

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE DU 20 AOUT 1955 SKIKDA

Faculté de Technologie
Département : Génie Electrique



Thèse

En vue de l'obtention du diplôme de :

Doctorat LMD

Spécialité : AUTOMATIQUE

Thème

**Algorithmes bio-inspirés appliqués pour la commande
des systèmes**

Par : **Rochdi BOUCHEBBAT**

Soutenu Le : 21/05/2017 Devant Le Jury:

| | | | |
|------------|---------------------|-----|----------------------|
| Président | LACHOURI Abderrazek | Pr | Université de Skikda |
| Rapporteur | GHERBI Sofiane | MCA | Université de Skikda |
| Examineur | BOUDEN Toufik | Pr | Université de Jijel |
| | RAMDANI Messaoud | Pr | Université de Annaba |
| | AHMIDA Zahir | MCA | Université de Skikda |
| | MEHENAOUI Lamine | MCA | Université de Skikda |

Code : **D012117005D**

À ma famille

Remerciements

Je remercie ALLAH le tout puissant pour la volonté et la patience qu'il m'a donné tout au long de mes études.

Je tiens à remercier particulièrement Monsieur Sofiane GHERBI, Maître de conférence à l'université de Skikda pour la proposition du sujet de cette thèse et pour son soutien tout au long de ce travail. Merci Monsieur pour vos conseils et la confiance que vous m'avez accordé au cours de ces années d'encadrement.

Je tiens à remercier chaleureusement, Monsieur Abderazek LACHOURI, Professeur à l'université de Skikda, d'avoir accepté la présidence du jury de ma soutenance, ainsi que Messieurs Toufik BOUDEN, Professeur à l'université de Jijel, Messaoud RAMDANI, Professeur à l'université de Annaba, Lamine MEHENNAOUI Maître de conférence à l'université de Skikda et Zahir AHMIDA Maître de conférence à l'université de Skikda, qui ont accepté d'examiner mon manuscrit de thèse.

Je remercie le laboratoire d'Automatique à l'université de Skikda pour le stimulant cadre intellectuel qu'il m'a offert tout au long de mon Doctorat.

J'adresse un grand merci à mes amis et collègues Abderahmane GANOUCHE, Adel MAKHBOUCHE, et à tous ceux qui m'ont aidé de près ou de loin durant ces années de recherche et d'études.

À tous mes enseignants tout le long de ma formation à l'université de Skikda.

R. Bouchebbat ...

ملخص – لطالما كان تأمل الظواهر الطبيعية مصدر إلهام للبشر، في الواقع، الطبيعة دائما ما تجد الحلول المثلى لبقائها. في هذا السياق، نشهد هذه الأيام اتجاه قوي نحو استخدام النظم المستوحاة من البيولوجيا في جميع المجالات. هذه الأطروحة هي توليفة من مختلف الخوارزميات المستوحاة من البيولوجيا، واحتمال استخدامها في مجال الآلية. كل من هذه الخوارزميات، وفقا لخصوصيتها، تساهم بشكل كبير سواءا في التحكم في الأنظمة او في الاستمثال. في الواقع، تصميم وحدة تحكم مستوحاة من نظام المناعة يمكن أن يزيد إلى حد كبير على قوة حلقة التحكم، و استخدام الشبكات العصبية المستوحاة من الدماغ البشري توفر القدرة على التكيف والقدرة على التعلم. من جهة اخرى، العثور على الحلول المثلى يتم عبر خوارزميات التحسين المستوحاة من الطبيعة مثل الخوارزميات الوراثةية او الخورزميات الاستثنائية لعناصر السرب أو لمستعمرات النمل. تطبيق هذه الخوارزميات للتحكم على الأنظمة الخاضعة لقيود مختلفة، أظهر مساهمة معتبرة.

كلمات مفتاحية - أنظمة مستوحاة بيولوجيا، الاستمثال، التحكم في الأنظمة

Résumé - L'observation des phénomènes naturels a toujours été une source d'inspiration pour l'être humain. En effet, la nature trouve toujours des solutions optimales pour sa survie. Dans ce cadre, on assiste ces derniers temps à une forte tendance vers l'utilisation des systèmes bio-inspirés dans tous les domaines. Dans cette thèse, on fait une synthèse des différents algorithmes bio-inspirés récents, et leur potentielle exploitation dans le domaine de l'automatique. Chacun de ces algorithmes, selon sa spécificité, apporte une contribution non négligeable sous à la commande des systèmes soit à l'optimisation. En effet, un contrôleur inspiré du système immunitaire peut augmenter de façon substantielle la robustesse d'une boucle de commande. Les réseaux de neurones inspirés du fonctionnement du cerveau humain, apportent leur adaptabilité et leur capacité d'apprentissage. Des solutions optimales sont trouvées par des algorithmes d'optimisation tels que l'algorithme génétique, l'optimisation par les essaims particulaires ou par les colonies de fourmis. L'application de ces algorithmes bio-inspirés pour la commande de systèmes particuliers, soumis à diverses contraintes, montre un apport certain.

Mots-clés - systèmes bio-inspirés, optimisation, commande des systèmes.

Abstract - The observation of natural phenomena has always been a source of inspiration for the human being; in fact, nature always finds optimal solutions for its survival. In this context, there has recently been a strong trend towards the use of bio-inspired systems in all fields. In this thesis, we synthesize the various recent bio-inspired algorithms, and their potential use in the field of automation. Each of these algorithms, according to its specificity, makes a significant contribution to the control of systems and to optimization. Indeed, a controller inspired by the immune system can substantially increase the robustness of a control loop, neural networks inspired by the functioning of the human brain; bring their adaptability and their ability to learn. Optimal solutions can be found by bio-inspired optimization algorithms such as genetic algorithm, optimization by particulate swarms or ant colonies. The application of these bio-inspired algorithms for the control of particular systems, subjected to various constraints, shows a certain contribution.

Keywords - Bio-inspired systems, optimization, control systems.

Table des matières

| | |
|--|-----------|
| Introduction générale | 1 |
| I Généralités sur les systèmes bio-inspirés | 6 |
| I.1 Introduction | 6 |
| I.2 Systèmes bio-inspirés pour la commande | 7 |
| I.2.1 Le système immunitaire artificiel | 7 |
| I.2.1.1 Le système immunitaire biologique | 8 |
| I.2.1.2 Principales caractéristiques | 10 |
| I.2.1.3 Principales théories immunitaires | 10 |
| I.2.1.4 Les algorithmes immunitaires artificiels | 11 |
| I.2.2 Le système neuronal artificiel | 14 |
| I.2.2.1 Le neurone biologique | 14 |
| I.2.2.2 Le neurone artificiel | 15 |
| I.2.2.3 Règles d'apprentissage du réseau neuronal artificiel | 17 |
| I.2.2.4 Architecture du réseau neuronal artificiel | 18 |
| I.3 Algorithmes d'optimisation bio-inspirés | 21 |
| I.3.1 Les algorithmes évolutionnaires | 21 |
| I.3.1.1 L'algorithme génétique | 22 |
| I.3.1.2 La programmation génétique | 23 |
| I.3.1.3 La programmation évolutionnaire | 25 |
| I.3.2 Les algorithmes à base de l'intelligence distribuée | 26 |
| I.3.2.1 L'algorithme d'optimisation par essaims particuliers | 27 |
| I.3.2.2 L'algorithme d'optimisation "colonies de fourmis" | 35 |
| I.4 Conclusion | 38 |
| II Conception d'une loi de commande robuste inspirée par le système immunitaire | 39 |
| II.1 Introduction | 39 |
| II.2 La commande robuste | 39 |
| II.3 Conception d'une loi de commande robuste inspirée du système immunitaire | 41 |
| II.3.1 Mécanisme de la rétroaction immunitaire | 41 |
| II.3.2 Modélisation de la loi de rétroaction immunitaire | 42 |

| | |
|---|-----------|
| II.3.3 Conception du contrôleur IMF-PID | 44 |
| II.3.3.1 Loi de commande du contrôleur IMF-PID | 45 |
| II.3.3.2 Choix de la fonction $f(x)$ | 46 |
| II.4 Réglage optimale des paramètres du contrôleur IMF-PID flou | 48 |
| II.4.1 Première phase | 49 |
| II.4.2 Deuxième phase | 49 |
| II.5 Exemple d'application | 50 |
| II.5.1 Méthode d'optimisation à base d'algorithmes de recherche bio-inspirés | 50 |
| II.5.1.1 L'optimisation par PSO | 51 |
| II.5.1.2 L'optimisation par ACO | 52 |
| II.5.2 Méthode d'optimisation directe de type simplex (Méthode de Nelder Mead)..... | 53 |
| II.6 Simulations, résultats et commentaires | 56 |
| II.7 Conclusion | 59 |
| III Conception d'un contrôleur auto-adaptatif bio-inspiré pour la commande des systèmes sous réseau | 60 |
| III.1 Introduction | 60 |
| III.2 Les systèmes commandés sous réseau (NCS) | 60 |
| III.2.1 Les problèmes fondamentaux des NCSs..... | 62 |
| III.2.1.1 La variance du temps de transmission..... | 62 |
| III.2.1.2 Le retard induit par le réseau | 63 |
| III.2.1.3 Les Abandons de paquets | 64 |
| III.2.2 Simulation des NCSs par TrueTime | 65 |
| III.2.2.1 Le Bloc noyau TrueTime | 66 |
| III.2.2.2 Le bloc réseau TrueTime..... | 67 |
| III.2.2.3 Les Blocs TrueTime du réseau autonome | 67 |
| III.2.2.4 Exemple 1 (architecture noyau) | 68 |
| III.2.2.5 Exemple 2 (architecture autonome) | 69 |
| III.3 Conception d'un contrôleur PID auto-adaptatif à neurone unique pour la commande des systèmes sous réseau..... | 70 |
| III.3.1 Modèle du NCS considéré | 70 |
| III.3.2 Caractéristiques du réseau..... | 70 |
| III.3.3 Le contrôleur PID à neurone unique avec réglage immunitaire | 71 |
| III.3.3.1 L'algorithme de commande d'un PID à neurone unique | 71 |
| III.3.3.2 Le réglage immunitaire | 73 |

| | |
|--|------------|
| III.3.4 Application de l'approche proposée sur un NCS..... | 74 |
| III.4 Conclusion | 77 |
| IV Commande et gestion d'une centrale hybride photovoltaïque-éolien-diesel par l'algorithme d'optimisation génétique..... | 78 |
| IV.1 Introduction | 78 |
| IV.2 Les centrales hybrides autonomes à énergies renouvelables..... | 79 |
| IV.3 Architecture du CHAER | 79 |
| IV.4 Dimensionnement du CHAER | 81 |
| IV.5 Modélisation du CHAER | 83 |
| IV.5.1 Modèle du panneau photovoltaïque..... | 83 |
| IV.5.2 Modélisation du générateur éolien..... | 85 |
| IV.5.3 Modèle de la batterie d'accumulateur..... | 87 |
| IV.5.4 Modèle du groupe électrogène..... | 90 |
| IV.6 Gestion énergétique du CHAER | 90 |
| IV.6.1 Gestion du stockage | 91 |
| IV.6.2 Gestion des charges | 92 |
| IV.6.3 L'approche de planification énergétique proposée..... | 93 |
| IV.7 Conception d'un schéma de commande et réglage optimal du CHAER | 95 |
| IV.7.1 Boucle de commande avec contrôleur PID MPPT pour le système PV | 96 |
| IV.7.2 Boucle de commande avec contrôleur PI pour l'éolienne..... | 96 |
| IV.7.3 Réglage optimal des paramètres des contrôleurs du CHAER | 97 |
| IV.7.4 Résolution du problème de minimisation multiobjective..... | 98 |
| IV.8 Application de l'approche proposée..... | 100 |
| IV.8.1 Etude comparative de l'approche proposée par rapport aux méthodes classiques | 103 |
| IV.8.2 Résultats de la simulation | 104 |
| IV.9 Conclusion..... | 109 |
| Conclusion générale | 110 |
| Bibliographie..... | 113 |

Tables des figures

| | | |
|---------------|--|----|
| Figure I.1. | L'approche conceptuelle pour dériver des algorithmes bio-inspirés | 7 |
| Figure I.2. | Représentation graphique du mécanisme du système immunitaire..... | 9 |
| Figure I.3. | L'approche de la construction des solutions AIS..... | 13 |
| Figure I.4. | Le neurone biologique simplifié..... | 15 |
| Figure I.5. | Un neurone artificiel basique..... | 16 |
| Figure I.6. | Architecture d'un neurone artificiel | 17 |
| Figure I.7. | Architecture d'un réseau neuronal artificiel..... | 18 |
| Figure I.8. | Architecture d'un réseau neuronal monocouche..... | 19 |
| Figure I.9. | Architecture d'un réseau neuronal multicouche | 20 |
| Figure I.10. | Architecture d'un réseau neuronal récurrent..... | 21 |
| Figure I.11. | Diagramme d'un algorithme génétique..... | 23 |
| Figure I.12. | Algorithme de la programmation génétique..... | 25 |
| Figure I.13. | Algorithme de la programmation évolutionnaire | 26 |
| Figure I.14. | Algorithme gbest PSO | 30 |
| Figure I.15. | Algorithme lbest PSO..... | 31 |
| Figure I.16. | Mise à jour de la vitesse et la position d'une particule dans un espace de recherche bidimensionnel..... | 34 |
| Figure I.17. | Mise à jour de la vitesse et la position des multi-particules dans gbest PSO..... | 34 |
| Figure I.18. | Mise à jour de la vitesse et la position des multi-particules dans lbest PSO..... | 35 |
| Figure I.19. | Etapes de la recherche de nourriture par une colonie de fourmis..... | 36 |
| Figure II.1. | Schéma du système de régulation immunitaire..... | 42 |
| Figure II.2. | La forme de $f(x)$ pour différentes valeurs de a | 43 |
| Figure II.3. | Schéma bloc de la boucle de rétroaction immunitaire | 44 |
| Figure II.4. | Système commandé en boucle fermée | 44 |
| Figure II.5. | Schéma du contrôleur IMF-PID | 46 |
| Figure II.6. | Modèle flou de la fonction f | 46 |
| Figure II.7. | Les fonctions d'appartenance d'entrée | 47 |
| Figure II.8. | Les fonctions d'appartenance de sortie..... | 48 |
| Figure II.9. | Schéma bloc du contrôleur immunitaire PID flou | 48 |
| Figure II.10. | Schéma bloc de la première phase | 49 |

| | |
|---|----|
| Figure II.11. Schéma bloc de la deuxième phase | 50 |
| Figure II.12. Tous les points utilisés pour la méthode Nelder Mead | 55 |
| Figure II.13. Dynamiques de minimisation du cout par les différentes méthodes..... | 56 |
| Figure II.14. Dynamiques d'optimisation du paramètre K_p par les différentes méthodes..... | 57 |
| Figure II.15. Dynamiques d'optimisation du paramètre K_i par les différentes méthodes | 57 |
| Figure II.16. Dynamiques d'optimisation du paramètre K_d par les différentes méthodes..... | 57 |
| Figure II.17. Dynamiques d'optimisation du paramètre n par les différentes méthodes | 58 |
| Figure II.18. Réponses indicielles du système commandé par IMF-PID flou | 58 |
| Figure II.19. Rejets des perturbations | 58 |
| Figure II.20. Réponses indicielles du système ayant subi une variation de 15% de ses paramètres..... | 59 |
| Figure III.1. Schema bloc d'un systeme commandé par réseau | 61 |
| Figure III.2. Schéma temporel de deux noeuds sur un réseau d'accès aléatoire | 62 |
| Figure III.3. Retards éventuels induits par le réseau sur un système de commande aléatoire | 64 |
| Figure III.4. La bibliothèque de blocs TrueTime 2.0 | 65 |
| Figure III.5. Boîte de dialogue du bloc noyau..... | 66 |
| Figure III.6. Boîte de dialogue du bloc réseau | 67 |
| Figure III.7. Boîte de dialogue des blocs TrueTime du réseau | 68 |
| Figure III.8. L'architecture noyau d'un NCS à l'aide de Truetime..... | 69 |
| Figure III.9. Truetime L'architecture autonome d'un NCS à l'aide de Truetime | 69 |
| Figure III.10. Boucle de commande sous réseau | 70 |
| Figure III.11. Des NCSs sur un réseau Ethernet | 71 |
| Figure III.12. La structure du régulateur PID à neurone unique | 72 |
| Figure III.13. Structure de la commande PID à neurone unique avec réglage immunitaire ... | 73 |
| Figure III.14. Le modèle de simulation du système commandé sous réseau par le controleur PID à neurone unique avec réglage immunitaire à base du simulateur TrueTime..... | 74 |
| Figure III.15. Réponse du système à un signal de référence à onde carrée..... | 75 |
| Figure III.16. Signal de commande | 75 |
| Figure III.17. Ordonnancement des tâches de contrôle sous Ethernet | 75 |
| Figure III.18. Réponse du système avec différents retards de phase | 76 |
| Figure III.19. Réponse du système avec différents propabilité de perte | 76 |
| Figure III.20. Réponse du système avec différents protocoles de communication..... | 77 |
| Figure IV.1. Structure d'une CHAER..... | 80 |

| | | |
|---------------|---|-----|
| Figure IV.2. | Architecture commutée d'une CHAER | 81 |
| Figure IV.3. | Schéma de connexion d'un module PV..... | 83 |
| Figure IV.4. | Schéma électrique équivalent d'une cellule photovoltaïque..... | 83 |
| Figure IV.5. | Éléments constitutifs d'une éolienne..... | 85 |
| Figure IV.6. | Schéma électrique équivalent d'une cellule de la batterie plomb-acide..... | 88 |
| Figure IV.7. | Courbe de variations du courant et du DOD de la batterie..... | 89 |
| Figure IV.8. | Diagramme de gestion des priorités des charges..... | 92 |
| Figure IV.9. | Schéma UML de planification énergétique d'une CHAER | 93 |
| Figure IV.10. | Organigramme de planification énergétique du CHAER..... | 94 |
| Figure IV.11. | Schéma bloc de la stratégie de commande proposée..... | 95 |
| Figure IV.12. | Schéma synoptique de la Structure de commande MPPT PID du générateur PV | 96 |
| Figure IV.13. | Structure de commande PI de l'éolienne..... | 97 |
| Figure IV.14. | Valeurs moyennes journalières pendant une période d'une année de conditions météorologiques: a) température ambiante, b) rayonnement solaire et c) vitesse du vent..... | 101 |
| Figure IV.15. | Schéma de simulation sous Matlab/Simulink du CHAER | 104 |
| Figure IV.16. | Variation de la puissance totale générée..... | 105 |
| Figure IV.17. | Variation des puissances de charge et de décharge de la batterie..... | 105 |
| Figure IV.18. | Variation de la puissance produite par le générateur diesel | 106 |
| Figure IV.19. | Profils des puissances mises en jeu | 107 |
| Figure IV.20. | Variation de la puissance demandée et la puissance produite du système hybride..... | 108 |
| Figure IV.21. | Répartition de la puissance consommée | 108 |

Liste des tableaux

| | |
|---|-----|
| Tableau I.1. Paradigmes du calcul évolutionnaire | 22 |
| Tableau II.1. Réactions immunitaires des cellules T..... | 43 |
| Tableau II.2. Analogie entre le système immunitaire artificielle et une boucle de commande | 45 |
| Tableau II.3. Les règles floues de la fonction $f(x)$ | 47 |
| Tableau II.5. Paramètres de l'algorithm PSO | 52 |
| Tableau II.6. Paramètres de l'algorithm ACO..... | 53 |
| Tableau II.7. Paramètres du PID IMF flou avec les différents algorithmes..... | 53 |
| Tableau IV.1. Synthèse des outils de dimensionnement des CHAER..... | 82 |
| Tableau IV.2. Paramètres de GA | 100 |
| Tableau IV.3. Données de la consommation électrique de la ferme..... | 100 |
| Tableau IV.4. Caractéristiques techniques des générateurs | 102 |
| Tableau IV.5. Configuration choisie du système hybride | 103 |
| Tableau IV.6. Analyse des systèmes complémentaires..... | 107 |

Introduction générale

Allah a créé la nature et l'a doté d'une formidable capacité d'adaptabilité et de survie face à diverses situations complexes, en effet, elle trouve toujours une solution optimale pour sa perpétuation, quel que soit le problème qu'elle doit résoudre et les défis qui lui sont posés. Cela a depuis toujours inspiré l'être humain pour résoudre les différents problèmes auxquels il fait face dans sa vie quotidienne.

Aujourd'hui, le calcul inspiré par la biologie "bio-inspired computing" représente une nouvelle ère pour l'ingénierie. Il englobe un large éventail d'algorithmes couvrant la plupart des domaines tels que les réseaux informatiques, la sécurité industrielle, la robotique, l'électronique biomédical, les systèmes de commande...etc. Le terme algorithme fait référence à une procédure pour résoudre un problème donné, ce dernier peut avoir des caractéristiques et des structures différentes. Dans le cas où le problème est bien compris, des algorithmes spécifiques peuvent être conçus pour atteindre des solutions performantes (optimales) pour le problème considéré, dans ce contexte, les algorithmes bio-inspirés constituent une alternative sérieuse aux méthodes classiques.

Dans le domaine de l'automatique, on assiste ces dernières années à l'émergence d'une multitude d'algorithmes, de méthodes et de techniques bio-inspirées appliquées dans divers domaines. La recherche dans ce domaine n'en est encore qu'à ces débuts, et elle est en pleine expansion.

Dans cette thèse, on se propose de présenter les techniques bio-inspirées les plus récentes dans le domaine de l'automatique, et plus spécialement dans la commande des systèmes. Nous essaierons d'utiliser les nombreux avantages qu'elles peuvent apporter en termes de robustesse, adaptabilité et optimisation, pour répondre aux nombreux défis que pose la commande de systèmes spécifiques comme : l'adaptabilité aux divers changements du système, l'exigence de la robustesse face aux perturbations et incertitudes agissantes sur la boucle de commande, les performances de plus en plus pointues requises par les cahiers de charges.

Par exemple, le système immunitaire a inspiré une loi de commande appelée IMF "Immune Feedback", cette loi tire parti du grand potentiel d'adaptabilité et de la robustesse inné du système immunitaire naturel face aux divers germes et microbes, ces derniers peuvent être associés aux perturbations et incertitudes qui agissent sur le système. Quand on sait que le

but de toute loi de commande dite robuste, est justement de garantir la stabilité et de bonnes performances pour le système bouclé, et ce quel que soit les incertitudes et perturbations qui peuvent l'affecter, on imagine facilement le formidable apport que peut avoir une loi de commande inspirée du fonctionnement du système immunitaire.

Le cerveau humain est un autre exemple, il est connu entre autre pour : le traitement intelligent de l'information, le traitement distribué, le haut niveau de parallélisme, l'apprentissage, l'adaptation, la tolérance élevée aux informations inexacts... etc. a inspiré les réseaux de neurones artificiels, ces derniers ont été utilisés avec succès dans divers domaines dont le traitement d'image, la commande des systèmes... etc.

En outre, l'observation de phénomènes naturels a donné lieu à de multiples algorithmes d'optimisation qu'on peut classer dans deux grandes catégories : les algorithmes évolutionnaires et les algorithmes à base de l'intelligence distribuée.

Les algorithmes évolutionnaires sont des algorithmes de recherche stochastiques et d'optimisations heuristiques directement inspirés de la théorie de l'évolution naturelle énoncée par Charles Darwin en 1859, le principe fondamental étant que les individus les mieux adaptés à leur environnement survivent et peuvent se reproduire, laissant une descendance qui transmettra leurs gènes. Il existe de nombreux modèles du calcul évolutionnaire dont : la programmation évolutionnaire, les stratégies d'évolution, la programmation génétique et les algorithmes génétiques.

L'autre catégorie des algorithmes d'optimisation inspirés de la biologie est appelée : les algorithmes à base de l'intelligence distribuée ou intelligence collective, il s'agit d'un ensemble d'algorithmes inspirés de l'apparition de phénomènes cohérents à l'échelle d'une population dont les individus agissent selon des règles simples. En effet, la manière dont des individus interagissent permet l'émergence de formes, d'organisations, ou de comportements collectifs, complexes ou cohérents, tandis que les individus eux se comportent à leur échelle indépendamment de toute règle globale. Par exemple, la façon dont un essaim d'oiseaux vole vers un objectif précis, en prenant toujours le chemin optimal, ou encore la capacité d'une colonie de fourmis à trouver un chemin optimal vers une source de nourriture (toujours le plus court et le plus rapide), est d'une magnifique perfection. C'est donc tout à fait logique que ces phénomènes ont inspirés des algorithmes d'optimisation très efficaces, respectivement connus sous le nom de PSO pour "Particle Swarm Optimization" et ACO pour "Ant Colony Optimization".

L'objectif de cette thèse est d'exploiter toutes les perspectives prometteuses offertes par les systèmes bio-inspirés, et les appliquer dans le domaine de la commande des systèmes. En effet, les processus industriels actuels exigent de plus en plus de performances, mais aussi d'adaptabilité et de robustesse face aux divers aléas pouvant affectés leurs stabilité. Les systèmes à retard, les systèmes commandés sous réseau ou encore les centrales de conversion des énergies renouvelables, sont autant d'exemples de systèmes dont la commande est difficile à mettre en œuvre, car ils sont soumis à diverses contraintes et perturbations. En effet, la présence du retard dans une boucle de commande risque d'altérer ses performances et peut mener à son instabilité.

Quant aux systèmes commandés sous réseau, le partage d'un support de communication implique diverses contraintes comme : la diversité des intervalles d'échantillonnage/transmission, les différents délais de transmission (retards), les abandons de paquets...etc. Cela requiert donc un haut degré d'auto-adaptabilité que peuvent apporter les réseaux de neurones par exemple.

La commande des centrales hybrides de conversion des énergies renouvelables pose de nombreux défis de dimensionnement, de performances et de partage intelligent de l'énergie produite. Dans ce sens les algorithmes d'optimisation bio-inspirés peuvent constituer une réponse adéquate.

Ainsi, nous ambitionnons de mettre en œuvre diverses algorithmes bio-inspirés afin d'apporter des solutions crédibles pour une commande performante, adaptative et robuste des systèmes cités plus haut. Dans chaque chapitre, une contribution à partir d'algorithmes bio-inspirés sera proposée pour la commande de ces systèmes, apportant une amélioration certaine concernant la robustesse, l'adaptabilité ou encore l'optimisation de leur boucles de commande.

Cette thèse est constituée de quatre chapitres, dont trois représentent des contributions sous la forme de nouvelles structures/lois de commande, à base d'algorithmes bio-inspirés, pour une commande adaptative, robuste et optimale de différents systèmes spécifiques. Après une introduction générale, où on pose le contexte générale de la thèse ainsi que ces objectifs ; des généralités sur les systèmes bio-inspirés sont abordées dans le premier chapitre, il s'agit de présenter l'état de l'art des principaux algorithmes et méthodes bio-inspirées récentes, ces dernières sont classées en deux grande catégories du domaine de l'automatique :

- La commande des systèmes : où ils seront présentés les systèmes immunitaires artificiels et les systèmes neuronaux artificiels.
- L'optimisation : où ils seront présentés les algorithmes évolutionnaires et les algorithmes à base de l'intelligence distribuée.

A noter que ces méthodes sont appliquées seules ou combinées, dans les trois chapitres qui suivent, donnant lieu à des contributions intéressantes pour la commande de différents systèmes, en leur apportant différentes solutions innovantes.

Dans le deuxième chapitre, on propose la conception d'un contrôleur PID robuste basé sur le principe de la rétroaction immunitaire "IMF-PID", il est directement inspiré du circuit de contre-réaction immunitaire des cellules T. Le réglage des paramètres de ce contrôleur est assuré par deux algorithmes bio-inspirés étudiés dans le premier chapitre à savoir : PSO et ACO. Ensuite, la méthode proposée est appliquée pour la commande d'un système à retard mal conditionné, les résultats en termes de robustesse et de performances sont commentés et comparés avec ceux d'un contrôleur dont les paramètres ont été trouvés par une méthode d'optimisation directe (Nelder Mead).

Le troisième chapitre est consacré à la conception d'un contrôleur auto-adaptatif bio-inspiré pour la commande des systèmes sous réseau ou "Networked Control System" NCS, en effet, comme on l'a évoqué précédemment, les spécificités de tels systèmes requiert un haut degré d'auto-adaptabilité pour faire face aux nombreuses variations qui les affectent.

Dans le quatrième et dernier chapitre, nous proposons une nouvelle stratégie de commande et de gestion d'une centrale Hybride Autonome à Energie Renouvelable (CHAER), une telle tâche constitue un défi technologique majeur, car il faut trouver des solutions optimales à plusieurs problèmes, par exemple: Comment assurer une coopération intelligente entre les systèmes de commande des sous-systèmes constituant la centrale hybride afin d'augmenter ses performances ? Comment gérer intelligemment l'énergie produite et satisfaire totalement la demande ? Comment utiliser le moins possible les systèmes complémentaires (batterie, générateur diesel...etc). Pour cela, nous proposons une nouvelle configuration de la boucle de commande du CHAER, couplée à une optimisation multi objective assurée par l'algorithme génétique GA. Cette stratégie est appliquée pour l'alimentation en énergie d'une ferme isolée située à la ville de Skikda (Nord-Est d'Algérie), les résultats sont commentés et comparés avec une des stratégies classiques.

Enfin, en guise de conclusion générale, nous présentons une synthèse des principaux algorithmes bio-inspirés évoqués dans cette thèse, ainsi que leurs applications, des résultats obtenus et des perspectives envisagées dans nos futurs travaux.

Chapitre I

Généralités sur les systèmes bio-inspirés

I.1 Introduction

L'être humain a toujours utilisé la nature comme source d'inspiration pour résoudre des problèmes complexes, vu qu'elle présente des phénomènes très diversifiés, dynamiques, adaptatifs et robustes. La nature trouve toujours la solution optimale pour résoudre ses problèmes et maintenir l'équilibre parfait entre ses composantes. Les systèmes bio-inspirés, comme leur noms l'indique sont des systèmes méta heuristiques qui imitent des phénomènes observés dans la nature pour résoudre de nombreux problèmes dans divers domaines.

Dans le domaine de l'automatique, on assiste au développement d'un nombre considérable de méthodes développées à partir de l'observation des différents phénomènes de la biologie. Pour notre part, nous nous sommes intéressés aux structures de commande et/ou de contrôleurs et à l'optimisation bio-inspirés. Dans ce chapitre nous allons présenter des méthodes bio-inspirés récentes classées selon leur utilisation dans les chapitres qui suivent :

- Pour la commande des systèmes : Les systèmes immunitaires artificiels et les systèmes neuronaux artificiels.
- Pour l'optimisation : Les algorithmes évolutionnaires et les algorithmes à base de l'intelligence distribuée.

Ces méthodes peuvent-être utilisées seules ou ensemble pour obtenir de meilleurs résultats.

Plusieurs questions préoccupent les biologistes : dans une colonie d'insectes sociaux, tel les fourmis, les abeilles, les termites, etc., pourquoi le groupe est-il souvent cohérent alors que chaque individu semble autonome? Comment les activités de tous les individus sont-elles coordonnées sans supervision? Par exemple, les éthologistes qui étudient le comportement

des insectes sociaux ont observés que la coopération au sein des colonies de fourmis est auto-organisée, elle résulte d'interactions entre les individus. Bien que ces interactions puissent être simples, elles permettent à la collectivité de résoudre des problèmes complexes, telle la recherche du chemin le plus court entre le nid et une source de nourriture parmi d'innombrables voies possibles [1]. Toutes ces observations et interrogations ont permis l'émergence d'un nouveau paradigme de calcul intelligent inspiré de la biologie « Bio-inspired Computing » ou calcul bio-inspiré, pour traiter les problèmes complexes et dynamiques du monde réel. Ce nouveau paradigme a connu un grand succès, et a contribué à la compréhension des différents phénomènes naturels, ainsi qu'au développement de nouvelles techniques de calcul en réduisant considérablement la complexité algorithmique [2]. La figure I.1 représente une illustration du passage d'un phénomène naturel vers une technique bio-inspirée.

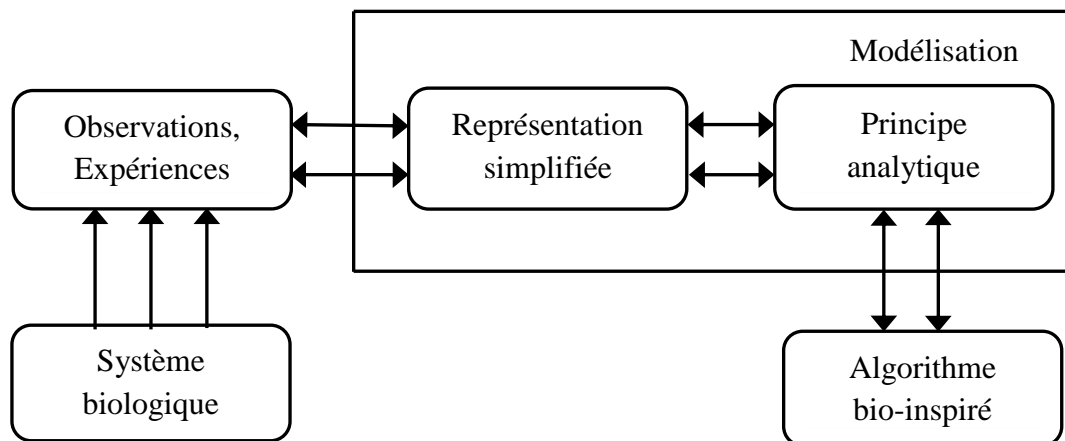


Figure I.1. L'approche conceptuelle pour dériver des algorithmes bio-inspirés

I.2 Systèmes bio-inspirés pour la commande

Le calcul bio-inspiré peut garantir certaines caractéristiques très intéressantes y compris : l'auto-adaptation et la robustesse, cela a motivé la communauté des automaticiens à concevoir des lois de commande bio-inspirées. Dans ce contexte, nous présentons dans cette section deux méthodes bio-inspirées: Le système immunitaire artificiel et le système neuronal artificiel.

I.2.1 Le système immunitaire artificiel

Le système immunitaire biologique est un système complexe, adaptatif et robuste, qui défend le corps contre les agents pathogènes étrangers. Il est capable de classer toutes les cellules (ou molécules) à l'intérieur du corps comme des cellules du soi ou des cellules du

non-soi. Ces principes ont conduit à l'émergence d'une technique inspirée par le système immunitaire biologique, appelé « système immunitaire artificiel » (AIS : Artificial immune system). Dans ce qui suit, nous décrivons brièvement les métaphores du système immunitaire biologique qui sont pertinentes pour les méthodes des systèmes immunitaires artificiels. Il convient de noter que : comme l'AIS est un domaine encore jeune et en constante évolution, il n'y a pas encore un modèle d'algorithme fixe et donc les implémentations réelles peuvent différer de temps en temps et selon le problème à traiter.

I.2.1.1 Le système immunitaire biologique

Le système immunitaire biologique est un système de défense complexe qui a évolué au fil de millions d'années. De nombreux détails sur les mécanismes immunitaires (adaptatifs et innés) et les processus (humérale et cellulaire) sont encore inconnus (même aux immunologistes), il est cependant bien connu que le système immunitaire utilise la défense à plusieurs niveaux d'une manière parallèle séquentielle, en fonction du type de l'agent pathogène et la façon dont il pénètre dans l'organisme. Le système immunitaire utilise différents mécanismes de réaction, soit pour neutraliser l'effet pathogène ou pour détruire les cellules infectées [3]. Les deux plus importantes cellules dans ce processus sont les globules blancs, elles sont classées en deux catégories : « les cellules T » et « les cellules B », toutes les deux proviennent de la moelle osseuse, mais les cellules T passent sur le thymus à mûrir, avant qu'elles ne circulent dans le sang et dans les vaisseaux lymphatiques. Il existe trois types de cellules T :

- Cellules T auxiliaires : elles sont essentielles à l'activation des lymphocytes B.
- Cellules T tueuses : elles se lient à des envahisseurs étrangers et injectent en eux des produits chimiques toxiques causant leur destruction.
- Les cellules T suppressives : c'est elles qui inhibent l'action des autres cellules immunitaires, empêchant ainsi les réactions allergiques et maladies auto-immunes.

Les cellules B sont responsables de la production et la sécrétion d'anticorps particuliers, ces derniers sont des protéines spécifiques qui se lient à l'antigène pour détruire la cellule envahissante comme représenté sur la figure I.2.

