

## مسح وتحليل تجريبي لخوارزمية التطور التفاضلي

اريتاس أحمد خليل\*<sup>1</sup> محمد المحمد الحسين<sup>2</sup>

<sup>1</sup>. طالب دكتوراه في قسم هندسة الالكترونيات والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة

دمشق. [aretas1.khaleel@damascusuniversity.edu.sy](mailto:aretas1.khaleel@damascusuniversity.edu.sy)

<sup>2</sup>. استاذ في قسم هندسة الالكترونيات والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة دمشق

[m.alhussin@damascusuniversity.edu.sy](mailto:m.alhussin@damascusuniversity.edu.sy)

### الملخص:

لاقت خوارزمية التطور التفاضلي Differential Evolution (DE) منذ تقديمها عام 1997 انتشاراً واسعاً في مختلف المجالات الهندسية والتطبيقية. وهي أحد خوارزميات البحث الارشادية التي تستخدم في عمليات اتخاذ القرار الأمثلي. ونظراً لما قدمته من اضافات مفيدة في مجالات البحث عن الحلول للنماذج المعقدة، كان من المفيد تقديم مراجعة لهذه الخوارزمية وما جرى عليها من تعديلات واطافات بهدف زيادة كفاءة الاستخدام ورفع مستوى الأداء. تقدم هذه الورقة مراجعة حديثة للـ DE وللتعديلات المقترحة لتعزيز فعالية وكفاءة DE الأصلية من خلال تحليل نقاط القوة والضعف في العديد من المقالات والاعمال القيمة المنشورة. يتم إجراء تحليلات إضافية في هذا المسح بواسطة التحقيق في تأثيرات إعدادات المعلمات المختلفة على متغيرات DE لتحديد القيم المثلى المطلوبة لحل مشكلة معينة. يتم أيضاً تقييم صفات التعديلات المضمنة في متغيرات DE المحددة من خلال قياس مكاسب الأداء المحققة من حيث دقة البحث والكفاءة مقابل DE الأصلية.

**الكلمات المفتاحية:** خوارزميات الأمثلة، التطور التفاضلي، التهيئة، الطفرة، العبور، الاختيار.

تاريخ الإيداع: 2022/8/30

تاريخ القبول: 2022/10/27



حقوق النشر: جامعة دمشق - سورية،

يحتفظ المؤلفون بحقوق النشر بموجب

الترخيص CC BY-NC-SA 04

# Survey And Experimental Analysis Of The Differential Evolution Algorithm

Aretas Ahmad Khaleel<sup>\*1</sup> Mohammad Al Mohammad Al-Hussein<sup>2</sup>

<sup>\*1</sup>. PhD student, Department of communication and electronic engineering, Faculty of mechanical and electrical Engineering, Damascuse University  
[aretas1.khaleel@damascusuniversty.edu.sy](mailto:aretas1.khaleel@damascusuniversty.edu.sy).

<sup>2</sup>. Prof. Department of communication and electronic engineering, Faculty of mechanical and electrical Engineering, Damascuse University,  
[alhussin@damascusuniversity.edu.sy](mailto:alhussin@damascusuniversity.edu.sy)

## Abstract:

The differential evolution algorithm, since its introduction in 1997, has spread widely in various engineering and applied fields. It is one of the metaheurism search algorithms used for optimal decision-making processes. In view of the valuable additions made by this algorithm in the search for solutions to complex models, it was useful to provide a review of this algorithm and the modifications and additions that have been made to it in order to increase the efficiency of use and raise the level of performance. This paper presents an updated review of differential evaluation and suggested modifications to enhance the effectiveness and efficiency of the original evaluation by analyzing the strengths and weaknesses of several valuable articles and works published. Additional analyzes are performed in this survey by investigating the effects of different parameter settings on DE variables to determine the optimal values required to solve a particular problem. The properties of the modifications included in the selected DE variables also evaluated by measuring the performance gains achieved in terms of research accuracy and efficiency against the original DE.

**Keywords:** Optimization Algorithms, Differential Evolution, Initialization, Mutation, Crossing Over, Selection.

Received: 30/8/2022  
Accepted: 27/10/2022



**Copyright:** Damascus University- Syria, The authors retain the copyright under a CC BY- NC-SA

**المقدمة:**

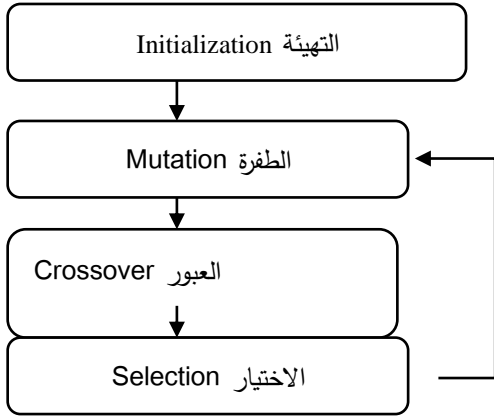
في ظل التطورات الهائلة التي أحدثتها الثورة الصناعية الرابعة، جرى تصميم العديد من الانظمة الهندسية في مختلف المجالات الصناعية [1،2]. بسبب ما تتصف به هذه الانظمة الهندسية من تعقيد عالي بما تتضمنه من نماذج معقدة مثل اللاخطية، الوسائط المتعددة، الانقطاع وعدم التفاضل وغيرها. لحل هذه النماذج المعقدة بنجاح، يتم استخدام عملية اتخاذ القرار الأمثلي (عملية الأمثلة) للبحث عن أفضل القيم لمتغيرات القرار التي يمكن أن تزيد أو تقلل من تابع الهدف (objective function) المحددة مسبقاً مع تلبية جميع القيود التقنية وغير الفنية خلال فترة زمنية معقولة. لجأ الباحثون إلى حل مشكلات التحسين بشكل تقليدي باستخدام العديد من طرق البرمجة الرياضية مثل البرمجة الخطية [3] والبرمجة

الديناميكية [4] وأساليب نيوتن [5] وغيرها. تعتبر خوارزميات البحث الارشادية العليا (Metaheuristic search algorithm) (MSAs) من التقنيات الواعدة لحل مسائل اتخاذ القرار الأمثلي من خلال الاستفادة من آليات البحث المستوحاة من الظواهر الطبيعية المختلفة، كما تعد MSA بشكل عام أكثر مرونة وقدرة على الوصول إلى حلول شبه عامة (global) لمسائل الأمثلة المحددة بشكل أكثر كفاءة دون الحاجة إلى تعديلات جوهرية في هيكل الخوارزمية. ظهرت الاتجاهات في مجالات الذكاء الاصطناعي في العقود الماضية لتطوير MSA جديدة مع أداء بحث أمثلي لحل أنواع مختلفة من هذه المسائل. اعتماداً على مصادر الإلهام المستخدمة لتوليد حلول جديدة، يمكن تقسيم MSA الحالية إلى أربع فئات رئيسية [6] كما هو واضح في الجدول 1.

الجدول (1) تصنيف خوارزميات ذاتية الارشاد (عالية المستوى).

اسم الخوارزمية	MSAs
البرمجة التطورية ( Evolutionary programming ) [7]، الخوارزمية الوراثة ( genetic algorithm ) [8]، خوارزمية التطور المشتركة (co- evolving ) [9]، البرمجة الوراثة ( genetic programming ) [10]، التطور التفاضلي ( differential evolution ) [11]، نموذج التطور البشري ( human evolutionary model ) [12]	الخوارزميات التطورية
عناصر السرب ( Particle swarm optimization ) [13]، مستعمرة النمل ( ant colony optimization ) [14]، مستعمرة النحل (artificial bee colony ) [15]، خوارزمية اليراع ( firefly algorithm ) [16]	خوارزميات ذكاء السرب
خوارزمية Jaya [16]، أمثلة التعلم- التعليم (teaching-learning based optimization ) [18]، التطور الاجتماعي وأمثلة التعلم ( socio evolution and learning optimization ) [19]	الخوارزميات القائمة على الإنسان
خوارزمية البحث الجاذبية ( Gravitational search algorithm ) [20]، المغناطيسية الكهربائية ( electro-magnetism optimization ) [21]، التفاعل النووي ( nuclear reaction optimization ) [29]	الخوارزميات القائمة على الفيزياء

التهيئة هي العملية الأولى التي تحدث في DE للبحث عن حل أمثلي عام مكون من  $D$  - بُعد لفضاء المعلمات الحقيقية. تتكون الحلول الأولية لمسألة الأمثلة متعددة الأبعاد من أشعة المعلمات ذات القيم الحقيقية بطول NP، حيث يمثل NP حجم السكان لـ DE. أثناء التكرار



الشكل (1) مخطط صندوقي لخوارزمية DE الأساسية.

$t$ ، يمكن تمثيل كل حل فردي لـ DE كشعاع من  $D$ -بُعد كما يلي:

$$X_i^t = (X_{i,1}, X_{i,2}, \dots, X_{i,D}) \quad (1)$$

حيث  $i = 1, 2, \dots, NP$ . تبدأ حالة السكان الأولية عند  $t = 0$ . يمكن إنشاء الحلول المرشحة الأولية أثناء مرحلة التهيئة على أساس حدود الحد الأدنى والأعلى لفضاء البحث عن الحلول التي تمثلها (2) و (3)، على التوالي كما يلي:

$$X_{min} = (X_{min,1}, X_{min,2}, \dots, X_{min,D}) \quad (2)$$

$$X_{max} = (X_{max,1}, X_{max,2}, \dots, X_{max,D}) \quad (3)$$

لكل حل  $i$  من حلول DE، يمكن تهيئة المكون رقم  $j$  عن طريق التوليد العشوائي لقيمة بين الحد الأعلى لـ  $X_{max,j}$  والحد الأدنى لـ  $X_{min,j}$  كما يلي

$$X_{i,j}^{(0)} = X_{min,j} + rand_{i,j}[0,1](X_{max,j} - X_{min,j}) \quad (4)$$

حيث  $rand_{i,j}$  توزيع منتظم يمكن أن يولد أي قيمة حقيقية بين 0 و 1.

