

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



UNIVERSITE DJILLALI LIABES DE SIDI-BEL-ABBES
Faculté de Génie Electrique
Département d'Electrotechnique

Thèse présentée par :

KHERFANE Riad Lakhdar

Pour l'obtention du diplôme de :

Doctorat en Electrotechnique

Option: Réseaux électriques

Intitulé de la thèse :

***Optimisation Multiobjectif de L'écoulement de Puissance
Par des Algorithmes Multiagents Probabilistes***

Présentée devant le jury composé de :

Pr. ZIDI Sid Ahmed	Professeur à l'université UDL - SBA	Président
Pr. YOUNES Mimoun	Professeur à l'université UDL - SBA	Rapporteur
Pr. SAYAH Houari	Professeur à l'université UDL - SBA	Examineur
Pr. ALLALI Ahmed	Professeur à l'USTO-Oran	Examineur
Pr. LAOUER Mohammed	Professeur à l'université de SAIDA	Examineur
Pr. BOUZBOUDJA Hamid	Professeur à l'USTO-Oran	Examineur

Soutenue le : 01/03/2017

Dédicaces

A mes parents

A mes frères et sœurs

A ma femme et mes enfants

A tous mes amis

Remerciements

En premier lieu, je tiens à exprimer ma profonde gratitude à mon directeur de thèse, monsieur YOUNES Mimoun, Professeur à l'UDL-SBA, qui a assuré l'encadrement de mon travail avec une grande compétence. Pendant six années passées ensemble, il a été une source de motivation et d'encouragement. Je conserverai un très bon souvenir de nos discussions, de sa façon de chercher de nouvelles solutions et de toujours m'avoir soutenu et aidé à réaliser ce travail et de le mener à bien pendant ces années de recherches.

J'exprime aussi toute ma reconnaissance et ma profonde gratitude à monsieur ZIDI Sid Ahmed, Professeur à l'UDL-SBA, pour avoir accepté de présider mon jury de soutenance.

Je suis très honoré que messieurs BOUZEBOUJJA Hamid et ALLALI Ahmed, Professeurs à l'USTO et monsieur SAYAH Houari, Professeur à l'UDL-SBA et monsieur LAOUER Mohammed, Professeur à l'université de SAIDA, aient accepté d'examiner ce travail de recherche. Je les en remercie très vivement.

Je voudrai plus particulièrement exprimer ma reconnaissance envers monsieur MAASSOUM Ahmed et sa secrétaire pour leur sérieux et disponibilité inconditionnelle.

J'adresse également mes sincères remerciements:

A Mr FLAZI Samir, Professeur à l'USTO pour son soutien et ses conseils précieux.

A mes collègues et amis Fouad KHODJA, Naas KHERFANE et Belkacem TOUAL.

A tous mes amis et en particulier Nouredine, Benyahia, Abdelhafid, Khaled et Chargui.

A toute ma belle-famille et en particulier mon beau-père C^{dt} Abdelbaki CHAHTA pour ses prières et ses encouragements.

A tous mes frères et sœurs et en particulier Samir pour ses conseils et son soutien inconditionnel.

A mon père Abdesslam et ma mère Baya qu'Allah les garde, et leur procure santé, bonheur et longue vie, afin que je puisse les combler à mon tour.

A mes enfants, ma plus belle réussite et ma grande fierté, Nour El Houda, Abdessalam, Chaimaa et Okba.

A ma femme Fatima que je l'ai trouvée toujours à mes côtés et surtout aux moments difficiles elle était toujours disponible, et sans son aide et ses sacrifices, je ne serais pas arrivé à réaliser ce travail.

Merci à tous

Table des matières

ETAT DE L'ART

I.1 Introduction	16
I.2 Généralités	17
I.3 L'intelligence artificielle comme nouvelle tendance dans les problèmes d'optimisation.	18
I.4 Les applications de l'intelligence artificielle dans les réseaux électriques.....	21
Références	21

GENERALITES ET FORMULATION DU PROBLEME DE L'OPF

II.1. Introduction	25
II.2. Généralités	25
II.2.1. Production de l'énergie électrique	25
II.2.2. Coût de production de l'énergie électrique	26
II.2.3. La fonction non-lisse du coût	27
II.2.4. La fonction coût avec multi-fuel	28
II.2.5. Les émissions des gaz	29
II.3. Formulation du problème	30
II.3.1. Ecoulement de puissance	30
II.3.1.1. Résolution du problème de l'écoulement de puissance	31
II.3.1.2. Méthode du Newton Raphson	31
II.3.2. Dispatching économique	33
II.3.2.1. Dispatching économique sans contraintes	33
II.3.2.2. Dispatching économique avec des limites sur les puissances générées	34
II.3.2.3. Dispatching économique avec des pertes constantes	36
II.3.2.4. Dispatching économique avec les pertes en fonction des puissances générées ...	37

II.3.3. Optimisation multi objectif	38
II.3.3.1. Minimisation du coût et les émissions de pollution	39
II.3.3.2. Minimisation du coût avec les pertes actives totales	39
II.3.4. Conclusion	40
Références	41

PROBLEMES D'OPTIMISATION

III.1. Introduction	45
III.2. Problème d'optimisation mono-objectif	45
III.2.1. Minimum local et minimum global	46
III.2.2. Optimisation sans contraintes	47
III.2.2.1. Les méthodes d'optimisation locales	48
III.2.2.2. Les méthodes d'optimisation globales.....	48
III.2.2.2.1. Les méthodes déterministes	49
III.2.2.2.2. Les méthodes évolutionnaires et les méthodes non déterministes	49
III.2.2.2.2.1. Les méthodes inspirées des principes physiques	50
A) Le recuit simule	50
III.2.2.2.2.2. Les méthodes inspirées par des comportements biologiques	51
A) Recherche taboue	51
B) L'algorithme de colonie de fourmis	53
C) Les algorithmes génétiques	54
D) La méthode des essaims particulaires	55
III.2.2.3. Les méthodes d'optimisation hybride	57
III.2.3. Optimisation continue avec contraintes	58
III.2.3.1. Méthodes d'optimisation par transformation	59

III.2.3.2. Méthodes de pénalités intérieures et extérieures	59
III.2.3.3. Méthodes de pénalités intérieures	60
III.2.3.4. Méthodes de pénalités extérieures	60
III.3. Optimisation multiobjectif	61
III.3.1. Formulation d'un problème multiobjectif	61
III.3.2. Dominance et optimalité de Pareto	62
III.3.3. Optimalité de Pareto	63
III.4. Conclusion	64
Références	64

LES METHODES UTILISEES POUR L'OPTIMISATION

IV.1. Introduction	68
IV.2. Algorithmes génétiques (GA)	68
IV.2.1. Représentation	68
IV.2.2 Opérateurs GA	69
IV.2.3 Algorithme génétique code en binaire (BCGA)	69
IV.3. Méthode d'optimisation par essaim de particules	71
IV.4. L'algorithme de la programmation quadratique séquentielle (SQP)	74
IV.5. L'algorithme firefly	75
IV.5.1. Attractivité	76
IV.5.2. Distance et mouvement	78
IV.6. L'algorithme artificiel de colonies des abeilles (ABC)	79
IV.7. L'algorithme de singe (MA)	81
IV.8. La technique de l'hybridation entre les méthodes étudiées	83
IV.8.1. La méthode hybride GA-PSO-SQP	83

IV.8.2. La méthode hybride GA-FFA	87
IV.8.3. L'algorithme hybride (FFA-ABC)	87
IV.8.4. L'algorithme hybride (GA-MA)	89
IV.9. Conclusion	91
Références	92

APPLICATIONS, RESULTATS ET DISCUSSION

V.1. Introduction	95
V.2. Formulation du problème	96
V.2.1. Problème EPD conventionnel	96
V.2.2. Fonction objectif	97
V.2.2.1. Minimisation du coût de carburant.	97
V.2.2.2. Minimisation des pertes de la puissance réelle	98
V.2.2.3. Minimisation des émissions	98
V.2.2.4 La fonction non-lisse	99
V.2.2.5 La fonction coût avec multi fuel	100
V.2.3 Les contraintes du problème	100
V.2.3.1. L'équation de l'équilibre de la puissance active.	100
V.2.3.2. Les limites de la production de la puissance active.	101
V.2.4 Transformation d'un problème contraint en un problème sans contraintes	102
V.2.4.1. La méthode des pénalités externes	102
V.2.4.2. La méthode des pénalités internes	103
V.2.4.3. La méthode des pénalités mixtes	103
V.2.4. L'énergie éolienne	104
V.3. Applications et résultats	104

V.3.1 Application de la méthode GA-MA	104
V.3.1.1 Conclusion	111
V.3.2. Application de la méthode GA-FFA	111
V.3.2.1 Cas 1 (système IEEE 30 nœuds 6 générateurs, $P_D=189.2$ MW).....	111
V.3.2.2 Cas 2 (système IEEE 57 nœuds 7 générateurs, $P_D=1250.8$ MW).....	111
V.3.2.3 Conclusion	115
V.3.3 Application de la méthode FFA-ABC	116
V.3.3.1. Le réseau IEEE 30-nœuds.	116
V.3.3.2. Le réseau IEEE 57-nœuds.	116
V.3.3.3 Conclusion	121
V.3.4 Application de la méthode GA-PSO-SQP	121
V.3.4.1 Réseau 1 (réseau IEEE 30 nœuds)	121
V.3.4.1.1 Cas 1: minimisation quadratique du coût de carburant	123
V.3.4.1.2 Cas 2: la minimisation des émissions	124
V.3.4.1.3 Cas 3: la minimisation des émissions et du coût simultanément	124
V.3.4.2 Réseau 2	128
V.3.4.2.1 Cas 1 (minimisation du coût et des émissions simultanément).....	129
V.3.4.2.2 Cas 2 (minimisation du coût et des émissions séparément).....	130
V.3.4.2.3 Cas 3 (injection de l'énergie éolienne).....	132
V.3.4.2.4 Conclusion	133
Conclusion générale	135
Références	138

Liste des figures

Fig II.1 -Centrale thermique à vapeur	26
Fig II.2 -Caractéristique entrée sortie d’une unité thermique	27
Fig II.3 -Caractéristique entrée sortie d’une unité thermique à 4 valves	28
Fig III.1 - Représentation du minimum local et global d’une fonction	47
Fig III.2 - Recuit Simulé	51
Fig III.3 - Recherche Tabu	52
Fig III.4 - Algorithme Génétique standard	55
Fig III.5 -Organigramme de la méthode des essais particuliers	56
Fig. III.6 -L’optimalité locale au sens de Pareto	64
Fig IV.1 -Application de l'AG	71
Fig IV.2 -L’organigramme de l’optimisation par essaim de particules	74
Fig IV.3 -L’organigramme de l’approche GA-PSO-SQP proposée pour l’EPD basée sur l’énergie éolienne	85
Fig IV.4 -L’espace de recherche avec GA-PSO-SQP	86
Fig IV.5 -L’organigramme de l’algorithme hybride GA-PSO-SQP proposé	86
Fig.IV.6 -Concept de la méthode hybride	87
Fig.IV.7 -Optimisation globale de tous les générateurs du système IEEE 30-nœuds	88
Fig.IV.8 -Optimisation globale des 7 générateurs du système IEEE 57-nœuds	88
Fig.IV.9 -Le pseudo code du FFA-ABC	89
Fig IV.10. -Organigramme pour l’EPD utilisant GA-MA	90
Fig V.1. -Coût du méga watt heure en dollars donné par l’approche GA-MA et sa comparaison aux autres méthodes pou la demande de 2400 MW (1 ^{ère} combinaison de carburants)	106
Fig V.2. -Coût du méga watt heure en dollars donné par l’approche GA-MA et sa comparaison aux autres méthodes pou la demande de 2400 MW (2 ^{ème} combinaison de carburants)	107
Fig V.3. -Coût du méga watt heure en dollars donné par l’approche GA-MA et sa comparaison aux autres méthodes pou la demande de 2500 MW	108
Fig V.4. -Coût du méga watt heure en dollars donné par l’approche GA-MA et sa comparaison aux autres méthodes pou la demande de 2600 MW	109
Fig V.5. -Graphe de la Convergence de la méthode GA-MA, pour un système de 10 générateurs, avec une demande de 2400 MW	109

Fig. V.6. -Graphe de la Convergence de la méthode GA-MA, pour un système de 10 générateurs, avec une demande de 2500 MW	110
Fig. V.7. - Graphe de la Convergence de la méthode GA-MA, pour un système de 10 générateurs, avec une demande de 2600 MW	110
Fig V.8. -Coût du méga watt heure en dollars donné par l'approche GA-FFA et sa comparaison aux autres méthodes pour le système 30-nœuds IEEE, ($P_D=189.2$ MW, $P_L = 0.00$ MW)	113
Fig V.9. -Coût du méga watt heure en dollars donné par l'approche GA-FA et sa comparaison aux autres méthodes pour le système 57-nœuds IEEE, ($P_D=1250.8$ MW, $P_L = 0.00$ MW)	113
Fig V.10. -Coût du méga watt heure en dollars donné par l'approche GA-FA et sa comparaison aux autres méthodes pour le système 57-nœuds IEEE, ($P_D=1250.8$ MW, $P_L = 19.06$ MW)	114
Fig V.11. -L'évolution du coût de production au cours des itérations avec des pertes nulles.....	114
Fig V.12. -L'évolution du coût de production au cours des itérations avec des pertes constantes 19.06 MW	115
Fig.V.13 -Diagramme d'une ligne du système IEEE 30-nœuds	116
Fig.V.14. -Diagramme d'une ligne du système IEEE 57-nœuds	117
Fig V.15. -Coût du méga watt heure en dollars donné par l'approche FA-ABC et sa comparaison aux autres méthodes pour un système IEEE 30 nœuds	118
Fig V.16. -Coût du méga watt heure en dollars donné par l'approche FA-ABC et sa comparaison aux autres méthodes pour un système IEEE 57 nœuds	119
Fig.V.17. -Les valeurs de la fonction coût dans différentes itérations pour la méthode FFA-ABC (IEEE 30-nœuds)	119
Fig.V.18. -Les valeurs de la fonction coût dans différentes itérations pour la méthode ABC (IEEE 30-nœuds)	120
Fig.V.19. Les valeurs de la fonction coût dans différentes itérations pour la méthode PSO (IEEE 57-nœuds)	120
Fig.V.20. -Les valeurs de la fonction coût dans différentes itérations pour la méthode FFA-ABC (IEEE 57-nœuds)	121
Fig V.21. -Coût du méga watt heure en dollars donné par l'approche GA-PSO-SQP et sa comparaison aux autres méthodes pour un système IEEE 30 nœuds	123

Fig V.22. -Tau des émissions en ton/h donné par l'approche GA-PSO-SQP et sa comparaison aux autres méthodes pour un système IEEE 30 nœuds	124
Fig V.23. -Coût du carburant en (\$/MWh) donné par l'approche GA-PSO-SQP pour différents objectifs sur un système IEEE 30 nœuds	126
Fig V.24. -Tau des émissions en (ton/h) donné par l'approche GA-PSO-SQP pour différents objectifs sur un système IEEE 30 nœuds	126
Fig V.25. -Les pertes en (MW) donné par l'approche GA-PSO-SQP pour différents objectifs sur un système IEEE 30 nœuds	127
Fig V.26. -Graphe de convergence de GA-PSO-SQP, système IEEE 30 nœuds (cas 1).	127
Fig V.27. -Graphe de convergence de GA-PSO-SQP, système IEEE 30 nœuds (cas 2).	128
Fig V.28. -Coût du méga watt heure en dollars donné par l'approche GA-PSO-SQP et sa comparaison aux autres méthodes pour le réseau algérien (1er cas)	130
Fig V.29. -Coût du carburant en (\$/h) donné par l'approche GA-PSO-SQP et sa comparaison avec la méthode SLPEED pour différents objectifs sur le réseau algérien	131
Fig V.30. -Tau des émissions en (ton/h) donné par l'approche GA-PSO-SQP et sa comparaison avec la méthode SLPEED pour différents objectifs sur le réseau algérien	131
Fig V.31. -Les pertes en (MW) donné par l'approche GA-PSO-SQP et sa comparaison avec la méthode SLPEED pour différents objectifs sur le réseau algérien	132
Fig V.32. -Coût du méga watt heure en dollars donné par l'approche GA-PSO-SQP pour le réseau algérien avec introduction de l'énergie éolienne (3ème cas)	133

Liste des tableaux

Tableau V.1. Les paramètres du système à 10 générateurs en considérant les effets des soupapes d'admission et les multi-carburants	105
Tableau V.2. Comparaison du résultat de la simulation avec d'autres méthodes pour le cas de la demande de 2400 MW	106
Tableau V.3. Comparaison du résultat de la simulation avec d'autres méthodes pour le cas de la demande de 2500 MW	107
Tableau V.4. Comparaison du résultat de la simulation avec d'autres méthodes pour le cas de la demande de 2600 MW	108
Tableau V.5. Les paramètres des générateurs du système IEEE 30 nœuds	112
Tableau V.6. Les paramètres des générateurs du système IEEE 57 nœuds	112
Tableau V.7. Les résultats de l'approche GA-FA comparée à FA et GA pour le système 30-nœuds IEEE, ($P_D=189.2$ MW, $P_L = 0.00$ MW)	112
Tableau V.8 Les résultats de l'approche GA-FA comparée à GAmatpower, FA et GA pour le système 57-nœuds IEEE, ($P_D=1250,8$ MW, $P_L = 0.00$ MW)	113
Tableau V.9. Les résultats de l'approche GA-FA comparée à GAmatpower, FA et GA pour le système 57-nœuds IEEE, avec des pertes constantes ($P_D=1250,8$ MW, $P_L = 19.06$ MW)	114
Tableau V.10. Résultats de l'optimisation par l'approche FFA-ABC pour le système IEEE 30-nœuds	117
Tableau. V.11. Comparaison entre différentes méthodes pour le système IEEE 57-nœuds	118
Tableau V.12. Coefficients de carburant et d'émission des générateurs pour le réseau IEEE 30 nœuds	122
Table. V.13. Les limites des variables de contrôle	122
Tableau. V.14. Comparaison des résultats des différents algorithmes pour la fonction objectif coût du système IEEE 30-nœuds.	123
Tableau V.15. La comparaison des résultats obtenus pour le cas 2 pour le système IEEE 30-nœuds.	124
Tableau V.16. Résultats de l'optimisation par l'approche GA-PSO-SQP pour le système IEEE 30-nœuds	125
Tableau V.17. Paramètres des générateurs du réseau algérien 59 nœuds.	128

Tableau V.18. Paramètres d'émissions des générateurs du réseau algérien 59 nœuds.	129
Tableau V.19. Comparaison de différentes méthodes pour le cas 1 dans le réseau algérien.	129
Tableau V.20. La comparaison des résultats obtenus pour les différentes formes du cas 2 sur le réseau algérien	130
Tableau V.21. Comparaison des différents cas de l'EPD dans le réseau algérien avec l'énergie éolienne	132

Nomenclature

Abréviations

GA : Les algorithmes génétiques

BCGA : Les algorithmes génétiques codés en binaire

SQP : L'algorithme de la programmation quadratique séquentielle

PSO : L'optimisation par essais particulaires

FFA : L'algorithme firefly

ABC : L'algorithme artificiel de colonies des abeilles

MA : L'algorithme de singe

OPF : L'optimisation de l'écoulement de puissance

EPD : Le dispatching économique

Symboles

L'optimisation

$f(x)$: Le critère à minimiser appelé aussi fonction objectif

x : est un vecteur à n variables x_k qui représentent les paramètres du problème à optimiser

$g_i(x)$, $h_j(x)$: Respectivement les contraintes d'inégalité et d'égalité

$x_{k \min}$, $x_{k \max}$: Les contraintes de domaine

λ_i : Multiplicateur de Lagrange.

$L(x, \lambda)$: Fonction de Lagrange

r_k : Coefficient de pénalité actualisé à chaque itération du processus d'optimisation

W : Une fonction de pénalisation

Ψ : La frontière du domaine réalisable.

α : Facteur de contrôle inclus entre 0 et 1

\mathfrak{R}^n : L'espace de recherche borné par les contraintes de domaine.

∇f : Le gradient de la fonction objectif

$H = \nabla^2 f$: La matrice de dérivées secondes partielles de f , qualifiée de Hessien.

L'optimisation par essaim particulaire PSO

V_i^t : La vitesse de la $i^{\text{ème}}$ particule dans l'essaim à l'itération t .

X_i^t : La position de la $i^{\text{ème}}$ particule dans l'essaim à l'itération t

P_{besti} : Le leader local (la meilleure position personnelle)

g_{best} : Le leader global (la meilleure position globale)

i : Nombre de particules

w : Facteur de poids initial

c_1 , c_2 : Constantes d'accélération

$rand_1$, $rand_2$: La valeur aléatoire uniforme dans l'intervalle $[0,1]$.

w_{max}, w_{min} : Deux nombres aléatoires appelés poids initial et poids final respectivement

$iter_{max}$: Le nombre d'itérations maximale

$iter$: Le numéro de l'itération courante

L'algorithme de la programmation quadratique séquentielle SQP

$L(x, \lambda, \sigma)$: Le lagrangien

λ, σ : Des multiplicateurs de Lagrange.

d : Direction de recherche

L'algorithme Firefly FFA

$I(r)$: L'intensité lumineuse

I_s : L'intensité lumineuse à la source.

r : La distance

β : L'attractivité d'une luciole

β_0 : L'attractivité pour $r=0$.

Γ : La distance caractéristique

α : Un paramètre aléatoire déterminé par le problème d'intérêt

L'algorithme artificiel de colonies des abeilles ABC

x_i : La population de solutions

v_i : Positions de source de nourriture

P_i : Probabilité pour la solution x_i

f_i : Valeur de fitness

F_i : La valeur du coût de la fonction objectif.

x_{minj}, x_{maxj} : Respectivement la limite inférieure et supérieure du paramètre j .

L'algorithme de singe MA

M : La taille de la population de singes

N : Le nombre de montées.

x_i : Les positions initiales des singes

a : La longueur du pas du processus d'escalade.

p : Le pivot du saut périlleux

L'optimisation de l'écoulement de puissance

$h(x, u)$: La contrainte typique d'égalité.

$g(x, u)$: La contrainte d'inégalité.

x : Le vecteur des variables d'état consistant de la puissance générée, V_{L1} : La tension de charge du nœud 1.

Q_{G1} : La puissance réactive de sortie générée

S_{L1} : La ligne de transmission de chargement

N_{PQ}, N_G et N_L : Le nombre de nœuds de charge, le nombre de générateurs et le nombre de lignes de transmission, respectivement.

u : Le vecteur de variables de contrôle.

V_G : Les tensions des générateur.

T : Les paramètres de prise de transformateur.

Q_C : La puissance réactive injectée.

nt : Le nombre de transformateurs de régulation.

nc : Le nombre de VAR de compensation.

$f(P)$: Le coût total de production en \$/h;

$f_i(P_{Gi})$: La fonction de coût de carburant de l'unité i en \$/h;

a_i, b_i, c_i, e_i, f_i : Les coefficients de coûts de carburant de l'unité i ;

P_{Gi} : La puissance active à la sortie de l'unité i en MW;

g_k : La conductance d'une ligne de transmission k .

$V_i, V_j, \alpha_i, \alpha_j$: Les amplitudes de tension et les angles de phase du $i^{\text{ème}}$ et $j^{\text{ème}}$ nœud respectivement.

nl : Le nombre total de lignes de transmission.

$\alpha, \beta, \gamma, \varepsilon$ et λ : Les coefficients des caractéristiques d'émission du $i^{\text{ème}}$ générateur.

h : Le facteur de pénalité de prix.

β : Facteur de pondération qui satisfait $0 < \beta < 1$.

B_{ij} : Le coefficient des pertes de transmission.

P_i, P_j : La puissance générée des $i^{\text{ème}}$ et $j^{\text{ème}}$ unités.

B_{oi} : Le coefficient des pertes de l' $i^{\text{ème}}$ élément du vecteur

B_{oo} : Le coefficient des pertes constantes.

P_G : La production totale du système.

P_D : La demande de la charge totale.

P_L : Les pertes de transmission totales du système.

N_G : Le nombre des unités génératrices dans le système.

nb : Le nombre de nœuds.

G_{ij}, B_{ij} : La conductance de transfert et la susceptance entre le nœud i et le nœud j respectivement.

A : La surface parcourue par le vent.

ρ : La densité de l'air.

v : La vitesse du vent.

C_e : Le facteur d'efficacité.

Liste des travaux

I. Publications Internationales :

1. **R. L. Kherfane**, M. Younes, F. Khodja, N. Kherfane, Intelligent algorithm solutions to economic dispatch with multiple fuels and non-smooth cost function, Rev. Roum. Sci. Techn. – Electrotechn. Et Energ., 61, 1, pp. 32–36, Bucarest, 2016. **Indexed in : Thomson Reuters, scopus.**
2. M. Younes, **Riad Lakhdar Kherfane**, A new hybrid method for multi-objective economic power/emission dispatch in wind energy based power system, int J Syst Assur Eng Manag. Springer, DOI 10.1007/s13198-013-0208-z-2013. **Indexed in: scopus.**
3. M. Younes, **R. L. Kherfane**, F. Khodja, A hybrid Approach for economic power dispatch, WSEAS TRANSACTIONS on POWER SYSTEMS, Issue 3, pp 134-143 Volume 8, July 2013. **Indexed in: scopus.**
4. M. Younes, **R. L. Kherfane**, HYBRID FA AND FOR GENERATION ALLOCATION PROBLEM OPTIMIZATION, Journal of Electrical Engineering, Volume 14, 100-107 / 2014 – Edition 1, 2014. **Indexed in: scopus.**
5. M. Younes, Fouad Khodja, **Riad Lakhdar Kherfane**, Multi-objective economic emission dispatch solution using hybrid FFA (firefly algorithm) and considering wind power penetration, Energy journal, (67) 595-606, 2014. (Elsevier science direct). **Indexed in: Thomson Reuters, scopus.**
6. **R.L.Kherfane**, M. Younes , Use Of Artificial Intelligence Techniques To Estimate The Flashover Voltage, Journal of Electrical Engineering : Volume 14, 270-277 / 2014 Edition 1. **Indexed in: scopus.**
7. M. Younes, **Riad Lakhdar Kherfane**, Fouad Khodja, Naas Kherfane, Firefly algorithm for environmental/economic power dispatch including renewable energy, INTERNATIONAL JOURNAL OF ENERGY, Volume 8,8-15, 2014.
8. **Kherfane Riad Lakhdar**, M. Younes, Khodja Fouad, Kherfane Naas, Modeling the Flashover Voltage Using ANN, INTERNATIONAL JOURNAL of NEURAL NETWORKS and ADVANCED APPLICATIONS, Volume 1.7-12, 2014.
9. **R. L. Kherfane**, M. Younes, N. Kherfane and F. Khodja, Solving Economic Dispatch Problem Using Hybrid GA-MGA and Wind Power, ENERGY PROCEDIA ELSEVIER. ISSN: 1876-6102. 2014
10. N. Kherfane, **R. L. Kherfane**, M. Younes, F. Khodja, Economic and Emission Dispatch with renewable energy using HAS, ENERGY PROCEDIA ELSEVIER. ISSN : 1876-6102. 2014.

11. F. Khodja, M. Younes, M. Laouer, **R. L. Kherfane**, N. Kherfane, A New Approach ACO for Solving the Compromise Economic and Emission with the Wind Energy, ENERGY PROCEDIA ELSEVIER.ISSN: 1876-6102, 2014
12. **R. L. Kherfane**, M. Younes, Estimation de la tension de contournement par un algorithme génétique, Rev. Roum. Sci. Techn. – Electrotechn. Et Energ., 58, 3, p. 231-241, Bucarest, 2013. **Indexed in: Thomson Reuters, scopus.**

II. Communications Internationales :

1. F ; Khodja, M. Younes, M. Laouer, **R. L . Kherfane**, N. Kherfane, A New Approach ACO for Solving the Compromise Economic and Emission with the Wind Energy, the International Conference on Technologies and Materials for Renewable Energy, Environment and Sustainability TMREES14 International Conference 10th – 13th, April 2014/Beirut – Lebanon.
2. **R. L. Kherfane**, M. Younes, N. Kherfane and F. Khodja, Solving Economic Dispatch Problem Using Hybrid GA-MGA and Wind Power, the International Conference on Technologies and Materials for Renewable Energy, Environment and Sustainability TMREES14 International Conference 10th- 13th, April 2014/ Beirut – Lebanon.
3. N. Kherfane, **R. L. Kherfane**, M. Younes, F. Khodja, Economic and Economic Dispatch with Renewable Energy using HAS, the International Conference on Technologies and Materials for Renewable Energy, Environment and Sustainability TMREES14 International Conference 10th- 13th, April 2014/ Beirut – Lebanon.
4. M. Younes, F. Khodja, **R. L. Kherfane**, Economic and emission dispatch problems using a new hybrid algorithm, Proceedings of the 2013 international conference on environment, Energy , ecosystems and development, pp 119-126
5. M. Younes, **R. L. Kherfane**, F. Khodja, Environmental/Economic power dispatch problem / renewable energy using firefly algorithm, Proceedings of the 2013 international conference on environment, Energy , ecosystems and development, pp 170-176
6. F. Khodja, M. Younes, **R. L. Kherfane**, The streamers dynamics study by an intelligent system based on Neural Networks, Proceeding of the 2013 International Conference on Environment, Energy Ecosystems and Development, pp 202-206
7. **R. L. Kherfane**, M. Younes, Exploitation des algorithmes génétiques pour l'estimation de la tension de contournement d'un isolateur HT pollué, the 7th international Conference on Electrical engineering CEE 2012, 08-10 Octobre 2012 Batna, Algeria.

Chapitre I

ETAT DE L'ART

I.1. Introduction

Le problème de la répartition économique de l'énergie électrique, ou le dispatching économique (EPD) est un sujet d'étude essentiel dans les réseaux électriques, où l'on doit générer moins d'énergie tout en satisfaisant la demande imposée. Donc avec une bonne gestion et une distribution de l'énergie bien calculée, on arrivera à produire l'énergie électrique avec le moindre coût possible. D'où moins de combustibles consommés ce qui engendre la baisse du prix du kWh et bien évidemment une bonne contribution à la conservation de l'environnement. Plusieurs techniques d'optimisation classiques ont été appliquées pour résoudre ce problème. Toutes ces méthodes mathématiques sont fondamentalement fondées sur la convexité de la fonction objectif pour trouver le minimum global. Cependant, le problème de l'EPD a les caractéristiques de haute non linéarité et non convexité.

L'application des techniques classiques d'optimisation telle que les algorithmes fondés sur le gradient ne sont pas assez bons pour résoudre ce problème, parce qu'ils dépendent de l'existence de la première et de la seconde dérivée de la fonction objectif et sur le bon calcul de ces dérivés dans un grand espace de recherche. Par conséquent, les méthodes conventionnelles fondées sur la technique mathématique ne peuvent pas donner une garantie de trouver l'optimum global. En outre, les performances de ces approches traditionnelles dépendent aussi des points de départ et sont susceptibles de converger vers un minimal local, voire diverger.

Récemment, de nombreuses tentatives pour surmonter les limites des approches de programmation mathématiques ont été étudiées telles que les méthodes d'optimisation métaheuristiques, leur application à ce genre de problème devient attrayante parce qu'elles ont de meilleures capacités de recherche globale par rapport aux algorithmes d'optimisation classiques. Ces méthodes permettent de trouver des solutions plus ou moins proches de l'optimum, mais avec un coût élevé en matière de temps.

Pour résoudre ce problème, c'est-à-dire améliorer les résultats et le temps de convergence, nous avons utilisé, dans ce travail, la technique d'hybridation qui consiste à combiner deux ou trois méthodes pour profiter des avantages de l'une et contourner les inconvénients de l'autre.

Nous avons utilisé : la combinaison entre les algorithmes génétiques et l'algorithme de la luciole (firefly) pour obtenir l'algorithme hybride FFA-GA, la combinaison entre les algorithmes génétiques et l'algorithme du singe pour obtenir l'algorithme hybride GA-MA, la combinaison entre l'algorithme de la luciole (firefly) et l'algorithme de colonies des abeilles pour obtenir l'algorithme hybride FFA-ABC, la combinaison entre les algorithmes génétiques et l'algorithme des essaims de particules et la programmation quadratique séquentielle pour obtenir l'algorithme hybride GA-PSO-SQP.

I.2. Généralités

Dans le domaine de l'électrotechnique, l'ingénierie des systèmes de puissance est le secteur qui a la plus longue histoire de développement, et cela est dû essentiellement aux méthodes pratiques d'optimisation numérique qui ont joué un rôle très important dans l'exploitation des systèmes de puissances. La valeur apportée par l'optimisation du système est considérable en termes économiques avec des centaines de millions de dollars économisés chaque année dans les grands services publics en matière de coût de carburant, l'amélioration de la fiabilité opérationnelle et la sécurité du système [1, 2]. Comme les systèmes de puissance deviennent de plus en plus complexes en raison de l'augmentation de la demande de la charge, la demande de combustibles fossiles par les centrales thermiques augmente aussi à son tour ce qui provoque la hausse des coûts et l'augmentation des émissions dans l'environnement. Par conséquent, l'optimisation est devenue essentielle pour le fonctionnement des services du système d'alimentation en matière de réduction des coûts de carburant et la préservation de l'environnement [3].

L'objectif est donc de réduire au minimum le coût de la production d'électricité dans les systèmes électriques réglementés et de maximiser le bien-être social dans les systèmes d'alimentation déréglementés tout en satisfaisant diverses contraintes d'exploitation. En général, les problèmes d'optimisation sont non linéaires, incluant les fonctions objectifs et les contraintes d'égalité et d'inégalité non linéaires. En outre, avec la baisse des ressources en combustibles fossiles tels que le pétrole et le charbon, les limitations à grande échelle du développement des énergies renouvelables et de l'énergie nucléaire controversée ainsi que les préoccupations au sujet des niveaux inquiétants des émissions dans l'environnement, l'optimisation est devenue encore plus importante pour le fonctionnement des systèmes d'alimentation pour des raisons économiques et environnementales [4-6].

Il y a eu de nombreuses méthodes, incluant des techniques classiques et d'intelligence artificielle, appliquées pour résoudre les problèmes d'optimisation des systèmes d'alimentation [7-18]. Ces méthodes sont constamment améliorées et développées pour surmonter le problème des systèmes de grande taille et de plus en plus interconnectés. Les problèmes d'optimisations sont complexes en raison du grand nombre de contraintes. Par conséquent, trouver de meilleures solutions avec un temps de calcul réduit est le but de ces méthodes, ce qui a mené les chercheurs dans ce domaine à proposer plusieurs nouvelles méthodes améliorées à cet effet [6].

Le dispatching économique [1, 4] détermine les puissances actives optimales de sortie des unités de production en ligne de sorte que le coût du carburant de production est réduit au minimum tout en satisfaisant toutes les contraintes des unités et du système d'exploitation. Les émissions peuvent être également ajoutées à la fonction objectif de ce problème. Dans l'approche du dispatching économique, la fonction du coût de carburant des unités génératrices est une courbe non linéaire et la solution économique optimale se trouve au point où la puissance totale des unités de production en ligne répond à la demande totale de la charge de manière optimale. La fonction du coût de carburant des unités de production dans l'approche du dispatching économique, peut-être exprimée approximativement par une fonction quadratique. Cependant, d'autres fonctions du coût de carburant réel comme le multi-fuel, et l'effet de valve-point, peuvent être incluses.

I.3. L'intelligence artificielle comme nouvelle tendance dans les problèmes d'optimisation

Récemment, des méthodes fondées sur l'intelligence artificielle ont été largement utilisées pour résoudre des problèmes d'optimisation. Ces méthodes ont l'avantage de surmonter les problèmes complexes qui ne peuvent être résolus par des méthodes conventionnelles. De plus, ces méthodes sont faciles à appliquer en raison de leur structure mathématique simple et facile à combiner avec d'autres méthodes pour des systèmes hybrides en exploitant les points forts de chaque méthode. Les méthodes de l'intelligence artificielle se fondent généralement sur la simulation des phénomènes naturels ou le comportement social des êtres humains ou des animaux.

Un système expert [19], connu aussi sous le nom d'un système fondé sur la connaissance, est un programme informatique qui intègre les connaissances provenant d'experts dans un domaine spécifique pour fournir une analyse des problèmes aux utilisateurs. La forme commune d'un système expert est un programme informatique contenant les règles d'analyse et les recommandations pour les utilisateurs moins expérimentés dans la résolution d'un problème spécifique. Les systèmes experts ont été développés au cours des années 1960 et 1970 et appliqués dans le commerce dans les années 1980. Les méthodologies de systèmes experts peuvent être classées dans les catégories de systèmes d'agents intelligents, la méthodologie de base de données, la modélisation et l'ontologie. Récemment, avec le développement des techniques informatiques, les systèmes experts sont applicables à des applications en ligne.

