



University of Mohamed Khider – Biskra
Faculty of Science and Technology
Department of Electrical Engineering

MASTER DISSERTATION

Science and Technology
Electronics
Embedded Systems

Reference No.:

Submitted and defended by:
Mohamed Cheikh Ahmed El Imam

Defense Date: 2 June 2025

Geometric Mean Optimizer for Solving a Problem of a Real-Life Embedded System Application

Jury Members:

Prof. Baarir Zineeddine	Professor	University of Mohamed Khider – Biskra	President
Prof. Abida Toumi	Professor	University of Mohamed Khider – Biskra	Supervisor
Prof. Sbaa Salim	Professor	University of Mohamed Khider – Biskra	Examiner

Academic Year: 2024 – 2025

جامعة محمد خيضر بسكرة
كلية العلوم والتكنولوجيا
قسم الهندسة الكهربائية



مذكرة الماستر

علوم وتكنولوجيا
إلكترونيك
الالكترونيك أنظمة مضمنة
المرجع :

إعداد الطالب:

محمد الشيخ أحمد الإمام

تاريخ المناقشة: 02 جوان 2025

خوارزمية التحسين بالمتوسط الهندسي لحل مشكلة في تطبيق واقعي لنظام مضمن

لجنة المناقشة:

الرئيس	جامعة محمد خيضر بسكرة	أستاذ	بعرير زين الدين
المؤطر	جامعة محمد خيضر بسكرة	أستاذ	عبيدة تومي
المتحن	جامعة محمد خيضر بسكرة	أستاذ	السبع سليم

السنة الجامعية: 2024 - 2025



University of Mohamed Khider – Biskra
Faculty of Science and Technology
Department of Electrical Engineering

MASTER DISSERTATION

Science and Technology
Electronics
Embedded Systems

Reference No.:

Geometric Mean Optimizer for Solving a Problem of a Real-Life Embedded System Application

Defense Date: 2 June 2025

Submitted by:

Mohamed Cheikh Ahmed El Imam

Supervisor:

Abida Toumi

Co-Supervisor:

Dr. Nouredine Samia

Approval and Signature of the Jury President

Prof. Baarir Zineeddine

Stamp and Signature

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

هَدَاءٌ

إلى من كانت جذورهم ثابتة في أرض قلبي،
وسُقياهم صبرٌ ودعاء، ومحبتهم ظلالٌ تظللني كلما لَقَّني التعب...
إلى جدتي الغالية، التي بقيت حاضرة في وجداني، بدعائها وحنانها،
إلى والديّ الكريمين، من علّمني أن المعرفة نور، وأن العلم رسالة،
وأن الطريق إلى النجاح يبدأ بسجدة رضا وبركة.

إلى من شاركوني رحلة السهر والكدّ،
إلى إخوتي وأخواتي، سندي في الشدة، وفرحي في النجاح.
إلى زملائي ورفقاء الدرب، من تقاسموا معي الحلم، والهَمِّ، والأمل.

إلى أستاذتي وموجّهتي الفاضلة،
التي غرست في نفسي بذور الثقة، وروح الاجتهاد،
فكانت كالشمس التي لا تطلب الشكر، ولكنها تنير الطريق.

إلى كل من آمن بي، حتى حين كنت أرتبك في الإيمان بنفسي،
وإلى كل من دعمني بكلمة، بنصيحة، أو حتى بصمتٍ حنون.

ثم...

إلى كل ساعٍ للعلم بعزمٍ ونية صافية،
وإلى كل من جعل من المعرفة رسالة... أهدي هذا العمل،
تقديرًا لفضلهم، وامتنانًا لما منحني الله من توفيق

شكر وتقدير

أولاً وقبل كل شيء، أحمد الله العليّ القدير، الذي منحني القوة والصبر والإرادة لإنجاز هذا العمل المتواضع.

كما أتوجه بالشكر لمشرفتي على المذكرة الأستاذة الدكتورة: عبيدة تومي على إشرافها وتوجيهاتها وتواجدها الدائم. وأشكرها أيضاً على تشجيعها وتعاطفها طوال فترة إعداد رسالتي.

يتمد شكري أيضاً لأعضاء لجنة المناقشة، الأستاذ الدكتور بعير زين الدين والأستاذ الدكتور: السبع سليم، على حضورهما والوقت الذي تفضلاً بتخصيصه لتقييم هذا العمل.

أشكر كذلك جميع أساتذة قسم الهندسة الكهربائية بجامعة محمد خيضر بسكرة الذين ساهموا في تكويني طوال المسار الجامعي.

أشكر أيضاً جميع أصدقائي وزملائي الذين دعموني ونصحوني وساعدوني كثيراً.

Abstract:

This Dissertation investigates the use of metaheuristic optimization in embedded systems, focusing on the Geometric Mean Optimizer (GMO) algorithm. It combines theoretical insights into metaheuristic mechanisms under resource constraints with two applications: PID controller tuning for a DC motor, and chest X-ray classification for pneumonia detection using transfer learning and GMO-based feature selection. The results validate GMO's efficiency and adaptability in high-performance, resource-limited scenarios.

Keywords: Metaheuristics, GMO, Embedded Systems, PID, Pneumonia, Transfer Learning, Feature Selection.

الملخص:

تستعرض هذه المذكرة تطبيق تقنيات التحسين الميتاهيورستية في الأنظمة المدججة، مع التركيز على خوارزمية المحسن بالمتوسط الهندسي (GMO). تشمل الدراسة تحليلاً نظرياً لآليات الميتاهيورستيك في البيئات محدودة الموارد، يتبعه تطبيقان عمليان: ضبط متحكم PID لمحرك تيار مستمر، وتصنيف صور أشعة الصدر لاكتشاف الالتهاب الرئوي باستخدام نقل التعلم وانتقاء السمات عبر GMO. تؤكد النتائج كفاءة ومرونة الخوارزمية في تحقيق أداء عالٍ ضمن قيود صارمة.

الكلمات المفتاحية: التحسين الميتاهيورستي، GMO، الأنظمة المدججة، PID، الالتهاب الرئوي، نقل التعلم، اختيار السمات.

Résumé :

Ce mémoire explore l'application des techniques d'optimisation métaheuristiques dans les systèmes embarqués, en mettant l'accent sur l'algorithme Optimiseur de Moyenne Géométrique (GMO). L'étude combine une analyse des mécanismes métaheuristiques en environnements contraints avec deux cas pratiques : l'ajustement d'un contrôleur PID d'un moteur à courant continu, et la classification de radiographies thoraciques pour la détection de pneumonie via l'apprentissage par transfert et la sélection de caractéristiques par GMO. Les résultats démontrent la robustesse et l'adaptabilité de l'algorithme face à divers défis d'optimisation.

Mots-clés : Métaheuristiques, GMO, systèmes embarqués, PID, pneumonie, transfert de l'apprentissage, sélection de caractéristiques.

Table of Contents

جدول المحتويات

قائمة الأشكال List of Figures

قائمة الجداول List of table

قائمة الاختصارات List of Abbreviations

II مقدمة عامة

الفصل الأول: الميتاهيورستيات METAHEURISTICS

2.....	مقدمة	I.1
2.....	التحسين التوافقي Combinatorial Optimization	I.2
4.....	طرق التحسين التوافقي Combinatorial Optimization Methods	I.2.1
5.....	تعريف الميتا-استكشافيات	I.3
6.....	تصنيف الميتا-استكشافيات	I.4
7.....	الميتاهيورستيات المعتمدة على البناء (Construction-Oriented Metaheuristics)	I.4.1
7.....	الميتاهيورستيات المعتمدة على بحث الجوار	I.4.2
8.....	الميتاهيورستيات المعتمدة على السكان (Population-Based Metaheuristics):	I.4.3
10.....	الميتاهيورستيات الهجينة (Hybrid Metaheuristics):	I.4.4
11.....	منظور متعدد الأبعاد لتصنيف خوارزميات الميتاهيورستيك	I.4.5
12.....	معايير تقييم الخوارزميات الميتاهيورستية:	I.5
13.....	ملاءمة الخوارزميات الميتاهيورستية للأنظمة المدمجة	I.6
13.....	الخلاصة	I.7

الفصل الثاني: المحسن بالمتوسط الهندسي

15.....	المقدمة:	II.1
15.....	الخلفية النظرية	II.2
15.....	المتوسط الهندسي Geometric Mean	II.2.1
19.....	خوارزميات الميتا-استكشافيات Metaheuristic Algorithms	II.2.2
21.....	الأساس الرياضي للمحسن بالمتوسط الهندسي (GMO)	II.2.3
25.....	خطوات تنفيذ المحسن بالمتوسط الهندسي (GMO)	II.3
25.....	تهيئة السكان (Population Initialization)	II.3.1
25.....	تقييم الأداء وتحديد النخبة (Fitness & Elite Selection)	II.3.2
25.....	التوجيه بالمتوسط المرجح (Weighted Geometric Guidance)	II.3.3
25.....	تحديث المواقع (Position Update)	II.3.4
25.....	آليات البحث والاستكشاف (Search and Exploration Mechanism)	II.3.5
26.....	استراتيجية الطفرة (Mutation Strategy)	II.3.6
26.....	اختيار الحل الأفضل وإيقاف الخوارزمية (Best Solution & Stopping Criteria)	II.3.7
27.....	الخلاصة	II.4

الفصل الثالث: تطبيقات نظرية لخوارزمية GMO في الأنظمة الذكية

29.....	المقدمة	III.1
30.....	التطبيق الأول: تحسين معاملات متحكم PID باستخدام GMO	III.2
30.....	مقدمة حول التحكم التناسبي التكاملي التفاضلي (PID)	III.2.1
31.....	التحديات في ضبط معاملات PID	III.2.2
31.....	خطوات تطبيق خوارزمية GMO في ضبط معاملات متحكم PID	III.2.3
33.....	المميزات النظرية لاستخدام خوارزمية GMO في تحسين PID	III.2.4
34.....	خلاصة	III.2.5
35.....	التطبيق الثاني: تصنيف الالتهاب الرئوي عبر Raspberry Pi باستخدام GMO	III.3
35.....	المقدمة	III.3.1
36.....	استخلاص السمات العميقة باستخدام نقل التعلم (Transfer Learning)	III.3.2
36.....	الشبكة العصبية التلافيفية ResNet50 والاتصال المتبقي (Residual Connection)	III.3.3
37.....	الدالة الانتقالية ذات الشكل S (Sigmoid Function)	III.3.4
38.....	مشكلة ارتفاع الأبعاد والحاجة إلى اختيار السمات	III.3.5
39.....	خوارزمية Geometric Mean Optimizer (GMO)	III.3.6
40.....	تكامل خوارزمية GMO مع اختيار السمات المستخرجة من ResNet50	III.3.7
40.....	النظام المدمج ومحاكاة التشغيل باستخدام Raspberry Pi	III.3.8
41.....	خلاصة التطبيق الثاني	III.3.9
42.....	الخلاصة	III.4

الفصل الرابع: الجانب التطبيقي

44.....	القسم الأول تقييم أداء خوارزمية المُحسّن بالمتوسط الهندسي (GMO)	IV.1
44.....	المقدمة	IV.1.1
44.....	آلية التنفيذ العامة لخوارزمية GMO	IV.1.2
46.....	التجارب العددية ومقارنتها	IV.1.3
49.....	تحليل منحنيات التقارب (Convergence Analysis)	IV.1.4
52.....	تحليل التعقيد الحسابي	IV.1.5
53.....	خلاصة القسم الأول	IV.1.6
54.....	القسم الثاني التطبيقات الواقعية	IV.2
54.....	التطبيق الأول ضبط متحكم PID لمحرك تيار مستمر باستخدام GMO	IV.2.1
62.....	التطبيق الثاني اكتشاف الالتهاب الرئوي باستخدام خوارزمية GMO	IV.2.2
79.....	الخلاصة	IV.3

الخاتمة

المراجع

List of Figures قائمة الأشكال

الفصل الأول: الميتاهيورستيات METAHEURISTICS

- الشكل 1.I: القيم الصغرى والعظمى المحلية والعامية Local and Global Minima and Maxima 3
- الشكل 2.I: تصنيف طرق التحسين التوافقي 5
- الشكل 3.I: المبادئ الأساسية لخوارزميات الوصفية P-metaheuristics 8
- الشكل 4.I: دورة عمل الخوارزمية الجينية 9
- الشكل 5.I: سرب الجسيمات مع المواقع والسرعات المرتبطة بها 9
- الشكل 6.I: استلهام من سلوك مستعمرة النمل في البحث عن المسار الأمثل 10
- الشكل 7.I: تصنيف متعدد الأبعاد لخوارزميات الميتاهيورستيك 12

الفصل الثاني: المحسن بالمتوسط الهندسي

- الشكل 1.II: الإجراء التخطيطي لتحديث وكلاء البحث في التكرار t من خوارزمية GMO 24

الفصل الثالث: تطبيقات نظرية لخوارزمية GMO في الأنظمة الذكية

- الشكل 1.III: الهيكل العام لنظام التحكم المغلق وكيفية ضبط معاملات PID باستخدام خوارزمية GMO 30
- الشكل 2.III: مراحل تنفيذ خوارزمية GMO لضبط معاملات PID من التهيئة حتى الاستخراج 33
- الشكل 3.III: مقارنة بين صور أشعة لصدر سليم (الصف العلوي) و صدر يعاني من التهاب رئوي (الصف السفلي) 35
- الشكل 4.III: المخطط العام للنظام المقترح 36
- الشكل 5.III: بنية نموذجية للكتلة المتبقية في شبكة ResNet50 37
- الشكل 6.III: منحني الدالة الانتقالية على شكل S 38

الفصل الرابع: الجانب التطبيقي

- الشكل 1.IV: المخطط الانسيابي العام لخوارزمية GMO 45
- الشكل 2.IV: منحني التقارب لخوارزميات متعددة عند تطبيقها على الدالة F1 50
- الشكل 3.IV: منحني التقارب لخوارزميات متعددة عند تطبيقها على الدالة F2 51
- الشكل 4.IV: منحني التقارب لخوارزميات متعددة عند تطبيقها على الدالة F3 51
- الشكل 5.IV: تصميم المتحكم 55
- الشكل 6.IV: استجابة النظام المكافئ 57

- الشكل 7.IV : مقارنة الاستجابة الخطية قبل وبعد 57
- الشكل 8.IV : القيمة التراكمية للخطأ IAE 57
- الشكل 9.IV : مخطط Box Plot للقيم التراكمية لـ IAE عبر 20 تجربة مستقلة 58
- الشكل 10.IV : منحنى بود 59
- الشكل 11.IV : التحليل الترددي - تحليل بود 60
- الشكل 12.IV : منحنى التقارب 60
- الشكل 13.IV : نموذج من صور الأشعة الأصلية وصورها بعد المعالجة المسبقة 63
- الشكل 14.IV : منحنيات خسارة التدريب والتحقق لموديل ResNet 50 64
- الشكل 15.IV : مقارنة بنيوية بين ResNet 50 و VGG16 من حيث عدد الطبقات، نوع التمثيل، وعدد الأبعاد الناتجة 65
- الشكل 16.IV : منحنيات تقارب خوارزمية GMO عبر الطيات الخمس 67
- الشكل 17.IV : مصفوفات الالتباس للمصنف Logistic Regression بعد اختيار السمات (الطيات 1 إلى 5) 67
- الشكل 18.IV : مصفوفات الالتباس Confusion Matrices للمصنفات 69
- الشكل 19.IV : منحنيات ROC لكل مصنف 69
- الشكل 20.IV : منحنيات PR لكل مصنف 70
- الشكل 21.IV : متوسط مقاييس الأداء مع الانحراف المعياري على مجموعة الاختبار 71
- الشكل 22.IV : توزيع مقاييس الأداء عبر الطيات باستخدام Boxplot 72
- الشكل 23.IV : مقارنة عدد السمات المختارة 73
- الشكل 24.IV : مقارنة مؤشرات الأداء (Accuracy, Precision, Recall, F1-score, ROC AUC) 74
- الشكل 25.IV : منحنيات ROC لمقارنة قدرة التمييز بين الخوارزميات 74
- الشكل 26.IV : تمثيل عنكبوتي (Radar Chart) للأداء الكلي لكل خوارزمية 74
- الشكل 27.IV : مقارنة زمن التنفيذ واستهلاك CPU لكل خوارزمية 75
- الشكل 28.IV : مقارنة استهلاك RAM بين الخوارزميات 75
- الشكل 29.IV : تحليل سرعة التقارب وعدد التكرارات 76
- الشكل 30.IV : منحنى Trade-off بين نسبة تقليص السمات وجودة الأداء 76
- الشكل 31.IV : مقارنة Trade-off شامل لمختلف مؤشرات الأداء 77
- الشكل 32.IV : تخطيط لوحة النظام باستخدام Raspberry Pi 4 والمكونات الملحقة 78
- الشكل 33.IV : مخطط PCB 78

قائمة الجداول List of table

- جدول 1 : ذاكرات البحث لبعض الخوارزميات الوصفية P-Metaheuristics9
- جدول 2: مقارنة بين المتوسط الهندسي والحسابي17
- جدول 3 : نقاط القوة لكل خوارزمية مقارنة بـGMO20
- جدول 4 : إعدادات معلمات GMO والخوارزميات المنافسة له47
- جدول 5: مقارنة بين GMO و PSO49
- جدول 6: تفاصيل إعدادات التنفيذ56
- جدول 7: نتائج التجربة قبل وبعد GMO56
- جدول 8: جدول المقارنة61
- جدول 9 : عدد السمات المختارة بعد تطبيق خوارزمية GMO عبر الطيات الخمس (5-Fold Cross Validation)66
- جدول 10: نتائج الأداء التصنيفي للمصنفات بعد اختيار السمات بواسطة خوارزمية GMO68
- جدول 11: تحليل استهلاك الزمن للمصنفات بعد اختيار السمات بواسطة خوارزمية GMO68
- جدول 12 : جدول مقارنة بين الخوارزميات73

List of Abbreviations قائمة الاختصارات

الترجمة	المعنى الكامل	الاختصار
المحسن بالمتوسط الهندسي	Geometric Mean Optimizer	<i>GMO</i>
المتحكم التناسبي التكامل التفاضلي	Proportional-Integral-Derivative	<i>PID</i>
خوارزمية تحسين السرب الجزيئي	Particle Swarm Optimization	<i>PSO</i>
الخوارزمية الجينية	Genetic Algorithm	<i>GA</i>
خوارزمية الجار الأقرب	K-Nearest Neighbors	<i>KNN</i>
آلة المتجهات الداعمة	Support Vector Machine	<i>SVM</i>
الشبكة العصبية الالتفافية	Convolutional Neural Network	<i>CNN</i>
مؤشر اللياقة المزدوج	Dual Fitness Indicator	<i>DFI</i>
منحنى خصائص التشغيل المستلم	Receiver Operating Characteristic	<i>ROC</i>
المساحة تحت المنحنى	Area Under Curve	<i>AUC</i>
التكامل المطلق للخطأ	Integral of Absolute Error	<i>IAE</i>
وحدة معالجة الرسومات	Graphics Processing Unit	<i>GPU</i>
ذاكرة الوصول العشوائي	Random Access Memory	<i>RAM</i>
إنترنت الأشياء	Internet of Things	<i>IoT</i>
جهاز راسبيري باي	Raspberry Pi	<i>RPi</i>
التلدين المحاكي	Simulated Annealing	<i>SA</i>
خوارزمية مستعمرة النحل الاصطناعية	Artificial Bee Colony	<i>ABC</i>
مصنف بايز البسيط	Naive Bayes	<i>NB</i>
اختبار كاي تربيع	Chi-Squared Test	<i>Chi2</i>
التعلم بالنقل	Transfer Learning	<i>TL</i>

اختيار السمات	Feature Selection	<i>FS</i>
الاسترجاع والدقة	Precision-Recall	<i>PR</i>
مقياس F1 للأداء	F1-Score	<i>F1</i>
متوسط الخطأ المطلق	Mean Absolute Error	<i>MAE</i>
متوسط الخطأ التربيعي	Mean Squared Error	<i>MSE</i>
الجذر التربيعي لمتوسط الخطأ التربيعي	Root Mean Squared Error	<i>RMSE</i>

مقدمة عامة

**General
Introduction**

مقدمة عامة

General Introduction

تُعدّ مسائل التحسين من الركائز الأساسية في العلوم التطبيقية والهندسية، نظرًا لدورها المحوري في الوصول إلى حلول فعّالة ضمن سياقات تتسم بالتعقيد، والقيود المتعددة، والتغير الديناميكي المستمر. ومع تصاعد متطلبات الأداء في الأنظمة المعاصرة، خصوصًا تلك التي تعمل ضمن بيئات ذات موارد محدودة كأنظمة الطاقة المنخفضة والأنظمة المدمجة، برزت الحاجة إلى اعتماد أدوات تحسين تتسم بالكفاءة والمرونة في آنٍ واحد.

في هذا الإطار، لم تعد الأساليب التقليدية كالطرق التحليلية أو البحث الشامل كافية لمعالجة المشكلات غير الخطية أو متعددة الأهداف، مما مهّد الطريق أمام خوارزميات الميتاهيورستيك (Metaheuristic Algorithms). وتمتاز هذه الخوارزميات بقدرتها على موازنة الاستكشاف الواسع لفضاء الحلول مع استغلال المناطق الواعدة، ما يقلل من فرص الوقوع في الحلول المحلية.

تأتي خوارزمية المُحسّن بالمتوسط الهندسي (Geometric Mean Optimizer - GMO) كأحد النماذج الحديثة والواعدة ضمن هذه الفئة، حيث تعتمد على خواص رياضية للمعدل الهندسي لتوجيه عملية البحث. وتهدف إلى تحقيق توازن ديناميكي بين الاستكشاف والاستغلال، ما يضمن كفاءة التقارب، ويزيد من فرص الوصول إلى الحلول المثلى في بيئات متنوعة.

تهدف هذه الدراسة إلى تقديم تحليل شامل ومتكامل لخوارزمية GMO، يجمع بين الأساس النظري والتقييم التطبيقي. ويتضمن العمل تجارب عددية باستخدام دوال معيارية مرجعية، ومقارنات دقيقة مع خوارزميات كلاسيكية مثل PSO و GA و SA، إضافة إلى اختبار الخوارزمية ضمن تطبيقات عملية واقعية باستخدام منصة Raspberry Pi، ما يسمح بتقييم أدائها في ظروف تشغيل فعلية.

تنقسم الدراسة إلى أربعة فصول متكاملة:

الفصل الأول: يُقدّم خلفية شاملة حول خوارزميات الميتاهيورستيك، بما يشمل تصنيفاتها، وآليات عملها، ومعايير تقييم أدائها، مع التركيز على ملاءمتها لتطبيقات الأنظمة المضمنة.

الفصل الثاني: يُعالج البناء النظري والرياضي لخوارزمية GMO، ويشرح خطوات تنفيذها بالتفصيل مع إبراز الآليات الرياضية المستخدمة في التوجيه والتحسين. الفصل الثالث: يُخصّص لتطبيق

الفصل الثالث: يُخصص لتطبيق الخوارزمية في بيئتين تجريبيتين، تمثل الأولى ضبط معاملات متحكم PID في نظام ديناميكي، والثانية تصنيف صور طبية اعتمادًا على اختيار السمات.

الفصل الرابع: يُركّز على التحليل التطبيقي العميق، من خلال تقييم أداء الخوارزمية على دوال اختبار معيارية، ثم دمجها في تطبيقين عمليين: ضبط متحكم PID لمحرك تيار مستمر، وتصنيف صور أشعة للصدر للكشف عن الالتهاب الرئوي باستخدام تقنيات التعلم العميق وانتقاء السمات المحسّن.

تُختتم الدراسة باستخلاص أبرز النتائج وتقديم توصيات مستقبلية تسهم في تعميم استخدام خوارزمية GMO ضمن مجالات الأنظمة الذكية والمضمنة، وتحفيز المزيد من الأبحاث حول تطوير آلياتها أو دمجها مع تقنيات تحسين أخرى.

الفصل الأول:

الميتاهيورستيات

Metaheuristics

I.1 مقدمة

تُعد الميتاهيورستيات (Metaheuristics) إطارًا عامًا لحل المشكلات التوافقية (Combinatorial Problems)، هي مسائل تتسم بفضاءات حلول ضخمة تتزايد أُسِّيًّا مع حجم المشكلة، مما يجعل الطرق التقليدية غير فعّالة في كثير من الحالات.

برز هذا النوع من الخوارزميات منذ ثمانينيات القرن العشرين، كردّ على محدودية الأساليب الاستدلالية والحتمية، خاصةً في المسائل غير الخطية أو متعددة الأبعاد. وتمتاز الميتاهيورستيات بقدرتها على تحقيق توازن ديناميكي بين استكشاف الفضاء (Exploration) واستغلال المناطق الواعدة (Exploitation)، ما يسمح بالوصول إلى حلول شبه مثالية خلال وقت معقول.

ومع تنامي الحاجة إلى حلول مرنة وسريعة ضمن بيئات حوسبة محدودة الموارد، كأنظمة الزمن الحقيقي والأنظمة المدمجة (Embedded Systems)، أصبحت الميتاهيورستيات أداة مركزية بفضل مرونتها وقابليتها للتكيف.

تشمل عائلة الميتاهيورستيات تقنيات متعددة، منها: الخوارزميات الجينية (GA)، البحث المحظور (Tabu Search)، التلدين المحاكى (SA)، خوارزميات مستعمرة النمل (ACO)، وأساليب هجينة تدمج بين عدة منهجيات. وتستمد هذه الخوارزميات مبادئها من مجالات متداخلة تشمل الفيزياء، والبيولوجيا، والذكاء الاصطناعي، مما يعزز من قدرتها على التعامل مع التعقيدات الحديثة مثل البيانات الضخمة، متطلبات الزمن الحقيقي، والاستدامة.

I.2 التحسين التوافقي Combinatorial Optimization

التحسين التوافقي هو فرع من التحسين الرياضي يهدف إلى إيجاد أفضل حل ممكن ضمن مجموعة محدودة ولكن ضخمة من الحلول. يتضمن هذا النوع من المشكلات عادةً دالة هدف (Objective Function) يُراد تعظيمها أو تقليلها، تحت مجموعة من القيود (Constraints) المفروضة على المتغيرات [1] [2].

صياغة ذلك رياضياً تتم على النحو الآتي:

لنفترض أن n عدداً صحيحاً موجباً (strictly positive integer)، وأن $D \subset R^n$ تمثل مجموعة جزئية غير فارغة من R^n (non-empty subset of R^n)، وأن لدينا دالة $f: D \rightarrow R$: تأخذ قيماً حقيقية على D .

فإننا نبحث عن:

$$f(x) \min_{x \in D} \quad \text{أو} \quad f(x) \max_{x \in D}$$

حيث:

النقطة $x^* \in D$ تحقق:

- الحل الأمثل الأدنى العام **Global Minimum** إذا تحقق:
 $\forall x^* \in D, \quad f(x^*) < f(x)$

- الحل الأمثل الأقصى العام **Global Maximum** إذا تحقق:
 $\forall x^* \in D, \quad f(x^*) > f(x)$

ومع أن الهدف هو بلوغ الحل الأمثل، إلا أن كثيرًا من الخوارزميات قد تتوقف عند حلول محلية مثلى (Local Optima) بسبب طبيعة فضاء البحث. ويُعد ذلك تحديًا رئيسيًا، يُعرف بظاهرة التقارب المبكر (Premature Convergence).

أنواع الحلول المثلى المحلية **Types of Local Optima**

- الحل الأدنى المحلي **Local Minimum**

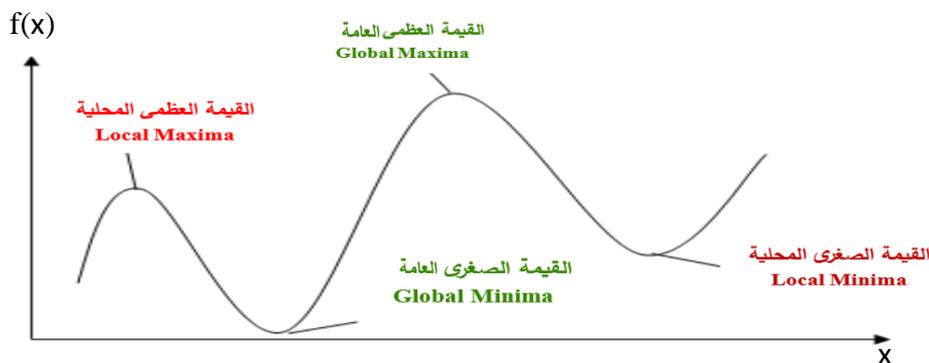
النقطة x هي حدٌ أدنى محلي ضمن بنية الجوار $N(x)$ إذا تحقق:

$$\forall x^* \in N(x), \quad f(x^*) < f(x)$$

- الحل الأقصى المحلي **Local Maximum**

النقطة x هي حدٌ أقصى محلي ضمن بنية الجوار $N(x)$ إذا تحقق:

$$\forall x^* \in N(x), \quad f(x^*) > f(x)$$



الشكل 1.I: القيم الصغرى والعظمى المحلية والعامة **Local and Global Minima and Maxima**

1.2.1 طرق التحسين التوافقي Combinatorial Optimization Methods

قبل اختيار منهجية الحل (solution method)، يجب تقييم تعقيد المشكلة (problem complexity) وتنقسم الطرائق عمومًا إلى نوعين رئيسيين تبعًا لدقة النتائج ومدى ضمان الوصول إلى الحل الأمثل:

١. الطرق الدقيقة Exact Methods:

تهدف هذه الخوارزميات إلى إيجاد الحل الأمثل بدقة تامة، مع ضمان صحة النتائج. وهي تعتمد غالبًا على تعداد منظم أو استكشاف شامل لفضاء البحث، مما يجعلها مناسبة للمشكلات ذات الحجم الصغير أو متوسط التعقيد [3].

أبرز أمثلتها:

❖ البرمجة الديناميكية Dynamic Programming :

تعتمد على تقسيم المسألة إلى مشكلات فرعية تُحل بشكل تكراري، وتجميع الحلول الجزئية بطريقة منظمة لبناء الحل النهائي. فعالة لمسائل ذات بنية تكرارية واضحة [4].

❖ البرمجة الخطية Linear Programming :

تهدف إلى تحسين دالة خطية (Objective Function) تحت قيود خطية. تُستخدم في مجالات الإنتاج والتخطيط والتمويل.

❖ الفرع والقيود Branch and Bound :

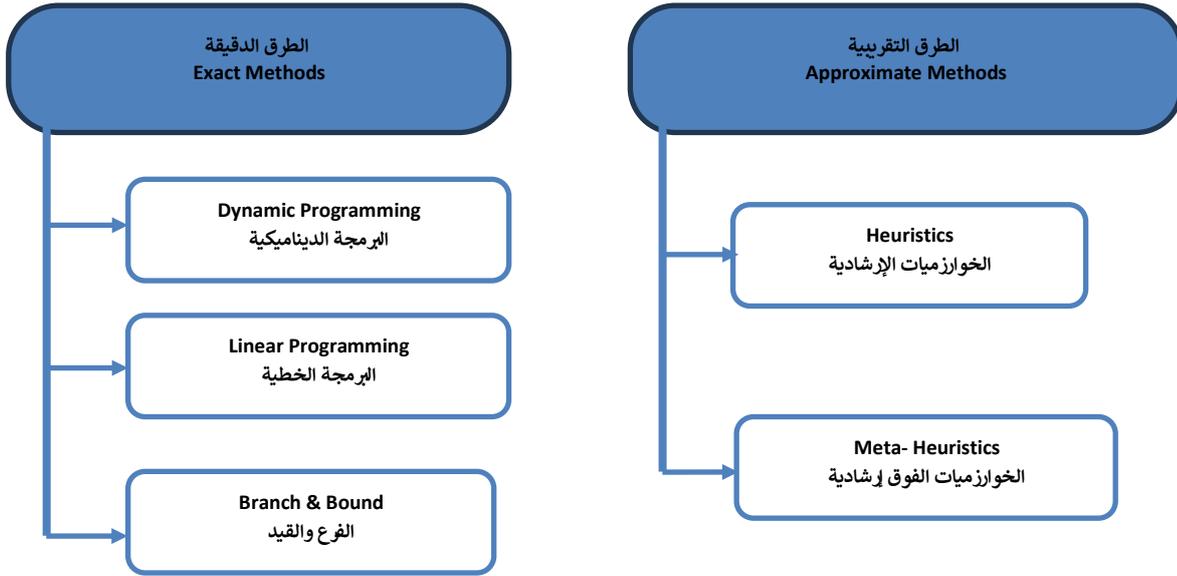
تعمل على تقسيم فضاء البحث (Branching)، وتقدير حدود دنيا أو عليا (Bounding) لاستبعاد الفروع غير الواعدة [3] [5].

