dont la consommation d'énergie totale est autour de 4.56 Joules avec un écart-type de 0.39, en un temps moyen de 587s avec un écart-type de 326.9. Malgré l'écart-type important du temps d'exécution, QIC réduit considérablement le temps d'exécution du solveur intlinprog de plus de 16.47%.

Ainsi, QIC permet des réductions de la consommation de l'énergie dans les réseaux IoT comprenant des stations de bases se situant à l'intérieur et à l'extérieur de la zone couverte.

Les figures 5.5 et 5.6 présentent une comparaison des résultats obtenus en termes de consommation d'énergie en exécutant les algorithmes QIC et intlinprog sur cinq réseaux IoT ayant les caractéristiques listées dans le tableau 5.4 avec la consommation de l'énergie dans les mêmes réseaux sans clustering suivant la localisation de la station de base dans le réseau.

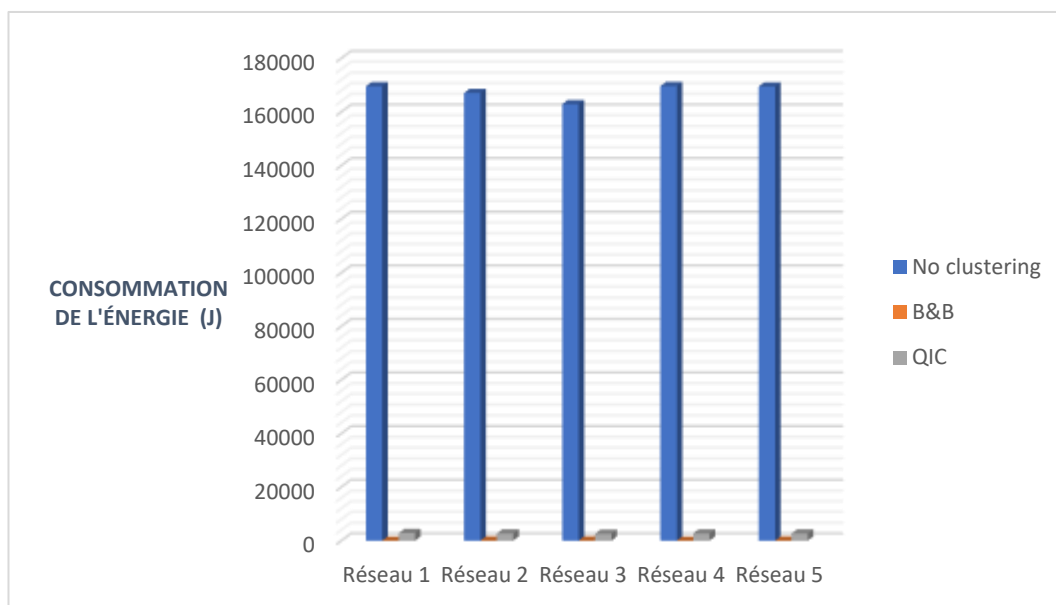


Figure 5.5 Consommation de l'énergie dans des réseaux IoT avec une station de base périphérique.

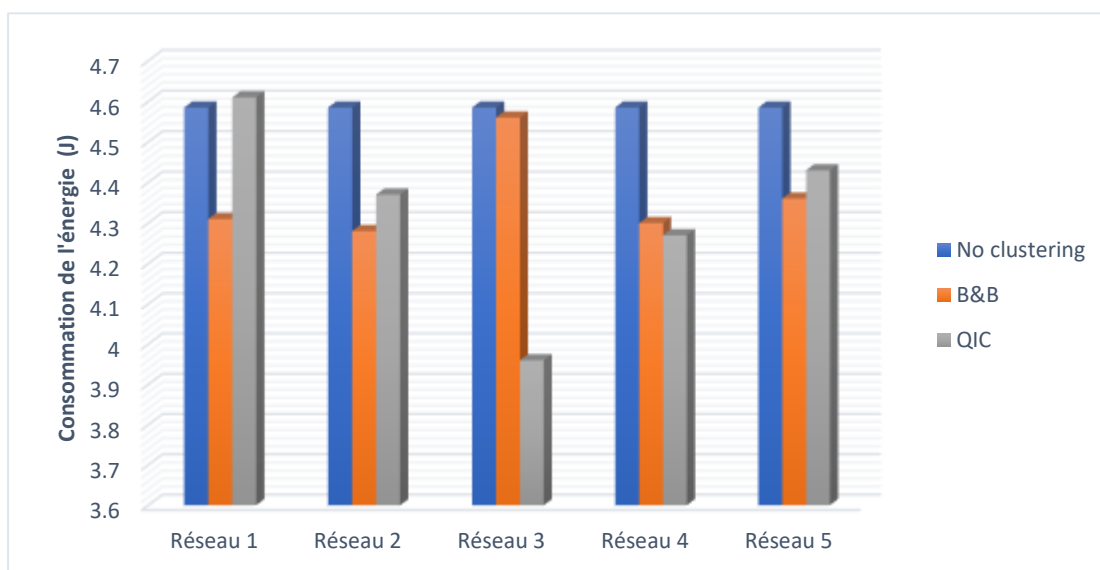


Figure 5.6 Consommation de l'énergie dans des réseaux IoT avec une station de base centrale.

Il convient de noter que même si les économies d'énergie offertes par l'algorithme QIC sont très intéressantes, elles ont été obtenues lors des premières itérations de l'algorithme. Au-delà d'un petit nombre d'itérations, aucune solution proposée par l'algorithme n'améliorait davantage l'efficacité énergétique du réseau, même lorsque le nombre de nœuds passait de 10 à 100 (figure 4.7).



Figure 5.7 Réduction de la consommation d'énergie par le réseau en fonction du nombre d'itérations effectuées par l'algorithme QIC

De plus, nous avons constaté que pour la plupart des réseaux considérés, l'approche par séparation et évaluation permettait d'atteindre de meilleurs résultats en termes de réduction de la consommation de l'énergie, et que les clusterings fournis par l'algorithme QIC définissaient des schémas de routage comprenant plusieurs liaisons de longueurs supérieures au seuil de la distance d_0 ce qui nécessite une consommation d'énergie plus importante que celle induite par l'emprunt de liaisons de longueurs inférieures à d_0 (voir l'équation 4.1) entraînant, ainsi, une détérioration de la qualité des clusterings fournis en termes d'économie en énergie offerte.

Dans la section suivante, nous allons affiner l'algorithme QIC afin d'améliorer la qualité de la solution qu'il offre en étudiant et en corrigeant la non-amélioration observée après un petit nombre d'itérations tout en favorisant le choix de liaisons de longueurs inférieures au seuil de la distance.

5.5 Une nouvelle approche inspirée-quantique améliorée pour l'optimisation des réseaux IoT

Dans le but d'améliorer la qualité de la solution fournie par l'algorithme QIC et de surmonter le problème de la stagnation de la solution après un petit nombre d'itérations, nous décrivons une nouvelle formulation mathématique de la fonction objectif du programme mathématique (PMC) afin de minimiser la distance totale à parcourir par les données tout en privilégiant les chemins comprenant des liaisons de longueurs inférieures ou égales au seuil de la distance d_0 .

La nouvelle fonction objectif consiste à minimiser l'énergie totale nécessaire pour transmettre les données depuis les nœuds membres vers la station de base par le biais des têtes des clusters suivant le clustering réalisé. Elle est décrite par,

$$\text{Min} \sum_{i=1}^n \sum_{\substack{j=1 \\ i \neq j}}^n \left(E_{TX}(L, a_{ij}) + E_{RX}(L) + E_{TX}(L, d_j) \right) x_{ij} + \sum_{j=1}^n E_{TX}(L, d_j) y_j \quad (4.17)$$

De plus, comme démontré dans le chapitre 4, l'optimisation du nombre de têtes de clusters à sélectionner permet d'offrir de meilleures économies en termes d'énergie. De ce fait, la contrainte (4.8) ne sera pas considérée dans la présente modélisation mathématique du problème considéré.

Ainsi, le nouveau modèle mathématique formulant le problème de clustering efficace énergétiquement dans les réseaux IoT, noté (MPMC), est décrit par,

$$(MPMC) \begin{cases} \text{Min} \sum_{i=1}^n \sum_{\substack{j=1 \\ i \neq j}}^n \left(E_{TX}(L, a_{ij}) + E_{RX}(L) + E_{TX}(L, d_j) \right) x_{ij} + \sum_{j=1}^n E_{TX}(L, d_j) y_j \\ \sum_{j=1}^n x_{ij} = 1 & , i = \overline{1, n} \\ x_{ij} \leq y_j & , i, j = \overline{1, n} \\ \sum_{i=1}^n x_{ij} \left(E_{TX}(L_i) + E_{RX}(L_i, d_j) \right) \leq y_j (E_j - E_{TX}(L_j, d_j)) & , j = \overline{1, n} \\ x_{ij}, y_j \in \{0,1\} & , i, j = \overline{1, n} \end{cases} \quad (4.18)$$

Nous avons également étudié les propriétés de l'algorithme des lucioles (FA) et de l'algorithme PSO hybridés pour la conception de l'algorithme QIC, et examiné leurs performances lors de leurs applications pour la résolution de différents problèmes d'optimisation. Nous avons constaté, en conséquence, que l'algorithme des lucioles

(FA) présente un certain nombre d'inconvénients liés à la recherche globale, en particulier une faible vitesse de convergence et une forte probabilité de rester bloqué dans un optimum local.

D'autre part, l'équilibre entre les capacités d'exploration et d'exploitation des particules, dans l'algorithme PSO, doit être renforcé en améliorant le mécanisme de coopération entre les meilleures particules personnelles et globales, en introduisant un paramètre d'amortissement inertiel χ pour conduire l'algorithme vers un optimum global de manière plus efficace.

La nouvelle approche que nous proposons est une version inspirée de l'informatique quantique de l'algorithme PSO que nous nommons « Quantum-Inspired PSO Clustering » QIPSOC. Dans laquelle, nous affinons le processus de l'exploration de l'espace des solutions pour s'approcher le plus possible de l'optimum en combinant les forces et l'efficacité de l'algorithme PSO avec l'utilisation d'un coefficient d'amortissement, tout en bénéficiant de la vitesse d'exécution offerte par l'informatique quantique.

La première étape de QIPSOC consiste à définir une population initiale de m particules.

5.5.1 Modélisation quantique

Chaque particule s est une solution quantique du programme (MPMC) représentée par un n -Qbit QY_s comme suit :

$$QY_s = \begin{bmatrix} \cos(\theta_s^1) & \cos(\theta_s^2) & \dots & \cos(\theta_s^n) \\ \sin(\theta_s^1) & \sin(\theta_s^2) & \dots & \sin(\theta_s^n) \end{bmatrix} \quad (5.18)$$

Where, $\forall j \in \{1, \dots, n\}$,

- $\theta_s^j \in \left[0, \frac{\pi}{2}\right]$
- $|\cos(\theta_s^j)|^2$ représente la probabilité de ne pas choisir le nœud j comme tête de cluster.