## نظرة عامة على التطور التفاضلي:

تعتبر خوارزمية التطور التفاضلي (DE) المقترحة في [22] أحد أكثر خوارزميات الأمثلة شيوعاً لحل المسائل المعقدة. تنتمي DE إلى عائلة (Evolutionary Algorithms (EA)، وهي طريقة تعتمد على السكان، تُستخدم على نطاق واسع لحل أنواع مختلفة من مشاكل الأمثلة. تولد الخوارزمية نسلاً جديداً من خلال إعادة توحيد الحلول في ظل ظروف معينة، على عكس EA. سيتم استبدال الحل الفردي الحالي إذا تفوق عليه حل الجيل الجديد [23]. تعتبر DE خوارزمية متينة (robust) وبسيطة لأن عملية البحث الخاصة بها يحكمها عدد قليل من المعلمات، مثل عامل التحجيم ومعدل التقاطع. على عكس EAs، يمكن لـ DE أن تنتج حلولاً جديدة للنسب من خلال ثلاث آليات: الطفرة، التقاطع والاختيار. من الشائع ملاحظة أن الطفرة والتقاطع لها تأثير أكبر على أداء بحث الخوارزمية [24]. على الرغم من أنه تم اقتراح العديد من MSA المستوحاة من ظواهر طبيعية مختلفة في العقود الماضية، إلا أن DE لا تزال واحدة من أشهر MSA التي يستخدمها الباحثون لمعالجة مجموعات متنوعة من مشاكل الأمثلة في العالم الحقيقي نظراً لمزاياها التنافسية العديدة. على الرغم من بساطتها، فإن تقنية DE قادرة على إظهار قدرة تحسين واحدة أكثر من MSA الأخرى في حل أنواع متنوعة من مشاكل الأمثلة.

## 1- المفهوم الأساسي لخوارزميات DE

يتكون الإطار العام لخوارزمية التطور التفاضلي الأساسية من أربع مراحل، وهي التهيئة، الطفرة، التقاطع والاختيار. التهيئة هي عملية لمرة واحدة، بينما يتم تكرار الآليات الثلاث المتبقية في عملية البحث لـ DE في فضاء الحلول المكون من  $D$ -بُعد حتى يتم استيفاء معايير المطلوبة، يبين الشكل (1) مخطط صندوقي لخوارزمية DE الأساسية.

### 2-1. التهيئة Initialization

## 2-2 الطفرة Mutation

من الناحية البيولوجية، يتم تعريف الطفرة على أنها تغيير فوري في الخاصية. في سياق الحساب التطوري، تُعتبر الطفرة عملية اضطراب عشوائي يتم إجراؤها على متغيرات القرار المختارة. في فلسفة DE، يُشار إلى شعاع متحول أو مانح على أنه  $i^t$  يتم إنشاؤه من عملية طفرة على أساس شعاع الهدف المعطى لـ  $X_i^t$  [26,25]. في الأدبيات، جرى تمثيل عملية الطفرة بست صيغ مختلفة كالتالي:

$$Y_i^t = X_{r_1}^t + F(X_{r_2}^t - X_{r_3}^t) \quad (5)$$

$$Y_i^t = X_{r_1}^t + F(X_{r_2}^t - X_{r_3}^t) + F(X_{r_4}^t - X_{r_5}^t) \quad (6)$$

$$Y_i^t = X_{best}^t + F(X_{r_2}^t - X_{r_3}^t) \quad (7)$$

$$Y_i^t = X_{best}^t + F(X_{r_1}^t - X_{r_2}^t) + F(X_{r_3}^t - X_{r_4}^t) \quad (8)$$

$$Y_i^t = X_i^t + F(X_{best}^t - X_i^t) + F(X_{r_1}^t - X_{r_2}^t) \quad (9)$$

حيث  $r_1$  هو مؤشر السكان لحل DE المحدد كشعاع أساسي؛ و  $r_2, r_3, r_4, r_5$  هي المؤشرات السكانية لحلول DE التي تم اختيارها عشوائياً لبناء شعاع متحول. حيث  $r_5, r_4, r_3, r_2, r_1 \in [1, NP]$  and  $r_5 \neq r_4 \neq r_3 \neq r_2 \neq r_1$ ؛  $r_2 \neq r_1 \neq i$ ؛  $X_{best}^t$  هو أفضل حل فردي في مجموعة DE يتم اختياره باعتباره الشعاع المستهدف؛ و  $F$  هو عامل تقييم يستخدم للتحكم في عملية الطفرة وله قيمة في المجال بين  $[0,1]$ . يعد اختيار القيمة المناسبة لـ  $F$  أمراً ضرورياً لتحقيق التوازن المناسب بين عمليات البحث عن الاستكشاف والاستغلال للخوارزمية لمنع العيوب غير المرغوب فيها مثل التقارب المبكر أو سرعة التقارب البطيئة.

## 3-2 العبور Crossover

في هذه المرحلة، يُعبر كل من الهدف والأشعة الطافرة مكوناتها معاً بطريقة احتمالية لإنتاج شعاع تجريبي (نسل). تسمح عملية العبور هذه للحل المستهدف أن يرث سمات حل المانح أو المتحول. يُعرف للعبور مشغلان شائعان الاستخدام

باسم العبور المنتظم والعبور الأسي. يتم التحكم في مخطط التقاطع المنتظم بواسطة معدل عبور (crossover rate CR) له قيمة بين  $[0,1]$ . يمكن تحديد الحل التجريبي الناتج عن التقاطع المنتظم في (10) على النحو التالي:

$$Z_i^t = \begin{cases} Y_{i,j}^t & \text{if } rand_{i,j}[0,1] \leq CR \text{ or } j = k \\ X_{i,j}^t & \text{otherwise} \end{cases} \quad (10)$$

حيث  $rand_{i,j}$  هو رقم عشوائي يقع في النطاق  $[0,1]$  و  $k \in \{1,2, \dots, D\}$  هو مؤشر بعد تم اختياره عشوائياً لضمان مكون واحد على الأقل من مكونات الحل التجريبي  $Z_i^t$  موروث من الشعاع المانح  $Y_{i,j}^t$ .

للعبور الأسي، عدد صحيح  $n \in \{1,2, \dots, D\}$  يتم اختيار  $D$  بشكل عشوائي كنقطة انطلاق لمؤشر البعد للشعاع المستهدف لإجراء العبور مع شعاع متحول أو متبرع. عدد صحيح آخر  $L \in \{1,2, \dots, D\}$  يشير إلى عدد المكونات البعدية الموروثة من الشعاع المتبرع أو المتحول لتشكيل الحل التجريبي. بالإشارة إلى قيم  $n$  و  $L$ ، يمكن الحصول على الحل التجريبي ( $Z_i^t$ ) من (11) على النحو التالي:

$$Z_i^t = \begin{cases} Y_{i,j}^t & \text{if } j = \langle N \rangle_D, \langle n+1 \rangle_D, \dots, \langle n+L-1 \rangle_D \\ X_{i,j}^t & \text{otherwise} \end{cases} \quad (11)$$

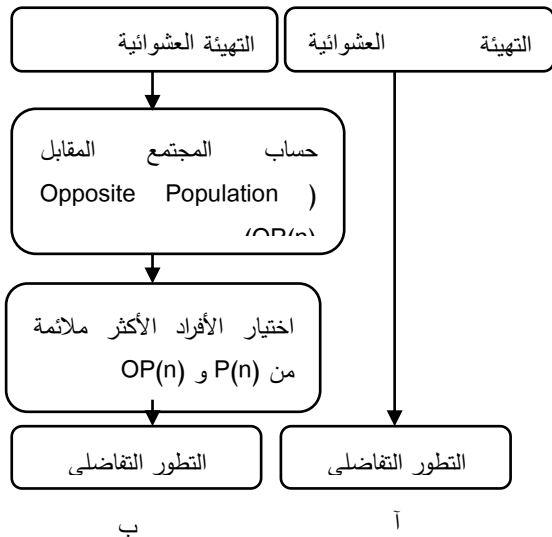
يشير  $\langle \cdot \rangle_D$  إلى باقي القسمة على  $D$ .

## 4-2 الاختيار Selection

تُمكن عملية الاختيار DE من تحديد بقاء الحل المستهدف (الأصل) أو التجريبي (النسل) في التكرار التالي  $X_i^{t+1}$  لعملية البحث مع الاحتفاظ بحجم السكان لـ DE في كل جيل. بمجرد تكوين المجتمع الجديد في الجيل التالي، يتم تنفيذ العمليات التكرارية للطفرة والعبور والاختيار بشكل مستمر حتى يتم استيفاء معايير الإنهاء. يوجد نوعان من الاختيار، وهما المحلي والعام [27]. يتم وصف عملية اختيار DE رياضياً على النحو التالي:

$$X_i^{t+1} = \begin{cases} Z_i^t & \text{if } f(Z_i^t) \leq f(X_i^t) \\ X_i^t & \text{otherwise} \end{cases} \quad (12)$$

لعملية التهيئة تميل إلى إظهار أداء أمثلي أفضل من ذلك الذي تم تهيئته باستخدام التسلسلات العشوائية الكلاسيكية.