٢. الطرق التقريبية Approximate Methods

تهدف إلى إيجاد حلول عالية الجودة ضمن زمن حسابي معقول، دون ضمان الوصول إلى الحل الأمثل. وتُعد الخيار الأفضل في المسائل واسعة النطاق أو المعقدة. تشمل:

الخوارزميات الاستدلالية (Heuristics)

الخوارزميات الوصفية (Metaheuristics) الفئة الرئيسية التي يتناولها هذا الفصل بالتفصيل. تُستخدم هذه الأساليب على نطاق واسع في التطبيقات الواقعية، نظرًا لمرونتها وفعاليتها في تقليص الزمن الحسابي، لا سيما في مسائل لا يمكن حلها بفعالية باستخدام الطرق الدقيقة.



الشكل 2.I: تصنيف طرق التحسين التوافقي

ورغم أن الطرق الدقيقة (Exact Methods) مثل البرمجة الخطية والفرع والقيود توفر حلولاً مثلى مضمونة، إلا أنها غالباً ما تصبح غير عملية في المشكلات التوافقية الكبيرة، بسبب ما يُعرف بـ الانفجار التوافقي (Combinatorial Explosion).

وهنا تبرز الميتاهيورستيات كحل عملي واستراتيجي، فهي لا تسعى دائماً إلى الحل الأمثل النظري، بل تهدف إلى حلول شبه مثالية خلال زمن مقبول، مما يجعلها أكثر ملاءمة لمشكلات التحسين التوافقي واسعة النطاق.

إضافةً إلى ذلك، فإن الميتاهيورستيات تتميز بمرونتها العالية:

لا تعتمد على خصائص رياضية دقيقة (كاشتقاق أو تقعر دالة الهدف).

قابلة للتكيف مع القيود المعقدة أو غير الخطية.

فعالة في تجاوز مشكلة التقارب المبكر (Premature Convergence)، التي تؤدي إلى البقاء في حل

محلي دون التقدم نحو الحلول العامة الأفضل.

لهذا السبب، أصبحت الميتاهيورستيات الإطار المفضل في حل عدد متزايد من مسائل التحسين

التوافقي في السياقات الحديثة مثل الأنظمة المدمجة، وإنترنت الأشياء، والأنظمة السيبرانية الفيزيائية.

I.3 تعريف الميتا-استكشافيات

يرجع أصل مصطلح الميتاهيورستيك (Metaheuristic) إلى مزيج لغوي يوناني؛ حيث تعني

"heuriskein" الاكتشاف أو البحث، بينما تُشير "meta" إلى ما هو فوق أو أعلى، مما يعكس طبيعة

هذه الخوارزميات كمستوى توجيهي متقدّم يهدف إلى تعزيز فعالية أساليب البحث والتحسين التقريبي [6].

تمثل الميتاهيورستيات إطارًا عامًا مرناً يُستخدم لتحسين الحلول التقريبية من خلال تكرارات متتالية، وتتميز بأنها لا تعتمد على خصائص رياضية دقيقة للمسألة، مما يمنحها قدرة كبيرة على التعامل مع مشكلات تحسين معقدة، وغير خطية، وعالية الأبعاد.

تستوحي هذه الخوارزميات مبادئها من مجموعة من الظواهر الطبيعية والأنظمة الديناميكية، مثل: النمو التطوري (كما في الخوارزميات الجينية)، الفيزياء الإحصائية (كما في التلدين المحاكي)، السلوك الجماعي للكائنات (كما في مستعمرات النمل وسراب الطيور)، الذاكرة التكوينية (كما في البحث المحظور).

من الناحية المنهجية، تُعرّف الميتاهيورستيك بأنها عملية تحكم عالية المستوى (Master Process) تعمل على إدارة وتوجيه خوارزميات فرعية أو أساليب استدلال تعتمد على الذاكرة والتعلم التكويني. يتضمن هذا النهج مزيجًا من استراتيجيات الاستكشاف والاستغلال المنظمة، بما يتيح تحسينات تدريجية نحو حلول ذات جودة عالية.

كما أوضحت دراسات (Osman (1995 و Osman & Kelly (1996 و Osman & Laporte (1996، بالإضافة إلى (Voss et al (1999، فإن الميتاهيورستية لا تقتصر على نوع واحد من الخوارزميات، بل يمكن تطبيقها على حلول فردية أو جماعية، كاملة أو ناقصة، بل وحتى على مجموعات خوارزميات استدلالية. وبهذا المعنى، فإن الميتاهيورستيات تمثل منهجًا تكامليًا لتصميم خوارزميات قوية ومرنة، قادرة على تجاوز القيود التقليدية في مواجهة مسائل تحسين يصعب حلها بالطرق الكلاسيكية [7].

I.4 تصنيف الميتا-استكشافيات

تُصنّف خوارزميات الميتاهيورستيك عمومًا إلى ثلاث فئات رئيسية وفقًا لآلية البحث التي تعتمد عليها، وهي: الخوارزميات المبنية على البناء التدريجي، وتلك المعتمدة على بحث الجوار، بالإضافة إلى الخوارزميات السكانية. يُساهم هذا التصنيف في فهم المنهجيات المختلفة التي تتبناها كل فئة في التعامل مع فضاء الحلول، يُمكن تصنيف هذه الخوارزميات إلى أربع فئات رئيسية:

I.4.1 الميتاهيورستيات المعتمدة على البناء (Construction-Oriented Metaheuristics)

تركز هذه الفئة من الخوارزميات على بناء الحلول خطوة بخطوة انطلاقاً من حل أولي فارغ. يتم إنشاء الحل النهائي تدريجياً عن طريق إضافة مكونات تُختار وفق معايير محددة تعتمد على المعرفة التراكمية أو الاحتمالية. من أبرز أمثلتها:

خوارزمية مستعمرة النمل (*Ant Colony Optimization*)، التي تستلهم سلوك النمل الطبيعي في البحث عن أقصر الطرق إلى مصادر الغذاء، من خلال استخدام إشارات الفرمونات لتوجيه عمليات الاختيار، وهو ما يُترجم في الخوارزمية على شكل تعزيز احتمالية اختيار المسارات التي أثبتت فاعلية في التكرارات السابقة [8].

تُظهر هذه الخوارزميات فعالية كبيرة في المشكلات التي تتطلب توليفات متسلسلة من القرارات، مثل مشكلات تخصيص الموارد، وجدولة المهام، وتصميم الشبكات.

I.4.2 الميتاهيورستيات المعتمدة على بحث الجوار**Neighborhood Search-Oriented Metaheuristics**

تعتمد هذه الفئة من الخوارزميات على تحسين حل وحيد من خلال استكشاف جواره المحلي، حيث يُجرى الانتقال عبر تغييرات طفيفة تُعرف بـ "الحركات" (Moves)، تهدف إلى تحسين تدريجي في قيمة دالة الهدف. ويستمر هذا البحث إلى أن يصل إلى نقطة لا يمكن تحسينها باستخدام أيّ انتقال محلي، وهو ما يُعرف بـ الحل المحلي الأمثل.

تُظهر هذه الخوارزميات كفاءة عالية في المسائل ذات البنية المستقرة، التي تُظهر استجابات متوقعة لتحسينات محلية متعاقبة.

من أبرز الخوارزميات التي تندرج ضمن هذه الفئة:

التلدين المحاكي (*Simulated Annealing - SA*): مستوحى من عملية التلدين الفيزيائي، حيث يُسمح في البداية بقبول حلول أقل جودة وفق احتمالية تعتمد على "درجة حرارة" مرتفعة، ثم تُخفض تدريجياً لتقليل فرص القبول العشوائي، مما يساعد في تجاوز الحلول المحلية.

البحث المحظور (*Tabu Search - TS*): يستخدم هياكل ذاكرة قصيرة وطويلة المدى لتسجيل التحركات السابقة ومنع العودة إليها، مما يُحسن من تغطية فضاء البحث ويمنع التكرار غير المفيد، ويُعد من أنجح خوارزميات البحث المحلي في تطبيقات الجدولة والتصميم.

وغالباً ما تُستخدم خوارزميات هذه الفئة كعنصر أساسي في بناء خوارزميات هجينة أكثر تعقيداً [9].

I.4.3 الميتاهيورستيات المعتمدة على السكان (Population-Based Metaheuristics):

تُعالج هذه الخوارزميات مجموعة من الحلول المتوازية في كل دورة بحثية، على خلاف الخوارزميات القائمة على حل واحد. وتُعرف هذه المجموعة بـ "السكان" (Population)، حيث يتفاعل الأفراد داخلها عبر آليات مستوحاة من العمليات الطبيعية، كالتكاثر، التكيف، والتعاون الجماعي. يعتمد هذا النمط من الخوارزميات على عمليات مثل:

❖ التزاوج (Crossover)

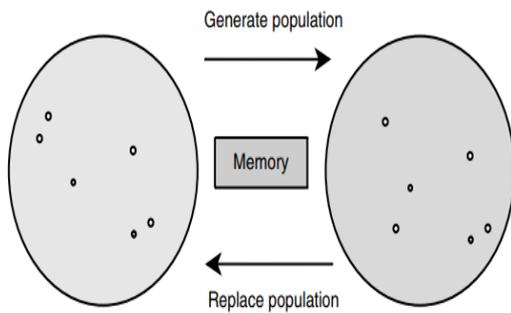
❖ الطفرة (Mutation)

❖ الانتقاء الطبيعي

❖ التفاعل الجماعي

وتهدف هذه العمليات إلى تحسين التنوع في فضاء البحث، والحد من مخاطر الانحشار في الحلول المحلية.

تمتاز هذه الخوارزميات بقدرتها على تغطية واسعة لفضاء البحث، مما يجعلها مناسبة للمشكلات المعقدة، خصوصًا متعددة الأهداف أو متعددة الأنماط (Multimodal).



يوضح الشكل (I.3) التسلسل البنوي العام للخوارزميات السكانية، والذي تتبعه معظم الخوارزميات مثل GA و PSO و ACO، حيث تبدأ العملية بتوليد مجموعة أولية من الحلول ثم تحديثها تكرارياً وفقاً لآليات التحسين الجماعي.

الشكل 3.I : المبادئ الأساسية للخوارزميات الوصفية [9]P-metaheuristics

ويعرض الجدول (1) مقارنة بين أنواع الذاكرات المستخدمة في هذه الخوارزميات، مما يُبرز تنوع آليات الاستكشاف والاستغلال.

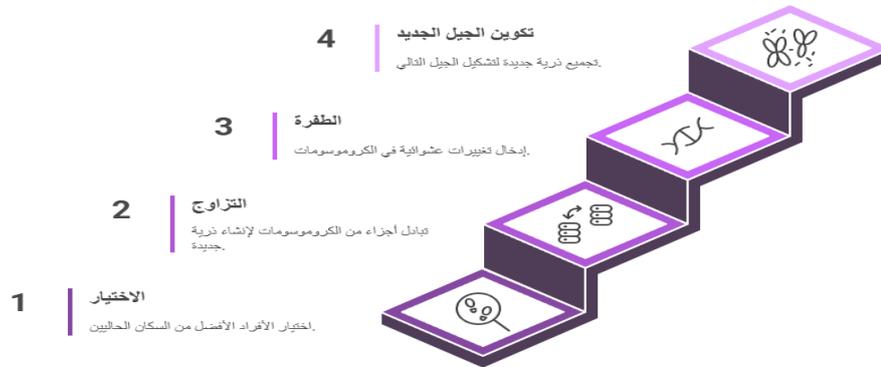
جدول 1 : ذاكرات البحث لبعض الخوارزميات الوصفية P-Metaheuristics

الخوارزمية الوصفية (P-metaheuristic)	ذاكرة البحث (Search Memory)
الخوارزميات التطورية	مجموعة الأفراد
البحث المتناثر	مجموعة الحلول، مجموعة مرجعية
مستعمرات النمل	مصفوفة الفيرومونات
خوارزميات تقدير التوزيع	نموذج التعلم الاحتمالي
تحسين سرب الجسيمات	مجموعة الجسيمات، أفضل الحلول العالمية والمحلية
مستعمرات النحل	مجموعة النحل
أنظمة المناعة الاصطناعية:	مجموعة الأجسام المضادة
الاختيار النسيلي -	

ومن أبرز أمثلتها:

• الخوارزميات الجينية (Genetic Algorithms - GA)

تقوم على تمثيل الحلول ككائنات حية رقمية تخضع لعمليات انتخاب طبيعي، عبر التزاوج والطفرة. يُظهر الشكل (I.4) دورة حياة خوارزمية GA من توليد السكان الأولي إلى إنتاج الأجيال اللاحقة.

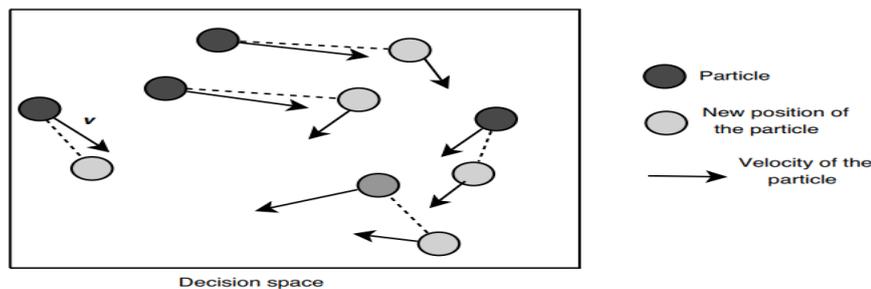


الشكل 4.I: دورة عمل الخوارزمية الجينية

• تحسين سرب الجسيمات (Particle Swarm Optimization – PSO)

تستلهم سلوك أسراب الطيور أو الأسماك، حيث يتبادل "الجسيم" موقعه وسرعته وفقاً لخبرته الفردية وخبرة المجموعة. تُظهر هذه الخوارزمية كفاءة عالية في مشكلات التحسين المستمر وتتميز بسهولة التطبيق وقوة التقارب [10].

ويوضّح الشكل (I.5) التفاعل الديناميكي بين الجسيمات في فضاء البحث. تُعتبر خوارزمية PSO فعّالة في حل مسائل التحسين المستمرة، كما تتميز بسهولة التطبيق وقوة التقارب نحو الحل الأمثل.

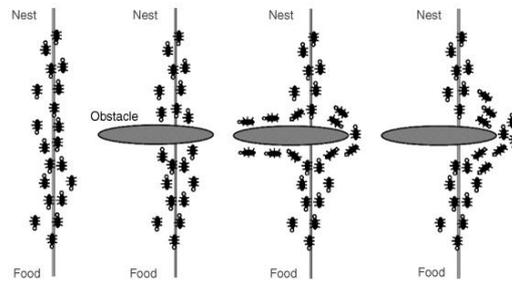


الشكل 5.I: سرب الجسيمات مع المواقع والسرعات المرتبطة بها [10].

I.4.3.1 خوارزمية مستعمرة النمل (Ant Colony Optimization - ACO)

حاكي تفاعل النمل في الطبيعة، حيث يختار الأفراد المسارات بناءً على تراكم الفرمونات. يُعزز هذا الأسلوب المسارات الأفضل بشكل تراكمي، مما يزيد من فعالية البحث خاصةً في مسائل المسارات والشبكات [8].

الشكل (I.6) يوضح مثالاً واقعيًا مستوحى من تجربة أجراها Goss وزملاؤه [8]، حيث يُبين كيف يتفاعل النمل مع وجود عائق في الطريق، ويقوم بإعادة توجيه سلوكه تدريجيًا حتى الوصول إلى أقصر مسار ممكن. هذا السلوك يُظهر بوضوح قدرة النمل على التكيف باستخدام آلية بسيطة جماعية دون تحكّم مركزي.



الشكل I.6: استلهام من سلوك مستعمرة النمل في البحث عن المسار الأمثل [8].

I.4.4 الميتاهيورستيات الهجينة (Hybrid Metaheuristics):

تُمثّل الخوارزميات الهجينة اتجاهًا متقدمًا في مجال التحسين التوافقي، إذ تسعى إلى دمج استراتيجيات متعددة ضمن بنية واحدة لتحقيق توازن فعال بين الاستكشاف الشامل والاستغلال المركز [10]. تقوم هذه المنهجية على توظيف تقنيات متكاملة من فئات مختلفة من الميتاهيورستيات - سواء كانت مبنية على السكان (P-type)، أو على حل فردي (S-type) - مع أدوات من البرمجة الرياضية، برمجة القيود (CP)، أو الذكاء الاصطناعي (كالتعلم الآلي). يُسهم هذا التمازج في بناء خوارزميات ذات أداء أعلى وقدرة على التكيف مع تعقيدات مشكلات العالم الحقيقي. تشمل الأساليب الهجينة:

دمج الخوارزميات الجينية (GA) مع تحسين سرب الجسيمات (PSO):

للاستفادة من التنوع الوراثي في GA وسرعة التقارب في PSO.

دمج خوارزمية مستعمرة النمل (ACO) مع البحث المحظور (Tabu Search):

لتوجيه حركة البحث بشكل ديناميكي مع تحسين محلي فعال.

دمج الميتاهيورستيات مع تقنيات أخرى مثل برمجة القيود (Constraint Programming)، البرمجة الرياضية، أو خوارزميات تعلم الآلة:

وذلك لإضفاء طابع تكيفي وتقييدي أكثر دقة على عمليات البحث [6] [10].

I.4.4.1 أنواع الميتاهيورستيات الهجينة

يمكن تصنيف الخوارزميات الهجينة إلى نوعين رئيسيين وفقاً لبنية الدمج:

التهجين التصميمي (Design-Level Hybridization)

وتتناول المعمارية العامة، مثل ترتيب المراحل، واختيار المكونات، وطبيعة الربط بينها.

التهجين التنفيذي (Operational-Level Hybridization)

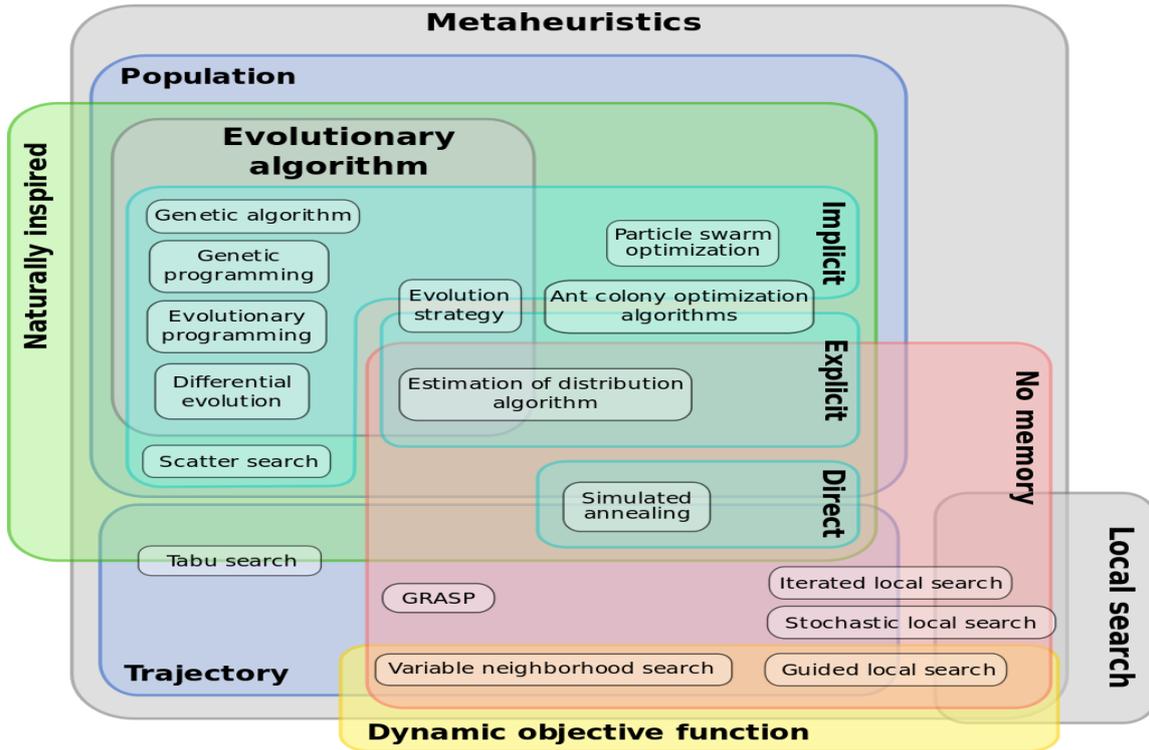
وتشمل بيئة التشغيل، البرمجة الفعلية، إدارة الموارد الحاسوبية، وآليات التفاعل بين الأجزاء. تُوفّر هذه الأساليب الهجينة قدرة استثنائية على معالجة المسائل الكبيرة والمعقدة، وتُعد من الاتجاهات المتقدمة في أبحاث التحسين الذكي.

I.4.5 منظور متعدد الأبعاد لتصنيف خوارزميات الميتاهيورستيك

على الرغم من وضوح الحدود المفاهيمية بين التصنيفات السابقة، فإنّ العديد من الخوارزميات قد تنتمي فعلياً إلى أكثر من فئة، وفقاً لطريقة تنفيذها أو آلية تفاعل مكوناتها. فعلى سبيل المثال، يمكن اعتبار خوارزمية ACO خوارزمية بنائية وسكانية في آنٍ واحد، بينما قد تتحوّل SA إلى مكون داخل بنية هجينة. ويُعد هذا التداخل سمة مرنة تُمكن الباحث من توظيف الخوارزميات بما يتناسب مع خصائص المشكلة قيد المعالجة.

كما يمكن تصنيف بعض الخوارزميات أيضاً بحسب عدد الحلول التي تتم معالجتها أثناء كل دورة من البحث؛ فبعضها يعتمد على حل فردي مثل Simulated Annealing، بينما يعمل البعض الآخر على مجموعة من الحلول مثل الخوارزميات الجينية و PSO. هذا التصنيف يُعبّر عن البنية التنفيذية أكثر من كونه منهجاً مفاهيمياً مستقلاً [11].

يُبرز الشكل (I.7) تصنيفاً متعدد الأبعاد لخوارزميات الميتاهيورستيك، يشمل عدد الحلول المعالجة (فردية/جماعية)، مصدر الإلهام، استخدام الذاكرة، وطبيعة البحث المحلي. ويُظهر كيف يمكن أن تنتمي الخوارزمية الواحدة إلى أكثر من فئة، وفقاً لبنيتها التنفيذية ووظيفتها التحسينية.



الشكل 7.I : تصنيف متعدد الأبعاد لخوارزميات الميتاهيورستيك [12]

I.5 معايير تقييم الخوارزميات الميتاهيورستية:

لتقييم فعالية الخوارزميات الميتاهيورستية، يعتمد الباحثون على مجموعة من المؤشرات التي تُعكس كفاءة الأداء وسلوكه في بيئات متنوعة. من أبرز هذه المعايير:

• سرعة التقارب **Convergence Speed** : مدى سرعة الخوارزمية في الوصول إلى حل شبه مثالي، وهو عامل حاسم في الأنظمة الزمنية الحساسة.

• جودة الحل **Solution Quality** : مدى قرب الناتج من الحل الأمثل من حيث القيمة أو الكفاءة.

• زمن التنفيذ **Execution Time** : لوقت الإجمالي المطلوب للوصول إلى نتيجة مقبولة.

• الاستقرار **Stability** : قدرة الخوارزمية على تقديم نتائج متكررة عند تطبيقها على نفس المسألة في تجارب مختلفة.

• قابلية التوسع **Scalability** : مدى كفاءة الخوارزمية في التعامل مع مشكلات ذات أحجام كبيرة دون تدهور كبير في الأداء.

I.6 ملاءمة الخوارزميات الميتاهيورستية للأنظمة المدمجة

تتسم الأنظمة المدمجة (Embedded Systems) بقيود صارمة على مستوى الموارد، مما يستدعي استخدام خوارزميات تحسين ذات خصائص محددة. وعند اختيار الخوارزمية الميتاهيورستية الأنسب لمثل هذه البيئات [12] ، ينبغي مراعاة ما يلي:

- البنية الحسابية البسيطة: تقليل العمليات المعقدة لتناسب المعالجات المحدودة.
- القدرة على العمل في الزمن الحقيقي **Real-Time Capability** الاستجابة في الوقت المناسب دون تأخير حرج.
- الاقتصاد في استخدام الذاكرة: الاستفادة من مساحة محدودة للتخزين دون الإضرار بالأداء.
- القدرة على التكيف: التفاعل بمرونة مع التغيرات الديناميكية في بيئة التشغيل.

I.7 الخلاصة

تناول هذا الفصل الأسس النظرية لخوارزميات الميتاهيورستيك باعتبارها إطارًا تقريبيًا فعالًا لحل مشكلات التحسين التوافقي، والتي تتسم عادةً بتعقيد حسابي عالٍ وصعوبة الوصول إلى الحلول المثلى باستخدام الطرائق الدقيقة التقليدية.

تمت مراجعة تصنيفات الميتاهيورستيات من حيث منهجياتها التنفيذية، بدءًا بالخوارزميات المبنية على الحل الفردي مثل التلدين المحاكى والبحث المحظور، مرورًا بالخوارزميات السكانية مثل الخوارزميات الجينية وتحسين سرب الجسيمات، وصولًا إلى الخوارزميات الهجينة التي تدمج أكثر من تقنية لتعزيز الاستكشاف والتقارب.

كما أُشير إلى المعايير المعتمدة لتقييم فعالية هذه الخوارزميات، بما في ذلك سرعة التقارب، جودة الحل، زمن التنفيذ، الاستقرار، وقابلية التوسع، مع إبراز أهمية توافقها مع متطلبات الأنظمة المدمجة من حيث البساطة الحسابية والكفاءة الطاقية والمرونة التكوينية.

الفصل الثاني: المحسن بالمتوسط الهندسي

Geometric Mean Optimizer (GMO)

II.1 المقدمة:

في مجال تحسين الأنظمة المدمجة، تلعب الخوارزميات الميتا-استكشافية دورًا حيويًا في إيجاد حلول فعّالة للمشكلات المعقدة. من بين هذه الخوارزميات، يبرز المحسن بالمتوسط الهندسي كأداة قوية وفعّالة. تستند هذه الخوارزمية إلى محاكاة الخصائص الفريدة لمشغل المتوسط الهندسي في الرياضيات، مما يسمح بتقييم مترامن لملاءمة وتنوع وكلاء البحث في فضاء الحلول. يُستخدم المتوسط الهندسي للقيم الهدفية المعدلة لمعاكسات وكيل معين لتحديد وزنه، مما يعكس أهليته العامة لتوجيه الوكلاء الآخرين في عملية البحث عند حل مشكلة تحسين معينة. علاوة على ذلك، لا يتطلب هذا المحسن ضبط أي معاملات، مما يساهم في موثوقية نتائجه العالية.

يعد تحسين الأنظمة المدمجة أمرًا بالغ الأهمية في التطبيقات الهندسية، مثل تحليل أداء الأنظمة الزمن الحقيقي وتحسين استهلاك الطاقة في الأجهزة الذكية. من بين الخوارزميات الميتا-استكشافية، يبرز المحسن بالمتوسط الهندسي كنهج فريد يستند إلى خصائص المتوسط الهندسي في تقييم كفاءة وتنوع وكلاء البحث، مما يجعله مناسبًا لمجموعة واسعة من المشكلات الهندسية [14].

يهدف هذا الفصل إلى تقديم تحليل نظري شامل لخوارزمية GMO، بدءًا من الأسس الرياضية التي تستند إليها، وصياغتها الرياضية، وآلية البحث والاستكشاف التي تتبعها، وصولًا إلى تحليل تقاربها ومدى كفاءتها في إيجاد الحلول المثلى. كما سيتم تسليط الضوء على المفاهيم الأساسية التي تجعل GMO نهجًا متميزًا ضمن الخوارزميات الميتا-استكشافية

II.2 الخلفية النظرية

II.2.1 المتوسط الهندسي Geometric Mean

II.2.1.1 تعريف المتوسط الهندسي وخصائصه الرياضية

Definition of the Geometric Mean and Its Mathematical Properties

المتوسط الهندسي هو أحد أنواع المتوسطات المستخدمة لقياس القيمة المركزية لمجموعة من الأعداد الموجبة، ويُحسب من خلال الجذر النوني لجداء هذه القيم. يُحسب المتوسط الهندسي بأخذ الجذر النوني لحاصل ضرب هذه الأعداد، حيث "X" تمثل عدد القيم في المجموعة. يُعبر عنه رياضياً بالصيغة التالية:

$$X = \{x_1, x_2, x_3, \dots, x_n\} \quad (II.1)$$

$$GM(X) = \left(\prod_{i=1}^n x_i \right)^{\frac{1}{n}} \quad (II.2)$$

حيث x_i هي القيم الفردية و n هو عدد هذه القيم. يُستخدم المتوسط الهندسي في الحالات التي تكون فيها القيم مرتبطة بعلاقات تضاعفيه أو عند التعامل مع معدلات النمو النسبي [14].
من أبرز خصائصه:

- عدم التأثير بالقيم المتطرفة: بخلاف المتوسط الحسابي، لا يتأثر المتوسط الهندسي بالقيم المرتفعة جدًا أو المنخفضة جدًا في المجموعة.
- التعامل مع النسب المئوية والتغيرات النسبية: يُعتبر المتوسط الهندسي مناسبًا عند التعامل مع البيانات التي تمثل نسبة مئوية أو معدلات نمو، حيث يعكس التغيرات النسبية بدقة.
- الشرط الإيجابي: يتطلب أن تكون جميع القيم موجبة، حيث أن القيم السالبة أو الصفرية تجعل الناتج غير معرف.

على سبيل المثال، عند حساب متوسط معدلات النمو السنوية لاستثمار معين، فإن المتوسط الهندسي يوفر تمثيلًا أكثر دقة مقارنة بالمتوسط الحسابي، خاصة عندما تكون القيم متباينة بشكل كبير. فإذا كانت معدلات النمو السنوية لاستثمار معين هي (5% , 10% , 15%)، فإن المتوسط الحسابي يعطي 10%، بينما المتوسط الهندسي يعطي قيمة أقل تعبر بشكل أدق عن النمو الفعلي.

II.2.1.2 مقارنة بين المتوسط الهندسي والمتوسط الحسابي

Comparison Between the Geometric Mean and the Arithmetic Mean

يُعد المتوسط الحسابي (Arithmetic Mean) الأكثر شيوعًا واستخدامًا في الإحصاء، ويُحسب بجمع القيم وقسمتها على عددها:

$$A = \frac{1}{n} \sum_{i=1}^n x_i \quad (\text{II.3})$$

بينما يُركز المتوسط الهندسي على العلاقة التضاعفية بين القيم. وفقًا لمتباينة المتوسطات، يكون المتوسط الهندسي دائمًا أقل من أو يساوي المتوسط الحسابي، مع تحقيق المساواة فقط عندما تكون جميع القيم متساوية. هذا يعني أن:

$$GM(X) \leq AM(X) \quad (\text{II.4})$$

تُستخدم هذه الخاصية في العديد من التطبيقات لتحديد مدى تشتت البيانات. بالإضافة إلى ذلك، بينما يُعطي المتوسط الحسابي وزنًا متساويًا لجميع القيم، فإن المتوسط الهندسي يُعطي وزنًا أكبر

للقيم الأصغر، مما يجعله أكثر ملاءمة في الحالات التي تتأثر فيها البيانات بالقيم المتطرفة أو عند تحليل معدلات النمو المركبة [14].

جدول 2: مقارنة بين المتوسط الهندسي والحسابي [14]

المعيار	المتوسط الحسابي (Arithmetic Mean)	المتوسط الهندسي (Geometric Mean)
الحساسية للقيم المتطرفة	عالية	منخفضة
قابلية الاستخدام مع القيم السالبة	نعم	لا
مناسب للعلاقات	جمعية	ضربية
الاستخدام الشائع	بيانات منتظمة أو موزعة بشكل طبيعي	بيانات نمو وتغير نسبي

II.2.1.3 تطبيقات المتوسط الهندسي في التحسين والأنظمة المضمنة

(Applications of the Geometric Mean in Optimization and Embedded Systems)

II.2.1.3.1 تطبيقات المتوسط الهندسي في المجالات المختلفة

Applications of the Geometric Mean in Various Fields

استخدم العديد من الباحثين المتوسط الهندسي كمقياس لتحسين أداء الخوارزميات الاستكشافية، خاصة في الحالات التي تتطلب تقويمًا دقيقًا لأداء وكفاءة عدة حلول في وقت واحد. فعلى سبيل المثال، تُستخدم القيم الناتجة من المتوسط الهندسي لتقدير مدى انتشار مجموعة من الحلول (Agents) ضمن فضاء الحل، مما يسهل توجيه عملية البحث نحو المناطق الواعدة. كذلك، يُعتمد على هذا المتوسط في تقييم "اللياقة" في بعض الخوارزميات السكانية، بحيث يتم تعيين وزن لكل عنصر بناءً على العلاقة التراكمية بين أدائه وأداء العناصر الأخرى ضمن نفس الجيل [14].

