



Université Mohamed Khider de Biskra
Faculté des Sciences et de la Technologie
Département de génie électrique

MÉMOIRE DE MASTER

Sciences et Technologies
electronique
Electronique des systemes embarques
Réf. :

Présenté et soutenu par :
Merabet Abderrahmane

Le :

**Spider wasp optimizer : a novel meta-heuristic
optimization Algorithm, study and application**

Jury :

Dr Sbaa Salim	Pr	Université de Biskra	Président
Dr Abida TOUMI	Pr	Université de Biskra	Encadreur
Dr Baarir Zineedine	Pr	Université de Biskra	Exminateur

Année universitaire : 2024/2025



Université Mohamed Khider de Biskra
Faculté des Sciences et de la Technologie
Département de génie électrique

MÉMOIRE DE MASTER

Sciences et Technologies
Entrez votre filière
Entrez votre spécialité

Réf. : Entrez la référence du document

Spider wasp optimizer : a novel meta-heuristic optimization Algorithm, study and application

Le :

Présenté par :

Merabet Abderrahmane

Avis favorable de l'encadreur :

Abida Toumi

Assistant encadré :

Noureddine Samia

Signature Avis favorable du Président du Jury

Cachet et signature

Handwritten Arabic calligraphy in black ink on a white background. The text is arranged in a circular, stylized format, likely representing the Basmala (Bismillah). The central vertical stroke is prominent, with the word 'Bismillah' written in a highly decorative, cursive style. The letters are thick and black, with small decorative flourishes and dots. The overall composition is balanced and aesthetically pleasing.

إهداء

إلى من أضاءوا درب حياتي بالحب والدعم، وإلى من كانت كلماتهم مصدر إلهامي وسند لي
في كل خطوة.

إلى والدتي العزيزين، اللذين غرسوا فيّ القيم والمبادئ، وأمدوني بالقوة والعزيمة، ورافقوني
في مسيرة الحياة بحبهم وتفانيهم، ودعائهم الذي كان دافعاً لي في كل لحظة.
إلى والدتي الحبيبة، التي علمتني معنى الصبر والتضحية، وكانت ولا تزال مثلاً في الحنان
والعطاء، أهديك ثمرة جهدك ودعواتك.

إلى والدي العزيز، الذي علمني معنى العمل الجاد والإصرار، وكان دائماً يشجعني على
تحقيق أحلامي، أهديك هذا العمل كتعبير بسيط عن امتناني لكل ما قدمته لي.
إلى أساتذتي الكرام، اللذين شكلوا بفكرهم ومعرفتهم قاعدة صلبة لمستقبلي العلمي، واللذين كان
لتوجيهاتهم وإرشاداتهم الأثر الكبير في تطوير مهاراتي وزيادة معرفتي.
إلى أصدقائي الأعزاء، اللذين كانوا رفاق دربي وشركاء النجاح، واللذين شاركوني اللحظات
السعيدة والصعبة، وكانوا دائماً إلى جانبي، أهديك هذا العمل تقديراً لصدقتكم ودعمكم.
إلى كل من كان له دور في رحلتي العلمية، سواء بكلمة تشجيع أو بنصيحة صادقة أو بمساعدة
عملية، أهدي هذا العمل، وأتمنى أن يكون ثمرة تعبكم وجهودكم

شكر و عرفان

الحمد لله الذي بنعمته تتم الصالحات، وبفضله تتوالى الإنجازات. أحمده سبحانه وتعالى على توفيقه وسداده، وأسأله أن يبارك في هذا العمل ويجعله خالصاً لوجهه الكريم.

أتقدم بخالص الشكر والتقدير إلى المشرفة، الأستاذة البروفيسورة تومي عبيدة ، على دعمها وتوجيهاتها القيمة خلال مسيرتي الأكاديمية. لقد كانت نصائحها وإرشاداتها نبراساً أضاء لي

الطريق، وساهمت بشكل كبير في إنجاز هذا العمل.

كما أود أن أعبر عن عميق امتناني لأساتذتي الأفاضل في قسم الهندسة الكهربائية

الذين لم ييخلوا عليّ بعلمهم ومعرفتهم، وقدموا لي الدعم

الأكاديمي والتوجيه اللازم لتحقيق هذا الإنجاز.

إلى والديّ العزيزين، اللذين كانا لي الدعم والسند، واللذين غرسوا فيّ قيم الاجتهاد والمثابرة.

كلمات الشكر لا تكفي للتعبير عن مدى امتناني وحيي لكم. أنتما منبع قوتي وأساس نجاحي.

إلى والدتي الحبيبة، التي كانت ولا تزال مصدر حنان وعطاء لا ينضب، أشكرك من أعماق

قلبي على دعائك المستمر وتضحياتك العظيمة.

إلى والدي العزيز، الذي علمني أن النجاح يأتي من العمل الجاد والتفاني، أشكرك على كل ما

قدمته لي من دعم وتوجيه.

إلى أصدقائي وزملائي، اللذين كانوا لي خير رفاق، وشاركوا معي لحظات الفرح والتعب،

وقدموا لي الدعم النفسي والمعنوي، لكم مني كل الحب والتقدير.

إلى كل من ساهم في هذا العمل من قريب أو بعيد، أقدم لكم شكري وامتناني، سائلاً الله أن

يجزيكم عني خير الجزاء

ملخص

تتناول هذه المذكرة دراسة خوارزمية محسن دبور العنكبوت (Spider Wasp Optimizer – SWO) ، وهي خوارزمية ميتا-استكشافية حديثة مستوحاة من السلوك الطبيعي لدبابير العنكبوت الإناث في الصيد، الملاحقة، التعشيش، والتزاوج. تهدف هذه الدراسة إلى عرض المبادئ الأساسية للخوارزمية، وآلياتها الرياضية، ومراحل عملها التي تجمع بين الاستكشاف والاستغلال.

خُصص الفصل الأول لتقديم نظرة عامة حول الخوارزميات الميتا-استكشافية، وتصنيفها، وخصائصها العامة، إضافة إلى مجالات استخدامها، خصوصاً في الذكاء الاصطناعي والتحكم.

تم في الفصل الثاني تقديم وصف تفصيلي لخوارزمية SWO من حيث الدافع البيولوجي، والبنية الرياضية، والخطوات المنهجية لتطبيقها، مع تسليط الضوء على آليات البحث والاستغلال.

أما الفصل الثالث فشمل الجانب التطبيقي، حيث تم تقييم أداء SWO باستخدام مجموعتين من دوال الاختبار القياسية) مجموعة 2005، ومجموعة (CEC 2019 ، وتمت مقارنتها مع عدد من الخوارزميات الحديثة مثل : EO ، SMA ، GWO ، PSO ، MPA ، GNDO ، وذلك باستخدام مؤشرات معيارية تشمل : أفضل قيمة، المتوسط، والانحراف المعياري.

أظهرت النتائج أن خوارزمية SWO تقدم أداءً تنافسيًا، خاصة في الوظائف المعقدة متعددة القمم، بفضل قدرتها على الاستغلال، لكنها قد تستفيد من تطوير آليات الاستكشاف في بعض الحالات.

كما تم توظيف SWO في تحسين معاملات المتحكم PID لنظام ميكانيكي (كتلة-مخمد-نابض)، مما أدى إلى تحسين الاستجابة الزمنية وتقليل الخطأ. وتم أيضاً استخدامها في تحسين المسارات (Path Planning) لزيارة مواقع أعطال موزعة عشوائياً، حيث تفوقت على خوارزميات مثل GWO والترتيب العشوائي من حيث تقليل المسافة الإجمالية.

تؤكد هذه النتائج فعالية SWO في حل مسائل تحسين متنوعة، سواءً على مستوى الاختبارات القياسية أو التطبيقات الواقعية.

الكلمات المفتاحية:

خوارزمية SWO ، تخطيط المسارات، متحكم PID ، خوارزميات التحسين، مقارنة GWO ، منحني التقارب

Résumé

Ce mémoire présente une étude approfondie de l'algorithme Spider Wasp Optimizer (SWO), un algorithme métaheuristique récent inspiré du comportement naturel des guêpes chasseuses d'araignées. L'objectif principal est d'analyser le fonctionnement de cette méthode à travers ses bases biologiques, sa modélisation mathématique et ses mécanismes opérationnels, notamment les phases d'exploration, de poursuite, de nidification et de reproduction. Le travail débute par une présentation générale des algorithmes métaheuristiques, leurs catégories principales (physiques, évolutionnaires, essaims, humains), ainsi que leurs domaines d'application dans le traitement des problèmes d'optimisation complexes. Ensuite, l'algorithme SWO est détaillé au niveau théorique, en mettant en évidence ses opérateurs de recherche et sa capacité à équilibrer l'exploration globale et l'exploitation locale. L'étude expérimentale consiste à appliquer SWO sur deux ensembles standards de fonctions tests, à savoir la suite de 2005 et le benchmark CEC 2019, et à le comparer avec des algorithmes récents tels que EO, SMA, MPA, GWO, GNDO, en se basant sur des métriques de performance telles que la meilleure solution, la moyenne et l'écart type. Par ailleurs, l'algorithme a été appliqué à deux cas pratiques : l'optimisation des paramètres d'un contrôleur PID dans un système masse–ressort–amortisseur, et la planification de trajectoires pour visiter des points d'erreurs générés aléatoirement. Les résultats obtenus démontrent que SWO présente des performances compétitives, particulièrement dans les fonctions à multiples optima, et qu'il constitue une solution efficace et prometteuse tant pour les problèmes théoriques que pour les applications réelles.

Mots-clés :

Algorithme SWO, Planification des trajets, Régulateur PID, Algorithmes d'optimisation, Comparaison avec GWO, Courbe de convergence.

SUMMARY

This thesis presents an in-depth study of the Spider Wasp Optimizer (SWO), a recent metaheuristic algorithm inspired by the natural behavior of female spider wasps during hunting, nesting, and mating. The primary objective is to analyze the algorithm's operational mechanisms, biological foundations, and mathematical modeling, with a focus on its exploration, pursuit, nesting, and reproduction phases. The work begins with a general overview of metaheuristic algorithms, including their major classifications (physics-based, evolutionary, swarm-based, and human-based), and their relevance in solving complex optimization problems. The SWO algorithm is then detailed theoretically, emphasizing its search operators and its ability to balance global exploration with local exploitation. The experimental part involves evaluating the performance of SWO on two standard sets of benchmark functions, namely the 2005 test suite and the CEC 2019 benchmark, and comparing it with recent algorithms such as EO, SMA, MPA, GWO, and GNDO using performance metrics like best value, average, and standard deviation. Furthermore, SWO is applied to two real-world scenarios: optimizing PID controller parameters in a mass–spring–damper system, and planning paths to visit randomly distributed fault locations. The results demonstrate that SWO delivers competitive performance, especially in complex multimodal functions, and confirms its efficiency and robustness in both theoretical optimization tasks and practical engineering applications.

Keywords:

SWO Algorithm, Path Planning, PID Controller, Optimization Algorithms, GWO Comparison, Convergence Curve.

قائمة الأشكال :

الشكل II.1 : دبور أثناء البحث عن الفريسة

الشكل II.2 : دبور أثناء عملية هجوم [16]

الشكل II.3 : عنكبوت مشلول يسحب من طرف دبور للعش

الشكل II.4 : جنس وشكل دبور (wasp pompilidae)

الشكل II.5 : العلاقة بين السلوكيات الطبيعية لخوارزمية دبور العنكبوت (SWO) وتطبيقها في الخوارزمية

الشكل III.1 : المخطط الانسيابي لخوارزمية (SWO) Spider Wasp Optimizer.

الشكل III.2 : منحنيات التقارب التي تم الحصول عليها باستخدام طريقة SWO والعديد من الطرق الاستدلالية مع وظائف الاختبار أحادية النمط عالية الأبعاد.

الشكل III.3 : منحنيات التقارب التي تم الحصول عليها باستخدام طريقة SWO والعديد من طرق التحليل الفوقي مع وظائف الاختبار متعددة الوسائط عالية الأبعاد 2005.

الشكل III.4 : منحنيات التقارب التي تم الحصول عليها باستخدام طريقة SWO والعديد من الطرق الاستدلالية مع وظائف الاختبار منخفضة الأبعاد متعددة الوسائط 2005.

الشكل III.5 : منحنيات التقارب التي تم الحصول عليها باستخدام طريقة SWO والعديد من الطرق الاستدلالية مع وظائف الاختبار 2019.

الشكل III.6 : نموذج كتلة-نابض-مخمّد (Mass-Spring-Damper system).

الشكل III.7 : نموذج Simulink للنظام بدون متحكم PID

الشكل III.8 : رسم استجابة النظام بدون متحكم PID

الشكل III.9 : نموذج Simulink للنظام بوجود متحكم PID

الشكل III.10 : رسم استجابة النظام بوجود متحكم PID

الشكل III.11 : نموذج Simulink للنظام بوجود متحكم PID

الشكل III.12 : رسم استجابة النظام بعد تحسين معاملات PID

الشكل III.13 : رسم استجابة النظام في 3 حالات

الشكل 14. III : منحنى تقارب خوارزمية SWO

الشكل 15. III : مواقع الأعتال العشوائية

الشكل 16. III : أفضل مسار باستخدام SWO

الشكل 17. III : أفضل مسار باستخدام GWO

الشكل 18. III : مقارنة بين المسافات الكلية الناتجة عن الطرق الثلاث (SWO، GWO، و الترتيب العشوائي).

قائمة الجداول :

الجدول I.1 :أنواع دوال الهدف

الجدول I.2 :أنواع القيود

الجدول I.3 :أنواع فضاء البحث

الجدول I.4 : مقارنة عامة بين الخوارزميات التقليدية والطبيعية

الجدول I.5 : أمثلة ومقارنة خوارزميات التحسين التقليدية

الجدول I.6 : أمثلة ومقارنة خوارزميات التحسين الطبيعية

الجدول I.7 : أمثلة ومقارنة خوارزميات التحسين الهجينة

الجدول I.8 : مقارنة شاملة للخوارزميات

الجدول III.1: دوال الاختبار (F01 إلى F07)

الجدول III.2 : الدوال المعيارية (F08 إلى F13)

الجدول III.3: دوال المقارنة المرجعية (F14 إلى F23)

الجدول III.4 وظائف المعايير المرجعية لعام 2019

الجدول III.5 نتائج SWO وغيرها من الخوارزميات الفوقية للوظيفة متعددة الوسائط عالية الأبعاد على 23

دالة اختبار تقليدية ضمن مجموعة وظائف 2005 القياسية

الجدول III.6 نتائج SWO وغيرها من الخوارزميات الفوقية للوظيفة متعددة الوسائط عالية الأبعاد على 10

دوال اختبار حديثة من مجموعة CEC-C06 لعام 2019

الجدول III.7 قيم المتحكمات قبل وبعد التحسين

الجدول III.8 قيم الأداء قبل وبعد التحسين

الجدول III.9 نتائج مسافات الطرق الثلاث

قائمة الاختصارات :

- PSO : Particle Swarm Optimization
- ABC : Artificial Bee Colony
- SA : Simulated Annealing
- GA : Genetic Algorithm
- GD : Gradient Descent
- LP : Linear Programming
- NLP : Nonlinear Programming
- DE : Differential Evolution
- EO : Equilibrium Optimizer
- GNDO : Generalized Normal Distribution Optimization
- MRFO : Manta Ray Foraging Optimization
- MPA : Marine Predator Algorithm
- SMA : Slime Mould Algorithm
- HHO : Harris Hawks Optimization
- PFA : Path Finder Algorithm
- JS : Jellyfish Search
- PID : Proportional-Integral-Derivative controller
- CEC : Congress on Evolutionary Computation
- GWO : Grey Wolf Optimizer

الفهرس

1	المقدمة
2	الفصل الأول : خوارزميات التحسين العامة
2	General optimization algorithm
3	1.I- مقدمة حول خوارزميات التحسين:
3	1.1.I-تعريف خوارزميات التحسين:
3	2.1.I-خصائص خوارزميات التحسين:
3	3.1.I-أهمية خوارزميات التحسين:
3	4.1.I-أهمية التحسين في المجالات المختلفة:
3	1.4.1.I-في الهندسة والتصميم الصناعي:
4	2.4.1.I-في تحليل البيانات والأنظمة الرقمية:
4	3.4.1.I-في الاقتصاد والإدارة:
4	4.4.1.I-في مجال النقل والخدمات اللوجستية:
4	5.4.1.I-في الرعاية الصحية:
4	6.4.1.I-في شبكات الاتصال والمعلومات:
4	7.4.1.I-في الطاقة والبيئة:
4	8.4.1.I-في التمويل والاستثمار:
5	2.I-التصنيف العام لخوارزميات التحسين:
5	1.2.I-التصنيف حسب طبيعة البحث:
5	2.2.I-التصنيف حسب نطاق الحل:
6	3.2.I-التصنيف حسب الاعتماد على التدرج:
6	4.2.I-التصنيف حسب آلية البحث:
6	3.I-مفاهيم أساسية في التحسين:
6	1.3.I-دالة الهدف (Objective Function)

7.....	2.3.I- القيود (Constraints)
8.....	3.3.I- فضاء البحث (Search Space)
8.....	4.3.I- أنواع الحلول في التحسين:
9.....	4.I- مقارنة بين الخوارزميات التقليدية والخوارزميات الطبيعية:
9.....	1.4.I- الخوارزميات التقليدية (Classical Optimization Algorithms)
9.....	2.4.I- الخوارزميات الطبيعية (Nature-Inspired Algorithms)
10.....	5.I- مقارنة بين أنواع خوارزميات التحسين: المزايا، العيوب، والاستخدامات
10.....	5.1.I- خوارزميات التحسين التقليدية (Classical Optimization Algorithms)
11.....	2.5.I- خوارزميات التحسين الطبيعية (Nature-Inspired Algorithms)
12.....	3.5.I- خوارزميات التحسين الهجينة (Hybrid Optimization Algorithms)
12.....	4.5.I- ملخص مقارن شامل
13.....	6.I- الخاتمة:
14.....	الفصل الثاني: خوارزمية محسن دبور العنكبوت
14.....	Spider wasp optimizer algorithms
15.....	1.II- مقدمة حول خوارزمية محسن دبور العنكبوت (SWO):
15.....	1.1.II- الدافع وراء تطوير الخوارزمية:
15.....	2.1.II- أهمية خوارزمية SWO في التحسين:
16.....	2.II- نظرة عامة على دبابير العنكبوت وسلوكها
16.....	1.2.II- لمحة عن دبابير العنكبوت:
16.....	2.2.II- السلوكيات الفريدة لدبابير العنكبوت:
16.....	1.2.2.II- البحث عن الفريسة (Hunting & Foraging)
17.....	2.2.2.II- ملاحقة الفريسة والهجوم (Chasing & Hunting)
17.....	3.2.2.II- التعشيش ووضع البيض (Nesting & Egg Laying)
18.....	4.2.2.II- العناية باليرقات ونموها (Larval Development)
18.....	5.2.2.II- التزاوج وإنتاج الجيل الجديد (Mating & Reproduction)
18.....	3.2.II- العلاقة بين السلوكيات الطبيعية لخوارزمية دبور العنكبوت (SWO) وتطبيقها في الخوارزمية:
19.....	3.II- المبادئ الأساسية لخوارزمية محسن دبور العنكبوت (SWO)
20.....	1.3.II- التهيئة العشوائية للحلول (Initialization of Solutions)
20.....	2.3.II- مرحلة البحث والاستكشاف (Exploration Phase)
21.....	3.3.II- مرحلة الملاحقة والتحديث (Chasing & Exploitation Phase)

21.....	4.3.II-مرحلة التعشيش وتحسين الحلول (Nesting & Optimal Solution Construction)
22.....	5.3.II-مرحلة التزاوج وإنتاج الجيل الجديد (Mating & New Generation Production)
23.....	6.3.II-آلية التحديث وتقليل عدد السكان (Update & Population Reduction Mechanism)
23	4.II-النموذج الرياضي لخوارزمية SWO
24.....	1.4.II-المتغيرات والمعادلات الأساسية
24.....	2.4.II-تمثيل حركة الدبابير في فضاء البحث
25.....	3.4.II-محاكاة التعشيش والتزاوج رياضياً
25.....	4.4.II-آلية تقليل عدد السكان
26.....	5.II- الخاتمة :
27	الفصل الثالث : تنفيذ خوارزمية « SWO »
28.....	1.III-مقدمة :
	2.III- تنفيذ خوارزمية (SWO) Spider Wasp Optimizer على دوال الاختبار القياسية 2005 و2019.
30.....	1.2.III دوال الاختبار لعام 2005:
31.....	1.1.2.III دوال أحادية القمة وعالية الأبعاد:(F01-F07)
33.....	2.1.2.III الدوال متعددة الأنماط عالية الأبعاد (F08-F13):
35.....	3.1.2.III الدوال منخفضة الأبعاد متعددة الوسائط (F14-F23):
37.....	4.1.2.III مناقشة النتائج '1':
37.....	2.2.III وظائف الاختبار 2019:
38.....	1.2.2.III تطبيق خوارزمية SWO على مجموعة دوال 2019
39.....	2.2.2.III مناقشة النتائج '2':
39.....	1. الوظائف التي تفوقت فيه SWO :
40.....	2. الوظائف التي أظهرت فيها SWO أداءً ضعيفاً نسبياً:
49.....	3.III تحليل أداء خوارزمية SWO:
50.....	4.III تطبيق خوارزمية SWO على متحكم PID لتحسين معاملاته :
50.....	1.4.III- الجزء لنظري :نظام الكتلة-المخمّد-النابض(Mass-Damper-Spring System)
50.....	1.1.4.III-تعريف النظام:
51.....	2.1.4.III-المعادلة التفاضلية للنظام:
52.....	2.4.III- الجزء التطبيقي :
57.....	1.2.4.III-التحليل:

59	5.III تطبيق خوارزميات التحسين الذكية في جدولة التدخلات التقنية
59	1.5.III مقدمة
59	2.5.III توصيف المشكلة الميدانية
60	3.5.III خوارزمية الذئب الرمادي (GWO)
60	4.5.III إعداد النموذج والمحاكاة
61	5.5.III عرض النتائج
61	1.5.5.III الرسومات التوضيحية
63	2.5.5.III نتائج المسافات المقطوعة لثلاث الطرق
64	6.5.III تحليل النتائج
65	7.5.III خاتمة جزئية
66	6.III الخاتمة :
67	الخاتمة
68	المراجع :

المقدمة

تُعد خوارزميات التحسين الميتا-استكشافية من الأدوات الحسابية الفعالة والمرنة التي أحدثت نقلة نوعية في مختلف المجالات الهندسية والصناعية، نظرًا لقدرتها على معالجة مسائل تحسين معقدة تتسم بالطبيعة غير الخطية والتعدد في الأبعاد والقيود. وقد شهد هذا المجال تطورًا كبيرًا من خلال بروز العديد من الخوارزميات المستوحاة من الطبيعة، والتي تحاكي سلوك الكائنات الحية في التفاعل مع البيئة والبحث عن الغذاء أو النجاة، مثل خوارزميات أسراب الطيور، مستعمرات النحل، الذئاب، وغير ذلك.

من بين الخوارزميات الحديثة التي برزت في هذا السياق، نجد خوارزمية محسن دبور العنكبوت (**Spider Wasp Optimizer – SWO**)، وهي مستوحاة من سلوك دبابير العنكبوت الإناث في مراحل الصيد، والمطاردة، والتعشيش، والتزاوج. وتُعد هذه الخوارزمية محاولة جديدة لتحقيق توازن فعال بين عمليتي الاستكشاف والاستغلال، من خلال مجموعة من الآليات الذكية التي تتيح لها القدرة على البحث في فضاء الحلول واختيار أفضلها دون الوقوع في الحلول المحلية.