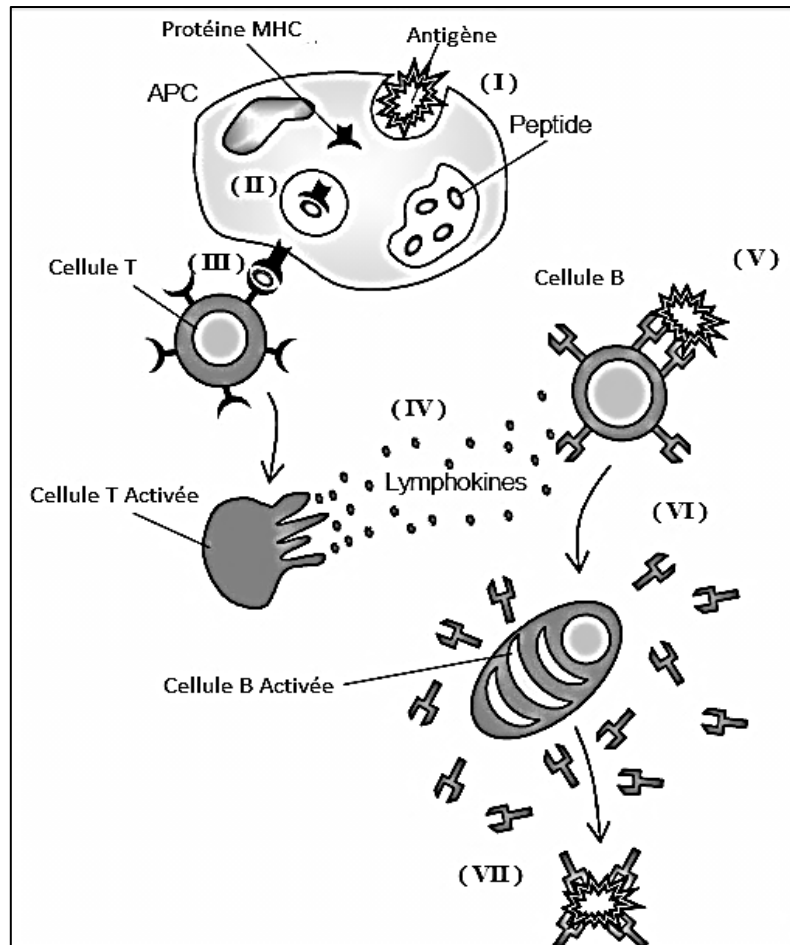


Figure I.2. Représentation graphique du mécanisme du système immunitaire [4] (I-III montre l'entrée de l'envahisseur dans le corps et l'activation de cellules T, puis en IV l'activation des cellules B, V l'appariement de l'antigène, VI la production de l'anticorps et VII destruction de l'antigène)

Comme mentionné auparavant, le corps humain est protégé contre les envahisseurs étrangers par un système à couches multiples. Le système immunitaire est composé de barrières physiques (telles que la peau et le système respiratoire) et de barrières physiologiques (telles que les enzymes destructrices et acides de l'estomac), il est divisé en deux types : immunité innée (non spécifique) et immunité adaptative (spécifique). L'immunité adaptative est elle-même subdivisée en deux types : immunité humorale et immunité cellulaire.

- **L'immunité innée:** Le système immunitaire inné est un sous-système important du système immunitaire global qui comprend les cellules et les mécanismes qui défendent l'hôte contre l'infection par d'autres organismes. Les cellules du système inné reconnaissent et répondent aux agents pathogènes d'une manière générique, mais contrairement au système immunitaire adaptatif, il ne fournit pas une immunité durable à

l'hôte [3]. Le système immunitaire inné est considéré comme la première ligne de défense contre les antigènes et inclut des éléments tels que la peau et les muqueuses.

- **L'immunité adaptative:** Le système immunitaire adaptatif subdivisé en deux types (immunité humorale et immunité cellulaire) est responsable de la protection de l'organisme contre les microorganismes infectieux non rencontrés auparavant, ce système est capable d'apprendre et de se rappeler des formes moléculaires des antigènes.

I.2.1.2 Principales caractéristiques

Les principales caractéristiques du système immunitaire biologique sont présentées ci-après [5-7]:

- **Distribution et auto-organisation :** Le comportement du système immunitaire est déployé à travers les actions de milliards d'agents (cellules et molécules) répartis dans tout le corps. Leurs effets collectifs peuvent être très complexes sans aucun contrôleur central. Une réponse organisée émerge comme une propriété dérivée des comportements d'agents. Ces agents immunitaires agissent simultanément en rendant les processus immunisés naturellement parallélisés.
- **Apprentissage, adaptation et mémoire :** Le système immunitaire est capable de reconnaître des agents pathogènes précédemment invisibles (capacité d'apprendre). L'apprentissage implique la présence de la mémoire, qui est présente dans le système immunitaire permettant de «se souvenir» des pathogènes précédemment encodés, ceci est une traduction du phénomène des réponses primaires et secondaires: la première rencontre d'un agent pathogène, la réponse immunitaire primaire est suscitée, la seconde fois que le pathogène est rencontré, une réponse plus rapide et souvent plus agressive est appliquée (la réponse secondaire).
- **Reconnaissance de formes :** Grâce à ses différents récepteurs et molécules, le système immunitaire est capable de reconnaître une gamme variée de modèles, ceci est accompli par des récepteurs qui perçoivent des matériaux antigéniques.

I.2.1.3 Principales théories immunitaires

Il existe plusieurs théories immunitaires ([3], [8], [9]), parmi lesquelles : la théorie de la sélection clonale, la théorie du réseau immunitaire, et la théorie de la sélection négative. Ces théories sont directement inspirées du processus d'adaptation de l'antigène et de l'anticorps, elles sont donc principalement utilisées dans les modèles des AIS. Un bref aperçu de ces théories est donné ci-après.

a. Théorie de la sélection clonale

Le principe de la sélection clonale décrit les caractéristiques fondamentales d'une réponse immunitaire à un stimulus antigénique, il établit l'idée que seules les cellules qui reconnaissent l'antigène prolifèrent. Les principales caractéristiques de la théorie de la sélection clonale sont :

- Les nouvelles cellules sont des copies de leurs parents (clone) soumis à un mécanisme de mutation avec des taux élevés (hyper mutation somatique).
- Élimination des lymphocytes nouvellement différenciés portant des récepteurs auto réactifs.
- Prolifération et différenciation au contact des cellules matures avec les antigènes.

b. Théorie du réseau immunitaire

La théorie du réseau immunitaire avait été proposée au milieu des années soixante-dix [9]. L'hypothèse est que le système immunitaire maintient un réseau idiotypique de cellules B interconnectés pour la reconnaissance de l'antigène, ces cellules à la fois stimulent et suppriment mutuellement dans certaines voies qui conduisent à la stabilisation du réseau. Deux cellules B sont connectées si les affinités qu'elles partagent dépassent un certain seuil, et la force de la connexion est directement proportionnelle à l'affinité qu'elles partagent.

c. Théorie de la sélection négative

Le but de la sélection négative est de fournir une tolérance pour les cellules autonomes, elle traite la capacité du système immunitaire à détecter des antigènes inconnus et à ne pas réagir aux cellules autonomes. Lors de la génération de cellules T, les récepteurs sont réalisés par un processus de réarrangement génétique pseudo-aléatoire. Ensuite, ils sont soumis à un processus de censure dans le thymus, appelé sélection négative. Là, les cellules T qui réagissent contre les protéines du soi sont détruites; Par conséquent, seules celles qui ne se lient pas aux protéines du soi sont autorisées à quitter le thymus. Ces lymphocytes T matures circulent alors dans tout le corps pour exécuter des fonctions immunologiques et pour protéger le corps contre les antigènes étrangers.

I.2.1.4 Les algorithmes immunitaires artificiels

De Castro et Timmis ont proposé une approche flexible et générique pour le développement de solutions d'ingénierie inspirées du système immunitaire [7], la figure I.3

identifie les principales étapes de conception qui doivent être prises en compte lors du déploiement d'une solution inspirée du système immunitaire.

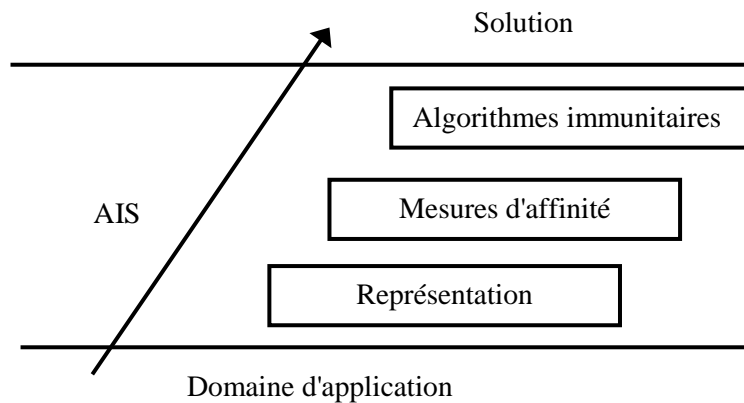


Figure I.3. L'approche de la construction des solutions AIS

Les trois principaux algorithmes immunitaires artificiels sont présentés ci-après.

a. Algorithme inspiré par la théorie de la sélection clonale

Les algorithmes de sélection clonale emploient le principe de la mutation et de la sélection d'une population de solutions candidates : Un ensemble initialisé aléatoirement de cellules B est préférentiellement choisi en fonction de leur affinité pour l'antigène, les cellules d'affinité plus élevée sont clonées proportionnellement à leur affinité et mutées à un taux inversement proportionnel à l'affinité. L'algorithme inspiré par la sélection clonale CLONALG (Clonal selection algorithm) [10, 11] est donné comme suit :

1. initialiser aléatoirement une population de M éléments (cellules immunitaires).
2. déterminer l'affinité d'un antigène avec chaque élément de la population M .
3. sélectionner n éléments de la population M , ayant la plus haute affinité.
4. cloner les éléments sélectionnés proportionnellement à leur affinité avec l'antigène. On en produit plus de copies tant que l'affinité est haute.
5. muter chaque clone avec un taux de mutation inversement proportionnel à leur degré d'affinité, plus l'affinité est élevée, plus le taux de mutation est faible.
6. ajouter les éléments ayant subi une mutation à la population M , puis faire la resélection de M parmi ces éléments mûrs afin d'être retenus comme les cellules mémoires du système.
7. répéter les étapes (2) à (6) jusqu'à ce qu'un certain critère soit satisfait.

Cet algorithme peut être adapté à des problèmes d'optimisation en supprimant l'ensemble d'antigènes et en représentant directement la fonction ou le domaine à optimiser en tant que fonction d'affinité, il tend à être semblable aux algorithmes évolutionnaires [12].

b. Algorithme inspiré par la théorie du réseau immunitaire

Il s'agit d'une version modifiée de CLONALG qui intègre un mécanisme de suppression parmi les cellules B. Dans cet algorithme, les données sont représentées comme un antigène reconnu par les détecteurs de cellules B. Comme dans l'algorithme de la sélection clonale, la maturation par affinité produit des cellules B avec des spécificités différentes, et la compétition supprime le pire de ces cellules de la population. Un mécanisme de suppression supprime alors les cellules de spécificités similaires de la population. Le réseau résultant de cellules B est alors représentatif des grappes dans les données. Un algorithme générique du réseau immunitaire basé sur [13], est donné par :

1. Initialisation : initialiser un réseau de cellules immunitaires.

2. Pour chaque antigène **faire**

- ✓ **Métadynamique** : introduire de nouvelles cellules dans le réseau et éliminer les cellules inutiles (selon un certain critère).
- ✓ **Identification antigénique** : confronter les cellules immunitaires à l'antigène.
- ✓ **Interactions du réseau** : confronter les cellules immunitaires entre elles.
- ✓ **Niveau de stimulation** : évaluez le niveau de stimulation de chaque cellule immunitaire.
- ✓ **Dynamique de réseau** : mettre à jour la structure du réseau selon le niveau de stimulation : propager les cellules qui ont les plus grandes affinités et éliminer les cellules qui ont les plus faibles affinités.

Fin pour

3. Cycle : répéter l'étape 2 jusqu'à ce qu'un critère donné d'arrêt soit rencontré.

c. Algorithme inspiré par la théorie de la sélection négative

Cet algorithme est la traduction des systèmes immunitaires naturels qui différencient le « Soi » du « Non Soi » [14] : A supposer que l'ensemble des éléments du « Soi » soit connu, l'algorithme standard de sélection négative a pour rôle de générer un ensemble de cellules immunitaires, appelées détecteurs, capable de reconnaître toute autre cellule sauf celles

appartenant à l'ensemble du « Soi ». L'algorithme inspiré par la théorie de la sélection négative est présenté comme suit :

1. **Initialisation** : générer aléatoirement un ensemble de détecteurs candidats.
2. **Censure** : **Tant que** le nombre de détecteurs est insuffisant, **faire**
 - ✓ **Evaluation d'affinité** : calculer l'affinité entre chaque élément du « soi » et un détecteur candidat.
 - ✓ **Sélection** : éliminé tout détecteur qui reconnaît un élément du « soi » Autrement, incrémenter le nombre de détecteurs valides.

Fin

3. **Pilotage** : piloter un nouvel ensemble de « soi' » pour détecter des variations : si un détecteur de l'ensemble des détecteurs ainsi générés identifie un élément parmi le nouvel ensemble de « Soi », alors cela signifie qu'une variation a été détectée.

I.2.2 Le système neuronal artificiel

Un système neuronal artificiel autrement dit «réseau neuronal artificiel » (ANN : Artificial neural network) est un modèle mathématique qui tente de simuler la structure et les fonctionnalités des réseaux de neurones biologiques. Il simule différents aspects liés au comportement du cerveau humain, tels que: traitement intelligent de l'information, traitement distribué, haut niveau de parallélisme, apprentissage, adaptation, tolérance élevée aux informations inexactes (ou erronées). Un ANN se compose d'un groupe interconnecté de neurones artificiels et traite des informations en utilisant une approche connexionniste.

I.2.2.1 Le neurone biologique

Les concepts opérationnels du cerveau humain sont encore une énigme, seuls quelques aspects sont connus. L'élément principal du cerveau est un type particulier de cellule, qui, contrairement au reste du corps, ne se régénère pas. Puisque ce type de cellule est la seule partie du corps qui n'est pas remplaçable, il est supposé que ces cellules nous fournissent les capacités de se souvenir, de penser, et de prendre en considération les expériences précédentes pour chacune de nos actions [15]. Ces cellules (plus de 100 milliards...), sont connues sous le nom de neurones, ils peuvent se connecter avec un maximum de 200.000 autre neurones, bien que 1.000 à 10.000 sont typiques [16]. Un neurone biologique simplifié est représenté sur la figure I.4.




Figure I.4. Le neurone biologique simplifié [17]

Un neurone est d'abord constitué d'un corps cellulaire pourvu d'un noyau, il est en liaison avec d'autres neurones grâce à deux types de prolongements : les dendrites et les axones. Les dendrites, courts, nombreux et ramifiés s'étendent à la périphérie du corps cellulaire. Ils permettent au neurone de recevoir des informations en provenance d'autres neurones sous forme d'influx nerveux. Le soma traite ensuite ces signaux entrants au fil du temps et transforme alors cette valeur traitée à une sortie, qui est envoyée à d'autres neurones par l'intermédiaire de l'axone et les synapses [16].

I.2.2.2 Le neurone artificiel

Les premiers travaux sur les réseaux de neurones artificiels remontent aux années quarante par Mc Culloh et Pitts en 1943. Partant du constat que le modèle biologique fait intervenir une notion temporelle qui est difficile à intégrer dans un modèle simple, cette notion d'intégration temporelle a donc été remplacée par une simple sommation des signaux arrivant au neurone (les entrées du neurone). Finalement, un neurone artificiel réalise simplement une somme pondérée de ces entrées (x_i), ajoute un seuil à cette somme et fait passer le résultat par une fonction d'activation pour obtenir sa sortie (y) [17]. La figure I.5 présente un schéma synoptique du neurone basique.




Figure I.5. Un neurone artificiel basique

Une représentation plus détaillée d'un neurone artificiel est illustré sur la figure suivante :




Figure I.6. Architecture d'un neurone artificiel

Dans la figure I.6, le signal de sortie du neurone est donné par la relation suivante: [18]

$$y = f(act) = f(\sum_{j=1}^n w_j x_j) \quad (I.1)$$

Où w_i est le vecteur poids (coefficients synaptiques), et la fonction $f(act)$ est appelée fonction d'activation. La variable act est défini comme étant le produit scalaire du poids et des vecteurs d'entrée :

$$act = w^T x = w_1 x_1 + \dots + w_n x_n \quad (I.2)$$

Où T est la transposition d'une matrice. Dans le cas le plus simple, la valeur de la sortie y est calculée comme suit :

$$y = f(act) = \begin{cases} 1 & \text{si } w^T x \geq \theta \\ 0 & \text{autrement} \end{cases} \quad (I.3)$$

Où θ est appelé le seuil (ou le biais). Ce type de réseau est appelé « unité linéaire à seuil ».

L'architecture de base se compose de trois types de couches neuronales: les couches d'entrée, les couches cachées et les couches de sortie. Le réseau neuronal doit être configuré de telle sorte que l'application d'un ensemble d'entrées produise les sorties désirés. Différentes méthodes pour établir les forces des connexions existent, elles se basent sur la détermination explicite des poids, en utilisant une connaissance a priori. Une autre façon est de former le réseau neuronal en l'alimentant par des modèles d'enseignement et en le laissant changer ses poids selon une règle d'apprentissage. Les règles d'apprentissage dans les réseaux neuronaux peuvent être classées en trois catégories distinctes : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement.

- Apprentissage supervisé: les coefficients synaptiques sont évalués en minimisant l'erreur (entre sortie souhaitée et sortie obtenue) sur une base d'apprentissage. Les exemples les plus connus de cette technique se trouvent dans la règle Hebb et la règle de Perceptron [18].

- Apprentissage non-supervisé: on ne dispose pas de base d'apprentissage, les coefficients synaptiques sont déterminés par rapport à des critères de conformité : spécifications générales.
- Apprentissage par renforcement: on minimise l'erreur sur la base d'apprentissage à chaque itération mais on augmente l'erreur sur la base d'essai. Le modèle perd alors sa capacité de généralisation : c'est l'apprentissage "par cœur".

I.2.2.3 Règles d'apprentissage du réseau neuronal artificiel

a. La règle de Hebb :

En 1949, Donald Hebb a proposé une règle d'apprentissage basée sur la physiologie du système nerveux qui permet de modifier la valeur des coefficients de poids en fonction de l'activité des unités qu'ils relient. Cette règle aujourd'hui connue sous le nom de «la règle de Hebb» est présente dans la majorité des modèles actuels, même les plus sophistiqués.

L'idée de base de la règle d'apprentissage Hebbien est que si deux neurones sont actifs simultanément, leur interconnexion doit être renforcée. Si l'on considère un réseau monocouche, l'un des neurones interconnectés sera une unité d'entrée et une unité de sortie en même temps. Si les données sont représentées sous forme bipolaire, il est facile d'exprimer la mise à jour du poids souhaitée par [18]:

$$w_i(k) = w_i(k - 1) + x_i y_d(k) \quad (\text{I.4})$$

Où y_d est la sortie désirée pour : $i = 1$ à n (*entrées*) et k est le pas d'avancement.

b. La règle de Perceptron :

Le perceptron est un réseau neuronal monocouche, il est inspiré du système visuel dont les poids et les biais peuvent être formés pour produire un vecteur cible correct, lorsque il est présenté avec le vecteur d'entrée correspondant. La technique d'apprentissage utilisée est appelée la règle de perceptron, les perceptrons sont particulièrement adaptés pour les problèmes simples comme la reconnaissance de formes.

Supposons que l'on dispose d'un ensemble d'échantillons d'apprentissage constitué d'un vecteur d'entrée x et d'une sortie désirée $y_d(k)$. La règle de perceptron peut être énoncée comme suit [18]:

1. Commencez par des poids aléatoires pour les connexions.
2. Sélectionnez un vecteur d'entrée x dans l'ensemble des échantillons d'apprentissage.

3. Si la sortie $y(k) \neq y_d(k)$ (le perceptron donne une réponse incorrecte), modifiez toutes les connexions w_i en fonction de $w_i = \eta(y_d(k) - y(k))x_i$; (η = taux d'apprentissage).
4. Revenez à l'étape 2.

Notez que la règle de perceptron est très semblable à la règle de Hebb, la seule différence est que lorsque le réseau répond correctement, aucun poids de connexion n'est modifié.

I.2.2.4 Architecture du réseau neuronal artificiel

En général, l'architecture de base se compose de trois types de couches neuronales comme illustré dans la figure I.7: les couches d'entrée, les couches cachées et les couches de sortie :




Figure I.7. Architecture d'un réseau neuronal artificiel [18]

- La couche d'entrée : Cette couche est chargée de recevoir des informations (données), des signaux, des caractéristiques ou des mesures de l'environnement externe. Ces entrées (échantillons ou modèles) sont normalisées dans les valeurs limites produites par les fonctions d'activation. Cette normalisation se traduit par une meilleure précision numérique pour les opérations mathématiques effectuées par le réseau.
- La couche cachée : Cette couche est composée de neurones qui sont responsables de l'extraction des motifs associés au processus ou au système analysé. La couche cachée effectue la majeure partie du traitement interne.
- La couche de sortie : Cette couche est responsable de la production et de la présentation des sorties de réseau finales, qui résultent du traitement effectué par les neurones dans les couches précédentes.

Les architectures principales des réseaux neuronaux artificiels, en considérant la disposition des neurones, ainsi que leur interconnexion et la composition de ses couches, peuvent être réparties comme suit: réseau monocouche, réseau multicouche, réseau récurrent.

a. Le réseau monocouche

Ce réseau neuronal artificiel a juste une couche d'entrée et une seule couche neuronale, qui est aussi la couche de sortie. La figure I.8 illustre un réseau monocouche composé de n entrées et m sorties. L'information circule toujours dans une seule direction (unidirectionnelle), qui va de la couche d'entrée à la couche de sortie. A partir de la figure I.8, on peut voir que dans les réseaux appartenant à cette architecture, le nombre de sorties de réseau coïncide toujours avec sa quantité de neurones. Ces réseaux sont habituellement employés dans la classification des modèles et les problèmes de filtrage linéaire.




Figure I.8. Architecture d'un réseau neuronal monocouche [19]

b. Le réseau multicouche

Contrairement aux réseaux appartenant à l'architecture précédente, les réseaux multicouches sont composés d'une ou plusieurs couches neuronales cachées (Figure I.9). Ils sont employés dans la résolution de divers problèmes, comme ceux liés à l'approximation fonctionnelle, la classification des modèles, l'identification du système, le contrôle des processus, l'optimisation, la robotique, etc.

La figure I.9 montre un réseau multicouche composé d'une couche d'entrée avec n signaux, deux couches neuronales cachées constituées de n_1 et n_2 neurones respectivement, et enfin une couche neuronale de sortie composée de m neurones représentant les valeurs de sortie.




Figure I.9. Architecture d'un réseau neuronal multicouche [19]

c. Le réseau récurrent

Dans ce réseau, les sorties des neurones sont utilisées comme entrées de rétroaction pour d'autres neurones. La caractéristique de rétroaction qualifie ces réseaux pour le traitement dynamique de l'information, ce qui signifie qu'ils peuvent être utilisés sur des systèmes variant dans le temps, tels que la prévision des séries chronologiques, l'identification et l'optimisation du système, le contrôle du processus, etc. La figure I.10 illustre un exemple d'un réseau récurrent, où l'un de ses signaux de sortie est renvoyé à la couche intermédiaire. Ainsi, en utilisant le processus de rétroaction, les réseaux avec cette architecture produisent des sorties en tenant compte également des valeurs de sortie précédentes.




Figure I.10. Architecture d'un réseau neuronal récurrent [19]

I.3 Algorithmes d'optimisation bio-inspirés

Il est connu que la nature trouve toujours des solutions optimales pour sa perpétuation, on assiste ces dernières années à une prolifération de méthodes d'optimisation bio-inspirés. Dans ce qui suit, nous présentons deux principales catégories : les algorithmes évolutionnaires et les algorithmes à base de l'intelligence distribuée.

I.3.1 Les algorithmes évolutionnaires

Les algorithmes évolutionnaires sont des algorithmes de recherche stochastiques et d'optimisations heuristiques dérivées de la théorie de l'évolution classique énoncée par Charles Darwin en 1859. Le principe fondamental étant que les individus les mieux adaptés à leur environnement survivent et peuvent se reproduire, laissant une descendance qui transmettra leurs gènes. La clef étant l'adaptation des individus face à la pression de l'environnement ; l'analogie avec l'optimisation devient claire. Cette adaptation peut alors être assimilée à une optimisation des individus afin qu'ils soient de mieux en mieux adaptés à leur environnement au fur et à mesure des générations (correspondant aux itérations de l'algorithme). Nous pourrions alors définir les algorithmes évolutionnaires comme étant des méthodes faisant évoluer un ensemble de solutions appelé "population". Les solutions, appelées "individus", sont représentées par leur génotype, qui s'exprime sous la forme d'un phénotype. Afin d'évaluer la performance d'un individu, on associe au phénotype la valeur de la fonction objectif (ou fonction d'aptitude 'fitness'). Un algorithme évolutionnaire se décompose en plusieurs étapes, chacune d'elles étant associée à un opérateur décrivant la façon de manipuler les individus. Le processus de l'algorithme évolutionnaire implique une séquence d'opérations: la création d'une population initiale (une collection d'individus), l'évaluation de cette population, puis l'évolution de la population à travers plusieurs générations. A la fin de chaque génération les individus les plus aptes, à savoir, ceux qui représentent la meilleure solution de la population sont conservés et sont autorisés à croiser avec d'autres membres aptes. L'opération de croisement est effectuée afin de créer des individus qui sont plus en forme que les deux parents en prenant les meilleures caractéristiques de chacun des parents. Ainsi, après un certain nombre de générations, l'aptitude de la population augmentera avec les gènes de l'individu le plus apte représentant la solution optimale. L'ensemble du processus évolutionnaire est similaire à des espèces vivantes qui évoluent en fonction de leurs conditions environnementales changeantes.

Dans ce qui suit, on présentera les algorithmes évolutionnaire qui ont émergés au cours des dernières décennies, tels que : « la programmation évolutionnaire » [20], « les stratégies d'évolution » [21], « la programmation génétique » [22] et « les algorithmes génétiques » [23, 24]. Bien que ces techniques présentent des points communs, chacune d'elles met en œuvre l'algorithme de sa propre manière unique, elles se différencient sur presque tous les aspects des algorithmes évolutionnaires, y compris :

- La représentation de la structure de données des individus
- Les méthodes de sélection du parent
- les méthodes de sélection de la survie
- La taille de la population

Dans ce qui suit, nous présenterons les paradigmes majeurs des algorithmes évolutionnaires indiquées dans tableau I.1.

Tableau I.1. Paradigmes du calcul évolutionnaire

| Paradigme | Créé par |
|------------------------------|---|
| Algorithmes génétiques | <i>J.H. Holland</i> |
| Programmation génétique | <i>De Garis et John Koza</i> |
| Programmation évolutionnaire | <i>L.J. Fogel, A.j. Owens, M.J. Walsh</i> |

I.3.1.1 L'algorithme génétique

Initialement proposé par John Holland en 1975, les algorithmes génétiques (GA : Genetic Algorithm) sont des algorithmes d'optimisation s'appuyant sur des techniques dérivées de la génétique et des mécanismes d'évolution de la nature. Le processus de GA est structuré comme suit [25]: On part avec une population de solutions potentielles (chromosomes) initiales arbitrairement choisies. On évalue leur performance (fitness) relative. Sur la base de ces performances, on crée une nouvelle population de solutions potentielles en utilisant des opérateurs évolutionnaires simples : la sélection, le croisement et la mutation. On recommence ce cycle jusqu'à ce que l'on trouve une solution satisfaisante. L'organigramme d'un algorithme génétique typique est représenté sur la figure I.11.

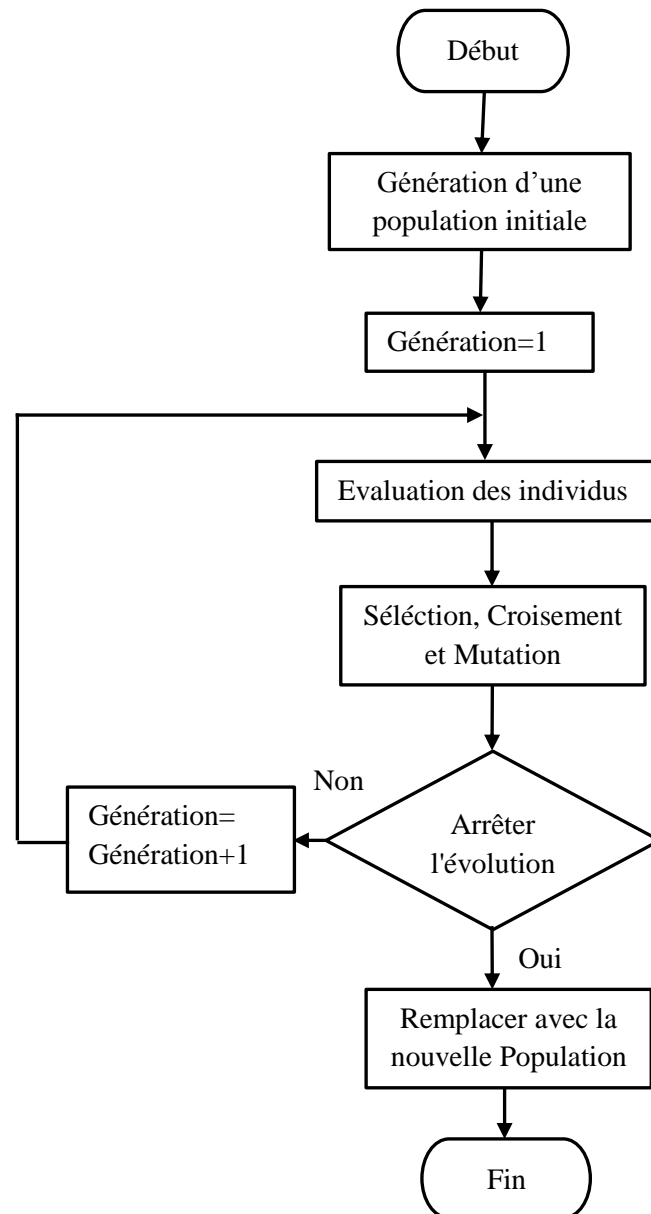


Figure I.11. Diagramme d'un algorithme génétique

I.3.1.2 La programmation génétique

L'idée principale derrière le développement de la programmation génétique (GP : Genetic Programming) proposée par John Koza en 1990, était la programmation automatique. GP peut être considéré comme une forme spécialisée d'un algorithme génétique, qui manipule des chromosomes en utilisant des opérateurs génétiques modifiés.

En général, la programmation génétique développe des expressions symboliques sous un langage fonctionnel, un programme évolutionnaire peut contenir des segments de code qui, lorsqu'il est retiré du programme ne modifierait pas le résultat produit par le programme. La taille du programme évolutionnaire peut aussi se développer de manière incontrôlable jusqu'à ce qu'il atteigne la profondeur maximale autorisée de l'arbre alors que le degré d'aptitude reste

inchangé. Cet effet est connu sous le nom de ballonnement [26], il s'agit d'un grave problème dans la programmation génétique, car il conduit généralement à la réduction de l'effet des opérateurs de recherche. Une fois qu'il se produit, le degré d'aptitude baissera fortement. La figure I.12 présente un algorithme d'une programmation génétique.

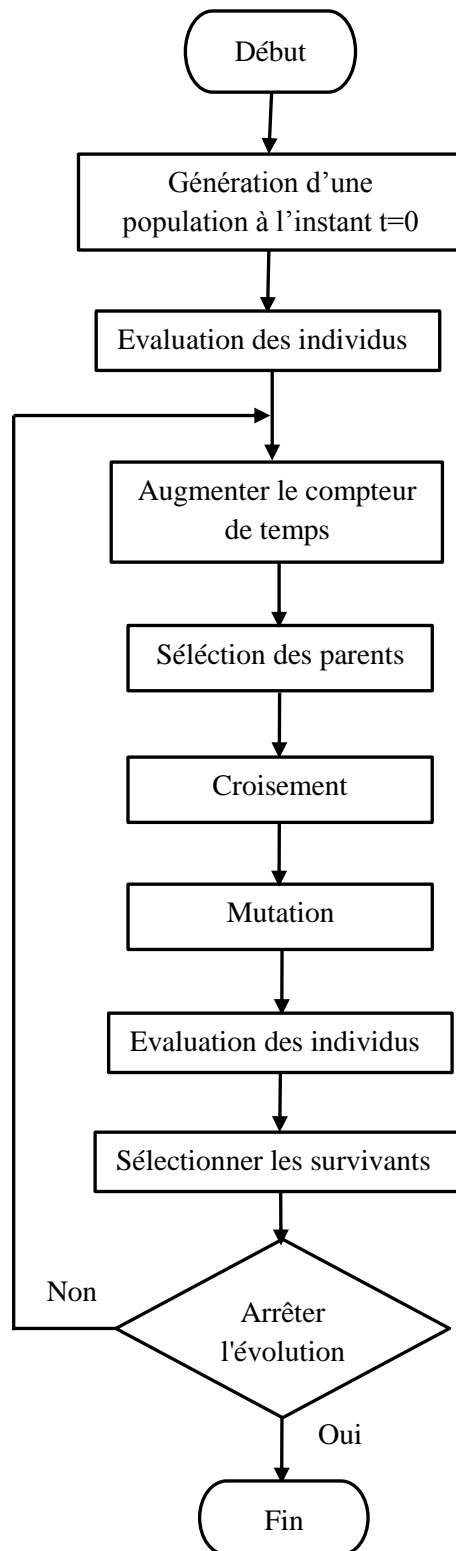


Figure I.12. Algorithme de la programmation génétique

I.3.1.3 La programmation évolutionnaire

La programmation évolutionnaire (EP : Evolutionary programming) est une stratégie d'optimisation stochastique initialement développé par Lawrence J. Fogel en 1960. Le fonctionnement du EP est similaire aux algorithmes génétiques avec la seule différence que la programmation évolutionnaire met le point sur le lien comportemental entre les parents et leur progéniture, plutôt que de chercher à imiter les opérateurs génétiques spécifiques comme observé dans la nature. EP est une méthode efficace pour résoudre des problèmes d'optimisation par rapport à des techniques telles que l'algorithme du gradient. Les problèmes d'optimisation des fonctions combinatoires dans lesquelles la surface d'optimisation est "robuste", sont facilement et efficacement calculés en utilisant la programmation évolutionnaire. La méthode EP se décompose en trois étapes récursives jusqu'à ce qu'un seuil soit dépassé pour l'itération ou une solution adéquate est obtenue [20] :

Étape 1: Choisir aléatoirement une population initiale de solutions, le nombre de solutions dans une population est étroitement liée à la vitesse de l'optimisation, mais il n'y a pas de méthodes pour prédire le nombre de solutions appropriées (autres que > 1) et prévoir les solutions rejetées.

Étape 2: Chaque solution produite est copiée dans une nouvelle population, ensuite ces descendants subissent un degré de mutation allant du minimum à un maximum avec des types de mutation continue entre les deux. La sévérité de la mutation est devinée sur la base de la modification fonctionnelle appliquée sur les parents.

Étape 3: Chaque progéniture est évaluée en calculant sa fonction d'aptitude. En règle générale, une sélection stochastique est appliquée pour déterminer le nombre de solutions pour la population. De plus, aucune contrainte n'est appliquée sur la taille de la population. En principe, EP n'utilise pas de croisement comme un opérateur génétique. L'algorithme EP est représenté par la figure I.13.

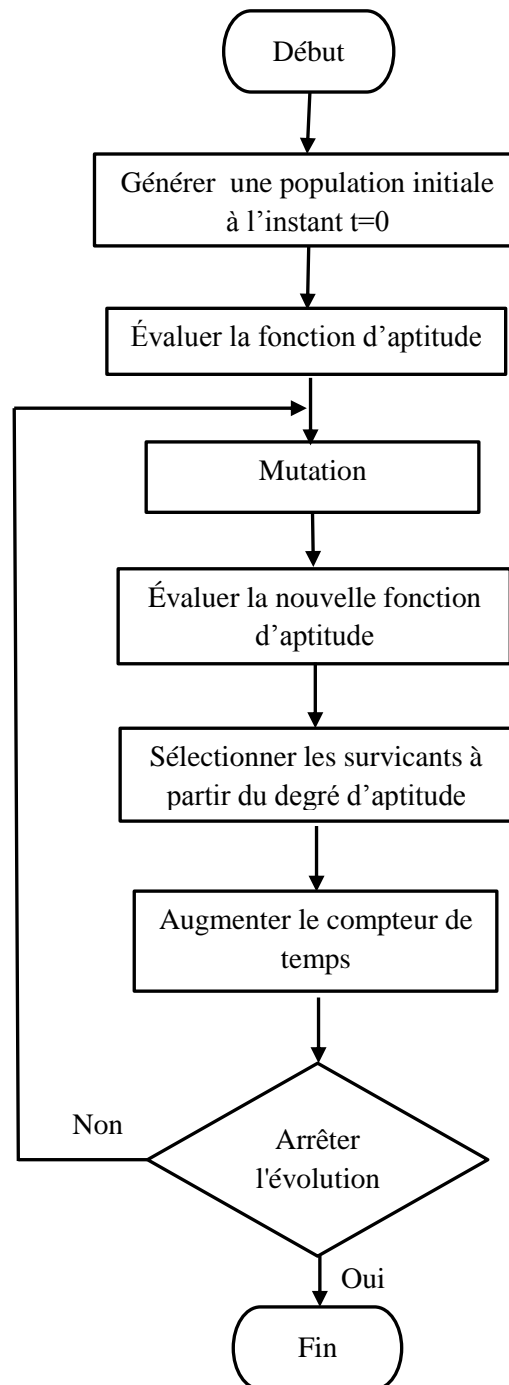


Figure I.13. Algorithme de la programmation évolutionnaire

I.3.2 Les algorithmes à base de l'intelligence distribuée

L'intelligence distribuée (autrement dit «intelligence collective») désigne l'apparition de phénomènes cohérents à l'échelle d'une population dont les individus agissent selon des règles simples. L'interaction ou la synergie entre les actions individuelles simples peut de façons variées permettre l'émergence de formes, organisations, ou comportements collectifs,

complexes ou cohérents, tandis que les individus eux se comportent à leur échelle indépendamment de toute règle globale [27].

