



**Tikrit Journal of Administrative
and Economics Sciences**

مجلة تكريت للعلوم الإدارية والاقتصادية

EISSN: 3006-9149

PISSN: 1813-1719



Marine Predator Algorithm MPA Review: Marine Predator-Inspired Optimization and Its Applications to Optimization Problems

Rafal Abdulhameed Saeed*, Nazar K. Hussein

College of Computer Science and mathematics/ Tikrit University

Keywords:

Marine Predator Algorithm, Exploration, Exploitation, Optimization, Optimal Solutions.

ARTICLE INFO

Article history:

Received 29 Oct. 2024

Accepted 17 Nov. 2024

Available online 30 Jun. 2025

©2023 THIS IS AN OPEN ACCESS ARTICLE
UNDER THE CC BY LICENSE

<http://creativecommons.org/licenses/by/4.0/>



***Corresponding author:**

Rafal Abdulhameed Saeed

College of Computer Science and
mathematics/ Tikrit University



Abstract: In recent years, the Marine Predator Algorithm (MPA) has emerged as a powerful tool in the field of metaheuristic optimization, an algorithm inspired by the behavior of marine predators in the natural environment. This algorithm is based on three main strategies to simulate what happens between predators and prey, which gives a strong balance between the exploration process and the exploitation process. This paper attempts to review the most important improvements, modifications and applications of the MPA algorithm in several fields. Compared to algorithms such as PSO, SMA and other algorithms, MPA has proven its effectiveness and strength, especially in improving the speed and accuracy in reaching optimal solutions. Despite its successes, MPA faces some challenges in certain problems, such as the need for additional modifications to improve its performance in more complex environments. In this context, we discuss future directions for developing this algorithm and expanding its use in new fields.

مراجعة خوارزمية المفترس البحري: التحسين المستلهم من سلوك المفترسات البحرية وتطبيقاته في مسائل الأمثلية

رفل عبد الحميد

نزار خلف حسين

كلية علوم الحاسوب والرياضيات/ جامعة تكريت

المستخلص

في السنوات الأخيرة، برزت خوارزمية المفترس البحري Marine Predator Algorithm (MPA) كأداة قوية في مجال التحسين، وهي خوارزمية مستلهمة من أنواع سلوك المفترسات البحرية في البيئة الطبيعية. حيث تستند هذه الخوارزمية على استراتيجيات ثلاثة رئيسة لأجل محاكاة ما يحدث بين المفترسات والفرائس، وهذا ما يعطي توازناً قوياً بين عملية الاستكشاف وعملية الاستغلال. هذه البحث محاولة لمراجعة أهم تحسينات وتعديلات وتطبيقات خوارزمية MPA في مجالات عدة. بالمقارنة مع خوارزميات مثل Particle Swarm Optimization (PSO) و Slime Mould Algorithm (SMA) وغيرها من الخوارزميات الأخرى أثبتت MPA فعاليتها وقوتها، خاصة في تحسين السرعة والدقة في الوصول إلى الحلول المثلى. على الرغم من نجاحاتها، تواجه MPA بعض التحديات في مشاكل معينة، مثل الحاجة إلى تعديلات إضافية لتحسين أدائها في بيئات أكثر تعقيداً. في هذا السياق، ناقش الاتجاهات المستقبلية لتطوير هذه الخوارزمية وتوسيع نطاق استخدامها في مجالات جديدة.

الكلمات المفتاحية: خوارزمية المفترس البحري، الاستكشاف، الاستغلال، الأمثلية، الحلول المثلى.

1. المقدمة:

لطالما كان الهدف من الرياضيات التطبيقية وخوارزميات التحسين تحديداً هو إيجاد الحل الأمثل لدوال أو مسائل معقدة. تواجه المشكلات المتعلقة بالدوال غير الخطية وغير المحدبة والمتعددة القمم وخاصة منها غير القابلة للاشتقاق في الفضاء المستمر تحديات كبيرة. في الوقت الحالي، يتم استخدام منهجيات البحث الاستكشافي (metaheuristic) على نطاق واسع لحل العديد من مسائل التحسين غير التقليدية. وقد أثبتت هذه المنهجيات فعاليتها في معالجة مسائل التحسين المعقدة (Sayarshad et al., 2010). علاوة على ذلك، أصبحت خوارزميات Metaheuristic محط اهتمام كبير في مجالات متعددة، بدءاً من الأبحاث الأكاديمية وصولاً إلى التطبيقات الهندسية العملية، نظراً لقدرتها على حل مجموعة واسعة من المسائل المعقدة. كذلك فإنه مع تزايد تعقيد مسائل التحسين في السنوات الأخيرة، ظهرت الحاجة إلى استراتيجيات جديدة وأكثر تقدماً. رغم وجود العديد من الخوارزميات الفعالة لحل المشكلات، لا يمكن عد أي منها الأفضل دون مقارنتها بغيرها (Wang and Tan, 2017).

لقد تمكنت خوارزميات Metaheuristic من حل العديد من التحديات الصعبة التي يصعب معالجتها باستخدام تقنيات التحسين التقليدية يمكن تصنيف هذه الخوارزميات إلى نوعين رئيسيين بناءً على بنيتها: الخوارزميات القائمة على المسار والخوارزميات القائمة على المجتمع (Fister Jr et al., 2013). تعتمد الخوارزميات القائمة على المسار على تحسين حل واحد ينتقل عبر فضاء البحث. وتستخدم في الغالب أساليب عشوائية وتوجيهات محددة، مثل المعايير الجسعة، ضمن عدد محدود من التكرارات لتحسين الحل. من أشهر الخوارزميات في هذا المجال

خوارزمية تلدين المحاكاة (Kirkpatrick, 1983) Simulate Annealing Algorithm وبحث التابو (Glover, 1989) tabu، وهذه الفئة تتطلب عددًا محدودًا من التقييمات وتتميز ببساطة الحسابات.

أما الخوارزميات القائمة على المجتمع، فهي تعتمد على توليد مجموعة كبيرة من الحلول البديلة في إطار قيود المسائلة بشكل متكرر. إذ يعتمد نجاح هذه الخوارزميات على نقل المعرفة (تبادل المعلومات)، والتعاون، والتفاعل بين الحلول المرشحة، مما يعزز من قدرتها على الوصول إلى الحل الأمثل.

الخوارزميات الأكثر شهرة في مجال التحسين القائمة على المجتمع تشمل تحسين سرب الجسيمات (PSO) (Kennedy and Eberhart, 1995) ومستعمرة النحل الاصطناعية (ABC) (Karaboga and Basturk, 2007) وخوارزمية مستعمرة النمل (Colormi et al., 1991) بالإضافة إلى التطور التفاضلي (Storn and Price, 1996) والخوارزمية الجينية GA (Goldberg and Holland, 1988)، ومحسن الذئب الرمادي (Mirjalili et al., 2014) وغيرها من الخوارزميات في هذا المجال.

تمتاز هذه الخوارزميات بقدرتها على استكشاف مجموعة واسعة من الحلول في كل تكرار، مما يمنحها قدرة قوية على البحث في فضاء الحلول بشكل شامل. هذه الميزة تساعد في تجنب الوقوع في الحلول المثلى المحلية، وهي مشكلة شائعة في أساليب التحسين التقليدية. كما إن تشغيل عوامل عدة بحث بالتوازي يساهم في تحسين الأداء العام للخوارزميات.

أيضا فإن هذه الخوارزميات قد أثبتت فعاليتها عند استخدامها في حل المسائل المعقدة للتحسين بما في ذلك مسائل التحسين في الهندسة (Zhao et al., 2021) وأيضا في اختيار وتقدير المعلمات (Islam et al., 2021) وهذا يأتي من استخدام هذه الخوارزميات لعمليات عشوائية لأجل تعزيز القدرة على الاستغلال والاستكشاف وهذه العمليات هي الطفرة والاختيار (Tu et al., 2019) وكذلك العبور (Faris et al., 2018) كل ذلك جعل الخوارزميات المعتمدة على المجتمع تتفوق على غيرها في كثير من التطبيقات والمسائل الواقعية المعقدة التي لا يمكن حلها بالطرق التقليدية أو إن الطرق التقليدية لاتصل إلى حل مقنع عند استخدامها.

تعد خوارزميات التحسين من أكثر الخوارزميات استخداما في تحديد التصميم الأفضل والأنسب للمشكلات الواقعية وخاصة الهندسية منها، لأن معظم المسائل الهندسية الواقعية تعد من أكثر المسائل الأمثل التي يوجد فيها درجة عالية من التعقيد مما يجعل عملية اختيار التصميم الأمثل لها وكذلك المعلمات المناسبة هي عملية صعبة للغاية، لأنها في الحقيقة تأتي من مشاكل رياضية أو صعوبات رياضية تتعلق بالنموذج الرياضي الذي يمثل المشكلة الحقيقية، كأن تكون هذه المشكلة مرتبطة بالنموذج الرياضي الذي يمثل المشكلة الحقيقية. الأبعاد العالية للمشكلة التي تمثل المشكلة، أو قد تكون مرتبطة بعدم الخطية مما يسبب ارتفاع تعقيد المشكلة، أو قد تكون مرتبطة بعدم استيفاء المشكلة للشرط المحدب، مما يجعل عملية البحث الحل الأمثل الشامل صعب للغاية.

يمكن تصنيف مشكلات التحسين إلى مشكلات خطية وغير خطية قد تكون مقيدة أو غير مقيدة ولذلك فإن مسائل الأمثلة تصنف إلى مسائل أمثلية مقيدة ومسائل أمثلية غير مقيدة، ويمكن أيضًا أن تكون متعددة الأهداف وليست ذات هدف واحد.

ولأن المسائل التي تأتي من الواقع عادة ما تكون شديدة التعقيد فضلاً عن كونها ذات بعد عالٍ جداً، فقد لا نحصل على نتائج مشجعة من الأساليب أو الخوارزميات الأصلية في شكلها وتقنياتها الأصلية، لذلك يتم اللجوء إلى الاستفادة من عملية مشاركة أو دمج هذه الأساليب من أجل الحصول على مزيج أفضل من الأصول، وتسمى هذه العملية بعملية التهجين بين الطرق، ويمكننا أيضاً اللجوء إلى عملية تحسين خوارزمية معينة باستخدام تقنيات رياضية تزيد من قدرة هذه الخوارزمية على تحسين أو قد يزيد من قدرتها على البحث ضمن مناطق أوسع أو قد يكون ذلك من خلال جعل الخوارزمية تتجنب الوقوع في فخ الحل المحلي والخروج إلى مساحة بحث أوسع.