- $|\sin(\theta_s^j)|^2$ représente la probabilité de choisir le nœud j comme tête de cluster.

Dans la deuxième étape, QIPSOOC génère une population initiale de solutions binaires réalisables, de manière à ce que chaque solution quantique QY_s corresponde à une solution binaire BS^s définie par une $(n \times n)$ -matrice $BS^s = (BS_{ij}^s)_{i,j=1,n}$, telle que $BS_{ij}^s \in \{0,1\}, \forall i, j \in \{1, \dots, n\}$.

La solution binaire BS^s est une solution réalisable du programme (MPMC) qui correspond à un clustering des nœuds du réseau, i.e. une sélection des têtes de cluster et une affectation des nœuds à ces têtes de cluster satisfaisant les contraintes (4.5), (4.6), (4.7) et (4.8).

5.5.2 Nouvel algorithme pour la construction d'une solution binaire

Les solutions binaires sont produites par l'algorithme polynomial CBS qui est une version améliorée de l'algorithme Construct_Binary_Solution décrit pour l'algorithme QIC (section 3.4).

Étant donnée une solution quantique QY , l'algorithme CBS démarre avec une solution réalisable binaire vide ($BS_{ii} = 0, \forall i \in \{1, \dots, n\}$). La première étape de la construction de la solution réalisable BS revient à sélectionner les têtes des clusters en se basant sur les composantes de la solution quantique QY considérée. Dans la deuxième étape s'effectue la formation des clusters en affectant les nœuds, dans l'ordre décroissant de leurs distances avec la station de base, aux têtes de clusters qui vérifient les contraintes (4.5), (4.6), (4.7) et (4.8), et minimisent, en même temps, la distance à parcourir à partir des nœuds membres vers la station de base. Un nœud non-affecté, compte tenu de son énergie résiduelle, est défini tête de cluster ou si non sera permuté avec un autre nœud déjà affecté qui a suffisamment d'énergie pour être réaffecté à une autre tête de cluster. La troisième et dernière étape fait retourner la solution binaire réalisable BS .

Le pseudo-code de l'algorithme "CBS" est le suivant,

Algorithme CBS

Entrée : une solution quantique QY

Sortie : Une solution binaire réalisable BS

1. Créer une solution binaire nulle BS ;
2. Créer un ensemble CH de têtes de clusters, et l'initialiser à $CH = \emptyset$;
3. Générer un nombre aléatoire $r \in [0,1]$;
4. Pour chaque nœud i faire

Si $|\sin(\theta_i)|^2 \geq r$, alors le nœud i est sélectionné tête de cluster, i.e. $BS_{ii} = 1$ et $CH = CH \cup \{i\}$;

FinSi;

FinPour;

5. Trier les nœuds membres dans l'ordre décroissant de leurs distances avec la station de base;
6. Pour chaque nœud non encore affecté j

Assigner le nœud j à la tête de cluster i correspondant à $\min(ETX(L, a_{ik}) + ERX(L) + ETX(L, d_k))_{k \in CH}$ et vérifiant les contraintes (4.7), i.e. $BS_{ji} = 1$

Si aucune tête de cluster ne vérifie la contraintes (4.7), alors

Si le nœud j a suffisamment d'énergie pour transmettre ses données à la station de base, alors

Le nœud j est défini comme tête de cluster, i.e. $BS_{jj} = 1$ et $CH = CH \cup \{j\}$

Sinon, permuter le nœud j avec un autre nœud l déjà affecté qui a suffisamment d'énergie pour être réaffecté à une autre tête de cluster.

FinSi ;

FinSi ;

FinPour ;

7. Retourner la solution binaire BS .
-

L'algorithme « CBS » est un algorithme polynomial efficace.

En effet, l'étape de la création de la solution binaire BS de l'ensemble des têtes de clusters et de la génération du nombre aléatoire se font en $o(n)$ opérations. L'étape de la sélection des têtes de clusters nécessitent l'exécution de $o(3n)$ opérations au maximum et l'étape de l'affectation des nœuds membres aux têtes des clusters est en $o(n^2)$ opérations. Finalement, retourner la solution binaire en exécutant 1 seule opération d'affichage.

5.5.3 Exploration de l'espace des solutions

Juste après la génération de la population initiale des solutions binaires réalisables, la fitness (valeur de la fonction objectif) de chaque solution est évaluée. Puis, le meilleur candidat personnel et le meilleur candidat global sont sauvegardés.

Dans la troisième étape de l'exploration, pour un nombre donné d'itérations et à chaque itération t , chaque solution quantique QY^s est examinée et déplacée vers une nouvelle position en utilisant l'équation suivante,

$$QY_{t+1}^s = QY_t^s + \omega_t V_{t+1}^s + c_1 r_1 (best_t^s - QY_t^s) + c_2 r_2 (Gbest_t - QY_t^s) \quad (5.19)$$

Avec, V_t^s et V_{t+1}^s les vitesses de la particule s aux itérations t et $t+1$ respectivement, ω_t est le poids d'inertie à l'itération t calculé en utilisant un facteur d'amortissement inertiel $\chi \in \mathbb{R}$ comme suit,

$$\omega_t = \begin{cases} \chi \omega_{t-1}, & t \geq 1 \\ 1, & t = 0 \end{cases} \quad (5.20)$$

c_1 et c_2 sont des facteurs d'apprentissage, r_1 et r_2 sont deux nombres aléatoires de l'intervalle $[0,1]$, $best_t^s$ est la position rétroactive optimale de la particule s , et $Gbest_t$ la meilleure position globale à l'itération t .

Par la suite, une nouvelle solution BS_{t+1}^s associée à la nouvelle solution quantique QY_{t+1}^s est générée par l'algorithme CBS. Sa fitness est évaluée. Et, la meilleure position personnelle et la meilleure position globale sont sauvegardées.

À la fin, l'algorithme QIPSOC retourne la meilleure solution binaire rencontrée.

5.5.4 L'algorithme QIPSOC

Le pseudo-code de notre algorithme Quantum-Inspired PSO Clustering QIPSOC est donné par,

Algorithme Quantum-inspired PSO Clustering QIPSOC

Entrées : La taille du réseau n , les positions des nœuds de capteurs, les paramètres de l'algorithme : $m, nb_{it}, \omega_0, \alpha, c_1, c_2, r_1$ et r_2 ;

Sorties : La meilleure solution binaire réalisable GBS

1. Générer la population initiale de m solutions quantiques $QP(0) = \{QY_0^1, QY_0^2, \dots, QY_0^m\}$;
 2. Construire la population $BP(0) = \{BS_0^1, BS_0^2, \dots, BS_0^m\}$ des solutions binaires réalisables correspondantes aux solutions quantiques de $QP(0)$ à l'aide de l'algorithme CBS ;
 3. Evaluer la fitnessse de chaque solution binaire de $BP(0)$;
 4. Enregistrer les meilleures solutions binaires et les meilleures solutions quantiques rencontrées dans $BBS(0) = \{bbs_0^1, bbs_0^2, \dots, bbs_0^m\}$ et $BQS(0) = \{bqs_0^1, bqs_0^2, \dots, bqs_0^m\}$, respectivement ;
 5. Enregistrer la meilleure solution binaire actuelle GBS et la meilleure solution quantique actuelle GQS ;
 6. Initialiser le compteur des itérations $t = 1$;
 7. Tant que ($t \leq nb_iterations$) faire
 - Pour $s = 1$ à m faire
 - Mettre à jour le poids d'inertie à l'aide de l'équation (5.20);
 - Calculer la position de la nouvelle solution quantique QY_{t+1}^s à l'aide des équations (5.19) et (5.20) ;
 - Construire la nouvelle solution binaire réalisable BS_{t+1}^s correspondant à la nouvelle solution quantique QY_{t+1}^s en utilisant l'algorithme CBS;
 - Evaluer la fitnessse de la nouvelle solution binaire BS_{t+1}^s ;
 - Enregistrer la meilleure solution binaire bbs_t^s et la meilleure solution quantique correspondante bqs_t^s ;
 - Mettre à jour la meilleure solution binaire actuelle GBS et la meilleure solution quantique actuelle GQS ;
 - FinPour ;
 - Incrémenter le compteur des itérations $t = t + 1$;
 - FinTantque ;
 8. Retourner la meilleure solution binaire réalisable GBS .
-

La complexité algorithmique de la méthode QIPSOC dépend essentiellement de la complexité algorithmique de ses différentes étapes. Étant donné que la méthode QIPSOC se compose de trois étapes principales : l'initialisation, l'exploration et la finalisation dont les complexités algorithmiques sont $o(n)$, $o(n)$ et $o(1)$ respectivement.

En conséquent, la méthode QIPSOC est une méthode polynomial efficace.

5.5.5 Tests et résultats

Pour analyser les performances de notre algorithme QIPSOC décrit ci-dessus, nous avons effectué une série de tests sur plus de 200 réseaux IoT avec les deux configurations de la station de base (centrale et périphérique) dont les paramètres sont identiques aux paramètres répertoriés dans le tableau 5.4. L'algorithme a été implémenté et exécuté à l'aide de Matlab R2021a, sur un ordinateur portable équipé d'un processeur Intel(R) Core (TM) i5-1135G7 de 11e génération @ 2,40 GHz.

Les paramètres du mouvement des particules dans QIPSOC sont configurés selon le tableau 5.6.

Tableau 5.6 Paramètres du mouvement PSO dans l'algorithme QIPSOC.

| Paramètre | Valeur |
|---|-----------------------|
| Taille de la population m | 100 |
| Nombres des itérations nb_it | 500 |
| Poids d'inertie initial ω_0 | 1 |
| Facteur d'amortissement inertiel χ | 0.85 |
| 1 ^{er} facteur d'apprentissage c_1 | 2 |
| 2 nd facteur d'apprentissage c_2 | 2 |
| r_1 et r_2 | Aléatoires dans [0,1] |

Un résumé des résultats obtenus par la simulation du QIPSOC sur plus de 200 réseaux IoT est présenté dans le tableau 5.7 Et visualisé par les figures 5.8 et 5.9. Ces

figures illustrent et comparent les économies d'énergie fournies par les méthodes intlinprog-DV-PMC que nous notons B&B, QIC et QIPSOC lorsqu'elles sont appliquées sur des réseaux avec des stations de base centrales et périphériques, respectivement.

Tableau 5.7 Résumé des résultats des tests sur les algorithmes QIPSOC, QIC et B&B.

| | Consommation moyenne en énergie (%) | | | Temps d'exécution moyen (s) | | | Écart moyen en économie d'énergie (%) | |
|--|-------------------------------------|---------|--------|-----------------------------|---------|--------|---------------------------------------|------------|
| | B&B | QIC | QIPSOC | B&B | QIC | QIPSOC | QIPSOC/B&B | QIPSOC/QIC |
| Réseaux avec station de base centrale | 4.34 | 5.54 | 3.67 | 702.94 | 587.11 | 18.8 | 14.93 | 18.95 |
| Réseaux avec station de base périphérique | 14.99 | 3424.12 | 11.73 | 3 245,9 | 1 308,2 | 134,5 | 21.75 | 99.69 |

Les résultats montrent que l'approche QIPSOC peut regrouper efficacement les nœuds du réseau en clusters offrant des économies d'énergie considérables allant de 17,99 à 20,74% dans les réseaux fonctionnant avec une station de base centrale. Dans les réseaux avec une station de base périphérique, QIPSOC permet des économies d'énergie de plus de 91 %.