Les caractéristiques de l'intelligence distribuée sont : [27]

- a. Un ensemble de règles simples : chaque individu obéit à un ensemble restreint de règles simples par rapport au comportement du système global.
- b. Des interactions sociales multiples : chaque individu est en relation avec un ou plusieurs autres individus du groupe.
- c. Une structure émergente utile à la collectivité : chaque individu trouve un bénéfice à collaborer (parfois instinctivement) et sa propre performance au sein du groupe est meilleure que s'il était isolé.

Parmi les algorithmes bio-inspirés basés sur l'intelligence distribuée qui ont connu une grande popularité, on notera l'algorithme d'optimisation par essais particuliers et l'algorithme d'optimisation par colonies de fourmis.

I.3.2.1 L'algorithme d'optimisation par essais particuliers

L'optimisation par essaim particulaire (PSO : Particle Swarm Optimization), est une technique proposée par Russel Eberhart et James Kennedy en 1995 aux Etats-Unis, pour résoudre les problèmes d'optimisation, elle est inspirée du comportement social des animaux évoluant en essaim [28]. L'algorithme PSO est une technique de recherche multi-agent parallèle qui maintient un essaim de particules, où chaque particule représente une solution potentielle à l'essaim. Toutes les particules volent à travers un espace de recherche multidimensionnel où elles ajustent ses positions en fonction de ses propres expériences et celle de ses voisins. Supposons que x_i^t désigne le vecteur de position des particules dans l'espace de recherche multidimensionnelle (i.e. R^n) au pas de temps t , la position de chaque particule est mis à jour dans l'espace de recherche avec :

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad \text{avec } x_i^0 \sim U(x_{min}, x_{max}) \quad (I.5)$$

Où :

v_i^t : est le vecteur de vitesse des particules qui entraîne le processus d'optimisation, il reflète à la fois la connaissance de l'expérience propre et la connaissance de l'expérience sociale des toutes les particules;

$U(x_{min}, x_{max})$: est la distribution uniforme où x_{min} et x_{max} sont les valeurs minimales et maximales respectivement.

Par conséquent, dans un procédé de PSO, toutes les particules sont lancées au hasard et évaluées pour trouver ensemble la meilleure position personnelle de chaque particule et la meilleure position de son voisinage. Après cela, une boucle se lance afin de trouver une solution optimale : d'abord la vitesse des particules est mise à jour par les records personnels et globaux, puis la position de chaque particule est mise à jour par la vitesse actuelle. La boucle est terminée par un critère d'arrêt prédéterminé à l'avance [29].

Il y a deux principaux algorithmes PSO, à savoir le meilleur global (Gbest : Global best) et meilleur local (Lbest : Local best), la différence entre eux réside dans la taille de leurs voisinages, ces algorithmes sont décrits ci-après.

a. Gbest PSO

Le meilleur global PSO (ou Gbest PSO) est une méthode où la position de chaque particule est influencée par la particule ayant le meilleur degré d'aptitude dans tout l'essaim, elle utilise une topologie de réseau en étoile où l'information sociale est obtenue à partir de toutes les particules dans tout l'essaim. Dans cette méthode, chaque particule individuelle, $i \in [1, \dots, n]$ où $n > 1$, a une position actuelle x_i , une vitesse actuelle v_i , et une meilleure position personnelle dans l'espace de recherche $P_{best,i}$ [30, 31].

Considérant un problème de minimisation, la meilleure position personnel $P_{best,i}$ correspond à la position où la particule i a eu la plus petite valeur telle que déterminée par la fonction objectif f . En outre, la position qui donne la plus faible valeur parmi tous les particules $P_{best,i}$ est appelée la meilleure position globale qui est désignée par G_{best} [32]. Les équations suivantes (I.6) et (I.7) définissent la manière dont les meilleures valeurs personnelles et globales sont mises à jour respectivement, compte tenu d'un problème de minimisation, la meilleure position personnelle $P_{best,i}$ à l'instant $t + 1$, où $t \in [0, \dots, N]$ est calculée comme suit :

$$P_{best,i}^{t+1} = \begin{cases} P_{best,i}^t & \text{Si } f(x_i^{t+1}) > P_{best,i}^t \\ x_i^{t+1} & \text{Si } f(x_i^{t+1}) \leq P_{best,i}^t \end{cases} \quad (\text{I.6})$$

Où $f: \mathbb{R}^n \rightarrow \mathbb{R}$ est la fonction d'aptitude. La meilleure position globale G_{best} (meilleur à l'instant t) est calculée comme suit :

$$G_{best} = \min\{P_{best,i}^t\}, \quad \text{Où } i \in [1, \dots, n] \text{ et } n > 1 \quad (\text{I.7})$$

$P_{best,i}$ sera donc la meilleure position que l'individu a visitée depuis le début. D'autre part, la meilleure position globale est la meilleure position G_{best} découverte par l'une des particules dans l'ensemble de l'essaim [18]. La vitesse de la particule est calculé par :

$$V_{ij}^{t+1} = V_{ij}^t + c_1 r_{1j}^t (P_{best,i}^t - X_{ij}^t) + c_2 r_{2j}^t (G_{best} - X_{ij}^t) \quad (I.8)$$

Où :

V_{ij}^t est le vecteur vitesse de la particule i dans la dimension j à l'instant t

X_{ij}^t est le vecteur position de la particule i dans la dimension j à l'instant t

$P_{best,i}^t$ est la meilleure position personnelle de la particule i dans la dimension j à l'instant t

G_{best} est la meilleure position globale de la particule i dans la dimension j à l'instant t

c_1 et c_2 sont des constantes d'accélération positives qui servent à niveler la contribution des composantes cognitives et sociales, respectivement;

r_{1j}^t et r_{2j}^t sont des nombres aléatoires d'après la distribution uniforme $U(0,1)$ à l'instant t .

Le diagramme de l'algorithme gbest PSO est présenté par la Figure I.14.

b. Lbest PSO

La méthode du meilleur local (ou *Lbest* PSO) (figure I.15), permet à chaque particule d'être influencée par la particule ayant le meilleur degré d'aptitude choisi dans son voisinage. Elle utilise une topologie de réseau en anneau. Dans ce cas, l'information sociale est échangée dans le voisinage de la particule, ce qui dénote une connaissance locale de l'environnement [30, 31]. La vitesse de la particule i est calculée par :

$$V_{ij}^{t+1} = V_{ij}^t + c_1 r_{1j}^t (P_{best,i}^t - X_{ij}^t) + c_2 r_{2j}^t (L_{best,i} - X_{ij}^t) \quad (I.9)$$

Où $L_{best,i}$ est la meilleure position que toutes les particules ont eu dans le voisinage de la particule i à l'instant t .

c. Paramètres du PSO

Les performances de l'algorithme PSO peuvent être influencées par quelques paramètres, pour tout problème d'optimisation donné, certains choix de ces paramètres peuvent avoir un grand impact sur l'efficacité de la méthode [33]. Les paramètres de base de PSO sont la taille des essaims (nombre de particules), le nombre d'itérations, les composantes de la vitesse, et les coefficients d'accélération.

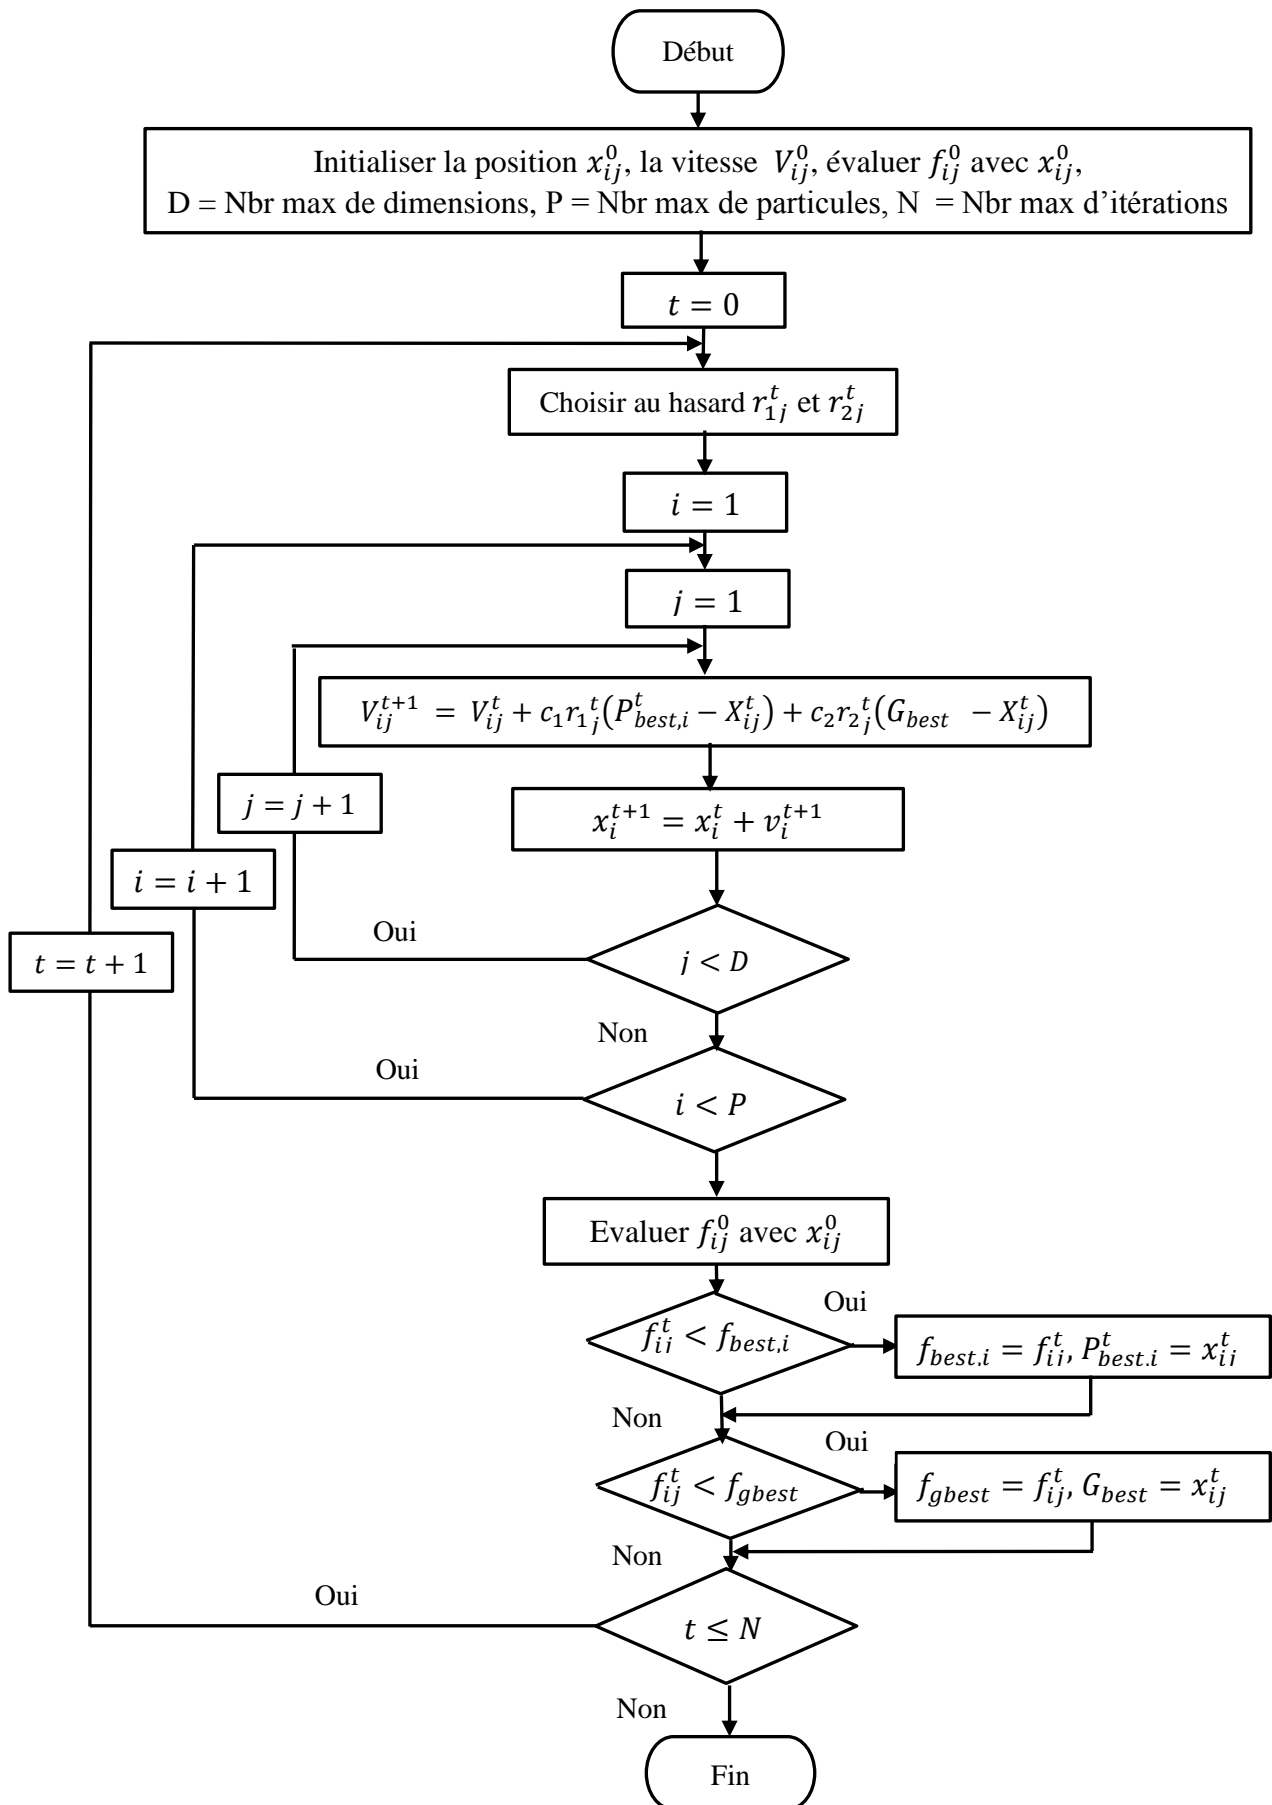


Figure I.14. Algorithme gbest PSO

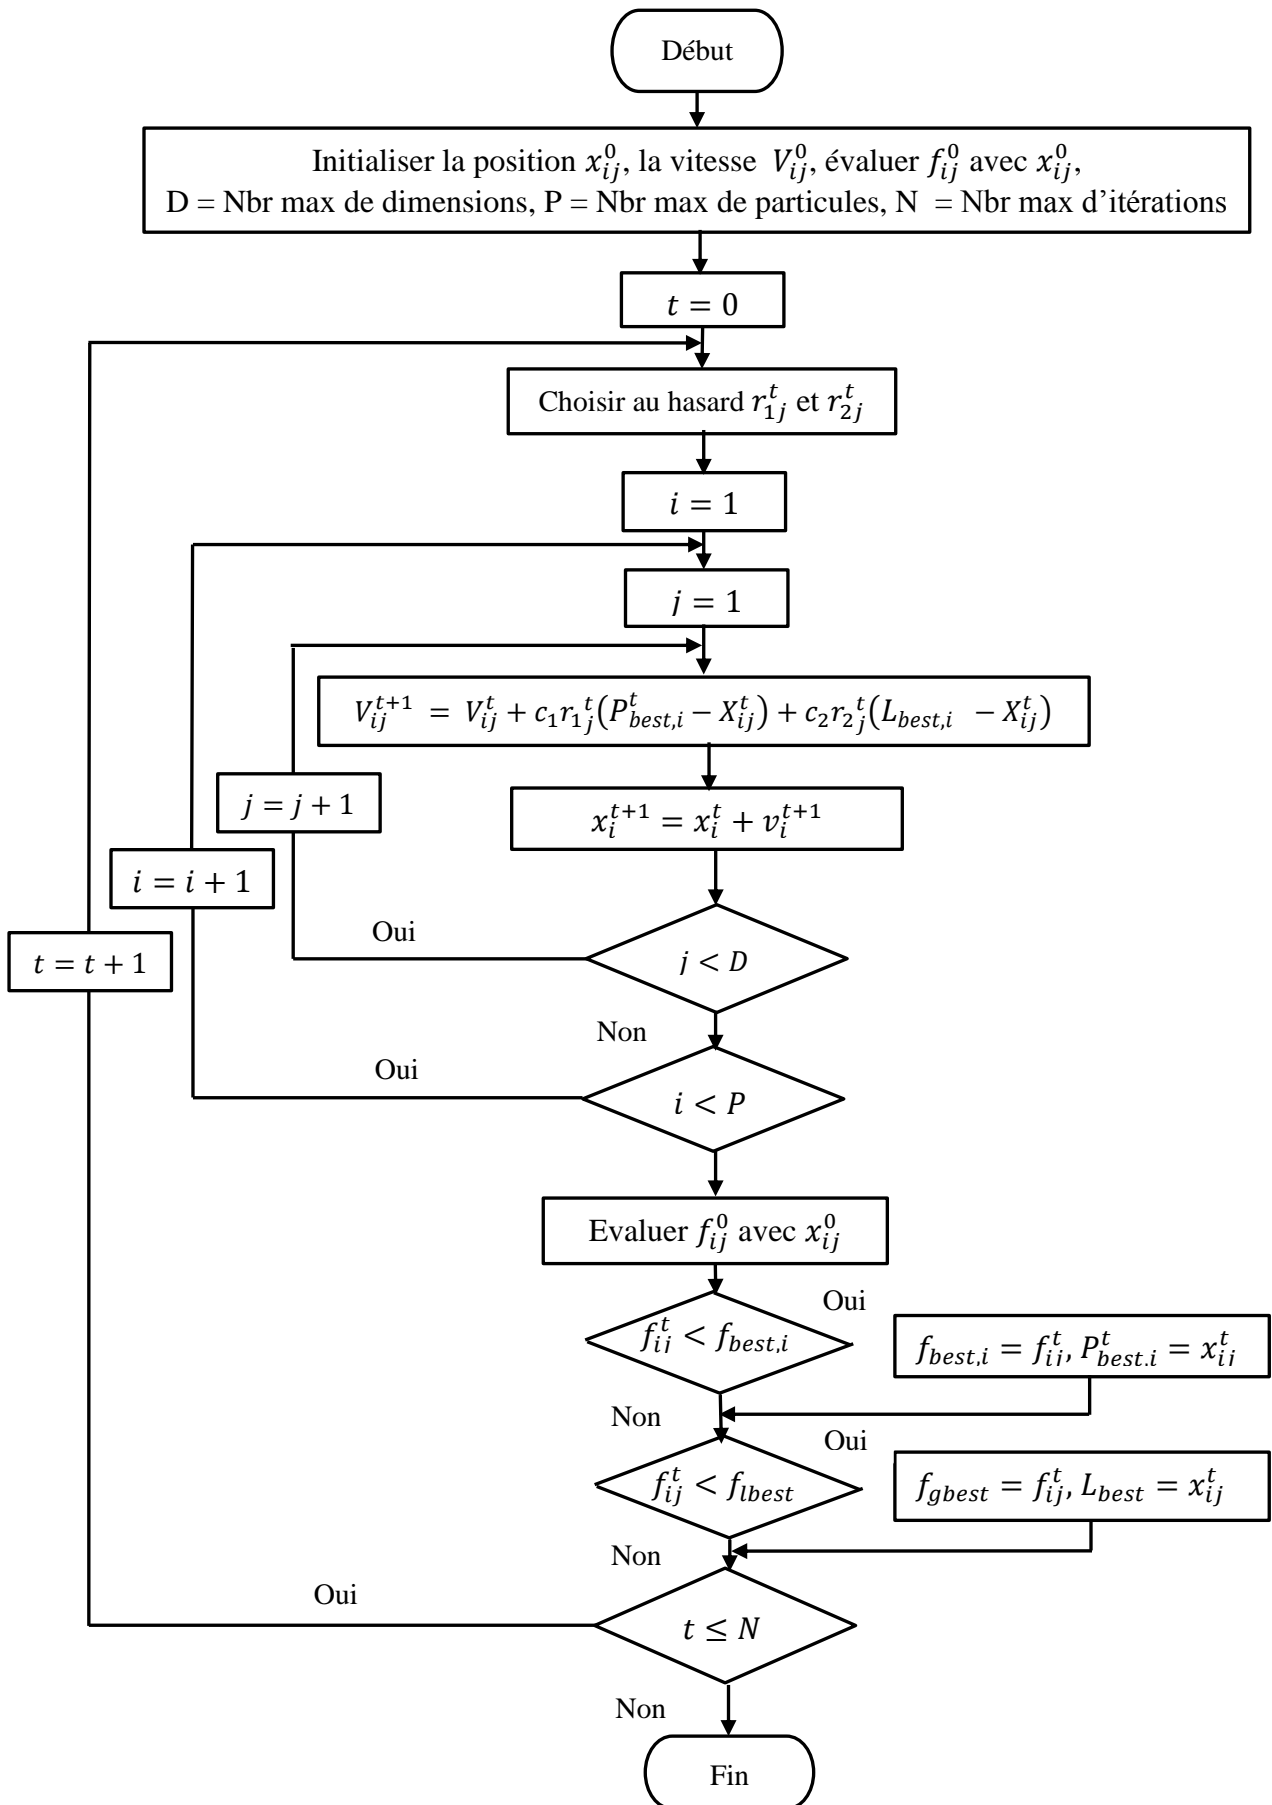


Figure I.15. Algorithme lbest PSO

➤ La taille de l'essaim

La taille d'essaim ou la taille de la population est le nombre de particules dans l'essaim. Un essaim ayant un grand nombre de particules génère de grandes parties dans l'espace de recherche à couvrir pour chaque itération. En revanche, d'énormes quantités de particules augmentent le temps d'optimisation et la complexité de calcul. De nombreuses études empiriques ont montrées que la plupart des implémentations de l'algorithme PSO utilisent un intervalle fini pour la taille d'essaim [31].

➤ Le nombre d'itérations

Le nombre d'itérations influe énormément sur la résolution du problème d'optimisation : un petit nombre d'itérations peut arrêter le processus de recherche prématurément, tandis que trop d'itérations peuvent compliquer les calculs et prendre plus de temps que nécessaire [31].

➤ Les composantes de la vitesse

Les composantes de la vitesse sont des facteurs très importants pour mettre à jour la vitesse de la particule. La composante de la vitesse se compose de trois termes (équations I.8 et I.9) :

1. Le terme V_{ij}^t est la composante d'inertie qui fournit une mémoire de la direction du vol précédent, il représente une impulsion qui empêche de changer radicalement l'orientation des particules afin de polariser l'essaim dans le sens du courant.
2. Le terme $c_1 r_1^t (P_{best,i}^t - X_{ij}^t)$ est la composante cognitive qui mesure la performance des particules par rapport aux performances passées, elle ressemble à une mémoire individuelle de la meilleure position pour la particule. L'effet de la composante cognitive (appelée « la nostalgie de la particule ») représente la tendance des individus à revenir à des positions qui les satisfaisaient plus dans le passé.
3. Le terme $c_2 r_2^t (G_{best} - X_{ij}^t)$ pour gbest PSO ou $c_2 r_2^t (L_{best,i} - X_{ij}^t)$ pour lbest PSO est la composante sociale qui mesure la performance des particules i par rapport à un groupe de particules voisines. L'effet de la composante sociale est que chaque particule vole vers la meilleure position trouvée par le voisinage de la particule.

➤ Les coefficients d'accélération

Les coefficients d'accélération c_1 et c_2 , ainsi que les valeurs aléatoires r_1 et r_2 maintiennent l'influence stochastique des composantes cognitives et sociales de la vitesse de la particule respectivement. La constante c_1 exprime combien la confiance d'une particule a en elle-même,

tandis que c_2 exprime combien la confiance d'une particule a en ses voisins [31]. Ci-après quelques propriétés concernant c_1 et c_2 :

- Lorsque $c_1 = c_2 = 0$, toutes les particules continuent à voler à leur vitesse actuelle jusqu'à ce qu'elles atteignent la limite de l'espace de recherche. Par conséquent, à partir des équations (I.8) et (I.9), l'équation de mise à jour de la vitesse est calculée comme suit :

$$V_{ij}^{t+1} = V_{ij}^t \quad (\text{I.10})$$

- Lorsque $c_1 > 0$ et $c_2 = 0$, toutes les particules sont indépendantes. L'équation de mise à jour de vitesse sera alors :

$$V_{ij}^{t+1} = V_{ij}^t + c_1 r_{1j}^t (P_{best,i}^t - X_{ij}^t) \quad (\text{I.11})$$

Au contraire, lorsque $c_2 > 0$ et $c_1 = 0$, toutes les particules sont attirées par un seul point (G_{best}) dans tout l'essaim et la vitesse de mise à jour sera:

$$V_{ij}^{t+1} = V_{ij}^t + c_2 r_{2j}^t (G_{best} - X_{ij}^t) \text{ Pour gbest PSO} \quad (\text{I.12})$$

$$\text{Or, } V_{ij}^{t+1} = V_{ij}^t + c_2 r_{2j}^t (L_{best,i} - X_{ij}^t) \text{ Pour lbest PSO} \quad (\text{I.13})$$

- Lorsque $c_1 = c_2$, toutes les particules sont attirées vers la moyenne de $P_{best,i}^t$ et G_{best} .
- Lorsque $c_1 \gg c_2$, chaque particule est plus fortement influencée par sa meilleure position personnelle, ce qui entraîne l'errance excessive. En revanche, lorsque $c_2 \gg c_1$ toutes les particules sont beaucoup plus influencées par la meilleure position globale, ce qui conduit toutes les particules à fonctionner prématurément à l'optima [31, 34].

Normalement, c_1 et c_2 sont statiques, leurs valeurs optimisées sont trouvées empiriquement. L'initialisation incorrecte de c_1 et c_2 peut entraîner un comportement divergent ou cyclique [31]. À partir des différentes recherches empiriques, il a été proposé que les deux constantes d'accélération doivent être $c_1 = c_2 = 2$ [31].

d. Illustration géométrique du PSO

La mise à jour de la vitesse pour les particules se compose de trois éléments suivant les équations (I.8) et (I.9). La figure I.16 illustre la façon dont les trois composantes de la vitesse contribuent à déplacer la particule vers la meilleure position globale au pas de temps t et $t + 1$, respectivement. La figure I.17 montre les mises à jour de position pour plus d'une particule

dans un espace de de recherche bidimensionnel dans la méthode gbest PSO. La position optimale est désignée par le symbole '✱'. La figure I.17 (a) montre la position initiale de toutes les particules ayant la meilleure position globale. La composante cognitive est nulle à $t = 0$ et toutes les particules ne sont attirées que vers la meilleure position par le composant social. De là, la meilleure position globale ne change pas. La figure I.17 (b) montre les nouvelles positions de toutes les particules et la nouvelle meilleure position globale après la première itération à $t = 1$.

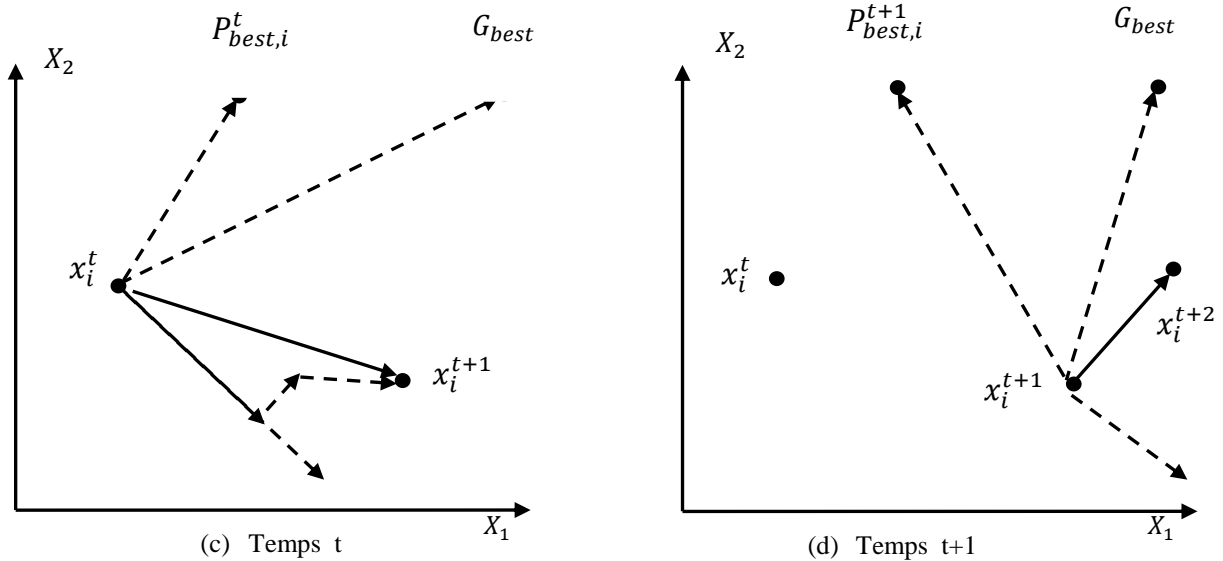


Figure I.16. Mise à jour de la vitesse et la position d'une particule dans un espace de recherche bidimensionnel




Figure I.17. Mise à jour de la vitesse et la position des multi-particules dans gbest PSO




Figure I.18. Mise à jour de la vitesse et la position des multi-particules dans lbest PSO

La figure I.18 illustre la manière dont toutes les particules sont attirées par leur voisin immédiat dans l'espace de recherche dans la méthode lbest PSO. La figure I.18 (a) montre les particules a , b et c se déplaçant vers la particule d , qui est à la meilleure position dans le 1er sous-ensemble. Dans le 2ème sous-ensemble, les particules e et f se déplacent vers la particule g . De même, les particules h et j se déplacent vers la particule i dans le sous-ensemble 3 à l'instant $t=0$. Figure I.18 (b) montre que à l'instant $t = 1$, la particule d est la meilleure position pour sous-ensemble 1 de sorte que les particules a , b et c se déplacent vers d .

I.3.2.2 L'algorithme d'optimisation "colonies de fourmis"

L'optimisation par colonies de fourmis (ACO : Ant Colony Optimization) initialement proposé par Marco Dorigo en 1992, est une autre approche bio-inspirée pour résoudre des problèmes d'optimisation [35, 36]. Contrairement aux algorithmes évolutionnaires, où les solutions sont construites à partir de la série actuelle de solutions, les solutions sont dans ce cas obtenues par des marches aléatoires sur un graphe direct. L'optimisation par colonies de fourmis est inspirée par la recherche d'une colonie de fourmis d'une source commune de nourriture. Il a été remarqué que les fourmis trouvent très rapidement le chemin le plus court à une source de nourriture, l'information sur la voie à suivre pour arriver à la nourriture est distribuée entre les fourmis en leur laissant sur le chemin un morceau de l'information appelée phéromone. Les valeurs de ces derniers sont plus grandes sur les plus courts chemins après une courte durée. La figure I.19 illustre le phénomène observé d'une colonie de fourmis à la recherche d'une source de nourriture.




Figure I.19. Etapes de la recherche de nourriture par une colonie de fourmis [37]

a. Construction des solutions

Les solutions d'un problème d'optimisation donné sont obtenues par des marches aléatoires de fourmis sur une construction graphique ayant des valeurs positives (les valeurs de phéromone), ces valeurs influencent les marches aléatoires d'une façon telle que les bords ayant des grandes valeurs ont une plus grande probabilité d'être traversés. En outre, le modèle d'algorithmes ACO nous permet d'inclure des informations heuristiques pour guider les marches aléatoires, cette information influe en outre la probabilité de quel sommet à la prochaine visite [36]. Dans un algorithme ACO, chaque fourmi de la colonie exploite la construction graphique à la recherche d'une solution optimale : Supposons que la colonie de fourmis est un ensemble $A = \{a_1, \dots, a_k\}$ de k fourmis, chaque a_i a une mémoire qui peut être utilisée pour stocker des informations sur le chemin qu'il a suivi jusqu'à présent, cette mémoire peut être utilisée pour construire des solutions réalisables, calculer une valeur heuristique η , évaluer la solution qui a été trouvée et revenir sur le chemin vers l'arrière.

En une seule étape, une fourmi se déplace d'un sommet v de la construction graphique à l'un de ses successeurs, ce mouvement est choisi sur la base d'une règle probabiliste et dépend des valeurs des phéromones sur les bords, de l'information heuristique associée à des composants et des connexions dans le voisinage de v , de la mémoire privée de la fourmi et des contraintes du problème. Lors de l'ajout d'un composant à la solution de la fourmi édifiée, l'algorithme peut mettre à jour la valeur de la phéromone de la connexion qui correspond à cette solution. Habituellement, les valeurs de phéromone sont mises à jour après que la solution complète a été construite. Ainsi, la fourmi retrace le chemin qu'il a fallu pour construire la solution et augmente les valeurs de phéromone le long de ces bords [35].

Soit $C=(V,E)$ la construction graphique d'un problème donné, la valeur de la phéromone d'un bord $e = (u, v) \in E$ est désignée par $\tau(u, v)$. En outre, il est possible d'affecter à chaque bord $(u, v) \in E$ un morceau d'information heuristique $\eta(u, v)$. Supposons que la fourmi est au sommet u et représente l'ensemble des successeurs par $N(u)$, en raison des contraintes du problème, cet ensemble peut être un sous-ensemble des successeurs de u en C . La probabilité que les fourmis visitent le sommet $v \in N(u)$ dans l'étape suivante est donnée par [35] :

$$P_v = \frac{[\tau(u,v)]^\alpha \cdot [\eta(u,v)]^\beta}{\sum_{\omega \in N(v)} [\tau(u,\omega)]^\alpha \cdot [\eta(u,\omega)]^\beta} \quad (\text{I.11})$$

Où : $\alpha, \beta \geq 0$ sont des paramètres qui déterminent l'importance des valeurs du phéromone et de l'information heuristique, respectivement.

b. Mise à jour des phéromones

Dans la procédure de mise à jour d'un algorithme ACO, les valeurs de la phéromone sont généralement diminuées d'une quantité qui dépend du facteur d'évaporation ρ , $0 \leq \rho \leq 1$ [35].

Soit $\tau(u, v)$ la valeur de la phéromone sur un bord $(u, v) \in E$ avant la mise à jour, cette valeur est réduite à $(1 - \rho) \tau(u, v)$ dans une première étape, cela implique que les informations sur les chemins d'accès prises en avant se perdent au cours de l'exécution de l'algorithme et aide à échapper aux optima locaux. En outre, les valeurs de la phéromone sur les bords d'une fourmi a_i sont augmentées d'une valeur i qui peut dépendre de ρ , ainsi que sur la valeur de la fonction de la solution que la fourmi a_i a construit. Par conséquent, la valeur de la phéromone $\tau'(u, v)$ du bord (u, v) après la mise à jour est donnée par :

$$\tau'_{(u,v)} = (1 - \rho)\tau_{(u,v)} + \sum_{i=1}^k \Delta_i \quad (\text{I.12})$$

➤ Règles de mise à jour des phéromones :

Il existe plusieurs règles pour la mise à jour des phéromones : Si toutes les fourmis de la colonie laissent des valeurs de phéromone sur les bords, ceci est connu comme la règle AS, c'est la première règle de mise à jour du ACO [35]. Dans cette règle, le montant par lequel une fourmi augmente une valeur de phéromone devrait dépendre de la valeur de la fonction de la solution construite, sinon les valeurs de phéromone sont totalement indépendantes de la fonction f à optimiser. Si cela est le cas, il ne serait pas possible de diriger la recherche.

Une autre règle de mise à jours est appelée IB ou « meilleur itération (Iteration-best) » : dans cette règle, les fourmis qui ont construit les meilleures solutions de la dernière itération

mettent à jour les valeurs de phéromone le long des bords qu'elles ont prises, cette règle introduit une tendance plus forte vers les meilleures solutions trouvées jusqu'à présent.

Enfin, dans la mise à jour BS (best-so-far) : les valeurs des phéromones sur les bords de la meilleure solution construite depuis la première itération de l'algorithme sont augmentées à chaque itération.

I.4 Conclusion

Les algorithmes inspirés par la biologie ont reçu beaucoup d'intérêt ces derniers temps en raison de leurs performances et leurs capacités exceptionnelles pour la résolution des problèmes théoriques et expérimentaux. A cela s'ajoute leurs grandes aptitudes à être facilement appliqués dans divers domaines. En fait, ils ont un fort potentiel pour aborder certains défis associés aux problèmes d'optimisation, de commande adaptatif et robuste des systèmes complexes, de traitement d'image...etc. Ce chapitre a donc été consacré à la présentation de l'état de l'art de ces techniques bio-inspirés: ainsi nous avons présenté les structures de commande inspirés du système immunitaire connus pour sa grande robustesse et adaptabilité, et les réseaux neuronaux pour leur capacité d'apprentissage. Enfin les techniques d'optimisation bio-inspirées les plus récentes à savoir PSO et ACO ont été présentées. Toutes ces méthodes (seules ou combinées) vont faire l'objet d'applications diverses dans les prochains chapitres afin d'évaluer leurs performances.

