

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

Université Saad Dahlab -Blida 1-
Faculté de Technologie
Département d'Automatique et électrotechnique



THESE

Présentée pour l'obtention du diplôme de

DOCTORAT

Spécialité : Réseaux Electriques

Par

Wahiba EL Mestari

Thème

Optimisation Technico-Economique des Système Hybrides à Energies Renouvelables par La Méthode des Plans d'Expérience

Devant un jury composé de

Rafik BRADAI	Professeur	USD Blida 1	Président
Karim SEBAA	Professeur	E.N.P Alger	Examineur
Rachid BOUKENOU	MCA	USD Blida 1	Examineur
Souhil MOUASSA	MCA	UNIV. Bouira	Examineur
Nawal CHEGGAGA	Professeur	USD Blida 1	Directrice de thèse

الملخص:

تلعب طاقة الرياح دوراً محورياً في التحول العالمي نحو إنتاج كهرباء مستدامة، غير أن تحسين توزيع توربينات الرياح داخل المزرعة يمثل مشكلة معقدة وغير خطية نتيجة لتأثيرات الذيل الهوائي والقيود البيئية. وتتمثل مثل معدلي العبور والطفرات –الإشكالية الرئيسية لهذا العمل في الضبط الأمثل لمعاملات الخوارزمية الجينية من أجل تحسين عملية البحث عن التوزيع الأمثل للتوربينات مع تقليل تأثير الذيل الهوائي. ولمعالجة هذه الإشكالية، تقترح هذه الأطروحة منهجاً هجيناً يجمع بين الخوارزميات الجينية ومنهجية تصميم التجارب من أجل ضبط منهجي وعلمي لمعاملات الخوارزمية. تم تنفيذ تصميم (Design of Experiments, DOE) (لدراسة تأثير هذه المعاملات وتحديد تفاعلاتها، مما أدى إلى تحسينات ملحوظة في سرعة 2^2 عاملي كامل) التقارب والصلابة والأداء العام للخوارزمية الجينية. وقد طبقت المنهجية على مزرعة رياح نموذجية ذات رياح أحادية الاتجاه وقيود مكانية، باستخدام دالة ملائمة تدمج نموذج جنسن لتأثير الذيل الهوائي. أظهرت النتائج تحسناً كبيراً في إنتاج الطاقة واستقرار الحلول مقارنة بالتوزيعات التقليدية، وكذلك تحسناً في استغلال الموقع وجود (والانحدار ANOVA) كما أكد التحليل الإحصائي (PSO) مقارنة بخوارزمية تحسين سرب الجسيمات تفاعلات ذات دلالة بين معاملات الخوارزمية الجينية. وبالمقارنة مع الدراسات السابقة، أظهرت المنهجية $2.5\% +$ وآخرين [17]، وبنسبة Mosetti مقارنة بـ $18.8\% +$ المقترحة تحسناً في إجمالي الطاقة المنتجة بنسبة والطاقة المنتجة، (91.298%) وآخرين [19]. إضافة إلى ذلك، حققت توازناً فعالاً بين الكفاءة Grady مقارنة بـ وآخرين، مما يؤكد أهمية الضبط Grady مقارنة بـ $17.6\% +$ مع تقليص عدد الأجيال اللازمة للتقارب بنسبة القائم على منهجية تصميم التجارب مقارنة بالأساليب التجريبية. ويقدم هذا العمل إطاراً علمياً صارماً وقابلاً للتكرار لتطوير تحسين تقني-اقتصادي لمزارع الرياح، مع آفاق عملية لتطبيقه في التخطيط التكيفي لأنظمة الطاقة المتجددة واسعة النطاق.

الكلمات المفتاحية

طاقة الرياح؛ تحسين توزيع التوربينات؛ الخوارزمية الجينية؛ منهجية تصميم التجارب؛ ضبط معاملات الخوارزمية؛ تأثير الذيل الهوائي؛ نموذج جنسن؛ إنتاج الطاقة

Résumé

L'énergie éolienne joue un rôle central dans la transition mondiale vers une production d'électricité durable. Cependant, l'optimisation de la disposition des turbines dans une ferme éolienne demeure un problème complexe et non linéaire, en raison des interactions de sillage et des contraintes environnementales. La problématique principale de ce travail réside dans le réglage optimal des paramètres de l'algorithme génétique (AG) afin d'améliorer la recherche de la configuration

optimale des éoliennes tout en réduisant l'effet de sillage. Pour répondre à cette problématique, cette thèse propose une approche hybride combinant les algorithmes génétiques (AG) avec la méthode des plans d'expériences (Design of Experiments, DOE) pour un réglage systématique et scientifique des paramètres algorithmiques. Un plan factoriel complet 2^2 a été mis en œuvre pour étudier l'influence de ces paramètres et identifier leurs interactions, conduisant à une amélioration notable de la rapidité de convergence, de la robustesse et des performances globales de l'AG. La méthodologie a été appliquée à une ferme éolienne modélisée avec un vent unidirectionnel et des contraintes spatiales, en utilisant une fonction de fitness intégrant le modèle de sillage de Jensen. Les résultats ont montré une amélioration significative de la production d'énergie et de la stabilité des solutions par rapport aux agencements classiques, ainsi qu'une meilleure exploitation du site comparée à l'optimisation par essaim particulaire (PSO). L'analyse statistique (ANOVA et régression) a confirmé l'existence d'interactions significatives entre les paramètres de l'algorithme génétique. Comparée aux études antérieures, l'approche méthodique utilisée dans cette recherche a permis d'améliorer la puissance totale produite de +18,8 % par rapport à Mosetti et al. [17] et de +2,5 % par rapport à Grady et al. [19]. De plus, elle atteint un compromis performant entre efficacité (91,298 %) et puissance, avec une génération de convergence réduite de 17,6 % par rapport à Grady et al., illustrant la pertinence d'un réglage basé sur les plans d'expériences face aux approches empiriques. Ce travail fournit enfin un cadre rigoureux, reproductible et généralisable pour l'optimisation technico-économique des parcs éoliens, ouvrant des perspectives concrètes pour la planification adaptative des systèmes d'énergie renouvelable à grande échelle

Mots-clés : Algorithme génétique (AG) ; Plans d'expériences (DOE) ; Réglage des paramètres ; Effet de sillage ; Modèle de Jensen ; Production d'énergie.

Abstract

Wind energy plays a central role in the global transition toward sustainable electricity production. However, optimizing the layout of turbines within a wind farm remains a complex and nonlinear problem due to wake interactions and environmental constraints. The main problem addressed in this work lies in the optimal tuning of Genetic Algorithm (GA) parameters in order to enhance the

search for the optimal turbine configuration while mitigating the wake effect. To tackle this issue, this thesis proposes a hybrid approach combining Genetic Algorithms (GA) with the Design of Experiments (DOE) method for a systematic and scientific tuning of algorithmic parameters. A full factorial design 2^2 was implemented to study the influence of these parameters and identify their interactions, leading to significant improvements in convergence speed, robustness, and overall GA performance. The methodology was applied to a wind farm modeled under unidirectional wind and spatial constraints, using a fitness function integrating Jensen's wake model. The results demonstrated a significant improvement in energy production and solution stability compared to conventional layouts, as well as better site utilization compared to Particle Swarm Optimization (PSO). Statistical analyses (ANOVA and regression) confirmed the presence of significant interactions between GA parameters. Compared with previous studies, the methodological approach used in this research improved total power output by +18.8% relative to Mosetti et al. [17] and by +2.5% relative to Grady et al. [19]. Moreover, it achieved an efficient trade-off between power and effectiveness (91.298%) with a 17.6% reduction in convergence generations compared to Grady et al., illustrating the relevance of DOE-based tuning over empirical methods. This work provides a rigorous, reproducible, and generalizable framework for the techno-economic optimization of wind farms, offering concrete perspectives for adaptive planning of large-scale renewable energy systems

Keywords: Wind farm layout optimization; Genetic algorithm (GA); Design of experiments (DOE); Parameter tuning; Wake effect; Jensen model; Power generation.

Remerciements

Avant toute chose, je rends grâce à Allah, Le Tout-Puissant, pour m'avoir accordé la santé, la patience et la force nécessaires pour mener à bien ce travail. Sans Sa volonté, rien n'aurait été possible.

Je tiens à exprimer ma profonde gratitude à ma directrice de thèse, **Pr. Nawal CHEGGAGA**, pour son encadrement de grande qualité, sa bienveillance, ses conseils avisés et son soutien constant tout au long de ces années. Son implication a été déterminante dans la réalisation de ce travail.

Je remercie également **Dr. Ferial ADLI** pour sa précieuse aide, sa disponibilité et ses conseils à des moments clés de mon parcours. Son soutien a grandement contribué à l'avancement de cette recherche.

Je tiens à remercier **Mr. Amine BOUCHIBA**, pour son aide. Son intervention précieuse a facilité certaines étapes cruciales de mon travail.

Mes remerciements vont aussi aux formateurs et formatrices qui nous ont accompagnés durant la première année du doctorat.

J'exprime également ma reconnaissance aux membres du jury, pour avoir accepté d'évaluer ce travail, pour l'intérêt qu'ils y ont porté, ainsi que pour leurs remarques constructives, qui contribuent à l'enrichissement scientifique de cette thèse.

Un grand merci à mes collègues doctorants, pour leur soutien, les discussions enrichissantes, les échanges stimulants et les nombreux moments de convivialité partagés au fil des années.

Enfin, je remercie profondément ma famille et mes amis, pour leur patience, leur soutien indéfectible, leur présence rassurante et leurs encouragements constants tout au long de cette aventure doctorale.

Dédicace

À toutes les personnes qui me sont chères

Liste des abréviations

ABC (Artificial Bee Colony Algorithm): L'algorithme de la colonie d'abeilles artificielles

ACO (Ant Colony Optimization): L'algorithme de colonie de fourmis

AG (Genetic Algorithm) : Algorithmes génétiques

ANOVA (Analysis of Variance): Analyse de la variance

α_i : Effets principaux

α_{ij} : Effets d'interactions

BCIR (Bi-Criteria Relocation Mechanism): Mécanisme de relocalisation bi-critères

CM (Mean Squares): Carrés moyens

CSA (Cuckoo Search Algorithm) : Algorithme de recherche du coucou.

DE (*Differential Evolution*): Évolution Différentielle (DE)

ddl : Degrés de liberté

DOE (Design of Experiments): plans d'expériences

FA (Firefly Algorithm): L'algorithme des lucioles.

F : Test de Fisher

GOA (Algorithme d'optimisation des sauterelles) : Grasshopper Optimization Algorithm

GOW (Grey Wolf Optimizer): Méthode du loup gris

GTO (*Gorilla Troops Optimizer*): Optimisation tropicale inspirée des gorilles

MC (Monte Carlo Method) : Méthode de Monte Carlo

NSGA (Non-dominated Sorting Genetic Algorithm) : Algorithme génétique à tri non dominé

P_c : Coefficient de croisement

P_m : Coefficient de mutation

PSO (Particle Swarm Optimization): Algorithme d'essaim particulaire

RMS (Response Surface Methodology): Plans de surface de réponse

SC (Sum of Squares): Sommes des carrés

SSA (Sparrow Search Algorithm): algorithme de recherche des moineaux

TLBO (Teaching–Learning-Based Optimization): Optimisation basée sur l'enseignement et l'apprentissage

UPFC (Unified Power Flow Controller): Contrôleur unifié de flux de puissance

X : Matrice d'expériences

X^T : La transposée de la matrice X

Table des matières

Liste de figures

Liste de tableaux

Table des matières	9
I. Chapitre 1 Etat de L'art sur L'optimisation des parcs éoliens	12
1.1. Introduction	13
1.2. Méthodes d'optimisation métaheuristiques des fermes éoliennes.....	13
1.2.1. Ferme éolienne	13
1.3. Principes de bases des AG	33
1.3.1. Fonctionnement général d'un algorithme génétique.....	34
1.4. Conclusion	43
II. Chapitre 2 Méthodologie des Plans d'Expériences	44
2.1. Introduction	45
2.2. Concepts généraux.....	47
2.2.2. Facteurs et variables	47
2.3. Les Plans Factoriels Complets – Étude Théorique et Méthodologique.....	58
2.4. Plans Factoriels Fractionnaires.....	65
2.5. Conclusion	71
III. Chapitre 3 Application de l'Algorithme Génétique pour l'Optimisation du Positionnement des Turbines dans les Fermes Éoliennes	74
3.1. Introduction	75
3.2. Modélisation de la ferme éolienne	76
3.3. Formulation du problème d'optimisation	82
3.4. Application de l'algorithme génétique	87
3.5. Processus d'optimisation complet	89
3.6. Évaluation des performances de l'algorithme	93
3.7. Discussion des résultats.....	95
3.8. Conclusion	97
IV. Chapitre 4 Réglage des Paramètres des Algorithmes Génétiques pour l'Optimisation des Fermes Éoliennes à l'Aide de la Méthode des Plans d'Expériences	99
4.1. Introduction	100
4.2. Méthodologie proposée	101
4.3. Mise en œuvre et résultats expérimentaux.....	102
4.4. Validation statistique du modèle.....	106
4.5. Analyse des effets principaux et interactions	110
4.6. Discussion des résultats.....	116

4.7. Généralisation à différentes vitesses de vent	117
4.8. Conclusion	120
V. Conclusion générale	122
Références	125

Liste des figures

Figure 1 Ferme éolienne terrestre (onshore) [10]	14
Figure 2 Ferme éolienne offshore [13]	15
Figure 3 l'effet de sillage dans une ferme éolienne [15]	16
Figure 4 Schéma illustrant le mécanisme de l'effet de sillage [17]	17
Figure 5 Etapes de fonctionnement d'un algorithme génétique	35
Figure 6 Principe du croisement à points.....	40
Figure 7 Principe du croisement uniforme.....	41
Figure 8 Principe de mutation	42
Figure 9 Présentation des variables codées	50
Figure 10 Représentation du domaine d'étude [98]	52
Figure 11 Effet principal	53
Figure 12 Illustration de l'effet global et l'effet moyen.....	54
Figure 13 Représentation des interactions entre les effets	56
Figure 14 Plans factoriels complets 2^2 et 2^3 [101].....	59
Figure 15 Plan factoriel fractionnaire 2^{3-1} [101].....	66
Figure 16 Régime de vent unidirectionnel de la ferme.....	78
Figure 17 Schéma du sillage [108]	79
Figure 18 illustre l'évolution typique de la vitesse du vent dans le sillage d'une turbine selon le modèle de Jensen [109]	80
Figure 19 Diagramme de la méthode des AG [109]	90
Figure 20 Diagramme d'optimisation [109]	91
Figure 21 Courbe de convergence de l'algorithme génétique	94
Figure 22 Effets principaux du taux de mutation (A) et du taux de croisement (B) sur la valeur de la fonction de fitness.	111
Figure 23 Graphique de l'interaction des facteurs sur les performances de l'algorithme génétique	112
Figure 24 Diagramme de Pareto des effets standardisés.....	113
Figure 25 Carte de contours de la réponse Y en fonction des paramètres	115
Figure 26 Disposition des éoliennes sur le site.....	116

Liste des tableaux

Tableau 1 Exemple de codage selon la nature du problème à optimiser	33
Tableau 2 Matrice des essais pour un plan factoriel complet 3^2	60
Tableau 3 Plan factoriel complet 2^3 : codage des niveaux et réponses expérimentales ...	61
Tableau 4 Matrice des essais et des effets pour un plan 2^2	63
Tableau 5 Signification des effets principaux et des interactions dans l'analyse factorielle	65
Tableau 6 Matrice d'un plan factoriel complet 2^3 avec trois facteurs A, B, C	67
Tableau 7 Matrice d'un plan factoriel fractionnaire 2^{3-1}	67
Tableau 8 Tableau des signes pour le calcul des contrastes	68
Tableau 9 Contrastes et effets des facteurs dans un plan factoriel	68
Tableau 10 Exemples de résolution des plans fractionnaires	70
Tableau 11 Résultats d'une sélection de configurations de paramètres de l'AG	95
Tableau 12 Variables du plan.....	102
Tableau 13 Le plan factoriel complet des expériences	103
Tableau 14 Coefficients du modèle calculés par Design-Expert en valeurs codées.	104
Tableau 15 Coefficients du modèle calculés par Design-Expert en valeurs	105
Tableau 16 Coefficients du modèle en valeurs réelles et codées.....	105
Tableau 17 Statistiques de la régression du modèle et analyse des résidu	106
Tableau 18 Tableau d'évaluation de la performance du modèle	108
Tableau 19 Comparaison des résultats avec ceux issus de la littérature	116
Tableau 20 Optimisation des paramètres de l'AG en fonction de la vitesse du vent.....	118
Tableau 21 Comparaison entre BPSO et GA-DOE	119
Tableau 22 Configuration du parc éolien selon les méthodes BPSO et GA-DOE [109] ...	119

Introduction générale

Introduction générale

La transition énergétique mondiale s'inscrit dans une dynamique irréversible visant à réduire la dépendance aux énergies fossiles et à limiter les émissions de gaz à effet de serre. Dans ce contexte, l'énergie éolienne s'est imposée comme l'une des principales sources d'électricité renouvelable, en raison de sa disponibilité, de sa maturité technologique et de ses faibles impacts environnementaux. Selon l'Agence Internationale de l'Énergie, la capacité éolienne mondiale a connu une croissance exponentielle au cours des dernières décennies, et cette tendance devrait se poursuivre pour atteindre les objectifs de neutralité carbone fixés par de nombreux pays.

Cependant, malgré les avancées technologiques significatives dans la conception des turbines et l'amélioration de leur rendement, l'optimisation de la disposition des éoliennes au sein d'un parc demeure un défi majeur. En effet, les interactions aérodynamiques entre turbines, notamment les effets de sillage, peuvent entraîner une diminution significative de la production énergétique si elles ne sont pas rigoureusement prises en compte lors de la phase de conception. Le sillage, zone de turbulence générée en aval d'une éolienne, réduit la vitesse du vent et augmente la turbulence pour les turbines situées en aval, affectant ainsi leur performance et leur durée de vie. Des études ont montré que les pertes de production dues aux effets de sillage peuvent atteindre jusqu'à 20 % dans certaines configurations de parcs éoliens. Pour relever ce défi, diverses approches ont été développées, allant des méthodes analytiques aux techniques d'optimisation avancées. Parmi ces dernières, les algorithmes d'optimisation métaheuristiques, tels que les algorithmes génétiques (AG), se sont imposés comme des outils puissants pour résoudre les problèmes complexes et non linéaires liés à l'agencement optimal des éoliennes. Inspirés des mécanismes de l'évolution naturelle, les AG permettent d'explorer efficacement de vastes espaces de recherche et de converger vers des solutions optimales ou quasioptimales. Leur flexibilité et leur capacité à gérer des problèmes multi-objectifs en font des candidats idéaux pour l'optimisation de la disposition des turbines, en tenant compte de multiples contraintes telles que la topographie du site, les conditions météorologiques et les contraintes économiques.

Néanmoins, la performance des AG dépend fortement du réglage de leurs paramètres, tels que le taux de mutation, le taux de croisement, la taille de la population et les critères

d'arrêt. Un mauvais paramétrage peut conduire à une convergence prématurée vers des optima locaux ou à une exploration inefficace de l'espace de recherche. Ainsi, le choix judicieux de ces paramètres est crucial pour garantir la robustesse et l'efficacité de l'algorithme.

Parallèlement, la méthode des plans d'expériences (Design of Experiments, DOE) s'est révélée être une approche statistique rigoureuse pour analyser et optimiser les systèmes complexes en limitant le nombre d'expérimentations nécessaires. Le DOE permet de modéliser les relations entre les facteurs d'entrée et les réponses du système, d'identifier les interactions significatives et de déterminer les configurations optimales. En combinant la puissance exploratoire des AG avec la précision analytique du DOE, il est possible de développer une approche hybride visant à améliorer de manière systématique et reproductible la conception des parcs éoliens.

L'objectif principal de cette thèse est donc de développer, appliquer et valider une méthodologie d'optimisation de la disposition des éoliennes en utilisant les algorithmes génétiques, tout en optimisant les paramètres de ces algorithmes à l'aide de la méthode des plans d'expériences. Cette approche vise à maximiser la production énergétique, à minimiser les pertes dues aux effets de sillage, et à garantir une convergence rapide et stable de l'algorithme. En outre, elle permet d'assurer la reproductibilité des résultats et de faciliter l'adaptation de la méthodologie à différents contextes opérationnels.

Pour atteindre ces objectifs, ce travail s'articule en quatre chapitres :

- **Chapitre 1** : Ce chapitre présente un état de l'art détaillé sur l'optimisation des parcs éoliens, en mettant l'accent sur les méthodes métaheuristiques et, plus spécifiquement, sur les algorithmes génétiques. Il explore également les différentes approches utilisées pour modéliser les effets de sillage et leur impact sur la production énergétique.
- **Chapitre 2** : Ce chapitre est consacré à la méthodologie des plans d'expériences. Il en expose les principes théoriques, les différents types de plans factoriels, et leur intérêt dans le réglage des paramètres d'algorithmes. Des exemples concrets illustrent l'application du DOE dans le contexte de l'optimisation des systèmes complexes.
- **Chapitre 3** : Ce chapitre décrit le développement d'un algorithme génétique pour l'optimisation de l'agencement des turbines. Il inclut la modélisation du problème, l'implémentation de l'AG et l'évaluation de ses performances. Les résultats obtenus sont comparés à ceux de la littérature pour une validation de l'approche proposée.

- **Chapitre 4** : Ce chapitre présente l'application de la méthode des plans d'expériences au réglage des paramètres de l'AG, avec une analyse statistique approfondie, une comparaison avec d'autres méthodes de la littérature ainsi qu'une généralisation à différentes vitesses de vent. Il met en évidence les gains de performance obtenus grâce à l'optimisation conjointe des paramètres de l'algorithme.

On termine avec une conclusion et perspectives

Ainsi, cette thèse vise à renforcer la robustesse, l'efficacité et la reproductibilité des approches d'optimisation pour les systèmes éoliens, en proposant un cadre méthodologique rigoureux et innovant, à la croisée de l'intelligence artificielle et des statistiques appliquées.

Chapitre 1

**Etat de L'art sur L'optimisation des parcs
éoliens**

1.1. Introduction

Dans un contexte mondial marqué par la transition énergétique et la recherche d'alternatives durables aux énergies fossiles, l'énergie éolienne s'impose comme l'une des solutions les plus prometteuses pour répondre à la demande croissante en électricité tout en réduisant l'impact environnemental [1]. La conception optimale des parcs éoliens, tant terrestres qu'en mer, constitue dès lors un enjeu stratégique majeur. En effet, la disposition des turbines influe directement sur les performances globales du parc, notamment à travers les phénomènes d'interférence aérodynamique tels que les effets de sillage, qui peuvent entraîner une diminution significative de la production énergétique [2].

Face à cette complexité, les méthodes d'optimisation ont évolué, passant des approches conventionnelles basées sur des techniques déterministes à des stratégies plus récentes et performantes inspirées des processus naturels. Ces méthodes, dites métaheuristiques, se distinguent par leur capacité à explorer efficacement des espaces de recherche vastes et non linéaires, en intégrant une part de stochastique et d'intelligence adaptative. Des algorithmes tels que les algorithmes génétiques [3], l'optimisation par essaim particulaire [4], l'algorithme des lucioles ou encore l'optimisation des loups gris, ont ainsi été largement exploités pour résoudre le problème complexe de l'agencement des turbines.

Ce chapitre propose une revue détaillée et structurée de l'état de l'art sur les approches d'optimisation appliquées à la conception des fermes éoliennes. Après une présentation des fondamentaux liés aux caractéristiques des fermes éoliennes et aux défis posés par les effets de sillage, nous retracerons l'évolution des méthodes d'optimisation, depuis les techniques conventionnelles jusqu'aux approches métaheuristiques les plus récentes. L'objectif est de fournir un panorama critique des contributions majeures dans ce domaine, en mettant en évidence les performances, les limites et les perspectives d'amélioration de chaque méthode.

1.2. Méthodes d'optimisation métaheuristiques des fermes éoliennes

1.2.1. Ferme éolienne

Une ferme éolienne, également appelée parc éolien, désigne un ensemble de turbines éoliennes disposées dans une zone géographique spécifique dans le but de produire de l'énergie électrique à partir de l'énergie cinétique du vent [5, 6]. Chaque turbine est équipée de pales qui captent le vent pour le convertir en électricité via un générateur [7]. La disposition des turbines au sein de la ferme éolienne est optimisée afin de maximiser l'exposition au vent

tout en réduisant au minimum les effets de sillage (réduction de la vitesse du vent derrière une turbine), ce qui permet de garantir une production d'énergie plus efficace et plus stable [8].

Les fermes éoliennes peuvent être classées en deux grandes catégories en fonction de leur emplacement : onshore (terrestres) et offshore (en mer) [9].

- a. Ferme éolienne terrestre (onshore) : Une ferme éolienne terrestre est installée sur des terres (fig.1), souvent dans des zones rurales ou dans des régions où la vitesse du vent est élevée et régulière. Ces fermes sont plus simples à installer en raison de l'accessibilité du site, mais elles peuvent être limitées par des contraintes géographiques, la proximité des zones habitées et des réglementations environnementales. De plus, les conditions de vent ne sont pas toujours aussi constantes ou fortes que celles en mer.



Figure 1 Ferme éolienne terrestre (onshore) [10]

- b. Ferme éolienne en mer (offshore) : Les fermes éoliennes offshore se trouvent en mer (fig.2), généralement à des distances variables des côtes, dans des zones où les conditions de vent sont souvent plus stables, plus fortes et plus prévisibles. En mer, les turbines bénéficient de meilleurs rendements énergétiques, car le vent est moins perturbé par les obstacles terrestres tels que les bâtiments ou la végétation. Cependant, ces fermes présentent des défis logistiques et techniques supplémentaires, tels que des coûts d'installation plus élevés, des exigences strictes en matière de maintenance et des difficultés d'accessibilité en raison des conditions maritimes et des distances. Les fermes

offshores peuvent être installées sur des fondations fixes dans des eaux peu profondes ou sur des plateformes flottantes dans des zones plus profondes [11, 12].



Figure 2 Ferme éolienne offshore [13]

1.2.1.1. Objectifs de la ferme éolienne

Le principal objectif d'une ferme éolienne est de maximiser la production d'énergie électrique en capturant efficacement l'énergie du vent. Pour ce faire, la disposition et l'orientation des turbines doivent être soigneusement optimisées afin de réduire les effets négatifs du sillage entre les turbines et d'assurer que chaque turbine puisse fonctionner à son rendement optimal. En outre, la gestion de l'espacement entre les turbines, la sélection des sites d'installation et la prise en compte des facteurs environnementaux et logistiques sont essentiels pour atteindre des performances maximales en termes de production d'énergie.

1.2.1.2. Facteurs influençant l'optimisation des fermes éoliennes

- a. Conditions météorologiques et géographiques : Les fermes éoliennes doivent être installées dans des zones où les conditions de vent sont favorables, avec une vitesse de vent régulière et suffisante pour garantir une production constante d'électricité. La topographie du terrain ou la profondeur de l'eau influence également la conception et la disposition des turbines.
- b. Impact environnemental et réglementations : L'impact sur les écosystèmes locaux, qu'ils soient marins ou terrestres, est un facteur crucial dans le processus de planification. Les fermes offshores, par exemple, doivent prendre en compte l'impact sur les habitats marins, la faune et la navigation maritime. Les fermes terrestres doivent également

respecter les règlements sur les zones protégées, les espèces menacées et les populations locales.

- c. Technologie des turbines : L'efficacité de la ferme dépend aussi de la technologie des turbines utilisées. Des turbines plus grandes et plus efficaces permettent une production d'énergie accrue, mais nécessitent un design et une installation spécifiques.
- d. Coûts d'installation et de maintenance : Les coûts associés à l'installation d'une ferme éolienne, qu'elle soit offshore ou onshore, peuvent varier considérablement en fonction de la technologie, de la localisation et de l'infrastructure nécessaire. L'optimisation doit également tenir compte des coûts de maintenance à long terme, en particulier pour les fermes offshore qui sont difficiles d'accès.

1.2.1.3. Le sillage et ses effets dans les fermes éoliennes

Le sillage désigne la perturbation du flux de vent générée par les turbines éoliennes lorsqu'elles captent l'énergie cinétique du vent. Ce phénomène se produit lorsque le vent, après avoir passé à travers une turbine, perd de sa vitesse et de son énergie, créant une zone de faible pression derrière la turbine. Cela influence la capacité des autres turbines situées dans le sillage à capter efficacement le vent, ce qui peut réduire leur rendement [14]. Ce phénomène est illustré par la fig.3



Figure 3 l'effet de sillage dans une ferme éolienne [15]

a. Mécanisme du sillage

Lorsque le vent passe à travers les pales d'une turbine, une partie de l'énergie cinétique est extraite, réduisant la vitesse du vent et créant une turbulence dans le flux d'air comme

illustré dans la figure 4. Cette zone de faible vitesse du vent derrière la turbine, appelée zone de sillage, peut s'étendre sur plusieurs dizaines de longueurs de turbine, en fonction de facteurs comme la vitesse du vent, la conception des turbines, et la disposition des éoliennes. La présence de ce sillage peut interférer avec les turbines suivantes, diminuant ainsi leur efficacité [16].




Figure 4 Schéma illustrant le mécanisme de l'effet de sillage [17]

b. Facteurs influençant le sillage

- Espacement entre les turbines : Un espacement trop faible entre les turbines augmente l'impact du sillage. Un espacement trop grand peut réduire l'efficacité globale de la ferme éolienne en réduisant le nombre de turbines installées dans une zone donnée. Il est donc essentiel de trouver un compromis optimal entre l'espacement pour minimiser le sillage et maximiser la production d'énergie.
- Vitesse du vent : À faible vitesse de vent, l'effet du sillage est moins marqué, car la perturbation de la vitesse du vent est moins importante. Par contre, avec des vitesses de vent plus élevées, l'effet de sillage devient plus prononcé, entraînant des pertes de rendement plus importantes pour les turbines suivantes.
- Angle d'attaque des pales et configuration des turbines : La conception des turbines, en particulier l'angle d'attaque des pales, joue un rôle dans la manière dont elles perturbent le vent. Les turbines avec des pales de plus grande taille ou des conceptions aérodynamiques particulières peuvent influencer l'intensité du sillage.
- Topographie et conditions environnementales : La topographie du terrain, la direction du vent et la température peuvent également affecter la formation et la dispersion du sillage.

Par exemple, des conditions météorologiques variables peuvent altérer la répartition du vent à travers les turbines. c. Effets du sillage

L'effet principal du sillage est la réduction de l'efficacité des turbines suivantes dans le flux du vent. Cela peut entraîner une baisse significative de la production d'énergie des turbines situées dans les zones de sillage. Ce phénomène peut également affecter la durabilité des turbines en augmentant les charges mécaniques dues aux turbulences et aux variations de pression dans l'air [18].

1.2.1.4. Optimisation de la disposition des turbines pour minimiser l'effet du sillage

La réduction de l'impact du sillage est essentielle pour optimiser la production d'énergie dans une ferme éolienne. Plusieurs stratégies sont employées pour minimiser cet effet :

- Espacement optimal : Calculer un espacement optimal entre les turbines pour réduire les interférences de sillage tout en maximisant la densité de turbines dans une zone donnée.
- Disposition en hélice ou en grille décalée : Plutôt que d'aligner les turbines de manière linéaire, les concepteurs peuvent adopter des configurations plus complexes, comme des dispositions en zig-zag ou en hélice, afin de réduire les zones de sillage direct entre les turbines.
- Utilisation d'algorithmes d'optimisation : Des méthodes d'optimisation mathématique et computationnelle, telles que les algorithmes génétiques ou autres techniques bio-inspirées, peuvent être utilisées pour déterminer la disposition optimale des turbines.

1.2.2. Méthodes conventionnelles

L'optimisation de la disposition des éoliennes dans un parc est un problème complexe, non convexe et fortement non linéaire, en raison des interactions entre turbines causées par les effets de sillage. Avant l'essor des méthodes d'optimisation bio-inspirées, plusieurs approches conventionnelles ont été développées. Cette revue présente ces méthodes dans un ordre chronologique, en mettant en évidence leur évolution, leurs avantages et leurs limites.

