

تصميم وتقييم خوارزمية تحسين هجينة تجمع بين ABC وACO

د. ميساء بهاء الدين دياب *

(تاريخ الإيداع ٢٠٢٥/١١/١٨ . قُبل للنشر في ٢٠٢٦/٢/٣)

□ ملخص □

تُعد مسائل التحسين من التحديات الجوهرية في مجالات الذكاء الاصطناعي نظرًا لتعقيد فضاءات البحث وزيادة عدد متغيرات القرار، مما يستدعي تطوير خوارزميات قادرة على تحقيق توازن فعال بين استكشاف فضاء الحلول وتعزيز الحلول المرتقبة في عملية البحث.

في هذا البحث، تم اقتراح خوارزمية هجينة تفاعلية تجمع بين خوارزمية مستعمرة النحل الصناعية **Artificial Bee Colony (ABC)** وخوارزمية تحسين مستعمرة النمل **Ant Colony Optimization (ACO)**، من خلال دمج آليات البحث الخاصة بـ ABC مع آلية الفيرومونات المستخدمة في ACO، بهدف تحسين كفاءة التوجيه نحو الحلول المثلى وتسريع عملية التقارب.

الكلمات المفتاحية (Keywords) الذكاء السربي، خوارزمية مستعمرة النحل الصناعية (ABC)، خوارزمية تحسين مستعمرة النمل (ACO)، الخوارزميات الهجينة، التحسين الميتاهيورستي، الفيرومونات.

*د. ميساء بهاء الدين دياب -مدرسة في الجامعة العربية الخاصة للعلوم والتكنولوجيا - كلية الهندسة المعلوماتية - قسم تقانة المعلومات.

Design and Evaluation of a Hybrid ABC–ACO Optimization Algorithm

Dr. Maisa bahaedeen Diab *

(Received 18/11/2025 . Accepted 3/2/2026)

□ ABSTRACT □

Optimization issues are fundamental challenges in the fields of artificial intelligence due to the complexity of search spaces and the increasing number of decision variables, which requires the development of algorithms capable of achieving an effective balance between exploring the solution space and promoting promising solutions in the search process.

In this research, a hybrid interactive algorithm was proposed that combines the Artificial Bee Colony (ABC) algorithm and the Ant Colony Optimization (ACO) algorithm, by integrating the search mechanisms of ABC with the pheromone mechanism used in ACO, with the aim of improving the efficiency of guidance towards optimal solutions and accelerating the convergence process.

Keywords: Swarm intelligence, Artificial Bee Colony Algorithm (ABC), Ant Colony Algorithm (ACO), Hybrid Algorithms, Metaheuristic Optimization, Pheromones.

* Dr. Maisa bahaedeen Diab - Lecturer in Faculty of Informatics Engineering, Arab Private University for Science and Technology- Department of information technology.

١ - المقدمة (Introduction)

تُعد مسائل التحسين من القضايا الأساسية في مجالات الذكاء الاصطناعي وعلوم الحاسوب، نظرًا لتعقيد فضاءات البحث وازدياد عدد متغيرات القرار، حيث يؤدي ذلك إلى توسع فضاء الحلول الممكنة وصعوبة الوصول إلى الحل الأمثل بكفاءة عالية [1]. وقد أدت هذه التحديات إلى محدودية فاعلية الأساليب التقليدية، مما شجّع على تطوير خوارزميات ميتاهيورستية مستوحاة من الظواهر الطبيعية.

من بين هذه الخوارزميات، حظيت خوارزمية مستعمرة النحل الاصطناعي (ABC) باهتمام واسع لقدرتها على استكشاف فضاء الحلول بكفاءة من خلال آليات البحث التعاوني، إلا أن دراسات متعددة أشارت إلى معاناتها من بطء نسبي في سرعة التقارب عند التعامل مع مسائل التحسين المعقدة [2], [3]. في المقابل، تعتمد خوارزمية تحسين مستعمرة النمل (ACO) على آلية الفيرومون لتوجيه عملية البحث، وقد أثبتت فاعلية في تعزيز الحلول المثلى، غير أنها قد تواجه خطر الوقوع في الحلول المحلية المثلى عند ضعف التنوع في الحلول [4], [5].

استجابةً لهذه التحديات، اتجهت بعض الدراسات الحديثة إلى اقتراح نماذج هجينة تجمع بين خوارزميات ABC و ACO بهدف تحسين الأداء العام للخوارزمية [6]. إلا أن معظم هذه الدراسات اعتمدت على الدمج التقليدي أو التنفيذ المتتابع للخوارزميتين، دون تقديم تطوير منهجي واضح لآلية التفاعل بينهما داخل دورة البحث، مما يحد من الاستفادة الكاملة من خصائص كل خوارزمية.