Chapitre II

Conception d'une loi de commande robuste inspirée par le système immunitaire

II.1 Introduction

Les dernières années ont connu l'émergence d'un grand nombre de techniques de commandes innovantes bio-inspirées, l'une des plus prometteuses d'entre elles est le système immunitaire artificiel, ce dernier est inspiré par le mécanisme de régulation du système immunitaire, connu par sa robustesse et son auto-adaptation dans des environnements perturbés. Dans ce contexte, on propose dans ce chapitre la conception d'une loi de commande robuste basée sur le principe de la rétroaction immunitaire en se focalisant sur le circuit de contre-réaction immunitaire des cellules T. Dans une deuxième phase, pour le réglage optimal de notre contrôleur robuste obtenu précédemment, on utilisera une méthode d'optimisation directe (Nelder Mead) ainsi que trois algorithmes bio-inspirés, pour la commande d'un système à retard mal conditionné, les résultats en termes de robustesse et performances seront commentés et comparés.

II.2 La commande robuste

La théorie de la commande robuste a connu un essor remarquable durant ces dix dernières années, sa popularité gagne aujourd'hui largement le milieu industriel où elle se révèle un outil précieux pour l'analyse et la conception des systèmes asservis. Cette percée rapide tient à deux atouts majeurs [38]:

- son caractère appliqué et son adéquation aux problèmes pratiques de l'ingénieur automaticien (prise en charge des différentes perturbations et incertitudes).
- sa contribution à la systématisation du processus de synthèse d'un asservissement.

Pour apprécier l'originalité et l'intérêt des outils de la commande robuste, rappelons qu'un asservissement a deux fonctions essentielles:

- façonner la réponse du système asservi pour lui imprimer le comportement désiré,
- maintenir ce comportement face aux aléas et fluctuations qui affectent le système pendant son fonctionnement (rafales de vent pour un avion, usure pour un système mécanique, changement de configuration pour un robot, etc.).

Cette seconde exigence est qualifiée de "robustesse à l'incertitude", elle revêt une importance critique pour la fiabilité du système asservi. En effet, l'asservissement est typiquement conçu à partir d'un modèle idéalisé et simplifié du système réel ; pour fonctionner correctement, il doit donc être robuste aux imperfections du modèle, c'est-à-dire aux écarts entre le modèle et le système réel, aux dérives des paramètres physiques, et aux perturbations externes [38].

La commande robuste prend en compte, non seulement le modèle nominal mais aussi un ensemble de modèles incertains définis (bornés), de façon à garantir la stabilité et les performances désirées en boucle fermée pour tous ces modèles, cette tâche est d'autant plus compliquée qu'il existe plusieurs types d'incertitudes (structurées ou non structurées) qui peuvent agir sur le système réel en plusieurs points de la boucle (en entrée, en sortie ou de façon additive). On dira alors qu'un système est robuste s'il demeure stable et garde les performances désirées en présence de ces différentes incertitudes.

Il existe deux types d'incertitudes : les incertitudes structurées et les incertitudes non structurées, elles sont classées selon la structure, les origines des erreurs du modèle ainsi que la manière dont elles influent sur le comportement du système.

➤ **Incertainces structurées**

Les incertitudes structurées ou paramétriques sont essentiellement liées aux variations ou erreurs d'estimation des paramètres physiques du système, elles interviennent principalement lorsque le modèle est obtenu à partir d'équations de la physique et peuvent apparaître directement sur les grandeurs physiques du système ou simplement sur le paramètre de son modèle mathématique [39].

➤ **Incertitudes non structurées**

Ce type d'incertitudes englobe les erreurs non mesurables et les dynamiques négligées dans le modèle nominal, pour toute information les concernant, on dispose, en général d'une borne supérieure sur leurs normes décrivant leurs impacts sur le modèle réel dans une plage fréquentielle définie.

Lorsque la partie commandée du processus est faiblement perturbée, les commandes classiques, par exemple à action proportionnelle intégrale dérivée, peuvent s'avérer suffisantes si les exigences en précision et en performance du système ne sont pas trop sévères. Dans le cas contraire, il faut concevoir des algorithmes de commande assurant une robustesse du comportement dynamique du processus vis-à-vis des incertitudes sur les paramètres.

II.3 Conception d'une loi de commande robuste inspirée du système immunitaire

Le système immunitaire biologique est un système de commande très fiable qui possède une auto-adaptation innée à des perturbations complexes. En s'inspirant de ce système, un algorithme immunitaire artificiel est proposé pour la conception d'un contrôleur ayant les capacités de rejet de perturbation et d'auto-adaptation.

II.3.1 Mécanisme de la rétroaction immunitaire

Dans cette section, nous décrivons la loi de rétroaction immunitaire sur la base du mécanisme de contre-réaction du système immunitaire. Pour simplifier notre conception, nous devons faire quelques hypothèses vu que le système immunitaire biologique est assez complexe et l'ensemble de ses mécanismes ne sont pas à nos jours clairement compris. En se concentrant sur le circuit immunitaire des cellules T [40, 41], considérons le simple mécanisme de contre-réaction comme indiqué sur la figure II.1, composée essentiellement de deux types de cellule : les lymphocytes et les anticorps, il existe deux types de lymphocytes: les cellules T eux même divisés en cellules T auxiliaires (T_h) et cellules T suppressives (T_s), l'autre type sont les cellules B. Dès l'invasion de l'organisme par les antigènes, l'information est perçue par les cellules T_h qui elles-mêmes stimulent les cellules B en leurs fournissant toutes les informations concernant les antigènes, les cellules B produisent alors des anticorps spécifiques pour éliminer les antigènes, le processus continu (et le nombre de cellules T_h continue à croître) tant que la quantité d'antigènes est importante, dès que celle-ci commence à diminuer, les cellules suppressives T_s entrent en jeux et commencent à éliminer les cellules

T_h et B jusqu'au retour à la situation normale, c'est-à-dire : élimination totale des antigènes et stabilisation du systèmes immunitaire.




Figure II.1. Schéma du système de régulation immunitaire

Le mécanisme de la réaction immunitaire des cellules T est décrit dans le tableau II.1.

Tableau II.1. Réactions immunitaires des cellules T

| Réponse immunitaire | Concentration d'antigènes | Concentration d'anticorps | Action de cellules T |
|-----------------------|---------------------------|---------------------------|----------------------|
| Invasion d'Antigène | Haute | Très faible | ----- |
| invasion préliminaire | Haute | Faible | Stimulation |
| Étape ultérieur | Faible | Haute | Suppression |
| Étape finale | Très faible | Faible | ----- |

II.3.2 Modélisation de la loi de rétroaction immunitaire

La coopération entre le mécanisme d'inhibition et le mécanisme de rétroaction principal, permet au système de régulation immunitaire de répondre rapidement à l'invasion de corps étrangers et à stabiliser rapidement le système immunitaire.

Pour simplifier, supposons que l'activation et l'inhibition sont toutes les deux imposées sur les cellules B , donc l'effet d'activation sur les cellules B est égal à la différence entre l'activation des cellules T_H et l'inhibition de cellules T_S [42, 43]:

$$B(k) = T_h(k) - T_s(k) \quad (\text{II.1})$$

$$T_h(k) = k_1 \varepsilon(k) \quad (\text{II.2})$$

$$T_s(k) = k_2 \{ f[\Delta B(k-d)] \} \varepsilon(k) \quad (\text{II.3})$$

Où $\varepsilon(k)$ est la concentration des antigènes à la k^{th} génération, K_1 est le facteur de stimulation, et K_2 est le facteur de suppression. $\Delta B(k-d)$ est le changement de la cohérence de cellules B et d est le temps de retard de la réponse immunitaire.

$f(x)$ est une fonction non linéaire qui représente l'interaction entre les anticorps qui émergent des cellules B et les antigènes, elle est donnée par: [40]

$$f(x) = 1 - \exp\left(-\frac{x^2}{a}\right) \quad (\text{II.4})$$

Où a est un paramètre qui sert à modifier la forme de la fonction f . La figure II.2 représente la forme de $f(x)$ pour différentes valeurs de a .




Figure II.2. La forme de $f(x)$ pour différentes valeurs de a

La fonction non linéaire $f(x)$ agit selon l'évolution de la quantité d'antigènes: si cette quantité est en train d'augmenter ($\Delta B(k-d)$ augmente : partie I de la figure II.), alors $f(x)$ doit accroître l'effet des anticorps (B) rapidement afin de les réduire rapidement et si les antigènes sont entrain de diminuer sous l'effet des anticorps B (partie II de la figure II.2), alors la fonction f doit minimiser la production de ces derniers afin d'arriver à un équilibre immunitaire ($f=1$). L'effet de robustesse apporté par la fonction f (élimination rapide de tout effet perturbant : invasion d'antigènes et autres organismes ainsi qu'un retour rapide à l'état d'équilibre) apparait clairement.

De (Eq. II.2) et (Eq. II.3), on peut obtenir la formule de l'interaction entre les cellules B et les antigènes, comme suite:

$$B(k) = k_1 \varepsilon(k) - k_2 \{f[\Delta B(k-d)]\} \varepsilon(k) \quad (\text{II.5})$$

$$B(k) = k\{1 - \eta f[\Delta B(k - d)]\}\varepsilon(k) \quad (\text{II.6})$$

Où : $k = k_1$ et $\eta = k_2/k_1$.

Le paramètre k est utilisé pour contrôler la vitesse de la réponse, alors que le paramètre η est utilisé pour contrôler l'effet de stabilisation. Par conséquent, la performance de la loi de contre-réaction immunitaire dépend fortement de la manière dont ces facteurs sont sélectionnés. Enfin, la loi de rétroaction immunitaire est représentée schématiquement sur la figure II.3.

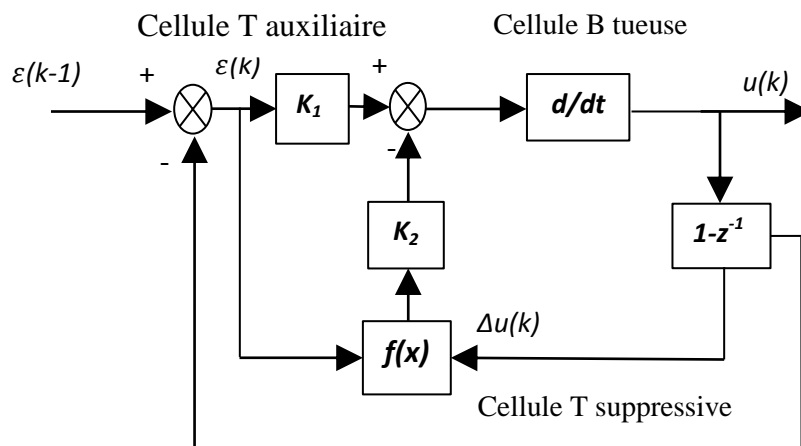


Figure II.3. Schéma bloc de la boucle de rétroaction immunitaire

II.3.3 Conception du contrôleur IMF-PID

Il existe plusieurs similitudes entre le fonctionnement du système immunitaire expliqué précédemment (figure II.3) et un système commandé en boucle fermée représenté par la figure suivante :




Figure II.4. Système commandé en boucle fermée

En considérant le numéro de génération k comme un nombre d'un échantillon d'un système dynamique discret, en traitant la quantité des matériaux étrangers $\varepsilon(k)$ comme une erreur de commande donnée par :

$$e(k) = y_d(k) - y(k) \quad (\text{II.7})$$

Où $y_d(k)$ est la sortie souhaitée du système et $y(k)$ est la sortie du système réel. En utilisant la quantité des cellules T tueuses comme une entrée de commande $u(k)$, l'analogie entre le mécanisme du système immunitaire et une boucle de commande classique est exprimée dans le tableau II.2.

Tableau II.2. Analogie entre le système immunitaire artificielle et une boucle de commande

| Systeme immunitaire | Boucle de commande |
|---|--|
| La reproduction de génération k^{th} des antigènes et des anticorps. | Le temps d'échantillon k^{th} du système discret. |
| $\varepsilon(k)$ est la concentration des antigènes de la k^{th} ème génération. | $e(k)$ est la déviation entre la valeur de consigne et de la valeur de sortie au moment de l'échantillon k^{th} . |
| $B(k)$ est la concentration des cellules B de la k^{th} ème génération. | $u(k)$ est la valeur de sortie du régulateur à la k^{th} ème d'échantillon. |

L'équation (II.6) peut être considérée comme une loi de commande d'un contrôleur proportionnel (non linéaire) appelé contrôleur IMF de type P discret, sa loi de commande peut être écrite comme suit [44]:

$$u(k) = k\{1 - \eta f[\Delta u(k - d)]\}e(k) = k_{pI}e(k) \quad (\text{II.8})$$

Où k_{pI} est le gain proportionnel non linéaire du contrôleur IMF.

II.3.3.1 Loi de commande du contrôleur IMF-PID

Vu que le contrôleur IMF est de type proportionnel, il ne pourrait pas compenser l'erreur de commande provoquée par le bruit existant et/ou les perturbations qui agissent sur le système, d'où l'idée de lui rajouter une action intégrale et une action dérivée pour aboutir à un contrôleur IMF-PID dont la structure est représentée sur la figure II.5.

La loi de commande du contrôleur PID peut être exprimée comme suit :

$$u_{pid}(k) = k_p \left(1 + \frac{k_i}{z-1} + K_d \frac{z-1}{z} \right) e(k) \quad (\text{II.9})$$

Où k_p , k_i et k_d sont les coefficients des actions proportionnelle, intégrale et dérivée, respectivement.

La loi de commande du contrôleur IMF-PID obtenue devient donc comme suit :

$$u(k) = k_p \{1 - \eta f[\Delta u(k - d)]\} \left(1 + \frac{k_i}{z-1} + K_d \frac{z-1}{z} \right) e(k) \quad (\text{II.10})$$

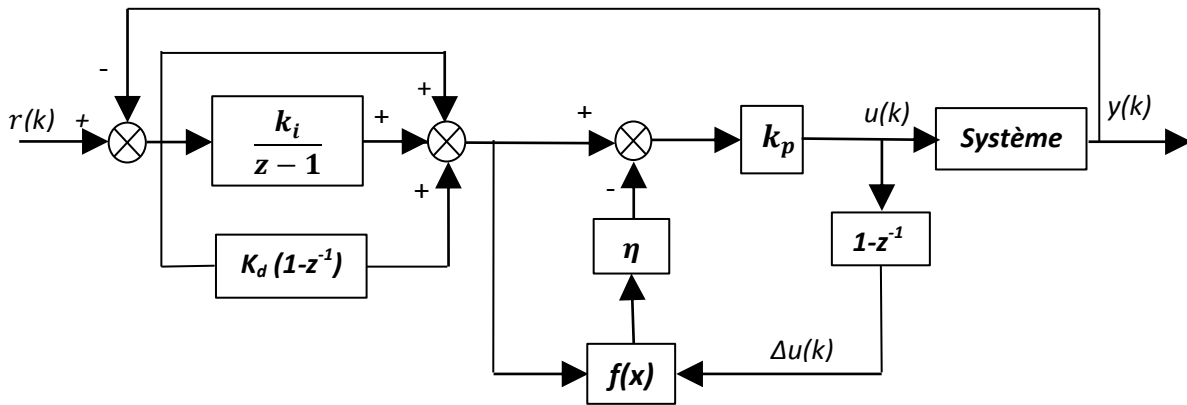


Figure II.5. Schéma du contrôleur IMF-PID


II.3.3.2 Choix de la fonction $f(x)$

Le choix de la fonction f est prépondérant pour la robustesse ainsi que les performances de notre contrôleur IMF-PID, en effet le bon choix de cette dernière va améliorer la robustesse de notre contrôleur tout en accélérant la réponse du système et en éliminant rapidement l'erreur, en effet, si on considère l'augmentation de la quantité d'antigènes comme tout effet des perturbations augmentant l'erreur de poursuite (la référence étant l'équilibre immunitaire: pas d'antigènes et pas d'anticorps), alors l'effet de robustification de la fonction f est clairement établie. La fonction f étant non linéaire, il existe plusieurs méthodes pour la modéliser, la plus utilisée étant la modélisation par la logique floue.

La logique floue est une extension de la logique booléenne créée par Lotfi Zadeh en 1965 en se basant sur sa théorie mathématique des ensembles flous, il s'agit d'une généralisation de la théorie des ensembles classiques en introduisant la notion de degré dans la vérification d'une condition, permettant ainsi à une condition d'être dans un autre état que vrai ou faux. La logique floue confère une flexibilité très appréciable aux raisonnements qui l'utilisent, ce qui rend possible la prise en compte des imprécisions, des incertitudes, et des non linéarité [45].

➤ Modèle flou de la fonction $f(x)$:

Cette technique étant largement vulgarisée de nos jours, nous allons directement présenter notre modèle flou de la fonction f illustré dans la figure suivante:

Figure II.6. Le modèle flou de la fonction $f(x)$

Le modèle de Mamdani a été choisi dans la conception du modèle flou modélisant la fonction non linéaire $f(x)$, ce modèle ayant deux entrées et une sortie, il possède les caractéristiques suivantes :

- ✓ les deux variables d'entrée sont la sortie du contrôleur IMF $u(k)$ et sa variation $\Delta u(k)$, tandis que la variable de sortie est la quantité de suppression des cellules T_S $f(u(k), \Delta u(k))$.
- ✓ Les opérateurs linguistiques d'entrée sont cinq ensembles flous: NB (Negative Big), NS (Negative Small), ZE (Zero), PS (Positive Small) et PB (Positive Big) ; les opérateurs linguistiques de sortie sont sept ensembles flous: NB, NM (Negative medium), NS, ZE, PS, PM (Positive Medium) et PB.
- ✓ Les fonctions d'appartenance choisies sont toutes définies dans l'intervalle $(-6, +6)$.

Selon le principe de la régulation immunitaire expliqué précédemment, les règles floues peuvent être représentées par le tableau II.3, tandis que les fonctions d'appartenance d'entrée et de sortie sont illustrées dans les figures II.7 et II.8 respectivement.

Tableau II.3. Les règles floues de la fonction $f(x)$

| u(k) | $\Delta u(k)$ | | | | |
|-------------|---------------------------------|-----------|-----------|-----------|-----------|
| | NB | NS | ZE | PS | PB |
| NB | <i>PB</i> | <i>PB</i> | <i>PM</i> | <i>PS</i> | <i>ZE</i> |
| NS | <i>PB</i> | <i>PM</i> | <i>PS</i> | <i>ZE</i> | <i>NS</i> |
| ZE | <i>PM</i> | <i>PS</i> | <i>ZE</i> | <i>NS</i> | <i>NM</i> |
| PS | <i>PS</i> | <i>ZE</i> | <i>NS</i> | <i>NM</i> | <i>NB</i> |
| PB | <i>ZE</i> | <i>NS</i> | <i>NM</i> | <i>NB</i> | <i>NB</i> |




Figure II.7. Les fonctions d'appartenance d'entrée




Figure II.8. Les fonctions d'appartenance de sortie

Le schéma bloc du système immunitaire PID flou est représenté sur la figure II.9.

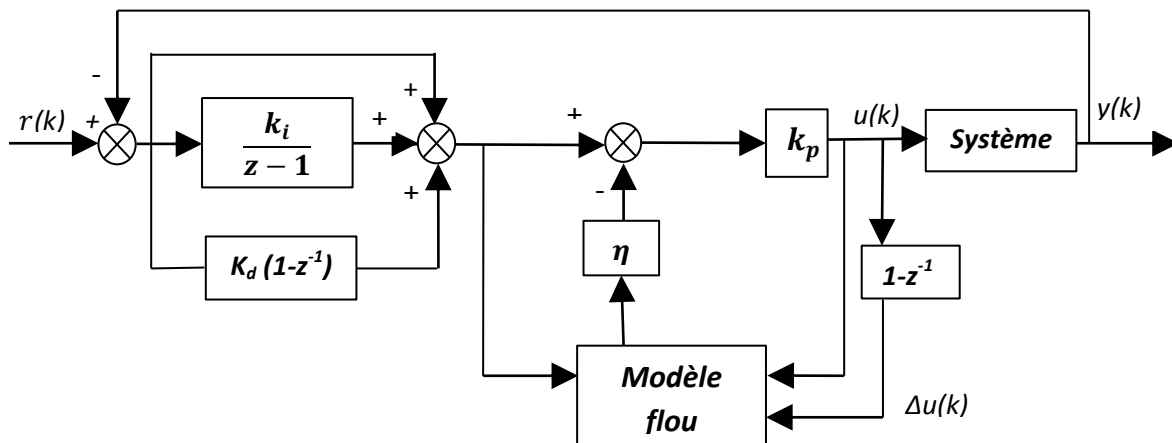


Figure II.9. Schéma bloc du contrôleur immunitaire PID flou

II.4 Réglage optimale des paramètres du contrôleur IMF-PID flou [46]

Dans ce qui suit, nous proposons une méthode de réglage robuste des paramètres (k_p , k_i , k_d , et η) de notre contrôleur IMF-PID flou, la procédure est divisée en deux étapes: la première est consacrée à l'ajustement des paramètres optimaux du régulateur PID, via la minimisation du critère de l'intégrale d'erreur absolue pondérée dans le temps (ITAE), par deux différents algorithmes d'optimisation bio-inspirés : PSO et ACO.

La deuxième étape concerne la consolidation de la robustesse (robustification) de la loi de commande de notre contrôleur, par rapport aux rejets de perturbations toujours via la minimisation du critère ITAE par les algorithmes bio-inspirés cités plus haut.

II.4.1 Première phase

Dans cette étape, nous nous concentrons uniquement sur le réglage optimal des trois paramètres (k_p , k_i , k_d) du régulateur PID pour obtenir de bonnes performances temporelles sans se soucier de la robustesse, cela signifie que le contrôleur immunitaire sera déconnecté de la loi de contrôle et reste comme dans l'équation (II.9), aucune perturbation ne sera considérée sur le système commandé dans cette étape ($d(k)=0$). Le schéma fonctionnel de la première phase est illustré ci-dessous:




Figure II.10. Schéma bloc de la première phase

Comme on l'a évoqué plus haut, on utilise des méthodes d'optimisation bio-inspirées pour obtenir les paramètres optimaux du contrôleur PID qui minimisent le critère ITAE définie par:

$$ITAE = \sum k|e(k)|dk \quad (II.11)$$

La minimisation de ce critère permet d'obtenir une erreur minimale en un temps minimal, le problème de minimisation devient alors comme suit :

$$\text{Min}_{k_p, k_i, k_d} |(k(r(k) - y(k)))| \quad (II.12)$$

II.4.2 Deuxième phase

Nous avons vu déjà que de par son fonctionnement, le contrôleur immunitaire artificiel possède une robustesse innée, nous allons maintenant nous concentrer sur l'amélioration de cette robustesse (par rapport au rejet de perturbations), nous utilisons pour cela sa partie immunitaire artificielle IMF. La stratégie consiste à fixer les paramètres optimaux (k_p , k_i , k_d) obtenus dans la première étape, et d'imposer une perturbation (échelon d'amplitude 15% du signal de référence) en la considérant comme la seule entrée du système ($r(k)=0$), il s'agira alors de trouver la valeur du paramètre η qui assure un rejet de perturbation optimal. Le schéma bloc de la deuxième étape est illustré par la figure suivante:

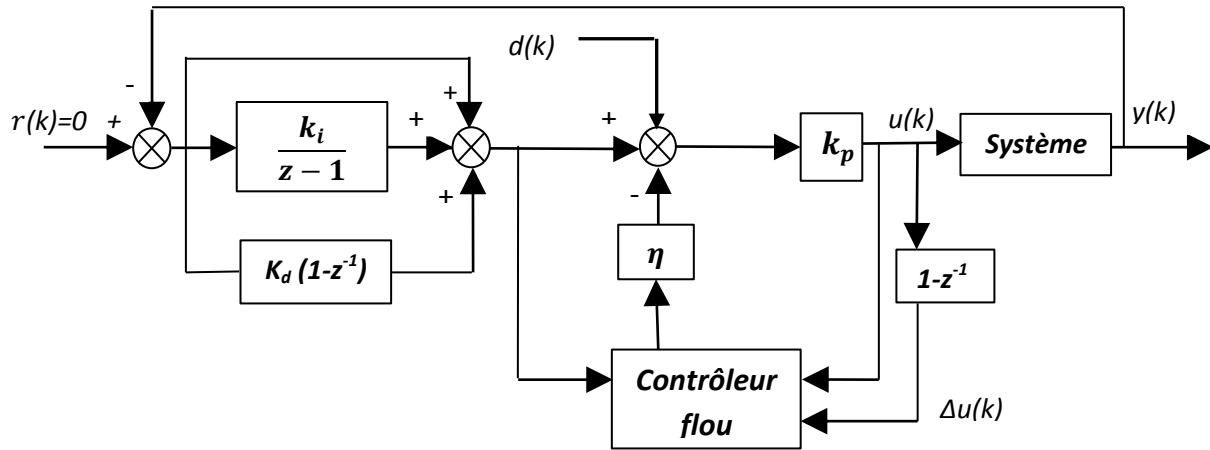


Figure II.11. Schéma bloc de la deuxième phase

Ce problème de minimisation devient alors comme suit :

$$\text{Min}_{\eta} |y(k)| \quad (\text{II.13})$$

II.5 Exemple d'application

Afin d'illustrer l'efficacité de la méthode proposée, nous allons dans ce qui suit l'appliquer sur un système à retard mal conditionné du deuxième ordre dont la fonction de transfert est donnée par:

$$G(s) = \frac{2(0.5s+1)e^{-0.1s}}{(s+1)(4s+1)}$$

Comme nous l'avons vu plus haut, les paramètres de notre contrôleur seront obtenus en résolvant les problèmes d'optimisation (Eq. II.12 et Eq II.13) Nous avons résolu ces problèmes par trois algorithmes d'optimisation bio-inspirés : PSO et ACO, les résultats seront comparés avec ceux des paramètres obtenus par une méthode d'optimisation directe du type simplex (la méthode de Nelder Mead).

II.5.1 Méthode d'optimisation à base d'algorithmes de recherche bio-inspirés

Les algorithmes d'optimisation bio-inspirés ont connus une évolution considérable ces dernières années. En effet, on assiste à l'émergence de plusieurs méthodes inspirées des différents phénomènes naturels plus efficaces les unes que les autres, parmi ces algorithmes :

II.5.1.1 L'optimisation par PSO

Dans l'optimisation par PSO, au lieu d'utiliser des opérateurs génétiques, les individus appelés « particules » sont évolués par la coopération et la concurrence entre eux à travers des générations. Une particule représente une solution potentielle à un problème. Chaque particule ajuste son vol en fonction de sa propre expérience et de l'expérience de ses compagnons. Dans notre application, chaque particule (ensemble de paramètres: k_p , k_i , k_d , et η) survole un espace de recherche à 4 dimensions pour rechercher la position optimale via l'algorithme PSO. Comme dans la procédure d'optimisation par GA, la terminaison de l'optimisation aura lieu lorsque le nombre maximal d'itérations est dépassé.

Les étapes pour optimiser les paramètres du contrôleur IMF-PID flou selon l'algorithme PSO sont les suivantes:

- Étape 1: Sélectionner le nombre de particules, les générations, les coefficients d'accélération de réglage et les nombres aléatoires pour démarrer la recherche.
- Étape 2: Initialiser la position et la vitesse de la particule.
- Étape 3: Sélectionner la meilleure valeur individuelle pour chaque génération.
- Étape 4: Choisir la particule ayant la meilleure valeur globale : la particule la plus proche de la cible parmi toutes les particules est obtenue en comparant toutes les meilleures valeurs individuelles.
- Étape 5: Mettre à jour la meilleure position individuelle P_{best} et la meilleure position globale G_{best} par l'équation (I.8) et obtenir la nouvelle vitesse optimale.
- Étape 6: Mettre à jour la nouvelle valeur de vitesse par l'équation (I.5) et obtenir la position de la particule.
- Étape 7: Déterminer si le nombre maximum d'itérations est atteint. Si oui, mettre fin à l'algorithme; sinon, revenir à l'étape 2.

Dans l'application de PSO, certains paramètres doivent être définis avant le démarrage de l'optimisation. La sélection de ces paramètres détermine en grande partie la capacité de minimisation globale. La vitesse maximale influe sur la capacité à échapper à l'optimisation locale et à affiner l'optimisation globale. La taille de l'essaim équilibre l'exigence d'optimisation globale et le coût de calcul. Les valeurs initiales de ces paramètres sont indiquées dans le tableau II.4.

Tableau II.4. Paramètres de l'algorithme PSO

| Paramètre | Valeur |
|-----------------------------|--------|
| Taille de la population | 50 |
| Nombre d'itérations | 50 |
| Constante de vitesse, c_1 | 1.4 |
| Constante de vitesse, c_2 | 1.4 |

II.5.1.2 L'optimisation par ACO

La méthode ACO est une approche d'optimisation inspirée par le comportement de fourrage des fourmis et leur capacité inhérente à trouver le chemin le plus court entre une source de nourriture et leur nid. Dans notre application, la population est représentée par une matrice 100×4 , où la fourmi sélectionne les paramètres optimaux k_p , k_i , k_d , et η du contrôleur en minimisant la fonction objective (Eq. II.12 et Eq. II.13).

Les étapes à suivre pour optimiser les paramètres du contrôleur selon l'algorithme ACO sont les suivants:

- Etape 1: Initialiser aléatoirement des solutions potentielles des paramètres (k_p , k_i , k_d , et η) en utilisant une distribution uniforme. Initialiser le tracé des phéromones et la valeur heuristique.
- Etape 2: Placez la $K^{\text{ème}}$ fourmi sur le nœud. Calculer la valeur heuristique associée à la fonction objective (minimisation du critère ITAE).
- Etape 3: Utilisez l'évaporation de phéromones donnée par l'équation (I.12) pour éviter une augmentation illimitée des pistes de phéromones et permettre l'oubli de mauvais choix.
- Etape 4: Évaluer les solutions obtenues en fonction des objectifs.
- Etape 5: Afficher les valeurs optimales des paramètres d'optimisation.
- Etape 6: Mettre à jour la phéromone selon les solutions optimales calculées à l'étape 5. Itérer de l'étape 2 jusqu'à ce que le maximum d'itérations soit atteint.

Dans l'optimisation par ACO, l'algorithme est testé pour différentes valeurs de paramètres en simulant le modèle pour différentes conditions de fonctionnement. Selon les essais, les

paramètres optimums utilisés pour vérifier les performances du contrôleur IMF-PID flou sont listés dans le Tableau II.5.

Tableau II.5. Paramètres de l'algorithme ACO

| Paramètre | Valeur |
|-----------------------|--------|
| Nombre de fourmis | 400 |
| Nombre de nœuds | 130 |
| Nombre de générations | 50 |
| Force des phéromones | 0.02 |
| Taux de décroissance | 0.84 |

Les valeurs des paramètres du contrôleur obtenues avec PSO et ACO sont indiquées dans le tableau suivant.

Tableau II.6. Paramètres du PID IMF flou avec les différents algorithmes

| Méthode de réglage | K_p | K_i | K_d | η |
|--------------------|--------|---------|--------|--------|
| PSO | 7.6047 | 11.0502 | 1.1060 | 1.3862 |
| ACO | 1.4233 | 0.4501 | 0.1952 | 0.4256 |

II.5.2 Méthode d'optimisation directe de type simplex (Méthode de Nelder Mead)

La méthode de Nelder Mead (NM) est un algorithme d'optimisation non-linéaire qui a été publiée par John Nelder et Mead en 1965, c'est une méthode numérique heuristique qui cherche à minimiser une fonction continue dans un espace à plusieurs dimensions.

Appelée également downhill simplex method, l'algorithme exploite le concept de simplexe qui est un polytope de $N+1$ sommets dans un espace à N dimensions. Partant initialement d'un tel simplexe, celui-ci subit des transformations simples au cours des itérations : il se déforme, se déplace et se réduit progressivement jusqu'à ce que ses sommets se rapprochent d'un point où la fonction est localement minimale [47].

L'optimisation de Nelder Mead se compose de B (le meilleur point), G (le bon point), W (le point le plus mauvais), M (le point du milieu), E (le point d'expansion), R (le point de réflexion), C (le point de construction) et S (le point de rétrécissement).

➤ **Le triangle initial BGW**

Soit $f(K)$ la fonction de minimisation pour laquelle la méthode de Nelder Mead essayera de trouver les trois points d'un triangle comme suit :

$$B = f(K_1), G = f(K_2), \text{ et } W = f(K_3) \quad (\text{II.14})$$

Où B est le meilleur point (valeur inférieure à G et W), G est le bon point (à côté du meilleur), et W est le point le plus mauvais.

➤ **Le point du milieu**

Le processus de construction utilise le point milieu de la ligne à partir de B et G comme suit:

$$M = \frac{B+G}{2} \quad (\text{II.15})$$

➤ **Le point d'expansion**

Le point d'expansion est calculé à partir du point milieu et du point le plus mauvais comme suit:

$$E = 3M - 2W \quad (\text{II.16})$$

➤ **Le point de réflexion**

Le point de réflexion est calculé à partir du point milieu et du point d'expansion comme suit:

$$R = \frac{M+E}{2} \quad (\text{II.17})$$

➤ **Le point de construction**

Les points de Contraction utilisés pour cette application sont deux. Le premier point est calculé à partir du point le plus mauvais et du point milieu et le deuxième point est calculé à partir du point de réflexion et du point milieu comme suit:

$$C_1 = \frac{W+M}{2} \text{ ou } C_2 = \frac{R+M}{2} \quad (\text{II.18})$$

➤ **Le point de rétrécissement**

Le point de rétrécissement est construit à partir du meilleur point et du point le plus mauvais comme suit:

$$S = \frac{B+W}{2} \quad (\text{II.19})$$

Tous les points utilisés pour la méthode de Nelder Mead sont représentés par la figure II.12.




Figure II.12. Tous les points utilisés pour la méthode Nelder Mead

Selon le calcul, Les étapes à suivre pour optimiser les paramètres du contrôleur selon l'algorithme de Nelder Mead sont les suivants:

- Etape 1: Générer une configuration initiale K de façon aléatoire, où $K_1 = [k_{p1} \ k_{i1} \ k_{d1} \ \eta_1]$, $K_2 = [k_{p2} \ k_{i2} \ k_{d2} \ \eta_2]$, et $K_3 = [k_{p3} \ k_{i3} \ k_{d3} \ \eta_3]$.
- Etape 2: Calculer $f(K_1)$; $f(K_2)$; $f(K_3)$ pour trouver B, G, W, avec $B < G < W$.
- Etape 3: Calculer M, E et $f(E)$.
- Etape 4: Comparer $f(E)$ et $f(G)$, si $f(E) < f(G)$ remplacer W avec E, (étape 8); sinon calculer R et $f(R)$, (étape 5).
- Etape 5: Comparer $f(R)$ et $f(W)$, si $f(R) < f(W)$ remplacer W avec R (étape 6).
- Etape 6: Comparer $f(R)$ et $f(G)$, si $f(R) \geq f(G)$ calculer C et $f(C)$ (étape 7); sinon aller à l'étape 8.
- Etape 7: Comparer $f(C)$ et $f(W)$, si $f(C) < f(W)$ remplacer W avec C, sinon calculer S, remplacer G avec M et remplacer W avec S.

- Etape 8: Réorganisez B, G, W, où $B < G < W$ et répétez l'étape (3) jusqu'à certains critères d'arrêt sont atteints.

Les paramètres optimaux obtenus avec la méthode de Nelder Mead sont donnés comme suit:

$$k_p = 0.804, \quad k_i = 0.016, \quad k_d = 1, \quad n = 0.42.$$

II.6 Simulations, résultats et commentaires

Les résultats de simulation du système avec le contrôleur IMF-PID flou proposé, dont les paramètres sont obtenus par les différentes méthodes d'optimisation (section II.5.1.1 et II.5.1.2), sont présentés dans les figures II.13-II.20 : les dynamiques de la minimisation des critères (Eq. II.12 et Eq II.13) (coûts) sont représentées par la figure II.13, ainsi que les dynamiques d'optimisation des paramètres du contrôleur (k_p , k_i , k_d , et η) sont représentées par les figures II.14-II.17, et les réponses indicielles sont représentées par la figure II.18. La figure II.19 montre les rejets de perturbation (échelon d'amplitude 0.15), tandis que la figure II.20 montre les réponses indicielles du système qui a subi une variation de 15% de ses paramètres y compris son temps de retard (incertitudes paramétriques).