تهدف هذه المذكرة إلى دراسة خوارزمية SWO من خلال جانبين:

جانب نظري يتم فيه عرض المفاهيم الأساسية وآلية عمل الخوارزمية والنموذج الرياضي المرافق لها.

وجانب تطبيقي يشمل اختبار أدائها على مجموعتين من دوال الاختبار القياسية (F1–F23) لسنة 2005 و(CEC2019)، إضافة إلى تطبيقها على مسائل واقعية تشمل: تحسين معاملات متحكم PID لنظام كتلة-نابض-مخمّد، وتحسين المسارات لزيارة مواقع أعطال موزعة عشوائيًا.

كما تشمل الدراسة مقارنة دقيقة لنتائج خوارزمية SWO مع عدد من الخوارزميات الحديثة الأخرى مثل EO، SMA، MPA، GNDO، PSO، GWO، وذلك باستخدام مؤشرات تقييم مثل: أفضل قيمة (Best Value)، المتوسط (Mean)، والانحراف المعياري (STD).

تُبرز النتائج المتحصل عليها قدرة خوارزمية SWO على تحقيق أداء تنافسي في وظائف اختبار معقدة، فضلًا عن فعاليتها في تطبيقات حقيقية مثل التحكم في الأنظمة وتحسين تخطيط المسارات، مما يؤكد إمكانيتها كأداة قوية في مجال التحسين الذكي.

الفصل الأول

خوارزميات التحسين العامة

General optimization algorithm

1.1.I- مقدمة حول خوارزميات التحسين:**1.1.1- تعريف خوارزميات التحسين:**

خوارزميات التحسين تمثل مجموعة من الأدوات والتقنيات التي تُستخدم لإيجاد أفضل حل ممكن لمشكلة معينة، مع الأخذ بعين الاعتبار قيودًا ومعايير محددة. وتُعد هذه الخوارزميات ضرورية في معالجة العديد من المشكلات الواقعية التي تتطلب تحقيق توازن بين أهداف متعددة، مثل تقليل التكاليف، زيادة الفعالية، أو تحسين الأداء ضمن بيئات معقدة ومتغيرة [1].

2.1.1- خصائص خوارزميات التحسين:

- وجود دالة هدف (Objective Function): وهي الدالة التي يتم تقييم جودة الحل بناءً عليها، إذ تسعى الخوارزمية إما لتعظيمها أو تصغيرها حسب طبيعة المسألة.
- احترام القيود (Constraints): تتعامل خوارزميات التحسين مع مجموعة من الشروط التي تقيد قيم الحلول المقترحة ضمن حدود مقبولة.
- استراتيجية بحث محددة (Search Strategy): تعتمد كل خوارزمية على آلية معينة لاستكشاف فضاء البحث واختيار الحلول الأفضل تدريجيًا.
- آلية تقييم ومقارنة (Evaluation Mechanism): تُقيم الحلول بناءً على معيار أو مجموعة معايير لاختيار الأنسب، مع إمكانية التكرار للوصول إلى نتائج محسنة [2].

3.1.1- أهمية خوارزميات التحسين:

- تحسين كفاءة الأنظمة الصناعية والإنتاجية:
- تُستخدم لتحسين ترتيب المهام وتقليل استهلاك الموارد في خطوط الإنتاج.
- خفض التكاليف التشغيلية:
- تسهم في تقليل الإنفاق في مجالات مثل النقل واللوجستيات والطاقة.
- تعزيز دقة النماذج الذكية:
- من خلال ضبط المعلمات في خوارزميات التعلم الآلي لزيادة دقة النتائج.
- إيجاد حلول للمشكلات المعقدة:
- تستخدم في حل مسائل مثل الجدولة، تخصيص الموارد، وتحليل البيانات الضخمة [2].

4.1.1- أهمية التحسين في المجالات المختلفة:**1.4.1.1- في الهندسة والتصميم الصناعي:**

- يساهم التحسين في تطوير النماذج الهندسية من خلال تقليل استهلاك المواد وتحسين كفاءة التصميم.
- يساعد في ضبط عمليات الإنتاج للحصول على مخرجات ذات جودة عالية بتكاليف أقل.
- يُستخدم في ضبط معايير الأمان، الوزن، والمتانة ضمن تصميمات معقدة.

2.4.1.I- في تحليل البيانات والأنظمة الرقمية:

- يُستخدم التحسين في اختيار المعايير المؤثرة للحصول على نتائج دقيقة وفعالة.
- يلعب دورًا حيويًا في تقليل الخطأ وتحسين موثوقية النتائج المستخرجة من البيانات.
- يُستخدم في ضبط خوارزميات النمذجة وتحسين سرعة الوصول للحلول المقبولة.

3.4.1.I- في الاقتصاد والإدارة:

- ❖ يُساهم في تحسين توزيع الموارد وتحقيق أقصى استفادة منها.
- ❖ يُستخدم في تحسين قرارات التسعير وتقليل النفقات التشغيلية.
- ❖ يساهم في تنظيم الجداول الزمنية للموظفين بطريقة تقلل الهدر.

4.4.1.I- في مجال النقل والخدمات اللوجستية:

- ❖ يُستخدم في تحديد المسارات المثلى لنقل السلع والخدمات بأقل تكلفة.
- ❖ يساعد على تقليل استهلاك الوقود والوقت اللازم للتوصيل.
- ❖ يُوظف في تحسين إدارة المستودعات وسلاسل الإمداد.

5.4.1.I- في الرعاية الصحية:

- يُساهم في جدولة العمليات وتخصيص الموارد الطبية بشكل فعال.
- يُستخدم في تصميم خطط علاج مخصصة بناءً على مؤشرات المريض.
- يُساعد في تحسين توزيع المعدات والأسرة الطبية ضمن المستشفيات.

6.4.1.I- في شبكات الاتصال والمعلومات:

- تُستخدم خوارزميات التحسين لتقليل التداخل بين إشارات الشبكات.
- تساعد على توزيع الموارد الشبكية بطريقة ديناميكية وفقًا للحاجة.
- تساهم في تقليل استهلاك الطاقة وتحسين جودة الخدمة.

7.4.1.I- في الطاقة والبيئة:

- ✓ تُستخدم في تحديد مواقع محطات الطاقة المتجددة لتحقيق أقصى إنتاجية.
- ✓ تساعد على تقليل الفاقد في شبكات المياه والكهرباء.
- ✓ تساهم في تحسين كفاءة استخدام الطاقة في البنية التحتية.

8.4.1.I- في التمويل والاستثمار:

- تُستخدم في بناء محافظ استثمارية متوازنة تضمن العائد وتقلل المخاطر.
- تساعد على تحليل السيناريوهات المالية واختيار الخطط الأمثل.
- تُستخدم أيضًا في تقييم وتحسين قرارات التمويل والتسعير. [2]

2.I-التصنيف العام لخوارزميات التحسين:**1.2.I-التصنيف حسب طبيعة البحث:****أ. خوارزميات حتمية (Deterministic Optimization)**

- تعتمد على خطوات رياضية واضحة ومحددة مسبقاً للوصول إلى الحل.
- تعطي نفس النتيجة عند تطبيقها على نفس البيانات.
- فعالة للمسائل البسيطة أو التي يمكن تمثيلها رياضياً بدقة.

أمثلة:

البرمجة الخطية – البرمجة الديناميكية – طرق التدرج.

ب. خوارزميات عشوائية (Stochastic Optimization)

- تستخدم مكونات عشوائية في عملية البحث عن الحلول.
- قد تنتج حلولاً مختلفة في كل مرة تُشغّل فيها.
- مناسبة للمشاكل غير المحددة أو ذات طبيعة معقدة.

أمثلة:

الأساليب التطورية – محاكاة التلدين – خوارزمية أسراب الجسيمات.[3]

2.2.I-التصنيف حسب نطاق الحل:**أ. خوارزميات التحسين المحلي (Local Optimization)**

- ✓ تركز على تحسين الحل ضمن منطقة ضيقة من فضاء البحث.
- ✓ قد تتوقف عند حل محلي دون الوصول للحل الأفضل عالمياً.

أمثلة:

خوارزمية التدرج – البحث الجشع.

ب. خوارزميات التحسين العالمي (Global Optimization)

- ✓ تهدف إلى استكشاف جميع أجزاء فضاء البحث لإيجاد أفضل حل ممكن.
- ✓ تُستخدم عادة لحل مشكلات ذات طبيعة غير خطية أو متعددة النقاط المثلى.

أمثلة:

خوارزميات تطورية – أسراب الجسيمات – البحث المتوهج.[4]

3.2.I-التصنيف حسب الاعتماد على التدرج:**أ. خوارزميات تعتمد على التدرج (Gradient-Based)**

- ✓ تستخدم المشتقات لتحديد اتجاه التحسين.
- ✓ فعالة للمسائل القابلة للاشتقاق لكنها غير مناسبة للدوال غير السلسة أو المنفصلة.

أمثلة:

الانحدار العشوائي – خوارزمية نيوتن.

ب. خوارزميات لا تعتمد على التدرج (Gradient-Free)

- ✓ لا تحتاج لحساب المشتقات، وتستخدم في حالات الدوال المعقدة أو غير القابلة للاشتقاق.
- ✓ تعتمد غالباً على التقييم العددي أو الاستكشاف العشوائي.

أمثلة:

الخوارزميات الجينية – البحث العشوائي.[5]

4.2.I-التصنيف حسب آلية البحث:**أ. خوارزميات تقليدية (Classical Optimization)**

- * تعتمد على نماذج رياضية ومعادلات تحليلية.
- * فعالة في المشكلات ذات التركيب البسيط والصيغة الرياضية المحددة.

أمثلة:

البرمجة الخطية – البرمجة غير الخطية.

ب. خوارزميات ميتا-يورستية (Metaheuristic Algorithms)

- * تستخدم آليات ذكية مستوحاة من الظواهر الطبيعية أو السلوكية.
- * فعالة في استكشاف فضاءات بحث كبيرة ومعقدة.

أمثلة:

خوارزمية أسراب الجسيمات (PSO) – خوارزمية النحل (ABC) – خوارزمية البحث المتوهج (SA) [6] .

3.I- مفاهيم أساسية في التحسين:**1.3.I- دالة الهدف (Objective Function)**

تُعد دالة الهدف العنصر المركزي في أي نموذج تحسين، حيث تعبر عن القيمة التي يسعى النظام إلى تحسينها، إما بالتعظيم أو التصغير. تعتمد جودة نتائج الخوارزمية بشكل مباشر على مدى دقة هذه الدالة في تمثيل الهدف الحقيقي للمشكلة [7] .

الجدول 1. I: أنواع دوال الهدف

النوع	الوصف	مثال رياضي
خطية (Linear)	تأخذ شكلاً رياضياً بسيطاً من الدرجة الأولى	$f(x)=3x+5$
غير خطية (Nonlinear)	تشمل حدوداً تربيعية أو دوال مثل الجذر، الجيب	$f(x)=x^2+\sin(x)$
مستمرة (Continuous)	تقبل متغيرات حقيقية ضمن مجال محدد	$f(x)=x^2-4x+1$
منفصلة (Discrete)	تأخذ قيماً صحيحة أو منتهية فقط	حيث $f(x) = x_1 + 2x_2$ $\{1, 0\} \ni x_i$
أحادية الهدف (Single objective)	تسعى لتحسين هدف واحد فقط.	تقليل التكلفة أو الزمن فقط
متعددة الأهداف (Multi-objective)	تهدف إلى تحسين أكثر من هدف في آن واحد	تقليل التكلفة وزيادة الجودة في آن واحد

2.3.I- القيود (Constraints)

القيود هي الشروط التي يجب أن تحققها الحلول لتكون صالحة، وقد تكون على شكل مساواة، عدم مساواة، أو حدود على المتغيرات. تمثل هذه القيود القيود الفيزيائية أو الاقتصادية أو التقنية التي تفرضها بيئة التطبيق، وتؤثر مباشرة على شكل فضاء البحث المتاح [7].

الجدول 2. I: أنواع القيود

نوع القيد	الوصف	مثال رياضي
قيود مساواة	تفرض أن العلاقة بين المتغيرات يجب أن تكون مساوية لقيمة معينة.	$x+y=10$
قيود عدم مساواة	تفرض أن تكون العلاقة بين المتغيرات أصغر أو أكبر من قيمة معينة.	$x+y \leq 20$
قيود حدود	تحدد الحدود الدنيا والعليا المسموح بها للمتغيرات.	$0 \leq x \leq 100$
قيود منطقية/شرطية	تفرض شروطاً تعتمد على القيم الأخرى	إذا استخدم x ، لا يُستخدم y

I.3.3-فضاء البحث (Search Space)

فضاء البحث هو النطاق الكامل لجميع الحلول الممكنة لمسألة التحسين. ويتحدد هذا الفضاء بناءً على عدد المتغيرات ونوعها والقيود المفروضة. وكلما زادت أبعاد هذا الفضاء، زادت صعوبة استكشافه، الأمر الذي يفرض تحديات كبيرة على الخوارزميات المستخدمة [8].

- الحجم (Size) كلما زاد عدد المتغيرات والقيود، زاد حجم فضاء البحث بشكل أسي، مما يزيد من صعوبة استكشافه بالكامل، خاصة في المشكلات المعقدة أو ذات الأبعاد العالية.
- الطبيعة (Nature) يمكن أن يكون الفضاء مستمرًا، حيث تأخذ المتغيرات قيمًا حقيقية ضمن مجالات محددة، أو منفصلاً، حيث تقتصر القيم على أعداد صحيحة أو خيارات محددة. بعض المسائل تجمع بين النوعين فيما يُعرف بالفضاء المختلط.
- التعقيد (Complexity) قد يحتوي فضاء البحث على نقاط محلية مثالية متعددة أو مناطق غير قابلة للاستكشاف بسهولة، مما يصعب الوصول إلى الحل الأمثل العام.
- القيود (Constraints) بعض المناطق في الفضاء قد تكون غير صالحة بسبب مخالفتها للقيود المفروضة على المتغيرات، مما يقلص حجم الجزء الفعّال من الفضاء الذي يجب استكشافه [8].

I.3. أنواع فضاء البحث

النوع	الوصف	مثال
مستمر (Continuous)	يحتوي على عدد غير محدود من القيم بين حدين.	تحديد أبعاد تصميم معين بدقة عالية.
منفصل (Discrete)	يحتوي على عدد محدود من القيم الممكنة.	اختيار عدد معين من العمال لمهمة.
مختلط (Mixed)	يحتوي على متغيرات مستمرة ومنفصلة معًا.	تحسين تصميم يحتوي على متغيرات عددية ومنطقية.

I.3.4-أنواع الحلول في التحسين:

تُصنف الحلول في مسائل التحسين حسب مدى قربها من الحل الأمثل ومدى تحقيقها للقيود، ويمكن تلخيصها كما يلي:

أنواع الحلول:

*** حل مقبول (Feasible Solution)**

هو أي حل يحقق جميع القيود المحددة للمسألة دون ضمان كونه الأفضل من حيث دالة الهدف. يُمثل نقطة انطلاق أساسية قبل البحث عن حلول أمثل.

- ✳ حل أمثل محليًا (Local Optimum) هو الحل الأفضل ضمن نطاق معين من فضاء البحث، حيث لا توجد حلول أفضل منه مباشرة ضمن هذا المجال، لكنه قد لا يكون الأفضل على مستوى الفضاء الكامل.
- ✳ حل أمثل عالميًا (Global Optimum) هو الحل الذي يعطي أفضل قيمة ممكنة لدالة الهدف على كامل فضاء البحث، ويُعد الهدف الأساسي لمعظم خوارزميات التحسين.
- ✳ حل شبه أمثل (Sub-optimal Solution) هو حل قريب من الأمثل، يُقبل غالبًا عندما يكون الوصول إلى الحل الأمثل صعبًا أو مكلفًا من حيث الزمن أو الموارد، ويُستخدم بكثرة في التطبيقات العملية [8].

I.4- مقارنة بين الخوارزميات التقليدية والخوارزميات الطبيعية:

I.4.1- الخوارزميات التقليدية (Classical Optimization Algorithms)

تعتمد الخوارزميات التقليدية على أسس رياضية صريحة، مثل اشتقاق الدوال وتحليل القيود والمعادلات الخطية أو غير الخطية. وتُستخدم غالبًا لحل المشكلات التي يمكن تمثيلها بصيغ محددة وواضحة. تتسم هذه الخوارزميات بالسرعة والدقة إذا توافرت الشروط الرياضية الملائمة، لكنها قد تفشل في مواجهة المشكلات المعقدة ذات الطبيعة غير المحددة أو عالية الأبعاد. [3]

✚ خصائص رئيسية:

تعتمد على مشتقات دوال الهدف. وتصل إلى الحلول بدقة عند توفر الشروط التحليلية المناسبة. أداؤها يتراجع في حالة وجود دوال غير قابلة للاشتقاق أو قيود غير خطية معقدة.

أمثلة:

- البرمجة الخطية (Linear Programming – LP)
- البرمجة غير الخطية (Nonlinear Programming – NLP)
- طريقة التدرج (Gradient Descent)
- طريقة نيوتن (Newton's Method) [3]

I.4.2- الخوارزميات الطبيعية (Nature-Inspired Algorithms)

الخوارزميات الطبيعية تستلهم سلوكها من الأنظمة الحيوية والفيزيائية، مثل التطور البيولوجي، سلوك الجماعات، أو الظواهر الطبيعية. لا تعتمد هذه الخوارزميات على الاشتقاق أو التحليل الدقيق للدوال، ما يجعلها مناسبة لحل مشكلات معقدة ذات فضاءات بحث واسعة وغير خطية، كما أنها تُظهر قدرة عالية على الهروب من الحلول المحلية والعثور على حلول شبه مثالية أو عالمية [3].

✚ خصائص رئيسية:

لا تحتاج إلى اشتقاق دالة الهدف. وتعتمد على البحث العشوائي الموجه أو على محاكاة طبيعية. فعالة في استكشاف فضاءات البحث المعقدة، لكنها قد تحتاج وقتًا حسابيًا أطول.

أمثلة:

- خوارزميات أسراب الجسيمات (PSO)
- الخوارزميات الجينية (GA)
- محاكاة التلدين (SA)
- خوارزمية الدبابير (SWO) [3]

الجدول I . 4 : مقارنة عامة بين الخوارزميات التقليدية والطبيعية

المعيار	الخوارزميات التقليدية	الخوارزميات الطبيعية
آلية العمل	تعتمد على النماذج الرياضية والتحليلية	تحاكي الظواهر البيولوجية أو الفيزيائية
الحاجة للاشتقاق	ضرورية	غير ضرورية
الأداء في المشكلات المعقدة	محدود في المسائل غير الخطية أو غير المحددة	فعالة جدًا
سرعة التنفيذ	سريعة في المسائل الخطية	أبطأ نسبيًا بسبب طبيعة البحث العشوائي
احتمالية الوصول للحل العام	منخفضة (تقع في الحل الخاصة)	مرتفعة نسبيًا بفضل الاستكشاف الواسع
سهولة التنفيذ	تتطلب خلفية رياضية قوية	مرنة وسهلة البرمجة نسبيًا

I.5- مقارنة بين أنواع خوارزميات التحسين: المزايا، العيوب، والاستخدامات

I.5.1- خوارزميات التحسين التقليدية (Classical Optimization Algorithms)

تعتمد هذه الفئة من الخوارزميات على نماذج تحليلية رياضية واضحة، وتستخدم لحل المسائل التي يمكن تمثيلها من خلال معادلات خطية أو غير خطية محددة. تمتاز بقدرتها على تقديم حلول دقيقة عند توافر الشروط المناسبة، إلا أن فعاليتها تتراجع عند التعامل مع مشكلات غير خطية أو معقدة [9].

الجدول I. 5 : أمثلة ومقارنة خوارزميات التحسين التقليدية

الخوارزمية	المزايا	العيوب	الاستخدامات المثلى
الانحدار المتناقص (GD)	-فعال في الدوال القابلة للاشتقاق -سرعة في التقارب	-يتوقف عند الحلول المحلية -لا يصلح للدوال غير المستمرة أو المعقدة	النمذجة الرياضية، تحليل الإشارات
البرمجة الخطية (LP)	-حل دقيق وسريع للمشكلات الخطية -استقرار عددي جيد	-غير فعال في الحالات غير الخطية -محدودية في تطبيقات العالم الحقيقي	التخطيط المالي، تخصيص الموارد
البرمجة غير الخطية (NLP)	-يمكنها التعامل مع قيود ودوال غير خطية	-حساسية لشروط البدء -معرضة للتوقف عند أمثلية محلية	التصميم الهندسي، تحسين الطاقة

I.2.5- خوارزميات التحسين الطبيعية (Nature-Inspired Algorithms)

تستخدم هذه الخوارزميات استراتيجيات مستوحاة من سلوكيات وظواهر في الطبيعة، كالانتقاء البيولوجي أو سلوك الحشرات أو الطيور. وهي مصممة لتجاوز القيود التقليدية التي تواجهها الخوارزميات الكلاسيكية، وتستخدم على نطاق واسع في المسائل التي يصعب تحليلها رياضياً أو التي تتضمن فضاءات بحث غير خطية [9].

الجدول I. 6 : أمثلة ومقارنة خوارزميات التحسين الطبيعية

الخوارزمية	المزايا	العيوب	الاستخدامات المثلى
الخوارزميات الجينية (GA)	-لا تعتمد على اشتقاق -فعالة في البحث عن الحلول العالمية	-بطيئة نسبياً -تتطلب ضبطاً دقيقاً للمعاملات	التصميم التوافقي، التحسين المركب
أسراب الجسيمات (PSO)	-سريعة في الاستكشاف -بسيطة في التنفيذ	-تميل للتوقف في الحلول المحلية -حساسية للإعدادات الأولية	تحسين المعلمات، تطبيقات التحكم

الجدولة، توزيع الموارد	-بطيئة في حالة الفضاء الواسع -لا تضمن الوصول للحل الاثمل دائما	-قابلة للهروب من الحلول المحلية -لا تحتاج لمشتقات	محاكاة التلدين(SA)
------------------------	-------------------------------------------------------------------	------------------------------------------------------	--------------------

I 3.5- خوارزميات التحسين الهجينة (Hybrid Optimization Algorithms)

تجمع الخوارزميات الهجينة بين نقاط القوة في الخوارزميات التقليدية والطبيعية، بهدف تحسين دقة البحث وكفاءته. وغالباً ما تستخدم هذه الخوارزميات تقنيات تكاملية، مثل استخدام التدرج في مرحلة الاستغلال ضمن خوارزمية طبيعية، أو دمج استكشاف عشوائي داخل نموذج رياضي [9].

الجدول I . 7 : أمثلة ومقارنة خوارزميات التحسين الهجينة

الاستخدامات المثلى	العيوب	المزايا	الخوارزمية الهجينة
تخطيط النقل، إدارة المخزون	-زيادة في التعقيد الحسابي	-دقة رياضية مع قدرة استكشاف واسعة	برمجة خطية + GA
التحكم الديناميكي، تحسين النماذج الفيزيائية	-يعتمد على تنسيق جيد بين المرحلتين	-تقارب أسرع للحلول -تقليل الوقوع في الأمثلية المحلية	PSO + GD

I 4.5- ملخص مقارن شامل

الجدول I . 8 : مقارنة شاملة للخوارزميات

المعيار	الخوارزميات التقليدية	الخوارزميات الطبيعية	الخوارزميات الهجينة
الدقة	عالية	تقريبية	متوازنة
سرعة التنفيذ	مرتفعة في المسائل المحددة	متوسطة إلى بطيئة	متغيرة حسب طريقة الدمج
القابلية للتطبيق	مشاكل رياضية واضحة	مسائل معقدة وغير خطية	تطبيقات متعددة ذات تعقيد عالٍ
قابلية الاستكشاف	ضعيفة	قوية	قوية جداً
سهولة التهيئة	تتطلب معرفة تحليلية	مرنة	تحتاج ضبطاً وتنسيقاً جيداً

6.I- الخاتمة:

يمثل التحسين أحد الأعمدة الأساسية في معالجة المشكلات العلمية والهندسية، حيث يُستخدم للوصول إلى حلول فعالة ضمن شروط وقيود محددة. وقد تناول هذا الفصل المفاهيم النظرية المرتبطة بخوارزميات التحسين، بدءاً من تعريفها وخصائصها، وصولاً إلى أهميتها في مجموعة واسعة من المجالات التطبيقية مثل النقل، الطاقة، الرعاية الصحية، وتحليل البيانات.