تعتمد الخوارزميات المعتمدة على ذكاء السرب في عملها على مرحلتين أساسيتين في البحث عن الحل الأمثل، وهما مرحلة الاستغلال ومرحلة الاستكشاف، إذ تبدأ الخوارزميات عادة باستكشاف مساحة البحث بشكل واسع وعشوائي العملية الاستكشاف، والذي كلما كان عشوائياً وشاملاً كان أداء الخوارزمية أفضل من حيث تغطية أكبر مساحة (Lin and Gen, 2009)،

أما مرحلة الاستغلال فهي مرحلة متابعة مرحلة الاستكشاف إذ إن الخوارزمية بعد أن تبدأ في الاستكشاف تبدأ أيضاً في استغلال المناطق التي تم اكتشافها في مرحلة الاستكشاف حيث المناطق البحثية الواعدة التي تم اكتشافها في مرحلة الاستكشاف يتم استغلالها من خلال إيجاد النقاط المثلى داخل فضاء البحث، لذا فإن مسألة توزيع المهام بين هذين المرحلتين هي مسألة مهمة للغاية إذ إن الخوارزمية تبدأ بمرحلة الاستكشاف أولاً ثم يتناقص الاستكشاف تدريجياً على حساب زيادة عملية الاستغلال وتسمى هذه العملية بالموازنة بين عمليتي الاستغلال والاستكشاف (Al-Betar et al., 2023; Rai et al., 2023).

طوال مرحلة الاستكشاف، يتم البحث في مساحة الحل بشكل شامل وعشوائي. يظهر أن سلوك الخوارزمية يتقارب مع القيمة المثالية داخل المنطقة المكتشفة أثناء مرحلة الاستكشاف وأثناء مرحلة الاستغلال. ويمثل مبدأ التقارب الفعال للمتوسط المتحرك بالتوازن بين المرحلتين.

الخوارزمية التي نحاول أن نعطي فكرة واضحة عنها وعن الخوارزميات المشتقة منها وكذلك النسخ المطورة منها هي خوارزمية المفترس البحري (Faramarzi, MPA, Heidarinejad, Mirjalili, et al., 2020)، وهي خوارزمية من خوارزميات ذكاء السرب والتي تحاكي سلوك المفترسات البحرية في الصيد وتتميز بأنها جمعت بين سلوك الأسماك البحرية المفترسة الكبيرة وسلوك الأسماك الصغيرة التي عادة ما تكون عرضة للافتراس من قبل الأسماك الأكبر منها فهذه الخوارزمية تقترح أسلوب متميز يجلب الأسماك الصغيرة في أوقات معينة أيضاً مفترسات وتقوم بعملية الصيد وهذه الميزة ستؤدي إلى زيادة فرص الحصول على الحل المثلى خلال عملية البحث. حيث تستخدم MPA التوزيعات Levy و Brownian بشكل متكرر مع الالتزام بفكرة التقارب المتوازن. لتقليل احتمالية الوقوع في المستوى الأمثل المحلي والحفاظ على هذا التوازن أثناء تقاربه مع المستوى الأمثل العالمي، يمكن تحسين المناطق البحرية المحمية في عدد من المجالات. ونظراً لأن MPA تستخدم نهجاً قائماً على التكرار، فإن مبدأ التقارب الفعال الخاص بها مضمون.

إن الهدف الرئيس من هذه الورقة هو تسليط الضوء على خوارزمية MPA وذلك لأهميتها وقوة أدائها إذ تم اقتراح هذه الخوارزمية في 2019، ولذلك فأنا سنحاول أن نراجع أكبر عدد من المصادر المتعلقة بهذه الخوارزمية منذ انشائها إلى وقتنا الحالي من حيث التطوير والتحسين الحاصل

للخوارزمية ومن حيث التهجين مع خوارزميات أخرى وأيضا تطبيقات للخوارزمية الأصلية في الهندسة والعلوم وغيرها من التطبيقات ومنشورة في دور نشر متعددة.

2. **خوارزمية الحيوانات المفترسة البحرية (MPA):** في هذا الجزء سيتم عرض الجزء الرياضي لخوارزمية MPA بالشكل الذي يظهر نقاط قوة وضعف هذه الخوارزمية

1-2. **صياغة MPA:** كما هو الحال مع أغلب أساليب metaheuristic فإن MPA خوارزمية تعتمد على المجتمع، حيث يتم توزيع الحل الابتدائي بشكل موحد على مساحة البحث كمجتمع ابتدائي أولي:

$$X_0 = X_{\min} + \text{rand}(X_{\max} - X_{\min}) \quad (1)$$

حيث rand هو متجه عشوائي يتبع التوزيع المنتظم ضمن الفترة من (0,1)، وأن $X_{\max} X_{\min}$ هما الحد الأدنى والأعلى لقيم المتغيرات.

وفقاً لنظرية البقاء للأصلح، فإن الحيوانات المفترسة العليا في العالم الطبيعي هي أكثر موهبة في البحث عن الطعام. ومن ثم، يتم ترشيح الحل الأفضل ليكون أفضل مفترس لبناء مصفوفة تسمى مصفوفة النخبة. ان صفوف هذه المصفوفة تعتمد على البحث والعثور على الفريسة بناءً على المعلومات المتعلقة بمواقع الفريسة.

$$\text{Elite} = \begin{bmatrix} X_{1.1}^I & X_{1.2}^I & \dots & X_{1.d}^I \\ X_{2.1}^I & X_{2.2}^I & \dots & X_{2.d}^I \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ X_{n.1}^I & X_{n.2}^I & \dots & X_{n.d}^I \end{bmatrix}_{n \times d} \quad (2)$$

إذ يمثل X^I متجه المفترس الأفضل، الذي يتم تكراره n من المرات لتكوين مصفوفة النخبة (Elite) وأن d تمثل بعد عدد المتغيرات، بينما n هي حجم المجتمع. تجدر الإشارة إلى أن كلاً من المفترس والفريسة يعتبران من عوامل البحث لأنه في الوقت الذي يبحث فيه المفترس عن فريسته تكون الفريسة تبحث عن طعامها في نهاية كل تكرار، سيتم تحديث مصفوفة النخبة (Elite) إذ يتم تحديثها بالمفترس الأفضل في كل تكرار، هناك مصفوفة أخرى لها نفس أبعاد مصفوفة النخبة (Elite) تسمى مصفوفة (Prey) والتي تقوم الحيوانات المفترسة بتحديث مواقعها بناءً عليها والتي يقوم المفترس الأصلح ببناء النخبة منها وتظهر مصفوفة الفريسة على النحو الآتي:

$$\text{prey} = \begin{bmatrix} X_{1.1} & X_{1.2} & \dots & X_{1.d} \\ X_{2.1} & X_{2.2} & \dots & X_{2.d} \\ X_{3.1} & X_{3.2} & \dots & X_{3.d} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ X_{n.1} & X_{n.2} & \dots & X_{n.d} \end{bmatrix}_{n \times d} \quad (3)$$

في معادلة (3) فإن $X_{i,j}$ يمثل البعد $j - th$ للفريسة $i - th$ وتجدر الإشارة إلى أن عملية التحسين مرتبطة بشكل أساسي بهاتين المصفوفتين.

يتم تقسيم إجراء تحسين MPA إلى ثلاث مراحل رئيسية من التحسين مع الأخذ بنظر الاعتبار نسبة السرعة المختلفة وفي الوقت نفسه محاكاة الحياة الكاملة للمفترس والفريسة في السرعة العالية أو عندما يتحرك الفريسة أسرع من المفترس وفي نسبة وحدة السرعة أو عندما يتحرك كل من الفريسة والمفترس بنفس السرعة وكذلك في السرعة المنخفضة أو عندما يتحرك المفترس بشكل أسرع من الفريسة. لكل مرحلة محددة يتم تحديد هذه الخطوات بناءً على قواعد تحكم طبيعة حركة المفترس والفريسة مع محاكاة حركة المفترس والفريسة في الطبيعة وهذه المراحل الثلاث هي:

المرحلة الأولى: في نسبة السرعة العالية أو عندما يتحرك المفترس أسرع من الفريسة. يحدث هذا السيناريو في التكرارات الأولية للتحسين، إذ يكون الاستكشاف مهماً. في نسبة السرعة العالية $v \geq 10$ فإن أفضل استراتيجية للمفترس هي عدم التحرك على الإطلاق، ويتم تطبيق النموذج الرياضي لهذه القاعدة على النحو الآتي: عندما تكون $t < \left(\frac{1}{3}\right) T$ فإن

$$\begin{aligned} \overrightarrow{\text{step size}}_i &= \overrightarrow{RB} \times (\overrightarrow{\text{Elite}}_i - \overrightarrow{RB} \times \overrightarrow{\text{prey}}_i) \quad i = 1, \dots, n \\ \overrightarrow{\text{prey}}_i &= \overrightarrow{\text{prey}}_i + P \cdot \overrightarrow{R} \times \overrightarrow{\text{step size}}_i \end{aligned} \quad (4)$$

حيث $\overrightarrow{RB}$ متجه يحتوي على أرقام عشوائية تعتمد على التوزيع الطبيعي الذي يمثل الحركة البراونية، تشير العلامة $\times$ إلى عملية ضرب $\overrightarrow{RB}$ في $\overrightarrow{\text{prey}}_i$ والتي تحاكي عملية حركة الفريسة. R هو متجه للأرقام العشوائية تتبع لتوزيع منتظم ضمن الفترة $[0, 1]$ و $P = 0.5$ وهو قيمة ثابتة. يحدث هذا السيناريو خلال الثلث الأول من التكرارات عندما تكون قدرة الاستكشاف عالية بسبب ارتفاع حجم الخطوة أو سرعة الحركة. وإن T هو أعلى عدد من التكرارات مسموح به و t تمثل التكرار الحالي.

المرحلة الثانية: عندما يتحرك المفترس والفريسة بالسرعة نفسه، يحدث هذا الجزء في المرحلة المتوسطة من التحسين، إذ يحاول الاستكشاف أن يتحول مؤقتاً إلى استغلال. يكون للاستكشاف والاستغلال أهمية كبيرة في هذه المرحلة ونتيجة لذلك، تم تخصيص نصف المجتمع للاستكشاف والنصف الآخر للاستغلال. تكون الفريسة مسؤولة عن الاستغلال خلال هذه المرحلة، بينما يكون المفترس هو المسؤول عن الاستكشاف، إذا تحركت الفريسة في ليفي بنسبة وحدة السرعة ($v \approx 1$)، فإن أفضل استراتيجية للمفترس هي البراونية. ولذلك فإن هذه الدراسة تتناول تحركات الفريسة في ليفي وتحركات المفترس في البراونية إذ إن هذه المرحلة كافية سلوك الصيد لدى الفريسة والمفترس معاً. عندما تكون $t > \frac{1}{2}T$ و $t < \frac{2}{3}T$ فإن

النصف الأول للمجتمع

$$\begin{aligned} \overrightarrow{\text{step size}}_i &= \overrightarrow{RL} \times (\overrightarrow{\text{Elite}}_i - \overrightarrow{RL} \times \overrightarrow{\text{Prey}}_i), \quad i = 1, 2, \dots, n/2 \\ \overrightarrow{\text{Prey}}_i &= \overrightarrow{\text{Prey}}_i + P \cdot \overrightarrow{R} \times \overrightarrow{\text{step size}}_i \end{aligned} \quad (5)$$

حيث $\overrightarrow{RL}$ هو متجه للقيم العشوائية التي تمثل حركة ليفي وتعتمد على توزيع ليفي. الذي يمثل حركة ليفي لمحاكاة حركة الفريسة عن طريق الضرب $\overrightarrow{RL}$ في $\overrightarrow{\text{Prey}}$ تتم محاكاة حركة الفريسة إلى موضعها من خلال حجم الخطوة. يساعد هذا الجزء في الاستغلال لأن الخطوات القصيرة تمثل غالبية حجم خطوة توزيع ليفي. أما النصف الثاني للمجتمع

$$\overrightarrow{\text{step size}}_i = \overrightarrow{RB} \times (\overrightarrow{RB} \times \overrightarrow{\text{Elite}}_i - \overrightarrow{\text{Prey}}_i) \quad i = n/2, \dots, n$$

$$\overrightarrow{\text{Prey}}_i = \overrightarrow{\text{Elite}} + P.CF \times \overrightarrow{\text{step size}}_i \quad (6)$$

تعد معلمة سيطرة قابلة للتكيف للسيطرة على حجم الخطوة لحركة المفترس. يحاكي ضرب عناصر مصفوفة النخبة في $\overrightarrow{RB}$ حركة المفترس بطريقة براونية بينما تقوم الفريسة بتحديث موقعها بناءً على حركة الحيوانات المفترسة في الحركة البراونية. الموقف يعتمد على حركة الحيوانات المفترسة في الحركة البراونية.