L'algorithme génétique [2, 4] est une technique de recherche utilisée pour trouver la solution exacte ou la meilleure approximation de la solution pour un problème d'optimisation. L'algorithme génétique appartient aux méthodes évolutionnaires utilisant les techniques inspirées de la biologie évolutive telle que l'héritage, la mutation, la sélection et le croisement. L'algorithme génétique a été développé à compter des années 1950 et est l'une des méthodes les plus populaires appliquées à divers problèmes d'optimisation dans la science y compris l'ingénierie. Cette méthode peut prendre un temps considérable de calcul pour trouver la solution optimale.

L'optimisation par essaims de particules [6] est l'une des méthodes basées sur des algorithmes heuristiques développés sous l'émulation du comportement social simplifié d'animaux en essaims, comme dans les bancs de poissons et les groupes d'oiseaux. Il est un algorithme évolutionnaire fondé sur la population trouvée pour être efficace dans la résolution de problèmes d'optimisation non linéaire continue. L'optimisation par essaim de particules fournit une procédure de recherche basée sur la population, dans laquelle les individus (particules) changent leurs positions (les états) au fil du temps. Elle utilise un vecteur de vitesse sur la base du comportement social des individus de la population pour mettre à jour la position actuelle de chaque particule dans l'essaim volant dans un espace de recherche multidimensionnel d'un problème. Durant le vol, chaque particule est ajustée dynamiquement, avec une certaine vitesse, en fonction de son expérience de vol et celle des particules voisines pour trouver la meilleure position pour elle-même parmi ses voisins. La technique d'optimisation par essaim de particules peut fournir une solution de haute qualité sur le plan de la réduction du temps de calcul avec des caractéristiques de convergence plus stables que d'autres méthodes stochastiques. Développée depuis 1995, l'optimisation par essaim de particules a été appliquée avec succès dans de nombreuses recherches et des domaines d'application tels que les systèmes d'ingénierie, finance et gestion et est maintenant l'une des méthodes les plus couramment utilisées dans les optimisations.

L'ABC, proposé par Karaboga [20] pour l'optimisation des problèmes numériques, simule le comportement des essaims d'abeilles de recherche intelligente de nourriture. Dans l'algorithme ABC, la colonie d'abeilles artificielles contient trois groupes d'abeilles: les abeilles employées, les abeilles chômeurs (spectateurs) et les scouts. Les éclaireuses cherchent au hasard, dans l'environnement entourant la ruche, les nouvelles sources de nourriture et ce comportement, qui est une sorte de fluctuation, est vital pour l'auto-organisation.

Les quêteuses en attente dans la ruche trouvent la source de nourriture au moyen des renseignements présentés par les butineuses employées.

Le nombre moyen de scouts est d'environ 5 à 10% des butineuses. Dans l'ABC, la première moitié de la colonie artificielle d'abeilles est constituée d'employées et la seconde moitié est constituée de spectateurs. L'abeille employée dont la source alimentaire a été épuisée devient une abeille scoute [20].

Dans l'algorithme ABC, la position d'une source de nourriture représente, une solution possible au problème de l'optimisation et de la quantité de nectar d'une source de nourriture correspond à la qualité (fitness) de la solution associée. Le nombre des abeilles employées est égal au nombre de sources d'alimentation, chacune d'entre elles représente également un site, étant exploité à l'heure actuelle ou pour le nombre de solutions dans la population [21].

Les fireflies (les bogues lumineuses) utilisent leur bioluminescence pour attirer les compagnons ou la proie. Ils vivent dans des endroits humides sous les débris sur le sol, ou sous l'écorce et la végétation en décomposition.

L'algorithme firefly (FFA) a été développé par Xin Yang-She à l'Université de Cambridge en 2007. Il utilise les trois règles idéalisées suivantes:

- 1) Chaque luciole attire toutes les autres lucioles avec un faible flash [22]. Toutes les lucioles sont unisexes de sorte qu'une luciole sera attirée vers d'autres lucioles indépendamment de leurs sexes.
- 2) L'attractivité est proportionnelle à leur luminosité; ainsi pour toutes deux lucioles clignotantes, la moins lumineuse se déplacera vers la plus lumineuse. L'attrait est proportionnel à la luminosité et ils diminuent tous les deux lorsque leur distance augmente. S'il n'y a pas une luciole plus brillante qu'une autre, elles se déplacent de manière aléatoire.
- 3) La luminosité d'une luciole est affectée ou déterminée par le paysage de la fonction objectif.

L'algorithme de singe (MA) a été inventé par Mucherino et Seref en 2007. MA est une approche métaheuristique pour l'optimisation globale [23]. Le concept de MA ressemble aux stratégies d'autres méthodes métaheuristiques comme les algorithmes génétiques, l'évolution différentielle, les colonies de fourmis, ...etc. [24]. Lors de l'escalade des arbres, le singe marque les branches des arbres par rapport à la qualité de la nourriture disponible. Par la suite lorsque le singe monte l'arbre à nouveau, il utilise les marques antérieures sur les branches,

pour choisir celles qui mènent à des parties de l'arbre avec une meilleure qualité de l'alimentation [24].

En général, les méthodes basées sur l'intelligence artificielle sont en développement permanent dans d'autres applications pour différents problèmes d'optimisation du système d'alimentation. Récemment, des systèmes hybrides combinant les points forts de chaque méthode ont été favorisés par des chercheurs en raison de divers avantages par rapport aux méthodes simples telles que présentés ci-dessus.

I.4. Les applications de l'intelligence artificielle dans les réseaux électriques

Pour les deux dernières décennies, les méthodes basées sur l'intelligence artificielle sont devenues populaires pour résoudre différents problèmes dans les systèmes de puissance, comme le contrôle, la planification, les prévisions, etc. Ces méthodes peuvent surmonter les tâches complexes rencontrées lors des applications dans les grands systèmes électriques modernes avec les interconnexions installées pour répondre à l'augmentation de la demande de la charge. L'application de ces méthodes a été couronnée de succès dans de nombreux domaines de l'ingénierie des systèmes d'alimentation.

Cependant, il y a encore de nombreux défis à relever. Par conséquent, ces méthodes sont continuellement développées et améliorées pour faire face à des systèmes d'alimentation complexes toujours en évolution avec un nombre croissant de contraintes que ce soit dans l'industrie de la production électrique traditionnelle ou le marché concurrentiel de l'environnement.

REFERENCES

1. A. J. Wood and B. F. Wollenberg, Power generation, operation and control. 2nd edn., Wiley and Sons, New York, 1996.
2. J. A. Momoh, Electric power system applications of optimization, Marcel Dekker, Inc., New York, 2001.
3. E. El-Hawary and G. S. Christensen, Optimal economic operation of electric power systems,10 Artificial Intelligence in Power System Optimization Academic Press Inc., New York, 1979.
4. D. P. Kothari and J. S. Dhillon, Power system optimization, Prentice-Hall of India Private Limited, New Delhi, 2006.

5. Ž. Bogdan, M. Cehil and D. Kopjar, "Power system optimization," *Energy*, vol. 32, no. 6, 2007, pp. 955–960.
6. J. Zhu, *Optimization of power system operation*, John Wiley & Sons Inc., New Jersey, 2010.
7. Yong-Hua Song, *Modern optimisation techniques in power systems*, Kluwer Academic Publisher, Dordrecht, 1999.
8. D. B. Fogel, *Evolutionary computation: Toward a new philosophy of machine intelligence*, 2nd edition, IEEE Press, New York, 2006.
9. C. T. Leondes, *Intelligent systems: Technology and applications*, vol. 6, CRC Press, California, 2002.
10. L. L. Lai, *Intelligence system application in power engineering*, John Wiley & Sons, New York, 1998.
11. K. Warwick, A. Ekwue and R. Aggarwal, *Artificial intelligence techniques in power systems*, IEE Publisher, London, 1997.
12. M. E. El-Hawary, *Electric power applications of fuzzy systems*, IEEE Press, New York, 1998.
13. N. P. Padhy, "Unit commitment—A bibliographical survey," *IEEE Trans. Power Systems*, vol. 19, no. 2, 2004, pp.1196–1205.
14. R. C. Bansal, "Bibliography on the fuzzy set theory applications in power systems (1994–2001)," *IEEE Trans. Power Systems*, vol. 18, no. 4, 2003, pp. 1291–1299.
15. S. Madan and K. E. Bollinger, "Applications of artificial intelligence in power systems," *Electric Power Systems Research*, vol. 41, 1997, pp. 117–131.
16. S. Rahinan, "Artificial intelligence in electric power systems a survey of the Japanese industry," *IEEE Trans. Power Systems*, vol. 8, no. 3, 1993, pp. 1211–1218.
17. A. Chakrabarti and S. Halder, *Power system analysis: Operation and control*, 3rd Ed., PHI Learning Private Limited, New Delhi, 2010.
18. S. Sivanagaraju and G. Screenivasan, *Power system operation and control*, Dorling Kindersley (India) Pvt. Ltd., New Delhi, 2010.
19. S. William and Buckley, *Fuzzy expert systems and fuzzy reasoning*, New York, Wiley-Interscience, 2005.
20. D. Karaboga, *An idea based on honey bee swarm for numerical optimization*. Technical Report TR06, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.

21. D. Karaboga and B. Basturk. *Advances in Soft Computing: Foundations of Fuzzy Logic and Soft Computing*, volume 4529/2007 of LNCS, chapter Artificial Bee Colony (ABC) Optimization
22. Fraga .H, Firefly luminescence: A historical perspective and recent developments, *Journal of Photochemical & Photobiological Sciences*, vol. 7, 2008, pp. 146–158.
23. A. Mucherino and O. Seref, Monkey Search: A Novel Meta-Heuristic Search for Global Optimization, *AIP Conference Proceedings 953, Data Mining, System Analysis and Optimization in Biomedicine*, 162–173 (2007).
24. A. Mucherino, O. Seref, P.M. Pardalos, Simulating Protein Conformations through Global Optimization, *arXiv:0811.3094v1 [math.OC]*, November 19, (2008).

Chapitre II

GÉNÉRALITÉS ET FORMULATION DU PROBLÈME DE L'OPF

II.1. Introduction

Le problème de l'écoulement de puissance joue un rôle important dans le fonctionnement des réseaux électriques. L'objectif principal est d'obtenir le coût d'exploitation minimal nécessaire pour satisfaire l'équilibre de puissance, et les contraintes des générateurs et les limites d'exploitation du réseau. Le point de fonctionnement optimal d'un système de génération de l'énergie est l'endroit où le niveau de fonctionnement de chaque unité génératrice est ajusté de telle sorte que le coût total de la puissance délivrée est au minimum. Pour un système de gestion de l'énergie, l'écoulement de puissance est utilisé pour déterminer chaque niveau de production dans le système afin de minimiser le coût total du carburant du générateur ou le coût total du générateur et l'émission des unités thermiques tout en couvrant la demande de la charge ainsi que les pertes de transmission [1].

II.2. Généralités

II.2.1. Production de l'énergie électrique

Pour répondre à la consommation croissante d'électricité, il a fallu concevoir et construire des usines capables de produire de l'électricité en grande quantité. En effet, les principaux modes de production de l'énergie électrique sont les centrales nucléaires, les centrales hydroélectriques et les centrales à combustibles fossiles, ainsi que les centrales décentralisées de l'énergie renouvelable solaire ou éolienne.

Dans le cas des centrales thermiques, la turbine et l'alternateur sont les deux pièces maîtresses de ces générateurs d'électricité. La turbine est entraînée par la vapeur produite dans les chaudières, où l'on brûle les combustibles (charbon, pétrole, gaz naturel, etc.), qui est couplée à un alternateur qui va produire un courant alternatif en tournant. Une fois le courant produit, il doit être transporté vers la consommation.

La figure (II.1) représente le schéma de principe d'un type simple de centrale thermique à vapeur formée d'une chaudière, d'une turbine, et d'un générateur.

La quantité de chaleur dégagée, par un combustible (charbon, fioul ou gaz) brûlé dans une chaudière, transforme l'eau en vapeur. La pression de la chaudière engendrée par la vapeur est appliquée à la turbine qui transforme l'énergie cinétique en énergie mécanique, ce qui fait tourner le turbo-alternateur, d'où la production de l'énergie électrique.

Comme le montre la figure II.1, une partie de la puissance brute appliquée à la turbine alimente à la sortie du générateur les auxiliaires (les pompes du système d'alimentation de la chaudière, les ventilateurs, les pompes d'eau de refroidissement ...etc.).




Figure II.1 Centrale thermique à vapeur

II.2.2. Coût de production de l'énergie électrique

Lors de l'exploitation des centrales électriques, il faut prendre en considération d'une façon particulière leurs caractéristiques technico-économiques. Le coût de production, les contraintes techniques et la fiabilité, sont les trois types de caractéristiques qui ont une influence particulière dans l'exploitation d'une centrale électrique. En considérant toujours les priorités du consommateur, il est clair que le plus important de ces caractéristiques est le coût variable de production qui reflète principalement le coût du combustible utilisé sans négliger bien sûr les autres coûts d'exploitation et de maintenance de la centrale. Le coût du combustible est évalué en utilisant des valeurs de consommation spécifique de chaleur (une quantité d'énergie thermique nécessaire pour produire de l'électricité) pour la centrale et le prix du combustible.

En pratique, et suite à une série de tests sur les unités de production le coût est approché par la fonction quadratique convexe suivante :

$$F_i(P_{Gi}) = c_i + b_i P_{Gi} + a_i P_{Gi}^2 \quad (\text{II.1})$$

Où : a_i , b_i , et c_i sont les coefficients de coût exprimés respectivement en (\$/hr, \$/MWhr, et \$/MW²hr), et P_{Gi} est la quantité d'énergie produite (figure II.2).




Figure II.2 Caractéristique entrée sortie d'une unité thermique [2]

Le coût est influencé principalement par la puissance active générée donc l'augmentation de celle-ci engendre l'augmentation du couple de rotation de la turbine, d'où une augmentation de la consommation de combustible.

La constante c_i est appelée coût de marche à vide, elle représente le coût pour maintenir la marche d'une unité de production à production nulle.

II.2.3. La fonction non-lisse du coût

Pour commander la puissance de sortie de l'unité, les générateurs électriques ont un certain nombre de soupapes d'admission de vapeur qui sont utilisés. Lorsque les effets de points de ces soupapes sont pris en compte, le problème devient extrêmement difficile à résoudre, car ce type de caractéristique d'entrée-sortie est non différentiable, l'effet de ces valves apparaît par l'ondulation dans la fonction du coût, figure (II.3).

En fait, les fonctions de coûts présentent des discontinuités et des changements brusques dus à l'effet des soupapes (valve point). Cet effet est une augmentation soudaine des pertes lorsqu'une soupape d'admission de vapeur d'eau commence à s'ouvrir, ce qui entraîne des ondulations dans la fonction de coût de l'unité (Fig. II.3).

Pour prendre en considération les effets de valve point, un terme sinusoïdal est ajouté à la fonction quadratique du coût comme suit:

$$F_i(P_{Gi}) = c_i + b_i P_{Gi} + a_i P_{Gi}^2 + |e_i \times \sin(f_i(P_{Gi \min} - P_{Gi}))| \quad (\text{II.2})$$




Figure II.3 Caractéristique entrée sortie d'une unité thermique à 4 valves [3]

II.2.4. La fonction coût avec multi-fuel

La prise en charge des contraintes de carburant devient de plus en plus importante pour le bon fonctionnement et la planification efficace puisqu'elles impliquent un problème encore plus vaste, comprenant un grand nombre de périodes de temps de fonctionnement et de planification et un plus grand nombre de contraintes et de variables. Le combustible utilisé dans une unité de production peut être obtenu par différents contrats à des prix différents. Les contrats de carburant sont généralement un accord take-or-pay et comprennent les limites maximales et minimales sur la livraison de carburant à des unités de production au cours de la période de validité du contrat. Le stockage du combustible pour couvrir les prévisions inexactes de la charge et les perturbations de livraison n'est généralement possible que dans des limites spécifiées [4].

L'objectif est de minimiser simultanément le coût total du carburant et le niveau des émissions des générateurs thermiques tout en satisfaisant l'équilibre de puissance, la livraison de carburant, les contraintes de stockage de carburant et les limites de fonctionnement des générateurs. [5-6].

Dans la pratique, les centrales thermiques à vapeur sont alimentées par plusieurs types de combustibles comme le charbon, le gaz naturel et le pétrole.

La fonction du coût de combustible de ces centrales est décomposée pour donner une fonction quadratique pour chaque type de combustible. Dans ce cas la fonction du coût donnée précédemment, peut être écrite comme suit :

$$F_i(P_{Gi}) = \begin{cases} c_{i1} + b_{i1}P_{Gi} + a_{i1}P_{Gi}^2 + \text{fuel } 1 \text{ si } P_{Gi}^{min} \leq P_{Gi} \leq P_{Gi1} \\ c_{i2} + b_{i2}P_{Gi} + a_{i2}P_{Gi}^2 + \text{fuel } 2 \text{ si } P_{Gi} \leq P_{Gi} \leq P_{Gi2} \\ \dots \\ c_{im} + b_{im}P_{Gi} + a_{im}P_{Gi}^2 + \text{fuel } m \text{ si } P_{Gi(m-1)} \leq P_{Gi} \leq P_{Gi}^{max} \end{cases} \quad (\text{II.3})$$

Avec a_{im} , b_{im} , et c_{im} sont les coefficients de coût du combustible de type m .

Cette fonction devient une fonction très complexe et les méthodes d'optimisation classiques donnent des optimums locaux.

II.2.5. Les émissions des gaz

Le but principal est de minimiser le coût de fonctionnement du système d'alimentation tout en satisfaisant les contraintes d'équilibre de puissance. Plusieurs techniques ont été adoptées pour la réduction des émissions comme l'installation d'un filtre à gaz, le passage de l'essence ordinaire à un carburant à faible teneur en soufre ...etc. La minimisation des émissions en dehors de la minimisation des coûts a reçu une large attention comme une technique efficace à court terme. Les principales préoccupations environnementales comprennent SO_2 , NO_x et les émissions de CO_2 [7-18].

Les techniques de traitement des émissions adoptent deux approches distinctes. Dans la première, les émissions sont traitées comme des contraintes. Dans l'autre, en raison de la nature contradictoire et non commensurable des coûts d'exploitation et les émissions, la fonction objectif, intègre la minimisation de l'émission dans le problème global de minimisation des coûts d'exploitation.

La fonction des émissions comprend deux termes, un terme polynomial et un terme exponentiel [19].

L'expression analytique de cette fonction pour l'unité i est la suivante :

$$E_i(P_{Gi}) = \gamma_i + \beta_i P_{Gi} + \alpha_i P_{Gi}^2 + \varepsilon_i \exp(\lambda_i P_{Gi}) \text{ Ton/hr} \quad (\text{II.4})$$

Avec α , β , γ , ε , λ , sont les coefficients des émissions de pollution pour l'unité i , et sont déterminés par des techniques d'interpolation basées sur des données réelles.

II.3. Formulation du problème

II.3.1. Ecoulement de Puissance

Le problème de la répartition optimale des puissances est un problème d'optimisation dont l'objectif est de minimiser le coût total de la production de la puissance d'un réseau électrique.

Si l'on prend en considération les équations de l'écoulement de puissance, les limites minimales et maximales des puissances engendrées par les alternateurs, la surcharge des lignes de transports et les niveaux de tensions admissibles pour les jeux de barres de charges, on est alors devant un problème d'optimisation avec contraintes d'égalités et d'inégalités. Le problème sera donc donné sous une forme standard d'optimisation avec contraintes d'égalités et d'inégalités [20,21]:

$\min. F(x)$ (fonction objective)

Selon

$$g_i(x) = 0, i=1, 2, \dots, n \text{ (contraintes d'égalités)}$$

Et

$$h_j(x) \leq 0, j=1, 2, \dots, m \text{ (contraintes d'inégalités)}$$

Par projection sur le problème de l'écoulement de puissance on aura :

$$F = \sum_{i=1}^{nG} f_i = \sum_{i=1}^{nG} [c_i + b_i P_{Gi} + a_i P_{Gi}^2] \quad (\text{II.5})$$

Si on prend en considération seulement cette équation comme fonction objectif, on parle alors d'une optimisation sans contraintes. Mais on sait qu'il faut que la somme des puissances active et réactive injectées dans chaque jeu de barres soit égale à zéro. Donc, on doit prendre en considération les contraintes d'égalité comme suit :

$$g_i(x_1, \dots, x_n) = 0 \quad i = 1, \dots, n \quad (\text{II.6})$$

$$\Delta P_i = 0 = V_i \sum_{j=1}^n V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) - P_{Gi} + P_{Di} \quad (\text{II.7})$$

$$\Delta Q_i = 0 = V_i \sum_{j=1}^n V_j (G_{ij} \sin \theta_{ij} + B_{ij} \cos \theta_{ij}) - Q_{Gi} + Q_{Di} \quad (\text{II.8})$$

En plus, on doit savoir qu'en pratique, on ne doit pas dépasser les limites des éléments physiques du réseau électrique tels que les générateurs, les transformateurs à prises de charge, et les transformateurs de phase. Donc, on peut citer d'autres contraintes d'inégalités en plus des contraintes sur les puissances actives et réactives à chaque générateur qui ont une influence directe sur la fonction coût, [20]:

$$P_{Gi \min} \leq P_{Gi} \leq P_{Gi \max} \quad (\text{II.9})$$

$$Q_{Gi \min} \leq Q_{Gi} \leq Q_{Gi \max} \quad (\text{II.10})$$

II.3.1.1. Résolution du problème de l'Écoulement de Puissance

Pour résoudre le problème de l'écoulement de puissance, on utilise des méthodes itératives appliquées à un système d'équations algébriques, non linéaires de grandes dimensions. Généralement les méthodes de résolution utilisées sont la méthode de Gauss Seidel, de Newton Raphson et Newton Raphson découplée et rapide. Bien sûr, le choix de la méthode repose sur la rapidité de convergence, la précision et la minimisation du temps d'exécution de calcul. La méthode la plus utilisée est la méthode de Newton Raphson.

II.3.1.2. Méthode du Newton Raphson

Le principe de cette méthode réside par le développement de Taylor des fonctions de l'écoulement de puissance P et Q autour des valeurs des variables d'état θ et V , pour les équations donc on peut écrire:

$$\left. \begin{aligned} \Delta P_i &= \sum_{k=1}^N \frac{\partial P_i}{\partial \theta_{ki}} \Delta \theta_k + \sum_{k=1}^N \frac{\partial P_i}{\partial V_k} \Delta V_k \\ \Delta Q_i &= \sum_{k=1}^N \frac{\partial Q_i}{\partial \theta_k} \Delta \theta_k + \sum_{k=1}^N \frac{\partial Q_i}{\partial V_k} \Delta V_k \end{aligned} \right\} \quad (\text{II.11})$$

En écrivant le système des équations précédentes sous la forme matricielle, on obtient :

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = [J] \begin{bmatrix} \Delta \theta \\ \frac{\Delta V}{V} \end{bmatrix} = \begin{bmatrix} H & N \\ J & L \end{bmatrix} \begin{bmatrix} \Delta \theta \\ \frac{\Delta V}{V} \end{bmatrix} \quad (\text{II.12})$$

$$\begin{bmatrix} \Delta \theta \\ \frac{\Delta V}{V} \end{bmatrix} = [J]^{-1} \begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} H & N \\ J & L \end{bmatrix}^{-1} \begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} \quad (\text{II.13})$$

$[J] = \begin{bmatrix} H & N \\ J & L \end{bmatrix}$ est la matrice jacobéenne, qui représente les dérivées partielles des P , Q par rapport à θ , V c'est-à-dire:

$$H = \left[\frac{\partial P}{\partial \theta} \right], N = \left[V \frac{\partial P}{\partial V} \right], J = \left[\frac{\partial Q}{\partial \theta} \right] \text{ et } L = \left[V \frac{\partial Q}{\partial V} \right]$$

La méthode de Newton Raphson consiste à résoudre le système (II.13) pour déduire à l'itération k les vecteurs des variables d'état; $\Delta \theta^k$ pour les jeux de barres PV et les jeux de barres PQ , et ΔV^k pour les jeux de barres PQ .

Puis mettre à jour les nouvelles valeurs des θ^{k+1} et V^{k+1} jusqu'à la convergence. Les étapes de l'algorithme de cette méthode sont résumées par :

- 1- Lire les données et les paramètres du réseau électrique donné.
- 2-Former la matrice admittance Y_{bus} .
- 3- Lire les valeurs estimées initiales des tensions nodales (module et argument).
- 4-Mettre $k=1$;
- 5- Calculer les puissances active et réactive (P_i , Q_j) en utilisant les équations (II.7) et (II.8), puis calculer $\Delta P_i = P_i^{sp} - P_i$, $\Delta Q_j = Q_j^{sp} - Q_j$, $i \in PV, PQ$ et $j \in PQ$ avec P_i^{sp} , Q_j^{sp} sont les puissances actives et réactives spécifiées.
- 6- Test de convergence si $\max(\Delta P_i) \leq \varepsilon$ et $\max(\Delta Q_j) \leq \varepsilon$ aller à l'étape 9, si non aller à l'étape 7.
- 7- Former la matrice jacobéenne et résoudre le système des équations (II.13) pour obtenir $\Delta \theta$ et ΔV , puis mettre à jour les nouvelles valeurs : $\theta^{k+1} = \theta^k + \Delta \theta$ et $V^{k+1} = V^k + \Delta V$
- 8-Test sur la limite de puissance réactive au jeu de barres PV si elle dépasse sa limite inférieure ou supérieure, elle prend la valeur limite et le nœud est basculé au jeu de barres PQ .

9- Calculer les puissances réactives générées au jeu de barres PV et la puissance active générée au jeu de barres de référence.

10- Calculer les puissances transmises dans les branches et les pertes de puissance.

II.3.2. Dispatching économique

Le problème est de réduire au minimum le coût de la puissance totale générée par l'ensemble des centrales interconnectées.

Les générateurs à combustibles distincts fournissent la même énergie électrique à des coûts différents. Donc à première vue le problème est simple à résoudre, en confiant aux générateurs les plus économiques la production de la majorité de l'énergie. Mais le problème, c'est qu'en tenant compte de l'architecture du réseau et des pertes de transmission, il sera quelquefois plus utile de produire l'énergie à des coûts élevés d'un générateur plus proche que d'aller chercher l'énergie d'un générateur lointain moins chère, mais plus coûteux à cause des pertes. [22]

II.3.2.1. Dispatching économique sans contraintes

Lorsque les limites des puissances de chaque générateur et les pertes dans le réseau sont négligées, le problème est simple, il est donc décrit comme suit:

$$F = \sum_{i=1}^{NG} f_i = \sum_{i=1}^{NG} a_i + b_i P_{Gi} + c_i P_{Gi}^2 \quad (\text{II.14})$$

Et

$$P_D = \sum_{i=1}^{NG} P_{Gi} \quad (\text{II.15})$$

Dans ce genre de problème il faut rappeler qu'il est utile d'utiliser la méthode de Lagrange:

$$L = F + \sum_{i=1}^n \lambda_i g_i + \sum_{j=1}^m \mu_j h_j \quad (\text{II.16})$$

Les conditions nécessaires pour trouver un minimum de L appelées conditions de Kuhn-Tucker sont les suivantes:

$$\begin{cases} \left\{ \begin{array}{l} \frac{\partial L}{\partial x_i} = 0 \text{ \& } \frac{\partial L}{\partial \lambda_i} = g_i(x) = 0 \quad i = 1, \dots, n \\ \frac{\partial L}{\partial \mu_j} = h_j(x) \leq 0 \\ \mu_j h_j(x) = 0 \end{array} \right. \quad j = 1, \dots, m \end{cases} \quad (\text{II.17})$$

Par projection sur notre problème on a :

$$L = F + \lambda [P_D - \sum_{i=1}^{NG} P_{Gi}] \quad (\text{II.18})$$

$$\frac{\partial L}{\partial P_{Gi}} = \frac{\partial F}{\partial P_{Gi}} + \lambda(0 - 1) = 0 = \frac{\partial F}{\partial P_{Gi}} = \lambda \quad (\text{II.19})$$

$$F = \sum_{i=1}^{NG} f_i \Rightarrow \frac{\partial F}{\partial P_{Gi}} = \frac{\partial f_i}{\partial P_{Gi}} = \lambda \quad i = 1, \dots, NG \quad (\text{II.20})$$

$$\lambda = \frac{\partial f_i}{\partial P_{Gi}} = b_i + 2c_i P_{Gi} \quad (\text{II.21})$$

$$\frac{\partial L}{\partial \lambda} = (P_D - \sum_{i=1}^{NG} P_{Gi}) = 0 \Rightarrow \sum_{i=1}^{NG} P_{Gi} = P_D \quad (\text{II.22})$$

Après la combinaison des équations précédentes on trouve:

$$\lambda = \left(\sum_{i=1}^{NG} \frac{1}{2a_i} \right)^{-1} \left(P_D + \sum_{i=1}^{NG} \frac{b_i}{2a_i} \right) \quad (\text{II.23})$$

Et

$$P_{Gi} = \frac{1}{2a_i} \left(\left(\sum_{i=1}^{NG} \frac{1}{2a_i} \right)^{-1} \left(P_D + \sum_{i=1}^{NG} \frac{b_i}{2a_i} \right) - b_i \right) \quad (\text{II.24})$$

Cette dernière expression qui nous donne donc l'ensemble des puissances générées minimisant le coût total (contraintes d'inégalités négligées) et constituant notre premier optimum, est applicable s'il n'existe pas de limites sur les puissances générées [23].

II.3.2.2. Dispatching économique avec des limites sur les puissances générées

Dans le cas où les puissances des générateurs sont limitées par des bornes inférieures P_{Gimin} et des bornes supérieures P_{Gimax} . Le problème d'optimisation devient de la forme [23]:

$$\left\{ \begin{array}{l} \min F = \sum_{i=1}^{NG} f_i = \sum_{i=1}^{NG} c_i + b_i P_{Gi} + a_i P_{Gi}^2 \\ \text{selon} \\ \sum_{i=1}^N P_{Gi} = P_D \\ P_{Gi \min} \leq P_{Gi} \leq P_{Gi \max} \end{array} \right. \quad (\text{II.25})$$

Les conditions de Kuhn-Tucker d'optimalité pour ce problème seront données par:

$$\left\{ \begin{array}{l} P_{Gi \min} < P_{Gi} < P_{Gi \max} \Rightarrow \frac{\partial C_i}{\partial P_{Gi}} = \lambda \\ P_{Gi} = P_{Gi \max} \Rightarrow \frac{\partial C_i}{\partial P_{Gi}} \leq \lambda \\ P_{Gi} = P_{Gi \min} \Rightarrow \frac{\partial C_i}{\partial P_{Gi}} \geq \lambda \end{array} \right. \quad (\text{II.26})$$

Et l'algorithme de résolution de ce problème est comme suit:

1- on calcule la puissance générée de chaque générateur par la formule de l'éq (II.24)

2- on vérifie les dépassements des puissances générées:

$$\text{si } P_{Gk} \geq P_{Gk \max}, P_{Gk} = P_{Gk \max}$$

$$\text{si } P_{Gk} \leq P_{Gk \min}, P_{Gk} = P_{Gk \min}$$

3- on prend la puissance générée qui atteint sa limite minimale ou maximale comme une charge c'est-à-dire: $P_{Dk'} = -P_{Gk}$ pour toute-puissance générée dépassée $k (k=1, \dots, nk)$

4-on recalcule l'équation de l'équilibre de puissance comme suit:

$$\sum_{\substack{i=1 \\ i \notin nk}}^N P_{Gi} = P_D + \sum_{k=1}^{nk} P_{Dk'} \quad \text{ou bien} \quad \sum_{\substack{i=1 \\ i \notin nk}}^N P_{Gi} = P_D - \sum_{k=1}^{nk} P_{Gk}$$

5- le processus itératif continue en retournant à l'étape 1 jusqu'à ce que toutes les contraintes soient satisfaites.

Si les pertes dans le réseau sont négligeables, cette méthode va donner de fausses informations de point de vue coût, parce qu'elle va répartir la plupart de la demande sur les générateurs qui ont l'incrément du coût le plus petit quoique ces générateurs soient les plus éloignés de la charge.

II.3.2.3. Dispatching économique avec des pertes constantes

À cause des pertes de puissance dans les lignes de transport qui varient en fonction de la répartition des puissances entre les centrales et la charge, le dispatching économique est très influencé par la topographie du réseau.

Il peut être plus intéressant de produire pour plus cher près du lieu de consommation, que loin et pour moins cher, à cause des pertes. Donc, nous devons multiplier le coût incrémental par un facteur de pénalité pour pénaliser les centrales qui produisent de la puissance dont le transit provoque d'importantes pertes.

Pour prendre en considération les pertes de puissance constantes, on doit les évaluer et les inclure dans la demande comme suit [23].

$$F(x) : \sum_{i=1}^{NG} f_i = \sum_{i=1}^{NG} c_i + b_i P_{Gi} + a_i P_{Gi}^2 \quad (\text{II.27})$$

$$g(x) : \sum_{i=1}^{NG} f_i = \sum_{i=1}^{NG} P_{Gi} = P_D + P_L \quad (\text{II.28})$$

$$h(x) : P_{Gi \min} \leq P_{Gi} \leq P_{Gi \max} \quad i = 1, \dots, NG \quad (\text{II.29})$$

L'équation résultante de l'optimisation:

$$\begin{cases} L = F + \lambda(P_D + P_L - \sum_{i=1}^{NG} P_{Gi}) + \sum_{i=1}^{NG} \mu_{i \max} (P_{Gi \max} - P_{Gi}) + \sum_{i=1}^{NG} \mu_{i \min} (P_{Gi} - P_{Gi \min}) \\ P_{Gi} < P_{Gi \max} \Rightarrow \mu_{i \max} = 0 \\ P_{Gi} > P_{Gi \min} \Rightarrow \mu_{i \min} = 0 \end{cases} \quad (\text{II.30})$$

Les conditions nécessaires pour trouver le minimum sont:

$$\begin{cases} \frac{\partial L}{\partial P_{Gi}} = 0 \\ \frac{\partial L}{\partial \lambda} = 0 \\ \frac{\partial L}{\partial \mu_{i(\max)}} = P_{Gi} - P_{Gi \max} = 0 \\ \frac{\partial L}{\partial \mu_{i(\min)}} = P_{Gi} - P_{Gi \min} = 0 \end{cases} \quad (\text{II.31})$$

Quand les limites du générateur ne sont pas satisfaites:

$$\frac{\partial L}{\partial P_{Gi}} = 0 = \frac{\partial F}{\partial P_{Gi}} + \lambda \left(0 + \frac{\partial P_L}{\partial P_{Gi}} - 1 \right) \quad (\text{II.32})$$

$$\frac{\partial F}{\partial P_{Gi}} = \frac{\partial}{\partial P_{Gi}} (f_1 + f_2 + \dots + f_{ng}) = \frac{\partial f_i}{\partial P_{Gi}} \quad (\text{II.33})$$

$$\begin{aligned} \therefore \lambda &= \frac{\partial f_i}{\partial P_{Gi}} + \lambda \frac{\partial P_L}{\partial P_{Gi}} = \left(\frac{1}{1 - \partial P_L / \partial P_{Gi}} \right) \frac{\partial f_i}{\partial P_{Gi}} = L_i \frac{\partial f_i}{\partial P_{Gi}} \text{ avec } L_i = \frac{1}{1 - \partial P_L / \partial P_{Gi}} \\ \frac{\partial L}{\partial \lambda} &= 0 = P_D + P_L - \sum_{i=1}^{ng} P_{Gi} \\ \therefore \sum_{i=1}^{ng} P_{Gi} &= P_D + P_L \end{aligned} \quad (\text{II.34})$$

Et l'algorithme de résolution qui a été utilisé dans le problème sans pertes, peut-être utilisé dans ce problème, seulement on va modifier la puissance générée comme suit:

$$P_{Gi} = \frac{1}{2a_i} \left(\left(\sum_{i=1}^{NG} \frac{1}{2a_i} \right)^{-1} \left(P_D + P_L + \sum_{i=1}^{NG} \frac{b_i}{2a_i} \right) - b_i \right) \quad (\text{II.35})$$

II.3.2.4. Dispatching économique avec les pertes en fonction des puissances générées

À cause de la situation effective des générateurs qui sont situés loin du centre de la demande de la charge électrique, les pertes de transport dans les réseaux électriques, en réalité, sont très importantes.

Si on veut simplifier les choses la forme de ces pertes sera:

$$P_L = \sum_{i=1}^{NG} \sum_{j=1}^{NG} P_{Gi} B_{ij} P_{Gj} \quad (\text{II.36})$$

Mais en réalité la forme la plus précise dite la formule de Kron est la suivante [23] [24]:

$$P_L = \sum_{i=1}^{NG} \sum_{j=1}^{NG} P_{Gi} B_{ij} P_{Gj} + \sum_{j=1}^{NG} B_{oj} P_{Gj} + B_{oo} \quad (\text{II.37})$$

Où les B_{ij} sont les coefficients des pertes, souvent supposés constants (en MW^{-1}).