الشكل 2 DE مع (أ) التهيئة العشوائية للسكان و (ب) التهيئة السكانية القائمة على المقابل.

في [30] جرى اقتراح عملية تهيئة تسمى ( smart DE sampling SSDE) القادرة على تحديد منطقة الحل الواعدة في فضاء البحث من خلال الاستفادة من قوة التعلم الآلي. تم إجراء عملية التهيئة المقترحة في مناطق مختلفة من فضاء البحث، وتهدف إلى مساعدة DE في تحديد مناطق الحل ذات الفرص الأكبر لتحديد الموقع الأمثل العام. عند مقارنة SSDE مع DE الأصلية، كشفت نتائج المحاكاة المكثفة عن مزايا مخطط التهيئة المقترح المدمج في SSDE في تحديد الموقع الأمثل العام لمشاكل الأمثلة المختلفة من حيث الكفاءة مع معدل نجاح أعلى (أي 96%) مقارنة مع تلك الخاصة بـ DE الأصلي (أي 80%).

في [31] جرى اقتراح مخطط ضبط السكان التكيفي (adaptive population tuning scheme APTS) للتحكم ديناميكياً في تعداد السكان لـ DE بناءً على التوزيع السكاني المرغوب وحالة البحث. مكن ذلك من التعرف على الأفراد ذوو

حيث  $f(.)$  هي عامل يستخدم لتحديد التابع الهدف أو قيمة الملاءمة لحل فردي. إذا كان أحدث شعاع تجريبي لـ  $t_i$  ينتج قيمة تابع الهدف أفضل، فسيتم استبدال الشعاع المستهدف الحالي  $t_i$  بواسطة  $t_i$  في التكرار التالي. يمكن تنفيذ عملية اختيار DE من خلال أوضاع متزامنة وغير متزامنة. يمكن تحديث مجموعة DE في وقت واحد أثناء الوضع المتزامن، بينما يمكن استخدام الوضع غير المتزامن لتحديث مجموعة DE بشكل فردي.

## 2- تحسين مخططات DE

### 1-3 مخطط التهيئة المحسن

يعد اختيار عملية التهيئة غير القابلة للتكرار أمراً حيوياً لأن جودة المجموعة الأولية التي تم الحصول عليها تميل إلى التأثير على التدفق الكلي لخوارزمية DE. في [28] تم اقتراح نهج للتهيئة يتكون من ثلاث مراحل أساسية. أولاً، يتم الحصول على مجموعة سكانية  $P(n)$  موزعة عشوائياً من مولد التوزيع المنتظم، حيث يشير  $n$  إلى تعداد السكان. ثم يجري حساب المجموعة المقابلة من  $OP(n)$  بناءً على استراتيجية التعلم القائمة على المقابل (opposition-based learning strategy). أخيراً، يتم تحديد التعداد السكاني الأولي عن طريق اختيار أفضل الحلول الفردية  $n$  التي تم تقييمها من مجموعة سكانية مجمعة من  $\{P(n) \cup OP(n)\}$ ، يوضح الشكل 2 المخطط الصندوقي لـ DE مع التهيئة العشوائية للسكان random (DEr) والتهيئة بالاعتماد على المقابل (DEo) opposed. تشير التقارير إلى أن DEo يمكن أن يحقق مكاسب في الأداء بنسبة 10% من حيث معدل التقارب. جرى اقتراح خوارزمية DE في [29] التي تم تهيئتها بشكل عشوائي مع معدل تقارب أسرع ومتانة أفضل ضد التقارب المبكر. تم اختيار مجموعة من الخرائط الفوضوية (chaotic) منها الدائرية والجيبية لتهيئة السكان. أظهرت نتائج المحاكاة أن خوارزميات DE المدمجة مع الخرائط الفوضوية

الآباء في مشغلي الطفرات عشوائياً بناءً على تصنيفات السكان الحالية. إن احتمال اختيار كل حل مرشح لعملية الطفرة يتناسب طردياً مع قيمة ملاءمته. أظهرت نتائج المحاكاة أن مشغلي الطفرات المركزة على الترتيب قادرين على تحسين أداء خوارزميات DE الكلاسيكية والمتقدمة من حيث قدرتها على الاستغلال. في [35] أقتُرحت خوارزمية DE ذات معلمات تحكم في الطفرات المنفصلة لمعالجة موازنة البحث عن الاستكشاف والاستغلال عند معالجة مسائل الأمثلة المختلفة. أظهرت نتائج المحاكاة المكثفة أن هذه الخوارزمية تتفوق على منافسيها في معظم المواقف.

أقتُرحت في [36]، خوارزمية DE مع مجموعة متوازنة متعددة السكان من استراتيجيات الطفرات لمعالجة مشاكل الأمثلة واسعة النطاق مع تعزيز التنوع السكاني. تم تقسيم الأفراد إلى مجموعات فرعية متعددة، حيث قُدم مخطط طفرات جديد لإنتاج حلول جيدة النوعية من خلال استخدام معلومات أفضل الافراد أو أي أفراد يتم اختيارهم عشوائياً من طوبولوجيا سكانية معينة. على الرغم من الأداء الجيد لهذه الخوارزمية في حل المسائل واسعة النطاق، إلا أنه تم الحصول على إعدادات المعلمات من خلال عملية الضبط اليدوي بدلاً من تلك التكيفية.

أقتُرحت في [37] خوارزمية DE للطفرة ذاتية التكيف تعتمد على طريقة أمثلة عناصر السرب Particle swarm optimization (PSO) لمعالجة التقارب البطيء والميل العالي للتقارب المبكر الذي أظهره DE الأصلية. تم تقديم مخطط طفرة مُحسَّن بناءً على إستراتيجية أرشيف النخبة (elite archive strategy) لتعزيز البحث الاستكشافي العام لـ DEPSO. وفي الوقت نفسه، تم تحسين سرعة تقارب DEPSO من خلال دمج مخطط طفرات آخر قائم على PSO. نجحت DEPSO في تحسين سرعة التقارب في حل مشكلات الأمثلة البسيطة دون التضحية بالتنوع السكاني.

الصفات غير المرغولة على أساس ترتيبهم ومن ثم إهمالهم من التجمعات السكانية. تم دمج APTS مع DE وتم تقييم أدائها. أظهرت نتائج المحاكاة أن DE المدمجة مع APTS تفوقت على متغيرات DE الأخرى في حل 100 مسألة بـ 100- بُعد دون تكبد تعقيد ووقت تشغيل كبيرين.

حرى اقتراح مخطط التهيئة على أساس طفرة كوشي وطريقة التجميع (clustering) لتوليد مجتمع DE في [32]. تم استخدام طريقة التجميع أولاً لتحديد المجالات المختلفة لفضاءات البحث عن الحلول ذات الصفات الواعدة نسبياً ثم تم إجراء طفرة لتوليد حلول جيدة أخرى، في حين تم تطبيق التوزيع المنتظم أيضاً لتوليد أعضاء سكانية آخرين للحفاظ على مستوى تنوع الحلول. كشفت تحليلات الأداء أن متغيرات DE المدمجة مع مخطط التهيئة المقترح هذا لها سرعة تقارب أعلى من تلك مع مخطط التهيئة التقليدي. يلخص الجدول 2 البحث المتعلق بمخططات التهيئة المحسنة.

### 2-3 مخطط الطفرات المحسنة

أقتُرحت في [33] خوارزمية DE مع إستراتيجية طفرة جديدة لتحسين أداء البحث في معالجة مشاكل الأمثلة العددية المعقدة. تم تعديل مشغل الطفرة جديد في العلاقة (9)، كما يلي:

$$\vec{V}_{i,G} = \vec{X}_{i,G} + F_i (\vec{X}_{gr-best,G} - \vec{X}_{i,G} + \vec{X}_{r_1^g,G} - \vec{X}_{r_2^g,G}) \quad (13)$$

حيث  $\vec{X}_{gr\_best,G}$  هي نسبة مئوية من الأشعة المختارة عشوائياً من مجموعة السكان؛  $\vec{X}_{r_1^g,G}$ ،  $\vec{X}_{r_2^g,G}$  هما شعاعان مختلفان. تم اختيار أفضل حل من السكان بشكل عشوائي من أحدث جيل لمقاطعة الشعاع المستهدف لتقليل احتمالية التقارب المبكر. أظهرت نتائج المحاكاة لهذه الطريقة أن طريقة الطفرات الجديدة يمكن أن تعزز أداء البحث عن DE بشكل كبير في حل الأنواع المختلفة من مشاكل الأمثلة. في [34]، أقتُرحت عامل طفرة DE القائم على الترتيب، حيث تم اختيار

أُقرحت طريقة جديدة في [39] لـ DE مع معلمات تحكم ذاتية التكيف واستراتيجيات الطفرات المتعددة، بهدف تحسين دقة الحل وسرعة التقارب. تتكون هذه الطريقة من ثلاثة مشغلين للطفرات مع معلمات تحكم فريدة. يمكن للطفرات في (5) و(7) تعزيز البحث العام وقدرات البحث المحلية، على التوالي. تم تصميم تقنية الطفرة الثالثة لتقديم توازن أفضل بين عمليات البحث الاستكشافية والاستغلال من خلال توليد أشعة متحولة جديدة من القيم المتوسطة لتلك التي تم الحصول عليها من مشغلي الطفرات المذكورين أعلاه. على الرغم من مكاسب الأداء التي حققتها هذه الطريقة، يمكن ملاحظة بعض تدهور الأداء عند التعامل مع وظائف الوسائط المتعددة. على أساس المراجعات المذكورة أعلاه، يلخص الجدول 3 البحث المتعلق بمخططات الطفرات المحسنة.

