



DOCTORAL THESIS

3rd Cycle Doctoral (D-LMD)

Presented by

DJERIBIE Soufiane

With a view to obtaining the doctoral diploma in 3rd Cycle Doctoral (D-LMD)

Branch: Automatic

Specialty: Diagnostic Industriel

Topic

**Modeling, Prediction and Diagnosis of Gas Turbine Performance Based on
Deterministic and Intelligent Methods**

Supported, on/....../ 2026, before the jury composed of:

Last and first name	Grade	Institution of affiliation	Designation
GUESMI Kamel	Professor	Djelfa University	President
BESSISSA Lakhdar	Professor	Djelfa University	Supervisor
HAFAIFA Ahmed	Professor	Djelfa University	Co-Supervisor
KEZRANE Cheikh	Professor	Djelfa University	Examiner
BOUKEZZI Larbi	Professor	Djelfa University	Examiner
DOUARA Abdelmalek	MCA	Tissemsilt University	Examiner



THESE DE DOCTORAT

Doctorat 3^{ème} Cycle (D-LMD)

Présentée par

DJERIBIE Soufiane

En vue de l'obtention du diplôme de Docteur en 3^{ème} Cycle D-LMD

Filière : Automatique

Spécialité : Diagnostic Industriel

Thème

**Modélisation, prédiction et diagnostic des performances d'une turbine à gaz à base
des méthodes déterministes et intelligentes**

Soutenue publiquement, le / / 2026, devant le jury composé de :

Nom et Prénom	Grade	Etablissement de rattachement	Désignation
GUESMI Kamel	Professeur	Université de Djelfa	Président
BESSISSA Lakhdar	Professeur	Université de Djelfa	Directeur de Thèse
HAFAIFA Ahmed	Professeur	Université de Djelfa	Co Directeur de Thèse
KEZRANE Cheikh	Professeur	Université de Djelfa	Examineur
BOUKEZZI Larbi	Professeur	Université de Djelfa	Examineur
DOUARA Abdelmalek	MCA	Université de Tissemsilt	Examineur

Remerciements

Avant tout, je remercie Allah, le Tout-Puissant, le Très Miséricordieux, de m'avoir donné la force, la patience et le courage nécessaires pour mener à bien ce travail de recherche.

Je tiens à exprimer ma profonde gratitude et mes sincères remerciements à Monsieur BESSISSA Lakhdar, mon directeur de thèse, pour son encadrement rigoureux, ses conseils avisés et son soutien constant tout au long de ce travail. Sa disponibilité, son expertise scientifique et ses encouragements ont été déterminants pour la réalisation de cette recherche. Qu'il trouve ici l'expression de ma reconnaissance et de mon profond respect.

Je remercie également Monsieur HAFAlFA Ahmed, mon co-encadreur, pour son accompagnement scientifique, ses orientations précieuses et sa contribution significative à l'enrichissement de ce travail. Ses remarques pertinentes et son expérience m'ont permis d'approfondir ma réflexion et d'améliorer la qualité de mes résultats.

Je remercie tout particulièrement Monsieur le Professeur GUESMI Kamel (Université de Djelfa), Président du jury, Monsieur le Professeur KEZRANE Cheikh (Université de Djelfa) Examineurs, et Monsieur le Professeur BOUKEZZIL Larbi (Université de Djelfa) Examineurs, pour leur disponibilité, leurs remarques pertinentes et l'intérêt accordé à cette recherche pour avoir accepté de présider cette soutenance et pour l'attention portée à l'examen de ce manuscrit.

J'adresse également mes sincères remerciements à Monsieur DOUARA Abdelmalek, Maître de conférences (A) (Université de Tissemsilt), Examineur, pour avoir accepté d'évaluer cette thèse et pour sa contribution scientifique à travers ses observations et suggestions.

Je remercie aussi Monsieur KORICH Belkacem, Maître de conférences (A) (Université de Djelfa), Invité, pour sa présence et l'intérêt porté à cette soutenance.

Mes remerciements les plus chaleureux vont à ma famille, pilier indéfectible de mon parcours. Je remercie particulièrement mes parents pour leur amour inconditionnel, leurs sacrifices, leurs prières et leur soutien moral durant ma vie.

Enfin, je remercie sincèrement tous mes amis pour leur présence, leur soutien moral. Leur amitié et leurs encouragements ont été une source précieuse de motivation tout au long de ce parcours doctoral.

À tous ceux qui ont contribué, de près ou de loin, à la réalisation de ce travail, je vous exprime ma profonde reconnaissance.

Dédicace

À ma famille et tous mes amis;

المخلص :

تحتل التوربينات الغازية (TAG) مكانة استراتيجية في إنتاج الطاقة الكهربائية وصناعة المحركات، غير أن أدائها يبقى شديد الحساسية للظروف المناخية وظواهر التدهور التدريجي، لا سيما تلوث الضاغط (المكثف) الذي يتسبب في أكثر من 70% من خسائر المردود. يقترح هذا العمل البحثي إطاراً منهجياً شاملاً يجمع بين النماذج الحسابية الكلاسيكية والنماذج الذكية لنمذجة والتنبؤ وتشخيص أداء توربين غازي صناعي من طراز MS5002B، يقع في منطقة حاسي الرمل بالجزائر، اعتماداً على بيانات تجريبية جمعت على مدى إثني عشر شهراً من التشغيل. تم أولاً تطوير نموذج إحصائي قائم على تصاميم التجارب (DoE)، حقق هذا النموذج معامل تحديد R^2 قيمته 0.9999. في موازاة ذلك، تم تحسين النمذجة بالشبكات العصبية الاصطناعية العميقة باستخدام خوارزميات ميتاهيورستيك متعددة الأهداف (MOGWO) و (SBOA) و (SHO) بهدف توليد جبهة باريتو توازن بين دقة التنبؤ والتكلفة الحسابية، وذلك بمعامل تحديد R^2 قيمته 0.999998، وهو أدق مقارنة بالنموذج (DoE)، كما تم دمج قيود فيزيائية ترموديناميكية في عملية التدريب لضمان تناسق التنبؤات. توفر النماذج المتحصل عليها، ولا سيما بنية خفيفة تم تحديدها بواسطة خوارزمية SBOA، أدوات موثوقة للمراقبة في الزمن الحقيقي، والصيانة التنبؤية، والكشف المبكر عن الأعطال، مما يساهم في تحسين الكفاءة الطاقوية للتوربين.

الكلمات المفتاحية : التوربين الغازي، النمذجة حتمية، الذكاء الاصطناعي، الشبكات العصبية العميقة، التحسين المتعدد الأهداف، التنبؤ، التشخيص، المردود الطاقوي.

Abstract :

Gas turbines (GTs) occupy a strategic position in electrical power generation and the hydrocarbon industry, yet their performance remains highly sensitive to climatic conditions and progressive degradation phenomena, particularly compressor fouling, which is responsible for more than 70% of efficiency losses. This thesis proposes a comprehensive methodological framework combining classical deterministic approaches with intelligent approaches for the modeling, prediction, and diagnosis of the performance of an industrial MS5002B gas turbine located in the Hassi R'mel region of Algeria, based on experimental data collected over twelve months of operation. A statistical model based on Design of Experiments (DoE) was first developed, achieving a coefficient of determination R^2 of 0.9999. In parallel, deep artificial neural networks were optimized using multi-objective metaheuristic algorithms (MOGWO, SBOA, and SHO) to generate a Pareto front balancing predictive accuracy and computational cost, achieving a coefficient of determination R^2 of 0.999998, more accurate than the DoE-based approach. Thermodynamic physical constraints were incorporated into the learning process to ensure the consistency of the predictions. The resulting models, particularly a lightweight architecture identified by SBOA, provide robust tools for real-time monitoring, predictive maintenance, and early anomaly detection, thereby contributing to the energy efficiency of the turbine.

Keywords : Gas turbine, deterministic modeling, artificial intelligence, deep neural networks, multi-objective optimization, prediction, diagnosis, energy efficiency.

Résumé :

Les turbines à gaz (TAG) occupent une place stratégique dans la production d'énergie électrique et l'industrie des hydrocarbures, mais leurs performances demeurent fortement sensibles aux conditions climatiques et à des phénomènes de dégradation progressive, notamment l'encrassement du compresseur, responsable de plus de 70% des pertes de rendement. Ce travail de thèse propose un cadre méthodologique complet combinant des approches déterministes classiques et des approches intelligentes pour la modélisation, la prédiction et le diagnostic des performances d'une turbine à gaz industrielle MS5002B sis à la région de Hassi R'mel en Algérie, à partir de données expérimentales collectées sur douze mois de fonctionnement. Un modèle statistique basé sur les Plans d'Expériences a d'abord été développé, atteignant un coefficient de détermination R^2 de 0,9999. En parallèle, des réseaux de neurones artificiels profonds ont été optimisés par des algorithmes métaheuristiques multi-objectifs (MOGWO, SBOA et SHO) afin de générer un front de Pareto équilibrant précision prédictive et coût computationnel, avec un coefficient de détermination R^2 de 0,999998 plus précis par rapport l'approche à base du plan d'expériences DoE. Des contraintes physiques thermodynamiques ont été intégrées à l'apprentissage pour garantir la cohérence des prédictions. Les modèles obtenus, notamment une architecture légère identifiée par SBOA, offrent des outils robustes pour la surveillance en temps réel, la maintenance prédictive et la détection précoce d'anomalies, contribuant ainsi à l'efficacité énergétique de la turbine.

Mots-clés : Turbine à gaz, modélisation déterministe, intelligence artificielle, réseaux de neurones profonds, optimisation multi-objectifs, prédiction, diagnostic, rendement énergétique.

Nomenclature

Symbole	Désignation
$\vec{A}$	Vecteur coefficient d'encerclement (GWO)
$\vec{B}$	Vecteur coefficient (SHO)
$\vec{C}$	Vecteur coefficient aléatoire
CF	Facteur de convergence (SBOA)
cp	Chaleur spécifique à pression constante
$\vec{D}$	Vecteur distance
$\vec{E}$	Vecteur coefficient (SHO)
f	Rapport carburant/air
F	Poussée
h	Paramètre de contrôle (SHO)
H	Enthalpie
J	Fonction de coût
$\dot{m}$	Débit massique
N	Nombre d'hyènes dans le cluster
P	Puissance / Pression
PCI	Pouvoir calorifique inférieur
Q	Chaleur / Énergie thermique
R^2	Coefficient de détermination
RMSE	Racine de l'erreur quadratique moyenne
SFC	Consommation spécifique de carburant
T	Température
W	Matrice de poids (réseau neuronal)
x	Vecteur d'entrée / Variable indépendante
y	Sortie / Variable réponse
α	Loup alpha / Coefficient
β	Loup bêta / Coefficient de régression
δ	Loup delta
ε	Terme d'erreur
η	Rendement / Efficacité
λ	Conductivité thermique
ρ	Masse volumique
τ	Temps caractéristique
ω	Taux de réaction / Loup oméga

P_c	Puissance absorbée par le compresseur
$\dot{m}_{air}$	Débit massique d'air
H_1	Enthalpie de l'air à l'entrée du compresseur
H_2	Enthalpie de l'air à la sortie du compresseur
$\dot{m}_{prélev}$	Débit massique d'air prélevé pour le refroidissement
$H_{prélev}$	Enthalpie de l'air prélevé
$\dot{m}_{fuel}$	Débit massique de carburant
$\dot{m}_{eau}$	Débit massique d'eau injectée dans la chambre de combustion
H_{eau}	Enthalpie de l'eau injectée
H_3	Enthalpie des gaz de combustion en sortie de la chambre de combustion
Q_{pertes}	Pertes thermiques dans la chambre de combustion
η_{comb}	Rendement (efficacité) de combustion
$Q_{réelle}$	Chaleur réellement dégagée par la combustion
$Q_{théorique}$	Chaleur théorique dégagée par la combustion complète
$\Delta H_{réel}$	Variation réelle d'enthalpie liée à la combustion
S_L	Vitesse de propagation laminaire de la flamme
τ_c	Temps caractéristique de la réaction chimique
δ_f	Épaisseur de la flamme
a	Diffusivité thermique des gaz chauds
P_{net}	Puissance nette délivrée par la turbine
P_t	Puissance produite par la turbine de détente
$\dot{m}_{gaz}$	Débit massique des gaz de combustion
T_3	Température des gaz à la sortie de la chambre de combustion (entrée turbine)
T_4	Température des gaz à la sortie de la turbine de détente
P_3	Pression des gaz à l'entrée de la turbine de détente
P_4	Pression des gaz à la sortie de la turbine de détente
γ	Rapport des chaleurs spécifiques (c_p/c_v)
η_t	Rendement isentropique de la turbine de détente
r_c	Taux de compression
P_1	Pression à l'entrée du compresseur

P_2	Pression à la sortie du compresseur
η_{th}	Rendement thermique du cycle
W_{net}	Travail net produit par le cycle
W_t	Travail produit par la turbine
W_c	Travail consommé par le compresseur
Q_{in}	Chaleur totale fournie au cycle par la combustion
Q_{comb}	Chaleur fournie par la combustion
$F_{pression}$	Composante de poussée due à la différence de pression
p_j	Pression statique du jet à la sortie de la tuyère
p_a	Pression atmosphérique ambiante
A_j	Section de sortie de la tuyère
c_j	Vitesse du jet à la sortie de la tuyère
u	Vitesse de l'air (ou de l'avion) à l'entrée du moteur
P_F	Puissance de propulsion
Q_{in}	Puissance thermique apportée par la combustion
$\dot{W}_{utile}$	Travail utile produit par unité de temps (puissance utile)
η_{prop}	Rendement de propulsion (rendement de Froude)
η_{global}	Rendement global du moteur
Q_{Refr}	Chaleur extraite par le système de refroidissement de l'air de turbine
Y	Variable réponse du système (sortie du modèle mathématique du plan d'expériences)
$X_1, X_2, ..., X_k$	Variables indépendantes (facteurs d'entrée) du plan d'expériences (k facteurs)
β_0	Terme constant du modèle (ordonnée à l'origine, valeur de la réponse quand tous les facteurs sont à leur niveau de référence)
β_i	Coefficient de l'effet principal du facteur i dans le modèle de régression du plan d'expériences
β_{ij}	Coefficient d'interaction entre les facteurs i et j dans le modèle de régression
$\hat{y}$	Valeur de la réponse prédite par le modèle de régression
$\bar{y}$	Moyenne arithmétique des observations expérimentales
n	Nombre total d'observations (expériences) dans le plan d'expériences

p	Nombre de paramètres (coefficients) estimés dans le modèle de régression
R²	Coefficient de détermination : proportion de variance de la réponse expliquée par le modèle (déjà présent — vérifié)
R²_{aj}	Coefficient de détermination ajusté, corrigé par le nombre de paramètres du modèle
Q²	Coefficient de détermination prédictif (R ² prédictif), mesurant la capacité du modèle à prévoir des points inconnus
PRESS	Somme des carrés des résidus prédictifs (Predicted Residual Error Sum of Squares), utilisée pour le calcul de Q ²
h_{ii}	i-ème élément diagonal de la matrice chapeau (Hat matrix), utilisé dans le calcul de PRESS
v	Niveau d'un facteur exprimé en valeur centrée réduite (valeur adimensionnelle entre -1 et +1)
V	Niveau réel d'un facteur expérimental (valeur physique)
V⁺	Niveau supérieur (valeur physique maximale) d'un facteur expérimental
V⁻	Niveau inférieur (valeur physique minimale) d'un facteur expérimental
k	Nombre de facteurs (variables d'entrée) dans le plan d'expériences
A_i	Effet principal du facteur i : constante caractérisant la variation de la réponse lorsque le facteur X _i passe du niveau -1 au niveau +1
σ(A_i)	Écart-type de l'effet principal A _i , utilisé dans le test de Student pour la signification des effets
S²(A_i)	Variance de l'effet A _i , estimée à partir du nombre d'expériences n et du nombre de coefficients p
t_{obs}	Valeur observée de la statistique de test t de Student pour l'effet A _i
t_{crit}(α, v)	Valeur critique de la loi de Student pour un niveau de risque α et v degrés de liberté
SCEL	Somme des carrés due à la liaison (régression) dans le tableau ANOVA
SCER	Somme des carrés des écarts résiduels dans le tableau ANOVA
SCET	Somme des carrés totale dans le tableau ANOVA
CML	Carré moyen de la liaison (régression) dans le tableau ANOVA : CML = SCEL / (p-1)
CMR	Carré moyen résiduel dans le tableau ANOVA : CMR = SCER / (n-p)

F_{obs}	Valeur observée de la statistique de Fisher ($F = CML/CMR$), utilisée pour valider globalement la régression
L	Nombre de couches (layers) dans un réseau de neurones (profondeur du réseau)
$W^{(l)}$	Matrice des poids synaptiques de la couche l du réseau de neurones
$b^{(l)}$	Vecteur des biais de la couche l du réseau de neurones
$f^{(l)}$	Fonction d'activation de la couche l du réseau de neurones
$a^{(l)}$	Vecteur d'activation (sortie) de la couche l après application de la fonction d'activation
$z^{(l)}$	Entrée pré-activation (somme pondérée des entrées) de la couche l : $z^{(l)} = W^{(l)}a^{(l-1)} + b^{(l)}$
$h^{(l)}$	Vecteur des activations cachées (hidden) de la couche l dans un réseau de neurones profond
g	Fonction d'activation de la couche de sortie (linéaire pour la régression, sigmoïde ou softmax pour la classification)
z	Variable d'entrée générique d'une fonction d'activation (neurone avant activation)
$\sigma(z)$	Fonction d'activation sigmoïde : $\sigma(z) = 1 / (1 + e^{-z})$
z_i	i -ème composante du vecteur d'entrée z de la fonction softmax
K	Nombre de classes dans la couche de sortie pour la fonction softmax (classification multiclasse)
$\partial J / \partial W^{(l)}$	Gradient de la fonction de coût J par rapport à la matrice de poids $W^{(l)}$ de la couche l , calculé par rétropropagation
$\partial J / \partial b^{(l)}$	Gradient de la fonction de coût J par rapport au vecteur de biais $b^{(l)}$ de la couche l , calculé par rétropropagation
$\vec{X}$	Vecteur de position d'un loup gris (agent de recherche) dans l'espace de recherche (GWO)
$\vec{X}_p$	Vecteur de position de la proie dans l'espace de recherche (GWO)
$\vec{D}$	Vecteur distance entre la proie et un loup gris (GWO)
$\vec{a}$	Vecteur de paramètre de contrôle du GWO, décroissant linéairement de 2 à 0 au cours des itérations pour réguler l'équilibre exploration/exploitation
$\vec{r}_1, \vec{r}_2$	Vecteurs aléatoires à composantes uniformément distribuées dans $[0, 1]$, utilisés dans les équations de mise à jour des positions (GWO)
t	Numéro de l'itération courante dans l'algorithme d'optimisation
T_{max}	Nombre maximum d'itérations fixé pour l'algorithme d'optimisation

$\vec{X}_a$	Vecteur de position de la meilleure solution (loup alpha) dans l'espace de recherche (GWO)
$\vec{X}_\beta$	Vecteur de position de la deuxième meilleure solution (loup bêta) dans l'espace de recherche (GWO)
$\vec{X}_\delta$	Vecteur de position de la troisième meilleure solution (loup delta) dans l'espace de recherche (GWO)
$\vec{D}_a$	Vecteur distance entre l'agent de recherche courant et la position du loup alpha (GWO)
$\vec{D}_\beta$	Vecteur distance entre l'agent de recherche courant et la position du loup bêta (GWO)
$\vec{D}_\delta$	Vecteur distance entre l'agent de recherche courant et la position du loup delta (GWO)
$\vec{A}_1, \vec{A}_2, \vec{A}_3$	Vecteurs coefficients d'encerclement distincts utilisés dans les trois calculs de distance (GWO, phase de chasse)
$\vec{C}_1, \vec{C}_2, \vec{C}_3$	Vecteurs coefficients aléatoires distincts associés respectivement aux loups alpha, bêta et delta (GWO, phase de chasse)
$\vec{X}_1, \vec{X}_2, \vec{X}_3$	Positions candidates calculées à partir des positions de l'alpha, du bêta et du delta respectivement, pour la mise à jour de position (GWO)
$\vec{X}(t+1)$	Position mise à jour d'un agent de recherche à l'itération t+1 (GWO)
$\vec{X}(i)$	Vecteur de position de l'agent de recherche i à l'itération courante (SBOA)
$\vec{X_rand1}, \vec{X_rand2}$	Vecteurs de position de deux membres aléatoires de la population, utilisés dans la phase d'exploration du SBOA (Phase 1)
$\vec{R}_i$	Vecteur aléatoire utilisé dans la phase d'exploration du SBOA (Phase 1 — Recherche de proie)
$\vec{Best_P}$	Vecteur de position de la meilleure solution (best position) de la population courante (SBOA)
$\vec{RB}$	Vecteur de mouvement brownien aléatoire utilisé dans la phase de transition du SBOA (Phase 2 — Approche de la proie)
T	Nombre total (maximum) d'itérations de l'algorithme (SBOA)
CF	Facteur de convergence du SBOA, contrôlant l'amplitude des mouvements en phase d'exploitation (Phase 3)
$Levy(\beta)$	Distribution de vol de Lévy paramétrée par β , utilisée dans la phase d'exploitation du SBOA pour générer des sauts multi-échelles
β_i	Paramètre de la distribution de Lévy contrôlant la forme de la queue dans le vol de Lévy (SBOA, Phase 3)
$\vec{D}_h$	Vecteur distance entre la proie et une hyène tachetée (SHO, phase d'encerclement)

$\vec{P}_p$	Vecteur de position de la proie (solution optimale cible) dans l'espace de recherche (SHO)
$\vec{P}$	Vecteur de position d'une hyène tachetée (agent de recherche) dans l'espace de recherche (SHO)
$\vec{P}_h$	Vecteur de position de la meilleure hyène tachetée (solution optimale du groupe) dans l'espace de recherche (SHO)
$\vec{P}_k$	Vecteur de position de la k-ème hyène tachetée membre du cluster (SHO)
$\vec{C}_h$	Vecteur somme des positions de toutes les N hyènes du cluster de confiance (SHO)
rd_1, rd_2	Vecteurs aléatoires à composantes uniformément distribuées dans [0, 1] utilisés dans les équations du SHO
h	Vecteur de paramètre de contrôle du SHO, décroissant linéairement de 5 à 0 au cours des itérations
M	Vecteur aléatoire dans [0.5, 1] définissant le rayon de voisinage pour le comptage des hyènes du cluster (SHO)
nos	Nombre total de solutions (taille de la population) dans l'algorithme SHO
count	Compteur du nombre de solutions candidates suffisamment proches de la meilleure solution pour appartenir au cluster (SHO)
x	Numéro de l'itération courante dans l'algorithme SHO (équivalent à t dans GWO/SBOA)
$\vec{P}^{(x+1)}$	Vecteur de position mise à jour d'une hyène tachetée à l'itération x+1 (SHO)

Abréviation	Signification
ANN	Artificial Neural Network (Réseau de Neurones Artificiels)
CCD	Central Composite Design (Plan Composite Centré)
CFD	Computational Fluid Dynamics (Dynamique des Fluides Numérique)
DNN	Deep Neural Network (Réseau de Neurones Profond)
DoE	Design of Experiments (Plans d'Expériences)
GPA	Gas Path Analysis (Analyse du Parcours de Gaz)
GWO	Grey Wolf Optimizer (Optimiseur des Loups Gris)
MOGWO	Multi-Objective Grey Wolf Optimizer
NO_x	Oxydes d'azote
ReLU	Rectified Linear Unit
RSM	Response Surface Methodology (Méthodologie des Surfaces de Réponse)
SBOA	Secretary Bird Optimization Algorithm (Algorithme d'Optimisation du Secrétaire)
SHO	Spotted Hyena Optimizer (Optimiseur de Hyène Tachetée)
STIG	Steam Injected Gas Turbine
TAG	Turbine à Gaz

Liste des Tableaux

Tableau I.1 : État de surface des distributeurs de l'étage 1	27
Tableau I.2 : État de surface des aubes de turbine de l'étage 1	27
Tableau I.3 : État de surface des distributeurs de l'étage 2	28
Tableau III.1 : Exemple de transformation en valeurs centrées réduites	45
Tableau III.2 : Tableau d'analyse de variance	48
Tableau III.3 : Paramètres de Configuration des Algorithmes d'Optimisation	70
Tableau IV.1 : Solutions du Front de Pareto de l'Optimisation Multi-Objectifs	81
Tableau IV.2 : Performance Mensuelle du Réseau Neuronal Optimisé par SBOA	83
Tableau IV.3 : Caractéristiques des Algorithmes et Applications Recommandées	89

Liste des Figures

Figure I.1 : Différents composants d'une turbine à gaz	6
Figure I.2 : Définitions des températures de flamme	9
Figure I.3 : Bilan énergétique dans le brûleur	10
Figure I.4 : Diagramme température–entropie	13
Figure II.1 : Comparaison de l'efficacité fractionnaire pour des éléments filtrants de différents fournisseurs et différentes vitesses frontales à l'état neuf et encrassé ..	22
Figure II.2 : (a) Dépôt de carbone asymétrique dans le moteur et (b) l'une des aubes de turbine frappée par la chute de carbone	26
Figure III.1 : Effet d'un facteur sur la réponse	42
Figure III.2 : Notion d'interaction entre deux facteurs	42
Figure III.3 : Exemple de graphe d'adéquation du modèle	44
Figure III.4 : Exemple de surface de réponse pour deux facteurs	45
Figure III.5 : Plan factoriel complet à deux facteurs (2^2)	46
Figure III.6 : Division d'un plan 2^3 en deux plans fractionnaires $2^{(3-1)}$	47
Figure III.7 : Plan composite centré pour deux facteurs	47
Figure III.8 : Sigmoïde	50
Figure III.9 : Tangente hyperbolique	51
Figure III.10 : Rectified Linear Unit (ReLU)	51
Figure III.11 : Structure d'un réseau de neurones profond	52
Figure IV.1 : Méthodologie proposée pour l'optimisation de réseaux de neurones profonds légers pour la surveillance du rendement des turbines à gaz en périphérie de réseau	74
Figure IV.2 : Points expérimentaux dans le Plan Composite Centré à faces centrées pour deux facteurs	75
Figure IV.3 : Graphiques des résidus pour chaque terme du modèle de régression	77
Figure IV.4 : Courbes de régression pour les coefficients du modèle	78
Figure IV.5 : Fronts de Pareto atteints par les algorithmes MOGWO, SBOA et SHO dans l'espace bi-objectifs du score R^2 par rapport au temps d'entraînement	82
Figure IV.6 : Comparaison entre le rendement réel mesuré et le rendement prédit par SBOA- DNN sur douze mois d'opération	84
Figure IV.7 : Courbes de perte d'entraînement et de validation pour le modèle DNN optimisé par SBOA.....	84

Sommaire

Remerciement	i
Dédicace	ii
Nomenclature	iii
List des figures	v
List des tableaux	vi
Introduction Générale	1

Chapitre I : Généralités sur les Turbines à Gaz

I.1 Introduction	4
I.2 Présentation	4
I.2.1 Composants d'une turbine à gaz	5
I.2.1.1 Entrée d'air	6
I.2.1.2 Compresseur	7
I.2.1.3 Chambre de combustion	8
I.2.1.4 Turbine de détente	11
I.2.1.5 Échappement de la turbine à gaz	12
I.2.2 Puissances et rendements	12
I.3 Applications de la turbine à gaz	14
I.3.1 Réalisation pratique	14
I.3.2 Limites techniques et avantages	15
I.3.3 Domaines d'utilisation	16
I.3.3.1 Aéronautique	16
I.3.3.1.1 Turbocompresseur	16
I.3.3.1.2 Turbine à gaz d'avion	16
I.3.3.1.3 Moteur à turbopropulseur	17
I.3.3.1.4 Moteur à turbojet	17
I.3.3.1.5 Moteur à turboréacteur	18
I.3.3.1.6 Moteur à turbofusée	18
I.3.3.1.7 Moteur d'avion nucléaire	18
I.3.3.2 Turbines à gaz pour véhicules	18
I.3.3.2.1 Automobiles	18
I.3.3.2.2 Locomotives ferroviaires	18
I.3.3.2.3 Suralimentation par les gaz d'échappement	18
I.3.3.3 Turbines à gaz pour la production d'énergie électrique	18
I.3.3.4 Turbines à gaz dans l'industrie pétrochimique	19
I.3.3.5 Turbines à gaz dans le transport des hydrocarbures	20
I.4 Conclusion	20

Chapitre II : Mécanismes et facteurs de la dégradation dans les turbines à gaz

II.1 Introduction	21
II.2 Mécanismes de dégradation des turbines à gaz	21

II.2.1 Classification générale de la dégradation	21
II.2.2 Encrassement du compresseur (Compressor Fouling)	22
II.2.2.1 Phénoménologie de l'encrassement.....	23
II.2.2.2 Impacts sur les performances du compresseur	23
II.2.3 Érosion	24
II.2.4 Corrosion et corrosion à chaud	24
II.2.5 Frottement et usure (Rubbing Wear)	24
II.2.6 Dommages par corps étrangers (Foreign Object Damage)	25
II.3 Dégradation de la section chaude (Hot Section)	26
II.3.1 Mécanismes de dégradation dans la section turbine	26
II.3.2 Impact de l'enlèvement de matière	27
II.3.3 Évaluation de la qualité de surface	27
II.4 Facteurs influençant la dégradation	29
II.4.1 Conditions environnementales	29
II.4.2 Conditions opérationnelles	29
II.4.3 Qualité du combustible et de l'air	30
II.4.4 Conception et caractéristiques du moteur	30
II.5 Systèmes de filtration de l'air d'admission	30
II.5.1 Importance de la filtration	30
II.5.2 Performance des systèmes de filtration	30
II.5.3 Impact sur les performances à long terme	31
II.6 Surveillance des turbines à gaz	31
II.6.1 Systèmes de surveillances conventionnelles	31
II.6.2 Instrumentation et méthodologie diagnostique	32
II.6.3 Surveillance de la chambre de combustion	32
II.6.4 Caractéristiques du tourbillon (Swirl)	33
II.7 Méthodes de diagnostic et de surveillance avancées	33
II.7.1 Approches basées sur les modèles	33
II.7.2 Approches basées sur les données	33
II.7.3 Approches hybrides	34
II.7.4 Réseaux de neurones artificiels pour la surveillance	34
II.7.5 Applications de l'intelligence artificielle	35
II.8 Modélisation du comportement dynamique	35
II.8.1 Approches de modélisation avancée	35
II.8.2 Surveillance des vibrations et détection de défauts	36
II.8.3 Prédiction de la dégradation des performances	36
II.9 Gestion et atténuation de la dégradation	37
II.9.1 Stratégies de maintenance	37
II.9.2 Lavage et nettoyage	37
II.9.3 Surveillance et maintenance prédictive	37
II.9.4 Intervalles de révision et remplacement	38
II.10 Défis et perspectives futures	38
II.10.1 Défis opérationnels	38
II.10.2 Incertitudes de mesure et validation	38

II.10.3 Besoins de recherche future	39
II.11 Conclusion	39

Chapitre III : Algorithmes d'Optimisation et Mise en Œuvre

III.1 Introduction	41
III.2 Conception d'Expériences et Modélisation Mathématique Classique	41
III.2.1 Modèle Mathématique de la Conception d'Expériences	42
III.2.2 Estimation des Paramètres et Validation du Modèle	44
III.2.2.1 Critères de Qualité d'Ajustement	44
III.2.2.2 Graphe d'Adéquation du Modèle	45
III.2.2.3 Surface de Réponse	45
III.2.2.4 Conditions d'Application	46
III.2.2.5 Valeurs Centrées Réduites	46
III.2.2.6 Types de Plans Expérimentaux	47
III.2.3 Analyse Statistique et Tests de Signification	49
III.2.3.1 Test de Signification des Effets	49
III.2.3.2 Analyse de la Variance (ANOVA)	49
III.2.4 Validation du Modèle	50
III.3 Réseaux de Neurones et Réseaux de Neurones Profonds	50
III.3.1 Architecture Mathématique des Réseaux de Neurones	51
III.3.2 Fonctions d'Activation et Propagation	51
III.3.3 Réseaux de Neurones Profonds	53
III.3.4 Hyper paramètres des Réseaux de Neurones	54
III.4 Optimisation des Hyper paramètres des Réseaux de Neurones	54
III.4.1 Algorithme d'Optimisation du Loup Gris (GWO)	55
III.4.1.1 Hiérarchie Sociale	55
III.4.1.2 Phase d'Encerclement de la Proie	56
III.4.1.3 Phase de Chasse (Mise à Jour des Positions)	57
III.4.1.4 Phase d'Attaque de la Proie (Exploitation)	58
III.4.1.5 Phase de Recherche de Proie (Exploration)	59
III.4.2 Algorithme d'Optimisation du Secrétaire (SBOA)	60
III.4.2.1 Phase 1 - Recherche de Proie (Exploration)	60
III.4.2.2 Phase 2 - Approche de la Proie (Transition)	61
III.4.2.3 Phase 3 - Attaque de la Proie (Exploitation)	62
III.4.3 Algorithme d'Optimisation de l'Hyène Tachetée (SHO)	64
III.4.3.1 Phase d'Encerclement de la Proie	64
III.4.3.2 Phase de Chasse (Formation de Clusters)	66
III.4.3.3 Phase d'Attaque de la Proie (Exploitation)	67
III.4.3.4 Phase de Recherche de Proie (Exploration)	68
III.4.4 Adaptation Multi-Objectif	70
III.4.5 Mise en Œuvre et Configuration des Paramètres	71
III.4.6 Cadre d'Évaluation	72
III.4.7 Conclusion	73

Chapitre IV : Résultats et discussion

IV.1 Introduction	74
IV.2 Aperçu du Cadre Méthodologique	74
IV.3 Approche par Plans d'Expériences : Résultats de Modélisation Statistique	75
IV.3.1 Mise en œuvre du Plan Composite Centré	75
IV.3.2 Modèle de Régression Développé	76
IV.3.3 Validation Statistique et Performance du Modèle	77
IV.3.4 Analyse des Résidus et Adéquation du Modèle	78
IV.3.5 Analyse des Coefficients de Régression et Interprétation Physique	79
IV.3.6 Implications Pratiques du Modèle DoE	80
IV.4 Approche d'Optimisation Multi-Objectifs par Réseaux de Neurones	81
IV.4.1 Cadre d'Optimisation et Sélection d'Algorithme	81
IV.4.2 Formulation du Problème Multi-Objectifs	81
IV.4.3 Mise en œuvre des Contraintes Physiques	82
IV.4.4 Performance Comparative des Algorithmes	82
IV.4.5 Architecture de Réseau Neuronal Optimale et Performance	84
IV.4.6 Dynamique d'Entraînement et Convergence du Modèle	85
IV.4.7 Insights Architecturaux et Analyse d'Efficacité	87
IV.5 Analyse Comparative des Approches de Modélisation	87
IV.5.1 Comparaison de la Précision Prédictive	87
IV.5.2 Interopérabilité du Modèle et Insight Physique	88
IV.5.3 Exigences Computationnelles	88
IV.5.4 Généralisation et Comportement d'Extrapolation	89
IV.5.5 Exigences en Données et Efficacité d'Échantillonnage	90
IV.5.6 Guide de Sélection d'Algorithme	90
IV.6 Conclusion	91
Conclusion Générale	92
Références Bibliographiques	

Introduction Générale

Au cours des dernières décennies, les turbines à gaz (TAG) ont connu un développement considérable dans de nombreux secteurs industriels, notamment dans les domaines de la production d'énergie électrique et de l'industrie des hydrocarbures. Ces machines thermodynamiques, définies comme des dispositifs dans lesquels s'effectue un échange d'énergie entre un rotor tournant à vitesse constante et un fluide en écoulement permanent, constituent aujourd'hui des actifs stratégiques de l'infrastructure énergétique mondiale. Elles assurent des fonctions essentielles allant de la propulsion aéronautique à la production d'électricité, en passant par l'entraînement de compresseurs dans l'industrie pétrolière et gazière.