المرحلة الثالثة: في نسبة السرعة المنخفضة أو عندما يتحرك المفترس بشكل أسرع من الفريسة، هذه المرحلة تعد الأخيرة، والتي ترتبط عادة بقدرة استغلال عالية. في نسبة السرعة المنخفضة ($v = 0.1$) أفضل استراتيجية للمفترس هي ليفي، وتوصف هذه المرحلة كما يأتي: عندما تكون $t > \frac{2}{3}T$

$$\overrightarrow{\text{step size}}_i = \overrightarrow{RL} \times (\overrightarrow{RL} \times \overrightarrow{\text{Elite}}_i - \overrightarrow{\text{Prey}}_i) \quad i = 1, \dots, n$$

$$\overrightarrow{\text{Prey}}_i = \overrightarrow{\text{Elite}}_i + P.CF \times \overrightarrow{\text{step size}}_i \quad (7)$$

يحاكي ضرب $\overrightarrow{RL}$ بعناصر مصفوفة النخبة حركة المفترس في طريقة ليفي. بينما يحاكي إضافة حجم الخطوة إلى موقع النخبة حركة المفترس للمساعدة في تحديث موقع الفريسة [94].

3-4-2. تشكيل الدوامة وتأثير Fish Aggregating Devices (FADs): هناك عامل آخر يؤثر على التحول في سلوك الحيوانات المفترسة البحرية وهو العوامل البيئية، مثل تأثيرات أجهزة تجميع الأسماك (FADs). إن أسماك القرش تقضي ما يقارب 20% من وقتها في مناطق مختلفة للعثور على مناطق واعدة ممكن العثور على أسماك القرش بحيث تقضي 80% من وقتها في مناطق عيش الدلافين (FADs). تعد FADs كل أمثل محلي وهي تؤثر مساحة البحث (Filmlalter et al., 2013). يمكن التعبير عن تأثير FADs رياضياً كالآتي:

$$\overrightarrow{\text{prey}}_i = \begin{cases} \overrightarrow{\text{Prey}}_i + CF \left[\overrightarrow{X}_{\min} + \overrightarrow{R} \times (\overrightarrow{X}_{\max} - \overrightarrow{X}_{\min}) \right] \times \overrightarrow{U} & \text{if } r \leq \text{FADs} \\ \overrightarrow{\text{Prey}}_i + [\text{FADs}(1 - r) + r] (\overrightarrow{\text{Prey}}_{r1} - \overrightarrow{\text{Prey}}_{r2}) & \text{if } r > \text{FADs} \end{cases} \quad (8)$$

$\text{FADs} = 0.2$ هو احتمالية تأثير FADs على عملية التحسين. $\overrightarrow{U}$ هو المتجه الثنائي الذي يحتوي على واحد وصفر. يتم إنشاء ذلك عن طريق إنشاء متجه عشوائي في الفترة $[0,1]$ ، إذا كان كانت القيمة أقل من 0.2، تأخذ قيمة صفر، ويتم تغييره إلى واحد إذا كان أكبر من 0.2 و r عدد عشوائي يتبع التوزيع المنتظم ضمن الفترة $[0,1]$ وأن $\overrightarrow{X}_{\min}$ و $\overrightarrow{X}_{\max}$ متجه يحوي الحدود الدنيا والعليا للمتغيرات، وأن r_1, r_2 هي اعداد عشوائية تم اختيارها من المجموعة $\{1,2, \dots, N\}$. الشكل رقم (1) يبين المخطط العام لخوارزمية MPA وفيما يأتي خطوات الخوارزمية


خطوات خوارزمية MPA:

– تهيئة المجموعة الابتدائية من المواقع للفرائس Prey بشكل عشوائي بحجم N وايضاً أعطاء الحد الاقصى من التكرارات T والبعد dim والحد الاعلى Ub والحد الادنى Lb وقيمة

$$\text{FADs} = 0.2$$


– نضع $t = 1$ كقيمة أولية للتكرارات

- أحسب دالة الهدف (Fitness) لكل صف في مصفوفة Prey
- نجد مصفوفة النخبة Elite
- إذا كان شرط التوقف ($t > T$) غير متحقق
- إذا كان $t < \frac{T}{3}$
- نحدث Prey عن طريق المعادلة (4)
- والا إذا كان $T/3 < t < 2T/3$
- نحدث Prey عن طريق المعادلة (5)
- بالنسبة للنصف الأول من مواقع Prey أي $i = 1, 2, \dots, \frac{n}{2}$
- والا فاننا نحدث Prey عن طريق المعادلة (6)
- بالنسبة للنصف الثاني من مواقع Prey أي $i = \frac{n}{2} + 1, \dots, n$
- والا إذا $t > \frac{2T}{3}$
- نحدث Prey عن طريق المعادلة (7)
- يتم تحديث Prey عن طريق تطبيق تأثير FADs عن طريق المعادلة (8)
- حدث مصفوفة النخبة Elite
- نجد الحل الأفضل
- $t = t + 1$
- نتوقف



شكل (1) المخطط العام لخوارزمية MPA

3. تنوع تحسينات وتطبيقات خوارزمية MPA: إن قوة خوارزمية MPA جعلها من أكثر الخوارزميات دراسة وتحسينا إذ أجريت في الأربع سنوات الأخيرة تحسينات وتطبيقات كثيرة لهذه الخوارزمية وذلك لقدرتها الفائقة في حل الكثير من المسائل الهندسة والواقعية وقد قمنا بحصاء العديد من المصادر التي تخص هذه الخوارزمية وقد تنوعت هذه المصادر من حيث التحسين على الخوارزمية ومن حيث التطبيق والشكل رقم (2) يوضح البحوث التي تخص الخوارزمية موزعة على السنوات، ولكننا في المتن مجموعة متنوعة من المصادر الخاصة بخوارزمية MPA إذ حاولنا أن تكون المصادر متنوعة من التطبيق والتحسين على الخوارزمية وأيضا التنوع في سنوات ودور النشر لكي نغطي



شكل (2): توزيع المصادر حسب السنوات

في عام 2021 تم تقديم خوارزمية جديدة تُسمى خوارزمية تحسين المفترس البحري المحسنة EMPA لتحديد المعلمات غير المعروفة لنماذج الخلايا الكهروضوئية المختلفة، بما في ذلك النماذج الثابتة (ذات الصمام الثنائي الواحد والصمام الثنائي المزدوج) والنموذج الديناميكي. تم دمج عامل التطور التفاضلي (DE) في الخوارزمية الأصلية لتحقيق أداء مستقر عند التعامل مع مشكلة النمذجة الكهروضوئية غير الخطية. أظهرت الدراسة من خلال ثلاث حالات اختبار مختلفة فعالية الخوارزمية المقترحة، حيث تفوقت على الخوارزميات الأخرى مثل MPA و HCLPSO من حيث دقة التنبؤ بالمعلمات وسرعة التقارب والاستقرارية (Abd Elaziz et al., 2021)

أيضا في عام 2021 تم تطوير خوارزمية محسنة تعتمد على خوارزمية المفترس البحري لاستخراج القيم المثلى لمعايير الأنظمة الكهروضوئية. تعالج الخوارزمية المحسنة التحديات الخاصة بتقدير المعلمات للأنظمة الكهروضوئية من خلال استراتيجية تحسين جماعي لتعزيز جودة الحلول. يتم تحسين موقع الحلول ذات الجودة العالية باستخدام عملية طفرة تكيفية، بينما يتم تحديث موقع الحلول ذات الجودة المنخفضة بناءً على موقع أفضل الحلول المحققة وموقع حل جيد مختار من النصف الأول للمجتمع بعد فرز الحلول بترتيب تصاعدي. أظهرت نتائج التجارب المتعددة أداءً متفوقاً للخوارزمية المقترحة مقارنةً بالخوارزميات الحالية على مجموعة من نماذج الأنظمة

الكهروضوئية، مما يؤكد قدرتها العالية على تقديم بديل مفيد لتقدير معلمات نماذج الطاقة الشمسية الكهروضوئية (Abdel-Basset et al., 2021).

تم في 2021 تحسين خوارزمية الاستدلال الحديثة المعروفة باسم خوارزمية المفترس البحري (MPA) باستخدام استراتيجية التعلم المعتمد على المعارض (OBL)، مما أطلق عليها اسم MPA-OBL، لتحسين كفاءة البحث وسرعة التقارب. أجريت مجموعة شاملة من التجارب لتقييم فعالية MPA-OBL وإثبات تأثير دمج استراتيجية OBL مع MPA الأصلية على تحسين جودة الحلول وتسريع سرعة التقارب، فضلاً عن ذلك، تم إجراء تجارب باستخدام دالتين موضوعيتين (Kapur و Otsu) على مجموعة متنوعة من الصور المعيارية، مع تحليل النتائج باستخدام مقاييس تقييم شائعة مثل نسبة الإشارة إلى الضوضاء (PSNR)، التشابه الهيكلي (SSIM)، ومؤشرات التشابه المميزات (FSIM)، والتي أظهرت أن MPA-OBL يحقق نتائج فعالة وموثوقة مقارنة بالخوارزميات الأخرى (Houssein et al., 2021).

