



استخدام خوارزمية أسراب العناصر للأمتلة المحسنة في حل بعض المعادلات الرياضية المعيارية

إبراهيم أحمد بادي

الأكاديمية الليبية فرع مصراتة، مدرسة العلوم الهندسية، ليبيا

علي محمد عبد الشاهد

جامعة مصراتة، قسم الهندسة الكهربائية والإلكترونية، ليبيا

المخلص

تناولت هذه الدراسة أداء خوارزمية أسراب العناصر Particle Swarm Optimization (PSO) المحسنة مقارنةً بالخوارزمية القياسية في حل ثلاث معادلات رياضية معيارية، وهي معادلة شويفل (Schwefel)، ومعادلة جريوانك (Griewank)، ومعادلة راستريجين (Rastrigin). تم استخدام الخوارزمية المحسنة بجانب الخوارزمية القياسية للأمتلة، وفورن أدأهما باستخدام مقاييس تقييمية متعددة، بما في ذلك المتوسط والأفضل والأسوأ والانحراف المعياري لقيم دالة الهدف. أظهرت النتائج بشكل واضح تفوق الخوارزمية المحسنة في جميع الحالات الثلاثة. كما حققت النسخة المحسنة قيمةً أدنى للمتوسط والأفضل والأسوأ لقيم دالة الهدف مقارنةً بالخوارزمية القياسية. كما أظهرت الخوارزمية المحسنة انحرافاً معيارياً أقل، مما يشير إلى استقرارها وقدرتها على توليد الحلول المحسنة بشكل مستمر. تشير هذه النتائج إلى أهمية استخدام الخوارزمية المحسنة في تحسين أداء عمليات البحث والأمتلة، وتعزيز فهمنا لفعاليتها في حل مشاكل رياضية وهندسية. يمكن أن تكون هذه الدراسة أساساً للبحث المستقبلي في مجال تطوير وتحسين الخوارزميات لحل تحديات أكبر في مجموعة متنوعة من التطبيقات.

استلمت الورقة بتاريخ 2023/08/20، وقبلت بتاريخ 2023/11/04، ونشرت بتاريخ 2023/11/10

الكلمات المفتاحية: ذكاء السرب، الأمتلة، الخوارزميات التطورية، خوارزمية أسراب العناصر.

1. مقدمة

تعد عملية التحسين أو ما يمكن تسميته بالأمتلة (Optimization) أمراً ذا أهمية فائقة في عدد لا يحصى من التطبيقات الرياضية والهندسية المتنوعة. تهدف هذه العملية بشكل أساسي إلى تحسين أداء النماذج الرياضية عبر تقليل الأخطاء وزيادة الدقة في العديد من التطبيقات. يتم ذلك من خلال تحسين القرارات التي تؤثر على واحد على الأقل من أهداف محددة في مجموعة معينة من الظروف [1].

ذكاء السرب (SI) المعروف أيضاً باسم الحوسبة المستوحاة من الطبيعة يعتبر فرعاً حديثاً نسبياً في ميدان الذكاء الاصطناعي؛ حيث يعمل على اكتشاف أو تحسين الحلول المثلى لمسائل معقدة بين مجموعة من البدائل الممكنة. هذه الخوارزميات يمكن اعتبارها أحد أدوات صنع القرار الكمية الرئيسية. تشمل منهجية عملها إنتاج مجموعة من الأفراد وتقييم فعاليتهم، ثم إنشاء مجموعة جديدة تحسن من الأداء، وتكرار هذه العملية مراراً حتى الوصول إلى الحل الأمثل أو على الأقل إلى حل قريب من الأمثل [2].

في التسعينات من القرن الماضي، تطورت هذه البحوث نحو محاكاة سلوك كائنات حية أقل ذكاءً من الإنسان، مثل النمل والأسماك والطيور، لاستخراج الذكاء الاجتماعي الذي يظهر في تفاعلاتها. هذه المحاكاة أفضت إلى تطوير سلسلة من خوارزميات الأمتلة المستوحاة من الطبيعة [2]. تعتمد هذه الخوارزميات عادة على مجموعة بسيطة من القواعد وتكرار عملية التحسين حتى يتم الوصول إلى الحل الأمثل.