Les turbines à gaz présentent de multiples avantages techniques qui expliquent leur adoption généralisée : une puissance massique et volumique très élevée, une construction relativement simple, des émissions réduites de polluants, une excellente aptitude à la récupération de chaleur, et une capacité d'adaptation à divers types de combustibles [1-7]. Cependant, leur rendement demeure fortement influencé par les conditions atmosphériques, particulièrement la température de l'air ambiant, laquelle varie sensiblement entre le jour et la nuit, ainsi qu'entre les saisons. Cette dépendance thermique affecte directement les performances énergétiques et économiques des installations. À titre illustratif, une étude de cas sur la turbine M3142R/GE MS 3002 a démontré que l'efficacité chute de 26,78% à 25,03% lorsque la température d'entrée du compresseur augmente de 15 à 47°C, entraînant une perte de puissance dépassant 2,3 MW [8].

Au-delà des variations climatiques, les turbines à gaz sont confrontées à des problèmes de dégradation progressive de leurs performances dues à des défaillances physiques telles que l'encrassement du compresseur et l'érosion de la turbine, qui détériorent graduellement les paramètres de santé des composants comme la capacité d'écoulement et l'efficacité isentropique [9-11]. L'encrassement, responsable de plus de 70% de la dégradation des performances, diminue typiquement la capacité d'écoulement et l'efficacité isentropique du compresseur [12]. Ces phénomènes de détérioration affectent non seulement l'efficacité opérationnelle mais ont également des répercussions environnementales significatives, les centrales à turbine à gaz étant d'importants contributeurs aux émissions de dioxyde de carbone (CO₂), l'un des principaux gaz à effet de serre [13,14].

Les conséquences environnementales de cette inefficacité sont considérables, car des expériences répétées ont démontré que les niveaux d'émissions de CO₂ sont intrinsèquement liés à l'efficacité opérationnelle : une augmentation de l'efficacité thermique se traduit directement par une réduction des émissions par unité de puissance générée [15-17]. Cette corrélation entre performance thermique et impact environnemental souligne l'importance cruciale d'une estimation précise et d'une optimisation continue de l'efficacité des turbines à gaz pour répondre aux objectifs de réduction des émissions fixés par les accords internationaux sur le climat [18].

Face à ces enjeux, plusieurs techniques visant à améliorer les performances des turbines ont été développées, telles que la régénération [21-24], le refroidissement intermédiaire [25-34], le préchauffage [35-40], ainsi que l'injection d'eau [41-45] ou de vapeur d'eau [46-53]. Parmi ces approches, la méthode d'injection de vapeur d'eau en amont de la chambre de combustion, connue sous le nom de cycle STIG (Steam Injected Gas Turbine), a fait l'objet de nombreuses

études et applications industrielles, permettant d'augmenter la puissance spécifique tout en réduisant les émissions d'oxydes d'azote (NOx) [54-60].

Les méthodes classiques d'analyse des performances reposent essentiellement sur une modélisation thermodynamique de haute-fidélité [8,9]. Les modèles physiques développés dans des outils comme Matlab [8] ou des logiciels dédiés comme GasTurb 13 [9] sont inestimables pour simuler le cycle de Brayton et examiner les effets d'interventions telles que le refroidissement par évaporation [8] ou l'implantation de défauts spécifiques [9]. Toutefois, ces approches sont généralement coûteuses en calcul, nécessitant la résolution d'équations d'équilibre énergétique complexes et non linéaires, ainsi que des cartographies complètes des composants et des données spécifiques au moteur [9,20]. Cette complexité les rend peu adaptées à la nature rapide et continue requise par la prédiction et le contrôle des performances en temps réel.

Parallèlement à ces méthodes classiques d'analyse des performances, les paradigmes de l'intelligence artificielle (IA) offrent une alternative particulièrement attractive. Les réseaux de neurones profonds (Deep Neural Networks - DNNs), avec leur capacité reconnue à modéliser des systèmes complexes et non linéaires sans nécessiter d'équations physiques explicites, sont hautement adaptés à cette tâche [61]. Bien que des travaux antérieurs aient employé des modèles statistiques et de régression pour prévoir les émissions [17,62-63] et que les DNNs aient été appliqués au diagnostic de défauts [64], leur application à la prédiction de l'efficacité globale de modèles spécifiques de turbines à gaz, tout en étant optimalement conçus pour gérer le compromis entre précision prédictive et effort computationnel, demeure un domaine actuellement sous-développé.

Dans ce contexte, l'objectif principal de cette thèse est d'améliorer les performances des turbines à gaz opérant dans les conditions climatiques sévères du sud algérien, caractérisées par de fortes variations de température ambiante et d'humidité, par le développement d'un cadre méthodologique innovant basé sur les méthodes déterministes classiques et l'intelligence artificielle pour la surveillance et la prédiction en temps réel de l'efficacité des turbines à gaz.

Plus précisément, ce travail propose un cadre complet pour l'optimisation de réseaux de neurones profonds dédiés à la prédiction de l'efficacité de la turbine à gaz MS5002B, en utilisant des techniques avancées d'optimisation métaheuristique multi-objectifs. La nouveauté réside dans l'utilisation d'une approche d'optimisation multi-objectifs innovante qui intègre trois algorithmes de pointe inspirés de la nature - l'optimiseur de loup gris multi-objectifs (MOGWO), l'algorithme d'optimisation de l'oiseau secrétaire (SBOA) et l'optimiseur d'hyène tachetée (SHO) - pour minimiser simultanément le coût computationnel et maximiser la précision prédictive. Cette méthodologie produit un front de Pareto de conceptions optimales, offrant ainsi un cadre méthodologique rigoureux pour obtenir des modèles efficaces, légers et hautement précis adaptés à la prédiction et au contrôle des performances des turbines à gaz en temps réel.

L'étude s'appuie sur des données expérimentales recueillies auprès d'une turbine à gaz industrielle MS5002B opérant dans une centrale électrique à cycle combiné, englobant douze mois de fonctionnement continu et capturant les variations saisonnières des conditions ambiantes. Pour garantir que les modèles DNNs développés respectent les principes thermodynamiques fondamentaux, des contraintes physiques ont été explicitement incorporées dans le cadre d'apprentissage, notamment la relation zéro-puissance-vers-zéro-efficacité,

reflétant la réalité thermodynamique fondamentale selon laquelle l'absence de travail utile implique une efficacité nulle.

La présente thèse est organisée en quatre chapitres complémentaires comme suit :

- Chapitre I : Revue bibliographique exhaustive consacrée aux turbines à gaz, couvrant leurs principes de fonctionnement, leurs composants essentiels, leurs domaines d'application, ainsi que leurs avantages et limitations techniques.
- Chapitre II : Analyse des mécanismes et facteurs de dégradation des turbines à gaz, incluant les effets thermiques, mécaniques et environnementaux sur la performance et la durée de vie des composants.
- Chapitre III : Présentation des algorithmes d'optimisation adoptés et de leur mise en œuvre dans le cadre de la modélisation et de l'amélioration des performances des turbines à gaz.
- Chapitre IV : Résultats et discussions, comprenant l'évaluation des modèles proposés, l'analyse comparative des performances et l'interprétation des résultats obtenus au regard des contraintes physiques et des conditions opérationnelles réelles.

I.1 Introduction

Les turbines à gaz appartiennent à la famille des turbomachines, définies comme des dispositifs dans lesquels s'effectue un échange d'énergie entre un rotor, tournant à vitesse constante autour d'un axe, et un fluide en écoulement permanent

Une turbine à gaz également appelée *turbine à combustion* est une machine tournante de type thermodynamique, classée parmi les moteurs à combustion interne. Son principe repose sur la conversion de l'énergie chimique contenue dans un combustible (liquide ou gazeux) en énergie mécanique, matérialisée par la rotation d'un arbre [79,82].

Selon la nature du fluide moteur utilisé, les turbomachines peuvent être distinguées en trois grandes catégories : les turbines hydrauliques, les turbines à vapeur et les turbines à gaz. Dans cette dernière, le fluide actif est constitué des gaz de combustion produits par la réaction d'un carburant avec un comburant (généralement l'air).

I.2 Présentation

Les turbines à gaz (TAG) sont disponibles dans une très large gamme de puissances, allant d'environ 25 kW à plus de 250 MW [79,82,84,85]. Les modèles les plus couramment employés dans les installations de cogénération présentent des puissances comprises entre 1 et 40 MW, en raison de leur équilibre optimal entre efficacité, compacité et flexibilité d'exploitation [65,66].

En installation fixe, les combustibles les plus fréquemment utilisés sont le gaz naturel, le gaz de pétrole liquéfié (GPL), les gaz biologiques, ou encore le fuel domestique. Certaines turbines peuvent fonctionner au fuel lourd, mais son emploi nécessite des traitements complexes, tels que l'élimination du sodium et des particules solides, ou encore l'inhibition du vanadium. De plus, les gaz d'échappement doivent être épurés afin de respecter les normes environnementales en vigueur [82,84]. Ces contraintes rendent l'exploitation plus coûteuse, augmentent les besoins en maintenance et réduisent la durée de vie des équipements.

Le carburant est injecté dans les chambres de combustion à des pressions élevées, généralement comprises entre 13 et 45 bar [82,84]. Cette opération est relativement aisée pour les combustibles liquides, mais elle peut poser des difficultés pour le gaz naturel, dont la pression d'alimentation varie selon le réseau : de 40 à 75 bar pour les réseaux de transport, et de 4 à 16 bar pour les réseaux de distribution. Lorsque la pression disponible est insuffisante, il est nécessaire d'installer des surpresseurs de gaz, équipements coûteux et consommateurs d'énergie mécanique. Dans le cas des petites installations, leur utilisation réduit considérablement l'intérêt économique de la filière.

La combustion dans une turbine à gaz s'effectue avec un excès d'air très important, généralement compris entre 350 et 500 % [82,84]. Ce rapport air/carburant élevé influence fortement la performance de la machine. Ainsi, la puissance produite dépend de la température d'entrée de l'air et de l'altitude du site d'installation [67,70,73,75,78]. À vitesse de rotation constante, le compresseur fournit un débit massique d'air plus élevé lorsque la température extérieure diminue : la puissance de la turbine augmente donc en période hivernale, ce qui constitue un avantage pour les applications de génie climatique [67,69,73]. En revanche, le rendement chute rapidement lorsque la charge diminue [72,75].

À cet égard, les propriétés des airs entrants, telles que les températures, humidité et pressions, interviennent directement dans la puissance efficace exercée par la turbine [67,71,78]. Celle-ci varie donc selon les saisons et les hauteurs géographiques selon lesquelles se situe le site d'installation. De plus, les fuites de charge entrants (filtres, conduits, muelage, etc.) et les sortants (recovery grille chaudière et chaînée, cheminée, etc.) interviennent également dans la performance [82,84,8].

Les fabricants proposent au utilisateur des courbes La quasi-totalité de l'énergie thermique du combustible non convertie en énergie mécanique se trouve dans les gaz d'échappement dont les températures varient entre 450 et 550 °C [82,84,4]. "Les gaz chauds représentent donc l'une des valeurs d'approvisionnement en énergie thermique : ils peuvent servir à chauffer des fluides caloporteurs ou à produire de la vapeur d'eau. Ils sont généralement ductés vers une batterie d'échange thermique ou vers une chaudière de récupération. La vanne dite vanne d'aiguillage ou vanne dérivateur détourne tout ou partie du gaz direct vers l'atmosphère.

La vanne est actionnée manuellement ou électro magnétiquement. Cette vanne a un rôle important pendant les démarrages ou les opérations secours ou encore lorsque l'énergie résultant d'égouts de chaleur ne peut pas être utilisée. L'absence d'échappement parfait dans cette vanne est fondamentale dans la mesure où les gaz d'échappement doivent rester dans l'appareil afin d'éviter les fuites et les déper Les gaz de sortie des turbines gaz sont caractérisés par une très faible teneur en particules avec une teneur en oxygène résiduel comprise entre 15 % et 17 % [82,84].

Les gaz de sortie peuvent donc être directement utilisés dans le mais aussi comme air comburant dans le brûleur de postcombustion des chaudières ou des générateurs thermiques. Une telle utilisation des gaz de sortie a l'avantage de faire bénéficier des performances globales très optimales des systèmes de cogénération, ce que l'on obtient anche avec une amélioration importante du rendement de performance globale des systèmes de cogénération [65,66,72,4].

I.2.1 Composants d'une turbine à gaz

Une turbine à gaz (illustrée à la figure I 1) se compose de plusieurs éléments essentiels qui assurent la transformation de l'énergie chimique du combustible en énergie mécanique, puis éventuellement en énergie électrique. L'ensemble de ces composants forme une chaîne fonctionnelle continue comprenant :

- **L'entrée d'air**, qui assure le conditionnement du flux aspiré par la machine. Cette étape inclut la filtration pour éliminer les impuretés, et parfois le refroidissement de l'air, afin d'optimiser la densité du fluide et améliorer les performances du compresseur.
- **Le compresseur**, chargé d'augmenter la pression de l'air avant son admission dans la chambre de combustion. Il constitue l'un des organes principaux de la turbine, consommant une partie de la puissance mécanique produite par la turbine de détente.
- **La chambre de combustion**, où s'effectue le mélange et la combustion du carburant avec l'air comprimé. Ce processus libère une grande quantité d'énergie thermique, transformant le mélange gazeux en un flux à haute température et haute pression.
- **La turbine de détente**, dans laquelle les gaz de combustion se détendent en cédant leur énergie au rotor. Cette conversion d'énergie thermique en énergie mécanique de rotation permet d'entraîner le compresseur et, dans les applications motrices, un alternateur ou d'autres équipements.

- **Le système d'échappement**, qui dirige les gaz brûlés vers la cheminée ou vers un dispositif de récupération de chaleur (batterie, chaudière, ou échangeur), selon le type d'installation.

Dans les configurations destinées à la production d'électricité, la majorité des turbines à gaz sont conçues autour d'un arbre unique sur lequel sont montés en série le compresseur, la turbine de détente, et l'alternateur. Dans certains cas, notamment pour les machines de puissance inférieure à 100 MW, cet arbre peut également entraîner des pompes auxiliaires ou être couplé à un réducteur de vitesse afin d'adapter la vitesse de rotation du générateur aux besoins du réseau [79,82,84,85].




Figure I 1 : Différents composants d'une turbine à gaz

I.2.1.1 Entrée d'air

Le système d'admission d'air joue un rôle essentiel dans le bon fonctionnement d'une turbine à gaz [79,82]. Il assure à la fois la filtration et, le cas échéant, le refroidissement de l'air avant son entrée dans le compresseur.

Le dispositif de filtration a pour fonction d'éliminer les impuretés et particules en suspension dans l'air ambiant afin de protéger les composants internes de la turbine contre l'érosion et l'encrassement [9,12]. Cette filtration engendre une perte de charge généralement comprise entre 0,3 % et 1,3 %, soit environ 30 à 130 mm de colonne d'eau (mmCE), selon l'état d'encrassement des filtres [82]. Cette perte est représentée par un coefficient de perte de charge, souvent calibré sur une valeur de 0,6 % à pleine puissance.

Dans certaines installations, un refroidissement de l'air d'admission est mis en œuvre pour améliorer la densité du fluide et donc les performances du compresseur [68,77,2830,25,33]. Ce refroidissement ne doit toutefois pas abaisser la température en dessous de 5 à 7 °C, afin d'éviter les phénomènes de givrage. Il peut être réalisé par différents procédés :

- **Systèmes à évaporation**, utilisant l'humidité de l'air et l'enthalpie de vaporisation de l'eau [67,69,71,7].

- **Systèmes à brumisation d'eau**, qui augmentent l'humidité relative jusqu'à environ 90 à 95 % [77,29].
- **Systèmes à fluide caloporteur froid**, intégrant un circuit de réfrigération fermé [9,30,32,33].

Les systèmes à évaporation et à brumisation sont particulièrement efficaces dans les conditions climatiques chaudes et sèches [7,30], tandis que les procédés à fluide caloporteur introduisent une perte de charge additionnelle de l'ordre de 0,25 % [33].

La mesure régulière de la perte de charge au niveau de l'entrée d'air constitue un indicateur fiable de l'encrassement des filtres [9,12]. Elle doit être corrigée en fonction du débit d'air aspiré et des conditions atmosphériques pour une interprétation correcte de l'état du système.

I.2.1.2 Compresseur

Le compresseur constitue l'un des organes les plus importants de la turbine à gaz [79,82]. Il a pour fonction principale de comprimer l'air ambiant avant son admission dans la chambre de combustion, afin d'augmenter sa pression et sa température, conditions nécessaires à une combustion efficace et stable.

Cet élément consomme plus de la moitié de la puissance mécanique produite par la turbine de détente [79,82]. La puissance absorbée par le compresseur peut être exprimée par la relation (I 1), en tenant compte des prélèvements d'air effectués sur certains étages intermédiaires pour le refroidissement des parties chaudes de la turbine (telles que les aubes fixes et mobiles du premier étage) [9,11,34]:

$$P_c = \dot{m}_{air} (H_2 - H_1) - \dot{m}_{prelev} H_{prelev} \quad (I\ 1)$$

L'enthalpie H de l'air peut être évaluée, dans l'hypothèse du gaz parfait, à partir de sa température [79,81,19]. Par conséquent, l'estimation de la puissance absorbée par le compresseur repose sur la mesure précise des températures de l'air à l'entrée et à la sortie du compresseur.

Le débit massique d'air est quant à lui déterminé au moyen de dispositifs de mesure tels que des diaphragmes ou des venturis tuyères, équipés de prises de pression statique et totale [82,84]. Ces instruments permettent de calculer la vitesse et le débit du fluide en se basant sur les différences de pression, garantissant ainsi une évaluation fiable des conditions de fonctionnement du compresseur.

La dégradation progressive du compresseur due à l'encrassement, l'érosion et la corrosion affecte significativement ses performances [9,12]. L'encrassement, responsable de plus de 70% de la dégradation des performances, diminue typiquement la capacité d'écoulement et l'efficacité isentropique du compresseur [9,12]. Ces phénomènes nécessitent une surveillance continue et des opérations de maintenance préventive, notamment le lavage du compresseur pour récupérer une partie des performances perdues [9,12].

I.2.1.3 Chambre de combustion

La chambre de combustion est la zone où s'effectue la transformation de l'énergie chimique du combustible en énergie thermique, grâce à la combustion du mélange air carburant [79,82]. Ce processus provoque un échauffement important de l'air comprimé, avec un rendement de combustion généralement proche de 100 %, traduisant une utilisation quasi complète du pouvoir calorifique du carburant [82,19].

Le passage du flux gazeux à travers la chambre entraîne une perte de charge estimée à environ 6 %, due principalement aux frottements internes, aux turbulences et aux pertes de pression dans les zones de mélange et de réaction [82].

Dans certaines configurations, il est possible d'injecter de l'eau ou de la vapeur directement dans la chambre de combustion [18,22,41,45]. Cette technique présente deux avantages majeurs :

- Réduire les émissions d'oxydes d'azote (NOx), en limitant la température maximale de la flamme [22,5258,45,54-60];
- Augmenter la puissance développée par la turbine, en accroissant le débit massique total des gaz chauds produits [4042,42,44,46,53].

Cette injection est prise en compte dans le bilan énergétique sous la forme d'un débit massique d'eau $\dot{m}_{\text{eau}}$ possédant une enthalpie H_{eau} [4042,42,44].

Ainsi, le bilan d'énergie de la chambre de combustion peut s'écrire de la manière suivante :

$$\dot{m}_{\text{air}} H_2 + \dot{m}_{\text{fuel}} PCI + \dot{m}_{\text{eau}} H_{\text{eau}} = (\dot{m}_{\text{air}} + \dot{m}_{\text{fuel}} + \dot{m}_{\text{eau}}) H_3 - Q_{\text{pertes}} \quad (\text{I } 2)$$

Ce bilan exprime la conservation de l'énergie au sein de la chambre de combustion, reliant les apports thermiques dus à l'air, au combustible et à l'eau injectée à l'énergie contenue dans les gaz de combustion en sortie [19].

A. Température des gaz de combustion

La température des gaz en sortie de la chambre de combustion ne peut pas être mesurée directement, car elle est à la fois très élevée et fortement hétérogène [82,9]. Sa détermination n'est donc possible que par calcul, à partir du pouvoir calorifique inférieur (PCI) du combustible et du bilan énergétique établi pour la chambre de combustion [82,19]. Cette température est un paramètre critique, car elle influence directement la durée de vie des composants chauds de la turbine, notamment les aubes et les conduits de gaz [82,9,11].

Selon les conventions de mesure et les conditions de référence, plusieurs températures caractéristiques sont distinguées [82,9]:

- **La température d'entrée turbine ISO:** Définie par la norme ISO 2314, cette température correspond au cas idéal où l'intégralité du débit d'air fourni par le compresseur traverse la chambre de combustion, sans aucun prélèvement d'air pour le refroidissement, et où les pertes de charge à l'admission et à l'échappement sont nulles. Elle représente la valeur la plus basse parmi les températures de référence.

- **La température d'entrée de roue de turbine:** Elle est calculée en supposant que les gaz issus de la combustion sont parfaitement mélangés avec l'air de refroidissement de la directrice d'entrée. Cette valeur est intermédiaire, généralement supérieure d'environ 80 °C à la température ISO. Cet écart indique que le débit d'air de refroidissement utilisé pour les aubes et les cavités situées en aval représente environ 8 % du débit total d'air fourni par le compresseur [9,11].
- **La température de sortie de chambre de combustion:** Elle correspond à la température du flux gazeux traversant les tubes à flamme, soit environ 80 % du débit d'air total issu du compresseur. Cette température est la plus élevée, dépassant la précédente d'environ 80 à 100 °C (voir figure I 2) [82,9]. Le débit d'air traversant les tubes à flamme peut être déterminé expérimentalement à partir de la courbe caractéristique débit réduit / perte de charge d'un tube à flamme, obtenue sur banc d'essai [20].




Figure I 2 : Définitions des températures de flamme

Dans le brûleur, la température des gaz augmente de T_2 à T_3 sous l'effet de la combustion [79,82]. Pour garantir une combustion optimale, il est essentiel de régler avec précision le rapport carburant/air, lequel est défini par l'équation (I 3):

$$f = \frac{\dot{m}_{fuel}}{\dot{m}_{air}} \quad (I\ 3)$$




Figure I 3 : Bilan énergétique dans le brûleur

Le problème fondamental consiste à déterminer le rapport f requis pour transformer une unité de masse d'air à T_2 et f unité de masse de carburant à T_f en $(1+f)$ unité de produits de combustion à T_3 , figure (I 3) [79,81,19].

B. Efficacité de la combustion

Le rapport air carburant précédemment déterminé correspond à des conditions idéales, c'est à dire à une combustion complète et parfaite du carburant [82,19]. Cependant, dans les conditions réelles de fonctionnement, diverses pertes thermiques et chimiques surviennent notamment dues à une combustion incomplète, à des imbrûlés ou à des échanges thermiques imparfaits.

Pour tenir compte de ces écarts entre le modèle théorique et la réalité, on introduit un coefficient d'efficacité de combustion η_{comb} , permettant de corriger les calculs énergétiques et de représenter plus fidèlement les performances réelles du système [19]:

$$\eta_{comb} = \frac{Q_{reelle}}{Q_{theorique}} = \frac{\Delta H_{reel}}{\dot{m}_{fuel} \cdot PCI} \quad (I\ 4)$$

C. Vitesse de propagation d'une flamme dans un mélange laminaire

De nombreuses études ont été menées afin de prévoir la vitesse de propagation d'une flamme dans un mélange laminaire [54,58]. Les théories thermiques classiques ont mis en évidence que cette vitesse est proportionnelle à la racine carrée de la diffusivité thermique du mélange ainsi qu'à la racine carrée du temps moyen de réaction chimique [58].

Autrement dit, la vitesse de flamme dépend directement des propriétés de diffusion de la chaleur et de la cinétique de la réaction de combustion, qui gouvernent conjointement la stabilité et la rapidité de propagation de la flamme :

$$S_L \propto \sqrt{\frac{\lambda}{\rho c_p \tau_c}} \quad (I\ 5)$$

où λ désigne la conductivité thermique du mélange, tandis que τ_c correspond au temps caractéristique de la réaction chimique, c'est à dire la durée nécessaire à l'accomplissement du processus de combustion [58].

Ce temps chimique est inversement proportionnel au taux moyen de réaction (ω), ce qui signifie que plus la réaction est rapide, plus le temps requis pour qu'elle se produise est court. Autrement dit:

$$\tau_c = \frac{1}{\omega} \quad (\text{I } 6)$$

L'expression qui en découle permet de déterminer l'épaisseur de la flamme, laquelle s'écrit sous la forme suivante:

$$\delta_f = \frac{a}{S_L} = \sqrt{\frac{a}{\omega}} \quad (\text{I } 7)$$

où a est la diffusivité thermique des gaz chauds [58].

D. Consommation spécifique

Bien que le rendement thermique soit un indicateur pertinent pour comparer différents cycles thermodynamiques, il ne reflète pas toujours de manière directe l'efficacité réelle d'un système vis à vis de sa consommation de carburant [79,82].

Pour une évaluation plus pratique des performances, on utilise donc la consommation spécifique, communément appelée SFC (*Specific Fuel Consumption*). Celle ci représente la quantité de carburant nécessaire pour produire une unité de puissance (ou d'énergie) pendant une unité de temps.

En d'autres termes, la consommation spécifique permet de relier le débit massique de carburant à la puissance utile délivrée par la turbine à gaz, offrant ainsi un critère concret et directement exploitable pour apprécier son efficacité énergétique [82,84]:

$$SFC = \frac{\dot{m}_{fuel}}{P_{net}} \quad [kg / kWh] \quad (\text{I } 8)$$

I.2.1.4 Turbine de détente

La turbine de détente constitue l'élément essentiel de la turbine à gaz, car elle assure la production de l'énergie mécanique nécessaire pour entraîner à la fois le compresseur et, le cas échéant, l'alternateur ou d'autres équipements auxiliaires [79,82].

Son fonctionnement repose sur la détente des gaz chauds issus de la chambre de combustion, qui cèdent une partie de leur énergie thermique sous forme de travail mécanique sur les aubes de la turbine.

Le comportement de la turbine est généralement modélisé par une relation thermodynamique reliant les pressions, températures et rendement isentropique, permettant d'évaluer la puissance mécanique extraite des gaz lors de leur expansion [79,82,9]:

$$P_t = \dot{m}_{gaz} \cdot c_p (T_3 - T_4) = \dot{m}_{gaz} \cdot c_p \cdot T_3 \left[1 - \left(\frac{P_4}{P_3} \right)^{\frac{\gamma-1}{\gamma}} \right] \cdot \eta_t \quad (I\ 9)$$

L'hypothèse selon laquelle l'air traversant la directrice d'entrée participe pleinement au travail dans la turbine est couramment adoptée par les constructeurs [82,9]. Dans ce cadre, les conditions thermodynamiques en amont sont généralement considérées à l'entrée de la roue de turbine. Toutefois, pour simplifier les calculs, il est souvent préférable d'utiliser les conditions normalisées ISO, car les débits d'air de refroidissement $\dot{m}_c$ sont supposés négligeables [9].

Certaines turbines à gaz disposent d'un système de refroidissement de l'air de turbine reposant sur un échangeur thermique, qui transfère la chaleur extraite (notée Q_{Refr}) vers un fluide secondaire, tel que la vapeur d'eau ou le carburant, permettant ainsi une meilleure gestion thermique du système [11,34].

La mesure de la température moyenne des gaz d'échappement constitue l'une des opérations les plus délicates, en raison de la forte hétérogénéité de la répartition des températures dans la veine gazeuse [82,9,60]. Pour obtenir une valeur représentative, il est nécessaire d'utiliser un grand nombre de thermocouples, idéalement disposés sur au moins deux diamètres de la section de sortie. Cette température moyenne est un paramètre essentiel du diagnostic de performance [9,60]. Sur certaines machines, un coefficient de correction est appliqué afin d'ajuster la valeur mesurée à la température réelle des gaz [9].

I.2.1.5 Échappement de la turbine à gaz

Le système d'échappement influe sur le fonctionnement global de la turbine à gaz à travers les pertes de charge engendrées par les différents composants situés en aval [82,8]. Ces pertes se répartissent généralement comme suit :

- Diffuseur d'échappement : 0,5 à 1 %,
- Grille de tranquillisation : environ 0,5 %,
- Système de réchauffage des gaz : environ 0,3 %,
- Chaudière de récupération, vannes, coudes et cheminée, qui ajoutent leurs propres pertes au total [4,21].

Une conception soignée de la ligne d'échappement est donc essentielle pour limiter ces pertes de charge et optimiser le rendement global de l'installation [82,8].

I.2.2 Puissances et rendements

La puissance développée par une turbine à gaz (TAG) dépend avant tout du débit massique d'air qui la traverse, paramètre déterminant la taille et l'encombrement de la machine [79,82,84].

Le rendement thermodynamique de la turbine est directement influencé par deux grandeurs fondamentales [79,82]:

- le taux de compression $r_c = \frac{P_2}{P_1}$
- la température des gaz à la sortie de la chambre de combustion T_3 .

En conséquence, les chambres de combustion doivent être conçues pour résister à la pression P_2 , tandis que les aubes directrices et ailettes du premier étage de la turbine de détente doivent supporter des températures très élevées correspondant à T_3 [82,9,11].

Les valeurs typiques de températures et de pressions aux différents points caractéristiques du cycle d'une turbine à gaz sont généralement de l'ordre de grandeur indiquée dans la littérature [82,84,85].

Sur le diagramme température entropie (T s) illustré à la figure (I 4), le rendement thermodynamique du cycle est représenté de manière graphique [79,82].

Il correspond au rapport entre le travail utile produit par la turbine et la chaleur totale fournie lors de la combustion. Autrement dit, l'aire figurant sous la courbe de détente des gaz symbolise le travail mécanique récupéré, tandis que l'aire correspondant à la chaleur apportée traduit l'énergie thermique injectée dans le système.

Ainsi, le rendement thermodynamique peut être visualisé sur ce diagramme comme la proportion de l'énergie totale fournie qui est effectivement convertie en travail utile:

$$\eta_{th} = \frac{W_{net}}{Q_{in}} = \frac{W_t - W_c}{Q_{comb}} \quad (I\ 10)$$




Figure I 4 : Diagramme température entropie

I.3 Applications de la turbine à gaz

I.3.1 Réalisation pratique

La phase de compression dans une turbine à gaz est assurée par un compresseur d'air, qui peut être soit axial, soit centrifuge, selon la conception et la puissance de la machine [79,82]. Afin de réduire le travail de compression et d'améliorer le rendement global, il est possible d'introduire une pulvérisation d'eau à l'admission, permettant de refroidir l'air entrant [77,2830,25,33].

L'air comprimé issu du compresseur est ensuite réparti en trois flux principaux [82,9]:

- Un flux principal, dirigé vers le brûleur avec un mélange stœchiométrique d'air et de carburant afin d'assurer la combustion complète;
- Un flux de refroidissement, utilisé pour protéger la paroi de la chambre de combustion, puis mélangé aux gaz de combustion avant leur expansion;
- Un flux spécifique, destiné au refroidissement de la turbine, notamment des aubes et organes chauds exposés aux températures élevées [9,11,34].

Certaines configurations de turbines à gaz exploitent une injection de vapeur dans les gaz de combustion à l'entrée de la turbine [25,30,46,53]. Cette technique permet d'accroître le débit massique et donc d'augmenter la puissance développée. La vapeur est généralement produite par une chaudière de récupération, qui utilise l'énergie thermique résiduelle des gaz d'échappement [4,21,25,46,53]. Ce procédé correspond à un cycle combiné simplifié, combinant efficacité énergétique et valorisation de la chaleur perdue [66,72,25].

On distingue principalement deux types de turbines à gaz selon leur configuration mécanique [79,82]:

- **Turbine à simple arbre:** le compresseur, les étages de détente et l'organe récepteur (générateur ou autre dispositif entraîné) sont montés sur un même arbre;
- **Turbine à double arbre:** le compresseur est entraîné par un premier arbre solidaire des étages de détente nécessaires à sa mise en rotation, tandis qu'un second arbre, indépendant, regroupe les autres étages de la turbine et est directement relié à la machine entraînée.

La configuration à double arbre, plus complexe sur le plan mécanique, offre une meilleure adaptabilité lors des variations de charge et de régime, ce qui en fait une solution privilégiée pour les applications de propulsion (aéronautique, marine, etc.) [79,80,82]. En revanche, les turbines à simple arbre conviennent davantage à la production d'électricité, où les conditions de fonctionnement sont stables et la charge élevée [65,66,1,3].

La conception de la turbine, notamment celle du premier étage souvent appelé turbine de feu, soulève des défis métallurgiques majeurs [82,9,11]. En effet, les températures extrêmes et les forces centrifuges considérables exercées sur les aubes mobiles exigent l'emploi de matériaux hautement résistants, tels que des aciers fortement alliés contenant du chrome (Cr), du nickel (Ni) et du vanadium (Va). Ces alliages garantissent une tenue mécanique et thermique optimale [11].