Le facteur de pénalité L_i est en fonction de l'accroissement des pertes de transmission:

$$L_i = \left(1 - \frac{\partial P_L}{\partial P_{Gi}}\right)^{-1} \quad (\text{II.38})$$

Le coût sera le minimum, quand l'accroissement du coût de chaque centrale multiplié par son facteur de pénalité est le même pour toutes les centrales de production en service.

$$P_L = \sum_{i=1}^{NG} \sum_{j=1}^{NG} P_{Gi} B_{ij} P_{Gj} + \sum_{j=1}^{NG} B_{oj} P_{Gj} + B_{oo} \quad (\text{II.39})$$

$$\frac{\partial P_L}{\partial P_{Gi}} = 2 \sum_{j=1}^{NG} B_{oj} P_{Gj} + B_{oo}$$

$$\frac{\partial f_i}{\partial P_{Gi}} = b_i + 2a_i P_{Gi}$$

$$\lambda = \frac{\partial P_L}{\partial P_{Gi}} + \lambda \frac{\partial P_L}{\partial P_{Gi}} = b_i + 2a_i P_{Gi} + 2\lambda \sum_{j=1}^{NG} B_{ij} P_{Gj} + B_{oi} \quad (\text{II.40})$$

$$\text{On a : } \sum_{j=1}^{NG} B_{ij} P_{Gj} = B_{ii} P_{Gi} + \sum_{\substack{j=1 \\ j \neq i}}^{NG} B_{ij} P_{Gj}$$

D'après l'équation (II.40) on aura:

$$\left(\frac{a_i}{\lambda} + B_{ii}\right) P_{Gi} + \sum_{\substack{j=1 \\ j \neq i}}^{NG} B_{ij} P_{Gj} = \frac{1}{2} \left(1 - B_{oi} \frac{b_i}{\lambda}\right)$$

On peut écrire les équations sous forme matricielle

$$\begin{bmatrix} \frac{a_1}{\lambda} + B_{11} & B_{12} & \cdots & B_{1n} \\ B_{21} & \frac{a_2}{\lambda} + B_{22} & \cdots & B_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ B_{n1} & B_{n2} & \cdots & \frac{a_n}{\lambda} + B_{nn} \end{bmatrix} \begin{bmatrix} P_{G1} \\ P_{G2} \\ \vdots \\ P_{Gn} \end{bmatrix} = \frac{1}{2} \begin{bmatrix} 1 - B_{01} - \frac{b_1}{\lambda} \\ 1 - B_{02} - \frac{b_2}{\lambda} \\ \vdots \\ 1 - B_{0n} - \frac{b_n}{\lambda} \end{bmatrix} \quad (\text{II.41})$$

Si ces facteurs de pénalité ne sont calculés qu'une seule fois avant d'exécuter le dispatching en utilisant les informations prises de l'écoulement de puissance, les solutions trouvées, certes, sont très proches de la solution optimale, mais elles ne prennent pas vraiment avec exactitude l'effet des pertes avec la variation de la puissance engendrée d'où l'intérêt de la mise à jour du calcul du coefficient B et le recalcul du dispatching jusqu'à ce que la variation de la puissance du jeu de barres de référence soit négligeable.

II.3.3. Optimisation Multiobjectif

Les problèmes d'optimisation [25] issus de problématiques réelles sont la plupart du temps de nature multiobjectif, car plusieurs critères sont à considérer simultanément.

Donc, un problème d'optimisation multiobjectif consiste à optimiser plusieurs fonctions objectives simultanément qui sont, en général, contradictoires ou conflictuels.

Dans le domaine de l'écoulement de puissance optimal, on a trois types:

II.3.3.1. Minimisation du Coût et les Emissions de Pollution

Lors de la production de l'énergie électrique, on veut toujours minimiser à la fois le coût de combustible, et les émissions de pollution dans les centrales. Les émissions totales produites par les centrales thermiques sont données par la fonction suivante:

$$E_T = \sum_{i=1}^{NG} E_i \quad (\text{II.42})$$

Avec E_i est la fonction des émissions pour l'unité de production i définie par (II.4) et exprimée en Ton/hr.

Le contrôle des émissions est obtenu en assignant un facteur de coût sur la fonction des émissions totales :

$$F_e = w \times T_T \quad (\text{II.43})$$

Avec w est le facteur de contrôle des émissions exprimé en Ton/\$.

La fonction objectif du problème de la répartition économique de puissance devient [26] :

$$\text{Min}F = \alpha F_T + (1 - \alpha) F_e \quad (\text{II.44})$$

Avec α est un facteur de contrôle inclus entre 0 et 1. F_T représente la fonction du coût.

Si $\alpha = 1$ les contraintes environnementales ne seront pas considérées, et si $\alpha = 0$ notre objectif sera la minimisation des émissions sans tenir compte du coût de production. Si α varie de 0 à 1 la recherche ne nous donnera plus une solution unique mais une multitude de solutions. Ces solutions sont appelées solutions de Pareto et l'ensemble de solutions que l'on obtient à la fin de la recherche est la surface de compromis.

A vrai dire plusieurs difficultés surviennent après avoir trouvé les solutions du problème multiobjectif puisqu'il faut sélectionner une solution dans cet ensemble. La solution qui sera choisie par l'utilisateur va refléter les compromis opérés par le décideur vis-à-vis des différentes fonctions objectifs.

II.3.3.2. Minimisation du Coût avec les Pertes Actives Totales

On veut minimiser le coût de combustible avec la minimisation des pertes actives, la fonction objectif du problème de la répartition économique de puissance devient :

$$\text{Min. } F = \alpha F_T + (1 - \alpha) P_L \quad (\text{II.45})$$

De même que précédemment α est un facteur de contrôle inclus entre 0 et 1. P_L représente les pertes actives totales données par l'équation :

$$P_L = \sum_i^{NG} P_{Gi} - P_D \quad (\text{II.46})$$

Si $\alpha = 1$ les pertes actives ne seront pas considérées, et si $\alpha = 0$ notre objectif sera la minimisation des pertes actives totales sans tenir compte du coût de production. Si α varie de 0 à 1, la recherche ne donne pas une solution unique mais une multitude de solutions.

Ces solutions sont appelées solutions de Pareto et l'ensemble de solutions que l'on obtient à la fin de la recherche est la surface de compromis.

II.3.4. Conclusion

Dans ce chapitre une modélisation globale du problème de l'écoulement de puissance optimal a été donnée par la modélisation et la définition techno-économique des différentes centrales

thermiques électriques à vapeur, dont on doit minimiser leurs fonctions de coût. Ainsi, le problème de l'écoulement de puissance optimal a été formulé par la définition des types de fonctions objectifs, à savoir, le coût du combustible quadratique avec un ou plusieurs types de combustibles, le coût du combustible en tenant en compte l'effet des valves d'admission, la minimisation des pertes actives, l'optimisation multiobjectif, et on a défini toutes les variables de contrôle qui influent sur l'optimisation. Enfin, on a défini les contraintes d'égalités par la résolution des équations de l'écoulement de puissance qui sont satisfaites par l'égalité entre la génération et la demande et les pertes actives.

Plusieurs contraintes d'inégalités sont à maintenir pour satisfaire le fonctionnement et la sécurité du réseau électrique. Parmi ces contraintes, on trouve les limites sur les variables de contrôle, les limites des tensions des jeux de barres de charge et les limites des puissances transmises dans les lignes de transport de l'énergie électrique.

Après la modélisation du problème de l'écoulement de puissance optimal, l'optimisation de l'OPF devient facile par l'application des méthodes appropriées. Pour cela, il existe des méthodes classiques et des méthodes métaheuristiques, ces méthodes seront détaillées dans les deux chapitres qui suivent.

REFERENCES

1. J. Wood and B. F. Wollenberg, *Power Generation, Operation and Control*, John Wiley & Sons, Canada 1996.
2. M. Basu, "Fuel Constrained Economic Emission Load Dispatch Using Hopfield Neural Networks," *Electric Power Systems Research*, vol. 63, no. 1, Aug. 2002, pp. 51–57.
3. V. L. Vickers and W. J. Hobbbs, S. Vemuri and D. L. Todd, "Fuel Resource Scheduling with Emission Constraints," *IEEE Trans. Power Systems*, vol. 9, no. 3, Aug. 1994, pp. 1531–1538.
4. M. Djukanovic, B. B. B. Milosevic, D. J. Sobajic and Y.-H. Pao, "Fuzzy Linear Programming Based Optimal Fuel Scheduling Incorporating Blending/Transloading Facilities," *IEEE Trans. Power System*, vol. 11, no. 2, May 1996, pp. 1017–1023.

5. Y. -L. Hu and W. G. Wee, "A Hierarchical System for Economic Dispatch with Environmental Constrains," *IEEE Trans. Power Systems*, vol. 9, no. 2, May 1994, pp. 1076–1082.
6. R. Ramanathan, "Emission Constrained Economic Dispatch," *IEEE Trans. Power Systems*, vol. 9, no. 4, No. 1994, pp. 1994–2000.
7. C. -M. Huang, H. T. Yang, and C. L. Huang, "Bi-Objective Power Dispatch Using Fuzzy Satisfaction-Maximizing Decision Approach," *IEEE Trans. Power Systems*, vol. 12, no. 4, Nov. 1997, pp. 1715–1721.
8. Chao-Ming Huang and Yann-Chang Huang, "A Novel Approach to Real-Time Economic Emission Power Dispatch," *IEEE Trans. Power Systems*, vol. 18, no. 1, Feb. 2003, pp. 288–294.
9. J. H. Talaq Ferial and M. E. El-Hawary, "Minimum Emission Power Flow," *IEEE Trans. Power Systems*, vol. 9, no. 1, Feb. 1994, pp. 429–435.
10. P. Venkatesh, R. Gnanadass and N.P. Padhy, "Comparison and Application of Evolutionary Programming Techniques to Combined Economic Emission Dispatch with Line Flow Constraints," *IEEE Trans. Power Systems*, vol. 18, no. 2, May 2003, pp. 688–697.
11. Y. H. Song and In-Keun Yu, "Dynamic Load Dispatch with Voltage Security and Environmental Constraints," *Electric Power Systems Research*, vol. 43, 1997, pp. 53–60.
12. J. S. Dhillon and D. P. Kothari, "Economic-emission load dispatch using binary successive approximation-based evolutionary search," *IET Generation, Transmission & Distribution*, vol. 3, no. 1, Jan. 2009, pp. 1–16.
13. L. H. Wu, Y. N. Wang, X. F. Yuan and S. W. Zhou, "Environmental/economic power dispatch problem using multiobjective differential evolution algorithm," *Electric Power Systems Research*, vol. 80, no. 9, Sept. 2010, pp. 1171–1181.
14. L. Wang and C. Singh, "Environmental/economic power dispatch using a fuzzified multi-objective particle swarm optimization algorithm," *Electric Power Systems Research*, vol. 77, no. 12, Oct. 2007, pp. 1654–1664.
15. J. S. Dhillon, S. C. Parti and D. P. Kothari, "Stochastic economic emission load dispatch," *Electric Power Systems Research*, vol. 26, no. 3, Apr. 1993, pp. 179–186.
16. M. A. Abido, "Multiobjective particle swarm optimization for environmental /economic dispatch problem," *Electric Power Systems Research*, vol. 79, no. 7, Jul. 2009, pp. 1105–1113.

17. A.J.Wood and B.F.wollenberg "Power Generation, Operation and Control",2nd ed, Newyork : Wiley, 1996.
18. J.B. Park, K.S. Lee, J.R. Shin, K.Y.Lee," A Particle Swarm Optimization for Economic Dispatch with Nonsmooth Cost Functions", IEEE Trans. on Power Sys. Vol. 20, no.1,pp.34-42, Feb. 2005.
19. M.AIRashidi," Improved Optimal Economic and Environmental Operations of Power Systems Using Particle Swarm Optimization" Thèse en PHD, Université de Dalhousie, 2007, Halifax Nova Scotia.
20. T. Bouktir, R. Labdani , L. Slimani," Economic Power Dispatch of Power System with Pollution Control Using Multiobjective Particle Swarm Optimization" Journal of Pure & Applied Sciences Volume 4, No. 2, University of Sharjah, June 2007.
21. D. S. Kirschen, G. Strbac: "Fundamentals of power system economics" Wiley 2004.
22. H. W. Dommel, W. F. Tinney, "Optimal Power Flow Solutions," IEEE Trans on power apparatus and systems, Vol. PAS.87, N..10, pp.1866-1876, October 1968.
23. K. Y. Lee, Y.M. Park, and J.L. Ortiz, "A United Approach to Optimal Real and Reactive Power Dispatch," IEEE Trans on Power Systems, Vol. Pas-104, pp.1147-1153, May 1985.
24. M. Sasson, "Non linear Programming Solutions for load flow, minimum loss, and economic dispatching problems", IEEE trans. vol. Pas-88, No. 4, pp. 399-409, April 1969.
25. Dhaenens-Flipo C. Optimisation Combinatoire Multi-Objectif : Apport des Méthodes Coopératives et Contribution à l'Extraction de Connaissances, thèse d'Habilitation à diriger des Recherches de l'U.S.T.L, Lille, 2005.
26. M. Huneault and F. D. Galiana, "A Survey of the Optimal Power Flow Literature", IEEE Trans on Power Systems, Vol. 6, No. 2, pp. 762-770, May 1991.

Chapitre III

PROBLEMES D'OPTIMISATION

III.1. Introduction

Pour avoir une idée sur les méthodes mathématiques utilisées dans la résolution d'un problème d'optimisation. Nous devons présenter quelques définitions nécessaires à l'application de ces méthodes, ainsi que par l'exposition de concepts de base importants, tels que la formulation mathématique d'un problème d'optimisation. Commencant donc par l'adoption d'un vocabulaire spécifique comme suit :

Un problème d'optimisation mono-objectif est défini par un ensemble de variables, une fonction objectif et un ensemble de contraintes. Par contre, un problème d'optimisation multiobjectif est défini par un ensemble de variables, un ensemble de fonctions objectif et un ensemble de contraintes. L'ensemble des domaines de définition des différentes variables du problème est appelé l'espace d'état, appelé aussi domaine de recherche. Les variables du problème dites aussi variables de conception ou de décision, peuvent être de natures diverses (réelles, entières, booléennes. etc.) et exprimer des données qualitatives ou quantitatives. On cherche à minimiser ou à maximiser La fonction objectif (fonction de coût) qui définit le but à atteindre. En réalité, on cherche généralement à minimiser et non pas à maximiser, et si c'est le cas, on procède à une petite transformation de la fonction d'où on aura une fonction multimodale qui présente plusieurs minima (locaux et globaux), ou une fonction unimodale qui n'a qu'un minimum, le minimum global. L'ensemble des contraintes est en général un ensemble d'égalités ou d'inégalités que les variables de l'espace d'état doivent satisfaire. Ces contraintes limitent l'espace de recherche.

III.2. Problème d'optimisation mono-objectif

Un problème d'optimisation de dimension n peut être écrit de façon générale sous la forme:

$$(P) \begin{cases} \text{Min } f(x) \in \mathfrak{R}^n \\ g_i(x) \leq 0 \quad i = 1, \dots, p \\ h_j(x) = 0 \quad j = 1, \dots, q \end{cases} \quad (\text{III.1})$$

Où

$f(x)$ est le critère à minimiser appelé aussi fonction objectif

x est un vecteur à n variables x_k qui représentent les paramètres du problème à optimiser

$g_i(x)$ et $h_j(x)$ représentent respectivement les contraintes d'inégalité et d'égalité

$x_{k \min}$ et $x_{k \max}$ désignent les contraintes de domaine

\mathfrak{R}^n est l'espace de recherche borné par les contraintes de domaine.

La solution d'un problème d'optimisation est alors donnée par un ensemble de paramètres x^* pour lesquels la fonction objectif présente une valeur minimale, en respectant les contraintes d'égalité, d'inégalité et de domaine.

Suivant la nature de $f(x)$, des contraintes $g_j(x)$ et des variables x , le problème d'optimisation correspondant porte des noms divers. On distingue plus particulièrement la programmation linéaire, la programmation quadratique, la programmation convexe, la programmation discrète, les problèmes de la programmation continue, et la programmation non linéaire

Derrière toutes ces catégories, il y a bien entendu des méthodes mathématiques de résolution qui en général portent le même nom. Dans ce qui suit, nous nous limiterons aux méthodes de programmation non linéaires.

III.2.1. Minimum local et minimum global

Un point x^* de l'espace de recherche \mathfrak{R}^n représente un minimum local ou optimum local, s'il existe un voisinage de x^* noté $V(x^*)$, tel que:

$$\forall x \in V(x^*) f(x) \geq f(x^*) \quad (\text{III.2})$$

Cette relation signifie que dans le voisinage de x^* , défini par un ϵ , il n'existe aucun point pour lequel $f(x)$ est inférieur à $f(x^*)$.

Un point x^* de l'espace de recherche \mathfrak{R}^n est un minimum global ou optimum global si:

$$\forall x \in \mathfrak{R}^n f(x) \geq f(x^*) \quad (\text{III.3})$$

Nous pouvons dire aussi que le minimum global est le plus petit minimum local de l'espace de recherche, comme nous montre la Figure III.1.

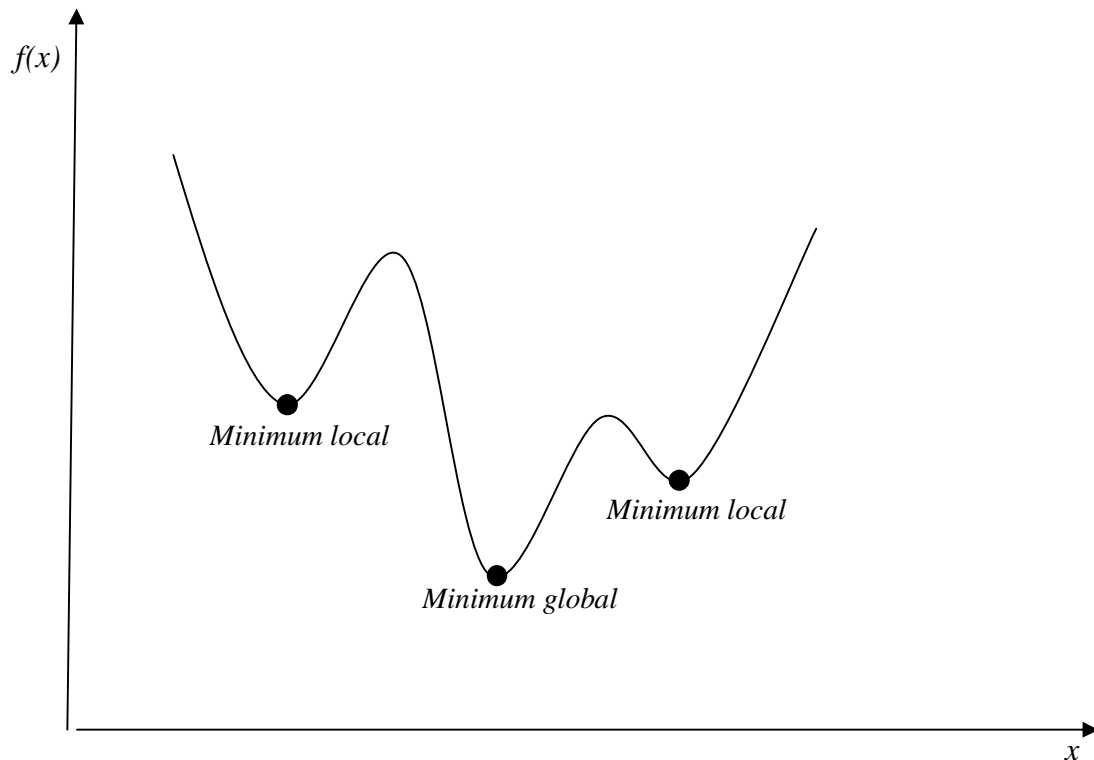


Figure III.1 - Représentation du minimum local et global d'une fonction [1]

Lorsqu'une fonction ne contient qu'un minimum local, elle est dite unimodale, dans le cas contraire, elle est dénommée multimodale.

III.2.2. Optimisation sans contraintes

Un problème d'optimisation est dit non contraint s'il ne contient pas de fonction contrainte, c'est-à-dire, si les fonctions $g_i(x)$ et $h_j(x)$ du problème (III.1) ne sont pas définies, comme dans le cas du problème (III.5):

$$(P) \{ \text{Min } f(x) \in \mathbb{R}^n \quad (III.5)$$

Une condition nécessaire pour que x^* soit minimum local d'un problème non contraint est donnée par (III.6):

$$\begin{cases} \nabla f(x^*) = 0 \\ H(x^*) \text{ non négative} \end{cases} \quad (III.6)$$

Où

∇f est le gradient de la fonction objectif

$H = \nabla^2 f$ est la matrice de dérivées secondes partielles de f , qualifiée de Hessien.

Une condition suffisante pour que x^* soit minimum local d'un problème non contraint est donnée par (III.7):

$$\begin{cases} \nabla f(x^*) = 0 \\ H(x^*) \text{ positive} \end{cases} \quad (\text{III.7})$$

Les conditions (III.6) et (III.7) sont uniquement valables pour des fonctions différentiables et ne s'appliquent pas à des points situés sur les frontières de l'espace de recherche [2].

Dans la pratique, nous classifions les problèmes d'optimisation non contraints selon la nature mathématique de la fonction objectif. Celle-ci peut être unidimensionnelle ou multidimensionnelle, continue ou discontinue, linéaire ou non linéaire, convexe ou non convexe, différentiable ou non différentiable.

Selon les caractéristiques du problème d'optimisation non contraint, nous pouvons appliquer différentes méthodes de résolution pour identifier sa solution. Ces méthodes sont séparées en deux grands groupes: les méthodes déterministes et les méthodes stochastiques.

III.2.2.1. Les méthodes d'optimisation locales

La recherche locale peut être utilisée sur des problèmes de recherche d'une solution maximisant un critère parmi un ensemble de solutions candidates. Les algorithmes de recherche locale passent d'une solution à une autre dans l'espace des solutions candidates (l'espace de recherche) jusqu'à ce qu'une solution considérée comme optimale soit trouvée ou que le temps imparti soit dépassé. En revanche optimiser localement, c'est chercher une solution à un problème qui soit proche d'une solution de départ (optimisation locale), mais qui soit meilleure en terme de coût (fonction objectif). Pour cela, nous recherchons une meilleure solution par itérations successives, cette classe de méthodes peut être déterministe ou non déterministe.

Notons que ces méthodes cherchent le minimum d'une fonction en se fondant sur la connaissance d'une direction de recherche. Bien sûr, ces méthodes seront toujours applicables et même recommandées lorsque la solution cherchée est réputée proche de la solution connue (point de départ) ou si la fonction objectif est convexe, en particulier, si le calcul n'est pas coûteux.

Toutefois, elles ne sont pas indiquées pour un problème multimodal où le risque de rester bloqué dans un optimum local est fort probable, cela suffit pour illustrer l'enjeu des problèmes d'autres types.

III.2.2.2. Les méthodes d'optimisation globales

Il s'agit, de trouver un état de minimum et de ne s'arrêter que s'il est le meilleur (l'optimum global). Pour illustration de cette diversité, nous citons dans la suite les méthodes les plus utilisées d'entre elles ainsi que les différents principes sur lesquels elles se fondent. En dépit de l'abondance des méthodes proposées, nous pouvons leur trouver des traits caractéristiques, suivant leurs approches. Ainsi, nous donnons la classification suivante : on distingue deux types d'approches selon qu'elles incluent ou non des processus probabilistes, les méthodes déterministes et les méthodes non déterministes.

III.2.2.2.1. Les méthodes déterministes

Une méthode d'optimisation est dite déterministe lorsque son évolution vers la solution du problème est toujours la même pour un même contexte initial donné, ne laissant aucune place au hasard. Ce sont en général des méthodes efficaces, peu coûteuses. Ces méthodes permettent de bien gérer les contraintes, contrairement aux méthodes stochastiques et peuvent s'appliquer aux problèmes mixtes (variables réelles, entières et de catégories). Elles garantissent l'obtention de la solution globale du problème. Cependant, il faut savoir que les méthodes déterministes globales restent utilisables tant que le nombre de variables ne devient pas trop important.

III.2.2.2.2. Les méthodes évolutionnaires et les méthodes non déterministes

Les méthodes d'optimisation stochastiques s'appuient sur des mécanismes de transition probabilistes et aléatoires. Cette caractéristique indique que plusieurs exécutions successives de ces méthodes peuvent conduire à des résultats différents pour une même configuration initiale d'un problème d'optimisation. Ces méthodes ont une grande capacité à trouver l'optimum global du problème. Contrairement à la plupart des méthodes déterministes, elles ne nécessitent ni point de départ, ni la connaissance du gradient de la fonction objectif pour atteindre la solution optimale. Cependant, elles demandent un nombre important d'évaluations avant d'arriver à la solution du problème.

Ces méthodes non déterministes font appel à des tirages de nombres aléatoires. Elles permettent d'explorer l'espace de recherche plus efficacement. Dans la suite, on s'intéressera plus particulièrement aux métaheuristiques.

Le mot métaheuristique est dérivé de la composition de deux mots grecs :

- heuristique qui vient du verbe heuriskein (euriskein) et qui signifie trouver ;
- méta qui est un suffixe signifiant au-delà, dans un niveau supérieur.

III.2.2.2.1. Les méthodes inspirées des principes physiques

a) Le recuit simulé :

L'origine de cette méthode vient de l'analogie avec la métallurgie, elle consiste à monter la température du solide à des valeurs élevées pour atteindre des états de basse énergie d'un solide. Lorsque le solide est à une forte température, chaque particule possède une très grande énergie et peut effectuer de grands déplacements aléatoires dans la matière. Au fur et à mesure que la température est abaissée, chaque particule perd de l'énergie et sa capacité de déplacement se réduit. Les différents états transitoires de refroidissement permettent d'obtenir des matériaux très homogènes et de bonne qualité. Ce processus est appelé recuit. [3]

En 1953, Metropolis [4] a proposé un modèle qui simulait l'évolution d'une configuration d'atomes vers l'équilibre thermique. Dans ce modèle, une nouvelle configuration est obtenue à partir d'une petite perturbation sur la configuration courante. Cette nouvelle configuration est acceptée avec une probabilité $p = 1$ lorsque la différence d'énergie ΔE , entre elle et la configuration courante, est inférieure à 0. Dans le cas où $\Delta E > 0$, la probabilité d'acceptation p est donnée par une équation fondée sur la loi de Boltzmann (III.8).

$$p = e^{\frac{-\Delta E}{T}} \quad (\text{III.8})$$

Où

T est la température du système.

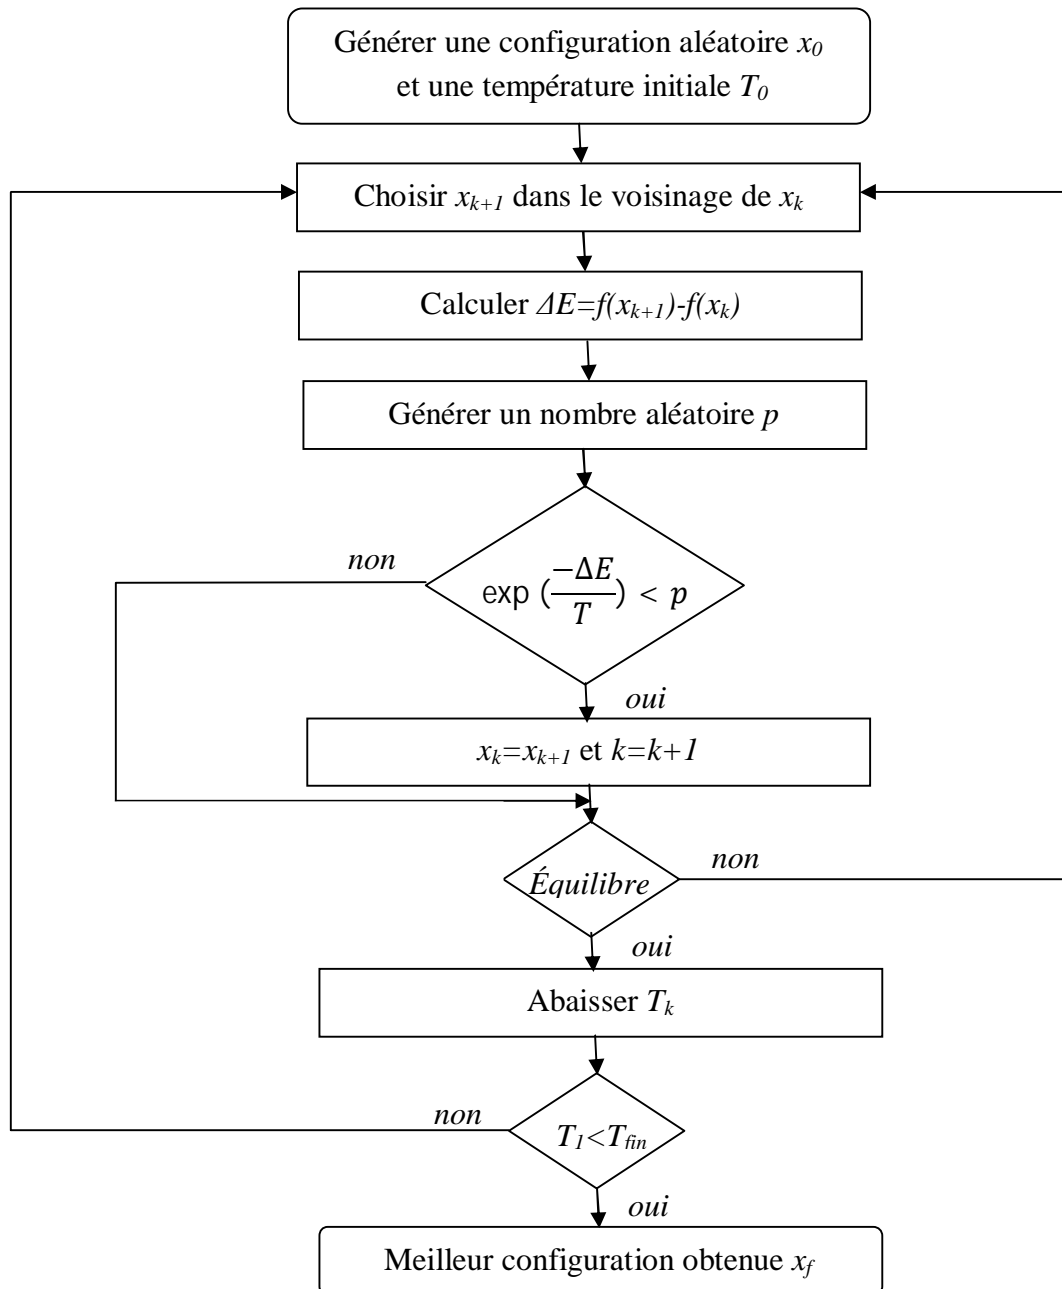


Figure III.2 – Organigramme de la méthode recuit simulé [1]

III.2.2.2.2. Les méthodes inspirées par des comportements biologiques

a) Recherche taboue

La recherche taboue [5-7] permet d'atteindre le minimum global d'un problème d'optimisation à partir d'une analogie avec la mémoire du cerveau humain.

Le processus de résolution développé par cette méthode commence avec la génération d'une configuration de paramètres au hasard. Ensuite, à chaque itération, le voisinage de la

configuration courante est parcouru par une série de mouvements aléatoires de façon à trouver une meilleure solution. Après son exécution, chacun de ces mouvements est ajouté à une liste qui représente la “mémoire” de la méthode. Cette liste, de taille limitée, est dénommée liste taboue.

Les mouvements qui font partie de la liste taboue sont considérés comme interdits. C'est-à-dire qu'ils ne peuvent pas être exécutés une autre fois tant qu'ils sont dans la liste. Par contre, s'il existe un mouvement qui appartient à la liste taboue, mais qui en même temps nous emmène à une meilleure solution du problème, une nouvelle exécution de ce mouvement sera alors acceptée. Dans ce cas-là, la nouvelle solution obtenue remplace la solution courante et le processus recommence.

Si pendant le processus d'optimisation la liste taboue devient pleine, nous retirons le plus ancien mouvement de la liste avant d'y ajouter un nouveau. L'algorithme s'arrête lorsque nous n'avons plus d'amélioration sensible de la valeur de la solution. La Figure III.3 illustre le processus développé par la méthode.

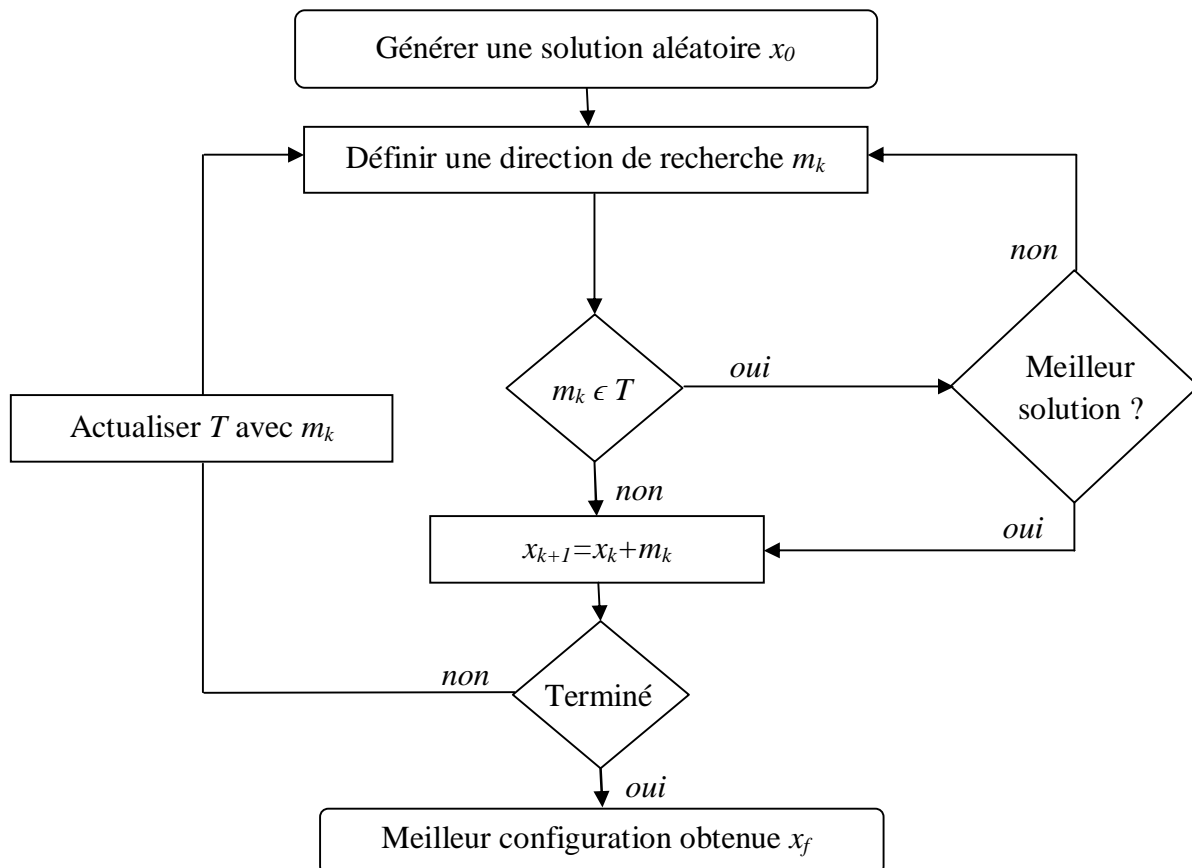


Figure III.3 – Organigramme de la méthode recherche taboue [1]

Les méthodes évolutionnaires ont un point commun puisque leurs itérations tendent à l'amélioration d'une solution unique. En effet, à partir d'une première solution, les approches décrites tentent de l'améliorer en fonction des contraintes du problème. Les méthodes auxquelles nous nous intéressons désormais considèrent la solution comme étant une population formée de plusieurs individus capables de répondre au problème.

b) L'algorithme de colonie de fourmis

Le premier algorithme d'optimisation par colonies de fourmis (Ant colony optimization, ACO) a été proposé par Dorigo [8,9] vers le début des années quatre-vingt-dix ; aussi appelé Ant System (AS), a été développé spécialement pour résoudre le problème du voyageur de commerce.

Depuis, cette approche a connu des variantes importantes et le nombre de travaux publiés augmente d'une année à l'autre, toute la théorie et les plus intéressants travaux récents sont dans [10,11] et [12].

Le principe de la méthode provient du comportement collectif des insectes, les algorithmes de colonies de fourmis sont nés d'une constatation simple : les insectes sociaux, et en particulier les fourmis, résolvent naturellement des problèmes complexes. Un tel comportement est possible, car les fourmis communiquent entre elles de manière indirecte par le dépôt de substances chimiques, appelées phéromones, sur le sol selon les pistes observées dans les colonies de fourmis et construisent ainsi une solution à un problème en tenant compte de leur expérience collective. Au fait, elles adoptent pour la recherche de la solution la notion du plus court chemin.