De plus, la comparaison des résultats obtenus par les méthodes B&B et la métaheuristique d'inspiration quantique QIC avec ceux délivrés par QIPSOC, montre que notre approche QIPSOC offre une amélioration significative des économies en énergie réalisées par les deux autres méthodes. En effet, dans le cas des réseaux avec

une station de base centrale, elle améliore les résultats de B&B et de QIC d'une moyenne de 14,93% et 18,95% respectivement. Et dans le cas des réseaux avec une station de base périphérique, elle améliore les résultats de B&B et de QIC d'une moyenne de 21.75% et 99.69% respectivement.

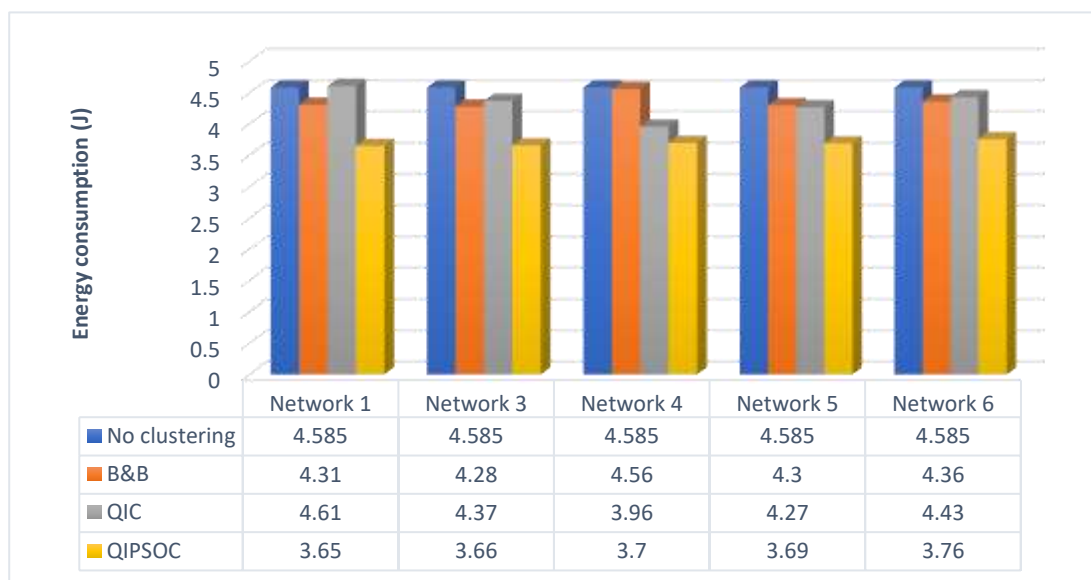


Figure 5.8 Consommation de l'énergie dans des réseaux IoT avec une station de base centrale.

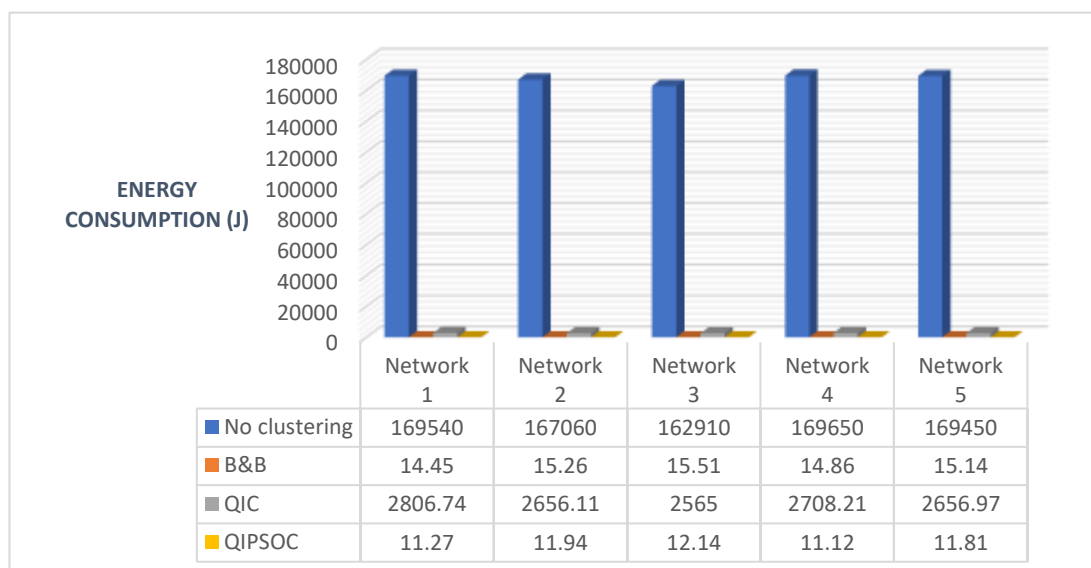


Figure 5.9 Consommation de l'énergie dans des réseaux IoT avec une station de base périphérique station.

D'un autre côté, la figure 5.10 décrit l'évolution de la fitness des meilleures solutions binaires identifiées au fil des itérations de l'algorithme QIPSO, ce qui correspond à la progression de l'exploration de l'ensemble des solutions lors de l'exécution de l'algorithme QIPSOC.




Figure 5.10. La progression de la recherche de la meilleure solution dans le QIPSOC.

Il est clair que le problème de stagnation rencontré dans l'approche QIC n'existe plus dans l'algorithme QIPSOC. Le QIPSOC est capable d'éviter la convergence prématurée vers un minimum local.

De plus, Les clusterings décrits par QIPSOC consomment des énergies dont la valeur est bien centrée autour de la moyenne qui est égale à 3.67 Joules, avec un écart-type d'énergie égale à 0.23. La figure 5.11 illustre la dispersion des consommations d'énergie de 200 réseaux IoT, ayant les caractéristiques listées dans le tableau 5.4, après clustering par QIPSOC.

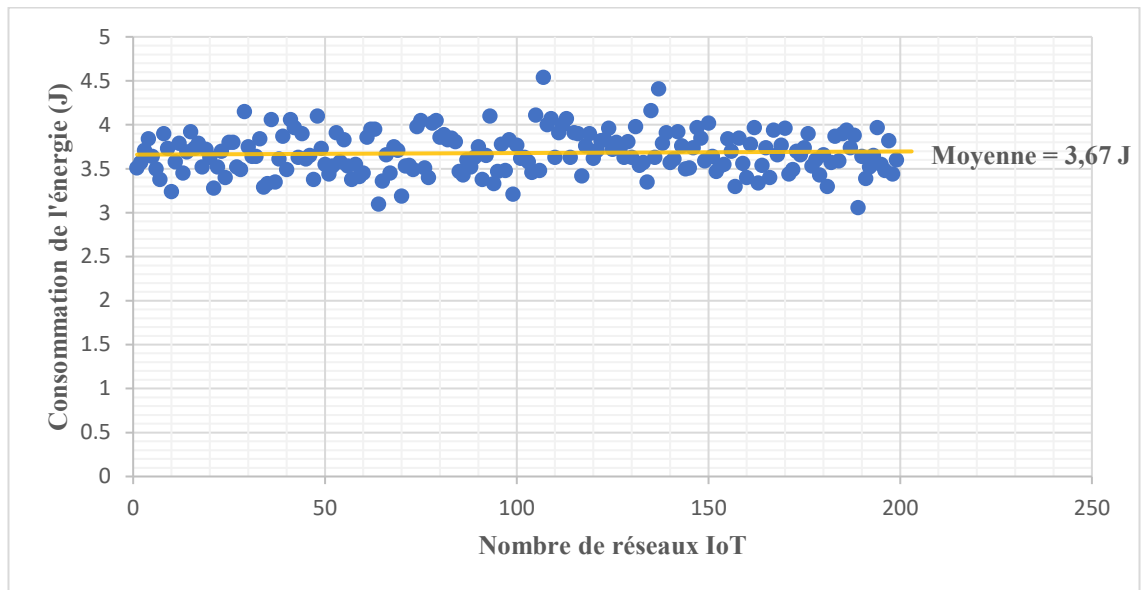


Figure 5.11. Dispersion des consommations d'énergie de 200 réseaux IoT dont les nœuds sont regroupés par clusters en utilisant QIPSOC.

Ceci atteste que la réduction de la consommation d'énergie offerte par le clustering obtenu par le biais de l'approche QIPSOC est due à la combinaison de plusieurs améliorations apportées au modèle mathématique, à l'algorithme de construction des solutions binaires et au processus de l'exploration de l'espace des solutions. En effet, la nouvelle formulation mathématique de la fonction objectif nous permet de prioriser le routage des données sur des chemins dont la longueur des liens ne dépasse pas le seuil de la distance d_0 . De plus, le nouvel algorithme de construction des solutions binaires CBS favorise la sélection des liaisons de longueurs inférieures ou égales à d_0 permettant ainsi la construction de solutions binaires de meilleure qualité. D'autres part, la nouvelle approche d'exploration de l'espace des solutions a montré son efficacité à prévenir la convergence précoce et la stagnation dans un optimum local grâce à l'utilisation du facteur d'amortissement inertiel χ et à la qualité des solutions binaires construites par CBS.

En complément, il a été montré, dans la section 5.4, que la méthode QIC est plus rapide que la méthode B&B. La méthode QIC offre une réduction significative du temps de calcul, allant de 16,47 à 59,79% du temps requis pour exécuter la méthode B&B. Plus intéressant encore, la méthode QIPSOC offre une réduction

supplémentaire encore plus impressionnante de 89.72 %. En effet, QIPSOC est tout à fait capable d'exécuter 500 itérations d'exploration sur une population de 100 particules de taille 100 en un temps moyen de 18,8 secondes lorsque la station de base est centrale, et de 134.5 secondes lorsque la station de base est périphérique.

Les figure 5.12 et 5.13 présentent une comparaison du temps requis pour l'exécution des méthodes B&B, QIC et QIPSOC sur cinq réseaux IoT de taille 100 avec station de base centrale et périphérique, respectivement.