1.2.2.1. Discrétisation par grille et recherche combinatoire (1994)

Dans l'une des premières contributions notables à l'optimisation de la disposition des éoliennes, Mosetti et al. (1994) ont proposé une approche combinant une discrétisation conventionnelle de l'espace (grille régulière de 100 points sur 2 km × 2 km) avec une métaheuristique d'optimisation, à savoir un algorithme génétique. Cette méthode a permis d'explorer efficacement un espace de recherche discret, en considérant chaque point de la grille comme un emplacement potentiel pour une turbine. Bien que cette stratégie ait jeté les

bases de l'optimisation par métaheuristique dans ce domaine, elle reste limitée par l'explosion combinatoire du nombre de solutions possibles lorsque le nombre de turbines augmente [19].

1.2.2.2. Programmation mathématique et heuristiques

Une autre approche intéressante a été développée dans les années 2010 avec l'utilisation de méthodes de programmation mathématique pour l'optimisation des parcs éoliens offshore. L'étude de Pérez, Mínguez et Guanche (2013) s'intéresse à l'application de techniques de programmation linéaire et non linéaire dans le cadre de l'optimisation de la disposition des turbines offshore. L'objectif était de maximiser la production d'énergie tout en prenant en compte des contraintes environnementales et économiques. Ces méthodes ont permis de formaliser les relations complexes entre les turbines, notamment en réduisant les effets de sillage [20].

Herbert-Acero et al. (2014) ont également présenté une synthèse des approches méthodologiques pour l'optimisation des parcs éoliens, en analysant des techniques comme la programmation linéaire, la recherche tabou et la programmation à contraintes. Bien qu'efficaces dans des modèles simplifiés, ces approches exactes se heurtent à la complexité du problème, surtout en raison de la nature non linéaire des modèles de sillage et de la discrétion du placement des turbines [21].

1.2.2.3. Monte Carlo

L'approche Monte Carlo (MC), bien connue pour sa capacité à gérer l'incertitude et à explorer efficacement de vastes espaces de recherche grâce à des méthodes d'échantillonnage aléatoire, a été utilisée dès le début des années 2010 pour résoudre le problème complexe de l'optimisation de l'agencement des parcs éoliens. L'une des premières applications notables a été réalisée par Brusca et al. (2014), qui ont utilisé la méthode de simulation Monte Carlo pour optimiser la position des turbines dans un parc éolien. Leur méthode visait à maximiser la production énergétique globale en simulant de nombreux scénarios d'agencement aléatoire, tout en prenant en compte les effets de sillage. Les résultats ont démontré la capacité de la méthode à générer de bonnes solutions dans des configurations simples [24].

Par la suite, Wang et al. (2018) ont approfondi cette approche dans un contexte probabiliste, en comparant la méthode de Monte Carlo avec des techniques de discrétisation pour optimiser la disposition des turbines sous une distribution de Weibull. Leur étude a souligné que la méthode Monte Carlo offrait une meilleure flexibilité et une plus grande

précision dans la modélisation des incertitudes liées au vent, tout en permettant une exploration efficace de l'espace de conception [25].

Dans une optique comparative, Javadi et al. (2021) ont opposé la méthode de simulation Monte Carlo à l'algorithme génétique pour la conception optimale de parcs éoliens, en utilisant le modèle de sillage de Jensen. Leur analyse a mis en évidence les forces de Monte Carlo dans l'exploration stochastique des configurations, même si elle pouvait être moins efficace que les méta-heuristiques classiques en termes de convergence [26].

L'algorithme a connu une évolution importante avec l'introduction de techniques hybrides. Bai et al. (2022) ont intégré la recherche Monte Carlo par arbre (Monte Carlo Tree Search) dans un algorithme évolutionnaire adaptatif pour l'optimisation des parcs éoliens. Cette combinaison a permis une exploration guidée, en renforçant la stratégie de sélection des solutions prometteuses tout en conservant la richesse d'exploration stochastique propre à Monte Carlo. L'approche a montré de très bonnes performances, en particulier pour les grands parcs éoliens où l'espace de recherche devient rapidement intraitable [27].

Enfin, deux études récentes ont élargi la portée de cette approche. Cinar (2023) a réalisé une revue comparative des méthodes d'optimisation de placement sur des grilles 10×10 et 20×20, dans laquelle la méthode Monte Carlo a été étudiée parmi d'autres métaheuristiques. Elle a été reconnue pour sa simplicité et son efficacité sur certains types de configurations, mais aussi pour ses limites dans la gestion des grandes dimensions sans hybridation [28]. De manière complémentaire, Song et al. (2024) ont inclus les méthodes Monte Carlo dans une revue globale sur l'intelligence artificielle appliquée à l'éolien offshore, soulignant son rôle historique comme méthode de base pour la simulation et l'optimisation dans des environnements marins incertains [29].

Dans l'ensemble, les méthodes basées sur Monte Carlo ont prouvé leur pertinence pour l'optimisation de la disposition des éoliennes, notamment grâce à leur capacité à gérer l'incertitude et à explorer efficacement des espaces de recherche complexes. Bien qu'elles soient parfois surpassées en termes de vitesse de convergence par des métaheuristiques modernes, leur robustesse et leur simplicité les rendent encore très utiles, surtout lorsqu'elles sont combinées à d'autres techniques intelligentes.

1.2.2.4. Optimisation locale basée sur le gradient avec remplacement séquentiel

Plus récemment, en 2025, Abdel-Basset et al. ont proposé une méthode hybride combinant optimisation par gradient et remplacement séquentiel pour l'optimisation de la

disposition des turbines. L'approche consiste à déplacer les turbines une par une en fonction du gradient local de la fonction objectif (puissance totale du parc). Cette méthode permet une exploration plus précise de l'espace de recherche tout en conservant un bon équilibre entre exploitation locale et gestion de la complexité du problème [23].

Les méthodes conventionnelles d'optimisation de la disposition des éoliennes ont évolué considérablement au fil des années. De la simple discrétisation par grille et recherche combinatoire (1994) à l'utilisation de techniques plus avancées comme le recuit simulé et la programmation mathématique (2010-2014), ces approches ont permis de poser les bases de l'optimisation des parcs éoliens. Toutefois, leur performance reste limitée dans des cas réalistes de grande échelle, en raison de la complexité du problème, notamment des effets de sillage. Ces méthodes ont ouvert la voie aux techniques plus récentes, notamment bioinspirées, qui permettent de mieux gérer la complexité et l'incertitude des problèmes d'optimisation dans les parcs éoliens.

1.2.3. Autres méthodes métaheuristiques

1.2.3.1. Recuit Simulé

Yoon et Kang (2019) ont développé une méthode d'optimisation de la disposition des turbines éoliennes fondée sur l'algorithme de recuit simulé, en s'inspirant du processus physique de refroidissement thermique. Cette approche a été testée sous trois scénarios de vent et a conduit à des agencements réguliers, jusqu'alors inédits dans la littérature, associés à des valeurs optimales de la fonction objective. Les résultats obtenus confirment l'applicabilité et l'efficacité du recuit simulé dans le contexte de l'optimisation des parcs éoliens[22].

1.2.3.2. Algorithme d'essaim particulaire (PSO)

L'algorithme d'optimisation par essais particuliers (PSO) s'inspire du comportement collectif des espèces naturelles, notamment celui des oiseaux en vol, pour explorer un espace de recherche à partir d'une population initiale de solutions aléatoires. Contrairement aux algorithmes génétiques, chaque particule (solution) possède une vitesse qui influence son déplacement, favorisant ainsi une exploitation efficace des meilleures solutions tout en maintenant une capacité d'exploration du domaine de recherche.

L'introduction du PSO dans le domaine de l'agencement des parcs éoliens remonte à 2009. Dans une étude pionnière, Bilbao et Alba (2009) ont comparé les performances de

l'algorithme PSO à celles d'un algorithme génétique sur plusieurs cas de configuration de parcs éoliens. Ils ont constaté que les deux approches aboutissaient à des performances similaires, atteignant la convergence après environ 10 000 à 15 000 évaluations de la fonction objectif pour des parcs comportant entre six et dix-huit éoliennes [30]. Ces résultats ont été corroborés par Kusiak et Song (2010), qui ont mené une étude fondée sur un modèle évolutif comparable. Leur méthodologie impliquait environ 100 générations, chacune composée de 100 individus, menant également à près de 10 000 évaluations nécessaires pour atteindre la convergence [31].

À la suite de ces premiers travaux, plusieurs recherches ont approfondi l'utilisation du PSO pour optimiser la production d'énergie dans des conditions plus complexes. Ainsi, Asaah et al. (2021) ont appliqué l'algorithme PSO à la disposition optimale des éoliennes, mettant en évidence son efficacité pour maximiser le rendement global dans un contexte réaliste [32]. La même année, Bellat et Raihani (2021) ont intégré un modèle de sillage gaussien dans le processus d'optimisation PSO, soulignant l'importance de la modélisation précise des effets aérodynamiques pour améliorer les performances énergétiques [33].

Plus récemment, les années 2023 et 2024 ont vu émerger des approches avancées du PSO intégrant des stratégies hybrides ou des techniques de contrôle. Song et al. (2023) ont proposé une méthode combinant le PSO avec un mécanisme de contrôle actif de l'orientation des turbines. Cette méthode vise à optimiser la production énergétique en tenant compte des effets d'interaction aérodynamique entre les éoliennes, permettant ainsi une meilleure gestion des interférences et une amélioration globale du rendement [34]. En parallèle, Wang et al. (2023) ont développé une version améliorée du PSO couplée à une recherche locale chaotique, appliquée à de vastes parcs éoliens. Leur objectif était de minimiser les pertes liées aux effets de sillage tout en maximisant la performance énergétique globale [35].

Enfin, en 2024, Devabhaktuni (2024) a proposé une approche centrée sur l'optimisation de l'agencement des éoliennes en considérant spécifiquement l'effet de sillage. Cette méthode a permis d'augmenter l'efficacité énergétique des parcs tout en respectant les contraintes environnementales et topographiques, confirmant ainsi la pertinence continue du PSO dans le domaine de l'optimisation des systèmes éoliens [36].

1.2.3.3. Méthode du loup gris (GOW)

L'optimisation de l'agencement des parcs éoliens a largement bénéficié de l'application de l'algorithme Grey Wolf Optimizer (GWO), une métaheuristique inspirée du comportement social des loups gris. Cette approche a été explorée dans diverses études visant à améliorer l'efficacité énergétique des parcs éoliens.

En 2016, Sultana et al. ont appliqué le GWO pour déterminer l'emplacement et la taille optimaux de plusieurs unités de production distribuée dans les systèmes de distribution. Leur objectif était de minimiser les pertes de puissance réactive et d'améliorer le profil de tension, démontrant ainsi l'efficacité du GWO par rapport à d'autres méthodes métaheuristicques telles que l'algorithme de recherche gravitationnelle et l'algorithme des chauves-souris [37].

En 2020, Tumari et al. ont proposé une version modifiée du GWO pour améliorer la production énergétique des parcs éoliens. Leur approche a introduit des mécanismes d'exploration et d'exploitation améliorés, aboutissant à une meilleure convergence vers des solutions optimales et une augmentation significative de la production d'énergie des parcs éoliens [38].

Poursuivant ces travaux, Tumari, Zahar et Ahmad (2021) ont affiné le réglage optimal de la production énergétique des parcs éoliens en utilisant une version améliorée du GWO. Cette étude a mis en évidence l'importance de l'ajustement précis des paramètres de l'algorithme pour optimiser les performances énergétiques des installations éoliennes [39].

En 2023, Huang et al. ont proposé un algorithme évolutif de faible complexité basé sur la technique d'optimisation Grey Wolf (GWOEM) pour l'optimisation de l'agencement des parcs éoliens. Cet algorithme visait à réduire la complexité computationnelle tout en maintenant une performance optimale dans la disposition des éoliennes [40].

Ces contributions successives illustrent l'évolution et l'adaptation des algorithmes inspirés de la nature, en particulier du GWO, pour relever les défis complexes de l'optimisation de l'agencement des parcs éoliens, avec pour objectif constant l'amélioration de la production énergétique et de l'efficacité opérationnelle.

1.2.3.4. Optimisation tropicale inspirée des gorilles (GTO)

En 2023, Mohamed et al. ont introduit l'algorithme d'optimisation tropicale Gorilla (GTO) pour améliorer les performances des parcs éoliens offshore. Cette méthode bio-inspirée simule le comportement social des gorilles pour résoudre des problèmes complexes d'optimisation. L'étude démontre que le GTO offre une convergence rapide et une efficacité énergétique accrue, surpassant d'autres algorithmes classiques dans des environnements marins complexes [41].

1.2.3.5. L'algorithme des lucioles (Firefly Algorithm, FA)

L'optimisation de l'agencement des parcs éoliens a été abordée par diverses méthodes métaheuristiques visant à maximiser la production d'énergie tout en tenant compte des contraintes environnementales et spatiales. Parmi ces approches, l'algorithme des lucioles (Firefly Algorithm, FA) a été utilisé pour résoudre des problèmes liés à l'énergie éolienne. Voici une synthèse des contributions majeures utilisant le FA, présentées par ordre chronologique.

En 2016, Gani et al. ont proposé une méthode hybride combinant la machine à vecteurs de support (SVM) avec l'algorithme des lucioles pour estimer la distribution de la vitesse du vent.

Cette approche visait à améliorer la précision des estimations de la vitesse du vent, essentielles pour évaluer le potentiel énergétique des sites éoliens [42].

En 2018, Putri et al. ont développé un algorithme des lucioles modifié pour améliorer l'extraction de la puissance maximale dans un système de conversion d'énergie éolienne connecté au réseau. Les résultats ont démontré que cet algorithme surpassait les méthodes existantes, telles que l'optimisation par essaims particulaires (PSO) et la méthode de perturbation et observation (P&O), en termes d'efficacité et de temps de réponse [43].

En 2022, Alghamdi a introduit un algorithme hybride combinant le FA et l'algorithme JAYA pour résoudre le problème de flux de puissance optimal en tenant compte des générations éolienne et solaire. Cette approche a permis d'améliorer la gestion et la distribution de l'énergie dans les systèmes hybrides [44].

En 2024, Zhang et al. ont proposé une méthode de prédiction à court terme de la puissance éolienne basée sur la combinaison de l'algorithme des lucioles et des réseaux de mémoire à long terme (LSTM). Cette approche a amélioré la précision des prévisions de

puissance éolienne, contribuant ainsi à une meilleure intégration de l'énergie éolienne dans le réseau électrique [45].

Ces études illustrent l'évolution et l'adaptation de l'algorithme des lucioles pour relever divers défis dans le domaine de l'énergie éolienne, notamment en matière d'estimation de la vitesse du vent, de suivi du point de puissance maximale, d'optimisation du flux de puissance et de prédiction de la production énergétique

1.2.3.6. Algorithme de recherche du coucou (Cuckoo Search Algorithm, CSA)

L'algorithme de recherche du coucou (CSA) est l'une des approches inspirées de la nature utilisées pour ce type de problématique. Il y-a eu quelques contributions à ce sujet.

En 2016, Rehman et al. ont introduit l'algorithme de recherche du coucou (CSA) pour l'optimisation de la disposition des éoliennes dans un parc éolien. Leur étude a démontré que le CSA pouvait être efficace pour minimiser les pertes d'énergie dues aux interférences entre les éoliennes. Ils ont comparé les performances du CSA à d'autres algorithmes d'optimisation classiques et ont montré qu'il offrait une meilleure efficacité énergétique dans l'agencement des parcs éoliens. Cette étude a constitué l'une des premières applications concrètes de CSA dans ce domaine [46].

Plus récemment, en 2024, Mohandes, Khan, Rehman, et al. ont présenté une analyse préliminaire sur l'optimisation des agencements de parcs éoliens pour Turaif, en Arabie Saoudite. Bien que cet article se concentre sur une comparaison entre différents algorithmes évolutionnaires, il s'inscrit dans la continuité des recherches utilisant des techniques inspirées de la nature, comme le CSA, pour améliorer la planification des parcs éoliens [47].

Enfin, dans un article publié en 2024, Kumar et al. ont étudié l'utilisation des algorithmes inspirés de la nature pour résoudre les problèmes d'optimisation de l'agencement des parcs éoliens. Leur travail a intégré différentes techniques, y compris des variantes du CSA, pour déterminer la disposition optimale des éoliennes dans de grands parcs. Cette étude a permis de confirmer l'efficacité du CSA dans la recherche de solutions optimales dans un cadre d'optimisation multi-objectifs [48].

Ces études montrent que le CSA, bien qu'introduit plus récemment dans ce domaine, a rapidement démontré son efficacité pour résoudre des problèmes complexes liés à l'optimisation des parcs éoliens, et il continue d'être un outil précieux dans la recherche d'une disposition optimale des éoliennes afin de maximiser la production d'énergie

1.2.3.7. Optimisation de l'agencement des parcs éoliens par Évolution Différentielle (DE)

L'évolution différentielle (DE) est une méthode populaire pour résoudre des problèmes complexes d'optimisation, notamment pour l'agencement des parcs éoliens. Cette méthode s'inspire du processus évolutif naturel pour explorer et exploiter efficacement l'espace de recherche. Plusieurs travaux ont utilisé cette approche pour maximiser la production énergétique des parcs éoliens en optimisant l'emplacement des turbines et en tenant compte des effets de sillage et des contraintes géographiques.

En 2017, Wang et al. ont présenté une version améliorée de l'évolution différentielle avec un nouveau mécanisme d'encodage pour optimiser l'agencement des parcs éoliens. Cette étude a montré que l'algorithme était capable de réduire efficacement les pertes énergétiques dues aux effets de sillage tout en maximisant le rendement global du parc éolien [49].

En 2022, Chen, Li, et Shen ont proposé un modèle de programmation bilatérale pour l'optimisation de l'agencement des parcs éoliens à l'aide de l'évolution différentielle. Ce modèle a permis de mieux capturer les interactions entre les différents objectifs, tels que l'optimisation de la production énergétique et la minimisation des coûts d'installation, et a démontré une amélioration significative des performances par rapport aux autres approches classiques [50].

En 2023, Yu et Lu ont intégré l'apprentissage par renforcement dans l'évolution différentielle multi-objectifs pour l'optimisation des parcs éoliens. Cette approche a permis de mieux gérer les compromis entre les différents objectifs, notamment la production énergétique et les coûts associés, en adaptant l'algorithme au fil du temps pour optimiser plus efficacement l'agencement des turbines [51].

Song (2024) a proposé un modèle d'optimisation bi-niveau combinant l'évolution différentielle et l'algorithme de Dijkstra pour optimiser simultanément l'agencement des éoliennes et le réseau de câblage dans les fermes offshore. Cette approche vise à maximiser la production d'énergie tout en minimisant les coûts de connexion, en prenant en compte les contraintes environnementales et techniques spécifiques aux sites offshore [52].

Enfin, en 2025, Tao et al. ont proposé une approche d'évolution différentielle pilotée par ordre fractionnaire pour l'optimisation des parcs éoliens. Cette méthode innovante a permis de mieux exploiter les capacités de l'algorithme tout en réduisant la complexité computationnelle, ce qui est particulièrement utile dans les grandes installations éoliennes [53].

1.2.3.8. Grasshopper Optimization Algorithm (GOA)

Le Grasshopper Optimization Algorithm (GOA) est un algorithme inspiré des mouvements de sauterelles, qui a été utilisé pour résoudre divers problèmes complexes d'optimisation.

Dans le domaine de l'optimisation des parcs éoliens, GOA a montré une grande efficacité pour maximiser la production d'énergie en optimisant la disposition des turbines tout en tenant compte des contraintes environnementales et techniques.

En 2019, Fathy et El-Baksawi ont utilisé l'algorithme GOA pour extraire la puissance maximale d'une éolienne installée dans la région d'Al-Jouf. Leur étude a démontré que le GOA pouvait optimiser la production d'énergie tout en étant moins coûteux en termes de calculs par rapport à d'autres méthodes classiques d'optimisation [54].

En 2021, Meraihi et al. ont élargi la théorie du GOA et étudié ses variantes, ainsi que ses diverses applications, notamment pour l'optimisation des parcs éoliens. Cette revue a fourni une compréhension plus approfondie des mécanismes sous-jacents à cet algorithme et a proposé de nouvelles façons de l'appliquer pour résoudre des problèmes d'optimisation dans différents domaines, y compris l'énergie éolienne [55].

En 2022, Fathy et al. ont appliqué le GOA pour une approche en temps réel de suivi de la puissance maximale générée par un système de conversion d'énergie éolienne. Cette étude a été particulièrement utile pour optimiser les performances des parcs éoliens en conditions réelles, en ajustant constamment les paramètres de manière dynamique [56].

En 2025, Nguyen et al. ont utilisé le GOA pour optimiser l'emplacement des turbines dans un parc éolien amélioré. Leur travail a démontré l'efficacité de cet algorithme pour maximiser la production énergétique en tenant compte des caractéristiques géographiques et des contraintes locales des sites d'implantation [57].

1.2.3.9. L'algorithme de la colonie d'abeilles artificielles (ABC)

L'algorithme de la colonie d'abeilles artificielles (ABC), inspiré du comportement de butinage des abeilles, a été appliqué à l'optimisation des agencements des parcs éoliens pour maximiser la production d'énergie et réduire les coûts.

Parmi les premières contributions notables à l'application de l'algorithme Artificial Bee Colony (ABC) dans l'optimisation des systèmes électriques, on peut citer l'étude de Haddi et al. (2014). Les auteurs y proposent une méthode d'optimisation de la taille et de l'emplacement des sources d'énergie renouvelable, incluant notamment les parcs éoliens,

dans un réseau électrique de grande envergure. L'approche intègre également un contrôleur unifié de flux de puissance (UPFC) afin d'améliorer la stabilité du réseau. Les résultats obtenus sur le système de test IEEE 30 bus ont montré une réduction significative des pertes de puissance et du coût de production, démontrant ainsi l'efficacité de l'algorithme ABC dans la résolution de problèmes complexes d'optimisation énergétique [58].

Une autre étude de Patel et al. en 2018 a utilisé l'ABC pour optimiser le placement des turbines éoliennes dans un grand parc éolien situé en Inde. L'algorithme a permis d'augmenter l'efficacité énergétique en réduisant les pertes dues à l'effet de sillage entre les turbines [59].

L'ABC continue d'évoluer, avec des études récentes telles que celles de Sharma et al. (2022) qui ont intégré des mécanismes d'adaptation dynamique dans l'algorithme pour améliorer sa performance dans les environnements changeants des parcs éoliens modernes [60]. Dans la même année Ibrahim Celik et al. ont présenté un modèle réaliste d'optimisation de la disposition des éoliennes en utilisant l'algorithme ABC, prenant en compte des données réelles de vent, les effets de sillage, et les caractéristiques spécifiques des turbines. Bien que l'étude se concentre sur un parc éolien terrestre situé dans le sud de la Turquie, les méthodologies et conclusions pourraient être adaptées aux contextes offshore, en tenant compte des contraintes spécifiques à ces environnements [61].

En 2023, Pranupa et al. ont présenté une revue détaillée des techniques d'optimisation des agencements de parcs éoliens, soulignant l'importance de l'ABC pour l'optimisation des fermes éoliennes dans des contextes réels, comme celui d'une ferme éolienne en Turquie. L'étude a montré que l'utilisation de l'ABC pour optimiser l'emplacement des éoliennes a permis d'augmenter la production énergétique annuelle tout en réduisant les coûts associés à l'installation [62].

Ces travaux illustrent l'évolution de l'algorithme ABC dans l'optimisation des agencements de parcs éoliens et son potentiel pour améliorer la production d'énergie, réduire les coûts d'exploitation, et gérer les défis complexes associés à la disposition des turbines.

1.2.3.10. L'algorithme de recherche des moineaux (SSA)

Inspiré du comportement social des moineaux dans la recherche de nourriture, L'algorithme de recherche des moineaux a été récemment utilisé pour optimiser l'agencement des parcs éoliens, principalement pour réduire les effets de sillage et maximiser la production énergétique.

En 2021, Kumar et al. ont utilisé l'algorithme SSA pour déterminer l'emplacement optimal des éoliennes dans un parc éolien. Leur étude a démontré que SSA permettait d'optimiser l'agencement tout en tenant compte des effets de sillage, améliorant ainsi la production d'énergie globale du parc éolien. Ce travail a permis de comparer SSA avec d'autres techniques d'optimisation telles que l'algorithme de colonie de fourmis et l'algorithme de recherche de particules, mettant en évidence les avantages de SSA en termes de convergence rapide et de stabilité des résultats [63].

En 2022, Daqaq et al. ont proposé une amélioration de l'algorithme SSA en introduisant une approche chaotique. Leur étude a exploré l'optimisation des agencements de parcs éoliens en utilisant un algorithme hybride entre SSA et l'algorithme de la raie manta chaotique. Ils ont constaté que l'algorithme amélioré offrait des performances supérieures pour résoudre les problèmes complexes d'optimisation des parcs éoliens, en réduisant les effets de sillage et en augmentant l'efficacité de la production énergétique [64].

En 2024, Pranupa et al. ont développé une approche d'optimisation des parcs éoliens en utilisant des algorithmes métaheuristiques bio-inspirés, dont l'algorithme SSA, pour minimiser l'effet de sillage. Cette méthode a montré qu'en tenant compte de l'interaction entre les éoliennes et du phénomène de turbulence créé par ces dernières, l'optimisation du placement permettait une meilleure performance énergétique des parcs éoliens. Les résultats ont montré que l'algorithme SSA se distinguait par son efficacité dans l'optimisation de l'agencement en raison de sa capacité à s'adapter à des configurations complexes [65].

Une autre étude de 2024 menée par Zhu et al. a combiné l'algorithme SSA avec un apprentissage opposé dynamique pour optimiser l'agencement des turbines. Cette approche dynamique a permis d'améliorer les performances de l'algorithme SSA en explorant efficacement l'espace de recherche pour trouver des configurations optimales en termes de réduction du sillage et d'augmentation de la production d'énergie. Cette étude a confirmé l'efficacité de l'algorithme SSA dans les problèmes complexes d'optimisation des parcs éoliens [66].

1.2.3.11. L'algorithme de colonie de fourmis (ACO)

Parmi les méthodes les plus étudiées, l'algorithme de colonie de fourmis (ACO) se distingue comme une technique puissante, inspirée du comportement collectif des fourmis à

la recherche de nourriture, utilisée pour résoudre des problèmes complexes de placement des turbines dans les parcs éoliens.

Les premiers travaux sur l'application de l'ACO à l'optimisation des parcs éoliens remontent à Eroğlu et Seçkiner (2012), qui ont introduit l'algorithme de colonie de fourmis pour optimiser l'agencement des turbines. Dans leur étude, l'ACO a été utilisé pour minimiser les effets de sillage entre les turbines, un facteur essentiel dans la maximisation de la production d'énergie. Les résultats ont montré que l'ACO pouvait fournir des configurations efficaces en termes de réduction des pertes dues à l'interférence entre turbines tout en maximisant la production d'énergie [67].

Plus récemment, Pongsak et al. (2024) ont appliqué l'algorithme d'optimisation par colonie de fourmis (ACO) pour optimiser la disposition de parcs éoliens sur différents types de terrains en Thaïlande. Leur approche a permis d'améliorer la production annuelle d'énergie et de réduire les pertes dues aux effets de sillage. L'étude a démontré que l'ACO est une méthode efficace pour traiter les configurations complexes de parcs, en maximisant l'efficacité énergétique globale [68].

Ainsi, à travers ces différentes études, il est apparu que l'algorithme de colonie de fourmis reste une méthode robuste et efficace pour l'optimisation des parcs éoliens. Grâce à son approche bio-inspirée et à sa capacité à gérer des espaces de recherche complexes, l'ACO continue de jouer un rôle central dans l'optimisation des agencements des turbines, en offrant des solutions qui maximisent la production d'énergie tout en minimisant les coûts et les effets négatifs liés aux interactions entre turbines.

1.2.3.12. Teaching–Learning-Based Optimization (TLBO)

L'algorithme Teaching–Learning-Based Optimization (TLBO), inspiré du processus d'apprentissage en classe, a été appliqué dès le milieu des années 2010 à l'optimisation des parcs éoliens, en particulier pour résoudre le problème de microsite des turbines en tenant compte des effets de sillage et de la maximisation de la production énergétique.

La première application notable a été celle de Patel et al. (2015), qui ont exploré l'utilisation du TLBO pour maximiser la production énergétique d'un parc éolien. L'étude démontre que cette approche est capable de fournir de meilleures solutions en termes de rendement énergétique par rapport aux méthodes conventionnelles. Le TLBO y est valorisé

pour sa capacité à converger rapidement vers des solutions optimales tout en évitant les minima locaux [69].

Cette méthode a été améliorée par la suite dans l'article de Patel et al. (2017), où une version améliorée du TLBO a été introduite pour optimiser la disposition des turbines sur un site donné. L'étude a montré que l'algorithme améliore significativement le facteur de capacité du parc éolien tout en respectant les contraintes de distance et les limitations liées à l'effet de sillage. Les résultats ont également mis en évidence que le TLBO surpassait les algorithmes génétiques et d'autres techniques classiques en termes de robustesse et de performance globale [70].

Plus récemment, Hussain et al. (2022) ont utilisé TLBO pour le micro-siting optimal de turbines éoliennes dans un parc, en tenant compte non seulement de la puissance produite, mais aussi des contraintes environnementales et topographiques.

L'étude a démontré que le TLBO est capable d'adapter les configurations aux conditions spécifiques du site, ce qui est essentiel pour les applications réelles [71].

Enfin, Kumar et Sharma (2022) ont appliqué TLBO dans un cadre plus récent et plus global, en s'inscrivant dans le contexte des systèmes intelligents. Leur étude a évalué les performances de TLBO en comparaison avec d'autres techniques métaheuristiques modernes, soulignant sa capacité à maintenir une bonne efficacité de calcul tout en générant des agencements très performants [72].

Ainsi, l'algorithme TLBO s'est imposé progressivement comme une méthode fiable, robuste et flexible pour l'optimisation de la disposition des turbines dans les parcs éoliens, offrant une bonne convergence, une gestion efficace des contraintes et une capacité élevée à maximiser la production d'énergie en tenant compte des effets de sillage et des particularités du terrain.

1.2.3.13. Algorithme génétique (AG)

L'optimisation de la disposition des parcs éoliens à l'aide des algorithmes évolutifs a connu une évolution significative depuis les années 1990. L'un des premiers travaux majeurs dans ce domaine est celui de Mosetti et al. (1994), qui ont proposé l'utilisation d'un algorithme génétique (GA) pour automatiser la configuration des éoliennes sur une grille 10x10. Chaque cellule pouvait contenir une éolienne, et les agencements étaient représentés par des

chromosomes binaires de 100 gènes [19]. Par la suite, Grady (2005) a approfondi cette approche en comparant les résultats des algorithmes génétiques à une solution analytique dans un cas simplifié. Il a élargi l'étude avec une population plus importante, démontrant la robustesse des GA [73].

Huang (2007) a proposé une variante distribuée des algorithmes génétiques, divisant l'espace de recherche en sous-régions indépendantes. Chaque sous-espace était optimisé séparément, puis un mécanisme de migration permettait de regrouper les solutions. Cette méthode visait à réduire le temps de calcul tout en maintenant une bonne diversité [74].

Elkinton et al. (2008) ont développé une approche hybride combinant GA et heuristique gloutonne, ce qui a permis d'obtenir de meilleures performances que chacune des méthodes utilisées séparément [75, 76]. Serrano et al. (2009) ont intégré une recherche locale dans les GA, augmentant la qualité des solutions. De leur côté [77].

Les travaux se sont ensuite orientés vers des approches multi-objectifs. Kusiak et Song (2010) ont utilisé l'algorithme SPEA2 pour maximiser la production énergétique tout en respectant des contraintes d'espacement [78].

Rethore et al. (2014) ont lancé le projet TopFarm, basé sur une stratégie multiétapes associant GA et recherche locale. Ce programme prenait également en compte des contraintes économiques détaillées, mais nécessitait des ressources computationnelles conséquentes [79].