كذلك في 2021 تم تقديم تحسين لخوارزمية المفترس البحري (MPA) من خلال إدخال نسخة محسنة تستخدم مشغل الهروب المحلي (LEO) Local Escaping Operator تعاني MPA من مشكلة التقارب المبكر بسبب عدم التوازن بين قدرات الاستكشاف والاستغلال، إذ يتم استبدال الحلول في الخوارزمية الحالية بحلول أفضل من التكرارات السابقة، مما يشير إلى ضعف الترابط بين الحلول والقبول المحتمل لحلول جديدة دون التأثير على عملية التحسين. في النهج المقترح، يتم استبدال أسوأ الحلول بحلول يتم إنشاؤها بواسطة LEO، الذي يعتمد على الحلول التمثيلية ويأخذ في حده العلاقة بين المفترسات وخصائصها (Oszust, 2021).

في عام 2022 تم اقتراح نهج هجين لتحديد العتبة المثلى لتجزئة الصور متعددة المستويات باستخدام خوارزمية المفترس البحري (MPA) وخوارزمية سرب السِّلْب (SSA)، والمعروفة باسم MPASSA. في السنوات الأخيرة، تم اختيار العتبة المثلى لتجزئة الصور بناءً على تقييمات مكثفة، إذ يتم استخدام طرق مثل Kapur و Otsu التي تتعامل بشكل جيد مع العتبات الأحادية أو الثنائية، ولكنها تواجه صعوبات عندما تمتد إلى مستويات متعددة، مثل زيادة الوقت المستغرق وتكلفة الحساب المرتفعة. تمثل الحلول الناتجة عن الطريقة المقترحة باستخدام تدرج الصورة، وتم تقييم فعالية طريقة التجزئة المقترحة باستخدام مقاييس تقييم معيارية متعددة مثل وظيفة اللياقة، الوقت المستغرق، نسبة الإشارة إلى الضوضاء (PSNR)، ومؤشر التشابه الهيكلي (Abualigah et al., 2022).

قدم مجموعة من الباحثين في 2022 أداة فعالة للتنبؤ بالطاقة الريحية باستخدام مجموعات بيانات السلاسل الزمنية من خلال تطوير نسخة محسنة من نظام الاستدلال العصبي الضبابي التكيفي (ANFIS) باستخدام خوارزميات تحسين ميتاهيرستية (MH). يتم تقديم نسخة جديدة من خوارزمية المفترس البحري (MPA) تُسمى MPAmu، والتي تستخدم عوامل طفرة إضافية لتعزيز قدرة MPA ومنع تقاربها المبكر إلى الحلول المحلية. تُستخدم MPAmu لتحسين معلمات ANFIS وتعزيز عملية تكوينه. تم تقييم نموذج MPAmu-ANFIS باستخدام مجموعات بيانات معروفة من توريينات الرياح في فرنسا، وتمت مقارنة النموذج المطور مع ANFIS التقليدي ونماذج ANFIS المعدلة الأخرى باستخدام خوارزميات MH مختلفة، فضلاً عن نماذج التنبؤ بالسلاسل الزمنية الأخرى مثل آلة الدعم الشعاعي (SVM)، الشبكة العصبية الأمامية، وذاكرة طويلة وقصيرة الأجل (Al-qaness et al., 2022).

أيضا في عام 2022 تم اقتراح طريقة مطورة تُدعى MPAO تعتمد على خوارزمية المفترس البحري (MPA) واستراتيجية الاستكشاف الضيق من خوارزمية النسر (AO) لمعالجة مشكلة اختيار الميزات (FS) ، والتحسين العالمي، والمشكلات الهندسية. تعزز هذه التعديلات سلوك الاستكشاف في MPA لتحديث واستكشاف مساحة البحث بشكل أفضل. تزيد استراتيجية الاستكشاف الضيق من AO من قدرة البحث لـ MPA ، مما يحسن قدرتها على الحصول على نتائج مثلى أو قريبة من المثلى ويساعد في التغلب على مشكلات الحلول المحلية في نطاق المشكلة.

في العام 2022 قدمت خوارزمية مُعدلة للمفترس البحري تُدعى MMMPA ، والتي تهدف إلى تحسين أداء التحسين لخوارزمية المفترس البحري (MPA). تتضمن التعديلات المقترحة آلية التعلم المعتمد على المعارضة اللوجستية (LOBL) لتعزيز تنوع السكان وتوليد حلول أكثر دقة، فضلا عن طرق التحديث الذاتي الفعالة مثل قاعدة تحديث المواقع الجديدة، ومعامل الوزن القصورى، واستراتيجية التحكم في حجم الخطوة غير الخطية. تم اختبار صحة MMMPA على 23 دالة معيارية كلاسيكية، ووظائف CEC 2020، وأربع مشكلات واقعية، وكذلك باستخدام وظائف معيارية ذات أبعاد عالية (100، 1000، و2000). أظهرت النتائج التجريبية والاختبارات الإحصائية المختلفة أن MMMPA تقدم أداءً متفوقاً وتتنافس بشكل جيد مع العديد من الخوارزميات المتقدمة من حيث الدقة، وسرعة التقارب، والثبات (Fan et al., 2022).

نسخة معدلة في عام 2022 من خوارزمية المفترس البحري تم تقديمها تُدعى MMMPA، وتُطبق لحل مشكلات التوزيع الاقتصادي والانبعاثات المجمعة (CEED) ذات الأهداف الأحادية والمتعددة. تهدف MMMPA إلى تحسين أداء خوارزمية المفترس البحري التقليدية من خلال إدراج نهج تعلم شامل لمشاركة أفضل التجارب بين الأفراد لتجنب التقارب المبكر. تزيد MMMPA من فعالية السكان للوصول إلى الحلول الأمثل في حالات الدوال الأحادية والمتعددة الأهداف. تم تقييم صحة MMMPA رياضياً على 28 دالة معيارية ذات أبعاد 50 من CEC2017 ، تمت مقارنة النتائج التي حققتها MMMPA مع تلك التي حصلت عليها الخوارزمية الأصلية MPA وطرق التحسين الحديثة الأخرى. بالنسبة لمشكلة الأهداف الثنائية (Hassan et al., 2022).

ركز مجموعة من الباحثين في 2022 أيضا على أحدث خوارزمية استدلالية تُدعى خوارزمية المفترس البحري (MPA) في مجال الطاقة، ويستعرض استخدام مزيج من التعلم التعزيزي (RL) مع MPA لتطوير طريقة جديدة تُدعى Deep-MPA ، حيث تُطبق مبادئ RL لتعديل وتعزيز البحث العالمي في MPA. يتم تنظيم نسبة الاستكشاف/الاستغلال من خلال تغيير حجم الخطوة، مما يؤثر على كفاءة MPA. بدلاً من تحديث قيمة المعامل لجميع العوامل بنفس الطريقة، تُستخدم مبادئ RL لتحديثه بناءً على حالة الفرد الحالي. فضلا عن ذلك، لتصميم نظام ميكروغريد للطاقة المتجددة الهجينة، بما في ذلك الألواح الشمسية، نظام توربينات الرياح، مولد ديزل، وأنظمة تخزين البطاريات (Houssein et al., 2022).

في عام 2022 أيضا تم اقتراح تحسين لخوارزمية MPA يُطلق عليه اسم NMMPA، والذي يتضمن استراتيجية التعلم المعتمد على الجوار واستراتيجية حجم السكان المتكيف. تم التحقق من تفوق NMMPA من خلال مقارنته مع MPA الأصلية، ونسخ MPA المحسنة الأخرى، وخوارزميات التحسين المستوحاة من الطبيعة على مجموعات الاختبار الشهيرة CEC 2017 و CEC 2020، فضلا عن ثلاث مشكلات تصميم هندسي. علاوة على ذلك، تُظهر عملية تحسين

نموذج السطح القابل للتطوير تقديرًا للدرجة القصوى للتطوير باستخدام NMPA. أظهرت النتائج التجريبية أن NMPA يتفوق على الخوارزميات الأخرى من حيث الدقة، وسرعة التقارب، وجودة الحلول. بشكل عام، تعتبر NMPA خوارزمية استدلالية تنافسية وممتازة لتصميم الأسطح القابلة للتطوير وحل مشكلات التحسين الهندسي (Hu et al., 2022).

عام 2022 تم تقديم تحسين يُسمى خوارزمية المفترس البحري المعتمدة على آلية الثقافة التعاونية (CECMPA) من خلال هذه الآلية، يمكن للعوامل البحثية في فضاءات مختلفة تبادل المعرفة والخبرة لتحسين أداء الخوارزمية الأصلية. على وجه التحديد، تتمتع CECMPA بفرصة أعلى لتجنب الأمثل المحلي ويمكنها البحث عن الأمثل العالمي بسرعة. يُستخدم هذا البحث لأول مرة CECMPA لتنفيذ اختيار مجموعة الميزات وتحسين المعلمات الفائقة في آلة الدعم الشعاعي (SVM) في الوقت نفسه. (Jia et al., 2022).

اقترح في عام 2022 تعديل لخوارزمية تحسين متعددة الأهداف مُحسَّنة تُعرف بخوارزمية المفترس البحري متعددة الأهداف (MOEMPA) للتعامل مع ثلاث وظائف هدف: تقليل تكلفة التشغيل والانبعاثات مع زيادة عامل الطاقة المتجددة لاستخدام أمثل لموارد الطاقة. تُستخدم MOEMPA لإدارة توزيع الطاقة في ميكروغريد مترابط مع الشبكة العامة. يتكون الميكروغريد من مصادر طاقة متجددة مثل الطاقة الشمسية وطاقة الرياح، مولد ديزل للأحمال الطارئة. تم مقارنة نتائج MOEMPA مع خوارزميات تحسين متعددة الأهداف الحديثة. MOEMP فضلًا عن ذلك، (Yousri et al., 2022).

قام الباحثون في عام 2023 بتقديم تحسينات جديدة على خوارزمية الصيادين البحرية (MPA). تم إدخال استراتيجيتين رئيسيتين لتحسين أداء الخوارزمية: الأولى هي الاستراتيجية المبنية على الجوار الأمثل (TNS) التي تهدف إلى تقليل المشكلات المرتبطة بالتحجيم المحلي والتغلب على التلاشي المبكر، والثانية هي استخدام مجال البحث غير المتماثل مع التعلم الديناميكي المعتمد على الخيارات لتحسين قدرة الاستغلال وزيادة احتمال الوصول إلى الحلول الأمثل العالمية. تم تقييم الخوارزمية المحسَّنة، المسماة "خوارزمية الصيادين البحرية مع معارضة ديناميكية وجوار تايلور" (DOTMPA)، ضد خوارزميات الحديثة الأخرى باستخدام مجموعات الاختبار CEC2017 و CEC2019 و CEC2022، وأثبتت التجارب تفوق DOTMPA من حيث دقة التقارب والثبات، مما يجعلها طريقة واحدة ومنافسة قوية لمشاكل التحسين في التطبيقات العملية (Bakır, 2024).