D'une manière simplifiée, les fourmis commencent par se déplacer au hasard. Puis, lorsqu'elles trouvent de la nourriture, elles retournent vers leur colonie, en marquant leur chemin à l'aide de phéromones. Si d'autres fourmis rencontrent ce chemin, il y a de fortes chances qu'elles arrêtent leurs déplacements aléatoires et qu'elles rejoignent le chemin marqué, en renforçant le marquage à leur retour, s'il mène bien vers la nourriture. Par conséquent, le chemin le plus court sera davantage parcouru, et donc plus renforcé et plus attractif. Par conséquent, le nombre de fourmis suivant cette trajectoire augmente. Au fil du

temps, la quantité de phéromones déposée sur le plus long chemin diminue et finit par disparaître. Toutes les fourmis suivent alors le chemin le plus court.

L'algorithme de colonies de fourmis a été principalement utilisé pour produire des solutions quasi optimales au problème du voyageur de commerce, puis, plus généralement, aux problèmes d'optimisation combinatoire. Récemment, son emploi se généralise à plusieurs domaines, depuis l'optimisation continue jusqu'à la classification, ou encore le traitement d'images.

c) Les algorithmes génétiques

Le concept d'algorithme génétique (de façon plus générale : algorithmes d'évolution) a été proposé par Holland en 1975 pour décrire les systèmes adaptatifs.

Les algorithmes génétiques, également appelés algorithmes évolutionnaires, sont inspirés du concept de sélection naturelle proposée par Charles Darwin. Le vocabulaire employé est directement calqué sur celui de la théorie de l'évolution et de la génétique. Nous parlerons donc ici d'individus (solutions potentielles), de populations, de gènes (variables), de chromosomes, de parents, de descendants, de reproductions, etc. Les points de l'espace de recherche sont alors les individus d'une population et la fonction à optimiser correspond à leur adaptation. Ces algorithmes font évoluer une population de manière itérative. Certains individus se reproduisent, d'autres mutent ou encore disparaissent et seuls les individus les mieux adaptés sont supposés survivre. L'héritage génétique des générations doit permettre à la population d'être de mieux en mieux adaptée et donc de mieux répondre au critère d'optimisation.

Les principales étapes d'un algorithme génétique sont :

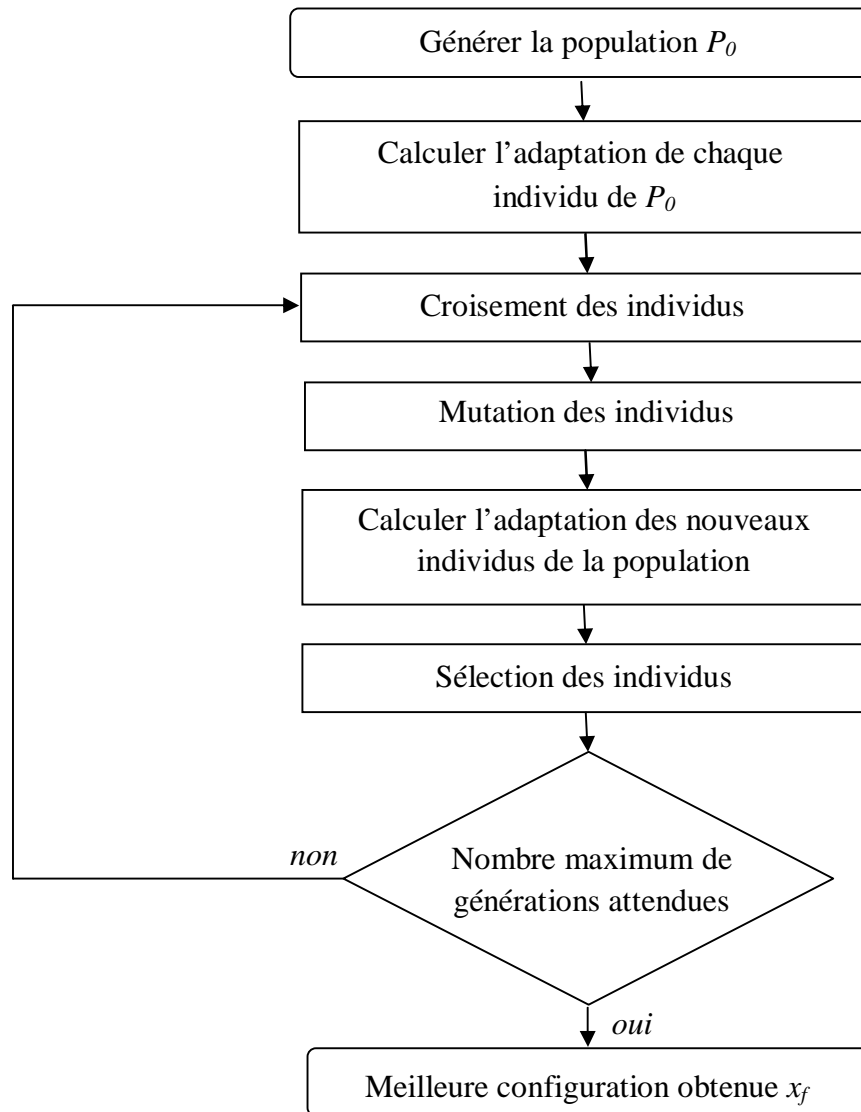


Figure III.4 – Organigramme de l'algorithme génétique standard [1]

En vue de sa généralisation et de son utilité dans plusieurs domaines industriels, maintes variantes de ces algorithmes ont vu le jour [13- 16].

d) La méthode des essais particuliers

L'optimisation par essaim particulier (OEP) est une métaheuristique d'optimisation née en 1995 aux États-Unis sous le nom de Particle Swarm Optimization (PSO). Elle a été inventée par Russel Eberhart (ingénieur en électricité) et James Kennedy (socio psychologue). Initialement, ces deux concepteurs cherchaient à modéliser des interactions sociales entre des «agents » devant atteindre un objectif donné dans un espace de recherche commun, chaque agent ayant une certaine capacité de mémorisation et de traitement de l'information. La règle de base était qu'il ne devait y avoir aucun chef d'orchestre, ni même aucune connaissance par

les agents de l'ensemble des informations, seulement des connaissances locales. Un modèle simple fut alors élaboré. Dès les premières simulations, le comportement collectif de ces agents évoquait celui d'un essaim d'êtres vivants convergeant parfois en plusieurs sous-essaims vers des sites intéressants. Ce comportement se retrouve dans bien d'autres modèles, explicitement inspirés des systèmes naturels. Ici, la métaphore la plus pertinente est probablement celle de l'essaim d'abeilles, particulièrement du fait qu'une abeille ayant trouvé un site prometteur sait en informer certaines de ses consœurs et que celles-ci vont tenir compte de cette information pour leur prochain déplacement

Finalement, le modèle s'est révélé être trop simple pour vraiment simuler un comportement social, mais par contre très efficace en tant qu'outil d'optimisation.

Les différentes étapes de l'algorithme sont présentées dans la figure ci dessous : [2]

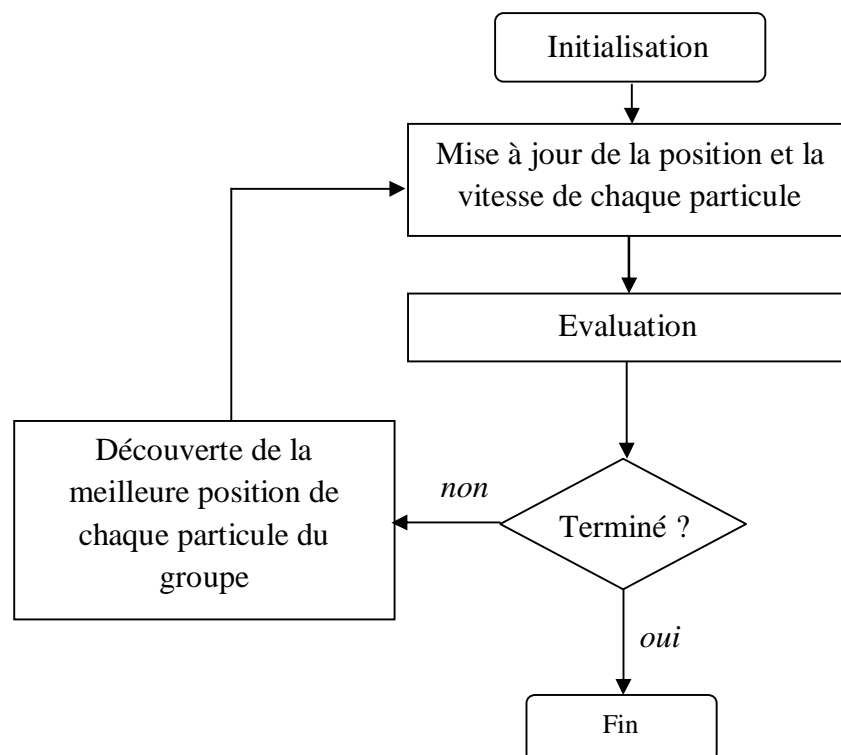


Figure III.5 : Organigramme de la méthode des essaims particulaires

III.2.2.3. Les méthodes d'optimisation hybride

L'utilisation des méthodes hybrides permet de combiner les avantages des deux types de méthodes (déterministes et non déterministes), elles peuvent être vues comme la solution parfaite vis-à-vis des désavantages et des méthodes locales et des méthodes globales. Quand

l'hybridation est basée sur une vraie maîtrise de l'idée derrière chacune des méthodes candidates, l'augmentation de la précision ainsi que la diminution du temps de calcul sont assurées. Dans cet esprit, plusieurs types d'hybridation sont possibles

Stratégie 1- On pourra par exemple s'approcher de l'optimum global par une méthode aléatoire puis affiner le résultat en appliquant successivement une méthode locale. Il est clair que le résultat sera meilleur mais au détriment du temps de calcul.

Stratégie 2- On pourra aussi essayer de trouver un état de minimum local et de n'y rester que s'il est le meilleur de minimums locaux (global). Cette stratégie a été utilisée dans trois méthodes d'optimisation globales suivantes :

La méthode des initialisations multiples ou (multi-start). On utilise plusieurs fois une technique d'optimisation locale en différents points de C ; on prend le meilleur résultat ; il serait solution de PO .

La méthode du tunnelier (tunneling method). On cherche par une technique locale un minimum local x_l ; on utilise une technique (du Tunnelier) pour éliminer tous les points qui ont une valeur supérieure à celle de x_l (en effet ils ne pourraient être optimums globaux). Puis on ré-optimise pour trouver un x_{l+1} et ... ainsi de suite. La suite des x_k ainsi construite converge vers le minimum global. Voir la figure ci dessous :

La méthode des montagnes russes (Steepest Ascent Descent : SAD.)

D'abord, on cherche un minimum local, puis on cherche cette fois-ci un maximum local ; cela permet d'échapper de l'état de minimum local. Puis on refait une minimisation suivie d'une autre maximisation et... ainsi de suite. Le plus petit minimum trouvé à la fin, est candidat pour être le minimum global.

III.2.3. Optimisation continue avec contraintes

Toutes les méthodes décrites dans la section précédente s'appliquent à des problèmes d'optimisation sans contraintes. Or, en réalité il est quasiment impossible de trouver ce genre de problème, il est habituel de poser des contraintes sur les variables de conception ou encore des contraintes imposées par le cahier des charges.

Un problème d'optimisation est dit problème contraint s'il contient au moins une fonction contrainte $g_i(x)$ ou $h_j(x)$ dans sa description, comme dans le cas du problème de l'équation (III.1).

Si nous considérons qu'une contrainte d'égalité $h_j(x) = 0$ peut être décrite par deux contraintes d'inégalité $h_j(x) \leq 0$ et $-h_j(x) \leq 0$, le problème (III.1) devient alors égal à celui donné par l'équation (III.9).

$$(P) \begin{cases} \text{Min } f(x) \in \mathfrak{R}^n \\ g_i(x) \leq 0 \quad i = 1, \dots, m = p + 2q \end{cases} \quad (\text{III.9})$$

On appelle fonction de Lagrange associée au problème (III.9), la fonction:

$$L(x, \lambda) = f(x) + \sum_{i=1}^m \lambda_i g_i(x), \quad (\text{III.10})$$

Où

$\lambda_i \geq 0$ sont appelés Multiplicateurs de Lagrange.

Une condition nécessaire pour que x^* soit minimum local d'un problème contraint est donnée par les équations de Kuhn-Tucker [17]:

$$\begin{cases} \nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla g_i(x^*) = 0 \\ \lambda_i^* g_i(x^*) = 0 \quad \forall i = 1, \dots, m \end{cases} \quad (\text{III.11})$$

Qui à l'aide de l'équation (III.10) s'écrit:

$$\begin{cases} \nabla_x L(x^*, \lambda^*) = 0 \\ \lambda_i^* g_i(x^*) = 0 \quad \forall i = 1, \dots, m \end{cases} \quad (\text{III.12})$$

La solution d'un problème contraint peut être obtenue à partir de l'application de méthodes que nous classifions en deux grands groupes: les méthodes par transformation et les méthodes directes.

III.2.3.1. Méthodes d'optimisation par transformation

Les méthodes d'optimisation par transformation consistent à introduire les contraintes de conception dans la fonction que l'on cherche à optimiser. Ainsi, le problème avec les contraintes de type inégalité peut être transformé en un problème équivalent sans contraintes.

Parmi les méthodes de transformation les plus utilisées, nous avons les méthodes de pénalités [18] [19], la méthode du lagrangien augmenté [20] [21], la méthode des variables mixtes [22] et la méthode des asymptotes mobiles [23].

III.2.3.2. Méthodes de pénalités intérieures et extérieures

L'idée de ces méthodes est de remplacer la résolution du problème avec contraintes (III.9) par une suite de résolutions de problèmes sans contraintes, en introduisant dans la fonction objectif une pénalisation concernant chacune des fonctions contraintes violées, comme nous le montre l'équation (III.13).

$$(P_k)\{Min \Phi(x, r) = f(x) + r_k \sum_{i=1}^m W(g_i(x)) \quad (III.13)$$

Où

$r_k > 0$ est un coefficient de pénalité actualisé à chaque itération du processus d'optimisation

W est une fonction de pénalisation définie en $\Re \rightarrow \Re$ telle que:

$$W(y) = 0 \text{ si } y \geq 0$$

$$W(y) = +\infty \text{ si } y < 0 \quad (III.14)$$

Selon la nature de la fonction de pénalité W utilisée, les méthodes de pénalités peuvent être divisées en deux classes: les méthodes de pénalités intérieures et les méthodes de pénalités extérieures.

III.2.3.3. Méthodes de Pénalités Intérieures

Les méthodes de pénalités intérieures [18] sont aussi appelées méthodes à barrière, car la fonction de pénalité forme une barrière infinie tout au long de la frontière du domaine réalisable Ψ . Les fonctions de pénalités les plus utilisées par ces méthodes sont la fonction inverse (III.15) et la fonction logarithmique (III.16).

$$W(g_i(x)) = -\frac{1}{g_i(x)} \quad (III.15)$$

$$W(g_i(x)) = -\log(-g_i(x)) \quad (III.16)$$

En utilisant ces fonctions, lorsque x appartient à Ψ , $W(x) > 0$ et lorsque x tend vers sa frontière, $W(x) \rightarrow +\infty$. Par conséquent, nous ne pouvons jamais franchir la frontière de Ψ , et les

solutions engendrées par l'algorithme seront donc admissibles pendant tout le processus d'optimisation. Cependant, ces méthodes présentent l'inconvénient d'avoir besoin d'un point initial qui soit à l'intérieur du domaine réalisable, ce qui n'est pas toujours facile à obtenir.

III.2.3.4. Méthodes de Pénalités Extérieures

Les Méthodes de pénalités extérieures [19] ne présentent pas le même inconvénient que les méthodes de pénalités intérieures, car l'approximation de la solution est faite par l'extérieur du domaine réalisable Ψ , ce qui nous permet d'avoir un point initial dans cette région de l'espace. La fonction de pénalité utilisée par ces méthodes est donnée par (III.17). Cette fonction nous donne une augmentation de la pénalisation à mesure que nous nous éloignons de Ψ .

$$W(g_i(x)) = \max[0, g_i(x)]^2 \quad (\text{III.17})$$

Contrairement aux méthodes de pénalités intérieures, les solutions engendrées par ces méthodes ne sont pas toujours admissibles pendant tout le processus d'optimisation. Cela peut représenter un inconvénient, surtout lorsque l'algorithme ne converge pas et nous nous retrouvons alors avec une solution irréalisable.

III.3. Optimisation multiobjectif

Les problèmes d'optimisation [24] issus de problématiques réelles sont la plupart du temps de nature multiobjectif, car plusieurs critères sont à considérer simultanément.

L'optimisation multiobjectif est un domaine fondamental de l'aide à la décision multicritère, nécessaire aux nombreux milieux scientifiques et industriels. La résolution d'un problème d'optimisation multiobjectif consiste à déterminer la solution correspondant au mieux aux préférences du décideur parmi les solutions de bon compromis. L'une des questions les plus difficiles est donc liée à l'identification de l'ensemble Pareto optimal, ou d'une approximation de celui-ci pour des problèmes complexes.

Un problème multiobjectif ou multicritère peut être défini comme un problème où l'on cherche à optimiser plusieurs composantes des vecteurs de la fonction objectif, tout en satisfaisant un ensemble de contraintes.

Contrairement à un problème mono-objectif, la solution n'est pas unique mais constituée d'un ensemble de solutions dites de Pareto optimales. La formulation mathématique d'un problème d'optimisation multiobjectif est donnée comme suit :

III.3.1. Formulation d'un problème multiobjectif

Comme le suggère le nom, un problème d'optimisation multiobjectif consiste à optimiser plusieurs fonctions objectifs simultanément qui sont, en général, contradictoires ou conflictuels. Dans tout ce qui suit, nous considérons que toutes les fonctions objectifs sont à "minimiser". Un problème d'optimisation multiobjectif (MOP) peut alors être posé sous la forme générale suivante :

$$(MOP) \begin{cases} \text{minimiser } f(x) = (f_1(x), f_2(x), \dots, f_k(x)) \\ \text{s.c. } x \in E \end{cases} \quad (\text{III.18})$$

Où $k \geq 2$ et

- $x = (x_1, x_2, \dots, x_n)$ représente l'action (ou le vecteur de décision) avec x_i les variables du problème et n le nombre de ces variables ;

- $f(x) = (f_1(x), f_2(x), \dots, f_k(x))$ est le vecteur de k fonctions objectifs f_i (ou critères de décision) et k le nombre d'objectifs ;

- E est l'ensemble non vide des solutions réalisables, c'est-à-dire celles qui respectent les contraintes du problème.

- L'ensemble \mathfrak{R}^n qui contient E est dit espace de décision ;

- L'ensemble \mathfrak{R}^k qui contient F est dit espace des critères ou espace des objectifs ;

- L'ensemble $F = f(E)$ est la projection de l'espace E sur l'espace des objectifs ;

III.3.2. Dominance et optimalité de Pareto

La difficulté principale lorsque l'on cherche à minimiser simultanément plusieurs critères est qu'il n'existe généralement pas de solution qui minimise tous les critères en même temps. On sait alors que de telles solutions ne peuvent pas intéresser le décideur puisque l'on peut en obtenir qui réalisent de meilleures performances sur tous les critères. La dominance de Pareto a donc été introduite avec l'idée de distinguer les solutions potentiellement intéressantes des autres en suivant le principe suivant : une solution potentiellement intéressante est une

solution telle qu'on ne peut pas améliorer la performance sur un critère sans dégrader la performance sur au moins un autre critère. Ces solutions sont appelées solutions de compromis.

Lorsque nous résolvons notre problème d'optimisation multiobjectif, nous obtenons une multitude de solutions. Seul un nombre restreint de ces solutions va nous intéresser. Pour qu'une solution soit intéressante, il faut qu'il existe une relation de dominance entre la solution considérée et les autres solutions, dans le sens suivant [25] :

Définition 1. : La relation de dominance

On dit que le vecteur $x = (x_1, x_2, \dots, x_k)$ domine le vecteur $y = (y_1, y_2, \dots, y_k)$ si :

- x est au moins aussi bon que y sur tous les objectifs et,
- x est strictement meilleur que y sur au moins un objectif.

D'une manière équivalente, nous avons :

Définition 2. : La solution x du problème (III.18) est dite dominer une autre solution y , si les conditions suivantes sont vérifiées :

$$f_i(x) \leq f_i(y) \quad \forall i \in \{1, \dots, k\} \text{ et } \exists i \in \{1, \dots, k\} \text{ tel que } f_i(x) < f_i(y).$$

Si la solution x domine la solution y , nous allons écrire $x < y$.

III.3.3. Optimalité de Pareto

Définition 1. : Une solution $\bar{x} \in E$ est dite solution efficace (ou Pareto optimale) si et seulement s'il n'existe pas de solution $x \in E$ telle que $f_i(x) \leq f_i(\bar{x})$, $\forall i \in \{1, \dots, k\}$ et $\exists j \in \{1, \dots, k\} / f_j(x) < f_j(\bar{x})$.

Définition 2. : Une solution $x \in E$ est faiblement efficace si et seulement s'il n'existe pas de solution $x \in E$ telle que $f_i(x) < f_i(\bar{x})$, $\forall i \in \{1, \dots, k\}$.

Il est clair qu'une solution efficace est faiblement efficace, mais l'inverse est faux.

On définit comme suit l'optimalité locale et l'optimalité globale au sens de Pareto.

Définition 3. : Optimalité locale au sens de Pareto

Un vecteur $x \in E$ est optimal localement au sens de Pareto s'il existe un réel $\delta > 0$ tel qu'il n'y ait pas de vecteur x' qui domine le vecteur x avec $x' \in E \cap B(x, \delta)$, où $B(x, \delta)$ représente une boule de centre x et de rayon δ .

D'une manière équivalente un vecteur x est optimal localement au sens de Pareto s'il est optimal au sens de Pareto sur une restriction de l'ensemble E . Cette définition est illustrée par la figure III.6.

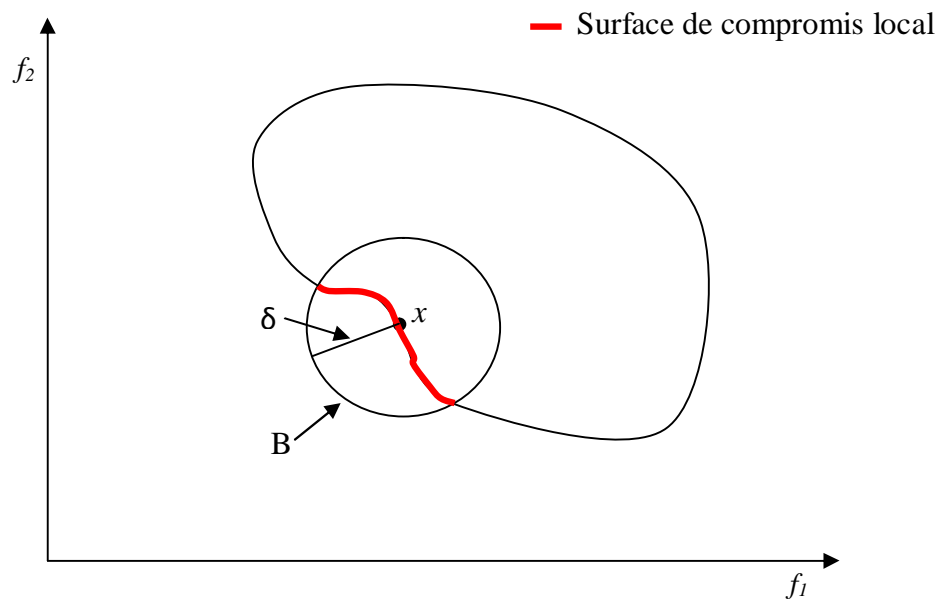


Fig. III.6 – L'optimalité locale au sens de Pareto [26]

Définition 4. : Optimalité globale au sens de Pareto

Un vecteur x est optimal globalement au sens de Pareto (ou optimal au sens de Pareto) s'il n'existe pas de vecteur x' tel que x' domine le vecteur x .

Souvent dans l'espace E , l'ensemble de Pareto global est évoqué simplement comme l'ensemble de Pareto. Cet ensemble est constitué par les solutions non dominées ou solutions efficaces ou solutions Pareto optimales du problème d'optimisation (III.18). L'image de l'ensemble Pareto optimal dans l'espace F est appelée frontière Pareto ou surface de Pareto. Selon que les fonctions objectifs doivent être minimisées ou maximisées, la frontière Pareto a une forme particulière.

III.4. Conclusion

Dans ce chapitre, nous avons présenté les problèmes d'optimisation mono-objectif et multiobjectif. Un ensemble de méthodes de résolution de ces problèmes a été présenté, notamment les métaheuristiques. Ces méthodes sont inspirées d'analogies avec des domaines aussi variés que la physique, la génétique et l'éthologie. Grâce à leur simplicité d'emploi et leur forte modularité Les métaheuristiques ont donné des solutions à des variétés et surtout grâce à leur capacité d'adaptation et la grande possibilité d'hybridation qui a mené à de meilleures performances pour la résolution des problèmes extrêmement difficiles.

REFERENCES

1. M. C. COSTA, « Optimisation de dispositifs électromagnétiques dans un contexte d'analyse par la méthode des éléments finis », thèse de doctorat, Institut National Polytechnique De Grenoble, 2001.
2. B. Sareni, "Méthodes d'Optimisation Multimodales Associées à la Modélisation Numérique en Electromagnétisme", Thèse de Doctorat, École Centrale de Lyon, 1999.
3. H. Hachimi, "Hybridations d'algorithmes métaheuristiques en optimisation globale et leurs application", thèse de doctorat, Institut National des Sciences Appliquées de Rouen, 2013.
4. N. Metropolis, A. Rosenbluth, M. Rosenbluth, A. Teller, E. Teller, "Equation of state calculations by fast computing machines", Journal of Chemical Physics, vol. 21, pp. 1087-1092, 1953.
5. F. Glover, "Tabu Search - Part I", ORSA Journal on Computing, vol. 1, n. 3, pp. 190-206, 1989.
6. F. Glover, "Tabu Search - Part II", ORSA Journal on Computing, vol. 2, n. 1, pp. 4-32, 1990.
7. N. Hu, "Tabu Search Method with random moves for globally optimal design", International Journal for Numerical Methods in Engineering, vol. 35, n. 5, pp. 1055-1070, 1992.
8. M. Dorigo. Optimization, learning and natural algorithms. Ph.D. Thesis, Politecnico di Milano, Italy, 1992.
9. M. Dorigo, V. Maniezzo, and A. Colorni. Ant system : optimization by a colony of cooperating agents. IEEE Trans. on Man. Cyber. Part B, 26 :29-41, 1996.

10. M. Dorigo, C. Blum. Ant colony optimization theory : A survey. *Theoretical Computer Sc*, 344 :243–278, 2005.
11. M. D. Toksari. Ant colony optimization for finding the global minimum. *Applied Mathematics and Computation*, 176 :308–316, 2006.
12. P. S. Shelokar, P. Siarry, V.K. Jayaraman, and B.D. Kulkarni. Particle swarm and ant colony algorithms hybridized for improved continuous optimization. *Applied Mathematics and Computation*, 188 :129–142, 2007.
13. K. Deep, M. Thakur. A new mutation operator for real coded genetic algorithms. *Applied Mathematics and Computation*, 193 :211–230, 2007.
14. A. Georgieva and I. Jordanov. Global optimization based on novel heuristics, low-discrepancy sequences and genetic algorithms. *European Journal of Operational Research*, 196 :413–422, 2009.
15. I. G. Tsoulos. Modifications of real code genetic algorithm for global optimization. *Applied Mathematics and Computation*, 203 :598–607, 2008.
16. Q. Yuan, Z. He, and H. Leng. A hybrid genetic algorithm for a class of global optimization problems with box constraints. *Applied Mathematics and Computation*, 197 :924–929, 2008.
17. R. R. Saldanha, “Optimisation en Electromagnétisme par application conjointe des Méthodes de Programmation Non Linéaire et de la Méthode des Éléments Finis”, Thèse de Doctorat, Institut National Polytechnique de Grenoble, 1992.
18. C. W. Carroll, “The Created Response Surface Technique for Optimizing Nonlinear Restrained Systems”, *Operational Research*, n. 9, pp. 169-184, 1961.
19. A. V. Fiacco, G. P McCormick, “Nonlinear Programming Sequential Unconstrained Minimization Techniques”, John Wiley, New York, 1968.
20. M. R. Hestenes, “Multiplier and Gradient Methods”, *Journal of Optimization Theory and Applications*, n. 4, pp. 303-320, 1969.
21. R. T. Rockaffelar, “A Dual Approach to Solving Nonlinear Programming Problems by Unconstrained Optimization”, *Mathematical Programming*, vol. 12, n. 6, pp. 555-562, 1973.
22. C. Fleury, “Structural Optimization: A New Dual Method Using Mixed Variables”, *International Journal on Numerical Methods in Engineering*, vol. 23, pp. 409-428, 1986.

23. K. Svanberg, "The Method of Moving Asymptotes. A New Method for Structural Optimization", International Journal on Numerical Methods in Engineering, vol. 24, pp. 359-373, 1987.
24. Dhaenens-Flipo C. Optimisation Combinatoire Multi-Objectif : Apport des Méthodes Coopératives et Contribution à l'Extraction de Connaissances, thèse d'Habilitation à diriger des Recherches de l'U.S.T.L, Lille, 2005.
25. Collette Y. et Siarry P. Optimisation multiobjectif, Editions Eyrolles, 2002.
26. O. ZERDANI, "L'Optimisation non Linéaire Multiobjectif », thèse de doctorat, Université Mouloud Mammeri, Tizi-Ouzou, 2013.

Chapitre IV

LES MÉTHODES UTILISÉES POUR
L'OPTIMISATION

IV.1. Introduction

Les métaheuristiques s'efforcent de résoudre tout type de problème d'optimisation. Elles sont caractérisées par leur caractère stochastique, ainsi que par leur origine discrète. Elles sont inspirées par des analogies avec la physique (recuit simulé, recuit micro canonique), avec la biologie (algorithmes évolutionnaires) ou encore l'éthologie (colonies de fourmis, essaims particulaires). Cependant, elles ont l'inconvénient d'avoir plusieurs paramètres à régler. Il est à souligner que les métaheuristiques se prêtent à toutes sortes d'extensions, notamment en optimisation mono-objectif et multiobjectif. De nos jours les gestionnaires et les décideurs sont confrontés quotidiennement à des problèmes de complexité grandissante, qui surgissent dans des secteurs très divers. Le problème à résoudre peut souvent s'exprimer sous la forme générale d'un problème d'optimisation, dans lequel on définit une ou plusieurs fonctions objectifs que l'on cherche à minimiser ou à maximiser par rapport à tous les paramètres concernés. La résolution d'un tel problème a conduit les chercheurs à proposer des méthodes de plus en plus performantes, parmi lesquelles on trouve les métaheuristiques qui sont des méthodes générales de recherches dédiées aux problèmes d'optimisation difficile. Dans ce chapitre, nous présentons en premier lieu, d'une manière détaillée, les métaheuristiques que nous avons étudiées dans le cadre de cette thèse. Ce sont les algorithmes génétiques, l'algorithme de la programmation quadratique séquentielle (SQP), la méthode de l'optimisation par essaim particulaire, l'algorithme Firefly, l'algorithme artificiel de colonies des abeilles (ABC), et l'algorithme de singe (MA). En second lieu, nous présentons la technique de l'hybridation entre les méthodes étudiées.

IV.2. Algorithmes génétiques (GA)

IV.2.1. Représentation

Il se trouve qu'il n'y a pas de définition rigoureuse des "algorithmes génétiques", acceptée par tous, dans la communauté des calculs évolutifs, qui différencie l'algorithme génétique (GA) des autres méthodes de calcul évolutif [1]. Cependant, on peut dire que la plupart des méthodes appelées «GA» ont au moins les éléments suivants en commun: Les populations de chromosomes, sélection selon le fitness et le croisement aléatoire pour produire de nouveaux descendants.

Les chromosomes dans une population GA prennent généralement la forme de chaînes de bits. Chaque lieu dans le chromosome possède deux allèles possibles: 0 et 1, chaque chromosome

peut être considéré comme un point dans l'espace de recherche de solutions candidats. Le GA traite les populations de chromosomes en remplaçant successivement une population par une autre. Le GA nécessite le plus souvent une fonction de fitness (remise en forme) qui attribue une note pour chaque chromosome dans la population actuelle. L'aptitude d'un chromosome dépend de la façon dont ce chromosome résout le problème [2].

IV.2.2 Opérateurs GA

La forme la plus simple de l'algorithme génétique implique trois types d'opérateurs: sélection, croisement (un point), et mutation [3].

1) Sélection

Cet opérateur sélectionne les chromosomes dans la population pour la reproduction. Le chromosome qui a la meilleure forme, est le plus susceptible d'être sélectionné à reproduire.

2) Croisement

Cet opérateur choisit au hasard un lieu dans une chaîne d'un chromosome et échange les séquences avant et après ce lieu avec un autre chromosome pour créer deux descendants. Par exemple, les chaînes 10000100 et 11111111 pourraient être croisées après le troisième lieu dans chaque chaîne pour produire les deux descendants qui auront les recombinaisons 10011111 et 11100100. L'opérateur de croisement imite pleinement la recombinaison biologique entre deux mono chromosomes d'un organisme (haploïdes).

3) Mutation

Cet opérateur permute, entre le 1 et le zéro, au hasard certains des bits dans un chromosome. Par exemple, la chaîne 00000100 pourrait être mutée dans sa seconde position pour obtenir 01000100. La mutation peut se faire à chaque position de bit dans une chaîne avec une certaine probabilité, généralement très faible (par exemple, 0,001).

IV.2.3 Algorithme Génétique codé en binaire (BCGA)

Face à un problème clairement défini à résoudre et une représentation de chaîne de bits pour des solutions candidats, un simple BCGA fonctionne comme suit:

1. On commence avec une population générée aléatoirement de n chromosomes à l bits (solutions candidats à un problème).
2. Calculer la fonction de fitness $f(x)$ de chaque chromosome x dans la population.
3. Répétez les étapes suivantes jusqu'à ce que n descendants soient créés:
 - Sélectionnez une paire de chromosomes parents de la population actuelle, la probabilité de sélection étant une fonction croissante de fitness. La sélection se fait «avec remplacement», ce qui signifie que le même chromosome peut être sélectionné plus d'une fois pour devenir parent.
Avec une probabilité p_c (la «probabilité de croisement» ou «taux de croisement»), on croise la paire à un point choisi au hasard (choisi avec une probabilité uniforme) pour former deux descendants. Si aucun croisement n'a eu lieu, on forme deux descendants qui sont des copies exactes de leurs parents respectifs. (Notez qu'ici le taux de croisement est défini comme étant la probabilité que les deux parents se croisent en un seul point. Il existe également des versions "multipoint de croisement» de la BCGA dans laquelle le taux de croisement pour une paire des parents est le nombre de points où un croisement a eu lieu.)
 - Muter les deux descendants à chaque lieu avec une probabilité p_m (la probabilité de mutation ou de taux de mutation), et placer les chromosomes résultants dans la nouvelle population. Si n est impair, un nouveau membre de la population peut être jeté au hasard [4].
4. Remplacez la population actuelle avec la nouvelle population.
5. Passez à l'étape 2. Chaque itération de ce processus est appelée une génération.

Les BCGA sont généralement réitérés de 50 à 500 générations ou plus. L'ensemble des générations est appelé une exécution. À la fin d'une exécution, il y a souvent un ou plusieurs chromosomes hautement adaptés dans la population. Puisque le hasard joue un rôle important dans chaque série, deux exécutions de nombres aléatoires et avec des semences différentes produisent généralement des comportements différents. Les chercheurs dans les BCGA signalent souvent des statistiques différentes (comme la meilleure forme physique trouvée dans une course et la génération à laquelle l'individu avec cette meilleure forme physique a

été découvert) en moyenne sur de nombreuses séries de la BCGA sur le même problème (Figure IV.1).

La procédure simple que nous venons de décrire est la base de la plupart des applications de BCGAs. Il ya un certain nombre de détails à combler, comme la taille de la population et les probabilités de croisement et de mutation, le succès de l'algorithme dépend souvent et grandement sur ces détails [5]. Il existe également des versions plus complexes de BCGA (par exemple, les BCGA qui travaillent sur des représentations autres que les chaînes ou les BCGA qui ont différents types d'opérateurs de croisement et de mutation).