### 3-3 مخطط العبور المحسن

في [40]، أُدخل عاملاً دورانياً ثابتاً يُعرف باسم عامل العبور القائم على الأشعة الذاتية eigenvector لمعالجة مشاكل الأمثلة مع شكل موائمة أكثر فاعلية. تم إنشاء نظام إحدائيات مستدير أولاً من خلال الإشارة إلى معلومات الأشعة الذاتية لمصفوفة التغيرات للسكان. يمكن بعد ذلك إنشاء حلول النسل من قبل الأباء الذين يتم اختيارهم عشوائياً من أنظمة إحدائيات قياسية أو دواراة لمنع فقدان التنوع السريع للسكان. أضاف استخدام هذا العامل تحسن كبير في أداء DE، خاصة عند التعامل مع وظائف أحادية الوسائط غير قابلة للفصل. ومع ذلك، تظل تأثيرات إعدادات البارامترات مثل حجم السكان والأبعاد على أداء الطريقة المقترحة غير مستكشفة.

أُقرحت في [41] مجموعة من الانتواع (speciation) القائمة على إعادة التركيب الحسابي لحل مشاكل الأمثلة متعددة الوسائط. على عكس النهج التقليدي، يمكن لهذه التقنية أن تعزز الاستكشاف دون التأثير سلباً على معلمات نصف

في [27] أُقرحت طريقة (إستراتيجيات متعددة للطفرة ذات الأبعاد المختلفة لـ DE) لمعالجة سرعة التقارب البطيئة والتقارب المبكر للخوارزمية التقليدية. تم اقتراح إستراتيجية طفرة أبعاد مختلفة أولاً لتعزيز التنوع السكاني، حيث يتم المساهمة بكل مكون من مكونات الشعاع المتحول بواسطة الشعاع الأساسي وشعاع الفرق من أبعاد مختلفة، كما يلي:

$$V_{i,j}^{g+1} = x_{r3,n}^g + F \cdot (x_{r1,m}^g - x_{r2,m}^g) \quad (14)$$

$$i \neq r1 \neq r2 \neq r3, j \neq n \neq m,$$

حيث  $V_{i,j}^{g+1}$  هو الشعاع المتحول؛  $V_{r3,n}^g$  الشعاع الأساسي؛  $x_{r1,m}^g - x_{r2,m}^g$  شعاع الفرق. تم تصميم مخطط الطفرات متعدد الإستراتيجيات أيضاً لتعزيز سرعة التقارب لهذه الطريقة من خلال تقسيم عملية الأمثلة الشاملة إلى أربع وحدات توليد. اعتمدت وحدات الجيل الأول والثالث على إستراتيجية طفرة تقليدية (7) التي عززت البحث عن الاستغلال، في حين تم استخدام إستراتيجية الطفرة الأبعاد الجديدة في وحدات الجيل الثاني والرابع في ظل وجود عامل طفرة ديناميكي لمنع ركود السكان في المناطق المحلية. تفوقت هذه الطريقة على الخوارزميات النظرية من حيث دقة الحل وسرعة التقارب عند تطبيقها على وظائف اختبار بسيطة.

تم تقديم طفرة غاوسية جديدة ومخطط طفرة مشتركة معدلة في [38] لإنتاج أشعة متحولة جديدة بشكل تعاوني وتكفي من خلال الإشارة إلى الدرجات التراكمية الخاصة بكل منها. تم اعتماد وظيفة دورية لتوليد معامل قياس لتحقيق التوازن المناسب بين قوة الاستكشاف والاستغلال. تم تعزيز التنوع السكاني من خلال معدل العبور المتقلب الذي يتم الحصول عليه من التابع الغوسي لضمان أدائها القوي في التعامل مع المسائل المعقدة. على الرغم من أداء البحث الواعد، فإن هذه الطريقة أكثر حساسية للتغيرات في معدل العبور نظراً لتأثيرها الأكبر على السكان، مما يتطلب عملية ضبط أكثر دقة للمعلمات لتحقيق الإعدادات المثلى.



قدم [43] إستراتيجية عبور متكيف لتحسين أداء DE. تم تصور كل فرد من ليكون لديه إستراتيجية عبور فريدة واستراتيجية طفرة وبارامترات تحكم يمكن تغييرها بشكل تكيفي من خلال الرجوع إلى التقدم في البحث الأخير. تمت محاكاة هذه الاستراتيجية، وثبتت أنها قادرة على المنافسة في حل وظائف ومسألة تقدير البارامترات الحركية لأكسدة الزئبق بسبب قدرتها على الاستغلال المعزز. في [44]، أقتراح تعديل على DE يتكون من مشغل عبور دوار مع إستراتيجية بحث متعددة الزوايا، بهدف تقليل احتمالية توليد حلول نسل رديئة. على عكس مخطط العبور التقليدي ذي الحدين، يمكن إنشاء شعاع التجربة لمشغل العبور المقترح بشكل متنوع داخل مناطق الدائرة حول الشعاع المانح والمستهدف من

القطر. أثبتت هذه التقنية أنها أكثر قابلية للتعميم في المواقف العملية لتكون قادرة على تحديد القيم العليا والسفلى المنشودة. أقتراح في [42] إستراتيجية عبور أعلى-أدنى (superior-inferior SI) واستراتيجية عبور أعلى-أعلى (superior SS) لتحسين تنوع سكان DE. يتم تشغيل مخطط SI لتعزيز قوة الاستكشاف لخوارزمية إذا كان التنوع السكاني منخفضاً جداً. في الوقت نفسه، يتم الترويج للبحث عن الاستغلال من خلال مخطط SS إذا كان السكان متنوعين. كل من مخططات SS و SI قابلة للتكيف مع مشغلي التقاطع النموذجي ذي الحدين والأسّي، وبالتالي يمكن دمجها في أطر عمل مختلفة. أظهرت دراسات المحاكاة أن أداء البحث يعتمد بشكل كبير على إعدادات المعلمات لكل من مخططات التقاطع SI و SS.

#### الجدول (2) ملخص للبحث عن مخطط التهيئة المعزز.

مؤلف	التقنية المقترحة	الأبعاد	نتائج	مزايا	محددات
[28]	طريقة التهيئة بالاعتماد على المقابل	2، 3، 4، 5، 6، 10، 20، 30، 100	تم تعزيز معدل التقارب في خوارزمية DE مع التهيئة بالاعتماد على المقابل بنسبة 10 % مقارنة مع خوارزمية DE مع التهيئة العشوائية.	أدت طريقة التهيئة المقترحة إلى تحسين مستوى التنوع من السكان الأولي، وبالتالي زيادة معدل التقارب في الخوارزمية.	يمكن ملاحظة تدهور الأداء الكبير لمعدل المقابل
[29]	تهيئة الفوضى DE (CIDE)	2 و 5 و 10	يمكن أن يؤدي وجود طرق التهيئة المعقدة والديناميكية إلى تحسين جودة الحلول.	انخفاض احتمال التقارب المبكرة بسبب تحسين قدرة البحث العام.	اثنان فقط من كل سبع خرائط فوضوية يمكن القياس. لم يتم التحقق في قدرة الخرائط الفوضوية الأخرى في توليد الحل بجودة أفضل لحل التطبيقات في العالم الحقيقي.
[30]	أخذ العينات الذكية DE (SSDE)	10، 20، 30، 40، 60	ثبت أن معدل النجاح وأداء نجاح SSDE يتفوق على الأداء الأصلي بنسبة 16 % و 76 % على التوالي.	يتمتع SSDE بفعالية أفضل لإيجاد مجموعات أولية ذات جودة فائقة بالمقارنة مع خوارزميات أخرى.	تكلفة حسابية عالية بسبب استخدام تقنيات التعلم الآلي لأداء نهج أخذ العينات الذكي.
[31]	نظام ضبط السكان التكيفي (APTS)	30، 100	حقق APTS Jade المقترح أداءً جيداً في 30 مشاكل الأبعاد وأفضل أداء في 100 مشكلة الأبعاد.	البساطة في التنفيذ. يمكن تعديل حجم السكان بشكل تكيفي لزيادة احتمال تحديد الموقع الأمثل العام.	لم يكن تأثير معاملات التحكم درس بعناية. ميل راقب التخلص من الحلول المرشحة التي لها أداء أدنى مؤقت ولكن قد تكون مفيدة من حيث الناحية الطويلة.
[32]	مخطط التهيئة على أساس طفرة كوشي وطريقة التجميع	4، 10، 30، 50	حققت طريقة التهيئة المقترحة سرعة معدل تقارب أسرع من نهج التهيئة التقليدي.	تمت زيادة معدل التقارب لمتغير DE المقترح بشكل ملحوظ عند مقارنته بمتغيرات DE مع طريقة تهيئة السكان التقليدية	درجة عالية من التعقيد الحسابي. صعوبة في تقدير النسب المثلى بين الحلول الناتجة عن طفرة كوشي والتوزيع المنتظم.