فيما بعد قام Zhang وآخرون [7] بتطوير نسخة محسنة متعددة الاستراتيجيات من خوارزمية ABC لتطبيقها في تحسين تغطية شبكات الاستشعار اللاسلكية. وأظهرت النتائج أن التكيف الذاتي في الخوارزمية حسن من أداء البحث بشكل ملحوظ مقارنة بالإصدارات التقليدية.

وفي سياق مشابه، اقترحت دراسة Hybrid ACO-ABC [8] خوارزمية هجينة جديدة لتوجيه المركبات الكهربائية متعددة الأهداف، حيث أظهرت نتائج التجارب أن الجمع بين آليات الفيرومون من ACO وعمليات الاستكشاف في ABC قد أدى إلى تسريع التقارب بنسبة تفوق ٢٠% وتحسين جودة الحلول بشكل واضح.

في هذا السياق، قدّم هذا البحث تطويراً منهجياً لآلية الخوارزمية الهجينة من خلال دمج آلية الفيرومون الخاصة بـ ACO كعنصر توجيهي تكيفي داخل مراحل التحديث في خوارزمية ABC، بهدف توجيه عملية البحث ديناميكياً نحو الحلول المثلى. ويسهم هذا التطوير في تحسين كل من سرعة التقارب، المتمثلة في تقليل عدد التكرارات اللازمة للوصول إلى حالة استقرار، وجودة الحلول، والتي يتم تقييمها باستخدام مؤشرات كمية مثل معدل الخطأ وقيم دالة الملاءمة النهائية.

٢ - أهمية البحث وهدفه:

تتبع أهمية هذا البحث من إسهامه في تطوير منهجية هجينة محسنة ضمن مجال خوارزميات التحسين الميتاهيورستية، وذلك من خلال الجمع المنهجي بين خوارزمية مستعمرة النحل الاصطناعي ABC وخوارزمية تحسين مستعمرة النمل ACO ضمن إطار حسابي موحد. وتكمن أهمية هذا الدمج في معالجة بعض القصور المرتبط بالخوارزميات الفردية، حيث تُظهر خوارزمية ABC كفاءة عالية في استكشاف فضاء الحلول، إلا أنها قد تعاني من الاستقرار المبكر في الحلول المحلية، في حين تمتلك خوارزمية ACO قدرة فعّالة على توجيه عملية البحث اعتماداً على آلية الفيرومون، مما يسهم في تعزيز جودة الحلول المتولدة.

وهذا البحث بصورة أساسية تحسين جودة الحلول النهائية في مسائل التحسين المعقدة من خلال بناء نموذج حسابي متكامل يوظف آلية الفيرومونات الخاصة بـ ACO داخل مراحل البحث في ABC ، بما يتيح توجيهها ديناميكياً أكثر كفاءة نحو الحلول ذات الجودة العالية. ويُعد هذا النموذج الحسابي المقترح مساهمة علمية بحد ذاته، إذ يقدم توصيفاً رياضياً واضحاً وآلية عمل منظمة يمكن من خلالها تقييم أداء الخوارزمية المقترحة بصورة كمية دقيقة، اعتماداً على مؤشرات أداء معتمدة.

إن تطوير هذا النموذج الحسابي وتحسين جودة الحلول الناتجة عنه يساهمان في تعزيز كفاءة خوارزميات التحسين الهجينة، ويوفران أساساً علمياً يمكن البناء عليه مستقبلاً لتوسيع المنهجية المقترحة وتكييفها مع أنواع مختلفة من مسائل التحسين، لا سيما المسائل المعقدة وعالية الأبعاد.

٣- طرائق البحث ومواده:

٣-١ مفهوم الذكاء السربي (Swarm Intelligence) ، وهو فرع من فروع الذكاء الاصطناعي المستوحى من السلوك الجماعي للكائنات الحية مثل النحل والنمل والطيور والأسماك، والذي يعتمد على مبدأ التحكم اللامركزي والتعاون الذاتي بين مجموعة من العوامل البسيطة لتحقيق هدف مشترك.

من هذا المبدأ انبثقت العديد من الخوارزميات الميتاهيورستية، التي تهدف إلى حل مسائل التحسين المعقدة بطريقة تكرارية تعتمد على التجريب والتعلم الجمعي بدلاً من الحسابات التحليلية البحتة.