De plus, un refroidissement intensif est assuré par de l'air prélevé sur le compresseur afin de protéger les composants critiques [9,11,34]. Enfin, des recherches avancées portent actuellement sur l'utilisation de matériaux céramiques, capables de résister à des températures plus élevées, dans le but d'augmenter la température d'entrée turbine (T_3) et d'améliorer ainsi le rendement global de la machine [82,11].

I.3.2 Limites techniques et avantages

La turbine à gaz présente plusieurs contraintes techniques liées à sa conception, à ses matériaux et à ses conditions de fonctionnement [79,82,84]. Ces limitations influencent directement son rendement, sa fiabilité et son domaine d'utilisation. Les principales limites techniques peuvent être résumées comme suit :

- Le taux de compression, et donc le rendement global, est restreint par le nombre d'étages de compression réalisables, compte tenu de la complexité mécanique et des pertes associées [79,82];
- Les compresseurs centrifuges subissent une forte baisse de rendement lorsque le régime de fonctionnement s'écarte du régime nominal, réduisant l'efficacité à charge partielle [72,75,82];
- La température maximale de combustion est limitée par la résistance mécanique et thermique des matériaux utilisés dans la turbine de détente, ce qui restreint la performance énergétique [82,9,11];
- Le rendement chute significativement à charge partielle, surtout dans les machines à simple arbre, qui ne permettent pas une adaptation optimale du couple compresseur turbine [72,75,82];
- Le coût d'usinage élevé des aubages, particulièrement ceux de la turbine, représente une contrainte économique importante [84,11];
- Les cycles d'arrêt et de démarrage fréquents sont mal tolérés, car ils engendrent des sollicitations thermiques et mécaniques importantes, diminuant la longévité de la machine [9,12].

Malgré ces limites, la turbine à gaz présente de nombreux avantages qui expliquent sa large utilisation dans des domaines variés [1,7]:

- Une puissance massique et volumique très élevée, liée au fonctionnement continu et à la densité énergétique du procédé;
- Une construction relativement simple, composée essentiellement d'un rotor, d'un carter et d'un brûleur, assurant un bon équilibrage mécanique et un faible niveau de vibrations;
- Une émission réduite de polluants, notamment en hydrocarbures imbrûlés (HC) et en oxydes d'azote (NO_x), grâce à un excès d'air et à une température de combustion modérée [15,16,54-60];
- Une grande aptitude à la récupération de chaleur, ce qui rend la turbine idéale pour des applications de cogénération (production simultanée d'électricité et de chaleur) [65,66,72,4,21];
- Une longévité élevée lorsqu'elle fonctionne en régime stationnaire et sous des conditions stables [82,84];
- Une capacité d'adaptation à divers types de combustibles, y compris des carburants de moindre qualité tels que les gaz pauvres ou les fuels lourds [82,84].

I.3.3 Domaines d'utilisation

Les turbines à gaz s'appliquent dans plusieurs domaines grâce à leur forte puissance massique, fonctionnement continu et compacité: propulsion aéronautique, navale et militaire, production d'électricité, et industrie pétrochimique. Les véhicules routiers ne constituent pas un domaine favorable car les variations rapides de charge dégradent le rendement [79,80,1928].

I.3.3.1 Aéronautique

I.3.3.1.1 Turbocompresseur

Dispositif utilisant les gaz d'échappement d'un moteur à pistons pour comprimer l'air d'admission. Il augmente la puissance massique et volumique grâce à une pression d'admission accrue. L'air comprimé est refroidi par un intercooler avant admission pour augmenter sa densité [8,25,33]. Le système améliore le rendement, particulièrement pour les moteurs Diesel [79,81]. Les modèles récents utilisent des turbocompresseurs à géométrie variable (VGT) avec aubages à incidence réglable pour une meilleure réactivité en régime transitoire.

I.3.3.1.2 Turbine à gaz d'avion

Cœur propulsif des moteurs d'avion modernes, fonctionnant selon un cycle à circuit ouvert et à pression constante. L'air est capté, comprimé dans le diffuseur puis le compresseur, avant d'entrer dans la chambre de combustion où il est réparti en flux primaire (combustion), secondaire (stabilisation de flamme), et tertiaire (régulation de température) [82]. Les gaz chauds traversent la turbine qui entraîne le compresseur, puis se détendent dans la tuyère générant la poussée [79,82].

a Poussée

La poussée est générée par l'accélération de l'air traversant le moteur [79,81]. La poussée résultant de la différence de pression s'exprime :

$$F_{pression} = (p_j - p_a)A_j \quad (I\ 11)$$

La poussée totale est donnée par :

$$F = \dot{m}(c_j - u) + (p_j - p_a)A_j \quad (I\ 12)$$

Avec détente complète :

$$F = \dot{m}(c_j - u) \quad (I\ 13)$$

La poussée augmente en accroissant la vitesse du jet ou le débit massique [79,81]. Puissance de propulsion :

$$P_F = F \cdot u \quad (I\ 14)$$

b Rendement de propulsion

L'énergie apportée au moteur par la combustion s'exprime [79,81] :

$$\dot{Q}_{in} = \dot{m}_{fuel} \cdot PCI \quad (I\ 15)$$

Le travail utile produit correspond à :

$$\dot{W}_{utile} = F \cdot u + \frac{1}{2} \dot{m}(c_j^2 - u^2) \quad (I\ 16)$$

Le rendement thermique s'exprime :

$$\eta_{th} = \frac{\dot{W}_{utile}}{\dot{Q}_{in}} = \frac{F \cdot u + \frac{1}{2} \dot{m}(c_j^2 - u^2)}{\dot{m}_{fuel} \cdot PCI} \quad (I\ 17)$$

Le rendement de propulsion (rendement de Froude) se définit comme [79,81] :

$$\eta_{prop} = \frac{2u}{c_j + u} = \frac{2}{1 + c_j / u} \quad (I\ 18)$$

Ce rendement diminue quand c_j/u augmente [80]. Maximum (100%) atteint quand $c_j = u$, mais poussée nulle.

c Rendement global

$$\eta_{global} = \eta_{th} \times \eta_{prop} = \frac{F \cdot u}{\dot{m}_{fuel} \cdot PCI} \quad (I\ 19)$$

I.3.3.1.3 Moteur à turbopropulseur

La turbine entraîne une hélice de grand diamètre déplaçant une grande masse d'air avec faible variation de vitesse [79,82]. La poussée par la tuyère représente seulement 10% de la poussée totale [79,81]. Considéré comme un moteur à double flux avec taux de dilution très élevé [79,81].

I.3.3.1.4 Moteur à turbojet

Toute la puissance turbine entraîne le compresseur, la propulsion est assurée exclusivement par la poussée générée dans la tuyère [79,82]. Un système de postcombustion peut être ajouté entre la turbine et la tuyère pour augmenter la poussée lors des phases critiques [79,82]. Utilisé couramment sur les avions militaires [79,80], mais présente une consommation spécifique de carburant élevée à faible nombre de Mach [79,81].

I.3.3.1.5 Moteur à turboréacteur

Les deux étages de turbine basse pression entraînent le ventilateur, tandis que l'étage de turbine haute pression entraîne le compresseur [79,82]. La quantité totale d'air admise s'exprime :

I.3.3.1.6 Moteur à turbofusée

Système intermédiaire entre le moteur fusée et le turboréacteur [79,80]. La turbine est entraînée par les gaz issus de la chambre de combustion du moteur fusée. Un réchauffeur placé en aval remplace la chambre de combustion conventionnelle. Utilisé pour assister les avions lors du décollage ou pour le transport vers les stations spatiales [79,80].

I.3.3.1.7 Moteur d'avion nucléaire

La chambre de combustion est remplacée par un échangeur de chaleur où l'énergie du réacteur nucléaire est transférée à l'air via un fluide caloporteur [74,5,6]. Le compresseur est entraîné par une turbine à air chaud opérant dans un environnement thermique moins extrême.

I.3.3.2 Turbines à gaz pour véhicules

I.3.3.2.1 Automobiles

Des recherches visent à concevoir des turbomoteurs adaptés aux voitures avec échangeurs de chaleur pour optimiser la consommation [79,80]. Résultats positifs pour les moteurs dépassant 200 kW, mais les variations rapides de charge dégradent fortement le rendement [72,75], limitant l'adoption généralisée.

I.3.3.2.2 Locomotives ferroviaires

Les trains longue distance utilisent des locomotives à turbines à gaz, notamment avec transmission électrique. Ce système offre des performances élevées tout en réduisant la dépendance aux moteurs à combustion classiques [79,80,1].

I.3.3.2.3 Suralimentation par les gaz d'échappement

La majorité des camions lourds et locomotives diesel sont équipés de systèmes de suralimentation. Les turbines entraînées par les gaz d'échappement actionnent des compresseurs d'air, augmentant la pression d'admission et améliorant le rendement global [79,80,10].

I.3.3.3 Turbines à gaz pour la production d'énergie électrique

a Cycle de Brayton

Principe thermodynamique fondamental des turbines à combustion. Trois types de cycles : simple, combiné, et cogénération. Deux catégories : machines dérivées des moteurs d'avion (légères, haut régime) et turbines industrielles (robustes, stationnaires) [79,82,84]. Carburants : kérosène, gaz naturel, ou gaz issus de charbon/biomasse [82,84].

b Cycle simple

Faciles à installer et à mettre en service rapidement, démarrage en temps réduit. Utilisées comme groupes électrogènes de secours ou pour production de pointe [65,1,3]. Rendements entre 30 et 35%. Les turbines utilisent des volumes d'air très importants (3 à 4 fois la quantité stœchiométrique), produisant des gaz d'échappement à plus de 500°C. Technologies avancées réduisent les émissions de NO_x à moins de 25 ppmv, voire moins de 5 ppmv avec SCR [54-60].

c Cycle combiné gaz vapeur

Les gaz d'échappement de la turbine à gaz génèrent de la vapeur dans une chaudière de récupération, entraînant une turbine à vapeur. Puissance unitaire d'environ 400 MW avec rendement global jusqu'à 60% [66,72,25].

d Cycle de cogénération

Turbine à gaz associée à une chaudière de récupération produisant de la vapeur pour un procédé industriel. Une turbine à vapeur à contrepression peut être intégrée pour optimiser l'utilisation énergétique. Rendement global de 50 à 60% [65,66,4,21].

e Unité d'énergie totale

La chaudière à vapeur récupère l'énergie des gaz d'échappement à haute température. La vapeur produite sert au chauffage des locaux ou autres besoins thermiques. Rendement global entre 60% et 75% [65,66,4,21].

f Centrale nucléaire

Configuration en circuit fermé utilisant l'hélium comme fluide réfrigérant et fluide de travail. Conditions : pression 25 à 50 bar, température 1000 à 1200 K. La turbine entraîne le compresseur et le générateur électrique.

Pour les réacteurs à neutrons rapides refroidis au gaz, le circuit primaire en hélium transfère son énergie à un circuit secondaire (mélange He N₂) comprenant turbine à gaz et générateur de vapeur. Le circuit tertiaire est un cycle vapeur classique. Rendement global d'environ 45%, pouvant atteindre 48% avec cycle supercritique [74,5,6].

I.3.3.4 Turbines à gaz dans l'industrie pétrochimique

Principales applications incluent la fourniture d'air préchauffé aux chaudières, la génération de gaz chauds pour procédés industriels, et la production d'acide nitrique. Avantages : souplesse d'utilisation des combustibles et valorisation de gaz résiduels [82-85,7]. Le refroidissement de l'air à l'admission réduit la taille du compresseur et le travail nécessaire [33].

I.3.3.5 Turbines à gaz dans le transport des hydrocarbures

Trois types de machines pour compression de gaz : compresseurs centrifuges entraînés par turbines à gaz, compresseurs à pistons entraînés par moteurs à gaz, et compresseurs entraînés par moteurs électriques. Les turbines à gaz sont particulièrement adaptées aux compresseurs centrifuges (technologies similaires) [83-85,7]. Configuration typique : turbines à gaz à deux arbres avec transmission directe de puissance par accouplement. Pour puissances jusqu'à 6000 kW, montage possible sur châssis unique entièrement capoté.

Dans la réinjection de gaz, configuration typique comprend trois unités identiques avec deux compresseurs centrifuges HP BP par unité. Le gaz résiduel entre à 70 80 bar effectifs et 60°C dans le compresseur BP, est comprimé jusqu'à 163 bar par le compresseur HP, puis refroidi à 60°C. Le second étage HP comprime de 160 à 321 bar effectifs. Après refroidissement final à environ 85°C, le gaz est injecté dans le puits pour maintenir la pression du réservoir et améliorer la récupération des hydrocarbures [83-85].

1.4 Conclusion

Ce chapitre présente une synthèse générale sur les structures des turbines à gaz, en mettant en évidence leurs principes de fonctionnement, leurs principaux composants et les paramètres déterminants de leurs performances. L'analyse du cycle thermodynamique, des phénomènes de combustion, ainsi que des échanges énergétiques au sein de la machine a permis de souligner l'influence majeure du taux de compression, de la température d'entrée turbine et des conditions d'admission de l'air sur la puissance et le rendement global.

L'étude des différents éléments constitutifs a montré que les performances d'une turbine à gaz résultent d'un compromis entre contraintes thermiques, mécaniques et aérodynamiques. Les pertes de charge, la dégradation progressive des composants et les limitations liées aux matériaux constituent des facteurs clés affectant l'efficacité et la durabilité des installations.

Par ailleurs, la diversité des domaines d'application des turbines à gaz, allant de l'aéronautique à la production d'énergie électrique, en passant par la cogénération et l'industrie des hydrocarbures, confirme leur importance stratégique dans les systèmes énergétiques modernes. La valorisation de la chaleur résiduelle à travers les cycles combinés et de cogénération apparaît comme un levier essentiel pour améliorer le rendement énergétique global.

En conclusion, ce chapitre pose les bases théoriques et technologiques nécessaires à l'analyse approfondie des performances des turbines à gaz. Il constitue un socle de référence pour les développements ultérieurs, orientés vers l'intégration de méthodes avancées de supervision et d'amélioration des performances.

II.1 Introduction

Les turbines à gaz sont des dispositifs mécaniques hautement complexes et centralement symétriques qui convertissent l'énergie thermodynamique en énergie mécanique pour la production d'électricité et d'autres applications industrielles. Bien qu'elles soient reconnues pour leur efficacité énergétique et leur fiabilité, les turbines à gaz subissent inévitablement une dégradation des performances au cours de leur cycle de vie opérationnel. Cette dégradation, résultant de facteurs asymétriques tels que le dépôt de carbone, les dommages mécaniques ou les déformations structurelles, compromet les métriques de performance critiques comme la poussée et la marge de pompage [86].

Comme tout équipement mécanique, les turbines à gaz industrielles présentent les effets de l'usure au fil du temps [87]. La dégradation des performances affecte non seulement l'efficacité opérationnelle mais augmente également les coûts de maintenance, réduit la disponibilité du système et peut compromettre la sécurité des vols dans les applications aéronautiques. Par conséquent, la compréhension approfondie des mécanismes de dégradation, l'identification des facteurs contributifs et le développement de systèmes de surveillance efficaces sont devenus des domaines de recherche prioritaires dans le secteur de l'aviation et de l'industrie énergétique.

La technologie de gestion de la santé des moteurs aéro, qui joue un rôle pivot dans l'amélioration de la sécurité, de l'efficacité et des performances environnementales du secteur de l'aviation, est devenue une direction de recherche prééminente [86]. En amalgamant des capteurs avancés, une analyse rigoureuse des données et des algorithmes sophistiqués d'intelligence artificielle, cette technologie facilite la surveillance en temps réel et la gestion précise de l'état opérationnel du moteur [86]. Cette capacité permet la détection de variations subtiles dans les performances du moteur dans des conditions de température élevée, de pression élevée et de charges aérodynamiques complexes, permettant ainsi l'identification et l'alerte en temps opportun des défaillances potentielles.

II.2 Mécanismes de dégradation des turbines à gaz

II.2.1 Classification générale de la dégradation

La dégradation des turbines à gaz peut être classée selon plusieurs critères. Une différenciation fondamentale distingue la dégradation récupérable de la dégradation non récupérable [87]. La dégradation récupérable fait allusion au fait que le nettoyage du moteur est possible pour certains types de dégradation, permettant ainsi la restauration des performances sans remplacement de composants. En revanche, la dégradation non récupérable nécessite le remplacement ou la réparation des pièces affectées et ne peut être inversée par de simples procédures de nettoyage.

Une autre classification distingue l'encrassement (fouling), où les particules fines adhèrent aux surfaces des aubes, de l'enlèvement de matière résultant de particules plus lourdes ou du frottement [87]. Cette distinction est particulièrement importante car elle détermine les stratégies de maintenance appropriées et les interventions correctives nécessaires.

II.2.2 Encrassement du compresseur (Compressor Fouling)

L'encrassement du compresseur représente l'un des mécanismes de dégradation les plus prévalents et les plus problématiques dans les turbines à gaz industrielles modernes. Ce phénomène est causé par l'adhérence de particules aux surfaces des aubes et des parois annulaires [87]. Les brouillards d'huile ou d'eau sur les surfaces augmentent considérablement la quantité de particules capturées, et typiquement, seules les petites particules (jusqu'à 10 μm) adhèrent à la surface. La fumée, les brouillards d'huile, le carbone et les particules de sel marin constituent des exemples typiques de contaminants responsables de l'encrassement.

L'accumulation de particules de saleté augmente la rugosité de surface et peut modifier la forme de l'aube [87]. Ces changements morphologiques ont des conséquences aérodynamiques significatives qui affectent la distribution de charge à travers les étages du compresseur et modifient les caractéristiques de performance globales du moteur. L'encrassement peut être contrôlé par un système de filtration d'air approprié et peut souvent être inversé dans une certaine mesure par le lavage au détergent des composants.

Les données de terrain ont démontré de manière concluante que l'encrassement est évitable si des filtres appropriés sont utilisés [87]. Le paramètre clé affectant l'encrassement et le taux d'encrassement est la qualité du système de filtration d'air. L'efficacité de filtration est décrite dans la norme EN 779, et des qualités de filtre supérieures peuvent réduire considérablement la dégradation des performances due à l'encrassement [87].




Figure II.1 : Comparaison de l'efficacité fractionnaire pour des éléments filtrants de différents fournisseurs et différentes vitesses frontales à l'état neuf et encrassé [87]

Des recherches ont montré que si un moteur ingère 100 kg/an de contaminants en l'absence de système de filtration dans une application offshore typique, un filtre F5 réduirait cette quantité à environ 21 kg/an, un filtre F6 à 6 kg/an, un système de filtre F7/H10 à 0,2 kg/an, et un système F7/F9/H10 à aussi peu que 0,05 kg/an [87]. Ces données indiquent que l'ingestion

globale de contaminants peut être influencée de plusieurs ordres de grandeur en utilisant un système de filtration d'air approprié, ce qui réduit considérablement le taux de dégradation.

II.2.2.1 Phénoménologie de l'encrassement

Le phénomène d'encrassement peut être décrit par trois phases distinctes [88] :

1. Le transport des contaminants (phase discrète) par l'air (phase continue)
2. Le contact et l'adhésion de la première phase discrète (particule) avec la surface
3. L'adhésion répétée des particules suivantes sur le contaminant précédemment déposé sur la surface

L'analyse expérimentale a révélé des modèles complexes de dépôt sur les aubes de compresseur. Des études utilisant l'injection virtuelle de particules et le suivi lagrangien ont montré que le bord d'attaque représente la région la plus encrassée, tandis que le côté pression est plus affecté par les dépôts près du bord d'attaque de la pointe (première partie de la corde de l'aube), avec certaines zones de l'aube restant presque propres (en particulier dans la zone médiane de la corde) [88]. Le côté aspiration est davantage affecté par les dépôts dans les zones proches du moyeu sur toute la longueur de la corde.

L'effet "château de sable" a été observé dans les installations sur le terrain, où l'adhésion des particules encrassantes avec les surfaces du compresseur et d'autres particules similaires en présence d'eau est notablement augmentée [87]. Ce phénomène explique pourquoi les taux d'encrassement sont significativement plus élevés lorsque la température du point de rosée dépasse la température de refroidissement de l'admission.

II.2.2.2 Impacts sur les performances du compresseur

L'encrassement du compresseur affecte les performances de plusieurs manières interconnectées. Trois effets majeurs déterminent la détérioration des performances du compresseur de turbine à gaz : l'augmentation des jeux en bout d'aube, les changements dans la géométrie de l'aube et les modifications de la qualité de surface de l'aube [87].

Les données expérimentales montrent que la perte de débit du compresseur est réduite deux fois plus que l'efficacité du compresseur par rapport au scalaire diagnostique, qui est un multiplicateur direct sur la caractéristique de la carte du compresseur [87]. La perte de puissance du moteur à pleine charge peut dépasser 10% en considérant cette seule diminution combinée.

Un compresseur dégradé aura également une marge de pompage ou de décrochage réduite [87]. Bien que la marge de pompage réduite puisse ne pas affecter directement le fonctionnement en régime permanent, elle peut réduire les capacités transitoires (par exemple, les charges par blocs ou les charges abandonnées pour les groupes générateurs) et pourrait causer des dommages si d'autres actions sont prises qui réduisent davantage la marge de pompage.

La dégradation d'étage a également un effet cumulatif : un étage dégradé créera des conditions de sortie différentes d'un nouvel étage, et chaque étage suivant fonctionnera plus loin de son point de conception [87]. Alors que dans la nouvelle machine, tous les étages fonctionnaient à leur point d'efficacité optimale aux marges de pompage de conception, la dégradation forcera tous les étages après le premier à travailler à des marges de pompage non optimales et à une efficacité inférieure à celle de conception.

II.2.3 Érosion

L'érosion est l'enlèvement abrasif de matière du parcours d'écoulement par des particules dures ou incompressibles ou des gouttelettes heurtant les surfaces d'écoulement [87]. Ces particules doivent typiquement avoir un diamètre supérieur à 10 μm pour causer l'érosion par impact. Les systèmes de filtration de pointe utilisés pour les applications industrielles peuvent empêcher ces particules plus grandes d'entrer dans le moteur. L'érosion peut devenir un problème pour les moteurs utilisant des gouttelettes d'eau pour le refroidissement de l'admission ou le lavage à l'eau.

Le comportement des particules concernant l'adhésion à une surface et le rebond dépend de la température [87]. Des recherches ont montré que les caractéristiques de restitution probabilistes des particules affectent significativement la dynamique des particules dans les turbines à écoulement axial et que l'impact des particules sur les surfaces de turbine peut varier considérablement en fonction des conditions de température.

II.2.4 Corrosion et corrosion à chaud

La corrosion à chaud (hot corrosion) est une forme d'oxydation accélérée qui se produit en raison de l'ingestion de sels (sulfates et sels de chlorure) par l'admission d'air du moteur en combinaison avec le soufre dans les combustibles de turbine à gaz [87]. Ces problèmes peuvent être contrôlés par la filtration de l'air et le traitement du combustible.

La corrosion et l'oxydation modifieront le parcours d'écoulement de deux manières : elles augmentent la rugosité de surface, mais peuvent également causer l'enlèvement de matière, en particulier au niveau des bords d'attaque et du bord de fuite des aubes [87]. Les aubes de turbine, fonctionnant à ou près de conditions d'étranglement, sont très sensibles aux changements de section d'écoulement.

L'augmentation de la rugosité de surface provoque des couches limites plus épaisses sur les aubes et les parois latérales, et peut ainsi réduire la capacité d'écoulement, en particulier près des conditions d'étranglement [87]. Des recherches ont montré que même une modeste détérioration de la qualité de surface a un impact mesurable sur les performances aérodynamiques de la section turbine.

II.2.5 Frottement et usure (Rubbing Wear)

Le frottement est causé lorsqu'une surface rotative frotte contre une surface stationnaire [87]. De nombreux moteurs utilisent des surfaces abrasables, où une certaine quantité de frottement est autorisée pendant le rodage du moteur, afin d'établir des jeux appropriés. Les paliers ont

tendance à devenir plus mous (réduction de la rigidité) en raison d'une augmentation du jeu au fil du temps qui provoque une augmentation de l'amplitude orbitale du tourillon. L'orbite plus grande peut entraîner l'enlèvement de matière aux extrémités des aubes et aux joints, ce qui augmentera les jeux des joints ou des extrémités.

Le maintien des jeux en bout d'aube est particulièrement problématique dans la section turbine, en raison des changements extrêmes de températures entre un moteur froid et un moteur accélérant à pleine charge [87]. Dans de nombreuses conceptions, les composants stationnaires se dilatent à un taux différent des composants rotatifs. De nombreuses nouvelles conceptions de turbines utilisent des joints abrasables pour minimiser ces jeux. Cependant, le cas le plus grave, qui est généralement après un redémarrage à chaud, déterminera le jeu minimal pour le moteur.

Des études ont rapporté une réduction de l'efficacité d'une turbine multi-étages de 0,6% lorsque les jeux radiaux ont été augmentés de 0,5% de la hauteur de l'aube aux rotors et 0,4% de la hauteur de l'aube aux stators à 0,8% de la hauteur de l'aube aux rotors et aux stators [87]. En plus d'une efficacité réduite, les jeux supplémentaires augmenteront également le blocage d'écoulement axial et provoqueront ainsi une réduction du débit et des vitesses accrues dans l'écoulement principal.

II.2.6 Dommages par corps étrangers (Foreign Object Damage)

Les dommages peuvent également être causés par des objets étrangers frappant les composants du parcours d'écoulement [87]. Ces objets peuvent entrer dans le moteur avec l'air d'admission ou sont le résultat de morceaux cassés du moteur lui-même. Des morceaux de glace se détachant de l'admission ou une accumulation de carbone se détachant des buses de combustible peuvent également causer des dommages.

Les observations sur le terrain après des essais de longue durée ont révélé que les facteurs asymétriques résultant en dégradation du moteur incluent le dépôt de carbone asymétrique et les blessures asymétriques aux aubes de turbine causées par la chute de carbone [86].



Figure II.2 : (a) Dépôt de carbone asymétrique dans le moteur et (b) l'une des aubes de turbine frappée par la chute de carbone [86].

II.3 Dégradation de la section chaude (Hot Section)

Alors que le compresseur d'une turbine à gaz est principalement affecté par l'encrassement, la section turbine verra les effets de l'oxydation et de la corrosion à chaud [87]. De plus, l'encrassement des passages de refroidissement peut être rencontré, ce qui peut altérer l'efficacité de l'élimination de la chaleur.

II.3.1 Mécanismes de dégradation dans la section turbine

Tout comme pour la section compresseur, la section turbine subit les problèmes suivants résultant de la dégradation : augmentation des jeux en bout d'aube, changements dans la géométrie de l'aube et modifications de la qualité de surface de l'aube [87]. La corrosion a tendance à altérer le parcours d'écoulement de deux manières : elle augmente la rugosité de surface, mais peut également enlever de la matière, en particulier au niveau des bords d'attaque et du bord de fuite des aubes.

Les aubes de turbine, fonctionnant à ou près de conditions d'étranglement, sont très sensibles aux changements de section d'écoulement [87]. De plus, les changements dans la capacité d'écoulement de la section turbine modifieront ultérieurement les points de fonctionnement du compresseur du moteur. L'augmentation de la rugosité de surface provoque des couches limites plus épaisses sur les aubes et les parois latérales, et peut ainsi réduire la capacité d'écoulement, en particulier près des conditions d'étranglement.

Des données ont montré que même une modeste détérioration de la qualité de surface a un impact mesurable sur les performances aérodynamiques de la section turbine [87]. Par exemple, pour une turbine à deux étages, des pertes d'efficacité de 2,5% ont été trouvées pour

une rugosité de surface de 10,2 μm par rapport aux aubes lisses. Il a également été constaté que les différences les plus prononcées apparaissent au point de fonctionnement optimal de la turbine, alors que l'efficacité loin de l'optimum était presque la même pour les aubes rugueuses et lisses.

II.3.2 Impact de l'enlèvement de matière

Cependant, si la dégradation de la section turbine conduit à l'enlèvement de matière, en particulier dans la zone de l'aubure, l'effet opposé sera observé : la capacité d'écoulement augmente pour un rapport de pression donné [87]. Parce que la capacité d'écoulement de toute aubure est limitée par la section de col effective, l'érosion du bord de fuite provoque l'augmentation de la section de col et l'angle d'écoulement de sortie devient plus axial. Cela signifie une réduction de la déviation dans le stator et le rotor, ce qui conduira à une extraction de travail réduite pour cet étage et à une capacité d'écoulement accrue.

Puisque les aubures de turbine constituent une restriction d'écoulement, tout changement dans la capacité d'écoulement de la section turbine aura également un impact sur les points de fonctionnement que le compresseur du moteur verra. Les données de terrain montrent un exemple où la dégradation de la turbine du générateur de gaz, tout en maintenant l'efficacité, a conduit à une réduction de la capacité d'écoulement [87].

II.3.3 Évaluation de la qualité de surface

Une évaluation approfondie effectuée sur un moteur Mars 100 après un retour de révision atteignant l'intervalle de service typique a fourni des informations précieuses sur la dégradation de la section chaude [87]. Cette unité était bien entretenue et fonctionnait à charge partielle sans frottements significatifs des composants rotatifs. Il n'y avait pratiquement pas de dégradation de performance non récupérable de l'état neuf à l'état tel que reçu.

Les données de finition de surface de la turbine du générateur de gaz ont été obtenues, montrant que tous les composants seraient conformes aux exigences de finition de surface des moteurs neufs même après avoir atteint l'intervalle entre révisions (TBO) [87]. Cette information, ainsi que le bon état général de tous les composants du parcours d'écoulement, des joints, des carters/carénages et des paliers, ont aidé à expliquer la constatation telle que reçue d'une perte de performance négligeable par rapport à l'état neuf.

Tableau 1 : État de surface des distributeurs de l'étage 1 [90]

Numero de serie	Bord de fuite de l'extrados de l'aube gauche	Bord de fuite de l'intrados de l'aube droite	Bord d'attaque de l'aube droite	Carenage interieur (inner shroud)
1	0,889	0,932	1,143	0,843
2	1,029	0,537	1,190	0,803
3	0,937	0,598	1,370	0,878
4	0,683	0,771	1,144	0,598
5	0,719	0,657	1,324	0,776
6	0,633	0,710	1,389	0,813
7	0,984	0,675	0,990	0,556
8	0,860	0,624	0,651	0,562
9	0,671	0,570	1,116	0,595
10	0,644	0,524	1,210	0,643
Moyenne	0,805	0,660	1,153	0,707

Tableau 2 : État de surface des aubes de turbine de l'étage 1 [90]

Numéro de série	Intrados (Pressure Side)	Extrados (Suction Side)	Bord d'attaque	Plateforme
1	1,137	0,965	0,908	1,024
2	0,952	0,754	0,741	1,008
3	0,954	0,767	0,684	0,879
4	0,910	0,927	0,825	0,894
5	1,095	0,956	0,798	1,073
6	0,922	0,837	0,668	0,722
7	0,989	0,817	0,698	0,752
8	0,983	0,763	0,668	0,779
9	1,016	0,687	0,789	0,890
10	0,973	0,908	0,798	0,878
Moyenne	0,993	0,838	0,758	0,890

Tableau 3 : État de surface des distributeurs de l'étage 2 [90]

Numéro de série	Bord de fuite de l'extrados de l'aube gauche	Bord de fuite de l'intrados de l'aube droite	Bord d'attaque de l'aube droite	Carénage intérieur (Inner Shroud)
1	0,638	0,698	0,516	0,540
2	0,903	0,867	0,543	0,721
3	0,660	0,832	0,546	0,975
4	0,648	0,841	0,510	0,759
5	0,733	0,913	0,586	0,786
6	0,610	0,843	0,486	0,803
7	0,637	0,829	0,579	0,843
8	0,686	0,637	0,500	0,889
9	0,492	1,056	0,622	0,856
10	0,851	0,776	0,594	0,805
Moyenne	0,686	0,829	0,548	0,797

II.4 Facteurs influençant la dégradation

II.4.1 Conditions environnementales

Les turbines à gaz fonctionnent dans des conditions rigoureuses telles que le brouillard, la poussière, le sel, et de plus, les opérations fréquentes d'arrêt-démarrage font également partie des environnements difficiles où la turbine à gaz fonctionne [89]. Les performances des capteurs qui sont destinés à contrôler et surveiller le processus de la turbine à gaz, qui ont été largement équipés dans différents types de machines et sous-systèmes des turbines à gaz, se dégradent généralement lorsqu'ils sont exposés à de tels environnements difficiles pendant de longues périodes.

La température ambiante de l'air d'admission a un impact direct sur les performances de la turbine à gaz et sur les niveaux d'émissions [89]. Il a été rapporté qu'une température ambiante basse de l'air d'admission conduit à une augmentation de l'émission de carbone de la turbine. Le type de combustible utilisé dans le processus de combustion a également un impact direct sur le niveau d'émission de gaz (c'est-à-dire l'émission de carbone).

Des données de terrain ont démontré l'influence significative du point de rosée sur les taux d'encrassement [87]. Une observation importante est qu'il y a un encrassement significatif pendant les parties de l'année où la température du point de rosée est constamment supérieure à la température de l'air d'admission refroidi. Lorsque la température du point de rosée descend en dessous de cette température, le taux d'encrassement est notablement réduit [90].

II.4.2 Conditions opérationnelles

Il a été détecté que les performances des turbines à gaz sont fonction de nombreux paramètres opérationnels et variables environnementales [89]. Les impacts de ces variables sur lesdites performances peuvent être atténués en utilisant des techniques de surveillance puissantes. Ainsi, les coûts de maintenance supplémentaires, les coûts de défauts de composants et les coûts de main-d'œuvre peuvent être éliminés.

L'impact de la dégradation sur les turbines à gaz à deux arbres dépend du mode de contrôle dans lequel elles se trouvent, c'est-à-dire si la vitesse du générateur de gaz ou la température de combustion sont les facteurs limitants [87]. De plus, la méthode et l'emplacement de mesure de la température de contrôle détermineront le comportement du moteur dans des conditions dégradées.

Les moteurs à arbre unique, fonctionnant à vitesse constante, montreront un comportement de dégradation différent de celui des moteurs à deux arbres [87]. Parce que les composants sont couplés mécaniquement et thermodynamiquement, leurs points de fonctionnement s'influencent mutuellement. En particulier, l'aubure de turbine est typiquement étranglée, et détermine ainsi le débit et, dans les machines à deux arbres et les machines multi-corps, la vitesse du générateur de gaz est déterminée par la vitesse où les puissances de la turbine et du compresseur sont égalisées.