كما تم استعراض التصنيفات المختلفة لهذه الخوارزميات وفقاً لعدة معايير، مثل طبيعة البحث ونطاق الحل وطريقة الاشتقاق وآلية البحث. وقد تبين من خلال هذا التصنيف أن لكل نوع من الخوارزميات خصائص تميزه، ما يستدعي اختيار الأداة المناسبة بناءً على طبيعة المشكلة قيد الدراسة.

بالإضافة إلى ذلك، تم التمييز بين الخوارزميات التقليدية، التي تعتمد على أسس رياضية وتحليلية دقيقة، والخوارزميات المستوحاة من الطبيعة، التي تتبع سلوكيات وأنماط مستلهمة من الأنظمة الحيوية والفيزيائية، فضلاً عن تقديم تصور لخوارزميات هجينة تجمع بين مزايا كلا النوعين.

من خلال المقارنة بين هذه الأنواع، يتضح أن فعالية أي خوارزمية تعتمد على التوازن بين الدقة الحسابية، وسرعة التنفيذ، والقدرة على استكشاف فضاء الحلول بشكل واسع. لذلك، يُعد فهم المبادئ الأساسية لهذه الخوارزميات ومعايير تصنيفها الخطوة الأولى نحو استخدامها الأمثل في التطبيقات العلمية والهندسية المتقدمة.

الفصل الثاني

خوارزمية محسن دبور العنكبوت

Spider wasp optimizer algorithms

1.II- مقدمة حول خوارزمية محسن دبور العنكبوت (SWO):

خوارزميات التحسين تُعد من الأدوات الأساسية في حل العديد من المسائل المعقدة التي يصعب التعامل معها باستخدام الطرق التقليدية. ومع تطور الأنظمة المعقدة وتعدد الأهداف، ظهرت الحاجة إلى ابتكار خوارزميات أكثر كفاءة ومرونة. في هذا السياق، برزت خوارزمية محسن دبور العنكبوت (Spider Wasp Optimizer (SWO) - التي طُوِّرت استنادًا إلى السلوك الطبيعي لدبابير العنكبوت في الصيد والتكاثر وبناء الأعشاش. تم اقتراح هذه الخوارزمية بهدف تقديم بديل فعال قادر على معالجة القيود التي تواجهها الخوارزميات الكلاسيكية والمستوحاة من الطبيعة، من حيث سرعة التقارب والقدرة على استكشاف الفضاءات الواسعة للحلول دون الوقوع في الحلول المحلية.

تعتمد خوارزمية SWO على مجموعة من الآليات الحيوية المستلهمة من دورة حياة دبور العنكبوت، مثل البحث النشط عن الفريسة، والمطاردة، والتزاوج، والتعشيش. تُترجم هذه السلوكيات إلى مراحل حسابية تتيح إنشاء وتحديث مجموعة من الحلول (Population) بطريقة تضمن التوازن بين الاستكشاف والاستغلال [10].

1.1.II- الدافع وراء تطوير الخوارزمية:

خوارزميات التحسين التقليدية، رغم فعاليتها في عدد من المسائل، غالبًا ما تعاني من مشكلات تتعلق بالانحباس في الحلول المحلية، أو ضعف التوازن بين مرحلتَي الاستكشاف والاستغلال. لهذا السبب، أصبح من الضروري تطوير خوارزميات جديدة تتسم بالمرونة والقدرة على التكيف مع بيئات بحث غير خطية وذات أبعاد عالية. خوارزمية SWO جاءت كاستجابة لهذه التحديات، حيث تم استلهامها من قدرة دبابير العنكبوت على تنفيذ سلوكيات معقدة وفعالة أثناء مطاردة الفريسة، مما يعكس ديناميكية عالية في التفاعل واتخاذ القرار. [10]

2.1.II- أهمية خوارزمية SWO في التحسين :

خوارزمية محسن دبور العنكبوت (SWO) تمثل إضافة نوعية إلى مكتبة الخوارزميات الميتاهوريستية الحديثة، نظرًا لما تقدمه من مرونة عالية في التعامل مع مختلف أنواع مسائل التحسين، سواء الخطية أو غير الخطية، المحددة أو غير المحددة، ذات هدف واحد أو متعددة الأهداف. وتكمن أهميتها بشكل خاص في قدرتها على تحقيق توازن فعال بين مرحلة الاستكشاف (Exploration) ومرحلة الاستغلال (Exploitation)، مما يجعلها فعالة في تجنب الوقوع في الحلول المحلية وزيادة فرص الوصول إلى الحل العالمية المثلى.

تمثل خوارزمية SWO نموذجًا متقدمًا من حيث البنية والتحديث الديناميكي للسكان، حيث تعتمد على محاكاة ذكية لسلوك دبور العنكبوت في مطاردة الفريسة، الهروب من الأعداء، وبناء العش. وهذا النموذج الحيوي يضمن تغطية أوسع لفضاء البحث وتحسين عملية اتخاذ القرار أثناء تحديث الحلول.

من جهة أخرى، أثبتت الخوارزمية أداءً تنافسيًا عند مقارنتها بخوارزميات شهيرة مثل PSO (خوارزمية سرب الجسيمات) و GA (الخوارزمية الجينية) و DE (الاستراتيجية التطورية التفاضلية)، خاصةً على وظائف اختبار قياسية ومشكلات تحسين واقعية مثل ضبط المتحكمات، الجدولة، وتصميم الأنظمة [10].

2.II- نظرة عامة على دبابير العنكبوت وسلوكها**1.2.II- لمحة عن دبابير العنكبوت:**

تُعد دبابير العنكبوت من الحشرات المفترسة المتخصصة التي تنتمي إلى فصيلة Pompilidae. وتتميز بسلوكها الفريد في اصطياد العناكب واستخدامها كمصدر غذائي ليرقاتها. تعيش هذه الدبابير في بيئات متنوعة، من الأراضي الجافة إلى الغابات الرطبة، وتُظهر تكيفًا بيولوجيًا استثنائيًا في طرق البحث عن الفريسة، شلها، ثم استخدام جسمها كحضانة حية. ما يميزها عن غيرها هو ارتباط دورة حياتها الكامل تقريبًا بالعناكب، وهو ما يمنحها مكانة خاصة بين الحشرات المتطفلة المفيدة في التوازن البيئي. [11]

2.2.II- السلوكيات الفريدة لدبابير العنكبوت:

تعتمد دبابير العنكبوت على مجموعة من السلوكيات المعقدة أثناء الصيد والتكاثر، والتي يمكن تقسيمها إلى المراحل التالية:

1.2.2.II- البحث عن الفريسة (Hunting & Foraging)

تبدأ إناث دبابير العنكبوت في استكشاف محيطها لاكتشاف عناكب مناسبة لتغذية صغارها. تستخدم أرجلها الطويلة وأجنحتها للمناورة والسرعة أثناء التنقل بين النباتات والترية، مع اعتمادها على حاستي الشم واللمس، بالإضافة إلى استشعار الاهتزازات لتحديد مواقع العناكب. [11]



الشكل 1.II : ديور أثناء البحث عن الفريسة [13]

2.2.2.II-ملاحقة الفريسة والهجوم (Chasing & Hunting)

عند تحديد موقع العنكبوت، تطارده الدبور بسرعة عالية وتهاجمه باستخدام لسعة سامة تؤدي إلى شل حركته، مما يمنع هروبه أو مقاومته. قد تتغير طريقة الملاحقة حسب حركة الفريسة وموقعها، سواء كانت على الأرض أو داخل شبكتها. [12]



الشكل II.2 : دبور أثناء عملية هجوم [16]

3.2.2.II-التعشيش ووضع البيض (Nesting & Egg Laying)

تسحب الدبور الفريسة المشلولة إلى جحر أو حفرة معدة مسبقاً، ثم تضع عليها بيضة واحدة. تختار الأنثى حجم العنكبوت بعناية، إذ تفضل العناكب الكبيرة عند إنجاب إناث، والصغيرة للذكور، في عملية تعكس تحكماً تكيفياً نادراً في تحديد الجنس. [11]



الشكل II.3 : عنكبوت مشلول يسحب من طرف دبور للعش [14]

4.2.2.II-العناية باليرقات ونموها (Larval Development)

عند فقس البيضة، تبدأ اليرقة في التهام العنكبوت بشكل تدريجي، بدءًا من الأعضاء غير الحيوية للحفاظ على الفريسة حيّة وطازجة لأطول فترة ممكنة. ومع نهاية المرحلة، تدخل اليرقة في طور الشرنقة، ثم تخرج لاحقًا كدبور بالغ. [11]

5.2.2.II-التزاوج وإنتاج الجيل الجديد (Mating & Reproduction)

يُعد حجم الفريسة عاملاً حاسماً في تحديد جنس النسل، حيث تعتمد الأنثى على حجم العنكبوت لتحديد ما إذا كان الجنين سيكون ذكرًا أو أنثى. بعد التزاوج، تبدأ دورة جديدة من الصيد والتعشيش لضمان استمرار السلالة. [12]



الشكل II.4 : جنس وشكل دبور (wasp pompilidae) [15]

3.2.II-العلاقة بين السلوكيات الطبيعية لخوارزمية دبور العنكبوت (SWO) وتطبيقها في الخوارزمية:

تستند خوارزمية محسن دبور العنكبوت (Spider Wasp Optimizer - SWO) إلى محاكاة السلوكيات الفريدة لدبابير العنكبوت في الطبيعة، حيث تُترجم هذه السلوكيات إلى مراحل وخطوات برمجية تهدف إلى تحقيق التوازن بين الاستكشاف والاستغلال داخل فضاء البحث.



الشكل II.5 : العلاقة بين السلوكيات الطبيعية لخوارزمية دبور العنكبوت (SWO) وتطبيقها في الخوارزمية

هذه المحاكاة للسلوكيات الطبيعية تتيح للخوارزمية تحقيق بحث فعال عن الحلول المثلى، حيث تساعد مراحل الاستكشاف في تجنب الوقوع في الحلول المحلية غير الأمثل، بينما تضمن مراحل الاستغلال والتركيز تطوير حلول دقيقة وفعالة. [10]

3.II-المبادئ الأساسية لخوارزمية محسن دبور العنكبوت(SWO)

تتكون خوارزمية Spider Wasp Optimizer (SWO) من مجموعة من المبادئ والمراحل الأساسية التي تحاكي سلوك دبابير العنكبوت في الطبيعة. تعتمد هذه المبادئ على التوازن بين الاستكشاف والاستغلال لضمان البحث الفعال عن الحلول المثلى. تبدأ الخوارزمية بتوليد مجموعة أولية من الحلول، ثم تعمل على تحسينها عبر تكرارات متعددة باستخدام استراتيجيات تحاكي الصيد، الملاحقة، التعشيش، والتزاوج [10].

1.3.II-تهيئة العشوائية للحلول (Initialization of Solutions)

في بداية خوارزمية Spider Wasp Optimizer (SWO)، يتم توليد مجموعة أولية من الحلول بطريقة عشوائية داخل فضاء البحث. يُمثّل كل حل على شكل متجه يضم قيمًا عددية تعبر عن متغيرات المسألة المراد حلّها. تُولّد هذه القيم ضمن الحدود الدنيا والعليا المسموح بها لكل متغير، ما يضمن تنوعًا في التهيئة ويمنع الخوارزمية من التقيّد بحلول ضعيفة منذ البداية.

خطوات التهيئة العشوائية:

- (1) تحديد عدد الأفراد في السرب (عدد الدبابير)، ويرمز له بـ N .
- (2) تحديد عدد أبعاد المسألة D (عدد المتغيرات).
- (3) تحديد حدود البحث لكل متغير: الحد الأدنى Lb ، والحد الأعلى Ub .
- (4) توليد المواقع الأولية عشوائيًا باستخدام العلاقة التالية:

$$sw_i = Lb + \text{rand}() \times (Ub - Lb)$$

حيث:

sw_i يمثل موقع الدبور i في فضاء البحث. $\text{rand}()$ دالة تولد عددا عشوائيا بين 0 و 1.

أهمية التهيئة العشوائية :

- تضمن تغطية جيدة لفضاء البحث.
- تقلّل احتمالية الانحصار في الحلول المحلية.
- توفّر تنوعًا ضروريًا لتغذية مراحل البحث والاستغلال. [10]

2.3.II-مرحلة البحث والاستكشاف (Exploration Phase)

بعد توليد مجموعة أولية من الحلول بطريقة عشوائية، تبدأ خوارزمية SWO في مرحلة البحث والاستكشاف، والتي تمثل جانب الاستكشاف في مبدأ "الاستكشاف مقابل الاستغلال". تحاكي هذه المرحلة سلوك دبابير العنكبوت أثناء تنقلها العشوائي في البيئة للبحث عن العناكب دون هدف محدد في البداية، مما يسمح بتغطية مساحة واسعة من فضاء البحث.

تتحرك كل دبور نحو موقع جديد بناءً على الفرق بين موقعين تم اختيارهما عشوائيًا من بين بقية الأفراد. يتم تحديث الموقع باستخدام المعادلة :

$$SW_i^{\{t+1\}} = SW_i^t + \mu_1 \cdot (SW_a^t - SW_b^t)$$

حيث :

SW_i^t : موقع الدبور i عدد التكرار t . SW_a^t و SW_b^t : موقعان عشوائيان لدبورين مختلفين.

μ_1 : عامل تحكم في مدى التحديث.

أهداف هذه المرحلة:

- تجنّب الانحصار في الحلول المحلية.
- توسيع البحث داخل فضاء الحل.
- زيادة تنوع السكان المبدئي. [10]

3.3.II-مرحلة الملاحقة والتحديث (Chasing & Exploitation Phase)

تمثل هذه المرحلة عملية الاستغلال، حيث تبدأ الدبابير في تحديد الفريسة وملاحقتها، مشيرة إلى محاولة الخوارزمية الاقتراب من الحل الواعدة بناءً على تقييم الأداء.

آلية التحديث:

يتم تحديث موقع كل دبور باستخدام المعادلة التالية :

$$SW_i^{\{t+1\}} = SW_i^t + C \cdot |2 \cdot r_5 \cdot (SW_a^t - SW_i^t)|$$

حيث :

C : عامل تقليل التأثير العشوائي بمرور الزمن. SW_a^t : أفضل حل تم العثور عليه حتى اللحظة.

r_5 : رقم عشوائي في النطاق [0,1] .

أهداف هذه المرحلة:

- * تعزيز التقارب نحو المناطق المثلى.
- * تسريع عملية البحث نحو الحل الدقيقة.
- * توجيه السكان نحو الحل ذات الجودة العالية. [10]

4.3.II-مرحلة التعشيش وتحسين الحل (Nesting & Optimal Solution Construction)

تُحاكي هذه المرحلة سلوك دبابير العنكبوت في سحب العنكبوت المشلول إلى العش ووضع البيض عليه. في SWO، يُعاد تركيز البحث على أفضل المناطق من خلال تعديل أفضل الحل بهدف تحسينها.

آلية تحسين الحل:

يتم تحديث موقع الدبور الأفضل باستخدام معادلة تعتمد على دالة جيب تمام:

$$SW_i^{\{t+1\}} = SW^* + \cos(2\pi l) \cdot (SW^* - SW_i^t)$$

حيث:

SW^* : أفضل موقع معروف.

l : عدد عشوائي بين [0,1] يحدد مقدار التعديل.

❖ الفائدة:

- تحسين استغلال الحلول الجيدة.
- تقوية استكشاف المناطق المحيطة بأفضل الحلول.
- استبعاد الحلول الضعيفة تدريجياً. [10]

5.3.II-مرحلة التزاوج وإنتاج الجيل الجديد (Mating & New Generation Production)

في هذه المرحلة، تُحاكي خوارزمية SWO سلوك التزاوج لدى دبابير العنكبوت، حيث يتم دمج الخصائص الوراثية بين أفضل الأفراد لإنتاج جيل جديد من الحلول. الهدف من هذه المرحلة هو تعزيز تنوع الحلول وتحسين فرص الوصول إلى الحلول المثلى.

(أ) آلية التزاوج:

يتم اختيار دبورين (حليين) من بين أفضل الأفراد. يُنشأ فرد جديد باستخدام معادلة العبور الوراثي :

$$SW_i^{\{t+1\}} = \frac{1}{2} (SW_i^t + SW_m^t)$$

حيث:

SW_i^t : موقع الدبور الحالي.

SW_m^t : موقع دبور آخر مختار عشوائياً من بين الحلول الجيدة.

يُضاف تعديل طفيف لزيادة التنوع باستخدام الضوضاء العشوائية :

$$SW_i^{\{t+1\}} = SW_i^{\{t+1\}} + \beta \cdot (Ub - Lb) \cdot rand()$$

حيث:

β : عامل تعديل للتحكم في شدة الضوضاء.

Lb,Ub : الحدود العليا والدنيا لمجال البحث.

(ب) أهمية هذه المرحلة:

تحسين تنوع السكان وتجنب الانحصار في الحلول المحلية. بدمج المعلومات من حلول متعددة لإنتاج حلول ذات جودة أعلى. وتسريع عملية التقارب نحو الحل الأمثل. [10]

6.3.II-آلية التحديث وتقليل عدد السكان (Update & Population Reduction Mechanism)

تُعد هذه المرحلة النهائية من التكرار في خوارزمية SWO، حيث يتم تقييم أداء الأفراد وتصفية السكان مع تقليل حجمهم تدريجياً، بما يتوافق مع مبدأ البقاء للأصلح في السلوك الطبيعي.

(أ) آلية التحديث:

1. تُقيم جميع الحلول باستخدام دالة الهدف.
2. يُحتفظ بأفضل الحلول ويتم إزالة الحلول الضعيفة.
3. تُحدّث مواقع الأفراد باستخدام العلاقة:

$$SW_i^{\{t+1\}} = SW^* + \gamma (SW^* - SW_i^t)$$

حيث:

γ : معامل تحكم في شدة التحديث.

SW^* : أفضل حل معروف حتى الآن.

(ب) تقليل عدد السكان:

يتم تقليل عدد الأفراد مع مرور الزمن وفق المعادلة:

$$N_t = N_0 \cdot \left(1 - \frac{t}{T_{max}} \right)$$

حيث:

N_t : عدد الأفراد في التكرار t .

N_0 : العدد الابتدائي للأفراد.

T_{max} : عدد التكرارات الكلي.

(ت) أهداف هذه المرحلة:

- تقليل الوقت الحسابي مع الحفاظ على جودة البحث.
- تعزيز الضغط الانتقائي نحو الحلول الأفضل.
- تركيز الجهد على تحسين أكثر الأفراد كفاءة. [10]

4.II-النموذج الرياضي لخوارزمية SWO

يعتمد النموذج الرياضي لخوارزمية محسن دبور العنكبوت (Spider Wasp Optimizer - SWO) على محاكاة دقيقة للسلوكيات الحيوية التي تقوم بها إناث دبابير العنكبوت خلال مراحل الصيد، التعشيش، والتكاثر.

تتمثل الفكرة الأساسية في تمثيل كل "دبور" كحل محتمل للمشكلة، ويجري تحريك هذه الحلول ضمن فضاء البحث باستخدام معادلات مستوحاة من هذه السلوكيات. [10]

1.4.II- المتغيرات والمعادلات الأساسية

لتمثيل الخوارزمية رياضياً، نُعرّف أولاً أهم الرموز والمعلمات:

SW_i^t : موقع الدبور i في التكرار t .

D : عدد الأبعاد (المتغيرات) في فضاء البحث.

N : عدد السكان (الحلول).

Lb, Ub : الحد الأعلى والأدنى لكل متغير.

SW^* : أفضل موقع تم العثور عليه حتى الآن.

$rand()$: عدد عشوائي موزّع بانتظام بين 0 و 1.

μ_1, γ, β, C : معاملات تحكم تختلف قيمها حسب مرحلة الخوارزمية. [10]

2.4.II- تمثيل حركة الدبابير في فضاء البحث

(أ) التهيئة العشوائية:

يتم توليد المواقع الأولية للحلول كما يلي:

$$sw_i = Lb + rand() \times (Ub - Lb)$$

حيث يتم توليد متجه عشوائي لكل دبور يغطي فضاء البحث.

(ب) مرحلة الاستكشاف:

تمثل محاكاة بحث الدبابير عن الفرائس عشوائياً وفقاً للمعادلة:

$$SW_i^{\{t+1\}} = SW_i^t + \mu_1 \cdot (SW_a^t - SW_b^t)$$

SW_a^t و SW_b^t : موقعا دبورين مختلفين يتم اختيارهما عشوائياً.

(ت) مرحلة الملاحقة (الاستغلال):

تقترب الدبابير من أفضل الحلول المكتشفة حتى الآن باستخدام:

$$SW_i^{\{t+1\}} = SW_i^t + C \cdot |2 \cdot r_5 \cdot (SW_a^t - SW_i^t)|$$

مع تقليل تأثير العشوائية تدريجيًا عبر معامل C . [10]

3.4.II- محاكاة التعشيش والتزاوج رياضياً

(أ) مرحلة التعشيش:

تعديل المواقع الجيدة باستخدام دالة جيبية لتعزيز الحلول المحلية:

$$SW_i^{\{t+1\}} = SW^* + \cos(2\pi l) \cdot (SW^* - SW_i^t)$$

حيث l متغير عشوائي بين 0 و 1.

(ب) مرحلة التزاوج:

توليد حلول جديدة بدمج المواقع:

$$SW_i^{\{t+1\}} = \frac{1}{2} (SW_i^t + SW_m^t)$$

ثم إضافة ضوضاء خفيفة للتنوع:

$$SW_i^{\{t+1\}} = SW_i^{\{t+1\}} + \beta \cdot (Ub - Lb) \cdot \text{rand}()$$

حيث :

β : معامل التحكم في شدة التعديل [10].

4.4.II- آلية تقليل عدد السكان

لتسريع التقارب وتقليل الحمل الحسابي، يتم تقليل عدد الدبابير تدريجيًا وفقًا للعلاقة:

$$N_t = N_0 \cdot \left(1 - \frac{t}{T_{max}}\right)$$

حيث :

N_t : عدد الأفراد عند التكرار t .

N_0 : العدد الأولي للحلول

T_{max} : العدد الأقصى للتكرارات.

5.II- الخاتمة :

تم التطرق بشمولية إلى خوارزمية محسن دبور العنكبوت (Spider Wasp Optimizer - SWO) باعتبارها إحدى الخوارزميات الميتاهيوريسية الحديثة المستلهمة من الطبيعة. استُهلَّ الفصل بتقديم لمحة بيولوجية عن دبابير العنكبوت، حيث تم تحليل سلوكها في البيئة الطبيعية مثل البحث عن الفريسة، الملاحقة، اللسع، التعشيش، والتزاوج. وقد شكل هذا السلوك المعقد والمنظم الأساس الحيوي لتصميم نموذج رياضي يعكس مراحل التحسين ضمن الخوارزمية.