Figure II.13. Dynamiques de minimisation du coût par les différentes méthodes




Figure II.14. Dynamiques d'optimisation du paramètre K_p par les différentes méthodes




Figure II.15. Dynamiques d'optimisation du paramètre K_i par les différentes méthodes




Figure II.16. Dynamiques d'optimisation du paramètre K_d par les différentes méthodes




Figure II.17. Dynamiques d'optimisation du paramètre η par les différentes méthodes




Figure II.18. Réponses indicielles du système commandé par IMF-PID flou




Figure II.19. Rejets des perturbations




Figure II.20. Réponses indicielles du système ayant subi une variation de 15% de ses paramètres

Commentaires:

D'une façon générale, les performances du contrôleur IMF-PID flou obtenu par l'algorithme PSO sont meilleurs en terme de:

- ✓ Rapidité de minimisation de la fonction coût (seulement après 14 itération comme le montre les figures II.13-II.17).
- ✓ Temps de réponse et dépassement (figure II.18)
- ✓ Robustesse par rapport aux rejets de perturbation (figure II.19) et aux variations paramétriques (figure II.20).

II.7 Conclusion

Le système immunitaire est connu par sa capacité à combattre toutes invasions exogènes (robustesse), son mécanisme a été la source d'inspiration de la loi de commande du contrôleur IMF-PID flou. Le réglage optimal des paramètres de ce dernier par les algorithmes bio-inspirés tel que PSO et ACO a donné des résultats encourageants en terme de performances temporelles, ainsi qu'en terme de robustesse vis-à-vis des perturbations et des variations paramétriques.

Chapitre III

Conception d'un contrôleur auto-adaptatif bio-inspiré pour la commande des systèmes sous réseau

III.1 Introduction

Avec le développement rapide des technologies de la commande, du traitement de l'information et de la communication, la recherche dans le domaine de la commande des systèmes sous réseau (Networked control system : NCS) connaît un intérêt croissant. En mettant l'accent sur la théorie de la commande ainsi que les systèmes bio-inspirés et en tirant pleinement parti de l'essor des recherches effectuées dans les structures et les protocoles du réseau, une nouvelle stratégie de commande auto-adaptative bio-inspirée pour les NCSs est abordée dans ce chapitre, cette méthode permet d'assurer la stabilité et les bonnes performances des systèmes commandés sous réseau sujet à divers variations.

III.2 Les systèmes commandés sous réseau (NCS)

Les systèmes commandés sous réseau sont des systèmes communicants avec leur différents organes (contrôleurs, capteurs...etc.), par l'intermédiaire d'un réseau de communication numérique, cette architecture de commande offre en effet de nombreux avantages suivant le type d'application envisagée: répartition des tâches à accomplir, coopération, commande à distance, facilitation du diagnostic...etc. La commande des systèmes sous réseau concerne plusieurs domaines parmi lesquels [48] : la chirurgie télé-opérée, l'observation à domicile, les transports (drones, formations de véhicules, équipements automobiles), l'environnement (prédiction et surveillance de désastres par réseaux de capteurs), l'espace (formations de satellites, exploration).

De nombreux défis se posent dans le contexte de la commande des systèmes sous réseau, en effet les canaux de communication entre les capteurs, les contrôleurs et les actionneurs doivent être partagés avec d'autres applications (inconnues). Le partage d'un canal de communication implique naturellement que le comportement du réseau lié aux propriétés de la commande en temps réel (comme le débit de données) soit incertain. La communauté de l'automatique s'est rendu compte que le partage des ressources de communication et l'incertitude du réseau sapent les hypothèses de base sur lesquelles s'appuient les contrôleurs de rétroaction (traditionnels), le développement de nouvelles méthodes de commande qui peuvent s'auto-adapter aux nombreuses variations des NCS devient donc une nécessité.

En effet, dans un NCS (figure III.1), il existe de nombreuses applications de commande en temps réel où la communication entre les capteurs, les actionneurs et les contrôleurs n'est pas toujours parfaite, plusieurs variations induisant des effets indésirables peuvent survenir [48]:

- La présence d'un support de communication partagé
- La diversité des intervalles d'échantillonnage/transmission
- Les différents délais de transmission (retards)
- Les abandons de paquets

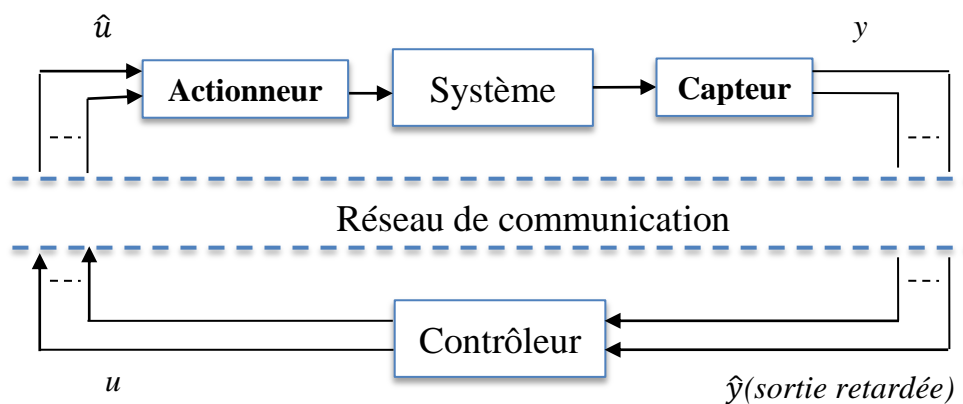


Figure III.1. Schéma bloc d'un système commandé sous réseau NCS

Il est bien connu que chacun de ces phénomènes dégrade la performance et peut même menacer la stabilité en boucle fermée. En fonction du réseau et/ou de l'application, l'influence/importance de chacun de ces quatre effets peut varier de manière significative, par exemple : les systèmes qui sont capables de transmettre les données de capteurs dans un paquet ne souffrent pas d'un support de communication partagé, mais ils peuvent prendre plus de temps pour collecter toutes les données et préparer la transmission du paquet, ce qui entraîne des retards.

III.2.1 Les problèmes fondamentaux des NCSs

Dans cette section, nous allons brièvement analyser certains problèmes de base dans les NCSs, y compris la période de transmission variable, le retard induit par le réseau, la transmission d'un seul ou plusieurs paquets et la chute des paquets réseau.

III.2.1.1 La variance du temps de transmission

Les systèmes commandés conventionnellement par l'ordinateur supposent un échantillonnage à distance pareil, ce qui signifie que les échantillons sont prélevés périodiquement aux instants de temps Kh , $h = 0, 1, \dots$, où h est la période d'échantillonnage constante. Cette hypothèse conduit à des systèmes dynamiques continus et simplifie considérablement l'analyse de la stabilité et des performances [48,49].

Cependant, l'hypothèse d'un échantillonnage à distance égale ne devrait pas être imposée à l'analyse d'un NCS, la transmission d'échantillons sur un NCS peut être périodique ou apériodique, selon le protocole « contrôle d'accès au support » (medium access control : MAC) du réseau de commande. Les protocoles MAC sont généralement utilisés pour deux catégories: pour les réseaux à accès aléatoire et pour l'ordonnancement des tâches du réseau. Accès multiple avec écoute de la porteuse (CSMA : Carrier Sense Multiple Access with) est le plus souvent utilisé dans les réseaux à accès aléatoire, tandis que le passage à jeton (Token Passing : TP) et accès multiple à répartition dans le temps (TDMA : time division multiple access) sont couramment utilisés dans l'ordonnancement des tâches du réseau.

Les commandes sous réseau utilisant les protocoles CSMA incluent DeviceNet et Ethernet, la figure III.2 illustre diverses situations possibles pour ces types de réseau, elle représente deux nœuds transmettant continuellement des messages (par rapport à une ligne temporelle fixe): Un nœud sur un réseau CSMA surveille le réseau avant chaque transmission, lorsque le réseau est inactif, il commence immédiatement la transmission, comme indiqué dans le 1^{er} cas de la figure III.2. Sinon, il attend que le réseau ne soit pas occupé. Lorsque deux ou plusieurs nœuds tentent de transmettre simultanément, une collision se produit, la façon de résoudre la collision dépend du protocole. DeviceNet, qui est un bus système série (bus CAN : Controller Area Network) [50], fonctionnant dans la couche physique et la couche liaison de données, utilise le protocole CSMA avec un protocole d'arbitrage bit à bit (CSMA/BA : Carrier-Sense Multiple Access with Bit-wise Arbitration). Tandis que les messages du bus CAN sont priorisés, le message de priorité le plus élevée est




Figure III.2. Schéma temporel de deux nœuds sur un réseau d'accès aléatoire

transmis sans interruption lorsqu'une collision se produite et la transmission du message de priorité inférieure sera terminée et retirée lorsque le réseau est inactif, comme illustré dans le deuxième cas de la figure III.2. Le réseau Ethernet utilise le protocole CSMA avec le protocole de détection de collision (CSMA/CD : Carrier sense multiple access with collision detection). En cas de collision, tous les nœuds affectés vont reculer, attendre un temps aléatoire et retransmettre, comme le montre le 3ème cas de la figure III.2. Nous pouvons voir que DeviceNet et Ethernet ne peuvent pas garantir un échantillonnage à distance égale, car leur transmission d'un échantillon pourrait être rebondie parce qu'un nœud de priorité plus élevée (DeviceNet) ou simplement un autre nœud (Ethernet) essaie de transmettre simultanément.

III.2.1.2 Le retard induit par le réseau

Le retard induit par le réseau (τ) se produit lorsque les capteurs, les actionneurs et les contrôleurs échangent des données à travers le réseau, ce retard peut dégrader les performances du système de commande et peut même déstabiliser le système.

Les paquets sur les réseaux d'accès aléatoire sont affectés par des retards aléatoires et le temps de transmission le plus défavorable d'un paquet est illimité, comme le montre la figure III.3. Par conséquent, les réseaux ayant le protocole CSMA sont généralement considérés comme non déterministes. Cependant, si les messages sont prioritaires, le message ayant la

priorité la plus élevée a une meilleure chance de transmission en temps opportun (comme sur CAN et DeviceNet).




Figure III.3. Retards éventuels induits par le réseau sur un système de commande aléatoire

D'autre part, la présence du retard (τ) dans une boucle de régulation peut causer beaucoup de difficultés pour la commande du processus, en effet: une perturbation à l'entrée du système ne sera détectée qu'à après un temps déterminé, et par conséquent le signal de commande développé par le régulateur ne sera efficace qu'après un certain temps. Un long retards peut même parfois mener à l'instabilité du système, car il rend le système à déphasage non minimale ; en effet : La fonction de transfert d'un retard pur d'une durée T secondes est donnée par : $e^{-T.s} = \frac{1}{e^{T.s}}$, on constate que cette fonction est d'ordre infini, car on peut développer le terme retard en série mathématiques d'ordre infini (type méthode de Padé), elle possède donc une infinité de pôles, ce qui rend la conception d'un contrôleur pour le système en boucle fermée assez compliqué.

III.2.1.3 Les Abandons de paquets

Les Abandons de paquets se produisent occasionnellement sur un NCS lorsqu'il y a des échecs de nœud ou des collisions de messages, bien que la plupart des protocoles de réseau soient équipés de mécanismes de réplification de transmission: ils peuvent être réémis pour une durée limitée, une fois ce délai expiré, les paquets sont abandonnés. En outre, pour les données d'une commande en boucle fermée en temps réel telles que les mesures de capteur et les signaux de commande calculés, il peut être avantageux de jeter l'ancien message non transmis et de transmettre un nouveau paquet si il est disponible, de cette façon le contrôleur reçoit toujours de nouvelles données pour le calcul de la commande.

Normalement, les systèmes commandés sous réseau peuvent tolérer une certaine perte de données, mais il est utile de déterminer si le système est stable lorsque les paquets sont uniquement transmis à un certain débit, et de calculer les limites inférieures acceptables sur le débit de transmission des paquets.

III.2.2 Simulation des NCSs par TrueTime

TrueTime est un simulateur sur Matlab/Simulink développé à l'Université de Lund, et dont l'objectif est de faciliter la modélisation de régulateurs embarqués et distribués. TrueTime est en libre téléchargement sur la page Web de l'Université de Lund (<http://www.control.lth.se/truetime>). Le simulateur se compose d'une bibliothèque de blocs Simulink (figure III.4) et d'une collection de fichiers MEX. Le bloc noyau (kernel bloc) simule un noyau en temps réel exécutant des tâches définies par l'utilisateur. Les différents blocs de réseau permettent aux nœuds de communiquer sur des réseaux câblés et sans fil.

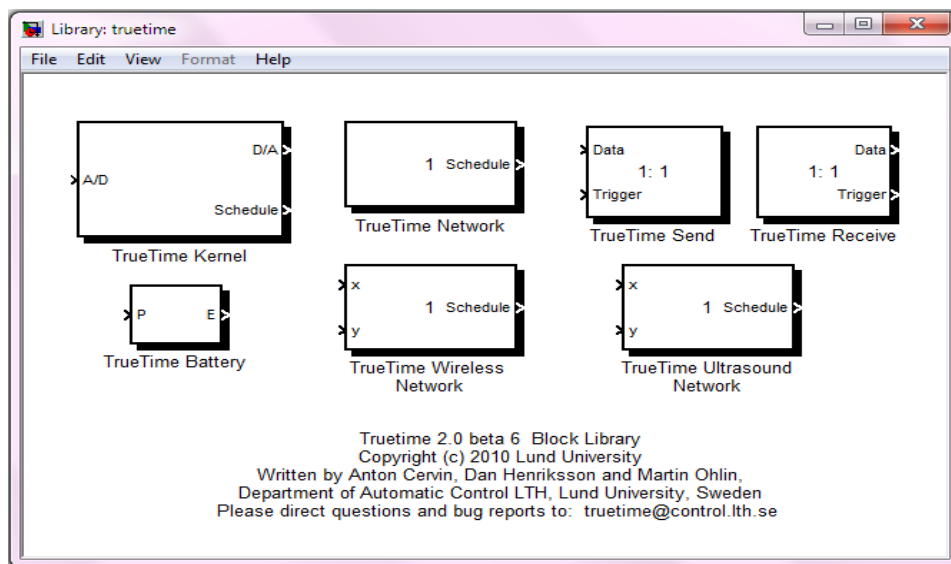


Figure III.4. La bibliothèque de blocs TrueTime 2.0

Selon [51], les blocs TrueTime sont connectés à des blocs Simulink ordinaires pour former un système de contrôle en temps réel, la caractéristique principale de TrueTime est la possibilité de co-simulation de l'interaction entre les dynamiques continues du monde réel du monde réel et l'architecture informatique sous forme d'exécution de tâches et de communication réseau.

Cet outil fournit une librairie composé de:

- Un noyau temps réel
- Réseau TrueTime

- Nœud émetteur et un nœud récepteur
- Réseau sans fil (réseau de capteurs, d'antenne, etc.)
- Réseau ultrason
- Batterie

TrueTime a été développé, notamment dans le but d'offrir aux concepteurs la possibilité de simuler des calculateurs monoprocesseurs disposant d'un exécutif en temps réel. Les tâches de contrôle peuvent être modélisées par des fonctions Matlab ou C++.

III.2.2.1 Le Bloc noyau TrueTime

Le bloc noyau est une fonction Simulink qui simule un ordinateur en temps réel, des convertisseurs analogique/numérique et numérique/analogique, une interface réseau et des canaux d'interruption externes. Le bloc exécute les tâches définies par l'utilisateur et les gestionnaires d'interruptions. Intérieurement, il maintient plusieurs structures de données qui se trouvent généralement dans un noyau en temps réel: Des enregistrements des tâches, des gestionnaires d'interruptions, des moniteurs et des temporisations créés pour la simulation.

Le bloc noyau TrueTime est configuré par la boîte de dialogue comme le montre la figure III.5. Le paramètre principal est le nom de la fonction d'initialisation, car chaque bloc noyau doit être initialisé au début de la simulation. Un argument facultatif pour le script d'initialisation, l'option batterie, la dérive d'horloge et décalage d'horloge peuvent être prédéfinis.

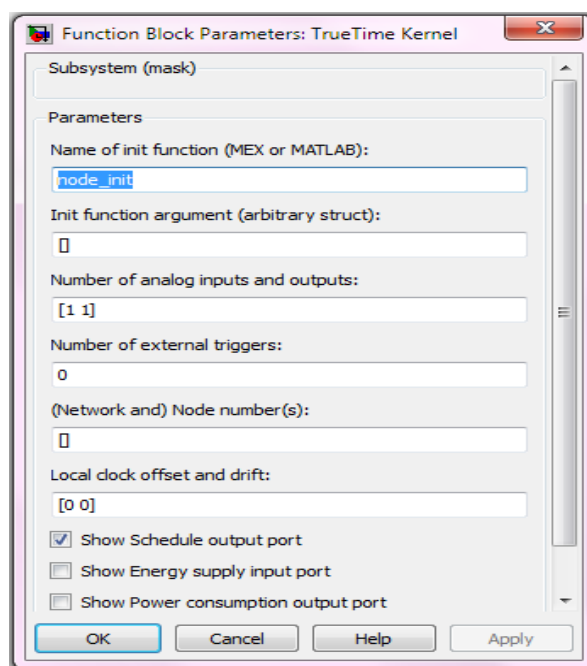


Figure III.5. Boîte de dialogue du bloc noyau

III.2.2.2 Le bloc réseau TrueTime

Le bloc réseau TrueTime simule la transmission de paquets dans un réseau local, lorsqu'un nœud tente de transmettre un message, un signal de déclenchement est envoyé au bloc réseau sur le canal d'entrée correspondant. Lorsque la transmission du message est terminée, le bloc réseau envoie un nouveau signal de déclenchement sur le canal de sortie correspondant au nœud récepteur. Le message transmis est placé dans un tampon au niveau du nœud de l'ordinateur récepteur [51].

Les types de réseaux pris en charge par ce bloc sont: CSMA/CD (Ethernet), CSMA/AMP (CAN), Round Robin (Token Bus), FDMA, TDMA (TTP), Switched Ethernet, WLAN (802.11b), et ZigBee (802.15.4).

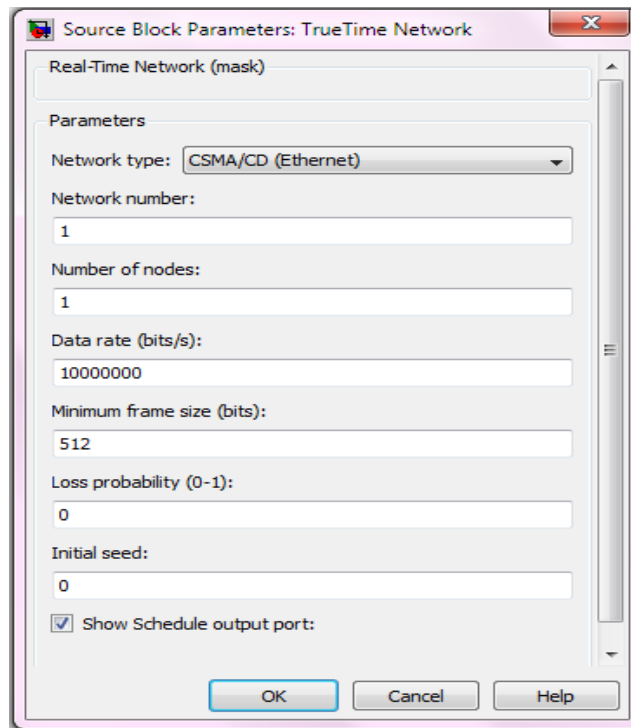


Figure III.6. Boîte de dialogue du bloc réseau

III.2.2.3 Les Blocs TrueTime du réseau autonome

Les blocs du réseau autonome (TrueTime Send, TrueTime Receive) peuvent être utilisés pour envoyer des messages via le réseau (à l'aide du bloc réseau) sans utiliser le bloc noyau. Cela signifie qu'aucun code d'initialisation ou code de tâche ne doit être implémenté. Selon [51], toute la simulation du réseau peut être créée dans Simulink sans utiliser des m-files, ni des codes C++.

Il est possible de mélanger les blocs autonomes avec les blocs noyau dans une simulation. Cela signifie que certaines stations peuvent envoyer des messages sans les codes de tâches m-file (par exemple; les capteurs) et certaines stations utilisent des blocs noyau (contrôleurs).

Les blocs d'envoi et de réception sont configurés via leurs boîtes de dialogue (Figure III.7). Le bloc d'envoi peut être déclenché en fonction du temps ou en fonction de l'évènement. Le port d'entrée de déclenchement peut être configuré pour être déclenché lors de l'élévation, la chute ou de chaque flanc.

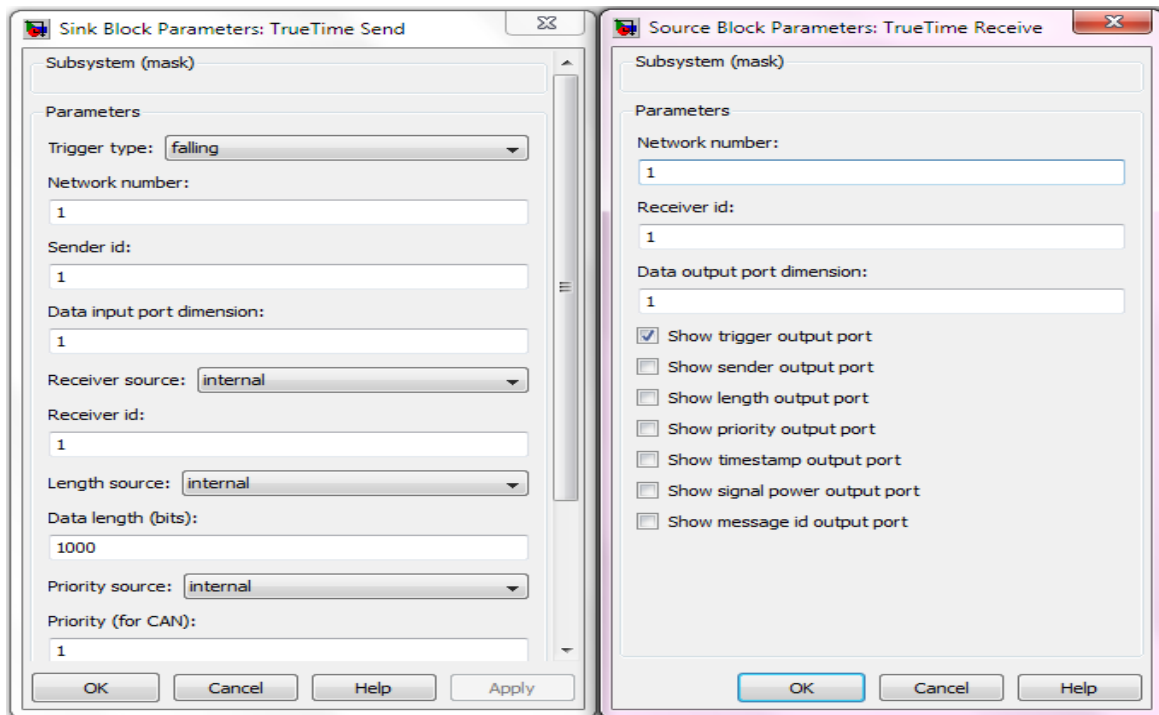


Figure III.7. Boîte de dialogue des blocs TrueTime du réseau

III.2.2.4 Exemple 1 (architecture noyau)

Dans ce qui suit, nous allons présenter un exemple d'une architecture de simulation d'un NCS, les blocs; capteur et actionneur sont simulés avec une fonction S (S-function) dans un bloc noyau Truetime dans laquelle leur entrée et leur sortie sont respectivement définies comme la sortie et l'entrée du système objectif. De plus, une seconde fonction S définie dans un second bloc noyau peut être utilisée pour la conception du contrôleur, comme le montre la figure III.8.

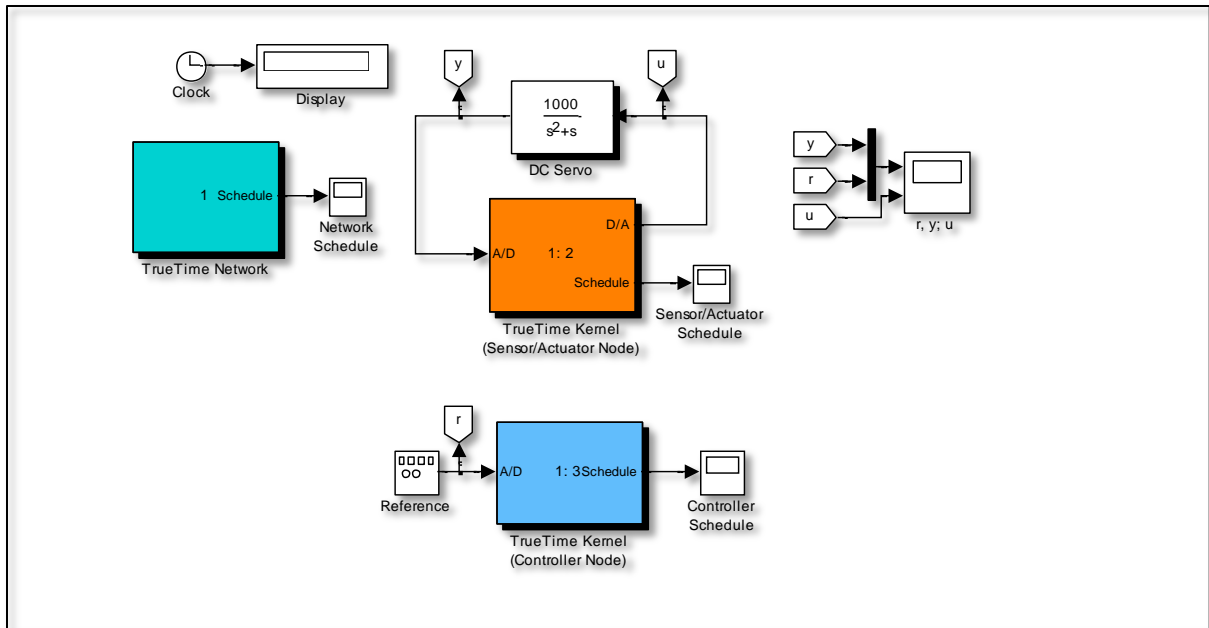


Figure III.8. L'architecture noyau d'un NCS à l'aide de TrueTime

III.2.2.5 Exemple 2 (architecture autonome)

Dans cet exemple nous présentons l'architecture autonome pour la simulation d'un NCS, les réseaux de communication entre le capteur et le contrôleur et entre l'actionneur et le contrôleur sont configuré comme représenté sur la figure III.9, cette architecture est simulé en utilisant des blocs séparés appelés TrueTime send et TrueTime receive (émetteur et récepteur). Par ailleurs, chaque émetteur et récepteur doit être identifié par un ID pour éviter la collision.

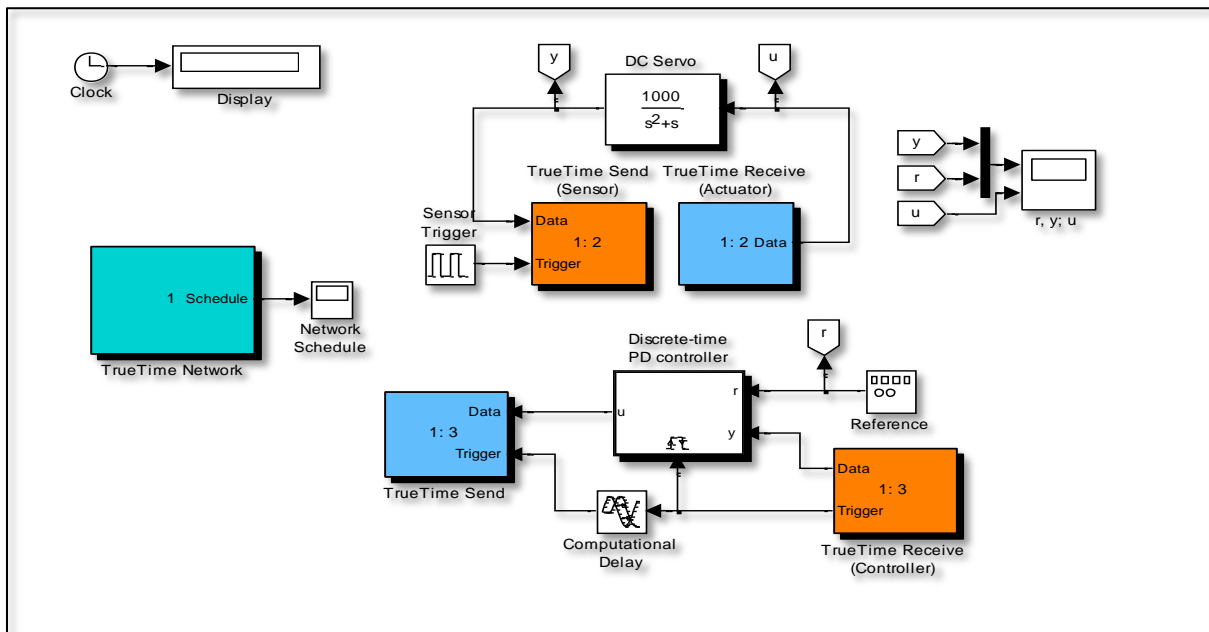


Figure III.9. TrueTime L'architecture autonome d'un NCS à l'aide de TrueTime

III.3 Conception d'un contrôleur PID auto-adaptatif à neurone unique pour la commande des systèmes sous réseau

Dans cette section, une nouvelle approche de commande est proposée pour la commande des systèmes sous réseau, nous proposons de concevoir un contrôleur PID à neurone unique basé sur le mécanisme de la rétroaction immunitaire. Cette approche nous permettra d'améliorer l'adaptabilité du système aux effets indésirables induits par le réseau. Des simulations utilisant le logiciel TrueTime sont présentées afin d'évaluer la faisabilité et l'efficacité de la stratégie de commande proposée.

III.3.1 Modèle du NCS considéré

Un modèle typique d'un NCS est présenté dans la figure III.10. $G_c(s)$ et $G_p(s)$ sont les fonctions de transfert du contrôleur et du processus respectivement, ils sont connectés à travers un réseau particulier tel que : Ethernet, CAN, Profibus, Internet, etc.

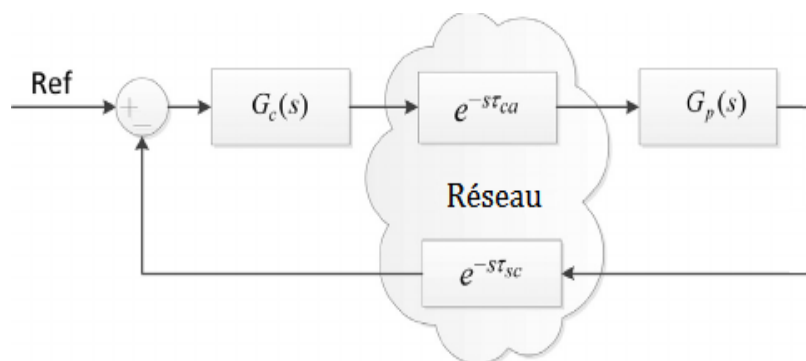


Figure III.10. Boucle de commande sous réseau

Les retards causés par la chaîne de communication: celui entre le contrôleur et l'actionneur et celui entre le capteur et le contrôleur sont notés τ_{ca} et τ_{sc} respectivement.

III.3.2 Caractéristiques du réseau

Nous considérons un NCS distribué et configuré sur un réseau Ethernet tel qu'illustré à la figure III.11. L'Ethernet est une technologie de réseau qui couvre les deux premières couches du modèle de référence OSI (Open Systems Interconnection), sa dominance repose sur des équipements à bas prix, faciles à configurer et à déployer.




Figure III.11. Des NCSs sur un réseau Ethernet

Ce qui nous intéresse le plus dans l'utilisation du réseau Ethernet, c'est son protocole de transmission défini par l'accès multiple avec détection de collision (CSMA/CD), en effet tous les périphériques peuvent essayer d'envoyer une trame à tout moment, chaque dispositif détecte si la ligne est inactive et donc disponible pour être utilisée, si tel est le cas, le dispositif commence à transmettre sa première trame. Si un autre périphérique a essayé d'envoyer en même temps, une collision se produit et les trames sont ignorées, chaque périphérique s'arrête alors et attend un temps aléatoire défini par: [51]

$$t_{\text{retrait}} = \text{Taille minimale du trame} / \text{taux de données} \times R \quad (\text{III.1})$$

Où $R = \text{rand}(0, 2k-1)$ (distribution uniforme discrète) et k le nombre de collisions d'une rangée. Notez que pour CSMA / CD, la taille minimale du trame ne peut pas être 0.

Après l'attente, le nœud tentera de retransmettre. Dans un exemple où deux nœuds attendent un troisième nœud pour terminer sa transmission, ils entrent en collision avec la probabilité 1, puis avec la probabilité 1/2 ($k = 1$), puis 1/4 ($k = 2$), et ainsi de suite.

La mise en place d'un NCS avec le protocole de transmission n'est pas toujours suffisante, il est toujours nécessaire d'introduire une méthode de commande adaptative, pour surmonter les effets indésirable causés par la variation du modèle et le retard induit par le réseau.

III.3.3 Le contrôleur PID à neurone unique avec réglage immunitaire

III.3.3.1 L'algorithme de commande d'un PID à neurone unique

Les méthodes de commande intelligentes combinant le réseau neuronal avec le contrôleur PID traditionnel sont généralement divisées en deux types: le contrôleur PID à réseau neuronal et le contrôleur PID à neurone unique. En raison des caractéristiques d'une implémentation facile et d'une faible complexité, le contrôleur PID à neurone unique a connu

un grand succès et a été largement appliqué dans le champ de la commande avancée [52]. La structure du contrôleur PID à neurone unique est représentée sur la figure III.12.




Figure III.12. La structure du régulateur PID à neurone unique

Où x_i ($i=1, 2, 3$) sont les signaux d'entrée du neurone, ils sont donnés par:

$$\begin{cases} x_1(k) = e(k) \\ x_2(k) = e(k) - e(k-1) \\ x_3(k) = e(k) - 2e(k-1) + e(k-2) \end{cases} \quad (\text{III.2})$$

La loi commande obtenue est celle d'un contrôleur PID discret:

$$\Delta u(k) = w_1 e(k) + w_2 (e(k) - e(k-1)) + w_3 (e(k) - 2e(k-1) + e(k-2)) \quad (\text{III.3})$$

Où w_1 , w_2 , et w_3 sont trois coefficients de poids ajustables, qui peuvent être manipulés par la capacité d'auto-apprentissage du neurone.

Selon les différents états du système de commande, le contrôleur PID à neurone unique ajuste le poids des coefficients par l'algorithme d'apprentissage supervisé, qui s'adapte automatiquement aux nouveaux changements [52].

La loi de commande et les algorithmes d'apprentissage de Hebb sont les suivantes:

$$u(k) = u(k-1) + K \sum_{i=1}^3 w'_i(k) x_i(k) \quad (\text{III.4})$$

$$w'_i(k) = w_i(k) / \sum_{i=1}^3 |w_i(k)| \quad (\text{III.5})$$

$$\begin{cases} w_1(k) = w_1(k-1) + \eta_p e(k) u(k) x_1(k) \\ w_2(k) = w_2(k-1) + \eta_I e(k) u(k) x_2(k) \\ w_3(k) = w_3(k-1) + \eta_D e(k) u(k) x_3(k) \end{cases} \quad (\text{III.6})$$

Où les coefficients η_i ($i=P, I, D$) représentent les taux d'apprentissage des actions de contrôle (proportionnelle, intégrale et dérivée), K ($K > 0$) désigne le ratio du neurone, ce

coefficient K a un impact important sur la réponse dynamique et la stabilité du système: En effet, on obtient une réponse rapide, un temps de montée court mais un dépassement élevé lorsque K est grand, par contre le dépassement est faible et la réponse du système est lente lorsque K est faible. En dépit du fait que le contrôleur PID à neurone unique ait une capacité d'adaptation, celle-ci doit être augmentée afin de contourner les changements très rapides du signal d'erreur $e(k)$ typique des NCS. Pour cela, nous proposons un réglage immunitaire artificiel connu par sa grande adaptabilité.

III.3.3.2 Le réglage immunitaire

Nous avons vu dans le chapitre précédent que le système immunitaire biologique est très similaire à un système de commande (voir la section II.3.3), et nous avons obtenu une loi de commande d'un contrôleur appelé IMF (voir Eq.II.6), dans laquelle apparaît une fonction non linéaire $f(x)$ représentant l'interaction entre les anticorps qui émergent des cellules B et les antigènes. L'effet d'auto-adaptation de cette fonction (démontré dans le chapitre précédent) est utilisé pour ajuster le coefficient K , ce dernier sera donc donné par l'équation suivante:

$$\begin{cases} f(x) = 1 - \exp(-x^2 / a) \\ K = k^* (1 + \eta^* f(e(k))) \end{cases} \quad (\text{III.7})$$

La structure complète du système commandé par le contrôleur PID immunitaire à neurone unique est montrée par la Figure III.13.