II.4.3 Qualité du combustible et de l'air

La corrosion à chaud se produit en raison de l'ingestion de sels (sulfates et sels de chlorure) par l'admission d'air du moteur en combinaison avec le soufre dans les combustibles de turbine à gaz [87]. Les problèmes peuvent être contrôlés par la filtration de l'air et le traitement du combustible. Une turbine à gaz alimentée au gaz naturel est préférable car elle a un niveau d'émission de gaz plus faible par rapport aux combustibles diesel et pétroliers [89].

L'analyse de l'impact de la qualité du combustible sur les performances a montré que le type de combustible utilisé dans le processus de combustion a un impact direct sur le niveau d'émission de gaz [89]. Les données de terrain ont confirmé que l'utilisation de combustibles plus propres et d'une maintenance appropriée peut maintenir la dégradation de la section chaude à un niveau très faible.

II.4.4 Conception et caractéristiques du moteur

Il existe un impact des caractéristiques de conception du moteur sur la dégradation non récupérable [87]. Une caractéristique de conception qui peut ralentir la dégradation est l'effort pour faire correspondre thermiquement les pièces fixes et rotatives du moteur. Cela signifie que la croissance thermique des composants est appariée de sorte que les jeux de fonctionnement restent constants pendant les cycles thermiques (c'est-à-dire le changement de charge ou le démarrage et l'arrêt).

Les étages du compresseur du moteur à vitesse aérodynamique de conception sont assez uniformément chargés, mais à basse vitesse aérodynamique (à haute température ambiante ou charge partielle), les étages avant deviennent plus chargés, et vice versa pour la haute vitesse aérodynamique (à basses températures ambiantes) [87]. L'encrassement du compresseur peut également changer le chargement des étages à travers le compresseur, impactant ainsi l'efficacité et la capacité d'écoulement.

II.5 Systèmes de filtration de l'air d'admission

II.5.1 Importance de la filtration

Les turbines à gaz industrielles peuvent se permettre des systèmes de filtration d'admission très efficaces [2,5]. Les systèmes modernes peuvent virtuellement éliminer l'ingestion de particules dans le compresseur du moteur qui peuvent causer l'érosion. Le compromis pour les systèmes de filtration réside dans la taille, le poids et le coût d'une part versus l'efficacité de filtration et la faible perte de pression d'autre part.

II.5.2 Performance des systèmes de filtration

Des recherches ont rapporté une comparaison de la perte de puissance de turbine à gaz pour deux systèmes de filtration d'air différents utilisés sur des turbines à gaz de 165 MW [87]. Les systèmes de filtration sont soit un système à 2 étages, soit un système à 3 étages. Le système à 3 étages provoque une réduction significative des particules plus fines entrant dans le moteur.

La perte de puissance après 3000 heures de fonctionnement était de 4% avec le système à 2 étages et de 2% avec le système à 3 étages.

Les données de terrain d'un moteur Mercury 50 ont démontré l'efficacité remarquable de l'amélioration des médias filtrants [87]. Une fois qu'un média filtrant amélioré (filtre HEPA) a été appliqué au système de filtration d'admission, toute dégradation du compresseur a été essentiellement éliminée malgré le fait d'être toujours susceptible à un point de rosée bien supérieur à la température de consigne du refroidisseur.

Cette observation de réduction de l'encrassement a validé ce média filtrant amélioré [87]. Cela suggère qu'une particule encrassante qui passait à travers le système de filtration standard d'origine ne passe pas par l'admission. Cette petite particule encrassante s'accumule sur les aubes et aubes de compresseur à un taux significativement plus élevé en présence d'eau condensante lorsque la température du point de rosée dépasse la température de consigne du refroidisseur.

II.5.3 Impact sur les performances à long terme

L'une des questions ouvertes dans un certain nombre de publications était la capacité de la poussière très fine à modifier suffisamment la forme de l'aube et la qualité de surface pour affecter une détérioration des performances [87]. Les données montrent les performances d'un moteur avec un système de filtration d'air qui filtre tout sauf les plus petites particules. Il semble donc que les données indiquent que les très fines particules ne causeront en effet aucun encrassement du tout.

Cela prouve également une affirmation selon laquelle l'effet du type de filtration d'air sur l'encrassement l'emporte de loin sur tout effet de la conception du moteur ou de la susceptibilité du moteur [87]. Le paramètre clé affectant l'encrassement et le taux d'encrassement est la qualité du système de filtration d'air, et non les caractéristiques de conception inhérentes du moteur lui-même.

II.6 Surveillance des turbines à gaz

II.6.1 Systèmes de surveillance conventionnels

Les systèmes de surveillance conventionnels qui dépendent de la main-d'œuvre humaine pour diagnostiquer et signaler les erreurs ne sont plus compatibles avec l'expansion considérable du système électrique [89]. Le déploiement de capteurs fabriqués à partir de matériaux semi-conducteurs pour détecter les fuites de gaz présente un inconvénient majeur en termes de mauvaise sensibilité au gaz.

La surveillance de l'état du moteur et l'application de schémas de maintenance appropriés réduisent à leur tour les dépenses de maintenance et du cycle de vie des turbines à gaz [89]. L'analyse du parcours de gaz (GPA) a été introduite pour la première fois en 1969 et reste une technologie durable pour accéder aux composants dégradés de la turbine à gaz et évaluer ses conditions. Cette technique est largement utilisée pour la surveillance de l'état des turbines à gaz et a un impact implicite sur la maintenance.

II.6.2 Instrumentation et méthodologie diagnostique

Certains moteurs ont une instrumentation standard étendue utilisée pour la surveillance de la santé et à des fins diagnostiques [87]. Par exemple, les moteurs Mercury 50 et Titan 250 disposent d'une telle instrumentation pour isoler chaque module de performance contribuant au comportement global du moteur et pour effectuer des diagnostics de modèle afin d'identifier les défauts du moteur et de l'instrumentation.

La température est mesurée à l'admission, à la sortie du compresseur, à la sortie du récupérateur, entre turbines et à l'échappement de la turbine [87]. La pression est mesurée à l'admission, à travers le filtre jusqu'à l'admission du compresseur, à la sortie du compresseur, à la sortie du récupérateur, à l'admission de la turbine, entre turbines et à l'échappement. Les vitesses d'arbre, la puissance, le débit de combustible et d'autres instrumentations plus spécialisées peuvent être incluses pour une granularité supplémentaire, comme pour les réseaux d'écoulement secondaires.

Le débit d'air d'admission est mesuré avec des mesures de chute de pression d'admission du compresseur calibrées aux valeurs mesurées en cellule d'essai [87]. Toutes ces mesures sont traitées pour la tendance et pour l'entrée dans des modèles de performance de moteur représentatifs. En faisant correspondre le modèle aux données mesurées, les caractéristiques du modèle sont mises à l'échelle. Les scalaires de composants peuvent être utilisés pour diagnostiquer les défauts de composants du moteur ou d'instrumentation.

II.6.3 Surveillance de la chambre de combustion

Les turbines à gaz, avec leurs performances remarquables dans le secteur de l'énergie, sont des centrales fiables et à établissement rapide [89]. Le nouveau siècle assiste à une expansion remarquable des turbines à gaz de petite taille, qui sont devenues stratégiquement essentielles dans le secteur de la production d'énergie. Les unités internes des turbines à gaz sont très complexes et nécessitent des systèmes experts de haute qualité pour la surveillance et le contrôle de chacune, ce qui n'est pratiquement pas possible.

Les turbines à gaz fonctionnent selon le principe des opérations de combustion qui incluent de multiples paramètres géométriques et physiques [89]. Cela rend le processus de combustion qui a lieu à l'intérieur de la chambre à gaz de la turbine un processus très complexe. Il est également compliqué à surveiller. Le flux de chaleur impactant les parois de la chambre à gaz est un opérande intégral. Cette variation du flux de chaleur impacte les paramètres de distribution, spatiaux et temporels, qui contrôlent le processus de combustion.

Cette variation peut conduire à des occurrences non désirées telles que la perte de performance du processus de combustion qui impacte le niveau de génération de la turbine à gaz [89]. Des dysfonctionnements, tels que l'erreur de brûleur et l'instabilité de la flamme, sont causés en raison de l'instabilité du processus de combustion. Une surveillance appropriée de ces changements/variations participe à son tour à maximiser les performances de la turbine à gaz et à maintenir une efficacité élevée.

II.6.4 Caractéristiques du tourbillon (Swirl)

Dans les études de parcours de gaz dans le système de combustion, la complexité dynamique a lieu lors de la considération de la propagation du gaz à travers la turbine [89]. La turbulence dans le mouvement des produits du système de combustion à l'intérieur du parcours de la turbine sous forme d'amas en spirale résulte du soi-disant tourbillon (swirl). Le mouvement des amas en spirale à l'intérieur de la turbine à gaz doit être en ligne droite pour éviter l'impact du tourbillon.

Pour surveiller les données de retour du mouvement du produit du système de combustion afin de juger de ses conditions et de son état de santé, il est obligatoire d'évaluer l'angle de tourbillon au moment de l'utilisation des profils de température du gaz en aval [89]. Des opérations d'imagerie laser ont été utilisées pour suivre le processus de combustion de la turbine, ce qui a déterminé l'angle de tourbillon. L'imagerie laser est une approche coûteuse mais, d'autre part, ne donne pas un état précis des conditions du système de combustion.

Alternativement, la modélisation numérique du système de combustion est réalisée en utilisant le modèle de dynamique des fluides numérique (CFD) [89]. Outre leur haute précision et leurs performances, les modèles CFD sont prouvés être des consommateurs de coûts de calcul élevés. Un réseau de neurones artificiels (ANN) est utilisé pour développer les modèles de boîte noire et de boîte blanche pour surveiller le système et obtenir de bons résultats. Le résultat satisfaisant de ces approches est dû à leurs configurations non paramétriques et non linéaires.

II.7 Méthodes de diagnostic et de surveillance avancées

II.7.1 Approches basées sur les modèles

Les méthodes de diagnostic de défauts internes du moteur sont catégorisées en trois sections : orientées données, orientées modèle et approche hybride [89]. L'approche orientée modèle nécessite une connaissance approfondie du modèle de turbine à gaz et des sous-systèmes où le modèle de défauts internes peut être simulé en utilisant ces connaissances exportées. Cette approche est susceptible de présenter différents défis en raison de la complexité du modèle de turbine à gaz.

Les approches orientées modèle sont basées sur l'analyse mathématique qui est destinée à l'établissement de modèles mathématiques de diagnostic de défauts [89]. Bien que ces méthodes offrent une compréhension physique approfondie des mécanismes de dégradation, elles nécessitent une connaissance détaillée des caractéristiques de conception et de fonctionnement du moteur, ce qui peut limiter leur applicabilité pratique.

II.7.2 Approches basées sur les données

D'autre part, le modèle orienté données est réservé pour une haute précision de détection de défauts ; il a employé des réseaux de neurones ou d'autres approches d'apprentissage profond [89]. La précision des approches orientées données dépend de la performance de la phase d'entraînement. L'approche de diagnostic de capteur basée sur l'exploration de données

utilise toutes les informations de détection historiques obtenues à partir des unités de turbine à gaz.

Ces méthodes (apprentissage automatique) sont utilisées pour l'entraînement sur les données de détection et, par conséquent, pour être utilisées pour les tests où les deux résultats peuvent être comparés pour évaluer l'efficacité de la méthode [89]. Le diagnostic de défauts utilisant une approche orientée données présente de multiples avantages tels que le modèle est entraîné par des données réelles (données de détection historiques) ; par conséquent, il donne un processus de détection bon et fiable proche des capteurs du monde réel.

L'extraction de caractéristiques est vitale pour l'efficacité de détection utilisant des approches orientées données [89]. Conventionnellement, la transformée de Fourier rapide (FFT) est utilisée pour effectuer une analyse de fréquence des données et pour produire la représentation dans le domaine fréquentiel de celles-ci. L'ondelette, d'autre part, peut produire des caractéristiques plus fiables en générant une présentation temps-fréquence des données originales de sorte que les informations du domaine temporel et du domaine fréquentiel sont utilisées pour l'attribution des données.

II.7.3 Approches hybrides

Les approches hybrides sont, d'autre part, faites pour aborder les défis rencontrés dans les technologies orientées modèle et orientées données [89]. Elles sont plus susceptibles d'être désirées pour atteindre une haute précision en moins de temps où aucun des modèles précédents ne le permet. Puisque le modèle hybride est fait d'une combinaison de deux méthodes différentes des modèles précédents pour répondre à l'amélioration souhaitée des performances, le compromis entre les métriques de performances est qualifié.

Certaines méthodes sont davantage axées sur les applications en temps réel où moins de temps de traitement est fourni, et d'autres sont davantage axées sur la précision (débit) et cela est essentiel pour d'autres types d'applications qui favorisent des débits élevés [89]. Le modèle de détection de défauts des dispositifs de détection dans les turbines à gaz basé sur la surveillance des signaux de capteur illustre cette approche intégrée.

II.7.4 Réseaux de neurones artificiels pour la surveillance

Le réseau de neurones artificiels (ANN) est parmi ces outils qui surpassent le diagnostic de défauts de capteur [89]. La popularité des réseaux de neurones artificiels a largement augmenté dans les applications mécaniques et les domaines industriels. Un grand nombre d'applications industrielles sont maintenant modélisées en utilisant le réseau de neurones artificiels. Il a été compté sur (ANN) par ces applications en raison de sa capacité d'approximation à grande vitesse et de sa capacité d'apprentissage de problèmes non linéaires complexes ayant lieu dans le secteur mentionné.

Plusieurs méthodes, incluant le diagnostic de défauts, la modélisation et les optimisations de systèmes, ont été illustrées dans la recherche récente [89]. Ces travaux ont été réalisés entre 2007 et 2017 ; le matériel le plus requis que l'ANN demande pour fonctionner est des données en grandes quantités, et il demande également une configuration de paramètres

d'entrée appropriée. La prédiction instantanée des propriétés de vitesse et de température dans les structures d'écoulement a été proposée en utilisant un modèle de prédiction basé sur l'ANN.

Un réseau de neurones Elman basé sur une rétroaction de sortie cachée (OHFEN) est utilisé pour la détection de défauts dans une turbine à gaz en enquêtant sur les conditions des aubes de la turbine [89]. L'approche peut indiquer si les aubes fonctionnent en douceur ou non. Le modèle ANN a été créé pour la mise en œuvre d'un modèle de diagnostic de réseau multi-neuronal pour l'évaluation de l'état de la turbine à gaz. Deux types d'algorithmes d'optimisation ont été appliqués au réseau de neurones multi-étages pour améliorer la précision du diagnostic. Ces algorithmes étaient la régularisation bayésienne et Levenberg-Marquardt.

II.7.5 Applications de l'intelligence artificielle

L'expansion des données dans divers domaines a entraîné le besoin de méthodes intelligentes et à moindre perte pour le traitement [89]. Les outils d'apprentissage automatique et profond sont des options faisables. Les outils d'apprentissage automatique ont été utilisés pour classer les caractéristiques de lecture des capteurs. L'extraction de caractéristiques est requise lors de l'utilisation d'outils d'apprentissage automatique à cette fin. Cependant, avec les outils d'apprentissage profond, l'étape d'extraction de caractéristiques est dispensée.

Une précision plus élevée de surveillance est obtenue en utilisant l'apprentissage profond tel qu'un réseau de neurones [89]. Pour adopter tout outil d'apprentissage automatique ou d'apprentissage profond, des applications insensibles et à haut risque telles que la surveillance de turbine à gaz, la précision de ces outils doit être optimisée à un niveau tel qu'ils puissent être fiables dans leurs tâches assignées.

Les réseaux de neurones dynamiques ont été utilisés pour la détection d'anomalie de signal en effectuant une cartographie entrée-sortie des données de capteur [89]. Un réseau de neurones de régression générale (GRNN) est utilisé pour la conception de réseau de détection automatique qui représente l'architecture optimisée du diagnostic de défauts de capteurs par la température d'admission d'échappement de la turbine à gaz. Une machine d'apprentissage extrême bayésienne clairsemée (SBELM) a été présentée, où le classifieur multi-sortie a été établi en utilisant un classifieur de signal-sortie utilisant la technologie clairsemée de la machine d'apprentissage extrême.

II.8 Modélisation du comportement dynamique

II.8.1 Approches de modélisation avancées

Jusqu'à présent, la popularité des réseaux de neurones artificiels a largement augmenté dans les applications mécaniques et les domaines industriels [89]. Un grand nombre d'applications industrielles sont maintenant modélisées en utilisant le réseau de neurones artificiels. On a compté sur lui (ANN) par ces applications en raison de sa capacité d'approximation à grande vitesse et de sa capacité d'apprentissage de problèmes non linéaires complexes ayant lieu dans

le secteur mentionné. Il est également connu pour sa flexibilité de solutions fournies pour les applications industrielles.

Un système de surveillance est l'une de ces applications intéressantes où l'ANN est appliquée [89]. Plusieurs méthodes, incluant le diagnostic de défauts, la modélisation et les optimisations de systèmes, ont été illustrées. Ces travaux ont été réalisés entre 2007 et 2017 ; le matériel le plus requis que l'ANN demande pour fonctionner est des données en grandes quantités, et il demande également une configuration de paramètres d'entrée appropriée.

La prédiction instantanée des propriétés de vitesse et de température dans les structures d'écoulement a été proposée en utilisant un modèle de prédiction basé sur l'ANN [89]. Les résultats obtenus du modèle proposé se sont révélés améliorés par rapport aux résultats du modèle dynamique maximal. La signature de puissance dynamique dans le processus de soudage a été surveillée en utilisant l'ANN, et les résultats ont été comparés avec ceux obtenus du modèle de régression. Cependant, les performances des deux ont été comparées, et les résultats ont montré que le modèle ANN est plus fiable en termes de qualité des données.

II.8.2 Surveillance des vibrations et détection de défauts

Actuellement, le domaine de surveillance de processus traité s'appuie sur des fonctions distinctes fournissant un ensemble d'outils solides pour améliorer les opérations de l'équipement de processus et pour garantir la proportion optimale coût/qualité [89]. L'un des principaux exercices dans la conception traitée de décisions de défauts est la surveillance des vibrations dans les machines rotatives qui est toujours un motif chaud dans les secteurs de processus maximum.

Le plan de la configuration observée fournira les données de début pour une méthodologie démonstrative pour ces machines afin de garantir leur protection contre la défaillance et d'évaluer leur conduite énergétique avec précision [89]. Les approches de modélisation conventionnelles de ce type de machine ne peuvent pas présenter leurs comportements dynamiques textuellement en raison des complications exactes considérablement non linéaires de systèmes comparables ; d'autre part, ce sont des procédures élevées.

Par conséquent, il y a une formidable nécessité élargie de créer des approches inutilisées pour garantir l'affichage exact des miracles intérieurs distants de configurations comparables [89]. C'est le cas des turbines à gaz, qui sont soumises à plusieurs phénomènes instables, qui sont horaires méchantes à interpréter en raison des problèmes de leurs complications dynamiques et de leur contexte opérationnel.

II.8.3 Prédiction de la dégradation des performances

La recherche récente a proposé une méthode de prédiction de la dégradation des performances pour les moteurs de turbine à gaz légers basée sur des données limitées [86]. La prédiction de la dégradation des performances modélisée avec la méthode GA-LSTM est validée en utilisant des données expérimentales. L'erreur de prédiction maximale de la poussée est de 70 daN, et l'erreur en pourcentage absolue moyenne (MAPE) est inférieure à 0,04.

Cette étude fournit une approche pratique pour mettre en œuvre la prédiction de la dégradation des performances dans les systèmes de surveillance de la santé afin d'améliorer la fiabilité, l'économie et les performances environnementales des moteurs de turbine à gaz [86]. Diverses types de signaux embarqués sont pris en considération parmi les données expérimentales. Seuls le temps d'utilisation cumulé, la température totale et la pression totale avant l'admission, la vitesse du rotor basse pression, la vitesse du rotor haute pression, le débit de combustible, la température d'échappement et la poussée sont utilisés dans le processus d'entraînement, ce qui est indispensable pour un moteur aéro.

II.9 Gestion et atténuation de la dégradation

II.9.1 Stratégies de maintenance

La gestion de la dégradation implique plusieurs stratégies interconnectées [87]. Les principales sources de dégradation du moteur sont les mécanismes d'encrassement, qui dominent la détérioration du compresseur, et la dégradation des matériaux due à la corrosion et à l'oxydation, qui dominent la section chaude du moteur. Tous les composants rotatifs du moteur verront également des jeux de fonctionnement accrus.

L'encrassement peut être géré avec des systèmes de filtration d'air appropriés, tandis que les dommages de la section chaude sont dans une certaine mesure affectés par le combustible utilisé [87]. Les données de terrain montrent également qu'avec des combustibles propres et une maintenance appropriée, la dégradation de la section chaude peut être maintenue très faible. Elle est souvent causée par des jeux accrus, car la gestion du changement des jeux pendant le démarrage et l'arrêt est difficile.

II.9.2 Lavage et nettoyage

Les mesures typiques pour récupérer la dégradation incluent la conduite d'un lavage à l'eau du compresseur pour restaurer le débit et l'efficacité aux niveaux tels que mis en service [87]. L'encrassement, la corrosion, la corrosion à chaud et l'érosion peuvent dans une certaine mesure être contrôlés par une filtration d'air d'admission appropriée. Alors que les effets d'encrassement peuvent être inversés par le nettoyage ou le lavage du moteur, d'autres effets nécessitent l'ajustement, la réparation ou le remplacement de composants.

Les données de terrain d'un moteur Mercury 50 ont montré que lors de chaque événement de lavage à l'eau, les performances du compresseur de turbine à gaz sont entièrement récupérables [87]. L'observation est que le client est obligé de conduire des lavages à l'eau fréquents pour maintenir un système très performant. Cependant, une fois qu'un média filtrant amélioré a été appliqué au système de filtration d'admission, toute dégradation du compresseur a été essentiellement éliminée.

II.9.3 Surveillance et maintenance prédictive

Avec l'application de la prédiction de la dégradation des performances dans le système de gestion de la santé, l'approche de maintenance tout au long du cycle de vie est plus susceptible de passer de la maintenance basée sur le temps à la maintenance prédictive, ce qui

assure la sécurité des moteurs d'aviation tout en maximisant les économies de coûts en maintenance [86].

Pendant ce temps, avec l'efficacité de transfert d'énergie améliorée dans le brûleur après la maintenance, les coûts sur le cycle de vie pourraient également être réduits [86]. Une approche de maintenance de système de locomotive basée sur l'ANN a été proposée pour surveiller le niveau d'huile lubrifiante dans le système. Cette approche est dite à faible coût et pour les applications en temps réel.

II.9.4 Intervalles de révision et remplacement

Il est ainsi courant de distinguer entre la dégradation récupérable et non récupérable [87]. Tous les mécanismes de dégradation qui peuvent être inversés par lavage à l'eau en ligne et hors ligne sont considérés comme dégradation récupérable. Les mécanismes de dégradation qui nécessitent le remplacement de pièces sont considérés comme non récupérables, car ils nécessitent généralement une révision du moteur.

Une dégradation lourde sera évitée par des mesures de révision en temps opportun, car l'économie du processus de production ne favorisera généralement pas le fonctionnement de moteurs fortement dégradés [87]. Enfin, des efforts supplémentaires dans le traçage des particules et des gouttelettes sur le parcours à travers les compresseurs dans les turbines sont en cours.

II.10 Défis et perspectives futures

II.10.1 Défis opérationnels

Les turbines à gaz sont généralement susceptibles à divers types de défauts [89]. Plus spécifiquement, le défaut des capteurs de turbine à gaz est considéré comme l'un des troubles opérationnels essentiels. Ce type de défaut est catégorisé en cinq groupes, à savoir : défaut d'étape, défaut de dérive, défaut d'impulsion, défaut de bruit et défaut périodique.

Les erreurs dans les dispositifs de détection causent des dysfonctionnements de la turbine à gaz et des erreurs opérationnelles [89]. La surveillance des défauts est essentielle pour éliminer les défauts du capteur. De même, deux méthodes sont déterminées pour le diagnostic de la santé des capteurs. Ces méthodes sont d'origine modèle et d'origine données. La méthode d'origine modèle est basée sur l'analyse mathématique qui est destinée à l'établissement de modèles mathématiques de diagnostic de défauts, tandis que la méthode d'origine données dépend de la technologie des données, telle que l'apprentissage automatique, pour l'évaluation du type de défaut.

2.10.2 Incertitudes de mesure et validation

La détermination du montant exact de dégradation des performances sur le terrain est plutôt difficile, en raison des incertitudes de test omniprésentes [87]. Même la tendance implique certaines incertitudes, en particulier lorsque les données de conditions de fonctionnement

transitoires doivent être identifiées. Peu de publications existent qui indiquent le taux de dégradation de la turbine à gaz.

Dans de nombreux cas, il semble que la dégradation initiale sur un nouveau moteur soit considérée comme plus rapide que la dégradation après plusieurs milliers d'heures de fonctionnement [87]. Une cause à cela pourrait résider dans différentes pratiques de test de performance de différents fabricants. Si le moteur, dans le cadre du processus de test d'usine, est soumis à un redémarrage à chaud (c'est-à-dire que le moteur est arrêté et presque immédiatement redémarré. Cela provoquera normalement les jeux les plus petits possibles) avant le test de performance, les données de performance refléteront déjà les jeux qui ne se détérioreront probablement pas pendant le fonctionnement ultérieur du moteur.

II.10.3 Besoins de recherche future

Actuellement, la stratégie principale pour prédire la dégradation des performances des moteurs aéro est la simulation de modélisation utilisant des ensembles de données simulées [86]. Cependant, par rapport aux données réelles du moteur, les ensembles de données de simulation souffrent de plusieurs lacunes évidentes. Premièrement, les ensembles de données de simulation reposent typiquement sur des modèles physiques et des hypothèses trop simplifiés qui ne capturent pas adéquatement la complexité inhérente et la diversité observées dans les opérations réelles de moteurs aéro.

Deuxièmement, les ensembles de données de simulation sont intrinsèquement incapables d'englober tous les modes de défaillance potentiels et les anomalies qui peuvent se produire pendant le cycle de fonctionnement d'un moteur aéro réel [86]. Enfin, en raison de l'écart entre l'ensemble de données simulé et les conditions de fonctionnement réelles d'un moteur aéro, un modèle entraîné sur les données simulées peut présenter une applicabilité et une stabilité limitées dans les scénarios de déploiement réels.

En termes de travail futur, la méthode proposée doit être validée avec plus de données expérimentales de différents échantillons du même type de moteur pour vérifier son efficacité dans la prédiction des performances à travers différents cycles [86]. De plus, des simulations basées sur des données expérimentales de différents types de turbines à gaz devraient être effectuées pour tester davantage l'universalité de la méthode proposée.

II.11 Conclusion

La dégradation des performances des turbines à gaz est un phénomène complexe et multifactoriel qui résulte de l'interaction de divers mécanismes physiques, chimiques et mécaniques. Les principaux mécanismes de dégradation incluent l'encrassement du compresseur, l'érosion, la corrosion, la corrosion à chaud, le frottement et les dommages par corps étrangers. Chacun de ces mécanismes affecte différemment les composants de la turbine à gaz et contribue à la détérioration globale des performances du système.

L'encrassement du compresseur est généralement le mécanisme de dégradation le plus significatif dans les turbines à gaz industrielles modernes, mais il est largement évitable grâce à l'utilisation de systèmes de filtration d'air haute efficacité. Les données de terrain ont

démontré de manière concluante que la qualité du système de filtration d'air est le paramètre clé affectant les taux d'encrassement, l'emportant de loin sur toute caractéristique de conception inhérente du moteur.

Les systèmes de surveillance modernes, particulièrement ceux basés sur l'intelligence artificielle et les réseaux de neurones artificiels, offrent des capacités prometteuses pour la détection précoce de la dégradation et la maintenance prédictive. Ces systèmes peuvent traiter de grandes quantités de données de capteurs, identifier des modèles complexes de dégradation et fournir des diagnostics précis de l'état du moteur. L'intégration de ces technologies avancées dans les systèmes de gestion de la santé des moteurs représente une évolution importante vers une maintenance plus proactive et économiquement efficace.

Cependant, des défis importants subsistent, notamment en ce qui concerne la fiabilité des capteurs dans des environnements difficiles, les incertitudes de mesure et la validation des modèles de prédiction avec des données opérationnelles réelles. La recherche future devrait se concentrer sur le développement de méthodes de surveillance plus robustes qui peuvent fonctionner avec des données limitées tout en maintenant une haute précision de prédiction, ainsi que sur la validation extensive de ces méthodes dans diverses conditions opérationnelles et types de moteurs.

III.1. Introduction

Ce chapitre présente les approches de modélisation et d'optimisation utilisées dans cette recherche pour développer des modèles prédictifs performants. Trois méthodologies complémentaires sont employées : les modèles mathématiques classiques de conception d'expériences, les réseaux de neurones artificiels avec leur formulation mathématique, et les algorithmes méta-heuristiques d'optimisation pour le réglage des hyper-paramètres. Ces approches forment un cadre méthodologique intégré où les modèles mathématiques classiques fournissent une base théorique solide, les réseaux de neurones offrent une capacité de modélisation non linéaire avancée, et les algorithmes d'optimisation permettent d'extraire automatiquement les configurations optimales.

Le plan d'expériences, avec son modèle mathématique bien établi, représente l'approche classique pour étudier les relations entre variables dans un système. Cette méthode repose sur des fondements statistiques solides et permet d'identifier les effets principaux et les interactions entre facteurs. Cependant, cette approche présente des limitations lorsqu'il s'agit de modéliser des relations non linéaires complexes ou des interactions d'ordre supérieur. C'est dans ce contexte que les réseaux de neurones artificiels offrent une alternative puissante, capable d'apprendre des relations complexes directement à partir des données sans hypothèses préalables sur la forme fonctionnelle.

Les réseaux de neurones, et particulièrement les réseaux de neurones profonds, constituent des modèles computationnels inspirés du fonctionnement biologique du cerveau. Leur architecture mathématique leur permet d'approximer des fonctions complexes grâce à la composition successive de transformations non linéaires. Cependant, la performance de ces modèles dépend crucialement du choix approprié de leurs hyperparamètres, tels que le nombre de couches cachées, le nombre de neurones par couche, et le taux d'apprentissage. L'espace de recherche de ces hyperparamètres est vaste, discret, et les évaluations sont coûteuses en termes computationnels.

Pour relever ce défi, trois algorithmes métaheuristiques d'optimisation de pointe ont été sélectionnés : l'Optimisateur des Loups Gris (GWO), l'Algorithme d'Optimisation du Secrétaire (SBOA), et l'Optimisateur de Hyène Tachetée (SHO). Ces algorithmes, inspirés de comportements naturels, offrent des mécanismes de recherche sophistiqués pour explorer efficacement l'espace des hyperparamètres et identifier des configurations optimales. La comparaison de ces trois algorithmes permettra d'évaluer leurs performances relatives dans le contexte spécifique de l'optimisation des hyperparamètres des réseaux de neurones.

Ce chapitre détaille donc successivement la méthodologie des plans d'expériences, l'architecture mathématique des réseaux de neurones, et les algorithmes d'optimisation métaheuristiques. Chaque section présente les fondements théoriques, les modèles mathématiques, et les considérations pratiques de mise en œuvre. L'objectif est de fournir un cadre méthodologique complet et cohérent pour le développement et l'optimisation des modèles prédictifs.

III.2. Conception d'Expériences et Modélisation Mathématique Classique

La conception d'expériences représente une approche méthodologique fondamentale pour modéliser et analyser des systèmes complexes. Cette méthode classique permet d'établir des relations quantitatives entre les variables d'entrée et les réponses du système à travers des modèles mathématiques paramétriques. Dans le contexte de cette recherche, la conception d'expériences

sert de cadre de référence pour comparer les performances des approches basées sur les réseaux de neurones [91-94].

La conception d'expériences s'appuie sur des principes statistiques rigoureux pour planifier, réaliser, analyser et interpréter des expériences contrôlées. L'objectif est d'obtenir des informations maximales sur un système avec un nombre minimal d'expériences, tout en contrôlant les sources de variabilité et en garantissant la validité des conclusions. Cette approche est particulièrement utile lorsque les relations entre les variables sont mal comprises ou lorsqu'il existe de nombreuses variables potentielles à étudier.

III.2.1. Modèle Mathématique de la Conception d'Expériences

Le modèle mathématique standard pour la conception d'expériences à k facteurs peut être représenté comme suit :

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \sum_{j=i}^k \beta_{ij} x_i x_j + \varepsilon \quad (\text{III.1})$$

où :

- y représente la variable réponse (efficacité du système)
- x_i sont les variables indépendantes (facteurs d'entrée)
- β_0 est le terme constant (ordonnée à l'origine)
- β_i sont les coefficients des effets principaux
- β_{ij} sont les coefficients des effets d'interaction
- ε est le terme d'erreur aléatoire, supposé normalement distribué

Ce modèle permet de quantifier l'influence individuelle de chaque facteur ainsi que les interactions entre facteurs. Les coefficients β sont estimés à partir des données expérimentales par la méthode des moindres carrés. La validation du modèle implique l'analyse des résidus et la vérification des hypothèses statistiques sous-jacentes [91].

Le terme β_0 représente la réponse moyenne lorsque tous les facteurs sont à leur niveau de référence. Les coefficients β_i mesurent l'effet moyen d'une variation unitaire du facteur x_i sur la réponse y , en maintenant constantes toutes les autres variables. Les coefficients β_{ij} capturent les interactions entre les facteurs x_i et x_j , c'est-à-dire l'effet combiné de ces facteurs qui ne peut être expliqué par leurs effets individuels.

Le terme d'erreur ε représente la variabilité non expliquée par le modèle, incluant les erreurs de mesure, les facteurs non contrôlés, et la variabilité naturelle du système. L'hypothèse de normalité de ε est cruciale pour les tests statistiques et les intervalles de confiance associés aux estimations des coefficients [92].