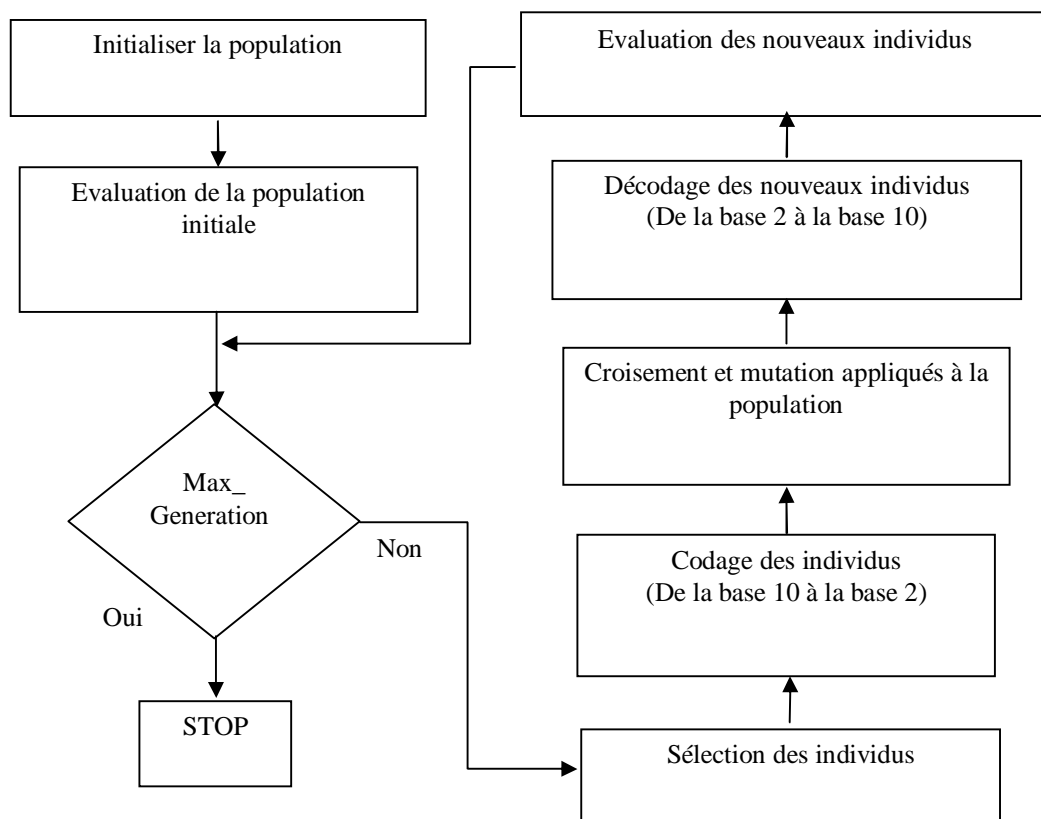


Figure IV.1 Application de l'AG

Pour faciliter la mise en œuvre et l'application de l'algorithme génétique, nous pouvons transformer le problème avec contraintes à un problème sans contraintes; cette transformation est effectuée en ajoutant des pénalités à la fonction objectif.

La fonction de pénalité est choisie pour que la faisabilité soit garantie dans tous les processus de recherche de l'optimum. Cette fonctionnalité est très importante pour éviter la convergence prématurée de l'algorithme génétique [6].

IV.3. Méthode d'optimisation par essais particulières

PSO est une technique évolutive prometteuse qui a quelques avantages sur les autres techniques d'optimisation similaires, PSO est plus facile à mettre en œuvre et il y a moins de paramètres à régler, et son algorithme nécessite moins de temps de calcul et moins de mémoire. En outre, la PSO est souple et donc, peut facilement être manipulée avec les fonctions objectifs. Mais elle a aussi quelques défauts, tels que la convergence prématurée. Pour surmonter ce problème, la PSO est associée [7] à un autre algorithme qui est proche, à savoir l'algorithme génétique [8].

La PSO a été initialement développée par Eberhart et Kennedy en 1995 [9] [10] en utilisant un algorithme stochastique basé sur la population. De même que pour les algorithmes génétiques [11], et l'approche des algorithmes évolutionnaires, l'OSP est un outil d'optimisation évolutionnaire dans le champ de l'intelligence en essaim. Fondée sur un essaim (population), où chaque membre est considéré comme une particule, et chaque particule est une solution potentielle au problème en cours d'analyse. Chaque particule dans la PSO a une vitesse aléatoire qui lui est associée, qui se déplace à travers l'espace du problème. Cependant, à la différence des algorithmes génétiques, la PSO n'a pas les opérateurs, tels que croisement et mutation. La PSO ne met pas en œuvre la survie des individus les plus forts; plutôt, il met en œuvre la simulation du comportement social [12]. Cependant, elle permet à chaque particule de maintenir une mémoire de la meilleure solution qu'elle a trouvée. Le modèle mathématique pour la PSO est le suivant :

$$V_i^{t+1} = w \times V_i^t + c_1 \times rand_1 \times (Pbest_i - X_i^t) + c_2 \times rand_2 \times (gbest_i - X_i^t) \quad (IV.1)$$

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (IV.2)$$

V_i^t : La vitesse de la $i^{ème}$ particule dans l'essaim à l'itération t

X_i^t : La position de la $i^{ème}$ particule dans l'essaim à l'itération t

P_{best_i} : Appelé le leader local ou la meilleure position personnelle, qui représente la meilleure position trouvée par la $i^{ème}$ particule elle-même jusqu'ici;

g_{best} : Appelé le leader global ou la meilleure position globale, qui représente la meilleure position globale trouvée par les voisins de cette particule jusqu'ici;

i : nombre de particules

w : facteur de poids initial

c_1, c_2 : constantes d'accélération

$rand_1, rand_2$: La valeur aléatoire uniforme dans l'intervalle [0,1].

L'utilisation de la diminution linéaire de l'inertie du facteur poids w a fourni de meilleures performances dans toutes les applications. Sa valeur est diminuée de façon linéaire d'environ 0,9 à 0,4 dans une course. Le choix approprié de la masse d'inertie assure un équilibre entre l'exploration et l'exploitation globale et locale, et résulte en moins d'itérations en moyenne pour trouver une solution suffisamment optimale. Sa valeur est définie selon l'équation suivante:

$$w = w_{\max} - \frac{w_{\max} - w_{\min}}{iter_{\max}} \times iter \quad (IV.3)$$

Où, w_{\max} , w_{\min} : sont deux nombres aléatoires appelés poids initial et poids final respectivement

$iter_{\max}$: Le nombre d'itération maximale

$iter$: Le numéro de l'itération courante

La procédure de la technique d'optimisation par essaim de particules peut être résumée dans la Figure IV.2.

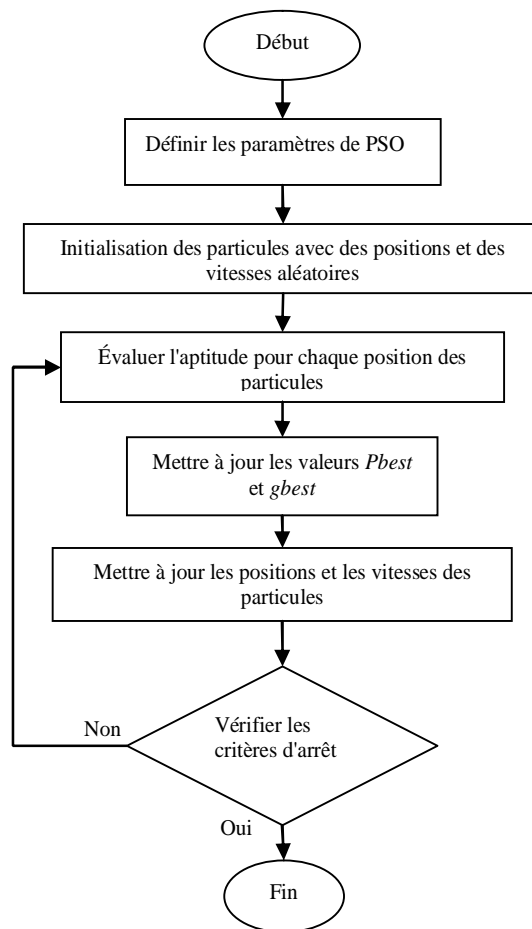


Figure IV.2 L'organigramme de l'optimisation par essaim de particules

IV.4. L'algorithme de la programmation quadratique séquentielle (SQP)

Dans la programmation, les méthodes quadratiques séquentielles (SQP) sont des méthodes itératives qui résolvent à chaque itération un problème de programmation quadratique (QP). La programmation quadratique séquentielle (SQP) gère efficacement les contraintes non linéaires avec de multiples points ou les fonctions sans formes analytiques.

La méthode ressemble étroitement à la méthode de Newton pour l'optimisation avec contraintes sauf qu'on le fait pour l'optimisation sans contrainte. A chaque itération, une approximation est faite du Hessien de la fonction de Lagrange en utilisant un BFGS un procédé quasi-Newton de mise à jour [13]. Il est ensuite utilisé pour générer un sous-problème

de programmation quadratique (QP), dont la solution est utilisée pour diriger la recherche pour une procédure de recherche de ligne.

L'algorithme de SQP fonctionne en résolvant une séquence de programmation quadratique (QP), il part d'un point de recherche unique et trouve une solution en utilisant les informations du gradient. Par conséquent, toutes les fonctions, y compris la fonction objectif et les contraintes, doivent être continûment dérivables [14]. Considérons un problème de programmation non linéaire de la forme.

$$\text{Min } f(x) \quad (\text{IV.4})$$

Avec

$$g(x) \leq 0 \quad (\text{IV.5})$$

$$h(x) = 0 \quad (\text{IV.6})$$

Le lagrangien pour ce problème est:

$$L(x, \lambda, \sigma) = f(x) - \lambda^T h(x) - \sigma^T g(x) \quad (\text{IV.7})$$

Où λ et σ sont des multiplicateurs de Lagrange. Lors d'une itération x_k , un algorithme de base de programmation quadratique séquentiel définit une direction de recherche approprié d comme une solution au sous-problème de programmation quadratique.

$$\begin{aligned} \min \quad & f(x_k) + \nabla f(x_k)^T d + \frac{1}{2} d^T \nabla_{xx}^2 L(x_k, \lambda_k, \sigma_k) d \\ \text{st} \quad & \begin{cases} h(x_k) + \nabla h(x_k)^T d \geq 0 \\ g(x_k) + \nabla g(x_k)^T d \geq 0 \end{cases} \end{aligned} \quad (\text{IV.8})$$

Notez que le terme $\min f(x_k)$ dans l'expression ci-dessus peut-être omis pour le problème de minimisation, car il est constant. SQP se compose de trois phases principales, à savoir:

- 1) Calcul d'une approximation de la matrice Hessienne de la fonction de Lagrange en utilisant une méthode quasi-Newton.
- 2) Déterminer la solution du problème QP.
- 3) Calcul de la ligne de recherche et la fonction de mérite.

Les détails de l'algorithme peuvent être trouvés dans Powell [15] [16].

La programmation quadratique séquentielle (SQP) surpasse les autres méthodes de programmation non linéaires en matière d'efficacité et de précision. Pour notre travail, il est utilisé comme un optimiseur local de la meilleure région explorée par GA-PSO.

IV.5. L'algorithme Firefly

Les fireflies (les bogues luminescentes) utilisent leur bioluminescence pour attirer les compagnons ou la proie. Ils vivent dans des endroits humides sous les débris sur le sol, ou sous l'écorce et la végétation en décomposition.

L'algorithme firefly (FFA) a été développé par Xin Yang-She à l'Université de Cambridge en 2007. Il utilise les trois règles idéalisées suivantes:

- 1) Chaque luciole attire toutes les autres lucioles avec un faible flash [17]. Toutes les lucioles sont unisexes de sorte qu'une luciole sera attirée vers d'autres lucioles indépendamment de leurs sexes.
- 2) L'attractivité est proportionnelle à leur luminosité; ainsi pour toutes deux lucioles clignotantes la moins lumineuse se déplacera vers la plus lumineuse. L'attrait est proportionnel à la luminosité et ils diminuent tout les deux plus leur distance augmente. S'il n'y a pas une luciole plus brillante qu'une autre, elles se déplacent de manière aléatoire.
- 3) La luminosité d'une luciole est affectée ou déterminée par le paysage de la fonction objectif.

Pour un problème de maximisation la luminosité peut être simplement proportionnelle à la valeur de la fonction objectif. Autres formes de luminosité peuvent être définies d'une manière similaire pour la fonction fitness dans les algorithmes génétiques en fonction de ces trois règles.

IV.5.1. Attractivité

Dans l'algorithme FFA, il y a deux enjeux importants: la variation de l'intensité lumineuse et la formulation de l'attractivité. Pour plus de simplicité, nous pouvons toujours supposer que l'attrait d'une luciole est déterminé par sa luminosité qui à son tour est associé à la fonction objectif codée [18].

Dans le cas le plus simple pour des problèmes d'optimisation de maximisation, la luminosité I d'une luciole à un endroit x particulier peut être choisie comme $I(x)$ correspondant à $f(x)$. Cependant, l'attractivité β est relative; elle doit être vue des yeux du spectateur ou jugée par les autres lucioles [19]. Ainsi, elle varie en fonction de la distance r_{ij} entre la luciole i et la luciole j . En outre, l'intensité lumineuse diminue avec la distance de sa source et de la lumière et est également absorbée dans l'immédiat alors nous devrions permettre à l'attractivité de varier avec le degré d'absorption. Dans la forme la plus simple, l'intensité lumineuse $I(r)$ varie en fonction de la loi en carré inverse.

$$I(r) = I_s / r^2$$

Où I_s est l'intensité à la source.

Pour un milieu donné avec un coefficient d'absorption lumineuse fixe, l'intensité lumineuse I varie avec la distance r [20].

Autrement dit, I_0 est l'intensité de lumière d'origine. Afin d'éviter la singularité au point $r=0$ dans l'expression $I(r) = I_s / r^2$ l'effet combiné de la loi en carrée inverse et l'absorption peuvent être approchés en utilisant le formulaire gaussien ci-dessous:

$$I(r) = I_0 e^{-\gamma r^2} \tag{IV.9}$$

Parfois, il se peut que l'on ait besoin d'une fonction qui diminue de façon monotone à un rythme lent. Dans ce cas, nous pouvons utiliser l'approximation suivante:

$$I(r) = \frac{1}{1 + \epsilon r^2} I_0 e^{-\gamma r^2} \tag{IV.10}$$

Pour une distance plus courte, les deux formes ci-dessus sont essentiellement les mêmes. Ceci est parce que les développements en série dans les environs de $r=0$ ont la forme:

$$e^{-\gamma r^2} \approx 1 - \gamma r^2 + \dots, \frac{1}{1 + \epsilon r^2} \approx 1 - \epsilon r^2 \tag{IV.11}$$

Et sont équivalentes l'une à l'autre jusqu'à l'ordre de 0 (r^3).

Puisque l'attractivité d'une luciole est proportionnelle à l'intensité lumineuse vue par les lucioles adjacentes, nous pouvons maintenant définir l'attractivité β d'une luciole par:

$$\beta(r) = \beta_0 e^{-\gamma r^2} \quad (\text{IV.12})$$

Où β_0 est l'attractivité pour $r=0$. Comme il est souvent plus rapide de calculer $1/(1+r^2)$ que d'une fonction exponentielle, l'expression ci-dessus, si nécessaire, peut avantageusement être

remplacée par : $\beta = \frac{\beta_0}{1+er^2}$.

L'équation (IV.40) définit une distance caractéristique $\Gamma = \frac{1}{\sqrt{\gamma}}$ sur laquelle l'attractivité

change de manière significative à partir de β_0 à $\beta_0 e^{-1}$.

Dans l'application, la forme réelle de la fonction de l'attractivité $\beta(r)$ peut être une fonction monotone décroissante telle que la forme générale suivante:

$$\beta(r) = \beta_0 e^{-\gamma r^m} \quad (\text{IV.13})$$

avec $m \geq 1$

Pour une γ fixe, la longueur caractéristique devient aussi : $\Gamma = \gamma^{-1/m} \rightarrow 1$ quand $m \rightarrow \infty$.

Inversement, pour une longueur de l'échelle Γ donnée pour un problème d'optimisation, le

paramètre γ peut être utilisé en tant que valeur initiale typique. C'est : $\gamma = \frac{1}{\Gamma^m}$

IV.5.2. Distance et Mouvement

La distance entre deux lucioles i et j à x_i et x_j est la distance cartésienne donnée par [21] de la manière suivante:

$$r_{ij} = |x_i - x_j| = \sqrt{\sum_k^d (x_{i,k} - x_{j,k})^2} \quad (\text{IV.14})$$

Où x_{ik} est le $k^{ème}$ composant de la coordonnée spatiale x_i de la $i^{ème}$ luciole, le mouvement d'une luciole i attirée par une autre luciole plus attrayante j est déterminé par :

$$x_{i+1} = x_i + \beta_0 e^{-\lambda r_{ij}^2} (x_j - x_i) + \alpha \left(rand - \frac{1}{2} \right) \quad (IV.15)$$

Où le premier terme est la position actuelle d'une luciole, le second terme est utilisé pour examiner l'attractivité d'une luciole à l'intensité lumineuse vue par les lucioles adjacentes et le troisième terme est utilisé pour le mouvement aléatoire d'une luciole dans le cas où il n'y a pas une plus lumineuse.

Le coefficient α est un paramètre aléatoire déterminé par le problème d'intérêt, tandis que $rand$ est un générateur de nombres aléatoires uniformément distribués dans l'espace $[0, 1]$ [22].

IV.6. L'algorithme artificiel de colonies des abeilles (ABC)

L'ABC, proposé par Karaboga [23] pour l'optimisation des problèmes numériques, simule le comportement des essaims d'abeilles de recherche intelligente de nourriture. Dans l'algorithme ABC, la colonie d'abeilles artificielles contient trois groupes d'abeilles: les abeilles ouvrière, les abeilles faux-bourdon et les quêteuses. Les éclaireuses cherchent au hasard, dans l'environnement entourant la ruche, les nouvelles sources de nourriture et ce comportement est une sorte de fluctuation qui est vital pour l'auto-organisation.

Les quêteuses en attente dans la ruche trouvent la source de nourriture au moyen des renseignements présentés par les butineuses ouvrières.

Le nombre moyen de quêteuses est d'environ 5 à 10% des butineuses. Dans l'ABC, la première moitié de la colonie artificielle d'abeilles est constituée d'employées et la seconde moitié est constituée de spectateurs. L'abeille ouvrière dont la source alimentaire a été épuisée devient une abeille scoute [23].

Dans l'algorithme ABC, la position d'une source de nourriture représente une solution possible au problème de l'optimisation et de la quantité de nectar d'une source de nourriture correspond à la qualité (fitness) de la solution associée. Le nombre d'abeilles ouvrières est égal au nombre de sources d'alimentation, chacune d'entre elles représente également un site, étant exploité à l'heure actuelle ou pour le nombre de solutions dans la population [24].

Les principales étapes de l'algorithme sont données ci-dessous:

- Initialisation.

- Répétez.
 - (a) Placez les abeilles ouvrières sur les sources alimentaires dans la mémoire;
 - (b) Placez les abeilles assistantes sur les sources alimentaires dans la mémoire;
 - (c) Envoyer les quêtesuses à la zone de recherche pour la découverte de nouvelles sources de nourriture.
- Jusqu'à (les exigences soient remplies).

Dans l'algorithme ABC, chaque cycle de la recherche comporte trois étapes:

Envoyer les abeilles ouvrières sur les sources de nourriture, pour mesurer leurs quantités de nectar; la sélection des sources de nourriture par les assistantes après le partage de l'information avec les abeilles ouvrières et déterminer la quantité de nectar des aliments; déterminer les éclaireuses pour les envoyer sur les sources alimentaires possibles.

- 1) Initialisation de la population de solutions $x_i = (x_{ij})$
- 2) Évaluer la population
- 3) Cycle = 1
- 4) la répétition
- 5) Produire de nouvelles solutions (positions de source de nourriture) v_i dans le quartier de x_i pour les abeilles employées; par exemple en utilisant la formule suivante.

$$v_{ij} = x_{ij} + \phi_{ij} (x_{ij} - x_{kj}) \quad (\text{IV.16})$$

- 6) Appliquer le processus de sélection avide entre v_i et x_i .
- 7) Calculer les valeurs de probabilité P_i pour la solution x_i au moyen de leurs valeurs de fitness f_i . Par exemple, en utilisant l'équation suivante.

$$P_i = \frac{f_i}{\sum_{i=1}^{SN} f_i} \quad (\text{IV.17})$$

Pour le problème de minimisation, la valeur de fitness peut être calculée comme suit.

$$f_i = \begin{cases} 1 & \text{if } F_i \geq 0 \\ \frac{1}{1 + F_i} & \\ 1 + \text{abs}(F_i) & \text{if } F_i < 0 \end{cases} \quad (\text{IV.18})$$

Où: F_i est la valeur du coût de la fonction objectif.

- 8) Produire de nouvelles solutions v_i (nouvelles positions) pour les assistantes à partir des solutions x_i , sélectionnées en fonction de P_i et les évaluer.
- 9) Appliquer le processus de sélection avide entre v_i et x_i .

10) Déterminer la solution abandonnée x_i (source), si elle existe, et la remplacer par une nouvelle solution x_i produite au hasard par l'éclaireuse. La définition suivante pourrait être utilisée à cette fin.

$$x_{ij} = x_{\min j} + rand(0,1) \times (x_{\max j} - x_{\min j}) \quad (IV.19)$$

Où $x_{\min j}$ et $x_{\max j}$ sont respectivement la limite inférieure et supérieure du paramètre j .

11) Mémorisez la meilleure position de source de nourriture (solution) réalisés jusqu'ici

12) Cycle = Cycle + 1

13) jusqu'à ce que (le cycle = Nombre de cycle maximum (MCN))

IV.7. L'algorithme de singe (MA)

L'algorithme de singe (MA) a été inventé par Mucherino et Seref en 2008. Le MA est une approche métaheuristique pour l'optimisation globale [25]. Le concept de MA ressemble aux stratégies des autres méthodes métaheuristicques comme les algorithmes génétiques, l'évolution différentielle, les colonies de fourmis,etc. [26]

Lors de l'escalade des arbres, le singe marque les branches des arbres par rapport à la qualité de la nourriture disponible. Par la suite lorsque le singe monte l'arbre à nouveau, il utilise les marques antérieures sur les branches, pour choisir celles qui mènent à des parties de l'arbre avec une meilleure qualité de l'alimentation [27]. En général l'algorithme du singe fonctionne comme suit :

Étape 1. Définir la fonction objectif et les variables de décision, entrer les paramètres du système et les limites des variables de décision, la taille de la population de singes (M), le nombre de montée (N). Pour notre cas, le problème d'optimisation est de minimiser la fonction de coût total de carburant.

Etape 2. Tout d'abord, générés de façon aléatoire les positions initiales des singes, $i = 1; 2; \dots;$ M , avec n dimensions:

$$x_i = (x_{i1}, x_{i2}, \dots, x_{in}) \quad i = 1, 2, \dots, M$$

Étape 3. Processus d'escalade: le processus d'escalade se déroule étape par étape pour changer les positions des singes à partir des positions initiales à des nouvelles, pour obtenir une amélioration de la fonction objectif. Le processus d'escalade est le suivant:

3-1. Un vecteur est généré de façon aléatoire comme suit:

$$\Delta x_i = (\Delta x_{i1}, \Delta x_{i2}, \dots, \Delta x_{in}), \quad i = 1, 2, \dots, M \quad (\text{IV.20})$$

Où

$$\Delta x_{ij} = \begin{cases} +a & p(+a) = 0.5 \\ -a & p(-a) = 0.5 \end{cases} \quad (\text{IV.21})$$

Avec a est la longueur du pas du processus d'escalade.

3.2. Calculer le pseudo-gradient de la fonction objectif f au point x_i .

$$f'_{ij} = \frac{f(x_i + \Delta x_i) - f(x_i - \Delta x_i)}{2\Delta x_{ij}}, \quad j = 1, 2, \dots, n \quad (\text{IV.22})$$

$$f'_i = f'_i = (f'_{i1}(x_i), f'_{i2}(x_i), \dots, f'_{in}(x_i)) \quad (\text{IV.23})$$

3.3. Définir le paramètre $y = (y_1, y_2, \dots, y_n)$ qui est calculé comme suit:

$$y_j = x_{ij} + a \cdot \text{sign}(f'_{ij}(x_i)) \quad j = 1, 2, \dots, n \quad (\text{IV.24})$$

Si $y = (y_1, y_2, \dots, y_n)$ est faisable, alors x_i est remplacé par y_i

Sinon x_i reste inchangé. Les étapes 3-1 à 3-3 seront répétées jusqu'à ce qu'il n'y ait pas de changements considérables sur les valeurs de la fonction objectif ou le nombre de montée N sera atteint.

Étape 4. Processus de supervision de saut: après le processus d'escalade, chaque singe arrive à son propre sommet, donc; chaque singe va regarder autour de lui pour trouver une montagne plus élevée. Si c'est le cas, le singe va y sauter. Pour cela, un paramètre b est défini selon la vue du singe qui est la distance maximale qu'il peut voir. Les sauts du singe sont fondés sur les étapes suivantes:

4-1. Un nombre réel y est généré de façon aléatoire dans la gamme:

$$y \in (x_{ij} - b, x_{ij} + b) \quad j = 1, 2, \dots, n \quad (\text{IV.25})$$

4-2. Si y est faisable et $f(y)$ est mieux que $f(x)$ pour le $i^{\text{ème}}$ singe ($f(y) > f(x)$), la position est mise à jour; par ailleurs, l'étape 4-1 est répétée.

Étape 5. Le processus d'escalade sera répété en considérant y comme position initiale.

Étape 6. Processus du saut périlleux: dans cette étape, les singes découvrent de nouveaux domaines de recherche. Prenant le centre des positions de tous les singes comme un pivot, chaque singe culbute à une nouvelle position en avant ou en arrière dans la direction de pointage au niveau du pivot. Sur la base de la nouvelle position, les singes vont continuer à grimper. Le processus du saut périlleux est le suivant:

6-1. Tout d'abord un intervalle de saut périlleux $[c, d]$ est défini, qui est la distance maximale que les singes peuvent culbute. Un nombre réel est généré de façon aléatoire dans cet intervalle.

6-2. On définit le paramètre y comme suit:

$$y_j = x_{ij} + \alpha(p_j - x_{ij}) \quad (\text{IV.26})$$

$$p_j = \frac{1}{M} \sum_{i=1}^M x_{ij} \quad j = 1, 2, \dots, n \quad (\text{IV.27})$$

Où p est le pivot du saut périlleux.

6-3. Si $y = (y_1, y_2, \dots, y_n)$ est faisable alors x sera remplacé par y , sinon, répéter 6-1, 6-3 jusqu'à ce qu'une y faisable sera trouvée.

Étape 7. Répétez les étapes 3-6 jusqu'à ce que le critère d'arrêt (nombre maximum d'itérations) soit atteint.

IV.8. La technique de l'hybridation entre les méthodes étudiées

IV.8.1. La méthode hybride GA-PSO-SQP

Dans ce travail, le processus pour résoudre les problèmes de l'EPD avec contraintes à l'aide de la méthode GA-PSO-SQP a été développé pour obtenir efficacement une solution de haute qualité. Cette méthode a été utilisée pour réduire le coût de la production totale et le coût total des émissions. L'approche GA-PSO-SQP est une hybridation de deux métaheuristiques, l'algorithme génétique (GA) et l'optimisation par les essaims de particules (PSO) pour la recherche globale et l'algorithme de programmation quadratique séquentielle (SQP) pour la recherche locale. L'algorithme proposé effectue la recherche en deux étapes:

Pour la recherche globale on utilise la méthode de PSO sur le top 10% des membres de la population de GA. D'autre part, les autres opérateurs de l'AG sont appliqués aux 90% restants de la population. Pour chaque itération, les résultats obtenus après l'application de ces deux algorithmes sont la solution courante à injecter au début de l'itération suivante et le processus est répété jusqu'à ce que les meilleurs résultats soient obtenus.

Pour la recherche locale: la recherche est complétée par une recherche locale en utilisant le SQP.

Les étapes suivantes résument la description de la méthode proposée:

Étape 1) générer une population initiale en prenant en compte les contraintes

Étape 2) évaluer la fonction objectif

Étape 3) appliquer les opérateurs génétiques à 90% de la population initiale

Étape 4) évaluer les enfants chromosomes générés par l'étape de la reproduction (3)

Étape 5) appliquer le PSO sur les meilleurs 10% de la population

Étape 6) Vérifier le critère d'arrêt:

Étape 6-1) si le critère d'arrêt n'est pas satisfait répéter à nouveau le cycle en injectant les résultats de PSO dans la nouvelle population.

Étape 6-2) si le critère d'arrêt est satisfait passez à l'étape 7

Étape 7) appliquer la SQP en prenant le résultat trouvé par GA -PSO comme un point de départ. Si le nombre d'itérations est satisfait la recherche est arrêtée et le résultat final est affiché.

Les figures IV.3, IV.4 et IV.5 montrent le mécanisme de recherche de la combinaison recherche globale-locale.

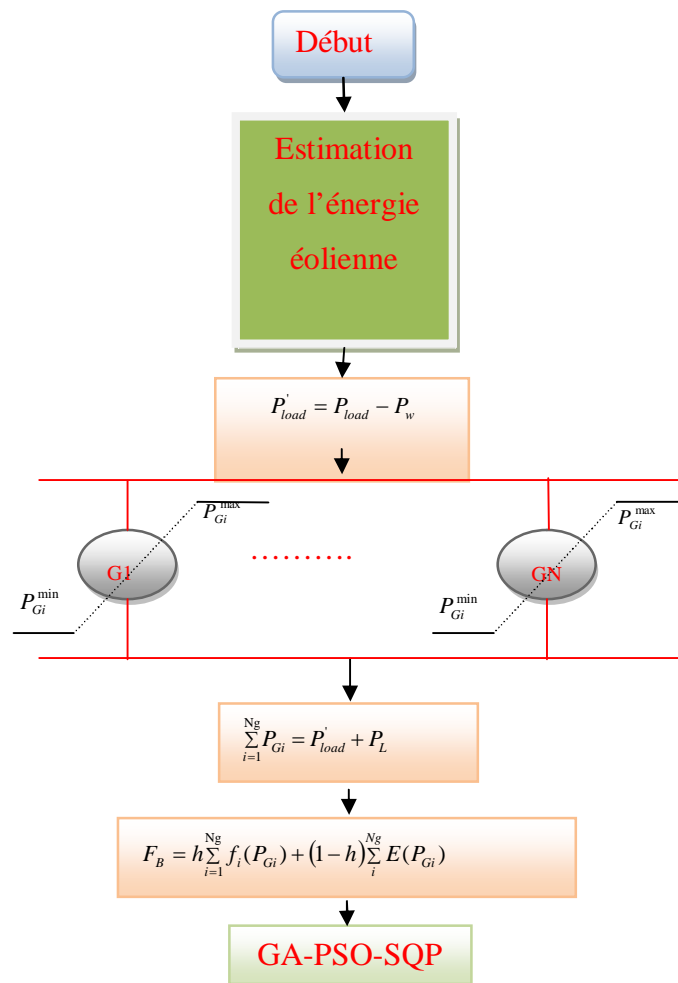


Fig. IV.3. L'organigramme de l'approche GA-PSO-SQP proposée pour l'EPD basée sur l'énergie éolienne




Fig. IV.4. L'espace de recherche avec GA-PSO-SQP

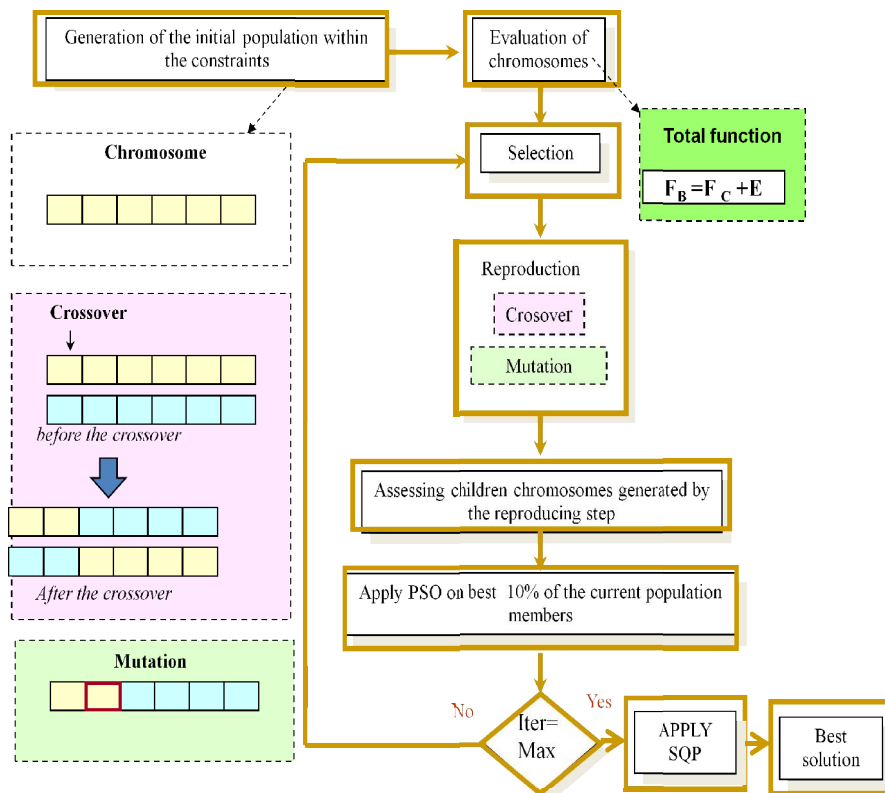


Fig. IV.5 L'organigramme de l'algorithme hybride GA-PSO-SQP proposé

IV.8.2. La méthode hybride GA-FFA

L'approche hybride consiste à exécuter les deux systèmes simultanément et sélectionne P individus de chaque système à échanger après les N itérations désignées. L'individu qui a une plus grande aptitude a plus de possibilités d'être sélectionné. Les principales étapes de l'approche hybride sont représentées ci-dessous:

- 1- Initialisation des sous-systèmes GA et FFA.
- 2- Exécuter GA et FFA simultanément.
- 3- Mémoriser la meilleure solution en tant que solution finale et arrêter si le meilleur individu dans l'un des deux sous-systèmes satisfait au critère d'arrêt.
- 4- Effectuer le processus hybride si les générations pourraient être divisées exactement par le nombre désigné d'itérations. Sélectionnez P individus des deux sous-systèmes au hasard en fonction de leur aptitude et échanger. Passer à l'étape 3.

IV.8.3. L'algorithme hybride (FFA-ABC)

Nous avons remarqué que les méthodes métaheuristiques sont très efficaces pour la recherche de la solution globale pour les problèmes complexes mieux que les méthodes déterministes.

Cependant, leur inconvénient est le temps de convergence en raison du nombre élevé des agents et des itérations. Pour résoudre ce problème, nous avons combiné deux méthodes métaheuristiques, le FFA et l'ABC avec un nombre le plus réduit possible d'abeilles et de lucioles.

Ce travail propose une méthode hybride qui comporte deux étapes de recherche. La première étape est une recherche par l'algorithme FFA et la deuxième étape est une recherche avec l'algorithme ABC. Les Figures IV.6, IV.7, IV.8 et IV.9 expliquent la procédure de calcul de la méthode hybride et son concept.

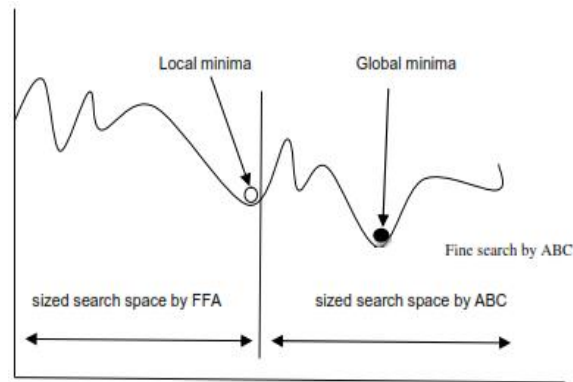


Fig.IV.6 Concept de la méthode hybride

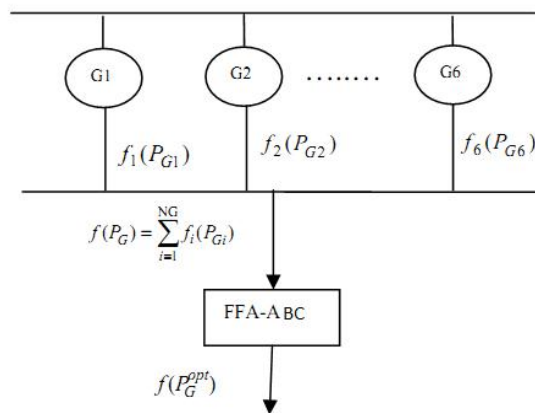


Fig.IV.7 Optimisation globale de tous les générateurs du système IEEE 30-nœuds

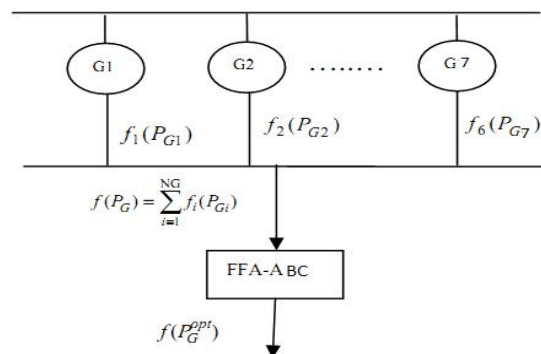


Fig.IV.8 Optimisation globale des 7 générateurs du système IEEE 57-nœuds

```

Initialize approach parameters;
Generate the initial population of fireflies or xi (i=1,
2,.... n)
Light Intensity of firefly n is determined by objective
function,  $I_n \sim f(x)$ 
While (termination criterion not satisfied)
For i = 1 to n (all n fireflies);
For j=1 to n (n fireflies)
if ( $I_j > I_i$ ), move firefly i towards j; end if
Attractiveness varies with distance r via  $\text{Exp}[-\gamma r^2]$ ;
Evaluate new solutions and update light intensity;
End for j;
End for i;
Rank the fireflies and find the current best;
End while;
The best solutions found by FFA are regarded as
initial points for ABC
Evaluate the fitness function for each employed bee
While (termination criterion not satisfied)
Employed Bees' Phase
For each employed bee
Produce new food source positions
Calculate the value
Apply greedy selection mechanism
End For.
Calculate the probability values for the solution.
Onlooker Bees' Phase
For each onlooker bee
Chooses a food source depending on
Produce new food source positions
Calculate the value
Apply greedy selection mechanism
End For
Scout Bee Phase
If there is an employed bee becomes scout
Then replace it with a new random source positions
Memorize the best solution achieved so far
End while;
Process results;
End procedure;

```

Fig. IV.9 Le pseudo code du FFA-ABC

IV.8.4. L'algorithme hybride (GA-MA)

L'équilibre entre l'exploration et de l'exploitation est réalisée avec l'approche GA-MA. Le processus de recherche commence par le GA en initialisant un groupe de chromosomes aléatoires, puis la recherche est poursuivie par le MA, les résultats trouvés par le GA sont utilisés comme points de départ pour le MA.