Kwong et al. (2014) ont appliqué l'algorithme NSGA-II afin de concilier la production énergétique et la réduction du bruit [80].

Liu et al. (2020) ont proposé une méthode d'optimisation de l'implantation des parcs éoliens en introduisant un mécanisme de relocalisation bi-critères (BCIR) intégré à un algorithme génétique. Leur approche améliore la convergence et permet d'obtenir de meilleures configurations sans alourdir la complexité de calcul [81].

En 2022, Asfour et al. ont proposé un modèle GA classique pour l'optimisation de la disposition [82]

Plus récemment, Qureshi et Warudkar (2023) ont proposé une approche hybride combinant GA et PSO (Particle Swarm Optimization), ce qui a permis d'améliorer l'efficacité et la convergence [83].

Parmi les différentes approches d'intelligence artificielle utilisées pour l'optimisation des parcs éoliens, les algorithmes génétiques (AG) occupent une place importante en raison de leur robustesse face à des espaces de recherche complexes. Étant donné que le présent travail se focalise spécifiquement sur ces algorithmes, il est pertinent d'en présenter les principes fondamentaux afin de mieux comprendre leur mécanisme et leur potentiel d'optimisation. La section suivante est donc consacrée aux bases théoriques et au fonctionnement des AG.

1.3. Principes de bases des AG

Les algorithmes génétiques (AG) sont une classe d'algorithmes évolutionnaires inspirés des mécanismes de l'évolution naturelle décrits par Charles Darwin, notamment la sélection naturelle et la reproduction avec variation génétique. Introduits formellement dans les années 1970 (Holland, 1975), et popularisés par D. E. Goldberg (1989), les AG sont des techniques de recherche stochastique utilisées pour résoudre des problèmes d'optimisation et d'exploration dans des espaces complexes. (Métaheuristiques pour l'optimisation et auto-organisation dans les systèmes biologiques [84, 85])

Pour mettre en œuvre un algorithme génétique, plusieurs composantes sont essentielles :

a. **Un schéma de codage des individus** : Chaque solution candidate (ou "individu") est représentée par un vecteur – binaire, entier, réel ou mixte – en fonction de la nature du problème. Ce codage permet de manipuler efficacement les solutions au sein de l'algorithme [86]. Le tableau 2 montre des exemples de codage selon la nature du problème.

Tableau 1 Exemple de codage selon la nature du problème à optimiser

Type de codage	Représentation du vecteur	Utilisation typique
Binaire	101101001	Problèmes discrets, combinatoires
Entier	[3, 1, 5, 2]	Classement
Réel	[2.5, 1.8, 0.6]	Problèmes continus (ex : optimisation de forme ou de position)
Mixte	[1, 0.75, 'A']	Problèmes hybrides (combinant plusieurs types de variables)

b. La génération de la population initiale : Une première population d'individus est générée aléatoirement ou à partir de connaissances a priori. Ce point de départ conditionne fortement la capacité de l'algorithme à converger rapidement vers de bonnes solutions [87].

c. Une fonction objectif (ou de fitness) : Chaque individu est évalué à l'aide d'une fonction à optimiser. Cette fonction détermine la "valeur d'adaptation" (fitness) qui guide le processus de sélection vers les solutions les plus performantes [88].

d. Des opérateurs de variation :

- **Croisement** : Combine des segments de deux individus pour produire de nouveaux descendants.

- **Mutation** : Apporte une modification aléatoire à un individu pour maintenir la diversité génétique et éviter les minima locaux.

e. Des paramètres de configuration : L'efficacité d'un AG dépend aussi du réglage de paramètres comme la taille de la population, le nombre maximal de générations, et les probabilités de croisement et de mutation. Ces paramètres influencent directement la balance entre exploration et exploitation de l'espace de recherche. Au fil des générations, l'algorithme applique ces opérateurs pour faire évoluer la population. Le processus se poursuit jusqu'à l'atteinte d'un critère d'arrêt (nombre de générations, convergence de la fitness, ou seuil de performance).

1.3.1. Fonctionnement général d'un algorithme génétique

Le schéma ci-dessous illustre les étapes principales du fonctionnement d'un algorithme génétique.

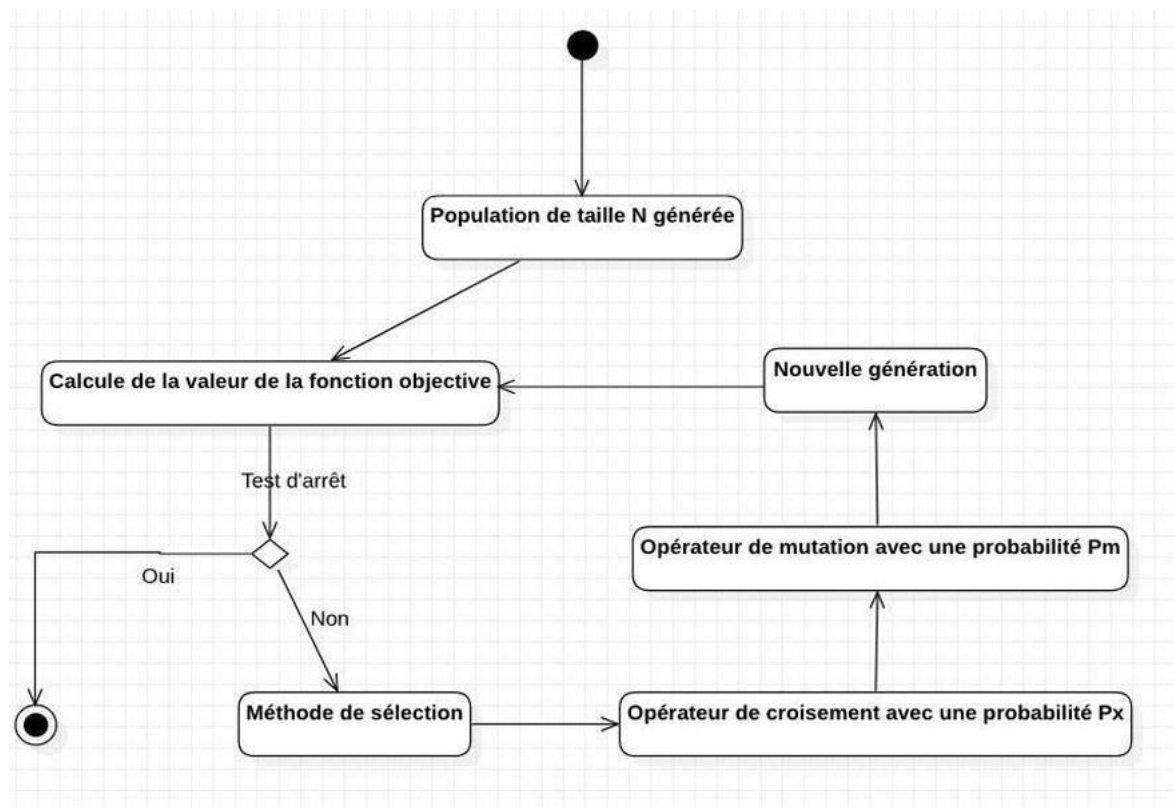


Figure 5 Etapes de fonctionnement d'un algorithme génétique

Initialisation de la population :

L'étape d'initialisation joue un rôle déterminant dans l'efficacité d'un algorithme génétique (AG), car elle conditionne en grande partie le déroulement du processus d'optimisation. Une population bien structurée dès le départ peut non seulement accélérer la convergence vers une solution optimale, mais aussi améliorer la qualité des solutions obtenues.

Dans ce cadre, la population initiale correspond à un ensemble de solutions potentielles générées au début de l'algorithme. Elle constitue le point de départ de l'exploration de l'espace de recherche. Bien que la génération de ces individus soit fréquemment réalisée de manière aléatoire, la méthode employée pour leur création peut avoir un impact significatif sur la rapidité de convergence ainsi que sur la robustesse de l'algorithme face aux minima locaux.

L'un des enjeux majeurs lors de cette phase est de garantir un niveau de diversité suffisant au sein de la population. Une population initiale trop uniforme peut limiter la capacité de l'algorithme à explorer efficacement l'espace des solutions, favorisant ainsi une convergence prématurée vers des optima locaux. À l'inverse, une diversité trop importante peut nuire à la convergence en diluant la pression sélective et en prolongeant inutilement l'exploration. Un équilibre judicieux doit donc être trouvé pour permettre à l'algorithme de combiner efficacement recherche globale et raffinement local [85] [89].

Les opérateurs de l'AG

Un algorithme génétique de base repose sur trois opérations principales : sélection, croisement et mutation.

– **Sélection** : Cette étape consiste à choisir les individus, ou chromosomes, dans la population pour les inclure dans le processus de reproduction. La sélection favorise les individus les plus adaptés, c'est-à-dire ceux qui possèdent des performances supérieures ou qui se rapprochent de la solution optimale, augmentant ainsi leurs chances d'être choisis pour la reproduction.

La sélection constitue le premier opérateur fondamental d'un algorithme génétique, appliqué à une population d'individus dans le but d'en assurer la régénération. Ce mécanisme repose sur le principe de proportionnalité à la valeur d'adaptation (fitness) des individus de la génération précédente, conditionnant ainsi la composition de la population suivante. Les individus présentant une meilleure aptitude vis-à-vis de la fonction objective disposent d'une probabilité accrue d'être sélectionnés pour la reproduction, augmentant par conséquent leur contribution génétique aux générations futures. Ce processus de sélection se décompose généralement en deux phases distinctes, chacune jouant un rôle spécifique dans le processus de renouvellement de la population [85] [90].

Le **clonage** représente la première étape du processus, durant laquelle des copies exactes des individus sont générées. Le nombre de copies produites est proportionnel à la performance relative de chaque individu au sein de la population.

La **sélection** correspond à la deuxième étape, où les individus clonés sont intégrés dans la nouvelle génération. Cette sélection est effectuée en fonction de l'adaptabilité de chaque individu, mesurée par sa performance dans l'étape précédente.

Il existe différent type de sélection :

La sélection aléatoire dans un algorithme génétique est un processus où chaque individu de la population a une probabilité égale d'être choisi, indépendamment de sa valeur d'adaptation. Cette méthode de sélection repose sur un tirage au sort uniforme, où chaque individu a une chance de $1/N$ d'être sélectionné, avec N représentant la taille de la population.

Bien que cette approche soit simple et exempte de biais en fonction de la performance, elle peut ralentir la convergence de l'algorithme. En effet, sans tenir compte de la qualité des

individus, des solutions moins adaptées peuvent être sélectionnées, entraînant des générations de descendants qui ne mènent pas rapidement à des solutions optimales. En conséquence, l'algorithme peut mettre plus de temps à explorer et exploiter l'espace de recherche de manière efficace.

Dans certaines situations, il est donc avantageux de recourir à des méthodes de sélection plus sophistiquées, telles que la sélection par tournoi ou la sélection proportionnelle à la fitness, qui favorisent la sélection d'individus plus performants, accélérant ainsi la convergence vers des solutions de qualité supérieure.

Il est aussi possible de combiner la sélection aléatoire avec d'autres mécanismes pour éviter la stagnation ou l'exploration trop restreinte du domaine de recherche. En ajustant dynamiquement les critères de sélection en fonction de l'évolution de la population, on peut améliorer l'efficacité des algorithmes génétiques.

Sélection par tournoi : La méthode de sélection par tournoi représente une approche distinctive dans les algorithmes génétiques, offrant un mécanisme inclusif qui permet l'intégration d'individus aux performances variables dans le processus évolutif. Contrairement aux méthodes basées exclusivement sur la valeur d'adaptation (fitness), cette technique autorise des candidats moins optimaux à contribuer à l'évolution de la population.

Le fonctionnement de cette méthode repose sur l'organisation de compétitions entre sous-ensembles de population. Une sous-population de taille M (où M est inférieur ou égal à N , la taille totale de la population) est constituée par tirage aléatoire. Ce paramètre M , défini préalablement par l'expérimentateur, constitue une variable déterminante influençant directement les dynamiques de sélection.

Lors de chaque tournoi, les performances des individus au sein de cette souspopulation sont évaluées comparativement. L'individu présentant la meilleure valeur d'adaptation est alors sélectionné pour participer aux phases de croisement génétique. Le choix de la valeur du paramètre M revêt une importance capitale. Lorsque M équivaut à N , signifiant que le tournoi englobe l'intégralité de la population, la sélection devient élitiste et identifie systématiquement le meilleur individu selon la fonction objectif. Dans cette configuration, l'algorithme génétique s'apparente davantage à une méthode de recherche locale, limitant l'exploration à une trajectoire unique dans l'espace des solutions.

Cette approche présente néanmoins certaines limitations, notamment le risque de convergence prématurée vers des optima locaux. Une compétition trop restreinte à un

segment limité de la population peut confiner l'algorithme dans des zones sousoptimales de l'espace de recherche. À l'opposé, lorsque M est fixé à 1, la méthode devient équivalente à une sélection purement aléatoire, sans considération des valeurs d'adaptation, puisque chaque individu est sélectionné au hasard sans critère discriminant.

Bien que la sélection par tournoi favorise l'exploration de la diversité génétique au sein de la population, son efficacité dépend fondamentalement du calibrage adéquat du paramètre M. Ce dernier doit être ajusté avec précision pour maintenir un équilibre entre l'exploration de nouvelles régions de l'espace des solutions et l'exploitation des caractéristiques avantageuses déjà identifiées, évitant ainsi une convergence hâtive vers des solutions suboptimales.

La sélection par rang est une méthode utilisée dans les algorithmes génétiques afin de limiter les effets négatifs de la sélection proportionnelle aux fitness, notamment la domination excessive d'un individu très performant. Proposée par J. Baker en 1985, cette méthode permet de mieux contrôler la pression sélective et de maintenir une diversité génétique suffisante dans la population.

Le principe consiste à ordonner les individus selon leur adaptation. Dans un problème de maximisation, les individus sont classés par ordre croissant des valeurs de la fonction objectif : l'individu le moins adapté reçoit le rang 1, le suivant le rang 2, et ainsi de suite jusqu'au plus performant. Pour un problème de minimisation, l'ordre est décroissant.

Une probabilité de sélection est ensuite attribuée à chaque individu en fonction de son rang, indépendamment de sa valeur de fitness absolue. Cette probabilité est donnée par la formule suivante :

$$P_s(i) = D_{\min}(D_{\max} - D_{\min}) \cdot \frac{N-i}{N-1} \quad (1.1)$$

Où :

- $P_s(i)$: est la probabilité de sélection de l'individu de rang i ,
- N : est la taille totale de la population,
- D_{\max} : est le nombre maximal de descendants qu'un individu peut produire,
- D_{\min} : est le nombre minimal de descendants, défini par la relation :

$$D_{\min} = 2 - D_{\max}; \text{ avec } 0 \leq D_{\max} \leq 2 \quad (1.2)$$

Cette formule garantit une distribution contrôlée des chances de sélection, avec une différence progressive entre les rangs. Ainsi, même les individus de rang moyen

conserver une chance raisonnable d'être sélectionnés, ce qui favorise la diversité génétique et limite la convergence prématurée vers des optima locaux.

Une fois la probabilité $P_s(i)$ calculée pour chaque individu, le nombre de clones qu'il génère est donné par :

$$V(Ind_i) = \lfloor P_s(i) \rfloor + \mathbb{1}(P_s(i) \geq r_i) \quad (1.3)$$

Où :

- $\lfloor P_s(i) \rfloor$: est la partie entière de $P_s(i)$,
- r_i : est un nombre aléatoire tiré dans l'intervalle $[0,1]$,
- $\mathbb{1}(P_s(i) \geq r_i)$: est une fonction prédicat qui retourne 1 si P est vrai, 0 sinon.

Cette dernière équation permet d'introduire une part de hasard tout en respectant la répartition probabiliste imposée par les rangs. Elle empêche qu'un individu accapare une trop grande part de la reproduction, même s'il est bien classé, et garantit que d'autres individus auront également l'opportunité de contribuer à la génération suivante.

La méthode ainsi formulée limite la dominance d'un individu en conservant des proportions adéquates de descendants. Elle présente également une prédisposition à l'exécution massivement parallèle des algorithmes génétiques [91].

La sélection par roulette est une méthode de sélection stochastique utilisée dans les algorithmes génétiques, où chaque individu de la population se voit attribuer une probabilité de sélection proportionnelle à sa valeur de fitness. Le processus peut être imaginé comme une roue de loterie dans laquelle chaque secteur représente un individu, et la taille de chaque secteur dépend de sa performance relative. La sélection consiste à effectuer autant de tirages aléatoires que la taille de la population souhaitée, favorisant ainsi les individus les plus adaptés tout en conservant une part de hasard dans le choix.

$$p_i = \frac{Fitness(Ind_i)}{\sum_{j=1 \text{ to } n} Fitness(Ind_j)}; 0 < p_i < 1 \quad (1.4)$$

Chaque individu est alors reproduit avec une probabilité p_i . Ainsi, les individus les plus performants auront davantage de chances d'être reproduits, tandis que les moins performants seront progressivement éliminés.

– **Croisement** : Le croisement représente le second opérateur génétique appliqué aux individus sélectionnés pour constituer la nouvelle génération. Inspiré du mécanisme biologique de reproduction, cet opérateur vise à mélanger l'information génétique de deux parents choisis avec une certaine probabilité P_c , en échangeant des segments de leurs

chromosomes. Ce processus, généralement effectué par paire, implique la définition d'un ou plusieurs points de découpe permettant de spécifier les portions à intervertir. Parmi les variantes les plus courantes figurent le croisement à un ou plusieurs points et le croisement uniforme.

- **Croisement à point (un et deux points)**

Dans le croisement à un point, un point de croisement est choisi sur la chaîne génétique d'un parent. À partir de ce point, les segments de chaîne qui suivent sont échangés entre les deux parents, produisant ainsi une nouvelle combinaison génétique. Cette méthode est influencée par la position du point de croisement, ce qui introduit un biais positionnel dans la structure génétique résultante.

Le croisement à deux points, quant à lui, implique la sélection de deux points aléatoires sur les chromosomes des parents. Le matériel génétique entre ces deux points est échangé, permettant un mélange plus complexe et plus diversifié des informations génétiques. Ces deux variantes font partie d'une technique générale de croisement à N points, où N peut être supérieur à deux, et plusieurs points de croisement sont utilisés pour échanger différents segments entre les parents.




Figure 6 Principe du croisement à points

- **Croisement uniforme**

Le croisement uniforme est une méthode de recombinaison génétique dans laquelle chaque gène d'un individu est sélectionné de manière aléatoire parmi les gènes correspondants des deux parents. Ce processus s'effectue indépendamment de la position des gènes sur les chromosomes, ce qui permet un mélange flexible et diversifié du matériel génétique des parents pour former un nouvel individu.




Figure 7 Principe du croisement uniforme

– Mutation

La mutation dans les algorithmes génétiques est un opérateur qui modifie aléatoirement un ou plusieurs gènes d'un individu, généralement avec une faible probabilité. Cela permet d'introduire de la diversité génétique, évitant ainsi la convergence prématurée vers un optimum local et favorisant l'exploration de nouvelles solutions.




Figure 8 Principe de mutation

1.4. Conclusion

L'optimisation de l'agencement des parcs éoliens représente un défi majeur en ingénierie énergétique, à l'intersection de la modélisation aérodynamique, de l'analyse économique et de l'intelligence computationnelle. Comme l'a démontré cet état de l'art. En raison des perturbations aérodynamiques liées au sillage, la disposition des turbines ne peut être déterminée de façon aléatoire sans compromettre les performances de l'ensemble du parc.

Bien qu'elles aient permis de poser les fondements de la modélisation du problème, les méthodes conventionnelles atteignent rapidement leurs limites face à la complexité du problème, caractérisé par une forte non-linéarité et la présence de multiples optima locaux. C'est dans ce contexte que les algorithmes d'optimisation métaheuristiques se sont imposés comme des alternatives robustes et flexibles. Inspirés du comportement de systèmes naturels, ces algorithmes offrent une exploration approfondie de l'espace de recherche et permettent souvent d'atteindre des solutions proches de l'optimal, tout en intégrant diverses contraintes techniques et environnementales.

L'analyse comparative des différentes approches – des algorithmes génétiques aux optimisations par essaim, en passant par les méthodes hybrides ou adaptatives – met en évidence la richesse des stratégies disponibles, mais aussi la nécessité d'adapter les outils à chaque contexte d'application. Le recours à des modèles précis de sillage, la prise en compte de l'environnement du site, et l'intégration de critères multiples (énergie, coût, impact) restent des axes essentiels pour affiner les processus d'optimisation.

Ce chapitre constitue ainsi une base théorique solide pour orienter les choix méthodologiques dans les chapitres suivants, notamment en vue de la conception et de la mise en œuvre d'une stratégie d'optimisation adaptée aux spécificités des parcs éoliens étudiés.

Chapitre 2

Méthodologie des Plans d'Expériences

2.1. Introduction

Le plan d'expériences (*Design of Experiments*, DOE) est une méthode statistique permettant de structurer, planifier et analyser des essais afin de comprendre l'influence de plusieurs facteurs (ou variables indépendantes) sur une ou plusieurs réponses mesurables (variables dépendantes) [92]. Contrairement aux approches expérimentales empiriques classiques, le DOE repose sur une stratégie proactive d'investigation, où les combinaisons de paramètres sont soigneusement sélectionnées selon des schémas mathématiques rigoureux afin d'extraire un maximum d'informations avec un minimum d'essais.

Les concepts fondamentaux associés au DOE incluent :

- Facteurs : les variables d'entrée contrôlées (ex. : température, pression de mutation, etc.)
- Modalités (ou niveaux) : les valeurs spécifiques prises par les facteurs
- Réponse : la variable mesurée (ex. : rendement, coût, production d'énergie).
- Effet principal : l'effet moyen d'un facteur sur la réponse, indépendamment des autres facteurs.
- Interactions : l'effet combiné de deux (ou plusieurs) facteurs qui diffère de la somme de leurs effets individuels.

Plans factoriels complets et fractionnaires, plans Taguchi, plans de surface de réponse (RSM) sont quelques types courants.

La méthode des plans d'expériences puise ses origines dans les disciplines mathématiques et statistiques appliquées à l'expérimentation. Historiquement, ce sont les chercheurs en agronomie qui ont été parmi les premiers confrontés à la problématique de l'organisation rigoureuse des essais, notamment en raison de la multiplicité des facteurs à analyser et de la difficulté à répéter les expérimentations à grande échelle. Ces contraintes étaient d'autant plus importantes que la durée des essais en milieu naturel était souvent longue et peu flexible.

C'est dans ce contexte que Ronald A. Fisher a proposé, dès les années 1920, une approche novatrice permettant l'étude simultanée de plusieurs variables influentes à l'aide d'un schéma expérimental rigoureusement structuré [93]. Cette démarche a ouvert la voie à une formalisation des expérimentations scientifiques, en posant les bases de l'analyse de la

Chapitre 2 Méthodologie des Plans d'Expériences
variance (ANOVA) et en introduisant les notions fondamentales de randomisation et de répliquabilité.

Par la suite, les statisticiens et mathématiciens ont enrichi cette méthode en développant des configurations expérimentales spécifiques (plans factoriels complets, fractionnaires, orthogonaux, etc.), accompagnées de tables et d'outils permettant d'optimiser le nombre d'expériences à conduire tout en conservant la fiabilité statistique des résultats.

L'essor industriel et les exigences croissantes en matière de qualité ont favorisé l'adoption massive de cette méthodologie, notamment grâce aux travaux de Taguchi dans les années 1960, qui ont contribué à sa diffusion dans l'industrie japonaise. Taguchi a introduit une vision pragmatique de l'optimisation des procédés en mettant l'accent sur la robustesse des systèmes face aux variations non contrôlées [94]. Aujourd'hui, les plans d'expériences sont largement utilisés dans de nombreux domaines : ingénierie, chimie, électronique, biotechnologie, ou encore optimisation énergétique. Leur capacité à extraire un maximum d'informations à partir d'un nombre réduit de tests en fait un outil incontournable dans les démarches de modélisation, d'optimisation et de validation.

L'une des principales forces de la méthode des plans d'expériences réside dans sa capacité à identifier rapidement les facteurs influents et leurs interactions, tout en réduisant significativement le nombre d'essais nécessaires. Contrairement aux approches empiriques classiques, le DOE permet une exploration simultanée de plusieurs variables, ce qui accélère l'optimisation des systèmes étudiés. Cette approche favorise une économie de ressources (temps, matériaux, énergie) sans compromettre la robustesse des résultats.

Un autre avantage majeur est la mise en évidence des interactions entre facteurs, souvent négligées lorsqu'on varie un seul paramètre à la fois. Grâce à des outils d'analyse statistique comme l'ANOVA (Analyse de la variance), le chercheur peut quantifier les effets principaux et secondaires, facilitant ainsi la compréhension du système. Le DOE contribue également à la robustesse des procédés, notamment par les approches introduites par Taguchi, qui visent à rendre les systèmes moins sensibles aux variations extérieures non maîtrisées [95].

Enfin, cette méthodologie est aujourd'hui utilisée dans de nombreux domaines, tels que l'ingénierie, l'électronique, l'agroalimentaire ou encore l'énergie, en raison de sa capacité à fournir des résultats fiables et généralisables sur la base d'un nombre limité d'essais.

Malgré ses nombreux avantages, l'utilisation des plans d'expériences présente certaines limites. Tout d'abord, cette approche nécessite une bonne maîtrise des concepts statistiques,

et une mauvaise conception du plan peut entraîner des conclusions erronées. L'analyse repose souvent sur des modèles linéaires ou quadratiques, dont les hypothèses ne sont pas toujours vérifiées dans des systèmes complexes ou fortement non linéaires.

Par ailleurs, le nombre d'expériences peut devenir rapidement important si le nombre de facteurs et de niveaux augmente, en particulier dans les plans factoriels complets. Cette contrainte peut poser problème lorsque les essais sont coûteux, longs, ou techniquement difficiles à reproduire. Dans les systèmes soumis à de fortes incertitudes ou à des fluctuations non maîtrisables (systèmes bruités), les résultats peuvent être moins fiables, à moins d'avoir recours à des techniques robustes spécifiques.

Enfin, lorsque les facteurs sont de nature catégorielle complexe ou hiérarchique, l'interprétation des effets peut devenir moins intuitive, voire ambiguë, sans outils adaptés [96].

2.2. Concepts généraux

2.2.2. Facteurs et variables

2.2.1.1. Typologie des facteurs dans un plan d'expériences

La nature des facteurs étudiés joue un rôle déterminant dans la conception du plan expérimental, le choix du modèle mathématique et l'interprétation statistique des résultats. Une classification rigoureuse des facteurs est donc essentielle pour garantir la validité de l'analyse et la pertinence des conclusions. Les principaux types de facteurs rencontrés dans les plans d'expériences sont les suivants :

a. Facteurs continus

Un facteur continu est un paramètre dont les valeurs peuvent varier de manière ininterrompue dans un intervalle défini. Ces facteurs sont représentés par des nombres réels, et leur variation permet d'étudier finement leur effet sur la réponse. Parmi les exemples les plus courants, on retrouve la température, la pression, la concentration chimique, la vitesse ou le taux de mutation dans les algorithmes.

Ces facteurs permettent une modélisation précise, notamment dans les plans de surface de réponse (*Response Surface Methodology*) où les effets quadratiques et les interactions sont analysés. L'échantillonnage de leur domaine de variation est crucial pour obtenir des modèles robustes [97].

b. Facteurs discrets

Les facteurs discrets ne peuvent prendre qu'un nombre limité de modalités distinctes. Ceux-ci peuvent être numériques (ex. : nombre de passes, niveaux de tension) ou non

numériques, comme des étiquettes, des catégories ou des propriétés. Par exemple : type de matériau (acier, aluminium, composite), méthode d'usinage, ou couleur (bleu, rouge, jaune).

Ils sont souvent modélisés sous forme de facteurs catégoriels dans les modèles statistiques, et leur traitement requiert des plans spécifiques, tels que les plans factoriels pour variables qualitatives [97].

c. Facteurs ordonnables

Les facteurs ordonnables (ou ordonnés) sont une sous-catégorie des facteurs discrets. Bien qu'ils prennent un nombre fini de modalités, ces dernières peuvent être rangées selon un ordre logique. Par exemple : « petit – moyen – grand », ou « débutant – intermédiaire – expert ».

Même si les modalités sont codées par des entiers (1, 2, 3), leur traitement statistique diffère des variables continues, car les écarts entre niveaux ne sont pas nécessairement constants ou significatifs. Ces facteurs sont souvent utilisés dans les études de perception, d'échelle de satisfaction, ou de classification qualitative.

d. Facteurs booléens (binaires)

Les facteurs booléens, aussi appelés facteurs binaires, sont des cas particuliers de facteurs discrets ne prenant que deux modalités : par exemple, "présent/absent", "marche/arrêt", "haut/bas", ou "oui/non". Ce type de facteur est très courant dans les études de type *screening*, où l'on souhaite identifier rapidement quels paramètres ont un effet significatif.

Le codage binaire (0/1 ou -1/+1) facilite leur intégration dans les modèles linéaires et dans les algorithmes d'optimisation. Les plans de Plackett-Burman, entre autres, sont bien adaptés à leur étude.

Dans la pratique, un même facteur peut être traité différemment selon le contexte de l'étude et les objectifs de l'analyse. Par exemple, un facteur discret peut être codé comme qualitatif dans une étude exploratoire, puis approximé comme continu dans une phase d'optimisation fine. Il est donc crucial d'adapter la modélisation à la nature des données disponibles et aux méthodes d'analyse choisies.

2.2.1.2. Types de variables

a. Variables naturelles (ou réelles)

Dans une étude expérimentale structurée, les grandeurs influençant le comportement du système sont représentées par des variables notées Z_j , où j appartient à l'ensemble

$\{1, 2, \dots, k\}$, k étant le nombre total de facteurs étudiés. Ces variables naturelles correspondent à des caractéristiques réelles et mesurables du système, telles que la concentration d'un composé chimique ou le taux de croisement dans un algorithme évolutif.

Pour mener à bien un plan factoriel à deux niveaux, chaque facteur est exploré selon deux bornes spécifiques : une limite inférieure, $(Z_j)^{\min}$, et une limite supérieure, $(Z_j)^{\max}$. Ce cadrage permet de circonscrire un domaine d'étude pertinent, équilibrant ainsi la couverture de la variabilité des facteurs et la faisabilité pratique des expérimentations. ‘

b. Variables centrées et réduites

Dans le cadre de la modélisation expérimentale, l'exploitation des résultats nécessite de convertir les variables opératoires réelles en variables sans dimension, dites variables codées ou centrées réduites. Cette transformation permet de simplifier les calculs statistiques, d'homogénéiser les échelles des différents facteurs étudiés, et de faciliter l'interprétation des effets [98].

La relation mathématique permettant de passer des variables physiques réelles aux variables codées s'exprime par : $x_j = \frac{Z_j - Z_{0j}}{\Delta Z_j}$ pour $j = 1, 2, \dots, k$ (II.1)

Dans cette expression :

Z_{0j} : représente le point central du domaine expérimental, calculé comme la

moyenne des valeurs extrêmes : $Z_{0j} = \frac{Z_j^{\min} + Z_j^{\max}}{2}$ (II.2)

ΔZ_j : Est la demi-variation du facteur, utilisée comme unité de normalisation,

déterminé par : $\Delta Z_j = \frac{Z_j^{\min} - Z_j^{\max}}{2}$ (II.3)

La transformation inverse, permettant de revenir des variables codées aux variables réelles, est également importante et s'exprime par :

$$Z_j = Z_{0j} + x_j \cdot \Delta Z_j \quad (\text{II.4})$$

Cette formule est essentielle pour traduire les résultats de l'optimisation dans l'espace des variables codées vers les valeurs réelles des paramètres opératoires. Pour les plans à

plusieurs niveaux, on peut généraliser le codage avec des formules adaptées. Par exemple, pour un plan à trois niveaux $(-1, 0, +1)$, les valeurs réelles correspondantes sont :

- Pour $x_j = -1$: $Z_j = Z_j^{\min}$
- Pour $x_j = 0$: $Z_j = Z_{0j}$
- Pour $x_j = +1$: $Z_j = Z_j^{\max}$

Il est essentiel de clarifier la signification des "variables centrées réduites" dans le contexte des plans d'expériences, car cette terminologie diffère de celle employée habituellement en statistique. En effet, dans le cadre des plans d'expériences, une variable centrée réduite prend spécifiquement les valeurs -1 et $+1$ aux bornes du domaine expérimental.