L'effet d'un facteur $[X_i]$ est la comparaison entre les valeurs prises par la réponse $[Y]$ lorsque ce dernier passe du niveau (-1) au niveau $(+1)$. Il est caractérisé par une constante notée « A_i » qui sera :

- **Positive** si cette variation du facteur est favorable à l'accroissement de la réponse
- **Négative** si elle est favorable à la diminution de la valeur de la réponse
- **Nulle** si elle est sans influence sur le système




Figure III.1 : Effet d'un facteur sur la réponse [20]

Nous avons une interaction entre deux facteurs ou plus si l'effet de chacun sur la réponse du système dépend des niveaux des autres. Dans la plupart des cas, les études se limitent au premier ordre (interactions entre deux facteurs) [93].




Figure III.2 : Notion d'interaction entre deux facteurs

Dans le schéma (a), l'effet du facteur X_1 reste constant quel que soit le niveau du facteur X_2 , donc il n'y a pas d'interaction. Dans le schéma (b), l'effet du facteur X_1 varie en fonction du niveau du facteur X_2 , indiquant la présence d'une interaction [94].

III.2.2. Estimation des Paramètres et Validation du Modèle

L'estimation des paramètres du modèle se fait par la méthode des moindres carrés ordinaires, qui minimise la somme des carrés des résidus :

$$\min_{\beta} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (\text{III.2})$$

où n est le nombre d'observations, y_i est la réponse observée, et $\hat{y}_i$ est la réponse prédite par le modèle.

III.2.2.1. Critères de Qualité d'Ajustement

La qualité d'ajustement du modèle est évaluée à l'aide de plusieurs critères statistiques :

A. Coefficient de détermination R^2

Le R^2 mesure la proportion de variance expliquée par le modèle :

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (\text{III.3})$$

où $\bar{y}$ est la moyenne des observations. Une valeur proche de 1 correspond à un modèle avec un très bon pouvoir prédictif.

B. R^2 ajusté

Le R^2 ajusté tient compte du nombre de paramètres dans le modèle :

$$R_{\text{ajusté}}^2 = 1 - \frac{(1 - R^2)(n - 1)}{n - p - 1} \quad (\text{III.4})$$

où p est le nombre de paramètres estimés.

C. Coefficient Q^2

Le coefficient Q^2 est le R^2 prédictif, calculé comme suit :

$$Q^2 = 1 - \frac{\text{PRESS}}{\text{SCET}} \quad (\text{III.5})$$

où PRESS (Somme des Carrés des Résidus Prédicatifs) est défini par :

$$PRESS = \sum_{i=1}^n \left(\frac{e_i}{1-h_i} \right)^2 \quad (\text{III.6})$$

avec h_i le i -ème élément diagonal de la matrice Hat. Le Q^2 varie généralement entre 0 et 1 et mesure la capacité du modèle à prévoir la réponse à des points inconnus du domaine expérimental.

III.2.2.2. Graphe d'Adéquation du Modèle

Les résultats peuvent être représentés graphiquement pour comparer les points mesurés et les réponses estimées. Le graphe d'adéquation place les réponses mesurées en abscisse et les réponses estimées en ordonnée.




Figure III.3 : Exemple de graphe d'adéquation du modèle

Si le nuage de points est aligné sur la droite d'équation $y = x$, la qualité descriptive du modèle est bonne.

III.2.2.3. Surface de Réponse

La surface de réponse modélisée peut être tracée en fonction des variables étudiées, permettant une visualisation tridimensionnelle de l'évolution du critère.




Figure III.4 : Exemple de surface de réponse pour deux facteurs

III.2.2.3. Plan Expérimental et Collecte de Données

Le plan expérimental est structuré pour obtenir des données représentatives permettant d'ajuster le modèle mathématique. Les variables d'entrée sont systématiquement variées selon un schéma prédéterminé, et les réponses correspondantes sont mesurées avec précision [91-94].

III.2.2.4. Conditions d'Application

Pour appliquer la méthode des plans d'expériences, deux conditions doivent être réalisées :

Condition 1 : La valeur que prend chaque variable doit être connue sans erreur significative. L'erreur induite sur la valeur de la variable doit être très petite, voire négligeable devant la variation de cette même variable.

Condition 2 : La réponse doit être homo-scédastique, c'est-à-dire que l'erreur de mesure doit être la même sur tout le domaine expérimental. L'expérimentateur doit maintenir les mêmes gestes, le même matériel et la même cadence lors de toute la campagne d'expérimentation.

III.2.2.5. Valeurs Centrées Réduites

Pour des simplifications mathématiques, les valeurs réelles des niveaux de facteurs sont remplacées par des valeurs se situant entre (+1) et (-1). Cette transformation permet de traiter tous les facteurs de la même manière.

Tableau III.1 : Exemple de transformation en valeurs centrées réduites

Facteur	Niveau -1	Niveau +1
Température (°C)	20	40
Distance (mm)	30	60

La formule de passage des valeurs réelles aux valeurs centrées réduites est :

$$v = \frac{2V - (V^+ + V^-)}{V^+ - V^-} \quad (\text{III.7})$$

où :

- v : Niveau du facteur en valeur centrée réduite
- V : Niveau du facteur en valeur réelle
- V^+ : Niveau supérieur du facteur
- V^- : Niveau inférieur du facteur

III.2.2.6. Types de Plans Expérimentaux

Plusieurs types de plans expérimentaux peuvent être utilisés selon les objectifs de l'étude :

A. Plans Factoriels Complets 2^k

Ces plans possèdent un nombre de niveaux limité à deux pour chaque facteur. Toutes les combinaisons de niveaux sont effectuées. Pour k facteurs, le plan nécessite 2^k expériences.




Figure III.5 : Plan factoriel complet à deux facteurs (2^2)

$$y = a_0 + a_1x_1 + a_2x_2 + a_{12}x_1x_2 + e \quad (\text{III.8})$$

B. Plans Factoriels Fractionnaires $2^{(k-q)}$

Ces plans permettent d'étudier tous les facteurs avec un nombre d'essais réduit (divisé par 2^q). Par exemple, un plan $2^{(5-2)}$ permet d'étudier cinq facteurs en seulement 8 essais au lieu de 32 [91-94].




Figure III.6 : Division d'un plan 2^3 en deux plans fractionnaires $2^{(3-1)}$

C. Plans Composites Centrés

Un plan composite est constitué de trois parties :

- Un plan factoriel (points aux sommets)
- Des points au centre du domaine
- Des points axiaux (plan en étoile)




Figure III.7 : Plan composite centré pour deux facteurs

- 4 points factoriels (sommets du carré)
- 4 points axiaux (sur les axes)
- 5 points centraux (répétitions)

Total : 13 expériences pour déterminer 6 coefficients d'un modèle quadratique.

III.2.3. Analyse Statistique et Tests de Signification

III.2.3.1. Test de Signification des Effets

Le test utilisé est le test t de Student. Un effet sera dit significatif si, pour un risque donné, il est significativement différent de 0.

On calcule :

$$t_i = \frac{|a_i|}{s_i} \quad (\text{III.9})$$

où s_i est l'écart-type de l'effet a_i .

La variance des effets est donnée par :

$$s^2 = \frac{\sum_{i=1}^n e_i^2}{n-p} \quad (\text{III.10})$$

où n est le nombre d'expériences et p le nombre de coefficients.

Règle de décision :

- Si $t_i > t_{\text{crit}}(\alpha, v)$, on rejette H_0 : l'effet est significatif
- Si $t_i < t_{\text{crit}}(\alpha, v)$, on accepte H_0 : l'effet n'est pas significatif

III.2.3.2. Analyse de la Variance (ANOVA)

L'analyse de la variance compare la somme des carrés due à la régression avec la somme des carrés des résidus.

Tableau III.2 : Tableau d'analyse de variance

Variation due à	Somme des carrés	DDL	Carré moyen	F
Liaison (régression)	SCEL	p-1	CML = SCEL/(p-1)	F_obs = CML/CMR
Résidus	SCER	n-p	CMR = SCER/(n-p)	-
Total	SCET	n-1	SCET/(n-1)	-

Avec :

$$\text{SCEL} = \sum (\hat{y}_i - \bar{y})^2 \quad (\text{variation due à la liaison}) \quad (\text{III.11})$$

$$SCER = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (\text{variation résiduelle}) \quad (\text{III.12})$$

$$SCET = SCEL + SCER \quad (\text{variation totale}) \quad (\text{III.13})$$

Le test F permet de valider globalement la régression en comparant F_{obs} avec F_{critique} lu dans la table de Fisher-Snedecor.

III.2.4. Validation du Modèle

Deux possibilités existent :

- A. Le modèle est validé :** Il représente suffisamment bien le phénomène étudié dans le domaine expérimental. Il peut être utilisé pour faire de la prévision en tout point du domaine.
- B. Le modèle n'est pas validé :** Son utilisation n'est pas possible. Il faut proposer un modèle différent (par exemple, passer d'un modèle linéaire à un modèle quadratique).

La validation peut être réalisée en effectuant des essais complémentaires en dehors des points du plan initial et en comparant les réponses mesurées aux réponses prédites par le modèle.

Un modèle est considéré comme satisfaisant si :

- $R^2 > 0,8$ (au moins 80% de variance expliquée)
- $Q^2 > 0,5$ (bonne capacité prédictive)
- La différence $R^2 - Q^2 < 0,3$
- Les résidus suivent une distribution normale
- Le test F de régression est significatif

III.3. Réseaux de Neurones et Réseaux de Neurones Profonds

Les réseaux de neurones artificiels constituent une famille de modèles computationnels inspirés du fonctionnement biologique du cerveau humain. Contrairement aux modèles mathématiques paramétriques de la conception d'expériences, les réseaux de neurones sont des modèles non paramétriques qui apprennent les relations complexes directement à partir des données sans hypothèses préalables sur la forme fonctionnelle. Cette flexibilité les rend particulièrement adaptés à la modélisation de systèmes complexes où les relations entre variables ne sont pas linéaires ou bien comprises.

Un réseau de neurones est composé d'unités de traitement élémentaires appelées neurones, organisées en couches. Chaque neurone reçoit des entrées, effectue une transformation, et produit une sortie. Les connexions entre neurones sont associées à des poids qui sont ajustés pendant l'apprentissage pour minimiser l'erreur entre les sorties prédites et les sorties désirées.

III.3.1. Architecture Mathématique des Réseaux de Neurones

Un réseau de neurones artificiel est mathématiquement défini comme une composition de fonctions, où chaque couche applique une transformation non linéaire à ses entrées. La formulation générale d'un réseau de neurones à L couches peut être exprimée comme suit [95-97] :

$$\hat{y} = f^{(L)} \left(W^{(L)} f^{(L-1)} \left(W^{(L-1)} \dots f^{(1)} \left(W^{(1)} x + b^{(1)} \right) \dots + b^{(L-1)} \right) + b^{(L)} \right) \quad (\text{III.14})$$

où :

- x est le vecteur d'entrée de dimension n
- $W^{(l)}$ est la matrice de poids de la couche l
- $b^{(l)}$ est le vecteur de biais de la couche l
- $f^{(l)}$ est la fonction d'activation de la couche l
- $\hat{y}$ est la sortie prédite du réseau

Cette formulation mathématique capture l'essence computationnelle des réseaux de neurones comme des approximateurs universels de fonctions. La puissance de modélisation des réseaux de neurones découle de leur capacité à composer des transformations non linéaires successives, ce qui leur permet de représenter des fonctions complexes.

Chaque neurone individuel implémente une opération simple consistant en une combinaison linéaire des entrées suivie d'une non-linéarité, mais la composition de nombreux neurones organisés en couches crée une capacité de modélisation exponentielle. Le théorème d'approximation universelle établit qu'un réseau de neurones avec une seule couche cachée et un nombre suffisant de neurones peut approximer toute fonction continue sur un compact avec une précision arbitraire.

III.3.2. Fonctions d'Activation et Propagation

Les fonctions d'activation introduisent la non-linéarité essentielle à la capacité d'approximation des réseaux de neurones. Les fonctions couramment utilisées incluent :

- Sigmoidé :




Figure III. 8: Sigmoidé

- Tangente hyperbolique : $\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$




Figure III.9 : Tangente hyperbolique

- Rectified Linear Unit (ReLU) : $\text{ReLU}(z) = \max(0, z)$




Figure III.10 : Rectified Linear Unit (ReLU)

- Softmax : $\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$

Chaque fonction d'activation a ses avantages et inconvénients. La fonction sigmoïde et la tangente hyperbolique ont été historiquement populaires mais souffrent du problème de gradient vanishing pour les réseaux profonds. La fonction ReLU et ses variantes sont actuellement les plus utilisées en raison de leur simplicité de calcul et de leur capacité à atténuer le problème de gradient vanishing [95-97].

La propagation avant calcule la sortie du réseau pour une entrée donnée. Pour un réseau avec L couches, le calcul procède séquentiellement :

$$\begin{aligned} a^{(0)} &= x \\ z^{(l)} &= W^{(l)} a^{(l-1)} + b^{(l)} \quad \text{pour } l = 1, \dots, L \\ a^{(l)} &= f^{(l)}(z^{(l)}) \quad \text{pour } l = 1, \dots, L \\ \hat{y} &= a^{(L)} \end{aligned} \tag{III.15}$$

où $a^{(l)}$ est l'activation de la couche l , et $z^{(l)}$ est l'entrée non linéarisée de la couche l .

La rétropropagation ajuste les paramètres (poids et biais) pour minimiser l'erreur entre les prédictions et les valeurs cibles. Ce processus utilise la règle de la chaîne pour calculer les gradients de la fonction de coût par rapport à chaque paramètre :

$$\begin{aligned}\frac{\partial J}{\partial W^{(l)}} &= \frac{\partial J}{\partial z^{(l)}} \cdot \frac{\partial z^{(l)}}{\partial W^{(l)}} \\ \frac{\partial J}{\partial b^{(l)}} &= \frac{\partial J}{\partial z^{(l)}} \cdot \frac{\partial z^{(l)}}{\partial b^{(l)}}\end{aligned}\quad (\text{III.16})$$

où J est la fonction de coût, généralement la moyenne des carrés des erreurs pour la régression ou l'entropie croisée pour la classification.

III.3.3. Réseaux de Neurones Profonds

Les réseaux de neurones profonds étendent l'architecture de base en incorporant plusieurs couches cachées, ce qui augmente considérablement leur capacité de représentation. La profondeur du réseau permet une hiérarchisation des caractéristiques, où les couches inférieures apprennent des caractéristiques simples et les couches supérieures combinent ces caractéristiques en représentations plus abstraites et complexes. Cette hiérarchie de caractéristiques est particulièrement efficace pour modéliser des phénomènes complexes où les relations entre les variables d'entrée et de sortie ne sont pas directes mais médiées par plusieurs niveaux d'abstraction [95-97].




Figure III.11 : Structure d'un réseau de neurones profond

La formulation mathématique d'un réseau de neurones profond avec L couches cachées s'écrit :

$$\begin{aligned}h^{(1)} &= f^{(1)}(W^{(1)}x + b^{(1)}) \\ h^{(2)} &= f^{(2)}(W^{(2)}h^{(1)} + b^{(2)}) \\ &\vdots \\ h^{(L)} &= f^{(L)}(W^{(L)}h^{(L-1)} + b^{(L)}) \\ \hat{y} &= g(W^{(L+1)}h^{(L)} + b^{(L+1)})\end{aligned}\quad (\text{III.17})$$

où g est la fonction d'activation de la couche de sortie, adaptée à la nature du problème (linéaire pour la régression, sigmoïde pour la classification binaire, softmax pour la classification multiclasse).

Les réseaux de neurones profonds présentent plusieurs avantages par rapport aux réseaux peu profonds. Ils peuvent représenter des fonctions plus complexes avec moins de paramètres, grâce à la factorisation hiérarchique des représentations. Ils apprennent également des caractéristiques hiérarchiques qui correspondent souvent à des concepts sémantiques dans les données. Cependant, ils présentent également des défis, notamment le problème de gradient vanishing, la nécessité de grandes quantités de données d'entraînement, et le risque de surapprentissage.

III.3.4. Hyperparamètres des Réseaux de Neurones

Les performances des réseaux de neurones dépendent crucialement du choix approprié de leurs hyperparamètres. Contrairement aux paramètres du modèle (poids et biais) qui sont appris automatiquement pendant l'entraînement, les hyperparamètres doivent être spécifiés avant le processus d'apprentissage [95-97]. Les hyperparamètres principaux comprennent :

- **Nombre de couches cachées** : Détermine la profondeur du réseau et sa capacité à apprendre des représentations hiérarchiques.
- **Nombre de neurones par couche** : Détermine la largeur du réseau et sa capacité à apprendre des représentations complexes.
- **Taux d'apprentissage** : Contrôle la taille des pas lors de la mise à jour des paramètres pendant l'optimisation.
- **Fonction d'activation** : Définit la non-linéarité appliquée à la sortie de chaque neurone.
- **Algorithme d'optimisation** : Méthode utilisée pour minimiser la fonction de coût.
- **Nombre d'époques** : Nombre de fois que l'ensemble de données complet est présenté au réseau.
- **Techniques de régularisation** : Méthodes pour prévenir le surapprentissage (dropout, weight decay, etc.).

L'optimisation de ces hyperparamètres constitue un défi majeur en apprentissage automatique, car l'espace de recherche est vaste, discret, et les évaluations sont coûteuses en termes computationnels. C'est dans ce contexte que les algorithmes métaheuristiques d'optimisation offrent une approche puissante pour explorer efficacement l'espace des hyperparamètres et identifier des configurations optimales.

III.4. Optimisation des Hyperparamètres des Réseaux de Neurones

L'optimisation des hyperparamètres des réseaux de neurones représente un problème complexe en raison de plusieurs caractéristiques : l'espace de recherche est de grande dimension, les variables peuvent être discrètes ou continues, les évaluations sont coûteuses en temps de calcul, et la fonction objectif est souvent bruitée et non convexe. Les méthodes traditionnelles comme la recherche exhaustive (grid search) ou la recherche aléatoire (random search) deviennent rapidement inefficaces lorsque le nombre d'hyperparamètres augmente.

Pour relever ce défi, trois algorithmes métaheuristiques d'optimisation de pointe ont été sélectionnés pour l'analyse comparative sur la base de leurs caractéristiques de recherche distinctes

et de leurs performances éprouvées dans des paysages d'optimisation complexes. Ces algorithmes ont été mis en œuvre pour optimiser les paramètres d'architecture des réseaux de neurones, notamment le nombre de couches cachées, le nombre de neurones par couche et le taux d'apprentissage. L'objectif principal est de maximiser la précision prédictive tout en maintenant l'efficacité computationnelle des modèles développés.

Les algorithmes métaheuristiques offrent plusieurs avantages pour l'optimisation des hyperparamètres. Ils ne nécessitent pas d'informations sur le gradient de la fonction objectif, ce qui les rend applicables même lorsque la fonction objectif n'est pas différentiable. Ils peuvent gérer des espaces de recherche complexes avec des variables discrètes et continues. Ils intègrent des mécanismes pour éviter les optimums locaux grâce à des composantes stochastiques et des stratégies d'exploration. Enfin, ils peuvent être facilement adaptés à des problèmes multi-objectifs pour considérer des compromis entre différentes métriques de performance.

III.4.1. Algorithme d'Optimisation du Loup Gris (GWO)

Inspiré par la hiérarchie sociale et le comportement de chasse des loups gris (*Canis lupus*), le GWO imite la structure de leadership et les mécanismes de chasse de ces prédateurs apex. L'algorithme modélise quatre types de loups gris : alpha, bêta, delta et oméga, pour simuler la hiérarchie de leadership. Les trois principales étapes de chasse - recherche de proie, encerclement de la proie et attaque de la proie - sont implémentées mathématiquement [98,99].

Les loups gris sont considérés comme des prédateurs apex, ce qui signifie qu'ils se situent au sommet de la chaîne alimentaire. Ils préfèrent vivre en meute, généralement composée de 5 à 12 membres en moyenne. Une caractéristique particulièrement intéressante est leur hiérarchie sociale dominante très stricte. Les leaders sont un mâle et une femelle, appelés alphas, principalement responsables des décisions concernant la chasse, le lieu de repos, l'heure du réveil, etc. Les décisions de l'alpha sont imposées à la meute, bien qu'un comportement démocratique ait également été observé, où l'alpha suit parfois les autres loups de la meute.

L'algorithme fonctionne en distinguant les solutions candidates selon leur qualité : la meilleure solution est considérée comme l'alpha, les deuxième et troisième meilleures solutions sont nommées respectivement bêta et delta, tandis que le reste des solutions candidates sont considérées comme oméga. Dans l'algorithme GWO, la chasse (optimisation) est guidée par alpha, bêta et delta, les loups oméga suivant ces trois loups.

III.4.1.1. Hiérarchie Sociale

La modélisation de la hiérarchie sociale constitue le fondement organisationnel de l'algorithme GWO. Cette structure permet de préserver et d'exploiter les meilleures solutions trouvées au cours du processus d'optimisation.

- **Alpha (α)** : Représente la meilleure solution candidate actuelle. L'alpha est le leader de la meute et guide la direction principale de la recherche. Bien qu'il ne soit pas nécessairement le membre le plus fort, il est le meilleur en termes de gestion de la meute, ce qui se traduit dans l'algorithme par la solution ayant la meilleure valeur de fonction objective.
- **Bêta (β)** : Représente la deuxième meilleure solution. Le bêta est un loup subordonné qui aide l'alpha dans la prise de décision. Dans l'algorithme, cette solution assiste l'alpha en

fournissant une direction alternative prometteuse et peut potentiellement devenir alpha si une meilleure solution est trouvée.

- **Delta (δ)** : Représente la troisième meilleure solution. Les deltas doivent se soumettre aux alphas et bêtas, mais dominent les omégas. Ils comprennent les éclaireurs, les sentinelles, les anciens, les chasseurs et les soignants, contribuant tous à l'efficacité globale de la chasse.
- **Oméga (ω)** : Représente toutes les autres solutions candidates. Les omégas constituent le rang le plus bas et doivent se soumettre à tous les autres loups dominants. Dans l'algorithme, ces solutions suivent les directives des trois meilleures solutions et sont constamment mises à jour pour explorer l'espace de recherche.

Cette hiérarchie permet à l'algorithme de maintenir une structure organisée tout en préservant la diversité de la population, évitant ainsi une convergence prématurée vers des optimums locaux [98,99].

III.4.1.2. Phase d'Encerclement de la Proie

Cette phase modélise le comportement d'encerclement que les loups gris adoptent lorsqu'ils ont identifié une proie potentielle. Mathématiquement, ce comportement est formulé comme suit :

$$\begin{aligned}\vec{D} &= |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \\ \vec{X}(t+1) &= \vec{X}_p(t) - \vec{A} \cdot \vec{D}\end{aligned}\tag{III.18}$$

où :

- t indique l'itération actuelle
- $\vec{A}$ et $\vec{C}$ sont des vecteurs coefficients
- $\vec{X}_p$ est le vecteur de position de la proie
- $\vec{X}$ indique le vecteur de position d'un loup gris
- $\vec{D}$ définit la distance entre la proie et le loup gris

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a}$$

$$\vec{C} = 2 \cdot \vec{r}_2$$

où :

- Les composantes de $\vec{a}$ sont linéairement décroissantes de 2 à 0 au cours des itérations
- $\vec{r}_1, \vec{r}_2$ sont des vecteurs aléatoires dans $[0, 1]$

Le mécanisme d'encerclement repose sur la capacité des loups gris à reconnaître la position de la proie et à l'encercler. Dans un espace de recherche abstrait, nous n'avons aucune idée de l'emplacement de l'optimum (proie). Par conséquent, l'algorithme suppose que l'alpha, le bêta et le delta ont une meilleure connaissance de l'emplacement potentiel de la proie.

Le vecteur $\vec{D}$ calcule la distance entre la position actuelle d'un agent de recherche et la position de la proie. Le facteur $|\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)|$ permet d'ajuster cette distance de manière stochastique, introduisant une composante aléatoire qui favorise l'exploration. La valeur absolue garantit que la distance est toujours positive, quel que soit l'emplacement relatif du loup par rapport à la proie.

Le vecteur $\vec{A}$ détermine la direction et l'amplitude du mouvement vers ou depuis la proie. Sa formulation $\vec{A} = 2a \cdot \vec{r}_1 - a$ crée une plage de valeurs entre $[-a, a]$. Lorsque $|\vec{A}| < 1$, le loup se déplace vers la proie (exploitation), et lorsque $|\vec{A}| > 1$, le loup s'éloigne de la proie (exploration).

Le vecteur $\vec{C}$ fournit des poids aléatoires dans $[0, 2]$ pour la proie, permettant d'accentuer de manière stochastique ($\vec{C} > 1$) ou de diminuer ($\vec{C} < 1$) l'effet de la proie dans la définition de la distance. Ce mécanisme peut être considéré comme l'effet des obstacles à l'approche de la proie dans la nature, rendant parfois la proie plus difficile à atteindre pour les loups, ou vice versa. Contrairement à $\vec{A}$, $\vec{C}$ n'est pas linéairement décroissant, fournissant délibérément des valeurs aléatoires à tout moment pour favoriser l'exploration non seulement lors des itérations initiales mais aussi lors des itérations finales.

Dans un espace bidimensionnel, un loup en position (X, Y) peut mettre à jour sa position en fonction de la position de la proie (X^*, Y^*) . En ajustant les valeurs des vecteurs $\vec{A}$ et $\vec{C}$, différents emplacements autour de l'agent optimal actuel peuvent être atteints. Par exemple, la position $(X^* - X, Y)$ peut être atteinte en définissant $\vec{A} = (1, 0)$ et $\vec{C} = (1, 1)$. Ce concept s'étend à des espaces de recherche n-dimensionnels, où les loups se déplacent dans des hyper-cubes (ou hyper-sphères) autour de la meilleure solution obtenue jusqu'à présent.

III.4.1.3. Phase de Chasse (Mise à Jour des Positions)

Les loups gris ont la capacité de reconnaître l'emplacement de la proie et de l'encercler. La chasse est généralement guidée par l'alpha, mais le bêta et le delta peuvent également participer occasionnellement à la chasse. Dans un espace de recherche abstrait, nous supposons que l'alpha, le bêta et le delta ont une meilleure connaissance de l'emplacement potentiel de la proie.

Ce mécanisme de chasse représente la collaboration entre les membres de la meute pour capturer une proie. Plutôt que de se fier uniquement à la meilleure solution (alpha), l'algorithme utilise les trois meilleures solutions pour guider la mise à jour des positions.

$$\begin{aligned}\vec{D}_\alpha &= |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \\ \vec{D}_\beta &= |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \\ \vec{D}_\delta &= |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}|\end{aligned}\tag{III.19}$$

Les trois vecteurs de distance $\vec{D}_\alpha$, $\vec{D}_\beta$, et $\vec{D}_\delta$ calculent respectivement les distances entre l'agent de recherche actuel et les trois meilleures solutions. Chaque calcul de distance utilise un vecteur $\vec{C}$ différent ($\vec{C}_1$, $\vec{C}_2$, $\vec{C}_3$), introduisant une variabilité stochastique qui permet d'explorer différentes régions autour des meilleures solutions.

$$\begin{aligned}\vec{X}_1 &= \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \\ \vec{X}_2 &= \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \\ \vec{X}_3 &= \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta\end{aligned}\tag{III.20}$$

Les trois vecteurs représentent les positions candidates basées sur les emplacements de l'alpha, du bêta et du delta. Chaque position candidate est calculée en soustrayant un vecteur de déplacement ($\vec{A}_i \cdot \vec{D}_i$) de la position de référence correspondante ($\vec{X}_\alpha$, $\vec{X}_\beta$, ou $\vec{X}_\delta$). Les vecteurs $\vec{A}$ différents permettent des mouvements d'amplitudes variables vers chaque solution de référence.

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (\text{III.21})$$

La position finale $\vec{X}(t+1)$ est obtenue en calculant la moyenne arithmétique des trois positions candidates. Cette approche présente plusieurs avantages :

- **Équilibre des influences** : Aucune des trois meilleures solutions ne domine complètement la mise à jour, créant un équilibre entre différentes directions prometteuses
- **Robustesse** : Si l'une des meilleures solutions est piégée près d'un optimum local, les deux autres peuvent compenser et guider la recherche vers des régions plus prometteuses
- **Exploration dirigée** : La position finale se trouve dans une région définie par un cercle (en 2D) ou une sphère (en dimensions supérieures) dont le centre et le rayon dépendent des positions de l'alpha, du bêta et du delta

III.4.1.4. Phase d'Attaque de la Proie (Exploitation)

Comme mentionné précédemment, les loups gris terminent la chasse en attaquant la proie lorsqu'elle cesse de bouger. Pour modéliser mathématiquement l'approche de la proie, nous diminuons la valeur de $\vec{a}$, ce qui réduit également la plage de fluctuation de $\vec{A}$.

Le paramètre $\vec{a}$ diminue linéairement de 2 à 0 au cours des itérations selon la formule :

$$\vec{a} = 2 - t \times \left(\frac{2}{T_{\max}} \right) \quad (\text{III.22})$$

où t est l'itération actuelle et $T_{\max}$ est le nombre maximum d'itérations.

Par conséquent, $\vec{A}$ est une valeur aléatoire dans l'intervalle $[-2\vec{a}, 2\vec{a}]$, qui se réduit progressivement à 0 vers la fin du processus d'optimisation.

Lorsque les valeurs aléatoires de $\vec{A}$ sont dans l'intervalle $[-1, 1]$, la prochaine position d'un agent de recherche peut se trouver n'importe où entre sa position actuelle et la position de la proie. Ce comportement force les loups à attaquer vers la proie, représentant la phase d'exploitation de l'algorithme [98,99].

Les caractéristiques clés de cette phase sont :

- **Convergence progressive** : À mesure que $\vec{a}$ diminue, la plage de $\vec{A}$ se rétrécit, forçant les agents de recherche à se rapprocher progressivement des meilleures solutions
- **Recherche locale intensive** : Les mouvements de faible amplitude permettent une exploration minutieuse du voisinage des solutions prometteuses

- **Raffinement des solutions** : Les dernières itérations se concentrent sur l'amélioration fine des meilleures solutions trouvées

Le mécanisme adaptatif de $a^{\rightarrow}$ assure une transition douce entre les phases d'exploration et d'exploitation :

- **Phase initiale ($t \approx 0$)** : $a^{\rightarrow} \approx 2$, donc $A^{\rightarrow} \in [-2, 2]$, permettant une exploration large
- **Phase intermédiaire** : $a^{\rightarrow} \approx 1$, donc $A^{\rightarrow} \in [-1, 1]$, équilibrant exploration et exploitation
- **Phase finale ($t \approx T_{\max}$)** : $a^{\rightarrow} \approx 0$, donc $A^{\rightarrow} \approx 0$, favorisant une exploitation intensive

Cette décroissance linéaire garantit qu'environ la moitié des itérations sont consacrées à l'exploration ($|A^{\rightarrow}| \geq 1$) et l'autre moitié à l'exploitation ($|A^{\rightarrow}| < 1$), créant un équilibre optimal entre ces deux composantes essentielles de l'optimisation métaheuristique.

III.4.1.5. Phase de Recherche de Proie (Exploration)

Les loups gris recherchent principalement en fonction de la position de l'alpha, du bêta et du delta. Ils divergent les uns des autres pour rechercher une proie et convergent pour l'attaquer. Pour modéliser mathématiquement la divergence, nous utilisons $A^{\rightarrow}$ avec des valeurs aléatoires supérieures à 1 ou inférieures à -1 pour obliger l'agent de recherche à diverger de la proie.

Lorsque $|A^{\rightarrow}| > 1$, les loups gris sont forcés de diverger de la proie pour espérer trouver une proie plus adaptée. Ce comportement représente la phase d'exploration de l'algorithme et présente plusieurs caractéristiques importantes :

- **Exploration globale** : Les agents de recherche peuvent se déplacer vers des régions éloignées de l'espace de recherche, augmentant la probabilité de découvrir de nouvelles zones prometteuses
- **Évitement des optimums locaux** : En s'éloignant périodiquement des meilleures solutions actuelles, l'algorithme réduit le risque de stagnation dans des optimums locaux
- **Diversité de la population** : Les mouvements de grande amplitude maintiennent la diversité des solutions candidates, essentielle pour une exploration efficace

Un autre composant du GWO qui favorise l'exploration est le vecteur $C^{\rightarrow}$. Comme on peut le voir dans son équation, le vecteur $C^{\rightarrow}$ contient des valeurs aléatoires dans $[0, 2]$ tout au long du processus d'optimisation.

Contrairement à $A^{\rightarrow}$, $C^{\rightarrow}$ n'est pas linéairement décroissant et maintient son caractère stochastique pendant toutes les itérations :

- **Accentuation stochastique ($C^{\rightarrow} > 1$)** : Augmente l'importance de la distance à la proie, rendant potentiellement la proie plus éloignée ou difficile à atteindre
- **Diminution stochastique ($C^{\rightarrow} < 1$)** : Réduit l'importance de la distance à la proie, facilitant l'approche
- **Évitement des optimums locaux tardifs** : Le caractère aléatoire persistant de $C^{\rightarrow}$ permet d'échapper aux optimums locaux même lors des itérations finales

Ce composant est particulièrement utile en cas de stagnation dans un optimum local, notamment lors des itérations finales, lorsque le paramètre a^+ est devenu très petit.

La combinaison des deux vecteurs crée un mécanisme d'exploration robuste :

- A^+ contrôle l'amplitude globale du mouvement avec une décroissance temporelle
- C^+ introduit une variabilité persistante qui maintient la capacité d'exploration tout au long du processus

Cette synergie permet à GWO de maintenir un bon équilibre entre exploration et exploitation, assurant une convergence fiable vers des solutions de haute qualité.

III.4.2. Algorithme d'Optimisation du Secrétaire (SBOA)

Inspiré du comportement de recherche de nourriture des oiseaux secrétaires, le SBOA imite leurs modèles de mouvement en spirale et leurs stratégies de recherche de nourriture. L'algorithme présente une stratégie de chasse en trois étapes avec un réglage adaptatif des paramètres. Les oiseaux secrétaires sont connus pour leurs techniques de chasse uniques qui combinent des marches systématiques, des coups de pied puissants et des stratégies d'évitement des prédateurs [100].

Ces comportements naturels sont transposés dans l'algorithme d'optimisation sous forme d'opérations mathématiques qui guident la recherche de solutions optimales. La première phase correspond à l'exploration large de l'espace de recherche, similaire à la recherche initiale de proies. La deuxième phase représente une approche plus ciblée une fois qu'une région prometteuse a été identifiée. La troisième phase correspond à l'exploitation intensive de la région identifiée. Chaque phase utilise des mécanismes mathématiques distincts qui reflètent les différentes stratégies de chasse observées chez les oiseaux secrétaires.