للأمتلة دور بارز في العديد من المجالات، ومن بينها مجال الاتصالات والتكنولوجيا. تُسلط الضوء العديد من الأبحاث والدراسات السابقة على أهمية هذا المفهوم، وسنستعرض بعضاً منها هنا:

في دراسة نفذها Kouhbor وآخرون في عام 2005، تم التركيز على العثور على مواقع مثلى لنقاط الوصول في الشبكات اللاسلكية. تم استخدام خوارزمية التدرج المترافق (Discrete gradient descent) لحل هذه المشكلة وتم استنتاج أن هذا النموذج يمكنه حل مشكلات التغطية بكفاءة لمجموعات متنوعة من المستخدمين [3].

في دراسة أخرى قام بها Ivan Vilovic و Niksa Burum في عام 2017، تم استخدام بعض الخوارزميات التطورية مثل (PSO) و Ant Colony Optimization (ACO) لتحسين توزيع نقاط الوصول. تمت المقارنة بين أداء هذه الخوارزميات، واستنتج الباحثان أن (PSO) كانت الأفضل في تحسين المواقع [4].

أما في دراسة أجريت بواسطة M. Ersoy و T. Yigit في عام 2014، تم التركيز على اختبار وتصميم شبكة محلية لاسلكية داخلية باستخدام تقنيات الذكاء الاصطناعي. تم استخدام الشبكة العصبية الاصطناعية لتحديد نقاط الوصول وقوة إشارة الاستقبال المثلى. واستخدمت الخوارزمية الجينية لتصميم الشبكة بشكل أمثل، واستنتج الباحثان أنها تقدم أداء أفضل من الأساليب التقليدية [5].

أخيراً، في دراسة أجريت بواسطة Lee, Shu-Hung وآخرون في عام 2023، على خوارزمية أسراب العناصر (PSO) المحسنة مع تطبيق عملي لتحديد موقع وتتبع الأهداف في الأماكن المغلقة. أظهرت النتائج أن طريقة خوارزمية أسراب العناصر (PSO) المحسنة تُمكن من تقليل عدد الجزينات في الخوارزمية، مما يعزز السرعة دون التأثير على الدقة [6].

تسلط هذه الأبحاث الضوء على أهمية استخدام الأمتلة في تطوير تقنيات وحلول لتحديد المواقع داخل المباني والبيئات الداخلية. كما تُشير الأبحاث إلى أنه لا يوجد طريقة واحدة فعالة لحل جميع مسائل الأمتلة. لهذا السبب، تم تطوير مجموعة متنوعة من الأساليب للتعامل مع أنواع مختلفة من

• الخوارزمية المناعية الصناعية Artificial Immune
Algorithm (AIA) [13]

أ. أسراب العناصر للأمتلة (Particle Swarm Optimization)
(PSO)

هي خوارزمية تطويرية تستخدم لإيجاد الحل الأمثل للمشكلات الرقمية والكمية، وهي مستوحاة من نظرية ابتكرها عالم الاجتماع (James Kenndy) والمهندس الكهربائي (Russell Eberhart) في عام (1995) بناءً على ملاحظتهما لسلوك سرب الطيور [9، 14].