في عام 2023 أيضًا قدمت دراسة خوارزمية جديدة لتحسين جودة صور الرنين المغناطيسي للدماغ (MRI). تشمل الطريقة المقترحة استخدام خوارزميات تعزيز الصورة مثل توازن الهيستوجرام التكيفي المحدود بالتباين (CLAHE)، وإزالة الضوضاء باستخدام الشبكة العصبية التلافيفية (DN-CNN)، والكشف عن الحواف باستخدام لابلاسيان (LED). بعد ذلك، نستخدم خوارزمية المفترسات البحرية (MPA) لإيجاد المعلمات التكيفية المثلى لتكوين الصورة المحسَّنة النهائية. تُظهر التجارب أن الصور الناتجة عن النموذج المقترح تتفوق على بعض الطرق الحديثة لتحسين الصورة، كما يحسن النموذج أداء خوارزميات دمج الصور (Dinh, 2023).

في العام نفسه 2023 تم تقديم نسخة محسنة من خوارزمية المفترسات البحرية (MPA)، تُدعى MMPA-TLBO، لحل مشكلة اختيار المعاملات في MPA والتي يمكن أن تؤدي إلى أداء ضعيف في الاستغلال والاستكشاف. تتضمن النسخة المحسنة استخدام خريطة شديدة الفوضى

واستراتيجية التعلم المعاكس في مرحلة التهيئة لتوليد أفراد عالية الجودة، فضلاً عن إدخال طريقة تحسين قائمة على التعليم والتعلم بدون معلومات لتحقيق توازن فعال بين الاستغلال والاستكشاف. أظهرت التجارب الواسعة أن MPPA-TLBO يتفوق على الخوارزميات الأخرى في حل مشاكل معيارية وفي تصميم المشكلات الهندسية، كما يتفوق على المتغيرات الأخرى خاصة في تتبع الحركة المفاجئة (Gao et al., 2023).

أيضاً في عام 2023 تم اقتراح خوارزمية هجينة لتحسين جزيئات السرب (HMPPSO) من خلال دمج استراتيجية البحث متعددة المراحل من خوارزمية المفترسات البحرية (MPA). تم تقسيم عملية البحث على ثلاث مراحل: المرحلة الأولى تستخدم حركة براونية للاستكشاف؛ في المرحلة الوسطى، يتم تقسيم السكان إلى جزئين، إذ يقوم النصف الأول بالاستكشاف من خلال الحركة البراونية، بينما يتبنى النصف الآخر استراتيجية التجول العشوائي لضبط تحديث الجزيئات ومنع الوقوع في الحلول المحلية المثلى. في المرحلة الأخيرة، يتم تحسين استراتيجية التعلم باستخدام معلومات تحكم لضبط الاستراتيجية وجعل طريقة التعلم الفردية وطريقة الت averaging تتناوب. يتم تعزيز تنوع السكان من خلال استخدام التهيئة الفوضوية واستراتيجيات التعلم المعاكس. تظهر النتائج أن أداء HMPPSO يتفوق بشكل كبير على خوارزميات أخرى عند تطبيقها على وظائف اختبار CEC2017 وأربعة مشاكل تصميم هيكلية غير خطية متعددة الأبعاد (Han et al., 2023).

في عام 2023 أيضاً تم تقديم نسخة متعددة الأهداف من خوارزمية المفترسات البحرية (MPA) تُعرف بخوارزمية المفترسات البحرية المحسنة متعددة الأهداف (MOIMPA)، والتي تدمج مفاهيم من نظرية الكم. باستخدام نظرية الكم، تهدف MOIMPA إلى تعزيز قدرة MPA على التوازن بين الاستكشاف والاستغلال والعثور على الحلول المثلى. تستخدم الخوارزمية مفهوماً مستوحى من دالة الموجة لشرويدنجر لتحديد موقع الجزيئات في فضاء البحث، مما يحسن كلاً من الاستكشاف والاستغلال ويؤدي إلى تحسين الأداء. فضلاً عن ذلك، تدمج MOIMPA آلية هيمنة باريتو، إذ يتم تخزين الحلول غير المهيمنة في مستودع وتوظيف استراتيجية العجلة الروليت لاختيار الحلول من المستودع مع مراعاة التغطية (Hassan et al., 2023).

تم في عام 2023 تحسين النموذج باستخدام EMPA لعدة تكرارات للحصول على تغطية الشبكة القصوى المحسنة ومخطط نشر العقد الأمثل المقابل. بناءً على MPA القياسية، يتم أولاً إدخال خريطة الشوشة Tent لتهيئة السكان للحفاظ على تنوع السكان في الخوارزمية؛ ثانياً، يتم إدخال عامل القفز التكيفي في مرحلة القفز لتحسين قدرة الخوارزمية على الخروج من الحد الأدنى المحلي؛ أخيراً، يتم إدخال استراتيجية تحديث الموقع المزدوج قبل نهاية كل تكرار من الخوارزمية، مما يمكن أن يوازن بشكل أفضل بين البحث المحلي والعالمي ويعزز قدرة الخوارزمية على البحث الأمثل. يتم مقارنة الخوارزمية بأربع دوال اختبار أحادية ومتعددة الأشكال وتطبيقها على ثلاثة سيناريوهات لتحسين تغطية الشبكة في أنظمة الاستشعار الحضرية. تُظهر النتائج أن خوارزمية EMPA يمكن أن تحسن بشكل فعال توزيع العقد بالتساوي، وتعزز تغطية الشبكة المتوسطة، وتوفر مستوى معيناً من تكاليف نشر العقد لأنظمة الاستشعار الحضرية (Jin et al., 2024).

في عام 2023 تم إدخال خوارزمية المفترسات البحرية المحسنة (EMPA)، المعروفة بدقتها وسرعتها الفائقة في التقارب، لتحسين المعلومات العشوائية لنموذج SVM. وأخيراً، تم بناء طريقة تعتمد على نموذج EMPA-SVM المحسن للتنبؤ بخسائر الطاقة في تبديل IGBT. تم التحقق

من صحة النهج المقترح باستخدام بيانات اختبار الخصائص الديناميكية، وأظهرت النتائج أن النموذج التنبؤي حقق قيمة R^2 تتجاوز 99.8% لخسائر التبديل. فصلا عن ذلك، تفوقت مقاييس الخطأ المطلق المتوسط والجذر التربيعي للخطأ لنموذج EMPA-SVM على النماذج الأخرى. ومن ثم، تُظهر نتائج البحث بوضوح الفوائد الكبيرة لتقدير خسائر تبديل IGBT بدقة في تعزيز أداء الجهاز (Liu et al., 2024).

في عام 2023 أيضاً تم اقتراح تحسين متعدد المراحل لخوارزمية المفترسات البحرية (MSMPA) في هذه الورقة. تحتفظ الخوارزمية بميزة البحث متعدد المراحل وتقدم استراتيجية الطيران الخطي في المرحلة الوسطى لتعزيز التفاعل بين المفترسات. يُطلب من المفترسات البعيدة عن المثلى التاريخية التحرك، مما يزيد من قدرة الاستكشاف للخوارزمية. في المرحلتين الوسطى والمتأخرة، يتم إدخال آلية البحث الخاصة بخوارزمية سرب الجسيمات (PSO)، والتي تعزز قدرة الاستغلال للخوارزمية. هذا يعني تقليل العشوائية، إذ يتم قمع فعال للمنطقة المثلى التي يخرج منها المفترسون. تم تطبيق الخوارزمية على أنواع مختلفة من وظائف اختبار CEC2017 ومشاكل تصميم هيكل غير خطي متعددة الأبعاد، وتمت مقارنتها مع خوارزميات حديثة أخرى. تظهر النتائج أن سرعة التقارب ودقة MSMPA أفضل بكثير من تلك الموجودة في خوارزميات المقارنة (Qin & Han, 2023).

في عام 2023 كذلك تم اقتراح نسخة محسنة من خوارزمية المفترسات البحرية متعددة الأهداف (IMOMPA) لحل MODEGD مع مراعاة المركبات الكهربائية القابلة للتوصيل. تحسن خوارزمية IMOMPA على خوارزمية المفترسات البحرية متعددة الأهداف الحالية بثلاث طرق رئيسية. أولاً، تم تعزيز تنوع السكان الأوليين باستخدام التعلم المعارض المدمج مع التشفير الفوضوي. ثانياً، تم تقديم عامل تقارب غير خطي لتسريع عملية التقارب. أخيراً، تم دمج آلية البحث الحلزوني من خوارزمية تحسين الحيتان (WOA) لتحسين القدرة على البحث العالمي للخوارزمية. من خلال اختبار أداء IMOMPA على وظائف اختبار متعددة الأهداف من نوع ZDT و DTLZ، تظهر IMOMPA قدرة بحث محلية قوية، وموثوقية أفضل، وسرعة تقارب ودقة تقارب أفضل. علاوة على ذلك، يمكن أن يخفف توصيل المركبات الكهربائية القابلة للتوصيل (PEVs) إلى الشبكة (V2G) من تذبذبات الشبكة ويوازن بين فترات الطلب القصوى (Yang et al., 2023).

كذلك في العام نفسه 2023 تم تقديم خوارزمية مفترسات البحر المحسنة (EMPA) المبنية على مشغل الطفرة المعتمد على التصنيف لتدريب الشبكات العصبية الأمامية (FNNS). الهدف من هذه الخوارزمية هو تحقيق أقل أخطاء تصنيف وتنبؤ وتقريب عن طريق تعديل أوزان الاتصال وقيم الانحراف. يوفر مشغل الطفرة المعتمد على التصنيف القدرة على تحديد أفضل وكيل بحث، مما يعزز القدرة على الاستغلال، كما يؤخر التلاشي المبكر ويعزز سرعة عملية التحسين. يدمج EMPA بين الاستكشاف والاستغلال لتقليل ركود البحث، ويتميز بالاستقرار والمرونة الكافية للحصول على أفضل حل تتميز EMPA بسرعة تقارب عالية واستقرار وقوة تحمل قوية (J. Zhang & Xu, 2023).

في عام 2024 تم تقديم طريقة جديدة لتوقع انبعاثات ثاني أكسيد الكربون (CO_2) من مصادر الفحم، تُقدّم الطريقة المعتمدة على التجميع الكسري المتوافق (WCFA)، والتي تُعدّ شكلاً موسّعاً للطرق السابقة للتجميع المعتمد على الأوزان والتجميع الكسري المتوافق. يتم إدخال نموذج التدرج الرمادي المتعدد المتغيرات غير الخطي لبرنولي لتشكيل التسلسلات التي تمت معالجتها بواسطة

WCFA. ثم يتم تحسين خوارزمية مفترسات البحر (IMPA) بإدخال خريطة الخيمة ومعامل التحكم الكوني. يتم التحقق من أداء IMPA من خلال تجارب مقارنة بين الخوارزميات واختبار فريدمان. وثبتت دراسات الحالة الثلاثة فعالية النموذج في التنبؤ، حيث تصل أخطاء التوفيق والتنبؤ إلى 1.1773% و 0.5402% على التوالي (Cang et al., 2024).