كما تم استخدام المتوسط الهندسي في مجموعة متنوعة من المجالات، نظرًا لقدرته على التعامل مع البيانات التضاعفية والنسبية. من أبرز هذه التطبيقات:

- التمويل: يُستخدم المتوسط الهندسي لحساب متوسط معدلات النمو السنوية المركبة للاستثمارات، مما يوفر صورة أكثر دقة للأداء على المدى الطويل مقارنةً بالمتوسط الحسابي.
- الإحصاء: عند التعامل مع البيانات التي تتبع توزيعًا لوغاريتميًا طبيعيًا، يُعتبر المتوسط الهندسي مقياسًا أكثر دقة للذروة المركزية.
- الهندسة: يُستخدم في حساب الأبعاد الهندسية التي تتطلب التناسب المضاعف، مثل حساب متوسط نسب الأبعاد في الأشكال الهندسية.

- العلوم البيئية: يُستخدم المتوسط الهندسي لتقدير المتوسطات في القياسات البيئية التي تتبع توزيعات غير متماثلة، مثل تركيزات الملوثات في الهواء أو الماء.
- الاقتصاد: يُستخدم في حساب مؤشرات الأسعار، مثل مؤشر أسعار المستهلك، حيث يتم حساب متوسط التغيرات النسبية في الأسعار.

II.2.1.3.2 تطبيقات المتوسط الهندسي في التحسين والأنظمة المضمنة

Applications of the Geometric Mean in Optimization and Embedded Systems

يُستخدم المتوسط الهندسي في مجموعة متنوعة من التطبيقات المتعلقة بالتحسين والأنظمة الذكية، حيث يُعد أداة رياضية قوية قادرة على تحسين أداء الخوارزميات في البيئات ذات البيانات المتغيرة. تشمل بعض التطبيقات الرئيسية ما يلي:

- تحسين أداء خوارزميات الميتا-استكشافيات:

Enhancing the Performance of Metaheuristic Algorithms

يُستخدم المتوسط الهندسي كآلية فعالة في خوارزميات البحث الذكي مثل المحسن بالمتوسط الهندسي (GMO)، حيث يساعد في تحقيق توازن بين الاستكشاف والاستغلال من خلال استخدام قيم مضاعفة تعكس العلاقات النسبية بين الحلول.

يساعد في تحسين قدرة الخوارزميات على التعامل مع فضاءات البحث المعقدة من خلال إعطاء أهمية أكبر للحلول التي تمتلك أداءً متوازنًا عبر أبعاد متعددة.

- تحسين البحث في الفضاءات عالية الأبعاد:

Improving Search in High-Dimensional Spaces

يُعتبر المتوسط الهندسي أداة قوية في البحث داخل الفضاءات المعقدة، حيث يسمح بالتعامل مع القيم التضاعفية التي يصعب على المتوسط الحسابي معالجتها.

يُستخدم بشكل خاص في الخوارزميات التطورية (Evolutionary Algorithms) لتحسين سرعة التقارب نحو الحل الأمثل وتقليل الاعتماد على البحث العشوائي.

- التحكم الذكي في الأنظمة المضمنة:

Intelligent Control in Embedded Systems

يُمكن استخدام المتوسط الهندسي في ضبط معاملات الأنظمة التكيفية (Adaptive Systems)

(Tuning) في الأنظمة المضمنة، مما يساعد في تحقيق استجابات ديناميكية أكثر دقة وكفاءة.

يُستخدم في تحسين خوارزميات التحكم الذاتي (Self-Tuning Control Algorithms) في الأجهزة المدمجة التي تحتاج إلى التكيف مع البيئات المتغيرة بسرعة.

- تحليل البيانات والاستشعار في الأنظمة المضمنة:

Data Analysis and Sensing in Embedded Systems

يُستخدم المتوسط الهندسي في معالجة بيانات المستشعرات (Sensor Data Processing)، خاصةً في الأنظمة التي تتعامل مع توزيعات غير متماثلة للبيانات (Non-Symmetric Data Distributions) مثل قياسات الضغط والحرارة في الأنظمة الصناعية.

يُساعد في تقليل التشويش والضوضاء في البيانات الحسية، مما يحسن من دقة القياسات ويزيد من موثوقية قرارات الأنظمة الذكية

II.2.2 خوارزميات الميتا-استكشافيات Metaheuristic Algorithms

II.2.2.1 مراجعة سريعة لأبرز خوارزميات الميتا-استكشافيات التقليدية

خوارزميات الميتا-استكشافيات Metaheuristic Algorithms هي تقنيات تحسين تعتمد على محاكاة عمليات طبيعية أو سلوكية لإيجاد حلول تقريبية لمشكلات معقدة. تتميز هذه الخوارزميات بقدرتها على التعامل مع فضاءات بحث كبيرة ومعقدة، وتجنب الوقوع في الحلول المحلية المثلى. من أبرز هذه الخوارزميات:

- خوارزمية التلدين المحاكي: (Simulated Annealing) تعتمد على محاكاة عملية تبريد المعادن للوصول إلى حالة طاقة دنيا. تبدأ الخوارزمية بحل عشوائي وتستكشف الجوار بحلول جديدة، مع قبول الحلول الأسوأ بفرصة تتناقص مع مرور الوقت، مما يسمح بتجنب الوقوع في الحلول المحلية المثلى.
- خوارزمية أسراب الجسيمات: (Particle Swarm Optimization) تعتمد PSO على حركة جسيمات في فضاء الحل، وتحديث مواقعها وسرعتها بناءً على أفضل المواقع التي تم الوصول إليها من قبل كل جسيم والجماعة ككل. تتميز ببساطة التنفيذ والسرعة في الوصول للحل.
- الخوارزميات الجينية: (Genetic Algorithms) مبنية على مبادئ الانتقاء الطبيعي والوراثة لتوليد حلول جديدة. تبدأ الخوارزمية بمجموعة من الحلول العشوائية (تُسمى الأفراد)، وتستخدم

عمليات مثل التهجين (Crossover) والطفرات (Mutations) لتوليد أجيال جديدة من الحلول، مع اختيار الأفراد الأكثر ملاءمة للبقاء.

خوارزمية البحث المحظور (Tabu Search) : تقوم هذه الخوارزمية بتخزين قائمة من الحلول أو التحركات التي يُمنع تكرارها لفترة زمنية معينة تُعرف باسم "الذاكرة القصيرة"، مما يسمح بتجاوز الحلول المحلية، واستكشاف مسارات جديدة. وقد أثبتت فعاليتها في مشاكل التخصيص والجدولة.

جدول 3 : نقاط القوة لكل خوارزمية مقارنة بـGMO [15]

المزايا	آلية العمل	الخوارزمية
جيد لتجاوز الحلول المحلية المثلى	محاكاة عملية تبريد المعادن	التلدين المحاكى (SA)
سريع ويعتمد على معلومات الجماعة	استلهام حركة الطيور والأسماك	أسراب الجسيمات (PSO)
فعال في البحث عن الحلول المتعددة	الانتقاء الطبيعي والتهجين والطفرات	الخوارزميات الجينية (GA)
لا يحتاج لضبط المعلمات، يقلل من الحساسية للقيم الأولية	استخدام المتوسط الهندسي لتوجيه البحث	المحسن بالمتوسط الهندسي (GMO)

II.2.2.2 التحديات والقيود في الخوارزميات الحالية

Challenges and Limitations in Existing Algorithms

على الرغم من فعالية خوارزميات الميتما-استكشافيات التقليدية، إلا أنها تواجه بعض التحديات والقيود، منها:

- الحاجة إلى ضبط العديد من المعلمات: تتطلب هذه الخوارزميات تحديد وضبط معلمات متعددة، مثل معدلات التبريد في خوارزمية التلدين المحاكى أو حجم السرب في خوارزمية أسراب الجسيمات، مما يزيد من تعقيد عملية الإعداد ويؤثر على أداء الخوارزمية.
- الوقوع في الحلول المحلية المثلى: قد تتوقف بعض الخوارزميات عند حلول محلية مثلى دون الوصول إلى الحل الأمثل العام، خاصة في المشكلات ذات فضاءات الحلول المعقدة.
- الحساسية تجاه القيم الأولية: يمكن أن تؤثر القيم الأولية المختارة لبدء الخوارزمية على مسار البحث والنتائج النهائية، مما يتطلب اختيارًا دقيقًا لهذه القيم.
- التكلفة الحسابية: قد تكون بعض الخوارزميات مكلفة من حيث الوقت والموارد الحسابية، خاصة عند تطبيقها على مشكلات كبيرة الحجم أو معقدة.

ومن بين أبرز التحديات التي تواجه خوارزميات الميتما-استكشافيات التقليدية أيضا هي مشكلة التقارب المبكر (Premature Convergence)، والتي تحدث عندما تتجمع مجموعة الحلول بسرعة حول قيمة

محلية مثلى دون مواصلة استكشاف الفضاء البحثي بشكل كافٍ. هذا السلوك يؤدي إلى فقدان التنوع في السكان ويمنع الوصول إلى الحل الأمثل العام. يعود سبب هذه الظاهرة غالبًا إلى ضعف آليات التوجيه أو غياب استراتيجيات فعالة تضمن الحفاظ على التوازن بين الاستكشاف والاستغلال. ومن هنا، تبرز الحاجة إلى تطوير خوارزميات مثل GMO التي تتبنى آليات ديناميكية لمواجهة هذه الظاهرة.

II.2.2.3 الحاجة إلى تطوير خوارزميات جديدة مثل GMO

The Need for Developing New Algorithms Like GMO

نظرًا للتحديات والقيود المذكورة أعلاه، ظهرت الحاجة إلى تطوير خوارزميات جديدة تتغلب على هذه المشكلات وتوفر حلولًا أكثر كفاءة وفعالية. يُعتبر المحسن بالمتوسط الهندسي (Geometric Mean Optimizer - GMO) إحدى هذه الخوارزميات المبتكرة التي تهدف إلى:

- تقليل الحاجة إلى ضبط المعلمات: من خلال استخدام المتوسط الهندسي، يسعى GMO إلى تقليل عدد المعلمات التي تحتاج إلى ضبط، مما يبسط عملية الإعداد ويقلل من الحساسية تجاه القيم الأولية.
- تحسين القدرة على استكشاف فضاء الحلول: يُعزز استخدام المتوسط الهندسي من قدرة الخوارزمية على استكشاف فضاء الحلول بكفاءة، مما يقلل من احتمالية الوقوع في الحلول المحلية المثلى.
- زيادة الاستقرار والموثوقية: من خلال تقليل التأثير بالقيم المتطرفة واستخدام آليات توجيه محسنة، يسعى GMO إلى تقديم حلول أكثر استقرارًا وموثوقية عبر مجموعة متنوعة من المشكلات.

II.2.3 الأساس الرياضي للمحسن بالمتوسط الهندسي (GMO)

Mathematical Foundations of the Geometric Mean Optimizer (GMO)

II.2.3.1 صياغة الخوارزمية Algorithm Formulation

تعتمد خوارزمية GMO على مبدأ توجيه مجموعة من الحلول (تسمى وكلاء - Agents) باستخدام متوسط هندسي لعوامل الأداء، بما يساعد على تحقيق توازن بين الانتشار (Diversification) والتقارب نحو الحلول المثلى (Intensification) تتمثل الفكرة الأساسية في تحديد تموضع كل وكيل في فضاء الحل اعتمادًا على تأثير بقية الوكلاء عليه من خلال مؤشر يسمى مؤشر تأثير الوكلاء (Agent Influence Index)

II.2.3.1.1 حساب وزن كل وكيل

يُحسب وزن كل وكيل باستخدام متوسط هندسي لأداء الوكلاء الآخرين مقارنةً به، ويُعطى بالصيغة التالية:

$$w_i = \left(\prod_{j=1}^n f(O_{ij}) \right)^{\frac{1}{n}} \quad (\text{II.5})$$

$$w_i = GM(O_{ij}) \quad (\text{II.6})$$

حيث:

W_i : الوزن المخصص للوكيل i

$f(O_{ij})$: دالة الهدف التي تقيس أداء الوكيل i في البعد j ،

n : عدد الوكلاء

II.2.3.1.2 مفهوم مؤشر اللياقة المزدوج (Dual-Fitness Index - DFI)

يُقدم GMO مفهومًا يُعرف بمؤشر اللياقة المزدوج (DFI)، وهو مؤشر يهدف إلى تقييم كل من جودة الحل وتنوعه. ويُحسب على النحو التالي:

$$DFI_i = \prod_{j \neq i} GM(O_{ij}) \quad (\text{II.7})$$

أي أن تأثير وكيل ما يُستخلص من المتوسطات الهندسية المقارنة مع أداء كل وكيل آخر، مما يضمن تقييمًا تراكميًا عادلًا.

II.2.3.2 تحليل التقارب Convergence Analysis

II.2.3.2.1 دراسة تقارب الخوارزمية نحو الحل الأمثل

يُعد تحليل التقارب عنصرًا أساسيًا في تقييم كفاءة أي خوارزمية تحسين، حيث يشير إلى قدرتها على الاقتراب التدريجي من الحل الأمثل مع زيادة عدد التكرارات. تعتمد GMO في تحقيق ذلك على استخدام المتوسط الهندسي لتوجيه وكلاء البحث نحو المناطق الأكثر وعدًا

يتم تقييم أداء الوكلاء بحساب المتوسط الهندسي للقيم الهدفية المعدلة، مما يُمكن الخوارزمية من توجيه البحث بفعالية نحو الحلول المثلى مع الحفاظ على تنوع مناسب داخل فضاء البحث. هذه الآلية تعزز من كفاءة الاستكشاف مع زيادة احتمالية الوصول إلى الحل الأمثل بسرعة ودقة [13].

II.2.3.2.2 شروط التقارب والتحليل الرياضي لضمان الوصول إلى الحلول المثلى

لضمان تقارب خوارزمية GMO نحو الحل الأمثل، يجب تحقيق عدة معايير، منها:

✓ ضبط المعلمات الأساسية مثل حجم السكان ومعدل التعلم لتحقيق التوازن بين الاستكشاف والاستغلال.

✓ الحفاظ على تنوع كافٍ في الوكلاء لتجنب الوقوع في الحلول المحلية.

✓ استخدام آلية تحديث قوية تستند إلى دالة التوجيه لضمان البحث في المناطق الأكثر وعدًا.

✓ تحديد شروط توقف فعالة مثل الحد الأقصى للتركرارات أو شرط استقرار النتائج بعد عدد معين من التكرارات.

يُظهر التحليل الرياضي أن GMO يمتلك قدرة استكشافية قوية بفضل آلية تخصيص الأوزان القائمة على المتوسط الهندسي، مما يُعزز من سرعة التقارب نحو الحل الأمثل [14].

II.2.3.3 دالة التوجيه (Guide Function) وآلية التحديث (Update Mechanism)

تعتمد آلية التحديث في GMO على دالة توجيه تستند إلى أوزان الوكلاء المحسوبة باستخدام المتوسط الهندسي. في كل تكرار، يتم تحديث موقع كل وكيل بناءً على موقع الوكيل ذو الوزن الأعلى، مما يضمن توجيه عملية البحث نحو المناطق الأكثر وعدًا في فضاء الحلول. تُعبر دالة التوجيه عن تحديث موقع الوكيل i بالصيغة التالية:

$$X_i^{t+1} = X_i^t + \alpha(X_{best}^t - X_i^t) \quad (II.8)$$

حيث

X_i^t هو الموقع الحالي للوكيل

X_{best}^t هو موقع الوكيل ذو الوزن الأعلى في التكرار t

α معامل العشوائية.

يُتيح هذا التحديث للخوارزمية المحافظة على استكشاف جيد لفضاء الحلول، وفي نفس الوقت توجيه البحث نحو المناطق التي أظهرت أداءً جيدًا.

ولتوضيح تأثير مؤشر DFI في عملية التحديث، يمكن تقسيم فضاء الحل إلى أربع مناطق بناءً على متوسط اللياقة في كل منطقة (R1 إلى R4). تُستخدم هذه المناطق لتصنيف الحلول وتوجيه الوكلاء ديناميكيًا.

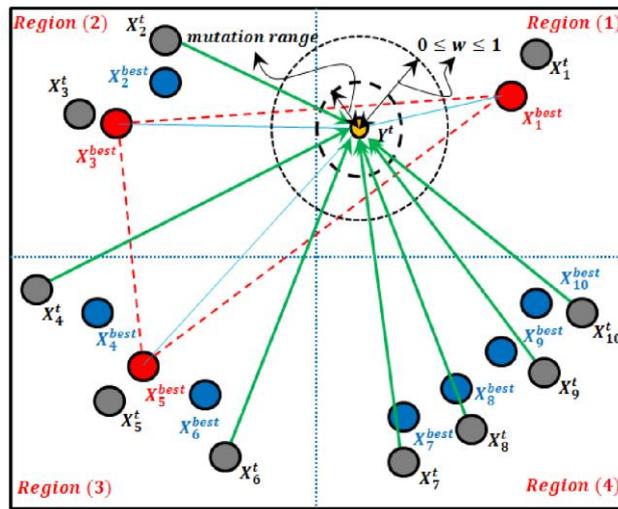
العلاقة بين متوسطات اللياقة تكون كالتالي:

$$\overline{fitness}_{R4} \leq \overline{fitness}_{R3} \leq \overline{fitness}_{R2} \leq \overline{fitness}_{R1} \quad (II.9)$$

حيث R تمثل المنطقة $Region$ وبناءً على هذا التصنيف، تُحدد مستويات مؤشر DFI للوكلاء ضمن هذه المناطق على النحو:

$$DFI_1^t > DFI_3^t > DFI_5^t \quad (II.10)$$

هذا التدرج في مؤشر اللياقة يوجّه التحديثات لتكون أكثر فاعلية، من خلال إعطاء أولوية للمناطق ذات الأداء الأعلى، مع الحفاظ على توزيع استكشافي يغطي كامل فضاء البحث.



الشكل II.1: الإجراء التخطيطي لتحديث وكلاء البحث في التكرار t من خوارزمية GMO [15]

II.2.3.4 خصائص خوارزمية GMO

تتميز خوارزمية GMO بعدة خصائص تجعلها مناسبة لمجموعة واسعة من تطبيقات التحسين [15]، من أبرزها:

- لا تعتمد على معلمات متعددة: يكفي استخدام عدد قليل جداً من المعاملات مما يجعلها سهلة التطبيق.
- قابلة للتكيف: يمكن تطبيقها على مشاكل تحسين ذات طبيعة مستمرة أو منفصلة.
- بنية بسيطة: سهولة التنفيذ مقارنة بخوارزميات أخرى معقدة.
- تحقيق التوازن بين الاستكشاف والاستغلال: تضمن الصيغة الرياضية الحفاظ على تنوع الحلول مع تحسين مستمر.

II.3 خطوات تنفيذ المحسن بالمتوسط الهندسي (GMO)

فيما يلي خطوات تنفيذ خوارزمية GMO:

II.3.1 تهيئة السكان (Population Initialization)

يتم توليد مجموعة أولية من الوكلاء (Agents) موزعين عشوائياً في فضاء البحث لضمان تنوع كافٍ. يُعد هذا التنوع ضرورياً لتغطية مساحات مختلفة من فضاء الحلول في المراحل الأولى من البحث [15].

II.3.2 تقييم الأداء وتحديد النخبة (Fitness & Elite Selection)

يتم تقييم كل وكيل باستخدام دالة الهدف المناسبة، ثم يُحسب مؤشر DFI الذي يجمع بين المتوسط الهندسي لعضوية الوكلاء (MF) وأداءاتهم النسبية. يتم اختيار نخبة من أفضل الوكلاء لتوجيه البحث لاحقاً [15].

II.3.3 التوجيه بالمتوسط المرجح (Weighted Geometric Guidance)

تُحسب المتوسطات الموزونة لقيم DFI الخاصة بالوكلاء المتميزين، ويتم استخدامها لإنشاء متجهات توجيه تُوجه باقي الوكلاء نحو مناطق واعدة. هذا النهج يعزز من كفاءة البحث من خلال التعلّم من الأفضل أداءً [15].

II.3.4 تحديث المواقع (Position Update)

يتم تعديل مواقع الوكلاء باستخدام متجهات التوجيه الجديدة الناتجة عن المتوسط المرجح، مع تضمين مكون عشوائي محدود (مثل الطفرة) لضمان عدم الانجراف إلى الحلول المحلية [16].

II.3.5 آليات البحث والاستكشاف (Search and Exploration Mechanism)

II.3.5.1 استخدام المتوسط الهندسي في توجيه عملية البحث

Using Geometric Mean to Guide Search

- تعتمد خوارزمية GMO على المتوسط الهندسي لتوجيه عملية البحث بشكل ديناميكي.
- يتم حساب وزن كل وكيل باستخدام المتوسط الهندسي للقيم الهدفية المعدلة لمعاكساته.
- يُستخدم هذا الوزن لتوجيه الوكلاء الآخرين نحو مناطق واعدة في فضاء الحلول.

II.3.5.2 استراتيجيات تحقيق التوازن بين الاستكشاف والاستغلال

Exploration vs. Exploitation Strategies

يتم استخدام استراتيجيات مختلفة لتحقيق توازن بين استكشاف مناطق جديدة وتحسين الحلول الحالية:

- الاستكشاف (Exploration): زيادة التنوع في السكان من خلال توليد حلول جديدة بعيدة عن الحلول الحالية.
- الاستغلال (Exploitation): تحسين الحلول الحالية من خلال التركيز على المناطق الواعدة في فضاء البحث.

II.3.5.2.1 الآليات الديناميكية في خوارزمية GMO لتعزيز التوازن بين الاستكشاف والاستغلال

تعتمد خوارزمية GMO على مجموعة من الآليات التي تُسهم في تعزيز قدرتها على استكشاف فضاء الحلول وتجنب الانحصر في حلول محلية. من أبرز هذه الآليات:

- مؤشر اللياقة والتنوع الموحد (DFI): يمثل هذا المؤشر آلية مدمجة تأخذ في الحسبان كلاً من جودة الحل وتنوعه داخل الفضاء البحثي. من خلال دمج المتوسطات الهندسية لأداء الحلول، يتم توجيه البحث نحو مناطق واعدة دون التضحية بالتنوع.
- الوكلاء النخبة (Elite Guide Agents): يتم اختيار مجموعة من الوكلاء ذوي الأداء العالي لتشكيل ما يُعرف بدليل التوجيه الجماعي. هذا الدليل يُحسب كمتوسط مرجح لمواقعهم، مما يُقلل من الاعتماد على وكيل واحد ويُعزز التنوع.
- الطفرة الغاوسية (Gaussian Mutation): تُستخدم لإدخال تغييرات صغيرة عشوائية على مواقع التوجيه المختارة، ما يساعد على كسر النمطية في حركة الوكلاء ويمنع التقارب المبكر.
- النخبوية (Elitism): يتم الحفاظ على أفضل الحلول المكتشفة في كل تكرار، مما يضمن عدم ضياعها أثناء عمليات التحديث، ويساهم في تسريع التقارب نحو الحل الأمثل.

II.3.6 استراتيجية الطفرة (Mutation Strategy)

تُستخدم الطفرات Gaussian بشكل دوري لإدخال تعديلات صغيرة على الحلول، مما يساعد على تقادي حالات الجمود المحلي ويزيد من احتمالية اكتشاف حلول ذات جودة أعلى [16].

II.3.7 اختيار الحل الأفضل وإيقاف الخوارزمية (Best Solution & Stopping Criteria)

يتم تتبع أفضل حل تم التوصل إليه عبر التكرارات، وعند تحقق شرط الإيقاف (عدد التكرارات أو استقرار الحلول)، يتم إخراج هذا الحل كأفضل نتيجة نهائية [16].

II.4 الخلاصة

في هذا الفصل، تم التعمق في دراسة المحسن بالمتوسط الهندسي (GMO) كخوارزمية ميتا-استكشافية مبتكرة تهدف إلى تحسين كفاءة ودقة عمليات البحث عن الحلول المثلى في المشكلات الهندسية. بدأنا بتقديم الخلفية النظرية، حيث تم تعريف المتوسط الهندسي وخصائصه الرياضية، ومقارنته بالمتوسط الحسابي، بالإضافة إلى استعراض تطبيقاته في مجالات متعددة.

تم التطرق إلى خوارزميات الميتا-استكشافيات التقليدية، مع التركيز على التحديات والقيود التي تواجهها، مما أبرز الحاجة إلى تطوير خوارزميات جديدة مثل GMO. بعد ذلك، تناولنا الأسس الرياضية لـ GMO، بما في ذلك صياغة الخوارزمية، واستخدام المتوسط الهندسي في عملية التحسين، ومفهوم مؤشر اللياقة المزدوج (DFI) ودوره في تقييم الحلول، بالإضافة إلى دالة التوجيه وآلية التحديث.

كما تم تحليل تقارب الخوارزمية نحو الحل الأمثل، مع دراسة شروط التقارب والتحليل الرياضي لضمان الوصول إلى الحلول المثلى. في خطوات تنفيذ GMO، تم استعراض تهيئة السكان، وتقييم اللياقة، وآليات البحث والاستكشاف، واستراتيجية الطفرة.

استعرض هذا الفصل التحليل النظري لخوارزمية GMO، موضحاً الأسس الرياضية التي تستند إليها وآليات البحث التي تعتمد عليها. كما تم شرح كيفية استخدام المتوسط الهندسي في توجيه عملية البحث وتحسين جودة الحلول. حيث سيتم تحليل أداء GMO مقارنة بالخوارزميات الأخرى في الفصل الثالث.

يُشكّل هذا التحليل النظري أساساً لفهم إمكانيات GMO، مما يمهد الطريق لاستكشاف تطبيقاته العملية في تحسين الأنظمة المدمجة، والتي سيتم مناقشتها بالتفصيل في الفصول القادمة.

الفصل الثالث: تطبيقات نظرية لخوارزمية GMO في الأنظمة

الذكية

III.1 المقدمة

يهدف هذا الفصل إلى استكشاف القدرات النظرية لخوارزمية المُحسّن بالمتوسط الهندسي (GMO – Geometric Mean Optimizer) من خلال تحليل تطبيقاتها على مسألتين هندسيتين وتقنيتين تمثل طيفًا واسعًا من تحديات التحسين متعددة الأهداف. تتميز هذه التطبيقات بتعقيدها البنوي أو الديناميكي أو الحسابي، وتُعدّ حالات واقعية شائعة في مجالات التحكم الصناعي، النمذجة الروبوتية، والذكاء الاصطناعي المدمج. وبذلك، فإن هذا الفصل لا يقتصر على عرض نظري، بل يُقدّم إطارًا تحليليًا لاختبار مدى ملاءمة خوارزميات التحسين الذكية، تمهيدًا للفصل التطبيقي الذي يلي.

ويأتي هذا الفصل استكمالًا لما طُرح في الفصل الثاني من تحليل رياضي لخوارزمية GMO، بما في ذلك شرح آلية التوجيه عبر المتوسط الهندسي، ومؤشر اللياقة المزدوج (DFI)، وآلية التحديث الحسابي. غير أن التركيز هنا سينتقل من البنية المجردة للخوارزمية إلى تفعيلها ضمن سياقات نظرية تطبيقية، بهدف تبيان قابليتها للتكيف مع نماذج متنوعة في سلوكها، وتركيبتها، ومتطلباتها.

إن ما يميّز خوارزمية GMO في هذا السياق هو قابليتها للاستخدام في مسائل يصعب تمثيلها رياضياً، بالإضافة إلى قدرتها على التعامل مع فضاءات بحث متعددة الأبعاد، دون الحاجة إلى اشتقاقات تفاضلية أو ضبط أولي معقد. وتُعدّ قدرتها على تحقيق توازن ديناميكي بين الاستكشاف والاستغلال من خلال بنية DFI إحدى أهم مزاياها عند مواجهة أنظمة غير خطية أو متغيرة زمنياً، كما هو الحال في التطبيقات التي ستُعرض لاحقاً.

بناءً على ذلك، يعرض هذا الفصل تطبيق خوارزمية GMO على مشكلتين مختلفتين من حيث الطبيعة والمنهج، الأولى تتعلق بضبط متحكم PID في أنظمة ديناميكية فيزيائية، والثانية تتعلق بالتصنيف الطبي للصور الشعاعية في بيئة مدمجة. هذا التنوع في المجالات يُبرز مرونة خوارزمية GMO في التكيف مع خصائص المسائل المختلفة، سواء من ناحية المعالجة الزمنية أو التمثيل البياني أو متطلبات الموارد.

III.2 التطبيق الأول: تحسين معاملات متحكم PID باستخدام GMO

III.2.1 مقدمة حول التحكم التناسبي التكاملي التفاضلي (PID)

تُعد المتحكمات التناسبية-التكاملية-التفاضلية (PID) من أكثر أدوات التحكم استخدامًا في الأنظمة الصناعية نظرًا لسيطرتها ومرونتها وكفاءتها في التحكم في الأنظمة الديناميكية. تتألف بنية هذا المتحكم من ثلاث معاملات رئيسية: معامل التناسب (Proportional Gain: K_p)، معامل التكامل (Integral Gain: K_i)، ومعامل التفاضل (Derivative Gain: K_d). حيث يُسهم كل منها في تصحيح سلوك النظام استنادًا إلى نوع الخطأ (لحظي، تراكمي، متغير [17] [18]).

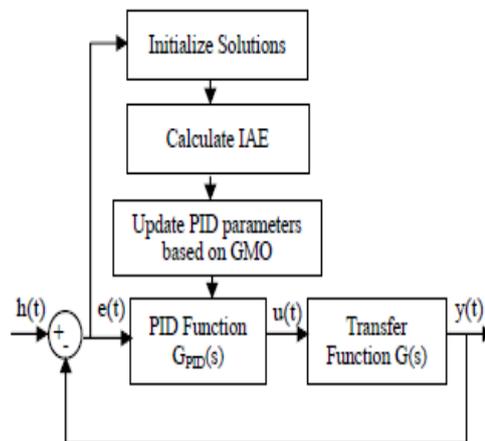
يُعبّر عن استجابة المتحكم PID بالصيغة التالية:

$$u(t) = K_p e(t) + K_i \int_0^t e(t) dt + K_d \frac{d}{dt} e(t)$$

حيث $e(t) = h(t) - y(t)$ ويمثل الفرق بين الإشارة المرجعية $h(t)$ والاستجابة الفعلية $y(t)$. يُستخدم في تقييم جودة الأداء عدد من المؤشرات، أبرزها زمن النهوض، وزمن الاستقرار، والتجاوز. أما من حيث دقة التتبع، فيُعتمد معيار الخطأ المطلق التكاملي (Integral of Absolute Error – IAE) المعرّف بالعلاقة:

$$IAE = \int_0^T |e(t)| dt = \int_0^T |h(t) - y(t)| dt$$

هذه المعايير تجعل من عملية الضبط مهمة دقيقة، خاصةً عند الحاجة إلى تحقيق توازن بين الاستجابة السريعة والاستقرار الديناميكي.



الشكل III.1: الهيكل العام لنظام التحكم المغلق وكيفية ضبط معاملات PID باستخدام خوارزمية GMO

[16]

III.2.2 التحديات في ضبط معاملات PID

- رغم بساطة بنية متحكم PID، إلا أن ضبط معالمه يمثل تحديًا حقيقيًا، خصوصًا في الأنظمة غير الخطية أو التي تتغير خصائصها مع الزمن [17]. ويعود ذلك إلى عدة أسباب جوهرية، منها:
- غياب قاعدة عامة للضبط الأمثل: تختلف القيم المثلى بحسب النظام، ولا توجد صيغة مغلقة تضمن الأداء المثالي في جميع الحالات.
 - الترابط غير الخطي بين المعاملات: تعديل أحد المعاملات يؤثر على أداء النظام بشكل قد يكون غير متوقع.
 - تغير خصائص النظام بمرور الوقت: مثل تغير الحمل أو الظروف البيئية، مما يستدعي إعادة الضبط دوريًا.
 - محدودية الزمن في الأنظمة الحقيقية: تتطلب بعض التطبيقات استجابات سريعة لا تسمح باستخدام طرق ضبط تقليدية بطيئة.
 - تعدد مؤشرات الأداء: مما يصعب تحسينها جميعًا في آن واحد دون مفاضلات معقدة.
- من هنا تظهر الحاجة إلى خوارزميات تحسين ذكية مثل GMO، القادرة على معالجة هذا التعدد في الأهداف والبنية غير الخطية بكفاءة ومرونة [16].

III.2.3 خطوات تطبيق خوارزمية GMO في ضبط معاملات متحكم PID

تقوم خوارزمية المحسّن بالمتوسط الهندسي (GMO) بضبط معاملات متحكم PID وفق منهج تطوري قائم على مبدأ التوجيه الجماعي باستخدام خصائص رياضية مشتقة من المتوسط الهندسي. وتنفذ هذه العملية عبر سلسلة متكاملة من الخطوات، تهدف إلى إيجاد القيم المثلى للمعاملات الثلاثة K_p, K_i, K_d التي تحقق أقل خطأ تحكيمي ممكن، ويُقاس عادة باستخدام معيار IAE [17] [15].