وبناءً على قواعد بسيطة تحدد الطيور اتجاهاتها وسرعتها، فينطلق الطير بعيداً عن السرب بحثاً عن الهدف متأثراً بالطيور الأخرى التي تسعى للوصول إلى الهدف. وعندما يعثر على الهدف يستدعي باقي الطيور للانضمام إليه، وهكذا حتى يصبح كل السرب متجهاً نحو الهدف [14]. يماثل إيجاد الهدف (مأوى، طعام) إيجاد حل في مجال الحلول المحتملة لمجال الحل. والفكرة هي أن أي طير يصل إلى الهدف يشجع أقرانه على التوجه نحوه مع زيادة احتمالات أن يصلوا أيضاً. خوارزمية أسراب العناصر تبرز التعاون بين العناصر في المجموعة، والتوافق المثالي بين الاستكشاف (البحث عن هدف) والهدف (إيجاد الهدف). بعض العناصر (الأفراد) تصل إلى حل جيد منذ البداية وبعضها يستغرق وقتاً للاقترب أو لا يقترب أبداً. وبإيجاز تسعى الخوارزمية إلى إيجاد أفضل حل بين المكونين الأساسيين (الفرد والجماعة). في كل تكرار من الخوارزمية، يتحرك كل عنصر بسرعة معينة نحو موضعه الشخصي الأفضل وموضع السرب الأفضل. موضعه الشخصي الأفضل هو أفضل حل وجده العنصر حتى الآن، ويسمى "Pbest". موضع السرب الأفضل هو أفضل حل وجده أي عنصر في المجموعة، ويسمى "gbest". بالتالي، يتأثر تحديث سرعة وموضع كل عنصر بثلاثة عوامل: سرعته الحالية، المسافة بين موضعه الحالي و"gbest"، والمسافة بين موضعه الحالي و"gbest". هذا يعني أن كل عنصر يتبع قاعدة بسيطة: اقترب من حل جيد وابتعد عن حل سيئ. بهذه الطريقة، تستطيع خوارزمية PSO استكشاف فضاء البحث بشكل فعال والوصول إلى حل مقبول في زمن قصير كما هو موضح بالشكل 1.

يمكن تمثيل خوارزمية PSO رياضياً بالصيغة الموضحة في المعادلتين (1)، (2).

$$v_i^{k+1} = v_i^k + \underbrace{c_1 \times rand() \times (P_{best_i} - x_i^k)}_{v_{P_{best}}} + \underbrace{c_2 \times rand() \times (g_{best} - x_i^k)}_{v_{g_{best}}} \quad (1)$$

(2)

حيث أن:

- v_i^k : سرعة العنصر عند التكرار k .
- x_i^k : موضع العنصر i عند التكرار k .
- c_1 : الثابت الفردي ويتعلق بـ P_{best} .
- c_2 : الثابت الجماعي ويتعلق بـ g_{best} .
- $rand()$: عدد عشوائي بين الصفر والواحد.
- P_{best_i} : موضع Pbest للعنصر i (أفضل موقع سابق).

مسائل الأمتلة. يُشار أيضاً إلى أن طرق البحث عن الحل المثلي تُعرف عادة باسم تقنيات البرمجة الرياضية، والتي تُدرس كجزء مكمل من مجال بحوث العمليات.

وقد اخترنا خوارزمية أسراب العناصر للأمتلة (PSO) التي تُعرف أيضاً باسم أسراب الجسيمات أو أسراب الطيور؛ لأنها تتمتع ببساطة وسرعة في التطبيق، وذلك لأنها لا تحتوي على متغيرات زائدة مثل التهجين (Crossover) والطفرة (Mutation) كما في الخوارزميات الوراثية (GA) وبالإضافة إلى ذلك، فإن (PSO) تستخدم الأعداد الحقيقية كعناصر أو طول أولية، وهذا يخالف الخوارزميات الوراثية (GA) التي تحتاج إلى خطوة إضافية وهي التحويل إلى الترميز الثنائي (Binary Encoding) أو استخدام المعاملات الوراثية (Genetic Operators) [8، 10].

في هذه الدراسة، سنتم دراسة خوارزمية أسراب العناصر (PSO) وتطبيقاتها بشكل تطبيقي؛ حيث تم تقديم حالة دراسية لشرح كيفية عمل هذه الخوارزمية بنسخة محسنة وتطبيقها بشكل فعال.