في [45] قُدمت خوارزمية DE قائمة على التباين مع عبور اختياري لحل جميع البيانات في مسائل الأمثلة مع سرعة تقارب محسنة وجودة في الحل. أولاً، تم اعتماد نهج تمثيل الحل الفردي للتغلب على قيود تقنيات الحلول القائمة على السكان في تهيئة وصياغة التجميع في مسائل الأمثلة. تم بعد ذلك دمج مخطط قابل للتحويل يتكون من مخططين للطفرات

خلال الإشارة إلى معلم العبور الذاتي المتكيف وأشعة التحكم في الدوران التي تتبع توزيع ليفي (Levy). عند دراسة الاداء، أظهرت نتائج المحاكاة أن مشغل العبور المقترح ودمجه مع DE تفوقها على الخوارزميات الأخرى من حيث دقة البحث ومعدل التقارب، مع مكاسب في الأداء في النطاق من 57% إلى 96%.

وتقدير قائم على

الجدول (3) ملخص بحث بالطفرات المحسنة

محددات	مزايا	نتائج	الابعاد	التقنية المقترحة	مؤلف
جری تقييم الأداء باستخدام وظائف اختبار بسيطة أحادية الهدف ومقارنتها بنوعين من DE. في وظائف الاختبار الكافية.	تم تحقيق مكاسب ملحوظة في الأداء من حيث معدل التقارب من خلال مقابل خوارزميات DE الأخرى.	تفوقت الطريقة المقترحة على خوارزميات DE الأخرى من حيث معدل التقارب.	2، 50	إستراتيجيات متعددة للطفرة ذات الأبعاد المختلفة لـ DE	[27]
ركزت تقييمات الأداء فقط على حجم المجموعة الثابت عبر الأجيال.	تم اقتراح إستراتيجية طفرة أكثر استكشافية للحفاظ على التنوع السكاني. قللت هذه الإستراتيجيات من احتمال التقارب المبكر في التعامل مع المسائل واسعة النطاق.	الطريقة المقترحة قادرة على حل مسائل الأمثلة على نطاق واسع مع تحسين أداء البحث.	30، 50، 100	خوارزمية DE قابلة للتكيف مع تحولات جديدة وإستراتيجيات عبور	[33]
بسبب المستوى المفرط في البحث عن الاستغلال، قد لا يكون مشغلي الطفرة المستندة إلى الترتيب فعال في تحسين أداء DE في حل أنواع معينة من المشكلات	تعزيز السلوك الاستغلالي. البساطة في التنفيذ دون زيادة تعقيد الخوارزمية بشكل ملحوظ.	تحسين في أداء خوارزميات DE مع اعتماد مشغلي الطفرة في الترتيب.	30، 50، 100، 200	DE مع مشغلي الطفرة القائمة على الترتيب	[34]
أداء الخوارزمية المقترحة لم يكون ملحوظ مقارنة بالخوارزميات الأخرى في حل المسائل مع حجم 30- بعد. زاد ترميز إستراتيجية الطريقة المقترحة من تعقيد الخوارزمية، مما يؤدي إلى وقت تنفيذ أطول.	تُعطي لكل متغير محسن معاملات خاصة للتحكم في الطفرة المختلفة وضبط التكيف لإستراتيجية الطفرة عبر المنافسة، مما يؤدي إلى الحفاظ على التنوع السكاني بشكل أفضل.	كان متوسط أداء التحسين أفضل من الخوارزميات الأخرى في حل المسائل بأحجام 50 و 100 بعد.	30، 50، 100	DE مع معاملات التحكم في الطفرة المنفصلة.	[35]
لم يتم التحقق من أداء الخوارزمية المقترحة تماماً مع التعديل التكيفي لمعاملات التحكم.	عززت الإستراتيجية المتعددة السكان الإستراتيجية الاستغلالية. اعتماد مخطط مشاركة المعلومات بين المجموعات السكانية الفرعية المختلفة لتقليل الخسارة الشديدة في التنوع السكاني.	الطريقة المقترحة لها أداء ممتاز في حل المسائل العامة بفعالية.	50، 100، 200، 500، 1000	خوارزمية DE مع مجموعة متوازنة متعددة السكان من إستراتيجيات الطفرات	[36]
لم يتم التحقق في قدرة الخوارزمية المقترحة في حل مشاكل التحسين الأكثر تعقيداً.	يمكن أن تحسن إستراتيجية طفرة DE وإستراتيجية الطفرة المستوحاة من PSO معدل التقارب في الخوارزمية المقترحة بشكل فعال.	الأداء العام تجاوز DE التقليدي و خوارزميات PSO.	30، 100	خوارزمية بطفرة ذاتية التكيف مع أمثلة عناصر السرب	[37]
لم يتم تحقيق تحسين أداء ملحوظ في مدة معدل التقارب بواسطة الخوارزمية المقترحة مقارنة بخوارزميات أخرى.	كان عامل القياس الدوري المقترح أظهرت إمكانات وإعادة لتحسين قدرات الاستغلال والاستكشاف للخوارزمية المقترحة.	أظهرت الخوارزمية المقترحة أداء تنافسي في حل أعداد محدودة من المسائل القياسية.	30، 50 و 100	طفرة غاوسية وتعديل المعلمة الديناميكية	[38]
يمكن ملاحظة تدهور الأداء الملحوظ من الخوارزمية المقترحة عند التعامل مع وظائف الوسائط المتعددة والتكوين. لا يزال أداء الخوارزمية المقترحة في حل مشاكل العالم الحقيقي غير مستكشفة.	اعتمدت إستراتيجية الطفرة المقترحة ثلاثة اتجاهات بحث تم تخصيصها مع أوزان مختلفة من سلوكيات البحث الاستكشافية والاستغلالية في توليد حلول جديدة لتحقيق أفضل للحفاظ على التنوع السكاني.	تم الإبلاغ عن الخوارزمية المقترحة تتفوق على خوارزميات DE الأخرى في حل وظائف القياس. تم الإبلاغ عن أن معدل التقارب أفضل من منافسيها.	30 و 50	خوارزمية DE المحسنة مع إستراتيجيات طفرة متعددة ومعلمات التحكم في تكيف الذات	[39]

أُتِرح في [48] خوارزمية DE مدمجة مع سياسات معالجة الضجيج لتعزيز متانة الأمثلة في التعامل مع فضاءات البحث عن الحلول التي تتكون من الضجيج العشوائي. بدايةً، تم دمج أتمتة التعلم العشوائية مع سياسات معالجة الضجيج لتحديد حجم عينة مناسب للحلول في المناطق المتأثرة بالضجيج لتحقيق تقدير جيد دون زيادة التعقيد الحسابي. تم اقتراح إستراتيجية جديدة لتقدير قيمة المطابقة من خلال النظر في المتوسط الموزون لجميع عينات الملاءمة، وذلك من أجل تقليل تأثيرات عينات المطابقة المضججة. تم تصميم معدل طفرة تكيفية لاختيار الحلول من فضاءات قليلة الضجيج نسبياً لعملية الطفرة. أخيراً، تم دمج استراتيجية ملائمة لمعالجة التأثير المخادع لإشارة الضجيج، وبالتالي ضمان المفاضلة المناسبة بين التنوع السكاني والجودة. عند تقييم الأداء، أثبتت تقنيات معالجة الضجيج بأنها تتمتع بمتانة وسرعة تقارب أفضل ضد منافسيها.

في [49]، أُتِرح تعديل على طريقة الانتهاء في DE من خلال تقديم قاعدة إنهاء قائمة على الفروق بين متوسطات توابع الهدف. تزيد هذه الطريقة من فعالية الاستكشاف والبحث من خلال اقتراح مخطط لتحديد المعلمات الحرجة. جرى اختبار فعالية الطريقة المقترحة على مجموعة من سلاسل الاختبار ذات البنية المعقدة وأبعاد كبيرة، وكانت النتيجة أنها متينة وذات حلول سريعة في المسائل ذات الأبعاد الكبيرة مقارنة بـ DE الأصلية. في [50] أُتِرح خوارزمية DE مع الاختيار المستقل لاستراتيجيات الطفرات ومعلمات التحكم، هنا، يتم استخدام أرشيف الخبرة التاريخية (historical experience) مع ميزات السكان للحفاظ على الخبرة التاريخية المتراكمة لمزيج من استراتيجيات الطفرات ومعايير التحكم. علاوة على ذلك، يمكن ربط الخبرة التاريخية المتراكمة بشكل مستقل في جدول القواعد، ويمكن للأفراد اختيار مزيج من استراتيجيات الطفرات ومعلمات التحكم وفقاً لتلك القواعد.

أشعة لعامل الطفرة لتحقيق توازن مناسب بين عمليات الاستكشاف والاستغلال. بالنظر إلى أن الحل الطافر قد يكون للخوارزمية مخطط صلاحية أفضل، فقد سُرّع المخطط المقترح سرعة تقارب الخوارزمية من خلال تحديد الملاءمة بين الحلول المتحولة والحلول التجريبية قبل الشروع في عملية الاختيار. تمت مقارنة أداء هذه الخوارزمية مع أخريات منافسة. وأظهرت النتائج أنها حققت تحسين بنسبة 11.98% في دقة التصنيف وكثافة الكتلة مقابل الأقران المتنافسين. على أساس المراجعات المذكورة أعلاه، يلخص الجدول 4 البحث المتعلق بمخططات التقاطع المحسنة.