١. تهيئة المجتمع الأولي

في البداية، يتم توليد مجموعة من العوامل (Agents) تمثل حلولاً مرشحة، حيث يتم لكل عامل i تحديد موقعه x_i^0 وسرعته الابتدائية v_i^0 عشوائيًا ضمن حدود دنيا وعليا كما في المعادلتين:

$$x_i^0 = U(x_{min}, x_{max}) \quad (III.1)$$

$$v_i^0 = U(v_{min}, v_{max}) \quad (III.2)$$

٢. تقييم الأداء باستخدام دالة الهدف المعدلة:

يتم تشغيل نموذج النظام لكل عامل باستخدام معايير الخاصة، ويُحسب مؤشر الأداء باستخدام دالة الهدف التالية:

$$IAE = \int_0^{T_{sim}} |y(t) - h(t)| dt \quad (III.3)$$

مع تطبيق عقوبة تلقائية (مثل $IAE = 1000$) لأي عامل يؤدي إلى عدم استقرار النظام، لضمان توجيه الخوارزمية نحو فضاء الحلول المستقر فقط.

٣. حساب دالة العضوية (MF) ومؤشر اللياقة المزدوج (DFI)

تُحسب دالة العضوية MF_i^t لكل عامل باستخدام دالة سينية تعتمد على متوسط وتباين أدائه مقارنة ببقية العوامل وفق الصيغة التالية [15]:

$$MF_i^t = \frac{1}{1 + \exp\left(-\frac{(z_i^{best} - \mu^t)}{\sigma^t \sqrt{2}}\right)} \quad (III.4)$$

μ المتوسط الحسابي لقيم DFI و Fitness

σ الانحراف المعياري للقيم كلما كان أكبر كانت الدالة أبطأ في التغيير

ثم يُحسب مؤشر اللياقة المزدوج DFI لكل عامل i باستخدام المتوسط الهندسي لقيم للعوامل الأخرى:

$$DFI_i^t = \prod_{j=1, j \neq i}^N MF_j^t \quad (III.5)$$

٤. اختيار الحلول الأفضل

يتم ترتيب العوامل بناءً على قيم DFI ترتيبًا تنازليًا، ويتم اختيار نسبة معينة (مثل أفضل 20%) لتُستخدم في المرحلة التالية من التوجيه.

٥. حساب الموضع الموجه الفريد (Guided Position)

حسب موضع جديد لكل عامل اعتمادًا على متوسط موجه مرجح بحسابات DFI للعوامل المختارة [14] [15]:

$$Y_i^t = \frac{\sum_{j \in N_{best} \setminus i} DFI_j^t \cdot X_j^{best}}{\sum_{j \in N_{best}} DFI_j^t + \varepsilon} \quad (III.6)$$

٦. تطبيق الطفرة الموجهة (Guided Mutation)

تُطبق طفرة Gaussian على الموضع الموجه لإضافة تنوع وتجنب التقارب المحلي:

$$Y_{i,mut}^t = Y_i^t + w \cdot randn \cdot (STD_{max} - STD_t) \quad (III.7)$$

حيث:

$randn$ عدد عشوائي من التوزيع الطبيعي.

STD_t الانحراف المعياري الحالي.

w هو معامل الانخفاض التدريجي المحسوب كالتالي:

$$w = 1 - \frac{t}{T_{max}}$$

٧. تحديث الموقع والسرعة لكل عامل

بعد ذلك، يتم تحديث سرعة وموقع كل عامل باستخدام المعادلات التالية:

$$v_i^{t+1} = w \cdot v_i^t + \varphi \cdot (Y_{i,mut}^t - X_i^t) \quad (III.8)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (III.9)$$

حيث:

$$\varphi = 1 + (2 \cdot rand - 1) \cdot w$$

٨. التحقق من شرط التوقف

يُعاد تنفيذ الخطوات من التقييم إلى التحديث حتى يتحقق أحد الشرطين:

• بلوغ الحد الأقصى لعدد التكرارات T_{max}

• أو تحقق شرط التقارب (تغير طفيف في قيمة دالة الهدف).

في النهاية، يُختار العامل الذي يحقق أقل IAE باعتباره أفضل حل، وتُعتمد

القيم المرتبطة به كمعاملات PID المثلث [17] [15] [16].



الشكل 2.III: مراحل تنفيذ خوارزمية GMO لضبط معاملات PID من التهيئة حتى الاستخراج

III.2.4 المميزات النظرية لاستخدام خوارزمية GMO في تحسين PID

تستمد خوارزمية (Geometric Mean Optimizer) GMO فعاليتها في ضبط معاملات متحكم PID

من بنيتها الرياضية المتناسكة وآلية بحثها التكريرية، مما يجعلها ملائمة بشكل خاص لمعالجة مشكلات

التحسين المعقدة وغير الخطية التي تتطلب توازناً دقيقاً بين مؤشرات أداء متعددة..

وتعتمد الخوارزمية على توجيه عملية البحث باستخدام المتوسط الهندسي، إلى جانب استخدام مؤشر

اللياقة المزدوج (DFI) الذي يُمكنها من تقييم جودة وتنوع العوامل داخل المجتمع التطوري، مما يُعزز

من توجه البحث الجماعي نحو مناطق واعدة ضمن فضاء الحلول [15] [14].

وتكمن أهم المميزات النظرية التي تدعم فاعلية خوارزمية GMO في مجال تحسين PID فيما يلي:

• توازن فعال بين الاستكشاف والاستغلال تُحقق GMO توازناً فعالاً بين آليتي الاستكشاف

(البحث عن حلول جديدة) والاستغلال (تحسين الحلول الجيدة)، من خلال اعتمادها على

تقييم متوسط هندسي يعزز التنقل المتزن في فضاء الحلول ويقلل من احتمالية الوقوع في الأمثلية المحلية.

- الحفاظ على تنوع الحلول وتقليل احتمالية الوقوع في الأمثلية المحلية : يساهم استخدام مؤشر DFI في الحفاظ على تنوع الحلول داخل المجتمع التطوري، ما يقلل من احتمالية الانحسار نحو حلول محلية ويُعزز الاستكشاف الفعّال.
- دعم الاستقرار الديناميكي للنظام: تتيح الخوارزمية استبعاد الحلول غير المستقرة تلقائيًا عبر فرض عقوبة على دالة الهدف مثل ($IAE = 1000$)، مما يوجّه البحث نحو حلول تضمن استقرارًا ديناميكيًا مقبولًا طوال فترة التشغيل [16].
- مرونة حسابية عالية: يمكن تعديل مكونات الخوارزمية مثل دالة العضوية وآلية الطفرة بسهولة لتناسب مع طبيعة النظام المستهدف، سواء أكان خطيًا أو غير خطي، مستقرًا أو غير مستقر، سريع الاستجابة أو بطيئًا. هذه المرونة تجعل GMO مناسبة لمجموعة واسعة من التطبيقات.
- الملاءمة للتنفيذ في الأنظمة المدمجة نظرًا لاعتمادها على عمليات حسابية بسيطة وعدم حاجتها إلى اشتقاقات تفاضلية، تُعد GMO ملائمة للتنفيذ على الأنظمة المدمجة (Embedded Systems) ذات الموارد الحسابية المحدودة
- قابلية الدمج مع تقنيات أخرى: تتمتع خوارزمية GMO بقابلية الدمج مع تقنيات تحكم أخرى مثل التحكم التكيفي (Adaptive Control)، الأنظمة الغامضة (Fuzzy Systems)، أو الشبكات العصبية (Neural Networks)، مما يُوسّع من نطاق استخدامها ويُعزز من تكاملها مع حلول الذكاء الاصطناعي الحديثة.

III.2.5 خلاصة:

وبذلك تُعتبر GMO خيارًا نظريًا مثاليًا لضبط متحكمات PID، نظرًا لما توفره من استقرار في الأداء، وكفاءة في الحساب، وقدرة على التكيف، مما يبرّر تصاعد الاهتمام بها في الدراسات الحديثة الخاصة بأنظمة التحكم الذكية.

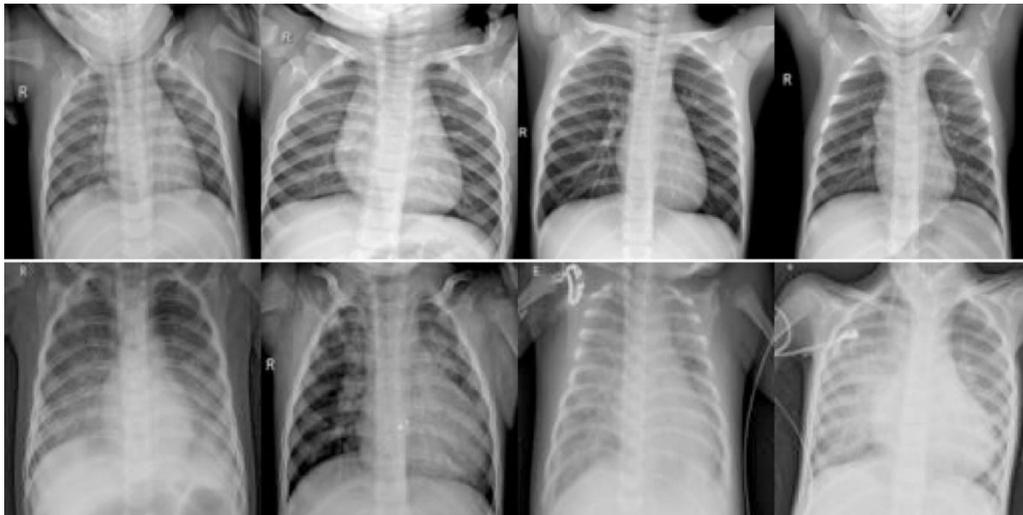
III.3 التطبيق الثاني: تصنيف الالتهاب الرئوي عبر Raspberry Pi باستخدام GMO

III.3.1 المقدمة

يُعدّ الالتهاب الرئوي (Pneumonia) أحد أبرز الأسباب المؤدية إلى الوفيات، خصوصًا في صفوف الأطفال في الدول ذات الدخل المحدود، حيث يشكّل ضعف البنية التحتية الطبية ونقص الكوادر المختصة تحديًا كبيرًا أمام التشخيص المبكر ورغم توافر وسائل علاج فعالة ومنخفضة التكلفة، إلا أنّ غياب التشخيص المبكر لا يزال أحد أبرز العوامل المؤدية إلى تفاقم الحالة الصحية للمريض [19].

في هذا السياق، برزت الأنظمة المعتمدة على الذكاء الاصطناعي، لا سيّما الأنظمة التشخيصية المدعومة بالحاسوب (Computer-Aided Diagnosis - CAD)، كحلّ واعدة يمكن توظيفها لتقديم بدائل تشخيصية دقيقة ومنخفضة الكلفة [20].

وتُعدّ صور الأشعة السينية للصدر (Chest X-rays) أداة تشخيصية شائعة وفعالة للكشف عن الالتهاب الرئوي، إلا أنّ تحليلها البشري يتطلب خبرات دقيقة قد لا تكون متاحة في جميع المراكز الطبية. من هنا، تهدف هذه الدراسة إلى تطوير نظام تشخيص ذكي يعتمد على استخلاص السمات العميقة من الصور باستخدام الشبكات العصبية، متبوعًا بخوارزمية تحسين ذكية لاختيار السمات الأكثر تميزًا، ومن ثم تصنيف الصور بدقة عالية.



الشكل III.3: مقارنة بين صور أشعة لصدر سليم (الصف العلوي) وصدر يعاني من التهاب رئوي (الصف

السفلي) [18]

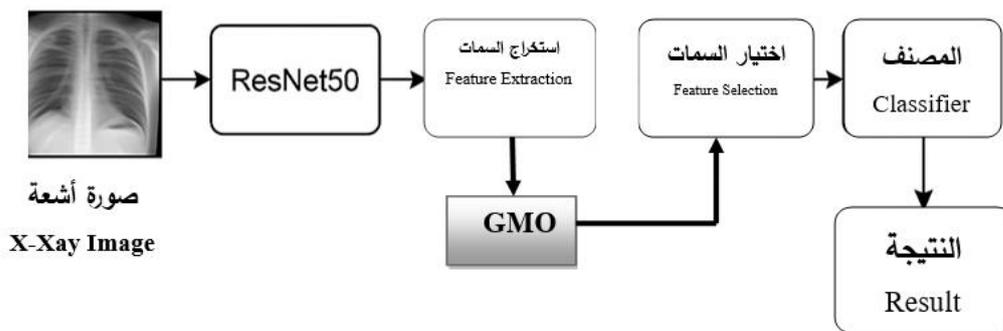
III.3.2 استخلاص السمات العميقة باستخدام نقل التعلم (Transfer Learning)

يمثل نقل التعلم نهجًا فعالًا لتجاوز التحديات المرتبطة بندرة البيانات الطبية المصنفة، وهو ما يُعد عائقًا شائعًا في مجالات التصنيف الطبي. يعتمد هذا النهج على الاستفادة من شبكات عصبية عميقة مُدرّبة مسبقًا على قواعد بيانات ضخمة، مثل ImageNet، ومن ثم إعادة تهيئتها لتلائم مجموعة البيانات المستهدفة. في هذا البحث، تم استخدام الشبكة العصبونية ResNet50، المعروفة ببنيته العميقة المدعومة بالوصلات المتبقية (Residual Connections) التي تعالج مشكلة تلاشي التدرج في الشبكات العميقة [20].

بعد إعادة تدريب النموذج على صور الأشعة الخاصة بحالات الالتهاب الرئوي، تُستخرج السمات من الطبقة قبل النهائية، وهي طبقة Fully Connected ذات تمثيل عددي كثيف، يتكون غالبًا من 512 بعدًا. وتُستخدم هذه السمات كمُدخلات لخوارزمية اختيار السمات، حيث تمثل الخصائص الأساسية التي تستند إليها عملية التنبؤ لاحقًا.

تمثل هذه المرحلة العمود الفقري للنظام، إذ تُحوّل البيانات الصورية غير المنظمة إلى تمثيلات عديدة قابلة للمعالجة والتحسين، ما يمكن النماذج اللاحقة من العمل بكفاءة وفعالية.

في الشكل III.4 يتم استخراج السمات من شبكة ResNet50، ثم تمريرها إلى خوارزمية GMO لاختيار السمات المثلى، يليها التصنيف باستخدام KNN.



الشكل III.4: المخطط العام للنظام المقترح

III.3.3 الشبكة العصبية التلافيفية ResNet50 والاتصال المتبقي (Residual Connection)

تُعدّ شبكة ResNet50 واحدة من أكثر نماذج التعلم العميق استخدامًا وفعالية، حيث طُوّرت من قبل He وآخرين عام 2016 تعتمد هذه الشبكة على مفهوم "الكتل المتبقية" (Residual Blocks)، والتي تتميز بوجود اتصال مباشر يتجاوز بعض طبقات النموذج. يُعرف هذا النوع من الاتصالات بـ

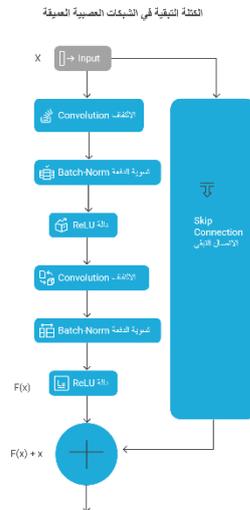
الاتصال المتبقي (Skip Connection)، وهو ما يساعد على معالجة مشكلة (Vanishing Gradient) تلاشي التدرج، الشائعة في الشبكات العميقة [21]. الفكرة الجوهرية وراء الاتصال المتبقي هي السماح بتجاوز بعض الطبقات بحيث يُنقل المخرج مباشرة إلى طبقة لاحقة، مما يسهّل عملية التدريب ويُحافظ على تدفق المعلومات في الشبكة، خصوصًا في الأعماق الكبيرة. تتم معالجة الإشارة داخليًا وفق المعادلتين التاليتين:

$$F(x) = \text{ReLU}(wx + b)$$

$$H(x) = F(x) + x$$

حيث إن x هو الإدخال الأصلي، و w و b يمثلان الوزن والانحياز على التوالي، و $F(x)$ هو الناتج بعد المعالجة التلافيفية، بينما $H(x)$ هو الناتج النهائي بعد إضافة الإشارة الأصلية.

تُظهر الصورة التالية بنية كتلة متبقية نموذجية مستخدمة في شبكة ResNet. تحتوي على طبقات من التلافيف (Convolution)، والتسوية الدفعية (Batch Normalization)، وتنشيط ReLU، والاتصال المتجاوز الذي يعيد دمج المدخلات الأصلية:



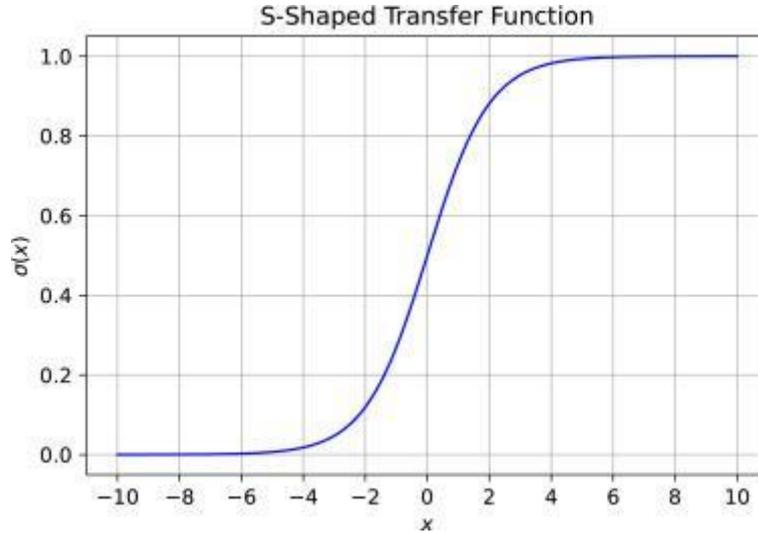
الشكل III.5: بنية نموذجية للكتلة المتبقية في شبكة ResNet50

III.3.4 الدالة الانتقالية ذات الشكل S (Sigmoid Function)

تلعب الدوال الانتقالية دورًا حيويًا في الخوارزميات الميتاهيورستية ثنائية التمثيل، حيث يُفترض تحويل المتجهات ذات القيم الحقيقية إلى تمثيل ثنائي مناسب لتمثيل القرارات، مثل اختيار سمة أو استبعادها. ومن بين أكثر الدوال شيوعًا في هذا السياق، تبرز دالة سيغمويد (Sigmoid)، والتي تُعرف أيضًا باسم الدالة الانتقالية ذات الشكل S، نظرًا لشكلها المنحني المميز [21].

يتم تطبيق هذه الدالة على القيم الناتجة من تحديث المواضع أو السرعات، بهدف إسقاطها ضمن المجال $[0, 1]$ ، مما يتيح بعد ذلك اتخاذ قرار ثنائي باستخدام عتبة عادة 0.5.

يعرض الشكل التالي المنحنى النموذجي لدالة سيغمويد:



الشكل III.6: منحنى الدالة الانتقالية على شكل S [21]

III.3.5 مشكلة ارتفاع الأبعاد والحاجة إلى اختيار السمات

رغم القوة التمثيلية العالية للسمات المستخرجة من الشبكات العصبونية العميقة، إلا أن كثافتها قد تؤدي إلى ما يُعرف بـ "لعنة الأبعاد" (Curse of Dimensionality)، حيث تزداد تعقيدات النموذج، ويرتفع احتمال تضمين معلومات زائدة أو غير مفيدة. لذا، يُعد اختيار السمات خطوة محورية لتقليل الأبعاد، مع التركيز على السمات الأكثر ارتباطاً بالهدف التصنيفي [22].

ويُفضل الاعتماد على خوارزميات ذكية في عملية الاختيار بدلاً من الطرق التقليدية الإحصائية، حيث تسمح الخوارزميات الميتاهيورستية باستكشاف مساحات البحث الكبيرة بطريقة فعالة. فبدلاً من استخدام جميع السمات المستخرجة من ResNet50، والتي يبلغ عددها عادة 512، يتم استخدام خوارزمية تحسين ذكية لتحديد مجموعة فرعية مثالية تمثل جوهر المعلومات المطلوبة للتصنيف، وتقلل من الضجيج أو التكرار.

بالتالي، لا يُعد اختيار السمات مجرد عملية تقليص للحجم، بل هو استراتيجية لتحسين الأداء وتوفير الموارد، خصوصاً إذا كان الهدف هو تنفيذ النموذج على منصة مدمجة بقدرات حسابية محدودة مثل

.Raspberry Pi

III.3.6 خوارزمية Geometric Mean Optimizer (GMO)

خوارزمية Geometric Mean Optimizer (GMO) هي إحدى الخوارزميات الميتاهيورستية الحديثة التي تستلهم آلية عملها من المفهوم الرياضي للمتوسط الهندسي، والذي يُستخدم عادةً لقياس الاتجاه العام لمجموعة من القيم المتعددة في سياقات النمو المتوازن. تستند هذه الخوارزمية إلى فرضية مفادها أن تحديث الحل يمكن أن يتم من خلال تقاربها نحو المتوسط الهندسي لمواقع المجموعة ككل، مما يُحدث توازنًا دقيقًا بين استكشاف فضاء البحث (Exploration) واستغلال أفضل المناطق المعروفة (Exploitation) [14] [15].

وعلى خلاف التطبيق الأول حيث يُمثل الحل متجهًا من القيم المستمرة (Kp, Ki, Kd) ، فإن في هذا التطبيق الثاني، يتم تمثيل الحل كسلسلة ثنائية تشير إلى السمات المختارة، ما يعكس قدرة GMO على التكيف مع طبيعة التمثيل واختلاف بنية فضاء البحث.

في إطار اختيار السمات، يتم ترميز كل حل أو "فرد" في الخوارزمية كسلسلة ثنائية من القيم 0 و 1، حيث تشير القيمة "1" إلى اختيار السمة، و "0" إلى استبعادها. وتتمثل مهمة GMO في تحسين هذه السلاسل بهدف الوصول إلى مجموعة السمات التي تحقق أفضل توازن بين دقة التصنيف وعدد السمات المستخدمة. يتم تحديث موقع كل حل عبر الاعتماد على المتوسط الهندسي لمواقع جميع الأفراد في الجيل الحالي، مع إضافة عنصر اضطراب محدود لضمان التنوع في السكان.

يتم حساب دالة اللياقة (Fitness Function) وفق الصيغة التالية:

$$Fitness = \alpha \times Accuracy + (1 - \alpha) \times \left(1 - \frac{|S_{selected}|}{|S_{total}|}\right) \quad (III.10)$$

حيث:

α هو معامل الوزن (يتراوح عادة بين 0.9 و 0.99)

$|S_{selected}|$ هو عدد السمات المختارة

$|S_{total}|$ هو العدد الكلي للسمات.

تسمح هذه الصيغة بضبط الأولوية بين الحفاظ على دقة التصنيف وتقليل عدد السمات، ما يجعل GMO مناسبة جدًا للأنظمة المدمجة حيث تُعد الموارد الحسابية عاملاً حاسماً.

III.3.7 تكامل خوارزمية GMO مع اختيار السمات المستخرجة من ResNet50

يمثل الدمج بين الشبكات العصبية العميقة وخوارزميات التحسين الذكي توجهاً متقدماً في بناء أنظمة تصنيف قوية وفعالة. ففي هذا العمل، بعد استخراج السمات من الطبقة Fully Connected في شبكة ResNet50، تُمرر إلى خوارزمية GMO التي تعمل على تحديد المجموعة المثلى منها وفقاً لدالة لياقة متوازنة. ويُعاد استخدام هذه المجموعة المختارة فقط في التصنيف، مما يساهم في بناء نموذج أكثر كفاءة من حيث الدقة والوزن الحسابي.

يمكن هذا التكامل من بناء نموذج هجين يتسم بالكفاءة العالية والقدرة على التكيف مع بيانات التنفيذ محدودة الموارد، وهو ما يفتح الباب أمام نشره ضمن نظم ميدانية حقيقية [14] [15].

III.3.8 النظام المدمج ومحاكاة التشغيل باستخدام Raspberry Pi

في إطار الاتجاه نحو حلول ذكية محمولة ومنخفضة الكلفة، باتت الأنظمة المدمجة (Embedded Systems) خياراً مثالياً لتطبيق نماذج الذكاء الاصطناعي في بيئات واقعية ذات موارد محدودة، مثل العيادات الريفية أو وحدات الطوارئ المحمولة. من بين أشهر المنصات التي تُستخدم في هذا السياق تبرز Raspberry Pi، وهي لوحة حوسبة صغيرة الحجم، تدعم أنظمة تشغيل خفيفة مثل Raspbian، وتوفر إمكانيات كافية لتشغيل نماذج تعلم آلي محوِّلة أو مُحسَّنة [24].

وفي هذا البحث، تم تصميم النظام النظري بحيث يكون قابلاً للنشر على Raspberry Pi، وذلك من خلال تقليص أبعاد النموذج عبر خوارزمية GMO، مما يجعل النموذج خفيفاً بما يكفي للتنفيذ ضمن القدرات المحدودة لهذه المنصة. وعلى الرغم من أن التنفيذ الفعلي لم يتم بعد على العتاد الحقيقي، فقد تم تنفيذ محاكاة بيئية افتراضية تحاكي بنية Raspberry Pi بهدف:

- تقدير استهلاك الموارد (CPU/RAM) ،
- قياس وقت الاستجابة،
- التأكد من قدرة النظام على تحميل النموذج وتشغيله بكفاءة.

تمثل هذه الخطوة امتداداً عملياً للنموذج، وتؤكد صلاحيته للتنفيذ الواقعي في أنظمة ذكية قابلة للنشر ميدانياً.

III.3.9 خلاصة التطبيق الثاني

يمثل الإطار المقترح في هذه الدراسة نموذجًا متكاملًا يجمع بين قوة التعلم العميق وفعالية التحسين الذكي، مع مراعاة إمكانية التطبيق العملي في بيئات منخفضة الموارد. وقد تم بناء هذا النموذج على ثلاث مرتكزات أساسية:

١. استخلاص سمات عميقة باستخدام شبكة ResNet50، مما يوفر تمثيلًا غنيًا لصور الأشعة.

٢. اختيار السمات المثلى باستخدام خوارزمية Geometric Mean Optimizer، ما يحقق توازنًا دقيقًا بين الأداء والدقة والحجم.

٣. تصميم النظام للتكامل مع بنى مدمجة مثل Raspberry Pi، مما يتيح إمكانية النشر العملي في تطبيقات الرعاية الصحية الذكية.

تشكل هذه الأسس النظرية قاعدة متينة للانتقال إلى التطبيق العملي، حيث سيتم توضيح مراحل التنفيذ، بدءًا من تجهيز البيانات، ثم بناء النموذج، وصولًا إلى تحليل الأداء. كما ستعرض مقارنة موضوعية بين النموذج المقترح ونماذج أخرى تعتمد على خوارزميات تحسين بديلة مثل PSO، بهدف تقييم فعالية خوارزمية GMO.

III.4 الخلاصة

استعرض هذا الفصل التطبيقات النظرية لخوارزمية المُحسّن بالمتوسط الهندسي (GMO) في سياقات متعددة من الأنظمة الذكية، مبرزاً قدرتها على التكيف مع تحديات التحسين المعقّدة وغير الخطية. شمل ذلك تطبيقين رئيسيين: تحسين ضبط معاملات متحكم PID في أنظمة ديناميكية فيزيائية، وتصنيف صور الأشعة السينية لاكتشاف الالتهاب الرئوي ضمن بيئة مدمجة باستخدام منصة Raspberry Pi.

في التطبيق الأول، يُنّ كيف تتيح بنية GMO الرياضية آلية فعّالة لتحقيق توازن ديناميكي بين الاستكشاف والاستغلال، مما يسهم في الوصول إلى إعدادات PID مثلى دون الحاجة إلى نمذجة تفاضلية معقّدة. أما في التطبيق الثاني، فقد استخدمت خوارزمية GMO لاختيار السمات الأمثل المستخرجة من شبكة ResNet50، ما أدى إلى بناء نموذج تشخيصي خفيف وفعّال ملائم للتنفيذ على أنظمة مدمجة.

وقد أثبتت هذه الدراسة النظرية أن خوارزمية GMO لا تقتصر على تقديم حلول تحسين عددية، بل تمثل إطاراً عاماً يمكن تكيفه مع نماذج ذات طبيعة متباينة في البنية والقيود. كما أظهرت قابليتها العالية للتكامل مع تقنيات الذكاء الاصطناعي الحديثة، بما في ذلك الشبكات العصبونية والأنظمة المدمجة. تمثل هذه النتائج الأساس النظري الذي يُبنى عليه الفصل القادم، حيث سيتم اختبار هذه الفرضيات ضمن بيئات تنفيذ فعلية أو محاكاة واقعية.

الفصل الرابع: الجانب التطبيقي

Practical Implementation

IV.1 القسم الأول تقييم أداء خوارزمية المحسن بالمتوسط الهندسي (GMO)

IV.1.1 المقدمة

في ظل التوسع المتسارع لتطبيقات الذكاء الاصطناعي والأنظمة الذكية، أصبحت خوارزميات التحسين الميتا-استكشافية أداة مركزية لحل المشكلات المعقدة التي يصعب تمثيلها رياضياً أو التعامل معها عبر الأساليب التقليدية. من بين هذه الخوارزميات، يبرز المحسن بالمتوسط الهندسي (Geometric Mean Optimizer - GMO) بوصفه نموذجاً حديثاً يتميز بمرونة عالية في التكيف مع بيانات متنوعة من حيث الطبيعة والدقة الحسابية.

يهدف هذا القسم إلى تقييم الأداء التطبيقي الفعلي لخوارزمية GMO، وذلك من خلال تحليل عددي شامل لاختبار قدراتها على حل مسائل تحسين قياسية، ومقارنتها بخوارزميات تحسين أخرى معروفة وموثقة في الأدبيات. يشمل التقييم عدة جوانب: آلية التنفيذ، منحنيات التقارب، الأداء الإحصائي، والتحليل الحسابي، وذلك بغرض التأكد من مدى فاعلية الخوارزمية، خصوصاً في البيئات التي تتطلب استجابة سريعة وكفاءة عالية.

ويمثل هذا التحليل التطبيقي امتداداً مباشراً للطرح النظري في الفصلين الثاني والثالث، حيث تنتقل الدراسة من بناء الأساس الرياضي وتطبيقاته المفاهيمية، إلى اختبار الخوارزمية ضمن بيئات معيارية، مما يُبرز جدواها في ظروف تنفيذ واقعية.

IV.1.2 آلية التنفيذ العامة لخوارزمية GMO

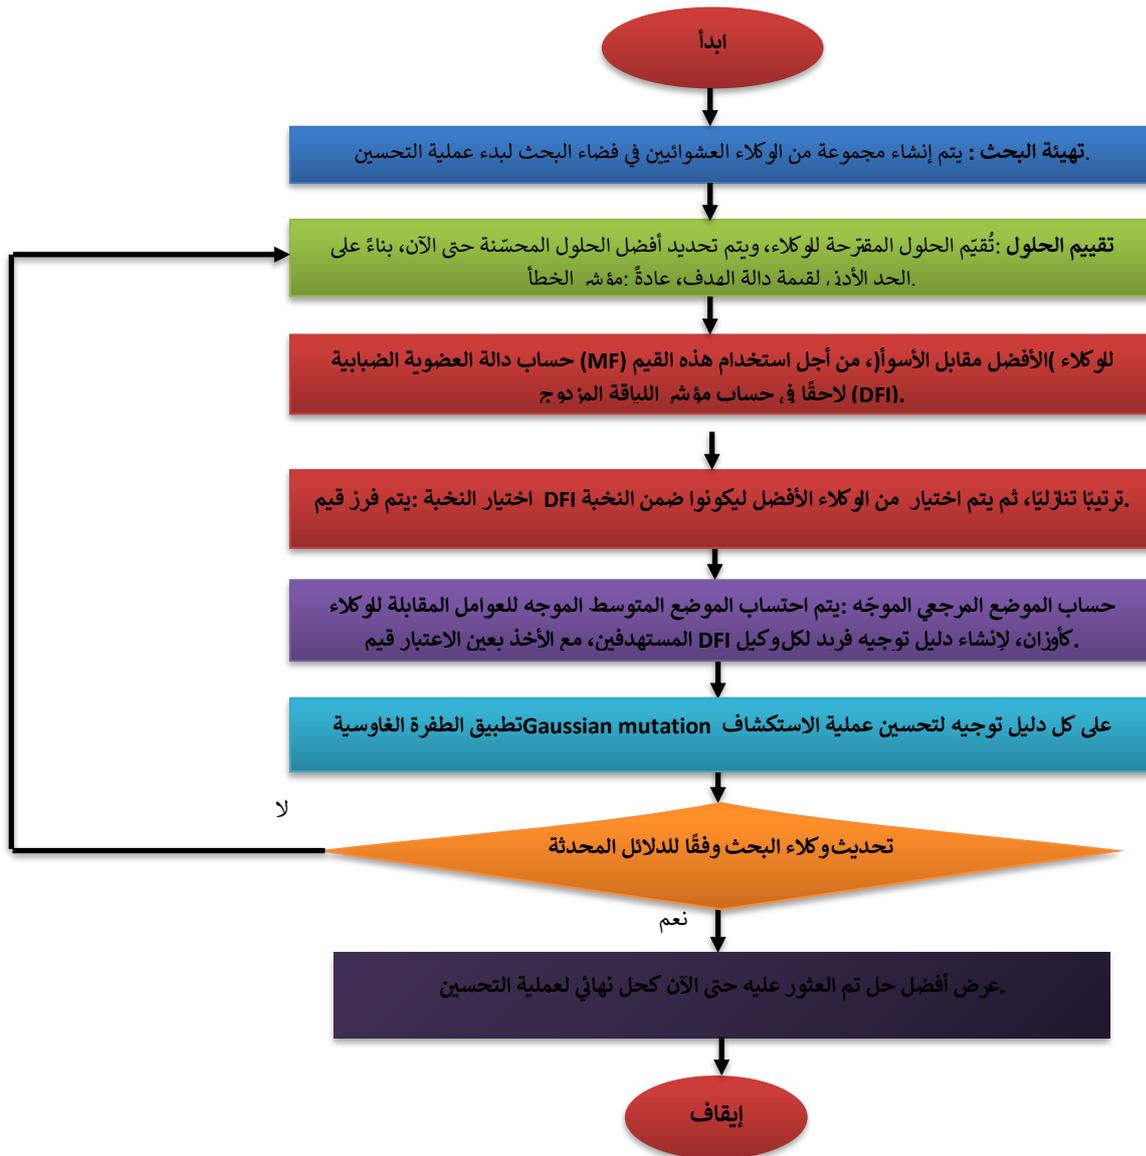
General Execution Mechanism of GMO

تعتمد خوارزمية المحسن بالمتوسط الهندسي (GMO) على مبدأ توجيه عملية البحث نحو الحلول المثلى من خلال آلية حسابية تركز على استخدام المتوسط الهندسي ومؤشر اللياقة المزدوج (DFI)، ما يسمح بتحقيق توازن ديناميكي بين الاستكشاف الواسع لفضاء الحلول والاستغلال المركز للحلول الواعدة.