تم لاحقاً عرض المبادئ الأساسية للخوارزمية بشكل تدريجي ومنهجي، ابتداءً من التهيئة العشوائية للحلول، مروراً بمرحلتَي الاستكشاف والاستغلال، ثم محاكاة عمليتي التعشيش والتزاوج لتوليد أجيال جديدة من الحلول، وصولاً إلى آلية التحديث وتقليل عدد السكان بمرور الزمن. كما تم التطرق إلى الجانب الرياضي من خلال المعادلات التي تضبط حركة الحلول (الدبابير) داخل فضاء البحث، بما يضمن تحسين الجودة والاستقرار في التقارب نحو الحل المثلى.

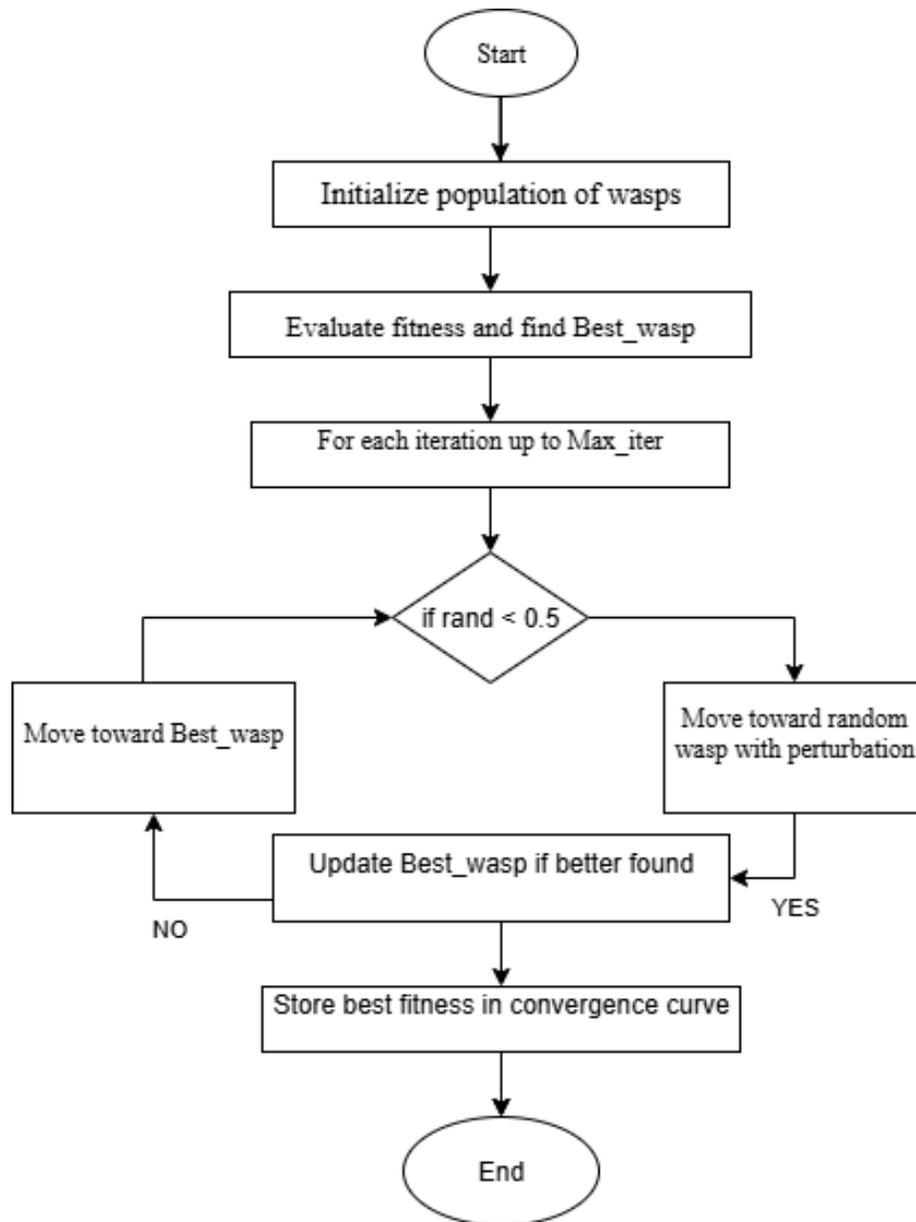
تُبرز خوارزمية SWO مزايا متعددة، من بينها التوازن الفعّال بين الاستكشاف والاستغلال، والقدرة على تجاوز العوائق المرتبطة بالحلول المحلية، ما يجعلها مرشحاً واعدًا لمعالجة فئات واسعة من مشكلات التحسين الرياضي والهندسي.

الفصل الثالث

تتفيذ خوارزمية « SWO »

1.III-مقدمة :

في هذا الفصل، سيتم تقديم خوارزمية الدبابير العنكبوتية (SWO) إلى جانب ثمانٍ من خوارزميات البحث الميتا-استدلالية الأخرى، وهي (EO، GNDO، MRFO، MPA، SMA، HHO، PFA، JS). وقد تم تقييم أداء هذه الخوارزميات باستخدام مجموعتين من دوال الاختبار القياسية: مجموعة دوال عام 2005، ومجموعة دوال عام 2019. تم تنفيذ المحاكاة على تكرار 30 مرة وتحليل النتائج باستخدام برنامج MATLAB 2017، على جهاز حاسوب واحد بمواصفات: معالج Intel® Celeron® N4020 بسرعة 1.10GHz، وذاكرة عشوائية (RAM) بسعة 4 جيجابايت، ونظام تشغيل 64-بت بمعمارية x64. وتطبيق خوارزمية SWO على معاملات المتحكم PID بهدف تحسينها تطبيق خوارزمية SWO في جدولة التدخلات التقنية ومقارنتها مع خوارزمية GWO.



الشكل III.1: المخطط الانسيابي لخوارزمية (SWO) Spider Wasp Optimizer [10].

2.III- تنفيذ خوارزمية Spider Wasp Optimizer (SWO) على دوال الاختبار القياسية 2005 و2019.

في هذا القسم، يتم استعراض مجموعات دوال الاختبار القياسية التي استُخدمت لتقييم أداء خوارزمية Spider Wasp Optimizer (SWO). تنقسم مجموعة دوال عام 2005 إلى ثلاث فئات رئيسية، حيث تشمل الفئة الأولى الدوال أحادية القمة وعالية الأبعاد (Unimodal High-Dimensional) والتي تتضمن الدوال من F01 إلى F07، وتُستخدم لاختبار قدرة الخوارزمية على الاستغلال المحلي (local exploitation). أما الفئة الثانية، فهي الدوال متعددة القمم وعالية الأبعاد (Multimodal High-Dimensional) وتشمل الدوال من F08 إلى F13، وتُعد مناسبة لتقييم كفاءة الاستكشاف العالمي (global exploration). بينما تضم الفئة الثالثة الدوال متعددة القمم ومنخفضة الأبعاد (Multimodal Low-Dimensional) والتي تتراوح من F14 إلى F23، وتُستخدم لاختبار التوازن بين الاستكشاف والاستغلال.

بالإضافة إلى ذلك، تم اعتماد مجموعة دوال CEC 2019 التي تتألف من عشر دوال قياسية (CEC01 إلى CEC10)، وتُعد من أحدث المجموعات التي تم تصميمها لتوفير بيئة اختبار أكثر واقعية وتحدياً. حيث تتميز هذه الدوال بخصائص متقدمة مثل تغير شكل فضاء البحث (landscape shifting)، ووجود قيود (constraints)، وتداخل الحلول المثلى (global optima overlap)، مما يجعلها أداة فعالة لاختبار قدرات الخوارزميات الحديثة.

تم اختيار هاتين المجموعتين لتوفير تقييم شامل وموضوعي لأداء خوارزمية SWO من خلال مقارنتها مع خوارزميات أخرى ضمن بيئات اختبار متنوعة، تُمكن من تحليل نقاط القوة والضعف بدقة في ظروف تحسين مختلفة.

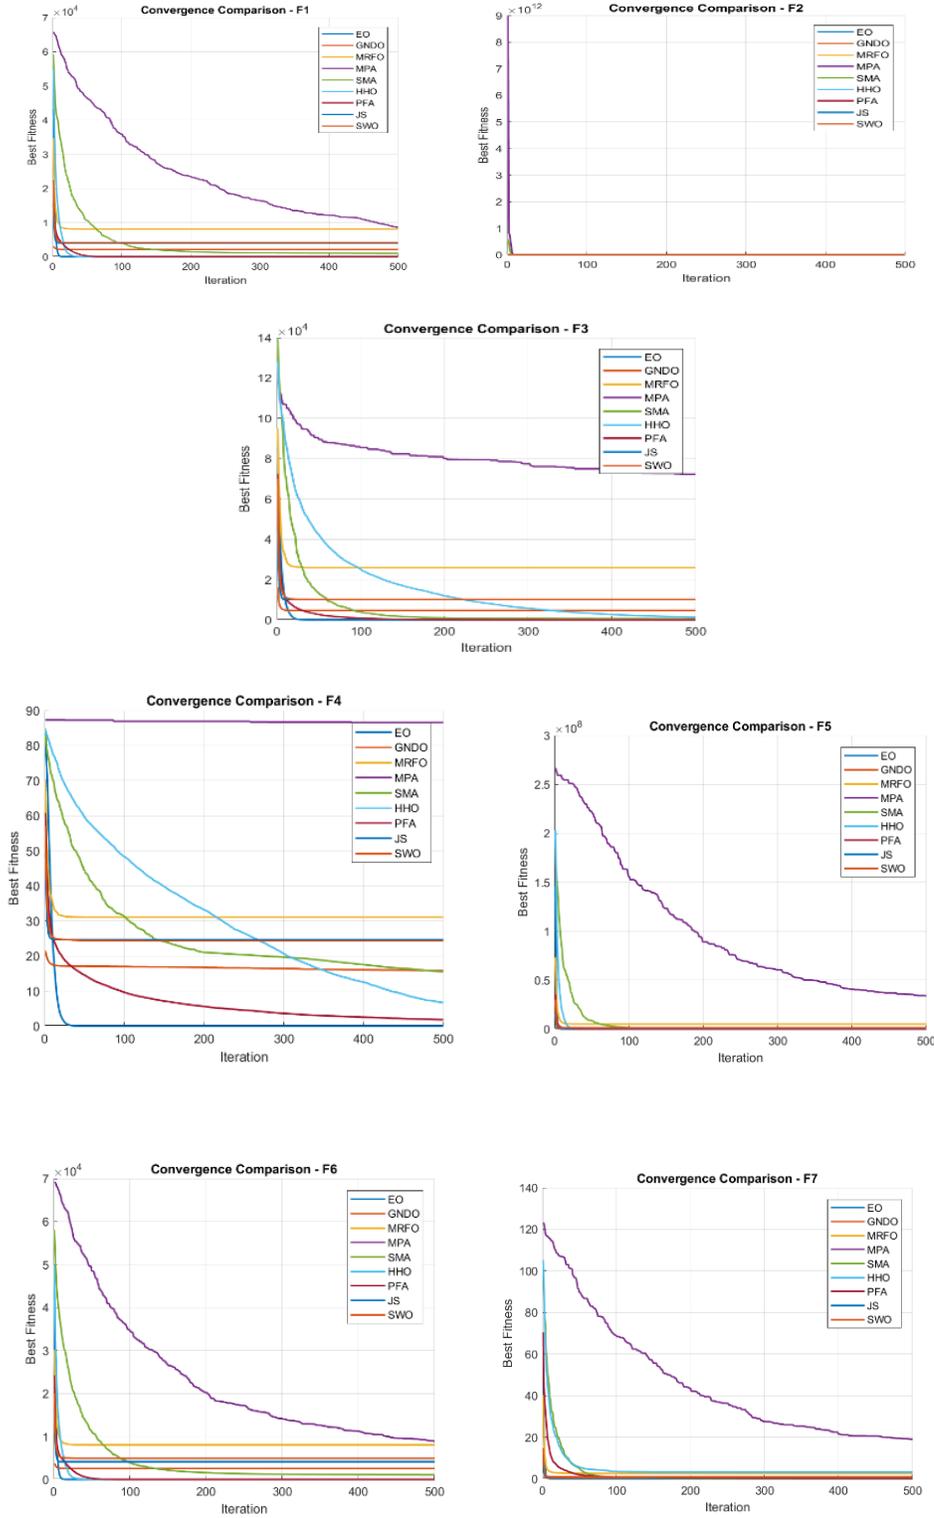
1.2.III دوال الاختبار لعام 2005:

1.1.2.III دوال أحادية القمة وعالية الأبعاد: (F01–F07)

الجدول 1.III: دوال الاختبار (F01 إلى F07)

Test functions	Dimension	Range	Maximum iteration
$F_{01} = \sum_{i=1}^n x_i^2$	30	[-100,100]	500
$F_{02} = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	[-10,10]	500
$F_{03} = \sum_{i=1}^n (\sum_{j=1}^i x_j)$	30	[-100,100]	500
$F_{04} = \max_i \{ x_i , 1 \leq i \leq D\}$	30	[-100,100]	500
$F_{05} = \sum_{i=1}^{D-1} [100 \times (x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	[-30,30]	500
$F_{06} = \sum_{i=1}^D ([x_i + 0,5])^2$	30	[-100,100]	500
$F_{07} = \sum_{i=1}^D [ix_i^4 + \text{random}(0,1)]$	30	[-1.28,1.28]	500

فيما يلي سوف نقدم نتائج هذه الوظائف أحادية النمط عالية الأبعاد:



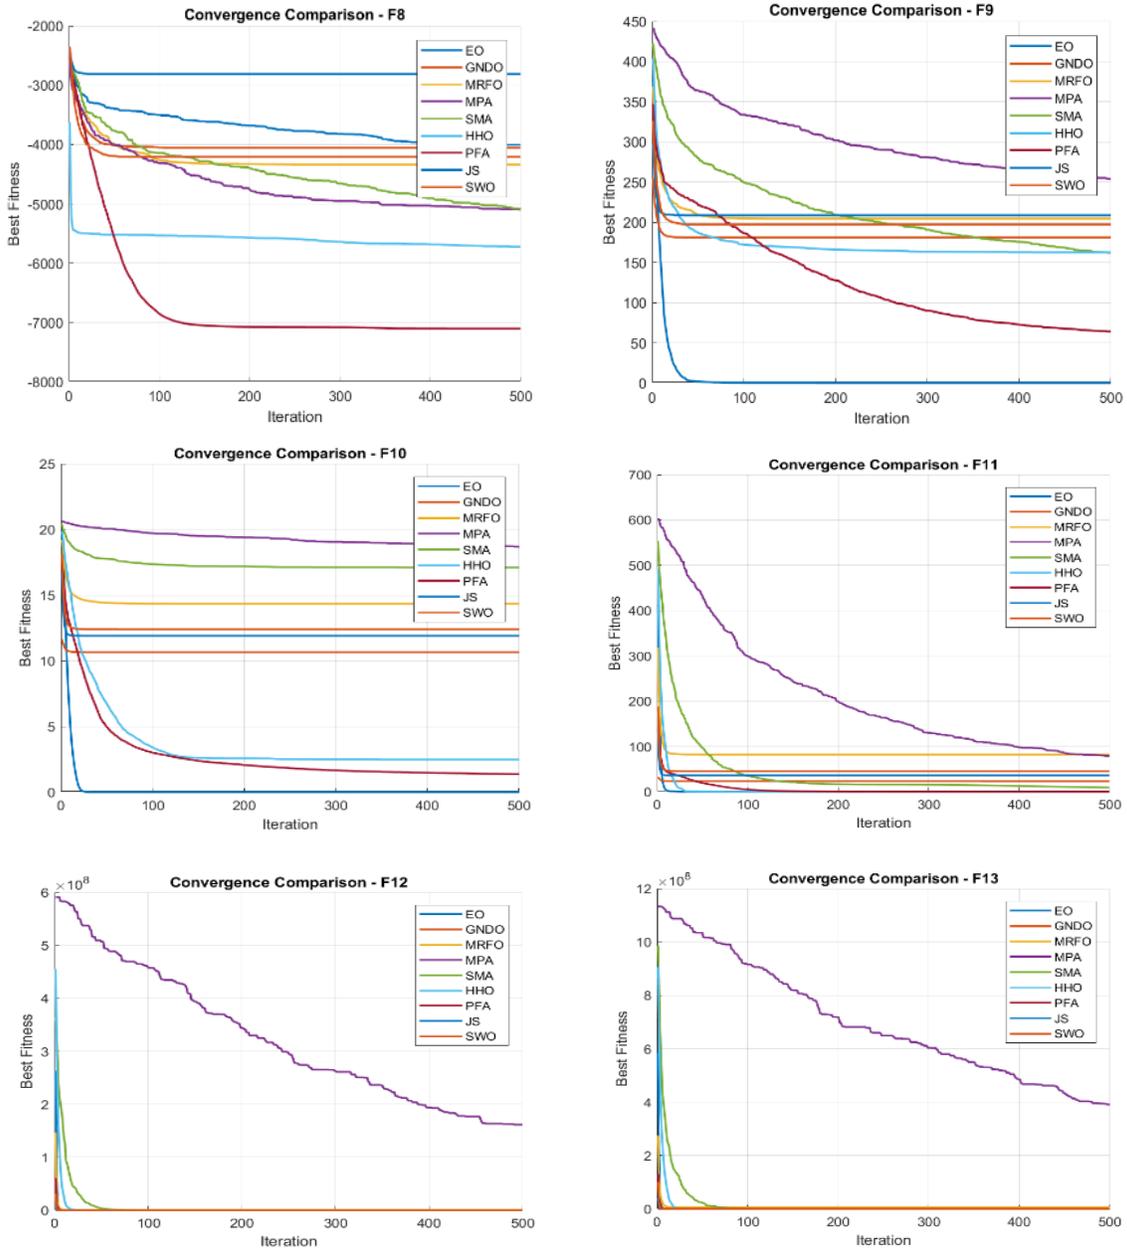
الشكل III.2 منحنيات التقارب التي تم الحصول عليها باستخدام طريقة SWO والعديد من الطرق الاستدلالية مع وظائف الاختبار أحادية النمط عالية الأبعاد.

2.1.2.III الدوال متعددة الأنماط عالية الأبعاد (F08-F13):

الجدول 2.III : الدوال المعيارية (F08 إلى F13)

Test functions	Dimension	Range	Maximum iteration
$F_{08} = \sum_{i=1}^D -x_i \sin(\sqrt{ x_i })$	30	[-500,500]	500
$F_{09} = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	[-5.12, 5.12]	500
$F_{10} = -20 \exp\left(-0, 2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2}\right) - \exp\left(\frac{1}{D} \sum_{i=1}^D \cos(2\pi x_i)\right) + 20 + e$	30	[-32,32]	500
$F_{11} = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	[-600,600]	500
$F_{12} = \frac{\pi}{D} \{10 \sin^2(\pi y_i) + \sum_{i=1}^{D-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_i + 1)] + (yD - 1)^2 + \sum_{i=1}^D u(x_i, 10, 100, 4)\}$ $y_i = 1 + \frac{x_i + 1}{4}$ $k(x_i - a)^m \quad x_i > a$ $u(x_i, a, k, m) = 0 \quad -a < x_i < a$ $k(x_i - a)^m \quad x_i < -a$	30	[-50,50]	500
$F_{13} = 0.1 \{10 \sin^2(\pi y_i) + \sum_{i=1}^{D-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_i + 1)] + (yD - 1)^2 + \sum_{i=1}^D u(x_i, 10, 100, 4)\}$	30	[-50,50]	500

فيما يلي سوف نقدم نتائج هذه الوظائف المتعددة الوسائط عالية الأبعاد:



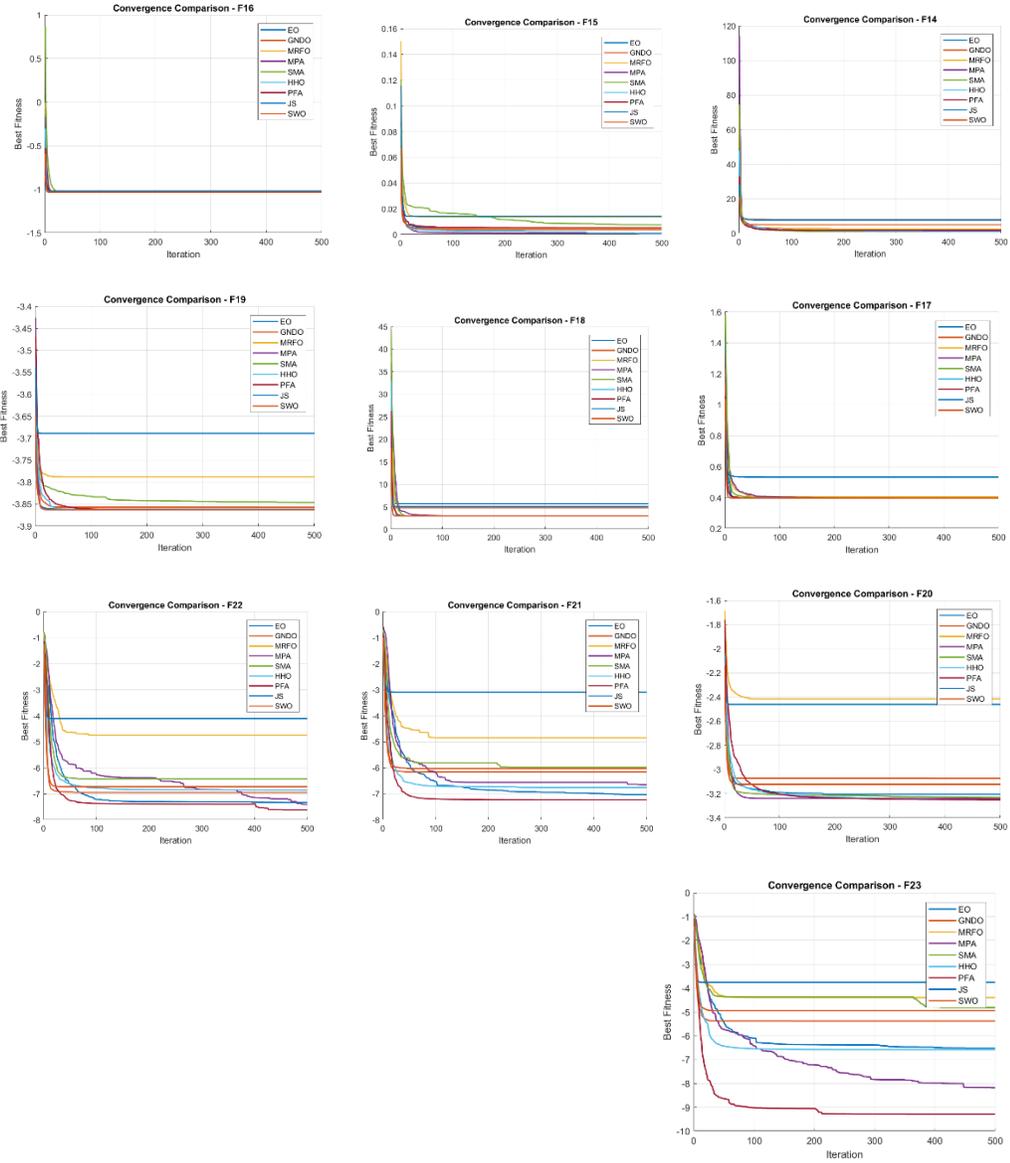
الشكل III.3 منحنيات التقارب التي تم الحصول عليها باستخدام طريقة SWO والعديد من طرق التحليل الفوقى مع وظائف الاختبار متعددة الوسائط عالية الأبعاد 2005.

