

République Algérienne Démocratique et Populaire

**Ministère de l'Enseignement Supérieur et de la
Recherche Scientifique**



Université Echahid Hamma Lakhdar d'El-Oued

FACULTE DE TECHNOLOGIE

DEPARTEMENT DE GENIE ELECTRIQUE

Mémoire de fin d'étude

Présenté pour l'obtention du diplôme de

MASTER ACADEMIQUE

Domaine : Sciences et Technologies

Filière : Génie Electrique

Spécialité : Réseaux Électriques

Présenté par

DRIHEM Mohammed Akram et DJELLOUL Elbachir Elomri

Thème

**Optimisation du Dispatching Économique de
l'Énergie Électrique par des Algorithmes
Métaheuristiques**

Soutenu le 13/06/2026. Devant le jury composé de :

Dr. LABBI Yacine

Maitre de conférences Président

Dr. BARKA Nouredine

Maitre de conférences Rapporteur

Dr. MAMMERI Oussama

Maitre de conférences Examineur

Année Universitaire 2025/2026



﴿ رَبَّنَا لَا تُؤَاخِذْنَا إِنْ نَسِينَا أَوْ أَخْطَأْنَا رَبَّنَا وَلَا تَحْمِلْ عَلَيْنَا إَصْرًا كَمَا حَمَلْتَهُ
عَلَى الَّذِينَ مِنْ قَبْلِنَا رَبَّنَا وَلَا تُحَمِّلْنَا مَا لَا طَاقَةَ لَنَا بِهِ وَاعْفُ عَنَّا وَاعْفِرْ لَنَا
وَارْحَمْنَا أَنْتَ مَوْلَانَا فَانصُرْنَا عَلَى الْقَوْمِ الْكَافِرِينَ ﴾ سورة البقرة : الآية 286 .

" صدق الله العظيم "



Remerciements

*Tout d'abord, Nous remercions dieu -**ALLAH**- le tout puissant de nous avoir donné le courage et la patience durant toutes ces années d'études.*

Nous tenons à exprimer toute notre gratitude et nos sincères remerciements à Monsieur

***Dr : BARKA Nouredine**, Maître de conférences à L 'Université Echahid Hamma Lakhdar d'El Oued, pour avoir dirigé ce travail.*

Nos sincères remerciements aux Messieurs les membres du jury pour l'honneur qu'ils nous font en participant au jugement de ce travail.

Nous tenons à remercier vivement toutes personnes qui nous ont aidé à élaborer et réaliser ce mémoire, ainsi à tous ceux qui nous aidés de près ou de loin à accomplir ce travail.

En fin nous remercions tout particulièrement nos parents, pour leur soutien inconditionnel tout au long de ces longues années d'études.





Dédicaces

Nous dédions ce modeste travail :

À nos très chers parents qui nous ont soutenu durant toute la durée de nos études.

À nos très chères freres, sœurs et à nos grandes familles.

À tous mes amis.

À tous ceux qui nous aiment et que nous aimons

À vous.



الملخص

Résumé

Abstract

Résumé

Ce travail porte sur l'optimisation du dispatching économique de l'énergie électrique à l'aide d'algorithmes métaheuristiques. L'objectif principal est de minimiser le coût de production tout en respectant les contraintes du système électrique.

Deux algorithmes ont été étudiés : Particle Swarm Optimization (PSO) et Differential Evolution (DE). Les deux algorithmes ont été appliqués sur différents systèmes de test.

Les résultats montrent que les deux méthodes offrent des solutions efficaces, avec une meilleure qualité de solution pour DE et une convergence plus rapide pour PSO. Ces approches se révèlent particulièrement adaptées aux problèmes complexes et non linéaires.

Mots clés : Dispatching économique, optimisation, PSO, DE, réseaux électriques, métaheuristiques

Abstract

This work focuses on the optimization of economic dispatch in electrical power systems using metaheuristic algorithms. The main objective is to minimize the total generation cost while satisfying system constraints.

Two algorithms were investigated: Particle Swarm Optimization (PSO) and Differential Evolution (DE). Their performance was evaluated using different test systems.

The results demonstrate that both algorithms provide efficient and reliable solutions. DE achieves slightly better cost optimization, while PSO offers faster convergence. These methods prove to be highly effective for solving complex and nonlinear optimization problems.


Keywords: Economic dispatch, optimization, PSO, DE, power systems, metaheuristics.

المخلص

تهدف هذه الدراسة إلى تحسين التوزيع الاقتصادي للطاقة الكهربائية من خلال استخدام خوارزميات ميتاهيورستية متقدمة، وذلك من أجل تقليل تكلفة الإنتاج مع احترام القيود التشغيلية للنظام الكهربائي. تم في هذا العمل دراسة خوارزميتي سرب الجسيمات (PSO) والتطور التفاضلي (DE)، وتطبيقهما على أنظمة اختبار مختلفة.

أظهرت النتائج أن كلا الخوارزميتين قادرتان على تحقيق حلول مثلى أو شبه مثلى، حيث تميزت خوارزمية DE بدقة أعلى في تقليل التكلفة، بينما أظهرت PSO سرعة كبيرة في التقارب. كما أكدت الدراسة فعالية هذه الطرق مقارنة بالأساليب التقليدية، خاصة في الأنظمة المعقدة وغير الخطية.

الكلمات المفتاحية: التوزيع الاقتصادي، الشبكات الكهربائية، PSO، DE، التحسين، الطاقة الكهربائية



Sommaire

Remerciement

Dédicace

Résumé

Table des matières

Liste des figures

Liste des tableaux

a

Introduction générale

Chapitre I : Fondements théoriques et modélisation du problème du dispatching économique	
I.1.Introduction	3
I.2 Généralités sur le Dispatching Économique (ED)	3
I.2.1 Définition et objectifs	3
I.2.1.1 Définition	3
I.2.1.2 Objectif du Dispatching Economique	4
I.2.2 Importance dans la gestion des réseaux électriques	4
I.3 Modélisation mathématique des coûts de production	7
I.3.1 Fonction de coût quadratique	7
I.3.2 Effet de point de vanne (Valve-Point Loading Effect)	7
I.4 Formulation des contraintes opérationnelles	8
I.4.1 Contraintes d'égalité (Bilan de puissance active)	8
I.4.1.1 Cas d'un système sans pertes	9
I.4.1.2 Cas d'un système avec pertes	9
I.4.2 Calcul des pertes de transmission (Coefficients B de Kron)	9
I.4.3 Contraintes d'inégalité (Limites des générateurs)	10
I.5 Méthodes d'optimisation classiques	10
I.5.1 Méthode Lambda-Itération	10
I.5.1.1 Organigramme de la méthode lambda	12
I.5.2 Méthode du Gradient	12
I.5.2.1 Organigramme de la Méthode du Gradient	14
I.5.3 Limitations des méthodes classiques	14
I.6.Conclusion	15

Chapitre II: Algorithmes Métaheuristiques et Techniques d'Optimisation	
II.1.Introduction	17
II.2. Aperçu sur les techniques d'optimisation	17
II.2.1. Optimisation déterministe vs stochastique	18
II.2.1.1. Les méthodes déterministes	19
II.2.1.2. Les méthodes stochastiques	19
II.2.1.3. Différence entre les méthodes déterministes et stochastiques	20
II.2.2. Classification des métaheuristiques	20
II.2.2.1. Méthodes métaheuristiques à population	21
II.2.2.2. Méthodes Métaheuristiques à solution unique (Parcours)	21
II.3. Algorithme d'Optimisation par Essaim de Particules (PSO) (Particle Swarm Optimization)	21
II.3.1. Inspiration biologique et principe de base	21
II.3.2. Modèle mathématique (Vitesse et Position)	22
II.3.2.1. Topologie du voisinage	23
II.3.2.2. Étapes de la méthode d'optimisation par essaim de particules	24
II.3.3. Paramètres de contrôle (Inertie, facteurs d'accélération)	26
II.3.4. Algorithme général du PSO	27
II.4. Algorithme à Évolution Différentielle (DE)	28
II.4.1. Principe de fonctionnement	28
II.4.2 Initialisation de la population	29
II.4.3 Opérateurs génétiques : Mutation, Croisement, Sélection	30
II.4.3.1 Mutation	30
II.4.3.2 Croisement	30
II.4.3.3 Sélection	30
II.4.4 Algorithme général du DE	31
II.4.5 Paramètres de contrôle du DE	31
II.5. Conclusion	32
Chapitre III : Application des Algorithmes Proposés pour le Dispatching Économique	
III.1. Introduction	34
III.2. Présentation du réseau d'étude	34
III.2.1. Réseau test IEEE 30-Bus	34

III.3. Méthodologie de résolution proposée	35
III.4. Adaptation du PSO au problème ED	37
III.4.1. Codage des particules et initialisation	37
III.4.2. Fonction d'évaluation (Fitness function)	37
III.5 Adaptation du DE au problème ED	40
III.5.1 Structure du vecteur individu	40
III.5.2 Stratégie de mutation et de croisement	40
III.6. Gestion des contraintes (Constraint Handling)	42
III.6.1. Traitement des limites de production	42
III.6.2. Gestion de la contrainte d'égalité (Méthode de pénalité)	43
III.7. Description des systèmes de test	46
III.7.1. Système à 3 générateurs	46
III.7.2. Système IEEE 30 bus (6 générateurs)	48
III.7.3. Système à 13 générateurs (avec Valve-Point)	48
III.8. Environnement de simulation et paramètres	48
III.9. Conclusion	50
Chapitre IV : Analyse des résultats et étude comparative.	
IV.1.Introduction	52
IV.2 Cas d'étude N°1 : Système à 3 unités	52
IV.2.1 Résultats de simulation	53
IV.2.1.1 Résultats PSO	53
IV.2.1.2 Résultats DE	55
IV.2.2 Validation par rapport aux méthodes conventionnelles	59
IV.3 Cas d'étude N°2 : Système IEEE 30 bus (avec pertes)	60
IV.3.1 Performance de l'algorithme PSO	60
IV.3.2 Performance de l'algorithme DE	60
IV.3.3 Analyse de la convergence	61
IV.4 Cas d'étude N°3 : Système complexe avec effet de vanne	62
IV.4.1 Comparaison de la qualité de solution	65
IV.4.2 Robustesse des algorithmes	66
IV.5 Synthèse comparative globale	67
IV.5.1 Comparaison des coûts de production	67
IV.5.2 Comparaison des temps de calcul	68

IV.5.3 Comparaison des temps de calcul	69
IV.5.4 Robustesse	71
IV.5.4 Analyse statistique (Meilleur, Pire, Moyenne)	72
IV.6 Discussion générale	73
IV.7 Conclusion	75
Conclusion générale	78
References Bibliographiques	
Annexe	



LISTE DES FIGURES

LISTE DES FIGURES

		Page
Figure I.1	Système électrique du modèle utilisé dans la répartition économique	3
Figure I.2	Modèle d'un réseau électrique concentré à un seul jeu de barres artificiel	4
Figure I.3	Fonction du coût convexe du générateur	5
Figure I.4	Courbe quadratique du coût de production d'un générateur	6
Figure I.5	L'effet d'ouverture des vannes	8
Figure I.6	L'explication graphique de la méthode Itératif du lambda	10
Figure I.7	Organigramme de la méthode lambda	12
Figure I.8	Organigramme de calcul de la méthode du gradient	14
Figure II.1	schéma bloc représente les différentes méthodes d'optimisation	18
Figure II.2	Déplacement d'une particule	22
Figure II.3	Trois topologies du voisinage différentes	23
Figure II.4	Organigramme de la méthode PSO	25
Figure II.5	Schéma de mutation DE	29
Figure III.1	Schéma du réseau IEEE 30 jeux de barre	35
Figure III.2	Organigramme de la méthodologie proposée	36
Figure III.3	Courbe de Convergence (PSO)	38
Figure III.4	Courbe de convergence de l'algorithme DE	41
Figure III.5	Évolution du Multiplicateur de Lagrange	45
Figure III.6	Répartition optimale de la génération	47
Figure IV.1	Réseau électrique à 3 bus	52
Figure IV.2	Répartition optimale de la production (PSO)	54
Figure IV. 3	Répartition optimale de la production par unité (DE)	56
Figure IV.4	Courbe de convergence de l'erreur (méthode conventionnelle)	59
Figure IV.5	Distribution de puissance	60
Figure IV.6	Comparaison de performance des algorithmes d'optimisation PSO et DE	61
Figure IV.7	Schéma unifilaire d'un réseau électrique à 6 bus	63
Figure IV.8	La courbe de convergence	63
Figure IV.9	Distribution de la Puissance (MW)	64
Figure IV.10	Évaluation de la robustesse et de la stabilité des algorithmes PSO et DE sur plusieurs exécutions	66
Figure IV.11	Comparaison des coûts de production	67



LISTE DES TABLEAUX

LISTE DES TABLEAUX

		Page
Tableau III.1	<i>Paramètre du réseau IEEE 30 jeux de barres</i>	35
Tableau III.2	<i>Coefficients de coût des générateurs</i>	46
Tableau III.3	<i>Limites de puissance des générateurs</i>	46
Tableau III.4	<i>Paramètres de l'algorithme SPO</i>	49
Tableau III.5	<i>Paramètres de l'algorithme DE</i>	49
Tableau IV.1	<i>Résultats PSO</i>	53
Tableau IV.2	<i>Résultats DE</i>	56
Tableau IV.3	<i>Comparaison des temps de calcul</i>	70



Liste des symboles

Liste des symboles

P : la puissance active (kW)

Q : la puissance réactive (KVAR)

S : la puissance apparente (KVA)

$\bar{S}_i$: Puissance apparente produite.

$\bar{V}_i$: La valeur complexe de la tension de jeu de barre i (V).

P_i : puissance active en un nœud i quelconque du réseau (W)

Q_i : puissance réactive en un nœud i quelconque du réseau (VAR)

OPF: Optimal power Flow (Ecoulement de Puissance Optimal)

$\bar{I}_i$: Courant débité

π : modèle la ligne électrique.

P_{Gi} : Puissance active injectée au jeu de barre i

Q_{Gi} : Puissance réactive injectée au jeu de barre i .

P_{Di} : Puissance active demandée au jeu de barre i .

Q_{Di} : Puissance réactive demandée au jeu de barre i .

S_{Gi} : Puissance générée au niveau de jeu de barre i .

S_{Di} : Puissance demandée au niveau de jeu de barre i .

δ_i : Angles des tensions en rad au niveau de jeu de barre i .

QL : Les pertes de puissance réactive.

PL : Les pertes de puissance active.

IBU : Courant complexe injecté à chaque jeu de barre en A

$VBUS$: Tensions complexes de chaque jeux de barres en Volt [V]

Y : L'admittance shunt par phase en (en Siemens [S])

Y_{ii} : Admittance propre en un nœud i quelconque du réseau (Ω^{-1}).

θ_i : Angle de la tension en un nœud i quelconque du réseau (rads)

θ_j : Angle de la tension en un nœud j quelconque du réseau (rads)

Y_{ij} : Admittance mutuelle entre le nœud i et le nœud j quelconques du réseau (Ω^{-1})

M_i : Fonction Mismatch en un nœud i quelconque du réseau (VA).

$\emptyset_{ij}$: Angle de l'admittance mutuelle au sommet i et j (rads)

PSO : Algorithme d'Optimisation par Essaim de Particules

DE : Algorithme à Évolution Différentielle

JB : Jeux de barre

AG : Algorithmes génétiques



Introduction générale

Introduction générale

Dans un contexte marqué par l'augmentation continue de la demande en énergie électrique et la nécessité d'optimiser les ressources disponibles, le dispatching économique constitue un problème fondamental dans l'exploitation des réseaux électriques. Il vise à déterminer la répartition optimale de la puissance entre les différentes unités de production afin de minimiser le coût total de génération tout en respectant les contraintes techniques et opérationnelles du système. [1]

Cependant, la complexité croissante des systèmes électriques modernes, notamment en présence de non-linéarités, de pertes de transmission et d'effets comme le Valve-Point, rend les méthodes classiques d'optimisation souvent insuffisantes. C'est dans ce contexte que les algorithmes métaheuristiques se sont imposés comme des outils performants pour résoudre ces problèmes complexes. [2]

Ce travail s'inscrit dans cette perspective et propose une étude approfondie de l'optimisation du dispatching économique à l'aide de deux algorithmes métaheuristiques : l'optimisation par essaim de particules (PSO) et l'évolution différentielle (DE).

Le mémoire est structuré comme suit :

Le premier chapitre est consacré aux fondements théoriques du dispatching économique. Il présente la modélisation mathématique du problème, les fonctions de coût, ainsi que les contraintes opérationnelles, en plus d'un aperçu des méthodes classiques d'optimisation.

Le deuxième chapitre introduit les techniques d'optimisation, avec une distinction entre méthodes déterministes et stochastiques. Il détaille ensuite les principes de fonctionnement des algorithmes métaheuristiques, en particulier PSO et DE.

Le troisième chapitre est dédié à l'application des algorithmes proposés au problème du dispatching économique. Il présente la méthodologie adoptée, l'adaptation des algorithmes, ainsi que les systèmes de test utilisés.

Le quatrième chapitre expose les résultats obtenus, leur analyse ainsi que la comparaison entre les différentes méthodes. Il met en évidence les performances en termes de coût, de convergence et de robustesse.

Le mémoire se terminera par une conclusion générale synthétisant les principaux résultats obtenus et des perspectives.