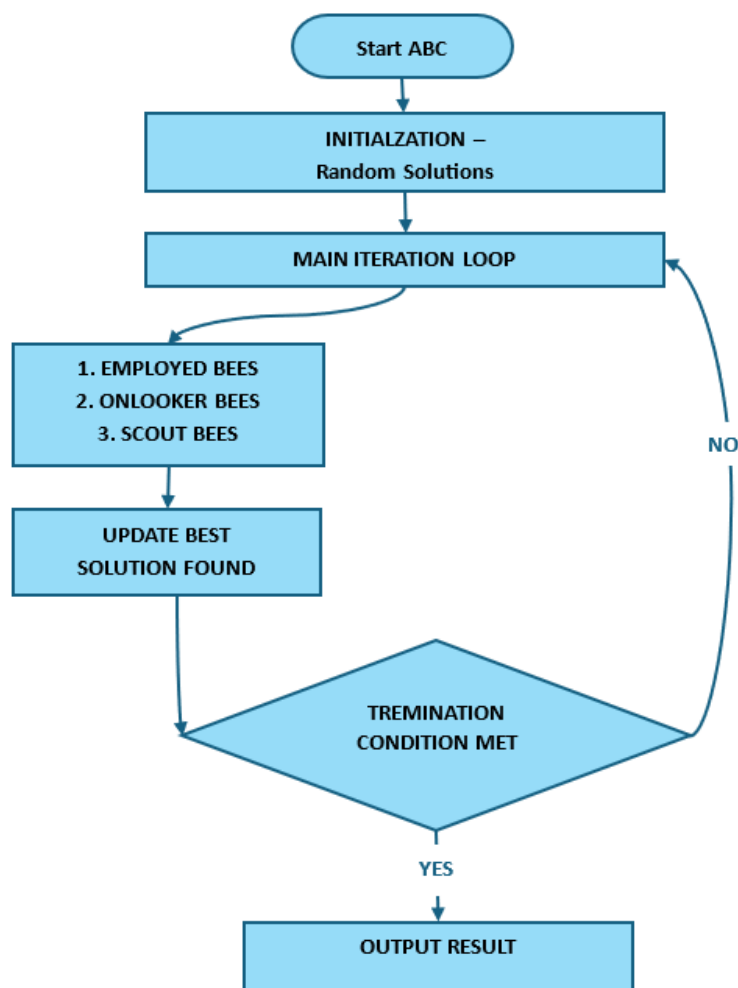
ومن بين أهم خوارزميات الذكاء السربي تبرز خوارزمية مستعمرة النحل الصناعية ABC ومستعمرة النمل ACO اللتان تمثلان الأساس النظري لهذا البحث [5] [1] .

٣-٢ خوارزمية مستعمرة النحل الصناعية (Artificial Bee Colony – ABC)

طُورت خوارزمية ABC من قبل Karaboga ، وتم تطويرها وتحليلها لاحقاً في أعمال لاحقة [2] استناداً إلى سلوك النحل الطبيعي في البحث عن مصادر الغذاء. تمثل مصادر الغذاء الحلول الممكنة لمسألة التحسين، بينما يمثل النحل العامل العوامل الباحثة عن تلك الحلول.

وتتألف الخوارزمية في الشكل (١) من ثلاث فئات رئيسية:

١. النحل العامل (Employed Bees) يقوم بالبحث عن مصادر غذاء جديدة في جوار المصادر الحالية، ويحتفظ بالمصدر الأفضل.
٢. النحل المراقب (Onlooker Bees) يختار أفضل المصادر من خلال مراقبة "رقصة الاهتزاز" التي تعبر عن جودة الحلول المكتشفة.
٣. النحل الكشاف (Scout Bees) يستكشف مناطق جديدة في فضاء الحلول عند توقف التحسين المحلي.



الشكل (١): خوارزمية مستعمرة النحل

تُستخدم الخوارزمية وفق مراحل محددة تشمل التهيئة، التحديث، والتقييم، وتُعتمد آلية اختيار الحلول الأفضل وفق دالة ملاءمة (Fitness Function) تُقيس جودة كل حل. ورغم أن ABC تمتاز بالبساطة والقدرة على البحث، إلا أنها قد تعاني من البطء في التقارب والاعتماد الكبير على القيم العشوائية الأولية [9]، [10].