3.1.2.III الدوال منخفضة الأبعاد متعددة الوسائط (F14-F23):

الجدول 3.III: دوال المقارنة المرجعية (F14 إلى F23)

Test functions	Dimension	Range	Maximum iteration
$F_{14} = \left[\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right]^{-1}$	2	[-65.53, 65.53]	500
$F_{15} = \sum_{i=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_i x_i)}{b_i^2 + b_1 x_3 + x_4} \right]^2$	4	[-5, 5]	500
$F_{16} = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$	2	[-5, 5]	500
$F_{17} = \left(x_2 - \frac{5.1}{4\pi^2} x_1^2 + \frac{5}{\pi} x_1 - 6 \right)^2 + 10 \left(1 - \frac{1}{8\pi} \right) \cos(x_1) + 10$	2	[5, 10] × [0, 15]	500
$F_{18} = [1 + (x_1 + x_2 + 1)^2 (19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \times [30 + (2x_1 - 3x_2)^2 (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$	2	[-5, 5]	500
$F_{19} = - \sum_{i=1}^4 c_i \exp \left(- \sum_{j=1}^3 a_{ij} (x_j - p_{ij})^2 \right)$	3	[0, 1]	500
$F_{20} = - \sum_{i=1}^4 c_i \exp \left(- \sum_{j=1}^6 a_{ij} (x_j - p_{ij})^2 \right)$	6	[0, 1]	500
$F_{21} = - \sum_{i=1}^5 [(X - a_i)(X - a_i)^T + c_i]^{-1}$	4	[0, 10]	500
$F_{22} = - \sum_{i=1}^7 [(X - a_i)(X - a_i)^T + c_i]^{-1}$	4	[0, 10]	500
$F_{23} = - \sum_{i=1}^{10} [(X - a_i)(X - a_i)^T + c_i]^{-1}$	4	[0, 10]	500

فيما يلي سوف نقدم نتائج هذه الوظائف المتعددة الوسائط منخفضة الأبعاد:



الشكل 4. III منحنيات التقارب التي تم الحصول عليها باستخدام طريقة SWO والعديد من الطرق الاستدلالية مع وظائف الاختبار منخفضة الأبعاد متعددة الوسائط 2005.

4.1.2.III مناقشة النتائج '1':

1. نقاط القوة في أداء SWO:

أظهرت خوارزمية SWO أداءً تنافسيًا في العديد من دوال الاختبار، وخاصة في الدوال متعددة القمم وعالية الأبعاد مثل F11 و F12 و F13، حيث احتلت مراتب متقدمة مقارنة بباقي الخوارزميات. هذا الأداء يبرز قدرة SWO على الاستكشاف الفعال ضمن فضاءات البحث المعقدة والتي تتطلب تجنب الحلول المحلية غير المثلى.

كذلك، أظهرت الخوارزمية نتائج قوية في بعض الدوال منخفضة الأبعاد، مثل F14 و F16، مما يعكس توازنًا نسبيًا بين قدرتها على الاستكشاف والاستغلال في البيئات الأقل تعقيدًا.

2. نقاط الضعف النسبية في أداء SWO :

في المقابل، سجلت SWO أداءً أقل تميزًا في بعض الدوال أحادية القمة وعالية الأبعاد، مثل F02 و F07، حيث احتلت مراتب متأخرة. يشير ذلك إلى أن الخوارزمية قد تواجه صعوبة في تحقيق استغلال دقيق في الدوال ذات البنية البسيطة والتي تتطلب تقاربًا منتظمًا وسريعًا نحو الحل الأمثل.

كما أظهرت الخوارزمية تقلبًا في الأداء عبر بعض دوال متعددة القمم منخفضة الأبعاد، حيث لوحظ تباين واضح بين أفضل النتائج والمتوسط، مما يدل على أن الأداء قد يتأثر بتوزيع العوامل العشوائية الأولية أو بحساسية الخوارزمية تجاه عدد الأبعاد.

3. الاستنتاج العام :

بصورة عامة، تُظهر خوارزمية SWO قدرة عالية على الاستكشاف الفعال في الدوال المعقدة والعالية الأبعاد، مما يجعلها مناسبة للمشكلات التي تحتوي على فضاءات بحث واسعة وتضاريس متعددة. ومع ذلك، قد تحتاج إلى تحسين آليات الاستغلال الدقيقة لتحقيق أداءً أكثر اتساقًا في البيئات الأبسط والأكثر انتظامًا.

2.2.III وظائف الاختبار 2019:

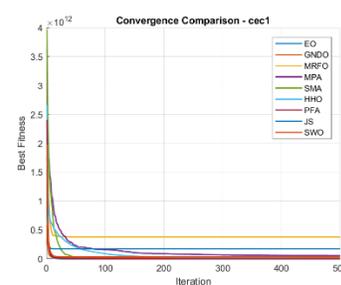
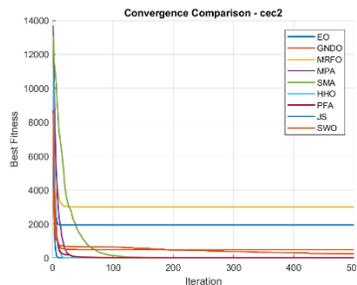
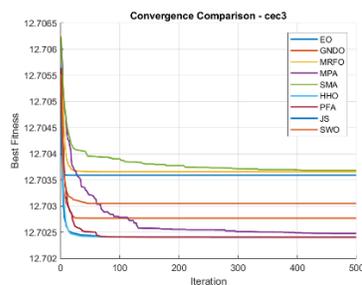
الجدول 4.III وظائف المعايير المرجعية لعام 2019

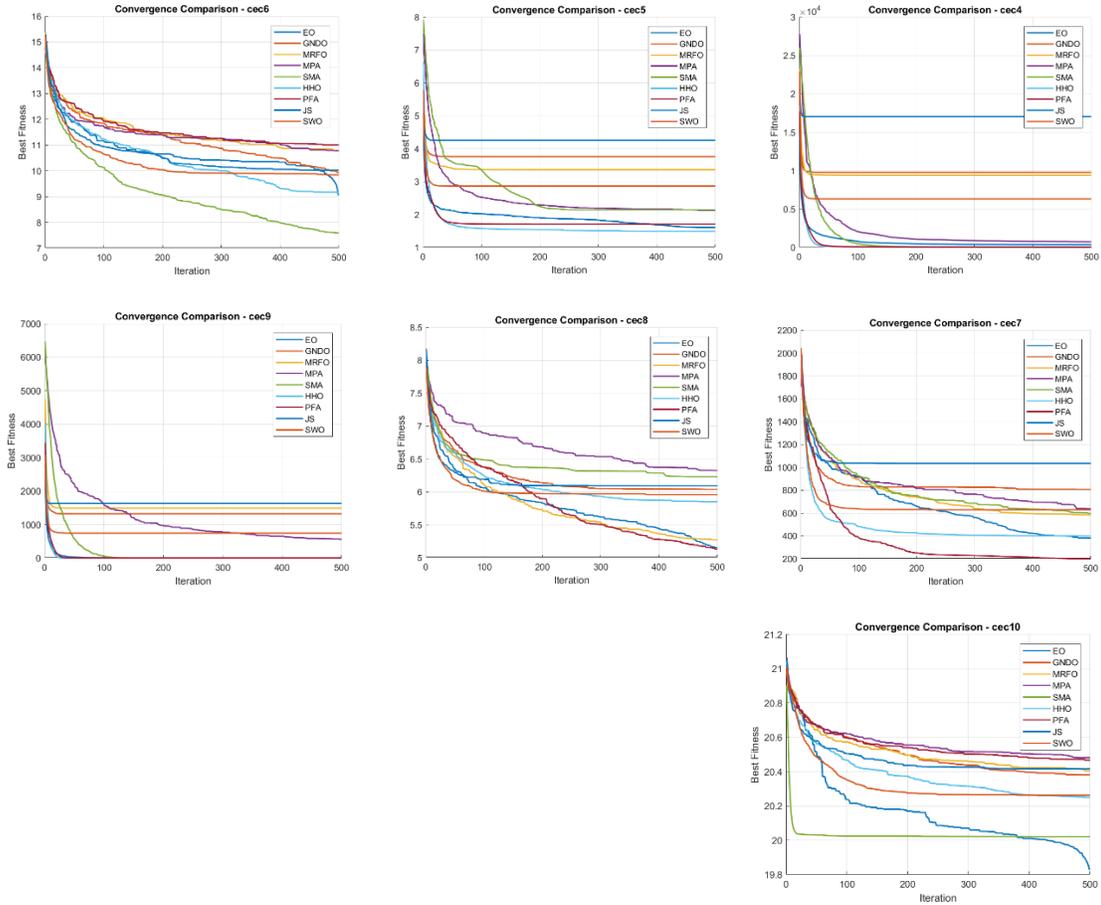
Test functions	Dimension	Range	Optimum Fitness
CEC ₁ : Storn's Chebyshev polynomial fitting problem	9	[-8192,8192]	1
CEC ₂ : Inverse Hilbert matrix problem	16	[-16384,16384]	1

CEC3: Lennard–Jones minimum energy cluster	18	[-4,4]	1
CEC4: Rastrigin's function	10	[-100,100]	1
CEC5: Griewangk's function	10	[-100,100]	1
CEC6: Weierstrass function	10	[-100,100]	1
CEC7: Modified Schwefel's function	10	[-100,100]	1
CEC8: Expanded Schaffer's F06 Function	10	[-100,100]	1
CEC9: Happy cat function	10	[-100,100]	1
CEC10: Ackley function	10	[-100,100]	1

III 1.2.2 تطبيق خوارزمية SWO على مجموعة دوال 2019

فيما يلي، سنعرض نتائج دوال 2019 Benchmark-CEC:





الشكل 3.5 منحنيات التقارب التي تم الحصول عليها باستخدام طريقة SWO والعديد من الطرق الاستدلالية مع وظائف الاختبار 2019.

III 2.2.2 مناقشة النتائج '2':

أظهرت خوارزمية Spider Wasp Optimizer (SWO) أداءً متبايناً عند تطبيقها على مجموعة وظائف CEC 2019، حيث برزت قوتها في بعض الوظائف ذات الطبيعة متعددة القمم، بينما واجهت تحديات واضحة في وظائف أخرى، خصوصاً الأحادية القمة أو تلك التي تتطلب استقراراً عالياً في النتائج.

1. الوظائف التي تفوقت فيه SWO :

• CEC3 :

وهي دالة متعددة القمم ذات بنية بسيطة نسبياً، وقد حققت فيها SWO قيمة Best بلغت $(1.2702e+01)$ ، وهي متطابقة تقريباً مع أفضل النتائج التي قدمتها خوارزميات رائدة مثل EO و MPA و PFA. هذا يدل على قدرة الخوارزمية العالية على الاستغلال الفعال لمناطق البحث المربحة، وعلى دقة في الوصول إلى الحلول المثلى.

• CEC6 :

تفوقت SWO على خوارزميات مثل EO ، MRFO ، و MPA في كل من القيمتين Mean و Best ، مما يعكس أداءً قوياً واستقراراً نسبياً في البحث. وعلى الرغم من أن SMA أظهرت أداءً متوسطاً أفضل بقليل، فإن SWO حافظت على مستوى تنافسي ملحوظ، خصوصاً مقارنة بخوارزميات أقل أداءً مثل JS و GNDO.

• CEC8 و CEC9 :

في هاتين الدالتين، أظهرت SWO أداءً ضمن النطاق المقبول. ففي CEC8 ، كانت القيمة المتوسطة قريبة من نتائج خوارزميات قوية مثل EO و PFA. أما في CEC9 ، فرغم أن أداءها لم يكن الأفضل، إلا أنه تفوق بوضوح على GNDO و MRFO و JS ، مما يشير إلى مرونة نسبية في التعامل مع الوظائف المعقدة.

2. الوظائف التي أظهرت فيها SWO أداءً ضعيفاً نسبياً:

• CEC1 :

وهي دالة أحادية القمة بسيطة، أظهرت فيها SWO أداءً ضعيفاً بشكل واضح. حيث بلغت القيمة المتوسطة للنتائج حوالي $(3.46e+10)$ ، مقارنة بـ $(5.22e+04)$ فقط لخوارزمية SMA. هذا الفارق الكبير يشير إلى قصور في آلية الاستغلال المبكر أو إلى ميل الخوارزمية نحو التشعب السريع في بيئات بحث بسيطة.

• CEC2 :

بالرغم من أن القيمة Best التي حققتها SWO كانت مقاربة لما حققته MPA و SMA ، إلا أن متوسط الأداء $(Mean = 485.36)$ والانحراف المعياري المرتفع أظهر عدم استقرار كبير في النتائج، مقارنة بخوارزميات مثل EO التي قدمت متوسطاً يبلغ (17.34) فقط.

• CEC4 و CEC7 :

في CEC4 ، قدمت SWO أداءً متوسطاً إلى ضعيف، في ظل تفوق واضح لخوارزميات مثل SMA و PFA. أما في CEC7 ، فرغم تحقيقها لقيمة Best منخفضة جداً (2.19) ، مما يشير إلى إمكانية الوصول إلى حلول مثالية، إلا أن متوسط الأداء (628.87) المصحوب بانحراف معياري كبير يدل على أن الخوارزمية تواجه صعوبة في الحفاظ على هذا الأداء المثالي بشكل منتظم.

3- نتائج SWO وغيرها من المقاييس الوصفية لوظائف اختبار المعايير 2019/2005:

تم اختبار خوارزمية **Spider Wasp Optimizer (SWO)** على 23 دالة اختبار تقليدية ضمن مجموعة وظائف 2005 القياسية (الجدول 5.III)، بالإضافة إلى عشر دوال اختبار حديثة من مجموعة CEC-C06 لعام 2019 (الجدول 6.III). وتمت مقارنة نتائجها مع نتائج مجموعة من الخوارزميات الميتا-ابتكارية الأخرى، وهي:

• خوارزمية التوازن (Equilibrium Optimizer - EO)

- خوارزمية التوزيع الطبيعي المعمم (Generalized Normal Distribution Optimization - GNDO)
- خوارزمية التطفل بالأشعة البحرية (Manta Ray Foraging Optimization - MRFO)
- خوارزمية المفترس البحري (Marine Predator Algorithm - MPA)
- خوارزمية العفن اللزج (Slime Mould Algorithm - SMA)
- خوارزمية صقور هاريس (Harris Hawks Optimization - HHO)
- خوارزمية الباحث عن المسار (Path Finder Algorithm - PFA)
- خوارزمية قنديل البحر (Jellyfish Search - JS)

تم تنفيذ كل خوارزمية مرة، وتم قياس كل من المتوسط الحسابي والانحراف المعياري للقيم الناتجة. كما تم تصنيف الخوارزميات من الأفضل إلى الأسوأ بناءً على دقة الحل الأمثل. (Opt)

الجدول 5.III نتائج SWO وغيرها من الخوارزميات الفوقية للوظيفة متعددة الوسائط عالية الأبعاد على 23 دالة اختبار تقليدية ضمن مجموعة وظائف 2005 القياسية

	Algorithm	Best	Mean	Std
Function F01	EO	7.6500e-154	1.0631e-149	5.4645e-149
	GNDO	8.0626e+02	2.1797e+03	7.7678e+02
	MRFO	4.5587e+03	8.1125e+03	1.8971e+03
	MPA	1.6001e+03	8.6781e+03	4.2333e+03
	SMA	4.1934e+02	1.0153e+03	3.2591e+02
	HHO	2.3963e-22	9.0602e-11	3.7018e-10
	PFA	3.3163e-02	5.6763e-02	1.5782e-02
	JS	2.1770e+03	4.0281e+03	1.1248e+03
	SWO	2.1915e+03	4.1266e+03	1.1397e+03
Function F02	EO	6.1942e-81	4.8892e-79	1.0579e-78
	GNDO	6.0827e+00	1.6461e+01	5.4045e+00
	MRFO	3.1937e+01	4.2122e+01	5.7192e+00
	MPA	2.1044e+00	9.1252e+00	4.2112e+00
	SMA	1.7274e+00	4.0150e+00	1.3344e+00
	HHO	1.0900e-13	8.8165e+00	8.8507e+00
	PFA	1.2128e+00	3.4076e+00	1.6517e+00
	JS	1.7985e+01	2.9244e+01	6.4978e+00
	SWO	2.1183e+01	3.4445e+01	8.6418e+00

Function F03	EO	2.7437e-82	9.7726e-75	4.7889e-74
	GNDO	1.1061e+03	4.6911e+03	3.1482e+03
	MRFO	1.1631e+04	2.5949e+04	9.7059e+03
	MPA	4.5251e+04	7.2275e+04	1.1927e+04
	SMA	1.5002e+02	5.3203e+02	2.8866e+02
	HHO	6.3563e+02	1.3356e+03	4.8490e+02
	PFA	2.6402e+00	1.0604e+01	4.5754e+00
	JS	4.5407e+03	1.0110e+04	3.2064e+03
	SWO	3.0540e+03	1.0157e+04	4.9991e+03
Function F04	EO	8.2405e-56	2.0243e-53	7.8488e-53
	GNDO	1.0472e+01	1.5844e+01	2.4235e+00
	MRFO	2.3841e+01	3.1071e+01	4.7434e+00
	MPA	7.5775e+01	8.6596e+01	4.2019e+00
	SMA	1.1555e+01	1.5503e+01	2.5543e+00
	HHO	2.5315e+00	6.7269e+00	3.6599e+00
	PFA	4.2047e-01	1.8294e+00	1.3755e+00
	JS	1.7941e+01	2.4652e+01	4.3025e+00
	SWO	1.6558e+01	2.4327e+01	3.8861e+00
Function F05	EO	2.7649e+01	2.8064e+01	2.8992e-01
	GNDO	1.1348e+05	4.4065e+05	2.7092e+05
	MRFO	1.6677e+06	5.1834e+06	3.0119e+06
	MPA	4.6082e+05	3.4108e+07	3.2878e+07
	SMA	1.6869e+04	1.1673e+05	7.6264e+04
	HHO	2.8417e+01	2.9273e+01	2.1110e+00
	PFA	3.3504e+01	2.2440e+02	3.3115e+02
	JS	2.4629e+05	1.1091e+06	6.5043e+05
	SWO	3.7335e+05	1.3278e+06	8.6885e+05

Function F06	EO	2.3719e+00	3.0430e+00	3.5343e-01
	GNDO	1.0572e+03	2.5552e+03	7.3840e+02
	MRFO	4.1153e+03	8.0703e+03	1.8164e+03
	MPA	2.2393e+03	8.8917e+03	4.9958e+03
	SMA	3.3961e+02	1.0850e+03	4.8814e+02
	HHO	1.2820e+00	2.2738e+00	5.6407e-01
	PFA	3.2336e-02	6.3556e-02	2.0144e-02
	JS	2.2776e+03	4.1409e+03	1.2191e+03
	SWO	2.6167e+03	4.9263e+03	1.3982e+03

Function F07	EO	1.0309e-04	4.7813e-04	3.1684e-04
	GNDO	7.2498e-02	3.3679e-01	2.2381e-01
	MRFO	4.6786e-01	2.5990e+00	1.3480e+00
	MPA	2.1843e+00	1.9063e+01	1.2074e+01
	SMA	1.6806e-02	4.3893e-02	1.8469e-02
	HHO	5.0456e-02	3.2397e+00	3.9248e+00
	PFA	8.3451e-02	1.6368e-01	4.6684e-02
	JS	2.9534e-01	7.0375e-01	3.6099e-01
	SWO	2.9975e-01	8.6048e-01	3.9665e-01
Function F08	EO	-4.5807e+03	-4.0046e+03	3.0894e+02
	GNDO	-5.3347e+03	-4.0534e+03	5.1548e+02
	MRFO	-5.3188e+03	-4.3367e+03	4.2346e+02
	MPA	-6.1777e+03	-5.0965e+03	5.2484e+02
	SMA	-5.6648e+03	-5.0928e+03	2.7892e+02
	HHO	-6.1333e+03	-5.7224e+03	1.6862e+02
	PFA	-8.6834e+03	-7.1040e+03	7.6221e+02
	JS	-3.7971e+03	-2.8128e+03	5.1713e+02
	SWO	-5.6117e+03	-4.2062e+03	6.6152e+02
Function F09	EO	0.0000e+00	1.6606e-01	9.0954e-01
	GNDO	1.3957e+02	1.8131e+02	2.2289e+01
	MRFO	1.8150e+02	2.0457e+02	1.3964e+01
	MPA	1.3654e+02	2.5393e+02	5.2159e+01
	SMA	1.3360e+02	1.6218e+02	1.3689e+01
	HHO	7.1204e+01	1.6256e+02	5.5299e+01
	PFA	3.9356e+01	6.4099e+01	1.5002e+01
	JS	1.6210e+02	2.0878e+02	2.0391e+01
	SWO	1.5082e+02	1.9718e+02	2.3397e+01

Function F10	EO	4.4409e-15	5.8620e-15	1.7702e-15
	GNDO	8.1089e+00	1.0651e+01	8.2885e-01
	MRFO	1.2801e+01	1.4349e+01	7.0132e-01
	MPA	7.6854e+00	1.8690e+01	2.9911e+00
	SMA	1.2796e+01	1.7109e+01	2.3863e+00
	HHO	7.9625e-12	2.4866e+00	6.0391e+00
	PFA	2.7197e-01	1.3791e+00	6.5864e-01
	JS	9.6465e+00	1.1916e+01	9.1586e-01
	SWO	1.0711e+01	1.2400e+01	9.5096e-01

Function F11	EO	0.0000e+00	6.4079e-03	1.1619e-02
	GNDO	1.2516e+01	2.3543e+01	6.4270e+00
	MRFO	5.1368e+01	8.2259e+01	1.7838e+01
	MPA	1.6243e+01	7.8800e+01	4.9191e+01
	SMA	3.3866e+00	9.2368e+00	4.0934e+00
	HHO	0.0000e+00	1.3930e-01	1.2698e-01
	PFA	8.1727e-03	2.8809e-02	1.3314e-02
	JS	2.0817e+01	3.6422e+01	1.0255e+01
	SWO	2.2553e+01	4.5179e+01	1.5084e+01
Function F12	EO	1.3662e-01	2.4635e-01	7.7679e-02
	GNDO	8.8809e+00	9.2356e+01	3.6717e+02
	MRFO	1.3806e+04	6.5592e+05	6.7335e+05
	MPA	3.2209e+06	1.6162e+08	1.3741e+08
	SMA	2.7542e+00	7.1530e+00	4.2243e+00
	HHO	1.7571e-01	6.6503e+00	3.3904e+00
	PFA	4.8870e+00	9.5601e+00	4.2002e+00
	JS	2.0592e+01	2.3005e+04	7.2455e+04
	SWO	1.1809e+01	1.5710e+04	4.8594e+04
Function F13	EO	1.3185e+00	1.8094e+00	1.9715e-01
	GNDO	1.8313e+03	2.0957e+05	4.9768e+05
	MRFO	1.2996e+06	6.4237e+06	5.9661e+06
	MPA	8.1230e+06	3.9112e+08	2.3744e+08
	SMA	2.5307e+01	5.1856e+03	1.2320e+04
	HHO	3.1542e-01	1.1795e+00	6.9746e-01
	PFA	1.0609e-02	3.1198e-02	1.3062e-02
	JS	6.3756e+03	7.8191e+05	6.7428e+05
	SWO	7.5436e+03	7.2683e+05	8.3902e+05

Function F14	EO	9.9800e-01	1.7220e+00	1.6566e+00
	GNDO	9.9800e-01	8.0146e+00	5.1890e+00
	MRFO	9.9800e-01	2.6088e+00	2.7392e+00
	MPA	9.9800e-01	1.3134e+00	5.4642e-01
	SMA	9.9800e-01	9.9820e-01	8.7687e-04
	HHO	9.9800e-01	9.9800e-01	1.2745e-15
	PFA	9.9800e-01	1.8534e+00	1.7993e+00
	JS	1.0566e+00	7.7663e+00	3.9865e+00
	SWO	9.9800e-01	5.0535e+00	3.7495e+00