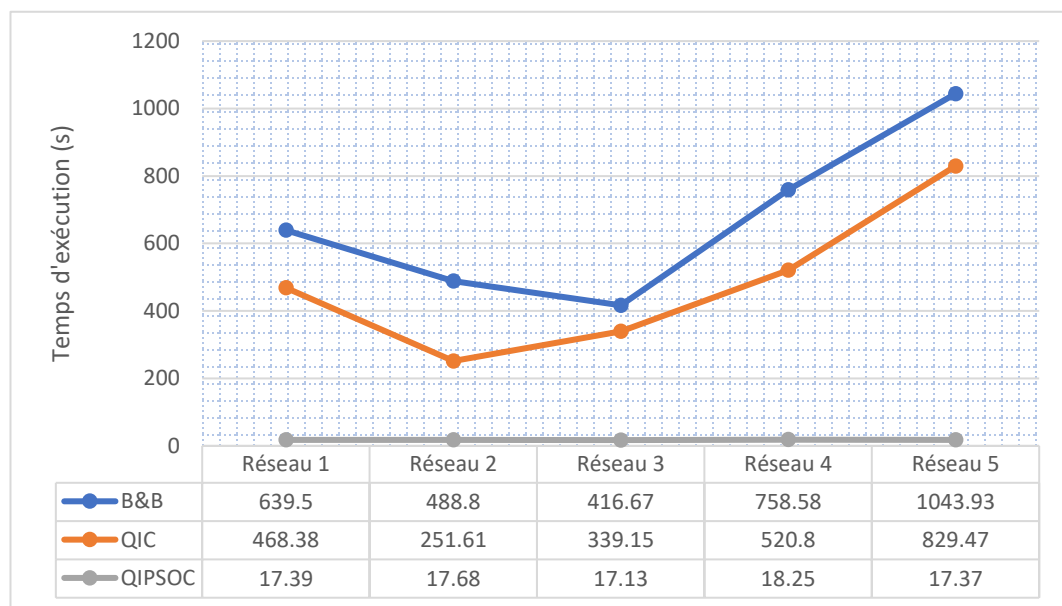


Figure 5.12. Comparaison des temps d'exécution de B&B, QIC et QIPSOC sur cinq réseaux IoT de taille 100 avec station de base centrale.




Figure 5.13. Comparaison des temps d'exécution de B&B, QIC et QIPSOC sur cinq réseaux IoT de taille 100 avec station de base périphérique.

De plus, l'algorithme QIPSO étant polynomial en le nombre des nœuds de capteurs, surpasse significativement les méthodes Multi-Hop Clustering [126], NSGA-II [10] et MOCAS [27] dont les complexités algorithmiques sont $(n^2 \log n)$, $O(kn^2)$ et $O(kn^2)$ (k est le nombre de fonctions objectif considérées, ici $k = 1$), respectivement.

Ces constatations nous amènent à déclarer que la métaheuristique QIPSOC de clustering économe en énergie dans les réseaux IoT, surpasse la méthode de clustering QIC en termes de réduction de la consommation de l'énergie et du temps d'exécution indépendamment de la configuration de la station de base.

Les améliorations que notre algorithme de clustering inspiré de l'informatique quantique QIPSOC offre en termes d'économies d'énergie et de temps d'exécution sont d'une grande ampleur. Par conséquent, notre algorithme QIPSOC est une excellente alternative aux stratégies de clustering conventionnelles et est le mieux adapté aux diverses applications de la technologie IoT dans le monde réel.

5.6 Conclusion

Dans ce chapitre, nous avons proposé deux nouvelles approches polynomiales d'inspiration quantique pour résoudre le problème de clustering économe en énergie dans les réseaux IoT. Nous avons codé les variables de décision liées au choix des têtes de cluster sous la forme d'un n-Qbit, correspondant à une solution quantique QY. Dans la première approche QIC, l'espace des solutions généré par l'algorithme est exploré en faisant la rotation des angles des Qbits selon les mouvements de l'algorithme des lucioles et de l'algorithme d'optimisation par essaim de particules PSO. Tandis que la deuxième approche QIPSOC effectue une exploration de l'espace des solutions en faisant une rotation des angles des Qbits selon les mouvements de l'algorithme d'optimisation par essaim de particules employant un facteur d'amortissement inertiel permettant ainsi de prévenir une convergence prématurée vers un optimum local. Nous avons également développé deux algorithmes « Construct_Binary_Solution » et « CBS » qui ont pour rôle de dériver une solution binaire à partir d'une solution quantique de deux manières différentes. En effet, l'algorithme « CBS » constitue une version améliorée de l'algorithme « Construct_Binary_Solution » qui offre des solutions binaires de meilleures qualités.

La motivation derrière la description de ces deux approches est d'exploiter la puissance et la vitesse de l'informatique quantique pour optimiser la consommation d'énergie dans les réseaux IoT. Dans l'approche QIC nous avons tenté d'exploiter les avantages mutualisés des mouvements FA et PSO lors de la navigation dans le domaine des solutions. Malgré le fait que les améliorations offertes par cet algorithme soient très considérables en termes d'économies d'énergie et de temps d'exécution, l'algorithme souffrait d'une convergence précoce et d'une stagnation de la solution après un petit nombre d'itérations.

Ceci nous a conduit à travers une inspection des caractéristiques des deux algorithmes FA et PSO ainsi qu'une amélioration de l'exploration des solutions en utilisant un facteur d'amortissement inertiel et de la procédure de construction des solutions binaire à décrire la méthode QIPSOC basée sur une nouvelle modélisation

du problème qui favorise les chemins de routage comprenant des liaisons de longueurs inférieures ou égales au seuil de la distance d_0 .

L'algorithme QIPSOC permet d'établir des clustering des réseaux IoT qui réduisent considérablement la consommation de l'énergie quel que soit la localisation de la station de base en un temps très raisonnable.

Ainsi, l'algorithme QIPSOC constitue une excellente alternative aux approches de clustering classiques non adaptées à la localisation périphérique des stations de base et qui nécessite un temps d'exécution important et non raisonnable pour les applications réelles.

CHAPITRE 6 – CONCLUSION GÉNÉRALE

La consommation de l'énergie est l'un des grands défis dans les réseaux IoT. En effet, les nœuds de capteurs qui constituent la base des réseaux IoT, sont alimentés principalement par des batteries ayant une capacité énergétique limitée. Une fois la batterie épuisée, le capteur n'est plus capable d'assurer ses tâches de recueil et de transmission des données ce qui influence les performances du réseau et le rend incapable d'assurer les services pour lesquels il a été conçu. De ce fait, une gestion optimisée de la consommation de l'énergie dans les réseaux IoT doit être adoptée pour assurer une durabilité maximale et un fonctionnement optimal du réseau.

6.1 Contributions

Dans notre étude, nous avons proposé une formulation mathématique originale complète et détaillée (PMC) du problème du clustering dans les réseaux IoT sans fil avec l'objectif d'optimiser la consommation de l'énergie. Ce dernier repose sur l'utilisation du modèle radio dépendant de la distance entre les nœuds émetteurs et récepteurs pour la mesure de l'énergie consommée. Une approche d'optimisation basée sur la méthode Branch-and-Bound a été implémentée pour résoudre le modèle mathématique décrit. Les expérimentations montrent que le modèle décrit est très pertinent en offrant une réduction importante de la consommation de l'énergie qui a atteint les 20%. Cependant, le temps d'exécution de la méthode de résolution proposée est au moins de 60 minutes ce qui ne peut pas être accepté dans des applications réelles dynamiques. Ceci nous a conduit vers l'exploitation des concepts et avantages de l'informatique quantique pour concevoir la métaheuristique inspirée-quantique QIC basée sur les mouvements inspirés-quantique FA et PSO pour résoudre le modèle (PMC). Les tests de performances montrent que QIC permet d'économiser 15.48% de l'énergie en un temps très raisonnable. En effet, QIC offre une accélération considérable en comparaison avec la méthode précédemment utilisée, il est capable d'exécuter 100 itérations incluant l'exploration d'une population de 100 solutions réalisables sur un réseau de 100 nœuds en moins de 5 minutes. L'algorithme QIC s'avère très intéressant pour le problème considéré,

néanmoins il a été constaté que malgré les réductions importantes offertes il souffre d'une convergence prématurée vers un optimum local.

Afin de raffiner la qualité de la solution fournie par l'algorithme QIC et de résoudre le problème de la stagnation de la solution après un petit nombre d'itérations, nous avons proposé une nouvelle formulation de la fonction objectif du programme mathématique (PMC) de manière à minimiser l'énergie à consommer lors de la transmission des données depuis les nœuds membres vers la station de base par le biais des têtes des clusters suivant le clustering réalisé en privilégiant les chemins comprenant des liaisons de longueurs inférieures ou égale au seuil de la distance d_0 .

Nous avons également mené une étude des propriétés des deux algorithmes FA et PSO pour déterminer les raisons favorisant cette stagnation puis procédé à leurs éliminations en adoptant un seul mouvement efficace, à savoir le mouvement de l'algorithme PSO, en renforçant le mécanisme de coopération entre les particules, et en intégrant un coefficient d'amortissement inertiel χ afin de guider la recherche vers une solution de meilleure qualité approchant l'optimum global.

De cette manière, nous avons développé la nouvelle méthode QIPSOC qui fournit des économies en énergie significatives variant entre 17,99 et 20,74% dans les réseaux fonctionnant avec une station de base centrale. Et d'une réduction de la consommation de l'énergie dépassant les 91% dans les réseaux avec une station de base périphérique. Améliorant ainsi les résultats de intlinprog-DV-PMC et QIC d'une moyenne de 21.75% et 99.69% respectivement.

Ces économies considérables ont été obtenues en un temps très raisonnable dont la moyenne est de 18.8 et de 134.5 secondes pour les réseaux avec station de base centrale et périphérique, respectivement, ce qui correspond à une réduction atteignant 59,79% et 89.72 % du temps nécessaire pour l'exécution des méthodes intlinprog-DV-PMC et QIC, respectivement.

De plus, les approches QIC et plus particulièrement QIPSOC, étant polynomiales en le nombre des nœuds de capteurs du réseau, surpassent les méthodes de clustering de

pointes Multi-Hop Clustering [127], NSGA-II [10] et MOCAS [27] en termes de complexité algorithmique.

Ceci atteste que les améliorations apportées ont permis l'élaboration d'une métaheuristique très efficace et très rapide pour la résolution du problème du clustering économe en énergie dans les applications réelles des réseaux IoT quel que soit la localisation des stations de base. QIPSOC est une excellente alternative à l'approche QIC et aux approches de clustering classiques qui ne sont pas adaptés aux réseaux avec stations de base périphériques et qui nécessitent un temps d'exécution non raisonnable.

Ces travaux ont mené à la rédaction de quatre articles scientifiques en tant que premier auteur et à la contribution à la rédaction de cinq articles scientifiques en lien avec l'optimisation et/ou l'informatique quantique [128,129,130,131,132], la publication de trois articles scientifiques dans des revues scientifiques avec comités de lecture [78,133,134] et de deux articles de communications dans des conférences internationales [135,136].

L'article [78] présente une revue des outils mathématiques applicables à l'informatique quantique pour la modélisation et l'optimisation des problèmes d'ingénierie. L'article [133] présente la première modélisation mathématique du problème du clustering économe en énergie (PMC) et la méthode de résolution basée sur le solveur intlinprog. Tandis que, l'article [134] présente la méthode inspirée quantique QIC.

De plus, le premier article de communication [135] présente le modèle (PMC) décrit pour la première modélisation mathématique du problème du clustering économe en énergie, ainsi qu'une présentation et une comparaison des deux méthodes intlinprog et QIC. Dans le deuxième article de communication [136], nous avons introduit les notions de base de l'informatique quantique, présenté une revue de la littérature des techniques de l'optimisation quantique et inspirée-quantique, tout en mettant en évidence les forces, les défis et les limitations de l'informatique quantique actuelle.