CHAPITRE I

**Fondements théoriques et
modélisation du problème du
dispatching économique**

I.1 Introduction

La répartition optimale de la production d'énergie est connue sous le nom de dispatching économique (DE). Le dispatching économique est un problème d'optimisation visant à minimiser le coût de production. Le problème du dispatching économique consiste à répartir la production entre les générateurs afin de minimiser le coût total de production tout en satisfaisant la demande.

Plusieurs techniques ont été développées et d'approches pour résoudre la question de l'affectation optimale de la charge, depuis que ce défi est devenu une préoccupation majeure nécessitant un suivi constant et une mise à jour régulière des recherches afin d'obtenir de meilleures performances.

I.2 Généralités sur le Dispatching Économique (ED)

I.2.1 Définition et objectifs

I.2.1.1 Définition

Les expressions « Dispatching Optimal », « Dispatching de génération Optimal », «Dispatching Economique Optimal », « Répartition de puissance optimale» et « Répartition de charge optimale» se réfèrent essentiellement à des synonymes basés sur un type de calcul de répartition, où certaines quantités sont minimisées. Dans le contexte du planning de génération, l'expression générale «Dispatching Economique» a production entre les générateurs afin de minimiser le coût total de production tout en satisfaisant la demande. [1]

Dans la distribution économique, l'objectif de minimisation est le coût global de production des centrales thermiques, afin que la demande électrique du système soit totalement comblée.

Dans ce contexte, la seule exigence est que l'addition de toutes les puissances actives produites doit correspondre à la charge globale du système. Il en découle que le modèle employé par la répartition économique standard estime que les pertes de puissance active dans les lignes de transport et les transformateurs sont insignifiantes, Dans le modèle classique du dispatching économique, les pertes de transmission sont négligées. [2]




Figure I.1: Système électrique du modèle utilisé dans la répartition économique [2].

I.2.1.2 Objectif du Dispatching Economique

L'objectif du dispatching économique est souvent de réduire une ou plusieurs fonctions au minimum. Ces fonctions s'appliquent principalement aux coûts finaux, y compris les coûts du carburant qui devraient refléter les coûts économiques.

Pour illustrer cet objectif, nous fournissons quelques exemples ici [3] :

- Dans un réseau doté de centrales hydroélectriques, une répartition optimale vise à réduire le gaspillage d'eau ou à générer le maximum de MWH à partir du volume d'eau disponible.
- Dans un réseau qui comprend des centrales à charbon, l'optimisation économique cherche à distribuer la production entre les différentes installations afin de réduire la pollution dans les zones sensibles limitées.
- Il y a deux générateurs, l'un qui fonctionne avec du pétrole et l'autre avec du gaz. La répartition idéale consiste à répartir la charge entre les deux générateurs afin de réduire au minimum le coût total de production.

I.2.2 Importance dans la gestion des réseaux électriques

Cette fonctionnalité vise à minimiser le coût total des puissances actives produites, en présumant que chaque générateur possède une courbe de coût convexe associée à sa propre puissance active, ayant des bornes supérieures et inférieures. L'addition de toutes les puissances actives produites doit correspondre à la charge totale du système en question. Ainsi, les pertes de puissance active dans les transformateurs et les lignes de transport sont jugées négligeables. [4]




Figure I.2: Modèle d'un réseau électrique concentré à un seul jeu de barres artificiel [4].

Donc, dans la répartition économique, la fonction d'optimisation n'intègre pas les équations non linéaires du flux de puissance. On postule que tous les producteurs d'énergie et toutes les charges électriques sont reliés directement à un ensemble de barres artificiel du système électrique (Figure I.2). Cela simplifie les équations de flux de puissances en une seule équation démontrant que : « la somme des puissances produites doit correspondre à la somme des puissances consommées ».

Le problème est formulé sur la base de l'alimentation d'une charge centralisée, où plusieurs générateurs sont connectés à cette unique charge. Chaque générateur i va générer sa propre puissance P_{gi} en se basant sur une fonction de coût convexe définie par la fonction quadratique suivante [4]:

$$C_i = a_{i0} + a_{i1}P_{gi} + a_{i2}P_{gi}^2 \quad ; \quad i = 1, 2, \dots, ng \quad (I.1)$$

Où les coefficients a_{i0} , a_{i1} et a_{i2} sont numériquement connus et $a_{i2} > 0$.




Figure I.3: Fonction du coût convexe du générateur [4].

La Figure I.3 illustre cette fonction quadratique, où l'axe des ordonnées représente le coût de production (\$/h) et l'axe des abscisses indique la puissance en sortie du générateur (en MW). On effectue cela en faisant varier la puissance du générateur P_{gi} entre P_{gimin} et P_{gimax} , et le MBtu/h associé à chaque niveau de puissance P_{gi} est consigné. Par la suite, ces points sont ajustés à une équation quadratique au sein d'une courbe [5].

Le problème d'optimisation est la minimisation de la somme de ces coûts individuels[3] :

$$C = \sum_{i=1}^{ng} C_i = \sum_{i=1}^{ng} (a_{i0} + a_{i1}P_{gi} + a_{i2}P_{gi}^2) \quad (I.2)$$

Conformément à une unique condition d'égalité stipulant que « la somme de toutes les puissances produites doit correspondre à la charge P_D ». On peut considérer numériquement la puissance demandée P_D [2]:

$$\sum_{i=1}^{ng} P_{gi} = P_D \quad (I.3)$$

En pratique, la puissance générée P_{gi} est limitée par une borne inférieure P_{gimin} et une borne supérieure P_{giMax} [3]:

$$P_{gimin} \leq P_{gi} \leq P_{gimax} \quad ; i = 1, ng \quad (I.4)$$




Figure I.4: Courbe quadratique du coût de production d'un générateur.

I.3 Modélisation mathématique des coûts de production

I.3.1 Fonction de coût quadratique

Le coût de production d'une centrale est habituellement représenté par une fonction polynomiale de degré deux en PG (puissance active générée par la centrale), les coefficients étant des constantes spécifiques à chaque centrale [6] :

$$C = \sum_{i=1}^{ng} C_i(P_{gi}) = \sum_{i=1}^{ng} aP_{gi}^2 + bP_{gi} + c \quad (I.5)$$

Si ces coefficients (a, b et c) sont inconnus et que les données des unités de production sont présentées sous forme de tableaux liant chaque puissance active produite à son coût de production. Pour définir les constantes a, b et c, diverses méthodes mathématiques sont nécessaires, telles que : l'analyse de régression « regression analysis » via la méthode des moindres carrés « least-squares method », la logique floue « fuzzy logic », et bien d'autres. [6]

I.3.2 Effet de point de vanne (Valve-Point Loading Effect)

En général, les centrales thermiques majeures sont équipées de multiples vannes d'admission de vapeur, employées pour réguler la puissance produite par l'unité. Chaque fois que l'on débute l'ouverture d'une vanne d'admission, l'ouverture des vannes provoque des ondulations dans la courbe du coût du carburant, ce qui entraîne alors des fluctuations dans la courbe du coût du carburant. Au fur et à mesure que la valve s'ouvre progressivement, ces pertes se réduisent petit à petit jusqu'à ce qu'elle soit entièrement ouverte [7].

La figure (I.5) illustre la courbe de coût standard d'une unité thermique associée à cinq vannes. Admission de vapeur.

A: Valve primaire **B:** valve secondaire **C:** Valve tertiaire **D:** Valve quaternaire **E:** Valve Quinaire.




Figure 1.5: L'effet d'ouverture des vannes [7].

L'effet d'ouverture de vanne est généralement représenté en intégrant un élément sinusoïdal à la fonction quadratique initiale [7] :

$$C_i(P_{gi}) = a_i P_{gi}^2 + b_i P_{gi} + c_i + |e_i \sin(f_i(P_i^{min} - P_i))| \quad (1.6)$$

a_i, b_i, c_i, e_i, f_i sont les coefficients de coût de l'unité génératrice i .

I.4 Formulation des contraintes opérationnelles

Les puissances actives générées de manière optimale, correspondant à un coût le plus bas possible, doivent impérativement satisfaire les contraintes d'égalité et d'inégalité. Les contraintes de sécurité précisent que même en cas de perte d'un ou plusieurs éléments de production et/ou de transport, le réseau demeure opérationnel dans des limites acceptables [8].

I.4.1 Contraintes d'égalité (Bilan de puissance active)

Dans le cadre de la répartition économique, l'objectif à atteindre est de minimiser le coût total de production des générateurs, afin d'assurer que la demande électrique du système soit complètement comblée [3].

- Il est possible d'affirmer que les contraintes d'égalités respectent la loi de Kirchhoff sur les bilans d'énergie.

I.4.1.1 Cas d'un système sans pertes

Ici, la seule restriction est que l'addition de toutes les puissances actives produites doit correspondre à la charge totale du système [9].

$$\sum_{i=1}^{g_i} P_{gi} = P_D \quad (I.7)$$

I.4.1.2 Cas d'un système avec pertes

Dans ce contexte, la somme de toutes les puissances actives produites doit être équivalente à la somme de la puissance requise par la charge du système et des pertes dues à la transmission de cette puissance [6].

$$\sum_{i=1}^k P_{gi} = \sum_{i=1}^k P_d + P_L \quad (I.8)$$

I.4.2 Calcul des pertes de transmission (Coefficients B de Kron)

Pertes de transmission : Il s'agit de l'écart entre les unités produites et celles qui sont distribuées. Ces derniers se répartissent en Les pertes considérées dans le modèle sont les pertes techniques dues aux lignes et transformateurs, aussi appelées commerciales. Les pertes techniques résultent de l'énergie perdue dans les conducteurs et équipements employés pour les lignes de transmission, ainsi que des pertes magnétiques dans les transformateurs [10].

$$P_L = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_i B_{ij} P_j + \sum_{i=1}^{N_g} B_{0i} P_i + B_{00} \quad (I.9)$$

B_{ij} , B_{0i} et B_{00} : sont les coefficients de perte ou B-coefficients.

B_{0i} : facteur linéaire variable.

B_{00} : Facteur constant.

B-Coefficients : également appelés coefficients de perte, Les coefficients B sont supposés constants autour d'un point de fonctionnement donné. Une précision acceptable est attendue lorsque les conditions d'opération réelles se rapprochent des conditions de base utilisées pour déterminer les coefficients. On les symbolise généralement par B_{ij} .

I.4.3 Contraintes d'inégalité (Limites des générateurs)

Contraintes du dispatching économique reflètent à la fois les contraintes sur l'équipement physique dans les systèmes d'alimentation et les limites imposées pour garantir la sécurité du système. Les types de contraintes d'inégalité les plus courants sont les limites maximales de tension des ensembles de barres génératrices et de charge, ainsi que les limites minimales de tension pour certains ensembles de barres avec plusieurs générateurs. On trouve également les contraintes liées à la capacité maximale de transport des lignes, ainsi que celles concernant les appareils et outils de réglage [11].

$$P_{Gi}^m \leq P_{Gi} \leq P_{Gi}^M \quad (I.10)$$

D'où :

P_{Gi}^M : la puissance active maximale que génère le générateur (i).

P_{Gi}^m : la puissance active minimale que génère le générateur (i).

I.5 Méthodes d'optimisation classiques

I.5.1 Méthode Lambda-Itération

La méthode Lambda-itération est généralement utilisée lorsque la fonction de coût est quadratique, c'est-à-dire que sa forme est un polynôme du second degré. Cette technique repose sur la fonction d'erreur qui postule l'existence d'une fonction continue pour mettre en œuvre le théorème de la valeur moyenne [10].




Figure I.6: L'explication graphique de la méthode Itératif du lambda [10].

Où les étapes de cette méthode sont :

L'étape 1: Estimation de $\lambda^{(1)}$

L'étape 2: On calcule les puissances générées par la méthode lagrangien et les pertes par leurs relation:

$$\frac{\partial C_i}{\partial P_{gi}} = \gamma \left(1 - \frac{\partial P_L}{\partial P_{gi}} \right) \quad (I.11)$$

L'étape 3: Calculer l'erreur :

$$e_1 = \sum_{i=1}^{ng} P_{gi} - P_d - P_L \quad (I.12)$$

- Si $e_1 = 0$: afficher les résultats (solution finale).
- Si non, on passe à l'étape 4.

L'étape 4: Nouvelle valeur de λ

Où $\lambda_2 = \lambda_1 + \Delta \lambda$

$-(10\% \lambda_1) \leq \Delta \leq + (10\% \lambda_2)$

- Si $e_2 = 0$, les résultats représentent la solution optimale.
- Si non :

*Si $e_1 \cdot e_2 < 0$ on passe à l'étape 5.

*Si non, on retourne à l'étape 4.

L'étape 5: On fait le calcul suivant : $P_{gi} = P_{g(max)}$

$$\frac{|e_2|}{\lambda_2 - \lambda_3} = \frac{|e_1|}{\lambda_3 - \lambda_1} \Rightarrow \lambda_3 = \frac{\lambda_1 - \lambda_2}{|e_1| + |e_2|} |e_2| + \lambda_2 \quad (I.13)$$

$e_3 = 0 \Rightarrow$ la solution optimale.

$e_3 \neq 0 \Rightarrow$ donc la solution optimale entre λ_1 et λ_3 ou entre λ_2 et λ_3 .

I.5.1.1 Organigramme de la méthode lambda [11]




Figure I. 7: Organigramme de la méthode lambda [11].

I.5.2 Méthode du Gradient

Les méthodes du gradient sont historiquement les plus anciennes. Elles facilitent la résolution de problèmes non linéaires et reposent sur une supposition robuste concernant la connaissance de la dérivée de la fonction objective à chaque point de l'espace. Cette technique se divise en deux catégories : de premier ordre et de deuxième ordre. Le premier ordre repose

sur une approximation linéaire via les séries de Taylor avec une initialisation du gradient, tandis que le deuxième ordre est fondé sur l'approximation quadratique à l'aide des séries de Taylor, en utilisant la matrice hessienne H pour l'initialisation du gradient. La formulation de l'algorithme du gradient est représentée par l'équation suivante [13] :

$$P_{gi} = \frac{\lambda - b_{i1}}{2a_i} \quad (I.14)$$

L'équation (II.7) peut s'écrire sous la forme

$$\sum P_{gi} = P_D \quad (I.15)$$

Voici un résumé des étapes du processus de recherche utilisant la méthode du gradient :

Etape 1 : Développez la partie gauche de l'équation (I.14) en utilisant la série de Taylor, tout en négligeant les termes de degré supérieur.

$$f(\gamma)^k + \left(\frac{df(\gamma)}{d\gamma} \right)^k \Delta\gamma^k = P_{Ci} \quad (I.16)$$

Etape2 : Dédurre l'expression de $\Delta\lambda$.

$$\Delta\gamma^k = \frac{\Delta P^k}{\left(\frac{df(\gamma)}{d\gamma} \right)^k} = \frac{\Delta P^k}{\sum \left(\frac{dP_{gi}}{d\gamma} \right)^k} \quad (I.17)$$

Ou bien

$$\Delta\gamma^k = \frac{\Delta P^k}{\sum \left(\frac{1}{2a_{i2}} \right)^k} \quad (I.18)$$

Etape 3 : Calculer la nouvelle valeur de λ

$$\gamma^{k+1} = \gamma^k + \Delta\gamma^k \quad (I.19)$$

Etape 4 : Calculer l'erreur exprimé par :

$$\Delta P^k = P_{Ci} - \sum_{i=1}^n P_{gi}^k \quad (I.20)$$

Etape 5 : le processus de calcul se termine si la condition suivante est vérifiée :

$\Delta P^k < \varepsilon$ ε : Est la précision désirée

I.5.2.1 Organigramme de la Méthode du Gradient [14]




Figure I.8: Organigramme de calcul de la méthode du gradient [14].

I.5.3 Limitations des méthodes classiques

Ces méthodes présentent des inconvénients majeurs lorsque le problème devient [15] :

- De plus en plus fortement non linéaire.
- La fonction à optimiser n'est pas différentiable.
- La fonction à optimiser a plusieurs objectifs à optimiser simultanément (optimisation multiobjectifs).

Leurs inconvénients se présentent dans les principales raisons suivantes :

- Leurs convergences vers des optimums locaux.
- Difficulté majeure confrontée lors de leur programmation et de mise en œuvre.

Ces limitations ont conduit au développement de méthodes métaheuristiques modernes (algorithmes génétiques, PSO, DE, etc.), largement étudiées dans la littérature récente en optimisation des systèmes électriques.

I.6.Conclusion

Dans ce chapitre, nous avons présenté les fondements théoriques du problème du dispatching économique ainsi que sa modélisation mathématique. Nous avons également introduit les contraintes du système et les méthodes classiques d'optimisation. Ces notions serviront de base pour l'étude des algorithmes métaheuristiques présentés dans le chapitre suivant.

Chapitre II

**Algorithmes Métaheuristiques et
Techniques d'Optimisation**

II.1. Introduction

L'optimisation est cruciale dans divers secteurs scientifiques et technologiques, y compris l'intelligence artificielle, l'ingénierie, la recherche opérationnelle et l'apprentissage automatique. L'optimisation est une démarche visant à identifier la solution optimale pour un problème spécifique, en maximisant ou minimisant une fonction cible dans le respect de certaines restrictions. Dans de nombreuses situations concrètes, les problèmes d'optimisation se distinguent par leur complexité considérable, leur non-linéarité, leur dimensionnalité importante et la présence de plusieurs optima locaux. [16]

Face à ces défis, les approches d'optimisation traditionnelles peuvent s'avérer être inefficaces ou complexes à mettre en œuvre. C'est dans ce cadre que les algorithmes métaheuristiques ont vu le jour. Ces méthodes se basent fréquemment sur des phénomènes naturels tels que l'évolution biologique, le comportement collectif des animaux ou encore divers processus physiques. Leur but premier est de naviguer efficacement à travers l'espace de recherche pour dénicher des solutions près de l'optimal global dans un délai raisonnable.