### 3-4. مخطط الاختيار المحسن

أُتِرح في [46] مشغل اختيار تكيفي القائم على المخططات (landscape) ودمجه DE مع لحل نطاقات واسعة من وظائف القياس بشكل أكثر كفاءة وفعالية. تم تقديم مخطط اختيار المشغل التكيفي، حيث تم النظر في كل من معلومات مخطط الصلاحية وسجلات تتبع الأداء لكل مشغل طفرة في توليد النسل المناسب عند اختيار مشغل الطفرة الأنسب لتطوير الطريقة بأكملها أثناء عملية الأمثلة. عند محاكاة الأداء أظهرت النتائج أن هذه الطريقة تتفوق على خوارزميات DE المتقدمة الأخرى في جميع الحالات تقريباً.

في [47]، قُدمت خوارزمية DE معدلة متعدد الأهداف لتقليل الانبعاثات التلوث وتكلفة الوقود في وقت واحد لمشكلة اصدار الانبعاثات الاقتصادية الديناميكية المدمجة مع محطة طاقة الرياح. تم تصميم مجموعة من طرق الاختيار التي تتضمن الفرز غير المنتظم والفرز القائم على التجميع، مما يتيح أداء فعال في مراحل مختلفة من عملية. تم تطوير تقنية معالجة القيد الإرشادية بشكل أكبر لتحديد موقع جميع أعضاء الحل في فضاء بحث عملية. كشفت دراسات المحاكاة أن الوضع المقترح قدم أداءً جيداً في حل كل من وظائف القياس المعيارية.

من خلال دمج شبكة العصبونات الذكية (artificial neural network ANN) متعدد الأهداف مع DE، أقرحت خوارزمية هجينة في [51]، والتي يمكنها تقريب وحل مشاكل اصدار الانبعاثات الاقتصادية الديناميكية في وقت واحد لتقليل تكلفة وانبعاثات النظام. في [52] أقرحت خوارزمية هجينة تكيفية من DE و ANN لتحسين جودة قرارات تقييم الموارد التي يتخذها نظام التنبؤ السحابي من خلال الضبط الدقيق لبارامترات النظام. خوارزمية أخرى أقرحت في [53] حيث قدم مصنفاً للمشاعر اللغوية قائماً على ANN فقد تم تحسين أفضل تكوين لهيكل الشبكة والبارامترات بواسطة DE. تتضمن بعض البارامترات الحرجة لمصنف المشاعر اللغوية التي تحتاج إلى ضبط دقيق بواسطة DE، أحجام مرشح الالتفاف وأرقام الخلايا العصبية ومعدل التسرب ومعدل التهيئة. في [54] جرى تقديم نموذج بديل هجين لـ DE و ANN لتصنيف البيانات البتروفيزيائية تلقائياً لتحسين إجراءات توصيف المكامن في صناعة النفط. تم تحديد البنية المثلى وإعدادات البارامترات لـ ANN (مثل أنواع التنظيم ووظيفة التنشيط والمحسن) بواسطة DE لإنتاج تصنيف قوي.

بالإضافة إلى ذلك، تم تصميم آلية تحديث واستخدام للخبرة التاريخية لضمان أن الخبرة التاريخية يمكن أن تتراكم بشكل فعال واستخدامها بكفاءة. بالمقارنة مع بعض خوارزميات الذكاء الحديثة، تتميز هذه الخوارزمية بمزايا دقة الحل، وسرعة التقارب، والمتانة في حل مشاكل الصندوق الأسود بسمات غير معروفة. لتقدير الملاءمة على أساس المراجعات المذكورة أعلاه، يلخص الجدول 5 البحث المتعلق بخطط الاختيار المحسنة.

### 3- تهجين خوارزمية DE

التهجين هو نهج شائع آخر يستخدم لتحسين أداء البحث في DE من خلال الاستفادة من نقاط القوة في مشغلي البحث التي يتم الحصول عليها من خوارزميات الذكاء الحسابي الأخرى. في هذا القسم، نركز على الاتجاهات المتنامية في السنوات القليلة الماضية في الأبحاث التي هجنت التعلم الذاتي مع خوارزميات الذكاء الحسابي الأخرى.

#### 4-1 DE مع ANN

الجدول (4) مخططات العبور المحسنة

مؤلف	التقنية المقترحة	الأبعاد	نتائج	مزايا	محددات
[40]	تحسين DE عبر ادخال عامل العبور القائم على الاشعة الذاتية	30، 50	تحسن كبير في الأداء من حيث التعامل مع التوابع أحادية الوسائط	سمحت عمليات التقاطع المقترحة بتوزيع النسل بشكل صحيح وفقاً لخرائط الصلاحية، ويتم توجيهها نحو الحل الأمثل العام دون التأثير على إمكانات البحث.	عدم وجود تفسيرات واضحة بين تأثير الأبعاد مع حجم السكان من الخوارزمية المقترحة.
[41]	مجموعة من الانتواع (speciation) القائمة على إعادة التركيب الحسابي لحل مشاكل الأمثلة متعددة الوسائط	1، 2، 3، 10	تفوقت الخوارزمية، من خلال الكفاءة والمتانة، في حل الوظائف متعددة الوسائط.	تم تنفيذ التحديد مع إعادة التركيب والحساب الاستراتيجية لتحسين سلوكيات البحث الاستغالية والاستكشافية للخوارزمية، على التوالي.	أداء الخوارزمية المقترحة لحل مسائل الأمثلة في العالم الحقيقي غير معروف.
[42]	إستراتيجية عبور (superior-inferior SI) واستراتيجية عبور (superior-superior SS) لتحسين تنوع سكان DE.	30، 50	اعتماد آلية SI التكيفية في خوارزميات DE يمكن أن يحسن الأداء في حل الوظائف المتعددة الوسائط، الأحادية، والأساسية والموسعة في حجم 30 - بعد.	تعزيز نقاط القوة والاستغلال في الخوارزمية المقترحة من قبل مشغلي SI و SS.	يمكن ملاحظة تدهور الأداء للخوارزمية المقترحة عند حل وظائف التكوين الهجينة.
[43]	إستراتيجية عبور متكيف لتحسين أداء DE.	100	تفوقت الاستراتيجية المقترحة على خوارزميات DE الأخرى من حيث دقة البحث.	يمكن أن تؤدي الآلية ذات التكيف الذاتي المقترحة إلى تحسين التنوع السكاني من خلال السماح لكل فرد بالحصول على مزيج فريد من استراتيجيات التبادل واستراتيجية الطفرة ومعلمات التحكم.	لم يتم تحليل قابلية التوسع للطريقة المقترحة بدقة مع مجموعة مختلفة من وظائف الاختبار في أبعاد أعلى.
[44]	تعديل على DE يتكون من مشغل عبور دوار مع إستراتيجية بحث متعددة الزوايا.	30، 60	يمكن لمشغل العبور المقترح في خوارزميات DE تحسين أداء الأمثلة من حيث دقة البحث ومعدل التقارب.	مشغل العبور الدوار بسيط للتنفيذ ويمكن دمجه بسهولة في خوارزميات DE مختلفة.	لم تتم دراسة آثار إعدادات المعلمات المختلفة على أداء الخوارزمية تماماً.
[45]	خوارزمية DE قائمة على التباين مع عبور اختياري لحل تجميع البيانات في مسائل الأمثلة.	غير محدد	متوسط تحسين الأداء حتى 11.98 % من حيث دقة التصنيف.	يمكن لمخطط طفرة DE القابل للتحويل أن يوازن سلوك البحث لخوارزمية DE. يمكن لعامل الطفرة متعدد الأبعاد المقترح أن يعزز جودة حلول النسل.	تعقيد حسابي عالي ناتج عن مهمة تجميع البيانات.

الجدول (5) مخطط الاختيار المحسن

مؤلف	التقنية المقترحة	الأبعاد	نتائج	مزايا	محددات
[46]	مشغل اختيار تكيفي القائم على المخططات (landscape) ودمجه DE	10، 30، 50	تفوقت الطريقة المقترحة على الخوارزميات الأخرى في حل توابع الأغلبية القياسية..	سرعة التقارب السريعة ودقة البحث الجيدة.	تم تحديد إعدادات المعلمة المثلى للخوارزمية المقترحة يدوياً.
[47]	خوارزمية DE معقدة لم يذكر متعدد الأهداف		ولدت الخوارزمية المقترحة أداءً جيداً في مشكلة الفعل	يوفر قيمة أفضل لانبعاث الطاقة بالمقارنة مع خوارزمية الأمثلة الأخرى.	قد تكون الأزمنة الحسابية للطريقة المقترحة غير ممكنة للتطبيق في العالم الحقيقي.
[48]	خوارزمية DE مدمجة مع سياسات معالجة الضجيج	10، 20، 30، 40، 50	تفوقت الخوارزمية المقترحة على جميع الخوارزميات الأخرى في مدة إمكانية البحث في أبعاد مختلفة وحذف الضجيج.	يمكن للطريقة المقترحة تحسين معدل التقارب ودقة البحث في DE.	أقل كفاءة في حل مشاكل الأمثلة مع مخططات الصلاحية المعقدة.
[49]	خوارزمية DE مع قواعد انتهاء معدلة	16، 32	تغلبت الطريقة المقترحة على الخوارزمية الأصلية عند استخدام قواعد إيقاف كلاسيكية.	للخوارزمية استكشاف أفضل في فضاء البحث للتوابع الهدف. وتساعد في تسريع الخوارزمية الأصلية.	كام التركيز على توابع الانتهاء دون المعلمات الأخرى للخوارزمية.
[50]	خوارزمية DE مع الاختيار المستقل لاستراتيجيات الطفرات ومعلمات التحكم	10، 30، 50، 100	تميزت هذه الخوارزمية بمزايا دقة الحل، وسرعة التقارب، والمتانة في حل مشاكل الصندوق الأسود بسمات مجهولة.	استخدام أرشيف الخبرة التاريخية لمزيج من استراتيجيات الطفرات ومعايير التحكم مع ميزات السكان.	تعقيد حسابي عالي، لم يتم اختبار الطريقة المقترحة بشكل كاف في العلم الحقيقي.