تبدأ الخوارزمية بتهيئة مجموعة من "الوكلاء" (Agents)، تمثل حلولاً مرشحة موزعة عشوائياً ضمن فضاء البحث. بعد التهيئة، يتم تقييم أداء كل وكيل باستخدام دالة الهدف المناسبة للمشكلة المدروسة، مع احتساب مؤشر DFI الذي يدمج بين الجودة الحسابية للحل وتنوعه داخل المجتمع التطوري. في كل تكرار، يتم اختيار مجموعة نخبوية من الوكلاء ذوي الأداء الأعلى لتكون مصدراً لتوجيه باقي السكان. يُحسب الموضع الجديد لكل وكيل باستخدام متوسط موجّه مستمد من مواقع النخبة، ثم

تُضاف طفرة غاوسية موجهة لضمان التنوع وتجنّب الوقوع في الحلول المحلية. تُكرر هذه الدورة من التقييم، التوجيه، والتحديث حتى يتحقق أحد شرطين: إما بلوغ الحد الأقصى لعدد التكرارات، أو استقرار أداء أفضل حل مكتشف. وتُعد هذه البنية الديناميكية مناسبة للتطبيق في مسائل تحسين متنوعة، سواء كانت مستمرة أو منفصلة، خطية أو غير خطية.

الشكل التالي يوضح تسلسل الخطوات الأساسية التي تتبعها الخوارزمية، ويُستخدم لاحقًا كأساس مشترك لتطبيق الخوارزمية في حالتَي الضبط التكيفي لمتحكم PID وتصنيف الصور الطبية:



الشكل 1.IV: المخطط الانسيابي العام لخوارزمية GMO

IV.1.3 التجارب العددية ومقارنتها

IV.1.3.1 إعداد التجارب (Algorithm Configuration)

لضمان تقييم موضوعي ودقيق لأداء خوارزمية GMO، تم تنفيذ مجموعة من التجارب العددية على دوال اختبار معيارية تستخدم على نطاق واسع في تقييم خوارزميات التحسين. وقد شملت هذه الدوال مجموعة متنوعة من الخصائص، منها: الدوال أحادية القمة (Unimodal)، متعددة القمم (Multimodal)، ودوال ذات أبعاد ثابتة أو متغيرة، مما يضمن تغطية طيف واسع من التحديات.

تم تنفيذ التجارب وفق الإعدادات التالية:

عدد الوكلاء (N): 50 وكيلاً.

عدد التكرارات القصوى (M): 1000 تكرار بالنسبة ل F1 اما (F2-F13) فقد تم اختيار 2000 تكرار، اما الدوال متعددة القمم ذات الأبعاد الثابتة (F14–F23)، حيث تم تقليص عدد التكرارات إلى 500 تم توضيح نتائج ذلك في الملحق .

عدد التجارب المستقلة: 30 تجربة لكل دالة اختبار

مؤشرات التقييم: تم الاعتماد على المتوسط الحسابي (Mean) والانحراف المعياري (Std) لقيم دالة الهدف كمعايير إحصائية للأداء.

ولتحقيق مقارنة عادلة، تم تطبيق نفس إعدادات التنفيذ على مجموعة من خوارزميات التحسين المرجعية، وهي:

- خوارزمية صقور هاريس (Harris Hawks Optimization – HHO)
- خوارزمية التحسين الحسابي (Arithmetic Optimization Algorithm – AOA)
- خوارزمية أكويدا (Aquila Optimizer – AO)
- خوارزمية المعتمدة على التدرج (Gradient-Based Optimizer – GBO)
- خوارزمية اتجاه التدفق (Flow Direction Algorithm – FDA)
- خوارزمية التوازن (Equilibrium Optimizer – EO)

تم اعتماد الإعدادات الأصلية لكل خوارزمية كما وردت في مصادرها العلمية، بينما تميزت خوارزمية GMO بأنها لا تتطلب أي معلمات خارجية للضبط، مما يُعد نقطة قوة مهمة من حيث سهولة التطبيق والموثوقية في الاستخدام.

جدول 4 : إعدادات معلمات GMO والخوارزميات المنافسة له

إعدادات المعلمات	الخوارزمية
لا توجد معلمات تحتاج إلى ضبط	HHO
$\alpha = 5; \mu = 0.5$	AOA
$r_1 \in [1, 20]; U = 0.00565; D_1 = D; \omega = 0.005; \alpha = \delta = 0.1; G_2 = [2, 0];$ عدد الأبعاد = D	AO
$\beta_{min} = 0.2; \beta_{max} = 1.2; pr = 0.5$	GBO
$\beta = 1$	FDA
$\alpha_1 = 2; \alpha_2 = 1; GP = 0.5$	EO
لا توجد معلمات تحتاج إلى ضبط	GMO

IV.1.3.2 مقارنة بنيوية وأدائية بين خوارزمية GMO وخوارزمية PSO

لتحليل أداء خوارزمية GMO ضمن سياق أوسع، من المفيد إجراء مقارنة بنيوية مع إحدى أشهر خوارزميات التحسين الميتا-استكشافية، وهي خوارزمية تحسين السرب الجزيئي (Particle Swarm Optimization - PSO)، التي تُعد معيارًا مرجعيًا في هذا المجال.

IV.1.3.2.1 آلية العمل في PSO

تعتمد خوارزمية تحسين السرب الجزيئي (Particle Swarm Optimization – PSO) على محاكاة السلوك الجماعي للطيور أو الأسماك أثناء البحث عن الغذاء، حيث يتعاون الأفراد ضمن سرب للتنقل في فضاء البحث استنادًا إلى التجارب الفردية والجماعية.

في هذه الخوارزمية، يتم تمثيل كل جسيم i ضمن فضاء بحث مكون من D ، أبعاد، ويُعبّر عن حالته من خلال متجهين:

موضع الجسيم:

$$X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$$

سرعة الجسيم:

$$V_i = (V_{i1}, V_{i2}, \dots, V_{iD})$$

كما يُسجل كل جسيم أفضل موقع شخصي وصل إليه خلال عملية البحث، ويُعبّر عنه بالمتجه ويمثل:

أفضل موقع شخصي (Pbest):

$$Pbest_i^t = (p_{i1}, p_{i2}, \dots, p_{iD})$$

أما أفضل موقع عالمي تم التوصل إليه من قبل جميع الجسيمات حتى لحظة التكرار t فيُعبر عنه بالمتجه:

أفضل موقع عام (Gbest):

$$Gbest^t = (p_{g1}, p_{g2}, \dots, p_{gD})$$

تُحدّث سرعة وموضع كل جسيم في كل تكرار باستخدام المعادلتين:

• معادلة تحديث السرعة:

$$V_i^{t+1} = wV_i^t + c_1r_1(Pbest_i^t - X_i^t) + c_2r_2(Gbest^t - X_i^t)$$

• معادلة تحديث الموضع:

$$X_i^{t+1} = X_i^t + V_i^{t+1}$$

حيث:

- $i \in \{1, 2, \dots, N\}$ حيث N هو حجم المجتمع.
- t هو عدد التكرارات الحالي.
- w هو وزن القصور الذاتي.
- r_1 و r_2 هما متجهان عشوائيان في النطاق 0 و 1.
- c_1 و c_2 هما معاملان يمكن ضبطهما وتعيينهما عادة الى 2.

تقوم الخوارزمية بتحديث الجسيمات وفقاً لهذه المبادئ:

- يساهم Pbest في الحفاظ على تنوع الجسيمات واستكشاف مناطق جديدة.
- يوجّه Gbest السرب نحو مناطق ذات أداء أعلى (استغلال).

IV.1.3.2.2 الاختلافات الرئيسية مع GMO

رغم أن كلا من PSO و GMO تنتمي إلى فئة خوارزميات التحسين الميتا-استكشافية، فإن لكل منهما آلية توجيه مختلفة، وبنية رياضية تُنتج سلوكاً مميزاً في التعامل مع مشكلات التحسين المعقّدة.

تعتمد PSO على توجيه مزدوج يُبنى على أفضل موقع شخصي لكل جسيم (Pbest) وأفضل موقع جماعي عالمي (Gbest)، دون أي اعتبار مباشر لتنوع المجتمع أو آلية طفرة مرافقة. في المقابل، تعتمد GMO على توجيه موحد مستند إلى نخبة الوكلاء باستخدام المتوسط الهندسي، بالإضافة إلى إدماج مؤشر لياقة مركب يُعرف باسم DFI (مؤشر اللياقة المزدوج)، والذي يأخذ في الاعتبار كلاً من جودة الحل وتنوعه.

كما تعتمد GMO على إدخال طفرة غاوسية موجهة في مرحلة التحديث لضمان الحفاظ على التنوع ومنع الانحصر المبكر في الحلول المحلية، وهو ما تقتصر إليه PSO في صيغتها الكلاسيكية. الجدول التالي يوضح الفروقات الجوهرية بين الخوارزميتين:

جدول 5: مقارنة بين PSO و GMO

الفرق الجوهرية	GMO	PSO	البند
تكامل بين الأداء الفردي وتنوع المجتمع	موحد: مؤشر DFI	منفصل: Gbest و Pbest	تقييم اللياقة
تبسيط التوجيه وزيادة كفاءته	موحدة (استناداً إلى نخبة الحلول باستخدام DFI)	مزدوجة (شخصي + جماعي)	آلية التوجيه
تحسين الاستكشاف وكسر التماثل	موجودة: طفرة غاوسية موجهة	غير موجودة	الطفرة
بساطة في التنفيذ وسهولة التهيئة	لا حاجة لضبط معاملات خارجية	أكثر من 4 (w, c1, c2, r1, r2)	عدد المعاملات
حفظ أفضل الحلول باستمرار	مدمجة عبر استخدام نخبة الوكلاء	غير مدمجة	النخبوية
استقرار الأداء عبر مختلف التطبيقات	منخفض للغاية (لا يتطلب معايرة)	مرتفع (يتطلب معايرة دقيقة للثوابت)	الاعتماد على المعلمات

يتضح من المقارنة أن GMO تتميز ببنية رياضية أبسط وأكثر مرونة، مما يمنحها مزايا ملحوظة في التطبيقات التي تتطلب كفاءة عالية، أو تلك التي تعمل في بيئات محدودة الموارد، مثل الأنظمة المدمجة أو الزمن الحقيقي.

IV.1.4 تحليل منحنيات التقارب (Convergence Analysis)

يُعد تحليل منحنيات التقارب أحد أهم أدوات تقييم كفاءة خوارزميات التحسين، إذ يُظهر كيفية تطور أداء الخوارزمية عبر التكرارات، ويكشف عن مدى قدرتها على الاقتراب من الحلول المثلى في الوقت المناسب. في هذا القسم، تم تحليل سلوك خوارزمية GMO مقارنةً بعدة خوارزميات منافسة عبر دوال معيارية تمثل فئات مختلفة من مشاكل التحسين.

IV.1.4.1 منحنى التقارب: الدالة F1 (Sphere Function)

هي دالة أحادية القمة، تُستخدم لاختبار سرعة التقارب نحو القيمة المثلى.

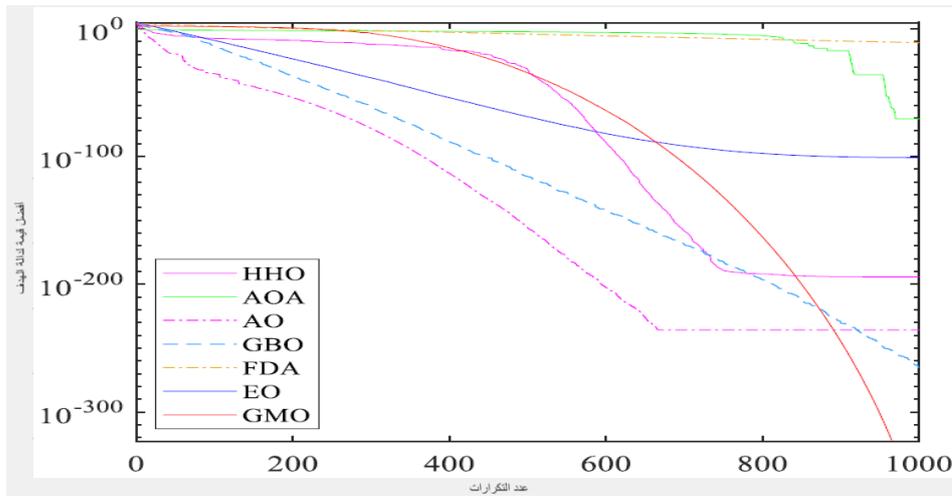
في الشكل المخصص للدالة F1 الشكل IV.1 ، يُلاحظ أن خوارزمية **GMO** (المنحنى الأصفر) أظهرت أفضل أداء من حيث السرعة والدقة. حيث انخفضت قيمة الهدف بشكل حاد ومستمر لتصل إلى القيم المثلى في أقل من 950 تكرار.

بينما:

أظهرت **HHO** و **GBO** و **AO** أداءً مقبولاً، إلا أنهما توقفتا عن التحسين بعد مرحلة معينة.

حافظت **GBO** على تقارب تدريجي دون بلوغ مستوى أداء **GMO**.

كانت **FDA** و **AOA** و **EO** الأضعف أداءً، حيث لم تقترب من الحل الأمثل بشكل فعال.



الشكل IV.2: منحنى التقارب لخوارزميات متعددة عند تطبيقها على الدالة F1

استنتاج: تُظهر خوارزمية **GMO** قدرة عالية على الاستغلال المبكر، بفضل استخدامها الفعال لمؤشرات التوجيه المركبة وآلية التحديث الديناميكي.

IV.1.4.2 منحنى التقارب: الدالة (Rastrigin Function) F2

هي دالة متعددة القمم، تحتوي على العديد من الحلول المحلية، وتُعد اختباراً صعباً للقدرة على الهروب من الحلول غير المثلى.

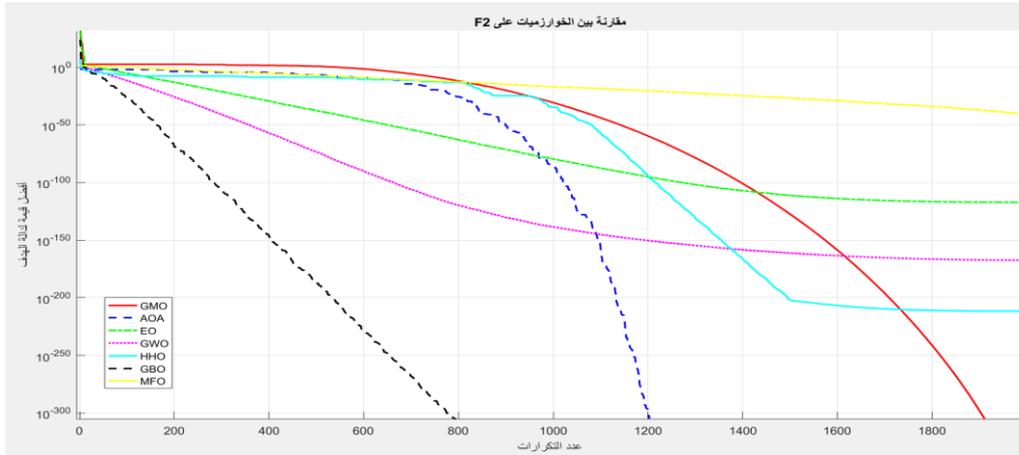
أظهرت **GMO** أداءً متميزاً مرة أخرى، حيث تجاوزت بقية الخوارزميات في الوصول إلى قيمة الهدف المثلى رغم تضاريس الدالة المعقدة.

AOA أظهرت تحسناً سريعاً في البداية لكنها توقفت مبكراً.

تقاربت **HHO** و **GBO** تدريجياً دون منافسة فعالة.

أظهرت **EO** و **GWO** تباطؤاً ملحوظاً.

MFO لم تحقق تقدماً يُذكر.



الشكل 3.IV: منحنى التقارب لخوارزميات متعددة عند تطبيقها على الدالة F2

الاستنتاج: يعكس أداء GMO قدرتها على مقاومة الانحسار في الحلول المحلية، ما يجعلها مناسبة للمشكلات ذات الطبيعة المعقدة والمتعددة القمم.

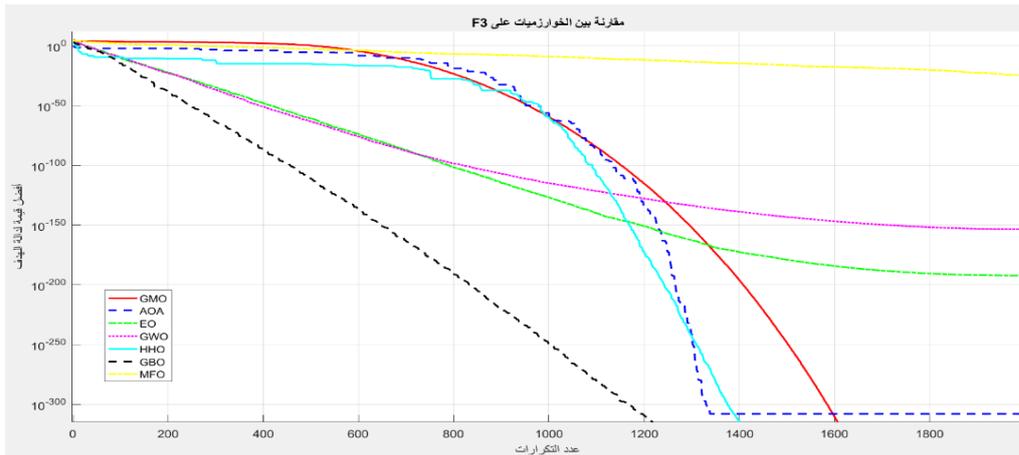
IV.1.4.3 منحنى التقارب: الدالة (Zakharov Function) F3

هي دالة اختبار سلسلة ذات بنية واضحة، تُستخدم لقياس توازن الخوارزمية بين سرعة التقارب والدقة النهائية. حافظت GMO على أداء ريادي، حيث اقتربت بسرعة من الحل المثالي واستقرت دون تقلبات ملحوظة. بينما:

أظهرت GBO وAOA تحسناً تدريجياً لكنه أبطأ.

سجلت HHO وEO أداءً أضعف.

لم تُظهر MFO أي تقدم ملموس.



الشكل 4.IV: منحنى التقارب لخوارزميات متعددة عند تطبيقها على الدالة F3

الاستنتاج: يُبرز هذا الأداء قدرة GMO على الانتقال السلس من مرحلة الاستكشاف إلى الاستغلال، مما يعزز كفاءتها في الدوال ذات الطبيعة المستمرة والمتوازنة.

IV.1.4.4 ملخص تحليل المنحنيات

يتضح من تحليل الدوال الثلاث أن خوارزمية GMO تتفوق في ثلاث جوانب رئيسية:

١. السرعة في الوصول إلى قيم هدف منخفضة.

٢. الدقة في التقارب النهائي نحو القيمة المثلى.

٣. الاستقرار وعدم وجود تذبذب في المسار الحسابي.

وهذه الخصائص تجعلها مناسبة بشكل خاص للتطبيقات التي تتطلب استجابة آنية أو تُنفذ في بيئات ذات قدرة حسابية محدودة.

IV.1.5 تحليل التعقيد الحسابي

يمثل تحليل التعقيد الحسابي جانباً أساسياً في تقييم أداء خوارزميات التحسين، خاصةً في التطبيقات التي تتطلب كفاءة عددية وموارد محدودة، مثل الأنظمة المدمجة أو بيئات الزمن الحقيقي. في هذا السياق، يُقدم هذا القسم تحليلاً دقيقاً لتعقيد خوارزمية GMO من حيث الكلفة العددية المرتبطة بالعمليات الأساسية التي تُنفذ خلال كل تكرار.

تعتمد خوارزمية GMO على أربع عمليات رئيسية، يمكن التعبير عن تعقيدها كما يلي:

١. تقييمات اللياقة (Fitness Evaluations)

لكل تكرار يتم فيه حساب لياقة N وكيلاً.

◊ التعقيد الحسابي لتقييمات اللياقة هو:

$$O(M \times N)$$

٢. آلية فرز الحلول النخبوية (Sorting Mechanism of the Elite Solutions)

◊ التعقيد الحسابي لكل من آلية الفرز للحلول النخبوية وآلية حساب الحلول الإرشادية هو:

$$O(M \times N^2)$$

٣. آلية حساب الحلول الإرشادية (Guide Solution Computation Mechanism)

◊ أما التعقيد الحسابي لعملية تحديث الحلول فهو:

$$O(M \times N \times D)$$

٤. إجراء تحديث الحلول (Updating Procedure of the Solutions)

وبناءً على ذلك، فإن التعقيد الحسابي العام لخوارزمية GMO يمكن صياغته على النحو التالي:

$$O(M \times N \times (N + D))$$

◊ حيث أن:

- M يمثل العدد الأقصى من التكرارات.
 - N هو عدد وكلاء البحث.
 - D هو عدد متغيرات القرار (أبعاد المسألة) في مسألة التحسين.
- ورغم أن هذه العمليات مركّبة، إلا أن خوارزمية GMO تظهر كفاءة عددية مقارنة بخوارزميات مماثلة بفضل ضبطها الداخلي وعدم حاجتها إلى معلمات خارجية.

IV.1.6 خلاصة القسم الأول

أظهرت نتائج التقييم العددي أن خوارزمية GMO تحقق أداءً متفوقاً من حيث سرعة التقارب، الدقة، والاستقرار، مقارنةً بخوارزميات تحسين معروفة. كما بيّن تحليل التعقيد الحسابي أن الخوارزمية تحتفظ بكفاءة عددية مناسبة بفضل بنيتها البسيطة وعدم حاجتها إلى ضبط معلمات خارجية. تعزز هذه النتائج من موثوقية GMO كخيار فعال للتحسين في البيئات الواقعية، وهو ما سيتم التحقق منه في الأقسام التطبيقية التالية.

IV.2 القسم الثاني التطبيقات الواقعية

IV.2.1 التطبيق الأول ضبط متحكم PID لمحرك تيار مستمر باستخدام GMO

PID Tuning for a DC Motor Using GMO

IV.2.1.1 المقدمة

بعد أن تم في الفصل السابق استعراض الجوانب النظرية لمتحكم PID وخوارزمية المتوسط الهندسي (GMO)، يتناول هذا الفصل الجانب العملي من الدراسة، حيث يتم تطبيق خوارزمية GMO لضبط معاملات متحكم PID بهدف تحسين أداء نظام التحكم في سرعة محرك تيار مستمر. يعتمد هذا التطبيق على نموذج رياضي دقيق للمحرك، ويتم من خلاله استخدام خوارزمية GMO لتوليف المعاملات الثلاثية المثلى $[K_p, K_i, K_d]$ باستخدام دالة الهدف IAE كمؤشر لتقييم جودة الاستجابة. يشمل الفصل عرضاً للنموذج الرياضي للمحرك، وهيكلية متحكم PID المستخدمة، ثم توضيح خطوات تنفيذ خوارزمية GMO، متبوعة بتحليل نتائج المحاكاة وتقييم الأداء الزمني والترددي للنظام بعد الضبط. كما يُختتم الفصل بمقارنة بين خوارزمية GMO وعدد من الخوارزميات التطويرية الأخرى، بهدف إبراز كفاءة الخوارزمية المقترحة في تحسين جودة التحكم واستجابة النظام.

IV.2.1.2 النموذج الرياضي لمحرك التيار المستمر

Mathematical Model of the DC Motor

يعتمد النموذج الديناميكي لمحرك التيار المستمر على توصيف دقيق للجانبين الكهربائي والميكانيكي للمحرك. ويمكن تمثيل سلوك المحرك بمعادلتين تفاضليتين رئيسيتين كما يلي:

IV.2.1.2.1 المعادلة الكهربائية: Electrical Equation

تعبر عن العلاقة بين الجهد الداخل إلى المحرك والتيار المار في ملفات العضو الثابت والسرعة الزاوية للعضو الدوار:

$$L_a \frac{di(t)}{dt} + R_a i(t) = u(t) - K_b \omega(t)$$

IV.2.1.2.2 المعادلة الميكانيكية: Mechanical Equation

تعبر عن العلاقة بين العزم الناتج عن التيار وبين حركة العضو الدوار المتأثرة بالعزم المقاوم والقصور الذاتي:

$$J \frac{d\omega(t)}{dt} + D\omega(t) = K_i i(t)$$

حيث أن الثوابت المادية للمحرك هي:

$$\begin{aligned}
 R_a &= 0.4 \Omega \\
 L_a &= 2.7 H \\
 J &= 4.0 \times 10^{-4} \text{ kg} \cdot \text{m}^2 \\
 D &= 2.2 \times 10^{-3} \text{ N} \cdot \text{m} \cdot \text{s/rad} \\
 K &= 1.5 \times 10^{-2} \text{ N} \cdot \text{m/A} \\
 K_b &= 5.0 \times 10^{-2} \text{ V} \cdot \text{s/rad}
 \end{aligned}$$

بعد دمج المعادلتين وتحويل النظام إلى مجال لابلاس، نحصل على دالة التحويل التي تمثل العلاقة بين دخل الجهد $U(s)$ الخرج المطلوب وهو السرعة الزاوية $\Omega(s)$:

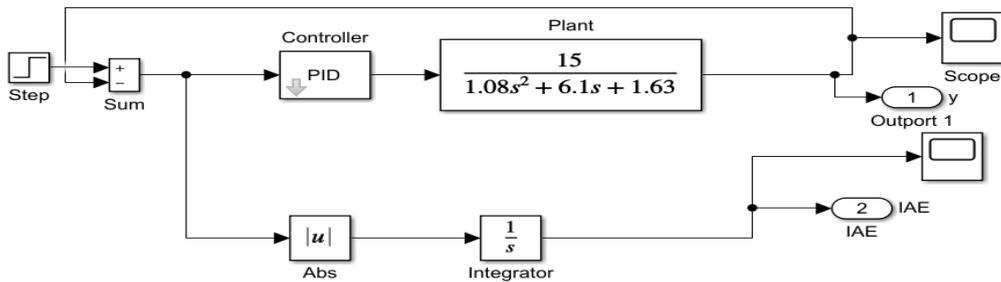
$$G(s) = \frac{\Omega(s)}{U(s)} = \frac{K}{JL_a s^2 + (R_a J + L_a D)s + (R_a D + K K_b)}$$

وبالتعويض بالقيم العددية، تصبح دالة التحويل على الشكل التالي:

$$G(s) = \frac{0.015}{0.00108s^2 + 0.0061s + 0.00163}$$

وتمثل هذه الدالة الأساس الذي يُبنى عليه تحليل النظام وتصميم المتحكم.

dc motor PID gains, Kp, Ki, and Kd.



الشكل 5.IV: تصميم المتحكم

IV.2.1.3 متحكم PID ودالة الهدف IAE

PID Controller and IAE Objective Function

تم اعتماد دالة الهدف IAE كما وردت في القسم النظري (الفصل الثالث)، لتقييم استجابة النظام المغلق بعد ضبط معاملات المتحكم PID.

IV.2.1.4 تطبيق خوارزمية GMO لضبط متحكم PID

Implementation of the GMO Algorithm for PID Tuning

طبقت خوارزمية GMO لضبط معاملات متحكم PID باستخدام مجتمع أولي من الحلول يعبر عن كل فرد بثلاثية $[K_p, K_i, K_d]$ وتم تقييم كل حل باستخدام معيار IAE السابق. استخدمت الخوارزمية آلياتها التطورية لاختيار وتحسين الحلول بمرور الأجيال، بهدف الوصول إلى أفضل استجابة للنظام.

فيما يلي تفاصيل إعدادات التنفيذ والمعلمات المستخدمة في التجربة.

جدول 6: تفاصيل إعدادات التنفيذ

القيمة	المعامل
$N = 100$	حجم المجتمع (Population Size)
$T = 100$	عدد الأجيال (Iterations)
$0 \leq K_p, K_i, K_d \leq 20, K_{p,i,d}^{min} = 0, K_{p,i,d}^{max} = 20$	حدود البحث للمعاملات
$T_{sim} = 5$ ثوان	زمن المحاكاة لكل تقييم

تم تحديد هذه القيم التجريبية لضمان استقرار النظام وتحقيق أداء أمثل ضمن الزمن المحدد للمحاكاة.

IV.2.1.5 تحليل نتائج المحاكاة

Simulation Results Analysis

بعد تنفيذ خوارزمية GMO وفق الإعدادات المبينة سابقاً، تم الحصول على القيم المثلى لمعاملات متحكم PID لمحرك التيار المستمر كما يلي:

$$K_p \approx 19.8114, K_i \approx 5.4078, K_d \approx 3.4773$$

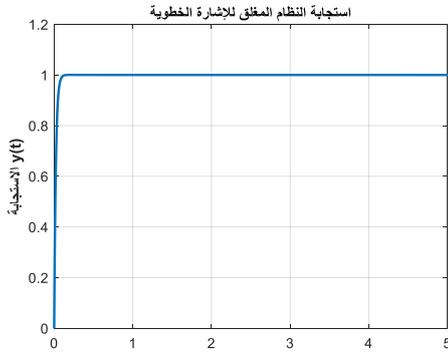
تم استخدام هذه القيم لتوليد استجابة النظام المغلق، ومقارنتها بالاستجابة الأصلية للنظام بدون تحكم (الدائرة المفتوحة). وقد أظهرت النتائج تحسناً كبيراً في خصائص الأداء الزمني.

IV.2.1.5.1 الاستجابة الخطوية (Step Response)

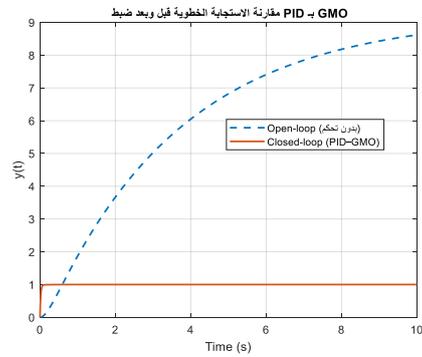
جدول 7: نتائج التجربة قبل وبعد GMO

المؤشر	قبل الضبط	بعد الضبط ب GMO
زمن النهوض (Rise Time)	7.8 ثانية	0.045376 ثانية
زمن الاستقرار (Settling Time)	14.1 ثانية	0 ثانية
نسبة التجاوز (Overshoot)	0%	0.041374
الخطأ في الحالة المستقرة	ملحوظ	شبه معدوم
قيمة IAE	—	0.021109

تُظهر استجابة النظام المكافئ في (الشكل IV.6) قدرة المتحكم على الوصول السريع والثابت إلى القيمة المطلوبة، مما يؤكد جودة الضبط ودقة اختيار ثوابت PID.