2. الخوارزميات التطورية Evolutionary Algorithms

تعتبر الخوارزميات التطورية عن مصطلح شامل لأنواع عديدة من خوارزميات الذكاء الاصطناعي التي تعتمد في مبدأ عملها على محاكاة بعض العمليات الحيوية التي تحدث في الطبيعة. وتستخدم هذه الخوارزميات في آلية عملها التقنيات الحيوية كإعادة الإنتاج (Reproduction)، إعادة التجميع (Recombination) والية الاصطفاء (Selection) وتستخدم مفاهيم التطور البيولوجي مثل الانتقاء الطبيعي (Natural Selection) والبقاء للأصلح (Survival of Fittest) من أجل حل المسائل المختلفة للحصول على أفضل النتائج (أو القريبة للأفضل). تأخذ هذه الخوارزميات أهميتها بسبب قدرتها على إيجاد حلول فعالة لمختلف المسائل دون الحاجة لمعرفة الكثير من المعلومات عن طبيعة المسألة المراد حلها [7].

في الخمسين عامًا الماضية، أظهرت الدراسات وجود أشكال مختلفة من الذكاء تنشأ من مجموعات متنوعة من الحيوانات، مثل الحشرات والأسماك والطيور والحيوانات بشكل عام. هذه المجموعات تشمل جيوش النمل ومستعمرات النحل وأسراب الطيور والأسماك. ومع ذلك، فإن التفاعلات البسيطة بين عدد كبير من الكائنات الحية البسيطة قد تؤدي إلى ظهور ذكاء يستطيع التكيف مع البيئة المحيطة. في مجتمعات الحشرات، يتبع النظام نمطاً غير مركزي. يتألف من عدة وحدات مستقلة ذات سلوك احتمالي بسيط، تنتشر في البيئة، كل وحدة تحصل فقط على المعلومات المحلية. هذه الوحدات لا تمتلك أي تصور أو معرفة بالهيكل الإجمالي الذي يفترض أن يتم إنشاؤه أو تطويره. كما أنها لا تتبع أي خطة مسبقة. بمعنى آخر، فإن المهمة الإجمالية ليست مخططة بوضوح من خلال الأفراد، بل تظهر نتيجة لعدد كبير من التفاعلات المحدودة بين الأفراد أو بينهم وبين البيئة. هذا النوع من الذكاء الجماعي، الذي يُبنى من قِبَل كائنات فردية بسيطة، كان مصدر إلهام لنظام جديد في علوم الحاسوب، وهو ذكاء السرب [8].

من بين الخوارزميات التطورية التي تقلد آليات الحياة في الطبيعة، نجد أنواعاً مختلفة مثل:

- أسراب العناصر للأمتلة Particle Swarm Optimization (PSO) [9]
- الخوارزمية الوراثية Genetic Algorithm (GA) [10]
- بحث طائر الوقواق Cuckoo Search (CS) [11]
- تحسين مستعمرات النمل Ant Colony Optimization (ACO) [12]

g_{best} : موضع السرب (أفضل موقع من أفضل مواقع العناصر المتحركة).

توضح المعادلتان (1) و (2) السرعة والموضع الجديدين على التوالي.


تحسب المعادلة (1) السرعة الجديدة لكل عنصر اعتماداً على سرعة العناصر السابقة وموضعها عند الحل الأمثل المحقق حتى اللحظة.

يلعب عامل الوزن (w) دوراً كبيراً في تحسين أداء خوارزمية أسراب العناصر القياسية. كما أن لهذا العامل دوراً حيوياً في تحقيق توازن بين إمكانية البحث الشامل والبحث المحلي للعناصر، ويمكن تعيينه كثابت موجب أو كمعادلة خطية أو غير خطية تتغير مع عدد دورات التحسين. ووفقاً للمرجع [15]، يُظهر البحث أن أفضل فرصة للعثور على الحل الأمثل ضمن عدد مقبول من التكرارات يمكن تحقيقه من خلال دمج هذا المتغير في معادلة السرعة الجديدة كما هو موضح في المعادلة (3).

$$v_i^{k+1} = w \times v_i^k + c_1 \times rand() \times (P_{best_i} - x_i^k) + c_2 \times rand() \times (g_{best} - x_i^k) \quad (3)$$

معادلة شوييفيل Schwefel تعتبر واحدة من أشهر المعادلات الرياضية وسيلة في مجال الأمثلة وخوارزميات التحسين، تعتبر المعادلات الرياضية وسيلة هامة لاختبار قدرة الخوارزميات على البحث عن الحلول المثلى في ظروف مختلفة. من بين هذه المعادلات، نجد معادلة شوييفيل (Schwefel)، ومعادلة جريوانك (Griewank)، ومعادلة راسترجين (Rastrigin) التي تتميز بتعقيد هياكلها الرياضية والتحدي الذي تمثله أمام الخوارزميات الذكية [16].

$$f(x) = \sum_{i=1}^n \sum_{j=1}^i (x_i)^2, \text{ with } -100 \leq x_i \leq 100; \quad (5)$$



شكل 2: معادلة شوييفيل Schwefel في بعدين.