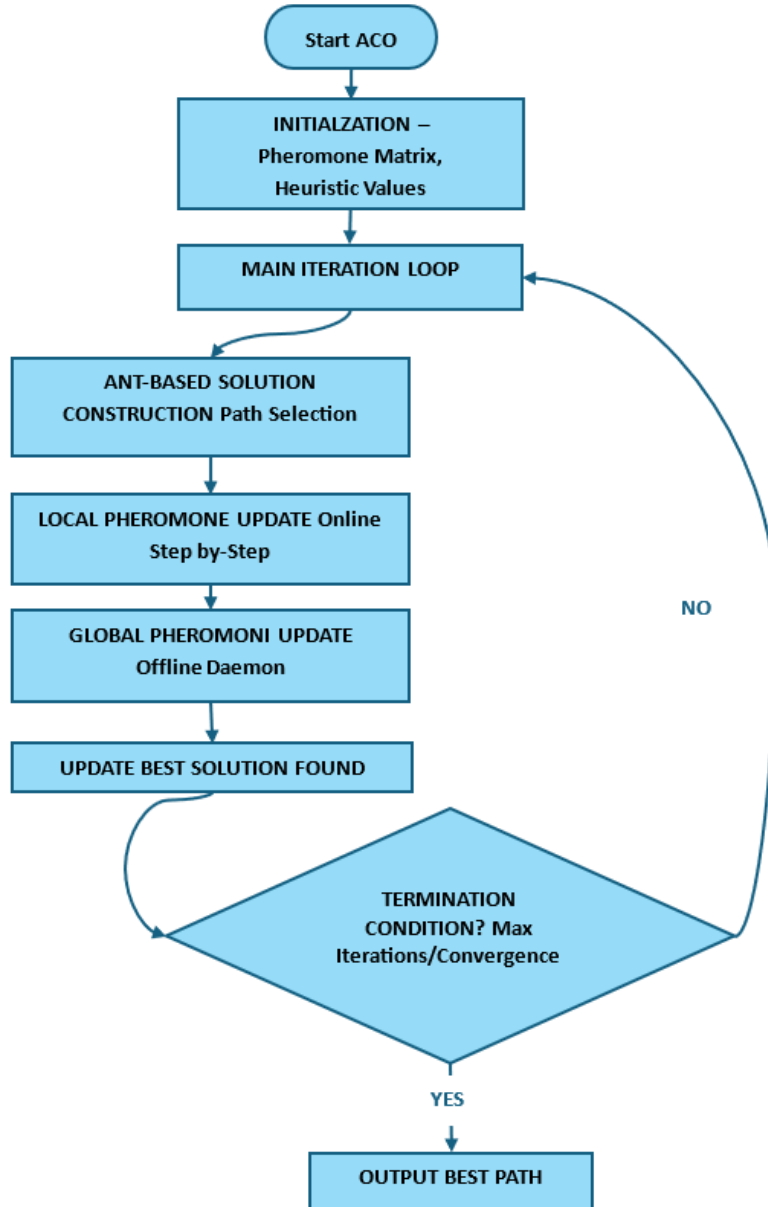
٣-٣ خوارزمية مستعمرة النمل (Ant Colony Optimization – ACO)

استلهمت خوارزمية ACO من سلوك النمل في الطبيعة أثناء بحثه عن المسارات المثلى بين العش ومصدر الغذاء، حيث يقوم كل نمل بترك أثر كيميائي يُعرف باسم الفيرومون (Pheromone) على الطريق الذي يسلكه.

ومع مرور الوقت، تتزايد تراكمات الفيرومون على المسارات الأقصر والأكثر فاعلية، مما يؤدي إلى توجيه النمل الآخر نحو هذه المسارات المثلى.

قدّم Dorigo و Stützle [5] عرضاً حديثاً وشاملاً لخوارزمية تحسين مستعمرة النمل، حيث تعتمد الخوارزمية كما في الشكل (٢) على تكرار ثلاث مراحل رئيسية، تبدأ بمرحلة

١. اختيار المسار (Path Selection): يختار النمل الطريق بناءً على تركيز الفيرومون وجودة الحل.
٢. تحديث الفيرومون (Pheromone Update): تُضاف كميات من الفيرومون إلى المسارات الأفضل، بينما تتبخر الكميات الأقل أهمية بمرور الوقت.
٣. التقارب نحو المسار الأمثل (Convergence): يتم تعزيز أفضل الحلول تدريجيًا حتى الوصول إلى الحل الأمثل.



الشكل (2): خوارزمية مستعمرة النمل

تُعدّ ACO فعالة في العديد من التطبيقات مثل تخطيط الشبكات، جدولة المهام، ومشكلات المسارات المعقدة، غير أنها قد تواجه عبئًا حسابيًا مرتفعًا عند التعامل مع فضاءات بحث كبيرة جدًا.

٣-٤ النموذج المقترح للدمج بين الخوارزميات

انطلق البحث من فكرة دمج خوارزميتي ACO و ABC في نظام واحد لتحقيق أداء أكثر توازنًا. حيث تم توظيف آلية التحكم بالفيرومونات من ACO لتوجيه عمليات البحث داخل مراحل الاستكشاف الخاصة بـ ABC. وبذلك يتم تحسين قدرة الخوارزمية على تسريع التقارب نحو الحلول المثلى مع الحفاظ على التنوع في فضاء البحث.

هذا الإطار الهجين يستند إلى فرضية أن الجمع بين السلوك التعاوني للنمل والمرونة في البحث العشوائي للنحل يمكن أن يؤدي إلى أداء يفوق أداء كل خوارزمية على حدة [11]، وهو ما سيتم التحقق منه تجريبيًا في هذا البحث.