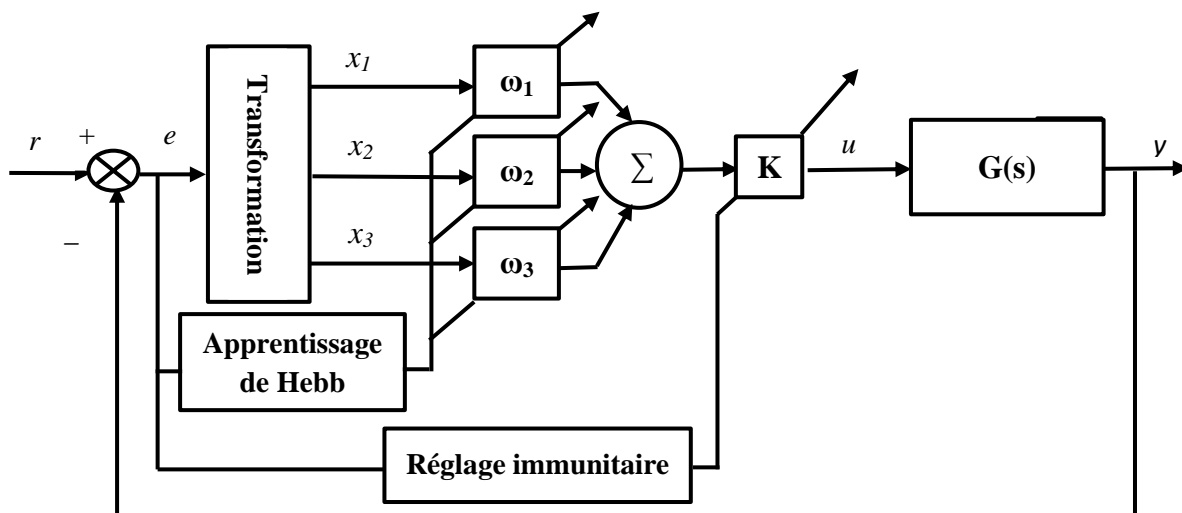


Figure III.13. Structure de la commande PID à neurone unique avec réglage immunitaire

III.3.4 Application de l'approche proposée sur un NCS [53]

Dans cette section, le contrôleur PID à neurone unique avec réglage immunitaire est appliqué sur un NCS composé d'un servomoteur à courant continu (CC), commandé sous réseau Ethernet, et dont le modèle mathématique est décrit par la fonction de transfert du second ordre suivante:

$$G(s) = \frac{1000}{s^2 + s}$$

Initialement, les coefficients pondérés du contrôleur à neurone unique sont donnés par : $w_1 = 0.10$, $w_2 = 0.10$, $w_3 = 0.10$, et les taux d'apprentissage sont: $\eta_p = 0.40$, $\eta_I = 0.30$, $\eta_D = 0.40$, tandis que les valeurs initiales du réglage immunitaire sont les suivantes: $a = 5$, $\eta^* = 0.45$.

Pour notre NCS, nous considérons l'architecture autonome (voir la section III.3.5), dans cette architecture trois bloc sont utilisés : TrueTime Network, TrueTime send et TrueTime receive (bloc réseau, bloc émission autonome, bloc réception autonome). Le modèle de simulation conçu pour notre étude est illustré dans la figure III.14: Le système comprend deux nœuds, le premier (en orange) est conçu pour la communication des données entre le contrôleur (SNPID) et l'actionneur, tandis que le second (en bleu) est conçu pour la communication des données capteur-contrôleur sur le réseau Ethernet (en vert).

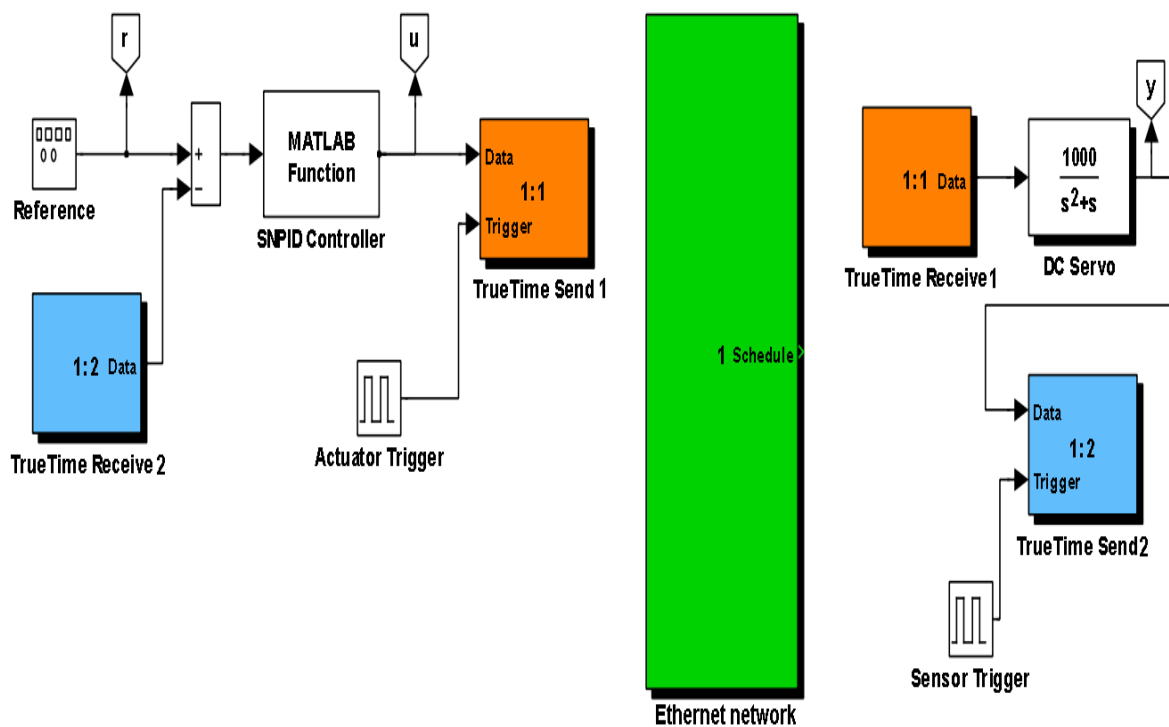


Figure III.14. Le modèle de simulation du système commandé sous réseau par le contrôleur PID à neurone unique avec réglage immunitaire à base du simulateur TrueTime

Les résultats de la simulation sont représentés dans les figures. (III.15) à (III.16).




Figure III.15. Réponse du système à un signal de référence à onde carrée




Figure II.16. Signal de commande




Figure III.17. Ordonnancement des tâches de contrôle sous Ethernet

On peut voir à partir des figures (III.15, III.16), que la démarche proposée donne de bonnes performances: le temps de réponse est appréciable avec un faible dépassement (<10%), l'influence du retard induit par le réseau est imperceptible. L'exécution des tâches et la transmission des messages sur le réseau Ethernet peut être étudiée en détail dans la figure III.17: un signal haut signifie l'émission ou l'exécution, un signal moyen signifie que l'émission est en attente, et un signal faible signifie que l'émission est inactive.

Afin de vérifier les performances de l'approche proposée en termes d'adaptabilité du système de commande par rapport aux problèmes fondamentaux des NCSs, une étude a été faite dans laquelle le NCS conçu subit: des retards de phases, des probabilités de perte d'information et un changement dans le protocole de communication. Les figures III.18-III.20 montrent les résultats de cette étude.




Figure III.18. Réponse du système avec différents retards de phase




Figure III.19. Réponse du système avec différentes probabilités de perte




Figure III.20. Réponse du système avec différents protocoles de communication

Dans les figures III.18 et III.19, on peut observer une légère dégradation dans les performances du NCS, cela est prévisible mais reste acceptable compte tenu de l'effet déstabilisateur de ces deux phénomènes (retard induit, perte de paquets). En outre, le NCS garde ses bonnes performances sous différents protocoles de communication ; CSMA/CD et CAN en particulier (Figure III.20).

III.4 Conclusion

Le développement et l'application d'une approche de commande adaptative bio-inspiré a été abordé dans ce chapitre, elle consiste en la conception d'un nouveau contrôleur PID à neurone unique avec un réglage basé sur le mécanisme de la rétroaction immunitaire. Cette méthode de commande a été appliquée sur un système commandé sous un réseau Ethernet. Les résultats de la simulation utilisant le logiciel TrueTime dans l'environnement Simulink/Matlab prouvent l'efficacité de l'approche proposée, en terme d'adaptabilité du système de commande par rapport aux problèmes fondamentaux des NCSs (retard induit, perte de paquets, etc). Enfin, nous envisageant d'appliquer cette approche pour une variété de systèmes non linéaires ayant des propriétés de variabilité dans le temps.

Chapitre IV

Commande et gestion d'une centrale hybride photovoltaïque-éolien-diesel par l'algorithme d'optimisation génétique

IV.1 Introduction

Les centrales de sources d'énergies renouvelables ont connu un développement exponentiel ces dernières années, cela est dû d'une part à la prise de conscience mondiale concernant la raréfaction des énergies fossiles, et d'autre part à leurs effets néfastes sur l'environnement (réchauffement climatique ... etc.). Le principal inconvénient des centrales à énergies renouvelables étant leur imprévisibilité, en effet la production d'électricité est liée à la disponibilité de telle ou telle énergies renouvelables en quantité suffisante, ce qui n'est pas toujours évident. L'idée des centrales hybrides est venue comme une réponse à ce problème, car elles utilisent plusieurs énergies renouvelables en même temps, pouvant ainsi pallier à la défection d'une source d'énergie par une autre (par exemple la nuit l'énergie éolienne peut pallier à l'énergie photovoltaïque). La conception, la commande et la gestion des centrales hybrides constituent un défi technologique majeur, car il faut aborder plusieurs problèmes en même temps comme : Comment assurer une coopération intelligente entre les systèmes de commande des sous- systèmes qui constituent la centrale hybride, Afin d'augmenter ses performances ? Comment gérer intelligemment l'énergie produite et satisfaire totalement la demande...etc. Dans ce chapitre, nous proposons une nouvelle méthode de commande et de gestion d'une Centrale Hybride Autonome à Energie Renouvelable (CHAER) en utilisant un algorithme d'optimisation multi-objective bio-inspiré qui est : l'algorithme génétique.

IV.2 Les centrales hybrides autonomes à énergies renouvelables

Les centrales électriques multi-sources à base d'énergie renouvelable sont soit autonomes soit connectés au réseau électrique public. Elles associent deux types de sources [54, 55]: des sources d'énergies renouvelables qui débitent aux réseaux aux moments de la disponibilité des énergies renouvelables et des sources complémentaires telles que les groupes diesels et les batteries; les groupes diesels interviennent pour débiter au CHAER en cas d'insuffisance d'énergie renouvelable, quant aux batteries, elles couvrent le manque d'énergie du réseau et stockent l'énergie supplémentaire au besoin de la charge. La CHAER représente la seule source d'énergie électrique pour l'installation à alimenter, il est adopté quand le réseau électrique public n'est pas disponible ou quand le fonctionnement de l'installation dépend uniquement de l'occurrence du soleil ou du vent (pompage, climatisation, chauffage, etc.).

Les CHAER doivent assurer la couverture de la demande en énergie de la charge en intégrant le maximum d'énergie à partir des sources d'énergie renouvelable, tout en maintenant la qualité de l'énergie fournie (stabilité et continuité). L'économie de carburant obtenue suite à l'installation d'une CHAER et l'innovation technologique dans les générateurs à énergie renouvelable rendent les CHAER très compétitives comparés aux réseaux alimentés par des sources conventionnelles. Les performances, le rendement et la durée de vie d'une CHAER sont influencés par sa conception, le dimensionnement et le type de ses composants. De plus, l'architecture et la stratégie de gestion du CHAER représentent un facteur déterminant pour son optimisation énergétique.

IV.3 Architecture du CHAER

En plus d'un ou de plusieurs générateurs électrogènes et d'au moins une source d'énergie renouvelable, une CHAER peut aussi contenir un système de distribution à courant alternatif (Bus CA), un système de distribution à courant continu (Bus CC), un système de stockage, des convertisseurs, des charges (y compris des charges de délestage), un gestionnaire de réseau et un système de supervision. La figure IV.1 présente l'architecture générale d'une CHAER. Les sources d'énergie renouvelable sont connectées selon leurs natures au bus CA ou au bus CC, l'interconnexion entre les deux bus est assurée par des convertisseurs unidirectionnels ou bidirectionnels de puissance.

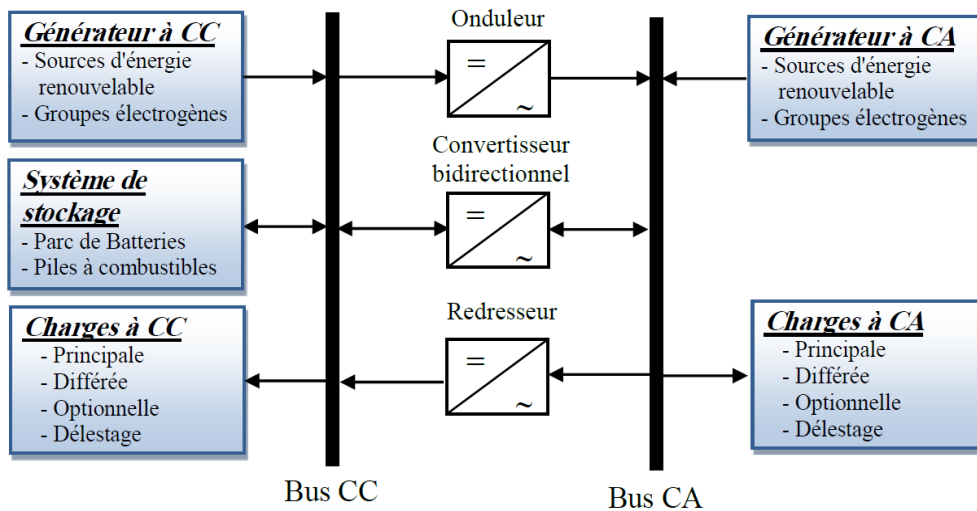


Figure IV.1. Structure d'une CHAER

La puissance délivrée par une CHAER varie du kilowatt pour des applications domestiques jusqu'à des mégawatts pour les réseaux d'électrification des zones rurales. Ainsi, les exploitations des CHAER sont classées comme suit [56, 57] :

- faible puissance (moins de 5kW) : stations de pompage de l'eau, unités de télécommunications, etc.
- moyenne puissance (10 à 250 kW) : micro réseau domestique, fermes, etc.
- grande puissance (plus que 250 kW) : alimentation de villages isolés.

Les CHAER sont classifiés selon l'indice moyen de pénétration de l'énergie renouvelable, cet indice est défini par [58] :

$$Ind_{moy} = \frac{W_{ER}}{W_{CH}} \quad (IV.1)$$

La pénétration moyenne (Ind_{moy}) est calculée sur des jours, des mois ou même des années. W_{ER} et W_{CH} , exprimées en kWh, représentent respectivement les énergies renouvelables et l'énergie totale consommée par la charge principale.

➤ Modèle du CHAER adopté dans notre étude

Il existe différentes topologies de CHAER dérivant de l'architecture globale. Dans notre application, nous considérons l'architecture commuté représentée par un panneau photovoltaïque équipé de son MPPT (maximum power point tracker) délivrant une tension continue de 12V, un générateur éolien utilisant une machine électrique asynchrone commandée qui fournit une tension alternative sinusoïdale monophasée de 230V-50Hz, un groupe électrogène (230V-50Hz), un parc de batteries (12V) muni de son contrôleur de charge, des convertisseurs statiques et des charges alternatives (230V-50Hz).

L'architecture commuté est fréquemment adoptée (figure IV.2), la charge est alimentée à travers un commutateur par une seule source à la fois : le groupe électrogène ou le bus continu regroupant le reste des sources à travers leurs convertisseurs convenables. Cette structure utilise moins de convertisseurs statiques, ce qui améliore le rendement global du réseau, de plus, en cas d'absence d'énergie renouvelable ou de décharge des batteries, le groupe électrogène intervient pour couvrir simultanément le besoin de la charge et charger les batteries. Toutefois, un système de pilotage du commutateur est nécessaire, ce système doit veiller à exploiter le maximum d'énergie renouvelable produite. Par contre, une électronique de commutation douce doit être installée en vue d'éviter les coupures instantanées de l'alimentation de la charge.

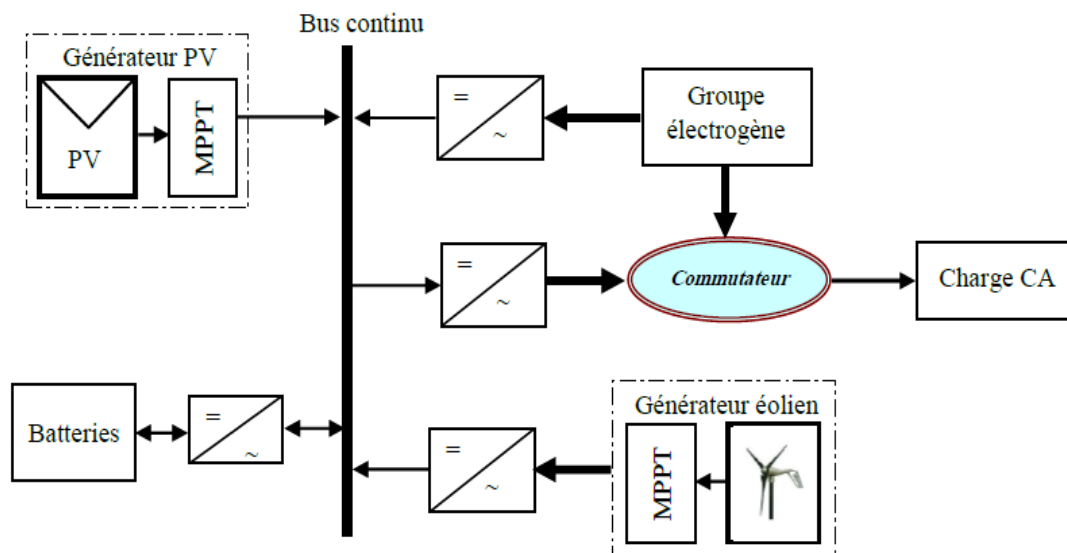


Figure IV.2. Architecture commutée d'une CHAER

IV.4 Dimensionnement du CHAER

Une fois l'architecture est sélectionnée, il est nécessaire de dimensionner les sources d'énergie, les convertisseurs et le système de stockage, une stratégie de fonctionnement efficace doit donc être établie [59]. Un dimensionnement et une stratégie de gestion judicieux permettent d'obtenir un taux de pénétration important des sources d'énergies renouvelables (Eq.IV.1), sans toutefois dégrader la qualité de l'énergie fournie [60].

Le dimensionnement des CHAER repose essentiellement sur la connaissance des facteurs suivants :

- le comportement des paramètres climatiques du site (ensoleillement, vitesse du vent, température, humidité) ;

- le profil de la charge ;
- les exigences de l'installation ;
- le budget alloué.

Dans ce contexte, plusieurs logiciels de dimensionnement et de simulation des CHAER ont été développés [61, 62] à savoir : HOMER, Hybrids, SOMES, Hybrid2, RETscreen, RAPSIM, SOLSIM, INSEL, etc. Ces logiciels ont pour but d'optimiser les dimensions des composants des systèmes hybrides moyennant différents outils standard. Le tableau IV.1 résume les références de ces outils et donne des observations sur leurs méthodologies de conception. Dans notre application, nous avons adopté l'outil HOMER.

Tableau IV.1. Synthèse des outils de dimensionnement des CHAER

| Outil | Organisme | Observations |
|-------------------------|---|--|
| HOMER | NREL : National Renewable Energy Laboratory, USA | - L'architecture du réseau doit être fixée. - Des configurations classées selon le coût et le cycle de vie des éléments du réseau sont proposées. |
| Hybrids | Solaris Homes, Queensland, Australie | - Il exige la connaissance de la moyenne (moyenne quotidienne de consommation d'énergie) et des données sur les ressources estimées pour chaque mois. - Il délivre des configurations triées en fonction d'un critère d'optimisation. |
| SOMES | Utrecht University, Pays-Bas | - L'optimisation tient compte de l'aspect technique et économique du réseau. - Délivre des simulations du comportement du réseau (entrées, sorties). |
| RAPSIM | Murdoch University Energy Research Institute, Australie | - Le dimensionnement optimal est obtenu suite à la comparaison des rendements de plusieurs configurations. - Le simulateur est paramétrable pour une sélection selon le besoin. |
| RETscreen International | Ministère des Ressources naturelles du Canada | - La conception se fait selon des modèles statistiques. - L'analyse des coûts et des émissions de gaz à effet de serre se fait selon des modèles énergétiques. |
| SOLSIM | Fachhochschule Konstanz, Allemagne | -L'optimisation tient compte de l'angle d'inclinaison des panneaux PV par le module SolOpti. - Les coûts du cycle de vie des éléments du réseau sont calculés par module SolCal. - Les générateurs éoliens sont simulés par l'unité SolWind. |

Dans l'objectif de dimensionner, gérer et commander les éléments du CHAER, une modélisation des différents composants s'avère nécessaire, la section suivante présente les modèles des différents composant du CHAER.

IV.5 Modélisation du CHAER

Dans cette section, nous présentons les modèles du générateur photovoltaïque, de l'éolienne, des batteries et du groupe électrogène ainsi que leur simulations, un modèle global du système hybride multi-sources Photovoltaïque/ Eolien/Diesel/Batterie est alors établi.

IV.5.1 Modèle du panneau photovoltaïque

Un module photovoltaïque est constitué d'un ensemble N_s de cellules connectées en série tandis qu'un panneau photovoltaïque (PV) est constitué d'un ensemble N_p de modules photovoltaïques connectés en parallèle. Le schéma de connexions d'un PPV est représenté par la figure suivante.




Figure IV.3. Schéma de connexion d'un PPV [63]

La puissance électrique produite par une cellule photovoltaïque dépend de l'intensité de l'ensoleillement G , de la température ambiante T_a et surtout de la tension V_c de sortie. Le schéma électrique équivalent d'une cellule d'un PPV est présenté par la figure IV.4.

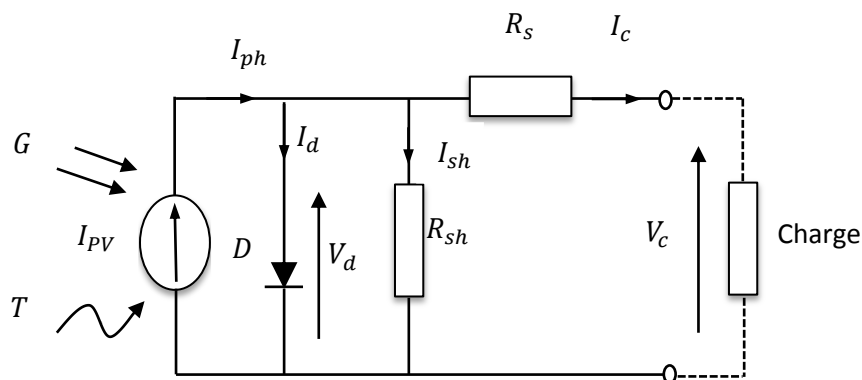


Figure IV.4. Schéma électrique équivalent d'une cellule photovoltaïque

Où I_{ph} représente le photo-courant créé dans les photopiles par le rayonnement solaire. Le courant I_c est proportionnel à l'ensoleillement reçu et opposé au courant de la diode équivalente D . I_d représente le courant direct de la diode. La résistance shunt R_{sh} caractérise le courant de fuites au niveau de la jonction alors que la résistance R_s représente les diverses résistances de contact et de connexion. De nombreux modèles mathématiques ont été développés pour représenter le comportement fortement non linéaire qui résulte des jonctions semi-conductrices qui sont à la base de leurs réalisations d'une cellule photovoltaïque. Le courant fourni par la cellule est exprimé par [63]:

$$I_c = I_{ph} - I_d - I_{sh} = I_{ph} - I_0 \cdot \left[\exp\left(\frac{V_c + R_s I_c}{n \cdot K_B \cdot \frac{T_a}{q}}\right) - 1 \right] - \frac{V_c + R_s I_c}{R_{sh}} \quad (IV.1)$$

Où I_0 est le courant de saturation inverse de la diode. La tension aux bornes d'un module photovoltaïque en fonction du courant de charge est décrite par l'équation suivante :

$$V_c = \frac{n \cdot K_B \cdot T_a}{q} \cdot \ln\left(\frac{I_{SC} - I_c}{I_0}\right) \quad (IV.2)$$

Le photo-courant I_{ph} s'exprime en fonction des variations de la température T_a et de l'ensoleillement G par [63]:

$$I_{ph} = I_{ph}(T_{1,ref}) + K_0 \cdot (T_a - T_{1,ref}) \quad (IV.3)$$

$$I_{ph} = I_{STC}(T_{1,ref,STC}) \cdot \frac{G}{G_{STC}} \quad (IV.4)$$

$$K_0 = \frac{I_{SC}(T_{2,ref}) - I_{SC}(T_{1,ref})}{(T_{2,ref} - T_{1,ref})} \quad (IV.5)$$

$$I_0 = I_0(T_1) \cdot \exp\left(\frac{q \cdot V_q(T_{1,ref})}{n \cdot K_B \cdot \left(\frac{1}{T_a} - \frac{1}{T_{1,ref}}\right)}\right) \cdot \left(\frac{T_a}{T_{1,ref}}\right)^{3/n} \quad (IV.6)$$

$$I_0(T_{1,ref}) = I_{SC}(T_{1,ref}) / \left(\exp\left(\frac{q \cdot V_{OC}(T_{1,ref})}{n \cdot K_B \cdot T_{1,ref}}\right) - 1\right) \quad (IV.7)$$

La résistance R_s d'une cellule au point VOC est calculée par l'équation :

$$R_s = -\frac{dV_c}{dI_c} \Big|_{VOC} - \left(\frac{n \cdot K_B \cdot T_{1,ref}}{q}\right) / \left(I_0(T_{1,ref}) \cdot \left(\exp\left(\frac{q \cdot V_{OC}(T_{1,ref})}{n \cdot K_B \cdot T_{1,ref}}\right) - 1\right)\right) \quad (IV.8)$$

Avec

I_{SC} : Courant de court-circuit

$I_{SC,STC}$: Courant de court-circuit dans les conditions standards

V_{OC} : Tension du module en circuit ouvert

STC : Conditions standards ($1000W/m^2$, $25\text{ }^\circ C$)

$T_{1,ref}$: Température de référence à $1000W/m^2$, $298K$ ($25^\circ C$)

K_B : Constante de Boltzmann ($1.3806 \cdot 10^{-23}$ en J/K)

q : Charge élémentaire d'électron ($1.6 \cdot 10^{-19}$ C)

T_a : Température ambiante (en Kelvin)

n : Facteur de non idéalité de la diode

G : Ensoleillement (en W/m^2)

$T_{2,ref}$: Température de référence pour à $800W/m^2$, $293K$ ($20^\circ C$)

K_0 : Coefficient température de variation du courant ISC (en %).

La puissance générée par un panneau photovoltaïque constitué de N_p modules en parallèle dont chacun est formé de N_s cellules en série est donnée par la relation suivante :

$$P_{pv} = V_{pv} \cdot I_{pv} = N_s \cdot V_c \cdot N_p \cdot I_c \tag{IV.9}$$

$$P_{pv} = N_s \left(\frac{nK_B T_a}{q} \ln \left(\frac{I_{SC} - I_c}{I_0} \right) \right) \cdot N_p \left(I_{ph} - I_0 \left[\exp \left(\frac{q(V_c + R_s I_c)}{nK_B T_a} \right) - 1 \right] - \frac{V_c + R_s I_c}{R_{sh}} \right) \tag{IV.10}$$

IV.5.2 Modélisation du générateur éolien

Dans notre étude, nous considérons un aérogénérateur tripale, associé à une turbine entraînant une génératrice asynchrone à cage à travers un arbre et un multiplicateur de vitesse. La figure suivante présente les différents éléments constitutifs d'une éolienne.

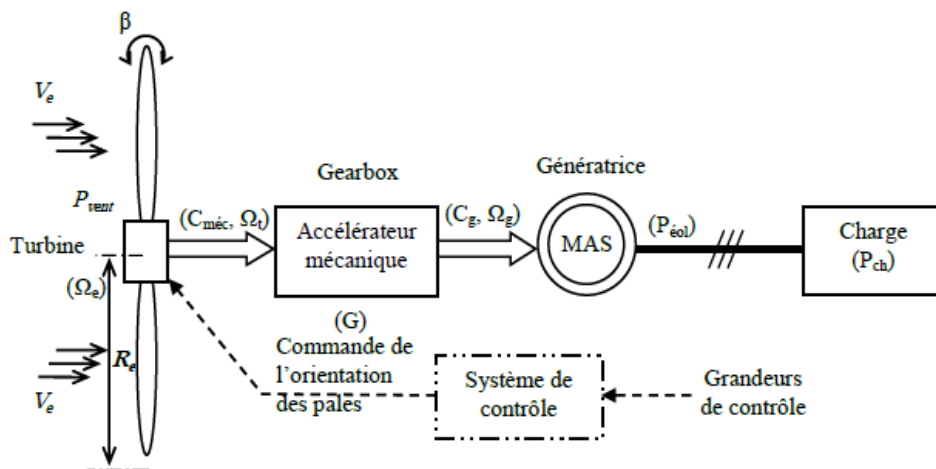


Figure IV.5. Eléments constitutifs d'une éolienne [64]

La puissance issue de l'énergie cinétique du vent disponible P_{vent} , est donnée par la relation [64]:

$$P_{vent} = \frac{1}{2} \cdot \rho_e \cdot S_e \cdot V_e^3 \quad (IV.11)$$

Le facteur ρ_e désigne la masse volumique de l'air, S_e est la surface de l'hélice de la turbine éolienne V_e et est la vitesse du vent en m/s.

Le rapport de la vitesse linéaire λ_e en fonction du rayon de l'hélice R_e et de la vitesse mécanique angulaire Ω_e de la turbine éolienne, au bout des lames, sur la vitesse de vent est exprimé par la relation suivante :

$$\lambda_e = \frac{\Omega_e R_e}{V_e} \quad (IV.12)$$

Le coefficient de puissance C_p est appliqué afin de transcrire le rendement de l'hélice pour le point d'étude considéré dépendant de la vitesse de rotation et de l'angle de calage des pales β .

$$C_p(\lambda_e, \beta) = 0.5176 \left(\frac{116}{\lambda_i} - 0.4\beta - 5 \right) e^{\frac{-21}{\lambda_i}} + 0.0068\lambda_e \quad (IV.13)$$

$$\frac{1}{\lambda_i} = \frac{1}{\lambda_e + 0.08\beta} - \frac{0.035}{\beta^3 + 1} \quad (IV.14)$$

Compte tenu des caractéristiques de la turbine éolienne, la puissance mécanique à la sortie est formulée par [64]:

$$P_{mec} = \frac{1}{2} \cdot C_p(\lambda_e) \cdot \rho_e \cdot S_e \cdot V_e^3 \quad (IV.15)$$

Le couple mécanique a pour expression :

$$C_{mec} = \frac{P_{mec}}{\Omega_e} = \frac{1}{2} \cdot \frac{C_p(\lambda_e)}{\lambda_e} \cdot \rho_e \cdot R_e \cdot S_e \cdot V_e^3 \quad (IV.16)$$

➤ Modèle du multiplicateur

Le multiplicateur est caractérisé par son gain G_e , il adapte la vitesse de rotation de la turbine Ω_t à la vitesse de la génératrice Ω_g :

$$\Omega_g = G_e \cdot \Omega_t \quad (IV.17)$$

➤ Modèle de l'arbre

L'équation fondamentale de la dynamique appliquée à l'arbre de la génératrice détermine l'évolution de la vitesse mécanique Ω_m à partir du couple mécanique total C_m :

$$j \frac{d\Omega_m}{dt} = C_m \quad (\text{IV.18})$$

L'inertie totale j qui apparaît sur le rotor de la génératrice est fonction de l'inertie de la génératrice j_g et de l'inertie de la turbine j_t reportée sur le rotor de la génératrice. Elle est donnée par [64]:

$$j = \left(\frac{j_t}{G_g^2} \right) + j_g \quad (\text{IV.19})$$

Le couple mécanique total dépend du couple issu du multiplicateur C_g , du couple électromagnétique produit par la génératrice C_{em} et du couple du frottement visqueux C_f caractérisé par son coefficient de frottement Ω_m visqueux f ($C_f = f \cdot \Omega_m$).

$$j \frac{d\Omega_m}{dt} = C_m = C_g - C_{em} - f \cdot \Omega_m \quad (\text{IV.20})$$

La puissance mécanique qui apparaît sur l'arbre de la génératrice (P_m) est exprimée comme étant le produit du couple mécanique (C_m) et de la vitesse mécanique.

$$P_m = \Omega_m \cdot C_m \quad (\text{IV.21})$$

➤ Bilan des puissances

La puissance aérodynamique peut être essentiellement maximisée en ajustant le coefficient de puissance C_p , ce dernier dépend de la vitesse de rotation et de la forme de la turbine ainsi que de la vitesse du vent. En régime permanent, la puissance aérodynamique $P_{aéro}$ diminuée des pertes (représentées essentiellement par les frottements visqueux) est convertie directement en puissance électrique.

$$P_{éol} = P_{aéro} - P_{pertes} = P_{méc} \cdot \eta_{éol} \quad (\text{IV.22})$$

Où : $\eta_{éol}$ est le rendement de l'éolienne

L'aérogénérateur est équipé d'un système de protection assurant un fonctionnement correct pour des vitesses du vent comprises entre des vitesses limites. La courbe de la puissance générée par le générateur éolien en fonction de la vitesse du vent est donnée par la figure :

IV.5.3 Modèle de la batterie d'accumulateur

L'énergie électrique produite par les générateurs à énergie renouvelable ne peut couvrir les besoins de la charge que lorsque les sources naturelles sont disponibles. Pour cette raison, l'utilisation de batteries d'accumulateurs s'avère indispensable pour stocker l'excédent de production et pour compléter les besoins de la charge en cas d'insuffisance d'énergie. Une

batterie d'accumulateurs est un générateur électrique qui utilise les propriétés électrochimiques d'un couple oxydant-réducteur. Une batterie est une association de plusieurs cellules formées d'électrodes positives et négatives jointes par un électrolyte. Ces cellules convertissent l'énergie chimique en énergie électrique. Les accumulateurs se distinguent des piles classiques par leur aptitude à la recharge. La batterie la plus répandue est celle dite Plomb-acide, disponible en deux catégories : les accumulateurs plomb-calcium et les accumulateurs plomb-antimoine.

La performance d'une batterie au Plomb-acide est exprimée essentiellement par la tension entre ses bornes, la capacité C_{pb} et la profondeur en décharge maximale (DOD : *Depth Of Discharge*) Le schéma électrique équivalent d'une cellule d'une batterie plomb-acide est donné par la figure suivante:




Figure IV.6. Schéma électrique équivalent d'une cellule de la batterie plomb-acide

Le courant de la cellule I_{bat} est compté positivement en décharge et négativement au cours de la charge, V_{bat} est la tension de sortie et Z , formée par le triplet R_1 , R_2 et C_1 , constitue l'impédance interne équivalente d'une cellule. La tension de la batterie en circuit ouvert E_0 est proportionnelle à la profondeur en décharge DOD (nulle quand la batterie est complètement chargée et maximale ($DOD=1$) quand la batterie est vide) [65].

$$E_0 = \tilde{n} \cdot (2.15 - DOD(2.15 - 2)) \quad (IV.23)$$

La charge totale tirée de la batterie à l'instant en fonction de (\tilde{n}) sa valeur à l'instant ($\tilde{n} - 1$) est donnée par l'équation suivante [65]:

$$C_{z,\tilde{n}} = C_{z,\tilde{n}-1} + \frac{\delta t}{3600} \cdot I_{bat\tilde{n}}^{k_p} \quad (IV.24)$$

Où C_z est la capacité tirée de la batterie à chaque pas de temps auquel la valeur du courant I_{bat} est relevée ; k_p est le coefficient de Peukert ($k_p = 1.12$).

En conséquence, la profondeur en décharge DOD est donnée par :

$$DOD_{\tilde{n}} = \frac{C_{R,\tilde{n}}}{C_{pb}} \quad (IV.25)$$

Où C_{pb} est la capacité de Peukert en fonction du temps de décharge à courant constant exprimée par :

$$C_{pb} = I_{bat}^{Kp} \cdot T_{déch} \quad (IV.26)$$

En nous référant à la figure IV.6, la tension à la sortie d'une batterie s'écrit :

$$V_{bat} = E_0 - RI_{bat} \quad (IV.27)$$

L'équation quadratique de la puissance de la batterie est la suivante :

$$P_{bat} = V_{bat}I_{bat} = (E_0 - RI_{bat}) \cdot I_{bat} \quad (IV.28)$$

La valeur algébrique du courant de la batterie peut être calculée par :

$$I_{bat} = \frac{E_0 - \sqrt{E_0^2 - 4RP_{bat}}}{2R} \quad (IV.29)$$

- Nous avons simulé le comportement de la batterie dans l'installation en la faisant débiter sur une charge de puissance variable entre 0 et 1000W. La puissance de charge de la batterie est assurée par le réseau hybride multisources à énergie renouvelable. La figure IV.7 présente les variations temporelles de la puissance mise en jeu, le courant et la profondeur de décharge (DOD) de la batterie durant six heures de fonctionnement.




Figure IV.7. Courbe de variations du courant et du DOD de la batterie

IV.5.4 Modèle du groupe électrogène

En tant que dernier système de puissance de secours, le générateur diesel est toujours prêt à fournir à la charge lorsque l'énergie requise dépasse l'énergie totale produite par le système hybride. L'énergie générée (E_{DG}) par un générateur diesel (DG) est donnée comme suit [66]:

$$E_{DG} = \eta_{DG} t \int P_{DG} \cdot dt \quad (IV.30)$$

Où P_{DG} est la puissance nominale du DG, η_{DG} est son rendement et t est le temps de fonctionnement.