L'algorithme d'optimisation par essaim de particules (PSO) et l'algorithme d'évolution différentielle (DE) sont deux des algorithmes métaheuristiques les plus couramment utilisés. Ces techniques sont largement utilisées dans divers secteurs tels que l'optimisation de fonctions compliquées, la planification, la robotique et aussi l'apprentissage automatique. [17]

Dans ce chapitre, nous présentons d'abord un aperçu général des techniques d'optimisation, puis nous détaillons le fonctionnement de l'algorithme (PSO) et de l'algorithme DE, ainsi que leurs principes fondamentaux et leurs paramètres de contrôle.

II.2. Aperçu sur les techniques d'optimisation

L'optimisation englobe toutes les méthodes mathématiques et algorithmiques qui permettent d'identifier la solution optimale à un problème spécifique, selon un critère déterminé. Ces techniques peuvent être classées en deux principales catégories : les techniques déterministes et les techniques stochastiques. [16]

Les approches déterministes se basent sur des règles rigoureuses et génèrent constamment le même résultat pour un problème spécifique avec des conditions initiales identiques. Elles ont souvent recours à des méthodes analytiques ou à des techniques orientées gradient, telles que la méthode du gradient ou les techniques de Newton. [18]

Toutefois, face à des problèmes particulièrement complexes ou non linéaires, les techniques déterministes peuvent se heurter à des obstacles, en particulier lorsqu'il y a de

nombreux minima locaux. Dans ce contexte, les approches stochastiques, y compris les métaheuristiques, proposent une solution efficace.

Les métaheuristiques représentent des approches de recherche universelles capables de gérer des problèmes complexes sans avoir besoin de comprendre en profondeur la structure du problème. Elles font appel à des mécanismes basés sur la probabilité afin d'explorer l'espace de recherche et d'améliorer progressivement les solutions proposées. [18]

II.2.1. Optimisation déterministe vs stochastique

Le choix de la méthode d'optimisation employée sera influencé par les caractéristiques des variables, les champs de définition et les critères à améliorer.

Il y a deux grandes familles de méthode d'optimisation [19] :

- Les méthodes déterministes, qui assurent la convergence vers l'optimum de la fonction qui assurent la convergence vers l'optimum le plus proche de la solution courante.
- Les méthodes stochastiques, qui s'attachent à faire converger la solution vers l'optimum global de la fonction.

La méthode par essai/erreur représente l'approche la plus primitive et naturelle pour résoudre un problème d'optimisation. Le responsable ajuste ses mesures en fonction des résultats jusqu'à trouver une solution satisfaisante. Cette approche, à première vue basique, constitue le fondement d'une multitude de méthodes d'optimisation. [20]




Figure II.1: schéma bloc représente les différentes méthodes d'optimisation. [21]

II.2.1.1. Les méthodes déterministes

Les méthodes déterministes sont caractérisées par une exploration systématique de l'espace de recherche. On trouve une multitude de techniques d'optimisation déterministes. On distingue les techniques locales qui garantissent une convergence vers l'optimum de la fonction le plus proche de la solution actuelle en sondant son entourage, et les méthodes d'optimisation globale qui visent à diriger la solution vers l'optimum global de la fonction.

Parmi les méthodes déterministes, on va citer quelques méthodes [21] :

- Les méthodes de gradient.
- Les méthodes de Newton
- La méthode multi-start.
- La méthode de Nelder-Mead ou la méthode du simplexe.
- L'algorithme de séparation – évaluation : branch and bound.

Habituellement, les techniques déterministes mentionnées précédemment sont particulièrement efficaces pour des problèmes spécifiques, généralement de taille modeste. Cependant, pour les problèmes de grande envergure, la possibilité de trouver la solution optimale dans un délai acceptable repose principalement sur une compréhension approfondie du problème par le preneur de décision. Si les critères mentionnés précédemment ne sont pas satisfaits, le preneur de décision devra privilégier des techniques stochastiques. [22]

II.2.1.2. Les méthodes stochastiques

Les méthodes stochastiques se distinguent par un processus de génération aléatoire ou pseudo-aléatoire de solutions dans l'espace d'état, une approche heuristique qui favorise la convergence de l'algorithme.

Ces techniques sont utilisées pour des problèmes pour lesquels il n'existe pas d'algorithme de résolution à temps polynomial et pour lesquels on espère obtenir une solution proche de l'optimum global.

Sur le plan théorique, des théorèmes de convergence ont été établis pour les algorithmes génétiques et le recuit simulé, ce qui légitime l'utilisation de ces techniques. Plusieurs études montrent que qu'avec un temps de calcul substantiel, la probabilité de découvrir une solution optimale est considérablement accrue. [21]

Parmi ces méthodes, on peut citer :

- La méthode Monte Carlo.
- La méthode recuit simulé.

- La méthode branch and bound stochastique.
- La méthode Tabou.
- La méthode des algorithmes évolutionnaires.

Cette catégorie inclut les algorithmes métaheuristiques comme le PSO, l'algorithme différentiel évolutif (DE), les algorithmes génétiques et le recuit simulé. Ces techniques conviennent tout particulièrement aux problèmes qui sont non linéaires, multidimensionnels ou mal définis [23].

II.2.1.3. Différence entre les méthodes déterministes et stochastiques

Si la méthode de résolution progresse de manière prévisible sans recourir à la recherche aléatoire (randomisée), on la qualifie de déterministe. En revanche, les méthodes dites stochastiques reposent sur des processus de transition probabilistes qui fournissent des résultats distincts pour des conditions initiales et des paramètres de contrôle identiques. Certaines méthodes déterministes sont locales, tandis que d'autres peuvent être globales, signifiant ainsi qu'elles convergent vers un optimum qui est uniquement lié au point de départ, qu'il s'agisse d'un optimum local ou global. Toutefois, Les méthodes stochastiques permettent de s'approcher de l'optimum global avec une certaine probabilité. [24]

Tableau II.1 : Différence entre les méthodes déterministes et stochastiques

Critère	Déterministe	Stochastique
Convergence	Locale	Globale probal
Rapidité	Élevée	Moyenne
Complexité	Faible	Élevée

II.2.2. Classification des métaheuristiques

Les métaheuristiques constituent un groupe d'algorithmes d'optimisation conçus pour s'attaquer aux problèmes d'optimisation complexes. Ces méthodes sont souvent basées sur des systèmes naturels, qu'il s'agisse de physique (comme le recuit simulé), de biologie évolutive (comme les algorithmes génétiques) ou même d'éthologie (comme les algorithmes de colonies de fourmis ou l'optimisation par essaims particuliers) [22]. Ces méthodes métaheuristiques se divisent en deux catégories : les techniques à population de solutions, également appelées algorithmes évolutionnaires tels que les algorithmes génétiques, et les méthodes à solution unique comme le recuit simulé. Les techniques métaheuristiques ont démontré leur efficacité

dans le secteur de l'optimisation à objectif unique. À l'heure actuelle, les études impliquant ces algorithmes sont conçues pour résoudre des problèmes d'optimisation multi-critères, tout en prenant en considération diverses contraintes et de nouvelles configurations de réseaux électriques, particulièrement dans le cadre d'associations avec des sources d'énergies renouvelables. La résolution de ce système complexe représente un défi majeur [25].

II.2.2.1. Méthodes métaheuristiques à population

Ce type de techniques nécessite une population d'individus ou de particules dans un domaine d'étude pour l'exploration et la recherche d'une solution optimale globale. On peut trouver parmi ces techniques [26] :

- ❖ Les méthodes de calcul évolutionnaire qui engendrent les algorithmes génétiques (GA), Stratégies d'évolution (SE), la programmation évolutionnaire (PE) et l'évolution différentielle (DE).
- ❖ L'optimisation par l'essaim particulaire (OEP ou PSO).

II.2.2.2. Méthodes Métaheuristiques à solution unique (Parcours)

On utilise une recherche de parcours pour obtenir un optimum avec ce genre de métaheuristiques. Partant d'une solution initiale x_0 , déterminée par exemple grâce à une heuristique constructive, l'objectif de la recherche est de progresser d'une solution vers une autre solution proche grâce à des déplacements successifs. L'ensemble des solutions accessibles à partir d'une solution x est désigné par le terme voisinage $N(x)$ de cette dernière. Trouver une solution voisine de x est bien sûr conditionné par le problème en question. Par exemple, ce type inclut le Recuit Simulé (RS), la Recherche Taboue (RT) et la technique GRASP (*Greedy Randomized Adaptive Search Procedure*) [23].

II.3. Algorithme d'Optimisation par Essaim de Particules (PSO) (Particle Swarm Optimization)

II.3.1. Inspiration biologique et principe de base

Introduite pour la première fois par Kennedy et Eberhart en 1995, l'optimisation par essaim de particules Particle Swarm Optimization (PSO) est une technique stochastique d'optimisation basée sur l'observation des déplacements collectifs de certains animaux sociaux comme les oiseaux migrateurs et les poissons. [24]

Contrairement aux algorithmes génétiques qui simulent les processus évolutifs [24], la PSO est fondée sur l'observation du comportement collectif des volées d'oiseaux et des bancs de poissons, qui tendent à reproduire les actions fructueuses qu'ils perçoivent dans leur environnement tout en ajoutant leurs propres variations [25],[26]. À l'instar des algorithmes génétiques, PSO initie le processus d'optimisation en utilisant une population de solutions aléatoires qui se déplacent à travers l'espace de recherche.

L'intelligence collective de l'essaim découle donc directement des interactions locales entre les diverses particules qui le composent. La performance globale du système résulte des interactions entre les particules. Kennedy et Eberhart [27] ont élaboré l'algorithme PSO en se basant sur ces comportements socio-psychologiques. Un nuage de particules, représentant des solutions potentielles pour le problème d'optimisation, explore l'espace de recherche à la recherche de l'optimum global. Le mouvement d'une particule est affecté par les trois éléments suivants [28] :

- Une composante physique : la particule tend à suivre sa direction courante de déplacement ;
- Une composante cognitive : la particule tend à se diriger vers le meilleur site par lequel elle est déjà passée ;
- Une composante sociale : la particule tend à se fier à l'expérience de ses congénères et, ainsi, à se diriger vers le meilleur site déjà atteint par ses voisins.

II.3.2. Modèle mathématique (Vitesse et Position)

Dans un souci d'optimisation, on évalue la qualité d'un emplacement dans l'espace de recherche en se basant sur la valeur de la fonction objectif à cette position. La figure ci-dessous illustre la stratégie de mouvement d'une particule. [29]




Figure II.2: Déplacement d'une particule. [29]

Chaque particule est décrite par sa position sur les axes XY ainsi que par sa vitesse, représentée par V_x (vitesse sur l'axe x) et V_y (vitesse sur l'axe y).

II.3.2.1. Topologie du voisinage

La structure du réseau social est formée par le voisinage. Les particules au sein d'un voisinage échangent entre elles. Divers voisinages ont été examinés (Kennedy, 1999) et sont pris en compte selon les identifiants des particules plutôt qu'en fonction des données topologiques telles que les distances euclidiennes dans l'espace de recherche [30] :

- Topologie en étoile : chaque particule est reliée à toutes les autres. L'optimum du voisinage est l'optimum global.
- Topologie en anneau : chaque particule est reliée à n particules (en général, $n=3$), c'est la topologie la plus utilisée.
- Topologie en rayon : les particules ne communiquent qu'avec une seule particule centrale.




Figure II.3: Trois topologies du voisinage différentes. [30]

À l'instar des algorithmes génétiques, PSO initie le processus d'optimisation avec une population de solutions aléatoires qui évoluent dans l'espace de recherche. Chaque particule est décrite par ses coordonnées sur les axes XY ainsi que par sa vitesse, définie par V_x (vitesse le long de l'axe x) et V_y (vitesse le long de l'axe y) [25]. Le mouvement de chaque particule dans l'espace de recherche dépend de sa position présente et de la mise à jour de sa vitesse.

$$s_i^{k+1} = s_i^k + v_i^{k+1} \quad (\text{II.1})$$

Tel que :

s_i^{k+1}, s_i^k : Position de la particule i à l'itération $k + 1$ et k respectivement

v_i^{k+1} : vitesse de la particule i à l'itération $k + 1$

Chaque particule dans le nuage modifie sa vitesse en fonction de deux données cruciales. Elle est associée à son expérience individuelle, qui représente la meilleure position déterminée par la particule lors de la procédure de recherche *pbest*. La seconde donnée, relative à la meilleure position découverte par les voisins (*lbest*) (ou par l'ensemble du groupe, dans le cadre de la version globale de l'algorithme *gbest*). Cette information est tirée de la manière dont d'autres agents ont mené leurs investigations. [30]

L'équation (II.2) définit le concept de modification de la vitesse [29] :

$$v_i^{k+1} = wv_i^k + c_1rand_1 \times (pbest_i - s_i^k) + c_2rand_2 \times (gbest - s_i^k) \quad (II.2)$$

Tel que :

v_i^k : vitesse de l'agent i à l'itération k

w : Fonction de pondération

c_j : Facteurs de pondération

$rand_1$ et $rand_2$: sont des nombres aléatoires uniformes dans l'intervalle $[0,1]$.

s_i^k : Position actuelle d'agent i à l'itération k

$pbest_i$: Meilleure position trouvée par la particule i jusqu'ici

$gbest$: Meilleure position trouvée par l'essai jusqu'ici

La fonction de pondération w est donnée par l'équation suivante :

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

w_{max} : Poids initial

w_{min} : Poids final

$iter_{max}$: Nombre d'itérations maximum.

$iter$: Itération courante.

Le rôle de la fonction de pondération w est crucial dans le processus de recherche. Elle assure une balance entre l'investigation locale et mondiale, un choix judicieux de cette fonction boostera l'efficacité de la méthode pour obtenir une solution globale. L'expérience a

démontré que réduire progressivement la valeur de w de 0.9 à 0.4 pendant le processus de recherche produit des résultats supérieurs. [31]

II.3.2.2. Étapes de la méthode d'optimisation par essaim de particules

1ère étape : Initialisation des coefficients $C1$ et $C2$, le coefficient d'inertie (W).

2ème étape : Génération aléatoire de la population initiale et évaluation de l'adéquation de chaque particule ($pbest_i$) : la position optimale de la particule i dans l'ensemble actuel ; ($pgbest$) : la position optimale sur toutes les populations (l'optimum absolu).

3ème étape : L'utilisation des formules pour déterminer la nouvelle vitesse et position de chaque particule.

4ème étape : Le calcul du meilleur fitness de la population initiale et comparer par la précédente pour trouver la meilleure de toute les populations ($pgbest$)

5ème étape : incrémentation du nombre d'itération $t = t+1$.

6ème étape : Si un critère d'arrêt est satisfait alors passer à la 7ème étape.

Autrement, aller à la 3ème étape.

7ème étape : La position enregistrée dans ($pgbest$) est la solution optimale.




Figure II.4: Organigramme de la méthode PSO. [30]

II.3.3. Paramètres de contrôle (Inertie, facteurs d'accélération)

L'algorithme PSO agit de manière fortement dépendante à la sélection de ses paramètres de contrôle en termes de comportement et performance. Ces paramètres ont un impact direct sur la compétence de l'algorithme à parcourir l'espace de recherche (l'exploration) et à tirer parti des solutions prometteuses (l'exploitation). Il est crucial de trouver un juste milieu entre ces deux éléments pour assurer une convergence efficace vers l'optimum global. [32]

❖ Le poids d'inertie (w)

Le rôle du coefficient d'inertie w est crucial pour l'actualisation de la vitesse des particules. Il régule l'impact de la vitesse antérieure sur la vitesse actuelle. En termes mathématiques, il fonctionne comme un multiplicateur de mémoire du mouvement. [28]

- Un w élevé privilégie l'exploration extensive, autorisant les particules à traverser de vastes zones de l'espace de recherche.
- Un w bas privilégie l'exploitation locale, ce qui permet un affinage de la recherche autour des solutions prometteuses.

Dans la mise en œuvre, il est fréquent d'appliquer un poids d'inertie dégressif au fil des itérations. Cela permet de démarrer par une phase d'exploration avant de se focaliser progressivement sur l'exploitation. [25]

❖ Le coefficient cognitif (c_1)

Le facteur cognitif c_1 symbolise la faculté de chaque particule à s'appuyer sur sa propre expérience (meilleure position individuelle p_{best}). [29]

- Une valeur élevée de c_1 encourage les particules à explorer autour de leurs positions individuelles optimales.
- Cela encourage une recherche autonome, mais peut entraver la convergence globale si les particules s'écartent trop.

❖ Le coefficient social (c_2)

Le coefficient social c_2 représente l'impact de la solution optimale globale g_{best} découverte par l'ensemble de la colonie. [29]

- Un grand nombre de c_2 favorise rapidement la convergence des particules vers la solution globale optimale.
- Cependant, cela peut aussi entraîner un danger de convergence anticipée vers un optimum local.

II.3.4. Algorithme général du PSO

L'algorithme général de l'optimisation par essaim de particules (PSO) repose sur un processus itératif visant à mettre à jour les positions et les vitesses des particules dans l'espace de recherche afin de trouver la solution optimale. Chaque particule ajuste son déplacement en fonction de sa propre expérience ainsi que de celle de l'ensemble de l'essaim.

L'algorithme débute par une phase d'initialisation où une population de particules est générée aléatoirement avec leurs positions et vitesses initiales, puis la fonction objectif est évaluée pour chaque particule.