ب. معادلة جريوانك (Griewank):

$$f(x) = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{x_i^2}{\sqrt{|x_i|}} \quad (4)$$

تمثل تحدياً آخر للخوارزميات الذكية بسبب تعقيد هياكلها. تحتوي هذه المعادلة على العديد من القمم الصغيرة داخل فضاء الحل، مما يجعل البحث عن الحلول المثلى صعباً ومعقداً. سنتناول في هذا المقال كيفية استخدام معادلة Griewank كمعيار لاختبار كفاءة خوارزميات أسراب العناصر. شكل 3 يوضح معادلة جريوانك في بعدين.

تعطي القيم المثالية لعامل الوزن (w) في المجال (0.9-1.2) وفقاً للمرجع [15].

يمكن أن تتغير قيم جميع المتغيرات المتضمنة في المعادلة (3) بناءً على خصائص المشكلة المحددة. تتفاوت طرق تعديل هذه المتغيرات بناءً على نوع المشكلة، وهي تتطلب تعديلاً أو تغييراً دقيقاً لضمان تحسين أداء الخوارزمية.



شكل 1: مفهوم تعديل نقطة البحث.

يقوم الطير بضبط موقعه استناداً إلى موقعه الحالي وسرعته، وفي كل تحديث، يعدل الطير سرعته وفقاً للمعادلات (1) و (2) المذكورة سابقاً. بالتالي، يتم استخدام عامل الوزن (w) للتحكم في تأثير السرعة السابقة، وبالنتيجة تأثير التوازن بين إمكانية البحث الشاملة (وسع المجال) والبحث المحلي (مجال ضيق) لنقاط الطيران في خوارزمية PSO. يتحكم عامل الوزن بشكل رئيسي في هذا التوازن، ويمكن التحكم في هذا التأثير من خلال المعادلة (4).

حيث أن:

w : عامل الوزن الابتدائي.

w_{max} : هي القيمة العظمى لعامل الوزن.

w_{min} : هي القيمة الصغرى لعامل الوزن.

لقياس أداء خوارزمية أسراب الجسيمات، تم استخدام مجموعة من المقاييس $f(x)$ التي تساهم في تقدير مدى اقتراب الخوارزمية من الحل الأمثل، بالإضافة إلى تقييم جودة الحلول التي تنتجها. فيما يلي بعض المقاييس الشائعة لتقييم خوارزميات الأمثلة:

1. أفضل قيمة: تُعدُّ القيمة الأفضل التي تم العثور عليها بواسطة الخوارزمية (قيمة الدالة) مؤشراً أساسياً؛ حيث ينبغي أن تكون هذه القيمة قريبة إلى الحد الأدنى العام المتوقع (الذي يكون عادةً مساوياً للصفر في حالة البحث عن الأدنى)؛ كلما كانت القيمة أقل، كان أداء الخوارزمية أفضل. في هذا البحث سيتم استخدام المتوسط والأفضل والأسوأ والانحراف المعياري لقيم دالة الهدف.

2. منحني التقارب: يتيح رسم منحني التقارب متابعة تطور أفضل القيم التي تم العثور عليها بواسطة الخوارزمية خلال كل تكرار. يُظهر هذا الرسم إذا كانت الخوارزمية تتقارب تدريجياً نحو الحد الأدنى العام أم لا.