الشكل 6.IV: استجابة النظام المكافئ

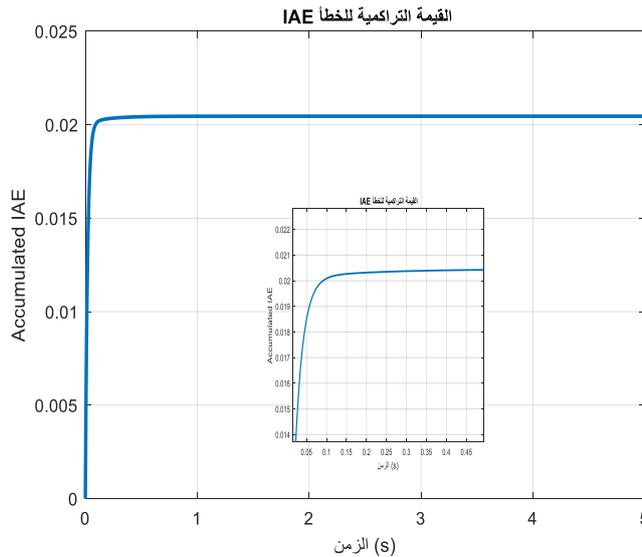


الشكل 7.IV : مقارنة الاستجابة الخطية قبل وبعد

IV.2.1.5.2 تحليل مؤشر الخطأ التراكمي IAE

IAE Accumulated Error Analysis

يبدأ منحني $IAE(t)$ بالارتفاع خلال الثواني الأولى من الاستجابة، ثم يستقر تدريجياً عند قيمة تقريبية 0.0204 بحلول 0.5 ثانية و يشير ثبات القيمة بعد تلك النقطة إلى انتهاء مرحلة التكيف ودخول النظام في حالة تعقب دقيق للإشارة المرجعية. يُعتبر المستوى المنخفض والثابت لمؤشر IAE دليلاً على كفاءة المتحكم في تقليل كل من الخطأ اللحظي والتراكمي، مما يعكس استقراراً ديناميكياً عالياً للنظام.



الشكل 8.IV : القيمة التراكمية لخطأ IAE

IV.2.1.5.3 التحليل الإحصائي (Box Plot)

Statistical Analysis (Box Plot)

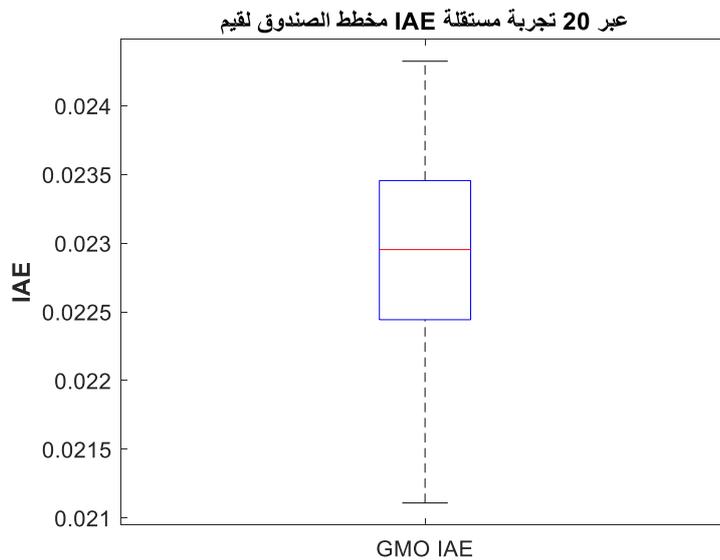
يُوضح الشكل IV.9 التحليل الإحصائي لقيم مؤشر الخطأ التراكمي IAE عبر 20 تجربة مستقلة لخوارزمية GMO، باستخدام مخطط الصندوق (Box Plot). يبيّن هذا المخطط معلومات مهمة عن توزيع البيانات، تشمل الوسيط، وحدود الربعين الأول والثالث، والقيم القصوى، بالإضافة إلى عدم وجود أية قيم شاذة واضحة (outliers).

الوسيط (Median) يقع تقريباً عند القيمة 0.023، وهو مؤشر على مركز التوزيع.

المدى بين الربعين (IQR) صغير نسبياً، مما يدل على انخفاض تشتت النتائج واتساق الأداء بين التجارب.

أطراف الصندوق (whiskers) تمتد من حوالي 0.0212 إلى 0.0245، وهي حدود ضيقة تعكس استقرار الخوارزمية وعدم وجود تقلبات كبيرة في الأداء.

هذا التوزيع المنتظم والمضغوط لمؤشر IAE يدل على أن خوارزمية GMO ليست فقط دقيقة في تحقيق نتائج منخفضة للخطأ، بل إنها موثوقة ومتسقة في الأداء عبر تكرارات متعددة، وهو عامل مهم في تطبيقات الضبط التلقائي في الأنظمة المدمجة.



الشكل 9.IV: مخطط Box Plot للقيم التراكمية لـ IAE عبر 20 تجربة مستقلة

IV.2.1.5.4 التحليل الترددي مخططات بود

Frequency Analysis (Bode Plots)

يعرض الشكل IV.10 منحنيات بود (Bode Plots) للاستجابة الترددية للنظام المغلق بعد ضبط متحكم PID باستخدام خوارزمية **GMO** يظهر التحليل النقاط التالية:

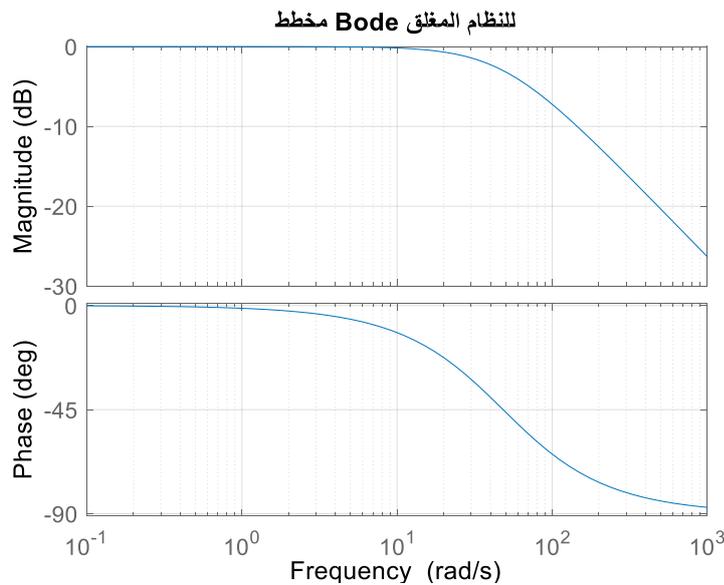
عند الترددات المنخفضة (أقل من 1 rad/s)، يكون الكسب قريباً من 0 dB، وزاوية الطور تقترب من 0°، مما يشير إلى قدرة النظام على تثبيت المدخل المرجعي بدقة عالية.

نقطة عرض الحزمة (-3 dB Bandwidth) تظهر عند تردد يقارب 40 rad/s، وهو مؤشر على الاستجابة السريعة للنظام، ويُفسر زمن الصعود القصير الملحوظ في النتائج الزمنية.

هامش الطور (Phase Margin) يُقدّر بحوالي 60° عند تقاطع خط الكسب 0 dB، مما يشير إلى متانة ديناميكية جيدة للنظام أمام اضطرابات الطور أو التأخيرات الزمنية.

هامش الكسب (Gain Margin) يُعد كبيراً أو غير محدود ضمن نطاق الترددات المعروضة، وهو ما يُشير إلى استقرار مرتفع للنظام عبر مدى واسع من الترددات.

تُظهر هذه النتائج أن متحكم PID المضبوط باستخدام **GMO** لا يحقق فقط أداءً زمنياً ممتازاً، بل أيضاً استجابة ترددية مستقرة، مما يعزز موثوقية النظام وتحمله للتشويش وتغيرات الحمل.



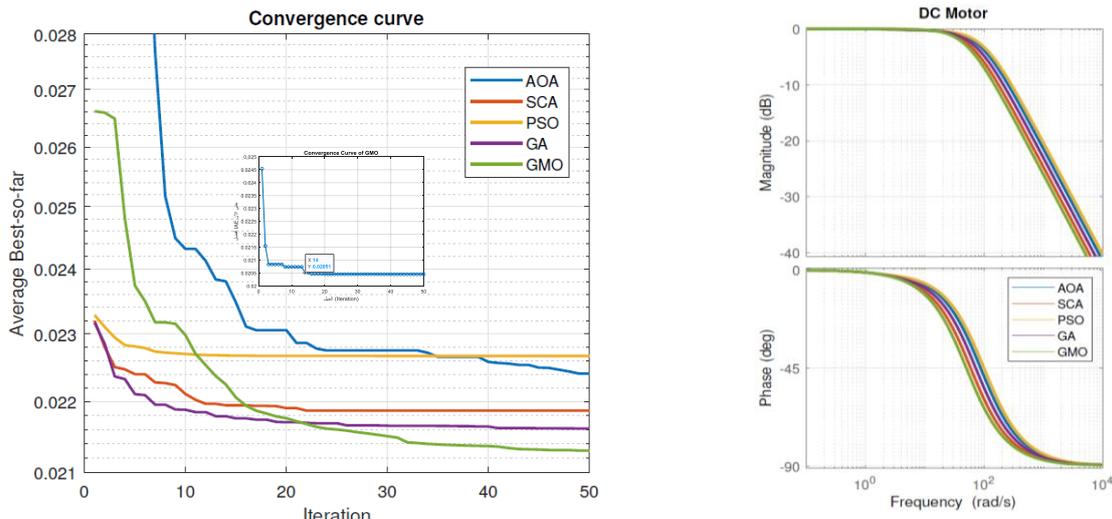
الشكل IV.10: منحنى بود

IV.2.1.6 مقارنة الأداء مع خوارزميات أخرى

Performance Comparison with Other Algorithms

يعرض الشكلين كلا من منحنيات التقارب و التحليل الترددي - تحليل بود (Bode Analysis) باستخدام خمس خوارزميات تطويرية لضبط معاملات متحكم PID، وهي: GA، AOA، PSO، و.GMO.

وضّح المنحنى تطور أفضل قيمة لمؤشر الأداء IAE عبر الأجيال (Iterations)



الشكل IV.11: التحليل الترددي - تحليل بود

الشكل IV.12: منحنى التقارب

IV.2.1.6.1 تحليل منحنيات التقارب

Convergence Curves Analysis

❖ خوارزمية GMO انخفضت قيمة IAE بسرعة منذ الجيل الأول، ووصلت إلى (≈0.02051)

عند الجيل 14

❖ خوارزمية GA حققت متوسط (Best-so-far ≈0.0215)، ببطء طفيف عن GMO

❖ خوارزمية SCA استقرت عند (≈0.0218)، متفوقة على AOA و PSO

❖ خوارزمية PSO استقرت مبكراً عند (≈0.0223) بدون انخفاض إضافي بعد الجيل 10

❖ خوارزمية AOA أباطاً الجميع، استقرت عند (≈ 0.0227)

IV.2.1.6.2 التحليل الترددي - بود

Frequency Analysis – Bode Plot

أجري تحليل بود للمتحكم المغلق ومقارنته بنتائج الخوارزميات الأربعة الأخرى، كما في الشكل IV.11 تظهر النتائج ما يلي:

عرض الحزمة الترددية (Bandwidth) : أعلى قيمة لـ GMO ، حيث يبدأ تراجع الكسب (-3 dB) عند تردد أكبر، ما يحسن تتبع الإشارات السريعة

هامش الطور (Phase Margin) : ($\approx 60^\circ$) لـ GMO ، يضمن متانة أمام التشويش.

هامش الكسب : كبير جداً لـ GMO ، ما يزيد من استقرار النظام.

مقارنة سلوكية : GA و SCA و PSO أظهروا انحداراً أقوى عند الترددات المنخفضة، لكن تقلص عرض الحزمة كان أضيق مقارنةً بـ GMO

IV.2.1.7 الجدول المقارن للمعاملات والمؤشرات

Comparative Table of Parameters and Performance Metrics

جدول 8: جدول المقارنة

الانحراف المعياري	أسوأ IAE	متوسط IAE	أفضل IAE	التجاوز %	زمن الاستقرار (ثانية)	زمن الصعود (ثانية)	IAE	Kd	Ki	Kp	الخوارزمية
0.000701	0.02366	0.02240	0.021144	0%	0.12994	0.02826	0.021144	6.1300	5.3350	19.988	AOA
0.000559	0.02358	0.02266	0.021833	0%	0.16404	0.02489	0.021833	7.0011	5.1890	19.583	PSO
0.000703	0.02344	0.02161	0.020840	0%	0.09311	0.03348	0.020840	5.0980	5.3333	20.000	GA
1.9893e-05	0.02052	0.02048	0.020453	0%	0.07966	0.04419	0.020453	3.5936	5.3402	20.000	GMO

IV.2.1.8 الاستنتاجات Conclusions

أظهرت خوارزمية GMO أداءً متميزاً في ضبط معاملات متحكم PID لمحرك تيار مستمر، حيث حققت أدنى قيمة لمؤشر الخطأ المطلق التراكمي ($IAE \approx 0.020453$) مع تشتت منخفض جداً ($\sigma \approx 1.9893e-05$)، ما يدل على دقة وموثوقية عالية في الأداء.

كما سجّلت الخوارزمية أقصر زمن استقرار (≈ 0.0797 ثانية)، مما يعكس سرعة الوصول إلى الحالة المستقرة. وعلى الرغم من أن خوارزمية PSO حققت زمن صعود أسرع (≈ 0.0249 ثانية)، إلا أنها أظهرت تذبذباً أكبر في النتائج عبر التكرارات.

تجدر الإشارة إلى أن جميع الخوارزميات المقارنة حافظت على تجاوز صفري تقريباً (\approx Overshoot 0%)، مما يؤكد فعالية منهجيات الضبط التحسيني المعتمدة، مع أفضلية واضحة لصالح GMO من حيث التوازن بين الدقة، الثبات، وسرعة الاستجابة.

IV.2.2 التطبيق الثاني اكتشاف الالتهاب الرئوي باستخدام خوارزمية GMO

IV.2.2.1 المقدمة

في هذا الجزء التطبيقي، نعرض نظامًا ذكيًا لتشخيص الالتهاب الرئوي من صور أشعة الصدر (Chest X-rays - CXR)، يجمع بين تقنيات التعلم العميق وخوارزميات التحسين الذكية. يعتمد النموذج المقترح على ثلاث مراحل رئيسية:

- ❖ استخلاص السمات: باستخدام الشبكة العصبية التلافيفية ResNet50 المدربة مسبقًا.
- ❖ اختيار السمات المثلى: عبر خوارزمية المحسن بالمتوسط الهندسي (GMO).
- ❖ تصنيف الصور: باستخدام مصنف نهائي ملائم للأجهزة الطرفية.

يهدف هذا الإطار إلى تحقيق دقة عالية وزمن استجابة منخفض، ما يؤهله للعمل في بيئات ذات موارد محدودة—كالمستشفيات الريفية أو العيادات المتنقلة—بدون الاعتماد على خوادم قوية أو اتصال دائم بالإنترنت.

صُمم النظام ليتوافق مع منصات منخفضة التكلفة مثل Raspberry Pi، ل يتيح الدعم التشخيصي الفوري في المواقع النائية. وتشمل مؤشرات الأداء التي اعتمدها في التقييم: الدقة (Accuracy)، الاستدعاء (Recall)، المعيار التوافقي (F1-score) ومساحة تحت منحنى ROC. مع تحليل تقارب الخوارزمية واستقرار نتائجها عبر تجارب متعددة.

IV.2.2.2 إعداد البيانات ومعالجة الصور

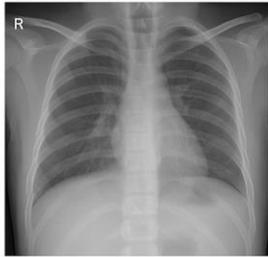
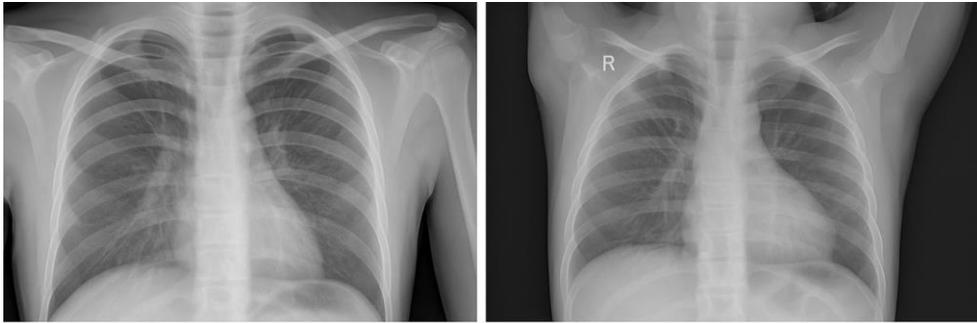
Data Preparation and Image Preprocessing

تم اعتماد مجموعة بيانات عامة من منصة Kaggle، تتضمن 5,836 صورًا شعاعية لصدر أطفال (CXR) مصنفة سريريًا إلى حالتين: "سليم" (Normal) و"مصاب بالالتهاب الرئوي" (Pneumonia) فُسِّمت الصور كالتالي:

- 4,273 صورة لتدريب النموذج (Training Set)
- 585 صورة للتحقق من الصحة (Validation Set)
- 978 صورة للاختبار (Test Set)

قبل إدخال الصور إلى ResNet50، تم تطبيق مجموعة من تقنيات المعالجة المسبقة لتحسين جودة البيانات وتقليل الضوضاء، وذلك وفق الخطوات التالية:

- التحويل إلى التدرج الرمادي (Grayscale) لتقليل عدد القنوات وتقليص التعقيد الحسابي دون التأثير على السمات الطبية البصرية الأساسية.
- إعادة تحجيم الصور إلى أبعاد قياسية (224×224 بكسل) طبقاً لمتطلبات الشبكة.
- تطبيع القيم البكسلية إلى المجال [0,1] عبر قسمة كل قيمة بكسل على 255، ما أسهم في تسريع التدريب وتحسين ثبات النموذج.
- تعزيز البيانات (Data Augmentation) باستخدام التدوير العشوائي (Random Rotation) والانزياح الأفقي (Horizontal Shift)، مما يزيد من تنوع العينات ويعزز قدرة النموذج على التعميم خارج بيانات التدريب.



Grayscale



Resize

الشكل 13.IV: نموذج من صور الأشعة الأصلية وصورها بعد المعالجة المسبقة

هذه الخطوة التحضيرية في المعالجة تُمكن من نشر النموذج على أجهزة مثل Raspberry Pi التي لا تحتوي على وحدات معالجة رسومية قوية، حيث تكون الصور الموحدة والمصغرة والمبسطة مناسبة للمعالجة السريعة على معالجات منخفضة الأداء دون المساس بجودة التشخيص

IV.2.2.3 استخراج المميزات باستخدام الشبكات العصبية الالتفافية CNN

Deep Feature Extraction Using Convolutional Neural Networks (CNNs)

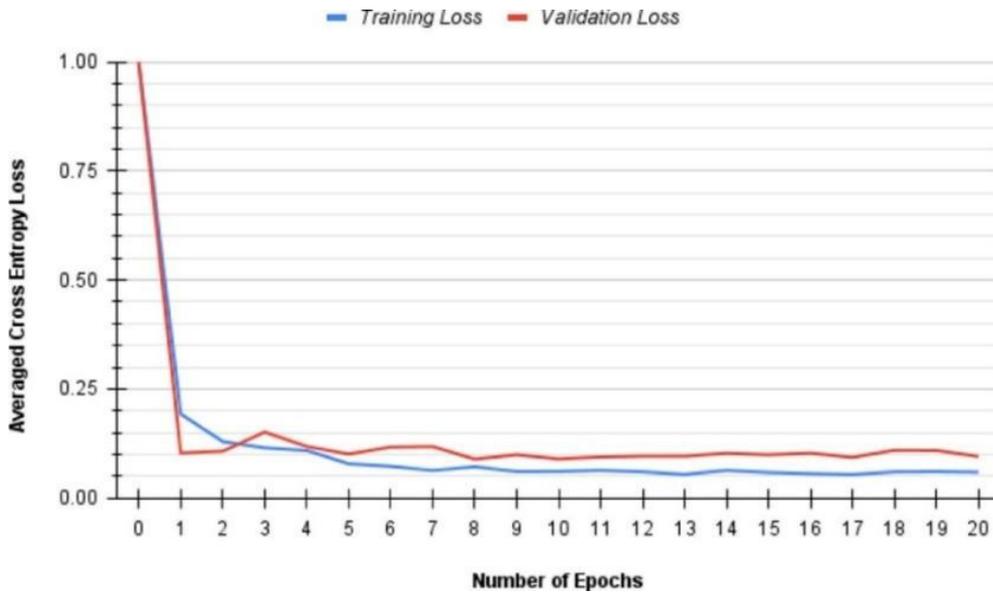
بهدف تحويل صور الأشعة السينية إلى تمثيلات عددية قابلة للمعالجة بواسطة خوارزميات التعلم الآلي، تم اعتماد تقنية استخلاص السمات العميقة (Deep Feature Extraction) باستخدام شبكات عصبية تلافيفية مدربة مسبقاً (Pretrained CNNs).

تمت مقارنة نموذجين شهيرين في الأدبيات:

IV.2.2.3.1 نموذج ResNet50

تُعد ResNet 50 شبكة عصبية تلافيفية عميقة تعتمد على الوصلات المتبقية (Residual Connections)، والتي تُساهم بشكل فعّال في استقرار عملية التعلم داخل الطبقات العميقة عبر تسهيل تدفق المعلومات وتخفيف مشكلة تلاشي التدرج.

في هذا السياق، تم إزالة الطبقة التصنيفية النهائية من النموذج، واعتماد طبقة Global Average Pooling لاستخراج شعاع سمات (Feature Vector) مكون من 2048 بعدًا لكل صورة شعاعية. يتميز هذا التمثيل العددي بقدرته العالية على التجريد واستخلاص الأنماط البصرية المعقدة في صور أشعة الصدر (CXR)، مع الحفاظ على حجم مضغوط مناسب يسمح بعمليات المعالجة اللاحقة بكفاءة عالية، خصوصًا في البيئات ذات الموارد المحدودة.



الشكل 14.IV: منحنيات خسارة التدريب والتحقق لموديل ResNet 50

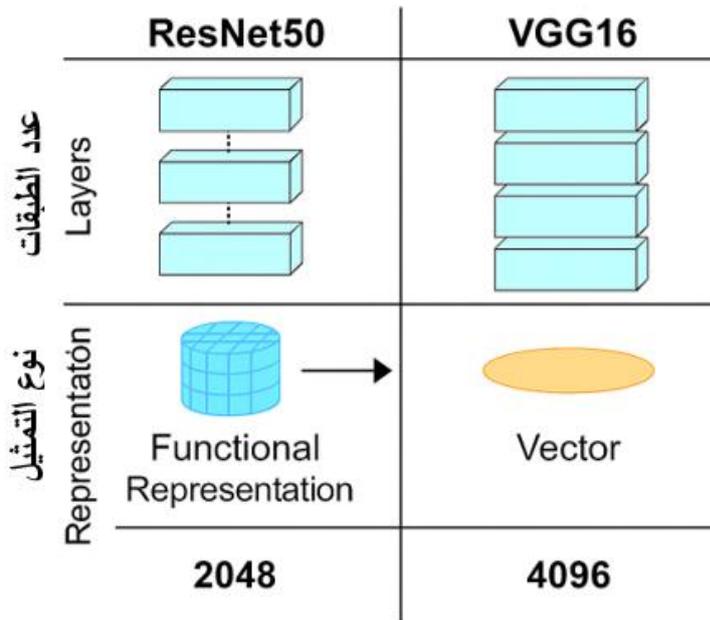
IV.2.2.3.2 نموذج VGG16

نموذج كلاسيكي يعتمد على تسلسل ثابت من طبقات الالتفاف والتجميع. تم استخراج السمات من الطبقة fully connected الأولى (fc1) لإنتاج شعاع بعدد 4096 بُعدًا. ورغم غنى التمثيل، إلا أن هذا الحجم الكبير يُعد مرهقًا من حيث الحسابات، خاصة في البيئات محدودة الموارد.

IV.2.2.3.3 المقارنة واختيار النموذج النهائي

أظهرت التجارب أن سمات ResNet50:

- أكثر استقرارًا وأقل تشتتًا بعد مرحلة اختيار السمات بـ GMO
 - أقل تعقيدًا من حيث عدد الأبعاد، ما يُقلل زمن المعالجة بشكل واضح.
 - أكثر ملاءمة للنشر على أجهزة مثل Raspberry Pi مقارنة بـ VGG16.
- بناءً عليه، تم اعتماد ResNet50 كنموذج أساسي لاستخلاص السمات في هذا التطبيق.



الشكل IV.15: مقارنة بنيوية بين ResNet 50 و VGG16 من حيث عدد الطبقات، نوع التمثيل، وعدد الأبعاد الناتجة

IV.2.2.4 اختيار المميزات باستخدام خوارزمية GMO

Feature Selection Using Geometric Mean Optimizer (GMO)

بعد استخراج التمثيل العددي للصور عبر شبكة ResNet50، تم تطبيق خوارزمية المحسن بالمتوسط الهندسي (GMO) باستخدام نسخة محسنة من الخوارزمية، طُبقت ضمن إطار تحقق متقاطع من نوع 5-Fold Cross-Validation لضمان استقرار الأداء وموثوقيته كل طية خضعت للمعالجة التالية:

- تحجيم السمات باستخدام StandardScaler.
- تنفيذ خوارزمية GMO على مجموعة التدريب فقط، باستخدام الانحدار اللوجستي كمصنف لتقييم اللياقة.

- تمثيل كل حل (Agent) كسلسلة ثنائية بطول (2048 عدد السمات الأصلية)، حيث يشير "1" إلى اختيار السمة و"0" إلى إقصائها.

- تم استخدام 20 عاملاً (Agents) و30 تكراراً (Generations) لكل طية.

احتساب دالة هدف تجمع بين الدقة وتقليص عدد السمات، وفق الصيغة:

$$j = \alpha(1 - Accuracy) + \beta \left(\frac{Number\ of\ Selected\ Features}{Total\ Features} \right)$$

حيث أن:

- $\alpha = 0.9$ (لتركيز أعلى على الدقة)

- $\beta = 0.1$ (لتقليل عدد السمات)

النتائج المتحصل عليها:

جدول 9: عدد السمات المختارة بعد تطبيق خوارزمية GMO عبر الطيات الخمس (5-Fold Cross Validation)

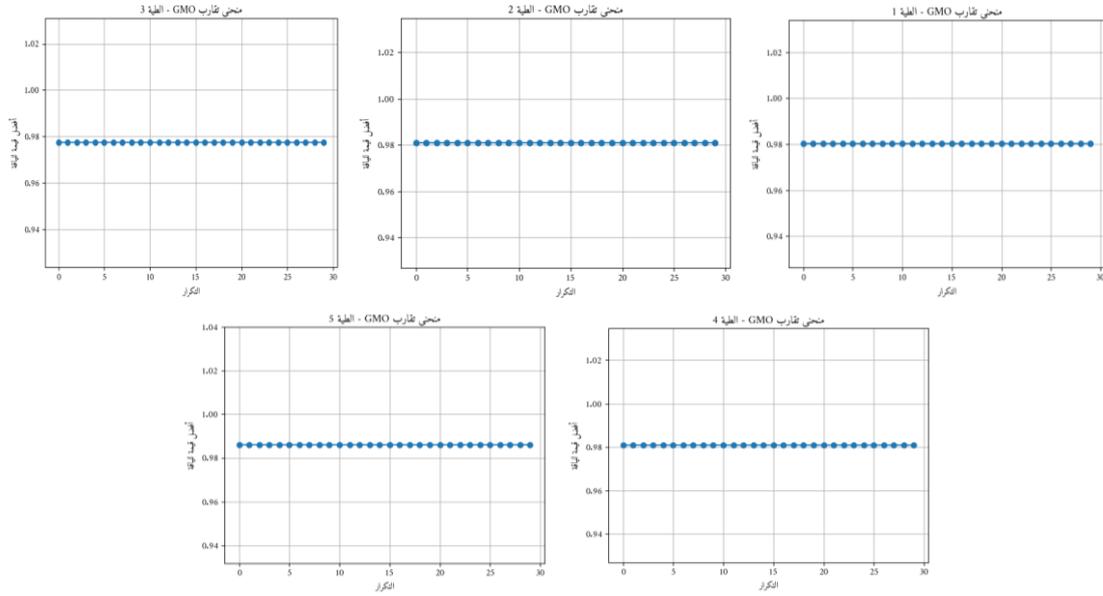
Fold	عدد السمات الأصلية	عدد السمات المختارة	نسبة الاختيار
1	2048	258	12.60%
2	2048	290	14.16%
3	2048	294	14.36%
4	2048	293	14.31%
5	2048	293	14.31%

متوسط الدقة (Accuracy): 94.88%

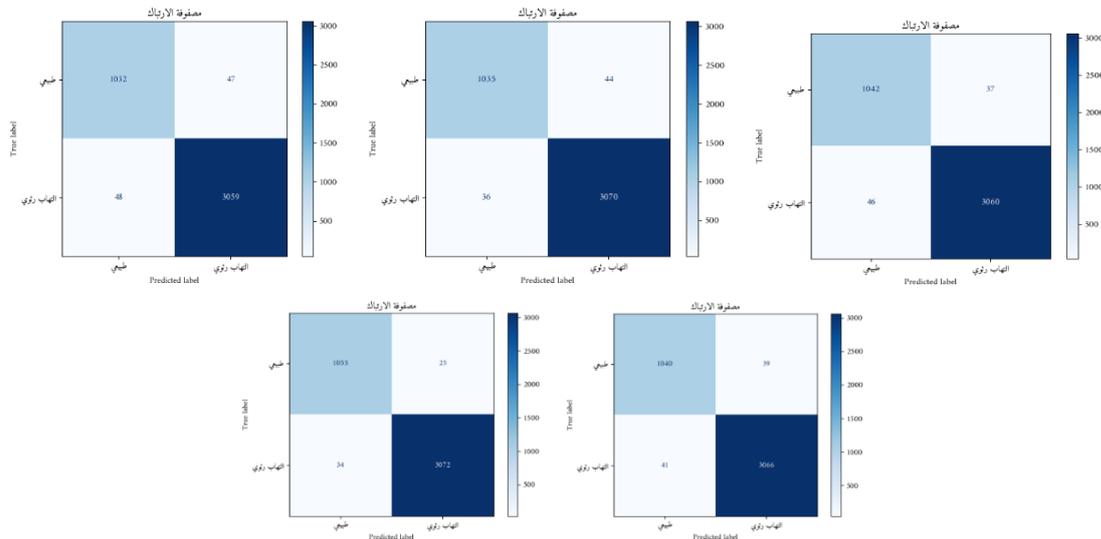
الانحراف المعياري: ±0.57

يُلاحظ أن خوارزمية GMO نجحت في تقليص عدد السمات بنسبة كبيرة تجاوزت 86%، مع الحفاظ على أداء تصنيفي قوي ومستقر، وهو ما يعزز جدوى استخدامها في تطبيقات تتطلب كفاءة حسابية عالية.

كما تُظهر جميع المنحنيات الخمسة (من الطية 1 إلى الطية 5) تظهر سلوكاً شبه متطابق ومستقرًا منذ أولى التكرارات، حيث تستقر القيمة المثلى بسرعة وتبقى ثابتة عبر التكرار.



الشكل 16.IV: منحنيات تقارب خوارزمية GMO عبر الطيات الخمس



الشكل 17.IV: مصفوفات الالتباس للمصنف Logistic Regression بعد اختيار السمات (الطيات 1 إلى 5)

IV.2.2.5 مقارنة المصنفات بعد اختيار السمات باستخدام GMO

بعد تقليص الأبعاد بواسطة خوارزمية (Geometric Mean Optimizer (GMO)، تم تقييم أداء أربع مصنفات كلاسيكية لتحديد الأنسب للاستخدام العملي على منصات منخفضة الموارد (مثل Raspberry Pi).

تم اختبار المصنفات التالية:

- K-Nearest Neighbors (K=5)
- Support Vector Machine (SVM)
- Naive Bayes (Gaussian)
- Logistic Regression

IV.2.2.5.1 النتائج الرقمية للأداء التصنيفي

الجدول التالي يوضح نتائج المصنفات من حيث الدقة (Accuracy)، الاسترجاع (Recall)، المعيار التوافقي (F1-Score)، ومعامل ROC-AUC، إلى جانب عدد الأخطاء التصنيفية:

جدول 10: نتائج الأداء التصنيفي للمصنفات بعد اختيار السمات بواسطة خوارزمية GMO

عدد الأخطاء	ROC-AUC	F1-Score	recall	precision	Accuracy	المصنف classifier
58	0.982654	0.962581	0.960103	0.965071	0.944604	الانحدار اللوجستي Logistic Regression
67	0.979341	0.956802	0.954955	0.958656	0.936008	SVM الخطي
147	0.925337	0.898830	0.840411	0.965976	0.859599	Naive Bayes (Gaussian)
80	0.970034	0.947781	0.934363	0.961589	0.923591	KNN (k=5)

لكن الأداء التصنيفي وحده ليس كافيًا لتحديد المصنف الأنسب في السياق التطبيقي. لذلك تم تحليل استهلاك الزمن (Training & Inference) لكل مصنف بهدف تقييم ملاءمته للأجهزة ذات الموارد المحدودة.