Chaque particule mémorise alors sa meilleure position individuelle (*pbest_i*), tandis que la meilleure solution globale de l'essaim est enregistrée sous la forme (*gbest*).

Ensuite, durant la boucle principale de l'algorithme, la vitesse de chaque particule est mise à jour selon une équation prenant en compte trois composantes essentielles : l'inertie représentant la mémoire du mouvement précédent, l'attraction vers la meilleure solution personnelle et l'attraction vers la meilleure solution globale.

$$v_i(t + 1) = w \cdot v_i(t) + c_1 r_1 (pbest_i - s_i(t)) + c_2 r_2 \times (gbest - s_i(t)) \quad (II.4)$$

Cette équation combine trois influences :

- Inertie (mémoire du mouvement)
- Attraction vers la meilleure solution personnelle
- Attraction vers la meilleure solution globale

La position de la particule est ensuite actualisée à partir de sa nouvelle vitesse, lui permettant ainsi de se déplacer dans l'espace de recherche vers des solutions plus performantes.

$$s_i(t + 1) = s_i(t) + v_i(t + 1) \quad (II.5)$$

Après chaque déplacement, la nouvelle position est évaluée à l'aide de la fonction objectif, puis les valeurs de *pbest*, *ipbest* et *gbest* sont mises à jour lorsqu'une meilleure solution est trouvée. Ce processus itératif se poursuit jusqu'à la satisfaction d'un critère d'arrêt, tel que l'atteinte du nombre maximal d'itérations, la convergence vers une solution stable ou l'obtention d'une valeur seuil de la fonction objectif.[32]

II.4. Algorithme à Évolution Différentielle (DE)

Après la présentation du PSO, nous introduisons maintenant l'algorithme DE. L'algorithme par évolution différentielle (ED) s'inspire des stratégies évolutives et des algorithmes génétiques. Cette proposition a été faite par Rainer Storn et Kenneth Price en 1997 [22]. Il applique trois opérations dérivées des algorithmes évolutionnaires : l'altération, le brassage et la sélection. La création d'un nouvel individu s'effectue en trois étapes. Tout d'abord, une mutation génère un individu à partir d'un groupe d'autres sélectionnés au hasard dans la population. De nombreux modèles de changement ont été établis et seront expliqués ultérieurement. Puis vient une étape de croisement, au cours de laquelle diverses méthodes peuvent être mises en œuvre pour créer un individu dérivant du croisement entre le parent et l'individu précédemment produit. On procède alors à une sélection par substitution.

II.4.1. Principe de fonctionnement

L'algorithme à évolution différentielle (DEA) [30], une méthode méta-heuristique stochastique d'optimisation, fait partie des techniques assez récentes, élaborée pour résoudre des problèmes sur les domaines continus. Cet algorithme s'inspire des stratégies évolutionnistes et des algorithmes génétiques, tout en intégrant une méthode de recherche géométrique. Les individus sont modifiés par les algorithmes génétiques à l'aide de la mutation et du crossover, tandis que les stratégies évolutionnistes effectuent l'auto-adaptation en manipulant géométriquement ces individus. Ces concepts ont été réalisés par une opération de mutation de vecteurs, simple mais néanmoins puissante, proposée par Storm et Price en 1995. L'évolution différentielle s'est depuis imposée comme une approche indispensable, surpassant de nombreuses techniques de recherche stochastique globale existantes pour résoudre un grand nombre de problématiques concrètes [31].

Dans cette méthode, chaque variable décisionnelle est symbolisée dans le chromosome (ou individu) par un chiffre réel. Comme c'est le cas pour tout algorithme évolutionnaire, la population initiale du DEA est produite de manière aléatoire, puis elle est soumise à une évaluation. Par la suite, la procédure de sélection est mise en œuvre. Durant la phase de sélection, trois parents sont sélectionnés et produisent un unique descendant (ou progéniture) qui rivalise avec l'un des parents pour décider lequel perdurera dans la prochaine génération. Le DEA produit un unique descendant (contrairement aux algorithmes génétiques qui en produisent deux) en intégrant le vecteur de différence pondérée de deux parents à un troisième parent. Si le vecteur produit à une valeur inférieure de la fonction objectif par rapport à un

membre prédéfini de la population, le vecteur nouvellement créé prend la place du vecteur avec lequel il a été comparé. [32]

Une tâche d'optimisation comportant D paramètres peut être représentée par un vecteur de dimension D . Au départ, une population de N_p vecteurs solution est générée de manière aléatoire. Au fil des générations, G , cette population est progressivement améliorée grâce à l'utilisation d'opérateurs de mutation, de croisement et de sélection afin d'obtenir une solution optimale [32].




Figure II.5: Schéma de mutation DE[32]

II.4.2 Initialisation de la population

L'algorithme débute en créant une population initiale de NP vecteurs dans un espace ayant une dimension D . On définit chaque individu de la manière suivante[32] :

$$S_i = (s_{i1}, s_{i2}, \dots, s_{iD}) \quad (\text{II.6})$$

Les composantes sont initialisées aléatoirement dans les bornes du problème :

$$s_{ij} = s_j^{\min} + \text{rand}(0,1) \cdot (s_j^{\max} - s_j^{\min}) \quad (\text{II.7})$$

où :

$s_j^{\max}, s_j^{\min}$: bornes inférieure et supérieure

$\text{rand}(0,1)$: nombre aléatoire uniforme

Une initialisation adéquate assure une diversité suffisante, indispensable pour prévenir la convergence anticipée.

II.4.3 Opérateurs génétiques : Mutation, Croisement, Sélection

II.4.3.1 Mutation

Pour chaque individu cible i, G , un vecteur mutant $v_{i, G+1}$ est engendré selon [29] :

$$v_{i, G+1} = s_{r_1, G} + F \cdot (s_{r_2, G} - s_{r_3, G}) \quad (\text{II.8})$$

où r_1, r_2, r_3 sont trois entiers distincts choisis dans l'ensemble $\{1, 2, \dots, NP\}$, et qui ne sont pas égaux à i . Dans l'équation (II.8), F est une constante nommée facteur d'amplification qui détermine l'amplitude de la différence $(x_{r_2, G} - x_{r_3, G})$.

II.4.3.2 Croisement

Suite à la mutation, une opération de croisement est réalisée entre les individus $v_{i, G+1}$ et $s_{i, G}$ dans le but d'apporter une diversité. Pour un croisement binomial (bin), l'équation suivante génère un vecteur $u_{i, G+1} = \{u_{1i, G+1}, \dots, u_{Di, G+1}\}$ [29]:

$$u_{i, G+1} = \begin{cases} v_{ji, G+1} & \text{si } (rand_j(0,1) \leq CR) \quad \text{ou } (j = rnbr(i)) \\ s_{ji, G} & \text{si } (rand_j(0,1) > CR) \quad \text{ou } (j \neq rnbr(i)) \end{cases} \quad (\text{II.9})$$

$\forall j \in \{1, \dots, D\}$

Dans ce contexte, $rand_j(0,1)$ représente un nombre aléatoire $\in [0;1]$ généré selon une distribution uniforme pour la dimension j . $CR \in [0, 1]$ représente une constante connue sous le nom de taux de croisement, tandis que $rnbr(i)$ est un indice dimensionnel sélectionné au hasard, garantissant qu'au moins un paramètre de l'individu mutant $v_{i, G+1}$ est transmis à $u_{i, G+1}$.

II.4.3.3 Sélection

Pour décider si l'individu créé fera partie de la génération suivante ($G+1$) de la population, une condition de sélection est mise en œuvre. Concernant un problème de minimisation, nous avons [24]:

$$s_{i, G+1} = \begin{cases} u_{i, G+1} & \text{si } f(u_{i, G+1}) \leq f(s_{i, G}) \\ s_{i, G} & \text{sinon} \end{cases} \quad (\text{II.10})$$

Ainsi, cet algorithme dispose d'un nombre limité de paramètres : la dimension de la population NP et les coefficients F (F est le facteur d'amplification) et CR (CR le taux de

croisement). Lorsque la taille de la population NP est considérable, elle offre une plus grande exploration de l'espace de recherche et renforce la diversité des orientations potentielles (c'est-à-dire, les variations entre les paires d'individus). Toutefois, une valeur élevée réduit la capacité de convergence de l'algorithme. Le paramètre CR régule l'impact de l'individu ciblé, tandis que F détermine le poids de la trajectoire (c'est-à-dire, la différence calculée dans l'équation (II.8)). L'algorithme 3 décrit le processus global du DE. [21]

II.4.4 Algorithme général du DE

L'algorithme DE peut être décrit de manière structurée comme suit [25]:

❖ **Initialisation :**

- Générer la population initiale
- Évaluer chaque individu

❖ **Répéter jusqu'au critère d'arrêt :**

Pour chaque individu :

- Générer un vecteur mutant V_i
- Appliquer le croisement pour obtenir U_i
- Évaluer U_i
- Appliquer la sélection

❖ **Retourner la meilleure solution trouvée**

II.4.5 Paramètres de contrôle du DE

Les performances de DE dépendent de trois paramètres principaux [21] :

- Taille de la population (NP) : généralement 5D à 10D
- Facteur de mutation (F) : typiquement entre 0.4 et 1
- Taux de croisement (CR) : souvent entre 0.7 et 0.9

Le réglage de ces paramètres influence fortement la convergence et la qualité des solutions.

II.5. Conclusion

Dans ce chapitre, nous avons exposé les concepts clés relatifs aux méthodes d'optimisation et aux algorithmes métaheuristiques. Suite à la présentation de la différence entre les techniques d'optimisation déterministes et stochastiques, nous avons examiné deux algorithmes fréquemment cités dans les publications scientifiques : l'Optimisation par Essaims de Particules (PSO) et l'Évolution Différentielle (DE).

Ces deux algorithmes s'appuient sur des concepts tirés de la nature et sont capables de résoudre de manière efficace des problématiques complexes d'optimisation. Le PSO exploite l'intelligence collective des essaims pour sonder le domaine de recherche, alors que l'algorithme DE fait appel à des processus évolutifs fondés sur la mutation, la reproduction et la sélection.

Ces algorithmes, en raison de leur simplicité, flexibilité et aptitude à résoudre des problèmes non linéaires et multidimensionnels, se sont imposés comme des instruments indispensables dans divers secteurs scientifiques et industriels.

Chapitre III

**Application des Algorithmes
Proposés pour le Dispatching
Économique**

III.1 Introduction

Le problème du dispatching économique (ED) constitue une problématique fondamentale dans l'exploitation optimale des systèmes électriques. Il vise à minimiser le coût total de production tout en satisfaisant la demande énergétique et les contraintes opérationnelles.

Dans ce chapitre, deux approches métaheuristiques sont exploitées :

- Particle Swarm Optimization (PSO)
- Differential Evolution (DE)

Leur intérêt réside dans leur capacité à traiter :

- Les fonctions non convexes
- Les discontinuités (effet Valve-Point)
- Les contraintes non linéaires

III.2. Présentation du réseau d'étude

III.2.1. Réseau test IEEE 30-Bus

Pour vérifier et valider la robustesse de cette nouvelle approche, une étude comparative détaillée a été réalisée entre les méthodes d'optimisation par essaim particulaire (Particle Swarm Optimization - PSO) et l'évolution différentielle (Differential Evolution - DE). L'approche proposée a été testée sur le réseau électrique standard IEEE 30-Bus. La puissance demandée à satisfaire est de 488.07 MW

Les résultats obtenus confirment l'efficacité de cette nouvelle technique d'optimisation. Le schéma unifilaire du réseau IEEE 30-Bus est représenté ci-dessous :




Figure III.1: Schéma du réseau IEEE 30 jeux de barres

Tableau III.1: Paramètre du réseau IEEE 30 jeux de barres

Paramètre	Valeur
Nombre de bus	30
Nombre de générateurs	6
Nombre de lignes	41
Charge totale	488.07 MW

III.3. Méthodologie de résolution proposée

L'approche suggérée pour traiter le problème de l'Economic Dispatch (ED) se base sur une procédure d'optimisation itérative. Elle débute par la création d'un ensemble préliminaire de solutions candidates qui illustrent diverses distributions de la production d'électricité. Chaque option est par la suite examinée en utilisant une fonction de coût pénalisée qui

combine le coût du carburant avec des termes de pénalité pour tenir compte des restrictions du système, comme l'équilibre énergétique et les limites des générateurs.

Par la suite, l'algorithme perfectionne de façon itérative les solutions en les révisant et en les peaufinant grâce à une tactique d'optimisation (telle que PSO ou des techniques comparables), tout en équilibrant l'exploration de nouvelles zones de recherche et l'utilisation des meilleures solutions trouvées. Ce processus continue jusqu'à ce qu'un critère de convergence soit atteint, comme un nombre d'itérations maximal ou la stabilisation de la meilleure solution.

Pour finir, les graphes de convergence sont employés pour examiner la performance de l'algorithme en illustrant le changement de la fonction de coût à travers les itérations. Cela facilite l'évaluation de la rapidité de convergence, la stabilité et l'efficacité de la technique.



Figure III.2: Organigramme de la méthodologie proposée

III.4. Adaptation du PSO au problème ED

III.4.1. Codage des particules et initialisation

Dans la méthode PSO utilisée pour le problème du dispatching économique (ED), chaque particule symbolise une solution possible complète au problème, à savoir un vecteur des puissances produites par les diverses unités de production. Donc, on peut définir une particule de la façon suivante :

$$Particle_i = [P_{g1}, P_{g2}, \dots, P_{gn}] \quad (III.1)$$

Où P_i représente la puissance produite par la i -ème unité de génération.

La performance de l'algorithme est grandement influencée par l'initialisation de la population. Elle est effectuée de façon aléatoire dans les contraintes opérationnelles des générateurs, ce qui garantit une vaste couverture de l'espace d'exploration dès les premières itérations.

III.4.2. Fonction d'évaluation (Fitness function)

L'évaluation joue un rôle crucial dans l'élaboration du problème de Dispatch Économique (ED), puisqu'elle offre la possibilité d'évaluer la performance de chaque solution proposée par l'algorithme d'optimisation. On la définit généralement comme une fonction objectif pénalisée qui combine le coût global de production et les éventuelles infractions aux contraintes du système électrique.

Dans ce contexte, la fonction est exprimée sous la forme suivante :

$$F = \sum_{i=1}^n (a_i P_i^2 + b_i P_{gi} + c_i) + \lambda \left(\sum P_i - P_D \right) \quad (III.2)$$




Figure III.3 : Courbe de Convergence (PSO)

La figure III.3 illustre la courbe de convergence de l'algorithme PSO (Particle Swarm Optimization), représentant l'évolution de la valeur de la fonction objectif (fitness/coût) en fonction du nombre d'itérations. Cette courbe permet d'évaluer le comportement dynamique de l'algorithme, sa vitesse de convergence ainsi que la stabilité de la solution obtenue.

On remarque qu'au début du processus d'optimisation, précisément durant les premières itérations (environ entre 0 et 5 itérations), la valeur du coût diminue de manière extrêmement rapide. La fonction objectif passe d'une valeur initiale très élevée, proche de 3.7×10^5 , à une valeur beaucoup plus faible, de l'ordre de 0.3×10^5 . Cette chute brutale traduit une forte capacité d'exploration globale de l'espace de recherche. Durant cette phase, les particules du PSO se déplacent rapidement sous l'influence de leurs meilleures positions individuelles (pbest) ainsi que de la meilleure position globale (gbest), ce qui permet de localiser rapidement des régions prometteuses contenant des solutions de meilleure qualité.

Après cette phase initiale, à partir d'environ la 5^e itération, la courbe devient presque horizontale et évolue très lentement jusqu'à la 100^e itération. Cette évolution indique que l'algorithme entre dans une phase d'exploitation locale, où les particules ne cherchent plus de nouvelles régions éloignées mais affinent progressivement la meilleure solution déjà trouvée.

La faible variation de la valeur du coût montre que les améliorations successives deviennent minimales, ce qui signifie que l'algorithme approche d'un optimum stable.

L'un des aspects importants observés dans cette figure est l'absence d'oscillations importantes dans la courbe de convergence. En optimisation, les oscillations apparaissent généralement lorsque les particules continuent à se déplacer de manière excessive autour de la solution optimale sans parvenir à se stabiliser. Cela se traduit graphiquement par des montées et descentes répétitives de la valeur du coût. Dans cette figure, la courbe présente au contraire une décroissance monotone et régulière, sans fluctuations brusques ni variations périodiques significatives. Cela indique que les paramètres du PSO (facteur d'inertie, coefficients cognitifs et sociaux) sont correctement équilibrés, permettant aux particules de converger progressivement sans comportement instable.

Cette absence d'oscillations constitue un indicateur important de stabilité numérique et dynamique de l'algorithme. En effet, lorsqu'un algorithme présente de fortes oscillations, cela peut refléter :

- Une vitesse excessive des particules,
- Une mauvaise exploitation de la solution optimale,
- Ou encore une difficulté à atteindre l'équilibre.

Dans le cas présent, la stabilité de la courbe montre que les particules réduisent progressivement leur vitesse et se regroupent autour de la meilleure solution globale sans divergence. Cela signifie que le système d'optimisation atteint un état d'équilibre stable où les nouvelles itérations n'apportent plus que des améliorations très faibles.

Par ailleurs, la stabilité prolongée de la courbe jusqu'à la dernière itération confirme plusieurs propriétés importantes de l'algorithme :

- Une convergence rapide vers une solution satisfaisante,
- Une bonne robustesse du processus d'optimisation,
- Une absence de divergence numérique,
- Et une capacité efficace à maintenir la meilleure solution trouvée.