3. جودة الحل: بالإضافة إلى أفضل قيمة، يمكنك أيضاً تقييم جودة الحل الذي تم العثور عليه من خلال مقارنته بالحد الأدنى العام المعروف. يتم ذلك من خلال حساب الخطأ المطلق أو الخطأ النسبي بين أفضل القيم التي تم العثور عليها والحد الأدنى العام الفعلي.

4. التوازن بين الاستكشاف والاستغلال: يُحلل هذا المجال قدرة الخوارزمية على تحقيق توازن بين عملية الاستكشاف (البحث في مساحة الحل بشكل شامل) وعملية الاستغلال (التركيز على أفضل الحلول التي تم العثور عليها حتى الآن). يمكن تمثيل هذا التوازن من خلال رسم توزيع الجسيمات عبر مساحة الحل أثناء عملية التحسين.

د. النتائج ومناقشتها

في هذا الجزء من البحث، سنتناول النتائج التي تم الحصول عليها من خلال تطبيق الخوارزمية المقترحة على ثلاث دوال معيارية باستخدام لغة البايثون، وهي معادلة شوفيل (Schwefel)، ومعادلة جريوانك (Griewank)، ومعادلة راسترجين (Rastrigin). تضمنت هذه التجارب استخدام خوارزميتين مختلفتين للتحسين، وهما خوارزمية أسراب العناصر القياسية ونسخة محسنة من الخوارزمية. الهدف من هذا البحث هو تحليل ومقارنة أداء هاتين الخوارزميتين استناداً إلى المقاييس التقييمية الرئيسية، والتي منها المتوسط والأفضل والأسوأ والانحراف المعياري لقيم دالة الهدف.


بالنسبة لمعادلة شوفيل (Schwefel)، أظهرت النتائج بوضوح تفوق الخوارزمية المحسنة على خوارزمية أسراب العناصر القياسية. أثبتت النسخة المحسنة من الخوارزمية بثبات تفضيلها من خلال جميع مقاييس الأداء. تحققت الخوارزمية المحسنة قيماً أدنى للمتوسط والأفضل والأسوأ لقيم دالة الهدف، مما يشير إلى فعاليتها في عملية الأمثلة. علاوة على ذلك، عرضت الخوارزمية انحرافاً معيارياً أقل بشكل كبير، مما يؤكد على استقرارها وموثوقيتها الأكبر في توليد الحلول المحسنة.

بالنسبة لمعادلة جريوانك (Griewank)، أظهرت الخوارزمية المحسنة أداءً متفوقاً مماثلاً للمعادلة السابقة. حققت قيماً أدنى للمتوسط والأفضل والأسوأ لقيم دالة الهدف، مما يشير إلى فعاليتها في الوصول إلى الحلول المثلى. عرضت الخوارزمية أيضاً انحرافاً معيارياً أقل بشكل ملحوظ، مما يؤكد على استقرارها واستمراريتها في تحقيق النتائج المحسنة.

بالنسبة لمعادلة راسترجين (Rastrigin)، أظهرت الخوارزمية المحسنة تفوقاً مستمراً على خوارزمية أسراب العناصر القياسية. حققت قيماً أدنى للمتوسط والأفضل والأسوأ لقيم دالة الهدف، مما يشير إلى فعاليتها البارزة في التعامل مع تحديات معادلة راسترجين (Rastrigin) المعيارية.

$$f(x) = \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1, \text{ with } (6)$$

$$-600 \leq x_i \leq 600;$$




شكل 3: معادلة جريوانك Griewank في بعدين.

ج. معادلة راسترجين (Rastrigin):

معادلة راسترجين Rastrigin تعتبر أيضاً من المعادلات الشهيرة في مجال الأمثلة والبحث عن الحلول. تمتاز بتعقيد هيكلها وشكلها المميز الذي يحتوي على قيم منخفضة وعدة قمم عالية في فضاء الحلول. تُستخدم هذه المعادلة كمعيار لاختبار كفاءة الخوارزميات في التعامل مع تحديات البحث عن الحلول في الفضاء المعطى. سنقوم في هذا المقال بالتركيز على كيفية استخدام معادلة Rastrigin كمعيار اختبار خوارزميات أسراب العناصر. شكل 4 يوضح معادلة راسترجين Rastrigin في بعدين.

$$f_3(x) = \frac{1}{4000} \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10), \text{ with } -5.12 \leq x_i \leq 5.12; (7)$$



شكل 4: معادلة راسترجين Rastrigin في بعدين.