جدول 11: تحليل استهلاك الزمن للمصنفات بعد اختيار السمات بواسطة خوارزمية GMO

inference_time_per_Sample (s) زمن الاستدلال لكل عينة (ثانية)	inference_time_total (s) زمن الاستدلال الكلي (ثانية)	Training Time (s) زمن التدريب (ثانية)	المصنف classifier
0.000005	0.00517	3.233	الانحدار اللوجستي Logistic Regression
0.000294	0.30802	13.100	SVM الخطي
0.000027	0.02842	0.06151	Naive Bayes (Gaussian)
0.008015	8.39144	0.01387	KNN (k=5)

IV.2.2.5.2 تحليل النتائج والتمثيل البياني للمقارنة بين المصنفات

بعد تقييم الأداء الرقمي والزمني للمصنفات الأربعة (Logistic Regression, SVM, KNN, Naive Bayes)، أظهرت النتائج أن:

Logistic Regression حقق توازنًا مثاليًا بين الأداء والدقة مع أقل عدد من الأخطاء.

Naive Bayes رغم دقته النوعية العالية (Precision)، إلا أنه سجل أضعف أداء شامل

KNN قدّم دقة مقبولة، لكن زمن الاستدلال العالي يجعله غير عملي للأجهزة محدودة الموارد.

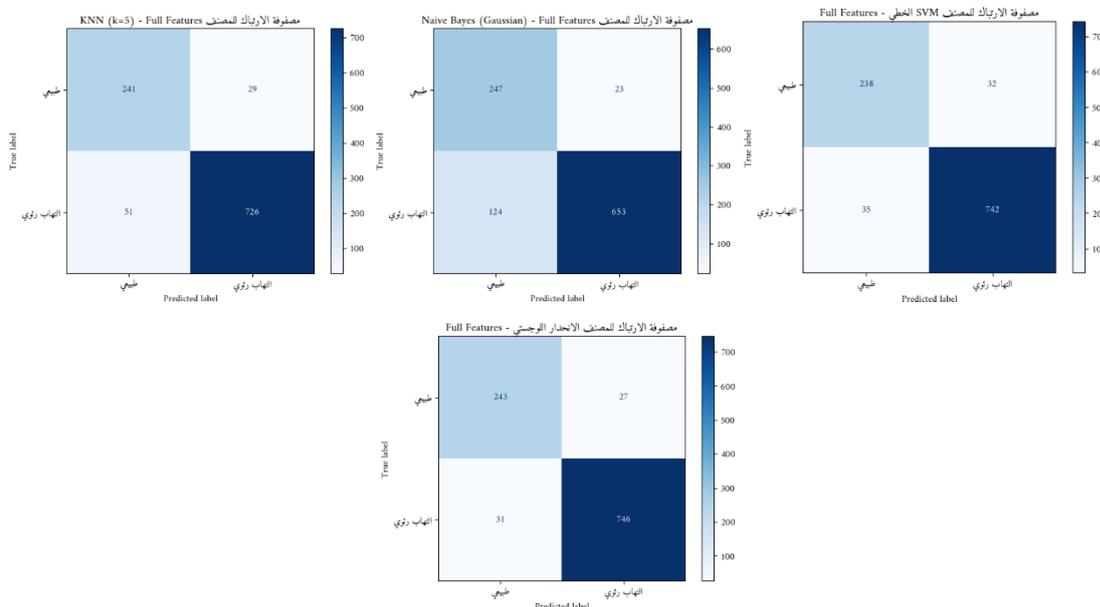
SVM كان قويًا من ناحية الأداء، لكنه استهلك وقتًا أطول في التدريب والاستدلال.

IV.2.2.5.2.1 التمثيل البياني

تم تدعيم التحليل أعلاه باستخدام ثلاث وسائل بصرية رئيسية:

أولاً – مصفوفات الالتباس (Confusion Matrices):

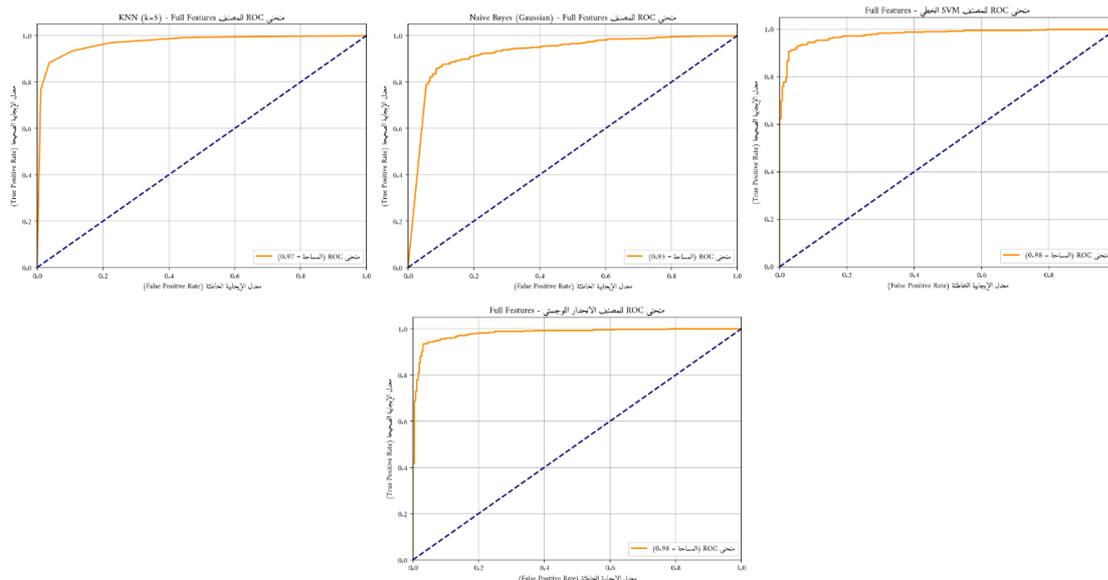
توضح فعالية النموذج في التمييز بين الفئتين وعدد العينات المصنفة بشكل صحيح وخاطئ.



الشكل 18.IV: مصفوفات الالتباس Confusion Matrices للمصنفات

ثانياً – منحنيات ROC (Receiver Operating Characteristic):

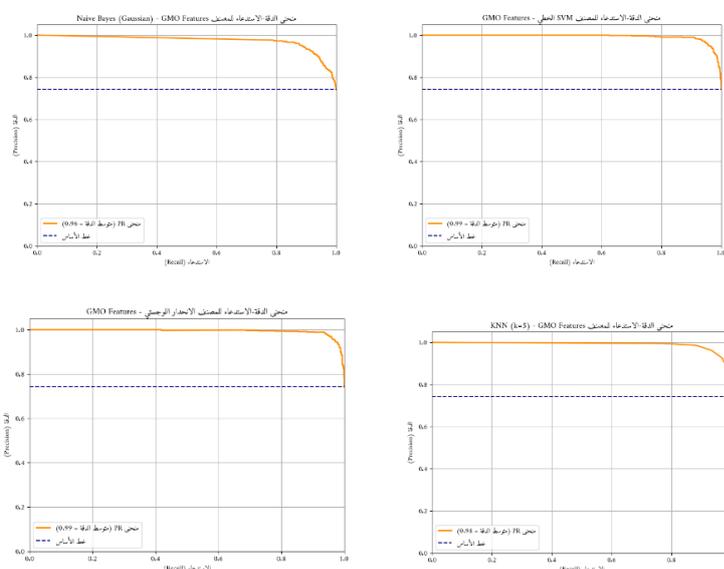
تقيس القدرة على التمييز بين الفئات. المنحنى الأقرب للزاوية العليا اليسرى يدل على أداء أعلى.



الشكل 19.IV: منحنيات ROC لكل مصنف

ثالثاً – منحنيات (Precision-Recall (PR Curves):

تُظهر العلاقة بين الدقة والاسترجاع، وتكون مهمة خصوصاً في حالات عدم توازن البيانات.



الشكل 20.IV: منحنيات PR لكل مصنف

IV.2.2.5.2.2 الاستنتاج النهائي

يتضح من التحليل الرقمي والرسومي أن Logistic Regression هو الخيار الأنسب، نظراً لتفوقه في كافة مؤشرات الأداء، وسهولة تنفيذه على الأجهزة منخفضة الموارد، مما يجعله ملائماً للتطبيق العملي بشكل خاص.

IV.2.2.6 نتائج النموذج النهائي : GMO + Logistic Regression

IV.2.2.6.1 إعداد التجربة

بعد مقارنة المصنفات المختلفة، تم اعتماد النموذج المكوّن من خوارزمية اختيار السمات GMO متبوعة بمصنف الانحدار اللوجستي (Logistic Regression) كنموذج نهائي بفضل توازنه العالي بين الأداء والدقة وسرعة التنفيذ. أجري التقييم باستخدام مجموعتي Validation و Test، بعد تقليص عدد السمات من 2048 إلى متوسط 286 سمة فقط، أي بنسبة كبيرة تجاوزت 86%

التقنيات المستخدمة:

StandardScaler لمعايرة السمات

Logistic Regression باستخدام liblinear solver

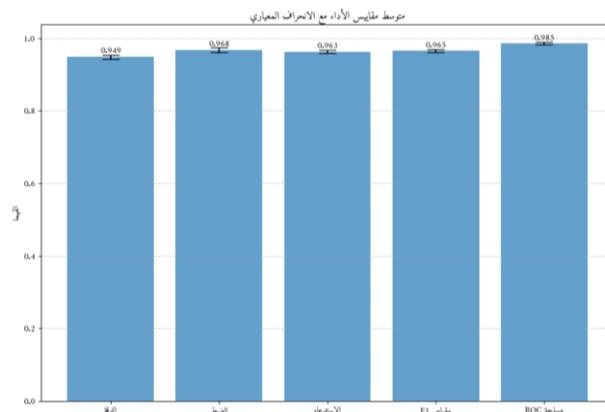
IV.2.2.6.2 النتائج النهائية

تم تسجيل النتائج التالية:

المؤشر	Validation	Test
Accuracy	94.9%	95.45%
Precision	96.8%	96.5%
Recall	96.3%	96.0%
F1-Score	96.5%	96.3%
ROC-AUC	98.5%	98.3%

IV.2.2.6.3 تحليل الأداء - متوسط الدرجات

تم تلخيص أداء النموذج بشكل مرئي عبر متوسطات المؤشرات والانحراف المعياري لكل منها باستخدام الرسم البياني :



الشكل IV.21: متوسط مقاييس الأداء مع الانحراف المعياري على مجموعة الاختبار

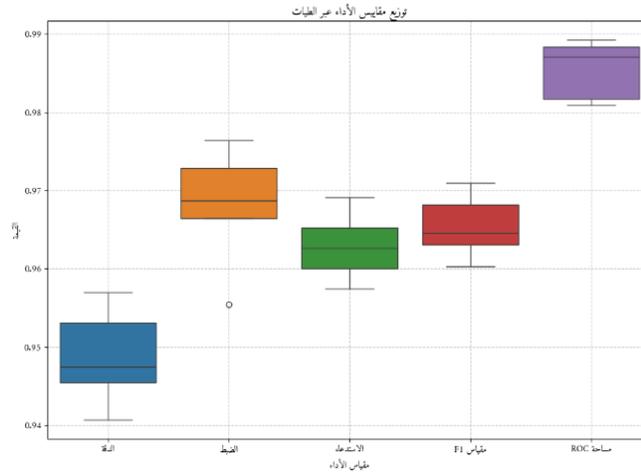
IV.2.2.6.4 التحليل الإحصائي (Boxplot عبر الطيات)

للتأكد من ثبات النموذج، تم تطبيق تقنية التحقق المتقاطع 5-Fold Cross Validation. وقد تم تسجيل القيم التالية:

المؤشر	متوسط الدقة Accuracy	متوسط الضبط (Precision)	متوسط الاسترجاع (Recall)	متوسط F1-Score	متوسط ROC-AUC	أعلى دقة	أدنى دقة	الانحراف المعياري
القيمة	94.88%	96.79%	96.29%	96.47%	98.49%	95.70%	94.07%	±0.57%

يشير الانحراف المعياري المنخفض (>1%) إلى أن النموذج مستقر للغاية.

جميع التجارب حققت دقة تفوق 94%، وAUC فوق 98%.



الشكل 22.IV: توزيع مقاييس الأداء عبر الطيات باستخدام Boxplot

يُظهر الشكل مدى استقرار الأداء وانخفاض التشتت، مع عدم وجود قيم شاذة واضحة، مما يؤكد موثوقية النموذج.

IV.2.2.7 المقارنة مع خوارزميات اختيار المميزات الأخرى

Comparative Analysis with Other Feature Selection Methods

تجدر الإشارة إلى أن نتائج خوارزمية Geometric Mean Optimizer (GMO) التي تم استعراضها سابقاً في القسم المتعلق بالنموذج النهائي تعكس أداء النموذج بعد عملية تحسين شاملة وتكييف خاص (Fine-Tuning).

أما في هذا القسم، فإن التحليل يركّز على مقارنة القدرات الجوهرية لخوارزمية GMO كآلية لاختيار المميزات مقابل خوارزميات مرجعية أخرى هي:

- خوارزمية تحسين سرب الجسيمات (Particle Swarm Optimization – PSO)
- الخوارزمية الجينية (Genetic Algorithm – GA)
- طريقة التصفية الإحصائية (Chi-squared – Chi2)

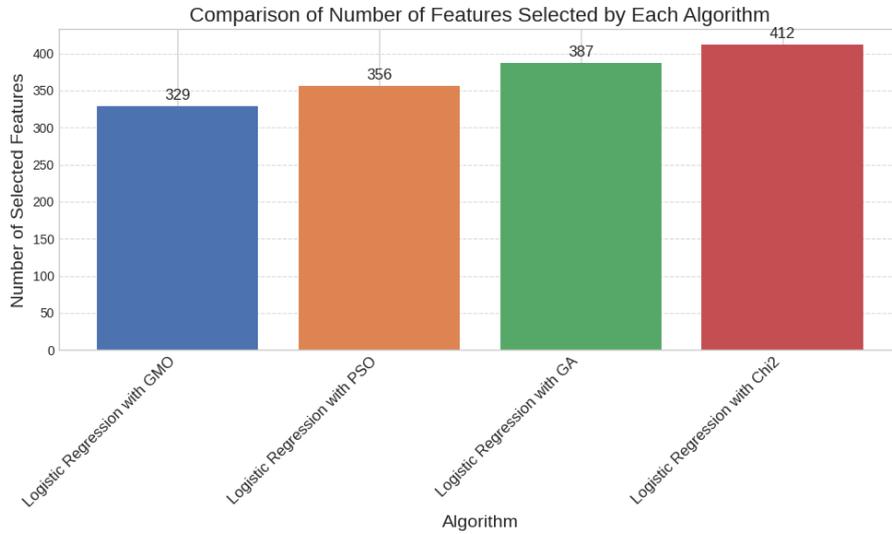
وذلك في ظل نفس ظروف التقييم والمعالجة، بهدف تقديم تحليل موضوعي لأداء خوارزميات اختيار المميزات بعيداً عن تأثير مراحل التهيئة النهائية للنموذج

IV.2.2.7.1 كفاءة اختيار المميزات (Feature Reduction Efficiency)

تمثل كفاءة تقليل الأبعاد أحد المعايير الحاسمة في تقييم خوارزميات اختيار المميزات، لاسيما في التطبيقات التي تتطلب نماذج خفيفة وسريعة.

أظهرت نتائج المقارنة أن خوارزمية GMO تمكنت من تقليص عدد السمات إلى 329 سمة من أصل 2048، محققة بذلك أفضل نسبة تقليص.

في المقابل، سجلت PSO (356 سمة)، GA (387 سمة)، بينما حافظت Chi2 على أعلى عدد مختار (412 سمة).



الشكل 23.IV: مقارنة عدد السمات المختارة

IV.2.2.7.2 جودة الأداء التصنيفي (Classification Performance)

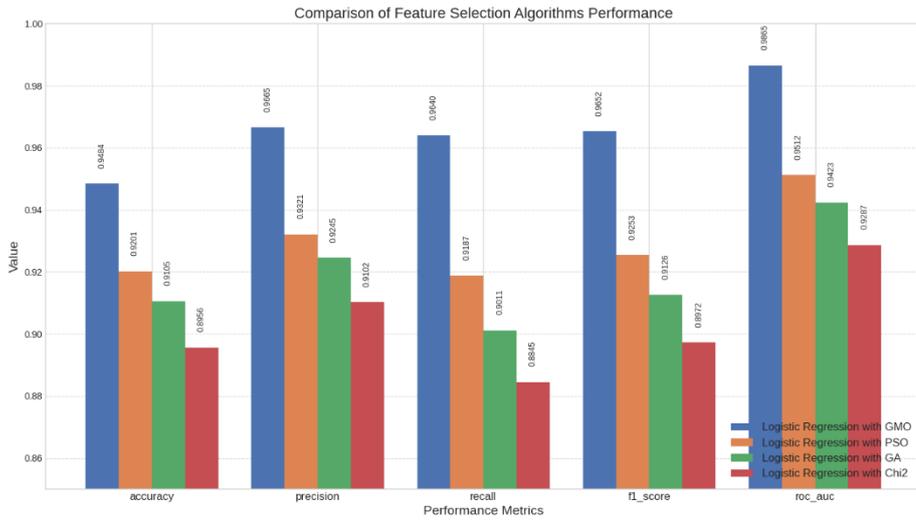
تم استخدام مصنف Logistic Regression (Liblinear) لتقييم تأثير السمات المختارة على دقة النماذج.

أظهرت خوارزمية GMO تفوقًا ملحوظًا، محققة دقة تصنيف 0.9494، تلتها PSO (0.9201)، ثم GA (0.9105)، وأخيرًا Chi2 (0.8956).

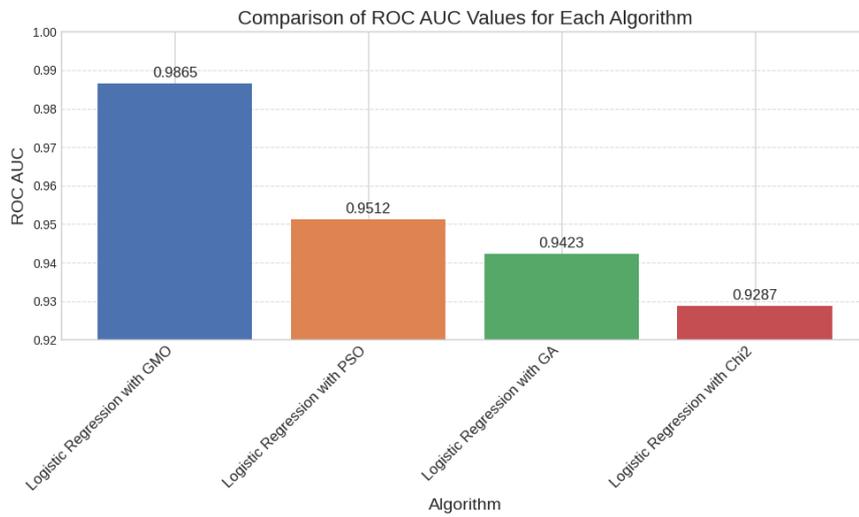
كذلك حافظت GMO على أفضل القيم في مؤشرات الأداء التفصيلية

جدول 12: جدول مقارنة بين الخوارزميات

ROC (AUC)	F1-score	الدقة Accuracy	عدد السمات المختارة	الخوارزمية
0.9287	0.8972	89.5%	329	Logistic Regression with Chi2
0.9423	0.9126	91.1%	356	GA Logistic Regression with
0.9512	0.9253	92.1%	387	PSO Logistic Regression with
0.9865	0.9652	94.8%	412	Logistic Regression with GMO



الشكل 24.IV: مقارنة مؤشرات الأداء (Accuracy, Precision, Recall, F1-score, ROC AUC)



الشكل 25.IV: منحنيات ROC لمقارنة قدرة التمييز بين الخوارزميات

Comprehensive Comparison of Feature Selection Algorithms

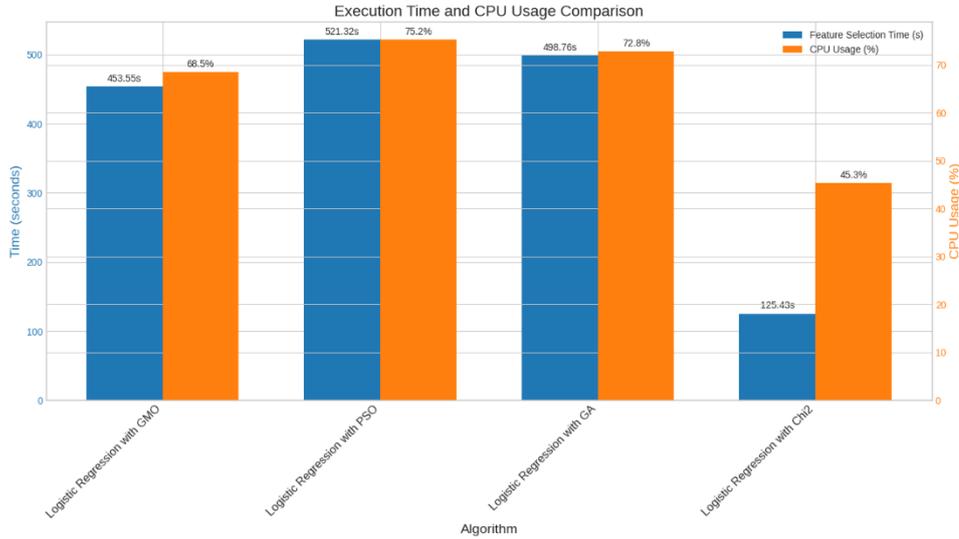


الشكل 26.IV: تمثيل عنكبوتي (Radar Chart) للأداء الكلي لكل خوارزمية

IV.2.2.7.3 الكلفة الحسابية واستهلاك الموارد (Computational Cost & Resource Utilization)

تم قياس الكلفة الزمنية والموارد المستخدمة خلال عملية اختيار السمات.

أظهرت النتائج أن خوارزمية GMO سجلت زمن تنفيذ بلغ 453.55 ثانية، وهو أقل من PSO (521.32 ثانية) و GA (498.76 ثانية)، في حين كانت Chi2 الأسرع (125.43 ثانية).

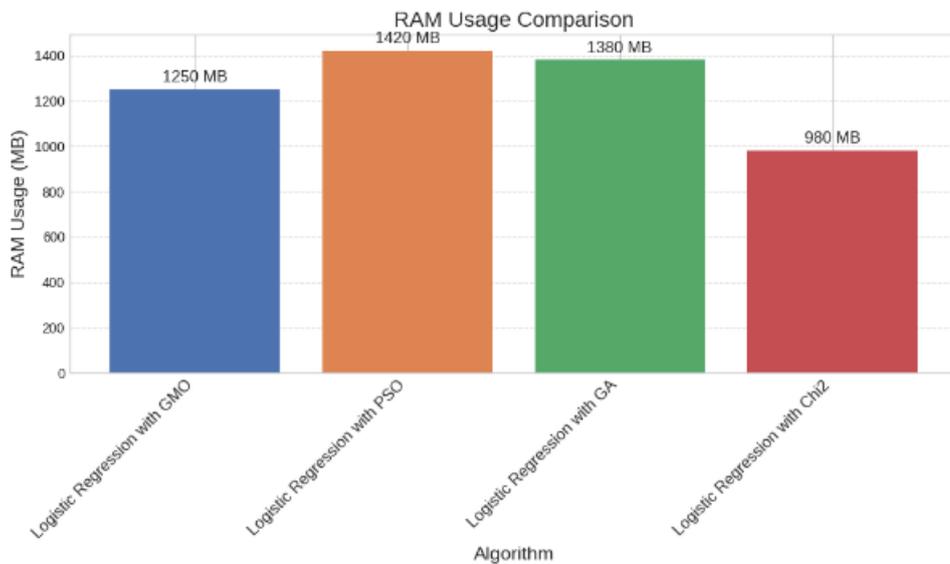


الشكل 27.IV: مقارنة زمن التنفيذ واستهلاك CPU لكل خوارزمية

من حيث استهلاك الموارد:

CPU Usage: GMO (68.5%) < PSO (75.2%) < GA (72.8%) < Chi2 (45.3%)

RAM Usage: GMO (1250MB) < PSO (1420MB) < GA (1380MB) > Chi2 (980MB)

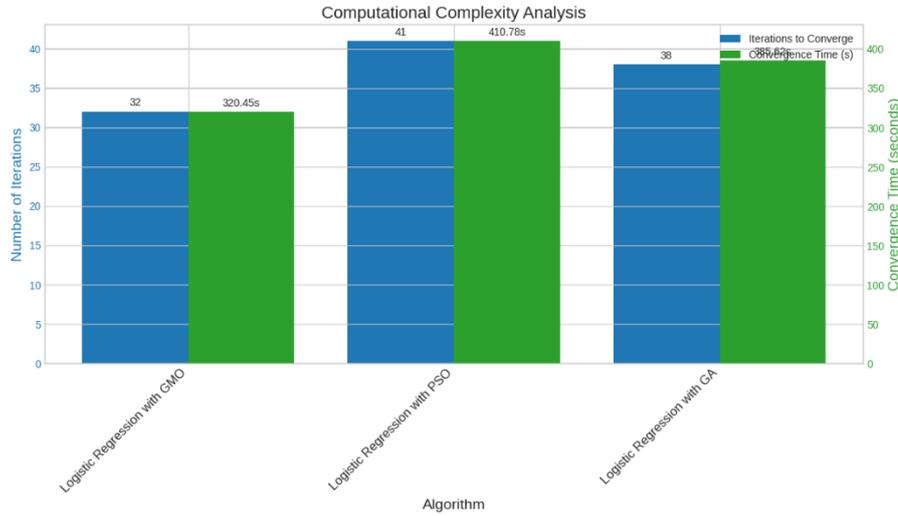


الشكل 28.IV: مقارنة استهلاك RAM بين الخوارزميات

IV.2.2.7.4 التعقيد الحسابي وسرعة التقارب

Computational Complexity & Convergence Speed

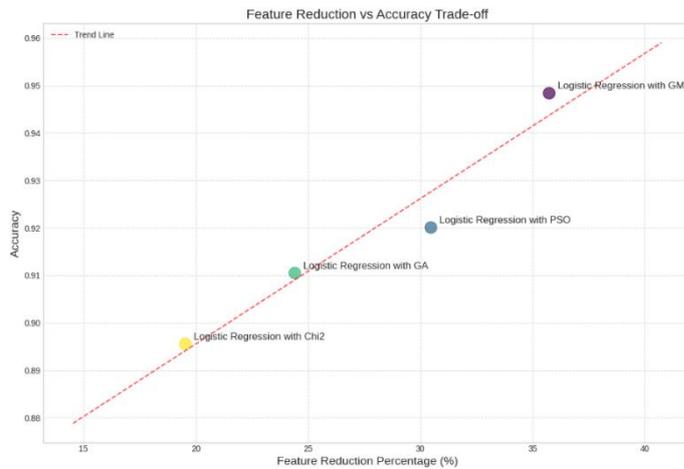
بالإضافة إلى الأداء الكلي، تم تحليل سرعة تقارب الخوارزميات وعدد التكرارات اللازمة للوصول إلى الحل الأمثل:



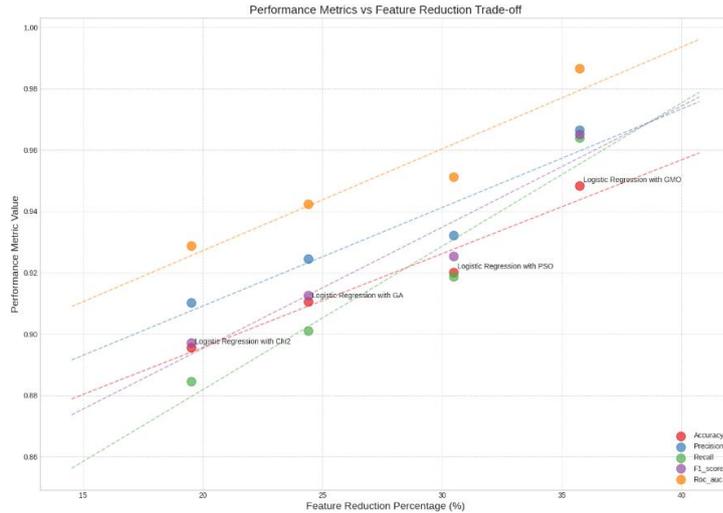
الشكل IV.29: تحليل سرعة التقارب وعدد التكرارات

IV.2.2.7.5 موازنة الأداء والتقليص (Feature Reduction vs Performance Trade-off)

أظهرت نتائج تحليل الموازنة بين نسبة تقليل السمات وجودة الأداء أن GMO تقدم أفضل توازن، حيث تمكنت من تحقيق أعلى الدرجات في Accuracy و F1-score مع نسبة تقليص للأبعاد تتجاوز 84%. في المقابل، عانت خوارزميات PSO و GA من انخفاض في الأداء مقابل نسبة التقليص، بينما سجلت Chi2 أضعف النتائج رغم بساطتها الحسابية.



الشكل IV.30: منحنى Trade-off بين نسبة تقليص السمات وجودة الأداء



الشكل 31.IV: مقارنة Trade-off شامل لمختلف مؤشرات الأداء

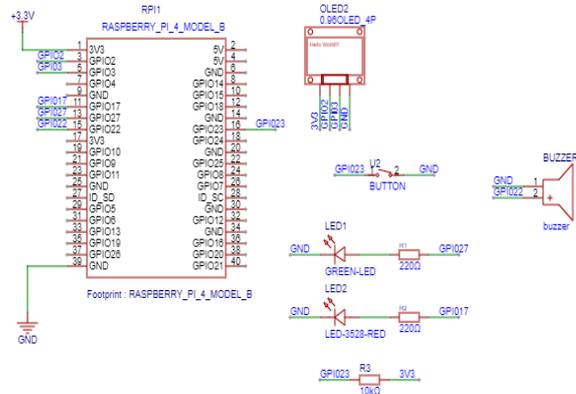
IV.2.2.8 النظام المدمج ومحاكاة التشغيل باستخدام Raspberry Pi

لتعزيز الطابع العملي للنظام وتحويله إلى تطبيق طبي مدمج حقيقي، تم تصميم وتنفيذ دائرة إلكترونية متكاملة باستخدام Raspberry Pi. تتكون هذه الدائرة من شاشة OLED تعمل بتقنية I2C لعرض نتائج التصنيف، ومؤشرات LED ملونة (أحمر للإشارة إلى وجود التهاب رئوي، وأخضر للحالة الطبيعية)، وجرس إنذار للتنبيه الصوتي في حالة اكتشاف المرض، بالإضافة إلى زر ضغط لبدء عملية التصنيف.

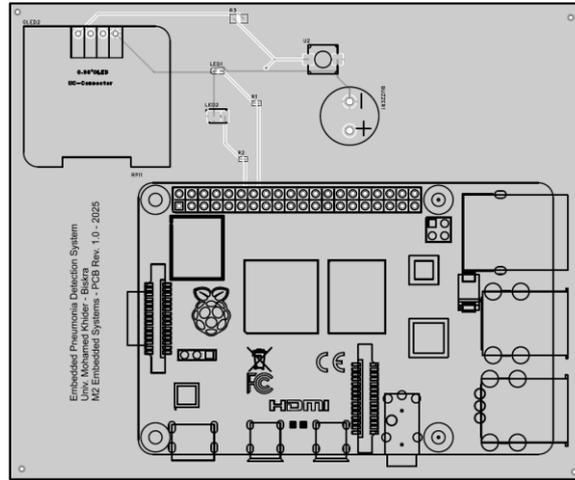
تم تصميم الدائرة بعناية لتوفير واجهة مستخدم بديهية وفعالة، حيث تعرض شاشة OLED نتيجة التصنيف ونسبة الثقة بشكل واضح، بينما توفر مؤشرات LED تمييزاً بصرياً سريعاً للحالة. يعمل الجرس على تنبيه الطاقم الطبي في حالة اكتشاف التهاب رئوي، مما يضمن استجابة سريعة للحالات الإيجابية. تم توصيل جميع المكونات باستخدام منافذ GPIO المناسبة على Raspberry Pi، مع مراعاة متطلبات الطاقة والحماية اللازمة كما هو موضح في الشكل IV.32 (مخطط التخطيط الفيزيائي PCB)، والشكل IV.33 (المخطط الإلكتروني).

تم تطوير برمجيات خاصة باستخدام Python ومكتبات RPi.GPIO و Adafruit_SSD1306 للتحكم في المكونات المادية. يقوم البرنامج بدمج نموذج التصنيف المدرب مسبقاً (باستخدام خوارزمية GMO لاختيار الميزات) مع منطق التحكم بالأجهزة، حيث يتم تنشيط المكونات المناسبة بناءً على نتيجة التصنيف. يمثل هذا التكامل بين الخوارزميات المتقدمة والمكونات المادية خطوة مهمة نحو تطوير أنظمة تشخيص طبية مدمجة قابلة للنشر في البيئات السريرية.