ويُعد هذا الإطار الهجين نموذجًا حسابيًا منظمًا يوضّح آلية التفاعل بين الخوارزميتين على المستوى الرياضي والتنفيذي.

٣-٥ الخوارزمية الهجينة

تم الاعتماد في هذا البحث على منهجية تجريبية كمية هدفت إلى اختبار أداء الخوارزمية الهجينة المقترحة (ACO-ABC) مقارنةً بالخوارزميات التقليدية ACO و ABC في مسائل التحسين المعقدة. تم تنفيذ التجارب باستخدام بيئة Python 3.10 نظرًا لما توفره من مكتبات متخصصة في الخوارزميات الميטהيورستية وتحليل البيانات مثل: Matplotlib, Pandas, NumPy.

١. تصميم الخوارزمية الهجينة (Hybrid Algorithm Design)

تم بناء الخوارزمية المقترحة على مرحلتين أساسيتين:

• المرحلة الأولى: مرحلة ABC

في هذه المرحلة يتم توليد مجموعة أولية من الحلول العشوائية تمثل مواقع الغذاء (Food Sources) باستخدام المعادلة الرياضية:

$$x_i = L_i + \text{rand}(0,1) \times (U_i - L_i) \quad (1)$$

ثم يتم تقييم جودة كل حل باستخدام دالة الملاءمة (Fitness Function)، ويقوم النحل العامل (Employed Bees) بتحديث المواقع بناءً على المقارنة مع حلول أخرى في فضاء البحث. بعد ذلك، يقوم النحل المراقب (Onlooker Bees) باختيار الحلول المثلى اعتمادًا على احتمالية اختيار تتناسب طرديًا مع قيم الملاءمة.

وفي حال لم يتحقق تحسن ملحوظ بعد عدد معين من الأجيال، يتم تفعيل النحل الكشاف (Scout Bees) لتوليد حلول جديدة تحافظ على تنوع البحث وتمنع الوقوع في الحلول المحلية المثلى.

• المرحلة الثانية: مرحلة ACO

بعد انتهاء كل جيل من خوارزمية ABC، تبدأ مرحلة ACO لتطبيق آلية الفيرومون (Pheromone Mechanism) على أفضل الحلول التي تم الحصول عليها.

يقوم كل نمل (Ant) ببناء مسار حل جديد استنادًا إلى احتمالية تعتمد على تركيز الفيرومون (τ) والقيمة الإرشادية (η) وفق العلاقة:

$$P_{ij} = (\tau_{ij}^{\alpha} \times \eta_{ij}^{\beta}) \div \sum_k (\tau_{ik}^{\alpha} \times \eta_{ik}^{\beta}) \quad (2)$$

بعد ذلك يتم تحديث قيم الفيرومونات باستخدام المعادلة:

$$\tau_{ij} = (1 - \rho) \cdot \tau_{ij} + \Delta \tau_{ij}^k \quad (3)$$

حيث ρ تمثل معدل تبخر الفيرومونات (Evaporation Rate) و $\Delta \tau$ تمثل الزيادة الناتجة عن أفضل الحلول في الجيل الحالي.

تعمل هذه المرحلة بمثابة عامل تعزيز (Reinforcement Mechanism) لتوجيه النحل في الأجيال اللاحقة نحو مناطق البحث الأكثر صحة.

بعد الانتهاء من مرحلتي ABC وACO في كل جيل، يتم استبدال أسوأ الحلول في مجموعة النحل بأفضل الحلول الناتجة عن النمل، ثم يُعاد تقييم جميع الحلول لتحديد أفضل موقع (Global Best Solution). يتكرر هذا التفاعل بين المرحلتين حتى الوصول إلى حالة الاستقرار (Tmax).

يوضح **Algorithm 1** الخطوات التفصيلية لتنفيذ الخوارزمية الهجينة المقترحة. ACO–ABC.

Algorithm 1: Hybrid ACO–ABC Algorithm

Input:

Na, Tmax, ρ , α , β , L, U

Output:

X_best (best global solution)

١. Initialize ABC and ACO parameters
٢. Generate initial food sources $X_i = L_i + \text{rand}(0,1) \cdot (U_i - L_i)$
٣. Evaluate fitness $F(X_i)$
٤. Set $X_best = \text{best}(X_i)$
٥. Initialize pheromone τ_{ij} and heuristic η_{ij}
٦. For $t = 1$ to Tmax do
 - // ---- ABC Phase ----
 - For each employed bee i
 - Select random source $k \neq i$
 - $V_i = X_i + \varphi_i \times (X_i - X_k)$
 - If $F(V_i) > F(X_i)$ then $X_i \leftarrow V_i$
 - End for
 - Compute selection probabilities P_i
 - For each onlooker bee
 - Select source based on P_i
 - Apply local search
 - End for
 - If stagnation \rightarrow scout bee search
 - // ---- ACO Phase ----
 - For each ant $a = 1$ to N_a do

```

Construct solution using:
    Pij = (τij^α × ηij^β) / Σ(τik^α × ηik^β)
Evaluate fitness F(Xa)
End for
Update pheromone:
    τij = (1 - ρ) × τij + Δτij

// ---- Integration ----
Replace worst ABC solutions with best ACO ones
Update X_best if improvement found
End for

-----
Return X_best
-----