Ensuite, les meilleurs résultats (mieux que GA) trouvés par le MA sont également communiqués au GA comme espace de recherche initial. Le processus est répété jusqu'à ce que la solution finale soit atteinte. Fig. IV.10 montre le mécanisme de recherche de la combinaison globale-locale. Les étapes suivantes résument la description de l'algorithme proposé:

Étape 1. Exécutez GA (avec le maximum d'itérations)

Étape 2. Les meilleures variables de contrôle optimisées par le GA sont communiquées au MA et considérées comme l'espace de recherche initial (avec le maximum d'itérations).

Étape 3. Communiquer la meilleure solution trouvée par le MA au GA et la considérer comme l'espace de recherche initial.

Étape 4. Le processus se répète ensuite jusqu'à ce que la solution finale soit atteinte.

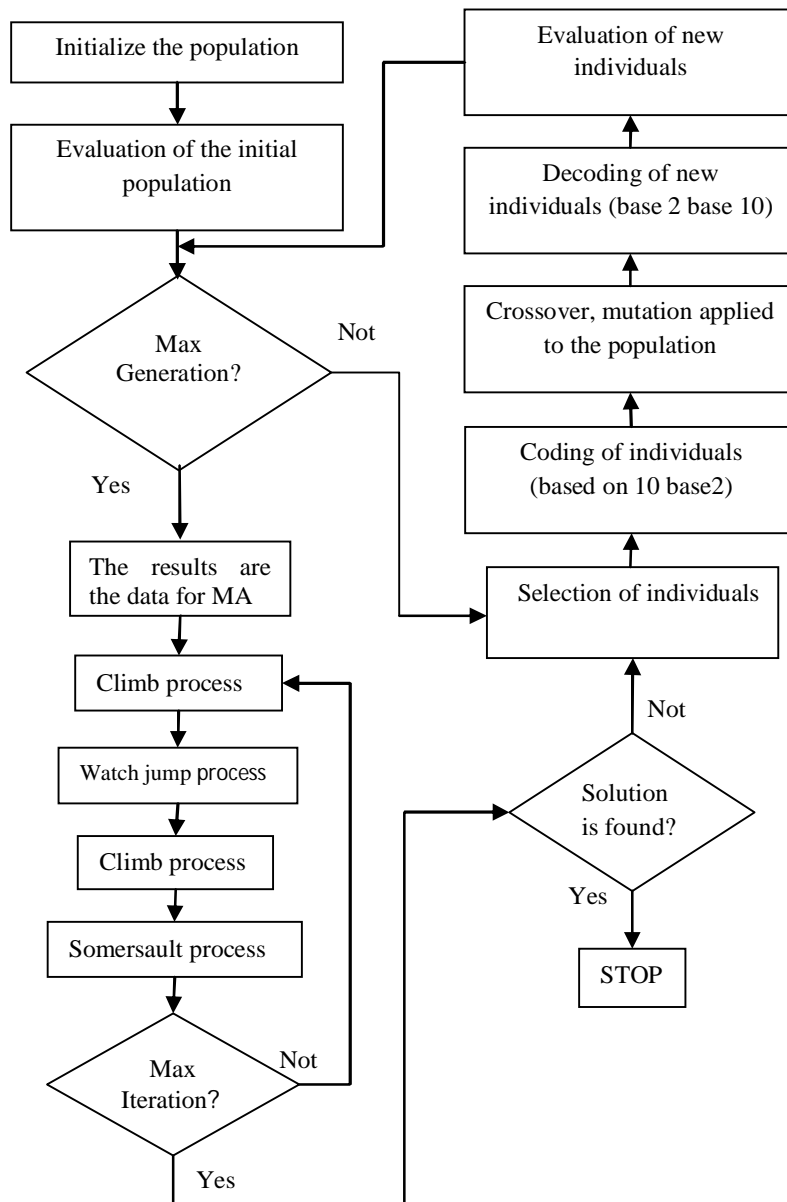


Fig. IV.10. Organigramme pour l'EPD utilisant GA-MA

REFERENCES

1. Holland JH (1975) *Adaptation in natural and artificial systems*. The University of Michigan Press, Ann Arbor
2. Goldberg DE (1989) *Genetic algorithms in search, optimization and machine learning*. Addison Wesley, Boston
3. Radetic E, Pelikan M, Goldberg DE (2009) Effects of a deterministic hill climber on hBOA. *Genetic and Evolutionary Computation Conference (GECCO-2009)*, pp 437–444
4. Abido MA (2006) Multiobjective evolutionary algorithms for electric power dispatch problem. *IEEE Trans Evol Comput* 10:315–329
5. Younes M, Rahli M, Lahouari AK (2006) Economic power dispatch using evolutionary algorithm. *J Electr Eng* 57:211–217
6. Rahli M, Pirotte P (1999) Optimal load flow using sequential unconstrained minimization technique (SUMT) method under power transmission losses minimization. *Electr Power Syst Res* 52:61–64
7. Yao F, Dong ZY, Meng K, Xu Z, Ho-Ching Iu, Po WongKit (2012) Quantum-inspired particle swarm optimization for power system operations considering wind power uncertainty and carbon tax in Australia 2012. *IEEE Trans Ind Inf* 8:880–888
8. Younes M, Rahli M, Lahouari AK (2007) Optimal power flow based on hybrid genetic algorithm. *J Inf Sci Eng* 23:1801–1816
9. Kennedy J, Eberhart R (1995) Particle swarm optimization. *Proceedings of the IEEE international conference on neural networks*,
10. Eberhart RC, Kennedy J (1995) A new optimizer using particle swarm theory. *Proceedings of 6th International Symposium on Micro Machine and Human Science*, IEEE Service Center, Piscataway, Nagoya, Japan, pp. 39–43
11. Goldberg DE (1989) *Genetic algorithms in search, optimization and machine learning*. Addison Wesley, Boston
12. Coelho LS, Viviana CM (2009) A novel chaotic particle swarm optimization approach using He non map and implicit filtering local search for economic load dispatch. *Chaos Solitons Fractals* 39:510–518
13. Boggs PT, Tolle JW (1995) Sequential quadratic programming. *Acta Numer* 4:1–51
14. Hock W, Schittkowski K (1983) A comparative performance evaluation of 27 nonlinear programming codes. *Computing* 30: 335–358

15. Powell MJD (1978) Algorithms for nonlinear functions that use lagrangian functions. Math Program 14:224–248
16. Jian JB, Tang CM, Hu QJ, Zheng HY (2005) A feasible descent SQP algorithm for general constrained optimization without strict complementarity. J Comput Appl Math 180:391–412
17. Fraga .H , Firefly luminescence: A historical perspective and recent developments, Journal of Photochemical & Photobiological Sciences, vol. 7, 2008, pp. 146 –158.
18. Yang .X.S., Firefly algorithms for multimodal optimization, Stochastic Algorithms: Foundations and Applications Lecture Notes in Computer Sciences, vol. 5792, 2009, pp. 169–178.
19. Z.-L. Gaing, “Particle swarm optimization to solving the economic dispatch considering the generator constraints,” IEEE Trans. Power Syst., vol. 18, no. 3, 2003, pp. 1187–1195.
20. Yang .X. S., “Firefly :al gorithm, stochastic 0test functions and design optimization, International Journal of Bio-Inspired Computation, vol. 2 n. 2, 2010, pp. 78 –84.
21. S. X. Yang, “Firefly Algorithm”, Engineering Optimization. Hoboken, New Jersey: Wiley, 2010, pp. 221-230.
22. Xin-She Yang, “Firefly Algorithm”, Engineering Optimization: An Introduction with Metaheuristic Applications, Wiley, 2010, pp. 221-230.
23. D. Karaboga, An idea based on honey bee swarm for numerical optimization. Technical Report TR06, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.
24. D. Karaboga and B. Basturk. Advances in Soft Computing: Foundations of Fuzzy Logic and Soft Computing, volume 4529/2007 of LNCS, chapter Artificial Bee Colony (ABC) Optimization
25. A. Mucherino and O. Seref, *Monkey Search: A Novel Meta-Heuristic Search for Global Optimization*, AIP Conference Proceedings 953, Data Mining, System Analysis and Optimization in Biomedicine, 162–173 (2007).
26. A. Mucherino, O. Seref, P.M. Pardalos, *Simulating Protein Conformations through Global Optimization*, [arXiv:0811.3094v1](https://arxiv.org/abs/0811.3094v1) [math.OC], November 19, (2008).
27. R.Q. Zhao, W.S. Tang, *Monkey algorithm for global numerical optimization*, Journal of Uncertain Systems, vol 2 (3), 165–176 (2008).

Chapitre V

APPLICATIONS, RESULTATS ET
DISCUSSION

V.1. Introduction

Le problème du dispatching économique de la puissance (EPD) a été l'un des sujets les plus étudiés par les chercheurs du domaine des systèmes d'énergie depuis Carpentier, le premier qui a publié le concept, en 1962 [1]. L'EPD est un problème d'optimisation non linéaire et non convexe fortement contraint [2]. Pour le résoudre, un certain nombre de techniques classiques d'optimisation telles que la programmation non linéaire (NLP) [3], programmation quadratique (QP) [4], la programmation linéaire (LP) [5] la méthode Newton-based [6], la méthode du point intérieur [7], programmation mixte en nombres entiers [8] , la programmation dynamique [9], Branch and Bound [10], ont été appliquées.

Toutes ces méthodes mathématiques sont fondamentalement fondées sur la convexité de la fonction objectif pour trouver le minimum global. Cependant, le problème de l'EPD a les caractéristiques de non-linéarité élevée et non-convexité. Les techniques classiques d'optimisation donc ne sont pas assez bonnes pour résoudre ce problème parce qu'ils dépendent de l'existence de la première et de la seconde dérivées de la fonction objectif et sur le bon calcul de ces dérivés sur un grand espace de recherche. En outre, les performances de ces approches traditionnelles dépendent aussi des points de départ et sont susceptibles de converger vers un minimum local, voire diverger.

Récemment, de nombreuses tentatives pour surmonter les limites des approches de programmation mathématiques ont été effectuées telles que les méthodes d'optimisation métaheuristiques, par exemple, la recherche taboue (TS) [11], recuit simulé (SA) [12], algorithmes génétiques [13], programmation évolutive (EP) [14], réseaux de neurones artificiels [15], essaim de particules [16] , les colonies de fourmis (ACO) [17], l'algorithme de l'harmonie de recherche [18] . Leur application à des problèmes d'optimisation globale devient attrayante parce qu'elles ont des capacités de recherches globales meilleures que les algorithmes d'optimisations classiques. Les techniques métaheuristiques semblent être prometteuses et en pleine évolution, et vont être les outils les plus utilisés pour résoudre EPD.

Bien que le problème le plus abordé par les chercheurs soit essentiellement la minimisation du coût de la production de l'énergie électrique, qui est un problème d'optimisation mono-objectif, ces dernières années et avec les préoccupations au sujet des niveaux inquiétants des émissions dans l'environnement, notre problème est devenu l'optimisation du coût de carburant et les émissions des polluants simultanément tout en satisfaisant certaines contraintes du système. Ce qui est un problème multiobjectif.

Pour obtenir une bonne conception avec différentes solutions dans un problème d'optimisation multiobjectif, le coût de carburant et les émissions de polluants sont convertis en un problème d'optimisation unique en introduisant le facteur de pénalité.

Pour les problèmes de minimisation/ maximisation les méthodes métaheuristiques permettent de trouver des solutions plus proches de l'optimum, mais avec un coût élevé en temps.

Pour résoudre ce problème, nous avons utilisé la technique d'hybridation qui consiste à combiner deux ou trois méthodes pour profiter des avantages de l'une et contourner les inconvénients de l'autre. Dans ce travail, nous avons utilisé : la combinaison entre les algorithmes génétiques et l'algorithme de la luciole (firefly) pour obtenir l'algorithme hybride FA-GA, la combinaison entre les algorithmes génétiques et l'algorithme du singe pour obtenir l'algorithme hybride GA-MA, la combinaison entre l'algorithme de la luciole (firefly) et l'algorithme de colonies des abeilles pour obtenir l'algorithme hybride FA-ABC, la combinaison entre les algorithmes génétiques et l'algorithme des essaims de particules et la programmation quadratique séquentielle pour obtenir l'algorithme hybride GA-PSO-SQP.

À la fin de ce travail le problème est abordé en tenant en compte l'injection de l'énergie éolienne dans le réseau électrique.

V.2. Formulation du problème

V.2.1. Problème EPD conventionnel

L'objectif du problème de l'EPD classique consiste à trouver une allocation optimale l'énergie engendrée dans un système d'alimentation. La contrainte de l'équilibre de la puissance et les contraintes de production de la puissance pour toutes les unités devraient être satisfaites. En d'autres termes, le problème EPD est de trouver la combinaison optimale de la génération de la puissance qui minimise le coût total du carburant tout en satisfaisant la contrainte d'égalité de l'équilibre de la puissance et de plusieurs contraintes d'inégalité sur le système.

Le problème de l'EPD est un problème d'optimisation non linéaire et non convexe qui détermine les variables de contrôle optimal pour minimiser certains objectifs qui sont soumis à plusieurs contraintes d'égalité et d'inégalité. Le problème de l'EPD est généralement formulé comme suit:

$$f(x, u) \tag{V.1}$$

Avec

$$h(x, u) = 0 \quad (\text{V.2})$$

$$g(x, u) \leq 0 \quad (\text{V.3})$$

Où $h(x, u)$ est la contrainte typique d'égalité, $g(x, u)$ est la contrainte d'inégalité. x est le vecteur des variables d'état consistant de la puissance générée du nœud P_{G1} , la tension de charge du nœud V_{L1} , la puissance réactive de sortie générée Q_{G1} et la ligne de transmission de chargement S_{L1} . D'où x peut être exprimée comme suit :

$$X^T = [P_{G1}, V_{L1}, \dots, V_{LN_{PQ}}, Q_{G1}, \dots, Q_{GN_G}, S_{L1}, \dots, S_{LNL}] \quad (\text{V.4})$$

Où N_{PQ} , N_G et N_L sont le nombre de nœuds de charge, le nombre de générateurs et le nombre de lignes de transmission, respectivement.

u est le vecteur de variables de contrôle, comprenant les puissances réelles de sortie des générateurs, sauf au niveau du nœud P_G , les tensions des générateur V_G , les paramètres de prise de transformateur T et la puissance réactive injectée Q_C . Par conséquent, u peut être exprimé en tant que :

$$u^T = [P_{G2}, \dots, P_{GN_g}, V_{G1}, \dots, V_{GN_g}, T_1, \dots, T_{nt}, Q_{C1}, \dots, Q_{Cnc}] \quad (\text{V.5})$$

Où nt est le nombre de transformateurs de régulation et nc est le nombre de VAR de compensation.

V.2.2. Fonction objectif

V.2.2.1. Minimisation du coût de carburant.

L'objectif de l'EPD est de trouver une allocation optimale de la puissance engendrée dans un système d'alimentation. Les contraintes de l'équilibre et de la production de la puissance devraient être satisfaites pour toutes les unités. En d'autres termes, le problème de l'EPD est de trouver la combinaison optimale de la génération de la puissance qui minimise le coût total du carburant tout en satisfaisant la contrainte d'égalité de l'équilibre de la puissance et plusieurs contraintes d'inégalité dans le système [19].

La fonction du coût total de carburant est formulée comme suit:

$$f(P_G) = \sum_{i=1}^{NG} f_i(P_{Gi}) \quad (V.6)$$

$$f_i(P_{Gi}) = a_i P_{Gi}^2 + b_i P_{Gi} + c_i \quad (V.7)$$

Où $f(P)$ est le coût total de production en\$ / h;

$f_i(P_{Gi})$ est la fonction de coût de carburant de l'unité i en\$ / h;

a_i, b_i, c_i sont les coefficients de coûts de carburant de l'unité i ;

P_{Gi} est la puissance active à la sortie de l'unité i en MW;

V.2.2.2. Minimisation des pertes de la puissance active

L'objectif est de minimiser les pertes de la puissance active dans le réseau tout en satisfaisant un certain nombre de contraintes d'exploitation. La fonction objectif peut être exprimée comme suit:

$$P_L = \sum_{k=1}^{nl} g_k [V_i^2 + V_j^2 - 2V_i V_j \cos(\alpha_i - \alpha_j)] \quad (V.8)$$

Où g_k est la conductance d'une ligne de transmission k connectée entre le $i^{ème}$ et $j^{ème}$ nœud, $V_i, V_j, \alpha_i, \alpha_j$ sont les amplitudes de tension et les angles de phase du $i^{ème}$ et $j^{ème}$ nœud respectivement, nl est le nombre total de lignes de transmission.

V.2.2.3. Minimisation des émissions

Les émissions les plus importantes prisent en compte dans l'industrie de la production d'électricité, en raison de leurs effets sur l'environnement, sont le dioxyde de soufre (SO2) et les oxydes d'azote (NOx). Ces émissions peuvent être modélisées par des fonctions qui associent les émissions avec la production d'énergie pour chaque unité. Une approche pour représenter les émissions de SO2 et de NOx est d'utiliser une combinaison de termes polynomiaux et exponentiels [20]:

$$E(P_G) = \sum_{i=1}^{N_G} (\alpha_i P_{Gi}^2 + \beta_i P_{Gi} + \gamma_i) + \varepsilon_i \exp(\lambda_i P_{Gi}) \quad (V.9)$$

Où

α , β , γ , ε et λ sont les coefficients des caractéristiques d'émission du $i^{\text{ème}}$ générateur.

Le problème combiné bi-objectif économique-émissions dispatch est converti en un problème d'optimisation unique en introduisant un facteur de pénalité de prix h .

Cette fonction objectif combinée est décrite par :

$$\min F_B = \beta \sum_{i=1}^{N_G} f_i(P_{Gi}) + (1 - \beta) h_i \sum_{i=1}^{N_G} E(P_{Gi}) \quad (\text{V.10})$$

Où β est un facteur de pondération qui satisfait $0 < \beta < 1$.

Le facteur de pénalité de prix h_i est le rapport entre le coût maximal du carburant et l'émission maximale du générateur correspondant.

$$h_i = \frac{\sum_{i=1}^{N_G} f_i(P_{Gi}^{\max})}{\sum_{i=1}^{N_G} E(P_{Gi}^{\max})} \quad (\text{V.11})$$

V.2.2.4 La fonction non-lisse

Pour commander la puissance de sortie de l'unité, les générateurs électriques ont de multiples soupapes d'admission de vapeur qui sont utilisés. Lorsque les effets de pointe de valve sont considérés, le problème de l'ED devient extrêmement difficile à résoudre par des techniques classiques [21], en raison des changements brusques et les discontinuités présentes dans les fonctions de coûts supplémentaires correspondants. Valve points sont les niveaux de sortie à laquelle une nouvelle soupape d'admission est ouverte; lorsqu'une soupape d'admission de vapeur d'eau commence à s'ouvrir, une augmentation soudaine des pertes se produit, ce qui entraîne des ondulations dans la fonction de coût de l'unité.

Les effets des soupapes sont habituellement modélisés en ajoutant un terme sinusoïdal rectifiant à la fonction quadratique des coûts de base, comme il est indiqué ci-dessous [22, 23].

$$f_i(P_{Gi}) = a_i P_{Gi}^2 + b_i P_{Gi} + c_i + |e_i \sin(f_i(P_{Gi}^{\min} - P_{Gi}))| \quad (\text{V.12})$$

V.2.2.5 La fonction coût avec multi-fuel

En pratique, de nombreuses unités de production thermique fonctionnent avec plusieurs types de combustibles, comme le charbon, le gaz naturel et le pétrole. Le coût de production de ces unités en considérant ces fossiles est représenté par des fonctions coût quadratiques par partie [24, 25]. Comme suit.

$$f(P_{Gi}) = \begin{cases} a_{i1}P_{Gi1}^2 + b_{i1}P_{Gi} + c_{i1} & P_{Gi}^{\min} \leq P_{Gi} \leq P_{Gi1} \\ a_{i2}P_{Gi2}^2 + b_{i2}P_{Gi} + c_{i2} & P_{Gi1} \leq P_{Gi} \leq P_{Gi2} \\ \dots\dots\dots & \dots\dots\dots \\ a_{im}P_{Gim}^2 + b_{im}P_{Gi} + c_{im} & P_{Gim-1} \leq P_{Gi} \leq P_{Gi}^{\max} \end{cases} \quad (V.13)$$

Où a_{im} , b_{im} , c_{im} sont les coefficients du coût du $i^{\text{ème}}$ générateur pour le type m de carburant.

La fonction de coût de carburant de (V.13) est substituée en (V.12) pour obtenir la fonction objectif réelle F du problème de l'ED pratique.

$$F(P_{Gi}) = \begin{cases} a_{i1}P_{Gi1}^2 + b_{i1}P_{Gi} + c_{i1} + |e_{i1} \sin(f_{i1}(P_{Gi}^{\min} - P_{Gi}))| & P_{Gi}^{\min} \leq P_{Gi} \leq P_{Gi1} \\ a_{i2}P_{Gi2}^2 + b_{i2}P_{Gi} + c_{i2} + |e_{i2} \sin(f_{i2}(P_{Gi}^{\min} - P_{Gi}))| & P_{Gi1} \leq P_{Gi} \leq P_{Gi2} \\ \dots\dots\dots & \dots\dots\dots \\ a_{im}P_{Gim}^2 + b_{im}P_{Gi} + c_{im} + |e_{im} \sin(f_{im}(P_{Gi}^{\min} - P_{Gi}))| & P_{Gim-1} \leq P_{Gi} \leq P_{Gi}^{\max} \end{cases} \quad (V.14)$$

V.2.3 Les contraintes du problème

V.2.3.1. L'équation de l'équilibre de la puissance active.

Pour que la puissance soit équilibrée une contrainte d'égalité doit être satisfaite. La puissance générée devrait être égale à celle de la demande totale de la charge ajoutée aux pertes totales de la ligne. Elle est représentée comme suit:

$$\sum_{i=1}^{N_G} P_{Gi} = P_D + P_L \quad (V.15)$$

La valeur exacte des pertes du système peut être déterminée au moyen d'une solution de l'écoulement de puissance. L'approche la plus populaire pour trouver une valeur approximative des pertes est par le biais de la formule de perte de Kron comme indiqué dans l'équation. (V.13), qui représente les pertes en fonction du niveau de sortie des générateurs de système [26].

$$P_L = \sum_{i=1}^{N_G} \sum_{j=1}^{N_G} P_i B_{ij} P_j + \sum_{i=1}^{N_G} B_{0i} P_{Gi} + B_{00} \quad (\text{V.16})$$

Où

B_{ij} est le coefficient des pertes de transmission, P_i , P_j la puissance générée des $i^{\text{ème}}$ et $j^{\text{ème}}$ unités.

B_{0i} est le coefficient des pertes de l' $i^{\text{ème}}$ élément du vecteur

B_{00} est le coefficient des pertes constantes.

P_G est la production totale du système;

P_D est la demande de la charge totale

P_L sont les pertes de transmission totales du système en MW;

N_G est le nombre des unités génératrices dans le système;

Les contraintes d'égalité de la puissance active et réactive à chaque nœud sont données par.

$$P_{Gi} - P_{Di} - V_i \sum_{j=1}^{nb} V_j [G_{ij} \cos(\alpha_i - \alpha_j) - B_{ij} \sin(\alpha_i - \alpha_j)] = 0 \quad (\text{V.17})$$

$$Q_{Gi} - Q_{Di} - V_i \sum_{j=1}^{nb} V_j [G_{ij} \sin(\alpha_i - \alpha_j) - B_{ij} \cos(\alpha_i - \alpha_j)] = 0 \quad (\text{V.18})$$

où $i = 1, 2, \dots, nb$, (nb est le nombre de nœuds); Q_{Gi} est la puissance réactive générée au niveau du $i^{\text{ème}}$ nœud; P_{Di} et Q_{Di} sont les puissances de charges active et réactives, respectivement; G_{ij} et B_{ij} sont la conductance de transfert et la susceptance entre le nœud i et le nœud j , respectivement; V_i et V_j sont les amplitudes de tension au nœuds i et j , respectivement; et α_i et α_j sont les angles de tension au nœud i et au nœud j , respectivement.

V.2.3.2. Les limites de la production de la puissance active.

Les contraintes de production: les tensions des générateurs, la puissance active et réactive sont limités par leurs bornes inférieures et supérieures comme suit:

$$V_{Gi}^{\min} \leq V_{Gi} \leq V_{Gi}^{\max} \quad (\text{V.19})$$

$$P_{Gi}^{\min} \leq P_{Gi} \leq P_{Gi}^{\max} \quad (\text{V.20})$$

$$Q_{Gi}^{\min} \leq Q_{Gi} \leq Q_{Gi}^{\max} \quad (\text{V.21})$$

Les contraintes des transformateurs: Les réglages de prise des transformateurs sont limités par leurs limites minimales et maximales comme suit:

$$T_i^{\min} \leq T_i \leq T_i^{\max} \quad (\text{V.22})$$

Les contraintes de la puissance réactive shunt : La puissance réactive injectée aux nœuds est limitée par ses valeurs maximales et minimales:

$$Q_{Ci}^{\min} \leq Q_{Ci} \leq Q_{Ci}^{\max} \quad (\text{V.23})$$

Les contraintes de sécurité: L'amplitude de la tension aux nœuds de charge et les charges de la ligne de transmission sont données comme suit:

$$V_{Li}^{\min} \leq V_{Li} \leq V_{Li}^{\max} \quad (\text{V.24})$$

$$S_{li} \leq S_{li}^{\max} \quad (\text{V.25})$$

V.2.4 Transformation d'un problème contraint en un problème sans contraintes

Pour faciliter l'implémentation de la méthode de résolution, il est toujours utile de transformer le problème avec contraintes équation (V.1) en un problème sans contraintes. Cette transformation est faite par l'ajout d'une pénalité à la fonction objectif, cette dernière va être alors remplacée par :

$$F(P_{Gi,r^k}) = f(P_G) + \left(\frac{1}{r^k}\right) \sum_{j=1}^n H(h_j(P_{Gi})) + (r^k) \sum_{i=1}^m G(g_i(P_{Gi})) \quad (\text{V.26})$$

Où

$F(PG)$ est la fonction objectif, $\sum_{j=1}^n H(h_j(P_{Gi}))$ et $\sum_{i=1}^m G(g_i(P_{Gi}))$ sont les fonctions de pénalités (contraintes d'égalité et d'inégalité) n est le nombre de contraintes d'égalités, m est le nombre de contraintes d'inégalité et r^k est le coefficient de pénalisation.

La fonction de pénalité est choisie de telle façon que la faisabilité soit garantie durant tout le processus de recherche de l'optimum.

La méthode de pénalité est déterminée selon le type des fonctions $H(h_j(P_{Gi}))$ et $G(g_i(P_{Gi}))$, d'où il y a trois méthodes.

V.2.4.1. La méthode des pénalités externes :

Dans ce cas on a :

$$G(g_i(P_{Gi}))=0 \text{ et } H(h_j(P_{Gi}))=[h_j(P_{Gi})]^2$$

La fonction à résoudre donc devient :

$$F(P_{Gi,r^k}) = f(P_G) + \left(\frac{1}{r^k}\right) \sum_{j=1}^n [h_j(P_{Gi})]^2 \quad (\text{V.27})$$

Une séquence d'augmentation de la valeur de r est générée, et à chaque itération k du processus, le problème d'optimisation non contraint Eq. (V.27) est résolu. Lorsque k tend vers l'infini, Eq. (V.27) devient équivalente à celle de notre problème Eq (V.1).

L'avantage de cette méthode est que le point de départ n'est pas éligible si l'on s'assure que le point final est dans la zone éligible, mais son inconvénient est qu'elle ne donne un optimum possible que si k tend vers l'infini.

V.2.4.2. La méthode des pénalités internes :

Dans ce cas seules les contraintes d'inégalité sont prises en considération et sont définies ainsi :

$$G(g_i(P_{Gi})) = \frac{1}{g_i(P_{Gi})}$$

Et la fonction à minimiser devient :

$$F(P_{Gi,r^k}) = f(P_G) + (r^k) \sum_{i=1}^m \frac{1}{g_i(P_{Gi})} \quad (\text{V.28})$$

Cette technique ne convient pas à des problèmes avec des contraintes d'égalités. La fonction de pénalité a l'avantage de conduire toujours à une séquence de solutions possibles, mais l'inconvénient que le point de départ doit être dans la région admissible, ce qui conduit à la nécessité d'un autre algorithme supplémentaire pour le trouver.

V.2.4.3. La méthode des pénalités mixtes :

Il s'agit de la combinaison des deux précédentes méthodes, la fonction à minimiser devient donc :

$$F(P_{Gi,r^k}) = f(P_G) + \left(\frac{1}{r^k}\right) \sum_{j=1}^n [h_j(P_{Gi})]^2 + (r^k) \sum_{i=1}^m \frac{1}{g_i(P_{Gi})} \quad (\text{V.29})$$

Dans notre étude, nous avons utilisé cette méthode pour ses avantages.

V.2.5. L'Énergie Éolienne :

La puissance contenue sous forme d'énergie cinétique, $P(W)$, du vent est exprimée par:

$$P = \frac{1}{2} \cdot \rho \cdot A \cdot v^3 \quad (\text{V.30})$$

Avec:

A est la surface parcourue par le vent (m^2); ρ est la densité de l'air ($1,225 \text{ kg/m}^3$) et v est la vitesse du vent (m/s).

L'éolienne peut récupérer une partie de cette énergie qui est représentée par P_{el} et donnée par:

$$P_{el} = \frac{1}{2} \cdot \rho \cdot C_e \cdot A \cdot v^3 \cdot 10^{-3} \quad (\text{V.31})$$

C_e est le facteur d'efficacité, qui dépend de la vitesse du vent et l'architecture du système [27].

V.3. Applications et résultats

V.3.1. Application de la méthode GA-MA

L'approche GA-MA proposé fondée sur la recherche locale et globale est développée dans le langage de programmation Matlab utilisant la version 7.04. Afin d'évaluer la robustesse de la méthode proposée, un système de 10 générateurs a été considéré et la fonction objectif utilisée est celle de l'équation (V.14), les données du coût du carburant sont données dans Tableau V.2 [24].

Pour tester cette méthode on a fait varier la demande totale du système de 2400 MW à 2600 MW avec des incréments de 100MW. Le résultat est comparé aux résultats des diverses approches heuristiques dont HM [28], HNN [29] et [30] et HGA [31], avec les cas de la demande totale de 2600 MW, 2500 MW et 2400 MW respectivement, étant donné que les documents cités ne fournissent que ces cas. Les résultats de l'algorithme proposé et les diverses méthodes heuristiques mentionnées ci-dessus sont résumés dans les tableaux V.2, V.3 et V.4. Comme cela est représenté, le GA-MA fournit la meilleure solution (le coût le moins cher).

Si l'on considère, par exemple dans le cas de la demande de 2400 MW, et pour le premier type de carburant, il a été amélioré de 0.442\$ pour le deuxième type, il a été amélioré de 0.8742\$. Dans le cas de la demande de 2500 MW, le meilleur coût est donné par HNN [29], nous l'avons amélioré de plus de 0,11\$, et enfin pour le cas de la demande de 2600 MW, le meilleur coût est donné par HM [28] nous l'avons amélioré de 0.4972\$. On peut donc dire que cette technique peut avoir une contribution remarquable dans la réduction du coût de la production de l'énergie électrique.

Tableau V.1.

Les paramètres du système à 10 générateurs en considérant les effets des soupapes d'admission et les multi-carburants

Unit	Generation					Fuel Type	Cost coefficients				
	Min	P1	P2	Max			a_i	b_i	c_i	e_i	f_i
	F ₁	F ₂	F ₃								
1	100	196	250		1	0.2176e-2	-0.3975e0	0.2697e2	0.2697e-1	0.3975e1	
	1	2			2	0.1861e-2	-0.3059e0	0.2113e2	0.2113e-1	-0.3059e1	
2	50	114	157	230	1	0.4194e-2	-0.1269e1	0.1184e3	0.1184e0	-0.1269e2	
	2	3	1		2	0.1138e-2	-0.3988e-1	0.1865e1	0.1865e-2	-0.3988e0	
					3	0.1620e-2	-0.1980e0	0.1365e2	0.1365e-1	-0.1980e1	
3	200	332	388	500	1	0.1457e-2	-0.3116e0	0.3979e2	0.3979e-1	-0.3116e1	
	1	3	2		2	0.1176e-4	0.4864e0	-0.5914e2	-0.5914e-1	0.4864e1	
					3	0.8035e-3	0.3389e-1	-0.2875e1	-0.2876e-2	0.3389e0	
4	99	138	200	265	1	0.1049e-2	-0.3114e-1	0.1983e1	0.1983e-2	-0.3114e0	
	1	2	3		2	0.2758e-2	-0.6348e0	0.5285e2	0.5285e-1	-0.6348e1	
					3	0.5935e-2	-0.2338e1	0.2668e3	0.2668e0	-0.2338e2	
5	190	338	407	490	1	0.1066e-2	-0.8733e-1	0.1392e2	0.1392e-1	-0.8733e0	
	1	2	3		2	0.1597e-2	-0.5206e0	0.9976e2	0.9976e-1	-0.5206e1	
					3	0.1498e-3	0.4462e0	-0.5399e2	-0.5399e-1	0.4462e1	
6	85	138	200	265	1	0.2758e-2	-0.6348e0	0.5285e2	0.5285e-1	-0.6348e1	
	2	1	3		2	0.1049e-2	-0.3114e-1	0.1983e1	0.1983e-2	-0.3114e0	
					3	0.5935e-2	-0.2338e1	0.2668e3	0.2668e0	-0.2338e2	
7	200	331	391	500	1	0.1107e-2	-0.1325e0	0.1893e2	0.1893e-1	-0.1325e1	
	1	2	3		2	0.1165e-2	-0.2267e0	0.4377e2	0.4377e-1	-0.2267e1	
					3	0.2454e-3	0.3559e0	-0.4335e2	-0.4335e-1	0.3559e1	
8	99	138	200	265	1	0.1049e-2	-0.3114e-1	0.1983e1	0.1983e-2	-0.3114e0	
	1	2	3		2	0.2758e-2	-0.6348e0	0.5285e2	0.5285e-1	-0.6348e1	
					3	0.5935e-2	-0.2338e1	0.2668e3	0.2668e0	-0.2338e2	
9	130	213	370	440	1	0.1554e-2	-0.5675e0	0.8853e2	0.8853e-1	-0.5675e1	
	3	1	3		2	0.7033e-2	-0.4514e-1	0.1530e2	0.1423e-1	-0.1817e0	
					3	0.6121e-3	-0.1817e-1	0.1423e2	0.1423e-1	-0.1817e0	
10	200	362	407	490	1	0.1102e-2	-0.9938e-1	0.1397e2	0.1397e-1	-0.9938e0	
	1	3	2		2	0.4164e-4	0.5084e0	-0.6113e2	-0.6113e-1	0.5084e1	
					3	0.1137e-2	-0.2024e0	0.4671e2	0.4671e-1	-0.2024e1	

Tableau V.2.