Cette définition se distingue de l'acception statistique classique, où une variable centrée réduite possède une moyenne nulle et une variance unitaire. Pour éviter toute ambiguïté, précisons que si Z représente une variable qui, au cours de l'expérimentation, prend les valeurs extrêmes Z_j^{\min} et Z_j^{\max} , alors les variables codées correspondantes seront respectivement -1 et $+1$.

Cette méthode de codage présente plusieurs avantages significatifs :

- Elle facilite la comparaison directe des effets des différents facteurs
- Elle améliore la stabilité numérique des calculs matriciels
- Elle simplifie l'interprétation des coefficients du modèle polynômial
- Elle réduit les risques d'erreurs de calcul liés aux différences d'échelle entre variables




Figure 9 Présentation des variables codées

2.2.2. Domaine d'étude et contraintes

Dans le cadre d'une expérimentation planifiée, le domaine d'étude (ou domaine expérimental) représente l'espace dans lequel les variables contrôlables, appelées facteurs, sont autorisées à évoluer. Mathématiquement, ce domaine est un espace à k dimensions, chaque dimension correspondant à un facteur étudié. Chaque point de cet espace est une combinaison spécifique des niveaux des facteurs, et constitue ainsi une configuration expérimentale.

Le domaine d'étude est généralement de forme hyper-rectangulaire, c'est-à-dire un parallélépipède à k dimensions, construit à partir des bornes inférieures et supérieures définies pour chaque facteur. Ces bornes fixent les limites du domaine d'investigation, souvent appelées plages de variation. Pour deux facteurs A et B , le domaine d'étude est représenté comme une surface rectangulaire dans un plan bidimensionnel. De façon plus générale, pour k facteurs, le domaine est un hypercube restreint, dans lequel chaque axe correspond à une variable indépendante.

Ainsi, tout point $x \in \square$, représenté par un vecteur de k composantes, correspond à une expérience. Ces vecteurs servent ensuite d'entrées aux modèles de

réponse, exprimant la relation fonctionnelle : $y = f(x)$

Où : y est la variable de réponse observée et x un vecteur de facteurs codés ou réels, situés dans le domaine d'étude.


Le choix du domaine est une étape stratégique de l'expérimentation. En pratique, l'expérimentateur sélectionne une zone restreinte de l'espace global des facteurs, ce qui constitue le domaine d'étude afin de limiter le nombre d'essais tout en maintenant la représentativité des phénomènes étudiés. Ce choix dépend à la fois des plages de fonctionnement réalistes des facteurs, de la faisabilité technique et des ressources disponibles, et parfois de contraintes physiques ou économiques imposant des relations entre facteurs (par exemple, des interdépendances ou des domaines interdits).

Ces contraintes supplémentaires transforment parfois le domaine d'étude en un sous-ensemble non rectangulaire du plan expérimental. Dans de tels cas, des techniques d'optimisation sous contraintes ou des méthodes de projection peuvent être utilisées pour adapter les plans d'expériences aux domaines restreints.

Chapitre 2 Méthodologie des Plans d'Expériences

Il est essentiel de noter que le domaine d'étude conditionne directement la validité des modèles ajustés : tout modèle construit n'est fiable que dans les limites du domaine défini.

L'extrapolation en dehors de ce domaine peut mener à des prédictions erronées.



2.2.3. Notions de réponses et d'effets

Dans le cadre de l'analyse des résultats d'un plan d'expériences, on s'intéresse à la relation entre les facteurs (ou variables indépendantes) et la réponse observée. Cette réponse, notée Y , représente la grandeur mesurable influencée par les conditions expérimentales : il peut s'agir, par exemple, d'un rendement, d'un coût, d'un temps de réponse ou d'une qualité de produit.

L'objectif est de quantifier l'effet de chaque facteur sur la réponse, c'est-à-dire la variation moyenne de cette réponse lorsqu'on modifie le niveau d'un facteur, toutes choses égales par ailleurs. On distingue deux types d'effets fondamentaux dans la méthodologie des plans d'expériences :

2.2.1.3. Effet principal

Un effet principal correspond à l'influence moyenne d'un facteur individuel sur la réponse, indépendamment des autres facteurs. Par exemple, si l'on étudie l'effet de la température sur un procédé chimique, toutes choses égales par ailleurs, l'effet principal est la variation observée de la réponse entre le niveau bas et le niveau haut de la température.

Chapitre 2 Méthodologie des Plans d'Expériences

Mathématiquement, cet effet est souvent représenté dans les modèles linéaires par le coefficient associé au facteur. Graphiquement, il peut être illustré par une droite de tendance sur un graphique de moyenne des réponses par niveau.




Figure 11 Effet principal

La figure 11 illustre l'effet du facteur A sur la réponse Y en présentant, sur l'axe horizontal, les deux niveaux testés du facteur A (Bas et Haut), et, sur l'axe vertical, la moyenne de la réponse Y observée à chacun de ces niveaux. La courbe bleue relie les moyennes de la réponse correspondant à chaque niveau, mettant en évidence une nette augmentation de Y (de 45 à 70) lorsque le facteur A passe du niveau bas au niveau haut. Cette pente ascendante reflète un effet principal positif, c'est-à-dire que le facteur A a une influence favorable sur la réponse : l'augmentation de son niveau améliore significativement les performances observées. La flèche rouge annotée « Effet positif » renforce visuellement cette interprétation. Ainsi, ce graphique permet de quantifier et de visualiser l'influence moyenne du facteur A, indépendamment des autres facteurs du plan expérimental.

2.2.1.3.1. Calcul de l'effet d'un facteur

L'effet d'un facteur A sur une réponse Y se mesure par la variation de cette réponse lorsque le facteur A passe d'un niveau bas (codé -1) à un niveau haut (codé $+1$), toutes choses égales par ailleurs. Ce changement permet d'isoler l'influence propre du facteur sur le système étudié.

Soit :

- Y_- : la valeur moyenne de la réponse lorsque $A = -1$,
- Y_+ : la valeur moyenne de la réponse lorsque $A = +1$.

On définit alors :

- L'effet global du facteur A par la différence absolue :

$$Effet_{global} = Y_+ - Y_- \quad (II.5)$$

- L'effet moyen, souvent utilisé dans les modèles linéaires ou dans les tableaux ANOVA, par la demi-différence :

$$Effet_{moyen} = \frac{Y_+ - Y_-}{2} \quad (II.6)$$

Cet effet moyen correspond au coefficient du facteur A dans un modèle de régression linéaire à deux niveaux, et représente l'influence unitaire du passage d'un niveau à l'autre sur la réponse.

Cette distinction est utile dans l'interprétation statistique des résultats (ex. : analyse des coefficients estimés), et dans la construction de modèles mathématiques simples du type : $y = \mu + a \cdot x_A$ (II.7)

Où :

- μ : est la moyenne générale,
- a : l'effet moyen du

facteur,

- A : la variable codée

(± 1) .

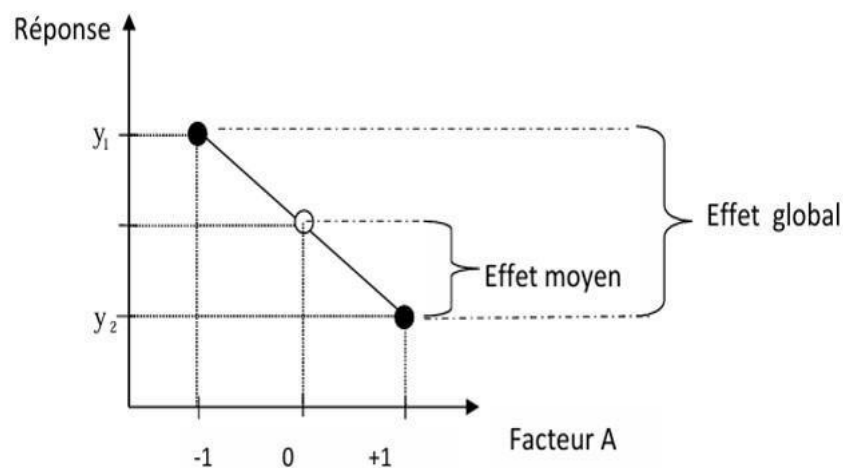


Figure 12 Illustration de l'effet global et l'effet moyen

La Figure 12 illustre la distinction entre l'effet global et l'effet moyen d'un facteur sur la réponse dans un plan d'expériences. L'axe horizontal représente les niveaux du facteur A : -1 (niveau bas), 0 (niveau central), et +1 (niveau haut), tandis que l'axe vertical indique la

réponse mesurée. Les points pleins noirs y_1 et y_2 correspondent respectivement aux réponses observées aux niveaux -1 et $+1$ du facteur A . L'effet global est défini comme la différence totale entre la réponse au niveau bas et celle au niveau haut (i.e., $y_1 - y_2$), ce qui reflète l'impact maximal du facteur A sur la réponse. L'effet moyen, représenté par la double accolade centrale, est la demi-différence entre ces deux réponses, souvent utilisée dans le calcul des effets dans les modèles linéaires classiques. Le point vide au niveau 0 représente la moyenne entre y_1 et y_2 , servant de référence pour évaluer la linéarité de la tendance. Ainsi, cette figure permet de visualiser à la fois l'influence absolue d'un facteur (effet global) et sa contribution moyenne (effet moyen) à la variation de la réponse.

2.2.2.2. Interactions entre facteurs

On parle d'interaction entre deux facteurs, notés ici A et B , lorsque l'effet du facteur A sur la réponse dépend du niveau auquel se trouve le facteur B , et réciproquement. Autrement dit, l'influence d'un facteur ne peut plus être analysée de manière indépendante : les deux facteurs agissent de façon conjointe sur la réponse, et leur combinaison produit un effet différent de la simple somme de leurs effets individuels.

Formule (pour deux facteurs à deux niveaux) :

$$Effet_{AB} = \frac{1}{4}(Y_{++} - Y_{+-} - Y_{-+} + Y_{--}) \quad (II.8)$$

Ce phénomène se traduit souvent par le non-parallélisme des courbes de moyenne des réponses dans un graphique d'interactions comme le montre la figure 13. La prise en compte des interactions est essentielle dans les plans d'expériences car elle permet d'identifier des effets croisés, souvent décisifs dans l'optimisation des systèmes complexes.

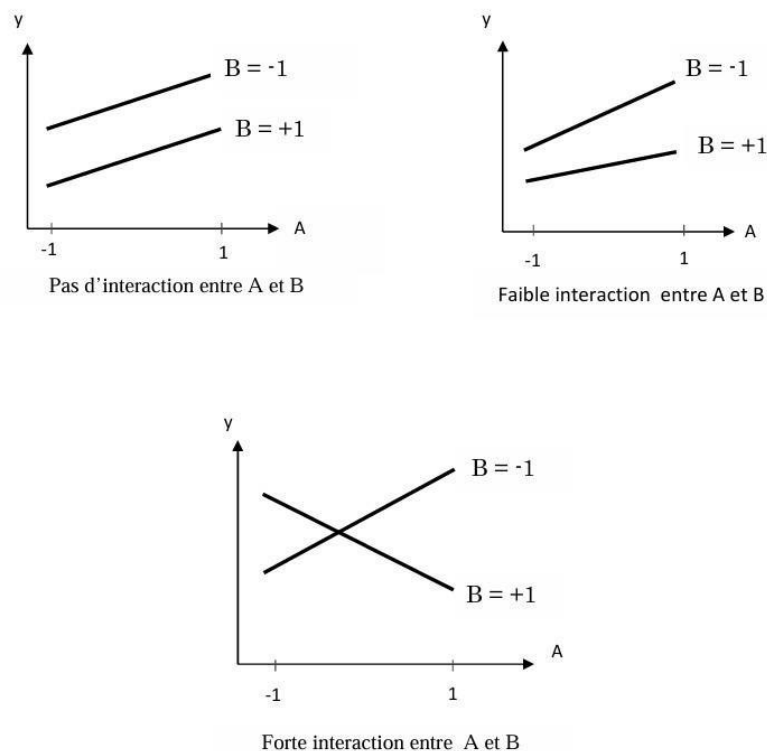


Figure 13 Représentation des interactions entre les effets

Les interactions entre facteurs jouent un rôle fondamental dans les plans d'expériences. Une interaction signifie que l'effet d'un facteur dépend du niveau d'un autre facteur.

Autrement dit, les facteurs n'agissent pas indépendamment les uns des autres.

Détecter ces interactions est essentiel, car elles influencent la stratégie d'optimisation : négliger une interaction peut conduire à des conclusions erronées sur l'influence réelle d'un facteur.

L'identification des interactions repose sur la conception du plan (plans factoriels complets, fractionnaires, etc.) et sur une analyse statistique appropriée.

Méthodes d'estimation des effets

L'analyse des effets dans un plan d'expériences vise à quantifier l'impact de chaque facteur (ou interaction de facteurs) sur la réponse mesurée. Cette estimation permet :

- D'interpréter les résultats de manière rigoureuse,
- D'identifier les paramètres clés influençant la performance du système étudié (ex. : fitness dans une optimisation de parc éolien par AG), et de construire un modèle prédictif.

L'outil central pour cette démarche est l'ANOVA (Analyse de la Variance), qui fournit un cadre statistique pour tester et comparer les effets, permettant de quantifier la contribution

Chapitre 2 Méthodologie des Plans d'Expériences

de chaque facteur (ou combinaison de facteurs) à la variation totale de la réponse, tester la significativité statistique des effets (à l'aide de tests F), et d'identifier les facteurs les plus influents.

L'ANOVA s'applique aussi bien aux plans factoriels complets qu'aux plans fractionnaires ou aux plans de surface de réponse (RSM). Elle constitue un outil central pour la modélisation prédictive, en associant une équation mathématique (modèle de régression) à un comportement expérimental

L'Analyse de la Variance décompose la variabilité totale de la réponse en plusieurs sources de variation :

- Variation due à chaque facteur principal,
- Variation due aux interactions,
- Résidu (erreur non expliquée par le modèle).

Formule générale :

$$SC_{totale} = SC_A + SC_B + SC_{AB} + SC_{erreur} \quad (II.9)$$

Étapes :

1. Calcul des sommes des carrés (SC)

pour chaque effet :

$$SC_A = n_B \cdot (Effet_A)^2 \quad (II.10)$$

Idem pour B et AB .

2. Degrés de liberté (ddl) :

- 1 pour chaque effet à 2 niveaux
(dans un plan 2^2)

- $n - k - 1$ pour l'erreur,

2. Carrés moyens (CM) :

$$CM = \frac{SC}{ddl} \quad (II.11)$$

4. Calcul du test de Fisher (F) :

$$F = \frac{CM_{effet}}{CM_{erreur}} \quad (II.12)$$

5. **Comparaison à une valeur critique** (ou $p - value$) pour juger de la significativité.

Si $p < 0.05$, l'effet est statistiquement significatif à 95 % de confiance.

4. Modèle de régression associé

À partir des effets estimés, on construit un modèle de régression (en variables codées ou réelles) :

a. Variables codées ($A, B = \pm 1$) :

$$Y = \mu + \alpha A + \beta B + \gamma AB \quad (II.13)$$

Où :

- μ est la moyenne des réponses,
- α, β, γ sont les demi-effets de A , B et

AB .

b. Variables réelles :

$$Y = a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 \quad (II.14)$$

Obtenu par transformation linéaire à partir du modèle codé. L'ANOVA et l'estimation des effets permettent de :

- Déterminer la configuration optimale (niveaux des facteurs maximisant ou minimisant la réponse),
- Réduire le nombre de facteurs à considérer dans des modèles complexes (screening),
- Modéliser le comportement du système,
- Prévoir la performance pour de nouvelles configurations.

2.3. Les Plans Factoriels Complets – Étude Théorique et Méthodologique

Les plans factoriels font partie des méthodes fondamentales de la conception d'expériences (Design of Experiments, DOE). Ils permettent d'étudier simultanément l'effet de plusieurs facteurs sur une ou plusieurs réponses. Un plan est dit factoriel complet lorsque toutes les combinaisons possibles des niveaux des facteurs sont testées. Deux grandes familles de plans factoriels sont distinguées [99] :

- Les plans N^k , où chaque facteur peut prendre N niveaux,

- Les plans 2^k , cas particulier où chaque facteur est à deux niveaux (souvent codés -1 et $+1$), très utilisés pour leur efficacité.

Ces plans permettent de quantifier les effets principaux de chaque facteur, détecter les interactions entre facteurs et modéliser le système étudié à l'aide d'équations de régression [100].

2.3.1. Types de plans d'expériences complets

2.3.1.1. Plans factoriels complets N^k – Cas général :

Un plan factoriel complet N^k , désigne un plan où N est le nombre de niveaux de chaque facteur, k est le nombre de facteurs étudiés. Le nombre total d'expériences à réaliser est donc N^k , chaque expérience est une combinaison unique des niveaux de chaque facteur.

Nombre d'effets [92]:

Dans un plan N^k , on peut estimer :

- k : effets principaux,
- $\frac{k(k-1)}{2}$: interactions à deux facteurs, etc., jusqu'à l'interaction d'ordre

k , une constante moyenne (effet global).




Figure 14 Plans factoriels complets 2^2 et 2^3 [101]

La figure 14 illustre des plans factoriels complets 2^2 et 2^3 , utilisés en plan d'expériences pour étudier l'effet de plusieurs facteurs simultanément. Le plan 2^2 (à gauche) concerne deux facteurs (A et B), chacun à deux niveaux codés -1 et $+1$, et comprend 4 expériences représentant toutes les combinaisons possibles, ce qui permet d'estimer les effets principaux ainsi que l'interaction $A*B$. Le plan 2^3 (à droite) inclut trois facteurs (A, B et C), également à deux niveaux, formant un cube de 8 expériences, permettant d'analyser non seulement les

Chapitre 2 Méthodologie des Plans d'Expériences

effets principaux, mais aussi les interactions à deux facteurs ($A*B$, $A*C$, $B*C$) et l'interaction triple ($A*B*C$). Ces plans sont dits "complets" car ils testent toutes les combinaisons, offrant une analyse exhaustive, mais leur principal inconvénient est que le nombre d'expériences croît exponentiellement avec le nombre de facteurs, ce qui peut devenir coûteux ou impraticable pour des études à grande échelle.

Exemple :

Pour un plan 3^2 (2 facteurs à 3 niveaux), il faudra $3 \times 3 = 9$ expériences. Voici la matrice des essais :

Tableau 2 Matrice des essais pour un plan factoriel complet 3^2

Facteur A	Facteur B
Niveau 1	Niveau 1
Niveau 1	Niveau 2
Niveau 1	Niveau 3
Niveau 2	Niveau 1
Niveau 2	Niveau 2
Niveau 2	Niveau 3
Niveau 3	Niveau 1
Niveau 3	Niveau 2
Niveau 3	Niveau 3

Dans les plans saturés, la variance résiduelle est supposée négligeable. Cela permet une première analyse exploratoire. Toutefois, en pratique, il est souvent plus pertinent d'utiliser un modèle réduit d'ordre 2, qui ignore les interactions d'ordre supérieur à 2 supposées peu

Chapitre 2 Méthodologie des Plans d'Expériences significatives. L'interaction d'ordre 3 est alors intégrée dans l'erreur résiduelle, qui devient estimable (même avec peu de degrés de liberté).

2.3.1.2. Plans factoriels à deux niveaux 2^k

Un plan 2^k est un plan factoriel où chaque facteur prend deux niveaux, généralement notés :

- -1 (niveau bas),
- $+1$ (niveau haut).

Le nombre total d'expériences est alors : 2^k

Il a l'avantage d'avoir une représentation facile, un codage simple, une détection efficace des interactions, et une facilité de modélisation mathématique [102].

Exemple – plan 2^3 :

Le plan factoriel 2^3 implique 3 facteurs (A, B, C), chacun à 2 niveaux, pour un total de $2^3 = 8$ essais. La matrice expérimentale complète est présentée ci-dessous :

Tableau 3 Plan factoriel complet 2^3 : codage des niveaux et réponses expérimentales

Facteur A	Facteur B	Facteur C	Réponse (Y)
-1	-1	-1	$y(-1, -1, -1)$
-1	-1	1	$y(-1, -1, 1)$
-1	1	-1	$y(-1, 1, -1)$
-1	1	1	$y(-1, 1, 1)$
1	-1	-1	$y(1, -1, -1)$
1	-1	1	$y(1, -1, 1)$
1	1	-1	$y(1, 1, -1)$
1	1	1	$y(1, 1, 1)$

Chaque ligne de cette matrice représente un essai. Ce plan permet d'estimer 3 effets principaux (A, B, C), 3 interactions d'ordre 2 ($A \times B$, $A \times C$, $B \times C$) et 1 interaction d'ordre 3 ($A \times B \times C$). En l'absence de répétition, le plan est dit saturé, car le nombre de paramètres à estimer est égal au nombre d'essais.

Approche matricielle dans les plans factoriels 2^k

L'approche matricielle permet une formulation algébrique rigoureuse du plan d'expériences et du modèle de réponse, facilitant le calcul des effets principaux et interactions, l'interprétation statistique, et l'automatisation via des outils numériques [97]. Matrice d'expériences X Dans un plan 2^k , la matrice X est une matrice de taille $2^k \times 2^k$ contenant :

- Une première colonne de 1 (pour l'effet moyen),
- Des colonnes représentant les niveaux des facteurs $(-1, +1)$,
- Des produits de ces niveaux pour les interactions (ex : x_1x_2).

2.3.1.3. Modèle général pour un plan 2^k

Un plan factoriel 2^k permet de modéliser la réponse y par une fonction linéaire des facteurs et de leurs interactions.

$$Y = \mu + \sum_{i=1}^k a_i x_i + \sum_{i < j} a_{ij} x_i x_j + \sum_{i < j < l} a_{ijl} x_i x_j x_l + \dots + a_{12\dots k} x_1 x_2 \dots x_k \quad (\text{II.15})$$

Où :

- μ : est la moyenne générale,
- a_i : sont les effets principaux,
- a_{ij} : sont les interactions d'ordre 2, 3, etc.,
- $x_i \in \{-1, +1\}$: sont les niveaux codés des facteurs.

Ce modèle est exact dans un plan complet sans erreur expérimentale.

Moyenne expérimentale : La moyenne (ou effet constant) représente la valeur centrale de la réponse, toutes conditions confondues. Pour un plan 2^k , elle est simplement la moyenne des réponses mesurées :

$$\mu = \frac{1}{2^k} \sum_{i=1}^{2^k} y_i \quad (\text{II.16})$$

Elle constitue la référence autour de laquelle s'expriment les effets des facteurs.

Exemple pour un plan 2^2 : deux facteurs deux niveaux

Tableau 4 Matrice des essais et des effets pour un plan 2^2

Essai	Constante	x_1	x_2	x_1x_2	y
1	1	-1	-1	+1	y_1
2	1	-1	+1	-1	y_2
3	1	+1	-1	-1	y_3
4	1	+1	+1	+1	y_4

Matrice

$$X = \begin{pmatrix} 1 & -1 & -1 & +1 \\ 1 & -1 & +1 & -1 \\ 1 & +1 & -1 & +1 \\ 1 & +1 & +1 & -1 \end{pmatrix}$$

Vecteur des réponses y

Ce vecteur contient les réponses expérimentales observées :

$$y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \end{bmatrix}$$

Vecteur des effets E

Dans le cas d'un plan factoriel à deux facteurs (A et B) à deux niveaux, le vecteur des effets est généralement composé des éléments suivants :

$$E = \begin{bmatrix} \mu \\ a_1 \\ a_2 \\ a_{12} \end{bmatrix}$$

- μ effet moyen global (moyenne de toutes les réponses expérimentales),
- a_1, a_2 Les effets principaux
- a_{12} L'effet d'interaction.

Calcul des effets

Les effets sont calculés à partir de la relation matricielle suivante :

$$E = \left(\frac{1}{n}\right) \cdot X^T \cdot y \quad (\text{II.17})$$

Où :

- X^T : est la transposée de la matrice X,
- $n = 2^k$: est le nombre d'expériences.

Cela signifie que chaque effet est la projection de la réponse sur la colonne correspondante de X divisée par n.

Exemple avec 2^2

Si :

$$y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \end{bmatrix}$$

$$\mu = \left(\frac{1}{4}\right) (y_1 + y_2 + y_3 + y_4) \quad (\text{II.18})$$

$$a_1 = \left(\frac{1}{4}\right) (-y_1 - y_2 + y_3 + y_4) \quad (\text{II.19})$$

$$a_2 = \left(\frac{1}{4}\right) (-y_1 + y_2 - y_3 + y_4) \quad (\text{II.20})$$

$$a_{12} = \left(\frac{1}{4}\right) (y_1 - y_2 - y_3 + y_4) \quad (\text{II.21})$$

Une fois les effets calculés, le modèle s'écrit sous la forme :

$$y = \mu + a_1 x_1 + a_2 x_2 + a_{12} x_1 x_2 \quad (\text{II.22})$$

Le tableau 5 présente la signification des principaux effets et des interactions dans le cadre de l'analyse factorielle. Un effet positif indique que la réponse augmente lorsque le facteur passe du niveau bas au niveau haut, tandis qu'un effet négatif correspond à une diminution de la réponse. En présence d'une interaction forte, l'effet d'un facteur dépend significativement du niveau d'un autre facteur, ce qui traduit une interdépendance entre les variables expérimentales. À l'inverse, l'absence d'interaction signifie que les effets des facteurs sont additifs et indépendants, simplifiant ainsi l'interprétation des résultats. Ce tableau constitue une base essentielle pour analyser les résultats d'un plan factoriel et interpréter correctement les coefficients estimés ou les diagrammes des effets.

Tableau 5 Signification des effets principaux et des interactions dans l'analyse factorielle

Type d'effet	Signification
Effet positif	La réponse augmente quand le facteur passe du niveau bas au niveau haut
Effet négatif	La réponse diminue
Interaction forte	L'effet d'un facteur dépend fortement du niveau de l'autre
Pas d'interaction	Les effets des facteurs sont additifs et Indépendants

2.4. Plans Factoriels Fractionnaires

2.4.1. Principe et Construction

Les plans factoriels fractionnaires constituent une stratégie expérimentale permettant de réduire significativement le nombre d'essais requis dans une étude multivariée. Ils consistent à exécuter une fraction déterminée d'un plan factoriel complet, tout en conservant l'information essentielle concernant les effets principaux et, si nécessaire, certaines interactions d'ordre inférieur. En cela, ils s'inscrivent parfaitement dans l'objectif fondamental des plans d'expériences : obtenir un maximum d'information avec un minimum de ressources [92].

Cette approche se révèle particulièrement avantageuse lorsque le nombre de facteurs augmente. Par exemple, un plan complet nécessiterait 128 essais, bien que l'expérimentateur ne s'intéresse généralement qu'aux 7 effets principaux et aux 21 interactions d'ordre 2 les plus significatives. Il devient donc pertinent, dans un souci de temps et de coût, d'envisager une alternative plus efficace, d'où l'intérêt des plans fractionnaires [98].




Figure 15 Plan factoriel fractionnaire 2^{3-1} [101]

Notation générale :

Un plan fractionnaire est noté 2^{k-p} , où :

- k désigne le nombre de facteurs totaux,
- p représente le degré de fractionnement,
- 2^{k-p} correspond au nombre d'essais effectivement réalisés.

Construction

La construction d'un plan fractionnaire repose sur l'emploi de générateurs qui déterminent les colonnes supplémentaires à partir de combinaisons d'effets. Ainsi, certains facteurs sont définis comme des produits de facteurs de base. La matrice d'expériences obtenue est divisée selon un schéma rigoureux, permettant une exploration partielle mais ciblée de l'espace expérimental [92].

Prenons l'exemple d'un plan factoriel à trois facteurs binaires. Un plan complet 2^3 impliquerait 8 essais. En utilisant un plan fractionnaire $2^{3-1} = 4$, on ne retient qu'une moitié des essais en choisissant ceux pour lesquels l'interaction triple ABC a un signe positif ou négatif donné comme montré dans les figures suivantes.

Tableau 6 Matrice d'un plan factoriel complet 2^3 avec trois facteurs A, B, C

Moyenne	A	B	C	AB	AC	BC	ABC
+	-	-	-	+	+	+	-
+	-	+	-	-	+	-	+
+	+	-	-	-	-	+	+
+	+	+	-	+	-	-	-
+	-	-	+	+	-	-	+
+	-	+	+	-	-	+	-
+	+	-	+	-	+	-	-
+	+	+	+	+	+	+	+

Dans le tableau 6, chaque ligne représente un essai expérimental unique, où chaque facteur (A, B, C) prend soit le niveau bas (noté -) soit le niveau haut (+). Ce plan complet $2^3 = 8$ couvre l'ensemble des 8 combinaisons possibles des niveaux des trois facteurs. Les colonnes nommées AB, AC, BC, et ABC correspondent aux interactions entre facteurs, obtenues en multipliant les signes des facteurs concernés ligne par ligne (ex. : $AB = A \times B$). La colonne Moyenne (souvent fixée à + pour tous les essais) symbolise la constante du modèle.

Tableau 7 Matrice d'un plan factoriel fractionnaire 2^{3-1}

Moyenne	A	B	C	AB	AC	BC	ABC
+	-	+	-	-	+	-	+
+	+	-	-	-	-	+	+
+	-	-	+	+	-	-	+
+	+	+	+	+	+	+	+

Le tableau 7 montre un plan fractionnaire de résolution III, noté $2^3 = 4$. Ce plan retient uniquement la moitié des essais du plan complet, choisis ici selon le générateur $ABC = +$: seules les lignes du plan complet où le produit des signes de A, B et C donne + sont conservées. Ce sous-ensemble permet une réduction du nombre d'essais tout en garantissant

Chapitre 2 Méthodologie des Plans d'Expériences

une certaine exploration de l'espace expérimental. Cependant, il induit des alias : par exemple, les effets C et AB deviennent confondus (comme illustré en rouge dans le tableau), car ils prennent les mêmes signes dans toutes les lignes retenues.

Cette réduction est rendue possible par la division de la matrice selon la condition imposée par l'interaction. Elle illustre le principe de hiérarchisation de l'information, selon lequel les effets principaux et les interactions simples sont privilégiés.

On observe alors que la colonne du facteur C est identique à celle de l'interaction AB . Cela implique que l'effet estimé pour C est confondu avec celui de l'interaction AB , ce qu'on appelle un alias ou contraste. On écrit : $C = AB$

Cela signifie que le contraste I_C est la somme de l'effet E_c et de l'interaction I_{AB} , c'est-à-dire : $I_C = E_c + I_{AB}$

Les contrastes se calculent comme les effets dans un plan complet, à partir des signes des colonnes et des réponses mesurées. Par exemple, pour le tableau suivant [92] :

Tableau 8 Tableau des signes pour le calcul des contrastes

Moyenne	A	B	C	Réponse y
+	-	+	-	y_1
+	+	-	-	y_1
+	-	-	+	y_1
+	+	+	+	y_1

Le contraste pour chaque facteur ou interaction est obtenu par la somme des produits (niveau \times réponse) divisée par le nombre total d'essais.

Tableau 9 Contrastes et effets des facteurs dans un plan factoriel

Contraste	Formule	Résultat
l_I	$\frac{+y_1 + y_2 + y_3 + y_4}{4}$	Moyenne
l_A	$\frac{-y_1 + y_2 - y_3 + y_4}{4}$	Effet A
l_B	$\frac{+y_1 - y_2 - y_3 + y_4}{4}$	Effet B

l_c	$\frac{-y_1 - y_2 + y_3 + y_4}{4}$	Effet C
-------	------------------------------------	---------

Ainsi, dans ce type de plan, chaque effet principal est confondable avec une interaction, ce qui complique l'interprétation. Le demi-plan réduit le nombre d'essais, mais cette économie se fait au prix d'une ambiguïté dans les effets estimés. Dans la pratique, on cherche à aliaser les effets principaux avec des interactions d'ordre élevé que l'on suppose négligeables, afin de conserver l'interprétabilité des effets d'intérêt.