اقترحت في 2024 هذه الدراسة خوارزمية مفترسات البحر المحسنة (IMPA) من خلال تقديم استراتيجية تعديل الوزن التكيفية وآلية التعلم الاجتماعي الديناميكية، تحسن الدراسة بشكل كبير من تردد وكفاءة اللقاءات بين المفترسات والفريسة في النظم البيئية البحرية. تم تقييم أداء IMPA من خلال دوال المعايير، ومشكلات مجموعة CEC2021، ومشكلات تصميم الهندسة مثل تصميم الشعاع الملحوم، وتصميم الزنبرك الشد/الضغط، وتصميم الوعاء الضغط، وتصميم الثلاثي القضبان. تظهر النتائج أن IMPA حققت نجاحاً ملحوظاً في عملية التحسين مقارنةً بالطرق الأخرى، حيث أظهرت أداءً ممتازاً في حل حلول المعلمات المثلى وتحسين قيم الدوال الموضوعية. كما يظهر IMPA أداءً جيداً من حيث الدقة والموثوقية، مما يثبت كفاءته في حل مشكلات تصميم الهندسة الصناعية المعقدة بنجاح (Chun et al., 2024).

قدمت في 2024 خوارزمية تحسين الكفاءة في الجدولة تسمى خوارزمية مفترسات البحر المحسنة (EMPA). أولاً، تم بناء نموذج جدولة المهام مع زمن التنفيذ واستخدام الموارد. ثانياً، كل فرد يمثل نتيجة من نتائج جدولة المهام، والهدف من الخوارزميات هو العثور على النتيجة المثلى للجدولة، وبالتالي يتم إدخال مشغل WOA، ومعامل الوزن العطالي غير الخطي، واستراتيجية الجيب الذهبي إلى خوارزمية مفترسات البحر. في تجربة المحاكاة، يتم مقارنة EMPA مع خوارزمية الذئب الرمادي (GWO)، خوارزمية الجيب الكوني (SCA)، خوارزمية سرب الجسيمات (PSO)، وخوارزمية تحسين الحوت (WOA) تحت أعداد مختلفة من المهام في مجموعات بيانات صناعية ومجموعات بيانات GoCJ. تظهر النتائج التجريبية أن خوارزمية EMPA تتمتع بميزات أكبر من حيث زمن التنفيذ، درجة عدم التوازن، واستخدام الموارد (Gong et al., 2024).

اقترحت في عام 2024 دراسة لخوارزمية مفترسات البحر المحسنة (IMPA) مع وحدة الذاكرة التكرارية ثنائية الاتجاه (BiGRU) للتنبؤ بسُمك خروج الشريط. أولاً، تم إدخال عامل وزن تكيفي إلى خوارزمية مفترسات البحر (MPA) للتغلب على عيوب سرعة التلاشي المبكر المحدودة ونطاق البحث الضيق، مما يعالج مشكلة التحسين المحلي. ثانياً، تم تطوير استراتيجية لياقة متوسط لتحسين جودة مجموعة خوارزمية، تحسين دقة التحسين، وتعزيز استقرار الخوارزمية. فضلاً عن ذلك، تم استخدام IMPA لتحسين المعلمات، مما يقلل من تأثير المعلمات الفائقة مثل عدد خلايا الطبقة المخفية، معدل التعلم، وحجم الدفعة على دقة التنبؤ لـ BiGRU، مما أدى إلى إنشاء نموذج-IMPA. BiGRU تم إجراء التجارب على مجموعة بيانات عملية التدحرج الفعلي. أظهرت النتائج التجريبية أن IMPA تفوقت على خوارزمية MPA التقليدية، خوارزمية سرب الجسيمات (PSO)، خوارزمية الذئب الرمادي (GWO)، خوارزمية تحسين الحوت (WOA)، والأشكال الحديثة من MPA. كما أظهر نموذج IMPA-BiGRU قدرات تنبؤية ممتازة لسُمك خروج الشريط، مما يلبي متطلبات الإنتاج العملية للمنتجات المدرفلة عالية الجودة (Luo et al., 2024).

في عام 2024 أيضاً قدمت خوارزمية تحسين Metaheuristic جديدة تُسمى خوارزمية مفترسات البحر المعارضة القائمة على الموجات التجميعية (CWOMPA) لمعالجة بعض القيود

الموجودة في خوارزمية مفترسات البحر (MPA) المعروفة. تتضمن CWOMPA ثلاث استراتيجيات رئيسية: نهج التجميع الضبابي للهروب من الحلول المحلية المثلى، استخدام تعديل معامل التأثير القائم على دالة الموجة لتجنب التحلل المبكر، وأخيراً استراتيجية تعلم المعارض التكيفية للحفاظ على تنوع السكان. مقارنة ببعض خوارزميات التحسين الميتا-هيوريستية الحديثة، تؤكد التقييمات الواسعة أن CWOMPA تحقق أفضل رتبة فريدمان، 4.30 و 1.95 على التوالي، على 23 دالة اختبار ومجموعة اختبار CEC 2017. لا تقتصر فعالية CWOMPA على ستة مشاكل مقيدة من معايير CEC 2020 الحقيقية، ولكن أيضاً عند تطبيقها على 14 مجموعة بيانات طبية، تحقق CWOMPA تصنيفات فريدمان متفوقة من حيث الميزات المحددة، دقة التصنيف، مقياس-F، وقيمة الدالة الهدف، 2.5، 2.25، 2.96، 2.93 على التوالي، متفوقة على الطرق الشائعة الأخرى. أخيراً، تظهر CWOMPA أعلى دقة تصنيف عبر جميع مجموعات البيانات وأفضل أداء لمقياس-F. في تسع مجموعات بيانات مقارنة بالخوارزميات التقليدية لاختيار الميزات. (Rezaei & Fard, 2024). اقترحت في عام 2024 تقنية تحسين مفترسات البحر المحسنة (IMPT) كنهج منهجي لتوضيح الخصائص غير المعروفة لبطاريات LiBs. تمثل هذه التقنية تقدماً جديداً في المجال، وتهدف إلى تقديم وسيلة أكثر فعالية لتحديد المعلمات لهذه الأجهزة التخزينية للطاقة المعقدة. تدعم تقنية IMPT تكتيكات المفترس. تم التحقق من دالة الهدف وخطأ الانحراف المعياري على نموذج ديناميكي للـ LiB بواسطة IMPT المطورة. تم مقارنة نتائجها أيضاً مع عدة مُحسِّنات جديدة. تُظهر التجارب على بطاريات Kokam بقدرة 40 Ah ونمط القيادة ARTEMIS إلى جانب الدراسات المحاكاة، كيف أن IMPT المقترحة فعالة كطريقة تعريف. علاوة على ذلك، تُظهر IMPT المقترحة دقة كبيرة مقارنةً بأساليب التحسين الحالية لبطاريات Kokam ونمط القيادة ARTEMIS. (Shaheen et al., 2024) كذلك في 2024 قدمت دراسة لتعزيز كفاءة الطاقة بشكل شامل واستكشاف إمكانيات النظام الطاقى المتكامل في الحفاظ على الطاقة وتقليل الانبعاثات من خلال اقتراح حلول مبتكرة. تم تقديم استراتيجيات محسنة لتحميل التدفئة وتحميل الطاقة، مع الأخذ في الاعتبار قدرة نقل الطاقة لنظام التخزين. علاوة على ذلك، تم اقتراح استراتيجية هجينة تتيح التبديل المرن بين هاتين الاستراتيجيتين. بعد ذلك، تم اقتراح مُحسِّن مفترس البحر المحسن لحل النموذج، مما يعزز بشكل كبير كفاءة الحل وقدرته على تجاوز النقاط المحلية المثلى. تشير النتائج إلى تحسين شامل في أداء النظام تحت الاستراتيجيات المقترحة مقارنةً بالطرق التقليدية. تسهم هذه الدراسة في تقليل تكاليف تشغيل النظام، واستهلاك الطاقة، وانبعاثات الكربون، مما يبرز دورها الكبير في تعزيز تكامل الطاقة المتجددة، وتعزيز الاقتصاد الأخضر (Yuwei et al., 2024).

اقترحت في 2024 خوارزمية مفترس البحر المحسن (IMPA) لاستخراج نقطة أقصى قدرة في نظم الطاقة الشمسية تحت ظروف الإشعاع الشمسي المعقدة. تم تحسين خوارزمية مفترس البحر التقليدية (MPA) من خلال إدخال استراتيجية التعلم المعاكس (OBL) ودمج خوارزمية جيب التمام والجيب (SCA) لتعزيز قدرة البحث. فضلاً عن ذلك، تم استبدال المحول من الدرجة المنخفضة في نظم التحكم التقليدية (MPPT) بمحول زيتا لزيادة مدى الجهد التشغيلي. تُظهر نتائج المحاكاة أن MPPT المعتمد على IMPA يتمتع بكفاءة تتبع أعلى وزمن استجابة أقصر، كما تؤكد النتائج التجريبية جدواه العملية ومستوى عالٍ من الاستقرار والمتانة (H. Zhang et al., 2024).

قام الباحث بتطوير خوارزمية محسنة تسمى خوارزمية المفترس البحري المحسنة (IMPA) لمعالجة التحديات التي تواجه خوارزمية المفترس البحري (MPA)، مثل الوقوع في الحلول المحلية ونقص التنوع. أثبتت نتائج الدراسة أن الخوارزمية المحسنة تفوقت بشكل كبير في تحقيق دقة أعلى وقدرة أفضل على التحمل مقارنة بالأساليب الأخرى (Chun et al., 2024).

4. **تقييم MPA على دوال IEEE CEC2021**: لتقييم أداء خوارزمية MPA بدقة، أجرينا تقييماً شاملاً باستخدام دوال IEEE CEC2021 المعيارية. يهدف هذا التقييم إلى مقارنة MPA بالعديد من خوارزميات التحسين الحديثة، بما في ذلك (Ahmadianfar et al., 2021) EGBO و SMA (Li et al., 2020) و PSO (Kennedy & Eberhart, 1995) و EO (Faramarzi, 2020) و CL-PSO (Liang et al., 2006) و Heidarinejad, Stephens, et al., 2020 و HPSO_TVAC (Chung et al., 2014). تم إجراء التجارب باستخدام Python على نظام مجهز بمعالج Intel Core i7-13700H و 16 GB من ذاكرة الوصول العشوائي RAM. لضمان نتائج قوية، أجرينا 30 عملية تشغيل مستقلة لكل خوارزمية، مع كل تشغيل يتكون من 2500 تكرار. يتم تفصيل تكوينات المعلمات لجميع الخوارزميات في الملحق 1، مما يضمن مقارنة عادلة ومنصفة.