Comparaison du résultat de la simulation avec d'autres méthodes pour le cas de la demande de 2400 MW

Unit	Fuel type	ARCGA [32]	GA-MA	Fuel type	HM [28]	GA-MA
1	1	189.3053	189.3067	1	193.200	196.0000
2	1	202.5519	202.0194	1	204.100	204.0709
3	1	255.4481	255.0323	1	259.100	255.9424
4	3	232.9209	232.7787	3	234.300	233.9215
5	1	240.3603	241.3553	1	249.000	245.9422
6	3	232.6514	232.9536	1	195.500	200.0000
7	1	252.2638	254.0768	1	260.100	260.4579
8	3	233.0552	233.1367	3	234.300	234.1303
9	1	320.3954	319.0338	1	325.300	323.6130
10	1	241.0479	239.3061	1	246.300	244.9212
Cost (\$/h)		481.7434	481.3014		488.500	487.6258

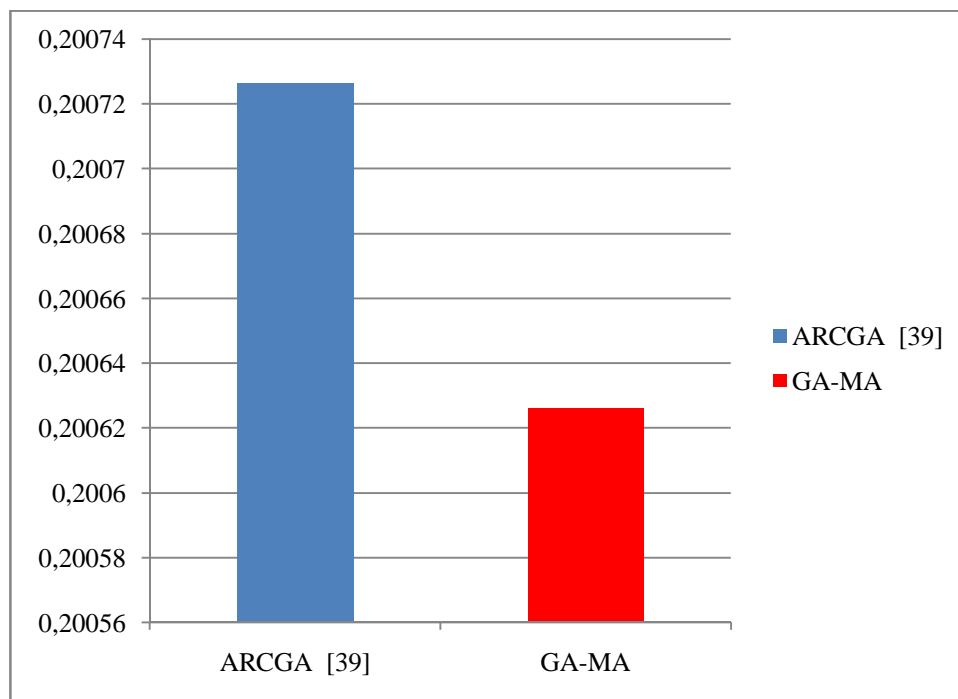


Fig V.1. Coût du méga watt heure en dollars donné par l'approche GA-MA et sa comparaison aux autres méthodes pour la demande de 2400 MW (1ère combinaison de carburants)

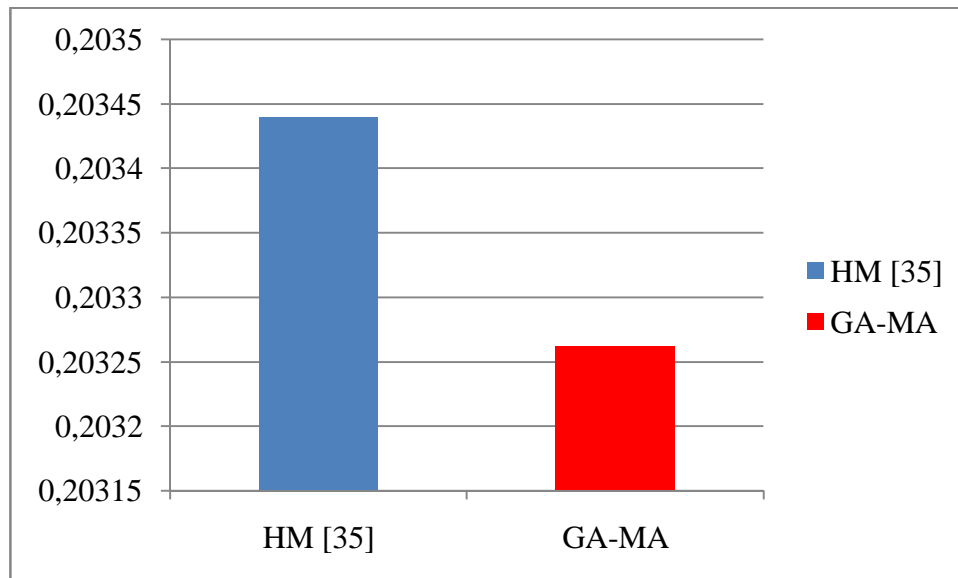


Fig V.2. Coût du méga watt heure en dollars donné par l'approche GA-MA et sa comparaison aux autres méthodes pour la demande de 2400 MW (2ème combinaison de carburants)

Tableau V.3

Comparaison du résultat de la simulation avec d'autres méthodes pour le cas de la demande de 2500 MW

Unit	Fuel type	HM [28]	HNN [29]	AHNN [30]	HGA [31]	ICDEDP [33]	GA-MA
1	2	206.6	206.1	206.0	206.5422	206.5190	206.074796
2	1	206.5	206.3	206.3	206.4582	206.4573	206.300000
3	1	265.9	265.7	265.7	265.7636	265.7391	265.700000
4	3	236.0	235.7	235.9	235.9436	235.9531	235.700000
5	1	258.2	258.2	257.9	257.9942	258.0177	258.200000
6	3	236.0	235.9	235.9	235.9546	235.9531	235.900000
7	1	269.0	269.1	269.6	268.8709	268.8635	269.100000
8	3	236.0	235.9	235.9	235.9425	235.9531	235.900000
9	1	331.6	331.2	331.4	331.4712	331.4877	331.200000
10	1	255.2	255.7	255.4	255.0589	255.0562	255.693159
Cost (\$/h)		526.700	526.13	526.230	526.2388	526.2388	526.018678




Fig V.3. Coût du méga watt heure en dollars donné par l'approche GA-MA et sa comparaison aux autres méthodes pour la demande de 2500 MW

Tableau V.4

Comparaison du résultat de la simulation avec d'autres méthodes pour le cas de la demande de 2600 MW

Unit	Fuel type	HM [28]	HNN [29]	AHNN [30]	HGA [31]	ICDEDP [33]	GA-MA
1	2	216.4	215.3	215.8	216.5442	216.5442	216.3110
2	1	210.9	210.6	210.7	210.9058	210.9058	210.6716
3	1	278.5	278.9	279.1	278.5441	278.5441	278.4612
4	3	239.1	238.9	239.1	239.0967	239.0967	39.0791
5	1	275.4	275.7	276.3	275.5194	275.5194	276.1137
6	3	239.1	239.1	239.1	239.0967	239.0967	238.8180
7	1	285.6	286.2	286.0	285.7170	285.7170	285.0428
8	3	239.1	239.1	239.1	239.0967	239.0967	238.9756
9	1	343.3	343.5	342.8	343.4934	343.4934	343.0398
10	1	271.9	272.6	271.9	271.9861	271.9861	271.7867
Cost(\$/h)		574.030	574.26	574.370	574.3808	574.3808	573.5328

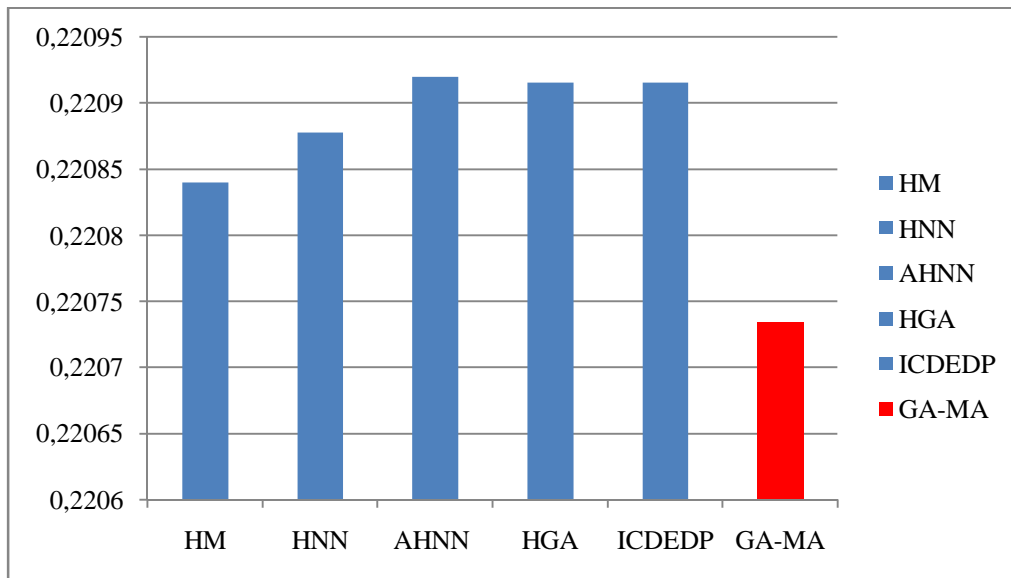


Fig V.4. Coût du méga watt heure en dollars donné par l'approche GA-MA et sa comparaison aux autres méthodes pour la demande de 2600 MW




Fig V.5. Graphe de la Convergence de la méthode GA-MA, pour un système de 10 générateurs, avec une demande de 2400 MW




Fig. V.6. Graphe de la Convergence de la méthode GA-MA, pour un système de 10 générateurs, avec une demande de 2500 MW




Fig. V.7. Graphe de la Convergence de la méthode GA-MA, pour un système de 10 générateurs, avec une demande de 2600 MW

Les figures V.5, V.6, V.7 montrent les courbes de la dernière colonne des tableaux V.2, V.3 et V.4 respectivement, où l'on constate que la méthode proposée converge pour les différentes valeurs de la puissance demandée, à un meilleur coût minimal que le reste des méthodes mentionnées dans la littérature, en plus, il est clair que la convergence est très rapide (entre 60 et 80 itérations). Par conséquent, nous pouvons dire que cette méthode est très efficace puisqu'elle conduit à de bons résultats dans un court temps de calcul.

V.3.1.1. Conclusion

Cette approche est utilisée pour résoudre le problème du dispatching économique de la puissance (EPD), la réduction du coût de production prend en compte les multiples carburants. Les résultats numériques et la vitesse de convergence montrent que cette méthode est très efficace dans ce genre de problème et peut contribuer à économiser des milliers de dollars par an.

V.3.2. Application de la méthode GA-FFA

La méthode proposée a été comparée à la méthode GA et à la méthode FFA en l'appliquant aux deux systèmes de tests (cas 1 et cas 2). Avec la fonction objectif de l'équation (V.6).

V.3.2.1 Cas 1 (système IEEE 30 nœuds 6 générateurs, $P_D=189.2$ MW)

Tout d'abord, l'algorithme proposé est testé sur le système IEEE 30 nœuds 6 générateurs. Chaque générateur est représenté par une fonction de coût quadratique. La demande totale de puissance est fixée à 189,2 MW.

Les valeurs des coefficients du coût de combustible sont données dans le tableau V.5, la demande de charge totale du système est 189.2 (MW), et les 6 générateurs doivent satisfaire à cette demande de charge sur le plan économique. Les résultats obtenus par la méthode proposée sont présentés dans le tableau V.7.

V.3.2.2. Cas 2 (système IEEE 57 nœuds 7 générateurs, $P_D=1250.8$ MW)

En second lieu, l'algorithme proposé est testé sur le système IEEE 57 nœuds 7 générateurs [34].

Les valeurs des coefficients du coût de combustible sont données dans le tableau V.6, la demande de charge totale du système est 1250,8 (MW), et 7 générateurs doivent satisfaire à cette demande de charge sur le plan économique. Les résultats obtenus par la méthode proposée sont présentés dans les tableaux V.8-V.9.

En particulier deux cas de tests sont considérés, le premier cas de test ne tient pas compte des pertes de transmission. Le second cas de test, les pertes de lignes de transmission sont calculées et maintenues constantes ($PL = 19.06$ MW).

Tableau V.5.

Les paramètres des générateurs du système IEEE 30 nœuds

Nœud	P_{Gimin} MW	P_{Gimax} MW	Coefficients du coût		
			a_i	b_i	c_i
P_{G1}	50	200	0.00375	2.00	0.00
P_{G2}	20	80	0.01750	1.75	0.00
P_{G5}	15	50	0.06250	1.00	0.00
P_{G8}	10	35	0.00834	3.25	0.00
P_{G11}	10	30	0.02500	3.00	0.00
P_{G13}	12	40	0.02500	3.00	0.00

Tableau V.6.

Les paramètres des générateurs du système IEEE 57 nœuds

Nœud	P_{Gimin} MW	P_{Gimax} MW	Coefficients du coût		
			a_i	b_i	c_i
P_{G1}	0.0	575.88	0.01	0.30	0.20
P_{G2}	0.0	100.00	0.01	0.30	0.20
P_{G3}	0.0	140.00	0.01	0.30	0.20
P_{G6}	0.0	100.00	0.01	0.30	0.20
P_{G8}	0.0	550.00	0.01	0.30	0.20
P_{G9}	0.0	100.00	0.01	0.30	0.20
P_{G12}	0.0	410.00	0.01	0.30	0.20

Tableau V.7.

Les résultats de l'approche GA-FFA comparée à FFA et GA pour le système 30-nœuds IEEE,
($P_D=189.2$ MW, $P_L = 0.00$ MW)

	FFA	GA	GA-FFA
P_{G1} (MW)	65.010627	44.839351	43.813900
P_{G2} (MW)	19.957552	70.894148	57.196700
P_{G3} (MW)	23.444470	12.426175	21.721800
P_{G4} (MW)	40.818984	21.038463	29.861400
P_{G5} (MW)	11.124227	2.104106	14.944800
P_{G6} (MW)	22.813034	30.062627	15.557000
Coût (\$/h)	589.841591	574.154619	553.633000



Fig V.8. Coût du mégawatt heure en dollars donné par l'approche GA-FFA et sa comparaison aux autres méthodes pour le système 30-nœuds IEEE, ($P_D=189.2$ MW, $P_L = 0.00$ MW)

Tableau V.8

Les résultats de l'approche GA-FFA comparée à GAmatpower, FFA et GA pour le système 57-nœuds IEEE, ($P_D=1250,8$ MW, $P_L = 0.00$ MW)

	GAmatpowerOPF [34]	FFA	GA	GA-FFA
P_{G1} (MW)	262.352	305.12976	269.9591	301.49463
P_{G2} (MW)	100.000	99.078087	98.8967	74.938124
P_{G3} (MW)	140.000	131.99147	136.554	117.55363
P_{G4} (MW)	100.000	97.704647	91.9394	99.231235
P_{G5} (MW)	275.537	276.20137	245.5221	295.46947
P_{G6} (MW)	99.9999	93.520327	98.9920	48.916911
P_{G7} (MW)	272.265	246.76597	308.1162	281.84984
Coût (\$/h)	3062.89	3042.398	3044.442	3016.627




Fig V.9. Coût du mégawatt heure en dollars donné par l'approche GA-FFA et sa comparaison aux autres méthodes pour le système 57-nœuds IEEE, ($P_D=1250.8$ MW, $P_L = 0.00$ MW)

Tableau V.9

Les résultats de l'approche GA-FFA comparée à Gamatpower, FFA et GA pour le système 57-nœuds IEEE, avec des pertes constantes ($P_D=1250,8$ MW, $P_L = 19.06$ MW)

	GamatpowerOPF [34]	FFA	GA	GA-FFA
P_{G1} (MW)	277.149	343.399	289.04	262.296
P_{G2} (MW)	100.000	99.349	96.851	96.4467
P_{G3} (MW)	140.000	134.872	134.83	138.410
P_{G4} (MW)	100.000	97.4055	87.664	99.0715
P_{G5} (MW)	277.282	219.134	303.55	292.827
P_{G6} (MW)	100.000	99.6873	95.319	87.8319
P_{G7} (MW)	275.403	275.176	260.98	291.326
Coût (\$/h)	3173.982	3171.99	3185.44	3166.72

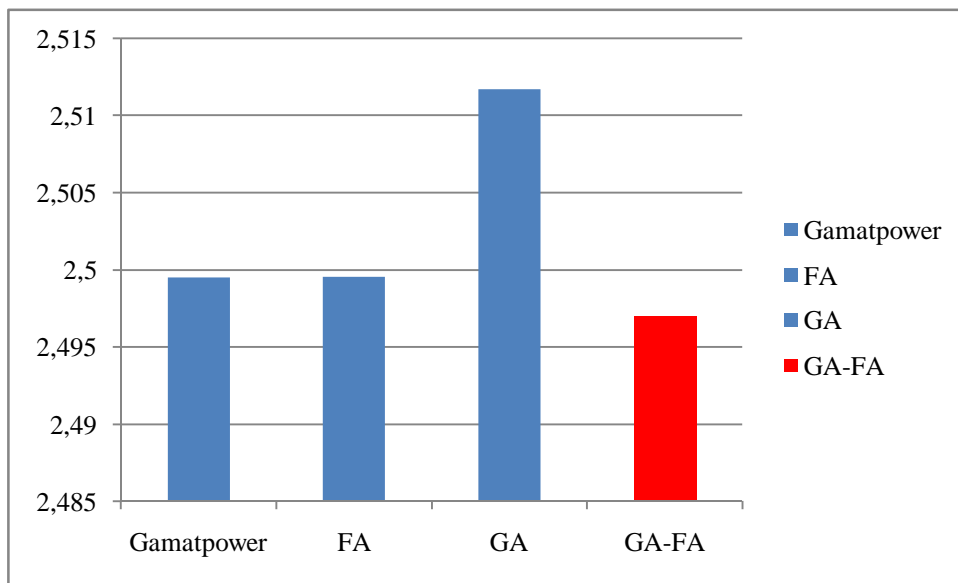


Fig V.10. Coût du méga watt heure en dollars donné par l'approche GA-FFA et sa comparaison aux autres méthodes pour le système 57-nœuds IEEE, ($P_D=1250.8$ MW, $P_L = 19.06$ MW)




Fig V.11. L'évolution du coût de production au cours des itérations avec des pertes nulles




Fig V.12. L'évolution du coût de production au cours des itérations avec des pertes constantes 19.06 MW

V.3.2.3 Conclusion

L'algorithme firefly (FFA) est une méthode de recherche heuristique relativement récente qui est basée sur l'idée d'un comportement de collaboration au sein des populations biologiques. La FFA est similaire à l'algorithme génétique (GA) dans le sens où elles sont des approches dont leur recherche est fondée sur la population et que les deux dépendent de l'échange d'informations entre les membres de la population pour améliorer leurs processus de recherche en utilisant des règles probabilistes.

L'objectif de cette recherche est la combinaison de ces deux méthodes pour améliorer leur efficacité (qualité de la solution)

La faisabilité de l'algorithme proposé est démontrée sur le système IEEE 57-nœuds. Les résultats montrent que l'algorithme proposé est applicable et efficace dans la solution des problèmes EPD qui tiennent compte des caractéristiques non linéaires des systèmes d'alimentation. GA-FFA peut générer une solution de qualité efficace élevée et avec une convergence plus stable.

L'avantage de l'approche GA-FFA par rapport aux autres méthodes est la flexibilité de la modélisation, la fiabilité et la convergence rapide.

V.3.3 Application de la méthode FFA-ABC

La méthode proposée a été testée sur deux réseaux électriques IEEE 30-nœuds et IEEE 57-nœuds. Avec la fonction objectif de l'équation (V.6).

V.3.3.1. Le réseau IEEE 30-nœuds.

Le système se compose de 41 lignes, 6 générateurs, 4 transformateurs de changement de prise et de banques de condensateurs shunt montées dans 9 nœuds.

Le tableau V.5 montre les paramètres techniques et économiques des six générateurs du système IEEE 30-nœuds (Voir figure V.13). La demande totale de la charge du système est 283,4000 MW.

V.3.3.2. Le réseau IEEE 57-nœuds.

Le système a 80 circuits de transmission. Le schéma unifilaire de ce système est représenté sur la figure V.14 et les données détaillées sont données dans [35]. Les valeurs des coefficients de coûts de carburant sont données dans le tableau V.6, la demande de la charge totale du système est 1250,8 (MW), et 7 générateurs doivent répondre à cette demande de la charge économiquement.

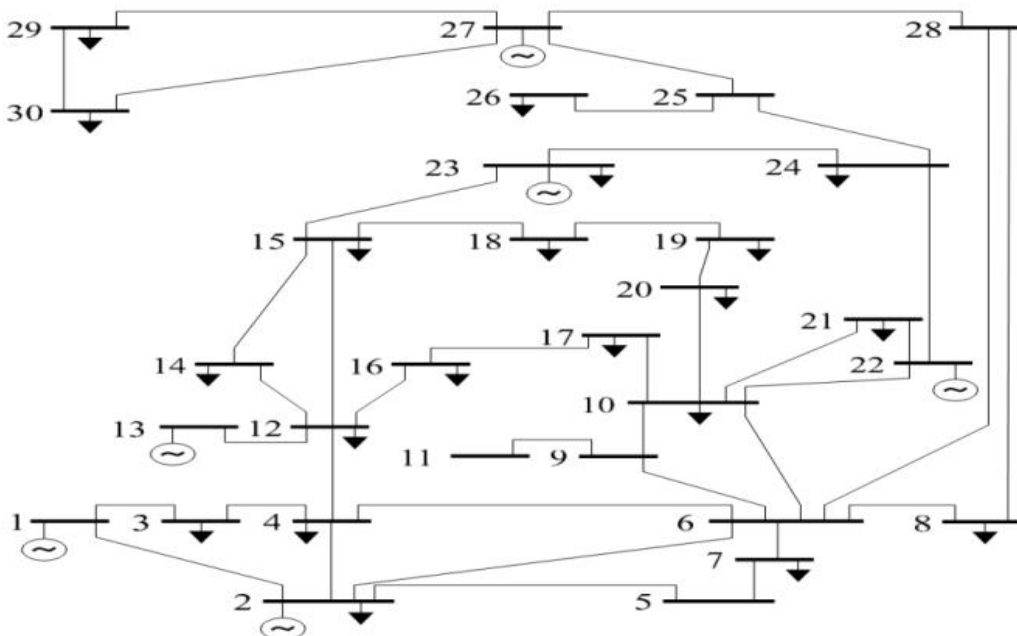


Fig.V.13 Diagramme unifilaire du système IEEE 30-nœuds

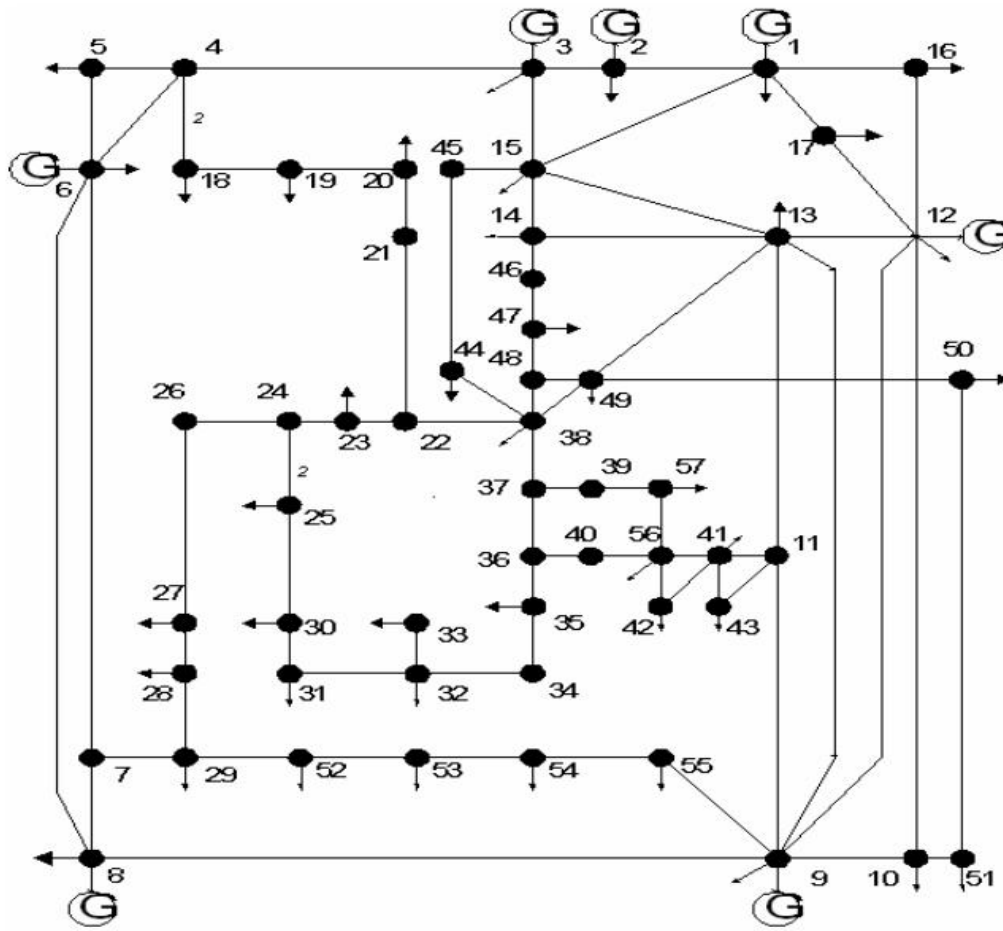


Fig.V.14. Diagramme unifilaire du système IEEE 57-nœuds

Le tableau V.10 présente les résultats de chaque méthode à part qui sont les méthodes ABC et FFA, ainsi que les résultats de l'approche hybride FFA-ABC appliquée à un réseau de 30 nœuds avec une demande de puissance 283.40MW et des pertes constantes de 9,459 MW.

Tableau V.10

Résultats de l'optimisation par l'approche FFA-ABC pour le système IEEE 30-nœuds

Bus	MDEOPF [36]	PSO	ABC	FFA	FFA-ABC
P_{G1}	175.974	178.061	178.061	178.710	190.382
P_{G2}	48.884	54.056	54.056	49.017	47.800
P_{G5}	21.510	19.836	19.836	22.151	19.399
P_{G8}	22.240	14.890	14.890	14.112	11.862
P_{G11}	12.251	12.427	12.427	13.587	15.262
P_{G13}	12.000	13.129	13.129	14.693	14.024
P_L	9.459	9.459	9.459	9.459	9.459
$t(s)$	23.070	14.961	13.768	12.373	10.219
Cost (\$/hr)	802.376	801.105	801.105	801.588	799.270




Fig V.15. Coût du mégawatt heure en dollars donné par l'approche FA-ABC et sa comparaison aux autres méthodes pour un système IEEE 30 nœuds

Tableau.V.11.
Comparaison entre différentes méthodes pour le système IEEE 57-nœuds

Bus	MatpowerOPF [37]	GAOPF [37]	GAMatpowerOPF [37]	PSO	FFA-ABC
P_{G1}	265.330	277.127	277.149	311.212	301.890
P_{G2}	100.000	100.000	100.000	97.232	97.468
P_{G3}	140.000	140.000	140.000	122.835	139.980
P_{G6}	100.000	100.000	100.000	98.598	92.183
P_{G8}	276.970	277.260	277.282	269.168	236.501
P_{G9}	100.000	100.000	100.000	99.965	99.115
P_{G12}	287.560	275.403	275.403	266.826	301.582
P_L	16.060	19.06	19.060	19.060	19.060
Cost (\$/h)	3176.390	3175.579	3173.982	3156.684	3149.614




Fig V.16. Coût du méga watt heure en dollars donné par l'approche FA-ABC et sa comparaison aux autres méthodes pour un système IEEE 57 nœuds

Les tableaux V.10, V.11 et les figures V.15, V.16, illustrent les résultats de l'application des méthodes ABC, FFA, PSO et la FFA-ABC ainsi que les résultats d'autres chercheurs [36] – [37] avec deux réseaux électriques. Ces résultats montrent clairement l'efficacité et la performance de la FFA-ABC sur les autres méthodes soit en matière de la valeur du coût ou en matière du temps de convergence comme indiqué dans les Figures V.17, V.18, V.19 et V.20.




Fig. V.17. Les valeurs de la fonction coût dans différentes itérations pour la méthode FFA-ABC (IEEE 30-nœuds)




Fig.V.18. Les valeurs de la fonction coût dans différentes itérations pour la méthode ABC (IEEE 30-nœuds)




Fig.V.19. Les valeurs de la fonction coût dans différentes itérations pour la méthode PSO (IEEE 57-nœuds)




Fig. V.20. Les valeurs de la fonction coût dans différentes itérations pour la méthode FFA-ABC (IEEE 57-nœuds)

V.3.3.3 Conclusion

Cette unité présente une méthodologie pour résoudre le problème de l'EPD en utilisant deux méthodes métaheuristiques basée sur le FFA et l'ABC. La méthode développée a été testée sur le système IEEE 30-nœuds et le système IEEE 57-nœuds. Les cas étudiés ont montré que la méthode est robuste et peut fournir une solution optimale avec un temps de calcul rapide et un petit nombre d'itérations.

V.3.4 Application de la méthode GA-PSO-SQP

L'approche proposée GA-PSO-SQP basée sur la recherche globale et locale, est mise au point dans l'environnement Matlab utilisant la version 7.04 et testée sur deux réseaux:

V.3.4.1 Réseau 1 : (Réseau IEEE 30 nœuds)

Les normes IEEE 30 nœuds, les données des nœuds, les données des générateurs et les limites minimales et maximales pour les variables de contrôle sont présentées dans les tableaux (V.12 et V.13).

Le système de test dispose de six générateurs aux nœuds 1, 2, 5, 8, 11 et 13 et quatre transformateurs avec rapport de prise nominale aux lignes 6-9, 6-10, 4-12 et 28-27. En outre, les nœuds 10, 12, 15, 17, 20, 21, 23, 24 et 29 ont été choisis comme les nœuds de

compensation shunt VAR. La demande totale du système est 283,4 MW à la base de 100 MVA. Les tensions maximales et minimales de tous les bus de charge sont considérées de 1,05 à 0,95 en pu, voir tableau V.13 [38]. L'approche proposée a été appliquée pour résoudre différents cas:

Tableau V.12.
Coefficients de carburant et d'émission des générateurs pour le réseau IEEE 30 nœuds [38]

		P_{G1}	P_{G2}	P_{G5}	P_{G8}	P_{G11}	P_{G13}
Coefficients du carburant	a_i	0.00375	0.01750	0.06250	0.00834	0.02500	0.02500
	b_i	2.0	1.75	1.00	3.25	3.00	3.00
	c_i	0.0	0.0	0.0	0.0	0.0	0.0
Coefficients de l'émission	a_i	0.06490	0.05638	0.04586	0.03380	0.04586	0.05151
	β_i	-0.05554	-0.06047	-0.05094	-0.03550	-0.05094	-0.05555
	γ_i	0.04091	0.02543	0.04258	0.05326	0.04258	0.06131
	ε_i	0.0002	0.0005	0.000001	0.002	0.000001	0.00001
	λ_i	2.857	3.333	8.000	2.000	8.000	6.667

Tableau V.13.
Les limites des variables de contrôle [39]

	Min	Max
P_{G1} (MW)	50	200
P_{G2} (MW)	20	80
P_{G5} (MW)	15	50
P_{G8} (MW)	10	35
P_{G11} (MW)	10	30
P_{G13} (MW)	12	40
V_{G1} (p.u.)	0.95	1.1
V_{G2} (p.u.)	0.95	1.1
V_{G3} (p.u.)	0.95	1.1
V_{G4} (p.u.)	0.95	1.1
V_{G5} (p.u.)	0.95	1.1
V_{G6} (p.u.)	0.95	1.1
TCL_{11}	0.90	1.1
TCL_{12}	0.90	1.1
TCL_{15}	0.90	1.1
TCL_{36}	0.90	1.1
QC_{10} (p.u.)	0.00	0.05
QC_{12} (p.u.)	0.00	0.05
QC_{15} (p.u.)	0.00	0.05
QC_{17} (p.u.)	0.00	0.05
QC_{20} (p.u.)	0.00	0.05
QC_{21} (p.u.)	0.00	0.05
QC_{23} (p.u.)	0.00	0.05
QC_{24} (p.u.)	0.00	0.05
QC_{29} (p.u.)	0.00	0.05

V.3.4.1.1 Cas 1: Minimisation quadratique du coût de carburant

Dans ce cas, la fonction objectif est d'une forme quadratique Eq (V.6). La minimisation du coût de carburant a été diminuée à 790.8299\$ / h (soit 14,0831%) dans le cas 1 en comparaison à 920,4639 MW pour le cas 2. Les résultats obtenus à partir de la GA-PSO-SQP sont comparés avec d'autres méthodes décrites dans la littérature. Cette comparaison est présentée dans le tableau V.14. On peut voir que le coût minimal de la puissance active totale obtenue par le procédé est de 790,8299\$ / h, ce qui est moins que les autres méthodes, [38], GA-OPF et FGA [40], PEI [41], TS [42], EP [14], Hybrid MPSO-SFLA, PSO, SFLA [43].

Tableau. V.14.

Comparaison des résultats des différents algorithmes pour la fonction objectif coût du système IEEE 30-nœuds

Méthodes	P_{G1} (MW)	P_{G2} (MW)	P_{G3} (MW)	P_{G8} (MW)	P_{G11} (MW)	P_{G13} (MW)	Loss (MW)	Cost (\$/h)	T (S)
MSFLA [38]	179.19	48.98	20.45	20.92	11.58	11.95	9.69	802.28	/
GA-OPF [40]	174.83	48.88	23.78	20.2	13.14	12.22	/	803.92	/
FGA [40]	175.14	50.35	21.45	21.18	12.67	12.11	9.49	802	/
IEP [41]	176.24	49.01	21.5	21.81	12.34	12.01	10.87	802.47	594.08
TS [42]	176.04	48.76	21.56	22.05	12.44	12	/	802.29	/
EP [14]	173.85	50	21.39	22.63	12.93	12		802.62	/
MPSO-SFLA [43]	180.53	52.09	22.78	15.49	10	12.05	9.54	801.75	18.17
PSO [43]	180.23	52.09	22.81	15.62	10	12.21	9.56	801.89	20.19
SFLA [43]	181.06	52.17	22.47	15.35	10	12.07	9.72	802.21	20.75
GA-PSO-SQP	183.33	40.81	19.20	25.53	11.12	12.61	9.22	790.82	10.92




Fig V.21. Coût du méga watt heure en dollars donné par l'approche GA-PSO-SQP et sa comparaison aux autres méthodes pour un système IEEE 30 nœuds

V.3.4.1.2 Cas 2: La minimisation des émissions

La fonction objectif choisie était la minimisation totale du coût des émissions E tel que définie dans l'équation (V.9). Le tau total des émissions a été diminué à 0,198366 tonne/h (soit 47,8307%) dans le cas 2 en comparaison à 0,3630 tonne/h pour le cas 1. Les résultats obtenus à partir de la GA-PSO-SQP sont comparés à d'autres méthodes décrites dans la littérature. Cette comparaison est présentée dans le tableau V.15, où l'on constate que les résultats sont meilleurs que les procédés MSFLA, SFLA, PSO [38].

Tableau V.15.
La comparaison des résultats obtenus pour le cas 2 pour le système IEEE 30-nœuds.

Method	Total emissions (ton/h)
MSFLA [38]	0.2056
SFLA [38]	0.2063
GA [38]	0.21170
PSO [38]	0.2096
GA-PSO-SQP	0.198366




Fig V.22. Tau des émissions en ton/h donné par l'approche GA-PSO-SQP et sa comparaison aux autres méthodes pour un système IEEE 30 nœuds

V.3.4.1.3 Cas 3: La minimisation des émissions et du coût simultanément

Dans l'optimisation mono-objectif, il existe un optimum global, tandis que dans le cas multiobjectif aucune solution optimale n'est clairement définie, mais plutôt un ensemble d'optimums, ce qui constitue ce que l'on appelle le front de Pareto-optimal [44]. Dans ce cas, toutes les contraintes concernant le coût de carburant et les émissions polluantes sont prises en compte. Le problème EPD doit être considéré comme un problème multiobjectif.

La meilleure solution de compromis en utilisant GA-PSO-SQP est donnée dans le tableau V.16, où le coût du carburant est réduit de près de 11,5431 % par rapport à 920,4639 \$/h dans le cas 2 et l'émission est réduite d'environ 24,5859 % par rapport à 0,3803 tonne/h dans le cas 1. Dans ce cas, deux objectifs concurrents, à savoir, le coût du carburant et des émissions, ont été considérés, ce problème d'optimisation multiobjectif a été bien résolu par l'approche proposée (GA-PSO-SQP).

Les caractéristiques de convergence pour le coût et l'émission sont présentées dans les figures. V.26 et V.27, respectivement, le nombre d'itérations, après lequel le programme converge vers une solution presque optimale, est inférieur à 60 itérations. Le tableau V.16 répertorie les meilleurs résultats de simulation pour les trois cas.