Function F15	EO	3.0774e-04	5.3548e-03	9.0801e-03
	GNDO	3.1096e-04	3.9662e-03	5.5076e-03
	MRFO	1.4755e-03	1.3863e-02	1.4710e-02
	MPA	5.0446e-04	1.1465e-03	3.5079e-04
	SMA	6.8981e-04	7.6593e-03	1.6057e-02
	HHO	3.0760e-04	8.0560e-04	3.5813e-04
	PFA	3.2380e-04	5.3328e-03	8.4402e-03
	JS	9.4903e-04	1.4214e-02	1.5677e-02
	SWO	3.5330e-04	5.1162e-03	7.9381e-03
Function F16	EO	-1.0316e+00	-1.0316e+00	3.4612e-11
	GNDO	-1.0316e+00	-1.0316e+00	6.2532e-16
	MRFO	-1.0316e+00	-1.0312e+00	1.4034e-03
	MPA	-1.0316e+00	-1.0316e+00	3.6984e-06
	SMA	-1.0316e+00	-1.0313e+00	5.1830e-04
	HHO	-1.0316e+00	-1.0316e+00	6.8501e-16
	PFA	-1.0316e+00	-1.0316e+00	3.1164e-06
	JS	-1.0316e+00	-1.0173e+00	6.1104e-02
	SWO	-1.0316e+00	-1.0316e+00	6.5843e-16
Function F17	EO	3.9789e-01	3.9798e-01	5.0370e-04
	GNDO	3.9789e-01	3.9789e-01	0.0000e+00
	MRFO	3.9789e-01	4.0550e-01	1.6232e-02
	MPA	3.9789e-01	3.9823e-01	6.7402e-04
	SMA	3.9789e-01	3.9854e-01	1.1879e-03
	HHO	3.9789e-01	3.9789e-01	4.5015e-07
	PFA	3.9789e-01	3.9789e-01	4.1212e-06
	JS	3.9789e-01	5.3331e-01	2.0338e-01
	SWO	3.9789e-01	3.9789e-01	2.2704e-15

Function F18	EO	3.0000e+00	5.7000e+00	1.4789e+01
	GNDO	3.0000e+00	4.8000e+00	6.8501e+00
	MRFO	3.0000e+00	3.0029e+00	6.9572e-03
	MPA	3.0002e+00	3.0014e+00	1.0650e-03
	SMA	3.0000e+00	3.0000e+00	6.5133e-05
	HHO	3.0000e+00	3.0000e+00	2.0832e-14
	PFA	3.0000e+00	3.0002e+00	1.9876e-04
	JS	3.0000e+00	5.1122e+00	5.5747e+00
	SWO	3.0000e+00	3.0000e+00	9.6170e-16

Function F19	EO	-3.8628e+00	-3.8612e+00	3.2064e-03
	GNDO	-3.8628e+00	-3.8568e+00	1.5151e-02
	MRFO	-3.8578e+00	-3.7881e+00	5.4704e-02
	MPA	-3.8628e+00	-3.8628e+00	2.6684e-15
	SMA	-3.8628e+00	-3.8459e+00	3.4394e-02
	HHO	-3.8628e+00	-3.8628e+00	2.9541e-05
	PFA	-3.8628e+00	-3.8626e+00	1.1477e-04
	JS	-3.8518e+00	-3.6889e+00	2.0606e-01
	SWO	-3.8628e+00	-3.8626e+00	6.4571e-04
Function F20	EO	-3.3220e+00	-3.2048e+00	1.1262e-01
	GNDO	-3.3072e+00	-3.0726e+00	1.6662e-01
	MRFO	-2.9889e+00	-2.4159e+00	4.4184e-01
	MPA	-3.3220e+00	-3.2388e+00	5.5415e-02
	SMA	-3.3220e+00	-3.2309e+00	9.4623e-02
	HHO	-3.3213e+00	-3.2492e+00	7.1852e-02
	PFA	-3.3217e+00	-3.2504e+00	6.1659e-02
	JS	-3.1444e+00	-2.4606e+00	5.0350e-01
	SWO	-3.2937e+00	-3.1226e+00	1.2352e-01
Function F21	EO	-1.0153e+01	-7.0213e+00	2.8206e+00
	GNDO	-1.0151e+01	-6.1533e+00	3.3833e+00
	MRFO	-9.4519e+00	-4.8449e+00	1.7577e+00
	MPA	-1.0153e+01	-6.6464e+00	3.2608e+00
	SMA	-1.0153e+01	-5.9766e+00	3.3674e+00
	HHO	-1.0153e+01	-6.7512e+00	2.4406e+00
	PFA	-1.0153e+01	-7.2272e+00	3.2876e+00
	JS	-9.2661e+00	-3.0958e+00	1.6313e+00
	SWO	-1.0153e+01	-6.0259e+00	3.1445e+00

Function F22	EO	-1.0403e+01	-7.3265e+00	3.2060e+00
	GNDO	-1.0403e+01	-6.9438e+00	3.4165e+00
	MRFO	-1.0079e+01	-4.7455e+00	2.2634e+00
	MPA	-1.0403e+01	-7.4031e+00	3.2356e+00
	SMA	-1.0403e+01	-6.4202e+00	3.6397e+00
	HHO	-1.0403e+01	-6.8482e+00	2.5362e+00
	PFA	-1.0403e+01	-7.6089e+00	3.5331e+00
	JS	-1.0319e+01	-4.1024e+00	2.9900e+00
	SWO	-1.0403e+01	-6.7230e+00	3.3586e+00

Function F23	EO	-1.0536e+01	-6.5151e+00	3.6820e+00
	GNDO	-1.0530e+01	-5.3786e+00	3.3940e+00
	MRFO	-7.2316e+00	-4.3929e+00	1.4772e+00
	MPA	-1.0536e+01	-8.1768e+00	3.3995e+00
	SMA	-1.0536e+01	-4.8133e+00	3.5509e+00
	HHO	-1.0536e+01	-6.5814e+00	2.9718e+00
	PFA	-1.0536e+01	-9.2870e+00	2.8710e+00
	JS	-1.0469e+01	-3.7569e+00	2.3929e+00
	SWO	-1.0536e+01	-4.9414e+00	3.1000e+00

الجدول 6.III نتائج SWO وغيرها من الخوارزميات الفوقية للوظيفة متعددة الوسائط عالية الأبعاد على 10 دوال اختبار حديثة من مجموعة CEC-C06 لعام 2019

Function CEC1	EO	3.8360e+04	9.8715e+04	1.7274e+05
	GNDO	2.8456e+08	1.8223e+10	2.1157e+10
	MRFO	7.8572e+09	3.8052e+11	5.8487e+11
	MPA	6.2324e+09	5.5866e+10	4.2001e+10
	SMA	3.3058e+04	5.2196e+04	2.4788e+04
	HHO	4.6406e+07	8.8067e+09	8.7863e+09
	PFA	1.7910e+06	9.8026e+07	1.5890e+08
	JS	5.2038e+09	1.7398e+11	1.9689e+11
	SWO	7.9461e+08	3.4692e+10	3.8105e+10
Function CEC2	EO	1.7343e+01	1.7345e+01	1.4430e-03
	GNDO	1.8100e+01	2.4605e+02	3.6314e+02
	MRFO	2.5364e+02	3.0063e+03	1.7772e+03
	MPA	1.7454e+01	1.7576e+01	7.1271e-02
	SMA	1.7343e+01	1.7496e+01	2.0911e-01
	HHO	1.7343e+01	1.7352e+01	5.3000e-03
	PFA	1.7344e+01	1.7345e+01	6.3615e-04
	JS	1.5355e+02	1.9521e+03	1.2982e+03
	SWO	1.7558e+01	4.8536e+02	7.0198e+02
Function CEC3	EO	1.2702e+01	1.2702e+01	2.3148e-07
	GNDO	1.2702e+01	1.2703e+01	5.2476e-04
	MRFO	1.2702e+01	1.2704e+01	9.3878e-04
	MPA	1.2702e+01	1.2702e+01	6.4518e-05
	SMA	1.2702e+01	1.2704e+01	1.7620e-03
	HHO	1.2702e+01	1.2702e+01	3.0566e-06
	PFA	1.2702e+01	1.2702e+01	7.8914e-08

	JS	1.2702e+01	1.2704e+01	9.7913e-04
	SWO	1.2702e+01	1.2703e+01	8.1915e-04
Function CEC4	EO	7.2544e+01	3.5482e+02	4.7649e+02
	GNDO	2.1052e+03	9.7685e+03	4.5918e+03
	MRFO	1.2258e+03	9.3975e+03	4.9448e+03
	MPA	4.2264e+02	7.3299e+02	3.3448e+02
	SMA	2.2023e+01	3.1817e+01	5.3082e+00
	HHO	2.3141e+01	6.2682e+01	3.0331e+01
	PFA	8.3915e+00	2.4659e+01	9.7438e+00
	JS	6.6134e+03	1.7035e+04	5.9881e+03
	SWO	1.1467e+03	6.3134e+03	3.6376e+03
	Function CEC5	EO	1.3492e+00	1.6073e+00
GNDO		1.7734e+00	3.7607e+00	8.8116e-01
MRFO		2.0351e+00	3.3622e+00	9.4727e-01
MPA		1.9392e+00	2.1273e+00	8.1261e-02
SMA		1.3680e+00	2.1429e+00	5.8108e-01
HHO		1.1560e+00	1.4865e+00	3.3647e-01
PFA		1.1109e+00	1.7035e+00	5.8220e-01
JS		2.3995e+00	4.2547e+00	8.3351e-01
SWO		1.8473e+00	2.8648e+00	6.7385e-01
Function CEC6	EO	6.8883e+00	9.0643e+00	1.1934e+00
	GNDO	6.7907e+00	9.9336e+00	1.1932e+00
	MRFO	9.4210e+00	1.0773e+01	6.5162e-01
	MPA	9.4800e+00	1.0790e+01	6.7434e-01
	SMA	5.5918e+00	7.5843e+00	1.0222e+00
	HHO	6.5014e+00	9.1685e+00	1.1175e+00
	PFA	9.9966e+00	1.1004e+01	5.8767e-01
	JS	7.6946e+00	1.0024e+01	1.0699e+00
	SWO	6.9968e+00	9.8434e+00	1.0673e+00
Function CEC7	EO	3.5150e+01	3.8217e+02	1.6598e+02
	GNDO	2.5062e+02	8.0789e+02	2.9759e+02
	MRFO	2.2036e+02	5.8464e+02	1.9133e+02
	MPA	3.0073e+02	6.3821e+02	1.9397e+02
	SMA	3.3121e+02	5.9608e+02	1.5342e+02
	HHO	5.4268e+01	4.0015e+02	1.5816e+02
	PFA	-9.7477e+01	2.0002e+02	1.6022e+02
	JS	3.0015e+02	1.0350e+03	3.7874e+02

	SWO	2.1910e+00	6.2887e+02	2.7799e+02
Function CEC8	EO	3.8192e+00	5.1517e+00	7.6317e-01
	GNDO	4.9936e+00	6.0375e+00	4.6538e-01
	MRFO	3.8402e+00	5.2708e+00	7.1013e-01
	MPA	5.5859e+00	6.3249e+00	3.6120e-01
	SMA	4.9070e+00	6.2310e+00	5.2339e-01
	HHO	4.7266e+00	5.8494e+00	4.5753e-01
	PFA	3.5383e+00	5.1278e+00	8.3561e-01
	JS	4.4362e+00	6.0908e+00	6.7399e-01
	SWO	4.7561e+00	5.9571e+00	4.8471e-01
Function CEC9	EO	3.8741e+00	5.3255e+00	6.1991e-01
	GNDO	9.4531e+01	1.3225e+03	7.6989e+02
	MRFO	1.1635e+02	1.4934e+03	9.0791e+02
	MPA	2.7398e+02	5.6113e+02	2.0388e+02
	SMA	2.5008e+00	3.3059e+00	3.5625e-01
	HHO	2.3954e+00	2.4689e+00	4.9067e-02
	PFA	2.3423e+00	2.3578e+00	8.0553e-03
	JS	3.0651e+02	1.6306e+03	8.2648e+02
	SWO	1.2790e+02	7.4564e+02	4.9447e+02
Function CEC10	EO	7.5617e+00	1.9831e+01	2.3188e+00
	GNDO	2.0102e+01	2.0381e+01	1.4418e-01
	MRFO	1.9284e+01	2.0405e+01	2.2891e-01
	MPA	2.0345e+01	2.0481e+01	6.2190e-02
	SMA	2.0000e+01	2.0021e+01	9.4148e-02
	HHO	2.0087e+01	2.0249e+01	1.0417e-01
	PFA	2.0202e+01	2.0466e+01	1.0284e-01
	JS	1.9963e+01	2.0416e+01	1.3986e-01
	SWO	1.9067e+01	2.0262e+01	2.5493e-01

3.III تحليل أداء خوارزمية SWO:

❖ بالنسبة لدوال Unimodal عالية الأبعاد (F01–F07):

تم تصنيف خوارزمية SWO في المرتبة الثانية في الدالة F05، وفي المرتبة الثالثة في F02، بينما جاءت في مراكز متأخرة في بقية الدوال، مما يدل على أن قدرتها على الاستغلال متوسطة ومحدودة مقارنة بالخوارزميات الأخرى.

❖ بالنسبة لدوال Multimodal عالية الأبعاد (F08–F13):

حققت SWO المرتبة الأولى في F13، وجاءت ثانية في F12، وثالثة في F11، مما يشير إلى امتلاكها قدرة استكشافية قوية في بيئات متعددة القمم.

❖ بالنسبة لدوال Multimodal منخفضة الأبعاد (F14–F23):

حصلت SWO على المرتبة الأولى في F14 والثانية في F16، لكنها جاءت في مراتب متأخرة (6، 7 أو 8) في معظم الدوال الأخرى، مما يدل على أن أداءها متوسط إلى ضعيف في هذا النوع من الدوال.

❖ على دوال اختبار CEC-C06 2019:

احتلت SWO المرتبة الأولى في CEC3 والثالثة في CEC1 وCEC2.

لكن في بقية الدوال (CEC4 إلى CEC10)، كانت في المرتبة الأخيرة تقريباً، مما يشير إلى أن أداءها العام في هذا المعيار غير مستقر وضعيف نسبياً.

4.III تطبيق خوارزمية SWO على متحكم PID لتحسين معاملاته :

1.4.III- الجزء لنظري: نظام الكتلة-المخمّد-النابض (Mass-Damper-Spring System)

هو نموذج ميكانيكي كلاسيكي يُستخدم على نطاق واسع في تحليل الأنظمة الفيزيائية وتمثيلها رياضياً، خصوصاً في مجال أنظمة التحكم والتحكم بالاهتزازات. وهو يمثل حركة جسم تحت تأثير قوة خارجية ويقاوم الحركة من خلال نابض ومخمّد.

1.1.4.III-تعريف النظام:

نظام الكتلة-المخمّد-النابض هو نظام يتكون من:

➤ كتلة m (Mass): جسم يتحرك على سطح أو في مسار معين، وله كتلة تُقاس بالكيلوغرام (kg).

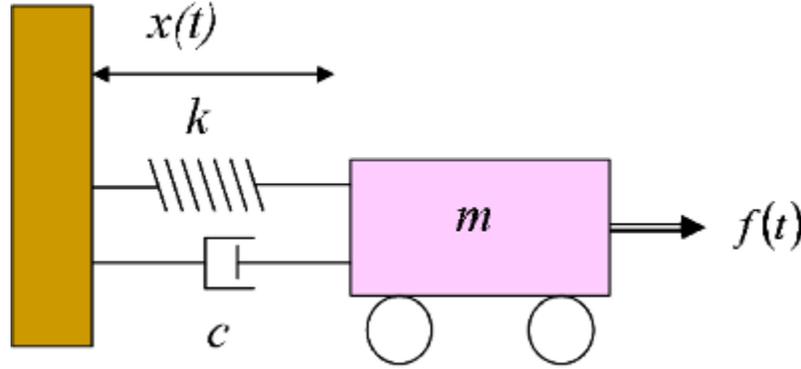
➤ نابض (Spring) –معامل النابض k :

يولّد قوة استرجاعية تتناسب مع الإزاحة (وفقاً لقانون هوك) $F = -kx$ ، حيث k بوحدة نيوتن/متر (N/m).

➤ مخمّد (Damper) –معامل التخميد c :

يولّد قوة مقاومة تتناسب مع سرعة الحركة (قوة لزجة) $F = -cx$ ، حيث c بوحدة نيوتن·ثانية/متر (Ns/m).

➤ قوة خارجية: $F(t)$ (Input Force) القوة التي تُطبق على الكتلة لتحريكها [17].



الشكل III.6 : نموذج كتلة-نابض-مخمّد. (Mass-Spring-Damper system).

III.2.1.4 - المعادلة التفاضلية للنظام:

وفقاً لقانون نيوتن الثاني (مجموع القوى = الكتلة × التسارع):

$$m\ddot{x}(t) + c\dot{x}(t) + kx(t) = F(t)$$

السرعة: $\dot{x}(t)$

الإزاحة كدالة في الزمن: $x(t)$

القوة المؤثرة: $F(t)$

التسارع: $\ddot{x}(t)$

• الدالة التحويلية: (Transfer Function)

⇐ في المجال الزمني:

$$m\ddot{x}(t) + c\dot{x}(t) + kx(t) = F(t)$$

⇐ بعد تحويل لابلاس:

$$ms^2X(s) + csX(s) + kX(s) = F(s)$$

⇐ تجميع: $X(s)$

$$X(s)(ms^2 + cs + k) = F(s)$$

• دالة التحويل: (Transfer Function)

$$G(s) = \frac{X(s)}{F(s)} = \frac{1}{ms^2 + cs + k}$$

البيانات المستخدمة:

• الكتلة (m) : 1 كغ. • ثابت النابض k : 100 نيوتن/متر

• معامل التخميد (c) : 0.15 نيوتن·ثانية/متر

• القوة المؤثرة (F) : 100 نيوتن (قيمة ثابتة) [18]

دالة التحويل بقيم :

$$G(s) = \frac{X(s)}{F(s)} = \frac{1}{s^2 + 0.15s + 100}$$

دالة الهدف المستخدمة في تحسين PID:

أثناء تحسين معاملات متحكم PID في هذا العمل، تم اعتماد دالة هدف من نوع *ITAE (Integral of Time-weighted Absolute Error)*، وهي تُستخدم بكثرة في أنظمة التحكم نظرًا لقدرتها على إعطاء وزن زمني للأخطاء، حيث تعاقب الأخطاء التي تحدث في وقت متأخر بشكل أكبر.

الصيغة الرياضية:

$$ITAE = \int_0^T t \cdot |r(t) - y(t)| dt$$

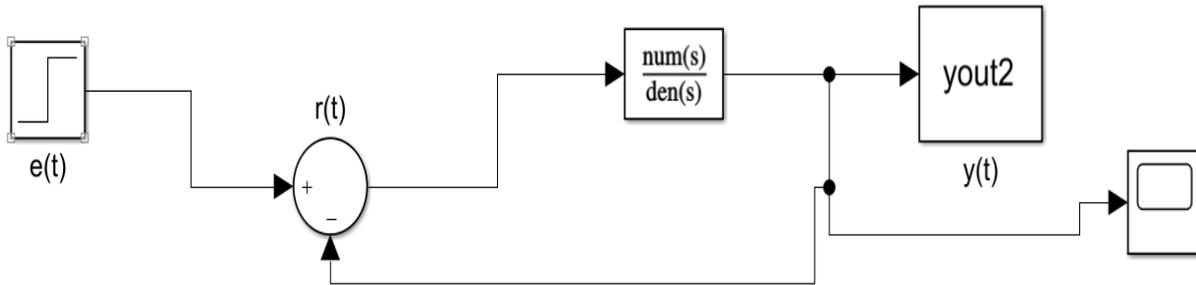
حيث:

$r(t)$: الإشارة المرجعية وغالبًا تساوي 1

$y(t)$: خرج النظام

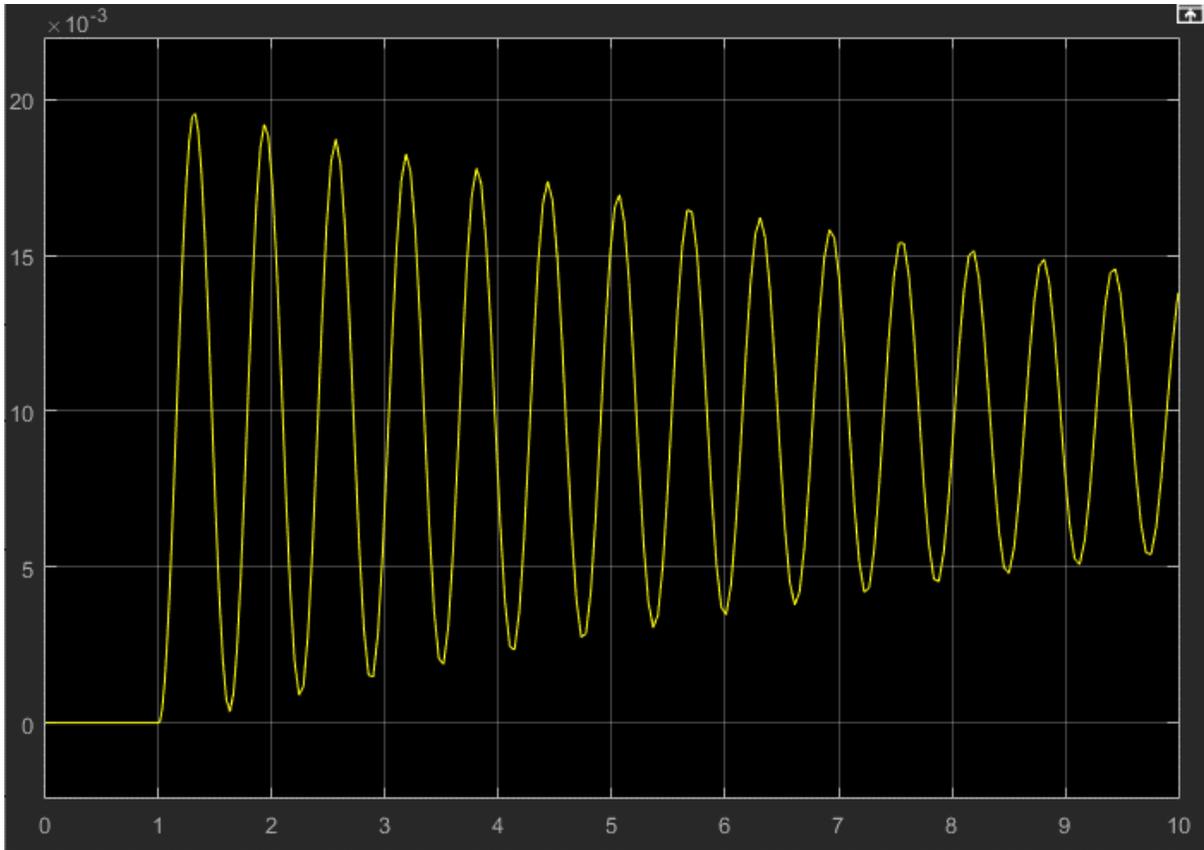
t : الزمن

III.2.4 - الجزء التطبيقي :