يمكن تطوير هذا النموذج الأولي مستقبلاً ليصبح جهازاً طبياً محمولاً يمكن استخدامه في المناطق النائية أو المستشفيات ذات الموارد المحدودة، مما يسهم في تحسين الرعاية الصحية وتسريع عملية التشخيص.



الشكل 32.IV: تخطيط لوحة النظام باستخدام Raspberry Pi 4 والمكونات الملحقة.



الشكل 33.IV: مخطط PCB

IV.2.2.9 خلاصة التطبيق الثاني

Conclusion of the Second Application

برهن النموذج الذي يجمع بين 50ResNet وGMO و Logistic Regression على فعالية عالية في تصنيف الالتهاب الرئوي حقق النموذج أداءً تصنيفياً قوياً عبر مختلف الطيات، مع متوسط دقة بلغ 94.88% ومعامل ROC-AUC تجاوز 98%، ونجح في تقليص عدد السمات بنحو 13.5% فقط من الحجم الأصلي. تُظهر هذه النتائج أن الإطار المقترح مناسب للتطبيقات الطبية على منصات مدمجة مثل Raspberry Pi، ويفتح المجال لتوسيع استخدام خوارزمية GMO في مجالات تشخيصية أخرى، مع إمكانية تحسينها مستقبلاً عبر أساليب هجينة أو شبكات بديلة.

IV.3 الخلاصة

Conclusion

يتناول هذا الفصل الجانب العملي من الدراسة، حيث تم اختبار خوارزمية المُحسّن بالمتوسط الهندسي (GMO) في سياقات متنوعة تشمل التقييم النظري والتطبيقات الواقعية.

في القسم الأول، جرى تقييم أداء GMO على دوال معيارية أحادية ومتعددة القمم. أظهرت الخوارزمية قدرة عالية على الاستكشاف وتجنب الحلول المحلية، إضافة إلى سرعة التقارب نحو الحل الأمثل. وقد أثبتت التجارب أن GMO تتفوق على خوارزميات مثل PSO و GA و AOA من حيث الدقة والاستقرار.

أما في التطبيق الأول، فقد استُخدمت GMO لضبط معاملات متحكم PID في محرك تيار مستمر. أظهرت النتائج تحسناً واضحاً في استجابة النظام، مع تقليل مؤشر الخطأ التراكمي (IAE) وزمن الاستقرار إلى مستويات منخفضة جداً. كما أكد التحليل الترددي استقرار النظام ومثابته بعد عملية الضبط.

وفي التطبيق الثاني، تم تصميم نظام ذكي لتصنيف الالتهاب الرئوي باستخدام صور الأشعة الصدرية. اعتمد النموذج على استخراج السمات بواسطة ResNet50، ثم اختيارها باستخدام GMO، يليه التصنيف باستخدام Logistic Regression. وقد حقق النموذج دقة تصنيف بلغت 95.45%، مع تقليص كبير في عدد السمات، مما جعله مناسباً للتنفيذ على منصات مدمجة مثل Raspberry Pi. أخيراً، أكدت نتائج الفصل أن خوارزمية GMO تجمع بين البساطة والفاعلية. أثبتت قدرتها على العمل بكفاءة في بيئات متنوعة، وبرزت كخيار واعد لتطبيقات الذكاء الاصطناعي، خاصة في الأنظمة الذكية محدودة الموارد.

الخاتمة

General Conclusion

الخاتمة

General Conclusion

جاء هذا العمل استجابةً للتحديات المتزايدة في مجال الأنظمة المدمجة، والتي تفرض قيودًا صارمة على الموارد الحسابية، مما يجعل الحاجة ملحة إلى أدوات تحسين قادرة على تحقيق أداء عالٍ ضمن بيئات محدودة. وفي هذا السياق، تم توظيف خوارزمية Geometric Mean Optimizer (GMO)، كما وردت في الأدبيات الحديثة، ضمن إطار تطبيقي جديد يستهدف تحسين أداء أنظمة تحكم وتصنيف ذكية تعمل في ظل هذه القيود.

انطلقت الدراسة من مراجعة شاملة لخوارزميات الميتاهيورستيك، بما في ذلك المبادئ النظرية والمعمارية الخوارزمية، مع تحليل خاص لقدرة هذه الأساليب على التكيف مع متطلبات الأنظمة المضمنة. وقد حُصص جانبٌ مهم من العمل لتقديم الخصائص البنوية لخوارزمية GMO، التي تعتمد على المتوسط الهندسي ومؤشر اللياقة المزدوج لتوجيه البحث في فضاء الحلول.

في الجانب التطبيقي، تم اعتماد منهجيتين لاختبار فعالية الخوارزمية: الأولى من خلال تحسين معاملات متحكم PID لمحرك تيار مستمر، والثانية في مهمة انتقاء السمات لتصنيف صور أشعة الصدر لرصد الالتهاب الرئوي. وقد أظهرت النتائج أن خوارزمية GMO كانت قادرة على إنتاج حلول ذات جودة عالية، محققة تحسناً في سرعة الاستجابة، ودقة التصنيف، وتقليل عدد السمات المدخلة، مقارنةً بخوارزميات مرجعية مثل PSO و GA، وذلك دون إحداث عبء زائد على الموارد عند تنفيذها على منصة Raspberry Pi.

تُبرز هذه النتائج القيمة التطبيقية للدراسة، حيث تبرهن على أن توظيف خوارزمية قائمة، كـ GMO، في سياقات جديدة مثل التحكم في الأنظمة أو التصنيف الطبي، يمكن أن يسفر عن أداء متميز إذا ما تم تكييفها بشكل مدروس مع خصائص التطبيق.

ورغم ما حققته هذه الدراسة من نتائج مشجعة، إلا أن لها بعض الحدود التي ينبغي أخذها بعين الاعتبار. من أبرز هذه الحدود أن التقييم اقتصر على حالتين تطبيقيتين فقط، ما لا يسمح بتعميم النتائج بشكل شامل على جميع أصناف الأنظمة المدمجة. كما أن بيئة التنفيذ المعتمدة (Raspberry Pi) تُعد وسيطاً بين الحواسيب التقليدية والمتحكمات الدقيقة، ولم تُختبر الخوارزمية بعد على عتاد

أقل قدرة كالمتحكمات من فئة STM32 أو ESP32، ما يجعل تقييم الأداء على هذه المنصات من الضرورات المستقبلية. أضف إلى ذلك أن الخوارزمية لم تُختبر تحت متطلبات صارمة للزمن الحقيقي، مثل تلك المستخدمة في أنظمة السلامة أو التحكم المباشر في الحركة، وهو ما قد يُبرز سلوكيات خوارزمية مختلفة تستحق الاستقصاء لاحقًا.

الآفاق المستقبلية:

بناءً على ما سبق، تُفتح آفاق بحثية متعددة يمكن أن تُثري هذا العمل، من بينها دمج خوارزمية GMO مع أساليب تعلم التعزيز العميق (Deep Q-Learning) لتطوير حلول ذاتية التكيف، أو اعتماد آليات ضبط تلقائي لمعاملات الخوارزمية بهدف تقليل الحاجة إلى الإعداد اليدوي. كما يُمكن استكشاف دور الخوارزمية في توليد هياكل شبكية فعالة في سياق البحث التوليدي عن المعمارية العصبية (Neural Architecture Search) الموجهة للأنظمة المدمجة.

وبهذا، فإن هذه الدراسة تُعد خطوة نحو تعميم استخدام خوارزميات التحسين الذكية في البيئات المقيدة، وتسهم في تأكيد إمكانات خوارزمية GMO ضمن سياقات تطبيقية جديدة لم تُختبر فيها من قبل، مما يجعلها مرشحًا واعدًا لمزيد من البحث والتطوير.

المراجع

REFERENCES

- [1] E.-G. Talbi, *Metaheuristics: From Design to Implementation*, Wiley, 2009.
- [2] H. A. R. Benkaddour, "Métaheuristiques parallèles pour la résolution des problèmes difficiles," Université Kasdi Merbah, Ph.D. dissertation, Ouargla, Algeria, 2013.
- [3] A. El Dor, "Perfectionnement des algorithmes d'optimisation par essaim particulière: Application en segmentation d'image et en électronique," Université Paris-Est, Ph.D. dissertation, Paris, 2012.
- [4] A. Bechir, "Résolution des problèmes d'optimisation par les systèmes multi-agents et les approches évolutionnaires," Université Mohamed Khider-Biskra, Ph.D. dissertation, Biskra, Algeria, 2016.
- [5] A. Layeb, "Utilisation des approches d'optimisation combinatoire pour la vérification des applications temps réel," Université M'Hamed Mentouri de Constantine, Ph.D. dissertation, Constantine, Algeria, 2010.
- [6] A. Gherboudj, "Méthodes de résolution de problèmes difficiles académiques," Université de Constantine 2, Ph.D. dissertation, Constantine, Algeria, 2013.
- [7] M. Gendreau and J.-Y. Potvin, *Handbook of Metaheuristics*, vol. 2, 2nd ed., New York: Springer, 2010.
- [8] C. Blum and A. Roli, "Metaheuristics in combinatorial optimization: Overview and conceptual comparison," *ACM Computing Surveys*, vol. 35, no. 3, pp. 268–308, 2003. DOI: 10.1145/937503.937505
- [9] M. Dorigo and T. Stützle, *Ant Colony Optimization*, Cambridge: MIT Press, 2004.
- [10] F. Glover and M. Laguna, *Tabu Search*, Boston: Springer, 1997.
- [11] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proc. IEEE Int. Conf. Neural Networks (ICNN)*, Perth, Australia, 1995, pp. 1942–1948.
- [12] E.-G. Talbi, "A taxonomy of hybrid metaheuristics," *Journal of Heuristics*, vol. 8, no. 5, pp. 541–564, 2002. DOI: 10.1023/A:1021249430704

- [13] D. Karaboga and B. Basturk, "A powerful and efficient algorithm for numerical function optimization: Artificial Bee Colony (ABC) algorithm," *Journal of Global Optimization*, vol. 39, no. 3, pp. 459–471, 2007. DOI: 10.1007/s10898-007-9149-x
- [14] F. Xhafa and A. Abraham, *Metaheuristics for Scheduling in Distributed Computing Environments*, Berlin: Springer, *Studies in Computational Intelligence*, vol. 146, 2008.
- [15] S. K. Sahoo, A. K. Sahu, H. E. H. El-Sayed, P. M. R. Sarkar, and M. M. El-Hawary, "An arithmetic and geometric mean-based multi-objective moth-flame optimization algorithm," *Cluster Computing*, vol. 27, pp. 6527–6561, 2024. DOI: 10.1007/s10586-023-04412-w
- [16] F. Rezaei, H. R. Safavi, and M. Abd Elaziz, "GMO: geometric mean optimizer for solving engineering problems," *Soft Computing*, vol. 27, pp. 10571–10606, 2023. DOI: 10.1007/s00500-023-08202-z
- [17] O. Abdellatif, M. Issa, and I. Ziedan, "Optimization of PID Controller Parameter using the Geometric Mean Optimizer," *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 4, pp. 245–252, 2024. DOI: 10.14569/IJACSA.2024.0150429
- [18] I. P. Rodrigues, A. F. Oliveira, M. G. Santos, and P. G. Alves, "Assessment of IAE and ITAE-based objective functions for PID controller tuning in buck converters within space systems," *Cadernos UniFOA*, vol. 19, no. 54, pp. 1–10, 2024. DOI: 10.47385/cadunifoa.v19.n54.4898
- [19] UNICEF, "Pneumonia: The Forgotten Killer of Children," UNICEF, New York, 2006. [Online]. Available: https://www.unicef.org/media/files/Pneumonia_The_Forgotten_Killer_of_Children.pdf
- [20] D. S. Kermany, M. Goldbaum, W. Cai, et al., "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning," *Cell*, vol. 172, no. 5, pp. 1122–1131.e9, 2018. DOI: 10.1016/j.cell.2018.02.010
- [21] M. Tajbakhsh, J. Y. Shin, S. R. Gurudu, et al., "Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?," *IEEE Transactions on Medical Imaging*, vol. 35, no. 5, pp. 1299–1312, 2016. DOI: 10.1109/TMI.2016.2535302

- [22] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Las Vegas, 2016, pp. 770–778. DOI: 10.1109/CVPR.2016.90
- [23] S. Mirjalili and A. Lewis, "S-shaped versus V-shaped transfer functions for binary Particle Swarm Optimization," Swarm and Evolutionary Computation, vol. 9, pp. 1–14, 2013. DOI: 10.1016/j.swevo.2012.11.002
- [24] R. Bellman, Adaptive Control Processes: A Guided Tour, Princeton: Princeton University Press, 1961.
- [25] S. Sharma, R. K. Gupta, and M. Kumar, "An Embedded System Based on Raspberry Pi for Effective Electrocardiogram Monitoring," Applied Sciences, vol. 13, no. 14, pp. 8273, 2023. DOI: 10.3390/app13148273

الملحق

Appendix

الجدول I : نتائج تقليل الدوال لمجموعة الخوارزميات على دوال المعايير التقليدية (Classical)
(Benchmark Functions)

Criteria	HHO	AOA	AO	GBO	FDA	EO	GMO
F1 Ave	9.2006E-193	7.8895E-182	1.5675E-204	5.7916E-267	9.1383E-12	3.8547E-101	3.0138E-322
F1 Std	0.0000E+00	0.0000E+00	0.0000E+00	0.0000E+00	9.7219E-12	1.8688E-100	0.0000E+00
F2 Ave	5.4605E-102	0.0000E+00	3.1414E-149	1.7127E-134	5.3877E-09	1.2494E-57	0.0000E+00
F2 Std	1.3951E-101	0.0000E+00	1.2478E-148	9.2323E-134	4.6955E-09	1.9448E-57	0.0000E+00
F3 Ave	2.8841E-167	8.2976E-04	2.2004E-207	2.2148E-223	4.0472E-01	9.4264E-27	4.9407E-324
F3 Std	0.0000E+00	3.3646E-03	0.0000E+00	0.0000E+00	2.2927E-01	4.9964E-26	0.0000E+00
F4 Ave	2.3132E-97	1.7737E-02	4.2317E-147	9.0252E-123	1.3682E+01	1.9210E-25	0.0000E+00
F4 Std	6.7674E-97	1.9819E-02	1.6275E-146	3.3185E-122	2.9451E+00	4.0403E-25	0.0000E+00
F5 Ave	6.4186E-04	2.7855E+01	3.8747E-04	1.6817E+01	3.7711E+01	2.3855E+01	2.4767E+01
F5 Std	7.4683E-04	5.9786E-01	6.0410E-04	2.8013E+00	2.7420E+01	1.8736E-01	2.4519E-01
F6 Ave	1.4291E-05	2.5305E+00	9.1910E-06	3.1451E-14	1.4526E-11	7.2632E-14	0.0000E+00
F6 Std	1.9068E-05	2.2793E-01	1.6930E-05	1.2886E-13	3.2988E-11	1.9410E-13	0.0000E+00
F7 Ave	5.1291E-05	1.7121E-05	3.1915E-05	2.4346E-04	5.7458E-02	4.1963E-04	2.1509E-05
F7 Std	6.9175E-05	1.3939E-05	3.0715E-05	1.7123E-04	2.3636E-02	2.5443E-04	2.5513E-05
F8 Ave	-1.2569E+04	-6.1649E+03	-9.7598E+03	-8.9161E+03	-8.8589E+03	-8.9007E+03	-6.4524E+03
F8 Std	5.0935E-02	3.6264E+02	3.5197E+03	9.1036E+02	6.2972E+02	5.9972E+02	1.2763E+03
F9 Ave	0.0000E+00	0.0000E+00	0.0000E+00	0.0000E+00	5.5187E+01	0.0000E+00	0.0000E+00
F9 Std	0.0000E+00	0.0000E+00	0.0000E+00	0.0000E+00	1.7723E+01	0.0000E+00	0.0000E+00
F10 Ave	8.8818E-16	8.8818E-16	8.8818E-16	8.8818E-16	3.0893E+00	4.5593E-15	4.4409E-15
F10 Std	0.0000E+00	0.0000E+00	0.0000E+00	0.0000E+00	1.0342E+00	6.4863E-16	0.0000E+00
F11 Ave	0.0000E+00	8.9483E-02	0.0000E+00	0.0000E+00	2.2411E-02	0.0000E+00	0.0000E+00
F11 Std	0.0000E+00	7.0152E-02	0.0000E+00	0.0000E+00	2.6768E-02	0.0000E+00	0.0000E+00
F12 Ave	5.1780E-07	3.0851E-01	4.5872E-07	1.5522E-15	5.6195E-01	2.7434E-15	5.2353E-11
F12 Std	6.2749E-07	4.9384E-02	6.9013E-07	6.8646E-15	8.0939E-01	4.9638E-15	3.2351E-11
F13 Ave	8.4075E-06	2.7668E+00	3.0672E-06	6.5554E-03	5.7681E-02	1.4498E-02	2.2873E-10
F13 Std	1.7001E-05	1.3359E-01	4.8375E-06	1.3038E-02	1.4114E-01	3.3424E-02	1.2323E-10
F14 Ave	1.1967E+00	1.1029E+01	2.1374E+00	9.9800E-01	9.9800E-01	9.9800E-01	3.9936E+00
F14 Std	4.8084E-01	3.3093E+00	3.1783E+00	4.1233E-17	0.0000E+00	1.3039E-16	2.7699E+00
F15 Ave	3.6063E-04	1.0170E-02	4.3820E-04	4.6010E-04	6.1041E-04	3.6525E-03	3.5231E-04
F15 Std	1.6866E-04	1.1417E-02	8.5052E-05	3.4709E-04	4.2494E-04	7.6011E-03	1.7746E-05
F16 Ave	-1.0316E+00	-1.0316E+00	-1.0314E+00	-1.0316E+00	-1.0316E+00	-1.0316E+00	-1.0312E+00
F16 Std	6.3393E-11	7.9937E-08	2.0443E-04	6.7752E-16	6.7752E-16	6.2532E-16	7.9623E-04
F17 Ave	3.9789E-01	4.0606E-01	3.9801E-01	3.9789E-01	3.9789E-01	3.9789E-01	4.5038E-01
F17 Std	2.2608E-06	6.8229E-03	2.1139E-04	0.0000E+00	0.0000E+00	0.0000E+00	1.6137E-01
F18 Ave	3.0000E+00	6.6006E+00	3.0217E+00	3.0000E+00	3.0000E+00	3.0000E+00	3.0000E+00
F18 Std	2.7520E-08	9.3349E+00	2.4593E-02	1.2506E-15	1.5927E-15	9.2567E-16	4.6526E-11
F19 Ave	-3.8619E+00	-3.8539E+00	-3.8584E+00	-3.8628E+00	-3.8628E+00	-3.8628E+00	-3.8794E+00
F19 Std	1.2915E-03	2.3635E-03	3.1826E-03	2.6962E-15	2.7101E-15	2.5391E-15	2.0881E-05
F20 Ave	-3.1367E+00	-3.0914E+00	-3.2276E+00	-3.2665E+00	-3.3102E+00	-3.2467E+00	-3.2322E+00
F20 Std	1.0382E-01	7.2463E-02	6.6068E-02	6.0328E-02	3.2733E-02	5.8273E-02	1.8617E-01
F21 Ave	-5.2199E+00	-3.7338E+00	-1.0147E+01	-7.7741E+00	-9.9833E+00	-8.7144E+00	-8.4704E+00
F21 Std	9.0694E-01	1.1264E+00	1.3926E-02	2.5868E+00	9.3076E-01	2.4632E+00	2.9088E+00
F22 Ave	-5.1821E+00	-4.5136E+00	-1.0399E+01	-8.6396E+00	-1.0003E+01	-9.3488E+00	-9.8629E+00
F22 Std	1.0536E+00	1.6562E+00	4.4476E-03	2.6167E+00	1.5320E+00	2.4261E+00	2.0590E+00
F23 Ave	-5.1275E+00	-4.0556E+00	-1.0531E+01	-8.7338E+00	-1.0313E+01	-1.0133E+01	-8.2832E+00
F23 Std	1.5118E-03	1.4526E+00	7.5564E-03	2.5929E+00	1.2234E+00	1.5454E+00	3.5562E+00

الجدول II: نتائج تقليل الدوال لمجموعة الخوارزميات على مجموعة اختبار CEC 2017

Criteria	HHO	AOA	AO	GBO	FDA	EO	GMO
F1 Ave	1.2471E+08	1.1127E+11	1.6838E+09	7.2920E+03	3.8818E+04	5.9034E+03	4.2020E+03
F1 Std	2.9145E+07	8.9943E+09	6.2457E+08	8.4348E+03	5.6460E+04	4.0853E+03	4.1389E+03
F3 Ave	9.8478E+04	1.7460E+05	2.0248E+05	3.9352E+04	2.7778E+04	8.1382E+04	1.3609E+05
F3 Std	2.2600E+04	1.7459E+04	4.4288E+04	9.7975E+03	9.1622E+03	1.2685E+04	1.7457E+04
F4 Ave	7.6510E+02	3.3253E+04	1.0630E+03	5.5786E+02	5.3390E+02	5.3319E+02	5.8965E+02
F4 Std	8.6911E+01	5.8561E+03	1.9549E+02	5.3041E+01	4.8907E+01	4.4751E+01	4.3998E+01
F5 Ave	9.0007E+02	1.1490E+03	8.6665E+02	8.1004E+02	8.3679E+02	6.7857E+02	6.2615E+02
F5 Std	3.2695E+01	4.4583E+01	3.3186E+01	4.9971E+01	5.2911E+01	3.2609E+01	2.9495E+01
F6 Ave	6.7481E+02	6.9431E+02	6.6537E+02	6.3725E+02	6.5672E+02	6.0158E+02	6.1310E+02
F6 Std	4.5326E+00	5.6010E+00	5.3658E+00	9.7671E+00	8.1625E+00	1.1725E+00	6.8630E+00
F7 Ave	1.8318E+03	1.9330E+03	1.5161E+03	1.2644E+03	1.3949E+03	9.7215E+02	8.8476E+02
F7 Std	9.1764E+01	7.2198E+01	1.2247E+02	9.4996E+01	1.0256E+02	7.8489E+01	3.7289E+01
F8 Ave	1.1852E+03	1.4682E+03	1.1804E+03	1.1110E+03	1.1360E+03	9.8236E+02	9.5240E+02
F8 Std	3.5456E+01	4.7037E+01	3.4016E+01	5.6324E+01	5.4639E+01	4.1611E+01	8.4595E+01
F9 Ave	2.6187E+04	2.9297E+04	2.1934E+04	7.4002E+03	1.0338E+04	2.4907E+03	1.5896E+03
F9 Std	2.7992E+03	3.5386E+03	3.8379E+03	2.4743E+03	2.2436E+03	2.1668E+03	1.4550E+03
F10 Ave	9.2152E+03	1.3223E+04	9.1459E+03	7.8672E+03	8.7429E+03	8.2564E+03	8.7748E+03
F10 Std	9.3959E+02	8.2921E+02	9.7917E+02	9.4913E+02	1.0974E+03	1.1778E+03	2.5236E+03
F11 Ave	1.5752E+03	2.2166E+04	2.2437E+03	1.3879E+03	1.3733E+03	1.3187E+03	1.3630E+03
F11 Std	7.4192E+01	3.4432E+03	2.7895E+02	8.3613E+01	8.8692E+01	6.5704E+01	4.3463E+01
F12 Ave	1.3152E+08	6.7197E+10	6.1213E+08	2.6664E+06	2.3629E+06	3.4670E+06	3.3511E+07
F12 Std	7.8725E+07	1.0985E+10	4.0105E+08	2.2857E+06	1.5430E+06	1.9766E+06	2.1415E+07
F13 Ave	2.9929E+06	3.4176E+10	2.3863E+07	1.2570E+04	7.0098E+03	8.5108E+03	5.8217E+04
F13 Std	8.5038E+05	1.0233E+10	3.8111E+07	9.9819E+03	6.4160E+03	5.4644E+03	3.0336E+04
F14 Ave	1.6473E+06	3.7757E+07	4.8743E+06	3.9591E+04	3.0465E+04	1.3926E+05	1.1122E+05
F14 Std	1.0895E+06	3.2667E+07	4.3827E+06	3.9226E+04	3.1819E+04	7.8283E+04	7.8991E+04
F15 Ave	6.4801E+05	3.4101E+09	6.1620E+05	1.2206E+04	1.0467E+04	1.2769E+04	2.9686E+04
F15 Std	2.7817E+05	2.1087E+09	3.6634E+05	7.4912E+03	6.8212E+03	7.2382E+03	2.3133E+04
F16 Ave	4.5310E+03	7.6573E+03	4.3612E+03	3.4870E+03	3.4046E+03	2.9975E+03	3.0996E+03
F16 Std	6.4335E+02	1.4310E+03	5.3030E+02	4.9718E+02	3.4684E+02	4.5459E+02	4.4990E+02
F17 Ave	3.7987E+03	9.0067E+03	3.6432E+03	3.0819E+03	3.4706E+03	2.8709E+03	2.7786E+03
F17 Std	4.5146E+02	2.0948E+03	3.8545E+02	3.4783E+02	3.1650E+02	3.3586E+02	2.6692E+02
F18 Ave	4.3723E+06	7.9914E+07	9.1232E+06	2.1870E+05	2.9449E+05	1.9514E+06	1.2999E+06
F18 Std	3.4563E+06	4.7896E+07	6.4256E+06	1.3210E+05	2.0203E+05	1.4504E+06	9.5764E+05
F19 Ave	1.1264E+06	3.1135E+09	2.2803E+06	1.8302E+04	2.0434E+04	1.9484E+04	9.0972E+05
F19 Std	8.5603E+05	1.6281E+09	2.1570E+06	1.1745E+04	1.1714E+04	1.1313E+04	9.4769E+05
F20 Ave	3.5328E+03	3.6188E+03	3.2709E+03	3.2025E+03	3.4861E+03	2.9766E+03	2.9560E+03
F20 Std	2.8422E+02	3.1895E+02	2.6175E+02	4.0586E+02	3.5025E+02	2.9144E+02	2.8389E+02
F21 Ave	2.8744E+03	3.0610E+03	2.7043E+03	2.5662E+03	2.6266E+03	2.4414E+03	2.4294E+03
F21 Std	8.0664E+01	7.1074E+01	6.3075E+01	5.1954E+01	6.4578E+01	3.2306E+01	4.3009E+01
F22 Ave	1.1291E+04	1.5943E+04	1.0965E+04	9.4638E+03	1.0150E+04	9.5673E+03	1.0416E+04
F22 Std	1.0318E+03	6.4563E+02	1.6841E+03	1.6273E+03	1.0895E+03	1.8416E+03	3.2104E+03
F23 Ave	3.8310E+03	4.4274E+03	3.4393E+03	3.0558E+03	3.1479E+03	2.8742E+03	2.8888E+03
F23 Std	2.0071E+02	2.4540E+02	9.2377E+01	7.8350E+01	1.1024E+02	4.6342E+01	6.8604E+01
F24 Ave	4.2735E+03	4.9461E+03	3.5218E+03	3.1724E+03	3.2978E+03	3.0284E+03	3.0248E+03
F24 Std	2.5064E+02	2.3884E+02	1.2135E+02	6.0068E+01	8.3941E+01	3.8189E+01	3.0351E+01
F25 Ave	3.2218E+03	1.4965E+04	3.4327E+03	3.0855E+03	3.0746E+03	3.0896E+03	3.0490E+03
F25 Std	4.7421E+01	1.6769E+03	8.8058E+01	2.3553E+01	2.9128E+01	2.5254E+01	2.2310E+01
F26 Ave	1.0559E+04	1.6721E+04	8.6249E+03	7.0615E+03	8.4098E+03	5.4083E+03	5.2625E+03
F26 Std	1.9144E+03	1.4623E+03	2.4721E+03	2.4977E+03	2.4109E+03	5.4784E+02	4.5503E+02
F27 Ave	4.3910E+03	6.6280E+03	4.0141E+03	3.5950E+03	3.5422E+03	3.3839E+03	3.4468E+03
F27 Std	4.2369E+02	6.2810E+02	1.9720E+02	1.3302E+02	1.0081E+02	6.8784E+01	5.7254E+01
F28 Ave	3.6322E+03	1.1991E+04	4.2899E+03	3.3326E+03	3.3361E+03	3.3539E+03	3.3184E+03
F28 Std	1.0426E+02	1.5119E+03	2.7492E+02	2.7941E+01	3.7231E+01	3.3683E+01	2.3001E+01
F29 Ave	5.9634E+03	3.3009E+04	6.1689E+03	4.6781E+03	4.7818E+03	4.0845E+03	4.5354E+03
F29 Std	5.4130E+02	1.6772E+04	6.9454E+02	3.7906E+02	4.8072E+02	2.8174E+02	3.5989E+02
F30 Ave	4.8890E+07	6.1577E+09	1.2248E+08	1.0718E+06	1.0221E+06	1.1758E+06	6.4005E+07
F30 Std	1.7314E+07	2.5496E+09	4.9406E+07	2.1165E+05	2.3146E+05	3.2019E+05	1.5360E+07

ملحق الأكواد البرمجية

يعرض هذا الملحق مقتطفات منتقاة من أبرز الأكواد البرمجية التي تم تطويرها أو إعادة هيكلتها خلال هذا العمل البحثي، بهدف تعزيز التكامل بين خوارزمية Geometric Mean Optimizer (GMO) والتطبيقات العملية، بما في ذلك اختيار الميزات، وضبط معاملات المتحكم PID، والتصنيف الطبي باستخدام الأنظمة المدمجة. وقد تم تقديم هذه الأكواد بأسلوب معياري يضمن قابليتها للتنفيذ وإعادة الاستخدام على منصات متعددة مثل Python، MATLAB، وRaspberry Pi.

تنفيذ خوارزمية GMO في بيئة Python

تمت إعادة بناء الخوارزمية الأصلية في بيئة Python ضمن هيكلية معيارية مرنة، ما يسمح بتكاملها بسلاسة مع الأنظمة الذكية والمصنفات الحديثة. يعرض المقتطف التالي البنية العامة للتهيئة وآلية التحديث داخل الحلقة الرئيسية للخوارزمية، كما طبقت في هذا العمل البحثي.

```
def GMO(num_agents, max_iter, train_data, train_label,
        clf_model, obj_function=compute_fitness):
    agents = initialize_agents(num_agents,
                               train_data.shape[1])
    fitness = np.array([obj_function(agent, train_data,
                                     train_label, clf_model) for agent in agents])
    best_agent = agents[np.argmin(fitness)]
    for t in range(max_iter):
        agents = update_positions(agents, best_agent)
    ...
```

كود النظام المدمج على Raspberry Pi

يعرض هذا المقتطف جزءًا من الكود المخصص لتفعيل عملية التصنيف في بيئة Raspberry Pi، اعتمادًا على واجهة مادية تشمل زر ضغط وشاشة OLED يُجسّد هذا التنفيذ التكامل العملي بين الذكاء الاصطناعي والتطبيقات المضمنة، مما يتيح الاستدلال اللحظي على البيانات ضمن نظام ذكي مستقل منخفض الموارد.

```
if GPIO.input(button_pin) == GPIO.HIGH:
    image = capture_image()
    result = model.predict(image)
    display_result(result)
```

تنفيذ اختيار الميزات وتقييم أداء المصنف

يوضح هذا المقتطف كيفية توظيف خوارزمية GMO لاختيار الميزات الأكثر تميزًا من بيانات صور أشعة الصدر، بهدف تحسين كفاءة النماذج التصنيفية. كما يبرز كيفية تقييم أداء المصنف باستخدام مؤشرات إحصائية دقيقة مثل تقارير التصنيف ومنحنيات الدقة (Precision-Recall) لتحديد جودة النموذج الناتج.

```
selected_features = GMO(...)
X_selected = X[:, selected_features]
model.fit(X_selected, y)
y_pred = model.predict(X_selected)
print(classification_report(y, y_pred))
```

مقتطف من خوارزمية PSO (في بيئة MATLAB)

يعرض هذا المقتطف جزءًا من كود خوارزمية الجسيمات (Particle Swarm Optimization - PSO) كما تم تنفيذه في بيئة MATLAB، حيث يُوضّح آلية تحديث المواقع والسرعات للجسيمات خلال عملية البحث. وقد استُخدمت هذه الخوارزمية كمرجعية للمقارنة التجريبية مع خوارزمية GMO من حيث الأداء ودقة النتائج.

```
for i=1:MaxIt
    for j=1:nPop
        particle.Vel = w*particle.Vel + c1*rand()*(pBest -
particle.Pos) + c2*rand()*(gBest - particle.Pos);
        particle.Pos = particle.Pos + particle.Vel;
    end
end
```

يُشار إلى أن جميع الأكواد الكاملة متاحة ضمن المستودع البرمجي للمشروع <https://github.com/Medlimam1/Memoire-de-Master.git>

تم اعتماد المقتطفات أعلاه لأغراض التوضيح والإشارة إلى مساهمات هذا العمل في الجانب البرمجي والتطبيقي