Cependant, cette convergence très précoce peut également révéler une possible convergence prématurée. En effet, lorsque la courbe devient stable très rapidement, cela peut signifier que les particules ont perdu leur diversité trop tôt et se sont regroupées autour d'un minimum local plutôt que du minimum global réel. Dans ce cas, l'algorithme cesse pratiquement l'exploration de nouvelles régions de recherche. Ce phénomène est fréquent

dans les métaheuristiques lorsque l'équilibre entre exploration et exploitation n'est pas parfaitement maintenu.

Ainsi, la figure III.3 met en évidence un comportement globalement performant du PSO, caractérisé par une convergence rapide, une grande stabilité et l'absence d'oscillations importantes, tout en suggérant la nécessité de surveiller le risque éventuel de convergence prématurée afin de garantir l'obtention de l'optimum global.

III.5 Adaptation du DE au problème ED

III.5.1 Structure du vecteur individu

Dans le cadre du problème ED, chaque individu de la population est représenté par un vecteur de puissances générées correspondant aux différentes unités de production. Cette représentation est similaire à celle adoptée dans PSO.

Les individus sont initialisés de manière aléatoire dans les limites admissibles de fonctionnement de chaque générateur, ce qui permet d'assurer une diversité initiale suffisante et une bonne couverture de l'espace de recherche.

L'absence de composante dynamique telle que la vitesse distingue fondamentalement DE de PSO. En effet, l'évolution des solutions dans DE ne dépend pas d'un historique de mouvement, mais exclusivement des interactions entre individus. Cette particularité permet d'éviter certains phénomènes indésirables tels que les oscillations ou la convergence prématurée, tout en garantissant une meilleure stabilité numérique.

III.5.2 Stratégie de mutation et de croisement

Le mécanisme d'évolution dans DE repose principalement sur deux opérateurs : la mutation et le croisement, suivis d'un processus de sélection.

La mutation constitue l'opérateur central de l'algorithme. Elle consiste à générer un vecteur mutant à partir de la combinaison de trois individus distincts choisis aléatoirement dans la population. Cette opération permet de créer de nouvelles directions de recherche en exploitant les différences entre individus, ce qui favorise l'exploration globale de l'espace des solutions et contribue à maintenir un niveau élevé de diversité au sein de la population.

Le croisement (crossover) intervient ensuite pour combiner le vecteur mutant avec l'individu courant, afin de générer un vecteur essai. Ce mécanisme permet d'introduire un compromis entre exploration et exploitation, contrôlé par le paramètre CR (taux de

croisement). Une valeur élevée de CR favorise l'exploration globale, tandis qu'une valeur plus faible privilégie l'exploitation locale des solutions prometteuses.

Enfin, une étape de sélection est appliquée afin de conserver la meilleure solution entre l'individu courant et le vecteur essai. Ce mécanisme de sélection de type « greedy » garantit une amélioration progressive de la qualité des solutions au fil des itérations.




Figure III.4: Courbe de convergence de l'algorithme DE

La figure de convergence obtenue met en évidence une diminution progressive du coût de production au fil des itérations. Contrairement à PSO, la convergence de DE se caractérise généralement par une évolution plus régulière et plus stable, sans fluctuations brusques.

Dans les premières itérations, la réduction du coût est relativement lente, ce qui traduit une phase d'exploration globale de l'espace de recherche. Cette phase permet à l'algorithme d'identifier plusieurs régions prometteuses. Par la suite, la convergence devient plus marquée et tend vers une stabilisation, indiquant que l'algorithme entre dans une phase d'exploitation autour de la meilleure solution trouvée.

Cette dynamique de convergence démontre la capacité de DE à éviter les optima locaux et à fournir des solutions de haute qualité, en particulier dans les problèmes complexes caractérisés par des fonctions objectif non convexes.

III.6. Gestion des contraintes (Constraint Handling)

La résolution du problème du dispatching économique nécessite la prise en compte de contraintes d'égalité et d'inégalité. Parmi celles-ci, la contrainte d'équilibre entre la production totale et la demande est fondamentale. Cette contrainte est généralement intégrée dans la fonction objectif via une méthode de pénalisation ou par l'introduction d'un multiplicateur de Lagrange.

III.6.1. Traitement des limites de production

Les générateurs du système électrique sont soumis à des contraintes opérationnelles strictes définies par leurs puissances minimales et maximales de production (P_{min} , P_{max}). Ces limites représentent les capacités physiques réelles des unités de production et doivent impérativement être respectées afin d'assurer un fonctionnement sécurisé, stable et économiquement réalisable du réseau électrique. Par conséquent, lors du processus d'optimisation par les algorithmes PSO (Particle Swarm Optimization) et DE (Differential Evolution), chaque solution candidate générée est systématiquement contrôlée afin de vérifier la satisfaction de ces contraintes de bornes.

Dans les métaheuristiques, il est fréquent que certaines particules ou individus dépassent les limites admissibles après les opérations de mise à jour des positions, de mutation ou de croisement. Ces dépassements conduisent à des solutions dites non faisables (infeasible solutions), qui ne correspondent pas à des conditions physiques réalisables du système électrique. Afin d'éviter ce problème, un mécanisme de correction appelé repair mechanism est appliqué après chaque génération de solution.

Le repair mechanism consiste à détecter automatiquement toute variable de puissance active sortant de l'intervalle autorisé, puis à la corriger avant l'évaluation de la fonction objectif. Dans ce travail, cette correction repose principalement sur la clipping technique (ou technique de saturation/projection), largement utilisée dans les problèmes d'optimisation sous contraintes en raison de sa simplicité et de son efficacité numérique.

Le principe de la clipping technique consiste à projeter directement toute valeur dépassant les bornes autorisées vers la limite admissible la plus proche. Mathématiquement, cette opération peut être exprimée par :

$$P_i = \begin{cases} P_{min,i} & \text{si } P_i < P_{min,i} \\ P_{max,i} & \text{si } P_i > P_{max,i} \\ P_i & \text{sinon} \end{cases} \quad (III.3)$$

Ainsi :

- si la puissance générée est inférieure à la limite minimale, elle est automatiquement fixée à P_{min} ,
- si elle dépasse la limite maximale, elle est ramenée à P_{max} ,
- sinon, la valeur est conservée sans modification.

Cette stratégie de réparation présente plusieurs avantages importants dans les algorithmes PSO et DE. Premièrement, elle garantit que toutes les solutions évaluées restent physiquement réalisables tout au long du processus d'optimisation. Deuxièmement, elle évite l'exploration inutile des régions non valides de l'espace de recherche, ce qui réduit le temps de calcul et améliore l'efficacité globale de l'algorithme. Troisièmement, elle contribue fortement à la stabilité numérique du processus d'optimisation en empêchant les particules ou individus de diverger vers des valeurs extrêmes.

Dans le cas du PSO, ce mécanisme limite les déplacements excessifs des particules causés par les mises à jour de vitesse, réduisant ainsi les oscillations importantes autour des bornes de production. Les particules restent alors confinées dans une région de recherche réaliste, ce qui améliore la stabilité de la convergence. Pour l'algorithme DE, le repair mechanism empêche que les opérations de mutation différentielle produisent des individus irréalistes ou trop éloignés des contraintes physiques du problème.

En outre, l'utilisation de la clipping technique favorise une convergence plus rapide vers des solutions optimales ou quasi optimales. En maintenant continuellement les solutions dans le domaine admissible, l'algorithme concentre efficacement la recherche dans les zones pertinentes de l'espace des solutions, ce qui améliore la robustesse et la qualité finale des résultats obtenus.

III.6.2. Gestion de la contrainte d'égalité (Méthode de pénalité)

Dans les problèmes d'optimisation des systèmes électriques, le respect de la contrainte d'équilibre entre la puissance produite et la puissance demandée constitue une condition fondamentale pour garantir la stabilité et le bon fonctionnement du réseau. Cette contrainte d'égalité impose que la somme des puissances générées par les unités de production soit égale à la charge totale demandée, tout en tenant compte des pertes de transmission dans le réseau. Cependant, lors du processus de recherche effectué par les algorithmes métaheuristiques tels que PSO et DE, certaines solutions candidates peuvent violer temporairement cette condition d'équilibre. Afin de guider l'algorithme vers des solutions réalisables, une méthode de pénalité (Penalty Method) est introduite dans la fonction objectif. Cette approche consiste à

pénaliser les solutions qui ne respectent pas la contrainte d'égalité en augmentant artificiellement leur coût total, ce qui réduit leur probabilité d'être sélectionnées comme solutions optimales.

La fonction de pénalité utilisée est donnée par :

$$F_{penalty} = F_{cost} + \lambda \times \left| \sum P_g - P_D - P_L \right| \quad (III.4)$$

où:

$F_{penalty}$: représente la fonction objectif pénalisée utilisée par l'algorithme d'optimisation ;

F_{cost} : correspond au coût total de production calculé à partir des puissances générées ;

λ : est le coefficient de pénalité, utilisé pour contrôler l'importance de la contrainte dans le processus d'optimisation ;

P_g : représente les puissances générées par tous les générateurs ;

P_D : représente la puissance totale demandée par la charge ;

P_L : correspond aux pertes actives dans les lignes de transmission.

Le terme $\sum P_g - P_D - P_L$ représente l'erreur d'équilibre de puissance du système. Lorsque cette différence est nulle, cela signifie que la contrainte d'égalité est parfaitement satisfaite et aucune pénalité supplémentaire n'est appliquée. En revanche, si un déséquilibre apparaît entre la production et la demande, la valeur de la pénalité augmente proportionnellement à cette violation, ce qui entraîne une augmentation de la valeur globale de la fonction objectif.

Ainsi, les solutions non réalisables deviennent moins attractives pour les algorithmes PSO et DE, tandis que les solutions respectant l'équilibre énergétique sont favorisées au cours des itérations. Ce mécanisme permet d'orienter progressivement la population vers la région faisable de l'espace de recherche tout en maintenant la simplicité des algorithmes d'optimisation.

Le choix du coefficient de pénalité λ joue un rôle essentiel dans les performances de l'algorithme. Une valeur trop faible risque de tolérer des violations importantes des contraintes, alors qu'une valeur excessive peut ralentir l'exploration de l'espace de recherche et provoquer une convergence prématurée. Un réglage approprié permet donc d'obtenir un compromis efficace entre l'optimisation du coût et le respect des contraintes physiques du système électrique.




Figure III.5: Évolution du Multiplicateur de Lagrange

On observe que la valeur de λ débute à environ 150 \$/MWh à la première itération, puis augmente très légèrement pour atteindre près de 150.0025 \$/MWh à la deuxième itération. Cette augmentation se caractérise par une variation linéaire, faible et parfaitement régulière, sans aucune oscillation notable.

Ce comportement met en évidence plusieurs points importants :

- Cette légère augmentation traduit une adaptation progressive vers l'état d'équilibre économique, ce qui est typique des problèmes de répartition économique de puissance (Economic Dispatch), où λ représente le coût marginal commun des unités de production.
- La linéarité de la courbe indique une stabilité numérique élevée du processus de calcul ou de l'algorithme d'optimisation.
- L'écart très faible entre les deux valeurs montre que la solution est déjà très proche de la convergence, avec des ajustements minimes nécessaires.
- Ce résultat reflète une grande précision dans la détermination de λ , suggérant que la méthode utilisée (par exemple PSO) a rapidement atteint une solution quasi optimale.

Cela confirme l'efficacité de l'approche adoptée pour résoudre le problème d'optimisation.

III.7. Description des systèmes de test

Afin d'évaluer les performances des algorithmes proposés, plusieurs systèmes de test de complexité croissante ont été considérés. Ces systèmes permettent d'analyser le comportement des méthodes dans des conditions variées, allant de cas simples à des situations plus réalistes et complexes.

III.7.1. Système à 3 générateurs

Ce système constitue un cas de base utilisé pour valider le bon fonctionnement des algorithmes de dispatching économique. Il se caractérise par une structure relativement simple ainsi qu'une fonction de coût quadratique classique permettant d'évaluer efficacement les performances de l'algorithme d'optimisation.

Avant de présenter les résultats de la répartition optimale de la puissance, les caractéristiques économiques et les contraintes opérationnelles des unités de production sont données dans les tableaux suivants.

Tableau III.2 : Coefficients de coût des générateurs

Unité de production	a_i (\$/h)	b_i (\$/MWh)	c_i (\$/MW ² h)
Unité 1	500	5.3	0.004
Unité 2	400	5.5	0.006
Unité 3	200	5.8	0.009

Tableau III.3 : Limites de puissance des générateurs

Unité de production	P_{min} (MW)	P_{max} (MW)
Unité 1	50	200
Unité 2	50	250
Unité 3	50	150

Ces limites définissent les contraintes opérationnelles de chaque unité de production afin d'assurer un fonctionnement stable et sécurisé du système électrique.




Figure III.6: Répartition optimale de la génération.

La figure III.6 illustre la répartition optimale de la puissance produite entre les trois unités de génération dans le cadre du dispatching économique. On observe une distribution non uniforme de la production, où l'unité 2 fournit la contribution la plus élevée avec une puissance proche de 200 MW, suivie de l'unité 1 avec environ 170 MW, tandis que l'unité 3 présente la plus faible contribution avec près de 130 MW.

Cette répartition traduit le principe fondamental du dispatching économique basé sur l'égalisation des coûts marginaux de production. Les unités présentant un coût marginal plus faible sont davantage sollicitées afin de réduire le coût total du système, alors que les unités plus coûteuses produisent une puissance plus faible. De plus, l'absence de saturation au niveau des limites minimales et maximales indique que la solution obtenue résulte d'un équilibre économique naturel plutôt que d'une contrainte imposée par le système.

Les résultats obtenus confirment l'efficacité de l'algorithme appliqué dans la détermination d'une solution optimale respectant simultanément les contraintes opérationnelles et l'objectif de minimisation du coût total de production.

III.7.2. Système IEEE 30 bus (6 générateurs)

Ce système représente un réseau électrique plus réaliste, intégrant plusieurs générateurs ainsi que des pertes de transmission. Il permet d'évaluer la performance des algorithmes dans un contexte plus complexe.

Dans ce cas, les interactions entre les unités de production et les contraintes réseau rendent le problème plus difficile à résoudre, ce qui met en évidence la capacité des algorithmes métaheuristiques à gérer des systèmes de grande dimension.

Toutes les caractéristiques de ce système sont répertoriées dans le Tableau III.1.

III.7.3. Système à 13 générateurs (avec Valve-Point)

Afin de rapprocher le modèle des conditions réelles de fonctionnement des centrales thermiques, ce système prend en considération l'effet Valve-Point, lié à l'ouverture progressive des soupapes d'admission de vapeur des turbines. Contrairement au modèle quadratique classique, cette caractéristique introduit des ondulations dans la fonction de coût de production, ce qui entraîne l'apparition de plusieurs minima locaux.

La fonction de coût tenant compte de l'effet Valve-Point est présentée dans l'équation (I.6).

L'ajout du terme sinusoïdal introduit des irrégularités et des discontinuités dans la courbe de coût, ce qui rend la fonction objectif non convexe. Par conséquent, le problème de dispatching économique devient plus complexe à résoudre, car les méthodes classiques basées sur les gradients peuvent converger vers des minima locaux au lieu de la solution globale optimale. Pour cette raison, les algorithmes métaheuristiques sont particulièrement adaptés à ce type de problème complexe et non linéaire.

III.8. Environnement de simulation et paramètres

Les simulations ont été réalisées à l'aide de l'environnement MATLAB, qui offre des outils performants pour l'implémentation des algorithmes d'optimisation.

Les paramètres des algorithmes ont été choisis de manière à assurer un bon compromis entre la vitesse de convergence et la qualité de la solution :

❖ Pour PSO :

- Taille de la population
- Facteur d'inertie (w)

- Coefficients d'apprentissage (c1, c2)

Tableau III.4 : Paramètres de l'algorithme SPO

Paramètre	Valeur
Population	50
Iterations	100
w	0.9 → 0.4
c1	2
c2	2

❖ Pour DE :

Afin d'assurer une bonne performance de l'algorithme d'Évolution Différentielle (DE) dans la résolution du problème du dispatching économique, plusieurs paramètres de contrôle ont été soigneusement sélectionnés. Ces paramètres influencent directement la qualité des solutions obtenues, la vitesse de convergence ainsi que la capacité de l'algorithme à éviter les optima locaux.

Les principaux paramètres utilisés sont présentés dans le tableau suivant :

Tableau III.5 : Paramètres de l'algorithme DE

Paramètre	Symbole	Valeur
Taille de la population	NP	50
Facteur de mutation	F	0.8
Taux de croisement	CR	0.9
Nombre maximal de générations	Generations	100

- Taille de la population (NP) : représente le nombre d'individus dans la population. Une population plus grande améliore la diversité des solutions mais augmente le temps de calcul.
- Facteur de mutation (F) : contrôle l'amplitude de la mutation appliquée aux individus. Une valeur élevée favorise l'exploration globale de l'espace de recherche.

- Taux de croisement (CR) : détermine la probabilité de croisement entre le vecteur mutant et l'individu courant. Ce paramètre influence l'équilibre entre exploration et exploitation.
- Generations : correspond au nombre maximal d'itérations exécutées par l'algorithme avant l'arrêt du processus d'optimisation.

Le choix approprié de ces paramètres joue un rôle déterminant dans la performance globale des algorithmes, influençant à la fois la vitesse de convergence et la précision des solutions obtenues.

III.9. Conclusion

Dans ce chapitre, nous avons appliqué les algorithmes métaheuristiques PSO et DE au problème du dispatching économique afin de minimiser le coût de production tout en respectant les contraintes du système électrique. L'adaptation des deux méthodes a été détaillée, notamment la représentation des solutions, la fonction objectif et le traitement des contraintes par pénalisation.