```

- Xi متجه حل i
- F(Xi) قيمة دالة الهدف للحل i
- X_best أفضل حل
- Tij تركيز الفيرومون بين العقد i و j
- ηij قيمة إرشادية للحل
- α, β معاملات تحكم تأثير الفيرومون
- ρ معدل تبخر الفيرومون

بعد انتهاء تنفيذ الخوارزمية سيتم حساب مؤشرات التقييم في كل تشغيل مستقل، وبالطبع لا تُعد جزءاً من آلية البحث نفسها، وإنما تُستخدم لأغراض المقارنة والتحليل الإحصائي للأداء.

٢. مجموعة البيانات (Dataset)

تم اختبار الخوارزمية المقترحة باستخدام مجموعة بيانات مكونة من ٥٠٠,٠٠٠ صورة تم الحصول عليها من منصة Kaggle ، حيث تم تحويل كل صورة إلى تمثيل عددي يُستخدم كحالة تحسين متعددة المتغيرات.

وقد استُخدمت البيانات لأغراض التقييم التجريبي لأداء الخوارزميات عبر عدة تجارب مستقلة، وذلك لضمان موثوقية النتائج وقابليتها للتكرار.

تم تطبيق معايير تقييم الأداء بناءً على قيمة دالة الهدف النهائية (Objective Function Value) ، ومعدل التقارب (Convergence Rate) ، وعدد التكرارات اللازمة للوصول إلى الحل الأمثل (Iterations to Optimum).

٣. معايير التقييم والمؤشرات الرياضية (Evaluation Metrics)

من أجل تقييم أداء الخوارزمية الهجينة المقترحة ومقارنتها مع الخوارزميات المرجعية، تم اعتماد مجموعة من المؤشرات الكمية القياسية، والتي تعكس جودة الحل النهائي وكفاءة عملية البحث وسرعة التقارب. وقد تم تعريف هذه المؤشرات رياضياً على النحو الآتي:

١. جودة الحل النهائي (Solution Quality)

تمثل جودة الحل النهائي مدى قرب الحل الناتج عن الخوارزمية من القيمة المثلى للمسألة، ويتم قياسها باستخدام قيمة دالة الهدف النهائية كما يلي:

$$\text{Solution Quality} = F_best$$

حيث F_best تمثل أفضل قيمة لدالة الهدف تم الوصول إليها عند نهاية التنفيذ، وكلما كانت F_best أقل (في مسائل التصغير) أو أعلى (في مسائل التعظيم)، دل ذلك على جودة أعلى للحل.

٢. معدل الخطأ (Error Rate)

$$\text{Error Rate (\%)} = |F_best - F_opt| / |F_opt| \times 100$$

حيث F_opt القيمة المثلى المعروفة أو المرجعية و F_best أفضل حل تم الحصول عليه وهذا المؤشر يربط مباشرة جودة الحل النهائي بالدقة الحسابية.

٣. معدل التقارب (Convergence Rate)

$$\text{Convergence Rate} = 1 / T_conv$$

حيث T_conv عدد التكرارات اللازمة للوصول إلى حالة استقرار في الحل، كلما كان T_conv أقل، كانت سرعة التقارب أعلى.

٤. عدد التكرارات للوصول إلى الحل الأمثل

$$\text{Iterations to Optimum} = t \text{ such that } |F(t) - F_best| < \varepsilon$$

حيث ε حد دقة صغير و t رقم التكرار

٥. زمن التنفيذ (Execution Time)

$$\text{Execution Time} = t_end - t_start$$

يستخدم لقياس الكفاءة الزمنية للخوارزمية.

يتيح هذا التعريف الرياضي لمؤشرات التقييم إجراء مقارنة كمية دقيقة بين الخوارزمية المقترحة والخوارزميات المرجعية، كما يوفر تفسيراً واضحاً لمفهوم جودة الحل النهائي من منظور حسابي ومنهجي.

٤- النتائج والمناقشة

تم إجراء مجموعة من التجارب لتقييم أداء الخوارزمية الهجينة المقترحة (ACO-ABC) ومقارنتها بخوارزميتي مستعمرة النحل الصناعية (ABC) ومستعمرة النمل (ACO).