6.2 Perspectives et recommandations

Nous proposons, dans cette section, plusieurs perspectives de recherche possibles basée sur les travaux effectués dans cette thèse, suivant principalement les directions suivantes :

(1) Affiner l'algorithme QISPOC pour améliorer son efficacité

Dans l'algorithme d'optimisation par essaim de particules, le coefficient d'inertie ω permet de définir la capacité d'exploration de chaque particule en vue d'améliorer la convergence de la méthode. En effet, ce paramètre offre un équilibre entre la recherche locale et la recherche globale dans l'espace des solutions. L'efficacité de l'exploration de l'espace de recherche dépend de la valeur du coefficient d'inertie, une grande valeur de ω favorise une exploration globale, tandis qu'une petite valeur encouragera l'exploration locale. Ainsi, le coefficient ω exerce une grande influence sur les performances de l'algorithme PSO, et plusieurs chercheurs ont proposé d'adopter un coefficient d'inertie dynamique qui varie au fil des itérations. C'est le cas de notre travail présenté à travers cette thèse, où nous avons utilisé un coefficient d'amortissement de valeur fixe pour modifier le coefficient ω au fil des itérations de l'algorithme QIPSOC.

Dans des travaux futurs, nous pouvons étudier la possibilité d'utiliser une autre formule d'inertie dynamique pour renforcer davantage les performances et accélérer la vitesse de convergence de l'algorithme QIPSOC en utilisant par exemple un coefficient de constriction ou une formule linéaire dynamique pour mesurer l'inertie à chaque itération.

(2) Étudier la capacité de QIPSOC à prolonger la durée de vie des réseaux IoT

Comme mentionné dans le chapitre 2, l'optimisation de la consommation de l'énergie dans les réseaux IoT est primordiale pour maximiser leurs performances et pour prolonger leurs durées de vie au maximum afin d'assurer la bonne qualité et la continuité de leurs services.

L'approche QIPSOC présentée dans la présente thèse est conçue spécialement pour optimiser la consommation de l'énergie dans réseaux IoT sans fils et son efficacité a été démontrée pour les réseaux de tailles inférieures ou égales à 100. Cependant, les applications réelles actuelles comptent un nombre de dispositifs beaucoup plus élevé. De ce fait, les résultats obtenus, illustrés dans la section 5, doivent être bonifiés avec une étude extensive des performances de la métaheuristique QIPSOC dans le cas de réseaux IoT de grande taille et de sa capacité à étendre la durée de vie de ces réseaux, et l'affiner, le cas échéant, pour atteindre cet objectif.

(3) Adapter QIPSOC aux réseaux IoT avec dispositifs mobiles ...

L'internet des objets peut avoir des applications dans divers domaines nécessitant le déploiement de réseaux à technologie IoT sur des objets mobiles, dont la localisation peut changer d'un moment à un autre, comme dans le domaine du transport, de la sécurité militaire, la santé ... etc.

Dans ce types d'applications nous distinguons deux cas de figures, soit l'objet connecté au réseau se déplace suivant une trajectoire bien définie et donc à n'importe quel moment sa position peut être déterminée en utilisant l'équation de sa trajectoire, soit il se déplace aléatoirement, et dans ce cas on ne connaît pas au préalable sa trajectoire, donc il doit communiquer à l'utilisateur sa position d'une façon continue ou sinon sur interrogation par l'utilisateur, ce qui induit, dans les deux cas, une consommation supplémentaire d'énergie de plus de la nécessité d'une prise de décision extrêmement rapide avant qu'il se déplace à nouveau.

De ce fait, nous proposons d'examiner et d'étudier la possibilité d'utiliser et d'adapter notre approche QIPSOC pour l'optimisation de la consommation de l'énergie dans ce type de réseaux IoT.

(4) Décrire une version entièrement quantique de l'algorithme QIPSOC.

Actuellement, le nombre d'objets connectés à l'internet des objets se compte par les milliards. Ce nombre ne peut pas être déterminé par exactitude puisqu'il est constante évolution. En conséquence, l'optimisation de la consommation de

l'énergie, du processus du routage, de l'analyse et du traitement des données est très complexe et ne peut pas être résolu sur les ordinateurs conventionnels. Ces derniers nécessitent un temps d'exécution interminable et une immense capacité de calcul et de stockage pour traiter de telles problèmes.

Les ordinateurs quantiques avec leur capacité de calcul très élevée et accélérée présentent une excellente ébauche pour résoudre des problèmes de grande complexité.

Si l'élaboration d'une métaheuristique inspirée de l'informatique quantique mais exécutée sur un ordinateur classique offre des réductions significatives de la consommation de l'énergie et du temps d'exécution. Alors, nous sommes convaincus que l'élaboration d'une version quantique de l'algorithme QIPSOC à exécuter sur un simulateur ou un ordinateur quantique va révolutionner la gestion des ressources énergétiques dans les réseaux IoT tout en fournissant des solutions instantanées.

(5) Adapter et appliquer pour la résolution d'autres problèmes d'optimisation,

Une des très grandes forces et avantages des méthodes métaheuristique réside dans le fait qu'elles ne soient pas spécifiques à un problème d'optimisation donné. Au contraire, elles sont flexibles et elles peuvent être adaptées à la résolution de différents types de problèmes d'optimisation.

De ce fait, il serait très intéressant d'utiliser et d'adapter l'approche QIPSOC à la résolution d'autres problèmes d'optimisation complexes. Nous citons, à titre d'exemple, le problème du clustering dans d'autres types de réseaux avec différents objectifs.

(6) Considérer d'autres schémas de routage,

Les architectures en grappes (clustering) ont démontré leurs capacités à améliorer l'efficacité énergétique, l'évolutivité du réseau tout en offrant en plus, des perspectives d'agrégation et de sécurité des données collectées.

Dans notre travail actuel, nous avons considéré des chemins de transmission en un seul saut entre les nœuds membres et les têtes de clusters et aussi entre les têtes de clusters et la station de base.

Il convient d'examiner, dans des travaux futurs, l'adoption d'une transmission multi-sauts (en chaîne) entre les nœuds membres et les têtes de clusters et entre les têtes de clusters et la station de base, ainsi que la considération d'un deuxième niveau de clustering, c'est-à-dire un clustering des clusters, dans lequel chaque cluster est perçu par la station de base comme étant un nœud de capteurs.

RÉFÉRENCES BIBLIOGRAPHIQUES

- 1 S., Messai, S. " Gestion de la Mobilité dans les Réseaux de Capteurs Sans Fil ". Thèse de Doctorat en Informatique. Université Ferhat Abbas Sétif 1 & Université Claude Bernard Lyon 1, Algérie, Sétif, 2019. Disponible en ligne sur : <http://dspace.univ-setif.dz:8888/jspui/handle/123456789/3613> (consulté le 17 Août 2022)
- 2 A., Asin et D., Gascon. " 50 sensor applications for a smarter world". Libelium Comunicaciones Distribuidas, Tech. Rep, 2012. Disponible : <https://docplayer.net/19760236-50-sensor-applications-for-a-smarter-world-get-inspired.html> (Consulté le 17 août 2022)
- 3 J.R.E., Leite, P. S., Martins, et E. L., Ursini. "Internet of Things: An Overview of Architecture, Models, Technologies, Protocols and Applications. In: Iano, Y., Arthur, R., Saotome, O., Vieira Estrela, and V., Loschi, H. (eds) *Proceedings of the 3rd Brazilian Technology Symposium*, pp. 75–85, BTSym 2017. Springer, Cham. doi: [10.1007/978-3-319-93112-8_8](https://doi.org/10.1007/978-3-319-93112-8_8)
- 4 N. Srinidhi, S. Dilip Kumar, et K. Venugopal. "Network optimization in the internet of things: A review". *Engineering Science and Technology, an International Journal*, Vol. 22, n° 1, pp. 1-21, 2019. doi: [10.1016/j.jestch.2018.09.003](https://doi.org/10.1016/j.jestch.2018.09.003)
- 5 V., Alcácer et V., Cruz-Machado. "Scanning the Industry 4.0: A Literature Review on Technologies for Manufacturing Systems". *Engineering Science and Technology, an International Journal.*, Vol. 22, n° 3, pp. 899-919, 2019. doi: [10.1016/j.jestch.2019.01.006](https://doi.org/10.1016/j.jestch.2019.01.006)
- 6 A., Azari et C., Cavdar. " Self-Organized Low-Power IoT Networks: A Distributed Learning Approach ". *2018 IEEE Global Communications*

-
- Conference (GLOBECOM)*, pp. 1-7, 2018. doi: [10.1109/GLOCOM.2018.8647894](https://doi.org/10.1109/GLOCOM.2018.8647894)
- 7 R., Alonso et al., " IoT-Based Management Platform for Real-Time Spectrum and Energy Optimization of Broadcasting Networks ". *Wireless Communications and Mobile Computing, Vol. 2018, 2018*. Disponible sur: <https://biblio.ugent.be/publication/8570860> (17 Août 2022)
 - 8 E., Jaime Moreno et al., " Optimizing a Centralized Control Topology of an IoT Network Based on Hilbert Space ", in Y. Ismail (Ed.) *Internet of Things (IoT) for Automated and Smart Applications*. London, United Kingdom, IntechOpen, 2019 [Online]. doi: [10.5772/intechopen.77404](https://doi.org/10.5772/intechopen.77404)
 - 9 H., CHI et A., RADWAN. " Multi-Objective Optimization of Green Small Cell Allocation for IoT applications in Smart City ". *IEEE ACCESS*, Vol. 8, pp. 101903-101914, 2020. doi: [10.1109/ACCESS.2020.2997761](https://doi.org/10.1109/ACCESS.2020.2997761)
 - 10 K., Deb et al. " A fast and elitist multiobjective genetic algorithm: NSGA-II ". *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182-197, 2002. doi: [10.1109/4235.996017](https://doi.org/10.1109/4235.996017)
 - 11 M., Ozturk et al. " Context-Aware Wireless Connectivity and Processing Unit Optimization for IoT Networks ". *IEEE Internet of Things Journal*, 2022. doi: [10.1109/JIOT.2022.3152381](https://doi.org/10.1109/JIOT.2022.3152381)
 - 12 H., Gupta et al. " iFogSim: A toolkit for modeling and simulation of resource management techniques in the internet of things, edge and fog computing environments ". *Software Practice and Experience*, Vol. 47, n° 9, pp. 1275–1296, 2017. doi: [10.48550/arXiv.1606.02007](https://doi.org/10.48550/arXiv.1606.02007)
 - 13 S., POPL et al. " A Survey on Energy Efficient Narrowband Internet of Things (NB-IoT): Architecture, Application and Challenges ". *IEEE ACCESS*, Vol. 7, pp. 16739-16776, 2019. doi: [10.1109/ACCESS.2018.2881533](https://doi.org/10.1109/ACCESS.2018.2881533)