Les résultats de simulation montrent que les deux algorithmes convergent efficacement vers des solutions optimales ou quasi optimales. PSO se distingue par une convergence rapide grâce à la coopération entre particules, tandis que DE offre une évolution plus stable et une meilleure exploration de l'espace de recherche.

Les tests réalisés sur différents systèmes, y compris le cas avec effet Valve-Point, confirment la capacité des deux méthodes à traiter des problèmes complexes, non linéaires et non convexes. Enfin, PSO et DE apparaissent comme des approches efficaces, précises et adaptées au dispatching économique, avec des performances qui seront comparées dans le chapitre suivant.

Chapitre IV

**Analyse des résultats et étude
comparative**

IV.1. Introduction

Ce chapitre présente une étude comparative entre les algorithmes métaheuristic PSO et DE appliqués au dispatching économique des systèmes électriques. L'objectif est d'évaluer leurs performances dans différents scénarios, allant des systèmes simples aux réseaux complexes avec pertes de transmission et effet Valve-Point.

La comparaison repose sur plusieurs critères essentiels, notamment le coût de production, les pertes, la vitesse et le temps de convergence, le nombre d'itérations, ainsi que la stabilité et la robustesse des algorithmes face aux problèmes non linéaires.

Les deux méthodes sont testées dans des conditions identiques sur les mêmes systèmes, puis analysées à l'aide de tableaux, courbes et indicateurs statistiques. Les résultats permettent d'évaluer la capacité de PSO et DE à trouver des solutions optimales et à éviter les minima locaux.

Enfin, une comparaison globale entre les deux approches est réalisée afin d'identifier l'algorithme le plus performant pour résoudre le problème du dispatching économique dans des environnements électriques complexes.

IV.2 Cas d'étude N°1 : Système à 3 unités

Dans cette section, nous abordons l'étude de performance et de stabilité à travers le premier cas d'étude, qui porte sur un système électrique composé de trois unités de production. Ce modèle est conçu pour simuler les flux de puissance et les interactions de tension entre les différents nœuds du réseau.




Figure IV.1 : Réseau électrique à 3 bus [21]

IV.2.1 Résultats de simulation

IV.2.1.1 Résultats PSO

- **Cas sans pertes**

Dans ce premier cas d'étude, l'algorithme PSO est appliqué à un système de dispatching économique sans prise en compte des pertes de transmission. Le système considéré comporte trois unités de production thermiques caractérisées par des fonctions de coût quadratiques et des limites minimales et maximales de génération.

L'objectif consiste à répartir de manière optimale la puissance produite entre les générateurs afin de satisfaire la demande totale tout en minimisant le coût global de production. Les simulations ont été réalisées sous MATLAB en utilisant les paramètres standards du PSO, notamment le facteur d'inertie w , les coefficients d'apprentissage c_1 et c_2 , ainsi qu'une population initiale aléatoire respectant les contraintes opérationnelles.

Les résultats obtenus montrent que l'algorithme PSO permet d'obtenir une solution économique stable avec une convergence rapide vers une valeur optimale du coût total. La répartition des puissances respecte les contraintes des générateurs et assure un équilibre précis entre la puissance produite et la demande du système.

Tableau IV.1: Résultats PSO

Unité 1	136.901 MW
Unité 2	164.006 MW
Unité 3	104.822 MW
Génération Totale	405.729MW
Pertes Totales (PI)	5.739 MW
Écart d'équilibre	0.011 MW
Coût Total	26410.187 \$/h




Figure IV.2 : Répartition optimale de la production (PSO)

Les résultats obtenus montrent tout d'abord que la répartition de la puissance entre les unités de production est équilibrée et respecte strictement les contraintes du système. En effet, les unités contribuent respectivement à hauteur de 136.901 MW, 164.006 MW et 104.822 MW, pour une production totale de 405.729 MW. Cette production couvre la demande tout en intégrant les pertes de transmission estimées à 5.739 MW. L'écart d'équilibre quasi nul (0.011MW) confirme la bonne satisfaction de la contrainte d'égalité entre production et demande, ce qui met en évidence la précision et la fiabilité du PSO dans le traitement des contraintes d'optimisation.

Sur le plan économique, le coût total obtenu (26410.187 \$/h) reflète une solution efficace, indiquant que l'algorithme parvient à minimiser la fonction objectif tout en respectant les contraintes techniques du système. Cela témoigne de la capacité du PSO à trouver un compromis optimal entre performance économique et faisabilité opérationnelle.

L'analyse de la courbe de convergence renforce ces observations. En effet, on constate une diminution rapide de la fonction coût au cours des premières itérations, traduisant une phase d'exploration efficace de l'espace de recherche. Les oscillations initiales observées sont dues au comportement collectif des particules qui explorent simultanément différentes zones prometteuses, guidées par les composantes cognitive et sociale de l'algorithme.

Avec l'avancement des itérations, ces fluctuations diminuent progressivement sous l'effet de la réduction du poids d'inertie, ce qui favorise une transition vers une phase

d'exploitation locale plus stable. Finalement, la courbe se stabilise, indiquant la convergence vers une solution optimale ou quasi optimale.

Ainsi, la combinaison des résultats numériques et de l'analyse de convergence met en évidence la robustesse du PSO, sa rapidité de convergence et sa capacité à garantir des solutions à la fois optimales, stables et économiquement efficaces pour le problème du dispatching économique.

- **Cas avec pertes**

Dans ce second cas d'étude, les pertes de transmission sont prises en compte afin de rendre le problème plus réaliste. Les pertes sont calculées à l'aide de la méthode des coefficients B de Kron, largement utilisée dans les problèmes de dispatching économique.

L'expression des pertes est donnée par :

$$P_L = \sum_{i=1}^N \sum_{j=1}^N P_i B_{ij} P_j \quad (IV.1)$$

Où :

P_L : représente les pertes totales de transmission,

P_i et P_j : sont les puissances générées,

B_{ij} : sont les coefficients de pertes du réseau.

Contrairement au cas sans pertes, les pertes sont recalculées à chaque itération de l'algorithme. Elles sont donc variables et dépendent directement de la répartition instantanée des puissances produites.

L'introduction des pertes augmente naturellement la puissance totale générée ainsi que le coût global du système, puisque les générateurs doivent produire une puissance supplémentaire afin de compenser l'énergie perdue dans les lignes de transmission.

IV.2.1.2 Résultats DE

- **Cas sans pertes**

Les résultats obtenus montrent que l'algorithme DE améliore légèrement le coût total par rapport à PSO. Cette amélioration s'explique principalement par la forte capacité d'exploration globale de l'algorithme DE ainsi que par son aptitude à maintenir une diversité importante dans la population.

Grâce aux mécanismes de mutation et de croisement, DE évite plus efficacement les minima locaux et explore plusieurs régions prometteuses de l'espace de recherche avant de converger vers la solution optimale. Cette stratégie permet d'obtenir des solutions légèrement plus économiques tout en conservant une bonne stabilité de convergence.

Tableau IV.2: Résultats DE

Unité 1	137.553 MW
Unité 2	162.767 MW
Unité 3	105.404 MW
Génération Totale	405.724 MW
Pertes (Ploss)	5.736 MW
Écart d'équilibre	0.01236 MW
Coût Total	26409.076 \$/h




Figure IV.3 : Répartition optimale de la production par unité (DE)

Les résultats numériques montrent que l'algorithme DE assure une répartition de puissance très proche de celle obtenue par PSO, avec des valeurs de 137.553 MW, 162.767 MW et 105.404 MW pour les trois unités de production. La génération totale (405.724 MW) permet de satisfaire la demande tout en intégrant les pertes du système (5.736 MW). L'écart d'équilibre extrêmement faible (0.01236 MW) confirme que la contrainte d'égalité entre production et demande est parfaitement respectée, ce qui traduit la robustesse de l'algorithme dans le traitement des contraintes physiques du réseau.

Sur le plan économique, le coût total obtenu (26409.076 \$/h) est légèrement inférieur à celui du PSO, ce qui indique une amélioration marginale de la qualité de la solution. Cette différence, bien que faible, est significative dans un contexte d'optimisation énergétique où chaque réduction du coût global représente un gain important. Cela suggère que DE est capable d'atteindre des régions de recherche légèrement plus optimales grâce à son mécanisme de mutation différentielle, favorisant une exploration plus diversifiée.

L'analyse de la courbe de convergence met en évidence un comportement distinct de celui du PSO. En effet, DE présente une évolution plus régulière et plus stable, sans oscillations importantes, ce qui traduit une exploration progressive et contrôlée de l'espace de recherche. La phase initiale de convergence plus lente reflète une exploration approfondie, permettant d'éviter les minima locaux et d'améliorer la diversité des solutions.

Par la suite, l'algorithme accélère sa convergence lorsque les individus se regroupent autour des meilleures solutions, traduisant une transition efficace vers la phase d'exploitation. Cette dynamique confirme la capacité de DE à maintenir un bon équilibre entre exploration et exploitation, mais avec une tendance plus conservatrice et stable que PSO.

- **La comparaison entre les résultats**

La comparaison entre les résultats met en évidence que les algorithmes PSO et DE offrent des performances très proches en matière de répartition optimale de puissance et de satisfaction des contraintes du problème de dispatching économique. En effet, les deux méthodes aboutissent à une production totale pratiquement identique, avec 405.729 MW pour PSO et 405.724 MW pour DE, permettant de satisfaire la demande énergétique tout en tenant compte des pertes de transmission du système. Les pertes obtenues sont également très similaires, atteignant 5.739 MW avec PSO contre 5.736 MW avec DE, ce qui confirme la capacité des deux approches à intégrer efficacement les contraintes physiques du réseau électrique.

L'analyse de la répartition de puissance entre les unités de production montre également une forte cohérence entre les deux algorithmes. Avec PSO, les unités génèrent respectivement 136.901 MW, 164.006 MW et 104.822 MW, tandis qu'avec DE, les puissances produites sont de 137.553 MW, 162.767 MW et 105.404 MW. Les différences observées demeurent relativement faibles, ce qui indique que les deux algorithmes convergent vers des solutions quasi optimales respectant le principe d'égalisation des coûts marginaux entre les générateurs. Toutefois, on remarque que DE tend à redistribuer légèrement la charge entre les unités, ce qui pourrait expliquer l'amélioration marginale du coût total obtenu.

Du point de vue du respect des contraintes, les deux méthodes démontrent une très grande précision numérique. En effet, l'écart d'équilibre entre la puissance générée et la demande reste extrêmement faible, avec 0.011 MW pour PSO et 0.01236 MW pour DE, des valeurs proches de zéro qui traduisent une excellente satisfaction de la contrainte d'équilibre du système électrique. Cela confirme la robustesse des deux algorithmes dans le traitement des contraintes d'optimisation complexes et leur aptitude à garantir la faisabilité des solutions.

Sur le plan économique, une légère supériorité est observée en faveur de l'algorithme DE. Le coût total de production obtenu avec PSO est de 26410.187 \$/h, tandis que DE atteint un coût légèrement inférieur de 26409.076 \$/h, soit une réduction d'environ 1.111 \$/h. Bien que cette différence paraisse faible à première vue, elle demeure importante dans les systèmes électriques réels fonctionnant en continu, où même une réduction minime du coût de production peut générer des économies considérables sur le long terme. Cette amélioration peut être attribuée à la capacité du mécanisme de mutation différentielle de DE à explorer plus efficacement l'espace de recherche et à éviter certaines convergences prématurées.

L'analyse des courbes de convergence permet également d'expliquer les différences observées entre les deux approches. L'algorithme PSO se caractérise par une convergence rapide dès les premières itérations, grâce aux mécanismes cognitifs et sociaux qui orientent rapidement les particules vers les meilleures régions de recherche. Cependant, cette rapidité s'accompagne de légères oscillations initiales, liées au déplacement simultané des particules autour des meilleures solutions locales et globales. Ces oscillations diminuent progressivement avec la réduction du poids d'inertie, jusqu'à atteindre une convergence stable vers une solution optimale ou quasi optimale.

En revanche, l'algorithme DE présente une évolution plus régulière et plus stable, caractérisée par une convergence initialement plus lente mais plus approfondie. Cette phase d'exploration progressive permet une meilleure diversification des solutions et réduit le risque de convergence vers des minima locaux. Avec l'avancement des itérations, la convergence devient plus rapide lorsque les individus se regroupent autour des meilleures solutions trouvées, assurant ainsi une transition efficace vers une phase d'exploitation plus précise.

Ainsi, la comparaison globale montre que PSO et DE sont deux méthodes performantes et complémentaires pour la résolution du problème du dispatching économique. PSO se distingue principalement par sa rapidité de convergence et son efficacité computationnelle, tandis que DE offre une meilleure stabilité de convergence et une qualité de solution légèrement supérieure sur le plan économique. Les résultats obtenus confirment donc que,

dans ce cas d'étude, DE présente une légère supériorité en termes de coût optimal, alors que PSO demeure particulièrement avantageux lorsqu'une convergence rapide est recherchée.

IV.2.2 Validation par rapport aux méthodes conventionnelles

Afin de valider la pertinence des résultats obtenus, une comparaison est effectuée avec une méthode conventionnelle telle que la méthode de λ -iteration. Cette étape permet de vérifier la cohérence et la précision des solutions fournies par les algorithmes métaheuristiques.




Figure IV.4 : Courbe de convergence de l'erreur (méthode conventionnelle)

La figure IV.4 illustre la courbe de convergence de l'erreur de déséquilibre de puissance ($|\Delta P|$) en fonction du nombre d'itérations dans le cadre de la méthode conventionnelle de λ -iteration.

On observe que l'erreur initiale est relativement faible, de l'ordre de 0.009 MW à la première itération, puis elle diminue de manière rapide et monotone pour atteindre une valeur quasi nulle (proche de 0.0005 MW) dès la deuxième itération. Cette décroissance linéaire et sans oscillation traduit un processus de correction efficace du déséquilibre entre la puissance produite et la puissance demandée.

Ce comportement met en évidence plusieurs éléments importants :

- La méthode de λ -iteration présente une convergence très rapide, puisqu'elle atteint un niveau d'erreur négligeable en un nombre très réduit d'itérations.

- L'absence de fluctuations indique une stabilité numérique élevée, confirmant la robustesse de la méthode conventionnelle dans ce type de problème.
- La faible valeur finale de l'erreur démontre une grande précision dans la satisfaction de la contrainte d'équilibre de puissance, ce qui est essentiel dans les problèmes de répartition économique.

Cette courbe confirme que la méthode conventionnelle utilisée constitue une référence fiable pour la validation des résultats. Elle permet ainsi de vérifier la cohérence et la précision des solutions obtenues par les algorithmes métaheuristiques, en montrant que ces dernières doivent converger vers un déséquilibre de puissance quasi nul pour être considérées comme optimales.

IV.3 Cas d'étude N°2 : Système IEEE 30 bus (avec pertes)

Dans ce second cas d'étude, un système plus complexe est considéré, intégrant les pertes de transmission. Cette complexité supplémentaire rend le problème plus réaliste et plus difficile à résoudre.

IV.3.1 Performance de l'algorithme PSO

L'évaluation des performances de PSO dans ce contexte montre que l'algorithme est capable de réduire rapidement le coût de production dès les premières itérations, grâce à sa capacité d'exploration globale.

IV.3.2 Performance de l'algorithme DE

L'analyse de cette courbe révèle une chute rapide du coût au début du processus, suivie d'une phase de stabilisation. Toutefois, cette rapidité peut parfois conduire à une convergence prématurée vers un optimum local, en particulier dans les systèmes complexes.




Figure IV.5: Distribution de puissance

La répartition de la puissance entre les six générateurs montre que les solutions obtenues par PSO et DE sont très proches, avec de légères différences sur certaines unités. Les générateurs G1 et G2 fournissent les puissances les plus élevées, ce qui indique leur rôle principal dans la production en raison de leur coût plus faible. Les écarts entre PSO et DE restent faibles, ce qui confirme la cohérence des solutions trouvées. Cependant, le DE semble proposer une répartition légèrement plus optimisée sur certains générateurs intermédiaires (comme G3 et G4), ce qui peut expliquer son coût global légèrement inférieur.

IV.3.3 Analyse de la convergence

L'analyse comparative des courbes de convergence met en évidence une différence notable entre les deux algorithmes. En effet, PSO se distingue par une vitesse de convergence élevée, tandis que DE, malgré sa lenteur relative, offre une meilleure précision et une stabilité supérieure. Cette observation met en évidence un compromis important entre la rapidité d'exécution et la qualité de la solution, ce qui doit être pris en compte lors du choix de l'algorithme.




Figure IV.6: Comparaison de performance des algorithmes d'optimisation PSO et DE

Ce la figure IV.6 illustre une comparaison des performances de deux algorithmes métaheuristiques, à savoir PSO (Particle Swarm Optimization) et DE (Differential Evolution), en termes d'évolution de la valeur de la fonction objectif en fonction du nombre d'itérations.

On observe tout d'abord que les deux méthodes présentent une diminution progressive de la valeur de la fonction objectif, ce qui indique qu'elles convergent toutes les deux vers une solution optimale ou quasi optimale. Cependant, des différences notables apparaissent dans la dynamique de convergence :

L'algorithme PSO (courbe bleue) montre une convergence plus rapide dès les premières itérations. La valeur de la fonction objectif chute brusquement au début, ce qui traduit une forte capacité d'exploration suivie d'une exploitation efficace.

En revanche, l'algorithme DE (courbe rouge) présente une convergence plus lente et plus progressive, avec une décroissance plus douce de la fonction objectif.