1-4. **مقاييس الأداء**: استخدمنا ثلاثة مقاييس أساسية لتقييم أداء كل خوارزمية وهي المتوسط (AVG): لتقييم الأداء العام عبر عمليات تشغيل متعددة والانحراف المعياري (STD): لقياس اتساق واستقرار الخوارزميات والوسيط (Med): لتوفير مقياس قوي للاتجاه المركزي، أقل تأثراً بالقيم المتطرفة

4-2. **النتائج والمناقشة**: يتم عرض النتائج التفصيلية لمقارنتنا بين MPA ومنافسيها في الجدول رقم 2. يتضمن هذا الملحق بيانات شاملة عن مقاييس الأداء (AVG و STD و Median) لكل خوارزمية عبر دوال معيار IEEE CEC2021. فضلاً عن ذلك، ويقدم رؤى حول الأداء النسبي لكل خوارزمية عبر جميع الدوال القياس. يقارن MPA بكل من الخوارزميات الحديثة الأساسية والمتقدمة في مجموعة معايير IEEE CEC2021. توفر هذه المقارنة الزوجية عرضاً تفصيلياً لكيفية أداء MPA بالنسبة لكل خوارزمية منافسة.

يكشف التحليل المقارن للخوارزمية المقترحة (MPA)، كما هو موضح في الجدول رقم 2، مقابل سبع خوارزميات تحسين أخرى عبر عشر دوال معيارية عن أدائها المتفوق. توضح المقارنة أن خوارزمية المفترسات البحرية الأصلية (MPA) تكون في مركز متقدم مقارنة بالخوارزميات المتقدمة الأخرى مثل EGBO و SMA و CL-PSO عبر معظم الدوال. اتساق الخوارزمية واستقرارها ملحوظان، مع انحرافات معيارية أقل بشكل عام مقارنة بالخوارزميات الأخرى. يشير هذا إلى قدرة MPA على توفير حلول أكثر موثوقية عبر عمليات تشغيل متعددة. يظهر أدائها القوي عبر أنواع الدوال المختلفة، بما في ذلك الدوال أحادية الوسائط ومتعددة الوسائط. القيم المتوسطة ل MPA منخفضة باستمرار وغالباً ما تكون قريبة من متوسط القيم، مما يشير إلى أن أدائها لا ينحرف بسبب القيم المتطرفة. بينما تتفوق MPA في الدالة F4 بينما تتفوق GBO في معظم الدوال. بشكل عام، تدعم هذه النتائج بقوة فعالية خوارزمية MPA في حل مشاكل التحسين المعقدة، مما يجعلها نهجاً واعداً في مجال التحسين metaheuristic.

function	Criter	GBO	EGBO	SMA	PSO	EO	MPA	CLPSO	HPSO_TVAC
F1	Avg	9.217E+02	1.499E+02	7.679E+03	2.137E+03	4.280E+07	5.679E+03	6.292E+06	1.754E+04
	Std	1.415E+03	2.704E+02	3.384E+03	2.187E+03	1.346E+08	3.952E+03	2.358E+07	6.309E+04
	Med	4.134E+02	1.000E+02	8.933E+03	1.453E+03	4.233E+03	6.683E+03	7.389E+04	2.327E+03
F2	Avg	1.122E+03	1.398E+09	9.045E+05	2.590E+05	6.700E+09	6.796E+05	2.040E+08	1.575E+08
	Std	6.650E+01	7.657E+09	7.804E+05	3.880E+05	1.369E+10	6.995E+05	5.861E+08	8.617E+08
	Med	1.101E+03	1.100E+03	6.705E+05	1.351E+05	2.509E+06	3.046E+05	9.251E+05	1.646E+04
F3	Avg	1.183E+05	1.183E+05	9.370E+03	2.991E+04	1.897E+09	3.040E+05	1.753E+08	1.554E+03
	Std	6.442E+05	6.442E+05	1.662E+04	1.418E+05	2.781E+09	2.855E+05	3.641E+08	3.196E+03
	Med	7.000E+02	7.000E+02	1.305E+03	7.000E+02	5.883E+07	2.445E+05	7.717E+06	7.000E+02
F4	Avg	1.907E+03	1.908E+03	1.905E+03	1.905E+03	1.907E+03	1.904E+03	1.913E+03	1.926E+03
	Std	3.669E+00	5.142E+00	1.525E+00	1.161E+00	1.179E+01	1.482E+00	3.100E+01	1.612E+01
	Med	1.906E+03	1.907E+03	1.903E+03	1.903E+03	1.903E+03	1.904E+03	1.906E+03	1.922E+03
F5	Avg	1.946E+04	1.280E+04	1.073E+05	5.173E+04	8.561E+04	1.565E+05	5.718E+04	5.280E+04
	Std	1.119E+04	1.259E+04	4.806E+04	2.961E+04	4.972E+04	7.196E+04	2.007E+04	2.411E+04
	Med	1.944E+04	7.881E+03	1.053E+05	4.306E+04	6.680E+04	1.397E+05	5.562E+04	4.808E+04
F6	Avg	2.115E+03	3.107E+03	2.309E+03	1.788E+03	6.070E+03	7.662E+03	2.920E+03	2.163E+03
	Std	5.474E+02	3.569E+03	8.531E+02	2.248E+02	2.584E+03	6.429E+03	1.306E+03	7.765E+02
	Med	2.013E+03	2.341E+03	2.006E+03	1.677E+03	5.359E+03	5.169E+03	2.649E+03	2.000E+03
F7	Avg	7.997E+03	4.270E+04	5.924E+04	1.203E+04	2.166E+05	1.722E+05	1.580E+05	1.678E+04
	Std	5.292E+03	9.986E+04	2.737E+04	6.035E+03	6.129E+05	9.707E+04	7.703E+05	8.566E+03
	Med	7.122E+03	8.697E+03	5.601E+04	1.063E+04	6.654E+04	1.637E+05	1.648E+04	1.326E+04
F8	Avg	2.332E+03	2.337E+03	2.303E+03	2.362E+03	2.320E+03	2.305E+03	2.328E+03	2.339E+03
	Std	8.092E+00	4.241E+00	6.499E+00	5.505E+01	1.135E+01	1.052E+01	2.165E+00	8.417E+00
	Med	2.334E+03	2.336E+03	2.300E+03	2.342E+03	2.324E+03	2.300E+03	2.328E+03	2.338E+03
F9	Avg	2.642E+03	2.622E+03	2.614E+03	2.715E+03	3.014E+03	2.652E+03	2.739E+03	2.647E+03
	Std	1.117E+02	8.419E+01	4.880E+01	3.634E+02	5.436E+02	2.837E+02	3.289E+02	1.382E+02
	Med	2.600E+03	2.600E+03	2.601E+03	2.600E+03	2.738E+03	2.600E+03	2.602E+03	2.600E+03
F10	Avg	3.216E+03	3.208E+03	3.160E+03	3.278E+03	3.035E+03	3.163E+03	3.423E+03	3.298E+03
	Std	6.647E+01	8.238E+01	4.418E+01	1.597E+02	7.140E+01	4.384E+01	9.664E+01	1.214E+02
	Med	3.213E+03	3.183E+03	3.149E+03	3.232E+03	3.017E+03	3.157E+03	3.443E+03	3.281E+03

5. **الاستنتاجات:** تعد خوارزمية المفترس البحري MPA احدى أهم خوارزميات ما فوق الحدس الحديثة ضمن خوارزميات ذكاء السرب الواعدة التي تحاكي الصيد للمفترسات البحرية عندما تقوم بالبحث عن الطعام وتتميز بانها تجمع بين سلوك المفترس والفرائس بحيث إن العملية تكون بالتبادل في دور الصياد وهذا ما يجعلها تنفرد تقريبا بهذا الأسلوب المميز. قمنا في هذا البحث بمراجعة مركزة ومختصرة لخوارزمية المفترس البحري MPA من خلال التركيز على التنوع في التحسينات والتطبيقات على الخوارزمية وحاولنا ان نتناول مجموعة متنوعة من التحسينات والتطبيقات. من المؤكد أن هذه الخوارزمية تعتبر من الخوارزميات ذات الأداء القوي والتي يمكن من خلال تحسينها أو تهجينها مع خوارزميات أخرى.

المصادر

1. Abd Elaziz, M., Thanikanti, S. B., Ibrahim, I. A., Lu, S., Nastasi, B., Alotaibi, M. A., Hossain, M. A., & Yousri, D. (2021). Enhanced Marine Predators Algorithm for identifying static and dynamic Photovoltaic models parameters. *Energy Conversion and Management*, 236, 113971. <https://doi.org/10.1016/j.enconman.2021.113971>
2. Abdel-Basset, M., El-Shahat, D., Chakraborty, R. K., & Ryan, M. (2021). Parameter estimation of photovoltaic models using an improved marine predators algorithm. *Energy Conversion and Management*, 227, 113491. <https://doi.org/10.1016/j.enconman.2020.113491>
3. Abualigah, L., Al-Okbi, N. K., Elaziz, M. A., & Houssein, E. H. (2022). Boosting Marine Predators Algorithm by Salp Swarm Algorithm for Multilevel Thresholding Image Segmentation. *Multimedia Tools and Applications*, 81(12), 16707–16742. <https://doi.org/10.1007/s11042-022-12001-3>
4. Ahmadianfar, I., Gong, W., Heidari, A. A., Golilarz, N. A., Samadi-Koucheksaraee, A., & Chen, H. (2021). Gradient-based optimization with ranking mechanisms for parameter identification of photovoltaic systems. *Energy Reports*, 7, 3979–3997.
5. Al-Betar, M. A., Awadallah, M. A., Makhadmeh, S. N., Alyasseri, Z. A. A., Al-Naymat, G., & Mirjalili, S. (2023). Marine predators algorithm: A review. *Archives of Computational Methods in Engineering*, 30(5), 3405–3435.
6. Al-qaness, M. A. A., Ewees, A. A., Fan, H., Abualigah, L., & Elaziz, M. A. (2022). Boosted ANFIS model using augmented marine predator algorithm with mutation operators for wind power forecasting. *Applied Energy*, 314, 118851. <https://doi.org/10.1016/j.apenergy.2022.118851>
7. Bakır, H. (2024). Enhanced artificial hummingbird algorithm for global optimization and engineering design problems. *Advances in Engineering Software*, 194, 103517. <https://doi.org/10.1016/j.advengsoft.2024.103671>
8. Cang, H., Zeng, X., & Yan, S. (2024). A novel grey multivariate convolution model based on the improved marine predators algorithm for predicting fossil CO2 emissions in China. *Expert Systems with Applications*, 243, 122865. <https://doi.org/10.1016/j.eswa.2023.122865>
9. Chun, Y., Hua, X., Qi, C., & Yao, Y. X. (2024). Improved marine predators algorithm for engineering design optimization problems. *Scientific Reports*, 14(1), 13000.