-
- 14 K. A., Sangaiah et al. " IoT Resource Allocation and Optimization Based on Heuristic Algorithm ". *Sensors* 2020, Vol. 20, n° 539, 2020. doi: [10.3390/s20020539](https://doi.org/10.3390/s20020539)
 - 15 U., Tekin et al. " IoT Activities Tuning for Energy Consumption Optimization ". *Procedia Computer Science*, Vol. 175, pp. 566-571, 2020.
 - 16 R. M., Praveen Kumar et B. M., Rajasekhara. " Energy efficient cluster head selection for internet of things ". *New Review of Information Networking*, Vol. 22, n° 1, pp. 54–70, 2017.
 - 17 A. V., Dhumane et R. S., Prasad. " Multi-objective fractional gravitational search algorithm for energy efficient routing in IoT ". *Wireless Networks*, Vol. 25, pp. 399-413, 2017.
 - 18 M., Alazab et al. " Multi-objective cluster head selection using fitness averaged rider optimization algorithm for IoT networks in smart cities ". *Sustainable Energy Technologies and Assessments*, Vol. 43, n° 100973, 2021.
 - 19 X., Yunfeng et al. "A simple and efficient artificial bee colony algorithm ". *Mathematical Problems in Engineering*, Vol. 2013, 2013.
 - 20 J., McCall. " Genetic algorithms for modelling and optimisation ". *Journal of Computational and Applied Mathematics*, Vol. 184, n° 1, pp. 205-222, 2005.
 - 21 M.E., Pedersen et A. J., Chipperfield " Simplifying particle swarm optimization ". *Applied Soft Computing*, Vol. 10, n° 2, pp. 618–628, 2010.
 - 22 E., Rashedi et al. " GSA: a gravitational search algorithm ". *Information Sciences*, Vol. 179, n° 13, pp. 2232-2248, 2009 .

-
- 23 S., Mirjalili et A., Lewis. " The whale optimization algorithm ". *Advances in Engineering Software*, Vol. 95, pp. 51-67, 2016.
- 24 A., Mahmood et al. " Energy-Reliability Aware Link Optimization for Battery-Powered IoT Devices with Non-Ideal Power Amplifiers ", *IEEE Internet of Things Journal*, Vol. 6, n° 3, pp. 5058-5067, 2018.
- 25 L., Guangshun et al. " Energy consumption optimization with a delay threshold in cloud-fog cooperation computing ". *IEEE Access*, Vol. 7, pp. 159688–159697, 2019.
- 26 D., Binu et B., Kariyappa. " RideNN: A New Rider Optimization Algorithm-Based Neural Network for Fault Diagnosis in Analog Circuits ". *IEEE Transactions on Instrumentation and Measurement*, Vol. 68, n° 1, pp. 2-26, 2019.
- 27 J., Huang et al. " A Novel Bioinspired Multiobjective Optimization Algorithm for Designing Wireless Sensor Networks in the Internet of Things ". *Journal of Sensor*, Vol. 2015, n° 192194, 2015.
- 28 O., ALSARYRAH et al. " Bi-objective Optimization for Energy Aware Internet of Things Service Composition ". *IEEE ACCESS*, Vol. 6, pp. 26809-26819, 2018.
- 29 N., Mehran et al. " MAPO: A Multi-Objective Model for IoT Application Placement in a Fog Environment ". *IoT 2019 : Proceedings of the 9th International Conference on the Internet of Things*, Article n° 21, pp. 1-8, 2019.
- 30 O., Skarlat et al. " Towards qos-aware fog service placement ". *IEEE 1st International Conference on Fog and Edge Computing (ICFEC)*, pp. 89–96, 2017.

-
- 31 N., Kashyap et al. " Multi-objective Optimization using NSGA II for service composition in IoT ". *Procedia Computer Science*, Vol. 167, pp. 1928-1933, 2020.
- 32 J. A. Ayoola, E. O. Asani, A. E. Okeynka, et P. Ayegba. "Towards Comparative Analysis Of Branch-And-Bound And Nearest Neighbour Algorithms ". in 2020 International Conference in Mathematics, Computer Engineering and Computer Science (ICMCECS), Mars 2020. doi: [0.1109/ICMCECS47690.2020.240901](https://doi.org/0.1109/ICMCECS47690.2020.240901)
- 33 B. R., Bhowmik. "Dynamic Programming – Its Principals, Applications, Strengths, And Limitations ". *International Journal of Engineering Science and Technology* Vol. 2(9), p. 4822-4826, 2010.
- 34 A., Akate. "Application of Dynamic Programing in Agriculture, Economics and Computer Science", *International Journal of Sustainable Development Research*. Volume 6, Issue 4, pp. 49-54, 2020. doi: [10.11648/j.ijdsr.20200604.11](https://doi.org/10.11648/j.ijdsr.20200604.11)
- 35 R., Bellman. *Dynamic Programming*. Princeton University Press, Princeton, New Jersey, 1957.
- 36 F., Tardella. "The fundamental theorem of linear programming: extensions and applications", *Optimization*, Vol. 60, n° 1-2, pp. 283-301, 2011. doi: [10.1080/02331934.2010.506535](https://doi.org/10.1080/02331934.2010.506535)
- 37 G. B., Dantzig. *Linear programming and extensions*. Princeton University Press Princeton, 1963.
- 38 G. A., gorry, J. F., Shapiro, et L. Wolsey. "Relaxation Methods for Pure and Mixed Integer Programming Problems". *Management Science*, Vol 18, 1972. doi: [10.1287/mnsc.18.5.229](https://doi.org/10.1287/mnsc.18.5.229)

-
- 39 H., Marachand, A., Martin, R., Weismantel, et L. Wolsey. "Cutting planes in integer and mixed integer programming". *Discrete Applied Mathematics*, Vol. 123, Issues 1–3, p. 397-446, 2002. doi: [10.1016/S0166-218X\(01\)00348-1](https://doi.org/10.1016/S0166-218X(01)00348-1)
- 40 M., Lübbecke. "Column Generation", in *Wiley Encyclopedia of Operations Research and Management Science*, 2011. doi: [10.1002/9780470400531.eorms0158](https://doi.org/10.1002/9780470400531.eorms0158)
- 41 T., Wu, Z., Shi, Z., Liang, X., Zhang et C., Zhang. "Dantzig-Wolfe decomposition for the facility location and production planning problem". *Computers & Operations Research*, Vol. 124, n° 105068, 2020. doi: [10.1016/j.cor.2020.105068](https://doi.org/10.1016/j.cor.2020.105068)
- 42 Y. Mahmoudi, *Approche polyédrale étendue en optimisation combinatoire : Application au problème du p-médian*. Chisinau, Moldova: NOOR PUBLISHING, 2017.
- 43 A., Ghomari. "Métaheuristiques adaptatives d'optimisation continue basées sur des méthodes d'apprentissage". Thèse de Doctorat en Informatique, école doctorale de Mathématiques et STIC, Université Paris Est, 2018.
- 44 J-K., Hao et C., Solnon. "Méta-heuristiques et intelligence artificielle". In : Pierre Marquis, Odile Papini, Henri Prade. *Algorithmes pour l'intelligence artificielle*, Volume 2, Série Panorama de l'intelligence artificielle, Cépaduès, pp.1-19, 2014.
- 45 J., Kennedy et R.C., Eberhart. " Particle swarm optimization". In *Proceedings of the IEEE International Conference on Neural Networks*, IEEE Service Center, Piscataway, NJ, Vol. IV, pp. 1942–1948, 1995. doi: [10.1109/ICNN.1995.488968](https://doi.org/10.1109/ICNN.1995.488968)

-
- 46 J., Sun et al. " Convergence analysis and improvements of quantum-behaved particle swarm optimization ". *Inf. Sci.*, Vol. 193, pp. 81–103, 2012. doi: [10.1016/j.ins.2012.01.005](https://doi.org/10.1016/j.ins.2012.01.005)
- 47 K. R., Harrison, A. P., Engelbrecht, et M., Ombuki-Berman. " Optimal parameter regions and the time dependence of control parameter values for the particle swarm optimization algorithm ". *Swarm Evol. Comput.*, Vol. 41, pp. 20–35, 2018. doi: [10.1016/j.swevo.2018.01.006](https://doi.org/10.1016/j.swevo.2018.01.006)
- 48 M. S., Nobile et al. " Fuzzy self-tuning PSO: a settings-free algorithm for global optimization ". *Swarm Evol. Comput.*, Vol. 39, pp. 70–85, 2018. doi: [10.1016/j.swevo.2017.09.001](https://doi.org/10.1016/j.swevo.2017.09.001)
- 49 A. El Dor. "Perfectionnement des algorithmes d'optimisation par essaim particulaire : applications en segmentation d'images et en électronique". Thèse de Doctorat en Informatique, Université Paris-Est, Ecole Doctorale Mathématiques et STIC, Paris, France, 2012.
- 50 S. L., Tilahun et H. C., Ong. " Modified Firefly Algorithm". *Journal of Applied Mathematics*, Vol. 2012, n° 467631, 2012. doi: [10.1155/2012/467631](https://doi.org/10.1155/2012/467631)
- 51 H. Amrouche. " Sur l'hybridation des métaheuristiques ". Thèse de Master, Université Mouloud Mammeri, Tizi-Ouzou, Algérie, 2012.
- 52 S.I. Gass. *Précis de recherche opérationnelle : Méthodes et exercices d'application*. Dunod, Paris, 2014.
- 53 F. Glover. " Future paths for integer programming and links to artificial intelligence ". *Computers Operations research*, Vol. 13, pp. 533-549, 1986.
- 54 J.J. Grefenslette. " Incorporating problem specific knowledge into genetic algorithms ", in *genetic algorithms and simulated annealing*. Davis, L. D. (Ed.), 1987.

-
- 55 O., Kramer, H., Mühlenbein, et M., Gorges-Schleuter. " Evolution Algorithms in combinatorial optimization ". *Parallel computing*, Vol. tome 7, 1988.
- 56 H., Abdul-Hussian et al. " An Improved Energy-Efficient Clustering Protocol to Prolong the Lifetime of the WSN-Based IoT ". *IEEE ACCESS*, Vol. 8, pp. 200500-200517, 2020.
- 57 H., Mostafaei. " Energy-efficient algorithm for reliable routing of wireless sensor networks ". *IEEE Transactions on Industrial Electronics*, Vol. 66, n° 7, pp. 5567-5575, 2019.
- 58 L., Abbad et al. " A weighted Markov-clustering routing protocol for optimizing energy use in wireless sensor networks ". *Egyptian Informatics Journal*, 2022. doi: [10.1016/j.eij.2022.05.001](https://doi.org/10.1016/j.eij.2022.05.001)
- 59 P., Avella et A., Sassano. " On the p-median polytope ". *Mathematical Programming*, Vol. 89, pp. 395-411, 2001.
- 60 M., Baiou et F., Barahona. " On the P-median polytope of a special class of graphs ". Laboratoire d'Econométrie, CNRS et Ecole polytechnique, 2005.
- 61 W., Zhao et al. " Polyhedral structure of the k-median problem ". Dissertation, Presented in Partial Fulfillment of the Requirements for the Degree Doctor Of Philosophy in the Graduate School of The Ohio State University. The Ohio State University, 2007.
- 62 J., Reese. " Solution Methods for the p-median Problem : An annotated Bibliography ". *Networks*, Vol. 48, n° 3, pp. 125-142, 2006.
- 63 S., Garcia et al. " Solving large p-median problems with a radius formulation ". *INFORMS Journal on Computing*, Vol. 23, n° 4, pp. 546-556, 2011.