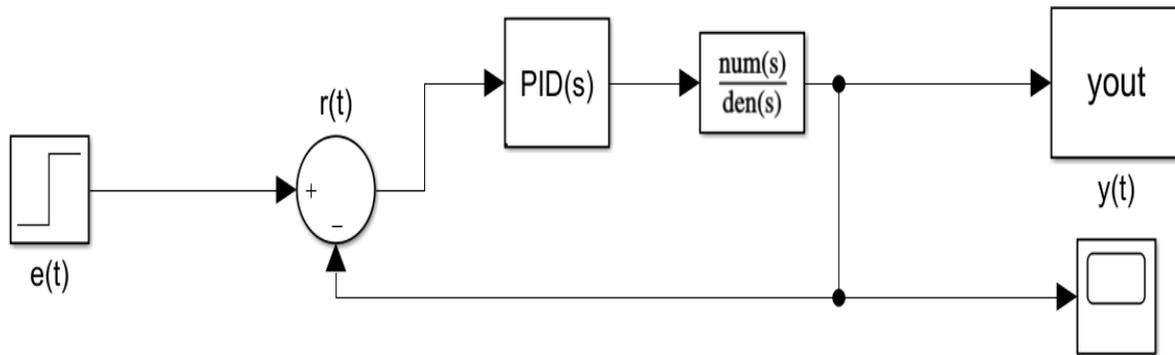


الشكل III.7 : نموذج Simulink للنظام بدون متحكم PID

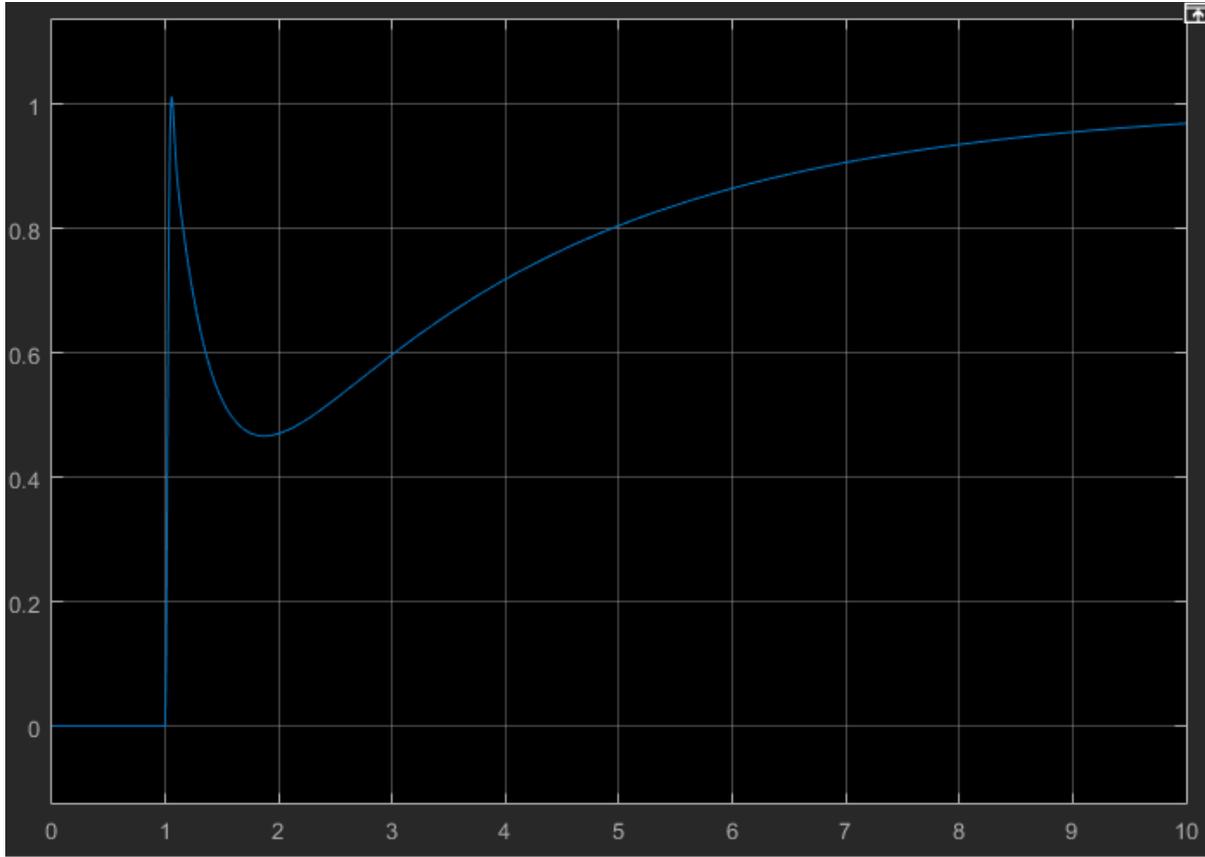
لا يتضمن تحكماً خارجي، فقط استجابة النظام الطبيعي.



الشكل III.8 : رسم استجابة النظام بدون متحكم PID



الشكل III.9 : نموذج Simulink للنظام بوجود متحكم PID



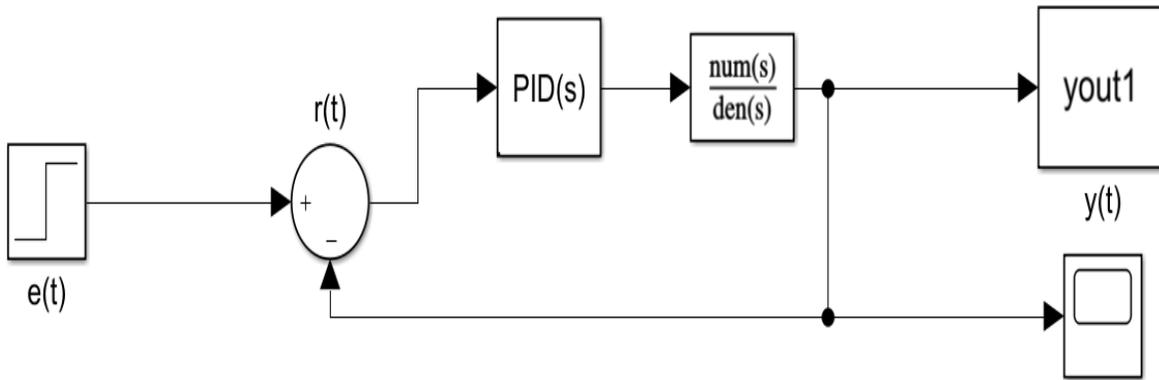
الشكل 10. III : رسم استجابة النظام بوجود متحكم PID

قبل التحسين قيم PID : $K_P = 55 ; K_I = 50 ; K_D = 50$

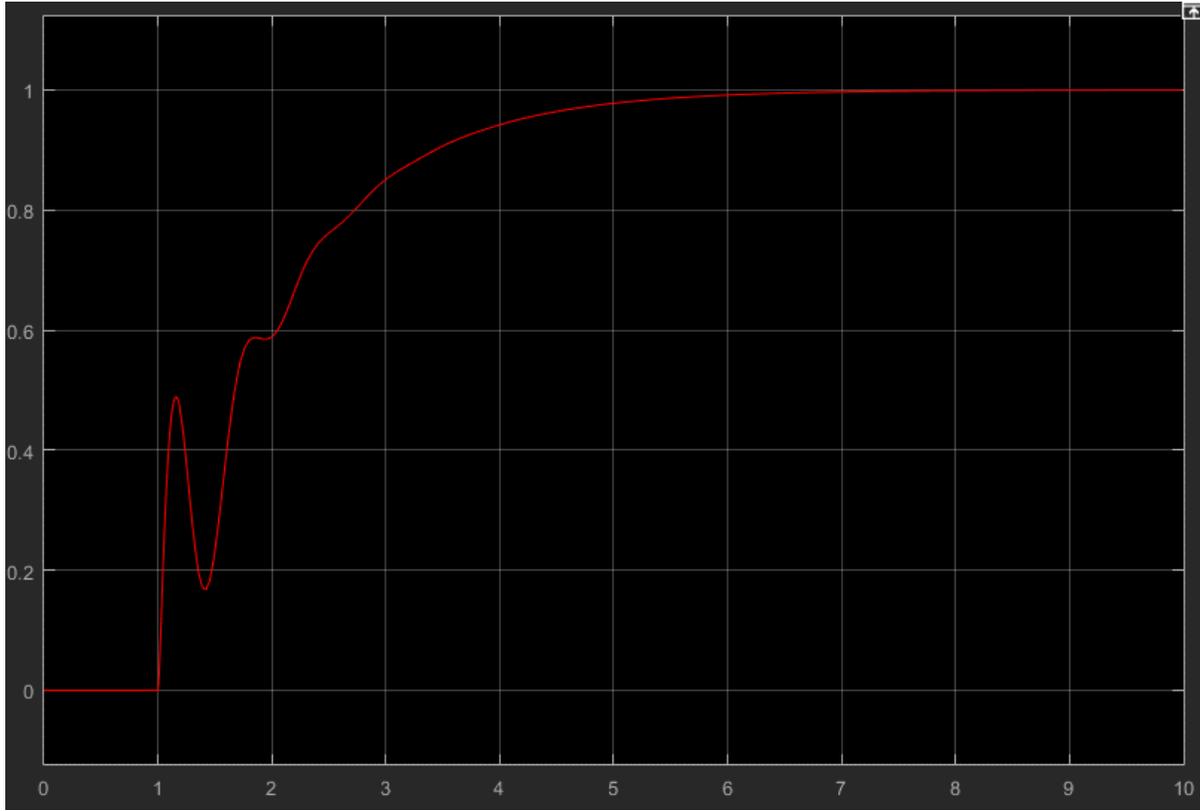
تم أخذ هذه القيم كقيم ابتدائية "يدويا"

نتائج الأداء:

Overshoot: 4.40% ; Settling Time: 8.69 s ; Steady-State Error: 0.0314



الشكل 11. III : نموذج Simulink للنظام بوجود متحكم PID



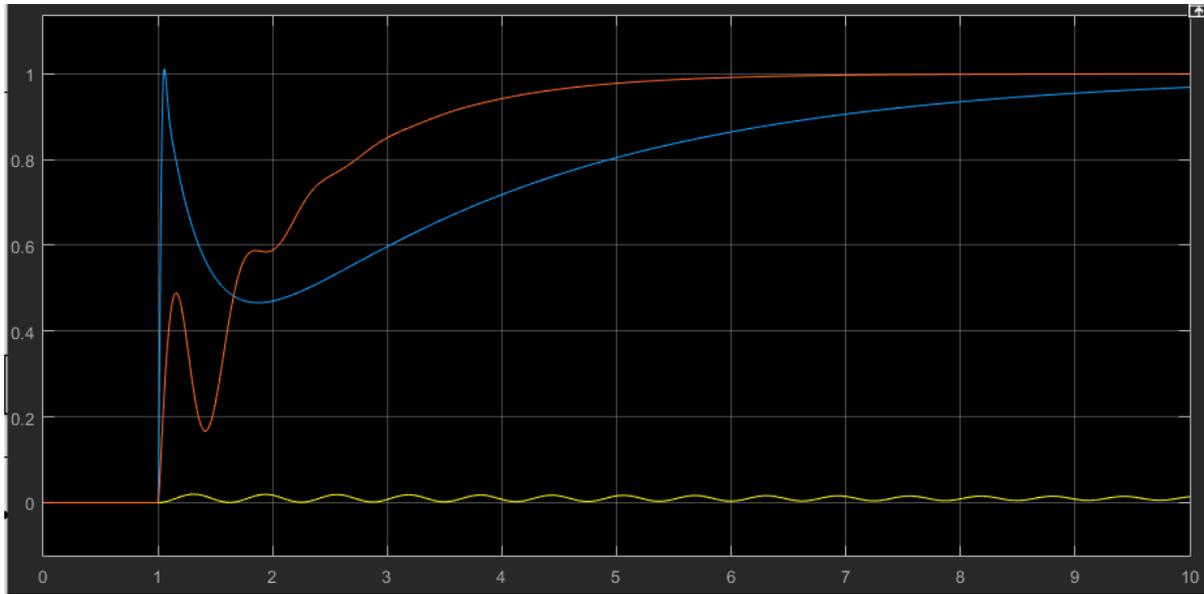
الشكل 12.III : رسم استجابة النظام بعد تحسين معاملات PID

الجدول 7.III قيم المتحكمات قبل وبعد التحسين

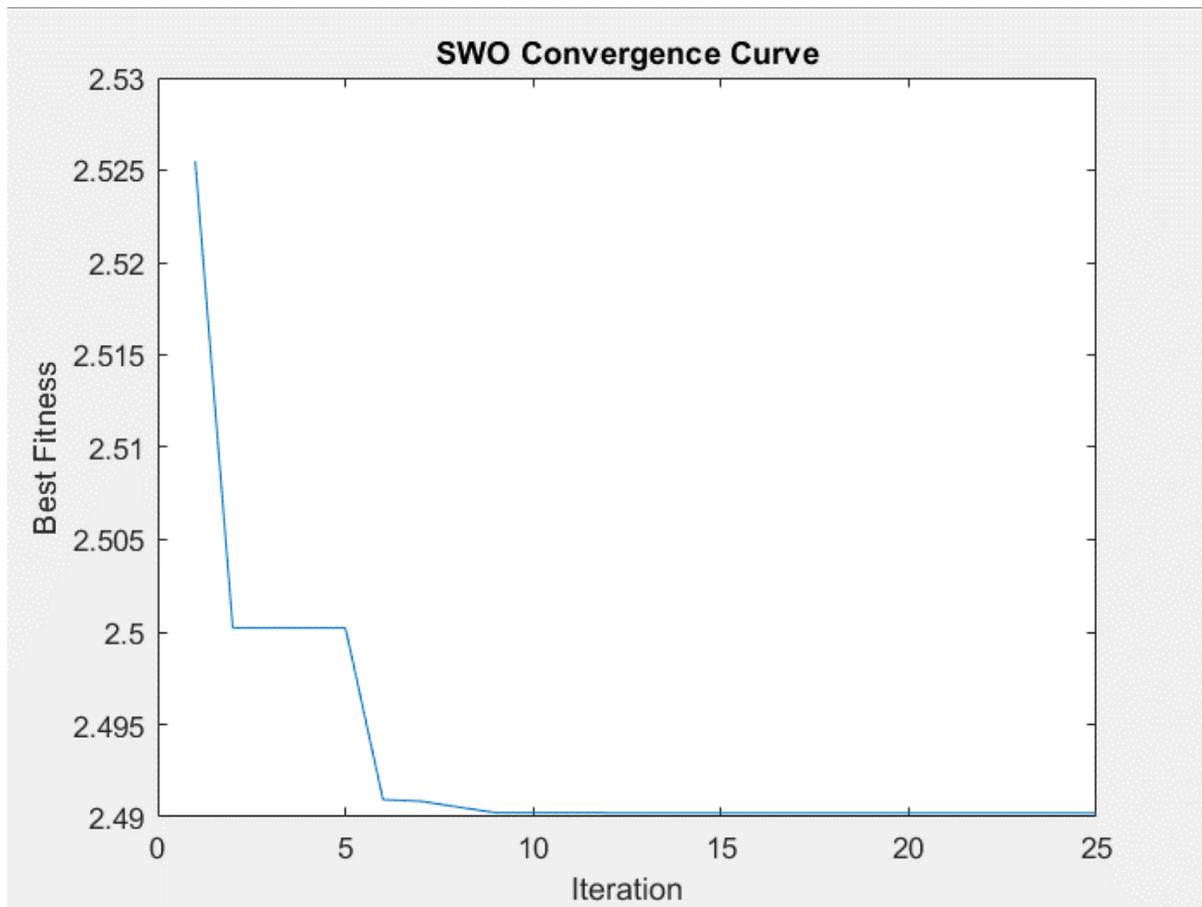
متحكمات	قبل التحسين	بعد التحسين
kp	55	7.9304
ki	50	98.3640
kd	50	6.1231

الجدول 8.III قيم الأداء قبل وبعد التحسين

الحالة	تجاوز الحد (Overshoot)	زمن الاستقرار (Settling Time)	الخطأ النهائي (Steady-State Error)
قبل التحسين	4.40%	8.69 s	0.0314
بعد التحسين (SWO)	0.00%	4.34 s	0.0223



الشكل III. 13 : رسم استجابة النظام في 3 حالات



الشكل III. 14 : منحنى تقارب خوارزمية SWO

التعليق :

يُظهر الشكل انخفاضاً سريعاً في قيمة دالة الهدف خلال التكرارات الأولى، حيث تبدأ الخوارزمية بالاستقرار تقريباً عند التكرار 10، وتبلغ قيمة ITAE النهائية حوالي 2.49 عند التكرار 25. هذا يدل على قدرة SWO على تحقيق تقارب سريع وحل فعال في عدد قليل من التكرارات.

III.1.2.4-التحليل:

1. المراحل الثلاثة وتفسير الألوان:

✓ الأصفر (قبل إضافة PID):

يمثل استجابة النظام بدون أي تحكم. نلاحظ تذبذبات واضحة، بطء في الاستجابة، وخطأ نهائي غير مهمل.

✓ الأزرق (بعد إضافة PID):

يمثل استجابة النظام بعد تطبيق وحدة تحكم PID بمعاملات يدوية (غير مُحسَّنة).

$$(K_d = 50, K_i = 50, K_p = 55)$$

التحسن الملحوظ هو تقليل التذبذبات مقارنة بالحالة الصفرية، لكن لا يزال هناك:

○ **Overshoot: 4.40%**

○ **Settling Time: 8.69** ثانية

○ **Steady-State Error: 0.0314**

أي أن النظام يستغرق وقتاً طويلاً للوصول إلى حالة الاستقرار، مع وجود نسبة خطأ غير معدومة.

✓ الأحمر (بعد تحسين PID):

يمثل استجابة النظام بعد تحسين المعاملات باستخدام خوارزمية SWO، بالمعاملات:

$$K_p = 7.9304 / K_i = 98.3640 / K_d = 6.1231$$

○ النتيجة كانت:

○ **Overshoot: 0.00%** (أي لا يوجد تجاوز للحد)

○ **Settling Time: 4.34 S**

○ **Steady-State Error: 0.0223**

هنا تكون استجابة أسرع، وأكثر ثباتاً، مع إزالة الخطأ النهائي تقريباً.

2. تحليل معاملات PID المُحسَّنة:

$$Kp = 7.9304 \quad \checkmark$$

قيمة متوسطة تضمن استجابة جيدة دون أن تسبب تذبذبًا كبيرًا. توازن بين السرعة والدقة.

$$Ki = 98.3640 \quad \checkmark$$

قيمة عالية جدًا، تدل على محاولة قوية لإزالة الخطأ النهائي بسرعة، مما يفيد في أنظمة تحتاج إلى دقة تتبع عالية.

$$Kd = 6.1231 \quad \checkmark$$

قيمة مناسبة تؤدي إلى كبح أي تذبذب محتمل وتقليل الـOvershoot، دون أن تسبب حساسية مفرطة للضوضاء.

النتيجة النهائية:

استجابة النظام المحسنة (باللون الأحمر) تُظهر:

- استجابة سريعة ومستقرة.
- غياب كامل للتجاوز. (Overshoot = 0%)
- زمن استقرار محسن (أقل بنسبة 50%).
- تقليل ملحوظ للخطأ النهائي.

هذا يدل على أن خوارزمية SWO قامت بتحسين المعاملات بشكل ناجح وفعال، وحققت أداءً متوازنًا بين السرعة والدقة والاستقرار.

5.III تطبيق خوارزميات التحسين الذكية في جدولة التدخلات التقنية

1.5.III مقدمة

في ظل التوسع المتزايد لخدمات الاتصالات وتنامي عدد المستخدمين، أصبحت إدارة التدخلات التقنية في الميدان أكثر تعقيداً وأهمية. تتطلب هذه التدخلات تنسيقاً فعالاً لضمان الاستجابة السريعة وإصلاح الأعطال بأقل وقت وجهد ممكن. من هذا المنطلق، بات من الضروري توظيف أدوات الذكاء الاصطناعي لتسهيل اتخاذ القرار وتحسين أداء الطواقم الفنية.

في هذا السياق، يقدم هذا الفصل دراسة تطبيقية لتوظيف خوارزميات تحسين ذكية لحل مشكلة **جدولة زيارات الفرق التقنية الميدانية**، والتي تُعد أحد الأوجه التطبيقية لمشكلة **البائع المتجول (Travelling Salesman Problem - TSP)**، التي تهدف إلى إيجاد أقصر مسار يربط بين مجموعة من النقاط [20].

تم التركيز في هذا العمل على خوارزميتين مميزتين:

- **خوارزمية الذئب الرمادي (Grey Wolf Optimizer - GWO)** وهي خوارزمية مستوحاة من سلوك الذئب الرمادي في الصيد، وتقوم على التعاون بين الأفراد والتوجيه وفق مواقع القادة، ما يسمح لها بالتحرك تدريجياً نحو الحل المثلى [19].
- **خوارزمية دبور العنكبوت (Spider Wasp Optimizer - SWO)** خوارزمية حديثة مستوحاة من استراتيجية الصيد عند الدبابير المفترسة، حيث تعتمد على آلية هجومية ذكية تجمع بين الاستكشاف السريع للمجال والقدرة على التمرکز حول الحل الجيدة، مما يجعلها فعالة في مشاكل التحسين ذات الطابع الديناميكي [10].

تهدف المقارنة بين GWO و SWO إلى تقييم أداء كل منهما في تقليل المسافة الكلية المقطوعة لزيارة عدد من البلاغات التقنية اليومية. كما تم اعتماد الترتيب العشوائي كمرجعية (Baseline) لتحديد مدى فعالية كل خوارزمية مقارنة بالحلول غير المحسنة.

2.5.III توصيف المشكلة الميدانية

أثناء فترة التربص بالشركة الوطنية للاتصالات بمدينة جامعة – ولاية المغير، تبين أن الفرق التقنية تتعامل يومياً مع عدد معتبر من البلاغات المرتبطة بمشاكل تقنية متنوعة، مثل ضعف تغطية الشبكة، انقطاع خطوط الهاتف، أو أعطال في الربط بخدمة ADSL. وتكمن الإشكالية الأساسية في ضرورة تحديد ترتيب أمثل لهذه التدخلات، بحيث يضمن تقليل مسافة التنقل وزمن التنفيذ، مما ينعكس مباشرة على جودة الخدمة وكفاءة الموارد البشرية.

لتمثيل هذه المشكلة، اعتمد على تبسيطها في شكل مجموعة نقاط (بلاغات) موزعة في فضاء ثنائي الأبعاد، وتمثل كل نقطة موقع بلاغ تقني. الهدف هو إيجاد أقصر مسار ممكن يربط بين جميع هذه النقاط، مع المرور بكل نقطة مرة واحدة.

3.5.III خوارزمية الذئب الرمادي (GWO)

تُصنّف خوارزمية الذئب الرمادي ضمن الخوارزميات التطورية المستوحاة من الطبيعة، حيث تحاكي السلوك الاجتماعي والصيادي للذئب الرمادي خلال مطاردة الفريسة. تعتمد الخوارزمية على بنية تنظيمية للذئب داخل القطيع، حيث يتم تصنيفها إلى أربعة مراتب:

a (ألفا) : القائد ويُعتبر أفضل حل حالي

β و δ : يمثلان الحلين الثاني والثالث في الجودة.

(ω أوميغا) : بقية الأفراد الذين يتبعون القادة.

تعتمد عملية التحديث في GWO على تحرك الذئب نحو مواقع α و β و δ ، عبر معادلات رياضية تعكس آلية الاقتراب من الفريسة. ويُعاد تحديث المواقع باستمرار إلى أن يتحقق التقارب حول أفضل حل ممكن.

في هذا العمل، تم اعتماد خوارزمية GWO للبحث عن ترتيب زيارات يحقق الحد الأدنى من المسافة الكلية بين البلاغات التقنية [19].