<https://doi.org/10.1038/s41598-024-63826-x>

10. Chung, H.-Y., Ye, Y.-A., Chang, J.-K., & Hou, C.-C. (2014). Multi-objects tracking based on HPSO-TVAC algorithm with searching window in real time. 2014 International Conference on Fuzzy Theory and Its Applications (IFUZZY2014), 41–46.
11. Coloni, A., Dorigo, M., & Maniezzo, V. (1991). Distributed optimization by ant colonies. *Proceedings of the First European Conference on Artificial Life*, 142, 134–142.
12. Dinh, P. H. (2023). A Novel Approach Based on Marine Predators Algorithm for Medical Image Enhancement. *Sensing and Imaging*, 24(1), 6. <https://doi.org/10.1007/s11220-023-00411-y>
13. Fan, Q., Huang, H., Chen, Q., Yao, L., Yang, K., & Huang, D. (2022). A modified self-adaptive marine predators algorithm: framework and engineering applications. *Engineering with Computers*, 38(4), 3269–3294. <https://doi.org/10.1007/s00366-021-01319-5>
14. Faramarzi, A., Heidarinejad, M., Mirjalili, S., & Gandomi, A. H. (2020). Marine Predators Algorithm: A nature-inspired metaheuristic. *Expert Systems with Applications*, 152, 113377.
15. Faramarzi, A., Heidarinejad, M., Stephens, B., & Mirjalili, S. (2020). Equilibrium optimizer: A novel optimization algorithm. *Knowledge-Based Systems*, 191, 105190.
16. Faris, H., Mafarja, M. M., Heidari, A. A., Aljarah, I., Ala'm, A.-Z., Mirjalili, S., & Fujita, H. (2018). An efficient binary salp swarm algorithm with crossover scheme for feature selection problems. *Knowledge-Based Systems*, 154, 43–67.
17. Filmlater, J. D., Capello, M., Deneubourg, J.-L., Cowley, P. D., & Dagorn, L. (2013). Looking behind the curtain: quantifying massive shark mortality in fish aggregating devices. *Frontiers in Ecology and the Environment*, 11(6), 291–296.
18. Fister Jr, I., Yang, X.-S., Fister, I., Brest, J., & Fister, D. (2013). A brief review of nature-inspired algorithms for optimization. *ArXiv Preprint ArXiv:1307.4186*.
19. Gao, Z., Zhuang, Y., Chen, C., & Wang, Q. (2023). Hybrid modified marine predators algorithm with teaching-learning-based optimization for global optimization and abrupt motion tracking. *Multimedia Tools and Applications*, 82(13), 19793–19828. <https://doi.org/10.1007/s11042-022-13819-7>
20. Glover, F. (1989). Tabu search—part I. *ORSA Journal on Computing*, 1(3), 190–206.
21. Goldberg, D. E., & Holland, J. H. (1988). *Genetic algorithms and machine learning*. 3 (2): 95-99. Kluwer Academic Publishers-Plenum Publishers.
22. Gong, R., Li, D. L., Hong, L. La, & Xie, N. X. (2024). Task scheduling in cloud computing environment based on enhanced marine predator algorithm. *Cluster Computing*, 27(1), 1109–1123. <https://doi.org/10.1007/s10586-023-04054-2>
23. Han, B., Li, B., & Qin, C. (2023). A novel hybrid particle swarm optimization with marine predators. *Swarm and Evolutionary Computation*, 83, 101375. <https://doi.org/10.1016/j.swevo.2023.101375>
24. Hassan, M. H., Daqaq, F., Selim, A., Domínguez-García, J. L., & Kamel, S. (2023). MOIMPA: multi-objective improved marine predators algorithm for solving multi-objective optimization problems. *Soft Computing*, 27(21), 15719–15740.

<https://doi.org/10.1007/s00500-023-08812-7>

25. Hassan, M. H., Yousri, D., Kamel, S., & Rahmann, C. (2022). A modified Marine predators algorithm for solving single- and multi-objective combined economic emission dispatch problems. *Computers and Industrial Engineering*, 164, 107906. <https://doi.org/10.1016/j.cie.2021.107906>
26. Houssein, E. H., Hussain, K., Abualigah, L., Elaziz, M. A., Alomoush, W., Dhiman, G., Djenouri, Y., & Cuevas, E. (2021). An improved opposition-based marine predators algorithm for global optimization and multilevel thresholding image segmentation. *Knowledge-Based Systems*, 229, 107348. <https://doi.org/10.1016/j.knosys.2021.107348>
27. Houssein, E. H., Ibrahim, I. E., Kharrich, M., & Kamel, S. (2022). An improved marine predators algorithm for the optimal design of hybrid renewable energy systems. *Engineering Applications of Artificial Intelligence*, 110, 104722. <https://doi.org/10.1016/j.engappai.2022.104722>
28. Hu, G., Zhu, X., Wang, X., & Wei, G. (2022). Multi-strategy boosted marine predators algorithm for optimizing approximate developable surface. *Knowledge-Based Systems*, 254, 109615. <https://doi.org/10.1016/j.knosys.2022.109615>
29. Islam, M. R., Ali, S. M., Fathollahi-Fard, A. M., & Kabir, G. (2021). A novel particle swarm optimization-based grey model for the prediction of warehouse performance. *Journal of Computational Design and Engineering*, 8(2), 705–727.
30. Jia, H., Sun, K., Li, Y., & Cao, N. (2022). Improved marine predators algorithm for feature selection and SVM optimization. *KSII Transactions on Internet and Information Systems*, 16(4), 1128–1145. <https://doi.org/10.3837/tiis.2022.04.003>
31. Jin, Z., Jiang, J., Kong, Z., Pan, C., & Ruan, X. (2024). A Novel Coverage Optimization Scheme Based on Enhanced Marine Predator Algorithm for Urban Sensing Systems. *IEEE Sensors Journal*, 24(5), 5486–5499. <https://doi.org/10.1109/JSEN.2023.3287582>
32. Karaboga, D., & Basturk, B. (2007). A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *Journal of Global Optimization*, 39, 459–471.
33. Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95-International Conference on Neural Networks*, 4, 1942–1948.
34. Kirkpatrick, S. (1983). Improvement of reliabilities of regulations using a hierarchical structure in a genetic network. *Science*, 220, 671–680.
35. Li, S., Chen, H., Wang, M., Heidari, A. A., & Mirjalili, S. (2020). Slime mould algorithm: A new method for stochastic optimization. *Future Generation Computer Systems*, 111, 300–323.
36. Liang, J. J., Qin, A. K., Suganthan, P. N., & Baskar, S. (2006). Comprehensive learning particle swarm optimizer for global optimization of multimodal functions. *IEEE Transactions on Evolutionary Computation*, 10(3), 281–295.
37. Lin, L., & Gen, M. (2009). Auto-tuning strategy for evolutionary algorithms: balancing between exploration and exploitation. *Soft Computing*, 13, 157–168.
38. Liu, J., Li, L., & Liu, Y. (2024). Enhanced marine predators algorithm optimized support vector machine for IGBT switching power loss estimation. *Measurement Science and*

- Technology, 35(1), 15035. <https://doi.org/10.1088/1361-6501/ad042b>
39. Luo, H., Chen, J., Sun, Z., Zhang, Y., & Zhang, L. (2024). Improved Marine Predators Algorithm Optimized BiGRU for Strip Exit Thickness Prediction. *IEEE Access*, 12, 56719–56729. <https://doi.org/10.1109/ACCESS.2024.3389489>
 40. Mirjalili, S., Mirjalili, S., software, A. L.-A. in engineering, & 2014, undefined. (n.d.). Grey wolf optimizer. Elsevier. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
 41. Oszust, M. (2021). Enhanced Marine Predators Algorithm with Local Escaping Operator for Global Optimization. *Knowledge-Based Systems*, 232, 107467. <https://doi.org/10.1016/j.knosys.2021.107467>
 42. Qin, C., & Han, B. (2023). Multi-Stage Improvement of Marine Predators Algorithm and Its Application. *CMES - Computer Modeling in Engineering and Sciences*, 136(3), 3097–3119. <https://doi.org/10.32604/cmes.2023.026643>
 43. Rai, R., Dhal, K. G., Das, A., & Ray, S. (2023). An inclusive survey on marine predators algorithm: Variants and applications. *Archives of Computational Methods in Engineering*, 30(5), 3133–3172.
 44. Rezaei, K., & Fard, O. S. (2024). Multi-strategy enhanced Marine Predators Algorithm with applications in engineering optimization and feature selection problems. *Applied Soft Computing*, 159, 111650. <https://doi.org/10.1016/j.asoc.2024.111650>
 45. Sayarshad, H. R., Javadian, N., Tavakkoli-Moghaddam, R., & Forghani, N. (2010). Solving multi-objective optimization formulation for fleet planning in a railway industry. *Annals of Operations Research*, 181, 185–197.
 46. Shaheen, A. M., Hamida, M. A., Alassaf, A., & Alsaleh, I. (2024). Enhancing parameter identification and state of charge estimation of Li-ion batteries in electric vehicles using an improved marine predators algorithm. *Journal of Energy Storage*, 84, 110982. <https://doi.org/10.1016/j.est.2024.110982>
 47. Storn, R., & Price, K. (1996). Minimizing the real functions of the ICEC'96 contest by differential evolution. *Proceedings of IEEE International Conference on Evolutionary Computation*, 842–844.
 48. Tu, Q., Chen, X., & Liu, X. (2019). Multi-strategy ensemble grey wolf optimizer and its application to feature selection. *Applied Soft Computing*, 76, 16–30.
 49. Wang, G.-G., & Tan, Y. (2017). Improving metaheuristic algorithms with information feedback models. *IEEE Transactions on Cybernetics*, 49(2), 542–555.
 50. Yang, W., Zhu, X., Xiao, Q., & Yang, Z. (2023). Enhanced multi-objective marine predator algorithm for dynamic economic-grid fluctuation dispatch with plug-in electric vehicles. *Energy*, 282, 128901. <https://doi.org/10.1016/j.energy.2023.128901>
 51. Yousri, D., Ousama, A., shaker, Y., Fathy, A., Babu, T. S., rezk, H., & Allam, D. (2022). Managing the exchange of energy between microgrid elements based on multi-objective enhanced marine predators algorithm. *Alexandria Engineering Journal*, 61(11), 8487–8505. <https://doi.org/10.1016/j.aej.2022.02.008>
 52. Yuwei, L., Li, L., & Jiaqi, L. (2024). Hybrid scheduling strategy and improved marine predator optimizer for energy scheduling in integrated energy system to enhance economic and environmental protection capability. *Renewable Energy*, 228, 120641.

<https://doi.org/10.1016/j.renene.2024.120641>

53. Zhang, H., Wang, X., Zhang, J., Ge, Y., & Wang, L. (2024). MPPT control of photovoltaic array based on improved marine predator algorithm under complex solar irradiance conditions. *Scientific Reports*, 14(1), 19745. <https://doi.org/10.1038/s41598-024-70811-x>
54. Zhang, J., & Xu, Y. (2023). Training Feedforward Neural Networks Using an Enhanced Marine Predators Algorithm. *Processes*, 11(3), 924. <https://doi.org/10.3390/pr11030924>
55. Zhao, W., Shi, T., Wang, L., Cao, Q., & Zhang, H. (2021). An adaptive hybrid atom search optimization with particle swarm optimization and its application to optimal no-load PID design of hydro-turbine governor. *Journal of Computational Design and Engineering*, 8(5), 1204–1233.