Un plan factoriel complet peut donc servir de base à la construction d'un plan fractionnaire. Par exemple, un plan peut être utilisé pour modéliser un système à 3 facteurs, où l'interaction remplace le facteur. Ce principe est le fondement des plans de Taguchi, où l'économie d'essais est systématiquement recherchée en conservant les effets essentiels à l'analyse [97].

Autrement dit, dans un tel plan fractionnaire, les effets principaux sont systématiquement aliassés avec des interactions. Voici d'autres exemples d'alias issus de l'équation de définition $I = ABC$:

- $A = BC$
- $B = AC$
- $C = AB$

Ainsi, seul un sous-ensemble d'effets est estimable indépendamment, sauf si l'on suppose que les interactions alaisées sont négligeables. Cela justifie l'intérêt des plans fractionnaires dans un cadre où seules les contributions majeures sont significatives.

On observe également ce phénomène dans des plans plus étendus. Par exemple, dans un plan 2^{4-1} où $D = ABC$, on obtient les relations d'alias suivantes :

- $A = BCD$
- $B = ACD$
- $C = ABD$
- $D = ABC$

Et pour les interactions d'ordre deux :

- $AB = CD, AC = BD, AD = BC$

Chapitre 2 Méthodologie des Plans d'Expériences

Cela reflète l'idée que des colonnes peuvent avoir exactement les mêmes séquences de signes (± 1) dans la matrice du plan. Cette structure sous-jacente permet de compresser l'information tout en maintenant une capacité d'analyse efficace lorsque certaines interactions sont négligeables [103].

2.4.2. Résolution d'un plan

La résolution est une mesure qualitative de la clarté avec laquelle un plan permet de séparer les effets. Plus la résolution est élevée, plus les effets principaux et les interactions d'ordre inférieur sont estimés de manière fiable [104].

- Résolution III : Les effets principaux sont confondus (aliassés) avec certaines interactions à deux facteurs. Par exemple : $A = BC$.
- Résolution IV : Les effets principaux sont distincts (non aliassés), mais les interactions à deux facteurs peuvent être aliassés entre elles
- Résolution V : Les effets principaux et les interactions à deux facteurs sont tous estimables indépendamment, sans confusion.

Tableau 10 Exemples de résolution des plans fractionnaires

Plan	Résolution	Signification
2^{3-1}	III	Effets principaux aliassés avec 2-facteurs
2^{4-1}	IV	Les effets principaux sont distincts (non aliassés), mais les interactions à deux facteurs peuvent être confondues entre elles.
2^{5-1}	V	Effets principaux + interactions clairs

Le tableau représente un résumé des différents types de plans fractionnaires 2^{k-p} en fonction de leur résolution (notée III, IV, V...), et de ce que cette résolution implique en termes de confusion possible entre les effets.

Ce tableau aide à choisir quel type de plan utiliser selon l'objectif expérimental. Si on n'a besoin que des effets principaux, un plan de résolution III peut suffire. Si on souhaite aussi détecter certaines interactions, il vaut mieux viser une résolution IV ou V. Les plans de résolution V sont idéaux mais demandent plus d'expériences

2.5. Conclusion

Ce chapitre a posé les bases théoriques et méthodologiques des plans d'expériences, en insistant sur leur rôle central dans l'analyse systématique des phénomènes complexes. La compréhension fine des concepts tels que les facteurs, les réponses, les effets principaux et les interactions permet de structurer efficacement les essais et d'extraire des informations pertinentes avec un minimum de ressources expérimentales.

Nous avons tout d'abord présenté les plans factoriels complets, qui offrent une couverture exhaustive de l'espace expérimental, idéale pour identifier tous les effets et interactions possibles. Cependant, leur coût devient prohibitif dès que le nombre de facteurs augmente.

C'est pourquoi nous avons ensuite introduit les plans factoriels fractionnaires, une alternative judicieuse permettant une réduction significative du nombre d'expériences tout en conservant une bonne capacité d'analyse, à condition de maîtriser les notions d'alias et de résolution.

Au-delà de leur intérêt théorique, ces plans sont aujourd'hui indispensables dans de nombreux domaines tels que l'ingénierie, la chimie, l'optimisation énergétique ou encore l'intelligence artificielle. Ils constituent un levier puissant d'amélioration de la performance, de la robustesse et de la compréhension des systèmes complexes. Enfin, la rigueur mathématique et statistique qui les sous-tend garantit la fiabilité des conclusions tirées, pour peu que le plan soit bien conçu et les hypothèses correctement vérifiées.

Chapitre 3

**Application de l'Algorithme Génétique pour
l'Optimisation du Positionnement des Turbines
dans les Fermes Éoliennes**

3.1. Introduction

L'optimisation des fermes éoliennes constitue un enjeu technique crucial pour maximiser la production d'énergie renouvelable tout en minimisant les coûts d'investissement et d'exploitation. Parmi les nombreux paramètres influençant la performance d'un parc éolien, la disposition spatiale des turbines joue un rôle déterminant [63]. Une configuration inadéquate peut engendrer des pertes significatives d'énergie dues aux effets de sillage (*wake effect*), c'est à-dire la perturbation du vent causée par les turbines amont, réduisant ainsi l'efficacité des turbines situées en aval [21][113].

Ce chapitre expose une méthodologie rigoureuse fondée sur l'utilisation des algorithmes génétiques (AG) pour optimiser la disposition des turbines dans une ferme éolienne.

L'approche prend en compte :

- Les contraintes physiques (distance minimale entre turbines, limites du site),
- Les phénomènes aérodynamiques (modélisés par exemple via le modèle de sillage de Jensen),
- Et les considérations économiques (coût d'installation, rendement énergétique, retour sur investissement).

Les algorithmes génétiques sont des techniques d'optimisation stochastiques inspirées des mécanismes de la sélection naturelle et de la génétique biologique, notamment la reproduction, la mutation, le croisement et la sélection. Ces méthodes sont particulièrement efficaces pour résoudre des problèmes non linéaires, discrets et multi-contraints, où les approches traditionnelles se montrent souvent limitées [84, 85].

Dans cette étude, l'AG est utilisé pour explorer l'espace de recherche défini par les différentes positions possibles des turbines sur le site. Chaque solution candidate est représentée par un chromosome, codant la position relative de chaque turbine. Une fonction de fitness, intégrant à la fois la production énergétique estimée (en tenant compte des pertes de sillage) et le coût associé, est définie pour évaluer la performance de chaque configuration.

L'objectif est de déterminer la configuration qui maximise la fonction de fitness, c'est-à-dire celle qui offre le meilleur compromis entre production énergétique et contraintes économiques. L'algorithme évolue ainsi génération après génération, affinant progressivement les solutions vers un optimum global.

L'intégration des algorithmes génétiques dans ce contexte présente plusieurs avantages :

- Capacité à éviter les optima locaux grâce à la diversité de la population,
- Flexibilité pour intégrer différents modèles physiques et économiques,
- Adaptabilité à des topologies de site variées (terrain plat, colline, mer).

Dans les sections suivantes, nous décrivons en détail le modèle de sillage retenu, la modélisation de la ferme éolienne, les paramètres de l'AG utilisés, ainsi que les résultats obtenus et leur interprétation.

3.2. Modélisation de la ferme éolienne

3.2.1. Caractéristiques du site d'étude

La ferme éolienne étudiée dans cette recherche constitue un système spatialement contraint, dont les caractéristiques géométriques et aérodynamiques influencent directement la modélisation du sillage et, par conséquent, l'efficacité énergétique globale du parc. Les paramètres suivants ont été définis pour cadrer le problème d'optimisation de la disposition des turbines :

Le domaine d'étude couvre une surface de 2 km². Cette étendue permet de simuler un parc de taille moyenne, typique des installations onshore de production d'énergie éolienne.

Afin de faciliter la modélisation de la disposition des turbines et de simplifier le codage génétique pour l'algorithme d'optimisation, la surface est divisée en 100 cellules de surface équivalente, soit 200 m² par cellule. Cette discrétisation permet de restreindre les emplacements possibles des turbines à un ensemble fini, ce qui simplifie l'espace de recherche de l'algorithme génétique.

Le coefficient de rugosité $z_0 = 0.3$ est utilisé pour modéliser les conditions de surface du terrain (par exemple, végétation, bâtiments, topographie). Cette valeur correspond à un terrain semi-urbanisé, ce qui influe directement sur le profil vertical du vent et sur la croissance du sillage derrière chaque turbine, notamment à travers la formule logarithmique du profil de vitesse du vent :

$$V(z) = V_{ref} \cdot \left(\frac{\ln\left(\frac{z}{z_0}\right)}{\ln\left(\frac{z_{ref}}{z_0}\right)} \right) \quad (III.1)$$

Où :

- $V(z)$: est la vitesse du vent à une hauteur z ,
- V_{ref} : est la vitesse de référence mesurée à la hauteur z_{ref}
- z_0 : est la hauteur de rugosité.

3.2.2. Modélisation du régime de vent

Dans le cadre de cette étude, nous avons adopté une hypothèse simplificatrice consistant à modéliser un régime de vent unidirectionnel, soufflant constamment du nord vers le sud, avec une vitesse constante de 12 m/s. Cette hypothèse, bien que simplifiée par rapport à la variabilité naturelle du vent, reste couramment utilisée dans la littérature pour l'évaluation préliminaire de la disposition optimale des turbines [19] [31] [73] [105]. Cette modélisation repose sur les considérations suivantes :

3.2.2.1. Hypothèse de direction constante

Le vent est supposé souffler selon une direction fixe (0°) correspondant à l'axe Nord-Sud, sans fluctuations angulaires. Cette hypothèse permet de réduire considérablement la complexité du problème d'optimisation, en limitant l'analyse à un seul sens de propagation du sillage. Elle est particulièrement utile pour :

- Identifier une configuration de base optimisée,
- Évaluer les performances du modèle d'optimisation en condition nominale,
- Comparer l'efficacité de différents algorithmes dans un environnement contrôlé.

3.2.2.2. Hypothèse de vitesse constante

La vitesse du vent est fixée à 12 m/s, ce qui correspond à une vitesse représentative d'un site bien exposé au vent, typique des régions côtières ou de crêtes en zones onshore. Cette valeur permet de modéliser un débit énergétique significatif, tout en maintenant la turbine dans sa zone de production optimale.

La Figure 16 présente une représentation schématique de ce régime unidirectionnel. Les flèches indiquent le flux de vent uniforme. Ce type de visualisation facilite la compréhension des interactions aérodynamiques (effets de sillage) qui seront modélisées par le modèle de Jensen dans la suite de l'étude.

Chapitre 3 Application de l'Algorithme Génétique pour l'Optimisation du Positionnement des Turbines dans les Fermes Éoliennes

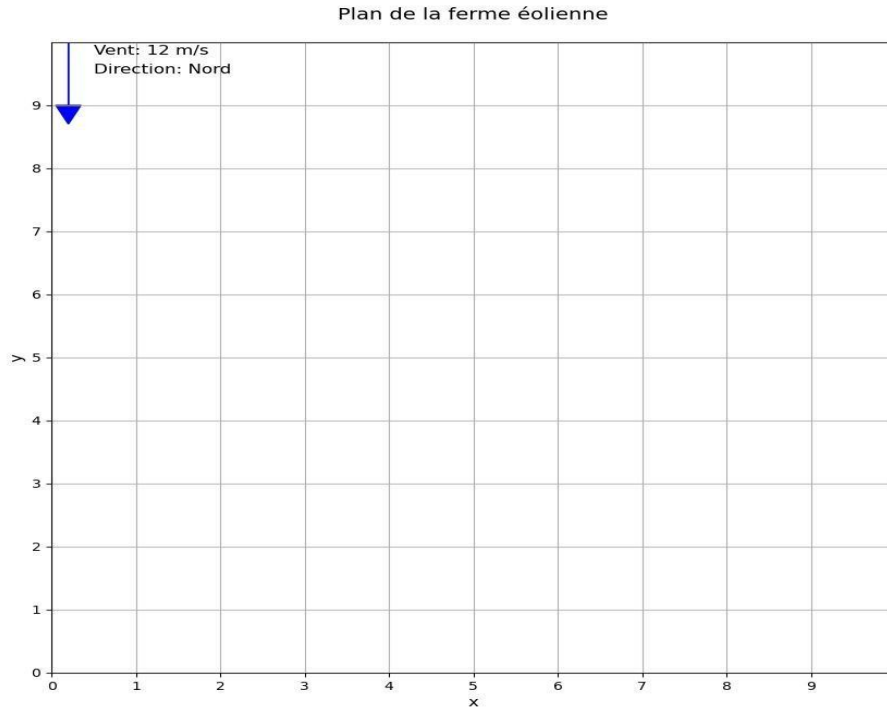


Figure 16 Régime de vent unidirectionnel de la ferme.

Cette simplification permet d'évaluer de manière adéquate la méthodologie d'optimisation proposée tout en maintenant un équilibre entre précision et faisabilité computationnelle. Bien que l'hypothèse d'un vent constant et unidirectionnel constitue une simplification notable par rapport aux conditions réelles, elle demeure pertinente pour notre cas d'étude.

3.2.3. Effet de sillage et modèle de Jensen

L'effet de sillage constitue un phénomène aérodynamique majeur dans la conception et l'optimisation des fermes éoliennes. Lorsqu'une turbine extrait de l'énergie du vent, elle crée en aval une zone où la vitesse du vent est réduite et la turbulence amplifiée. Ce sillage, s'il interfère avec d'autres turbines situées en aval, engendre une perte significative de production énergétique et peut augmenter les charges mécaniques sur les structures [21].

Afin de modéliser et d'anticiper cet impact, nous avons implémenté le modèle de sillage de Jensen, également connu sous le nom de modèle de Park. Ce modèle repose sur l'hypothèse d'une expansion conique et linéaire du sillage (figure 17), et offre un bon compromis entre précision et simplicité de calcul, ce qui en fait un outil de choix pour les approches d'optimisation [106] [107].




Figure 17 Schéma du sillage [108]

La figure 17 représente la formation du sillage derrière une turbine éolienne selon le modèle de Jensen. À gauche, les longues flèches bleues symbolisent le vent libre, noté U , de vitesse constante, non encore perturbé par l'action de la turbine. Cette zone correspond au vent incident arrivant sur la machine. Lorsqu'il traverse le rotor, représenté par la zone hachurée noire, une partie de l'énergie cinétique du vent est extraite pour produire de l'électricité. Ce processus engendre un ralentissement significatif du vent, formant immédiatement derrière la turbine une zone de sillage où la vitesse est réduite, notée $V < U$.

Ce ralentissement est bien visible dans le schéma par des flèches bleues plus courtes, en particulier au centre du sillage.

À mesure que l'on s'éloigne de la turbine vers la droite, ces flèches deviennent progressivement plus longues, ce qui traduit la récupération partielle de la vitesse du vent par mélange avec l'air environnant. Par ailleurs, les deux lignes obliques qui s'écartent illustrent l'expansion linéaire du sillage, modélisée par une ouverture conique. Cette expansion est gouvernée par le coefficient de décroissance k , selon la relation $r(x) = r_r + kx$, où $r_r = D/2$ est le rayon initial du rotor, D étant le diamètre balayé par les pales, et x la distance en aval, également notée d dans le schéma. Ainsi, plus on s'éloigne de la turbine, plus le diamètre du sillage augmente, ce qui représente la diffusion des perturbations dans l'écoulement.

Physiquement, le processus peut être résumé ainsi : le vent atteint la turbine avec une vitesse initiale U , puis une partie de cette énergie est prélevée par le rotor. Ce prélèvement ralentit localement le vent, formant un sillage à basse vitesse juste derrière la turbine. Ce sillage s'élargit avec la distance et la vitesse du vent y augmente graduellement. Ce phénomène de déficit de vitesse est fondamental à prendre en compte dans l'implantation des turbines au sein d'un parc éolien, car il affecte les performances des machines placées en aval.

Un tel schéma est donc essentiel pour visualiser l'impact spatial du sillage, estimer l'influence négative d'une turbine sur ses voisines en aval, déterminer les distances minimales d'espacement, et appliquer correctement le modèle de Jensen dans une stratégie d'optimisation de la disposition des turbines.

La vitesse du vent en aval à une distance x est donnée par l'expression suivante :

$$V = U \left(1 - \frac{C_T}{\left(1 + 2k \frac{x}{D} \right)^2} \right) \quad (\text{III.2})$$

Où :

- V : vitesse du vent à une distance x derrière la turbine,
- U : vitesse du vent libre (non perturbée),
- C_T : coefficient de traînée ou de poussée,
- k : coefficient d'expansion du sillage (dépend de la rugosité du sol),
- D : diamètre du rotor.




Figure 18 illustre l'évolution typique de la vitesse du vent dans le sillage d'une turbine selon le modèle de Jensen [109]

La Figure 18 illustre l'évolution typique de la vitesse du vent dans le sillage d'une turbine selon le modèle de Jensen. L'axe horizontal du graphique représente la distance en aval, exprimée en unités de x/D , c'est-à-dire en nombre de diamètres du rotor. L'axe vertical, quant à lui, indique la vitesse du vent en mètres par seconde. Sur la courbe, on observe que la vitesse du vent dans le sillage, représentée par une courbe bleue, augmente progressivement à mesure que l'on s'éloigne de la turbine. Cette tendance reflète une récupération partielle de la vitesse du vent par effet de mélange avec l'air environnant. En parallèle, une ligne rouge

pointillée apparaît comme une limite supérieure : elle correspond à la vitesse du vent libre, notée U_{∞} , qui est la vitesse initiale du vent avant toute interaction avec la turbine. Une zone bleue ombrée figure dans le graphique pour représenter visuellement le déficit de vitesse induit par la turbine, c'est-à-dire la portion de l'écoulement où la vitesse a été réduite à cause de l'extraction d'énergie. Enfin, une ligne verte pointillée marque une distance particulière, située à 100 diamètres de rotor en aval, servant de repère pour estimer l'étendue du sillage et son influence potentielle sur les turbines situées en aval.

Pour affiner la modélisation du sillage, plusieurs relations analytiques ont été intégrées afin de représenter plus fidèlement l'évolution des caractéristiques du flux derrière une turbine.

Tout d'abord, la variation du rayon du sillage en fonction de la distance en aval est prise en compte à travers une loi linéaire :

$$r_1 = \alpha x + r_r \quad (III.3)$$

Le rayon à une position x est exprimé comme la somme du rayon initial du rotor r_r et d'un terme proportionnel à la distance, via le coefficient de décroissance α . Cette relation traduit le fait que le sillage s'élargit progressivement à mesure qu'il s'éloigne de la turbine. Ce coefficient α dépend des propriétés du site, notamment de la rugosité du sol. Il est défini par :

$$\alpha = \frac{0.5}{\ln\left(\frac{Z}{Z_0}\right)} \quad (III.4)$$

Ce qui permet d'adapter le modèle à des environnements variés comme des terrains plats, vallonnés ou forestiers.

Ensuite, la vitesse du vent dans le sillage est modélisée par une expression qui dépend de la vitesse du vent incident u_0 , du facteur d'induction axiale α représenté par l'équation III.5 et du rayon élargi du sillage qu'on calcule en utilisant l'équation III.6. Cette vitesse diminue significativement juste derrière la turbine, traduisant l'extraction d'énergie mécanique, puis augmente avec la distance, traduisant la régénération partielle du flux. Le facteur d'induction axiale α , qui quantifie la capacité de la turbine à ralentir le vent, est lui même fonction du

coefficient de traînée C_T de la turbine, ce dernier étant déterminé par ses caractéristiques aérodynamiques.

$$a = \frac{1}{2} \left(1 - \sqrt{1 - C_T} \right) \quad (\text{III.5})$$

Enfin, pour tenir compte des effets d'interaction entre le flux ralenti et le flux environnant, un rayon corrigé du sillage est également introduit. Il dépend de r_r et du facteur a , selon une formule qui permet de moduler plus précisément l'intensité et la structure du sillage.

$$r_i = r_r \sqrt{\frac{1-a}{1-2a}} \quad (\text{III.6})$$

L'ensemble de ces expressions constitue une base robuste pour décrire l'évolution du sillage dans l'espace, notamment dans les modèles semi-analytiques comme celui de Jensen. Cette approche est essentielle pour anticiper l'interaction entre les turbines au sein d'un parc éolien et optimiser leur disposition de manière à maximiser la production tout en minimisant les effets de sillage négatifs.

3.3. Formulation du problème d'optimisation

3.3.1. Fonction objective

L'objectif principal de l'optimisation d'un parc éolien est de maximiser la production d'énergie électrique tout en minimisant les coûts associés à l'installation, l'exploitation et la maintenance du système. Dans cette optique, une fonction objective (ou fonction de fitness dans le cadre d'algorithmes évolutifs) est définie de manière à intégrer à la fois l'aspect économique et la performance énergétique du parc.

La fonction de fitness adoptée dans ce travail est une fonction à minimiser, formulée comme le rapport entre le coût global normalisé de la ferme éolienne et la puissance électrique totale produite. Elle s'écrit sous la forme suivante :

$$fitness = \frac{Coût}{P_{totale}} \quad (\text{III.7})$$

- *Coût* : désigne le coût total normalisé du projet, incluant les investissements initiaux, les coûts d'exploitation et de maintenance, ainsi que les pertes éventuelles dues à l'effet de sillage ;

Chapitre 3 Application de l'Algorithme Génétique pour l'Optimisation du Positionnement des Turbines dans les Fermes Éoliennes

- P_{totale} : représente la puissance totale générée par l'ensemble des turbines, exprimée en watts (W).

Cette formulation présente l'avantage de fournir une mesure synthétique de la performance technico-économique du parc éolien : plus le parc produit d'énergie pour un coût donné, plus la valeur de la fonction de fitness est faible, ce qui correspond à une solution plus optimale.

La puissance P générée par une turbine individuelle est modélisée selon l'expression physique classique issue de la dynamique des fluides, adaptée à la conversion de l'énergie cinétique du vent en énergie mécanique, puis électrique :

$$P = \frac{1}{2} \rho A u^3 \eta \quad (\text{III.8})$$

Avec :

- ρ : densité de l'air (en kg/m^3), dépendante de l'altitude et des conditions atmosphériques locales (en général, $\rho \approx 1,225 \text{ kg/m}^3$ au niveau de la mer) ;
- A : surface balayée par les pales de la turbine, soit $A = \pi R^2$ avec R le rayon des pales (en m^2) ;
- u : vitesse du vent à la hauteur du moyeu (en m/s), pouvant être affectée par les interactions aérodynamiques entre turbines (effet de sillage) ;
- η : coefficient d'efficacité globale de conversion, tenant compte du rendement aérodynamique, mécanique et électrique (généralement compris entre 0,3 et 0,5 selon les modèles de turbines).

Dans le cas d'un parc éolien composé de N turbines, la puissance totale est obtenue par la somme des puissances individuelles, tout en tenant compte des pertes induites par les interactions entre turbines (modélisées à l'aide du modèle de sillage de Jensen, voir section 3.2.3) :

$$P_{totale} = \sum_{i=1}^N \frac{1}{2} \rho A u_i^3 \eta \quad (\text{III.9})$$

Où u_i est la vitesse effective du vent reçue par la turbine i , corrigée par les effets de sillage générés par les turbines situées en amont.

Cette formulation de la fonction objective permet de guider l'algorithme d'optimisation vers des solutions qui offrent un bon compromis entre la quantité d'énergie produite et les

ressources économiques mobilisées. Elle est donc parfaitement adaptée dans le cadre d'une optimisation multi-critères condensée en un critère unique de performance, facilitant l'utilisation et la convergence des algorithmes génétiques ou autres métaheuristiques.

3.3.2. Modèle économique

Dans le cadre de cette étude, le modèle économique adopté vise à représenter de manière simplifiée mais représentative le comportement du coût total annuel en fonction du nombre de turbines éoliennes N installées dans le parc. Ce modèle prend en compte les principaux effets économiques observés dans les projets à grande échelle.

Le coût total annuel normalisé est exprimé par la relation suivante :

$$Coût = \left(\frac{2}{3}\right) + \left(\frac{1}{3}\right)e^{-0.00174N^2} \quad (III.10)$$

Cette équation est de nature empirique et présente plusieurs caractéristiques pertinentes du point de vue économique :

- Le terme constant $\frac{2}{3}$ représente la part incompressible des coûts totaux, incluant les coûts fixes d'infrastructure, tels que les postes de transformation, les réseaux de raccordement, les frais d'ingénierie et les coûts de maintenance prévisionnels récurrents. Ces coûts subsistent indépendamment du nombre de turbines et sont donc considérés comme proportionnellement plus importants pour de petits projets.
- Le terme exponentiel $\left(\frac{1}{3}\right)e^{-0.00174N^2}$ modélise la diminution relative des coûts unitaires grâce aux économies d'échelle. En effet, lorsque le nombre de turbines augmente, certains coûts peuvent être mutualisés ou réduits, par exemple via des contrats de maintenance globaux, une meilleure logistique d'installation, ou encore des effets de série dans l'achat des équipements.

Ce modèle reflète donc une diminution progressive du coût total unitaire avec l'augmentation du nombre de turbines, mais cette diminution tend asymptotiquement vers une limite fixée par les coûts incompressibles. Il ne suppose pas une décroissance linéaire, mais une décroissance rapide dans les faibles valeurs de N , suivie d'une stabilisation, ce qui correspond bien au comportement économique observé dans la planification des projets

éoliens à grande échelle. Cette formulation a été proposée dans plusieurs travaux antérieurs portant sur l'optimisation de la disposition des turbines dans les fermes éoliennes [110].

L'intérêt de cette approche réside dans sa simplicité mathématique tout en capturant les effets économiques fondamentaux nécessaires à l'évaluation technicoéconomique du parc. En outre, elle facilite l'intégration dans une fonction objective continue et différentiable, adaptée à une optimisation par algorithmes évolutionnaires.

3.3.3. Contraintes d'optimisation

Dans tout processus d'optimisation technico-économique appliqué à la disposition des turbines dans une ferme éolienne, l'intégration de contraintes physiques, techniques et environnementales est essentielle pour garantir la faisabilité et la pertinence des solutions obtenues. Le modèle proposé prend en compte un ensemble de contraintes multidimensionnelles, formulées pour refléter les réalités opérationnelles et réglementaires d'un projet de parc éolien à grande échelle.

Les principales contraintes intégrées sont décrites ci-dessous :

3.3.3.1. Contraintes spatiales

Les turbines doivent impérativement être implantées à l'intérieur des limites géographiques du site d'implantation défini. Ce périmètre, souvent de forme irrégulière, peut être contraint par des éléments naturels (relief, forêts, plans d'eau) ou artificiels (routes, lignes électriques, habitations).

Matériellement, cette contrainte est traduite par :

$$(x_i, y_i) \in \Omega, \forall i \in \{1, \dots, N\} \quad (\text{III.11})$$

Où Ω représente la zone admissible de placement et (x_i, y_i) les coordonnées de la turbine i .

3.3.3.2. Contraintes de distances minimales de sécurité

Pour des raisons de sécurité mécanique, d'accessibilité et de performance Aero-énergétique, une distance minimale doit être respectée entre chaque paire de turbines. Cette contrainte permet également de limiter l'interférence entre les structures et d'assurer une maintenance efficace [111, 112].

Elle s'exprime mathématiquement comme suit :

$$\|(x_i, y_i) - (x_j, y_j)\| \geq D_{\min} \forall i \neq j \quad (\text{III.12})$$

Où D_{\min} correspond généralement à un multiple du diamètre du rotor (typiquement $3D$ à $5D$).

3.3.3.3. Effet de sillage (aérodynamique)

L'effet de sillage constitue l'un des facteurs limitants majeurs de la production énergétique dans les fermes éoliennes. Lorsqu'une turbine extraite de l'énergie du vent, elle crée en aval une zone de turbulence caractérisée par une réduction de la vitesse du vent et une augmentation de la turbulence, ce qui dégrade les performances des turbines situées dans cette zone [113].

Cet effet est modélisé à l'aide du modèle de Jensen, qui permet de calculer la vitesse effective u_i perçue par chaque turbine en fonction de sa position relative aux autres turbines.

L'impact de cet effet est indirectement intégré dans la fonction objective via la puissance calculée P_{totale} , ce qui contraint implicitement l'algorithme à favoriser des dispositions réduisant les pertes dues au sillage.

3.3.3.4. Contraintes liées à la rugosité du terrain

La rugosité du sol influence le profil vertical de la vitesse du vent, modifiant la distribution de l'énergie disponible selon la topographie et la couverture du sol (végétation, bâtiments, etc.). Cette influence est intégrée via un modèle de loi de puissance ou de type logarithmique, permettant d'adapter la vitesse du vent à la hauteur du moyeu de la turbine en tenant compte de la rugosité z_0 du terrain.

Par exemple, le profil vertical peut être modélisé par :

$$u(z) = u_{ref} \left(\frac{z}{z_{ref}} \right)^\alpha \quad (\text{III.13})$$

Où α dépend de z_0 , la rugosité du site, influençant indirectement la productivité énergétique.

3.3.3.5. Contraintes environnementales et réglementaires

Les projets éoliens sont soumis à des réglementations locales, nationales et européennes en matière d'impact environnemental, de respect des zones protégées (Natura

2000, parcs naturels, zones de nidification), de nuisance sonore et de distance minimale aux habitations (généralement 500 m à 1000 m selon les pays) [114]. Ces exigences sont modélisées par des zones d'exclusion dans lesquelles l'installation de turbines est interdite, ou par l'imposition de pénalités dans la fonction de fitness en cas de non-conformité.

L'ensemble de ces contraintes permet de définir un espace de recherche réalisable dans lequel l'algorithme d'optimisation explore les configurations possibles, tout en garantissant la conformité aux exigences techniques, physiques et environnementales. Ce cadre contraint favorise l'obtention de solutions robustes, réalistes et exploitables en pratique.

3.4. Application de l'algorithme génétique

L'algorithme génétique (AG) constitue une méthode d'optimisation stochastique largement reconnue pour sa robustesse et sa capacité à explorer efficacement des espaces de recherche complexes. Son principe repose sur la métaphore de l'évolution biologique, intégrant des mécanismes tels que la sélection, le croisement et la mutation. Dans le contexte de l'optimisation des parcs éoliens, l'AG vise à identifier les agencements les plus efficaces de turbines afin de maximiser la production énergétique tout en minimisant les coûts associés.

3.4.1. Structure et représentation chromosomique

L'étape initiale de la mise en œuvre d'un AG consiste à choisir une représentation adéquate des individus. Dans notre cas, chaque chromosome encode une configuration spatiale de la ferme éolienne. Une grille discrétisée de dimension 10×10 a été utilisée pour modéliser la surface disponible, divisée en 100 cellules de taille égale.

Chaque chromosome est donc une chaîne binaire de longueur 100, où : - Un bit à 1 indique la présence d'une turbine dans la cellule correspondante ; - Un bit à 0 indique l'absence de turbine.

Cette représentation binaire présente de nombreux avantages :

- Simplicité d'encodage et d'analyse ;
- Compatibilité directe avec les opérateurs génétiques standards (croisement, mutation) ;
- Facilité d'intégration des contraintes spatiales (par exemple, en interdisant certains bits à 1 selon les limites physiques du site).

3.4.2. Génération de la population initiale

La diversité génétique de la population initiale est essentielle pour garantir une bonne exploration de l'espace de recherche. Dans notre étude, une population initiale de 300 individus a été générée selon une méthode aléatoire, chaque bit du chromosome est attribué de manière aléatoire, sous contrainte du nombre maximal de turbines autorisé, assurant une large dispersion initiale.

3.4.3. Évaluation du fitness

L'évaluation de la qualité de chaque individu repose sur une fonction de fitness reflétant le compromis entre production énergétique et coût. Le processus d'évaluation comprend les étapes suivantes :

- a. Calcul de la puissance individuelle : Pour chaque turbine, la puissance est estimée à partir de l'équation de Betz corrigée, en tenant compte des effets de sillage modélisés par la formule de Jensen (III.9).
- b. Puissance totale P : Somme des puissances nettes produites par toutes les turbines, ajustées selon leurs positions relatives.
- c. Coût total: Calculé selon l'équation économique (III.11), en fonction du nombre total de turbines.
- d. Fitness : Calculée comme le rapport du coût sur la puissance, selon la fonction objective (III.8)

Une fitness plus faible indique une solution plus performante économiquement et énergétiquement.