Dans le but de diminuer la consommation de carburant, la capacité du générateur doit être choisie en fonction de la demande de charge maximale attendue.

IV.6 Gestion énergétique du CHAER

Contrairement aux réseaux interconnectés qui sont considérés à puissance infinie, les CHAER sont classés comme des réseaux à faible puissance [67]. De plus, vu que l'alimentation des CHAER est assurée par des sources renouvelables, ces réseaux se caractérisent par une instabilité provoquée par l'intermittence des sources renouvelables et une discontinuité due à la disponibilité aléatoire ou périodique de ces sources. Compte tenu de ces contraintes, la conception des CHAER doit garantir continuellement la couverture du besoin énergétique de la charge. C'est ainsi, qu'une stratégie de gestion des flux énergétiques régissant les éléments du réseau est nécessaire, cette gestion doit satisfaire les exigences de la charge connectée au CHAER d'une façon instantanée ou planifiée (à court et moyen terme). De plus, elle doit prendre en considération les contraintes fonctionnelles et comportementales de la charge au cours du temps. Enfin, une gestion efficace doit offrir à la charge une bonne qualité d'énergie caractérisée par la protection des éléments du réseau (la batterie, les générateurs à énergie renouvelable) et par la stabilité de la fréquence et de la tension. En l'absence de source complémentaire (Groupe électrogène), plusieurs stratégies de gestion ont été tracées en vue de répondre aux exigences de la charge et du réseau. La dynamique d'une CHAER liée à l'aspect comportemental des sources à énergie renouvelable exige le développement d'une stratégie de gestion des énergies mises en jeux. Cette stratégie doit tenir compte [56, 60] :

- du profil de charge : les variations diurnes, les variations saisonnières, les pics et les creux.
- des caractéristiques des sources renouvelables : les valeurs moyennes, la fréquence des événements, les valeurs extrêmes, les variations diurnes et saisonnières.

- des caractéristiques des générateurs à énergies fossiles : le type de carburant, les limites de fonctionnement.
- de la configuration du système : le nombre et les types de composants (les sources d'énergie renouvelable, les sources classiques, les charges contrôlables, les types de stockage, les convertisseurs de puissance).
- des normes de qualité de l'énergie : les exigences en ce qui concerne les variations de la fréquence et de la tension.

Basée sur la supervision du CHAER, la gestion du réseau doit déboucher sur une prise de décision concernant l'instant et la durée de connexion de la charge au générateur convenable, tout en respectant la sécurité des éléments du réseau et les exigences fonctionnelles de la charge. Dans la littérature scientifique, différentes stratégies de gestion ont été développées [68], ces stratégies visent essentiellement à répondre aux exigences du réseau : optimisation de l'énergie produite, garantir l'alimentation permanente de la charge et respecter la sécurité des générateurs et des convertisseurs. Cependant dans des applications particulières, certaines stratégies de gestion sont plus efficaces que d'autres, l'efficacité dépend des objectifs du réseau et des contraintes de gestion.

IV.6.1 Gestion du stockage

Deux types de gestions sont adoptés : à court terme et à long terme [60], la stratégie de gestion de stockage à court terme permet de filtrer les fluctuations des énergies renouvelables et/ou de la charge. Cette stratégie réduit également le nombre de cycles démarrage/arrêt du groupe électrogène ce qui diminue la consommation de carburant. La gestion à long terme est utilisée de manière à alimenter la charge sur une période de temps plus longue. Cette stratégie permet d'améliorer l'équilibre énergétique et de réduire les cycles démarrage/arrêt du groupe électrogène. Avec cette stratégie, le groupe électrogène est arrêté jusqu'à ce que l'état de charge du système de stockage atteigne un niveau minimal. D'une manière cyclique, une fois ce seuil est atteint, le groupe électrogène est remis en service jusqu'à ce que l'énergie stockée atteigne un niveau maximal. Les algorithmes des deux types de gestion sont :

- **Gestion à court terme :**
 - alimenter continuellement la charge.
 - stocker l'excès de l'énergie produite.
 - si l'énergie produite devient inférieure au besoin de la charge, alors ajouter le complément d'énergie à partir de l'énergie stockée.

- si l'énergie totale produite ne couvre plus le besoin de la charge, alors mettre en service le groupe électrogène.

➤ **Gestion à long terme :**

- tester le niveau de l'énergie stockée :
 - Si le niveau est supérieur à seuil minimal, alors alimenter la charge à partir de cette énergie.
 - Sinon alimenter le réseau avec le groupe électrogène en cas d'absence d'énergie renouvelable.

IV.6.2 Gestion des charges

Elle consiste à agir sur les charges à alimenter pour varier la demande d'énergie, les charges sont alors connectées et déconnectées par ordre de priorité (Figure IV.8).

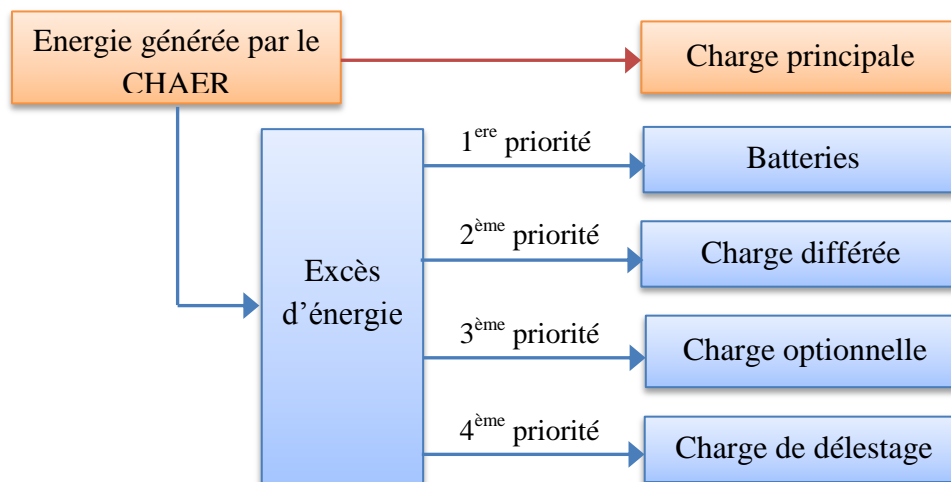


Figure IV.8. Diagramme de gestion des priorités des charges

La stratégie de contrôle à court terme consiste à connecter et à déconnecter les charges en fonction du dépassement de certains seuils fixes pour la fréquence du bus à courant alternatif. Selon les variations de la fréquence, les charges sont connectées de manière progressive. La charge de délestage (dump load) est une charge dont la puissance peut être modifiée en fonction de la déviation de fréquence. Ce qui permet de régler la fréquence du réseau dans des conditions de surplus d'énergie.

La gestion à long terme assure l'équilibre énergétique sur de longs intervalles de temps. Les charges différées et optionnelles ont une priorité réduite sur une partie de la journée. Elles sont connectées seulement quand leur régime de priorité est élevé. La stratégie de gestion des charges est aussi utilisée pour réduire les pertes énergétiques au niveau du groupe électrogène [69].

IV.6.3 L'approche de planification énergétique proposée

Nous proposons une approche de planification énergétique qui consiste à optimiser l'exploitation de l'énergie électrique d'un réseau hybride multi-sources autonome à énergies renouvelables. Basée sur des critères d'optimisation du coût de production de l'énergie électrique, la décision des connexions de la charge aux sources renouvelables ou au groupe électrogène est déterminée par l'algorithme de planification présenté par la figure IV.9.

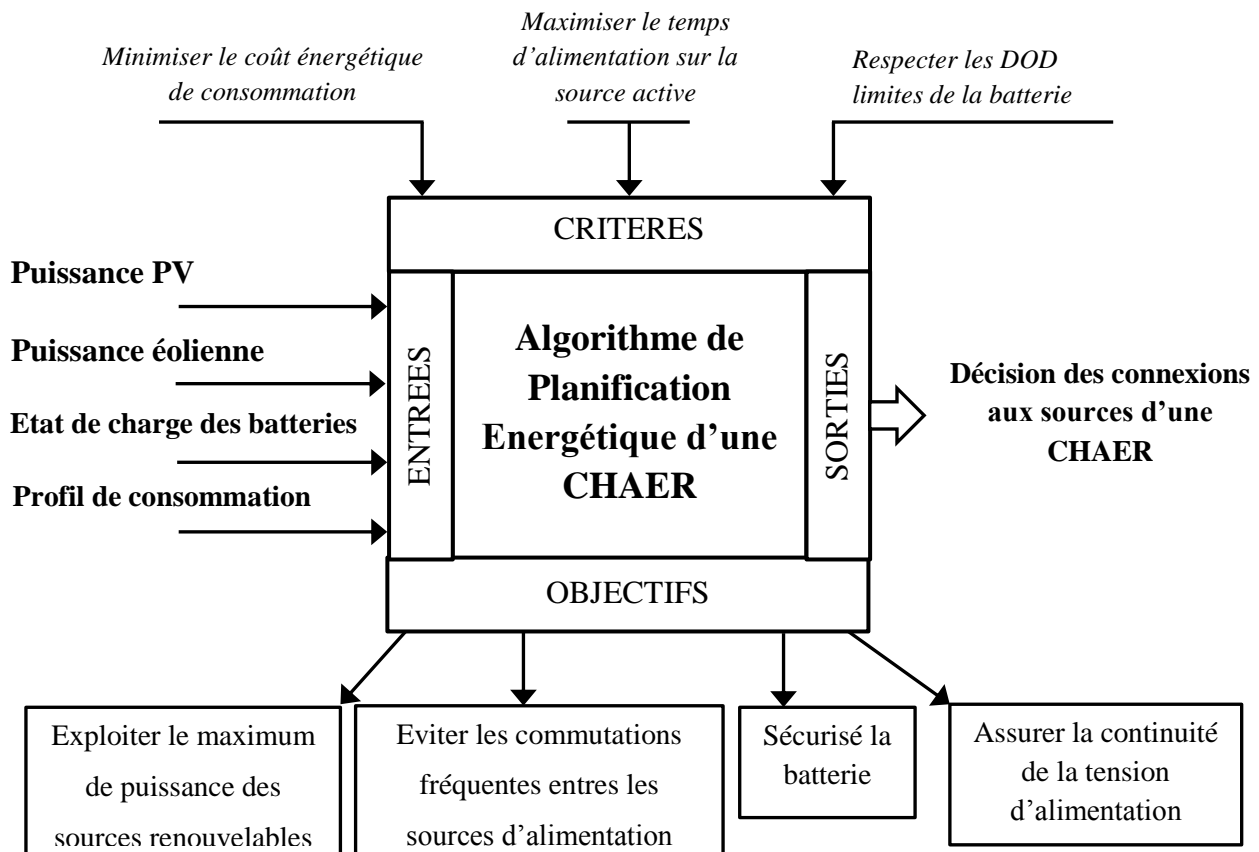


Figure IV.9. Schéma UML de planification énergétique d'une CHAER

La planification énergétique a été développée et simulée en utilisant la méthode de commutation. Cette méthode consiste à exécuter continuellement les tâches de test et de calcul des puissances mises en jeu par la CHAER de manière à maximiser le temps d'intégration de l'énergie électrique produite par les générateurs photovoltaïque et éolien. L'algorithme est structuré en cinq étapes (voir l'organigramme Figure IV.10) :

- Estimer les valeurs des énergies produites par les sources renouvelables du réseau (P_{pv} , P_w), de la profondeur de décharge des batteries (DOD) et des énergies consommées par la charge (P_{ch}) et cumulée dans les batteries (P_{bat}).

- Comparer l'énergie totale estimée fournie par les sources renouvelables à celle du besoin de la charge :
 - ✓ en cas de couverture du besoin, la charge est alimentée par le panneau photovoltaïque et le générateur éolien,
 - ✓ sinon l'énergie des batteries est ajoutée à celles provenant des sources renouvelables (en respectant l'état limite de décharge des batteries).
- Au cas où le besoin en énergie dépasse l'énergie totale produite par le panneau photovoltaïque, le générateur éolien et les batteries ; l'alimentation de la charge sera confiée au groupe électrogène.
- Par la suite, déduire l'énergie non consommée pour la recharge des batteries.
- Calculer le taux d'intégration des énergies renouvelables dans le système et établir un bilan énergétique de l'installation.

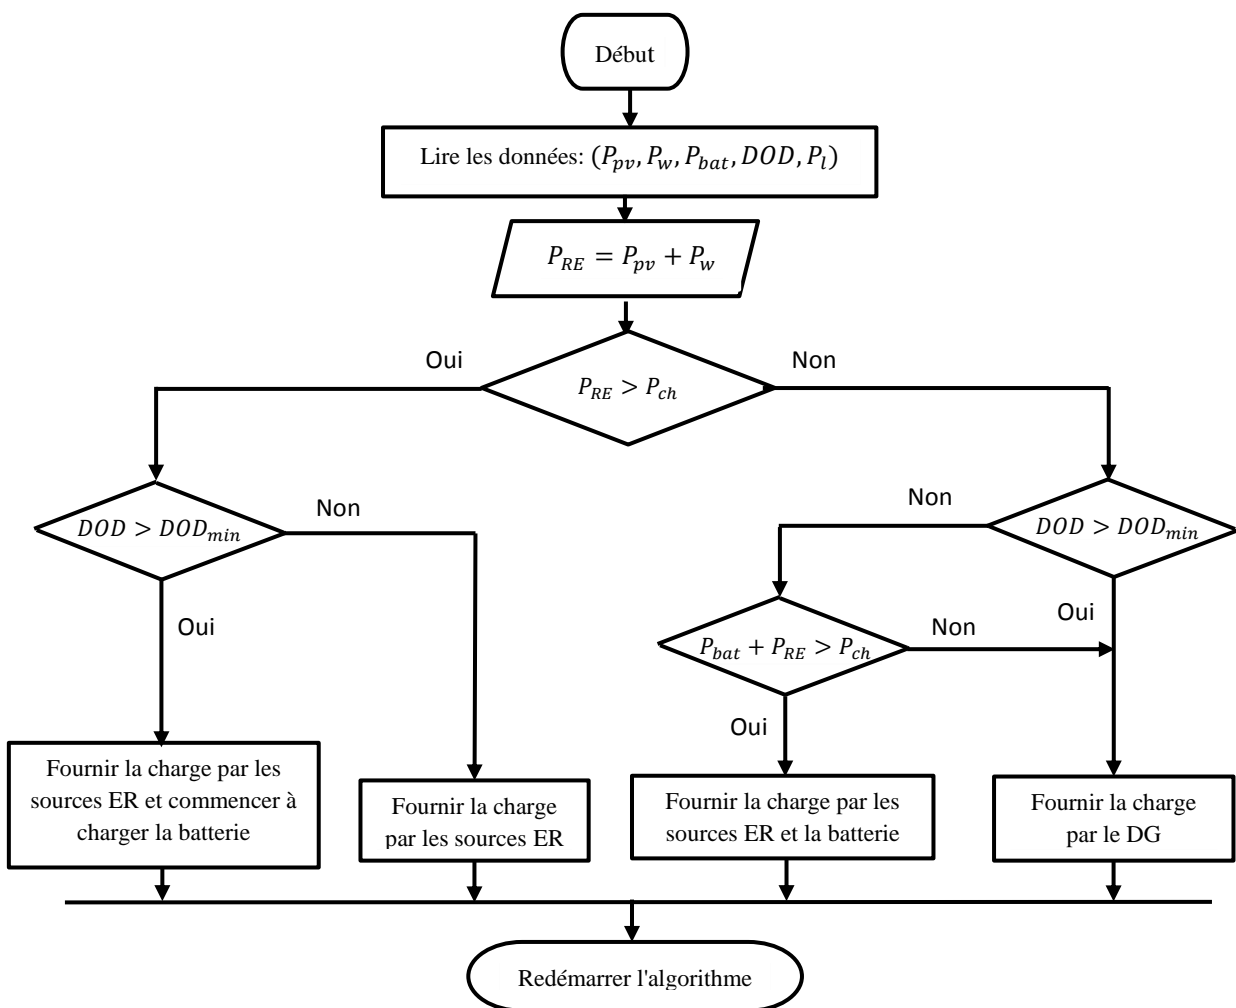


Figure IV.10. Organigramme de planification énergétique du CHAER

IV.7 Conception d'un schéma de commande et réglage optimal du CHAER [70]

La plupart des méthodes de commande des systèmes hybrides traitent chaque source d'énergie séparément, cette configuration ne permet pas une interaction instantanée entre les systèmes concernés, ceci entraîne une réponse moins rapide en cas d'augmentation soudaine de la demande de la charge ou d'une défection d'une source d'énergie. Dans ce contexte, nous proposons une nouvelle stratégie de commande, dans laquelle le système hybride est considéré comme un seul système MISO (multiple input, single output), cette structure permet une coopération efficace entre les systèmes d'énergie et une exploitation optimale des énergies renouvelables. La figure IV.11 présente le schéma bloc de la boucle de commande de la configuration proposée. Où R_{PV} , R_W et R_{RE} sont la puissance de référence des générateurs PV, éolien et de leur somme respectivement, P_{PV} , P_W et P_{RE} sont les puissances réelles produites par les générateurs PV, éolien et leur somme respectivement. Les erreurs de poursuite des boucles de commande des générateurs PV et éolien sont respectivement: e_{pv} et e_w , tandis que e_{RE} exprime l'écart entre l'énergie totale de référence du CHAER et celle produite réellement.

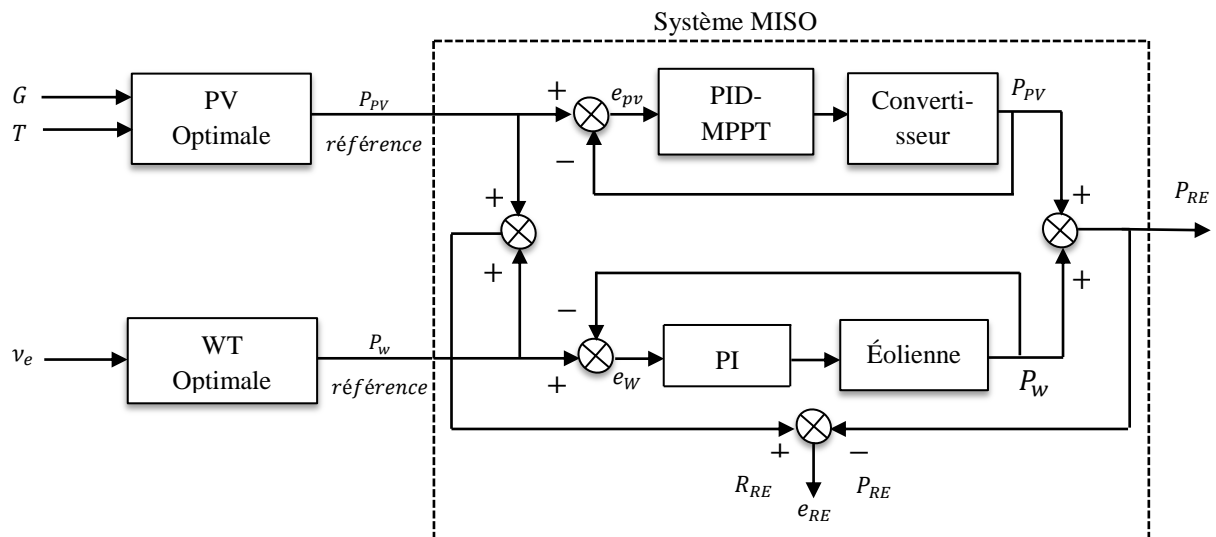


Figure IV.11. Schéma bloc de la stratégie de commande proposée

Le problème sera alors formulé comme suit: comment trouver les paramètres optimaux des deux contrôleurs qui minimisent simultanément les erreurs de poursuite mentionnées ci-dessus, il s'agit là d'un problème de minimisation multi-objectif. Avant d'aborder la résolution de ce problème, nous allons dans ce qui suit, décrire les boucles de commande adoptées pour chaque sous système.

IV.7.1 Boucle de commande avec contrôleur PID MPPT pour le système PV

La figure IV.12 représente le schéma synoptique de la boucle de commande du générateur PV.

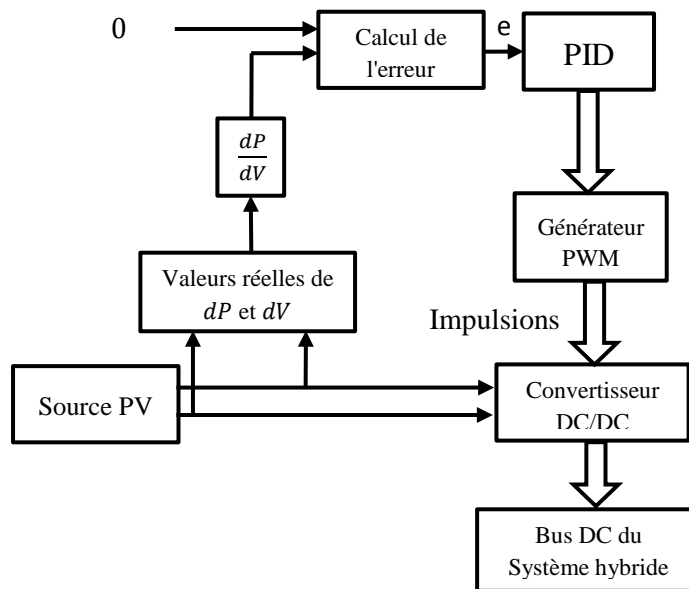


Figure IV.12. Schéma synoptique de la Structure de commande MPPT PID du générateur PV

Le but de la commande du générateur PV est d'en extraire le maximum de puissance électrique que permettent les conditions climatiques, il s'agit donc de trouver le point de puissance maximale MPPT à tout moment, ce point correspond à la condition :

$$\frac{dP_{pv}}{dV_{pv}} = 0 \quad (\text{IV.31})$$

Ce point est alors pris comme référence à atteindre, les variations du courants et de la tension sont mesurées à la sortie du générateur PV, la dérivée de la puissance par rapport à la tension est calculée et comparée à la valeur de référence (0). Le rôle du contrôleur PID est de généré le rapport cyclique du signal PWM (Pulse Width Modulation) pour avoir la tension désirée à la sortie du convertisseur DC-DC.

IV.7.2 Boucle de commande avec contrôleur PI pour l'éolienne

Il existe plusieurs méthodes de commande pour l'éolienne selon différentes boucles de commande (voir notamment [64] [71, 72]). On a choisi la boucle de commande en puissance, il s'agit d'imposer une puissance de référence maximale selon la vitesse actuelle du vent.

La dynamique du couple électromagnétique/puissance active du générateur peut être traduite par une fonction de transfert du deuxième ordre avec un zéro, [64] :

$$\frac{K_{pt}(T_z s + 1)}{(T_\Sigma s + 1)(T_{pt} s + 1)}$$

Avec : T_{pt} constante de temps principale, T_Σ constante de temps parasite, K_{pt} gain. Le zéro de la fonction de transfert peut être compensé par un filtre du premier ordre ayant une constante de temps T_z .

Dans la boucle de commande en puissance, on utilise comme entrée la vitesse rotationnelle Ω_e (elle-même en fonction du vent disponible) et qui deviendra notre vitesse rotationnelle de référence $\Omega_{réf}$, on peut alors obtenir le couple mécanique de référence $C_{réf}$ du générateur par la relation suivante [64]:

$$C_{mec(opt)} = C_{réf} = K \Omega_{réf}^2 \quad (IV.32)$$

En conséquence, et en se référant à l'équation (IV.16), on peut obtenir la puissance active de référence du générateur comme suit:

$$P_{mec(opt)} = P_{réf} = K \Omega_{réf}^3 \quad (IV.33)$$

Où :

$$K = \frac{1}{2} \frac{C_p(\lambda_{opt})}{\lambda_{opt}^3} \rho \pi \quad (IV.34)$$

La boucle de commande du système éolien comme le montre la figure IV.13.

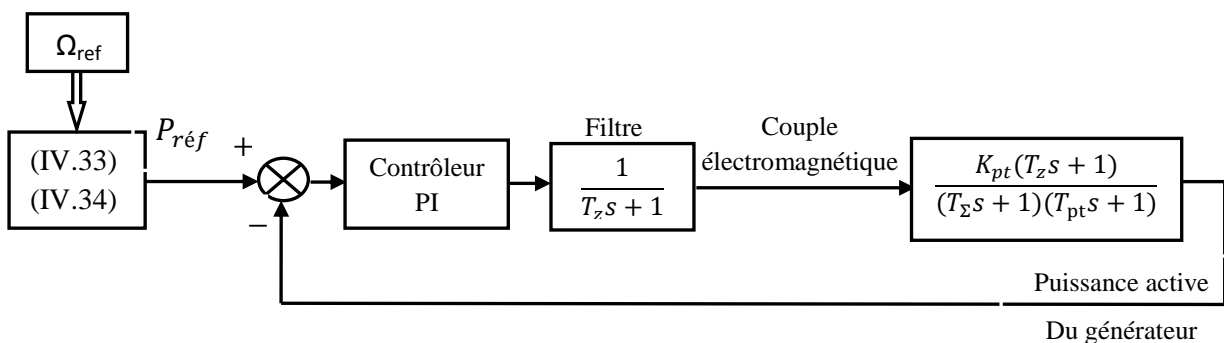


Figure IV.13. Structure de commande PI de l'éolienne

IV.7.3 Réglage optimal des paramètres des contrôleurs du CHAER

Comme expliqué précédemment (section IV.7), les paramètres des contrôleurs du générateur PV et de l'éolienne seront réglés par la minimisation de l'écart des erreurs de

poursuite (Figure IV.11). Nous avons choisis le critère ITAE comme fonction objective, elle sera donc exprimée par:

$$J = \begin{bmatrix} J_1 \\ J_2 \\ J_3 \end{bmatrix} \quad (IV.35)$$

Où :

$$J_1 = \int_0^{\infty} t |e_{PV}| dt \quad (IV.36)$$

$$J_2 = \int_0^{\infty} t |e_W| dt \quad (IV.37)$$

$$J_3 = \int_0^{\infty} t |e_{RE}| dt \quad (IV.38)$$

Le problème de minimisation multi-objectif peut alors être posé comme suit:

$$\begin{aligned} & \min_{(K_{p_{pv}}, K_{i_{pv}}, K_{d_{pv}}, K_{p_w}, K_{i_w})} J \\ \text{Sujet à } & \begin{cases} K_{p_{pv}}^{min} \leq K_{p_{pv}} \leq K_{p_{pv}}^{max} \\ K_{i_{pv}}^{min} \leq K_{i_{pv}} \leq K_{i_{pv}}^{max} \\ K_{d_{pv}}^{min} \leq K_{d_{pv}} \leq K_{d_{pv}}^{max} \\ K_{p_w}^{min} \leq K_{p_w} \leq K_{p_w}^{max} \\ K_{i_w}^{min} \leq K_{i_w} \leq K_{i_w}^{max} \end{cases} \end{aligned} \quad (IV.39)$$

Où $(K_{p_{pv}}, K_{i_{pv}}, K_{d_{pv}}, K_{p_w}, K_{i_w})$ sont les paramètres des contrôleurs PID-MPPT (générateur PV) et PI du générateur éolien, (K_0^{min}, K_0^{max}) sont leurs valeurs minimale et maximale.

IV.7.4 Résolution du problème de minimisation multiobjective

Le problème de minimisation multiobjective (Eq. IV.39) peut être résolu par différentes méthodes et algorithmes d'optimisation. De notre part, nous avons choisi l'algorithme génétique GA, car ce dernier offre de nombreux avantages parmi lesquels:

- Le GA étant une technique de calcul évolutif, elle fournit de bonnes solutions approximatives à des problèmes qui ne peuvent pas être résolus par d'autres techniques.
- Compte tenu des difficultés de l'optimisation multi-objective, GA n'essaie pas toutes les combinaisons possibles, il essaie plutôt de se rapprocher intelligemment de la meilleure solution sans imposer de restrictions sur l'espace de recherche. Par conséquent, beaucoup plus de variables peuvent être utilisées (parallélisme implicite).

- Le GA est considérée comme unique par sa structure chromosomique, lorsqu'elle est choisie et construit judicieusement, la structure chromosomique peut fonctionner à merveille en termes de résolution, de temps et de qualité des solutions par rapport à d'autres techniques.

➤ **Étapes de résolution du problème de minimisation multi-objective par GA :**

Les étapes de l'optimisation multi-objective GA du problème proposé sont résumées par:

Étape 1: Générer une solution initiale du problème en créant une population de chromosomes dont la structure est formée en une chaîne de génotype, chaque gène représente un paramètre ($K_{p_{pv}}$, $K_{i_{pv}}$, $K_{d_{pv}}$, K_{p_w} , K_{i_w}) du problème.

Étape 2: Évaluer les trois fonctions d'aptitude (fonctions objectives) dans le but de trouver les individus les plus prometteurs (chromosomes), l'évaluation du degré d'aptitude de chaque chromosome se fait simplement en lui assignant une valeur.

Étape 3: Reproduire une nouvelle génération (progéniture) en appliquant des opérations génétiques sur chaque chromosome pour simuler leur mécanisme d'évolution, ces opérations génétiques sont: sélection, croisement et mutation.

Étape 4: Remplacer la population réelle par la nouvelle.

Étape 5: Déterminer si l'évolution génétique doit cesser ou non. Si les conditions finales sont atteintes, mettre fin à l'évolution génétique; Sinon, revenir à l'étape 2.

L'algorithme génétique proposé est utilisé dans un mode en ligne, dans lequel la minimisation des fonctions objectives présentées dans les équations (IV.36) - (IV.38) est engagée à chaque instant, prenons en compte l'évolution des conditions météorologiques et les valeurs de demande de charge réelles, et garantissant ainsi une erreur minimale par rapport à la puissance de référence.

Certains paramètres particulièrement importants de GA sont la taille de la population (nombre d'individus) et le nombre de générations. Si le nombre de chromosomes est trop petit, GA a moins de possibilités pour effectuer le croisement et seulement une petite partie de l'espace de recherche est exploré. Les petites populations provoquent la convergence prématurée. Tandis qu'une grande population prend plus de temps à exécuter, mais converge plus rapidement que les petites populations. Un certain nombre de 20 individus sont utilisés comme un compromis. Les taux de croisement plus élevés conduisent à des meilleures valeurs de la fonction d'aptitude relative. Un taux de 0,80 de croisement a été utilisé. Une zéro probabilité de mutation provoque une convergence prématurée à une valeur optimale. Une

probabilité de mutation plus élevée, d'autre part, provoquent des fluctuations et perturbent la convergence. En général, la probabilité de mutation devrait être suffisante pour élargir l'espace de recherche élevé, mais assez bas pour assurer une convergence rapide. Dans ce sens, une probabilité de 10% de mutation a été utilisée. La mise en œuvre de l'algorithme proposé a été réalisée à l'aide de GA Toolbox dans MATLAB / SIMULINK en considérant les paramètres présentés dans le tableau IV.2

Tableau IV.2. Paramètres de l'algorithme génétique

| Paramètres | Valeur |
|-------------------------|----------|
| Méthode de sélection | Roulette |
| Taille de la population | 20 |
| Taux de croisement | 0.8 |
| Taux de mutation | 0.1 |
| Génération maximale | 100 |

IV.8 Application de l'approche proposée

Afin de prouver l'efficacité de la méthodologie proposée, nous avons simulé une solution globale d'approvisionnement en énergie renouvelable d'une ferme agricole située dans la ville de Skikda (nord-est de l'Algérie, coordonnées géographiques: 37 ° de latitude nord, 6,6 ° de longitude est et 9 m au-dessus de l'altitude du niveau de la mer), basée sur une centrale hybride autonome PV/Wind/Diesel. Les données recueillies de la consommation de l'électricité de cette ferme pour l'année 2015 sont illustrées dans le tableau IV.3.

Tableau IV.3. Données de la consommation d'électricité de la ferme

| Période | consommation d'électricité | Demande de charge moyenne |
|--|----------------------------|---------------------------|
| 1 st Janvier – 31 th Mars | 2550 kWh | 1,18055 kW/Jour |
| 1 st Avril – 30 th Juin | 2505 kWh | 1,14697 kW/Jour |
| 1 st Juillet – 30 th Septembre | 2421 kWh | 1,09646 kW/Jour |
| 1 st Octobre – 31 th Décembre | 2533 kWh | 1,14719 kW/Jour |

L'analyse des données a révélé une consommation énergétique moyenne quotidienne de 23,6 kWh et une demande maximale de 4,6 kW en hiver. Les données quotidiennes de la

vitesse du vent, du rayonnement solaire et de la température ambiante obtenues par le logiciel RETScreen pour l'année 2015 à Skikda sont présentées sur la figure IV.14.

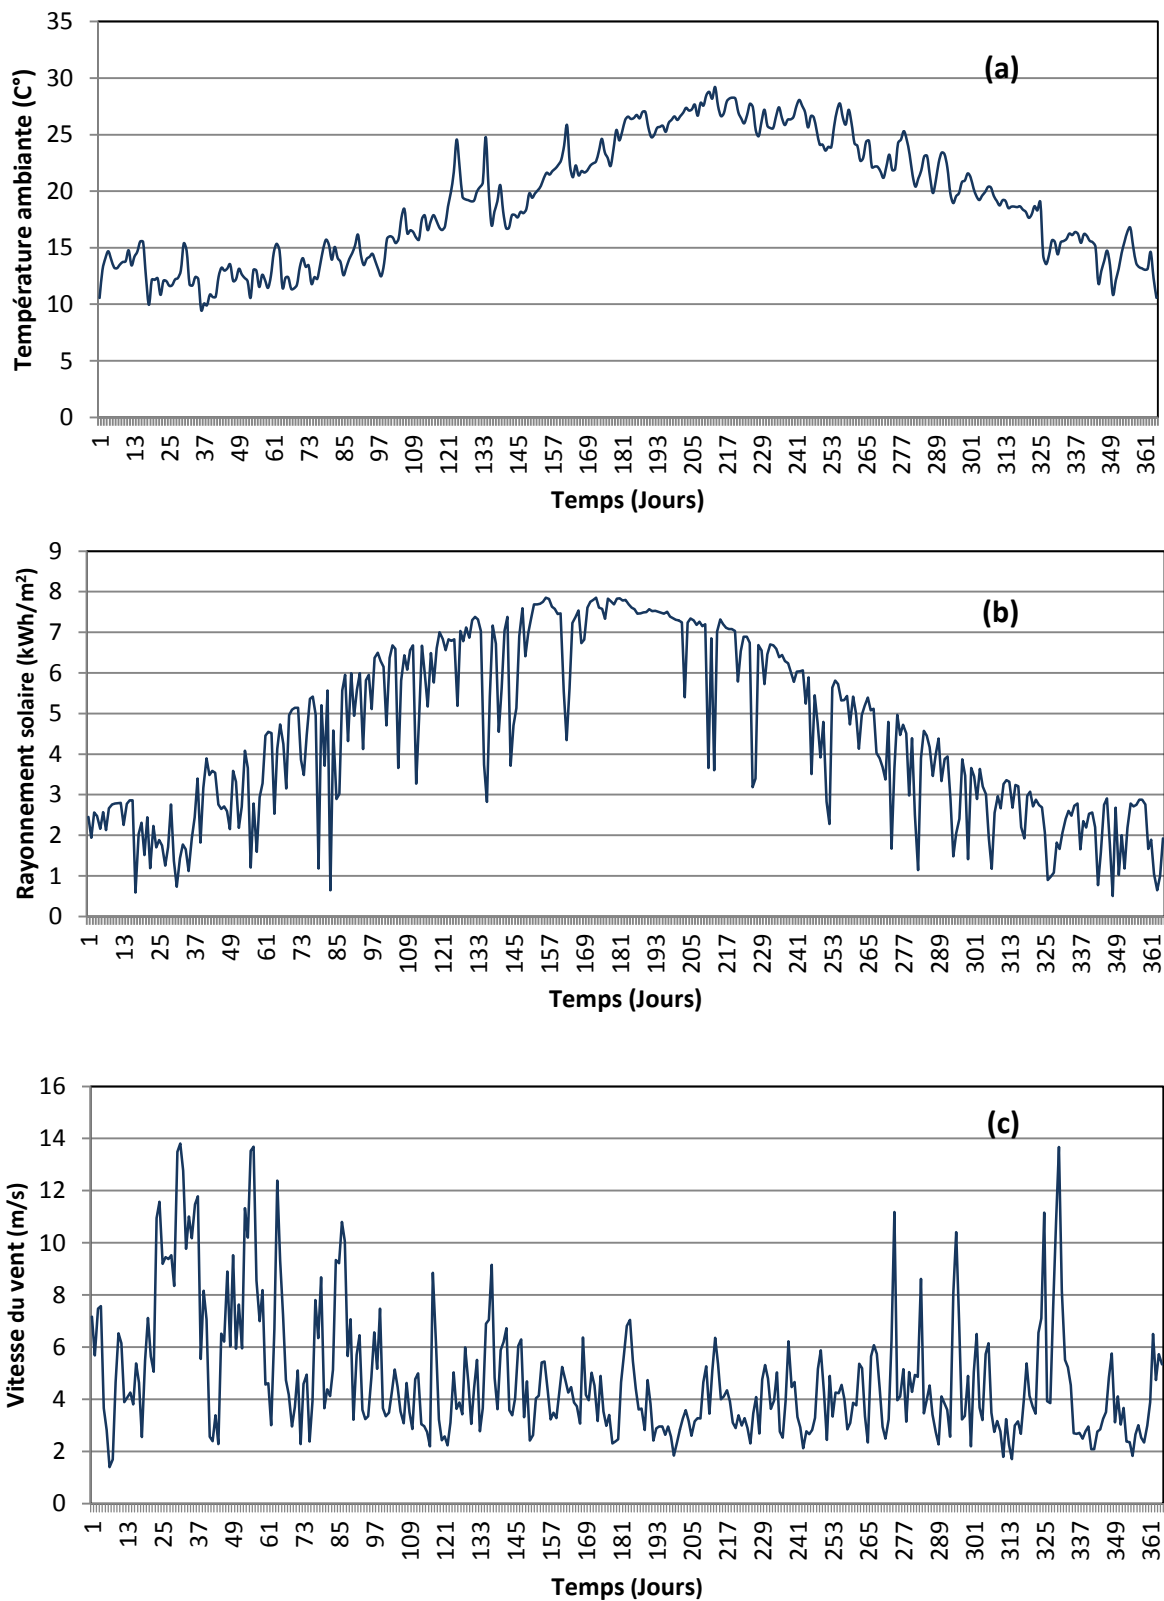


Figure IV. 14. Valeurs moyennes journalières pendant une période d'une année de conditions météorologiques: a) température ambiante, b) rayonnement solaire et c) vitesse du vent

Les caractéristiques techniques de chaque générateur du CHAER sont données dans le tableau IV.4. Une puissance nominale de 4,6 kW pour le DG a été choisie en fonction de la demande de charge maximale attendue enregistrée pendant une journée d'hiver.