نُفذت جميع التجارب ضمن بيئة حاسوبية موحدة لضمان الاتساق في ظروف التشغيل وتحقيق مقارنة موضوعية، كما تم تكرار كل تجربة ٤٠ مرة مستقلة، وأخذ المتوسط الحسابي للنتائج للحد من تأثير العشوائية.

٤-١ مقارنة الأداء العام

يوضح الجدول (١) نتائج المقارنة بين الخوارزميات الثلاث من حيث قيمة دالة الهدف النهائية

(F_best)، ومعدل الخطأ، ومعدل التقارب، وزمن التنفيذ.

الجدول (١): مقارنة أداء الخوارزميات الثلاث ACO-ABC ، ACO ، ABC

Execution Time	Convergence Rate	Error Rate %	F_best	Algorithms
4.81	10.9	2.2	٠,٠١٢	ACO-ABC
6.14	11.8	7.6	٠,٠٤١	ABC
5.23	12.5	5.9	٠,٠٢٨	ACO

تُظهر نتائج الجدول (١) تفوق الخوارزمية الهجينة المقترحة (ACO-ABC) في تحقيق أقل قيمة لدالة الهدف النهائية وأدنى معدل خطأ مقارنة بالخوارزميات المرجعية، إضافةً إلى تسريع معدل التقارب وتقليل زمن التنفيذ. ويعكس ذلك كفاءة أعلى في توجيه عملية البحث داخل فضاء الحلول. يُعزى هذا التحسن إلى دمج آلية الفيرومونات من خوارزمية ACO بوصفها آلية تعزيز حسابية ضمن دورة البحث في خوارزمية ABC، مما أسهم في توجيه البحث نحو المناطق الواعدة وتقليل التذبذب العشوائي للحلول.

٢-٤ التحليل الإحصائي للنتائج:


للتحقق من دلالة الفروق بين الخوارزميات، تم إجراء اختبار (t-test) لمقارنة متوسط قيم دالة الهدف النهائية (F_best) عبر ٤٠ تجربة مستقلة كما يظهر في الجدول رقم (٢). وأظهرت النتائج وجود فروق ذات دلالة إحصائية ($p < 0.05$) بين الخوارزمية الهجينة والخوارزميات المرجعية، مما يؤكد أن التحسن في الأداء يعكس فاعلية المنهجية الهجينة المقترحة وليس ناتجاً عن الصدفة.

الجدول ٢: نتائج اختبار t لمقارنة متوسط قيم دالة الهدف النهائية بين الخوارزميات الثلاث.

p-value	t-test	Std. Deviation	Mean F_best	Algorithms
-	-	1.5×10^{-3}	0.012	ACO-ABC
0.01	4.87	2.5×10^{-3}	0.041	ABC
0.03	3.92	2.0×10^{-3}	0.028	ACO

٣-٤ تحليل منحنيات التقارب:

يوضح الشكل (٣) منحنيات التقارب (Convergence Curves) لكل من خوارزميات ACO و ABC والخوارزمية الهجينة المقترحة ACO-ABC عبر عدد التكرارات.



الشكل (٣): منحنيات التقارب للخوارزميات الثلاث

يلاحظ أن الخوارزمية الهجينة تُظهر معدل تقارب أسرع مقارنة بالخوارزميات المرجعية، حيث تصل إلى حالة الاستقرار في عدد أقل من التكرارات مع الحفاظ على قيم أدنى لدالة الهدف النهائية. كما يُظهر منحنى ACO-ABC انخفاضاً أكثر انتظاماً في قيم دالة الهدف، مما يشير إلى استقرار أعلى في سلوك الخوارزمية وتقليل التذبذب العشوائي أثناء عملية البحث.

ويعكس هذا السلوك الدور الفعّال لآلية الفيرومونات المستمدة من خوارزمية **ACO** كآلية تعزيز حسابية داخل دورة التحديث في **ABC**، حيث تسهم في توجيه البحث نحو المناطق الواعدة في فضاء الحلول. وتتوافق هذه الملاحظات البصرية مع القيم الكمية لمعدل التقارب الموضحة في الجدول (1)، مما يؤكد أن التحسن في سرعة التقارب وجودة الحل النهائي ناتج عن التطوير المنهجي المقترح، وليس عن الصدفة أو التهيئة العشوائية. ويُبرز هذا السلوك التفوق الواضح للخوارزمية الهجينة في تحقيق توازن فعّال بين توسيع نطاق البحث وتوجيهه، وهو ما ينعكس مباشرة على تسريع الوصول إلى الحلول المثلى المطلوبة.