3.4.4. Opérateurs génétiques

Trois opérateurs fondamentaux ont été implémentés pour faire évoluer la population :

a. Sélection

La sélection des parents est effectuée via la méthode par tournoi avec $k = 3$, consistant à tirer aléatoirement trois individus et à choisir le meilleur selon leur fitness. Cette méthode offre un bon équilibre entre exploitation et exploration, tout en maintenant la diversité génétique.

b. Croisement

Un croisement à un point est réalisé entre deux parents sélectionnés, avec un taux de croisement variant entre 0.6 et 0.9 par tâtonnement.

c. Mutation

L'opérateur de mutation introduit une altération ponctuelle des gènes (bits), avec un taux de mutation entre 0.01 et 0.1.

L'élitisme est également intégré afin de conserver les meilleures solutions à chaque génération.

3.4.5. Critères d'arrêt et convergence

Deux critères d'arrêt ont été définis pour contrôler la durée de l'optimisation :

a. Nombre maximal de générations : L'algorithme est interrompu après 1500 générations, seuil établi empiriquement comme suffisant pour assurer la convergence dans notre cas d'étude.

b. Critère de stagnation : Si la meilleure valeur de fitness n'évolue pas pendant 100 générations consécutives, le processus est considéré comme convergé.

Ces deux critères assurent un bon compromis entre temps de calcul et qualité des solutions.

3.5. Processus d'optimisation complet

Le processus d'optimisation complet constitue l'intégration systématique de l'algorithme génétique avec la modélisation énergétique et économique de la ferme éolienne, tout en respectant l'ensemble des contraintes techniques et spatiales propres au site. Il s'agit d'un enchaînement itératif d'opérations dont l'objectif est de converger vers la meilleure configuration possible de turbines, en maximisant la production tout en maîtrisant les coûts.

Les Figures 19 et 20 illustrent l'organigramme détaillé de ce processus. Chaque étape y est représentée de manière séquentielle, soulignant les boucles d'itération et les interactions entre les différentes composantes de l'algorithme.

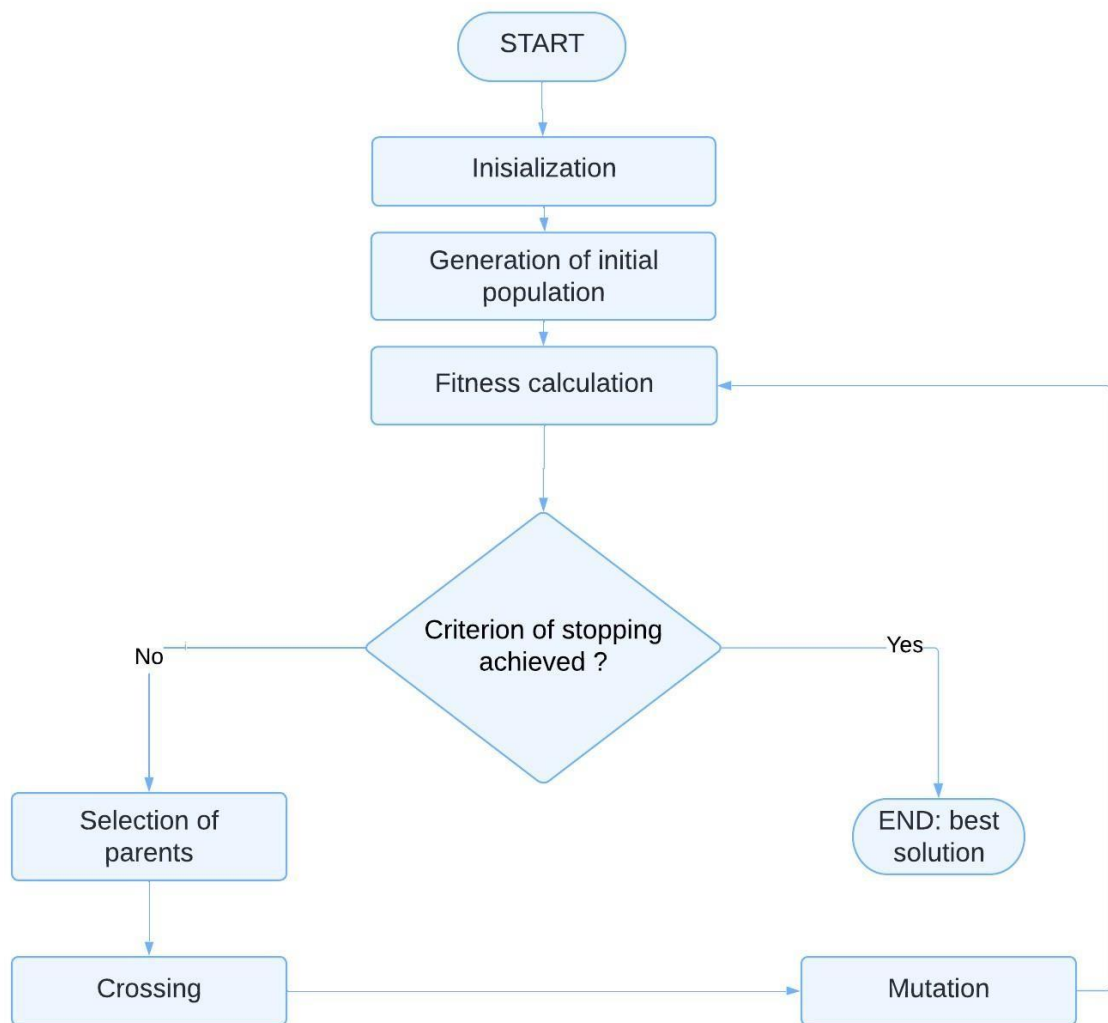


Figure 19 Diagramme de la méthode des AG [109]

Chapitre 3 Application de l'Algorithme Génétique pour l'Optimisation du Positionnement des Turbines dans les Fermes Éoliennes

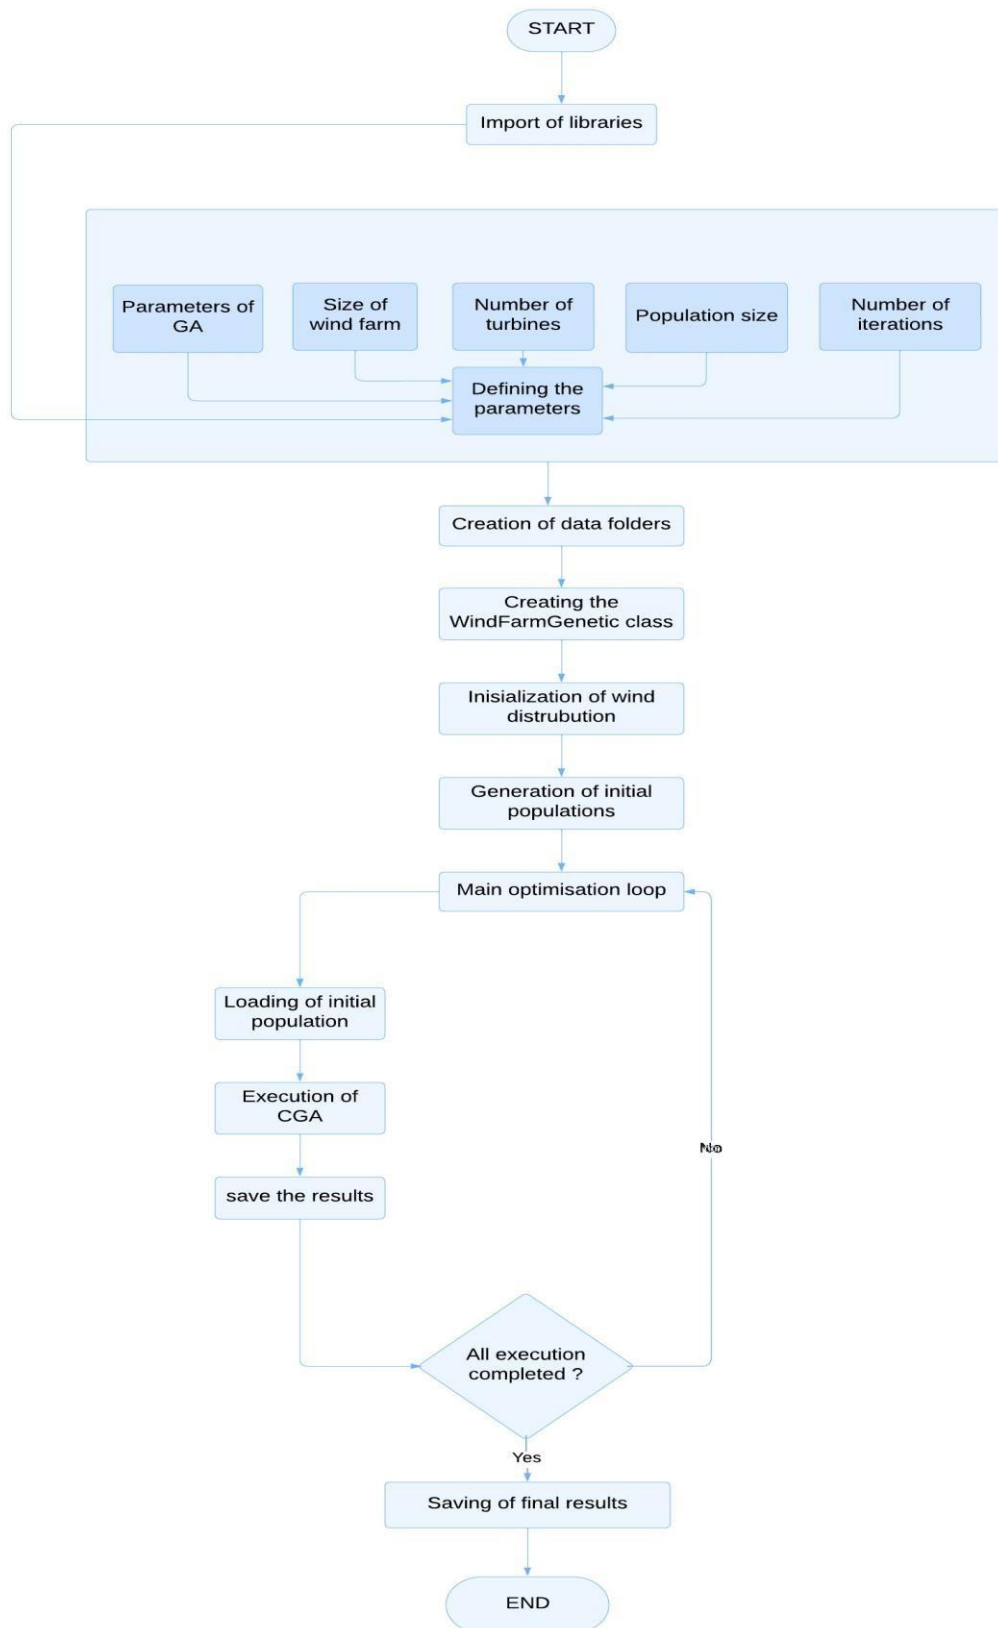


Figure 20 Diagramme d'optimisation [109]

Chapitre 3 Application de l'Algorithme Génétique pour l'Optimisation du Positionnement des Turbines dans les Fermes Éoliennes

L'optimisation commence par une phase d'initialisation qui prépare l'ensemble du système. Cette étape inclut la définition des paramètres physiques de la ferme éolienne, tels que la taille du site, la direction dominante du vent, la distance minimale entre turbines ou encore la puissance nominale. Parallèlement, les paramètres de l'algorithme génétique sont spécifiés, notamment la taille de la population, le nombre maximal de générations, les taux de croisement et de mutation, ainsi que la méthode de sélection. Une population initiale est ensuite générée selon des méthodes aléatoires et heuristiques présentées précédemment (section 3.4.2), de façon à garantir une diversité génétique suffisante dès le départ.

À chaque génération, les individus sont évalués suivant une procédure rigoureuse. Les effets de sillage sont modélisés à l'aide du modèle de Jensen, qui prend en compte l'interaction entre les turbines et la réduction du vent disponible en aval. Sur cette base, la production énergétique totale est calculée en intégrant les pertes de rendement liées aux interférences. Le coût d'implantation est également estimé à partir du nombre de turbines et des caractéristiques du site. L'évaluation de la fitness repose alors sur une fonction objective qui combine les objectifs de production et de coût (voir section 3.4.3).

Après l'évaluation, les meilleurs individus de la population actuelle sont sélectionnés comme parents pour générer la population suivante. La méthode du tournoi à trois individus est utilisée afin d'assurer une pression sélective modérée, ce qui permet d'équilibrer l'exploitation des bonnes solutions avec la préservation de la diversité génétique. Les parents ainsi sélectionnés subissent ensuite des opérateurs génétiques. Un croisement à un point est appliqué pour assurer un brassage efficace des informations génétiques, tandis qu'une mutation binaire introduit de nouvelles variations. Cette phase permet de produire une nouvelle génération d'individus.

La population suivante est alors construite à partir de ces enfants, en intégrant une stratégie d'élitisme. Les meilleurs individus de la génération précédente sont conservés dans la population actuelle, garantissant que les solutions de haute qualité ne soient jamais perdues au fil des générations. Ce processus d'évaluation, de sélection, de reproduction et de remplacement est répété de manière itérative jusqu'à ce qu'un critère d'arrêt soit atteint, qu'il s'agisse du nombre maximal de générations ou d'une stagnation prolongée de la meilleure valeur de fitness.

Enfin, une fois l'algorithme interrompu, la meilleure solution obtenue est extraite et soumise à une validation approfondie. Sur le plan énergétique, ses performances sont comparées à celles de configurations de référence ou issues d'autres méthodes.

Cette approche systématique assure une recherche équilibrée entre exploration et exploitation, tout en garantissant la convergence vers des solutions robustes et économiquement viables. Elle offre une méthodologie généralisable à d'autres scénarios d'optimisation en énergie renouvelable, en adaptant les modèles de fitness et les contraintes aux spécificités des systèmes considérés.

3.6. Évaluation des performances de l'algorithme

L'évaluation des performances de l'algorithme génétique constitue une étape cruciale pour valider son efficacité, sa fiabilité et sa pertinence dans le cadre de l'optimisation de la disposition des turbines dans une ferme éolienne. Cette section présente les métriques retenues pour l'évaluation, suivies d'une analyse de la convergence de l'algorithme.

3.6.1. Métriques d'évaluation

Pour caractériser de manière exhaustive les performances de l'algorithme développé, plusieurs indicateurs quantitatifs et qualitatifs ont été définis :

- Convergence : Elle mesure la rapidité avec laquelle l'algorithme atteint une solution stable ou proche de l'optimum. Elle est généralement évaluée en analysant la variation de la fitness maximale ou moyenne au cours des générations. Une convergence rapide traduit une efficacité exploratoire du processus évolutionnaire.
- Robustesse : Elle évalue la capacité de l'algorithme à fournir des résultats cohérents et performants sur plusieurs exécutions indépendantes. En raison de la nature stochastique des algorithmes génétiques, cette propriété est essentielle pour garantir la fiabilité du processus d'optimisation. Elle est souvent mesurée à travers l'écart-type des valeurs finales de fitness ou de production énergétique obtenues sur un ensemble d'exécutions (typiquement 30 runs).
- Efficacité computationnelle : Cet indicateur rend compte des ressources nécessaires pour atteindre une solution optimale, incluant :

Chapitre 3 Application de l'Algorithme Génétique pour l'Optimisation du Positionnement des Turbines dans les Fermes Éoliennes

- Le temps total d'exécution (en secondes ou minutes),
- Le nombre de générations nécessaires à la convergence,
- Et l'occupation mémoire si celle-ci est significative.

Cette métrique permet de juger de la praticabilité de l'algorithme dans un contexte industriel ou en temps contraint.

En combinant ces métriques, une évaluation globale et équilibrée de l'algorithme est obtenue, couvrant aussi bien les aspects qualitatifs (qualité et robustesse des solutions) que les aspects opérationnels (temps de calcul et rapidité de convergence).

3.6.2. Analyse de convergence

L'analyse de la convergence a été réalisée en observant l'évolution de la valeur de fitness maximale à travers les générations. Cette analyse permet d'identifier la phase d'exploration initiale, suivie d'une phase d'exploitation où l'algorithme affine progressivement les solutions.

La Figure 21 présente cette évolution typique pour une exécution représentative de l'algorithme. On y distingue clairement les différentes dynamiques de l'optimisation :




Figure 21 Courbe de convergence de l'algorithme génétique

On observe une phase de convergence rapide au début, où la diversité génétique permet d'explorer largement l'espace des solutions. La phase de convergence lente représente une stabilisation progressive, avec une augmentation plus lente mais continue du fitness maximal,

reflétant une convergence vers un optimum local ou global. La dernière phase est la phase de plateau, où le fitness ne s'améliore plus significativement, suggérant que l'algorithme a atteint une configuration stable ou que l'espace de recherche a été suffisamment exploré.

Réglage des paramètres de l'algorithme génétique

Le réglage approprié des paramètres de l'algorithme génétique (AG), en particulier les taux de mutation (P_m) et de croisement (P_c), constitue une étape essentielle pour assurer des performances optimales en termes de convergence, de qualité des solutions et d'efficacité computationnelle. Dans cette étude, une approche empirique structurée a été mise en œuvre afin d'identifier les combinaisons de paramètres les plus performantes pour l'optimisation d'un parc éolien.

Les intervalles de recherche suivants ont été définis :

- Taux de mutation P_m : de 0.01 à 0.10, avec un pas de 0.01 ;
- Taux de croisement P_c : de 0.60 à 0.90, avec un pas de 0.03.

Ces choix ont conduit à un total de 100 configurations différentes, représentant toutes les combinaisons possibles dans les intervalles spécifiés. Chaque configuration a été testée de manière indépendante, et évaluée selon deux critères principaux : l'amélioration de la valeur de la fonction objective et l'énergie totale produite par la ferme éolienne.

Tableau 11 Résultats d'une sélection de configurations de paramètres de l'AG

P_c	P_m	Énergie totale (kWh/an)	Valeur de fitness
0.60	0.01	14557	0.00155304
0.60	0.05	14663	0.00154182
0.60	0.10	14460	0.00156346
0.75	0.01	14602	0.00154826
0.75	0.05	14641	0.00154413
0.75	0.10	14615	0.00154688
0.90	0.01	14514	0.00155764

3.7. Discussion des résultats

Le tableau 11 présente une sélection de combinaisons de paramètres (P_c , P_m) testées dans le cadre du réglage des opérateurs génétiques. Chaque configuration est évaluée selon deux critères essentiels : l'énergie totale produite par la ferme éolienne (en kWh/an) et la

Chapitre 3 Application de l'Algorithme Génétique pour l'Optimisation du Positionnement des Turbines dans les Fermes Éoliennes

valeur de la fonction de fitness, qui est inversement proportionnelle à l'énergie (minimisation de la fonction).

Influence du taux de mutation P_m

Pour un taux de croisement fixé ($P_c = 0.60$), l'augmentation progressive du taux de mutation de 0.01 à 0.10 entraîne des effets contrastés :

- ✓ Une augmentation de P_m de 0.01 à 0.05 permet d'améliorer la performance globale (énergie totale passant de 14557 à 14663 kWh/an, et le fitness s'améliore à 0.00154182).
- ✓ En revanche, une mutation trop élevée ($P_m = 0.10$) dégrade les résultats (énergie à 14460 kWh/an, fitness = 0.00156346), probablement en raison d'un excès d'exploration perturbant la convergence.

Ce comportement confirme le rôle crucial du taux de mutation dans le compromis entre exploration de l'espace de recherche et exploitation des bonnes solutions. Un taux trop faible peut limiter la diversité génétique, tandis qu'un taux trop élevé introduit de l'instabilité.

Influence du taux de croisement P_c

En comparant les lignes pour un taux de mutation constant ($P_m = 0.05$), on observe :

Une progression de l'énergie produite entre $P_c = 0.60$ (14663 kWh/an) et $P_c = 0.75$ (14641 kWh/an), puis une légère régression à $P_c = 0.90$ (non testé avec $P_m = 0.05$, mais observé à $P_m = 0.01$).

Cela suggère qu'un taux de croisement intermédiaire ($P_c = 0.75$) permet un bon équilibre entre recombinaison efficace des individus et préservation des structures génétiques favorables. Un taux trop bas diminue la capacité de l'algorithme à générer de nouvelles solutions pertinentes, tandis qu'un taux trop élevé peut conduire à une perte de diversité prématurée.

Configuration optimale identifiée

Parmi les configurations testées, le couple ($P_c = 0.60$, $P_m = 0.05$) offre la meilleure valeur de fitness (0.00154182) et la plus haute énergie produite (14663 kWh/an), ce qui en fait un candidat optimal dans ce contexte. Cette configuration fournit un compromis satisfaisant entre intensification et diversification, tout en maintenant une bonne stabilité sur les exécutions.

Limites de l'approche actuelle

Il convient de noter que cette méthode ne permet pas d'explorer l'interaction croisée entre P_c et P_m de manière systématique. Seules certaines combinaisons discrètes ont été testées, ce qui peut masquer des effets combinatoires subtils. Ce constat renforce la nécessité de recourir à une méthode plus rigoureuse, telle que le plan factoriel complet ou fractionnaire, pour analyser ces interactions de façon structurée (comme présenté dans le chapitre suivant).

3.8. Conclusion

L'analyse approfondie du processus d'optimisation a permis d'identifier les combinaisons de paramètres génétiques (P_c , P_m) les plus performantes, assurant un équilibre optimal entre qualité des solutions obtenues, vitesse de convergence, et robustesse des résultats sur plusieurs exécutions indépendantes. Ces réglages ont ensuite été adoptés pour l'ensemble des simulations dans le cadre de l'optimisation de la disposition des turbines.

La méthode empirique utilisée, bien que simple à mettre en œuvre, s'est révélée efficace et fiable. Elle permet d'évaluer l'effet global des paramètres génétiques sur le comportement de l'algorithme, tout en offrant une bonne représentativité des performances. Toutefois, cette approche repose sur l'évaluation d'un nombre limité de combinaisons discrètes, ce qui ne permet pas d'analyser de manière systématique l'interaction croisée entre le taux de croisement P_c et le taux de mutation P_m . Il est donc possible que certaines synergies entre paramètres aient été ignorées ou mal estimées, ce qui pourrait affecter la qualité du réglage obtenu.

Par ailleurs, le nombre élevé de simulations nécessaires pour évaluer chaque configuration peut devenir coûteux en temps de calcul, en particulier pour des systèmes complexes ou des modèles fortement non linéaires.

Malgré ces limitations, cette démarche constitue une base solide pour une mise en œuvre rigoureuse de l'algorithme génétique appliqué à l'optimisation des fermes éoliennes. Les résultats obtenus confirment la pertinence du processus d'optimisation engagé et justifient l'exploration de méthodes plus avancées et plus structurées.

Dans le chapitre suivant, une nouvelle approche est introduite : la méthode des plans d'expériences (Design of Experiments, DOE). Elle offre un cadre statistique rigoureux pour analyser l'influence conjointe des paramètres P_c et P_m , en réduisant le nombre d'expériences

Chapitre 3 Application de l'Algorithme Génétique pour l'Optimisation du Positionnement des Turbines dans les Fermes Éoliennes

nécessaires tout en augmentant la fiabilité et la robustesse du réglage. Cette méthode vise à améliorer les performances de l'algorithme tout en réduisant significativement le coût computationnel global.

Chapitre 4

**Réglage des Paramètres des Algorithmes
Génétiques pour l'Optimisation des
Fermes Éoliennes à l'Aide de la Méthode
des Plans d'Expériences**

4.1. Introduction

L'optimisation des systèmes complexes, tels que les fermes éoliennes, nécessite des algorithmes capables d'explorer efficacement un espace de recherche vaste et non linéaire. Les algorithmes génétiques (AG), inspirés des principes de la sélection naturelle, se sont imposés comme des outils puissants dans ce domaine grâce à leur capacité à trouver des solutions proches de l'optimum global, même en présence de contraintes multiples et d'un espace de solutions complexe [78].

Cependant, l'efficacité des AG dépend fortement du réglage de leurs paramètres de contrôle, en particulier le taux de mutation et le taux de croisement. Un mauvais paramétrage peut considérablement dégrader les performances de l'algorithme, en ralentissant la convergence ou en favorisant des optima locaux. À l'inverse, un réglage judicieux de ces paramètres permet non seulement d'accélérer la recherche, mais aussi d'améliorer la qualité des solutions obtenues. Traditionnellement, ces paramètres sont fixés de manière empirique ou par essais successifs comme nous avons fait dans la section précédente, une démarche souvent longue, coûteuse et peu rigoureuse [73].

Face à ces limites, l'utilisation d'une approche statistique systématique, telle que la méthode des plans d'expériences (Design of Experiments, DOE), s'impose comme une alternative pertinente. Le DOE permet d'étudier simultanément les effets principaux et les interactions entre les paramètres, tout en réduisant le nombre d'expérimentations nécessaires [102]. Il offre ainsi un cadre méthodologique rigoureux pour optimiser le fonctionnement des AG, assurant une meilleure reproductibilité des résultats et une amélioration significative de leur performance.

Ce chapitre présente l'application d'un plan factoriel complet pour optimiser les paramètres de l'algorithme génétique appliqué à la disposition des turbines dans un parc éolien. Après avoir exposé la problématique du réglage des paramètres et justifié le recours à la méthodologie DOE, nous décrivons la mise en œuvre expérimentale du plan, puis établirons le modèle mathématique correspondant. Une analyse statistique approfondie (régression, résidus, test de Fisher) permettra de valider le modèle proposé. Enfin, nous analyserons les effets des paramètres et leurs interactions, avant de discuter les résultats et de les comparer aux approches existantes dans la littérature.

4.2. Méthodologie proposée

4.2.1. Problématique du réglage des paramètres des AG

Les approches traditionnelles utilisées pour régler les paramètres des algorithmes génétiques (AG) reposent encore largement sur des valeurs empiriques ou des règles heuristiques, souvent issues d'une expérience pratique plutôt que d'une validation rigoureuse. Par exemple, Mosetti et al. (1994) ont fixé de manière arbitraire le taux de mutation à 0,1 et le taux de croisement à 0,6, sans fournir de justification méthodologique. Plus tard, Grady et al. (2005) ont adopté une plage similaire de valeurs, également sans validation systématique [19] [73].

Bien que ces choix puissent parfois conduire à des résultats satisfaisants, cette méthode intuitive présente plusieurs limites notables :

- ✓ Un manque de rigueur scientifique : les paramètres sont définis sans appui sur un cadre expérimental structuré ou une analyse statistique.
- ✓ Une inefficacité computationnelle : le recours à l'essai-erreur nécessite un grand nombre d'exécutions de l'algorithme, ce qui augmente considérablement le temps de calcul.
- ✓ Une reproductibilité limitée : les résultats obtenus peuvent varier d'une expérimentation à l'autre, rendant difficile la comparaison entre études.
- ✓ Une ignorance des effets d'interaction : les influences croisées entre paramètres sont rarement prises en compte, ce qui peut masquer des combinaisons pourtant optimales.

Face à ces limitations, il devient essentiel d'adopter une approche plus structurée et statistiquement fondée pour garantir des réglages de paramètres à la fois efficaces, robustes et reproductibles. Pour répondre à cet enjeu, une méthode systématique basée sur les plans d'expériences (DOE) se révèle particulièrement pertinente. Elle offre tout d'abord un cadre statistique rigoureux permettant une analyse quantitative des effets individuels et combinés des paramètres. En outre, cette approche améliore considérablement l'efficacité expérimentale, en extrayant un maximum d'informations à partir d'un nombre réduit d'expériences. Elle permet également de détecter les interactions entre paramètres, souvent négligées dans les approches empiriques, en les modélisant explicitement. Enfin, elle favorise

une optimisation globale du processus, en prenant en compte l'ensemble des facteurs influents de manière simultanée et cohérente.

4.3.1. Choix des facteurs et des niveaux

Dans le cadre de cette étude, deux paramètres fondamentaux de l'algorithme génétique (AG) ont été sélectionnés comme facteurs d'étude, car ils influencent de manière significative la capacité de l'algorithme à explorer efficacement l'espace de recherche et à converger vers une solution optimale. Il s'agit du taux de mutation et du taux de croisement.

Ces deux facteurs ont été analysés chacun à deux niveaux (bas et haut), définis sur la base d'une revue de la littérature spécialisée dans l'optimisation bio-inspirée appliquée à l'éolien [19] [73]. Le tableau suivant résume les choix effectués :

Tableau 12 Variables du plan

Facteur	Symbole	Niveau bas	Niveau haut
Taux de mutation	A	0.01	0.1
Taux de croisement	B	0.6	0.9

Ces choix permettent de construire un plan factoriel complet 2^2 , correspondant à quatre combinaisons possibles de paramètres. Chaque combinaison est utilisée pour exécuter l'algorithme génétique dans le cadre d'un problème d'optimisation de l'emplacement des turbines au sein d'une ferme éolienne. Ce problème se distingue par sa complexité, en raison des effets de sillage induits par les interactions entre turbines.

L'objectif de cette étude est d'identifier la configuration des paramètres qui permet à l'algorithme génétique de maximiser la production énergétique totale du parc, de réduire les pertes liées aux effets de sillage, et d'assurer une convergence à la fois rapide et stable vers la solution optimale.

4.3. Mise en œuvre et résultats expérimentaux

4.3.1. Application du plan factoriel

Conformément à la configuration du plan factoriel complet 2^2 , quatre exécutions distinctes ont été réalisées, chacune correspondant à une combinaison unique des niveaux des deux facteurs étudiés : le taux de mutation (P_m) et le taux de croisement (P_c). Pour chaque

exécution, l'algorithme génétique a été appliqué à un cas test d'optimisation d'un parc éolien, en cherchant à minimiser la fonction de fitness, qui évalue les pertes dues aux effets de sillage et autres inefficiences dans la disposition des turbines.

La fonction de fitness (y) est donc l'indicateur principal de performance. Elle est exprimée ici en valeur réduite, avec des unités arbitraires mais comparables d'une exécution à l'autre. Une valeur plus faible de la fitness indique une meilleure configuration des turbines, c'est-à-dire un rendement énergétique global plus élevé.

Les résultats expérimentaux sont récapitulés dans le tableau suivant :

Tableau 13 Le plan factoriel complet des expériences

Expérience	A (P_m)	B (P_c)	Fitness (y)
1	0.01	0.60	0.00155304
2	0.10	0.60	0.00156346
3	0.01	0.90	0.00155764
4	0.10	0.90	0.00154087

Une première observation montre que la meilleure performance (fitness minimale) est obtenue pour la quatrième configuration ($P_m = 0.10$, $P_c = 0.90$), suggérant qu'une mutation plus élevée combinée à un croisement intensif permet à l'algorithme de mieux explorer l'espace de recherche et d'échapper à des optima locaux.

Ces données expérimentales serviront à l'analyse des effets principaux et d'interaction, en vue d'identifier les influences significatives sur la qualité des solutions et de recommander les paramètres optimaux pour des applications similaires.

4.4.2. Établissement du modèle mathématique

Le but est la détermination de l'équation de notre étude qui peut être représentée sous la forme suivante :

$$Y_i = f(A, B)$$

Avec :

- Y_i : La fitness,
- A : Le coefficient de croisement,
- B : Le coefficient de mutation.

D'après la relation (VI-1), le plan factoriel 2^2 donne une réponse de la forme suivante :

$$Y_i = \mu + a_1A + a_2B + a_{12}AB \quad (\text{IV.1})$$

Les coefficients du modèle sont exprimés par la somme algébrique des réponses expérimentales Y_i affectées des signes de la colonne de la matrice X correspondant au facteur, puis divisées par le nombre d'expériences. Afin de faciliter les calculs et l'analyse statistique, nous avons utilisé Design-Expert, un logiciel spécialisé dans la planification et l'exploitation des plans d'expériences (DOE). Développé par la société Stat-Ease, ce logiciel est largement reconnu pour sa robustesse, sa précision dans l'analyse des effets et des interactions, ainsi que pour sa capacité à générer des modèles mathématiques fiables à partir des résultats expérimentaux.