في تطوير خوارزميات التحسين وتفتح آفاقاً لمزيد من الاستكشاف والتحسين في مجال تقنيات التحسين لمشاكل معقدة.

4. الاستنتاجات

توضح النتائج التي تم الحصول عليها من هذا البحث أهمية استخدام الخوارزمية المحسنة في عمليات الأمثلة، وخصوصاً عند التعامل مع معادلات رياضية معيارية معقدة. بعض النقاط الرئيسية التي يمكن استخلاصها من هذه الدراسة هي:

1. تحقيق الأداء المحسن: أظهرت الخوارزمية المحسنة أداءً متفوقاً بشكل ثابت على الخوارزمية القياسية في جميع الحالات الثلاثة المدروسة. وهذا يشير إلى قدرتها على العثور على الحلول المثلى بشكل أفضل وأسرع.

2. زيادة استقرار النتائج: كان لدى الخوارزمية المحسنة انحراف معياري أقل بشكل ملحوظ في جميع الحالات. وهذا يشير إلى استقرار نتائجها وقدرتها على إنتاج حلول متميزة بشكل منتظم.

3. تحسين الأداء عبر مجموعة متنوعة من المعادلات: استناداً إلى النتائج، يمكن استخدام الخوارزمية المحسنة بنجاح في حل مجموعة متنوعة من المعادلات الرياضية المعيارية، مما يعزز تعميم تلك التقنية لحلول مشاكل أكثر تعقيداً في المستقبل.

4. تعزيز التطوير في مجال الخوارزميات: تسهم هذه النتائج في تطوير تقنيات التحسين وتعزيز الأداء في مجال الخوارزميات. ويمكن أن تكون الخوارزمية المحسنة نموذجاً للبحوث المستقبلية لتحسين الخوارزميات الأخرى وزيادة فعاليتها.

باختصار، تظهر هذه الدراسة أن استخدام الخوارزميات المحسنة يمكن أن يكون له تأثير كبير على تحسين الأداء في حل المعادلات الرياضية، وتوفير نتائج أفضل وأكثر استقراراً. وهذا يشجع على استمرار البحث والتطوير في هذا المجال للمساهمة في حل مشاكل معقدة في مختلف المجالات.

5. المراجع

- [1] A. G. Gad, "Particle swarm optimization algorithm and its applications: a systematic review," *Archives of computational methods in engineering*, vol. 29, no. 5, 2022, pp. 2531-2561.
- [2] T. M. Shami, A. A. El-Saleh, M. Alswaiti, Q. Al-Tashi, M. A. Summakieh, and S. Mirjalili, "Particle swarm optimization: A comprehensive survey," *IEEE Access*, vol. 10, 2022, pp. 10031-10061.
- [3] S. Kouhbor, J. Ugon, A. Kruger, and A. Rubinov, "Optimal placement of access point in WLAN based on a new algorithm," *International Conference on Mobile Business (ICMB'05)*, 2005, pp. 592-598: IEEE (
- [4] I. Vilović and N. Burum, "Location optimization of wlan access points based on a neural network model and evolutionary algorithms," *Automatika*, vol. 55, no. 3, 2014, pp. 317-329.
- [5] T. Yigit and M. Ersoy, "Testing and design of indoor WLAN using artificial intelligence techniques," *Elektronika Ir Elektrotehnika*, vol. 20, no. 6, pp. 154-157, 2014.
- [6] S.-H. Lee, C.-H. Cheng, C.-C. Lin, and Y.-F. Huang, "PSO-Based Target Localization and Tracking in Wireless Sensor Networks," *Electronics*, vol. 12, no. 4, p. 905, 2023.
- [7] J. Liang et al., "A survey on evolutionary constrained multiobjective optimization," *IEEE*


عرضت الخوارزمية أيضاً انحراف معياري أقل بشكل كبير، مما يؤكد على تحقيقها لنتائج محسنة بشكل ثابت واستقرارها.