٥- الاستنتاجات

- أظهرت نتائج هذا البحث أن الخوارزمية الهجينة المقترحة (**ACO-ABC**) تمثل خطوة متقدمة في تطوير خوارزميات التحسين المستوحاة من الطبيعة، إذ أثبتت كفاءتها في تحسين جودة الحلول وتسريع عملية التقارب ضمن فضاءات البحث المعقدة.
- بيّنت النتائج التجريبية أن دمج آليات الفيرومونات المستمدة من خوارزمية **ACO** مع ديناميكية البحث في خوارزمية **ABC** أسهم في توجيه عملية البحث نحو المناطق الواعدة، مما أدى إلى تسريع معدل التقارب بنسبة ملحوظة تجاوزت **15%** مقارنة بالخوارزميات المرجعية.
- أظهرت الخوارزمية المقترحة قدرة أعلى على تقليل احتمالية الوقوع في الحلول المحلية، وتحقيق قيم أدنى لدالة الهدف النهائية ومعدلات خطأ أقل، وهو ما يعكس تحسناً واضحاً في جودة الحلول النهائية.
- أكدت نتائج التحليل الإحصائي دلالة هذا التحسن، حيث أظهرت فروقاً ذات دلالة إحصائية ($p < 0.05$) بين الخوارزمية الهجينة والخوارزميات التقليدية، مما يعزز موثوقية النتائج واستقرار أداء الخوارزمية المقترحة.
- بيّنت النتائج أن الخوارزمية الهجينة تتمتع بدرجة أعلى من الثبات والكفاءة الزمنية عند التعامل مع مسائل تحسين عالية الأبعاد، بفضل آلية التوجيه المزدوجة التي تجمع بين السلوك التعاوني للنمل ومرونة البحث العشوائي للنحل.

٦- التوصيات المستقبلية

- في ضوء النتائج التي تم التوصل إليها في هذا البحث، يمكن اقتراح عدد من الاتجاهات البحثية المستقبلية التي تُعد امتداداً طبيعياً للعمل الحالي، يساعد في تطوير المنهجية المقترحة.
- أولاً: يمكن دراسة توسيع الخوارزمية الهجينة المقترحة (**ACO-ABC**) لتشمل مسائل التحسين متعددة الأهداف (**Multi-objective Optimization**)، وذلك من خلال دمج آليات تقييم متعددة لدوال الهدف مع الحفاظ على آلية التوجيه المعتمدة على الفيرومونات.
- ثانياً: يُقترح اختبار كفاءة الخوارزمية المقترحة على أنواع مختلفة من مسائل التحسين الواقعية، مثل مسائل الجدولة المعقدة أو تحسين المعلمات في النماذج الذكية، بهدف تقييم قابليتها للتعميم عبر تطبيقات متنوعة.
- ثالثاً: يمكن مستقبلاً دراسة تحسين الضبط التكميلي للمعلمات (**Adaptive Parameter Tuning**) داخل الخوارزمية الهجينة، بما يسهم في تعزيز مرونتها وأدائها في فضاءات بحث ذات خصائص متغيرة.

References

- [1]. Talbi, E. G. (2021). *Metaheuristics: From design to implementation* (2nd ed.). Wiley.
- [2]. Karaboga, D., & Akay, B. (2009). A comparative study of artificial bee colony algorithm. *Applied Mathematics and Computation*, 214(1), 108–132.
- [3]. Karaboga, D., & Akay, B. (2020). Artificial bee colony (ABC) algorithm on training artificial neural networks. *Signal Processing*, 162, 89–103.
- [4]. Dorigo, M., Maniezzo, V., & Colomi, A. (1996). Ant system: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, 26(1), 29–41.
- [5]. Dorigo, M., & Stützle, T. (2022). *Ant colony optimization* (Updated ed.). MIT Press.
- [6]. Zhang, Y., Liu, H., & Wang, S. (2023). A hybrid ABC–ACO algorithm for complex optimization problems. *Expert Systems with Applications*, 213, 118987.
- [7]. Zhang, Y., Zhu, Q., & Yuan, L. (2024). A novel self-adaptive multi-strategy artificial bee colony algorithm for coverage optimization in wireless sensor networks. *Journal of Computational Information Systems*, 10(22), 10247-10257.
- [8]. Chen, Y., & Li, S. (2023). A dynamic hybrid ABC-ACO algorithm for constrained optimization problems. *Engineering Applications of Artificial Intelligence*, 123, 106245.
- [9]. Gao, W., & Liu, S. (2011). Improved artificial bee colony algorithm for global optimization. *Information Processing Letters*, 111(17), 871–882.
- [10]. Zhu, G., & Kwong, S. (2010). Gbest-guided artificial bee colony algorithm for numerical function optimization. *Applied Mathematics and Computation*, 217(7), 3166–3173.
- [11]. Zhao, F., Zhang, L., Cao, J., & Tang, J. (2021). A cooperative hybrid algorithm based on artificial bee colony and ant colony system for multi-objective job shop scheduling. *Computers & Industrial Engineering*, 158, 107373.