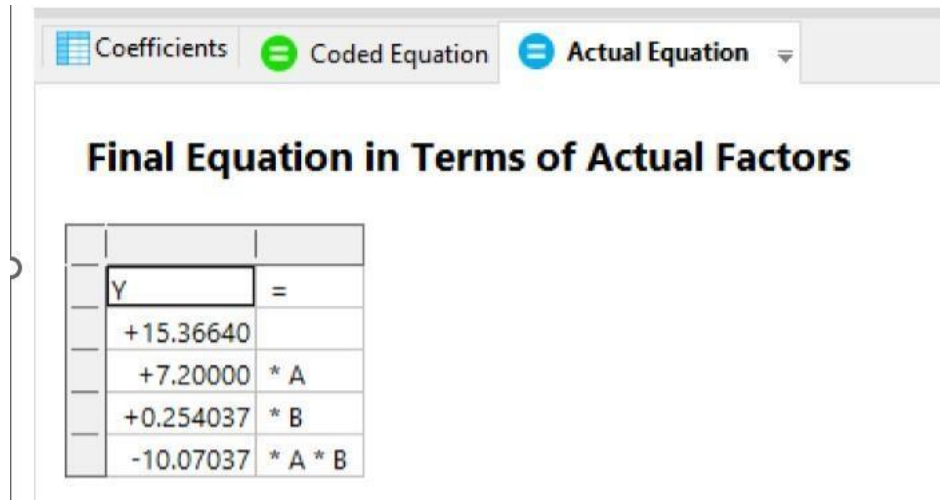
Les coefficients du modèle ont ainsi été estimés à l'aide de ce logiciel. Le tableau 12 présente les coefficients obtenus en valeurs codées, ce qui permet d'analyser directement l'importance relative de chaque facteur et de leurs interactions dans le cadre du plan d'expériences.

Tableau 14 Coefficients du modèle calculés par Design-Expert en valeurs codées.

Coefficients in Terms of Coded Factors							
	Factor	Coefficient Estimate	df	Standard Error	95% CI Low	95% CI High	VIF
	Intercept	15.54	1				
	A-A	-0.0159	1				1.0000
	B-B	-0.0450	1				1.0000
	AB	-0.0680	1				1.0000

À partir de ces coefficients codés, le logiciel fournit également l'équation finale en termes de facteurs réels, ce qui facilite l'interprétation pratique des résultats. Cette équation exprime la réponse en fonction directe des variables expérimentales étudiées. Les coefficients correspondants sont regroupés dans le tableau 13.

Tableau 15 Coefficients du modèle calculés par Design-Expert en valeurs



The screenshot shows the 'Coefficients' tab in Design-Expert. The title is 'Final Equation in Terms of Actual Factors'. Below it is a table representing the regression equation:

Y	=	
+15.36640		
+7.20000	* A	
+0.254037	* B	
-10.07037	* A * B	

Afin de faciliter la comparaison entre les coefficients exprimés en valeurs codées et ceux obtenus en valeurs réelles, le tableau 14 présente une synthèse récapitulative. Ce tableau met en évidence la correspondance directe entre les deux représentations du modèle

Tableau 16 Coefficients du modèle en valeurs réelles et codées

Coefficient	μ	a_1	a_2	a_{12}
Valeur codée	15.54	-0.0159	-0.0450	-0.0680
Valeur réelle	+15.36640	+7.20000	+0.254037	-10.07037

Le modèle mathématique correspondant à notre étude est donc le suivant :

$$Y = 15.36640 + 7.20000 \times A + 0.25404 \times B - 10.07037 \times A \times B \quad (\text{IV.2})$$

$$Y = 15.54 - 0.016 \times A - 0.045 \times B - 0.068 \times A \times B \quad (\text{IV.3})$$

C'est une fonction à deux variables avec :

- μ : effet moyen global (moyenne de toutes les réponses expérimentales),
- a_1, a_2 les coefficients des facteurs A et B ;
- a_{12} le coefficient des interactions d'ordre 2.

4.4. Validation statistique du modèle

4.4.1. Analyse de régression

L'examen des résidus accompagnant le modèle permettra de voir plus clairement la localisation de chaque point expérimental par rapport à sa valeur estimée. Nous avons déterminé à partir du modèle les réponses Y_i et on les a comparé avec celles obtenues en expérimentation, Les résultats sont représentés sur le tableau 15 montrant qu'effectivement le modèle proposé s'approche fortement du phénomène étudié. Les résidus sont les différences entre les valeurs Y_i réellement observées et celles qui sont fournies par l'équation de la régression.

D'après le tableau 15, on remarque bien que les résidus ont des valeurs nulles ce qui nous confirme l'adéquation de notre modèle

Tableau 17 Statistiques de la régression du modèle et analyse des résidu

	Run Order	Actual Value	Predicted Value	Residual
	1	15.63	15.63	0.0000
	2	15.58	15.58	0.0000
	3	15.53	15.53	0.0000
	4	15.41	15.41	0.0000

4.1.1. Coefficient de détermination R^2

Le coefficient de détermination R^2 mesure la proportion de la variance de la variable dépendante qui est expliquée par le modèle.

$$R^2 = 1 - \frac{SCE}{SCT} \quad (IV.4)$$

Où :

- SCE : est la somme des carrés des erreurs (aussi appelée somme des carrés résiduels),
- SCT : est la somme totale des carrés (mesure de la variance totale de la variable dépendante)

$$SCE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \text{ La somme des carrés résiduels (différence entre les valeurs}$$

observées y_i et les valeurs prédites \hat{y}_i)

$SCT = \sum_{i=1}^n (y_i - \bar{y})^2$ La somme totale des carrés (La différence entre les valeurs

observées y_i et la valeur moyennes des mesures \bar{y}) A partir du tableau 15 on a :

Valeurs observées $y = [15.63, 15.58, 15.53, 15.41]$

Valeurs prédites $\hat{y} = [15.63, 15.58, 15.53, 15.41]$

Donc la moyenne des valeurs observées \bar{y} est :

$$\bar{y} = \frac{15.63 + 15.58 + 15.53 + 15.41}{4} = \frac{62.15}{4} = 15.5375$$

La somme totale des carrés (SCT) est donnée par :

$$SCT = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (IV.5)$$

Calculons terme par terme :

$$(15.63 - 15.5375)^2 = (0.0925)^2 = 0.00855625$$

$$(15.58 - 15.5375)^2 = (0.0425)^2 = 0.00180625$$

$$(15.53 - 15.5375)^2 = (-0.0075)^2 = 0.00005625$$

$$(15.41 - 15.5375)^2 = (-0.1275)^2 = 0.01625625$$

Donc :

$$SCT = 0.00855625 + 0.00180625 + 0.00005625 + 0.01625625 = 0.026675$$

La somme des carrés résiduels (SCE) est :

$$SCE = \sum (y_i - \bar{y}_i)^2 = 0 \quad (IV.6)$$

Puisque $y_i = \bar{y}_i$ pour tous les points

Le coefficient de détermination R^2 vaut donc 1 selon l'équation IV.7 :

$$R^2 = 1 - \frac{0}{0.026675} = 1 \quad (IV.7)$$

4.1.1. Coefficient de détermination ajusté $R_{ajusté}^2$

$$R_{ajusté}^2 = 1 - \left(\frac{n-1}{n-p} \right) (1 - R^2)$$

Où :

Chapitre 4 **Réglage des paramètres des algorithmes génétiques pour l'optimisation des fermes éoliennes à l'aide de la méthode des plans d'expériences**

- R^2 : est le coefficient de détermination classique,
- $n=4$: est le nombre d'observations,
- $p=2$ est le nombre de facteurs du modèle.

Donc : $R^2_{ajusté} = 1$

On obtient alors ce tableau :

Tableau 18 Tableau d'évaluation de la performance du modèle

Critère	Valeur obtenue	Interprétation
R^2	1	Le modèle explique 100% de la variance
$R^2_{ajusté}$	1	Modèle toujours parfait même corrigé pour le nombre de paramètres
$RMSE$	0	Toutes les prédictions sont exactes sans aucune erreur

R^2 (Coefficient de détermination) : Cette valeur indique la proportion de la variation totale de la réponse expliquée par le modèle. Un $R^2=1$ indique que le modèle explique parfaitement les données expérimentales, c'est-à-dire que les valeurs ajustées correspondent exactement aux valeurs observées, sans aucune erreur résiduelle.

$R^2_{ajusté}$: Cette statistique ajuste la valeur de R^2 en tenant compte du nombre de paramètres du modèle. Elle évite une surestimation de la qualité du modèle lorsqu'on ajoute des variables explicatives. Ici, $R^2_{ajusté} = 1$ confirme que le modèle est parfaitement adapté aux données, sans effet de surajustement lié au nombre de facteurs.

$RMSE$ (Root Mean Square Error) : Il s'agit de l'écart-type des résidus, représentant l'erreur moyenne quadratique entre les valeurs observées et les valeurs prédites. Un $RMSE$ nul signifie que le modèle prédit parfaitement toutes les observations, sans aucune erreur.

Ces valeurs indiquent une précision élevée du modèle et une excellente adéquation aux données expérimentales, renforçant la validité du modèle pour l'optimisation des paramètres de l'algorithme génétique appliqué à l'optimisation du parc éolien.

Ainsi, la concordance parfaite entre les valeurs expérimentales et celles prédites par le modèle valide l'utilisation de ce modèle pour la mise au point et l'optimisation des paramètres d'AG dans le cadre de l'optimisation de l'emplacement des turbines dans un parc éolien.

4.4.2. Test de Fisher (ANOVA)

À partir des résultats obtenus :

La somme des carrés expliquée par le modèle (SCT) est de 0,026675, La somme des carrés résiduelle (SCE) est nulle, soit 0.

Les carrés moyens sont donc calculés comme suit :

$$CM_{\text{effet}} = \frac{SCT}{p-1} = \frac{0.026675}{1} = 0.026675 \quad (\text{IV.8})$$

$$CM_{\text{erreur}} = \frac{SCE}{n-p} = \frac{0}{2} = 0 \quad (\text{IV.9})$$

Le statistique de Fisher observé est donné par le rapport des carrés moyens :

$$F = \frac{CM_{\text{effet}}}{CM_{\text{erreur}}} \quad (\text{IV.10})$$

Le rapport $F_{\text{obs}} = \infty$ est supérieur à toute valeur critique lue dans les tables de Fisher, quel que soit le seuil de confiance choisi. Cela signifie que le modèle est parfaitement adéquat, car il reproduit exactement les données expérimentales : les valeurs prédites sont identiques aux valeurs observées, et les résidus sont nuls.

4.4.3. Intervalle de confiance

Afin d'évaluer la fiabilité des résultats expérimentaux, un intervalle de confiance à 95 % pour la moyenne de la réponse est estimé à partir de l'écart-type et du nombre d'observations. Cet intervalle fournit une plage dans laquelle la vraie valeur moyenne de la population a 95 % de chances de se situer.

Il est calculé à l'aide de la formule suivante :

$$CI_{95\%} = \bar{Y} \pm t_{\alpha/2, df} \times \left(\frac{s}{\sqrt{n}} \right) \quad (\text{IV.11})$$

Où :

- $\bar{Y} = 15.54$ (moyenne des réponses),
- $s = 0.0959$ (l'écart-type des réponses),
- $n = 4$ (le nombre d'observations),

- $t_{\alpha/2, df}$ est la valeur critique de la loi de Student pour un risque $\alpha/2 = 0.025$ and $df = n - 1 = 3$ degrés de liberté. Pour un intervalle de confiance à 95%, on a $t_{0.025, 3} \approx 3.182$.

En remplaçant les valeurs dans la formule de l'intervalle de confiance :

$$CI_{95\%} = 15.54 \pm 3.182 \times \left(\frac{0.09594}{\sqrt{4}} \right) \quad (IV.11a)$$

$$CI_{95\%} = 15.54 \pm 3.182 \times (0.04795) \quad (IV.11b)$$

$$CI_{95\%} = 15.54 \pm 0.1525 \quad (IV.11c)$$

Ainsi, l'intervalle de confiance à 95 % pour la moyenne de la réponse \bar{Y} est :

$$CI_{95\%} = [15.39; 15.69] \quad (IV.12)$$

Cela signifie que si l'expérience était répétée plusieurs fois, on s'attendrait à ce que la vraie moyenne des réponses Y se situe dans cet intervalle 95% du temps

4.5. Analyse des effets principaux et interactions

La Figure 25 met en évidence les effets principaux du taux de mutation (A) et du taux de croisement (B) sur la valeur de la fonction de fitness (Y). On observe que la pente négative associée au facteur B est plus marquée, ce qui indique que le taux de croisement exerce une influence plus importante sur la performance de l'optimisation que le taux de mutation.

Lorsque le taux de mutation passe de sa valeur la plus faible à sa valeur la plus élevée, la valeur de la fonction de fitness diminue légèrement, passant de 15,56 à 15,50, soit une variation modérée de 0,06. En revanche, une augmentation du taux de croisement entraîne une baisse plus significative de la valeur de fitness, qui passe de 15,60 à 15,45, soit une différence de 0,15.

Ces résultats suggèrent donc que le taux de croisement joue un rôle plus déterminant que le taux de mutation dans l'amélioration des performances de l'algorithme.

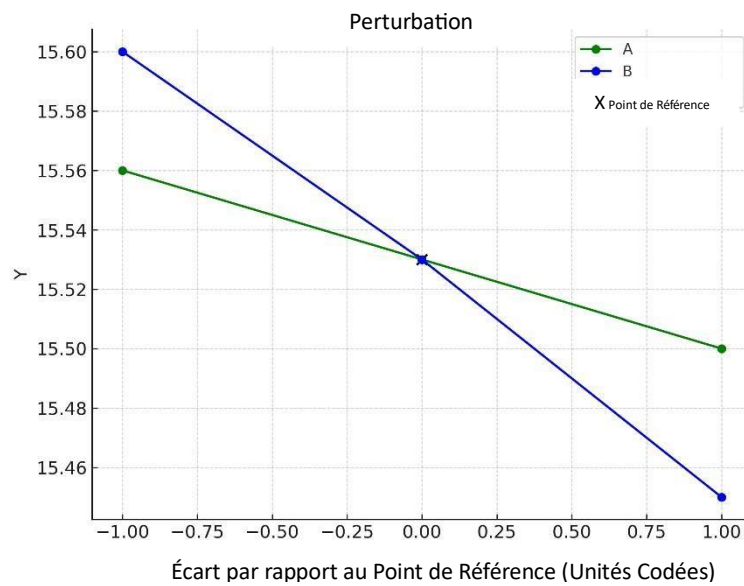


Figure 22 Effets principaux du taux de mutation (A) et du taux de croisement (B) sur la valeur de la fonction de fitness.

On observe une nette amélioration des performances lorsque le taux de croisement dépasse 0,75, ce qui se traduit par une diminution plus marquée de la valeur de fitness, atteignant environ 15,45 signes d'une optimisation plus efficace. En revanche, lorsque le taux de croisement est inférieur à ce seuil, les performances se dégradent progressivement, la valeur de fitness augmentant jusqu'à environ 15,60. Par ailleurs, le croisement des courbes présenté dans la figure 25 met en évidence une interaction significative entre les deux paramètres étudiés : le taux de mutation et le taux de croisement. Cela indique que l'effet du taux de mutation n'est pas constant, mais dépend du niveau du taux de croisement. Par conséquent, pour obtenir une configuration optimale, il est nécessaire d'ajuster ces deux paramètres de manière conjointe plutôt que de façon indépendante.

La figure 26 illustre l'effet d'interaction entre les deux paramètres étudiés. L'axe des abscisses représente les valeurs du taux de mutation (A), tandis que le taux de croisement (B) est visualisé à deux niveaux : un niveau bas (0,6) représenté par une ligne noire, et un niveau élevé (0,9) représenté par une ligne rouge.




Figure 23 Graphique de l'interaction des facteurs sur les performances de l'algorithme génétique

La variation du taux de croisement de 0,6 à 0,9 met en évidence son effet positif sur la fonction de fitness, tandis que l'impact moyen du taux de mutation apparaît moins marqué et dépend fortement du niveau de croisement, comme le montre la représentation graphique. En effet, lorsque le taux de croisement est faible (0,6), une augmentation du taux de mutation entraîne une dégradation des performances. À l'inverse, lorsque le taux de croisement est élevé (0,9), cette même augmentation améliore les performances de l'algorithme.

Cette interaction est particulièrement significative, car l'effet du paramètre A (mutation) s'inverse en fonction de la valeur prise par le paramètre B (croisement). Ces résultats montrent que le taux de croisement influence fortement l'impact du taux de mutation. Lorsque le croisement est faible, la diversité des solutions reste limitée, et une mutation excessive introduit un bruit perturbateur qui nuit à la convergence. En revanche, lorsque le croisement est élevé, il génère une diversité suffisante au sein de la population, permettant à la mutation de renforcer l'exploration de l'espace de recherche sans compromettre la stabilité de la convergence. C'est ce qui explique l'amélioration observée des performances dans ce cas.

À l'issue de l'analyse des résultats, Le modèle mathématique intégrant les effets principaux ainsi que leur interaction a déjà été déterminé dans la section précédente (Établissement du modèle mathématique). Il est rappelé ici sous sa forme codée, afin de faciliter l'interprétation des résultats graphiques :

$$Y = 15,54 - 0,016 * A - 0,045 * B - 0,068 * A * B$$

Dans cette équation, les coefficients associés aux termes A , B et AB représentent respectivement l'effet du taux de mutation, du taux de croisement, et de leur interaction sur la fonction de fitness. Plus un coefficient est élevé en valeur absolue, plus son influence sur la réponse est significative.

Pour mieux visualiser l'importance relative de ces effets, la figure 27 présente le diagramme de Pareto des effets standardisés. Ce graphique classe les facteurs du plus influent au moins influent, en fonction de leur poids dans le modèle. On y observe clairement que l'interaction AB constitue le facteur dominant, suivie par le taux de croisement B , tandis que le taux de mutation A a un effet plus modéré. Cette hiérarchisation confirme que l'optimisation conjointe des paramètres est plus efficace qu'un réglage individuel, et que le croisement joue un rôle central dans l'amélioration des performances de l'algorithme.

Le diagramme de Pareto des effets, présenté dans la figure 27, illustre l'importance relative des effets standardisés, classés du plus influent au moins influent selon les résultats de l'analyse.

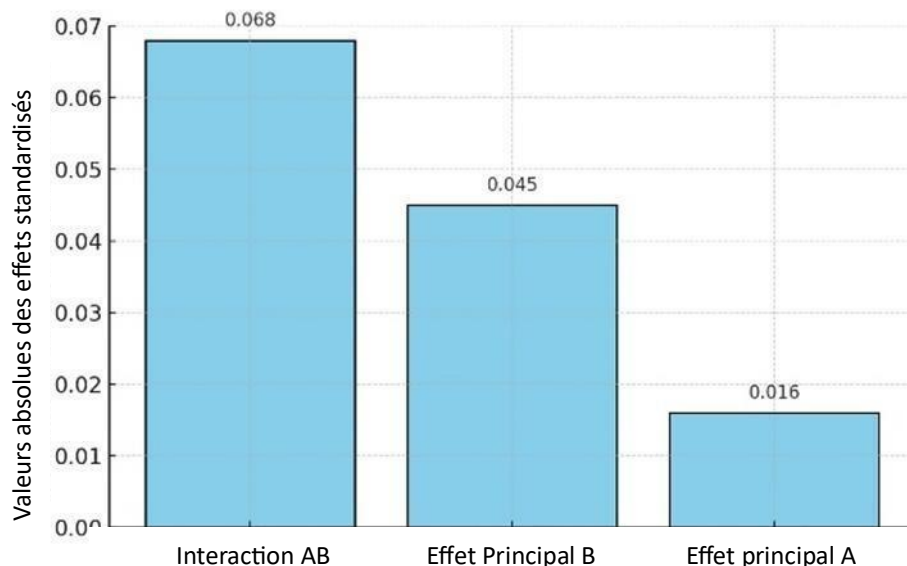


Figure 24 Diagramme de Pareto des effets standardisés.

Lorsque les deux paramètres A (mutation) et B (croisement) interagissent, l'effet d'interaction AB s'avère être le plus influent, avec une valeur de $(-0,068)$. L'effet principal

de A , relativement faible ($-0,016$), a un impact limité sur la réponse, tandis que l'effet principal de B ($-0,045$) montre une influence beaucoup plus marquée. Cette hiérarchisation des effets souligne l'importance de prendre en compte les interactions entre paramètres, plutôt que de les optimiser séparément.

L'optimisation conjointe des paramètres permet d'améliorer le fitness de 151,1 % par rapport à une optimisation individuelle du paramètre B , ce dernier ayant une influence plus notable sur la réponse que A . Cette analyse met ainsi en évidence la contribution significative de l'effet d'interaction et démontre que la prise en compte simultanée des deux facteurs permet d'atteindre des résultats plus performants et plus équilibrés.

L'analyse de la variance (ANOVA) confirme que les deux paramètres, le taux de croisement et le taux de mutation, influencent de manière significative les performances de l'algorithme génétique (AG). Elle met également en évidence une interaction forte entre ces deux facteurs, ce qui indique que l'efficacité du croisement dépend directement du niveau de mutation appliqué. Plus précisément, un faible taux de mutation limite l'efficacité du croisement, tandis que l'association d'un croisement élevé avec une mutation modérée conduit à de meilleures performances globales. Ce constat souligne l'importance d'un réglage systématique et conjoint des paramètres pour optimiser efficacement le fonctionnement de l'AG.

La figure 25 présente la carte de contours de la surface de réponse, illustrant l'effet des variations des taux de mutation (A) et de croisement (B) sur la valeur du fitness standardisée (Y) :

- Le minimum global est atteint pour $A = 0,1$ (taux de mutation) et $B = 0,9$ (taux de croisement), avec une valeur minimale de fitness de 15,4087.
- La zone optimale se situe dans le coin supérieur droit du domaine expérimental, ce qui indique que des taux de croisement élevés améliorent systématiquement les performances lorsqu'ils sont associés à une mutation modérée.
- La légère non-linéarité de la surface confirme l'existence d'un effet d'interaction entre les deux paramètres (AB), renforçant l'idée qu'ils doivent être optimisés conjointement, et non indépendamment.




Figure 25 Carte de contours de la réponse Y en fonction des paramètres

Contrairement aux approches fondées sur l'ajustement par essais et erreurs, notre méthodologie s'appuie sur un cadre rigoureux basé sur la méthode des plans d'expériences (DOE). Cette approche permet :

- Une sélection optimisée des paramètres, fondée sur des données expérimentales plutôt que sur des choix arbitraires,
- Une amélioration de la qualité des solutions obtenues grâce à un réglage systématique plutôt qu'empirique,
- Une efficacité accrue en termes de convergence, réduisant ainsi le coût computationnel inutile,
- Une meilleure reproductibilité, rendant le processus d'optimisation plus fiable et généralisable.

En adoptant les valeurs $A = 0,1$ pour le taux de mutation et $B = 0,9$ pour le taux de croisement, notre stratégie s'inscrit dans les plages de valeurs généralement reconnues dans la littérature, tout en les surpassant grâce à une optimisation guidée par les données, reproductible et plus efficace sur le plan computationnel.

4.6. Discussion des résultats

Grâce à l'application de la méthode des plans d'expériences, nous avons pu identifier un jeu de paramètres optimal, avec un taux de croisement $B = 0,9$ et un taux de mutation $A = 0,1$. Cette configuration permet une exploration plus ciblée de l'espace de recherche par l'algorithme génétique.

Comme l'illustre la figure 26, cette nouvelle configuration optimise l'utilisation de la surface du site en permettant l'installation d'un plus grand nombre de turbines, 31, contre 26 pour l'étude de Mosetti et 30 pour celle de Grady. Cette amélioration se traduit directement par une augmentation de la production énergétique.




Figure 26 Disposition des éoliennes sur le site

Le tableau 16 présente une synthèse comparative des résultats obtenus dans cette étude par rapport à ceux rapportés dans les travaux précédents [19] [73].

Tableau 19 Comparaison des résultats avec ceux issus de la littérature

Critère	Mosetti et al. [19]	Grady et al. [73]	Etude actuelle
Fitness	0.0016197	0.0015436	0.00154087
Puissance totale [kW/an]	12352	14310	14672
Nombre de turbine	26	30	31
Efficacité (%)	91.645	92.015	91.298
Génération de convergence	Non rapporté	1203	991

Le potentiel énergétique du site a été amélioré, comme en témoigne l'augmentation de la production, atteignant 14 672 kWh. Le coefficient de performance (fitness), évalué à 0,00154087 et défini comme le rapport entre le coût et la puissance installée, s'est également amélioré, ce qui traduit une solution plus rentable sur le plan technico-économique. Cette valeur confirme la fiabilité de notre approche pour optimiser l'implantation des turbines. De plus, la méthode proposée présente une convergence plus rapide, nécessitant moins de ressources informatiques pour parvenir à une solution optimale.

Cependant, une légère diminution de l'efficacité énergétique a été constatée par rapport aux expériences précédentes. Cette baisse peut s'expliquer par une densité plus élevée de turbines, susceptible d'entraîner des pertes d'énergie accrues liées aux effets d'interférence. Ce compromis entre l'efficacité énergétique et la réduction des coûts met en évidence les limites structurelles liées à l'optimisation de systèmes complexes. Malgré cette légère perte d'efficacité, les résultats comparatifs présentés dans le tableau 16 montrent que la réduction significative des coûts, l'augmentation de la production énergétique et la rapidité de convergence confirment la robustesse de cette stratégie hybride combinant les plans d'expériences et les algorithmes génétiques.

Cette étude constitue une avancée prometteuse dans le domaine de l'optimisation technico-économique des parcs éoliens, en proposant une méthode systématique de réglage des paramètres de l'algorithme génétique. Les perspectives futures pourraient viser à renforcer cette approche en l'adaptant à des problématiques plus larges liées à l'efficacité énergétique et en tenant compte de conditions de vent variées.

4.7. Généralisation à différentes vitesses de vent

Pour évaluer l'impact de la vitesse du vent sur les paramètres de croisement et de mutation, nous avons élargi l'étude initiale, réalisée à une vitesse de 12 m/s, à deux autres scénarios : 10 m/s et 17 m/s. Il est important de souligner que l'optimisation porte uniquement sur les paramètres de l'AG, et non sur la taille du parc : le nombre d'éoliennes reste donc constant à 31 pour toutes les vitesses de vent analysées.

L'objectif principal est de déterminer dans quelle mesure les paramètres optimaux de l'algorithme génétique (taux de croisement et de mutation) varient en fonction des conditions de vent, et si les tendances identifiées précédemment se maintiennent ou nécessitent des ajustements. Les combinaisons optimales ont été identifiées pour chaque scénario, et les

performances correspondantes, en termes de fitness et de production annuelle d'énergie sont résumées dans le tableau 17 :

Tableau 20 Optimisation des paramètres de l'AG en fonction de la vitesse du vent

Vitesse du vent (m/s)	P_c	P_m	Nombre de turbines	Energie annuelle (kWh/an)	Valeur de fitness
10	0.9	0.01	31	8831	0.00255993
12	0.9	0.1	31	14672	0.00154087
17	0.9	0.1	31	19607	0.00115303

L'analyse met en évidence que des vitesses de vent plus élevées entraînent une augmentation de la production énergétique annuelle, passant de 8 831 kWh/an à 10 m/s à 19 607 kWh/an à 17 m/s. Cette tendance confirme la relation directe entre la disponibilité du vent et l'efficacité de la production électrique. Par ailleurs, le taux de croisement optimal (P_c) reste constamment élevé à 0,9, quelle que soit la vitesse du vent, ce qui suggère qu'une plus grande diversité génétique favorise la convergence de l'algorithme et améliore la qualité des solutions obtenues.

En revanche, le taux de mutation optimal (P_m) varie selon les conditions de vent. À faible vitesse (10 m/s), une valeur plus basse (0,01) est plus efficace car elle limite l'introduction de bruit inutile dans la recherche. À des vitesses plus élevées (12 à 17 m/s), des taux de mutation plus élevés (0,1) se révèlent préférables pour aider l'algorithme à échapper aux optima locaux dans des environnements plus dynamiques. En parallèle, les valeurs de fitness diminuent avec l'augmentation de la vitesse du vent, de 0,00255993 à 10 m/s à 0,00115303 à 17 m/s, ce qui reflète une amélioration de l'efficacité de l'optimisation. Cette évolution suggère que des vitesses de vent plus élevées contribuent à une convergence plus stable et à de meilleures performances globales de l'AG.

Pour évaluer l'efficacité de notre approche d'optimisation combinant algorithme génétique et plan d'expériences (GA-DOE), une comparaison a été effectuée avec l'optimisation par essaim particulaire binaire (BPSO), en s'appuyant sur plusieurs indicateurs de performance clés. La configuration finale du parc éolien obtenue est présentée dans la

figure 27, et les résultats comparatifs sont résumés dans le tableau 18 [115]. Cette comparaison apporte des éléments d'analyse précieux sur la production énergétique, la valeur de fitness, l'efficacité, ainsi que la robustesse globale de chaque méthode, en mettant en lumière leurs avantages respectifs et leurs éventuelles limites.

Tableau 21 Comparaison entre BPSO et GA-DOE

Critère	BPSO [115]	Etude actuelle
Fitness	0.001544	0.00154087
Puissance totale (kwh/an)	14 310	14 672
Nombre de turbine	30	31
Efficacité (%)	92.01 %	91.29 %

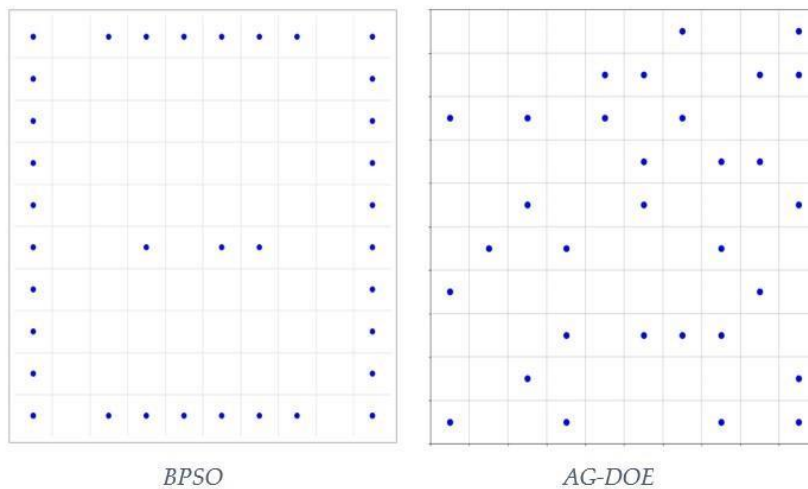


Tableau 22 Configuration du parc éolien selon les méthodes BPSO et GA-DOE [109]

La comparaison entre l'approche BPSO (Binary Particle Swarm Optimization) et la méthode GA-DOE (algorithme génétique optimisé par plan d'expériences) met en évidence des différences clés en termes d'efficacité, de production énergétique, de valeur de fitness et de capacité d'adaptation. Bien que la méthode BPSO atteigne une efficacité légèrement supérieure (92,01 % contre 91,29 % pour GA-DOE), cet écart s'explique principalement par l'utilisation d'un nombre réduit de turbines (30 contre 31). En revanche, GA-DOE génère une

production énergétique totale plus élevée, avec 14 672 kWh/an contre 14 310 kWh/an pour BPSO, soit une augmentation de +2,5 %. Ce résultat démontre une meilleure exploitation de l'espace disponible par GA-DOE, qui permet une disposition plus performante des éoliennes.

Par ailleurs, la valeur de fitness obtenue avec GA-DOE est plus avantageuse (0,00154087 contre 0,001544 pour BPSO). Une valeur de fitness plus faible traduit un meilleur rapport coût/puissance installée, ce qui signifie que l'approche GA-DOE alloue les ressources de manière plus optimale tout en maintenant un haut niveau de performance. Cela confirme l'intérêt du réglage systématique des paramètres basé sur les plans d'expériences, qui renforce l'efficacité globale de l'algorithme génétique.