الحواف الحادة التي يمكن أن تنتج استجابة تردد حافة حادة جيدة أثناء عملية الترشيح. خوارزمية هجينة أخرى أُقترحت في [58] لحل مشاكل الأمثلة العامة. تم تقديم مخطط تهيئة معدل في هذه الخوارزمية الهجينة لإنتاج مجموعة أولية ذات جودة أفضل يمكن أن تؤدي إلى نتائج تحسين أفضل.

#### 4-3 DE مع Fuzzy Logic

صممت [59] وحدة تحكم تناسبية تفاضلية عن طريق تهجين Fuzzy Logic (FL) و DE لحل مشكلة التحكم في تردد الحمل التي تصادف عادةً في أنظمة الطاقة المترابطة. ساهم الضبط المناسب لمعامل التحكم (أي احتمالية التقاطع وحجم الخطوة) في زيادة أداء الوحدة بشكل كبير. أُقترحت طريقة جديدة لتجزئة الصورة عن طريق تهجين DE و FL

#### 4-2 DE مع PSO

أُقترح في [89] خوارزمية هجينة من DE و PSO لضبط إعدادات البارامترات لوحدة تحكم تناسبي تفاضلي. كانت المفاهيم التي تم تبنيها مفيدة في معالجة مسائل التقارب المبكر لـ PSO و DE، وبالتالي إنتاج وحدة تحكم PID بأداء قوي. خوارزمية هجينة أخرى أُقترحت في [55] لتخطيط مسار للروبوت المتحرك، والذي تمت صياغته كمسألة أمثلة مقيدة متعددة الأهداف. تهجيناً معيارياً قُدّم في [56] لـ DE و PSO، حيث تم إنتاج ما مجموعه 800 متغير هجين بناءً على 16 مشغل تباين أصلي مختلف و 4 مشغلين اختياريين. أُقترحت في [57] خوارزمية هجينة لتحسين تصميم وتصنيع مرشحات

**7-4 DE مع Firefly Algorithm**

أُقرحت [68] خوارزمية هجينة من خوارزمية اليراع Firefly Algorithm (FA) و DE لحل العديد من مشاكل الأمثلة العامة. قُدمت خوارزمية هجينة أخرى FA و DE لحل مهمة جدولة الوظائف في شبكة نظام الحساب عن طريق تعظيم معدلات استخدام الموارد وتقليل تكلفة المعالجة [69]. في [70] جرى تهجين FA مع DE لتطوير تقنية تجميع فعالة حسابياً للأنظمة متعددة العوامل. أُقرحت خوارزمية متكيفة هجينة FA و DE لحل التوطين المستهدف السلبي مع الموازنة المناسبة للاستغلال المحلي وعمليات البحث الاستكشافية العامة خلال مسائل الأمثلة [71].

**8-4 DE مع Ant Colony Optimization**

قُدم تهجين بين Ant Colony Optimization (ACO) مع DE لتحسين إرسال الحمل الاقتصادي لنظام طاقة متكامل مع الطاقة المتجددة لتقليل تكلفة التشغيل [72]. أُقرحت في [73] خوارزمية هجينة لـ ACO و DE لمعالجة المشكلات الشائعة في مسألة جدولة موارد الحوسبة السحابية مثل وقت المعالجة الطويل والتوزيع غير المتكافئ لموارد الحوسبة.

**9-4 DE مع Genetic Algorithm**

قُدمت خوارزمية هجينة من Genetic Algorithm (GA) و DE لحل مسائل جدولة الالتزام (commitment) بالوحد [74]. أُقرحت خوارزمية أمثلة متعددة الأغراض عن طريق تهجين GA و DE لحل تطبيقات الحوسبة السحابية [75].

**10-4 DE مع Uncertainty Handling Technique**

جرى دمج DE مع تقنية معالجة عدم اليقين Uncertainty Handling Technique (UHT) لحل مشاكل جدولة متاجر العمل ذو العائد العشوائي [76].

**10-4 ملخص التهجين**

يظهر تحليل اتجاه التهجين زمنياً أن تهجين DE مع ANN و PSO و FL يظل شائعاً في مجتمع البحث. لوحظت

لتحديد قيم العتبة المثلى مع تقليل التعقيد الحسابي [60]. أُستخدمت خوارزمية هجينة من DE و FL لحل مشاكل التجميع الموفرة للطاقة [61]. كانت المجموعات الضبابية هي فكرة إنشاء مجموعة جديدة لتحديد أفضل عقدة داخل كل مجموعة. قُدمت خوارزمية هجينة من DE و FL لتطوير النماذج المستخدمة لتقدير الجهود المطلوبة لتطوير برامج الكمبيوتر [62].

**4-4 DE مع artificial bee colony**

أُقرحت في [63] خوارزمية هجينة من Artificial Bee Colony (ABC) و DE مع سرعة تقارب محسنة من خلال الاستفادة من تجربة البحث لكل حل في التكرارات السابقة. تم أيضاً دمج مخطط التهيئة المعدل بنظرية الفوضى لتحسين خاصية التقارب العام.

قُدمت خوارزمية هجينة من ABC مع DE لحل تخطيط المسار وتجنب العوائق ومشاكل شائعة في تطبيقات الحوامة الرباعية [64]. كانت ABC مسؤولة عن تعزيز قدرة البحث العامة، بينما تم استخدام DE لإدخال تنوع إضافي لمنع السكان من الوقوع في الحلول المحلية. في [65] أُقرحت طريقة جديدة لاختيار الميزات عن طريق تهجين ABC و DE لحل مشاكل تصنيف البيانات. كانت طريقة اختيار الميزة المقترحة قادرة على تقليل عدد الاستعلامات المرسل إلى قاعدة البيانات بمستويات مختلفة من الخصوصية دون المساس بدقة تصنيف النظام بشكل كبير.

**6-4 DE مع whale optimization algorithm**

أُقرحت خوارزمية هجينة من whale optimization algorithm (WOA) و DE لحل مشكلة تقدير المعلمات لتطبيق النموذج الشمسي [66]. قُدمت خوارزمية أخرى من WOA و DE لتحسين الصورة عن طريق تحسين كثافة البكسل [67]. يتم تحقيق ذلك باستخدام تابع التكلفة مع المعلومات العامة والمحلية.

### 5-2 إعدادات المعلمات

تعد إعدادات المعلمات أحد الأجزاء المهمة لإنتاج الحل الأمثل في أقصر وقت تشغيل. يعتمد أداء DE على إعدادات المعلمة المشتركة لعدد السكان (NP) وعامل الطفرة (F) ومعدل التقاطع (CR) [26,76]. عمل جميع الباحثين على تعديل هذه القيمة بمجموعة متنوعة من الأرقام. أن القيمة المشتركة المحددة على NP هي 100 و F و CR هي 0.5. تعد عمليات تشغيل المحاكاة الإجمالية مهمة لأنه يمكن الحصول على نتائج مختلفة في دورات مختلفة. كانت أقل عمليات تشغيل المحاكاة المستخدمة لتقييم الأداء هي 10، والأعلى هي 100. يفضل معظم الباحثين تعيين 30 و 50 تشغيلاً لعمليات المحاكاة الخاصة بهم.

### 5-3 مقاييس الأداء الأكثر استخداماً

يتم تسجيل مقاييس الأداء على نطاق واسع لجودة الحل ومعدل التقارب، على التوالي. لا يمكن الحكم على جودة الخوارزميات بناءً على عدد قليل من عمليات التشغيل لأن النتيجة قد تختلف عند الخضوع لعدة عمليات تشغيل و يجب إجراء عمليات تشغيل مستقلة إضافية للحصول على متوسط نتائج أكثر دقة. اعتبر بعض الباحثين حلول الجودة فقط وتجاهلوا معدل التقارب والعكس صحيح. بالإضافة إلى ذلك، نظر بعض الباحثين في جودة الحل ومعدل التقارب. تعتمد معايير قياس الأداء على هدف البحث. يميل معظم الباحثين إلى استخدام معدل النجاح والانحراف المعياري ومتوسط الخطأ التريبيعي وجذر متوسط الخطأ التريبيعي ورتبة فريدمان ومتوسط الملاءمة (average fitness) لتقييم دقة الحل الذي تم الحصول عليه أثناء إنهاء الخوارزمية.