4.5.III إعداد النموذج والمحاكاة

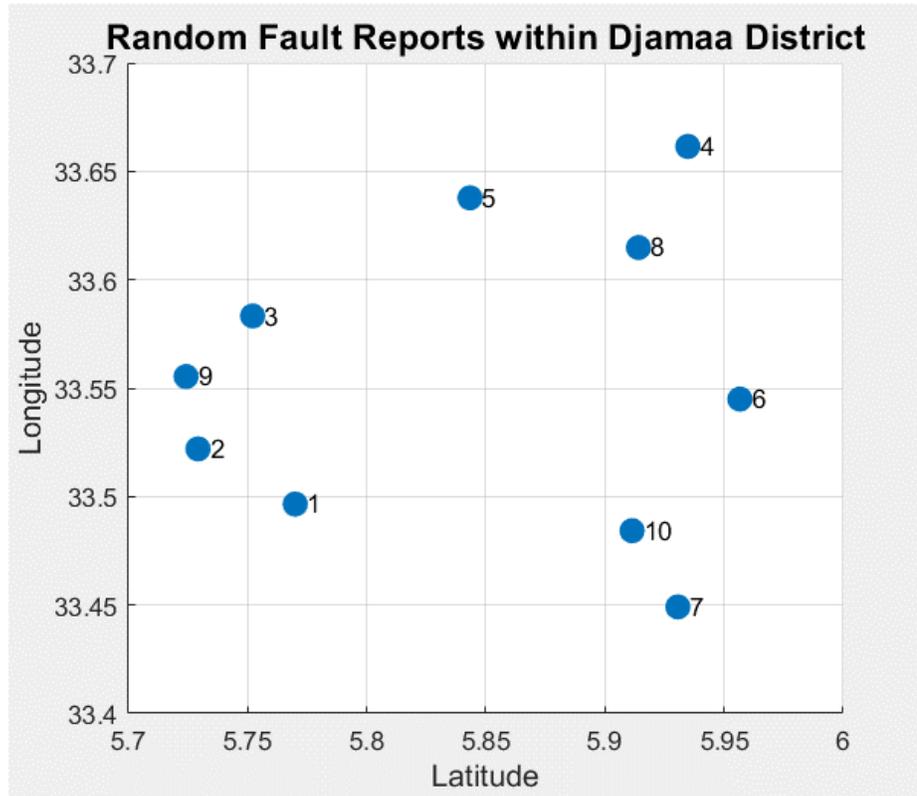
تم تصميم تجربة مبسطة لمحاكاة وضع حقيقي تواجهه الفرق التقنية، مع افتراض وجود 10 بلاغات تقنية موزعة بشكل عشوائي في مجال افتراضي ثنائي الأبعاد (100x100). تمثل كل بلاغ نقطة يجب زيارتها مرة واحدة فقط.

تم تنفيذ المحاكاة باستخدام برنامج MATLAB ، مع مقارنة ثلاث طرق مختلفة:

1. ترتيب عشوائي للزيارات.
2. نتائج خوارزمية GWO.
3. نتائج خوارزمية SWO.

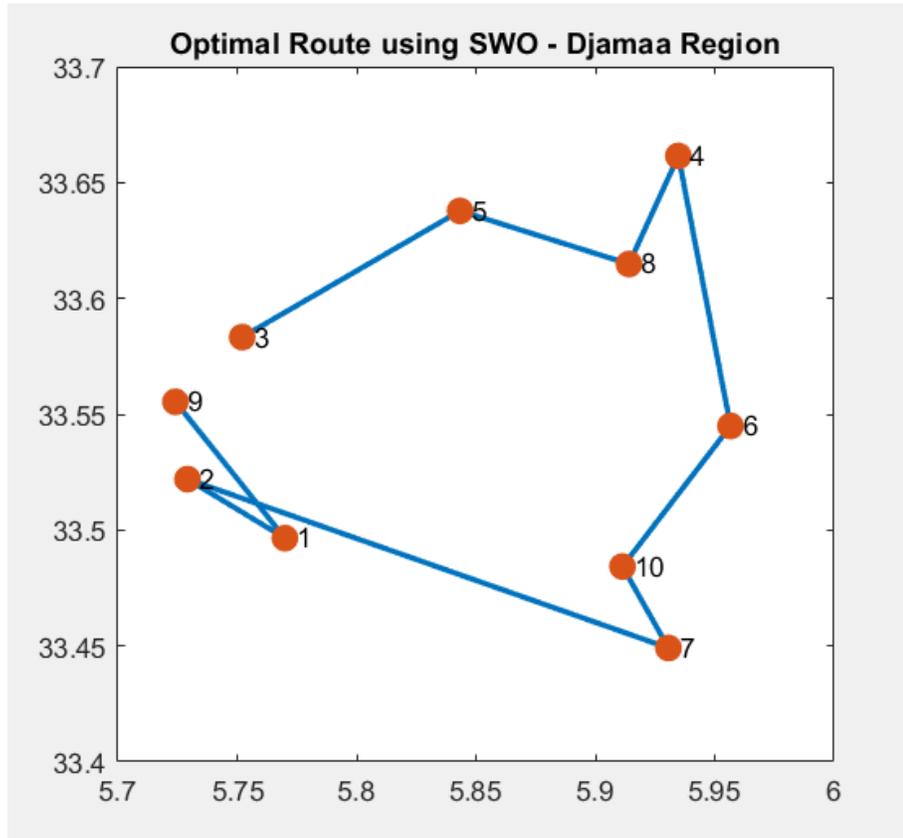
5.5.III عرض النتائج

1.5.5.III الرسومات التوضيحية



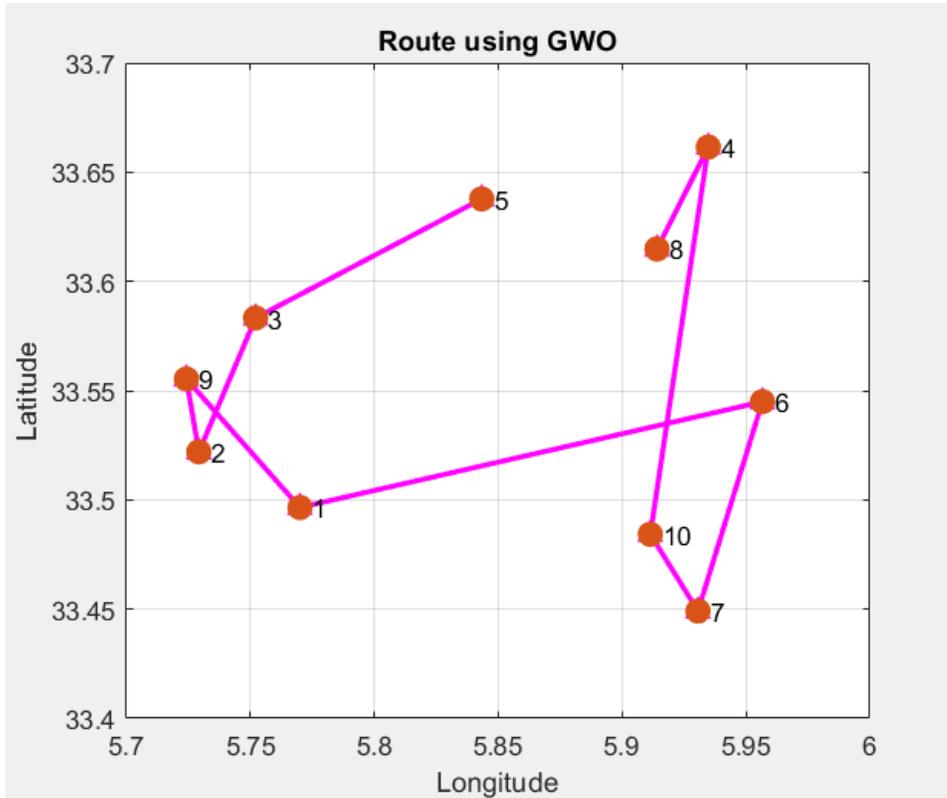
الشكل 15 III : مواقع الأعطال العشوائية

ترتيب الزيارات: 1-2-3-4-5-6-7-8-9-10



الشكل 16 III. : أفضل مسار باستخدام SWO

ترتيب الزيارات: 9-1-2-7-10-6-4-8-5-3



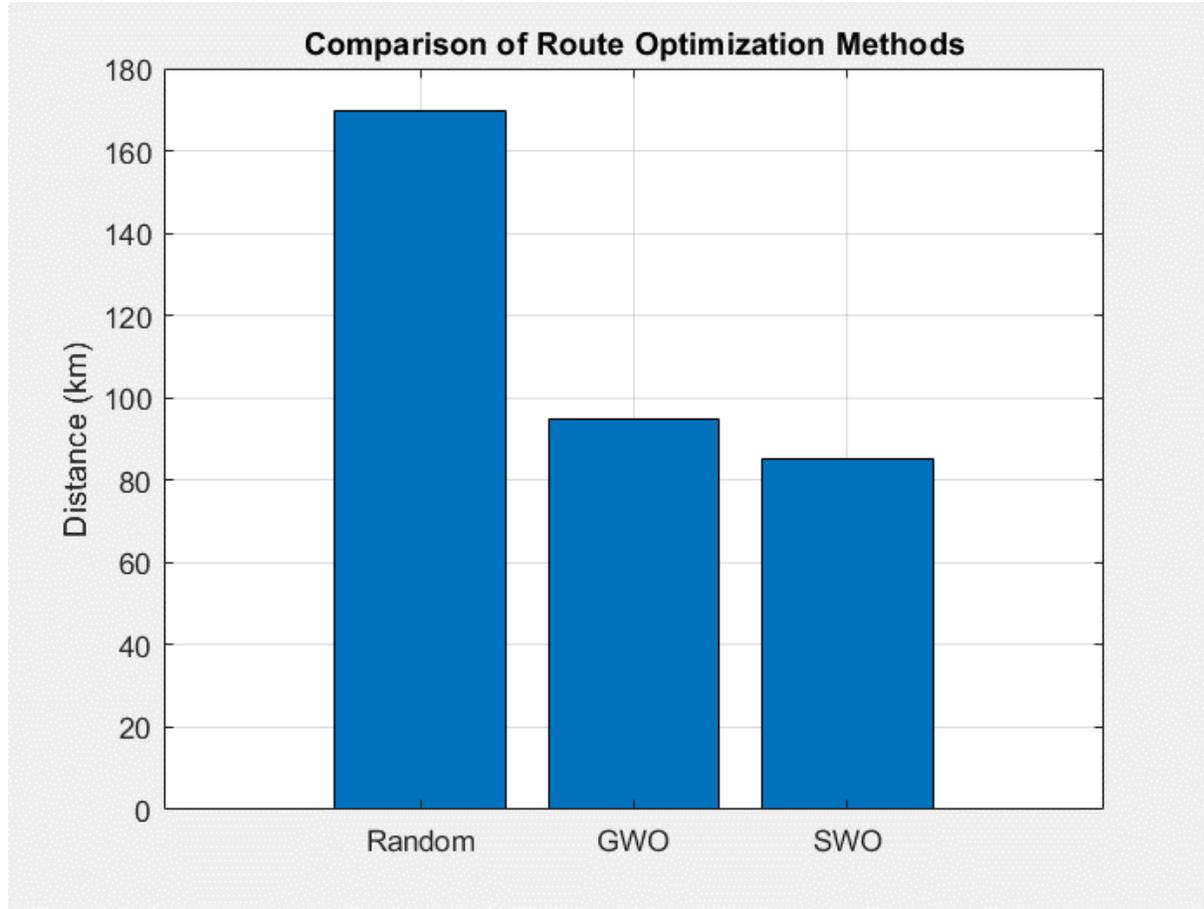
الشكل 17. III : أفضل مسار باستخدام GWO

ترتيب الزيارات: 5-3-2-9-1-6-7-10-4-8

III.2.5.5 نتائج المسافات المقطوعة لثلاث الطرق

الجدول 9.III نتائج مسافات الطرق الثلاث

المسافة الكلية (km)	نوع طريق المسار
169.49	ترتيب عشوائي
94.80	GWO
85.24	SWO



الشكل 18. III : مقارنة بين المسافات الكلية الناتجة عن الطرق الثلاثة (SWO، GWO، و الترتيب العشوائي).

6.5.III تحليل النتائج

أظهرت النتائج المستخلصة من المحاكاة فعالية واضحة لخوارزميات التحسين الذكية في تقليل المسافة الإجمالية المقطوعة من طرف الفريق التقني أثناء زيارة مواقع الأعطال. وكما هو موضح في الجدول (9.III)، فقد سجلت خوارزمية Spider Wasp Optimizer (SWO) أقل مسافة كلية بلغت 85.24 كم، مقارنة بـ 94.80 كم باستخدام Grey Wolf Optimizer (GWO)، في حين بلغ طول المسار الناتج عن الترتيب العشوائي 169.49 كم.

هذا يُترجم عملياً إلى انخفاض يُقدَّر بحوالي 49.7% في المسافة عند استخدام SWO بدلاً من الترتيب غير المحسّن، و 10% تقريباً مقارنةً بـ GWO، مما يدل على كفاءة SWO في استكشاف المسارات المثلى بشكل أسرع وأكثر دقة.

من خلال الرسومات التوضيحية، يظهر أن مسار SWO يتميز بانسيابية وعدم تقاطع، مع تسلسل منطقي في الزيارات، على عكس المسار الناتج عن GWO الذي يحتوي على بعض الالتواءات والتقاطعات، ما قد يبرر الفارق في النتائج.

وتُبرز الشكل III.18 مقارنةً بيانية واضحة بين الطرق الثلاث، حيث يظهر التفوق البصري الواضح لـ SWO من خلال أقصر عمود في الرسم، يليه GWO، بينما يُظهر العمود الخاص بالترتيب العشوائي أكبر قيمة، ما يؤكد الفوارق العددية المسجلة في الجدول.

يمكن تفسير تفوق SWO جزئياً بطبيعة آليتها المستوحاة من سلوك هجومي ذكي يتميز بالتوازن بين الاستكشاف والاستغلال، مما يساعدها على تجنب الحلول المحلية واكتشاف ترتيب أكثر كفاءة خلال عدد محدود من التكرارات.

III.7.5 خاتمة جزئية

من خلال هذا التطبيق الميداني المبسط، يتضح أن استخدام خوارزميات التحسين الذكية مثل SWO و GWO يُمكن أن يحدث فرقاً جوهرياً في تحسين تخطيط المهام الميدانية، لاسيما في مؤسسات خدمية كقطاع الاتصالات. بالرغم من أن النموذج المُعتمد كان مبسطاً، إلا أن النتائج المشجعة التي تم التوصل إليها تدعم التوجه نحو دمج هذه الخوارزميات في أنظمة الجدولة والتخطيط الذكية.

يفتح هذا العمل البسيط الباب أمام تطوير أدوات أكثر تقدماً تعتمد على معطيات حقيقية (مثل إحداثيات GPS، أولوية الأعطال، الوقت المستغرق....) ويمكن لاحقاً توسيعه ليشمل عدة فرق ميدانية وقيوداً زمنية وميدانية واقعية.

6.III الخاتمة :

في هذا الفصل، تم التركيز على الجانب التطبيقي لخوارزمية محسن دبور العنكبوت (SWO)، من خلال تقييم أداؤها على مجموعتين من دوال الاختبار القياسية لسنتي 2005 و2019، بالإضافة إلى تطبيقها في حالتين عمليتين: تحسين معاملات متحكم PID، وتخطيط المسارات لزيارة نقاط أعطال موزعة عشوائياً. وقد أظهرت الخوارزمية أداءً تنافسياً مقارنة بعدد من الخوارزميات الميتا-استكشافية الحديثة، لا سيما في الوظائف المعقدة متعددة القمم.

كما أثبتت الخوارزمية قدرتها على تعزيز دقة النتائج، وتقليل الخطأ، وتحسين استجابة الأنظمة الديناميكية، مما يبرز مرونتها وملاءمتها لتطبيقات متنوعة في مجالات التحسين. وبناءً على هذه النتائج، يمكن اعتبار خوارزمية SWO أداة فعالة وواعدة في معالجة مشكلات التحسين ذات الطبيعة غير الخطية والمعقدة، مع إمكانية تطويرها مستقبلاً لتعزيز قدراتها في الاستكشاف والتكيف مع بيئات أكثر ديناميكية وتعقيداً.

الخاتمة

تهدف هذه المذكرة إلى دراسة وتحليل خوارزمية محسن دبور العنكبوت (Spider Wasp Optimizer - SWO) باعتبارها إحدى الخوارزميات الميتا-استكشافية الحديثة المستوحاة من السلوك البيولوجي لدبابير العنكبوت. وقد تم تناول هذه الخوارزمية من خلال جانبين متكاملين: جانب نظري تضمن تقديم الخلفية البيولوجية للخوارزمية، ومبادئها الرياضية وآليات عملها، وجانب تطبيقي شمل اختبار أدائها على دوال معيارية ومقارنتها مع خوارزميات أخرى، بالإضافة إلى تطبيقها في مسائل واقعية.

أظهرت نتائج المحاكاة أن خوارزمية SWO تتمتع بقدرة تنافسية عالية، لا سيما في الوظائف المعقدة متعددة القمم، حيث استطاعت تحقيق توازن فعال بين الاستكشاف والاستغلال. كما أثبتت كفاءتها في تطبيقات عملية مثل تحسين استجابة أنظمة التحكم (PID) وتخطيط المسارات مقارنة مع خوارزمية أخرى، مما يدل على مرونتها وإمكاناتها الواسعة في مجالات مختلفة.

تفتح هذه الدراسة آفاقاً بحثية مستقبلية لتطوير الخوارزمية، سواء من خلال تحسين استراتيجيات البحث، أو دمجها مع تقنيات أخرى كالتعلم الآلي أو الخوارزميات الهجينة، بما يعزز أدائها في البيئات الديناميكية والمعقدة. وبذلك، تُعد خوارزمية SWO مساهمة واعدة في مجال التحسين الذكي وحل المسائل ذات الطابع غير الخطي والعالي الأبعاد.

المراجع :

- [1] X. S. Yang, Nature-Inspired Optimization Algorithms. Elsevier, 2014. Available: [https://scholar.google.com/scholar_url?url=https://www.academia.edu/download/51474350/Elsevier Insights Xin-She Yang Auth.-Nature-Inspired Optimization Algorithms-Elsevier 2014.pdf&hl=en&sa=X&ei=vsZiaLS9BrXCieoPsuWcoAQ&scisig=AAZF9b-8KjhcD-sV1mK8sqblGYnl&oi=scholar](https://scholar.google.com/scholar_url?url=https://www.academia.edu/download/51474350/Elsevier_Insights_Xin-She_Yang_Auth.-Nature-Inspired_Optimization_Algorithms-Elsevier_2014.pdf&hl=en&sa=X&ei=vsZiaLS9BrXCieoPsuWcoAQ&scisig=AAZF9b-8KjhcD-sV1mK8sqblGYnl&oi=scholar)
- [2] A. H. Gandomi and A. H. Alavi, "Metaheuristic Algorithms in Modeling and Optimization: A Review," Archives of Computational Methods in Engineering, vol. 19, no. 1, pp. 1–24, 2012. Available: [https://www.researchgate.net/publication/259603698 Metaheuristic Algorithms in Modeling and Optimization A Review](https://www.researchgate.net/publication/259603698_Metaheuristic_Algorithms_in_Modeling_and_Optimization_A_Review)
- [3] I. Boussaïd, J. Lepagnot, and P. Siarry, "A Survey on Optimization Metaheuristics , " Information Sciences, vol. 237, pp. 82–117, 2013. Available: <https://hal.science/hal-00764996>
- [4] J. Stork, A. E. Eiben, T. Bartz-Beielstein, et al., "A New Taxonomy of Global Optimization Algorithms," arXiv preprint arXiv:1808.08818, 2020. Available: <https://arxiv.org/abs/1808.08818>
- [5] S. Ruder, "An Overview of Gradient Descent Optimization Algorithms," arXiv preprint arXiv:1609.04747, 2016. Available: <https://arxiv.org/abs/1609.04747>
- [6] S. Luke, Essentials of Metaheuristics, 2nd ed., George Mason University, 2019. Available <https://cs.gmu.edu/~sean/book/metaheuristics/Essentials.pdf>
- [7] NPTEL, "Optimization Techniques: Module 1, Lecture 3," Indian Institute of Technology. Available: https://archive.nptel.ac.in/content/storage2/courses/105108127/pdf/Module_1/M1L3slides.pdf
- [8] NPTEL, "Optimization Methods," Indian Institute of Technology. Available: <https://archive.nptel.ac.in/courses/105/108/105108127/>

- [9] A. Kumar, A. Bhardwaj, and S. Sahu, "A Review of Classical Methods and Nature-Inspired Algorithms (NIAs) for Solving Optimization Problems," *Materials Today: Proceedings*, 2023. Available: <https://www.sciencedirect.com/science/article/pii/S2666720723001170>
- [10] M. Abdel-Basset, R. Mohamed, M. Jameel, and M. Abouhawwash, "Spider Wasp Optimizer: A Novel Meta-Heuristic Optimization Algorithm," *Artificial Intelligence Review*, 2023. Available : <https://doi.org/10.1007/s10462-023-10446-y>
- [11] Wild Explained, "The Fascinating Spider Wasp: An Insight into Its Behavior and Habits," 2023. Available: <https://wildexplained.com/animal-encyclopedia/the-fascinating-spider-wasp-an-insight-into-its-behavior-and-habits/>
- [12] EDIS, "Spider Wasp - Florida," University of Florida IFAS Extension. Available: <https://edis.ifas.ufl.edu/publication/IN1247>
- [13] Wikimedia Commons, "Spider-hunting wasp, Churchland Lane." Available: https://commons.wikimedia.org/wiki/File:Spider-hunting_wasp,_Churchland_Lane_-_geograph.org.uk_-_5267215.jpg
- [14] Wikimedia Commons, "Caliadurgus fasciatellus female with Garden Spider." Available: [https://commons.wikimedia.org/wiki/File:Caliadurgus_fasciatellus_female_with_Garden_Spider_\(24168265720\).jpg](https://commons.wikimedia.org/wiki/File:Caliadurgus_fasciatellus_female_with_Garden_Spider_(24168265720).jpg)
- [15] Wikimedia Commons, "Spider-hunting wasp, Churchland Lane." Available: https://commons.wikimedia.org/wiki/File:Spider-hunting_wasp,_Churchland_Lane_-_geograph.org.uk_-_5267215.jpg
- [16] Wikimedia Commons, "Tachypompilus analis." Available: https://commons.wikimedia.org/wiki/File:Tachypompilus_analis_155061932.jpg
- [17] K. Ogata, *Modern Control Engineering*, 5th ed., Prentice Hall, 2010. Available: <https://wp.kntu.ac.ir/dfard/ebook/lc/Katsuhiko%20Ogata-Modern%20Control%20Engineering-Prentice%20Hal%20%282010%29.pdf>
- [18] A. Ingale et al., "Modeling Mass-Spring-Damper System Using Simscape," *International Journal of Engineering Research and Applications*, vol. 8, no. 1, part 3, pp. 30–33. Available: https://www.ijera.com/papers/Vol8_issue1/Part-3/F0801033033.pdf

[19] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey Wolf Optimizer," *Advances in Engineering Software*, vol. 69, pp. 46–61, 2014. Available:

[https://www.researchgate.net/publication/260010809 Grey Wolf Optimizer](https://www.researchgate.net/publication/260010809_Grey_Wolf_Optimizer)

[20] P. Jaillet, "Online Traveling Salesman Problems with Time Windows," MIT Technical Report, 2003. Available:

https://dspace.mit.edu/bitstream/handle/1721.1/62212/jaillet_online%20traveling.pdf