L'un des principaux atouts de GA-DOE réside dans sa méthodologie rigoureuse de réglage des paramètres. Contrairement à BPSO, où les paramètres restent fixes tout au long de l'optimisation, GA-DOE s'appuie sur une structure expérimentale (DOE) pour ajuster dynamiquement les taux de croisement et de mutation. Cette stratégie permet :

- Une convergence plus fiable vers des solutions optimales,
- Une meilleure adaptabilité aux conditions de vent et aux configurations variables,
- Une robustesse accrue du processus d'optimisation, rendant la méthode applicable à un large éventail de scénarios.

Cela dit, le coût computationnel reste un aspect à prendre en compte, notamment pour les applications à grande échelle. Bien que le DOE améliore la vitesse et la précision de convergence, ses exigences en calcul peuvent limiter la montée en échelle. Il serait donc pertinent que de futurs travaux explorent des heuristiques adaptatives capables de réduire le nombre d'itérations tout en conservant l'efficacité de l'optimisation. Une telle amélioration rendrait l'approche GA-DOE plus scalable et donc mieux adaptée aux projets de parcs éoliens de grande envergure.

4.8. Conclusion

Ce chapitre a démontré la pertinence d'une approche rigoureuse de réglage des paramètres des algorithmes génétiques (AG) à l'aide de la méthode des plans d'expériences (DOE) appliquée à l'optimisation de l'agencement des turbines dans un parc éolien. Contrairement aux réglages empiriques classiquement employés dans la littérature, notre démarche systématique a permis de quantifier avec précision les effets principaux et les

interactions entre le taux de mutation et le taux de croisement, révélant notamment l'importance cruciale de leur optimisation conjointe.

L'analyse statistique approfondie (modélisation, ANOVA, test de Fisher, intervalle de confiance) a validé un modèle prédictif précis, dont la qualité a été confirmée par des indicateurs statistiques excellents ($R^2 = 1.0000$, $RMSE = 0.0000$). L'interprétation des effets a montré que le taux de croisement exerce un impact significatif sur la performance de l'AG, tandis que le taux de mutation, bien que moins influent seul, interagit fortement avec le croisement pour améliorer l'exploration de l'espace de recherche.

Les résultats expérimentaux obtenus ont surpassé ceux des travaux antérieurs (Mosetti, Grady) en termes de production énergétique et de configuration spatiale du parc. Par ailleurs, la méthode GA-DOE s'est montrée compétitive face à l'approche BPSO, avec une meilleure production énergétique et un meilleur compromis technicoéconomique, bien que légèrement moins efficace en pourcentage. L'étude a également confirmé la stabilité des paramètres optimaux à différentes vitesses de vent, soulignant la robustesse de l'approche proposée.

En conclusion, cette étude confirme l'intérêt de combiner l'algorithme génétique avec la méthodologie des plans d'expériences pour améliorer les performances d'optimisation des fermes éoliennes. Elle ouvre la voie à des recherches futures visant à adapter dynamiquement les paramètres des AG en fonction des conditions environnementales, à intégrer des contraintes économiques et environnementales plus complexes, et à rendre l'approche scalable pour de plus grands projets éoliens.

Conclusion générale

Conclusion générale

Dans un monde confronté à l'urgence climatique et à la nécessaire transition vers des systèmes énergétiques durables, l'énergie éolienne apparaît comme une solution incontournable. Toutefois, la maximisation de son rendement passe par une optimisation rigoureuse de l'agencement des turbines, un problème complexe en raison des effets aérodynamiques de sillage et des nombreuses contraintes technicoéconomiques. Cette thèse a apporté une contribution originale à cette problématique en proposant une approche hybride fondée sur l'utilisation des algorithmes génétiques (AG) combinés à la méthode des plans d'expériences (Design of Experiments – DOE).

Dans un premier temps, un état de l'art exhaustif a permis de situer les algorithmes bioinspirés, et notamment les AG, dans le contexte plus large des méthodes métaheuristiques appliquées à l'optimisation des fermes éoliennes. Ce panorama a mis en lumière les forces et limites des approches existantes, notamment en termes de convergence, de robustesse et de gestion de la complexité du problème d'agencement.

Le deuxième volet de cette thèse s'est consacré à la méthodologie des plans d'expériences, en particulier aux plans factoriels complets et fractionnaires. Ces outils statistiques ont été mobilisés pour structurer les campagnes de simulation, identifier les paramètres les plus influents des AG, et modéliser leurs effets sur les performances de l'optimisation.

Dans le troisième chapitre, un modèle d'optimisation basé sur les AG a été développé pour déterminer la configuration optimale d'un parc éolien. L'implémentation s'est appuyée sur une modélisation aérodynamique du sillage (modèle de Jensen), une structure chromosomique adaptée et des opérateurs génétiques soigneusement choisis. L'analyse des résultats a confirmé la capacité des AG à générer des solutions pertinentes surpassant celles issues des configurations classiques de la littérature (Mosetti, Grady).

Le quatrième chapitre a apporté une valeur ajoutée importante à travers l'application du DOE au réglage systématique des paramètres de l'AG. Grâce à un plan factoriel 2^2 , les effets principaux et les interactions du taux de croisement et du taux de mutation ont été analysés. Les résultats ont permis de dégager une combinaison optimale de paramètres assurant une convergence rapide, une production énergétique maximale et une meilleure stabilité.

Conclusion générale modèle statistique obtenu a été validé avec succès par une ANOVA, un test de Fisher et une analyse de régression, montrant un excellent ajustement avec un coefficient de détermination $R^2 = 1$ et une erreur quadratique moyenne $RMSE = 0$. Les résultats ont été arrondi à quatre chiffres après la virgule

L'approche GA-DOE a ensuite été testée sur différentes vitesses de vent, mettant en évidence sa robustesse et sa généralisable. De plus, une comparaison avec l'algorithme BPSO a démontré la compétitivité de l'approche proposée, tant en termes de production énergétique que de performance globale.

En conclusion, cette thèse a démontré que le couplage méthodologique entre intelligence artificielle (AG) et statistiques appliquées (DOE) permet d'atteindre un niveau supérieur de performance, de fiabilité et de rigueur scientifique dans l'optimisation des parcs éoliens. Elle ouvre également des perspectives intéressantes pour des recherches futures, notamment :

- L'adaptation dynamique des paramètres des AG en fonction des conditions de vent en temps réel ;
- L'intégration de contraintes économiques, environnementales et topographiques plus complexes ;
- L'extension à d'autres sources renouvelables ou à des systèmes hybrides ;
- L'exploitation de l'apprentissage automatique pour prédire les meilleures configurations initiales ou moduler l'algorithme en cours d'exécution

Références

- [1] R. Wade, «Properties of air: Wind resourcification via assetization in the republic of Ireland,» *Environment and Planning E: Nature and Space*, 2025.
- [2] M. F. Howland, S. K. Lele et O. John , «Wind farm power optimization through wake steering.,» *Proceedings of the National Academy of Sciences* , vol. 116, n° %129, pp. 1449514500, 2019.
- [3] G. Dong, J. Qin, C. Wu, C. Xu et X. Yang, «Reinforcement learning-enhanced genetic algorithm for wind farm layout optimization.,» 2024. [En ligne]. Available: <https://arxiv.org/abs/2412.06803>. [Accès le 22 Avril 2025].
- [4] J. Kennedy et R. Eberhart, «Particle swarm optimization.,» chez *Proceedings of ICNN'95international conference on neural networks*, 1995.
- [5] J. Meyers et C. Meneveau, «Optimal turbine spacing in fully developed wind farm boundary layers,» *Wind energy*, vol. 15, n° %12, pp. 305-317, 2012.
- [6] T. Burton, N. Jenkins, D. Sharpe et E. Bossanyi, *Wind energy handbook*, John Wiley & Sons, 2011.
- [7] D. A. SPERA , *Wind Turbine Technology: Fundamental Concepts of Wind Turbine Engineering*, A. Press, Éd., New York, 1994.
- [8] F. Abderrahmane, S. Bouslikhane et Z. Hajej, «OPTIMISATION CONJOINTE DE LA PLANIFICATION DE LA PRODUCTION D'ENERGIE, DE LA MAINTENANCE ET DES PIECES DE RECHANGE D'UN PARC EOLIEN,» chez *13ème CONFERENCE INTERNATIONALE DE MODELISATION, OPTIMISATION ET SIMULATION (MOSIM2020)*, AGADIR, Maroc, 12-14 NOVEMBRE 2020.
- [9] J. F. Manwell, J. G. McGowan et A. L. Rogers, *Wind Energy Explained: Theory, Design and Application*, John Wiley & Sons., 2010.
- [10] «CONNAISSANCE DES ÉNERGIES. Fiche pédagogique : Énergie éolienne,» [En ligne]. Available: <https://www.connaissancedesenergies.org/fiche-pedagogique/energie-eolienne>. [Accès le 20 juillet 2025].
- [11] P. Enevoldsen et S. V. Valentine, «Do onshore and offshore wind farm development patterns differ?,» *Energy for Sustainable Development*, vol. 35, pp. 41-51, 2016.
- [12] B. Pérez, R. Mínguez et R. Guanche, «Offshore wind farm layout optimization using mathematical programming techniques,» *Renewable Energy*, vol. 53, pp. 389-399, 2013.
- [13] Le Monde de l'Énergie, «Éolien offshore : les acteurs français entre innovation et exportation,» 2018.

- [14] R. Shakoor , M. Y. Hassan, A. Raheem et Y. K. Wu, «Wake effect modeling: A review of wind farm layout optimization using Jensen's model,» *Renewable and Sustainable Energy Reviews*, vol. 58, pp. 1048-1059, 2016.
- [15] «"Atlas Transmanche – Espace Manche : Face à face et côte à côte.",» [En ligne]. Available: <https://atlas-transmanche.certic.unicaen.fr/fr/page-445.html>. [Accès le 20 juillet 2025].
- [16] F. González-Longatt, P. Wall et V. Terzija, «Wake effect in wind farm performance: Steadystate and dynamic behavior,» *Renewable Energy*, vol. 39, n° %11, pp. 329-338, 2012.
- [17] Énergie Citoyenne en Combrailles, «Résultats des analyses des vents : nouvelles perspectives !».
- [18] M. B. Christiansen et C. B. Hasager, «Wake effects of large offshore wind farms identified from satellite SAR,» *Remote Sensing of Environment*, vol. 98, n° %12-3, pp. 251-268, 2005. [19] G. P. C. D. B. Mosetti, C. Poloni et B. Diviacco, «Optimization of wind turbine positioning in large windfarms by means of a genetic algorithm,» *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 51, n° %11, pp. 105-116, 1994.
- [20] B. Pérez, R. Mínguez et R. Guanche, «Offshore wind farm layout optimization using mathematical programming techniques,» *Renewable energy*, vol. 53, pp. 389-399, 2013. [21] J. F. Herbert-Acero, O. Probst et P. E. Réthoré, «A review of methodological approaches for the design and optimization of wind farms,» *Energies*, vol. 7, n° %111, pp. 6930-7016, 2014. [22] K. Yang et K. Cho, «Simulated annealing algorithm for wind farm layout optimization: A benchmark study,» *Energies*, vol. 12, n° %123, p. 4403, 2019.
- [23] M. Abdel-Basset, R. Mohamed, I. M. Hezam et A. Słowik, «Optimizing Wind farm layout using a one-by-one replacement mechanism-incorporated gradient-based optimizer.,» *Energy*, vol. 314, p. 134154, 2025.
- [24] S. Brusca., R. Lanzafame et M. Messina, «Wind turbine placement optimization by means of the Monte Carlo simulation method,» *Modelling and Simulation in Engineering.,* vol. 2014, n° %11, p. 760934, 2014.
- [25] L. Wang, J. Yuan, M. E. Cholette, y. Fu, y. Zhou et A. C. Tan, «Comparative study of discretization method and Monte Carlo method for wind farm layout optimization under Weibull distribution,» *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 180, pp. 148-155, 2018.
- [26] M. A. Javadi, H. Ghomashi, M. Taherinezhad, M. Nazarahari et R. Ghasemiasl, «Comparison of Monte Carlo simulation and genetic algorithm in optimal wind farm layout design in manjil site based on Jensen mode,» chez *7th Iran Wind Energy Conference (IWEC2021)*, 2021.

- [27] F. Bai, X. Ju, S. Wang, W. Zhou et F. Liu, «Wind farm layout optimization using adaptive evolutionary algorithm with Monte Carlo Tree Search reinforcement learning,» *Energy Conversion and Management*, vol. 252, p. 115047, 2022.
- [28] A. C. Cinar, «A review of 10× 10 and 20× 20 grid-type wind turbine placement problems solving by metaheuristics,» *Environmental Science and Pollution Research*, vol. 30, n° %15, pp. 1135911377, 2023.
- [29] D. Song, G. Shen, C. Huang, Q. Huang, J. Yang, M. Dong et N. Duić, «Review on the application of artificial intelligence methods in the control and design of offshore wind power systems,» *Journal of marine science and engineering*, vol. 12, n° %13, p. 424, 2024. [30] M. Bilbao et E. Alba, «GA and PSO applied to wind energy optimization,» chez *XV Congreso Argentino de Ciencias de la Computación.*, 2009.
- [31] A. Kusiak et Z. Song, «Design of wind farm layout for maximum wind energy capture,» *Renewable energy*, vol. 35, n° %13, pp. 685-694, 2010.
- [32] P. Asaah, I. Hao et J. Ji, «Optimal placement of wind turbines in wind farm layout using particle swarm optimization,» *Journal of Modern Power Systems and Clean Energy*, vol. 9, n° %12, pp. 367-375, 2021.
- [33] A. Bellat. et I. T. K. M. A. Raihani, «Optimization of Wind Farms by the Particle Swarm Algorithm Considering Gaussian Wake Model,» *International Journal on Technical and Physical Problems of Engineering (JITPE)*, vol. 48, n° %13, pp. 48-54, 2021.
- [34] J. Song, T. Kim et D. You, «Particle swarm optimization of a wind farm layout with active control of turbine yaws,» *Renewable Energy*, vol. 206, pp. 738-747, 2023.
- [35] Z. Lei, S. Gao, Z. Zhang, H. Yang et H. Li, «A chaotic local search-based particle swarm optimizer for large-scale complex wind farm layout optimization,» *IEEE/CAA Journal of Automatica Sinica*, vol. 10, n° %15, pp. 1168-1180, 2023.
- [36] S. Devabhaktuni, «Optimizing Wind Farm Layouts for Maximum Efficiency using PSO considering wake effect,» chez *2024 6th International Conference on Energy, Power and Environment (ICEPE)*, 2024.
- [37] U. Sultana, A. B. Khairuddin, A. S. Mokhtar, N. Zareen et B. Sultana, «Grey wolf optimizer based placement and sizing of multiple distributed generation in the distribution system,» *Energy*, vol. 111, pp. 525-536, 2016.
- [38] M. M. Tumari , M. H. Suid et M. A. Ahmad, «A modified grey wolf optimizer for improving wind plant energy production,» *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 18, n° %13, pp. 1123-1129, 2020.
- [39] M. Z. M. Tumari, M. M. Zahar et M. A. Ahmad, «Optimal tuning of a wind plant energy production based on improved grey wolf optimizer,» *Bulletin of Electrical Engineering and Informatics*, vol. 10, n° %11, pp. 23-30, 2021.

- [40] X. Huang, Z. Wang, C. Li et M. Zhang, «A low-complexity evolutionary algorithm for wind farm layout optimization,» *Energy Reports*, vol. 9, pp. 5752-5761, 2023.
- [41] N. A. Mohamed, H. M. Hasanien, E. A. Al-Ammar, M. Tostado-Véliz, R. A. Turkey, F. Jurado et A. O. Badr, «Gorilla tropical optimization algorithm solution for performance enhancement of offshore wind farm,» *ET Generation, Transmission & Distribution*, vol. 17, n° %110, pp. 23882400, 2023.
- [42] A. Gani, K. Mohammadi, S. Shamshirband, T. A. Altameem, D. Petković et S. Ch, «A combined method to estimate wind speed distribution based on integrating the support vector machine with firefly algorithm,» *Environmental Progress & Sustainable Energy*, vol. 35, n° %13, pp. 867875, 2016.
- [43] R. I. Putri, I. Mahmudi, M. Pujiantara, A. Priyadi, T. Taufik et M. H. Purnomo, «Modified Firefly Algorithm for Improved Maximum Power Extraction on Wind Energy Conversion System,» *International Journal of Renewable Energy Research (IJRER)*, vol. 8, n° %13, pp. 12081216, 2018.
- [44] A. S. Alghamdi, «A hybrid firefly–JAYA algorithm for the optimal power flow problem considering wind and solar power generations,» *Applied Sciences*, vol. 12, n° %114, p. 7193, 2022.
- [45] R. Zhang et X. Zheng, «Short-term wind power prediction based on the combination of firefly optimization and LSTM,» *Advanced Control for Applications: Engineering and Industrial Systems*, vol. 6, n° %12, p. e161, 2024.
- [46] S. Rehman, S. S. Ali et S. A. Khan, «Wind farm layout design using cuckoo search algorithms,» *Applied Artificial Intelligence*, vol. 30, n° %110, pp. 899-922, 2016.
- [47] M. Mohandes, S. A. Khan, S. Rehman, A. Al-Shaikhi, B. Liu et K. Iqbal, «A Preliminary Analysis of Different Grid Sizes for Wind Farm Micrositing Using an Evolutionary Algorithm for Turaif, Saudi Arabia,» chez *2024 6th International Symposium on Advanced Electrical and Communication Technologies (ISAECT)*, 2024.
- [48] M. Kumar , A. Sharma, N. Sharma et F. B. Sharma, «Wind Farm Layout Optimization Problem Using Nature-Inspired Algorithms,» *Journal of Electrical and Computer Engineering*, vol. 2024, n° %11, p. 9406519, 2024.
- [49] Y. Wang, H. Liu, H. Long, Z. Zhang et S. Yang, «Differential evolution with a new encoding mechanism for optimizing wind farm layout,» *IEEE Transactions on Industrial Informatics*, vol. 14, n° %13, pp. 1040-1054, 2017.
- [50] L. Chen, H. Li. et Y. Shen, «A Differential Evolution Algorithm for Wind Farm Layout Optimization Using a New Bilevel Programming Mode,» chez *etic and Evolutionary*

Computing: Proceedings of the Fourteenth International Conference on Genetic and Evolutionary Computing, Jilin, China, 2022.

- [51] X. Yu et Y. Lu, «Reinforcement learning-based multi-objective differential evolution for wind farm layout optimization,» *Energy*, vol. 284, p. 129300, 2023.
- [52] E. Song, «A bi-level optimization model and improved algorithm for wind farm layout,» *IET Renewable Power Generation*, vol. 18, n° %113, pp. 2017-2033, 2024.
- [53] S. Tao, S. Liu , R. Zhao, Y. Yang, H. Todo et H. Yang, «A State-of-the-Art Fractional OrderDriven Differential Evolution for Wind Farm Layout Optimization,» *Mathematics*, vol. 13, n° %12, p. 282, 2025.
- [54] A. Fathy et O. El-Baksawi, «Osama. Grasshopper optimization algorithm for extracting maximum power from wind turbine installed in Al-Jouf region,» *Journal of Renewable and Sustainable Energy*, vol. 11, n° %13, 2019.
- [55] Y. Meraihi, A. B. Gabis, S. Mirjalili et A. Ramdan-Cherif, «Grasshopper optimization algorithm: theory, variants, and applications,» *Ieee Access*, vol. 9, pp. 50001-50024, 2021.
- [56] A. Fathy, H. Rezk, D. Yousri, T. Kandil et A. G. Abo-Khalil, «Real-time bald eagle search approach for tracking the maximum generated power of wind energy conversion system,» *Energy*, vol. 249, p. 123661, 2022.
- [57] K. D. Nguyen, T. T. Tran et D. N. Vo, «Optimizing turbine location in upgraded wind farm using grasshopper optimization algorithm,» *Bulletin of Electrical Engineering and Informatics*, 2025.
- [58] H. Sebaa, K. R. Guerriche et T. Bouktir, «Optimal sizing and placement of renewable energy source in large scale power system using ABC technique in presence of UPFC,» chez *2014 International Renewable and Sustainable Energy Conference (IRSEC)*, 2014.
- [59] J. Patel, V. Savsani, V. Patel et R. Patel, «An unrestricted placement of wind turbines toward maximizing the energy output using teacher-artificial bee colony algorithm,» chez *Advances in Smart Grid and Renewable Energy: Proceedings of ETAEERE-2016*, 2018.
- [60] N. Sharma, H. Sharma, A. Sharma et J. C. Bansal, «A new effective solution for wind farm layout optimisation problem using self-sacrificing artificial bee colony algorithm,» *International Journal of Renewable Energy Technology*, vol. 13, n° %14, pp. 396-442, 2022.
- [61] I. Celik, C. Yildiz et M. Sekkeli, «Implementation of realistic wind farm layout optimization using artificial bee colony algorithm,» *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, vol. 44, n° %13, pp. 7253-7268, 2022.
- [62] S. Pranupa, A. T. Sriram et S. Nagaraja Rao, «A review of wind farm layout optimization techniques for optimal placement of wind turbines,» *Int J Renew Energy Res*, vol. 13, pp. 95765, 2023.

- [63] K. K. Kumar et G. N. Reddy, «he sparrow search algorithm for optimum position of wind turbine on a wind farm,» *nternational Journal of Renewable Energy Research (IJRER)*, vol. 11, p. 4, 2021.
- [64] F. Daqaq, R. Ellaia, M. Ouassaid et H. M. Zawbaa, «Enhanced chaotic manta ray foraging algorithm for function optimization and optimal wind farm layout problem,» *IEEE Access*, vol. 10, pp. 78345-78369, 2022.
- [65] S. Pranupa, A. T. Sriram et S. Nagaraja Rao, «Wind farm layout optimization approach using bio-inspired meta-heuristic algorithm to minimize wake effect,» *International Journal of Dynamics and Control*, vol. 12, n° %12, pp. 531-550, 2024.
- [66] Y. Zhu, Y. Guo, T. Hu, C. Wu et L. Zhang, «Wind Farm Layout Optimization Based on Dynamic Opposite Learning-Enhanced Sparrow Search Algorithm,» *International Journal of Energy Research*, vol. 2024, n° %11, p. 4322211, 2024.
- [67] Y. Eroğlu et S. U. Seçkiner, «Design of wind farm layout using ant colony algorithm,» *Renewable Energy*, vol. 44, pp. 53-62, 2019.
- [68] P. Makhampom, J. Waewsak et C. Chancham, «Optimal Wind Power Plant Layout Using Ant Colony Optimization,» *ASEAN Journal of Scientific and Technological Reports*, vol. 27, n° %11, pp. 44-57, 2024.
- [69] J. Patel, V. Savsani et R. Patel, «Maximizing energy output of a wind farm using teaching–learning-based optimization,» chez *Proceedings of the ASME 2015 9th International Conference on Energy Sustainability*, 2015.
- [70] J. Patel, V. Savsani, V. Patel et R. Patel, «Layout optimization of a wind farm to maximize the power output using enhanced teaching learning based optimization technique.,» *Journal of Cleaner Production*, vol. 158, pp. 81-94, 2017.
- [71] M. N. Hussain, N. Shaukat, A. Ahmad, M. Abid, A. Hashmi, Z. Rajabi et M. A. U. R. ariq, «Micrositing of wind turbines in an optimal wind farm area using teaching–learning-based optimization technique,» *Sustainability*, vol. 14, n° %114, p. 8846, 2022.
- [72] M. Kumar et A. Sharma, «Wind Farm Layout Optimization Problem Using Teaching–LearningBased Optimization Algorithm,» chez *International Conference on Communication and Intelligent Systems*, Singapore, 2022.
- [73] S. A. Grady, M. Y. Hussaini et M. M. Abdullah, «Placement of wind turbines using genetic algorithms,» *Renewable energy*, vol. 32, n° %12, pp. 259-270, 2005.
- [74] H. S. Huang, «Distributed genetic algorithm for optimization of wind farm annual profits,» chez *2007 International Conference on Intelligent Systems Applications to Power Systems*, 2007.

- [75] C. Elkinton , J. Manwell et J. McGowan, «Offshore wind farm layout optimization (OWFLO) project: Preliminary results,» chez *44th AIAA aerospace sciences meeting and exhibit*, 2006.
- [76] C. N. Elkinton, J. F. Manwell et J. G. McGowan, «Algorithms for offshore wind farm layout optimization,» *Wind engineering*, vol. 32, n° %11, pp. 67-84, 2008.
- [77] J. S. González, M. B. Payán, J. M. R. Santos et F. González-Longatt, «A review and recent developments in the optimal wind-turbine micro-siting problem.,» *Renewable and Sustainable Energy Reviews*, vol. 30, pp. 133-144, 2014.
- [78] A. Kusiak et Z. Song, «Design of wind farm layout for maximum wind energy capture,» *Renewable energy*, vol. 35, n° %13, pp. 685-694, 2010.
- [79] P. E. Réthoré, P. Fuglsang, G. C. Larsen, T. Buhl, T. J. Larsen et H. A. Madsen, «TOPFARM: Multifidelity optimization of wind farms,» *Wind Energy*, vol. 17, n° %112, pp. 1797-1816, 2014.
- [80] W. Yin Kwong, P. Yun Zhang et D. Romero, «Multi-objective wind farm layout optimization considering energy generation and noise propagation with NSGA-II,» *Journal of Mechanical Design*, vol. 136, n° %19, p. 091010, 2014.
- [81] F. Liu, X. Ju, N. Wang, L. Wang et W. J. Lee, «Wind farm macro-siting optimization with insightful bi-criteria identification and relocation mechanism in genetic algorithm,» *Energy Conversion and Management*, vol. 217, p. 112964, 1 August 2020.
- [82] R. Asfour, T. Brahimi et M. F. El-Amin, «Wind farm layout: Modeling and optimization using genetic algorithm,» chez *IOP Conference Series: Earth and Environmental Science*, 2022.
- [83] T. A. Qureshi et V. Warudkar, «Wind farm layout optimization through optimal wind turbine placement using a hybrid particle swarm optimization and genetic algorithm,» *Environmental Science and Pollution Research*, vol. 30, n° %131, pp. 77436-77452, 2023.
- [84] J. Holland, *Adaptation in artificial and natural systems*. Ann Arbor, vol. 232, The University of Michigan Press, 1975.
- [85] D. E. Goldberg, *Genetic Algorithm in Search, Optimization and Machine Learning*, Addison, vol. 1, W esley Publishing Company, Reading, MA, 1989, p. 9.
- [86] M. Mitchell, *An introduction to genetic algorithms*, MIT press, 1998.
- [87] T. Bäck, A. E. Eiben et N. A. van der Vaart, «An emperical study on GAs “without parameters”,» chez *Parallel Problem Solving from Nature – PPSN VI, 6th International Conference, Paris, France, September 18–20, 2000, Proceedings*.
- [88] A. E. Eiben et J. E. Smith, *Genetic algorithms. Introduction to Evolutionary Computing*, B. H. Springer, Éd., 2003, pp. 37-69.
- [89] A. E. Eiben et J. E. Smith, *Introduction to evolutionary computing*, Springer, Éd., 2003.
- [90] M. Mitchell, *An introduction to genetic algorithms*, MIT press, 1998.

- [91] K. A. De Jong et J. Sarma, «On Decentralizing Selection Algorithms,» chez *ICGA*, 1995.
- [92] F. Gillon, *MODELISATION ET OPTIMISATION PAR PLANS D'EXPERIENCES D'UN MOTEUR A COMMUTATIONS ELECTRONIQUES.*, Université des Sciences et Technologie de Lille-Lille I, 1997.
- [93] R. A. Fisher, «The design of experiments (Oliver and Boyd, Edinburgh),» *Journal of Econometrics*, vol. 395, p. 39, 1935.
- [94] G. Taguchi, *Introduction to quality engineering: designing quality into products and processes*, 1986.
- [95] D. C. Montgomery, *Design and analysis of experiments*, John Wiley & sons, 2017. [96] G. E. Box, J. S. Hunter et W. G. Hunter, *Statistics for experimenters*. In *Wiley series in probability and statistics*, Hoboken, NJ: Wiley, 2005.
- [97] S. VIVIER, *Stratégies d'optimisation par la méthode des plans d'expériences et Application aux dispositifs électrotechniques modélisés par éléments finis*, Université des Sciences et Technologies de Lille, 2002.
- [98] G. J. Tchein, «Étude des couplages thermomécaniques et microstructuraux d'un alliage de titane au cours du soudage FSW,» Université de Bordeaux, 2018.
- [99] C. M. Hsieh, T. L. Yang, A. D. Putri et C. T. Chen, «Application of design of experiments in the development of self-microemulsifying drug delivery systems,» *Pharmaceuticals*, vol. 16, n° 12, p. 283, 2023.
- [100] A. C. C. I. Serrano, M. C. Viana, N. V. Pinto, E. B. Lages, G. Carneiro et G. S. M. Borges, «The Use of Design of Experiments (DoE) Approaches for the Development of Self-Emulsifying Drug Delivery Systems (SEDDS),» *Applied Nano*, vol. 6, n° 11, p. 4, 2025.
- [101] M. S. DAAS, *Plans d'expériences*, Université Frères Mentouri - Constantine 1, 2020.
- [102] J. FAUCHER, *Les plans d'expériences pour le réglage de commandes à base de logique floue*, L'INSTITUT NATIONAL POLYTECHNIQUE DE TOULOUSE, 2006.
- [103] F. Husson, *Planification expérimentale*, UP mathématiques appliquées Agrocampus Rennes.
- [104] F. Bertrand, *Plans factoriels complets, plans fractionnaires cas des facteurs ayant deux modalités*, IRMA, Université de Strasbourg, France, 2018.
- [105] A. S. O. Ogunjuyigbe, T. R. Ayodele, O. D. Bamgboje et A. A. Jimoh, «Optimal placement of wind turbines within a wind farm using genetic algorithm,» chez *17th International Renewable Energy Congress*, Hammamet, Tunisia, 2016.
- [106] K. Yang, «Determining an Appropriate Parameter of Analytical Wake Models for Energy Capture and Layout Optimization on Wind Farms,» *Energies*, vol. 13, n° 13, p. 739, 2020.

- [107] I. Katic, J. Højstrup et N. O. Jensen, «A simple model for cluster efficiency,» chez *European wind energy association conference and exhibition*, 1987.
- [108] A. Bellat, I. Tyass, K. Mansouri et A. Raihani, «New approach to optimize the cost and interconnections of wind turbines using the PSO algorithm,» chez *E3S Web of Conferences*, 2022.
- [109] W. El Mestari, N. Cheggaga, F. Adli, A. Benallal et A. Ilinca, «Tuning parameters of genetic algorithms for wind farm optimization using the design of experiments method,» *Sustainability*, vol. 17, n° 17, p. 3011, 2025.
- [110] A. S. O. Ogunjuyigbe, T. R. Ayodele et O. D. Bamgboje, «Optimal placement of wind turbines within a wind farm considering multi-directional wind speed using two-stage genetic algorithm,» *Frontiers in Energy*, vol. 15, n° 11, pp. 240-255, 2021.
- [111] E. Hau et H. Renouard, *Wind turbines: fundamentals, technologies, application, economics*, vol. 2, Berlin: Springer, 2006.
- [112] L. J. Vermeer, J. N. Sørensen et A. Crespo, «Wind turbine wake aerodynamics,» *Progress in aerospace sciences*, vol. 39, n° 16-7, pp. 467-510, 2003.
- [113] E. Mahmoodi, M. Khezri, A. Ebrahimi, U. Ritschel, L. P. Chamorro et A. Khanjari, «A simple model for wake-induced aerodynamic interaction of wind turbines,» *Energies*, vol. 16, n° 15, p. 5710, 2023.
- [114] European Commission, *Wind energy developments and Natura 2000: Guidance document*, Publications Office of the European Union.
- [115] S. Pookpant et W. Ongsakul, «Design of optimal wind farm configuration using a binary particle swarm optimization at Huasai district, Southern Thailand,» *Energy conversion and management*, vol. 108, pp. 160-180, 2016.