L'algorithme fonctionne en trois phases distinctes qui représentent différentes stratégies de recherche. Chaque phase est caractérisée par des équations spécifiques qui déterminent comment les agents se déplacent dans l'espace de recherche. La transition entre les phases est contrôlée par des paramètres qui évoluent au cours des itérations, permettant une adaptation dynamique de la stratégie de recherche. La première phase favorise l'exploration en utilisant des mouvements aléatoires de grande amplitude. La deuxième phase introduit une composante plus dirigée tout en conservant une certaine exploration. La troisième phase se concentre sur l'exploitation locale avec des mouvements de plus faible amplitude mais plus précis.

III.4.2.1. Phase 1 - Recherche de Proie (Exploration)

Cette phase simule le comportement initial de l'oiseau secrétaire qui parcourt de vastes territoires à la recherche de proies potentielles. Durant cette étape d'exploration globale, l'algorithme privilégie la diversification et la découverte de nouvelles régions de l'espace de recherche plutôt que l'optimisation fine [100].

$$X_1 = X_i + (X_{\text{rand}_1} - X_{\text{rand}_2}) \cdot R_1 \quad (\text{III.23})$$

où R_1 est un vecteur aléatoire et X_{rand_1} , X_{rand_2} sont des membres aléatoires de la population.

Le mécanisme principal repose sur la différence entre deux solutions aléatoires ($X_{rand1} - X_{rand2}$), qui génère un vecteur de direction non biaisé. Cette approche présente plusieurs avantages :

- **Indépendance par rapport aux meilleures solutions** : contrairement à d'autres métaheuristiques, cette phase ne guide pas les agents vers les meilleures solutions connues, ce qui évite une convergence prématurée et maintient la diversité de la population.
- **Couverture extensive** : les mouvements aléatoires de grande amplitude permettent d'explorer des régions éloignées de l'espace de recherche, augmentant ainsi la probabilité de découvrir le voisinage de l'optimum global.
- **Évitement des minima locaux** : en ne se concentrant pas immédiatement sur les zones prometteuses, l'algorithme évite de se piéger dans des optimums locaux dès les premières itérations.

Cette phase est particulièrement active au début du processus d'optimisation, lorsque l'information sur la structure du problème est limitée et qu'une exploration large est nécessaire pour identifier les régions d'intérêt [100].

III.4.2.2. Phase 2 - Approche de la Proie (Transition)

Cette phase intermédiaire modélise le comportement de l'oiseau secrétaire qui, ayant repéré une proie, s'en approche progressivement tout en restant vigilant et prêt à explorer d'autres opportunités. Elle représente un équilibre crucial entre exploration et exploitation.

$$X_1 = Best_p + \exp\left(\left(\frac{t}{T}\right)^4\right) \cdot (RB - 0.5) \cdot (Best_p - X_{(i)}) \quad (III.24)$$

où RB est un vecteur de mouvement brownien aléatoire et le terme exponentiel fournit une mise à l'échelle adaptative.

Les composantes principales de cette équation sont :

- **Orientation vers la meilleure solution (Best_P)** : contrairement à la Phase 1, les agents commencent à se diriger vers les régions identifiées comme prometteuses, représentées par la meilleure solution de la population.
- **Mouvement brownien (RB - 0.5)** : le terme brownien introduit une composante stochastique qui simule des mouvements aléatoires de type "marche au hasard". Le facteur (RB - 0.5) centre cette perturbation autour de zéro, permettant des déplacements dans toutes les directions avec une probabilité équilibrée.
- **Mise à l'échelle adaptative $\exp((t/T)^4)$** : ce terme exponentiel constitue le mécanisme d'adaptation temporelle le plus important de cette phase. L'exposant 4 crée une décroissance non linéaire qui s'accélère au fil des itérations :
 - Aux premières itérations (t petit), $\exp((t/T)^4) \approx 1$, permettant une exploration locale large autour de Best_P

- Aux itérations finales (t proche de T), $\exp((t/T)^4) \rightarrow 0$, réduisant progressivement l'amplitude des perturbations
- **Vecteur de direction (Best_P - X(i))** : ce terme oriente le mouvement de l'agent actuel vers la meilleure solution, avec une intensité modulée par les facteurs précédents.

Cette phase assure une transition douce et progressive d'une stratégie d'exploration vers une stratégie d'exploitation, évitant des changements brusques qui pourraient déstabiliser le processus de convergence [100].

III.4.2.3. Phase 3 - Attaque de la Proie (Exploitation)

Cette phase finale simule l'attaque précise et ciblée de l'oiseau secrétaire sur sa proie. Elle représente l'exploitation intensive des régions les plus prometteuses identifiées lors des phases précédentes.

$$X_1 = \text{Best}_p + \text{CF} \cdot X_i \cdot \text{Levy}(\text{dim}) \quad (\text{III.25})$$

avec le facteur de convergence :

$$\text{CF} = \left(1 - \frac{t}{T}\right)^{\left(\frac{2t}{T}\right)} \quad (\text{III.26})$$

et la distribution de vol de Lévy pour la recherche locale améliorée :

$$\text{Levy}(\beta) = \frac{u}{|v|^{\frac{1}{\beta}}}, \quad u \sim N(0, \sigma_u^2), \quad v \sim N(0, \sigma_v^2) \quad (\text{III.27})$$

Les mécanismes clés de cette phase sont :

A. Le facteur de convergence

Ce facteur sophistiqué contrôle la vitesse de convergence avec une dynamique non linéaire remarquable :

- Au début (t petit) : $\text{CF} \approx 1$, permettant des mouvements d'amplitude significative
- À mi-parcours : la décroissance s'accélère progressivement
- À la fin ($t \rightarrow T$) : $\text{CF} \rightarrow 0$, les mouvements deviennent infinitésimaux, assurant une convergence fine vers l'optimum

L'exposant variable ($2t/T$) renforce cette accélération de la convergence au fil du temps, créant une dynamique d'intensification adaptative.

B. La distribution de vol de Lévy Levy(β)

Le vol de Lévy est un processus stochastique caractérisé par une distribution à queue lourde, particulièrement adapté à l'optimisation :

- **Petits pas fréquents** : la majorité des mouvements sont de faible amplitude, permettant une exploration minutieuse du voisinage de Best_P
- **Grands sauts occasionnels** : avec une faible probabilité, des déplacements de grande amplitude se produisent, permettant d'échapper aux minima locaux même en phase d'exploitation

Cette caractéristique "multi-échelle" du vol de Lévy est biologiquement inspirée des patterns de recherche observés chez de nombreux animaux et s'avère mathématiquement efficace pour éviter la stagnation.

C. Intensification progressive

La combinaison $CF \cdot X_i \cdot \text{Levy}(\text{dim})$ crée un processus d'intensification doublement adaptatif :

- Le facteur CF réduit globalement l'amplitude des mouvements
- La distribution de Lévy maintient une capacité d'exploration locale
- Le produit avec $X(i)$ permet des mouvements relatifs à la position actuelle de l'agent

Cette phase garantit une convergence précise tout en préservant une capacité résiduelle d'exploration, ce qui améliore significativement la qualité des solutions finales.

Stratégie d'Évasion

L'algorithme intègre des mécanismes d'évitement des prédateurs :

Cache :

Cette comportement de l'oiseau secrétaire se réfugie temporairement dans une position sûre lorsqu'il détecte un danger.

$$X_2 = \text{Best}_p + (1 - t / T)^2 \cdot (2R - 1) \cdot X_i \quad (\text{III.28})$$

Ce mécanisme est particulièrement utile lorsqu'un agent se trouve dans une région à faible qualité et doit rapidement rejoindre des zones plus prometteuses.

Fuite :

L'équation suivante modélise une réaction d'évitement plus agressive, où l'agent s'éloigne rapidement de sa position actuelle :

$$X_2 = X_i + R \cdot (X_{\text{random}} - K \cdot X_i) \quad (\text{III.29})$$

Ces stratégies d'évasion constituent un mécanisme de diversification crucial qui prévient la convergence prématurée et améliore la robustesse de l'algorithme face aux paysages d'optimisation complexes [100].

Ce mécanisme est activé selon des conditions spécifiques (généralement basées sur la stagnation ou la qualité de la solution) et permet :

- D'échapper à des minima locaux profonds
- De relancer l'exploration dans des régions inexplorées
- De maintenir la diversité de la population même dans les phases avancées

III.4.3. Algorithme d'Optimisation de l'Hyène Tachetée (SHO)

Inspiré par les relations sociales et le comportement de chasse collaboratif des hyènes tachetées (*Crocuta*), le SHO modélise la structure de réseau social et les stratégies de chasse de ces carnivores intelligents. L'algorithme présente une approche basée sur les groupes cohésifs où les hyènes tachetées forment des clusters d'amis de confiance pour chasser efficacement. Les trois étapes principales - recherche de proie, encerclement et attaque de la proie - sont implémentées mathématiquement avec des mécanismes adaptatifs uniques [101-103].

Les hyènes tachetées sont des chasseurs habiles et constituent la plus grande des trois autres espèces d'hyènes. Elles sont également appelées hyènes rieuses car leurs vocalisations ressemblent beaucoup à un rire humain. Ce sont des animaux complexes, intelligents et hautement sociaux. Elles ont une capacité à se battre sans fin pour le territoire et la nourriture. Dans les familles d'hyènes tachetées, les membres féminins sont dominants. Les hyènes tachetées vivent et chassent généralement en groupes, s'appuyant sur un réseau d'amis de confiance pouvant compter plus de 100 membres.

Selon des études comportementales, les hyènes tachetées utilisent leurs connaissances des relations sociales dans la prise de décisions. Elles peuvent reconnaître les parents tiers et classer les relations entre les membres de leur clan, utilisant ces connaissances lors de la prise de décision sociale. Les clusters cohésifs sont utiles pour une coopération efficace entre les hyènes tachetées et maximisent également la fitness. Dans ce travail, la technique de chasse et la relation sociale des hyènes tachetées sont modélisées mathématiquement pour concevoir le SHO et effectuer l'optimisation.

III.4.3.1. Phase d'Encerclement de la Proie

Les hyènes tachetées peuvent se familiariser avec l'emplacement de la proie et l'encercler. Pour modéliser mathématiquement la hiérarchie sociale des hyènes tachetées, nous considérons que la meilleure solution candidate actuelle est la proie cible ou l'objectif qui est proche de l'optimum.

$$\begin{aligned} \vec{D}_h &= |\vec{B} \cdot \vec{P}_p(x) - \vec{P}(x)| \\ \vec{P}(x+1) &= \vec{P}_p(x) - \vec{E} \cdot \vec{D}_h \end{aligned} \quad (\text{III.30})$$

où :

- D_h définit la distance entre la proie et l'hyène tachetée
- x indique l'itération actuelle
- B et E sont des vecteurs coefficients
- P_p indique le vecteur de position de la proie
- P est le vecteur de position de l'hyène tachetée

$$\begin{aligned} B &= 2 \cdot rd_1 \\ E &= 2h \cdot rd_2 - h \\ h &= 5 - (Itération \times (5 / MaxItération)) \end{aligned} \quad (III.31)$$

où :

- rd_1, rd_2 sont des vecteurs aléatoires dans $[0, 1]$
- h diminue linéairement de 5 à 0 au cours des itérations

Le vecteur D_h calcule la distance euclidienne entre la position actuelle d'une hyène tachetée et la position de la proie. Le coefficient $B = 2 \cdot rd_1$ introduit une composante aléatoire qui permet à la distance d'être modulée de manière stochastique. Contrairement au GWO où $C \in [0, 2]$, le vecteur B du SHO maintient une plage plus simple, facilitant des mouvements plus directs autour de la proie tout en conservant une variabilité suffisante pour l'exploration [101-103].

Le paramètre h est l'élément clé qui distingue SHO d'autres algorithmes similaires. Sa diminution linéaire de 5 à 0 crée une dynamique d'exploration-exploitation différente :

- **Valeur initiale élevée ($h = 5$)** : Permet une exploration très large avec $E \in [-5, 5]$, favorisant la découverte de régions éloignées de l'espace de recherche
- **Décroissance progressive** : Le facteur $(5/MaxItération)$ assure une transition plus rapide vers l'exploitation comparé au paramètre a du GWO (qui va de 2 à 0)
- **Phase finale ($h \rightarrow 0$)** : $E \rightarrow 0$, forçant une convergence serrée vers les meilleures solutions

Cette plage plus large au début ($[-5, 5]$ vs $[-2, 2]$ pour GWO) permet une exploration initiale plus agressive, particulièrement adaptée aux problèmes avec de vastes espaces de recherche ou de nombreux optimums locaux.

Pour un équilibre approprié entre exploration et exploitation, h diminue linéairement de 5 à 0 au cours du nombre maximum d'itérations. Ce mécanisme favorise davantage l'exploitation à mesure que la valeur de l'itération augmente. Le vecteur $E = 2h \cdot rd_2 - h$ crée une plage de valeurs $[-h, h]$, permettant :

- Lorsque $|E| \geq 1$: Exploration, les hyènes s'éloignent de la proie
- Lorsque $|E| < 1$: Exploitation, les hyènes convergent vers la proie

Dans un espace bidimensionnel, une hyène en position (A, B) peut mettre à jour sa position vers la position de la proie (A^*, B^*). En ajustant les valeurs des vecteurs B et E , différents emplacements

peuvent être atteints autour de la position actuelle. Dans un espace tridimensionnel et au-delà, le concept s'étend à des hyper-sphères où les hyènes peuvent se positionner aléatoirement autour de la proie.

III.4.3.2. Phase de Chasse (Formation de Clusters)

Les hyènes tachetées vivent et chassent généralement en groupes et s'appuient sur un réseau d'amis de confiance ayant la capacité de reconnaître l'emplacement de la proie. Pour définir mathématiquement le comportement des hyènes tachetées, nous supposons que le meilleur agent de recherche, celui qui est optimal, connaît l'emplacement de la proie.

$$\begin{aligned}\vec{D}_h &= |\vec{B} \cdot \vec{P}_h - \vec{P}_k| \\ \vec{P}_k &= \vec{P}_h - \vec{E} \cdot \vec{D}_h \\ \vec{C}_h &= \vec{P}_k + \vec{P}_{k+1} + \dots + \vec{P}_{k+n}\end{aligned}\tag{III.32}$$

où :

- $\vec{P}_h$ définit la position de la meilleure hyène tachetée
- $\vec{P}_k$ indique la position des autres hyènes tachetées
- N indique le nombre d'hyènes tachetées, calculé comme suit :

$$N = \text{count_nos}(\vec{P}_h, \vec{P}_{h+1}, \vec{P}_{h+2}, \dots, (\vec{P}_h + \vec{M}))\tag{III.33}$$

où :

- $\vec{M}$ est un vecteur aléatoire dans $[0.5, 1]$
- nos définit le nombre de solutions
- count compte toutes les solutions candidates qui, après addition avec $\vec{M}$, sont suffisamment similaires à la meilleure solution optimale dans l'espace de recherche donné
- $\vec{C}_h$ est un groupe ou cluster de N solutions optimales

Le mécanisme de formation de cluster est l'innovation principale du SHO. Contrairement au GWO qui utilise toujours les trois meilleures solutions (alpha, bêta, delta), le SHO identifie dynamiquement un groupe de solutions prometteuses formant un "réseau d'amis de confiance". Ce concept est directement inspiré du comportement social des hyènes tachetées qui forment des coalitions de membres de confiance pour chasser plus efficacement.

Le vecteur $\vec{C}_h$ est la somme de toutes les positions des N hyènes du cluster. Cette somme sera ensuite divisée par N pour obtenir la position moyenne, représentant le centre du cluster d'amis de confiance. Ce centre guide la mise à jour des autres agents de recherche.

Le nombre N de hyènes dans le cluster n'est pas fixe mais calculé dynamiquement à chaque itération :

- **Fonction count_nos** : Cette fonction compte combien de solutions candidates se trouvent dans un voisinage défini autour de la meilleure solution P_h^*
- **Paramètre M** : Le vecteur aléatoire $M \in [0.5, 1]$ définit le rayon du voisinage. Une valeur plus grande de M crée un cluster plus large incluant plus de solutions, tandis qu'une valeur plus petite crée un cluster plus restreint et sélectif
- **Adaptation automatique** : Le nombre N s'adapte naturellement à la distribution des solutions dans l'espace de recherche. Dans les régions denses de bonnes solutions, N sera grand ; dans les régions plus dispersées, N sera petit

Le mécanisme de clustering présente les avantages suivants :

- **Flexibilité** : Contrairement à l'utilisation fixe de trois solutions (GWO), le nombre variable permet une meilleure adaptation à la topologie du problème
- **Robustesse** : En moyennant plusieurs solutions prometteuses, l'algorithme est moins sensible aux fluctuations individuelles et aux optimums locaux isolés
- **Exploitation collective** : Le cluster représente une "connaissance collective" sur la région prometteuse, similaire au comportement collaboratif des hyènes tachetées réelles
- **Transition adaptative** : En début d'optimisation, quand les solutions sont dispersées, N est généralement petit (exploration). En fin d'optimisation, quand les solutions convergent, N peut être plus grand (exploitation collective)

Ce mécanisme reflète fidèlement le comportement des hyènes tachetées qui :

- Reconnaittent les relations entre membres du clan
- Forment des coalitions basées sur la confiance et la familiarité
- Prennent des décisions de chasse basées sur l'intelligence collective du groupe
- Ajustent dynamiquement la taille du groupe de chasse selon les conditions

III.4.3.3. Phase d'Attaque de la Proie (Exploitation)

Pour modéliser mathématiquement l'attaque de la proie, nous diminuons la valeur du vecteur h^* . La variation du vecteur E^* diminue également pour changer la valeur du vecteur h^* qui peut diminuer de 5 à 0 au cours des itérations.

$$\vec{P}(x+1) = \frac{\vec{C}_h}{N}$$

La formule $\vec{P}(x+1) = \vec{C}_h/N$ représente la position mise à jour d'une hyène tachetée, calculée comme la moyenne (barycentre) des positions de toutes les hyènes du cluster. Ce mécanisme d'attaque présente plusieurs caractéristiques importantes :

- **Exploitation collective** : Au lieu de suivre une seule meilleure solution, chaque agent converge vers le centre du groupe d'amis de confiance, représentant une stratégie d'attaque coordonnée
- **Stabilité** : La moyenne de N positions réduit l'impact des fluctuations aléatoires individuelles, créant une convergence plus stable
- **Adaptation dynamique** : Comme N varie, le comportement d'attaque s'adapte automatiquement à la distribution des solutions

Lorsque $|E^{\rightarrow}| < 1$, le groupe d'hyènes tachetées est forcé d'attaquer vers la proie. Cette condition se produit de plus en plus fréquemment à mesure que h diminue :

- **Phase initiale (h = 5)** : $E^{\rightarrow} \in [-5, 5]$, très peu de mouvements d'attaque, exploration dominante
- **Phase intermédiaire (h ≈ 2.5)** : $E^{\rightarrow} \in [-2.5, 2.5]$, équilibre entre exploration et exploitation
- **Phase finale (h → 0)** : $E^{\rightarrow} \rightarrow 0$, tous les mouvements sont des attaques, exploitation intensive

L'équation de $P^{\rightarrow}(x+1)$ sauvegarde la meilleure solution et met à jour les positions des autres agents de recherche en fonction de la position du cluster optimal. Ce mécanisme permet à l'algorithme SHO de :

- Préserver l'élitisme en maintenant la meilleure solution trouvée
- Guider la population vers les régions les plus prometteuses
- Éviter la perte de bonnes solutions lors des mises à jour stochastiques

À mesure que les itérations progressent :

1. Le paramètre h diminue linéairement
2. La plage de $E^{\rightarrow}$ se rétrécit
3. Les mouvements des hyènes deviennent de plus en plus orientés vers le cluster
4. Le cluster lui-même converge vers l'optimum global
5. Toutes les hyènes finissent par se rassembler autour de la meilleure solution

Cette convergence progressive garantit que l'algorithme SHO effectue une recherche locale intensive dans les régions prometteuses identifiées lors de la phase d'exploration, tout en maintenant la capacité d'échapper aux optimums locaux grâce au mécanisme de cluster adaptatif.

III.4.3.4. Phase de Recherche de Proie (Exploration)

Les hyènes tachetées recherchent la proie en fonction de la position du groupe ou du cluster d'hyènes tachetées qui réside dans le vecteur $C^{\rightarrow}_h$. Elles s'éloignent les unes des autres pour rechercher et attaquer une proie. Par conséquent, nous utilisons $E^{\rightarrow}$ avec des valeurs aléatoires supérieures à 1 ou inférieures à -1 pour forcer les agents de recherche à s'éloigner de la proie.

Pour trouver une proie appropriée, la condition $|E^{\rightarrow}| \geq 1$ facilite le déplacement des hyènes tachetées loin de la proie. Ce mécanisme d'exploration présente des caractéristiques uniques dans SHO :

Avec h démarrant à 5, la plage initiale de $E^{\rightarrow}$ est $[-5, 5]$, ce qui est significativement large. Cette plage étendue permet :

- **Sauts exploratoires de grande amplitude** : Les hyènes peuvent effectuer des mouvements très importants dans l'espace de recherche, atteignant des régions très éloignées
- **Couverture rapide de l'espace** : Dans les premières itérations, l'algorithme explore rapidement de vastes zones de l'espace de recherche
- **Découverte de bassins d'attraction multiples** : La portée étendue augmente la probabilité de découvrir plusieurs régions prometteuses simultanément

Un autre composant du SHO qui favorise l'exploration est $B^{\rightarrow}$. Le vecteur $B^{\rightarrow} = 2 \cdot rd_1$ contient des valeurs aléatoires dans $[0, 2]$ qui fournissent des poids aléatoires pour la proie :

- **Emphase ($B^{\rightarrow} > 1$)** : Accentue l'effet de la distance dans l'équation, rendant potentiellement la proie plus éloignée
- **Atténuation ($B^{\rightarrow} < 1$)** : Réduit l'effet de la distance, facilitant l'approche
- **Variabilité persistante** : $B^{\rightarrow}$ fournit des valeurs aléatoires à tout moment pour favoriser l'exploration non seulement lors des itérations initiales mais aussi lors des itérations finales

Le mécanisme d'exploration du SHO maintient activement la diversité de la population grâce à :

- **Mouvements divergents** : Lorsque $|E^{\rightarrow}| > 1$, les hyènes s'éloignent du cluster, créant une dispersion naturelle
- **Cluster dynamique** : La recomposition constante du cluster à chaque itération empêche la stagnation
- **Exploration multi-échelle** : La diminution progressive de h crée une exploration à plusieurs échelles, des sauts globaux initiaux aux mouvements locaux finaux

Cette phase de recherche est particulièrement efficace pour éviter les optimums locaux :

- **Échappement actif** : Les agents piégés près d'optimums locaux peuvent s'en échapper grâce aux mouvements de grande amplitude
- **Réévaluation continue** : Le cluster se reforme à chaque itération, permettant à l'algorithme de réévaluer quelles solutions sont vraiment prometteuses
- **Exploration tardive** : Le caractère aléatoire persistant de $B^{\rightarrow}$ maintient une capacité d'exploration même dans les itérations finales

Ce comportement reflète la stratégie de chasse des hyènes tachetées réelles qui :

- Se dispersent sur de vastes territoires pour maximiser les chances de trouver une proie
- Maintiennent une communication avec le groupe tout en explorant individuellement

- Ajustent dynamiquement leur stratégie de recherche en fonction des découvertes
- Peuvent rapidement se regrouper une fois qu'une proie est localisée

Le SHO crée un équilibre optimal entre exploration et exploitation grâce à :

- **h^* décroissant** : Contrôle la transition globale de l'exploration vers l'exploitation
- **B^* aléatoire persistant** : Maintient une capacité d'exploration à toutes les phases
- **Cluster adaptatif** : Ajuste automatiquement entre recherche large et raffinement local
- **N variable** : Adapte le niveau de collaboration selon la distribution des solutions

Cette combinaison de mécanismes fait du SHO un algorithme particulièrement robuste pour les problèmes d'optimisation complexes avec de nombreux optimums locaux et de vastes espaces de recherche.

III.4.4. Adaptation Multi-Objectif

Les trois algorithmes utilisent des mécanismes sophistiqués d'archive de Pareto pour maintenir des solutions non dominées diverses tout au long du processus d'optimisation. La maintenance de l'archive comprend l'estimation de la densité utilisant des approches basées sur des grilles et des techniques de nichage pour assurer une distribution uniforme le long du front de Pareto. La pression de sélection est équilibrée par la sélection par tournoi basée sur la dominance de Pareto et les métriques de distance d'encombrement.

L'archive de Pareto sert de référentiel pour toutes les solutions non dominées découvertes pendant le processus d'optimisation. À chaque itération, les nouvelles solutions sont comparées aux solutions existantes dans l'archive, et seules les solutions non dominées sont conservées. Cette comparaison repose sur le concept de dominance de Pareto, où une solution est considérée comme dominante si elle est au moins aussi bonne que les autres solutions sur tous les objectifs et strictement meilleure sur au moins un objectif.

L'estimation de la densité est cruciale pour maintenir la diversité des solutions le long du front de Pareto. Les approches basées sur des grilles divisent l'espace des objectifs en cellules et limitent le nombre de solutions par cellule pour éviter la concentration dans certaines régions. Les techniques de nichage favorisent la sélection de solutions situées dans des régions peu peuplées du front de Pareto, encourageant ainsi une exploration plus uniforme de l'espace des objectifs.

La sélection par tournoi combine la dominance de Pareto et la distance d'encombrement pour choisir les solutions qui seront utilisées pour guider la recherche. Cette approche permet de maintenir un équilibre entre la convergence vers le front de Pareto vrai et la diversité des solutions. La distance d'encombrement mesure la densité des solutions autour d'une solution donnée, avec des valeurs plus élevées indiquant des régions moins peuplées. En favorisant les solutions avec une grande distance d'encombrement, l'algorithme encourage l'exploration des régions peu visitées du front de Pareto.

Ces mécanismes combinés permettent aux algorithmes d'optimisation de générer un ensemble de solutions bien réparties qui représentent différents compromis entre les objectifs concurrents. Cette

capacité est essentielle pour les problèmes d'optimisation multi-objectif où il n'existe pas une solution unique optimale mais plutôt un ensemble de solutions optimales au sens de Pareto.

III.4.5. Mise en Œuvre et Configuration des Paramètres

Chaque algorithme d'optimisation a été mis en œuvre avec un réglage minutieux des paramètres pour assurer une comparaison équitable et des performances optimales. Comme présenté dans le Tableau 3.1, les approches basées sur la population ont été configurées avec 10 individus pour maintenir la diversité tout en assurant la faisabilité computationnelle. Le nombre maximal d'itérations a été fixé à 10 générations, permettant un temps de convergence suffisant tout en évitant des calculs excessifs.

Pour assurer la fiabilité statistique et tenir compte de la nature stochastique des algorithmes métaheuristiques, 5 exécutions indépendantes ont été effectuées pour chaque méthode, avec des résultats analysés pour la cohérence et la signification. Cette configuration permet d'obtenir des résultats statistiquement significatifs tout en maintenant des temps de calcul raisonnables pour les expériences.

La taille de population de 10 individus représente un compromis entre la diversité génétique nécessaire pour explorer efficacement l'espace de recherche et la complexité computationnelle de l'évaluation des solutions. Chaque individu représente un ensemble complet d'hyperparamètres pour le réseau de neurones, incluant le nombre de couches cachées, le nombre de neurones par couche et le taux d'apprentissage.

Le nombre d'itérations maximal de 10 permet aux algorithmes de converger vers des solutions de qualité tout en limitant le temps de calcul total. Ce nombre a été déterminé sur la base d'expériences préliminaires qui ont montré que la plupart des améliorations significatives se produisent dans les premières itérations.

Les 5 exécutions indépendantes avec des graines aléatoires différentes permettent d'estimer la variabilité des résultats due à la nature stochastique des algorithmes. Cette approche fournit une base solide pour comparer les performances des différents algorithmes de manière statistiquement rigoureuse.

Tableau III.3 : Paramètres de Configuration des Algorithmes d'Optimisation

Paramètre	MOGWO	SHO	SBOA
Taille de la Population	10		
Itérations Maximales	10		
Exécutions Indépendantes	5		
Couches Cachées	3		
Neurones par Couche	1–128		
Taux d'Apprentissage	0.001–0.1		

Ces bornes définissent l'espace de recherche dans lequel les algorithmes d'optimisation opèrent. Le nombre de couches cachées est fixé à 3, ce qui permet une architecture suffisamment profonde pour capturer des relations complexes tout en évitant une complexité excessive. Le nombre de neurones par couche varie entre 1 et 128 est opté suite à plusieurs simulations et qui offrant une

large gamme de capacités de modélisation. Cette plage permet aux algorithmes d'explorer différentes tailles de réseau, depuis les architectures très simples jusqu'aux architectures plus complexes. Le taux d'apprentissage varie entre 0.001 et 0.1, couvrant les valeurs typiquement utilisées dans l'entraînement des réseaux de neurones. Cette plage permet de trouver le compromis optimal entre la vitesse de convergence et la stabilité de l'entraînement. Ces bornes ont été choisies sur la base de la littérature existante et d'expériences préliminaires pour garantir que l'espace de recherche soit suffisamment large pour contenir des configurations optimales tout en étant suffisamment restreint pour permettre une exploration efficace dans le nombre limité d'itérations disponibles.

III.4.6. Cadre d'Évaluation

Un cadre d'évaluation complet a été établi pour évaluer à la fois la précision prédictive et l'efficacité computationnelle des modèles développés. Le coefficient de détermination R^2 a été utilisé comme métrique de précision principale, fournissant un aperçu de la proportion de variance expliquée par le modèle. L'erreur quadratique moyenne (RMSE) a complété cette analyse en quantifiant l'erreur de prédiction absolue en unités de pourcentage d'efficacité.

Le temps d'entraînement a été mesuré de l'initialisation à la convergence, incluant les phases de propagation avant et arrière. Toutes les mesures de temps ont été effectuées sur du matériel standardisé pour assurer la comparabilité. Des techniques de validation croisée ont été employées pour atténuer le surapprentissage, avec le jeu de données partitionné pour maintenir la cohérence temporelle dans la séquence mensuelle.

L'évaluation des performances se concentre sur deux aspects principaux : la qualité des solutions trouvées et l'efficacité du processus de recherche. La qualité des solutions est mesurée par leur performance sur les données de test, avec R^2 et RMSE fournissant des perspectives complémentaires sur l'adéquation du modèle. R^2 mesure la proportion de variance expliquée par le modèle, avec des valeurs plus élevées indiquant une meilleure adéquation. RMSE mesure l'erreur de prédiction moyenne dans les unités originales de la variable cible, fournissant une interprétation plus intuitive de la précision du modèle.

L'efficacité computationnelle est évaluée par le temps d'entraînement, qui inclut à la fois le temps nécessaire pour optimiser les hyperparamètres et le temps nécessaire pour entraîner le modèle final avec ces hyperparamètres. Cette mesure est importante car elle reflète la faisabilité pratique de l'approche d'optimisation dans des contextes réels où les ressources computationnelles peuvent être limitées.

La standardisation du matériel garantit que les comparaisons de temps sont significatives et non biaisées par des différences matérielles. La validation croisée est essentielle pour obtenir des estimations fiables de la performance du modèle sur des données non vues. La partition temporelle des données préserve la structure chronologique des séries temporelles, ce qui est crucial pour les problèmes de prédiction où l'ordre temporel a une signification. Cette approche garantit que le modèle est évalué sur sa capacité à prédire des observations futures à partir de données passées, simulant ainsi les conditions réelles d'utilisation.

Le cadre d'évaluation complet permet non seulement de comparer les performances des différents algorithmes d'optimisation mais aussi d'identifier les compromis entre la précision prédictive et l'efficacité computationnelle. Ces compromis sont particulièrement importants dans les

applications pratiques où les contraintes de temps et de ressources peuvent influencer le choix de l'approche d'optimisation. En fournissant une évaluation multidimensionnelle des performances, ce cadre permet de prendre des décisions éclairées sur la sélection de la méthode d'optimisation la plus appropriée pour un problème donné.

III.4.7. Conclusion

Dans ce chapitre, nous avons présenté un cadre méthodologique intégré combinant le plan d'expériences classique, les réseaux de neurones profonds et les algorithmes métaheuristiques d'optimisation. Le plan d'expériences fournit une base mathématique solide pour la modélisation des systèmes, avec son modèle paramétrique qui permet de quantifier les effets des facteurs et leurs interactions. Cette approche classique établit des relations quantitatives entre les variables d'entrée et les réponses du système, fournissant ainsi une référence pour évaluer les performances des méthodes plus avancées.

Les réseaux de neurones, avec leur formulation mathématique comme compositeurs de fonctions non linéaires, offrent une capacité de modélisation avancée pour capturer des relations complexes sans hypothèses préalables sur la forme fonctionnelle. Leur architecture hiérarchique permet d'apprendre des représentations abstraites des données, ce qui les rend particulièrement adaptés aux problèmes où les relations entre variables sont non linéaires ou mal comprises.

Enfin, les algorithmes d'optimisation métaheuristiques permettent d'automatiser le réglage des hyperparamètres critiques des réseaux de neurones, explorant efficacement des espaces de recherche vastes et complexes. Les trois algorithmes sélectionnés - MOGWO, SBOA, et SHO - offrent des mécanismes de recherche complémentaires inspirés de comportements naturels, permettant une exploration robuste et efficace de l'espace des hyperparamètres.

Cette approche intégrée garantit que les modèles développés sont à la fois théoriquement fondés, grâce aux principes du plan d'expériences, et pratiquement performants, grâce aux capacités d'apprentissage des réseaux de neurones et à l'optimisation automatique des hyperparamètres. Les résultats de cette méthodologie seront présentés et analysés dans le chapitre suivant, permettant une évaluation complète des performances des différentes approches dans le contexte spécifique de cette étude.

IV.1 Introduction

Ce chapitre présente les résultats complets obtenus en appliquant deux approches de modélisation distinctes : la méthodologie des Plans d'Expériences (DoE) et l'Optimisation Multi-Objectifs par Métaheuristiques avec Réseaux de Neurones Profonds, pour prédire le rendement global de la turbine à gaz MS5002B fonctionnant dans les conditions désertiques difficiles du site de Hassi R'Mel. Le chapitre est structuré pour présenter d'abord les résultats de la modélisation statistique par la Méthodologie des Surfaces de Réponse, suivis par l'approche avancée d'apprentissage automatique avec optimisation d'architecture neuronale, et se conclut par une analyse comparative des deux méthodologies.