جدول 1 يوضح ملخص للتجارب التي تم تنفيذها على ثلاث دوال معيارية، وهي معادلة شوفيل (Schwefel)، ومعادلة جريوانك (Griewank)، ومعادلة راسترجين (Rastrigin)، في عدد 30 بعد (Dimension) لكل معادلة وأهم النتائج التي تم الحصول عليها.


جدول 1: ملخص التجارب التي تم تنفيذها على الدوال المعيارية الثلاثة.

المعادلة	الخوارزمية	مؤشرات التقييم		
		Std	Worst	Best
معادلة شوفيل (Schwefel)	PSO	29.56	191.31	97.09
	PSO المحسنة	24.17	170.12	86.57
معادلة جريوانك (Griewank)	PSO	8.03	36.07	11.89
	PSO المحسنة	3.18	17.35	7.08
معادلة راسترجين (Rastrigin)	PSO	108.64	11467.22	11176.75
	PSO المحسنة	66.36	11232.06	11049.4

الشكل 5 يُبين كيفية تغير عمليتي الاستكشاف والاستغلال (exploration and exploitation) خلال مرحلة البحث عن الحل الأمثل باستخدام الخوارزمية المحسنة. من خلال هذا الشكل، يمكن الحصول على فهم حول كيفية توازن الخوارزمية بين البحث عن حلول جديدة واستغلال الحلول الأفضل التي تم العثور عليها. كما يوضح شكل 6 منحني التقارب لنتائج أفضل القيم التي تم العثور عليها بواسطة الخوارزمية خلال كل دورة.



شكل 5: تحقيق التوازن بين عملية الاستكشاف وعملية الاستغلال.



شكل 6: منحني التقارب الذي تم تحقيقه خلال كل تكرار

بشكل عام، تشير هذه النتائج إلى فعالية خوارزمية أسراب العناصر المحسنة في حل المعادلات المدروسة. استقرارها وقدرتها على تحسين قيم دالة الهدف تجعلها خياراً مناسباً لمهام التحسين المتنوعة. تلك النتائج تسهم

- Transactions on Evolutionary Computation*, vol. 27, no. 2, 2022, pp. 201-22.[8] Z.-H. Zhan, L. Shi, K. C. Tan, and J. Zhang, "A survey on evolutionary computation for complex continuous optimization," *Artificial Intelligence Review*, 2022, pp. 1-52.
- [9] J. Kennedy and R. Eberhart, "Particle swarm optimization," *Proceedings of ICNN'95-international conference on neural networks*, 1995, vol. 4, pp. 1942-1948: IEEE.
- [10] S. Mirjalili, "Genetic algorithm," *Evolutionary Algorithms Neural Networks: Theory Applications* رقم المجلد والعدد؟, 2019, pp. 43-55, .
- [11] X.-S. Yang and S. Deb, "Engineering optimisation by cuckoo search," *International Journal of Mathematical Modelling Numerical Optimisation*, vol. 1, no. 4, 2010, pp. 330-343.
- [12] M. Dorigo and T. Stützle, *Ant colony optimization: overview and recent advances*, 2019.
- [13] D. Dasgupta, *Artificial immune systems and their applications*. Springer Science & Business Media, 2012.
- [14] J. Nayak, H. Swapnarekha, B. Naik, G. Dhiman, and S. Vimal, "25 years of particle swarm optimization: Flourishing voyage of two decades," *Archives of Computational Methods in Engineering*, vol. 30, no. 3, 2023, pp. 1663-1725.
- [15] Y. Shi and R. Eberhart, "A modified particle swarm optimizer, 1998 IEEE International Conference on Evolutionary Computation Proceedings," in *IEEE World Congress on Computational Intelligence (Cat. No. 98TH8360)*, 1998, pp. 69-73.
- [16] F. Chen, X. Sun, D. Wei, and Y. Tang, "Tradeoff strategy between exploration and exploitation for PSO," *seventh international conference on natural computation*, 2011, vol. 3, pp. 1216-1222 :IEEE.