-
- 64 S., Elloumi. " A tighter formulation of the p-median problem ". *Journal of Combinational Optimization*, Vol. 19, pp. 69-83, 2010.
- 65 S., Elloumi et A., Plateau. " A computational study for the p-median problem ". *Electronic Notes in Discrete Mathematics*, Vol. 36, pp. 455-462, 2010.
- 66 N., Mladenovic et al. " The p-median problem: A survey of metaheuristic approaches ". *European Journal of Operational Research*, Vol. 179, n° 3, pp. 927-939, 2007.
- 67 S., Basu et al. " Metaheuristic applications on discrete facility location problems: a survey ". *OPSEARCH*, Vol. 52, n° 3, pp. 530-561, 2015.
- 68 D., César et al. " Chemical reaction optimization metaheuristic for locating service stations through the capacitated p-median problem ". *Pesquisa Operacional*, Vol. 38, pp. 441-478, 2018.
- 69 *MathWorks Help Center*. (2021). Retrieved from MathWorks: <https://fr.mathworks.com/help/optim/ug/mixed-integer-linear-programming-algorithms.html>
- 70 A., Panteli et B., Boutsinas. "Improvement of similarity-diversity trade-off in recommender systems based on a facility location model". *Neural Computing and Applications*, 2021.
- 71 P. W., Shor. Polynomial-Time Algorithms for Prime Factorization and Discrete Logarithms on a Quantum Computer. *SIAM Journal of Computing*, Vol. 26, no. 5, 1997. doi: <https://doi.org/10.1137/S009753979529317>
- 72 R. B., Griffiths. "*Consistent Quantum Theory*", Cambridge University Press, 2002.
- 73 D., McMahon. "*Quantum Computing Explained*", Wiley - IEEE, 2007.

-
- 74 J., Abhijith et al. "Quantum Algorithm Implementations for Beginners", *ACM Transactions on Quantum Computing*, Vol. 3, no. 4, pp. 1-92, 2022.
- 75 Qiskit, *Representing Qbit States*, <https://qiskit.org/textbook/ch-states/representing-Qbit-states.html> (Consulté le 22 février 2022)
- 76 L., Tisza. The Pauli Algebra. [https://math.libretexts.org/Bookshelves/Abstract_and_Geometric_Algebra/Applied_Geometric_Algebra_\(Tisza\)/02%3A_The_Lorentz_Group_and_the_Pauli_Algebra/2.04%3A_The_Pauli_Algebra](https://math.libretexts.org/Bookshelves/Abstract_and_Geometric_Algebra/Applied_Geometric_Algebra_(Tisza)/02%3A_The_Lorentz_Group_and_the_Pauli_Algebra/2.04%3A_The_Pauli_Algebra) (Consulté le 22 février 2022)
- 77 N. Zioui, Y. Mahmoudi, A. Mahmoudi, M. Tadjine et S. Bentouba. A new quantum-computing-based algorithm for robotic arms and rigid bodies'orientation. *Journal of Applied and Computational Mechanics*, Vol. 7, n° 3, pp. 1836-1846, 2021. doi: [10.22055/JACM.2021.37611.3048](https://doi.org/10.22055/JACM.2021.37611.3048)
- 78 Y. Mahmoudi, N. Zioui, H. Belbachir, M. Tadjine et A. Rezgui. A brief review of mathematical tools applicable to quantum computing for modeling and optimization problems in engineering. *Emerging Science Journal*, Vol. 7, n° 1, pp. 289-213, 2023. doi : [10.28991/ESJ-2023-07-01-020](https://doi.org/10.28991/ESJ-2023-07-01-020)
- 79 K-H, Han et J-H, Kim. "Quantum-inspired evolutionary algorithm for a class of combinatorial optimization". *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 6, pp. 580-593, 2002. doi: [10.1109/tevc.2002.804320](https://doi.org/10.1109/tevc.2002.804320)
- 80 W. P., Baritomba, D., Bulger, et G., Wood. "Grover's Quantum Algorithm Applied to Global Optimization", *SIAM Journal on Optimization*, Vol. 15, n° 4, pp. 1170-1184, 2005. doi: [10.1137/040605072](https://doi.org/10.1137/040605072)
- 81 Y., Liu et G. J., Koehler. "Using modifications to Grover's Search algorithm for quantum global optimization". *Journal of Global Optimization* vol.207, n° 2, pp. 620–632, 2010. doi: [10.1016/j.ejor.2010.05.039](https://doi.org/10.1016/j.ejor.2010.05.039)

-
- 82 L., Jiao, Y., Li, M., Gong, et X., Zhang. "Quantum-inspired immune clonal algorithm for global optimization". *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 38, n° 5, pp. 1234-1253, 2008. doi: [10.1109/tsmcb.2008.927271](https://doi.org/10.1109/tsmcb.2008.927271)
- 83 T., Zheng et M., Yamashiro. "Solving flow shop scheduling problems by quantum differential evolutionary algorithm". *The International Journal of Advanced Manufacturing Technology*, Vol. 49, pp. 643–662, 2010. doi: [10.1007/s00170-009-2438-4](https://doi.org/10.1007/s00170-009-2438-4)
- 84 Z., Zhisheng. "Quantum-behaved particle swarm optimization algorithm for economic load dispatch of power system". *Expert Syst. Appl.*, Vol 37, pp. 1800-1803, 2010. doi: [10.1016/j.eswa.2009.07.042](https://doi.org/10.1016/j.eswa.2009.07.042)
- 85 M. H., da Silva et R., Schirru. "Optimization of nuclear reactor core fuel reload using the new Quantum PBIL". *Annals of Nuclear Energy (Oxford)*, Vol. 38, n° 2-3, pp. 610-614, 2011. doi: [10.1016/j.anucene.2010.09.010](https://doi.org/10.1016/j.anucene.2010.09.010)
- 86 K., Karimi, et al. "Investigating the performance of an adiabatic quantum optimization processor". *Quantum Information Processing*, Vol. 11, pp. 77-88, 2012. doi: [10.1007/s11128-011-0235-0](https://doi.org/10.1007/s11128-011-0235-0)
- 87 A., Layeb. "A hybrid quantum inspired harmony search algorithm for 0-1 optimization". *Journal of Computational and Applied Mathematics*, Vol. 253, pp. 14-25, 2013. doi: [10.1016/j.cam.2013.04.004](https://doi.org/10.1016/j.cam.2013.04.004)
- 88 R., Shang, L., Jiao, Y., Ren, L., Li, et L., Wang. "Quantum immune clonal coevolutionary algorithm for dynamic multiobjective optimization". *Soft Computing*, Vol. 18, pp. 743-756, 2014. doi: [10.1007/s00500-013-1085-8](https://doi.org/10.1007/s00500-013-1085-8)

-
- 89 E., Farhi, J., Goldstone, et S., Gutmann. "A Quantum Approximate Optimization Algorithm". *arXiv:1411.4028v1*, 2014. doi: [10.18550/arXiv.1411.4028](https://doi.org/10.18550/arXiv.1411.4028)
- 90 E., Farhi, J., Goldstone, et S., Gutmann. "A Quantum Approximate Optimization Algorithm Applied to a Bounded Occurrence Constraint Problem". *arXiv:1412.6062v2*, 2015. doi: [10.48550/arXiv.1412.6062](https://doi.org/10.48550/arXiv.1412.6062)
- 91 D., Wecker, M. B., Hastings, et M., Troyer. "Training a quantum optimizer". *Phys. Rev. A*, Vol. 94, n° 022309, 2016. doi: [10.1103/PhysRevA.94.022309](https://doi.org/10.1103/PhysRevA.94.022309)
- 92 D., Zouache, F., Nouioua, et A., Moussaoui. "Quantum-inspired firefly algorithm with particle swarm optimization for discrete optimization problems. *Soft Computing*, Vol.20, n° 7, pp. 2781-2799, 2016. doi: [10.1007/s00500-015-1681-x](https://doi.org/10.1007/s00500-015-1681-x)
- 93 I., Hen et F. M., Spedalieri. "Quantum Annealing for Constrained Optimization". *Physical Review Applied*, Vol. 5, n° 3, id 034007, 2016. doi: [10.1103/PhysRevApplied.5.034007](https://doi.org/10.1103/PhysRevApplied.5.034007)
- 94 M., Ranjbar, W. G., Macready, L., Clark, et F., Gaitan. "Generalized Ramsey numbers through adiabatic quantum optimization". *Quantum Information Processing*, Vol. 15, n° 9, pp. 3519-3542, 2016. doi: [10.1007/s11128-016-1363-3](https://doi.org/10.1007/s11128-016-1363-3)
- 95 P., Palittapongarnpim, P., Wittek, E., Zahedinejad, S., Vedaie, et B. C., Sanders. "Learning in quantum control: High-dimensional global optimization for noisy quantum dynamics". *Neurocomputing*, Vol. 268, pp. 116-126, 2017. doi: [10.1016/j.neucom.2016.12.087](https://doi.org/10.1016/j.neucom.2016.12.087)
- 96 C. L., Chiang. "Quantum-behaved Particle Swarm Optimization for Power Economic Dispatch Problem of Units with Multiple Fuel Option". *European Journal of Engineering and Technology Research*, Vol. 2, n° 12, pp. 11-16, 2017. doi: [10.24018/ejeng.2017.2.12.492](https://doi.org/10.24018/ejeng.2017.2.12.492)