L'objectif principal de cette recherche était de développer des modèles prédictifs précis et efficaces sur le plan computationnel, capables de supporter la surveillance de performance en temps réel et l'optimisation opérationnelle des turbines à gaz industrielles. Les deux approches ont utilisé le même jeu de données opérationnelles couvrant douze mois de fonctionnement continu des turbines, permettant une comparaison directe de leurs forces et limites respectives.

IV.2 Aperçu du Cadre Méthodologique

Avant de présenter les résultats détaillés, il est instructif de visualiser la méthodologie de recherche globale qui a guidé les deux approches de modélisation. La Figure IV.1 illustre le cadre complet en cinq phases employé pour développer des réseaux de neurones profonds légers optimisés pour la surveillance du rendement des turbines à gaz en périphérie de réseau (edge).

La méthodologie englobe cinq phases interconnectées : (1) la préparation des données, incluant la collecte, le prétraitement et la mise en œuvre des contraintes physiques ; (2) la configuration de l'optimisation, définissant les critères multi-objectifs et la configuration de l'algorithme ; (3) la conception de l'architecture neuronale par exploration métaheuristique ; (4) le développement du modèle avec raffinement itératif ; et (5) l'évaluation et le déploiement incorporant la validation et les tests de performance. Ce cadre systématique garantit que les modèles développés atteignent non seulement une haute précision mais satisfont également les contraintes computationnelles pratiques essentielles pour un déploiement industriel.

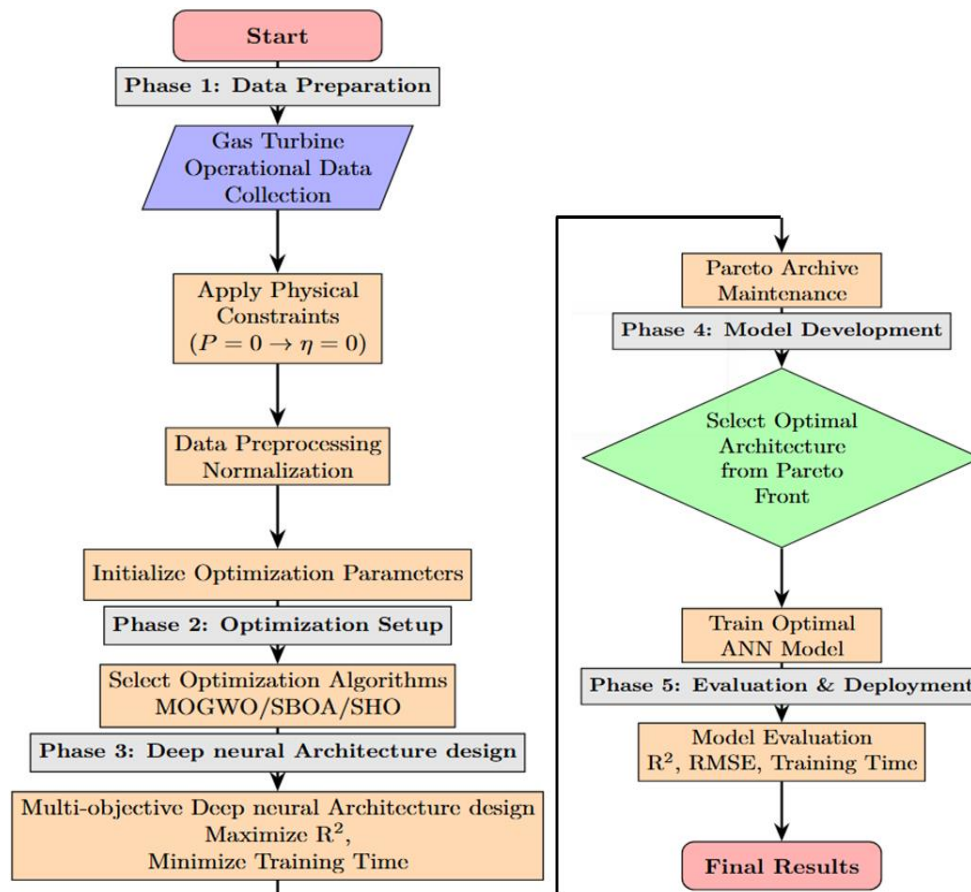


Figure IV.1 : Méthodologie proposée pour l’optimisation de réseaux de neurones profonds légers pour la surveillance du rendement des turbines à gaz en périphérie de réseau.

IV.3 Approche par Plans d’Expériences : Résultats de Modélisation Statistique

IV.3.1 Mise en œuvre du Plan Composite Centré

La méthodologie des Plans d’Expériences, employant spécifiquement un Plan Composite Centré (CCD) couplé à la Méthodologie des Surfaces de Réponse (RSM), a été appliquée pour établir un modèle statistique reliant le rendement de la turbine à la température ambiante et à la puissance de sortie. Le CCD à faces centrées consistait en 4 points factoriels, 4 points axiaux positionnés sur les faces du cube ($\alpha = 1$), et 3 points centraux répliqués, fournissant une exploration systématique du domaine expérimental tout en maintenant les propriétés d’orthogonalité essentielles pour une estimation fiable des paramètres.

La Figure IV.2 illustre la disposition géométrique des points expérimentaux dans l’espace factoriel bidimensionnel, démontrant la couverture systématique obtenue par l’approche CCD.




Figure VI.2 : Points expérimentaux dans le Plan Composite Centré à faces centrées pour deux facteurs. Les points 1-4 représentent les coins factoriels, les points 5-8 représentent les points axiaux centrés sur les faces, et le centre contient 3 observations répliquées.

Le domaine expérimental englobait toute la plage des conditions opérationnelles observées sur le site de Hassi R'Mel :

- Température ambiante (T_{moy}) : 282.65 K à 307.15 K (étendue de 24.5 K)
- Puissance de sortie (P) : 18 991 kW à 19 590,24 kW (plage de 599,24 kW)

Ce placement stratégique des points expérimentaux assure une estimation efficace de tous les paramètres du modèle quadratique tout en minimisant le nombre d'observations requises — un avantage critique lorsqu'on travaille avec des données opérationnelles industrielles où des expériences contrôlées sont impossibles.

IV.3.2 Modèle de Régression Développé

Par une analyse de régression multiple employant l'estimation des moindres carrés ordinaires, un modèle polynomial de second ordre a été développé pour prédire le rendement global :

$$\eta_g = 0.00853486 + 69.0693325T_{\text{moy}} + 0.56128272P - 0.00308481T_{\text{moy}}P - 2.1418 \times 10^{-5}P^2 - 0.0649829T_{\text{moy}}^2 \quad (\text{IV.1})$$

où η_g représente le rendement global (%), T_{moy} désigne la température ambiante moyenne (K), et P indique la puissance de sortie (kW).

Le modèle incorpore tous les termes essentiels : effets principaux, interactions à deux voies et effets quadratiques purs, fournissant une approximation de second ordre complète de la surface de réponse du rendement. Chaque coefficient offre des insights physiques sur le comportement thermodynamique de la turbine :

- **Effet principal de la température** (69.0693325) : Le coefficient positif représente la contribution linéaire de la température dans le modèle de régression. Toutefois, son interprétation ne peut être dissociée du terme quadratique. Pris conjointement avec ce dernier, il indique que la température exerce une influence non linéaire sur le rendement de la turbine à gaz, conformément au comportement physique attendu.
- **Effet principal de la puissance** (0.56128272) : Le coefficient positif suggère une augmentation du rendement à des niveaux de puissance plus élevés.
- **Interaction Température-Puissance** (-0.0030848) : Le terme d'interaction négatif indique que la sensibilité à la température varie avec le niveau de puissance opérationnel, révélant l'interdépendance complexe entre ces paramètres opérationnels.

- **Terme quadratique de température** (-0.0649829) : Le coefficient négatif traduit une courbure concave de la réponse, indiquant que le rendement diminue de manière de plus en plus marquée lorsque la température ambiante augmente. Ce comportement est cohérent avec les principes thermodynamiques, puisque l'élévation de la température réduit la densité de l'air admis, diminue le débit massique traversant le compresseur et entraîne ainsi une dégradation progressive du rendement de la turbine à gaz.
- **Terme quadratique de puissance** (-2.1418×10^{-5}) : L'amplitude proche de zéro indique que la relation rendement-puissance reste principalement linéaire dans le domaine étudié.

IV.3.3 Validation Statistique et Performance du Modèle

La validation statistique du modèle de régression élaboré a donné des résultats exceptionnels, démontrant l'efficacité de l'approche DoE pour capturer la relation complexe entre les paramètres opérationnels et le rendement de la turbine. Le tableau IV.1 présente les résultats expérimentaux et prédits du rendement global de la turbine avec la comparaison résiduelle.

Tableau IV.1 : Résultats expérimentaux, prédits et résidus du rendement de la turbine

Mois	T _{moy} (K)	P(KW)	Rendement Expérimental (%)	Rendement Prédite (%)	Résiduel (%)
Janvier	282,65	19590,24	25,67	25,6707	0,0007
Février	283,15	19578,034	25,65	25,6455	-0,0045
Mars	287,65	19468,143	25,64	25,6439	0,0039
Avril	292,15	19358,17	25,54	25,5394	-0,0006
Mai	296,65	19248,11	25,51	25,5112	0,0012
Juin	302,65	19101,24	25,36	25,3592	-0,0008
Juillet	307,15	18991,00	25,33	25,3295	-0,0005
Août	305,15	19040,003	25,22	25,2214	0,0014
Septembre	299,65	19174,693	25,12	25,1172	-0,0028
Octobre	293,15	19333,7181	25,03	25,0319	0,0019
Novembre	286,65	19492,571	24,95	24,9511	0,0011
Déc	283,65	19565,83	24,88	24,8788	-0,0012

A partir du tableau IV.1, le coefficient de détermination de 0.9999 indique que 99,99 % de la variance du rendement de la turbine est expliquée par le modèle, représentant un ajustement exceptionnel aux données expérimentales. La valeur de R^2 ajusté de 0.9999, tenant compte des 5 termes du modèle (2 linéaires, 1 interaction, 2 quadratiques) par rapport à la taille de l'échantillon de 12 observations, confirme que la complexité du modèle est entièrement justifiée sans risque de surparamétrage.

La statistique F de 1.94×10^4 dépasse largement la valeur critique fournissant une preuve statistique écrasante que le modèle de régression explique significativement plus de variance qu'un modèle nul contenant seulement la moyenne. La valeur p correspondante de 1.55×10^{-12} approche zéro, confirmant la significativité du modèle au-delà de tout doute raisonnable. Aussi la statistique F :

- Compare la variance expliquée par le modèle à la variance résiduelle.
- Plus F est grand, plus le modèle est meilleur qu'une simple moyenne.
- Ici F est énorme → le modèle explique vraiment quelque chose, ce n'est pas du hasard.

L'erreur standard de 0.00302 % représente l'amplitude typique des résidus de prédiction, qui est négligeable par rapport à la plage totale de rendement observée (24.88 % à 25.67 %, couvrant 0.79 point de pourcentage), soit moins de 0.39 % de cette plage. Ce niveau de précision permet des prédictions de rendement fiables pour les applications de planification opérationnelle et de surveillance de performance.

IV.3.4 Analyse des Résidus et Adéquation du Modèle

Des diagnostics complets des résidus ont été effectués pour vérifier les hypothèses fondamentales de régression et l'adéquation du modèle. La Figure IV.3 présente l'analyse détaillée des résidus pour chaque terme du modèle, démontrant l'absence de motifs systématiques qui indiqueraient une inadéquation du modèle.




Figure IV.3 : Graphiques des résidus pour chaque terme du modèle de régression. De haut en bas : résidus par rapport à la température (T), à la puissance (P), au carré de la température (TT), au carré de la puissance (PP), et à l'interaction température-puissance (T*P). Tous les graphiques montrent une dispersion aléatoire autour de zéro, confirmant l'adéquation du modèle.

Les graphiques des résidus révèlent plusieurs caractéristiques importantes validant les hypothèses du modèle :

- **Normalité :** Un graphique de probabilité normale a révélé que les résidus tombent approximativement le long d'une droite, indiquant une conformité à une distribution normale. Le test de Shapiro-Wilk a donné une valeur p dépassant 0.05, ne rejetant pas l'hypothèse de normalité aux niveaux de signification conventionnels. La distribution symétrique des résidus autour de zéro dans les cinq panneaux de la Figure IV.3 fournit une confirmation visuelle de cette normalité.

- **Homoscédasticité** : Les résidus tracés par rapport aux valeurs prédites ont montré une dispersion aléatoire sans motifs systématiques, confirmant une variance constante (homoscédasticité) sur toute la plage de prédiction. Le test de Breusch-Pagan a soutenu cette conclusion, validant une hypothèse clé de régression. Aucun motif en entonnoir ou tendance de variance n'est évident dans les graphiques des résidus.
- **Indépendance** : La statistique de Durbin-Watson approchait 2.0, suggérant l'absence d'autocorrélation significative dans les résidus. Ce résultat est approprié étant donné que des données moyennées mensuellement ont été employées, réduisant la dépendance temporelle qui pourrait autrement être présente dans des mesures à haute fréquence.
- **Détection des Valeurs Aberrantes** : Aucune observation n'a présenté de résidus standardisés dépassant ± 3 écarts-types, indiquant l'absence de valeurs aberrantes extrêmes. Tous les résidus standardisés se situaient dans la plage acceptable de -2,1 à +1,9, et par conséquent, tous les points de données ont été conservés dans le modèle final sans suppression ni transformation.

L'erreur de prédiction absolue maximale sur les douze mois était inférieure à 0,005 %, bien en deçà des limites d'incertitude des systèmes de mesure industriels. Cet accord remarquable entre les valeurs expérimentales et prédites confirme la capacité du modèle à représenter avec précision le comportement du rendement de la turbine sur tout l'enveloppe opérationnelle.

IV.3.5 Analyse des Coefficients de Régression et Interprétation Physique

Pour mieux comprendre la contribution de chaque terme du modèle, la Figure IV.4 présente les courbes de régression montrant la relation entre le rendement et chaque variable prédictive.




Figure IV.4 : Courbes de régression pour les coefficients du modèle. De haut en bas : rendement par rapport à la température (T), à la puissance (P), au carré de la température (T^2), et à l'interaction température-puissance (TP). Les carrés roses représentent le

rendement réel (R), et la ligne montre le rendement prédit (Prévisions R), démontrant un excellent accord pour tous les termes du modèle.

Les courbes de régression de la Figure IV.4 illustrent les relations fonctionnelles capturées par le modèle :

- **Effet de la Température** : Le rendement présente une tendance décroissante claire avec l'augmentation de la température, les points de données observés (carrés roses) suivant de près la relation prédite (ligne solide). La légère courbure visible dans cette relation justifie l'inclusion du terme quadratique de température dans le modèle.
- **Effet de la Puissance** : La relation entre la puissance et le rendement montre une tendance négative, bien que l'effet soit moins prononcé que pour la température. L'alignement étroit entre les valeurs réelles et prédites confirme une modélisation précise de cette relation.
- **Effet du Carré de la Température (Troisième Panneau)** : Ce panneau démontre la nature quadratique de la relation température-rendement, la courbure devenant plus apparente lors de l'examen du terme carré. Le coefficient de courbure positif suggère que le taux de baisse du rendement diminue légèrement aux températures extrêmes.
- **Interaction Température-Puissance (Panneau Inférieur)** : Le terme d'interaction capture comment l'effet de la température varie avec le niveau de puissance. L'excellent ajustement entre les valeurs prédites et réelles dans ce panneau confirme une modélisation réussie de cette interdépendance complexe.

IV.3.6 Implications Pratiques du Modèle DoE

Le modèle statistique développé fournit plusieurs insights exploitables pour l'opération industrielle des turbines à gaz :

- **Variation Saisonnière de Performance** : La différence de rendement de 3 % observée entre les mois d'hiver (25,67 %) et d'été (24,88 %) représente un impact économique substantiel. Pour une turbine fonctionnant en continu à environ 20 MW de puissance moyenne, cette dégradation de rendement se traduit par une consommation de carburant additionnelle annuelle significative, justifiant potentiellement un investissement en capital dans des systèmes de refroidissement d'air d'admission ou des technologies de refroidissement par évaporation.
- **Étalonnage de Performance en Temps Réel** : Le modèle permet une comparaison continue entre le rendement réel mesuré et le rendement prédit basé sur les conditions ambiantes actuelles et la puissance de sortie. Les écarts dépassant les limites d'incertitude attendues peuvent indiquer des problèmes de maintenance en développement, l'encrassement du compresseur, l'érosion des aubes de turbine ou d'autres mécanismes de dégradation des composants avant qu'ils ne précipitent des défaillances catastrophiques.
- **Planification Stratégique de la Maintenance** : Comprendre la relation quantitative température-rendement facilite la planification stratégique des activités de maintenance. Les révisions majeures peuvent être préférentiellement programmées pendant les périodes de rendement naturellement réduit (mois d'été chauds) pour minimiser l'impact économique de l'indisponibilité de l'unité, tout en préservant les périodes de haut rendement pour une production maximale.
- **Optimisation de la Charge** : Le modèle supporte les décisions optimales de répartition de charge dans les installations multi-unités en prédisant le rendement

relatif entre les unités sous diverses conditions ambiantes, permettant aux opérateurs de maximiser le rendement global de l'installation.

IV.4 Approche d'Optimisation Multi-Objectifs par Réseaux de Neurones

IV.4.1 Cadre d'Optimisation et Sélection d'Algorithme

La seconde approche de modélisation a employé des techniques avancées d'intelligence artificielle, spécifiquement des Réseaux de Neurones Profonds (DNN) optimisés par des algorithmes métaheuristiques multi-objectifs. Cette méthodologie aborde le défi fondamental de la conception de réseaux neuronaux : déterminer l'architecture optimale qui équilibre la précision prédictive contre l'efficacité computationnelle — une considération critique pour les applications industrielles en temps réel.

Trois algorithmes métaheuristiques de pointe basés sur des populations ont été implémentés pour une analyse comparative :

1. **Optimiseur des Loups Gris (GWO)** : Inspiré de la hiérarchie sociale et du comportement de chasse coopératif des meutes de loups gris, avec des loups alpha, bêta, delta et oméga guidant le processus de recherche.
2. **Algorithme d'Optimisation du Secrétaire (SBOA)** : Un nouvel algorithme bio-inspiré imitant les stratégies de recherche de nourriture uniques des oiseaux secrétaires, incorporant des motifs de mouvement en spirale et un mécanisme de chasse en trois étapes (recherche, approche, attaque).
3. **Optimiseur de la Hyène Tachetée (SHO)** : Basé sur les stratégies de chasse collaborative et la hiérarchie sociale des clans de hyènes tachetées, particulièrement efficace pour éviter les optima locaux grâce à des mécanismes d'encerclement sophistiqués.

Chaque algorithme a été configuré avec des paramètres identiques pour assurer une comparaison équitable : une taille de population de 10 individus, un maximum de 10 itérations, et 5 exécutions indépendantes pour tenir compte de la variabilité stochastique inhérente à l'optimisation métaheuristique.

IV.4.2 Formulation du Problème Multi-Objectifs

La conception de l'architecture neuronale a été formulée comme un problème d'optimisation bi-objectifs :

$$\left\{ \begin{array}{l} \text{Maximize: } R^2(\hat{\eta}, \eta) = 1 - \frac{\sum_{i=1}^n (\eta_i - \hat{\eta}_i)^2}{\sum_{i=1}^n (\eta_i - \bar{\eta})^2} \\ \text{Minimize: } t_{\text{train}} = \text{computational time for model training} \end{array} \right. \quad (\text{IV.2})$$

Cette formulation reconnaît explicitement le compromis fondamental entre la complexité du modèle (qui améliore généralement la précision mais augmente le coût computationnel) et les considérations de déploiement pratique (qui favorisent un apprentissage et une inférence rapides pour les applications en temps réel).

L'espace de recherche d'optimisation englobait :

- Nombre de couches cachées : 3 (profondeur d'architecture fixe)
- Neurones par couche : 1 à 128 (largeur de couche variable)
- Taux d'apprentissage : 0.001 à 0.1 (contrôlant la vitesse de convergence)

IV.4.3 Mise en œuvre des Contraintes Physiques

Pour garantir la validité thermodynamique, une contrainte physique critique a été explicitement incorporée dans le cadre d'entraînement du réseau neuronal :

$$\forall (T, M) \in \mathbb{R}^2, \quad P = 0 \Rightarrow \eta = 0 \quad (\text{IV.3})$$

Cette contrainte incarne le principe fondamental qu'une puissance de sortie nulle implique nécessairement un rendement nul — une réalité thermodynamique de base. Des points de données d'entraînement supplémentaires ont été systématiquement générés sur toute la plage de température opérationnelle (270-320 K) et pour tous les indices mensuels avec une puissance d'entrée nulle, forçant le réseau neuronal à apprendre ce comportement physique essentiel. Cette approche garantit que les prédictions du modèle restent physiquement plausibles même lors d'une extrapolation au-delà des limites du jeu de données d'entraînement original.

IV.4.4 Performance Comparative des Algorithmes

Le Tableau IV.1 présente les solutions complètes du front de Pareto découvertes par chaque algorithme d'optimisation, révélant des caractéristiques algorithmiques distinctes et des compromis de performance.

Tableau IV.1 : Solutions du Front de Pareto de l'Optimisation Multi-Objectifs

Algorithme	ID Solution	Architecture	Taux d'Apprentissage	Score R ²	Temps d'Entraînement (s)
MOGWO	M1	[22, 43, 40]	0.03877	0.999995	4.563
	M2	[50, 47, 12]	0.02564	0.999988	4.531
	M3	[20, 12, 31]	0.02833	0.999955	4.509
	M4	[16, 8, 5]	0.01772	0.999377	4.505
SHO	S1	[128, 36, 22]	0.09706	0.999998	4.721
	S2	[107, 57, 28]	0.05601	0.999975	4.663
	S3	[128, 38, 28]	0.07036	0.999999	4.767
SBOA	B1	[120, 4, 4]	0.10000	0.999998	4.475

L'algorithme MOGWO a démontré les capacités exploratoires les plus fortes, produisant quatre solutions diverses couvrant un large espace architectural, des réseaux compacts (M4 : [16, 8, 5]) aux architectures complexes (M1 : [22, 43, 40]). Cette diversité fournit aux décideurs de multiples options adaptées à différents scénarios de déploiement et profils de contraintes. Cependant, cette force exploratoire s'accompagne d'un compromis : l'étendue

significative des scores R^2 (0.999377 à 0.999995) indique une certaine variabilité dans la qualité des solutions, et les temps d'entraînement moyens n'étaient pas les plus compétitifs.

L'algorithme SHO a atteint la précision prédictive absolue la plus élevée avec la solution S3 ($R^2 = 0.999999$), confirmant sa capacité exceptionnelle à exploiter les régions haute performance de l'espace de recherche. Les trois solutions SHO présentaient des architectures relativement larges avec 107-128 neurones dans la première couche, reflétant la convergence de l'algorithme vers des réseaux complexes. Cependant, cette précision de pointe s'est faite au prix des temps d'entraînement les plus longs, dépassant systématiquement 4.66 secondes — environ 4-6 % plus lent que les solutions les plus rapides.

Contrairement à ces approches diverses, l'algorithme SBOA a convergé vers une solution unique et hautement spécialisée (B1 : [120, 4, 4]) représentant le meilleur équilibre entre précision et coût computationnel. Cette architecture en goulot d'étranglement unique — avec une première couche large suivie de couches subséquentes étroites — a atteint une précision quasi parfaite ($R^2 = 0.999998$) tout en offrant le temps d'entraînement le plus rapide (4.475 secondes). La convergence vers une solution unique suggère un comportement de recherche hautement exploitatif, concentrant les ressources computationnelles sur le raffinement d'un candidat exceptionnel plutôt que sur l'exploration d'alternatives.

La Figure IV.5 visualise les fronts de Pareto découverts par chaque algorithme dans l'espace objectif, illustrant clairement les compromis entre la précision prédictive et l'efficacité computationnelle.




Figure IV.5 : Fronts de Pareto atteints par les algorithmes MOGWO, SBOA et SHO dans l'espace bi-objectifs du score R^2 par rapport au temps d'entraînement. MOGWO (bleu) montre une distribution de solutions diverse, SBOA (rouge) converge vers un point optimal unique, et SHO (vert) se regroupe dans la région de haute précision avec des temps d'entraînement plus longs.

Le graphique de Pareto de la Figure IV.5 fournit une preuve visuelle convaincante des compromis algorithmiques discutés ci-dessus. Les solutions MOGWO (marqueurs bleus) sont réparties sur une région plus large de l'espace objectif, offrant de multiples solutions de compromis entre précision et vitesse. Les solutions SHO (marqueurs verts) se regroupent dans la région supérieure droite, privilégiant la précision maximale au détriment d'un temps

computationnel accru. Plus remarquablement, la solution SBOA (marqueur rouge) occupe la position idéale dans le coin inférieur droit, atteignant simultanément une précision quasi maximale avec un temps d'entraînement minimal — la véritable solution Pareto-optimale pour ce problème.

IV.4.5 Architecture de Réseau Neuronal Optimale et Performance

Sur la base de l'analyse multi-objectifs complète, la solution optimisée par SBOA est apparue comme la configuration la plus précieuse en pratique. L'architecture optimale consiste en :

- Couche d'entrée : 120 neurones
- Couche cachée 1 : 4 neurones
- Couche cachée 2 : 4 neurones
- Couche de sortie : 1 neurone (prédiction du rendement)
- Taux d'apprentissage optimal : 0.1

Cette architecture légère a atteint une performance statistique exceptionnelle, comme détaillé dans le Tableau IV.2.

Tableau IV.2 : Performance Mensuelle du Réseau Neuronal Optimisé par SBOA

Mois	Rendement Réel (%)	Rendement Prédit (%)	Erreur Absolue (%)
Janvier	25.670	25.670	0.000
Février	25.650	25.653	0.003
Mars	25.510	25.507	0.003
Avril	25.360	25.363	0.003
Mai	25.220	25.219	0.001
Juin	25.030	25.027	0.003
Juillet	24.880	24.882	0.002
Août	24.950	24.946	0.004
Septembre	25.120	25.123	0.003
Octobre	25.330	25.331	0.001
Novembre	25.540	25.539	0.001
Décembre	25.640	25.635	0.005

Métriques de Performance Globales :

- Coefficient de détermination : $R^2 = 0.999998$
- Racine de l'Erreur Quadratique Moyenne (RMSE) : 0.002771 %
- Erreur absolue maximale : 0.005 %
- Temps d'entraînement : 4.475 secondes

Le R^2 atteint de 0.999998 indique que le modèle explique virtuellement toute la variance du rendement de la turbine à gaz, avec la RMSE de 0.002771 % confirmant des différences négligeables entre les valeurs réelles et prédites. L'erreur de prédiction absolue maximale de 0.005 % se situe bien en deçà des limites d'incertitude des mesures industrielles, démontrant une précision pratique exceptionnelle.

La Figure IV.6 présente une comparaison visuelle entre les valeurs de rendement réelles et prédites sur les douze mois d'opération, démontrant l'alignement quasi parfait atteint par le réseau neuronal optimisé par SBOA.

La représentation visuelle de la Figure IV.6 illustre de façon frappante la performance du modèle. Les deux courbes sont virtuellement indistinguables sur tout le cycle annuel, suivant à la fois la variation saisonnière du rendement (de 24.88 % en juillet à 25.67 % en janvier) et les fluctuations subtiles de mois en mois. Ce niveau d'accord valide que le réseau neuronal a appris avec succès les relations non linéaires complexes gouvernant le rendement de la turbine sous diverses conditions ambiantes.




Figure IV.6 : Comparaison entre le rendement réel mesuré (ligne bleue) et le rendement prédit par SBOA-DNN (ligne orange) sur douze mois d'opération. Le chevauchement quasi parfait démontre la précision prédictive exceptionnelle du modèle, avec un écart maximal de seulement 0,005 %.

IV.4.6 Dynamique d'Entraînement et Convergence du Modèle

Le processus d'entraînement et la performance de validation du réseau neuronal optimisé par SBOA sont illustrés dans la Figure IV.7, qui présente les courbes de perte tout au long des époques d'entraînement.




Figure IV.7 : Courbes de perte d’entraînement et de validation pour le modèle DNN optimisé par SBOA. Les deux courbes montrent une descente initiale rapide suivie d’une convergence vers des valeurs proches de zéro, la perte d’entraînement (bleu) et la perte de validation (orange) suivant des trajectoires proches tout au long, confirmant une excellente généralisation sans surajustement (overfitting).

Les courbes de perte de la Figure IV.7 révèlent plusieurs caractéristiques importantes du processus d’entraînement :

- **Apprentissage Initial Rapide :** Les pertes d’entraînement et de validation diminuent fortement pendant les premières 20-30 époques, indiquant que le réseau capture rapidement les relations primaires dans les données. Cette convergence rapide est facilitée par le taux d’apprentissage optimisé de 0.1 découvert par SBOA.
- **Convergence Douce :** L’absence d’oscillations ou de comportements erratiques dans les courbes de perte confirme des dynamiques d’entraînement stables. La combinaison d’architecture et de taux d’apprentissage sélectionnée évite les pathologies courantes de l’entraînement telles que l’explosion ou la disparition du gradient.
- **Capacité de Généralisation :** Les trajectoires presque identiques de la perte d’entraînement (courbe bleue) et de la perte de validation (courbe orange) fournissent une preuve forte contre le surajustement. Un modèle bien généralisé devrait performer de manière similaire sur les données d’entraînement et sur des données de validation jamais vues, ce qui est clairement démontré ici.
- **Perte Finale Proche de Zéro :** Les deux courbes convergent vers des pertes approchant zéro (environ 10^{-8} en unités normalisées), correspondant à la RMSE exceptionnellement faible de 0.002771 % rapportée dans le Tableau IV.2. Cela confirme que le modèle a réussi à minimiser les erreurs de prédiction à des niveaux situés dans l’incertitude de mesure.
- **Comportement de Plateau :** Après environ 40-50 époques, les deux courbes atteignent un plateau stable, indiquant une convergence complète. Un entraînement supplémentaire au-delà de ce point apporterait une amélioration négligeable tout en augmentant le coût computationnel — l’optimisation SBOA a identifié avec succès la durée d’entraînement optimale.

IV.4.7 Insights Architecturaux et Analyse d'Efficacité

L'architecture distinctive en goulot d'étranglement découverte par SBOA ([120, 4, 4]) mérite une analyse détaillée. Ce motif structurel — avec une couche d'entrée large suivie de couches cachées sévèrement compressées — diffère substantiellement des architectures conventionnelles d'apprentissage profond qui maintiennent ou réduisent généralement la largeur des couches progressivement.

La première couche large (120 neurones) permet une extraction exhaustive des caractéristiques des trois variables d'entrée (température ambiante, puissance de sortie, indice du mois), apprenant potentiellement des transformations et interactions non linéaires complexes. La compression sévère subséquente à 4 neurones dans chaque couche cachée force le réseau à apprendre des représentations hautement efficaces, éliminant les informations redondantes tout en préservant les caractéristiques prédictives essentielles. Ce goulot d'étranglement d'information agit comme une forme de régularisation, empêchant le surajustement tout en maintenant la capacité de représentation pour la tâche de prédiction relativement simple.

D'un point de vue computationnel, cette architecture minimise le nombre de paramètres dans les couches plus profondes où la majeure partie du coût computationnel s'accumule pendant la rétropropagation. Le nombre total de paramètres entraînaux dans cette configuration est d'environ 15 000, substantiellement moins que des architectures comme S3 ([128, 38, 28]) qui contient plus de 30 000 paramètres, expliquant directement la vitesse d'entraînement supérieure.

La structure en goulot peut également être comprise d'un point de vue informationnel : la première couche étend l'entrée dans un espace de caractéristiques de haute dimension où les relations non linéaires peuvent être plus facilement séparées, tandis que les couches en goulot effectuent une réduction de dimensionnalité pour extraire seulement les caractéristiques les plus pertinentes pour la prédiction du rendement. Cela est analogue à une analyse en composantes principales dans un contexte non linéaire, où le réseau apprend automatiquement la compression optimale des caractéristiques.

IV.5 Analyse Comparative des Approches de Modélisation

IV.5.1 Comparaison de la Précision Prédictive

Les deux approches de modélisation ont atteint une précision prédictive exceptionnelle, bien que par des mécanismes fondamentalement différents :

Modèle Statistique (DoE/RSM) :

- $R^2 = 0.9999$
- Erreur standard = 0.00302 %
- Erreur maximale < 0.005 %
- Forme mathématique explicite permettant une interprétation analytique

Modèle de Réseau Neuronal (SBOA-DNN) :

- $R^2 = 0.999998$
- RMSE = 0.002771 %

- Erreur maximale = 0.005 %
- Représentation de type "boîte noire" avec une capacité d'ajustement supérieure

Le réseau neuronal a atteint une performance statistique marginalement supérieure (différence de R^2 de ~ 0.000098), bien que cette amélioration soit pratiquement négligeable étant donné que les deux modèles prédisent le rendement dans les limites de l'incertitude de mesure. La distinction clé réside non dans l'amplitude de la précision mais dans l'interprétabilité et la flexibilité du modèle.

Les erreurs maximales presque identiques (0.005 %) atteintes par les deux approches suggèrent que ce niveau représente la limite pratique de précision de prédiction compte tenu de l'incertitude de mesure inhérente aux données opérationnelles. Des améliorations supplémentaires nécessiteraient des données de capteurs de meilleure qualité ou des variables d'entrée additionnelles plutôt que des techniques de modélisation plus sophistiquées.

IV.5.2 Interprétabilité du Modèle et Insight Physique

Le modèle de régression statistique offre des relations mathématiques explicites avec des coefficients interprétables révélant des mécanismes physiques :

- Quantification directe de l'effet de la température : réduction du rendement de -0.0693 % par Kelvin
- Identification claire des effets d'interaction entre la température et la puissance
- Calcul immédiat des dérivées pour l'analyse de sensibilité
- Structure transparente facilitant l'approbation réglementaire et la confiance des parties prenantes

Les courbes de régression présentées dans la Figure IV.4 permettent aux ingénieurs de comprendre visuellement comment chaque facteur influence le rendement, soutenant une prise de décision éclairée concernant les stratégies opérationnelles et les initiatives d'optimisation de performance.