Tableau IV.4: Caractéristiques techniques des générateurs

| Paramètres | Valeur |
|--|---|
| <i>Spécifications du module PV</i> | |
| Tension en circuit ouvert | 22.2 V |
| Courant de court-circuit | 5.45 A |
| Tension de fonctionnement optimale | 17.2 V |
| Courant de fonctionnement optimal | 4.95 A |
| Puissance maximale à STC | 85 W |
| <i>Spécifications de l'éolienne</i> | |
| Tension de sortie | 48 V |
| Vitesse de vent minimale (vitesse de démarrage) | 2,5 m/s |
| Vitesse nominale du vent | 8 m/s |
| Vitesse de vent maximale | 10 m/s |
| Puissance nominale | 2 KW |
| Paramètres de la fonction de transfert : couple électromagnétique/puissance active | $T_{pt} = 0.36 s$ $T_{\Sigma} = 0.01 s$ $K_{pt} = 35$ $T_z = 1.42 s$ |
| <i>Spécifications de la batterie</i> | |
| Capacité nominale | 210 Ah |
| Tension nominale | 12 V |
| DOD | 80% |
| Efficacité | 85% |
| <i>Spécifications DG</i> | |
| Puissance nominale | 4,6 KW |

La configuration suivante du CHAER a été choisie selon HOMER :

Tableau IV.5: Configuration choisie du système hybride

| Paramètres | Valeur |
|----------------------|--------|
| Nombre de modules PV | 18 |
| Nombre d'éoliennes | 1 |
| Nombre de batteries | 4 |

IV.8.1 Etude comparative de l'approche proposée par rapport aux méthodes classiques

Afin d'étudier la performance de la stratégie de commande proposée, une étude comparative est entreprise avec la stratégie de commande décentralisée conventionnelle, dans laquelle les générateurs photovoltaïques et éoliens sont commandés séparément avec les méthodes classiques : MPPT avec l'algorithme Perturbation & Observation (P&O) et le contrôleur PI avec placement de pôles pour les générateur PV et éolien respectivement.

- **Pour les générateur PV** : l'algorithme MPPT P&O est le plus couramment utilisé dans la pratique en raison de sa facilité de mise en œuvre, la méthode est considérée comme une approche itérative, dans laquelle la tension de fonctionnement du PV est perturbée régulièrement et oscillée autour du point de puissance maximum $dP/dV = 0$ [73, 74].
- **Pour le générateur éolien** : la procédure de placement de pôles, détermine les pôles désirés en boucle fermée en fonction des exigences de la réponse transitoire et le régime permanent, telles que : le temps de réponse, le dépassement, le coefficient d'amortissement ou la bande passante.

La fonction de transfert en boucle fermée du système corrigé présente deux pôles et un zéro, il s'agit de la dynamique d'un système du deuxième ordre :

$$\frac{1}{s^2 + 2zw_n \cdot s + w_n^2}$$

On pourra donc imposé les performances désirée par un choix judicieux de la fréquence naturelle ω_n et du facteur d'amortissement z . Les paramètres du régulateur PI seront donc donnée en fonction de ω_n et z comme suite [64] :

$$\begin{cases} K_p = \frac{T_i \cdot T_{pt}}{K_{pt}} \cdot w_n^2 \\ T_i = \frac{2z}{w_n} - \frac{1}{w_n^2 \cdot T_{pt}} \end{cases} \quad (IV.40)$$

Après application numérique, on trouve les valeurs suivantes : $K_p = 0.59, T_i = 0.68$

La figure suivante présente le schéma du CHAER considéré, modélisé sous environnement Simulink.

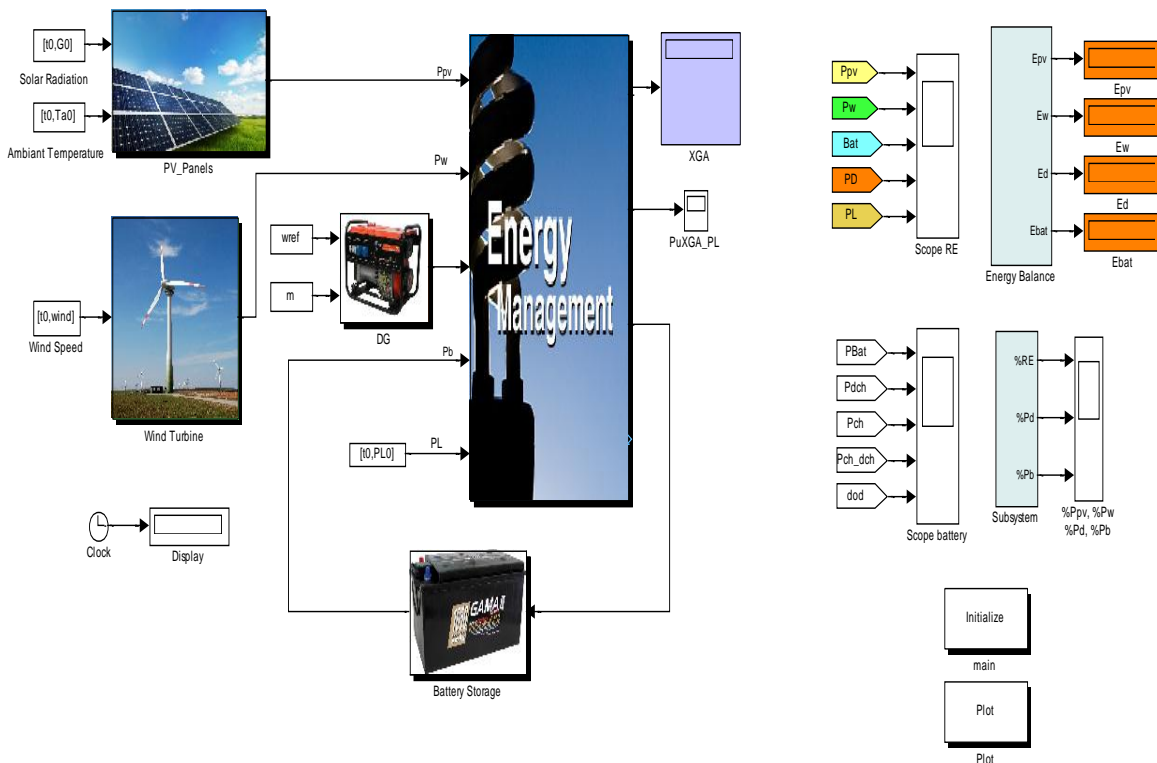


Figure IV. 15. Schéma de simulation sous Matlab/Simulink du CHAER

IV.8.2 Résultats de la simulation

La figure IV.16a montre la puissance renouvelable générée P_{RE} avec les différentes stratégies de commande dans les mêmes conditions météorologiques. Pour plus de détails, un zoom particulier sur la période comprise entre le 122^{ème} jour et le 135^{ème} jour est illustré dans la figure IV.16b. Quant aux figures IV.17 et IV.18, elles représentent les puissances de sortie du banc de batteries et du générateur diesel respectivement.

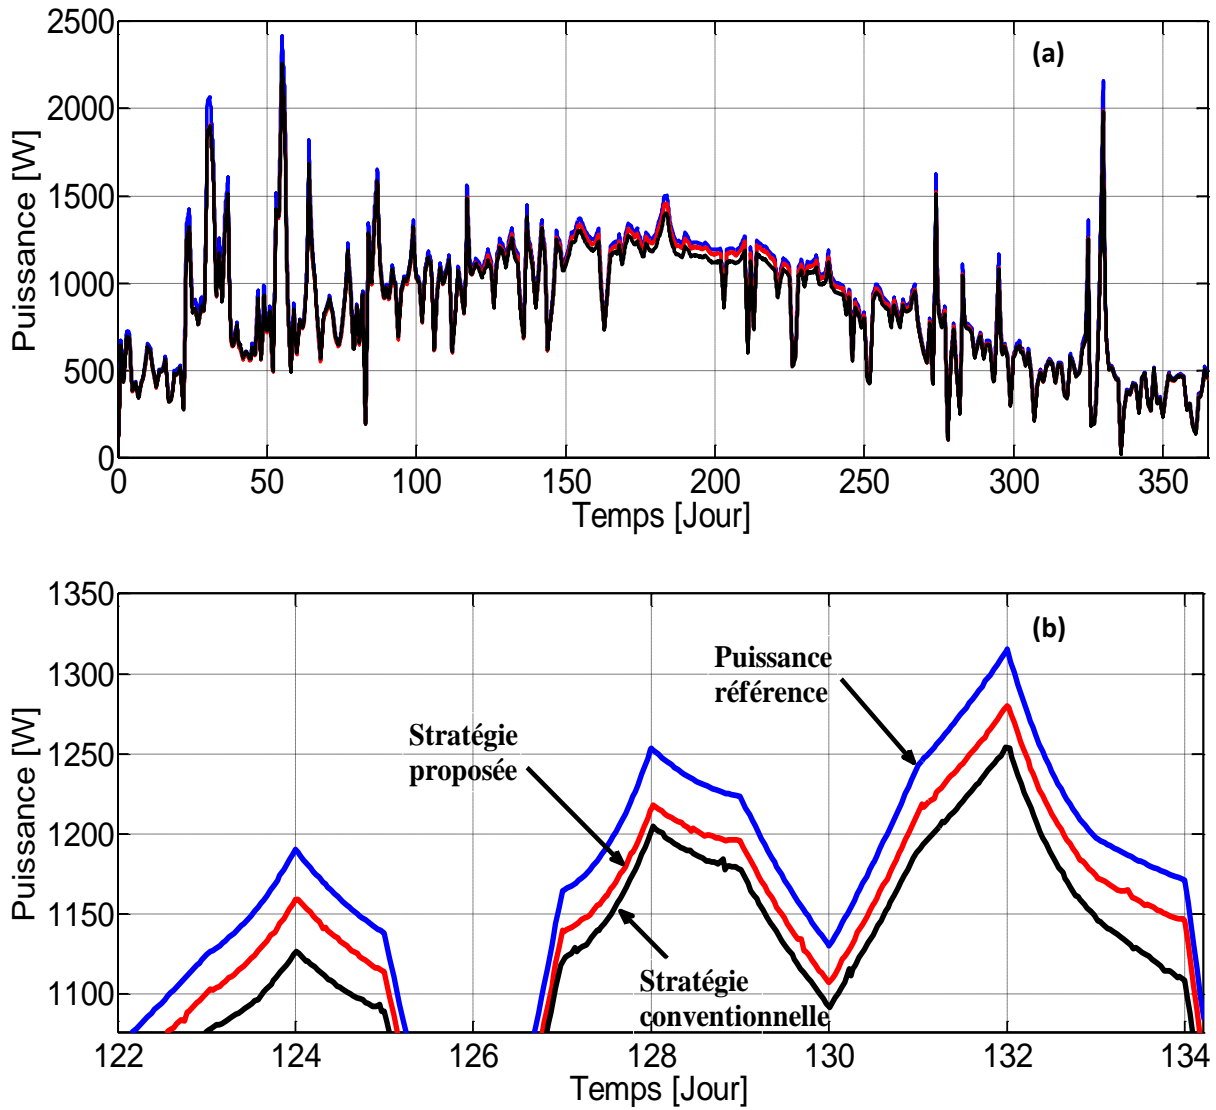


Figure IV.16. Variation de la puissance totale générée




Figure IV.17. Variation des puissances de charge et de décharge de la batterie




Figure IV.18. Variation de la puissance produite par le générateur diesel

➤ **Commentaires :**

L'analyse des résultats montre une moyenne de production d'électricité de 21,24 kWh / jour et une puissance crête de 2,436 kW lorsque la stratégie de commande proposée est appliquée, tandis qu'une moyenne de production de 21,18 kWh / jour et une puissance crête de 2,422 kW sont notées lors de l'application des méthodes de commande conventionnelles. Bien que la différence puisse paraître minime, sur une longue durée (des années), la stratégie proposée permettra une exploitation maximale des énergies renouvelables. La figure IV.17 représente la puissance de sortie du banc de batteries, on constate que lorsqu'on applique l'approche proposée, la batterie est moins sollicitée par rapport à la méthode décentralisée. Par conséquent, le banc de batteries obtient une puissance d'entrée plus élevée (573,37 kWh contre 514,83 kWh). Concernant le mode de décharge sous les limites acceptées du DOD et le cycle de vie du stockage de la batterie, un profit de 1,74% du DOD quotidien moyen a été observé en utilisant l'approche proposée.

La figure IV.18 représente la puissance de sortie du générateur diesel, on constate que la production journalière moyenne du DG et son temps de fonctionnement sont tous deux réduits, au totale 124 heures d'utilisation du générateur ont été économisés. Ces améliorations concernant le temps de charge des batteries et le temps de fonctionnement du DG sont principalement dues à une plus grande production de l'énergie, cet excédent de production est non seulement bénéfique économiquement mais aussi écologiquement, car la réduction du temps de fonctionnement du DG minimise la quantité de CO₂ émise ainsi que la consommation du carburant. En plus, la réduction du temps de décharge des batteries au plomb-acide est essentielle pour l'amélioration de leur cycle de vie.

Le tableau IV.6 résume l'étude comparative des stratégies de contrôle du système hybride.

Tableau IV.6: Analyse des systèmes complémentaires

| Paramètre | Valeurs | |
|--------------------------------------|-------------------|-------------------|
| | méthode proposé | méthode original |
| <i>Batterie d'accumulateur</i> | | |
| Profondeur moyenne de décharge (DOD) | 72.89 % /Jour | 74.63 % /Jour |
| <i>générateur Diesel</i> | | |
| Production moyenne d'énergie | 68.7955 watt/Jour | 73.2053 watt/Jour |
| Emission moyenne de CO2 | 1.4711 kgCO2/Jour | 1,5654 kgCO2/Jour |

Les résultats de la gestion énergétique réalisée à l'aide de l'organigramme présenté dans la figure IV.10 sont présentés sur la figure IV.19. La variation de la puissance produite par la CHAER par rapport à la puissance demandée par la charge (profil relevé de la ferme) est tracée sur la figure IV.20, quant à la figure IV.21, une répartition des différentes énergies régissant la CHAER y est présentée.




Figure IV.19. Profils des puissances mises en jeu




Figure IV.20. Variation de la puissance demandée et la puissance produite du système hybride




Figure IV.21. Répartition de la puissance consommée

➤ **Commentaires :**

On peut vérifier à partir de la figure IV.20 que la puissance de sortie générée par le système hybride est égale à la puissance requise par la charge avec un déficit d'énergie de 0%.

Dans la figure IV.21, on constate que l'apport en énergie renouvelable pour l'installation est d'environ 74% du besoin, le groupe électrogène lui ne participe que par 3%. La faible sollicitation du groupe électrogène souligne l'efficacité de la gestion d'énergie proposée (figure IV.19). Quant à la batterie, elle intervient avec 23% du besoin puisque son rôle est

restreint à assurer les manques d'énergie de courte durée afin d'éviter le lancement multiple du groupe électrogène.

IV.9 Conclusion

Dans ce chapitre, une nouvelle stratégie commande et de gestion énergétique d'une CHAER a été présentée, cette dernière est composée d'un générateur PV, d'une éolienne, d'une batterie et d'un groupe électrogène. Nous avons proposé une nouvelle configuration de la boucle de commande du CHAER, en le considérant comme un seul système multivariable à deux entrées et une sortie. L'application de cette stratégie pour l'alimentation en énergie d'une ferme isolée située à la ville de Skikda (Nord-est d'Algérie), a donné des résultats prometteurs par rapport aux stratégies de commandes classiques (décentralisées) : La puissance demandée par le consommateur (charge) est satisfaite à 100%, avec une utilisation minimale des systèmes complémentaires (batterie, générateur diesel).

Conclusion générale

On assiste ces dernières années à un retour à la nature, en s'inspirant de ses différents phénomènes. Dans ce cadre, la recherche dans le domaine des systèmes bio-inspirés connaît une grande progression, permettant des solutions alternatives de plus en plus performantes dans tous les domaines. Cette thèse s'inscrit dans ce cadre, il s'agissait pour nous de faire la synthèse des algorithmes bio-inspirés les plus récents dans le domaine de l'automatique, tout en s'intéressant plus spécialement à ceux qui sont appliqués pour la commande des systèmes.

Dans le premier chapitre, une revue générale de l'état de l'art des principaux systèmes bio-inspirés les plus récents, de leurs sources d'inspiration, leurs caractéristiques, leurs algorithmes ainsi que de leurs potentielles applications, nous a permis de dégager le terrain à leur utilisation dans le domaine de la commande dans les chapitres qui suivent, selon le type du système à commandé, les contraintes qu'il subit ainsi que les performances souhaitées.

Ainsi, dans le deuxième chapitre, le système immunitaire artificiel, inspiré du principe de rétroaction du système immunitaire naturel "IMF", connu pour son adaptabilité à toute épreuves et sa grande robustesse face aux germes, microbes et autres agressions extérieures, nous a permis de mettre en œuvre un contrôleur IMF-PID robuste.

Le réglage optimal des paramètres de ce dernier, est effectué par l'intermédiaire de deux différents algorithmes bio-inspirés : PSO pour l'optimisation par essaims particulaires et ACO pour l'optimisation par colonie de fourmis, ces deux algorithmes sont directement inspirés de l'observation de l'apparition de phénomènes cohérents à l'échelle d'une population.

Ensuite, une stratégie de commande a été mise en place en deux étapes : une pour le réglage optimal des paramètres du contrôleur PID et l'autre pour l'augmentation de la robustesse du contrôleur IMF-PID face aux perturbations extérieures (rejet de perturbation).

L'application de cette stratégie pour la commande d'un système à retard du deuxième ordre mal conditionné, a permis de constater l'efficacité des algorithmes bio-inspirés en termes de : performances temporelles et de robustesse face aux incertitudes paramétriques et perturbations extérieures, en outre, une comparaison avec les résultats obtenus en utilisant un algorithme d'optimisation direct du type simplexe "Nelder-Mead" a révélé la supériorité de la méthode proposée.

Le troisième chapitre a été consacré à la conception d'un contrôleur auto-adaptatif à neurone unique dont la structure est inspirée du mécanisme de la rétroaction immunitaire. Le

principe du contrôleur neuronal est directement inspiré du fonctionnement du cerveau humain, ses principales caractéristiques comme : sa grande adaptabilité, sa capacité de traitement intelligent et distribué de l'information, son haut niveau de parallélisme et d'apprentissage ainsi que sa tolérance élevée aux informations inexacts, sont hautement requise dans le domaine de la commande des systèmes sous réseau, ou "Networked Control System" NCSs, car ce type de systèmes est soumis à diverses contraintes comme : les retards de transmission de l'information, les pertes de paquets, les congestions...etc.

Cette méthode a donc été appliquée pour la commande d'un moteur à courant continu sous réseau Ethernet, pour cela, nous avons utilisé le logiciel de simulation de réseaux TrueTime, travaillant sous environnement Matlab/Simulink. Les résultats de la simulation prouvent l'efficacité de l'approche proposée, en terme d'auto-adaptabilité du système de commande par rapport aux problèmes fondamentaux des NCSs (retard induit, perte de paquets...etc.).

Dans le quatrième chapitre, nous nous sommes posé comme défi, l'utilisation d'un algorithme d'optimisation bio-inspiré pour la conception, la commande et la gestion d'une centrale hybride de conversion d'énergies renouvelables CHAER. Cette tâche constitue un véritable challenge, car il faut trouver une solution optimale à plusieurs problèmes simultanément, en termes de coopération intelligente entre les systèmes de commande de la centrale hybride pour augmenter ses performances, de gestion intelligente de l'énergie produite et de la totale satisfaction de la demande ; tous cela en utilisant le moins possible les systèmes complémentaires (batteries, générateur diesel)...etc, pour des raisons économiques et écologiques évidentes.

Pour cela, nous avons proposé une nouvelle configuration de la boucle de commande du CHAER, en le considérant comme un seul système multivariable à deux entrées et une sortie. Tous les problèmes cités plus haut ont été formulés sous la forme d'un problème de minimisation multi-objectif qui a été résolu par l'algorithme génétique GA : il s'agit d'un algorithme inspiré de la théorie de l'évolution, il est considéré comme unique par sa structure chromosomique, lorsque cette dernière est construite judicieusement, elle peut donner des résultats meilleurs en termes de résolution, de temps et de qualité des solutions par rapport à d'autres techniques.

Nous avons simulé l'application de cette stratégie pour l'alimentation en énergie d'une ferme isolée située à la ville de Skikda (Nord-est de l'Algérie), les résultats ont été très encourageants par rapport aux stratégies de commandes classiques (décentralisées), en effet,

la puissance demandée par le consommateur (charge) est satisfaite à 100% et les systèmes complémentaires (batterie, générateur diesel) ne sont utilisés que rarement.

Le travail que nous avons effectué dans le cadre de cette thèse, nous a permis de relever les principales caractéristiques des algorithmes bio-inspirés, leur mode de fonctionnement ainsi que les avantages qu'ils peuvent apporter pour la commande de différents systèmes spécifiques. Chaque un de ces algorithmes bio-inspirés, selon ses spécificités, apporte des performances intéressantes, en termes de robustesse, auto-adaptabilité, optimisation...etc.

Enfin, en guise de perspective : une classification rigoureuse des différents algorithmes bio-inspirés en fonction de leur domaines d'utilisation et des résultats espérés doit être effectuée dans nos prochains travaux. Nous envisageant aussi, d'appliquer ces approches pour des classes de systèmes stochastiques, non linéaires, à paramètres variants...etc.

Bibliographie

- [1] Bonabeau. E, Théraulaz. G. " L'intelligence en essaim", Pour la science «Biologie animale » . URL : http://www.pourlascience.fr/ewb_pages/a/article-l-intelligence-en-essaim-27702.php.
- [2] Labeled. S, " Méthodes bio-inspirées hybrides pour la résolution de problèmes complexes", Thèse de doctorat en science, Université de Constantine, 2013.
- [3] Richard. A. "Kuby immunology". 5ème edition. New York : W.H. Freeman, 2003.
- [4] De Castro. LN et Von Zuben. FJ, "Artificial immune systems: part i – basic theory and applications". DCA 01/99 Décembre, 1999.
- [5] Timmis. J et Andrews. P, "A Beginners Guide to Artificial Immune Systems", 3ème chapitre, 2007.
- [6] Timmis. J, Andrews. P, Owens. N, et Clark. E, "An interdisciplinary perspectives on artificial immune systems. Evolutionary Intelligence", 1(1):5–26, Mars 2008.
- [7] De Castro. LN et Timmis. J, "Artificial Immune Systems: A New Computational Approach". Springer-Verlag, London. UK., Septembre 2002.
- [8] Farmer. JD, Packard. NH et Perelson. AS, "The immune system, adaptation, and machine learning". Physica, vol. 22, pp. 187-204, 1986.
- [9] Jerne. NK, "Towards a network theory of the immune system Annals of Immunology", vol. 125, no. C, pp. 373-389, 1973.
- [10] De Castro. LN et Von Zuben. FJ, "Learning and optimization using the clonal selection principle". IEEE Transactions on Evolutionary Computation, 6(2):239–251, Juin 2002.
- [11] De Castro. LN et Von Zuben, FJ, "The clonal selection algorithm with engineering applications". In Proceedings of GECCO'00, Workshop on Artificial Immune Systems and Their Applications, Juillet 2000.
- [12] Newborough. J et S. Stepney, "A generic framework for population-based algorithms, implemented on multiple FPGAs". pages 43–55. 2005.

-
- [13] De Castro. LN et Von Zuben. FJ, “Learning and Optimization Using the Clonal Selection Principle”. IEEE Transactions on Evolutionary Computation, Special Issue on Artificial Immune Systems, 2001.
- [14] Forrest. S, Perelson. S, Allen. L, et Cherukuri. R, “Self-nonsel self discrimination in a computer”. IEEE Symposium on Security and Privacy, pages 202–212, Washington, DC, USA, 1994.
- [15] Picton. P, “introduction to neural networks” DOI: 10.1007/978-1-349-13530-1, 1994.
- [16] Jain. A, Mao. J, Mohiuddin. KM, “Artificial neural networks: A Tutorial” IEEE Computer, 1996.
- [17] <http://www.marekrei.com/blog/wp-content/uploads/2014/01/neuron.png>.
- [18] Abraham. A, “Artificial Neural Networks” Manuel sur la conception des systèmes de mesure, modifié par Peter H. Sydenham et Richard Thorn, 2005.
- [19] da Silva. IN, et al, “Chapter 2: Artificial Neural Network Architectures and Training Processes” Springer International Publishing Switzerland, 2017.
- [20] Lawrence. J, Owens. AJ, et Walsh. MJ, ‘Artificial Intelligence Through Simulated Evolution’, Wiley. New York, 1966.
- [21] Rechenberg, I, “Evolutions strategie—Optimierung technischer Systeme nach Prinzipien der biologischen Evolution” (PhD thesis). Réimprimé par Fromman-Holzboog, 1973.
- [22] Koza. JR, “Genetic Programming: A Paradigm for Genetically Breeding Populations of Computer Programs to Solve Problems”, Stanford University Computer Science Department STAN-CS-90-1314, 1990.
- [23] Holland. J.H, “Adaptation in Natural and Artificial Systems”. Cambridge, MA: MIT Press. 2ème édition, 1992.
- [24] Goldberg. D, “Genetic Algorithms in Search, Optimization and Machine Learning”. Reading, MA: Addison-Wesley Professional, 1989.
- [25] Davis. L, “Adapting operator probabilities in genetic algorithms”. Scha er, J.D., ned.: Proceedings of the Third International Conference on Genetic Algorithms, San Mateo, CA, Morgan Kaufman, 1989.
- [26] Langdon. WB, “Genetic Programming and Data Structures”. DOI: 10.1007/978-1-4615-5731-9, 1998.

-
- [27] Wikipedia contributors. "Collective intelligence." Wikipedia, The Free Encyclopedia. Wikipedia, The Free Encyclopedia, 12 Mars. 2017.
- [28] Ajith. A et Konar. SD, <http://www.softcomputing.net/aciis.pdf>, 2008.
- [29] Fatih. TM et Yun-Chia. L, "A Binary Particle Swarm Optimization Algorithm for Lot Sizing Problem," *Journal of Economic and Social Research*, vol. 5, no. 2, pp. 1-20, 2003.
- [30] Li. X et Deb. K, "Comparing lbest PSO Niching algorithms Using Different Position Update Rules," *Proceedings of the IEEE World Congress on Computational Intelligence*, pp. 1564-1571, Spain, 2010.
- [31] Engelbrecht. AP, "Computational Intelligence: An Introduction", John Wiley and Sons, ch. 16, pp. 289-358, 2007.
- [32] Engelbrecht. AP, van den Bergh. F, "A New Locally Convergent Particle Swarm Optimiser", *IEEE Conference on Systems, Man and Cybernetics*, Tunisia, 2002.
- [33] Carlisle. A et Dozier. G, "An Off-The-Shelf PSO", in *Workshop Particle Swarm Optimization*, Indianapolis, 2001.
- [34] van den bergh. F, "An Analysis of Particle Swarm Optimizers". Thèse de doctorat, Department of Computer Science. University of Pretoria, Pretoria, South Africa, 2006.
- [35] Colomi. A, Dorigo. M, Maniezzo. V, "An investigation of some properties of an "ant algorithm". *Proceedings of Parallel Problem Solving from Nature II (PPSN '92)*, Elsevier, 515–526, 1992.
- [36] Dorigo. M, Stutzle. T, "Ant Colony Optimization". MIT Press, 2004.
- [37] Toksari. DM, "A hybrid algorithm of Ant Colony Optimization (ACO) and Iterated Local Search (ILS) for estimating electricity domestic consumption: Case of Turkey", *International Journal of Electrical Power & Energy Systems*, Volume 78, Pages 776-782, Juin 2016.
- [38] Laroche. E, "Commande Robuste", *Mémoire de Master en Automatique Robotique Université de Strasbourg*, France, 2012.
- [39] Gherbi. S, "La Commande Robuste (Technique μ -Analyse et μ -Synthèse)", *Thèse de doctorat en Automatique. Université Badji Mokhtar, Annaba*, 2009.

-
- [40] Takahashi. K, Yamada. T, “Application of an immune feedback mechanism to control systems”. JSME international journal, series C, vol 41, No.2, 1998.
- [41] Zhen-Qiang. Q, Guang-Da. H, Zhao-Hua. Y, Fu-En. Z, “A Novel Control Algorithm Based On Immune Feedback Principle”, Proceedings of the First International Conference on Machine Learning and Cybernetics, Beijing, 2002.
- [42] Yuzhen. S, Chunmei. X, “Nonlinear PID Controller Based on Fuzzy Immune Method and Its Simulation in Superheater Steam Temperature”, Proceedings of the IEEE International Conference on Mechatronics and Automation, 2010.
- [43] Khoie. M, Sedigh. A, Salahshoor. K, “PID Controller Tuning using Multi-Objective Optimization based on Fused Genetic-Immune Algorithm and Immune Feedback Mechanism”, Proceedings of IEEE International Conference on Mechatronics and Automation, 2011.
- [44] Wang. B, Sun. Y, Cao. J, Zhang. G, “Control and simulation of an underwater robot using singloneuron PID control based on immune feedback mechanism”, Proceedings of the 8th World Congress on Intelligent Control and Automation, 2010.
- [45] Dernoncourt. F, “Introduction à La Logique Floue”, URL : francky.me/doc/course/fuzzy_logic_sdz_2012.pdf. Avril, 2011.
- [46] Bouchebbat. R, Gherbi. S, “Robust artificial-immune-PID parameters tuning”, International Conference on Automatic control, Telecommunications and Signals (ICATS15). University BADJI Mokhtar - Annaba - Algeria – Novembre 16-18, 2015.
- [47] Wikipedia contributors. "Nelder–Mead method." Wikipedia, The Free Encyclopedia. Wikipedia, The Free Encyclopedia, Web. 12 Mars. 2017.
- [48] Bauer. NW, “Networked Control Systems From Theory to Experiments”. California University, 2013.
- [49] Astrom. KJ et Wittenmark. B, “Computer-Controlled Systems: Theory and Design”, Prentice Hall, Upper Siddle River, NJ, 1997.
- [50] Franklin. GF, Powell. JD, Workman. ML, “Digital Control of Dynamic Systems”, Addison-Wesley Longman, Reading, MA, 1994.
- [51] Cervin. A, Henriksson. D, Ohlin. M, “TrueTime 2.0 beta-Reference Manual”. Lund University. Sweden, 2010.

-
- [52] Zhang. Y, Penga. L, Wen-jiangb. W, “Single Neuron PID Sliding Mode Parallel Compound Control for Alternating Current Servo System”, International Workshop on Information and Electronics Engineering. *Procedia Engineering* 29, pp. 2055-2061, 2012.
- [53] Bouchebbat. R, Gherbi. S, “ Adaptive immune single neuron PID tuning for networked control systems”, First International Conference on Technological Advances in Electrical Engineering (ICTAEE'14), Skikda, Algeria. 2014.
- [54] IEA-AIE, “ Key World Energy Statistics 2009”, International Energy Agency, rue de la fédération 75739 Paris Cedex 15, www.iea.org, Rapport, 2009.
- [55] LOPEZ. M, “Contribution à l'optimisation d'un système de conversion éolien pour une unité de production isolée”, Thèse de doctorat, Faculté des sciences d'Orsay, 2008.
- [56] Indradip. M, “Optimum Utilisation of Renewable Energy for Electrification of Small Islands in Developing Countries”, Thèse de doctorat, ISET, Institut für Solare Energieversorgungstechnik Verein an der Universität Kassel. Novembre, 2008.
- [57] Bialasiewicz. JT, “Renewable energy systems with photovoltaic power generators: operation and modeling”, *IEEE Trans. on Indus. Electronics*, Vol.55, pp.2752-58, 2008.
- [58] Kreuawan. S, “Etude d'un mini réseau hybride associant une centrale photovoltaïque et une micro turbine à gaz”, Mémoire de Master «Energie Renouvelable et Electronique de Puissance», Université des Sciences et Technologies de Lille, 2005.
- [59] PANKOW. Y, “Etude de l'intégration de la production décentralisée dans un réseau Basse Tension. Application au générateur photovoltaïque”, Thèse de doctorat, l'Ecole Nationale Supérieure des Arts et Métiers, décembre 2004.
- [60] VECHIU. I, “Modélisation et analyse de l'intégration des énergies renouvelables dans un réseau autonome”, thèse de doctorat en Génie Electrique de l'Université du Havre, décembre 2005.
- [61] National Renewable Energy Laboratory (NREL): HOMER Software, version 2.75 Disponible à: <http://www.homerenergy.com/software.html>, 2010.
- [62] National Renewable Energy Laboratory (NREL): HOMER Getting Started Guide, Version 2.1, 2005. Disponible à [http://www.homerenergy.com/ documentation.html](http://www.homerenergy.com/documentation.html), 2010.

-
- [63] Chenni. R, Maklouf. M, Kerbache. K, Bouzid. A, “A detailed modeling for photovoltaic cells”, *Solar Energy* 32, 2007.
- [64] Munteanu. I, Bratcu. A, Cutululis. N, et Ceanga. E, “Optimal control of wind energy systems”. *Advances in Industrial Control series*, Springer. ISSN 1430-9491, 2008.
- [65] Larminie. J et Lowry. J, “Electric Vehicle Technology explained, technology and engineering”. Hoboken: Wiley, 2004.
- [66] Hu. Y et Solana. P, “Optimization of a hybrid diesel-wind generation plant with operational options”. *Renewable Energy*, 51, 364–372, 2013.
- [67] Seeling-Hochmuth. G, “Optimisation of hybrid energy systems sizing and operation control”, Université de Kassel en candidature au diplôme Dr.-Ing. Canada, Octobre, 1988.
- [68] Djarallah. M, “Contribution à l’étude des systèmes photovoltaïques résidentiels couplés au réseau électrique”, Thèse de doctorat en génie électrique de de l’Université de Batna, Janvier, 2008.
- [69] Givler. T, Lilienthal.P, “Using HOMER Software, NREL’s Micropower Optimization Model, to Explore the Role of Gen-sets in Small Solar Power Systems; Case study: SriLanka”, NREL/TP-710-36774, Mai 2005 (www.nrel.gov/docs/fy05osti/36774.pdf)
- [70] Bouchebbat, R. & Gherbi, S. *J Control Autom Electr Syst* (2016). “A Novel Optimal Control and Management Strategy of Stand-Alone Hybrid PV/Wind/Diesel Power System” doi:10.1007/s40313-016-0290-y.
- [71] Bossanyi. EA, “The design of closed loop controllers for wind turbines”. *Wind Energy*, 3, 149–163, 2000.
- [72] Muljadi. E, Pierce. K, Migliore. PA, “Conservative control strategy for variable-speed stall-regulated wind turbines”. Rapport NREL/CP-500-24791, National Renewable Energy Laboratory, Colorado, USA, 2000.
- [73] Bendib. B, Belmili. H, et Krim. F, “A survey of the most used MPPT methods: Conventional and advanced algorithms applied for photovoltaic systems”. *Renewable and Sustainable Energy Reviews*, 45, 637–648, 2015.

- [74] Verma. D, Nema. S, Shandilya. A, et Dash. S, “Maximum power point tracking (MPPT) techniques: Recapitulation in solar photovoltaic systems”. *Renewable and Sustainable Energy Reviews*, 54, 1018–1034, 2016.