À partir d'environ 50 à 60 itérations, les deux courbes deviennent presque confondues, indiquant que les deux méthodes atteignent des solutions très proches en termes de qualité. La différence finale entre les deux valeurs est très faible, ce qui témoigne d'une précision comparable des deux algorithmes.

Par ailleurs, la stabilité des courbes en fin d'itérations montre que :

- Les deux méthodes sont numériquement stables,
- Elles ne présentent ni oscillations ni divergences,
- Elles assurent une convergence fiable.

En conclusion, cette comparaison met en évidence que :

- PSO est plus performant en termes de vitesse de convergence,
- DE reste compétitif et offre une convergence progressive mais stable,
- Les deux approches fournissent des solutions de haute qualité, validant ainsi la pertinence des méthodes métaheuristiques pour résoudre ce type de problème d'optimisation.

Ce résultat confirme également la cohérence des solutions obtenues par rapport aux méthodes conventionnelles, comme mentionné dans le texte d'introduction.

IV.4 Cas d'étude N°3 : Système complexe avec effet de vanne

Dans ce troisième cas d'étude, l'effet Valve-Point est introduit dans la fonction de coût, ce qui entraîne l'apparition d'un comportement non linéaire et non convexe.

La courbe de convergence montre une diminution très rapide du coût total dès les premières itérations, passant d'une valeur initiale élevée à une zone proche de l'optimum en un nombre réduit d'itérations. Cette chute brutale traduit une forte capacité d'exploration initiale de l'algorithme d'évolution différentielle (DE). Ensuite, la courbe devient presque plate, indiquant une phase d'exploitation où les améliorations sont marginales. Malgré la présence de l'effet Valve-Point, qui rend la fonction de coût non convexe et irrégulière, l'algorithme parvient à converger de manière stable vers une solution quasi optimale sans oscillations importantes. Cela reflète une bonne robustesse face aux minima locaux induits par les non-linéarités.




Figure IV.9: Distribution de la Puissance (MW)

La figure ci-dessous présente la répartition optimale de la puissance entre les six unités de production (G1 à G6) obtenue lors de la résolution du problème de dispatching économique intégrant l'effet de vanne (Valve-Point Effect).

L'analyse met en évidence la prédominance de l'unité G1, qui assure la plus grande part de la production avec une puissance dépassant 270 MW. Cette forte contribution suggère que cette unité dispose d'un coût de production plus avantageux ou d'une plage de fonctionnement plus flexible, même en présence des non-linéarités introduites par l'effet de vanne.

Les unités intermédiaires G3 et G5 présentent des niveaux de production très proches, autour de 160 MW, traduisant un comportement symétrique dans la répartition de la charge. De manière similaire, G2 et G4 contribuent de façon comparable, avec des puissances légèrement supérieures à 100 MW, ce qui reflète une certaine homogénéité dans leurs caractéristiques économiques.

En revanche, l'unité G6 est la moins sollicitée, avec une production inférieure à 60 MW, ce qui indique qu'elle est utilisée principalement comme unité d'appoint dans la satisfaction de la demande globale.

Dans le contexte non convexe induit par l'effet de vanne, cette répartition illustre la capacité de l'algorithme d'optimisation à gérer les discontinuités et les zones de forte variation de la fonction de coût. La distribution non uniforme obtenue confirme que la solution optimale évite les régions associées à des coûts marginaux élevés, tout en respectant les contraintes d'équilibre entre production et demande.

D'un point de vue académique, cette allocation de puissance résulte de la minimisation d'une fonction objectif rendue complexe par l'introduction de termes sinusoïdaux. L'algorithme a ainsi identifié une configuration optimale des unités de production permettant de minimiser le coût total tout en assurant la stabilité du système sous les contraintes techniques et opérationnelles.

IV.4.1 Comparaison de la qualité de solution

Dans ce contexte complexe, caractérisé par la présence de l'effet Valve-Point et la nature non convexe de la fonction de coût, les résultats obtenus mettent clairement en évidence la supériorité de l'algorithme DE par rapport à PSO en termes de qualité des solutions. En effet, l'introduction de ce type de non-linéarité rend le paysage de recherche beaucoup plus irrégulier, avec plusieurs minima locaux susceptibles de piéger les algorithmes d'optimisation classiques ou moins robustes.

Dans ce cadre, l'algorithme Differential Evolution (DE) se distingue par sa stratégie de mutation basée sur la combinaison vectorielle des solutions de la population. Cette approche lui confère une forte capacité d'exploration de l'espace de recherche, ce qui lui permet de maintenir une diversité suffisante et d'éviter une convergence prématurée vers des solutions sous-optimales. Ainsi, DE est capable de franchir les barrières des minima locaux et de se diriger progressivement vers des zones plus prometteuses contenant des solutions globalement optimales.

En revanche, bien que PSO soit reconnu pour sa rapidité de convergence et son efficacité dans des problèmes relativement simples ou convexes, il peut devenir plus sensible au piégeage dans des optima locaux dans ce type de configuration complexe. Cela s'explique par le fait que son mécanisme de mise à jour repose fortement sur l'influence des meilleures particules, ce qui peut réduire la diversité de la population au cours des itérations.

Par conséquent, les résultats expérimentaux confirment que DE offre un meilleur compromis entre exploration et exploitation dans les environnements fortement non linéaires.

Il parvient ainsi à produire des solutions de meilleure qualité, au prix d'une convergence parfois plus progressive. Cette capacité en fait un algorithme particulièrement adapté aux problèmes d'optimisation complexes tels que le dispatching économique avec effet Valve-Point.

IV.4.2 Robustesse des algorithmes

L'analyse de la robustesse montre que DE présente une stabilité supérieure sur plusieurs exécutions, avec une faible dispersion des résultats. En revanche, PSO, malgré sa rapidité, peut présenter une variabilité plus importante en raison de sa nature stochastique.




Figure IV.10: Évaluation de la robustesse et de la stabilité des algorithmes PSO et DE sur plusieurs exécutions

La figure IV.10 illustre l'évaluation de la robustesse des algorithmes PSO et DE à travers plusieurs exécutions indépendantes. On observe que les valeurs du coût obtenues par l'algorithme DE (points rouges) sont fortement concentrées dans un intervalle étroit, ce qui traduit une faible variance et donc une grande stabilité des résultats. En revanche, les résultats du PSO (points bleus) présentent une dispersion plus importante, indiquant une sensibilité accrue aux conditions initiales et aux composantes aléatoires de l'algorithme.

D'un point de vue statistique, cette différence de dispersion suggère que DE possède une meilleure reproductibilité et une fiabilité supérieure dans la recherche de solutions optimales. Le PSO, bien qu'efficace et rapide en convergence, montre une variabilité plus marquée, ce qui peut conduire à des performances moins prévisibles selon les exécutions.

Ainsi, dans le contexte des systèmes complexes et non linéaires, notamment avec la présence de multiples minima locaux, l'algorithme DE apparaît comme plus robuste et mieux adapté pour garantir des résultats cohérents.

IV.5 Synthèse comparative globale

IV.5.1 Comparaison des coûts de production




Figure IV.11: Comparaison des coûts de production

L'analyse comparative des résultats obtenus par les algorithmes PSO et DE met en évidence la capacité des deux approches à résoudre efficacement le problème du dispatching économique tout en respectant les contraintes opérationnelles du système électrique, notamment les limites de génération, l'équilibre entre la production et la demande ainsi que les pertes de transmission. Toutefois, une différence apparaît au niveau de la qualité économique des solutions obtenues.

Les résultats numériques montrent que l'algorithme DE fournit un coût total de production légèrement inférieur à celui obtenu par PSO. Dans le cas étudié, le coût obtenu par PSO est de 26410.187 \$/h, tandis que DE atteint 26409.076 \$/h, soit une amélioration économique d'environ 1.111 \$/h. Cette amélioration, bien que faible, demeure significative dans le contexte des systèmes électriques fonctionnant de manière continue, où une réduction marginale du coût peut engendrer des économies importantes à long terme.

Le pourcentage d'amélioration du coût obtenu par DE par rapport à PSO peut être calculé à partir de la relation suivante :

$$Amélioration(\%) = \frac{C_{PSO} - C_{DE}}{C_{PSO}} \times 100 \quad (IV.2)$$

En remplaçant par les valeurs obtenues :

$$C_{\text{PSO}} = 26410.187$$

$$C_{\text{DE}} = 26409.076$$

$$\text{Amélioration}(\%) \approx 0.0042(\%)$$

Ce résultat montre que DE présente une amélioration économique d'environ 0.0042 % par rapport à PSO, ce qui confirme une légère supériorité de l'algorithme DE en termes d'optimalité de la solution.

Cette différence peut être expliquée par la forte capacité d'exploration globale de DE, rendue possible grâce aux mécanismes de mutation différentielle et de recombinaison, qui permettent d'éviter plus efficacement les minima locaux et d'explorer plusieurs régions prometteuses de l'espace de recherche avant convergence. En revanche, PSO se distingue par une convergence plus rapide au début du processus d'optimisation, grâce au partage d'informations entre les particules. Toutefois, cette rapidité peut parfois conduire à une convergence prématurée, particulièrement dans les problèmes fortement non linéaires ou non convexes.

Par ailleurs, l'analyse comparative des différentes approches algorithmiques met en évidence la supériorité générale des méthodes métaheuristiques basées sur l'intelligence artificielle (PSO, DE et PSO-DE) par rapport à la méthode conventionnelle Lambda-itératif en matière de minimisation du coût de production. En effet, la méthode classique présente le coût le plus élevé (802.5 \$/h), ce qui souligne ses limites face aux systèmes complexes comportant des pertes réseau et des contraintes non linéaires. À l'inverse, les approches métaheuristiques améliorent significativement les performances économiques, avec des coûts de 799.2 \$/h pour PSO et 798.7 \$/h pour DE, confirmant la légère supériorité de DE.

Enfin, la meilleure performance est obtenue par l'approche hybride PSO-DE, qui atteint un coût minimal de 797.9 \$/h. Ce résultat confirme l'intérêt de combiner les avantages complémentaires des deux algorithmes, en exploitant à la fois la rapidité de convergence de PSO et la robustesse exploratoire de DE, afin d'améliorer davantage la qualité des solutions obtenues pour le problème du dispatching économique.

IV.5.2 Comparaison de la convergence

La convergence représente la capacité de l'algorithme à atteindre une solution stable et optimale après un certain nombre d'itérations. Dans cette étude, le critère de convergence adopté correspond soit :

- à la stabilisation de la valeur de la fonction objectif,
- soit à l'atteinte du nombre maximal d'itérations fixé.

Les résultats obtenus montrent que l'algorithme PSO présente une vitesse de convergence initiale plus rapide que DE. En effet, les particules se dirigent rapidement vers les meilleures solutions grâce aux mécanismes cognitifs et sociaux intégrés dans l'algorithme.

Cependant, l'algorithme DE présente une convergence plus progressive et plus stable. Grâce aux opérations de mutation et de croisement, DE conserve une meilleure diversité dans la population et réduit ainsi le risque de convergence prématurée vers des minima locaux.

L'analyse des courbes de convergence montre également que :

- PSO atteint la stabilité après environ 35 à 40 itérations,
- tandis que DE nécessite environ 50 à 60 itérations,
- mais fournit généralement une solution finale plus précise et plus stable.

Afin de renforcer la validité scientifique des résultats, une analyse statistique peut être réalisée à partir de plusieurs exécutions indépendantes des deux algorithmes. Les indicateurs statistiques recommandés sont :

- la moyenne du coût obtenu,
- le meilleur coût,
- le pire coût,
- l'écart-type,
- ainsi que le taux de convergence.

Cette analyse permet d'évaluer la stabilité et la reproductibilité des performances des algorithmes.

IV.5.3 Comparaison des temps de calcul

Le temps de calcul constitue un critère important dans l'évaluation des performances des algorithmes d'optimisation, notamment pour les applications en temps réel des systèmes électriques.

Dans cette étude, les simulations ont été réalisées sous :

- MATLAB R2023a,
- processeur Intel Core i7,
- fréquence CPU : 3.20 GHz,
- mémoire RAM : 16 Go.

Tableau IV.3: Comparaison des temps de calcul

Methode	Cout	Temps
Lambda	802.5	0.5
PSO	799.2	1.2
DE	798.7	1.5
PSO-DE	797.9	1.8

L'évaluation des performances des algorithmes d'optimisation ne se limite pas uniquement à la qualité des solutions obtenues, mais prend également en considération leur efficacité computationnelle, notamment à travers le temps d'exécution nécessaire pour atteindre une solution optimale ou quasi optimale. L'analyse comparative présentée dans le Tableau IV.2 met en évidence un compromis important entre rapidité de calcul et qualité économique des solutions.

Les résultats montrent que la méthode conventionnelle Lambda-itératif présente le temps d'exécution le plus faible, estimé à 0.5 s, ce qui en fait l'approche la plus rapide parmi les méthodes étudiées. Toutefois, cette rapidité s'accompagne d'une performance économique limitée, puisque cette méthode conduit au coût de production le plus élevé (802.5 \$/h). Ce résultat met en évidence les limites des approches conventionnelles face aux systèmes électriques complexes comportant des pertes de transmission et des fonctions de coût non linéaires, où leur capacité d'exploration reste relativement restreinte.

En revanche, les algorithmes métaheuristiques PSO et DE offrent un compromis plus équilibré entre temps de calcul et qualité des solutions. L'algorithme PSO présente un temps d'exécution de 1.2 s, tout en permettant une réduction significative du coût de production jusqu'à 799.2 \$/h. Cette efficacité computationnelle relativement élevée peut être expliquée par la simplicité du mécanisme de mise à jour des particules, basé principalement sur les composantes cognitive et sociale, ce qui réduit la complexité des calculs à chaque itération et favorise une convergence rapide dès les premières étapes du processus d'optimisation.

De son côté, l'algorithme DE nécessite un temps de calcul légèrement supérieur (1.5 s), mais permet d'obtenir une amélioration économique supplémentaire avec un coût réduit à 798.7 \$/h. Cette augmentation modérée du temps d'exécution s'explique par la présence d'opérations supplémentaires de mutation différentielle et de croisement, qui renforcent la capacité d'exploration globale de l'espace de recherche. Bien que plus coûteux computationnellement, ce mécanisme permet à DE d'éviter plus efficacement les minima

locaux et d'améliorer la robustesse de convergence, justifiant ainsi le léger surcoût temporel observé.

Par ailleurs, l'approche hybride PSO-DE présente le temps d'exécution le plus élevé (1.8 s) en raison de la combinaison des mécanismes de recherche propres aux deux algorithmes. Cependant, cet effort computationnel supplémentaire est compensé par l'obtention du coût de production le plus faible (797.9 \$/h), confirmant que l'intégration des capacités d'exploration de DE avec la rapidité de convergence de PSO permet d'améliorer significativement la qualité finale des solutions.

Il convient également de souligner que le temps de calcul des algorithmes métaheuristiques dépend fortement de plusieurs paramètres, notamment la taille de la population, le nombre maximal d'itérations, la dimension du système étudié, ainsi que la complexité de la fonction objectif et des contraintes associées. Une augmentation de ces paramètres peut améliorer la précision et la robustesse des solutions, mais entraîne généralement une hausse du coût computationnel.

Ainsi, les résultats obtenus montrent qu'aucune méthode ne peut être considérée comme optimale selon un unique critère. Si la rapidité d'exécution constitue le facteur prioritaire, PSO représente une solution avantageuse grâce à son temps de convergence réduit. En revanche, lorsque l'objectif principal est la minimisation maximale du coût et la robustesse des résultats, DE et particulièrement l'approche hybride PSO-DE apparaissent comme les alternatives les plus performantes. Cela met en évidence la nécessité d'établir un compromis entre précision des résultats et effort computationnel, selon les exigences spécifiques du problème de dispatching économique considéré.

IV.5.4 Robustesse

La robustesse représente la capacité d'un algorithme à fournir des résultats stables et reproductibles malgré les variations des conditions initiales ou des paramètres aléatoires.

Afin d'évaluer correctement la robustesse des algorithmes PSO et DE, plusieurs simulations indépendantes doivent être exécutées avec différentes initialisations aléatoires. Dans cette étude, chaque algorithme peut être exécuté plusieurs fois (par exemple 20 ou 30 simulations indépendantes) afin d'analyser la dispersion des résultats obtenus.

Les résultats montrent généralement que :

- PSO présente une convergence rapide mais peut parfois être sensible aux minima locaux,

- tandis que DE offre une meilleure robustesse grâce à sa forte capacité de diversification et à son aptitude à maintenir une diversité importante dans la population.

Cette caractéristique permet à DE de conserver des performances plus stables dans les problèmes complexes, non convexes et comportant plusieurs minima locaux, notamment dans les systèmes avec effet Valve-Point et pertes de transmission.

IV.5.5 Analyse statistique (Meilleur, Pire, Moyenne)

L'analyse statistique constitue une étape essentielle pour évaluer la stabilité, la robustesse et la fiabilité des algorithmes métaheuristiques appliqués au problème du dispatching économique. Contrairement aux méthodes déterministes, les algorithmes PSO et DE reposent sur des mécanismes stochastiques, ce qui implique que les résultats peuvent varier légèrement d'une exécution à une autre en raison de l'initialisation aléatoire des populations et des mécanismes d'exploration de l'espace de recherche. Pour cette raison, il est nécessaire d'effectuer plusieurs simulations indépendantes afin d'évaluer statistiquement leurs performances.