En revanche, le réseau neuronal fonctionne comme un approximateur de fonction de type "boîte noire". Bien qu'il réalise d'excellentes prédictions, les représentations apprises dans les couches cachées manquent d'interprétation physique directe. Comprendre pourquoi des prédictions spécifiques sont faites nécessite des techniques sophistiquées comme l'analyse de sensibilité, le calcul d'importance des caractéristiques ou des méthodes d'interprétation basées sur le gradient.

Pour les applications nécessitant une conformité réglementaire, une certification de sécurité ou une transparence envers les parties prenantes, l'interprétabilité du modèle statistique représente un avantage significatif. Pour une performance prédictive pure dans des contextes opérationnels où la précision prime sur l'interprétabilité, le réseau neuronal excelle.

IV.5.3 Exigences Computationnelles

A. Développement du Modèle :

- Modèle statistique : Une seule analyse de régression terminée en quelques secondes avec un logiciel statistique standard

- Réseau neuronal : De multiples exécutions d'optimisation (5 répétitions $\times$ 3 algorithmes $\times$ 10 itérations) nécessitant plusieurs heures de calcul

B. Déploiement et Inférence :

- Modèle statistique : Évaluation instantanée de l'équation polynomiale (microsecondes)
- Réseau neuronal : Propagation avant à travers 3 couches (millisecondes)

Les deux approches offrent une capacité de prédiction en temps réel adaptée aux systèmes de contrôle industriels, bien que le modèle statistique offre une implémentation plus simple dans les systèmes hérités. Le temps d'entraînement du réseau neuronal de 4.475 secondes par itération de modèle devient pertinent lorsqu'on considère un réentraînement périodique du modèle pour s'adapter à la dégradation de la turbine ou aux motifs saisonniers.

Cependant, l'investissement computationnel initial dans l'optimisation d'architecture neuronale porte ses fruits grâce à la découverte de la structure hautement efficace [120, 4, 4]. Cette architecture peut être réutilisée sur des installations de turbines similaires, amortissant le coût d'optimisation sur plusieurs déploiements.

IV.5.4 Généralisation et Comportement d'Extrapolation

A. Modèle Statistique :

- L'extrapolation polynomiale peut produire des valeurs irréalistes en dehors du domaine d'entraînement
- Les termes quadratiques peuvent faire augmenter les prédictions de rendement à des températures extrêmes (physiquement impossibles)
- Nécessite des restrictions de domaine soigneuses dans l'implémentation

B. Réseau Neuronale avec Contraintes Physiques :

- Explicitement entraîné pour satisfaire la contrainte puissance-nulle/rendement-nul
- Les fonctions d'activation ReLU fournissent une extrapolation bornée, linéaire par morceaux
- Prédiction mieux comportées près des limites du domaine
- La mise en œuvre des contraintes physiques améliore la robustesse

L'incorporation de contraintes thermodynamiques dans l'entraînement du réseau neuronal représente un avantage méthodologique significatif, garantissant que les prédictions restent physiquement plausibles même lors d'une extrapolation — une considération critique pour les applications de détection de défauts où des conditions opérationnelles anormales peuvent survenir.

Cette distinction est particulièrement importante pour les systèmes de surveillance d'état qui doivent distinguer les véritables anomalies (dégradation de composant, défaillance de capteur) des conditions opérationnelles légèrement en dehors du domaine d'entraînement. Le comportement d'extrapolation borné du réseau neuronal réduit les fausses alarmes, tandis que le modèle statistique pourrait prédire des rendements physiquement impossibles (par exemple, dépassant 100 % ou devenant négatifs) dans des conditions extrêmes.

IV.5.5 Exigences en Données et Efficacité d'Échantillonnage

Les deux approches ont utilisé des données identiques (12 observations mensuelles), mais leurs caractéristiques d'efficacité des données diffèrent :

A. Modèle Statistique :

- Estimation efficace des paramètres avec des données limitées (12 observations pour 6 paramètres)
- Repose sur des hypothèses structurelles fortes (forme quadratique)
- Peut sous-ajuster (underfit) des relations non linéaires complexes

B. Réseau Neuronal :

- Nécessite généralement des jeux de données plus importants pour un entraînement fiable
- A atteint une excellente performance malgré des données limitées grâce à [l'architecture optimisée, la régularisation, les contraintes physiques]

Pour cette application spécifique avec des relations thermodynamiques claires et des conditions opérationnelles variant naturellement de façon limitée, les deux approches démontrent une efficacité d'échantillonnage adéquate. Pour des configurations de turbine plus complexes avec des variables d'entrée additionnelles, l'approche structurée du modèle statistique pourrait nécessiter des termes d'ordre supérieur ou des transformations, tandis que le réseau neuronal pourrait s'adapter plus flexiblement dans ses représentations apprises.

L'application réussie des réseaux neuronaux à ce jeu de données limité souligne l'importance d'une sélection d'architecture appropriée. La structure en goulot découverte par SBOA fournit une capacité suffisante pour modéliser les relations non linéaires tout en évitant le surajustement — un équilibre qui serait difficile à atteindre par une conception d'architecture manuelle.

IV.5.6 Guide de Sélection d'Algorithme

L'analyse comparative des algorithmes, visualisée dans le graphique de Pareto (Figure IV.5), révèle des caractéristiques distinctes d'algorithmes d'optimisation adaptés à différents scénarios de déploiement :

Tableau IV.3 : Caractéristiques des Algorithmes et Applications Recommandées

Algorithme	Point Fort Clé	Cas d'Utilisation Recommandé
MOGWO	Grande diversité de solutions, fournissant de multiples options architecturales	Études exploratoires ; applications avec des contraintes incertaines ou de multiples parties prenantes nécessitant des choix
SHO	Précision prédictive maximale avec des architectures complexes robustes	Applications de recherche priorisant la précision absolue ; systèmes critiques pour la sécurité
SBOA	Équilibre optimal : haute précision avec une efficacité computationnelle supérieure	Systèmes de production ; déploiement en périphérie (edge) ; environnements à ressources limitées ; exigences d'inférence rapide

La découverte par SBOA d'une architecture efficace en goulot d'étranglement représente une contribution particulièrement précieuse, suggérant que ce motif structurel pourrait se généraliser à des tâches de prédiction industrielles similaires où les espaces de caractéristiques sont relativement de faible dimension mais où les relations non linéaires nécessitent la flexibilité des réseaux neuronaux.

Les preuves visuelles de la Figure IV.5 soutiennent une prise de décision claire : les organisations priorisant l'exploration et la diversité architecturale devraient employer MOGWO ; celles nécessitant une précision absolue maximale quel que soit le coût computationnel devraient utiliser SHO ; et celles recherchant un déploiement de production optimal devraient exploiter SBOA. En pratique, une approche hybride pourrait employer MOGWO lors de l'exploration initiale, puis raffiner les familles architecturales les plus prometteuses en utilisant SBOA pour l'optimisation finale.

IV.6 Conclusion

Ce chapitre présente les résultats complets de deux approches de modélisation proposées pour prédire le rendement de la turbine à gaz MS5002B sous diverses conditions opérationnelles sur le site de Hassi R'Mel en Algérie. Les deux méthodologies ont démontré une capacité prédictive exceptionnelle, le modèle statistique des Plans d'Expériences atteignant $R^2 = 0.9999$ et le réseau neuronal optimisé par SBOA atteignant $R^2 = 0.999998$.

L'analyse comparative a révélé que les deux approches offrent des avantages distincts : le modèle statistique excelle en interprétabilité et simplicité d'implémentation, tandis que le réseau neuronal offre une précision marginalement supérieure, un meilleur comportement d'extrapolation grâce aux contraintes physiques, et une plus grande flexibilité pour les relations non linéaires complexes. Plutôt que des alternatives concurrentes, ces méthodologies forment des composantes complémentaires d'une stratégie complète de surveillance de performance des turbines à gaz, le cadre complet (Figure IV.1) fournissant un modèle systématique pour des applications industrielles similaires.

La recherche démontre que des techniques de modélisation sophistiquées peuvent extraire un maximum d'informations de données opérationnelles limitées, fournissant des outils pratiques pour des applications industrielles où une expérimentation dédiée est coûteuse ou impossible. Les modèles développés permettent un étalonnage de performance en temps réel, une planification stratégique de la maintenance et des capacités d'optimisation opérationnelle de plus en plus essentielles alors que le secteur de l'énergie met l'accent sur l'efficacité, la réduction des émissions et la maintenance prédictive.

Conclusion Générale

Ce travail de recherche a abordé deux problématiques majeures liées aux turbines à gaz industrielles : la compréhension approfondie des mécanismes de dégradation et le développement de méthodologies avancées pour la prédiction en temps réel de leur rendement. À travers une approche méthodologique rigoureuse combinant modélisation statistique classique et techniques d'intelligence artificielle, cette thèse apporte des contributions significatives tant sur le plan scientifique que pratique.

L'analyse des mécanismes de dégradation présentée dans le deuxième chapitre a révélé que l'encrassement du compresseur constitue le facteur dominant, responsable de plus de 70% de la détérioration des performances. Ainsi que la qualité des systèmes de filtration d'air représente le paramètre clé influençant les taux d'encrassement, l'emportant largement sur les caractéristiques de conception inhérentes du moteur. Cette analyse souligne l'importance d'investir dans des systèmes de filtration haute performance plutôt que de se concentrer exclusivement sur l'optimisation des conceptions de turbines.

Les résultats de modélisation présentés dans le quatrième chapitre ont démontré l'efficacité remarquable des deux approches développées. Le modèle statistique basé sur la méthodologie des Plans d'Expériences a atteint un coefficient de détermination R^2 de 0,9999, avec une erreur standard de seulement 0.00302 %. Cette approche offre l'avantage d'une interprétabilité complète, quantifiant directement l'effet de la température (-0,0693% par Kelvin) sur le rendement. Parallèlement, l'approche par réseaux de neurones profonds optimisés par métaheuristiques a surpassé le modèle statistique avec un R^2 de 0,999998 et une RMSE de 0,002771%. Plus remarquablement, l'algorithme SBOA a découvert une architecture neuronale hautement efficace ([120, 4, 4]) qui représente le meilleur équilibre entre précision prédictive et efficacité computationnelle, avec un temps d'entraînement de seulement 4,475 secondes.

La contribution méthodologique majeure de cette recherche réside dans la formulation explicite du problème d'optimisation d'architecture neuronale comme un problème multi-objectifs, permettant la découverte de solutions Pareto-optimales qui équilibrent précision et coût computationnel. L'incorporation de contraintes physiques thermodynamiques dans le processus d'apprentissage garantit que les prédictions restent physiquement plausibles même lors d'extrapolations, une caractéristique essentielle pour les applications de détection d'anomalies.

Les modèles développés offrent plusieurs applications pratiques immédiates : étalonnage de performance en temps réel, planification stratégique de la maintenance, optimisation de répartition de charge dans les installations multi-unités, et détection précoce de dégradations anormales. L'architecture neuronale légère découverte est particulièrement adaptée au déploiement sur des dispositifs périphériques (edge computing) avec ressources computationnelles limitées, ouvrant la voie à des systèmes de surveillance décentralisés.

Malgré les résultats prometteurs obtenus, plusieurs perspectives de recherche méritent d'être explorées. Premièrement, la validation des modèles sur différents types de turbines et dans diverses conditions géographiques permettrait d'établir leur généralité. Deuxièmement, l'incorporation de variables additionnelles telles que l'humidité relative, la pression barométrique et l'historique de maintenance pourrait améliorer significativement la précision

prédictive. Troisièmement, le développement de systèmes de détection d'anomalies basés sur les écarts entre rendement prédit et mesuré représente une extension naturelle de ce travail.

En conclusion, cette recherche démontre que la combinaison judicieuse de méthodologies statistiques classiques et de techniques avancées d'intelligence artificielle permet d'extraire un maximum d'informations de données opérationnelles limitées. Les modèles développés fournissent des outils pratiques et robustes pour la surveillance et l'optimisation des performances des turbines à gaz, contribuant ainsi aux objectifs d'efficacité énergétique et de réduction des émissions qui constituent des priorités majeures du secteur énergétique moderne.

Références bibliographiques

- [1] Boissenin, Y., Moliere, M., et Remy, P., 1994, "Les atouts de la turbine à gaz MS6001 B en cogénération –exemple de l'usine d'électricité de Metz", Revue technique Gec Alstom N°15.
- [2] Jacques Maunand, Production d'électricité par turbine à gaz, Techniques de l'Ingénieur, Réf. D 4001, pp. 1–16, validated 04 Jul 2023.
- [3] André Lallemand. "Production d'énergie électrique par centrales thermiques," Techniques de l'Ingénieur, Réf. D4002. DOI:10.51257/a-v2-d4002 (article updated/reviewed 2021).
- [4] Yu, J., Zhang, G., Yang, Q., Zhang, H., Liu, M., & Xu, G. (2024). Analytical solution and its application for the dynamic characteristics of a heat recovery steam generator in gas–steam combined cycle. *Applied Thermal Engineering*, 238, 122170.
- [5] Chang H. Oh and Richard L. Moore, "Brayton cycle for high temperature gas-cooled reactors", Nuclear Technology Vol. 149, pp. 324-336, MAR. 2005.
- [6] Pascal Anzieu, Jean François Parisot et Bernard BIGOT, 2006, "Les réacteurs nucléaires à caloporteur gaz", CEA Saclay et Groupe Moniteur (Edition du Moniteur), Paris.
- [7] David J. Taylor Olivier Crabos, 2003, "GE Power Systems Gas Turbine and Combined Cycle Products Technology - Experience - Innovation", Gas turbine and Combined Cycle - GE Power Systems 2003.
- [8] Mzad, H., & Bennour, F. (2024). Industrial gas turbine performance prediction and improvement -- a case study. *Energy Harvesting and Systems*, 11(1), 20220094.
- [9] Salilew, W. M., Abdul Karim, Z. A., Lemma, T. A., Fentaye, A. D., & Kyprianidis, K. G. (2022). Predicting the performance deterioration of a three-shaft industrial gas turbine. *Entropy*, 24(8), 1052.
- [10] Kurz, R., & Brun, K. (2001). Degradation in gas turbine systems. *Journal of Engineering for Gas Turbines and Power*, 123(1), 70-77.
- [11] Morini, M., Pinelli, M., Spina, P. R., & Venturini, M. (2010). Influence of blade deterioration on compressor and turbine performance. *Journal of Engineering for Gas Turbines and Power*, 132(3), 032401.
- [12] Burnes, D., & Kurz, R. (2018, January). Performance degradation effects in modern industrial gas turbines. In *Proceedings of Zurich Global Power and Propulsion Forum* (Vol. 124).
- [13] United Nations. (2015). Report of the Conference of the Parties on its Twenty-First Session, held in Paris from 30 November to 13 December 2015.
- [14] Allam, R. J., Palmer, M. R., Brown Jr., G. W., Fetvedt, J., Freed, D., Nomoto, H., ... Jones Jr., C. (2013). High efficiency and low cost of electricity generation from fossil fuels while eliminating atmospheric emissions, including carbon dioxide. *Energy Procedia*, 37, 1135-1149.

- [15] Memon, A. G., Harijan, K., Uqaili, M. A., & Memon, R. A. (2013). Thermo-environmental and economic analysis of simple and regenerative gas turbine cycles with regression modeling and optimization. *Energy Conversion and Management*, 76, 852-864.
- [16] Bensouici, M., Azizi, M. W., & Bensouici, F. Z. (2023). Performance Analysis and Optimization of Regenerative Gas Turbine Power Plant using RSM: Optimization of regenerative gas turbine power plant. *International Journal of Automotive and Mechanical Engineering*, 20(3), 10671-10683.
- [17] Egware, H. O., & Kwasi-Effah, C. C. (2023). A novel empirical model for predicting the carbon dioxide emission of a gas turbine power plant. *Heliyon*, 9(3), e14645.
- [18] IEA. (2015). Energy and climate change, World Energy Outlook special report. International Energy Agency.
- [19] Balaji, C., & Balaji. (2021). *Thermal system design and optimization*. Springer International Publishing.
- [20] Kurzke, J. (2007). About simplifications in gas turbine performance calculations. Gasturb GmbH.
- [21] Masaki Bannai, Akira Houkabe, Masahiro Furukawa, Takao Kashiwagi, Atsushi Akisawa, Takuya Yoshida, Hiroyuki Yamada, 2006, "Development of efficiency-enhanced cogeneration system utilizing high-temperature exhaust-gas from a regenerative thermal oxidizer for waste volatile-organic-compound gases", *Applied Energy*, Vol. 83, pp. 929–942.
- [22] L. Bertin Erbay, Selahattin Gofiktun, Hashi Yavuz, 2001, "Optimal design of the regenerative gas turbine engine with isothermal heat addition", *Applied Energy*, Vol. 68, pp. 249-264.
- [23] Lingen Chen, Ye Li, Fengrui Sun, Chih Wu, 2004, "Power optimization of open-cycle regenerator gas-turbine power-plants", *Applied Energy*., Vol. 78, pp. 199–218.
- [24] Kyoung Hoon Kim, Horacio Perez-Blanco, 2007, "Potential of regenerative gas-turbine systems with high fogging compression", *Applied Energy*, Vol. 84, pp. 16–28.
- [25] Macchi, E., Consonni S., Lozza, G., and Chiesa, P., 1995, "An assessment of the thermodynamic performance of mixed gas-steam cycles: Part A – Intercooled and steam-injected cycles", *ASME J Eng Gas-Turbines Power*, 117:489–98.
- [26] Danilo Salvi, Paolo Pierpaoli, 2002, "Optimization of inlet air cooling systems for steam injected gas turbines", *International Journal of Thermal Sciences*, Vol. 41, pp. 815–822.
- [27] F.J. Wang, J.S. Chiou, 2004, "Integration of steam injection and inlet air cooling for a gas turbine generation system", *Energy Conversion and Management*, Vol. 45, pp. 15–26.
- [28] Milancej, M., 2005, "Advanced Gas Turbine Cycles: Thermodynamic Study on the Concept of Intercooled Compression Process", Diploma Thesis Institut für Thermodynamik und Energie wandlung Technische Universität Wien Vienna.

- [29] Mun Roy Yap and Ting Wang, 2006, "Simulation of Producer Gas Fired Power Plants with Inlet Fog Cooling and Steam Injection", ASME GT2006-90164, Proceedings of GT2006, ASME Turbo Expo 2006: Power for Land, Sea & Air, May 8-11, Barcelona, Spain.
- [30] Amir Abbas Zadpoor, Ali Hamedani Golshan, 2006, "Performance improvement of a gas turbine cycle by using a desiccant-based evaporative cooling system", *Energy*, vol. 31, pp. 2652–2664.
- [31] H. Canière, A. Willockx, E. Dick, M. De Paepe, 2006, "Raising cycle efficiency by intercooling in air-cooled gas turbines", *Applied Thermal Engineering*, Vol. 26, pp. 1780–1787.
- [32] S. Boonnasa, P. Namprakai, T. Muangnapoh, 2006, "Performance improvement of the combined cycle power plant by intake air cooling using an absorption chiller", *Energy*, Vol. 31, pp. 2036–2046.
- [33] Jean-Pierre Bédécarrats, Françoise Strub, 2008, "Gas turbine performance increase using an air cooler with a phase change energy storage", *Applied Thermal Engineering*, Volume 29, Issues 5-6, April 2009, pp: 1166-1172.
- [34] Bruno Facchini, Giovanni Ferrara and Luca Innocenti, 2000, "Blade cooling improvement for heavy duty gas turbine: the air coolant temperature reduction and the introduction of steam and mixed steam/air cooling", *Int. J. Therm. Sci.*, Vol. 39, pp. 74–84.
- [35] A.M. Bassily, 2004, "Performance improvements of the intercooled reheat recuperated gas-turbine cycle using absorption inlet-cooling and evaporative after-cooling", *Applied Energy*, Vol. 77, pp. 249–272.
- [36] K Sarabchi, 2004, "Performance evaluation of reheat gas turbine cycles", *IMechE Instn Mech. Engrs, Power and Energy*, Vol. 218 Part A: J. pp : 529-539.
- [37] A. Khaliq, S.C. Kaushik, 2004, "Thermodynamic performance evaluation of combustion gas turbine cogeneration system with reheat", *Applied Thermal Engineering*, Vol. 24, pp. 1785–1795.
- [38] Roberto Carapellucci, Adriano Milazzo, 2005, "Thermodynamic optimization of a reheat chemically recuperated gas turbine", *Energy Conversion and Management*, Vol. 46, pp. 2936–2953.
- [39] B. Sheikhbeigi, M. B. Ghofrani, 2007, "Thermodynamic and environmental consideration of advanced gas turbine cycles with reheat and recuperator", *Int. J. Environ. Sci. Tech.*, Vol. 4, No. 2, pp. 253-262.
- [40] A.M. Bassily, 2008, "Enhancing the efficiency and power of the triple-pressure reheat combined cycle by means of gas reheat, gas recuperation, and reduction of the irreversibility in the heat recovery steam generator", *Applied Energy*, Volume 85, Issue 12, December 2008, Pages 1141–1162.

- [41] Daniele FIASCHI and Giampaolo MANFRIDA, 1998, "Energy analysis of the semi-closed gas turbine combined cycle (SCGT/CC)", *Energy Convers. Mgmt* Vol. 39, No. 16-18, pp. 1643-1652.
- [42] Mathioudakis, K., 2002, "Evaluation of Steam and Water Injection Effects on Gas Turbine Operation Using Explicit Analytical Relations", *Proc. Inst. Mech. Eng., Part A*, No.6, vol. 216, pp. 419-431.
- [43] K. Mathioudakis, 2002, "Analysis of the Effects of Water Injection on the Performance of a Gas Turbine", *Journal of Engineering for Gas Turbines and Power*, Vol. 124, pp. 489-495.
- [44] Haselbacher, H., 2005, "Performance of Water/Steam Injected Gas Turbine Power Plants Consisting of Standard Gas Turbines and Turbo Expanders", *Int. J. Energy Technology and Policy*, Vol. 3, Issue 1/2, pp. 12-23.
- [45] B. de Jager, J.B.W. Kok, G. Skevis, 2007, "The effects of water addition on pollutant formation from LPP gas turbine combustors", *Proceedings of the Combustion Institute*, Vol. 31, pp. 3123–3130.
- [46] Fraize, W.E., and Kinney, C., 1979, "Effects of steam injection on the performance of gas-turbine power cycles", *ASME J Eng Power*, 101:217–27.
- [47] Brown, D.H., and Cohn, A., 1981, "An evaluation of steam-injected combustion turbine systems", *ASME J Eng Power*, 103:13–9.
- [48] A. I. Khandwawala and S. A. Asif, 1984, "Prediction of the effects of steam addition on performance of gas turbines with fixed-bed regenerators", *Heat Recovery Systems*, Vol. 4, No. 1, pp. 1-8.
- [49] Larson, E.D., and Williams, R.H., 1987, "Steam-injected gas-turbines", *ASME J Eng Gas-Turbines Power*, 109:55–63.
- [50] Rice, I.G., 1995, "Steam-injected gas-turbine analysis: steam rates", *ASME J Eng Gas-Turbines Power*; 117:347–53.
- [51] F. M. Penning and H. C. de Lange, 1996, "Steam injection: analysis of a typical application", *Applied Thermal Engineering* Vol. 16, No. 2, pp. 115-125.
- [52] Nishida, K., Takagi, T., and Kinoshita S., 2005, "Regenerative steam-injection gas-turbine systems", *Applied Energy*, 81:231–246.
- [53] Frank Delattin, Svend Bram, Sofie Knoops, Jacques De Ruyck, 2008, "Effects of steam injection on microturbine efficiency and performance", *Energy*, Vol. 33, pp. 241–247.
- [54] Yasushi Ozawa, Tomoharu Fujii, Shunji Kikumoto, Mikio Sato, 1995, "Development of a low NO_x catalytic combustor for a gas turbine", *Catalysis Today*, vol. 26, pp. 351-357.
- [55] Moore, M. J., 1997, "NO_x Emission Control in Gas Turbines for Combined Cycle Gas Turbine Plant", *Proc. Inst. Mech. Eng.*, No A1, vol. 211, pp. 43-52.
- [56] Ohno, Y., Zhao, D. Furuhashi, T., Yamashita, H., Arai, N., & Hisazumi, Y., 2000, "Combustion characteristics and NO_x formation of a gas turbine system with steam

- injection and two-stage combustion", UPGC2000-15046, Proceedings of 2000 International Joint Power Generation Conference & Exposition, Miami Beach, Florida, July 23-26, ASME paper UPGC2000-15046.
- [57] Zhao, D., Ohno, Y., Furuhashi, T., Yamashita, H., Arai, N., and Hisazumi, Y., 2001, "Combustion technology in a novel gas turbine system with steam injection and two-stage combustion", *Journal of Chemical Engineering of Japan*, Vol. 34, No.9 pp.1159-1164.
 - [58] Takahisa Yamamoto, Tomohiko Furuhashi, Norio Arai and Ashwani K. Gupta, 2002, "Prediction of NO_x emissions from high-temperature gas turbine : Numerical simulation for low-NO_x combustion", *JSME International Journal Series B*, Vol. 45, No. 2, pp. 221-230.
 - [59] Louis Tsaguea, Joseph Tsogo, Thomas Tamo Tatietse, 2006, "Technical note: Prediction of the production of nitrogen oxide (NO_x) in turbojet engines", *Atmospheric Environment*, vol. 40, pp. 5727-5733.
 - [60] Andrea Lazzaretto, Andrea Toffolo, 2008, "Prediction of performance and emissions of a two-shaft gas turbine from experimental data", *Applied Thermal Engineering*, S1359-4311(08)00049-5.
 - [61] Qader, M. R., Khan, S., Kamal, M., Usman, M., & Haseeb, M. (2021). Forecasting carbon emissions due to electricity power generation in Bahrain. *Environmental Science and Pollution Research*.
 - [62] Kwasi-Effah, C. C., Ighodaro, O., Egware, H. O., & Obanor, A. I. (2022). A novel empirical model for predicting the heat accumulation of a thermal energy storage medium for solar thermal applications. *Journal of Energy Storage*, 56, 105969.
 - [63] Ibrahim, T. K., Rahman, M. M., Mohammed, M. K., & Basrawi, F. (2016). Statistical analysis and optimum performance of the gas turbine power plant. *International Journal of Automotive and Mechanical Engineering*, 13(1), 3215--3225.
 - [64] Tahan, M., Muhammad, M., & Karim, Z. A. A. (2017). A multi-nets DNN model for real-time performance-based automatic fault diagnosis of industrial gas turbine engines. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 39, 2865--2876.
 - [65] Jan Strömberg and Per-Åke Franck, 1994, "Gas turbines in industrial CHP applications: assessment of economics", *Heat Recovery Systems & CHP* Vol. 14, No. 2, pp. 129-141.
 - [66] Y. S. H. Najjar and M. Akyurt, 1994, "Review paper: Combined cycles with gas turbine engines", *Heat Recovery Systems & CHP* Vol. 14, No. 2, pp. 93-103.
 - [67] T.S. Kim, C.H. Song, S.T. Ro, S.K. Kauh, 2000, "Influence of ambient condition on thermodynamic performance of the humid air turbine cycle", *Energy*, Vol. 25, pp. 313-324.
 - [68] Ashraf M. Bassily, 2001, "Effects of evaporative inlet and after cooling on the recuperated gas turbine cycle", *Applied Thermal Engineering*, Vol. 21, pp. 1875-1890.
 - [69] Andréas A. Amell, Francisco J. Cadavid, 2002, "Influence of the relative humidity on the air cooling thermal load in gas turbine power plant", *Applied Thermal Engineering*, Vol. 22, pp. 1529-1533.

- [70] Toru Takahashi, Eiichi Koda and Toshio Mimaki, 2002, "A systematic analysis of the effect of air humidification to gas turbine systems", JSME International Journal, Series B, Vol. 45, No. 3, pp. 530-535.
- [71] Jean Castaing-Lasvignottes, 2003, "Air humide: Propriétés thermodynamiques, opérations unitaires et technologie associées à son emploi", cours – Université de Pau et des pays de l'Adour, <http://jc.castaing.free.fr/>
- [72] Chia-Chin Chuang and Deng-Chern Sue, 2005, "Performance effects of combined cycle power plant with variable condenser pressure and loading", Energy, Vol. 30, pp. 1793-1801.
- [73] Felipe R. Ponce Arrieta, Electro E. Silva Lora, 2005, "Influence of ambient temperature on combined-cycle power-plant performance", Applied Energy, Vol. 80, pp. 261-272.
- [74] Jie Wang, Yihua Gu, 2005, "Parametric studies on different gas turbine cycles for a high temperature gas-cooled reactor", Nuclear Engineering and Design, Vol. 235, pp. 1761-1772.
- [75] Hasan Huseyin Erdem, Suleyman Hakan Sevilgen, 2006, "Case study: Effect of ambient temperature on the electricity production and fuel consumption of a simple cycle gas turbine in Turkey", Applied Thermal Engineering, Vol. 26, pp. 320-326.
- [76] Kyong Sok Oh, Tong Seop Kim, 2006, "Performance analysis on various system layouts for the combination of an ambient pressure molten carbonate fuel cell and a gas turbine", Journal of Power Sources, Vol. 158, pp. 455-463.
- [77] Jobaidur Rahman Khan and Ting Wang, 2006, "Fog and Overspray Cooling for Gas Turbine Systems with Low Calorific Value Fuels", Proceedings of GT2006 ASME Turbo Expo 2006: Power for Land, Sea & Air May 8-11, ASME GT2006-90396, Barcelona, Spain.
- [78] A. BOUAM, S. AISSANI & R. KADI, 2007, "Influence des conditions ambiantes sur les performances des turbines à gaz industrielles", Colloque international sur les Energies Renouvelables (CER) organisé du 4 Mai au 5 Mai 2007 par l'école polytechnique de Ouajda – Maroc.
- [79] Potter, P. J., 1976, "Power plant theory and design", 2nd edition of steam power plant John Wiley & sons New York Chichester Brisbane Toronto.
- [80] El-Wakil, M. M., 1985, "Power Plant Technology", International Student ed., 1st print, McGraw-Hill Education Singapore; International Ed edition.
- [81] Kenneth C. Weston, 1992, "Energy Conversion", is a mechanical engineering textbook, published in 1992 and now out of print, electronic version of the text as originally published, with some updates and minor revisions.
- [82] Horlock, J. H., 2003, "Advanced gas turbine cycles", Pergamon Press, Oxford edition.
- [83] CHRISTIAN ROBERT, 2000, "Techniques de l'ingénieur : Machines hydrauliques et thermiques", Avril 2000.

- [84] Philip P. Walsh, Paul Fletcher, 2004, "Gas Turbine Performance", Second Edition by Blackwell Science Ltd a Blackwell Publishing company, Editorial Offices: Blackwell Science Ltd, 9600 Garsington Road, Oxford OX4 2DQ, UK.
- [85] Olav Bolland, 2004, "Thermal power generation", Thermal power generation – TEP9-2004.
- [86] Hu, C., Miao, K., Zhou, M., Shen, Y., & Sun, J. (2025). Intelligent Performance Degradation Prediction of Light-Duty Gas Turbine Engine Based on Limited Data. *Symmetry*, 17, 277. <https://doi.org/10.3390/sym17020277>
- [87] Kurz, R., Brun, K., Pinelli, M., & Suman, A. (2024). Status of Gas Turbine Performance Degradation. *Proceedings of ASME Turbo Expo 2024*, GT2024-122216.
- [88] Suman, A., Kurz, R., Aldi, N., Morini, M., Brun, K., Pinelli, M., & Spina, P.R. (2017). A Compressor Fouling Review Based on an Historical Survey of ASME Turbo Expo Papers. *Journal of Turbomachinery*, 139(4), 041005.
- [89] Yousif, S., Alnaimi, F., & Thiruchelvam, S. (2023). Gas Turbine Performance Monitoring and Operation Challenges: A Review. *Gazi University Journal of Science*, 36(1), 154-171. DOI: 10.35378/gujs.948875
- [90] Burnes, D., & Kurz, R. (2018). Performance Degradation Effects in Modern Industrial Gas Turbines. *Proceedings of Zurich 2018 Global Power and Propulsion Forum*, GPPS-2018-0019.
- [91] Tinsson, W. (2010). Plans d'expérience: constructions et analyses statistiques (Vol. 67). Springer Science & Business Media.
- [92] Iboukhoullef, H. (2024). Initiation à la modélisation par la méthode des plans d'expérience.
- [93] BOUCENNA, A., & HAOUSSAOUI, N. (2021). Application de la méthodologie des plans d'expérience à l'optimisation des processus de forage (Doctoral dissertation).
- [94] Faucher, J. (2006). *Les plans d'expériences pour le réglage de commandes à base de logique floue* (Thèse de doctorat, Institut national polytechnique de Toulouse, Département de génie électrique).
- [95] Hu, Q., Guo, Y., Xie, X., Cordy, M., Ma, L., Papadakis, M., & Le Traon, Y. (2024). Test optimization in dnn testing: a survey. *ACM Transactions on Software Engineering and Methodology*, 33(4), 1-42.
- [96] Hussain, H., Tamizharasan, P. S., & Rahul, C. S. (2022). Design possibilities and challenges of DNN models: a review on the perspective of end devices. *Artificial Intelligence Review*, 55(7), 5109-5167.
- [97] Tahan, M., Muhammad, M., & Karim, Z. A. A. (2017). A multi-nets DNN model for real-time performance-based automatic fault diagnosis of industrial gas turbine engines. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 39, 2865–2876.

- [98]** Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46–61.
- [99]** Bakria, D., Gozim, D., & Korich, B. (2023). Chaos elimination for a Buck converter using the multi-objective Grey Wolf optimiser. *Power Electronics and Drives*, 8(1), 165–173
- [100]** Fu, Y., Liu, D., Chen, J., & He, L. (2024). Secretary bird optimization algorithm: a new metaheuristic for solving global optimization problems. *Artificial Intelligence Review*, 57(5), 123.
- [101]** Bakria, D., Azzouzi, M., & Gozim, D. (2021). Chaos control and stabilization of a PID controlled Buck converter using the Spotted Hyena Optimizer. *Engineering, Technology & Applied Science Research*, 11(6), 7922–7926.
- [102]** Dhiman, G., & Kumar, V. (2017). Spotted hyena optimizer: A novel bio-inspired based metaheuristic technique for engineering applications. *Advances in Engineering Software*, 114, 48–70.
- [103]** Korich, B., Benaissa, A., Rabhi, B., & Bakria, D. (2021). A novel MPPT design for a partially shaded PV system using Spotted Hyena Optimization Algorithm. *Engineering, Technology & Applied Science Research*, 11(6), 7776–7781.