-
- 97 A., Kaur, S., Kaur, et G., Dhiman. "A quantum method for dynamic nonlinear programming technique using Schrödinger equation and Monte Carlo approach". *Modern Physics Letters B*, Vol 32, n° 30, id 1850374, 2018. doi: [10.1142/S0217984918503748](https://doi.org/10.1142/S0217984918503748)
- 98 G. I., Sayed, A., Darwish, et A., Hassanién. "Quantum multiverse optimization algorithm for optimization problems". *Neural Computing and Applications*, Vol. 31, n° 7, pp. 2763-2780, 2019. doi: [10.1007/s00521-017-3228-9](https://doi.org/10.1007/s00521-017-3228-9)
- 99 C., Shao. "Fast variational quantum algorithms for training neural networks and solving convex optimizations". *Physical Review A*, Vol. 99, n° 4, id 042325, 2019. doi: [10.1103/PhysRevA.99.042325](https://doi.org/10.1103/PhysRevA.99.042325)
- 100 A., Ajagekar et F., You. "Quantum computing for energy systems optimization: Challenges and opportunities". *Energy*, Vol. 179, pp. 76-89, 2019. doi: [10.1016/j.energy.2019.04.186](https://doi.org/10.1016/j.energy.2019.04.186)
- 101 E., Greplova. "Solving optimization tasks in condensed matter". *Nature Machine Intelligence*, Vol. 2, n° 10, pp. 557-558, 2020. doi: [10.1038/s42256-020-00240-8](https://doi.org/10.1038/s42256-020-00240-8)
- 102 J., van Apeldoorn, A., Gilyen, S., Gribling, et R., de Wolf. "Convex optimization using quantum oracles". *Quantum*, Vol. 4, id 220, 2020. doi: [10.22331/q-2020-01-13-220](https://doi.org/10.22331/q-2020-01-13-220)
- 103 L., Gao, et al. "An Advanced Quantum Optimization Algorithm for Robot Path Planning. Journal of Circuits". *Systems and Computers*, Vol. 29, n° 08, id 2050122, 2020. doi: [10.1142/s0218126620501224](https://doi.org/10.1142/s0218126620501224)
- 104 C-M, Alexandru, et al. "Quantum speedups of some general-purpose numerical optimisation algorithms". *Quantum Science and Technology*, Vol. 5, n° 4, id 045014, 2020. doi: [10.1088/2058-9565/abb003](https://doi.org/10.1088/2058-9565/abb003)

-
- 105 A., Kaveh, M., Kamalinejad, et H., Arzani. "Quantum evolutionary algorithm hybridized with Enhanced colliding bodies for optimization". *Structures*, Vol. 28. Elsevier, pp. 1479-1501, 2020. doi: [10.1016/j.istruc.2020.09.079](https://doi.org/10.1016/j.istruc.2020.09.079)
- 106 D., Tang, Z., Liu, J., Zhao, S., Dong, et Y., Cai. "Memetic quantum evolution algorithm for global optimization". *Neural Computing and Applications*, Vol. 32. 13, pp. 9299-9329, 2021. doi: [10.1007/s00521-019-04439-8](https://doi.org/10.1007/s00521-019-04439-8)
- 107 S., El Gaily et S., Imre. "Constrained Quantum Optimization Algorithm". *20th International Symposium INFOTEH-JAHORINA (INFOTEH)*, IEEE, 2021. doi: [10.1109/infoteh51037.2021.9400679](https://doi.org/10.1109/infoteh51037.2021.9400679)
- 108 A., Tamoor et al. "Quantum beetle antennae search: a novel technique for the constrained portfolio optimization problem". *Science China Information Sciences*, Vol 64, n° 5, pp. 1-14, 2021. doi: [10.1007/s11432-020-2894-9](https://doi.org/10.1007/s11432-020-2894-9)
- 109 R. H., Warren. "A BENCHMARK FOR QUANTUM OPTIMIZATION: THE TRAVELING SALESMAN PROBLEM". *QUANTUM INFORMATION & COMPUTATION*, Vol. 21, n° 7-8, pp. 557-562, 2021. doi: [10.26421/QIC21.7-8-2](https://doi.org/10.26421/QIC21.7-8-2)
- 110 Y., Wang et W., Wang. "Quantum-Inspired Differential Evolution with Grey Wolf Optimizer for 0-1 Knapsack Problem". *Mathematics*, Vol. 9, n° 11, id 1233, 2021. doi: [10.3390/math9111233](https://doi.org/10.3390/math9111233)
- 111 S., Hadfield, et al. "From the Quantum Approximate Optimization Algorithm to a Quantum Alternating Operator Ansatz". *Algorithms*, Vol. 12, id 34, 2019. doi: [10.3390/a12020034](https://doi.org/10.3390/a12020034)
- 112 G., Pagano, et al. "Quantum approximate optimization of the long-range Ising model with a trapped-ion quantum simulator". *Proceedings of the National Academy of Sciences*, vol. 117, pp. 25396-25401, 2020. doi: [10.1073/pnas.2006373117](https://doi.org/10.1073/pnas.2006373117)

-
- 113 L., Li, M., Fan, M., Coram, P., Riley, et S., Leichenauer. "Quantum optimization with a novel Gibbs objective function and ansatz architecture search". *Physical Review Research*, Vol. 2, id 023074, 2020. doi: [10.1103/physrevresearch.2.023074](https://doi.org/10.1103/physrevresearch.2.023074)
- 114 D. J., Egger, J., Marecek, et S., Woern. "Warm-starting quantum optimization". *Quantum*, Vol. 5, pp. 479-499, 2021. doi: [10.22331/q-2021-06-17-479](https://doi.org/10.22331/q-2021-06-17-479)
- 115 M. P., Harrigan, et al. "Quantum approximate optimization of non-planar graph problems on a planar superconducting processor". *Nat. Phys*, Vol. 17, pp. 332–336, 2021. doi: [10.1038/s41567-020-01105-y](https://doi.org/10.1038/s41567-020-01105-y)
- 116 A. B., Finnila, M. A., Gomez, C., Sebenik, C., Stenson, et J. D., Doll. "Quantum Annealing: A New Method for Minimizing Multidimensional Functions". *Chem. Phys. Lett*, Vol. 219, n° 5-6, pp. 343-348, 1993. doi: [10.1016/0009-2614\(94\)00117-0](https://doi.org/10.1016/0009-2614(94)00117-0)
- 117 R., Biswas, et al. "A NASA perspective on quantum computing: Opportunities and challenges". *Parallel Computing*, pp. 81-98, 2017. doi: [10.1016/j.parco.2016.11.002](https://doi.org/10.1016/j.parco.2016.11.002)
- 118 M., Sao, H., Watanabe, Y., Mush, et A., Utsunomiya. "Application of Digital Annealer for Faster Combinatorial Optimization". *Fujitsu Scientific and Technical Journal*, Vol. 55, pp. 45-51, 2019.
- 119 T., Vyskocil et H., Djidjev. "Embedding Equality Constraints of Optimization Problems into a Quantum Annealer". *Algorithms*, Vol. 12, id 77, 2019. doi: [10.3390/a12040077](https://doi.org/10.3390/a12040077)
- 120 M., Ohzeki. "Breaking limitation of quantum annealer in solving optimization problems under constraints". *Sci Rep*, Vol.10, id 3126, 2020. doi: [10.1038/s41598-020-60022-5](https://doi.org/10.1038/s41598-020-60022-5)

-
- 121 S., Abel, A., Blance, et M., Spannowsky. "Quantum Optimisation of Complex Systems with a Quantum Annealer". *arXiv preprint arXiv:2105*, id 13945, 2021. doi: [10.48550/arXiv.2105.13945](https://doi.org/10.48550/arXiv.2105.13945)
- 122 Z., Gonzalez, I. I., Hen, et T., Albash. "Testing a Quantum Annealer as a Quantum Thermal Sampler". *ACM Transactions on Quantum Computing*, Vol. 2, n° 2, pp. 1-20, 2021. doi: [10.1145/3464456](https://doi.org/10.1145/3464456)
- 123 XS. Yang. "Firefly algorithm". In: *Nature-inspired metaheuristic algorithms*, chapter 8. Luniver Press, Bristol. 2008.
- 124 N. Zioui et al. "A novel quantum-computing-based quaternions model for robotic arm position". *International Journal of Computational Intelligence in Control*. Vol. 12, n° 2, pp. 1-4, 2021.
- 125 M. Fazilat et al. "A novel quantum model of forward kinematics based on quaternion/Pauli gate equivalence: Application to a six-jointed industrial robotic arm". *Results in Engineering*, Volume 14, 2022.
- 126 Y. Sung, S. Lee et M. Lee. "A multi-hop clustering mechanism for scalable IoT networks". *Sensors*, Vol. 18, no. 4, 961, 2018. doi: [10.3390/s18040961](https://doi.org/10.3390/s18040961)
- 127 Y. Sung, S. Lee et M. Lee. "A multi-hop clustering mechanism for scalable IoT networks". *Sensors*, Vol. 18, no. 4, 961, 2018. doi: [10.3390/s18040961](https://doi.org/10.3390/s18040961)
- 128 N. Zioui, A. Mahmoudi, Y. Mahmoudi, et M. Tadjine. Quantum computing based state domain equations and feedback control. *Results in Applied Mathematics*, Volume 19, 2023. doi: [10.1016/j.rinam.2023.100385](https://doi.org/10.1016/j.rinam.2023.100385)
- 129 A. Mahmoudi, Y. Mahmoudi, K. Benatchba, A. Rezgui, et N. Zioui. Towards Optimal Frequency Plans a Survey of Frequency Assignment Strategies, Models and Methods, 2023. Disponible sur SSRN: <https://ssrn.com/abstract=4535493> or <http://dx.doi.org/10.2139/ssrn.4535493>

-
- 130 M.E.A. Boudjoghra, S.A.S. Daimellah, N. Zioui, Y. Mahmoudi, et M. Tadjine. State-domain equations and their quantum computing solution based HHL algorithm. *Mathematical Modelling of Engineering Problems*, Vol. 9, No. 4, pp. 879-886, 2022. doi: [10.18280/mmep.090404](https://doi.org/10.18280/mmep.090404)
- 131 N. Zioui, Y. Mahmoudi, A. Mahmoudi, M. Tadjine, et S. Bentouba. A novel quantum-computing-based quaternions model for a robotic arm position. *International Journal of Computational Intelligence in Control* 13(2), pp.71-77, 2021. <https://www.mukpublications.com/resources/ijcic%20v13-2-9.pdf>
- 132 N. Zioui, A. Mahmoudi, Y. Mahmoudi, et A. Rezgui. A comparative study of performances between the sliding modes and the trust control strategies for an articulated robotic arm position control. *International Journal of Mechanical & Mechatronics Engineering*, Vol 21(1), 2021. doi: [10.22055/jacm.2021.37611.3048](https://doi.org/10.22055/jacm.2021.37611.3048)
- 133 Y. Mahmoudi, N. Zioui, H. Belbachir et H. Dagdougui. P-median based modelling-based optimization of energy consumption in smart wireless sensors networks in Internet of Things applications. *Operational Research in Engineering Sciences: Theory and Applications*, Vol. 66, Issue 1, 2023.
- 134 Y. Mahmoudi, N. Zioui, et H. Belbachir. A new quantum-inspired clustering method for reducing energy consumption in IoT networks. *Internet of Things*, Vol, 20, 2022. doi: [10.1016/j.iot.2022.100622](https://doi.org/10.1016/j.iot.2022.100622)
- 135 Y. Mahmoudi, N. Zioui, et H. Belbachir. Comparison between conventional and quantum based p-median optimisation for energy consumption in IoT networks. *9th International Conference on engineering and Emerging Technologies (ICEET2023)*, 27 -28 October 2023, Istanbul -Turkey.
- 136 Y. Mahmoudi, N. Zioui et H. Belbachir, "Quantum Optimization in Engineering: A Brief Review," *2023 International Conference on Decision Aid Sciences and*

Applications (DASA), Annaba, Algeria, 2023, pp. 23-27, doi:
[10.1109/DASA59624.2023.10286779](https://doi.org/10.1109/DASA59624.2023.10286779)