L'analyse statistique est généralement basée sur trois indicateurs principaux : le meilleur coût obtenu (Best), le pire coût obtenu (Worst) et le coût moyen (Average) calculé sur plusieurs exécutions indépendantes. Le meilleur résultat représente la solution optimale atteinte par l'algorithme, traduisant sa capacité maximale d'optimisation. À l'inverse, le pire résultat permet d'évaluer le comportement de l'algorithme dans les cas les moins favorables et renseigne sur sa sensibilité aux conditions initiales. Enfin, la valeur moyenne fournit une indication globale sur la stabilité et la régularité des performances.

Dans le cas étudié, les résultats précédemment obtenus montrent que DE atteint un coût minimal légèrement inférieur à celui de PSO, avec une valeur optimale de 26409.076 \$/h, contre 26410.187 \$/h pour PSO, ce qui suggère une meilleure capacité d'exploration globale. Cependant, la rapidité de convergence du PSO lui permet d'atteindre rapidement des solutions proches de l'optimal, bien que sa performance puisse être légèrement influencée par le risque de convergence prématurée.

En général, un algorithme est considéré comme plus robuste lorsque l'écart entre les valeurs Best, Worst et Average reste faible, traduisant une faible sensibilité aux variations aléatoires et une convergence stable. À cet égard, DE tend à présenter une meilleure stabilité statistique, grâce à son mécanisme de mutation différentielle qui maintient une plus grande diversité dans la population. En revanche, PSO, bien que plus rapide, peut parfois produire une dispersion légèrement plus importante entre les différentes exécutions.

Ainsi, l'analyse statistique des performances permet de confirmer les observations issues des courbes de convergence et des résultats économiques. PSO se distingue principalement par sa rapidité computationnelle, tandis que DE démontre une meilleure robustesse et une qualité de solution plus stable, ce qui renforce son intérêt pour les problèmes de dispatching économique complexes comportant des non-linéarités et plusieurs minima locaux.

IV.6 Discussion générale

Cette étude comparative a permis d'évaluer les performances des algorithmes métaheuristiques PSO (Particle Swarm Optimization) et DE (Differential Evolution) appliqués au problème du dispatching économique des systèmes électriques dans différents contextes de complexité : systèmes simples, réseaux avec pertes de transmission et systèmes non convexes intégrant l'effet Valve-Point. Les résultats obtenus montrent clairement que les deux approches sont capables de fournir des solutions optimales ou quasi optimales tout en respectant les contraintes opérationnelles du réseau. Toutefois, plusieurs différences importantes apparaissent en termes de qualité des solutions, vitesse de convergence, stabilité et robustesse.

L'analyse des résultats met tout d'abord en évidence que l'algorithme DE offre généralement de meilleures performances économiques que PSO, notamment dans les problèmes complexes et non convexes. Cette supériorité s'explique principalement par le mécanisme de mutation différentielle qui caractérise DE. En effet, cette stratégie permet une exploration plus diversifiée de l'espace de recherche et réduit considérablement le risque de convergence prématurée vers des minima locaux. Dans les systèmes comportant l'effet Valve-Point, où la fonction objectif présente des ondulations et plusieurs optima locaux, cette capacité d'exploration devient particulièrement importante. DE parvient ainsi à maintenir une diversité suffisante au sein de la population, ce qui améliore progressivement la qualité des solutions obtenues.

Par ailleurs, l'algorithme DE présente une convergence plus régulière et plus stable. Contrairement à PSO, les courbes de convergence obtenues avec DE montrent peu d'oscillations et une évolution progressive vers l'optimum global. Cette stabilité améliore la robustesse de l'algorithme et garantit une meilleure reproductibilité des résultats sur plusieurs exécutions indépendantes. Les analyses statistiques réalisées à partir des valeurs Best, Worst et Average confirment également que DE possède une variance plus faible, traduisant une meilleure fiabilité dans les systèmes fortement non linéaires.

Cependant, malgré ces avantages, l'algorithme PSO présente plusieurs points forts qui le rendent particulièrement intéressant dans certaines situations. En effet, PSO se distingue principalement par sa rapidité de convergence et sa simplicité de mise en œuvre. Grâce aux mécanismes cognitifs et sociaux qui orientent rapidement les particules vers les meilleures régions de recherche, PSO atteint souvent une solution satisfaisante en un nombre réduit d'itérations. Cette caractéristique est particulièrement avantageuse dans les applications nécessitant une réponse rapide ou un temps de calcul réduit, notamment dans les systèmes de petite ou moyenne dimension et les problèmes relativement convexes.

Ainsi, PSO apparaît plus adapté lorsque :

- la rapidité d'exécution constitue le critère principal,
- le problème possède une structure relativement simple,
- le nombre de générateurs reste limité,
- ou lorsque les contraintes computationnelles sont importantes.

À l'inverse, DE devient plus performant lorsque :

- le système étudié est fortement non linéaire,
- la fonction objectif est non convexe,
- plusieurs minima locaux sont présents,
- ou lorsqu'une meilleure robustesse et une plus grande précision sont recherchées.

L'étude met également en évidence l'influence importante des paramètres de contrôle sur les performances des deux algorithmes. Dans le cas du PSO, les coefficients cognitifs et sociaux ($c1$ et $c2$) ainsi que le poids d'inertie (w) jouent un rôle déterminant dans l'équilibre entre exploration et exploitation. Une valeur élevée du poids d'inertie favorise l'exploration globale mais peut ralentir la convergence, tandis qu'une valeur faible améliore l'exploitation locale mais augmente le risque de convergence prématurée.

De manière similaire, les performances de DE dépendent fortement du facteur de mutation (F) et du taux de croisement (CR). Un facteur de mutation élevé améliore la diversification et l'exploration globale, mais peut provoquer des instabilités dans la convergence. En revanche, un faible facteur de mutation accélère la convergence mais réduit la capacité d'exploration. Le taux de croisement influence quant à lui la combinaison des solutions et le maintien de la diversité au sein de la population.

La taille de la population (Population Size) constitue également un paramètre essentiel pour les deux méthodes. Une population importante permet une meilleure couverture de

l'espace de recherche et améliore la probabilité d'atteindre l'optimum global. Toutefois, cette augmentation entraîne un coût computationnel plus élevé et un temps d'exécution plus important. À l'inverse, une population trop faible réduit la diversité des solutions et augmente le risque de stagnation dans des minima locaux.

Le nombre maximal d'itérations influence directement la précision des solutions obtenues. Un nombre réduit d'itérations peut conduire à une convergence incomplète, tandis qu'un nombre élevé améliore généralement la qualité des résultats mais augmente le temps de calcul. Les résultats obtenus montrent que PSO atteint la stabilité plus rapidement, généralement entre 35 et 40 itérations, alors que DE nécessite souvent entre 50 et 60 itérations pour converger vers une solution plus stable et plus précise.

Enfin, cette étude montre qu'aucun algorithme ne peut être considéré comme universellement supérieur dans toutes les situations. Le choix de la méthode d'optimisation dépend fortement de la nature du problème traité, des contraintes de calcul et des objectifs recherchés. PSO représente une solution efficace lorsque la rapidité et la simplicité sont prioritaires, tandis que DE apparaît plus approprié pour les problèmes complexes nécessitant une forte capacité d'exploration et une meilleure robustesse.

Les résultats obtenus confirment également l'intérêt des approches hybrides combinant les avantages complémentaires des deux méthodes. L'algorithme hybride PSO-DE permet en effet d'exploiter simultanément la rapidité de convergence du PSO et la robustesse exploratoire du DE, conduisant ainsi à une amélioration globale des performances en termes de coût optimal, stabilité et qualité des solutions.

IV.7 Conclusion

Dans ce chapitre, une étude comparative des algorithmes PSO et DE appliqués au problème du dispatching économique a été réalisée sur différents systèmes, incluant des réseaux avec pertes de transmission et effet Valve-Point. Les résultats montrent que les deux méthodes permettent d'obtenir des solutions optimales ou quasi optimales tout en respectant les contraintes du système électrique.

L'analyse des performances révèle que PSO se distingue par une convergence rapide et une bonne efficacité computationnelle, tandis que DE offre une meilleure stabilité, une plus grande robustesse et une qualité de solution légèrement supérieure, notamment dans les problèmes non linéaires et non convexes comportant plusieurs minima locaux.

L'étude des temps de calcul met également en évidence un compromis entre rapidité d'exécution et qualité des résultats. Bien que la méthode conventionnelle soit plus rapide, les

approches métaheuristiques obtiennent des coûts de production plus faibles. Par ailleurs, l'approche hybride PSO-DE a montré les meilleures performances globales grâce à la combinaison des avantages des deux méthodes.

Enfin, cette étude confirme que le choix de l'algorithme dépend de la complexité du problème et des objectifs recherchés : PSO est plus adapté aux applications nécessitant une convergence rapide, tandis que D'est préférable pour les systèmes complexes exigeant une meilleure robustesse et précision.

Conclusion générale

Conclusion générale

Au terme de ce travail, nous avons étudié le problème du dispatching économique dans les systèmes électriques, en mettant l'accent sur l'utilisation des algorithmes métaheuristiques pour améliorer les performances d'optimisation.


Les résultats obtenus ont montré que les algorithmes PSO et DE sont capables de fournir des solutions optimales ou quasi optimales, même en présence de contraintes complexes et de fonctions non linéaires. L'algorithme DE a démontré une légère supériorité en termes de qualité de solution (coût minimal), tandis que PSO s'est distingué par une convergence rapide et une grande précision.

La comparaison avec les méthodes classiques a confirmé l'efficacité et la robustesse des approches proposées, notamment pour les systèmes de grande dimension et les problèmes non convexes.

Dans la perspective d'approfondir et d'améliorer cette étude, plusieurs axes de développement peuvent être envisagés :

- L'intégration des énergies renouvelables (solaire, éolien) dans le modèle de dispatching économique
- L'étude de l'optimisation multi-objectifs (coût, émissions polluantes, stabilité du réseau)
- L'utilisation d'algorithmes hybrides combinant plusieurs techniques métaheuristiques
- L'application à des systèmes électriques réels à grande échelle
- L'intégration de l'intelligence artificielle et du machine learning pour améliorer la performance des algorithmes

Ces perspectives ouvrent la voie à des recherches futures visant à améliorer encore davantage l'efficacité et la durabilité des systèmes énergétiques.



References


Bibliographiques

REFERENCES BIBLIOGRAPHIQUES

- [1] I. ZIANE, “contribution à l'application de l'optimisation multi-objective par la méthode de recuit simulé au dispatching dynamique”, Thèse de Doctorat, Université DJILLALI LIABES-Sidi-Bel-Abbès, 2018
- [2] O. KHAMED "Dispatching économique dynamique des réseaux électriques par les méthodes méta-heuristique" Thèse de Doctorat, Université Mohamed Khider Biskra, 2013.
- [3] Mostefa HAMED, " Dispatching Economique Dynamique par Utilisation de Méthodes d'Optimisation globales" Thèse de Magister, Université Mohamed Khider Biskra, 2013.
- [4] Mostefa HAMED, " Dispatching Economique Dynamique par Utilisation de Méthodes d'Optimisation globales" Thèse de Magister, Université Mohamed Khider Biskra, 2013.
- [5] Bouhanik Anes & Mchouchi EL ALdja, " Algorithme d'Ecosystème Artificiel destiné à l'Optimisation appliqué au Dispatching Economique (AEO)" Thèse de Doctorat, Université Mohamed Khider Biskra, 2020.
- [6] BEN ALI Mokbel, CHETUOUI Abdelkarim, " Optimisation de l'emplacement des condensateurs dans un réseau de distribution radiale par un algorithme métaheuristique." MÉMOIRE DE MASTER, Echahid Hamma Lakhdar - El Oued, 2025.
- [7] " BOUDDOU Riyadh, Optimisation du profit dans un marché d'électricité concurrentie", Thèse de Doctorat, UNIVERSITE DJILLALI LIABES DE SIDI-BEL-ABBES, 2022.
- [8] Abdani Rafik , Mémoire de Magistère “ optimisation de l'écoulement de puissance dans un marché d'électricité dérégulé par essaim de particules” Centre universitaire d'Oum el Bouaghi , 2007.
- [9] BELGANDI Imad Eddine. MEDJBER Rédha, « Application de la méthode (simulated Annealing) pour le calcul du dispatching économique », Mémoire de Master, Université Tahar Moulay-Saïda, 2017.
- [10] Y. SALHI, “Contribution à l'étude de dispatching dynamique d'un système énergétique dans un marché libre de l'électricité”, thèse de Doctorat de l'université de Sidi Bel Abbès, 2018.
- [11] YAHIA Bouthaina, " Méthode de recherche du corbeau améliorée et appliquée au dispatching économique", MÉMOIRE DE MASTER, Université Mohamed Khider Biskra, 2019.
- [12] Douida Nedjmeddine, Algorithme de recherche du corbeau dédié à l'optimisation appliqué au dispatching économique, mémoire de master à université de Biskra, 2017.

- [13]B. MAHDAD, “Dispatching Economique par Matlab”, El-Djazair, Alger, 2014.
- [14]LABED Imen, dispatching économique dans un système de Puissance électrique par L’intelligence Artificielle, mémoire de magistère à Université de Constantine 1 ,2013.
- [15]A. MESSAOUDI, “Application de la Programmation Orientée Objet et des Méthodes Heuristiques à l’Optimisation de l’Ecoulement de Puissance”, thèse de Doctorat, Université de Batna, 2013.
- [16]NESRAT Djebbari. SOLTANI Elbachir, « Résolution du problème de puissance active dans un réseau d’énergie utilisant les techniques méta-heuristique » Mémoire de Master, Université Hamma Lakhder-El-Oued, 2018.
- [17]ABID Yakoub. CHENNOUF Lakhdar. CHELI Salah, « Application d'une méthode méta heuristique à la répartition optimale des puissances dans les réseaux électriques avec une fonction multi objective » Mémoire de Master, Université Hamma Lakhder-El-Oued, 2016.
- [18]S. Moussa « Optimisation de l’écoulement de puissance par une méthode métaheuristiques (technique des abeilles) en présence d’une source renouvelable (éolienne) et des dispositifs FACTS » Mémoire de Magister, Université de Sétif 2012.
- [19]Douis Imad Eddine et Chemsah Mohamed Taher « Résolution de dispatching économique par des méthodes d’optimisations métaheuristique » L’Université Echahid Hamma Lakhdar d’El Oued ,2017.
- [20]Jebari Hakim, Rahali, Azzoizi Saida, Samadi Hassan “Hybridation des Métaheuristiques pour la Résolution de Problème D’ordonnancement Multi-Objectif dans un Atelier Flow-Shop”, <https://hal.archives-ouvertes.fr/hal-01260744> ,23 avril 2016
- [21]GACEM Abdelmalek Application des algorithmes génétiques à l’optimisation de la production énergie active dans réseau électrique Université d’EL-Oued 2014
- [22]Alain Berro. Thèse doctorat. Optimisation multi-objectif et stratégies d’évolution en environnement dynamique. Université des sciences sociales Toulouse I, le 18 décembre 2001.
- [23]SLIMANI Linda. Thèse doctorat. Contribution à l’application de l’optimisation par des méthodes méta-heuristiques à l’écoulement de puissance optimal dans un environnement de l’électricité dérégulé, 2009.
- [24]Mostefa HAMED. Mémoire de Magister. Dispatching Economique Dynamique par Utilisation de Méthodes d’Optimisation globales. Université Mohamed Khider – Biskra,2013.

- [25] ABID YAKOUB, CHENNOUF LAKHDAR, CHELI SALAH," Application d'une méthode métaheuristique à la répartition optimale des puissances dans les réseaux électriques avec une fonction multi objective", Mémoire présenté en vue de l'obtention du diplôme Master Académique en Electrotechnique 2016
- [26] J. Kennedy and R. C. Eberhart, Swarm Intelligence. San Francisco, CA : Morgan Kaufmann, 2001.
- [27] L. Kartobi," Optimisation de la Synthèse des FACTS par les Algorithmes Génétiques et les Essaims Particulaires pour le contrôle des Réseaux Electriques ", thèse Magister, ENP, Décembre 2006.
- [28] J. Kennedy and R. Eberhart "Particle Swarm Optimisation", In Proc 1995 IEEE. International conférence on Neural Networks '', Perth, Australie.
- [29] Rabah BENABID Optimisation Multiobjectif de la Synthèse des FACTS par les Particules en Essaim pour le Contrôle de la Stabilité de Tension des Réseaux Electriques Université de Jijel 2007
- [30] Sayeh Samir "Application de l'Intelligence Artificielle pour le Fonctionnement Optimal des Systèmes Electriques Thèse de doctorat université de Sétif Algérie.
- [31] L. Wu, Y. Wang, X. Yuan, S. Zhou, "Environmental/economic power dispatch problem using multibjective differential evolution algorithm'', Elect. Power Syst. Res. 80 (2010) 1171–1181.
- [32] A. Salhi 1, T. Bouktir 2, Résolution du Problème de Dispatching Economique par les Méthodes Métaheuristiques en utilisant la Logique Floue, Roadef 2013, Troyes France.



Annexe

Données du problème de Dispatching Économique

Tableau 1. Demande totale

Variable	Valeur
Pd	400 MW

Tableau 2. Coefficients de coût des unités de production

Unité	α	β	γ	Pmin (MW)	Pmax (MW)
1	25	10	0.4	30	500
2	20	6	0.35	30	500
3	35	15	0.5	30	300

Tableau 3. Matrice des coefficients de pertes (B)

	Unité 1	Unité 2	Unité 3
Unité 1	9e-5	0.7e-5	0.8e-5
Unité 2	0.7e-5	8e-5	0.75e-5
Unité 3	0.8e-5	0.75e-5	10e-5