Tableau V.16.
Résultats de l'optimisation par l'approche GA-PSO-SQP pour le système IEEE 30-nœuds

	Best Cost	Best emission	Best (cost, emission).
P_{G1} (MW)	193.569342	80.713787	122.4802
P_{G2} (MW)	34.492244	63.887810	68.43066
P_{G5} (MW)	16.160296	48.613229	22.4347
P_{G8} (MW)	12.430008	26.824138	27.9433
P_{G11} (MW)	11.737413	29.606316	17.0556
P_{G13} (MW)	19.793657	38.213197	27.5520
V_{G1} (p.u.)	0.9567	1.0177	1.0177
V_{G2} (p.u.)	1.0981	1.0693	1.0693
V_{G3} (p.u.)	1.0039	1.0996	1.0996
V_{G4} (p.u.)	1.0740	1.0633	1.0633
V_{G5} (p.u.)	1.0742	0.9728	0.9728
V_{G6} (p.u.)	1.0407	1.0964	1.0964
TCL_{11}	1.0383	1.0828	1.0828
TCL_{12}	0.9200	1.0512	1.0512
TCL_{15}	1.0260	1.0871	1.0871
TCL_{36}	0.9729	1.0946	1.0946
QC_{10} (p.u.)	0.0499	0.0277	0.0277
QC_{12} (p.u.)	0.0416	0.0296	0.0296
QC_{15} (p.u.)	0.0413	0.0418	0.0418
QC_{17} (p.u.)	0.0489	0.0407	0.0407
QC_{20} (p.u.)	0.0492	0.0553	0.0553
QC_{21} (p.u.)	0.0498	0.0460	0.0460
QC_{23} (p.u.)	0.0447	0.0439	0.0439
QC_{24} (p.u.)	0.0489	0.0491	0.0491
QC_{29} (p.u.)	0.0391	0.0428	0.0428
Fuel cost (\$/h)	790.8299	920.4639	814.211
Emission (ton/h)	0.3803	0.1983	0.2867
real loss (MW)	4.7830	4.4585	2.4967
$T(S)$	10.92	10.6424	10.9076

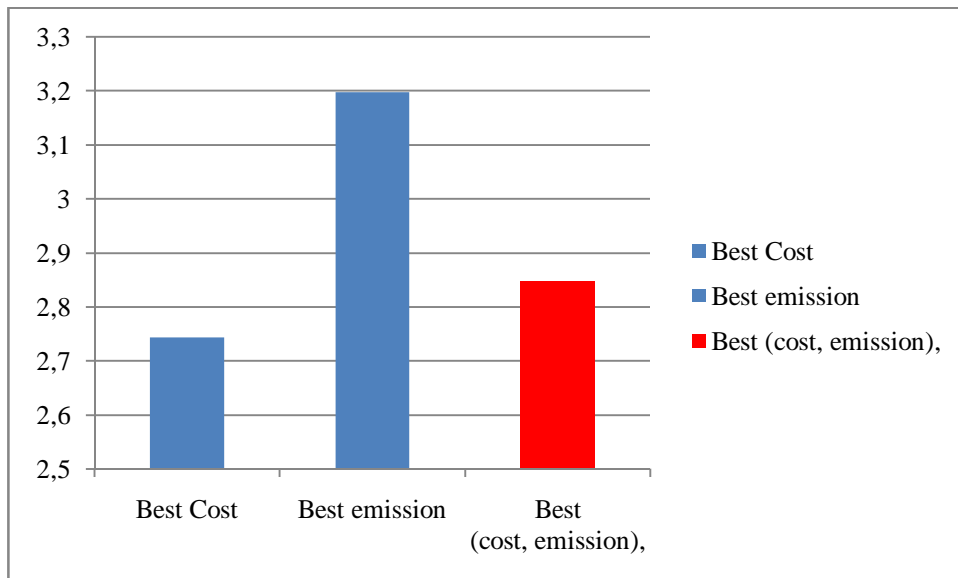


Fig V.23. Coût du carburant en (\$/MWh) donné par l'approche GA-PSO-SQP pour différents objectifs sur un système IEEE 30 nœuds




Fig V.24. Tau des émissions en (ton/h) donné par l'approche GA-PSO-SQP pour différents objectifs sur un système IEEE 30 nœuds

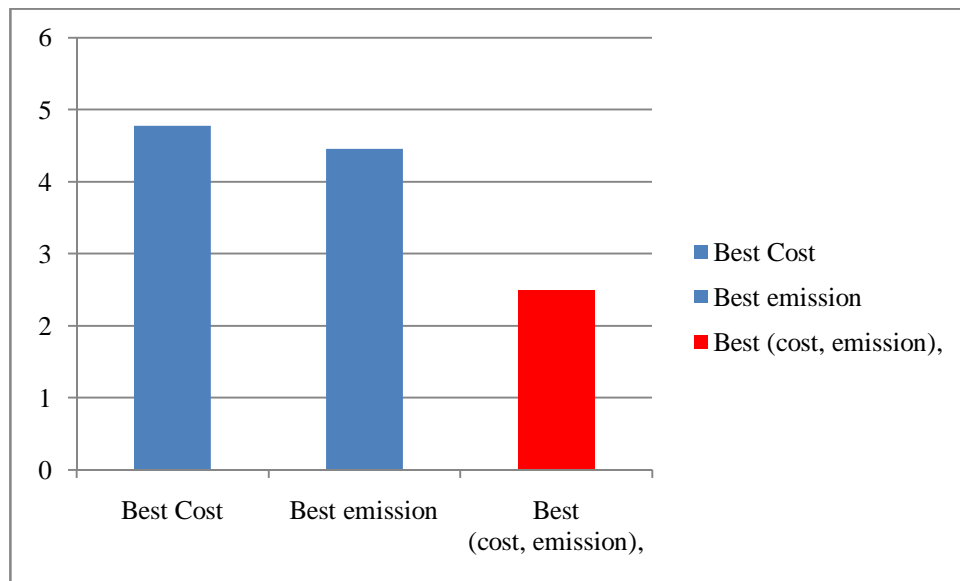


Fig V.25. Les pertes en (MW) donné par l'approche GA-PSO-SQP pour différents objectifs sur un système IEEE 30 nœuds




Fig V.26. Graphe de convergence de GA-PSO-SQP, système IEEE 30 nœuds (cas 1).




Fig V.27. Graphe de convergence de GA-PSO-SQP, système IEEE 30 nœuds (cas 2).

V.3.4.2 Réseau 2:

Cette approche a été également testée sur le réseau algérien. Ce réseau se compose de 59 bus, 83 branches (lignes et transformateurs) et 10 générateurs et peut-être connecté à un parc éolien, d'une capacité de 10 MW, sur une superficie de 30 hectares, le site où le parc éolien est situé est Kabertene, 73 km au nord de la ville d'Adrar, dans le Sahara algérien. Les tableaux V.17 et V.18 montrent les paramètres techniques et économiques des dix générateurs du réseau, sachant que le générateur du nœud №13 n'est pas en service, nous avons considéré trois cas:

Tableau V.17.
Paramètres des générateurs du réseau algérien 59 nœuds. [45]

Bus	p_{Gi}^{min} (MW)	p_{Gi}^{max} (MW)	Q_{Gi}^{min} (Mvar)	Q_{Gi}^{max} (Mvar)	a_i (\$/MW2hr)	b_i (\$/MWhr)	c_i (\$/h)
1	8	72	-10	15	0.0085	1.50	0
2	10	70	-35	45	0.0170	2.50	0
3	30	510	-35	55	0.0085	1.50	0
4	20	400	-60	90	0.0085	1.50	0
13	15	150	-35	48	0.0170	2.50	0
27	10	100	-20	35	0.0170	2.50	0
37	10	100	-20	35	0.0030	2.00	0
41	15	140	-35	45	0.0030	2.00	0
42	18	175	-35	55	0.0030	2.00	0
53	30	450	-100	160	0.0085	1.50	0

Tableau V.18.
Paramètres d'émissions des générateurs du réseau algérien 59 nœuds. [45]

Bus	α_i	β_i	γ_i	ε_i	λ_i
P_{G1}	6.490	-5.554	4.091	2.00e-04	2.857
P_{G2}	5.638	-6.047	2.543	5.00e-04	3.333
P_{G3}	4.586	-5.094	4.258	1.00e-06	8.000
P_{G4}	3.380	-3.550	5.326	2.00e-03	2.000
P_{G5}	4.586	-5.094	4.258	1.00e-06	8.000
P_{G6}	5.151	-5.555	6.131	1.00e-05	6.667
P_{G7}	6.490	-5.554	4.091	2.00e-04	2.857
P_{G8}	5.638	-6.047	2.543	5.00e-04	3.333
P_{G9}	4.586	-5.094	4.258	1.00e-06	8.000
P_{G10}	3.380	-3.550	5.326	2.00e-03	2.000

V.3.4.2.1 Cas 1 (minimisation du coût et des émissions simultanément) :

Application des méthodes GA-PSO-SQP, GA, PSO et GA-PSO pour optimiser la fonction bi-objectif (la fonction coût et la fonction des émissions)

Tableau V.19.
Comparaison de différentes méthodes pour le cas 1 dans le réseau algérien.

	GA	PSO	GA-PSO	GA-PSO-SQP
P_{G1}	68.126777	56.062191	61.874894	65.818901
P_{G2}	48.505156	36.298777	66.502307	65.651880
P_{G3}	64.223009	96.221301	105.401727	92.823647
P_{G4}	117.461719	114.803634	113.549690	95.659666
P_{G5}	0.000000	0.000000	0.000000	0.000000
P_{G6}	68.030481	85.303534	46.942235	47.618095
P_{G7}	55.748201	55.035350	50.352166	43.497912
P_{G8}	93.143996	92.425753	77.923946	79.931069
P_{G9}	58.789367	83.739087	73.939913	84.198103
P_{G10}	128.082905	81.010297	106.232043	126.960411
<i>Fuel cost</i> (\$/h)	1769.2	1763.6	1756.0	1753.1
<i>Emission</i> (ton/h)	0.459967	0.469345	0.458914	0.456543
<i>real loss</i> (MW)	18.0116	16.7999	18.6189	18.0597
<i>T(S)</i>	3.60362	2.80961	2.14788	1.61922




Fig V.28. Coût du méga watt heure en dollars donné par l'approche GA-PSO-SQP et sa comparaison aux autres méthodes pour le réseau algérien (1^{er} cas)

D'après le tableau V.19, nous remarquons que le coût et les émissions ont sensiblement diminué par l'application de la méthode GA-PSO-SQP, par rapport à d'autres méthodes GA, PSO et GA-PSO. Nous notons également que le temps de la convergence a été nettement amélioré.

V.3.4.2.2 cas 2 (minimisation du coût et des émissions séparément) :

Application de l'approche sous trois formes:

- 1) La minimisation du coût de carburant.
- 2) La minimisation des émissions.
- 3) Combinaison entre la minimisation du coût et les émissions.

Tableau V.20.

La comparaison des résultats obtenus pour les différentes formes du cas 2 sur le réseau algérien

	Best Cost GA-PSO-SQP	Best Emission GA-PSO-SQP	Best Compromise GA-PSO-SQP (cost, emission)	Best Compromise SLP EED [45]
<i>Fuel cost</i> (\$/h)	1734.299	1823.9	1753.1	1786.000
<i>Emission</i> (ton/h)	0.4844	0.4138	0.456543	0.4746
<i>real loss</i> (MW)	18.3579	18.2589	18.0597	18.83
<i>T(S)</i>	1.84081	1.19165	1.61922	/

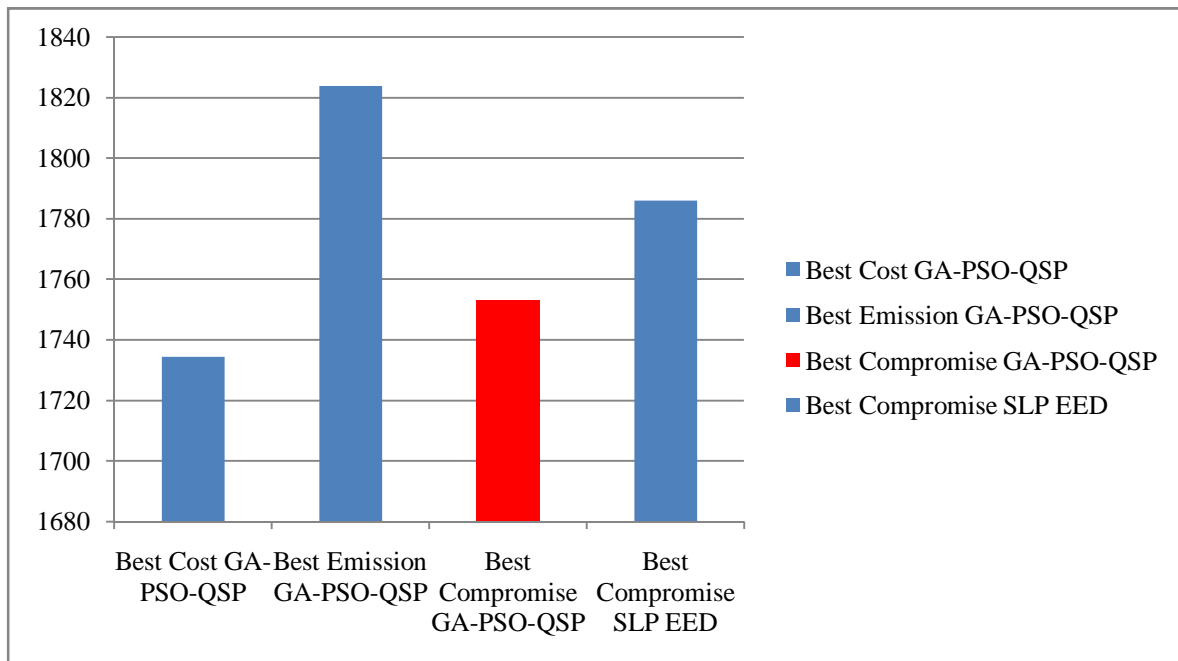


Fig V.29. Coût du carburant en (\$/h) donné par l'approche GA-PSO-SQP et sa comparaison avec la méthode SLP EED pour différents objectifs sur le réseau algérien




Fig V.30. Taux des émissions en (ton/h) donné par l'approche GA-PSO-SQP et sa comparaison avec la méthode SLPEED pour différents objectifs sur le réseau algérien




Fig V.31. Les pertes en (MW) donné par l'approche GA-PSO-SQP et sa comparaison avec la méthode SLP EED pour différents objectifs sur le réseau algérien

Dans le tableau V.20, on peut voir que le coût du carburant et les émissions sont des objectifs contradictoires, le coût augmente lorsque l'émission est au minimum. De la forme 3 nous avons la solution de compromis, la minimisation du coût et des émissions en même temps.

V.3.4.2.3 cas 3 (injection de l'énergie éolienne) :

Ici, la méthode GA-PSO-SQP est appliquée sur la fonction multiobjectif, pour améliorer le coût du carburant et les émissions, en tenant en compte l'injection de l'énergie éolienne ($P_w = 10$ MW) dans le réseau.

Tableau V.21.
Comparaison des différents cas de l'EPD dans le réseau algérien avec l'énergie éolienne

	25% P_w	50% P_w	75% P_w	100% P_w
P_{G1}	61.358740	47.011686	65.289221	57.030973
P_{G2}	51.441161	54.520379	56.343983	47.839738
P_{G3}	55.236052	82.499354	103.410860	78.253892
P_{G4}	139.102679	107.483468	112.572579	115.215837
P_{G5}	0.000000	0.000000	0.000000	0.000000
P_{G6}	61.472507	55.909879	58.379614	56.507420
P_{G7}	78.389920	58.586672	70.026283	51.726683
P_{G8}	80.256252	66.931147	58.351043	61.086463
P_{G9}	82.083964	106.413307	76.198093	89.105433
P_{G10}	90.291148	120.541670	94.142998	132.014652
Fuel cost (\$/h)	1741.6	1736.0	1723.5	1715.4
Emission (ton/h)	0.439487	0.434377	0.429227	0.425959
real loss (MW)	18.0324	20.7976	18.1147	14.6811
T(S)	1.49782521	1.19782521	0.9782521	0.72842




Fig V.32. Coût du méga watt heure en dollars donné par l'approche GA-PSO-SQP pour le réseau algérien avec introduction de l'énergie éolienne (3ème cas)

D'après le tableau V.21, nous pouvons voir que la méthode proposée GA-PSO-SQP avec l'injection de l'énergie éolienne dans le réseau peut obtenir la meilleure solution. Par exemple, si le système de l'énergie éolienne ne fonctionne qu'à 25% de sa capacité, nous pouvons économiser 14,4000 \$/h du coût du carburant et 0,0194 Ton/h des émissions de gaz, et dans les conditions favorables à savoir lorsque le système fonctionner à 100% de sa capacité, nous pouvons économiser jusqu'à 40,6000 \$/h du coût du carburant et 0,0330 Ton/h des émissions de gaz.

V.3.4.2.4 Conclusion

Ce cas propose une méthode hybride qui comporte deux métaheuristiques et une méthode classique, à savoir, l'algorithme génétique (GA), l'optimisation par essaim de particules (PSO) et la programmation quadratique séquentielle (SQP). Cette approche est utilisée pour résoudre le problème de l'écoulement de puissance économique (EPD), y compris le coût du carburant et les émissions de polluants doivent être minimisées simultanément tout en satisfaisant certaines contraintes du système. L'algorithme proposé a été testé sur le système IEEE 30-nœuds et une partie du réseau algérien pour vérifier son efficacité. L'approche proposée semble être très efficace, en particulier pour sa convergence rapide.

L'efficacité de l'approche proposée est démontrée en comparant sa performance avec d'autres algorithmes d'optimisations multiobjectifs évolutifs. Les résultats des calculs révèlent que l'approche GA-PSO-SQP est très utile puisque son application sur le réseau IEEE 30-nœuds nous a donné 790,82 \$/h et 0,1983 ton/h (Les meilleurs résultats dans la littérature sont

801,75 \$/h et 0,2056 ton/h), l'application de la méthode sur le réseau algérien 59 nœuds nous a donné 1,734.299 \$/h et 0,4138 ton/h (les meilleurs résultats dans la littérature sont 1,786.00 \$/h et 0,4746 ton/h).

En outre, les résultats confirment le bon potentiel de la méthode dans le traitement des problèmes multiobjectifs, le procédé peut être appliqué à d'autres problèmes d'optimisation. Le problème est abordé en tenant compte de l'injection de l'énergie éolienne dans le réseau électrique. Les résultats montrent que la puissance de l'éolienne a contribué de manière significative à l'amélioration de la fonction multiobjectif et la minimisation du coût du carburant et des émissions des gaz.

CONCLUSION GÉNÉRALE

Cette thèse a présenté une nouvelle approche pour résoudre l'EDP basée sur les données des réseaux et la technique multiagent. Cette approche repose sur la technique de l'hybridation c'est-à-dire combiner deux ou trois méthodes métaheuristiques. Avec les progrès actuels des techniques métaheuristiques et l'application de l'approche proposée, le problème du dispatching économique peut être résolu efficacement en aboutissant à des solutions de haute qualité.

Dans ce travail, on a commencé dans la première partie par décrire le problème brièvement tout en signalant les contraintes et les difficultés que l'on peut rencontrer en essayant de résoudre ce problème.

Dans la deuxième partie une modélisation globale du problème de l'écoulement de puissance optimal a été donnée par la modélisation et la définition techno-économique des différentes centrales thermiques, dont on doit minimiser leurs fonctions de coût. Ainsi, le problème de l'écoulement de puissance optimal a été formulé par la définition des types de fonctions objectifs, à savoir le coût du combustible quadratique avec un ou plusieurs types de combustibles, et le coût à la présence de l'effet des valves d'admission, la minimisation de la tension des jeux de barres de charge, la minimisation des pertes actives, tout en déterminant toutes les variables de contrôle qui influent sur l'optimisation. Enfin, on a défini les contraintes d'égalités par la résolution des équations de l'écoulement de puissance qui sont satisfaites par l'égalité entre la production, la demande et les pertes actives. Plusieurs contraintes d'inégalités à maintenir pour satisfaire le fonctionnement et la sécurité du réseau électrique. Parmi ces contraintes, on trouve les limites sur les variables de contrôle, les limites des tensions des jeux de barres de charge et les limites des puissances transmises dans les lignes de transport d'énergie électrique.

Dans la troisième partie, nous avons présenté les problèmes de l'optimisation mono-objectif et multiobjectif. Un ensemble de méthodes de résolution de ces problèmes a été présenté, notamment les métaheuristiques. Grâce à leur simplicité d'emploi et leur forte modularité les métaheuristiques ont donné des solutions à des variétés de problèmes et surtout grâce à leur capacité d'adaptation et la grande possibilité d'hybridation qui a mené à de meilleures performances pour la résolution des problèmes extrêmement difficiles.

Dans la quatrième partie, nous avons présenté en premier lieu les méthodes utilisées dans ce travail à savoir les algorithmes génétiques, l'optimisation par essais particuliers (PSO), la programmation quadratique séquentielle (SQP), l'algorithme Firefly, l'algorithme artificiel de colonies des abeilles (ABC) et l'algorithme de singe (MA). En deuxième lieu, nous avons présenté la technique d'hybridation à savoir entre les méthodes AG-PSO-SQP, GA-FFA, FFA-ABC, GA-MA.

La dernière partie a été consacrée à l'application de cette technique pour résoudre ce problème. On a commencé par la méthode GA-FFA où la faisabilité de l'algorithme proposé est démontrée sur le système IEEE 57-nœuds avec une demande de 1250.8 MW. Les résultats montrent que l'algorithme proposé est applicable et efficace dans la solution des problèmes EPD qui tiennent compte des caractéristiques non linéaires des systèmes d'alimentation. La GA-FFA peut générer une solution de qualité avec efficacité élevée et avec une convergence plus stable. Une autre technique qui est la FFA-ABC a été testée sur le système IEEE 30 nœuds avec une demande de 283.4 MW et sur le système IEEE 57 nœuds avec une demande de 1250.8 MW. Les cas étudiés ont montré que la méthode est robuste et peut fournir une solution optimale avec un temps de calcul rapide et un petit nombre d'itérations d'ailleurs si on la compare à la méthode GA-FFA on constate clairement qu'elle donne de meilleurs résultats. La méthode GA-MA a été testé sur un système de 10 générateurs avec une demande de 2400 MW, 2500 MW et 2600 MW, dans ce système, on prend en compte plusieurs types de carburant et l'effet des soupapes d'admission. Les résultats numériques et la vitesse de convergence montrent que cette méthode est très efficace aussi dans ce genre de problème et peut contribuer à économiser des milliers de dollars par an.

D'autre part on a proposé une technique d'hybridation de deux métaheuristiques et une méthode classique, à savoir, l'algorithme génétique (GA), l'optimisation par essaim de particules (PSO) et la programmation quadratique séquentielle (SQP). Cette approche est utilisée pour résoudre le problème de minimiser le coût du carburant et les émissions de polluants simultanément tout en satisfaisant certaines contraintes du système. L'algorithme proposé a été testé sur le système IEEE 30-nœuds et une partie du réseau algérien pour vérifier son efficacité. L'approche proposée est très efficace, en particulier pour sa convergence rapide.

L'efficacité de l'approche proposée est démontrée en comparant sa performance avec d'autres algorithmes d'optimisations multiobjectifs évolutifs. Les résultats des calculs révèlent que

l'approche GA-PSO-SQP présente d'excellentes caractéristiques de convergence et est supérieure aux autres algorithmes d'optimisation. En outre, les résultats confirment son grand potentiel dans le traitement des problèmes multiobjectifs, le procédé peut être donc appliqué à d'autres problèmes d'optimisation.

Enfin, on a procédé à l'injection de l'énergie éolienne dans le réseau électrique. Les résultats montrent que la puissance de l'éolienne a contribué de manière significative à la minimisation du coût du carburant et des émissions des gaz d'où on conclut que les énergies renouvelables sont très promettant dans le domaine de la production de l'énergie électrique sur le plan économique et environnemental.

Perspectives

La robustesse et l'efficacité des méthodes métaheuristiques dans la recherche pour modéliser, analyser ou résoudre les problèmes, ont été vérifiées dans la littérature.

Dans notre travail, on s'est concentré plus particulièrement sur la technique de l'hybridation. Cette approche, et à travers les résultats de ce travail a amélioré d'une façon très nette les qualités de ces méthodes et promet de résoudre beaucoup de problèmes dans le domaine scientifique que ce soit dans la physique ou dans les autres disciplines.

On espère ainsi que notre travail sera d'une aide utile aux chercheurs qui sont intéressés par ces techniques.

Il faut noter que durant tout ce travail, on a considéré que la demande est toujours constante ce qui n'est pas vrai réellement. La demande est très variable, elle change nettement d'une heure à une autre et par conséquent le dispatching doit être dynamique pour s'approcher plus de la réalité.

Donc, on espère que le travail sera continué dans ce sens.

REFERENCES

1. Carpentier J (1962) Contribution to the economic dispatch problem. *Bull Soc France Electr* 3:431–447
2. Vanderbei JR, Shanno FD (1999) An interior-point algorithm for nonconvex nonlinear programming. *Comput Optim Appl* 13:231–252
3. Bottero MH, Caliana FD, Fahmideh Vojdani AR (1982) Economic dispatch using the reduced hessian. *IEEE Trans on Power Apparatus Syst* 101:3679–3688
4. Reid GE, Hasdorf L (1973) Economic dispatch using quadratic programming. *IEEE Trans Power Apparatus Syst* 92:2015–2023
5. Stott B, Hobson E (1978) Power system security control calculation using linear programming. *IEEE Trans Power Apparatus Syst* 97:1713–1731
6. Sun DI, Ashley B, Brewer B, Hughes A, Tinney W (1984) Optimal power flow by Newton approach. *IEEE Trans Power Systems* 103:2864–2880
7. Momoh JA, Zhu JZ (1999) Improved interior point method for OPF problems. *IEEE Trans on Power Syst* 14:1114–1120
8. Bahiense L, Oliveira GC, Pereira M, Granville S (2001) A mixed integer disjunctive model for transmission network expansion. *IEEE Trans Power Syst* 16:560–565
9. Dusonchet YP, El-Abiad AH (1997) Transmission planning using discrete dynamic optimization. *IEEE Trans Power Apparatus Syst* 92:1358–1371
10. Haffner S, Monticelli A, Garcia A, Mantovani J, Romero R (2000) Branch and bound algorithm for transmission system expansion planning using transportation model. *IEEE Proc Gener Transm Distrib* 147:149–156
11. Glover F (1989) Tabu search: part i. *ORSA J Comput* 1:190–206
12. Kirkpatrick S, Gelatt CD, Vecchi MP (1983) Optimisation by simulated annealing. *Science* 220:671–679
13. Lai LL, Ma JT, Yokoyama R, Zhao M (1997) Improved genetic algorithms for optimal power flow under both normal and contingent operation states. *Electr Power Energy Syst* 19:287–292
14. Yuryevich J, Wong KP (1999) Evolutionary programming based optimal power flow algorithm. *IEEE Trans Power Syst* 14: 1245–1250
15. Maghrajabi H, Raface JA, Mohandes M (1998) Contingency analysis of bulk power system using neural network. *IEEE Trans on Power Syst* 2:1251–1254

16. Abido MA (2002a) Optimal power flow using particle swarm optimization. *Int J Electr Power Energy Syst* 24:563–571
17. Song YH, Chou CS, Stonham TJ (1999) Combined heat and power dispatch by improved ant colony search algorithm. *Electr Power Syst Res* 52:115–121
18. Fesanghary M, Mahdavi M, Minary-Jolandan M, Alizadeh Y (2008) Hybridizing harmony search algorithm with sequential quadratic programming for engineering optimization problems. *Comput Methods Appl Mech Eng* 197:3080–3091
19. Alsac O, Stott B (1974) Optimal load flow with steady state security. *IEEE Trans Power Apparatus Syst* 93:745–751
20. Yao F, Dong ZY, Meng K, Xu Z, Ho-Ching Iu, Po WongKit (2012) Quantum-inspired particle swarm optimization for power system operations considering wind power uncertainty and carbon tax in Australia 2012. *IEEE Trans Ind Inf* 8:880–888
21. Eric S. Fraga, Lingjian Yang, Lazaros G. Papageorgiou, (2012) On the modelling of valve point loadings for power electricity dispatch, *Applied Energy*, vol 91: 301–303.
22. P.S. Manoharan P.S. Kannan S. Baskar M.W. Iruthayarajan, (2008) Penalty parameter-less constraint handling scheme based evolutionary algorithm solutions to economic dispatch, *IET Gener Transm Distrib*, Vol. 2, No. 4, pp. 478–490.
23. Guojiang Xiong, Dongyuan Shi, Xianzhong Duan, (2013) Multi-strategy ensemble biogeography-based optimization for economic dispatch problems, *Applied Energy*, vol 111: 801–811.
24. J.H.Park, Y.S.Kim, I.K.Ecom, K.Y.Lee. (1993). Economic load dispatch for piecewise quadratic cost function using Hopfield neural network. *IEEE Trans. on Power Systems*, vol. 8, no.3, pp. 1030-1038.
25. Dieu Ngoc Vo, Weerakorn Ongsakul, (2012) Economic dispatch with multiple fuel types by enhanced augmented Lagrange Hopfield network, *Applied Energy*, vol 91: 281–289.
26. Niknam T, Mojarrad HD, Firouzi BB (2013) A new optimization algorithm for multi-objective economic/emission dispatch. *Electr Power Energy Syst* 46:283–293
27. Saidur R, Islam MR, Rahim NA, Solangi KH (2010) A review on global wind energy policy. *Renew Sustain Energy Rev* 14: 1744–1762
28. K.Y.Lee, A.Sode-Yome, and J.H.Park. (1998). Adaptive Hopfield neural network for Economic load dispatch. *IEEE Trans. on Power Systems*, vol.13, no. 2, pp. 519-526.

29. S.Baskar, P.Subbaraj, and M.V.C.Rao. (2003). Hybrid real coded genetic algorithm solution to economic dispatch problem. Paragmon, Computers and Electrical Engineering, vol. 29, pp. 407-419.
30. Nima Amjady, Hadi Nasiri-Rad. (2010). Solution of nonconvex and nonsmooth economic dispatch by a new Adaptive Real Coded Genetic Algorithm. Expert Systems with Applications, 37 :5239–5245
31. A.K. Barisal. (2013). Dynamic search space squeezing strategy based intelligent algorithm solutions to economic dispatch with multiple fuels. Electrical Power and Energy Systems, 45 , 50–59
32. R. Balamurugan, S. Subramanian. (2008). Hybrid integer coded differential evolution – dynamic programming approach for economic load dispatch with multiple fuel options. Energy Conversion and Management, 49: 608–614.
33. Su CT, Lin CT. (2000). New approach with a Hopfield modeling framework to economic dispatch. IEEE Trans Power Syst, 15(2):541–5.
34. Younes, M., Rahli, M., Koridak L.A.: Optimal Power Flow Based on Hybrid Genetic Algorithm, Journal of Information Science and Engineering, Vol. 23, pp. 1801-1816, 2007.
35. Dusonchet, Y. P., and El-Abiad, A. H., Transmission planning using discrete dynamic optimization, IEEE Trans. Power App. Syst., vol. PAS-92, (1997), pp. 1358–1371.
36. Sayah S., K. Zehar, Modified differential evolution algorithm for optimal power flow with non-smooth cost functions, Energy Convers Manage, vol. 49, 2008, pp. 3036 – 3042.
37. Younes.M., Rahli.M, Koridak, Optimal Power Flow Based on Hybrid Genetic Algorithm, Journal of Information Science and Engineering, vol. 23 n. 3, 2007, pp. 1801 – 1816.
38. Niknam T, Narimani MR, Jabbari M, Malekpour AR (2011) A modified shuffle frog leaping algorithm for multi-objective optimal power flow. Energy 36:6420–6432
39. Nayak MR, Nayak CK, Rout PK (2012) Application of multi-objective teaching learning based optimization algorithm to optimal power flow problem. Procedia Technol 6:255–264
40. Saini A, Chaturvedi DK, Saxena AK (2006) Optimal power flow solution: a GA-fuzzy system approach. Int J Emerg Electr Power Syst 5:1–21
41. Ongsakul W, Tantimaporn T (2006) Optimal power flow by improved evolutionary programming. Electr Power Compon Syst 34:79–95

42. Abido MA (2002b) Optimal power flow using tabu search algorithm. *Electr Power Compon Syst* 30:469–483
43. Narimani MR, Azizipanah-Abarghooee R, Zoghdar-Moghadam-Shahrekohne B, Gholami K (2013) A novel approach to multi-objective optimal power flow by a new hybrid optimization algorithm considering generator constraints and multi-fuel type. *Energy* 49:119–136
44. Gil C, Marquez A, Banos R, Montoya MG, Gomez J (2007) A hybrid method for solving multi-objective global optimization problems. *J Glob Optim* 38:265–281
45. Zehar K, Sayah S (2008) Optimal power flow with environmental constraint using a fast successive linear programming algorithm: application to the Algerian power system. *Energy Convers Manag* 49:3361–3365

Abstract

The main current concerns of power generators using thermal fossil fuel power plants are producing electricity with a low cost of fuel and minimizing emissions of toxic gases into the atmosphere.

Note that for cost minimization and reduction of emissions, it is necessary to consider the transmission losses that depend on the network map, the values of the impedances brought into play and the load distribution and productions. The latter plays the most important role in this area. For this it is necessary to express the total losses as a function of the generated power.

The high level of competitiveness today forced power plants to continuously improve reliability, efficiency and profitability, while enhancing their performance and compliance with environmental.

The use of probabilistic multi-agent algorithms enables solving problems of minimization of greenhouse gas emissions, improving dust control, optimizing the performance of fuels and yield optimization turbines.

Our work has focused on the exploitation of effective cooperation between software agents that require a high degree of coordination. The intelligence gained here is adaptive, agents must use the information received in order to behave properly in a scalable environment.

This work is validated through IEEE networks.

ملخص:

إن الانشغالات الرئيسية الحالية لمنتجي الطاقة الكهربائية بواسطة محطات التوليد الحرارية التي تعمل بالوقود الأحفوري هي إنتاج الكهرباء بأقل تكلفة والتقليل من انبعاث الغازات السامة في الجو. كما يجب الإشارة كذلك أنه من أجل هذا يجب الأخذ بعين الاعتبار خسائر النقل التي تتعلق بهيكل الشبكة، قيم الممانعات و توزيع الحمولة و المولدات. هذه الأخيرة تلعب الدور الأهم في هذا المجال لذلك يجب أن نعتبر على الخسائر الكلية بدلالة الاستطاعة المولدة.

المستوى العالي من المنافسة يدفع مراكز توليد الطاقة إلى التحسين باستمرار في الوثوقية و الكفاءة و الربحية مع تعزيز أدائها و التزاماتها البيئية و ذلك بالبحث على حلول لهذه المسائل من خلال استعمال الخوارزميات الاحتمالية متعددة العناصر و التي بالإضافة لهذه المسائل يمكنها إيجاد حلول لمشاكل التقليل من انبعاث الغازات المسببة للاحتباس الحراري و التحكم في الغبار الملوث بالإضافة إلى تحسين أداء الوقود و مردود التوربينات.

في هذا العمل ركزنا أساساً على استغلال التعاون الفعال بين عناصر البرمجيات التي تتطلب درجة عالية من التنسيق حيث الذكاء المكتسب له قابلية التكيف و يجب على العناصر هنا استعمال المعلومات الواردة من أجل التصرف الصحيح في وسط له قابلية كبيرة للتغير و التطور.

تم التحقق من صحة النتائج في هذا العمل من خلال شبكات IEEE .

Résumé :

Les principales préoccupations actuelles des producteurs d'électricité utilisant des centrales thermiques à combustibles fossiles sont la production de l'électricité avec un coût faible de combustibles et la minimisation des émissions des gaz toxiques dans l'atmosphère.

Il faut noter que pour la minimisation du coût et la diminution des émissions, il est nécessaire de considérer les pertes de transmission qui dépendent du schéma du réseau, des valeurs des impédances mises en jeu et de la répartition des charges et des productions. Cette dernière joue le rôle le plus important dans ce domaine. Pour cela, il est nécessaire d'exprimer les pertes totales comme une fonction des puissances générées.

Le niveau élevé de compétitivité contraint aujourd'hui les centrales électriques à améliorer en permanence fiabilité, rentabilité et efficacité, tout en renforçant leurs performances et leur conformité aux exigences environnementales.

L'utilisation des algorithmes multi-agents probabilistes rend possible la résolution des problèmes de la réduction au minimum des émissions de gaz à effet de serre, l'amélioration du contrôle des poussières, l'optimisation du rendement des combustibles et l'optimisation du rendement des turbines.

Notre travail s'est focalisé sur l'exploitation de la coopération efficace entre les agents informatiques qui nécessitent un bon degré de coordination. L'intelligence acquise ici est adaptative, les agents doivent utiliser les informations reçues de manière à se comporter correctement dans un environnement susceptible d'évoluer.

Ce travail est validé à travers des réseaux IEEE.