### 5- فتح تحديات البحث

### 6-1 استراتيجية الترميز

خوارزميات استخبارات حسابية أخرى مثل WOA و FA و ACO و GA كمرشحين أقل تفضيلاً ليتم تهجينهم مع DE. وفقاً لذلك، تعد ANN و PSO و FL و FA أشهر ذكاء حسابي و تم اختيار الخوارزميات ليتم تهجينها مع DE، كما هو مبين في الأعمال الأخيرة المنشورة في عامي 2020 و 2022. على النقيض من ذلك، تعد ACO و GA اختيارات أقل شيوعاً للمرشحين المستخدمين للتهجين لأنه لم يتم نشر أي أعمال ذات صلة في 2020 أو 2022.

### 4- تحليل أداء DE

يقدم هذا القسم تحليل أداء DE لجودة الحل والاتجاهات في تحسين خوارزمية DE.

### 5-1 توابع اختبار الأداء Benchmark functions

تم تقييم تعديلات DE، أي DE evaluated (EDE)، بمجموعات بيانات أو توابع اختبار معيارية. استخدم معظم الباحثين EDE لحل مسائل الأمثلة، متبوعاً بمسائل التحديد والتجميع. حجم البعد الأكثر شيوعاً المستخدم لتقييم الأداء هو D-30. عملية اختيار المعيار لها تأثير كبير على نتائج EDE. في السابق، استخدم معظم الباحثين Rosenbrock و Rastrigin و Dejong و Griewank و Ackley و Sphere والعديد من توابع الاختبار المعيارية الكلاسيكية لحل نماذجهم الخاصة. تشير الاتجاهات الحديثة إلى أن مجموعات معايير مؤتمر الحساب التطوري Congress of Evolutionary Computation (CEC) أصبحت شائعة في عام 2011 حتى عام 2022. وأحدث معيار تم استخدامه هو CEC 2017 نظراً لفعاليته في تقييم دقة البحث وقوة البحث وأداء الخوارزمية الناجحة. كما أنه متوافق مع حل أنواع مختلفة من الوظائف مثل أحادية الوسائط ومتعددة الوسائط والمقيدة وكبيرة الحجم والمختلطة. ومع ذلك، لم يستخدم أي من الباحثين مجموعات معيار CEC لتقييم مهمة التجميع لأن الخوارزميات المطورة عامة.



الضمني (implicit parallelism) لـ DE ومتغيراته لحل المسائل المتعددة والمتنوعة لـ MFO في وقت واحد في ظل بيئة متعددة المهام لتسريع عملية أمثلة المشكلات المعقدة. يجب معالجة بعض المشكلات الرئيسية لتطوير خوارزمية متعددة المهام فعال وقوية باستخدام DE.

## 6- الخلاصة والنتائج

تقدم هذه الورقة مراجعة حديثة تستند إلى التحسينات في DE، المشار إليها باسم EDE. يتم حساب نسب تحسين الأداء لـ EDE على DE باستثناء بعض الأبحاث التي لم تبلغ عن القيم العددية. تعتبر مقارنة أداء تحسينات DE بين الدراسات المختلفة غير عادلة لأن EDE يعمل في ظروف ومعايير مختلفة. تم تعديل DE من قبل الباحثين لتعزيز فعاليته وكفاءته في حل مشاكل التحسين المختلفة بدءاً من عام 2010. وقد يستمر هذا الاتجاه في الزيادة بشكل كبير في المستقبل بسبب العالمية والاهتمام بالنكاه الاصطناعي وكفاءته في حل المشكلات الهندسية المتعددة. كل هذه المعلومات يمكن أن تساعد الباحثين الجدد في البحث عن تعديلات مناسبة على DE الأصلية، وكذلك الباحثين الخبراء لتطوير مزيد من التحسينات على DE. تظهر النتائج التي توصلنا إليها أن معظم الباحثين استخدموا  $NP = 100$  و  $F$  و  $CR = 0.5$  كإعدادات للمعاملات الخاصة بهم لتنفيذ EDE في مجالات مختلفة. وبالتالي، نقترح هذه القيم كقيم معيارية لمعاملات DE. نهج الموازنة بين عمليتي الاستغلال والاستكشاف في خوارزمية DE مهم أيضاً في منع التقارب المبكر، وبالتالي تحسين جودة الحل النهائية. تعد عينة البيانات الضخمة مهمة أيضاً لأنها يمكن أن تتحقق من دقة الحل. ومع ذلك، فإن مخطط المعالجة السريعة مهم لمعالجة مشكلة الحوسبة البطيئة لهذا النهج.

**التمويل:** هذا البحث ممول من جامعة دمشق وفق رقم التمويل (501100020595).

تلعب إستراتيجية الترميز دوراً مهماً في تمثيل متغيرات القرار لمشكلات الأمثلة المحددة التي يتعين حلها بواسطة خوارزميات DE المختلفة. تُستخدم إستراتيجية الترميز المباشر بشكل شائع في معظم الأدبيات، حيث يتم تمثيل كل متغير قرار أو نمط ظاهري كعنصر جيني لحل محتمل لـ DE. بينما يعتبر مفهوم الترميز المباشر بديهاً وواضحاً في التعامل مع مسائل الأمثلة الشائعة، فإنه يواجه مشكلة الأبعاد في عصر البيانات الضخمة، الأمر الذي يتطلب حل مشكلات الأمثلة المعقدة بأعداد كبيرة جداً من متغيرات القرار [77]، خاصةً مع دفاع العالم في الوقت الحاضر ضد COVID-19، الأمر الذي يتطلب العديد من عينات البيانات [78]. في ظل هذا السيناريو، قد تكافح خوارزميات DE لحل مشكلات الأمثلة على نطاق واسع بدقة مرغوبة أو في غضون فترة زمنية معقولة بسبب التعقيد المفرط الذي ينطوي عليه الأمر.

## 6-2 مشاكل الأمثلة

تم تصميم EAs مثل DE بشكل أساسي لحل مشكلة تحسين واحدة من البداية في وقت واحد. لا يعكس هذا المفهوم فعلياً السيناريو الفعلي لمشاكل الأمثلة في العالم الحقيقي، والتي تتطلب العديد من الوظائف ليتم التعامل معها في نفس الوقت. ظهرت مؤخراً فئة جديدة من المشكلة تُعرف بالتحسين متعدد العوامل multi-factorial optimization (MFO) [79] لمعالجة هذه المشكلة. بشكل عام، تتميز مشكلة القوة المتعددة الأطراف بالوجود المترام لفضاءات بحث متعددة مرتبطة بمهام مختلفة قد تكون أو لا تكون مترابطة مع بعضها البعض. كمثال جيد على MFO هو منصة الحوسبة السحابية، التي تتلقى مهام أمثلة مختلفة من عدة مستخدمين في نفس الوقت. تم إجراء عدد قليل فقط من الدراسات للاستفادة من مزايا EAs في تصميم خوارزمية أمثلة متعددة المهام قادر على حل المسائل المتعددة في MFO في وقت واحد مع تحسين الإنتاجية. يمكن الاستفادة من التوازي

## References:

1. A.N. Azmi, Y. Kamin, M.K. Noordin, A.N.M. Nasir, Towards industrial revolution 4.0: employers' expectations on fresh engineering graduates, *Int. J. Eng. Technol.* 7(4.28) (2018) 267-272. [10.14419/ijet.v7i4.28.22593](https://doi.org/10.14419/ijet.v7i4.28.22593).
2. L. Damiani, M. Demartini, G. Guizzi, R. Revetria, F. Tonelli, Augmented and virtual reality applications in industrial systems: A qualitative review towards the industry 4.0 era, *IFAC-PapersOnLine* 51(11) (2018) 624–630. [10.1016/j.ifacol.2018.08.388](https://doi.org/10.1016/j.ifacol.2018.08.388).
3. N. Oladejo, A. Abolarinwa, S. Salawu, A. Lukman, Optimization principle and its' application in optimizing landmark university bakery production using linear programming, *Int. J. Civ. Eng. Technol. (IJCIET)* 10 (2) (2019) 183–190.
4. J. Kim, K.-K.-K. Kim, Dynamic programming for scalable just-in-time economic dispatch with non-convex constraints and anytime participation, *Int. J. Electr. Power Energy Syst.* 123 (2020), <https://doi.org/10.1016/j.ijepes.2020.106217> 106217.
5. M. Turkyilmazoglu, A simple algorithm for high order Newton iteration formulae and some new variants, *Hacettepe J. Math. Statist.* 49(1) (2020) 425-438. [10.15672/hujms.459810](https://doi.org/10.15672/hujms.459810).
6. A. Jamal, M. Tauhidur Rahman, H.M. Al-Ahmadi, I. Ullah, M. Zahid, Intelligent intersection control for delay optimization: Using meta-heuristic search algorithms, *Sustainability* 12(5) (2020) 1896. [10.3390/su12051896](https://doi.org/10.3390/su12051896).
7. J.D. Schaffer, P.J. Roebber, C. Evans, Development and evaluation of an evolutionary programming-based tropical cyclone intensity model, *Mon. Weather Rev.* 148 (5) (2020) 1951–1970, <https://doi.org/10.1175/MWR-D-19-0346.1>.
8. A. Zahir, S.S.N. Alhady, A. Wahab, M. Ahmad, Objective functions modification of GA optimized PID controller for brushed DC motor, *Int. J. Electrical Comput. Eng.* 10(3) (2020) 2426. [10.11591/ijece.v10i3.pp2426-2433](https://doi.org/10.11591/ijece.v10i3.pp2426-2433).
9. E. Özcan, J.H. Drake, C. Altıntaş, S. Asta, A self-adaptive multimeme memetic algorithm co-evolving utility scores to control genetic operators and their parameter settings, *Appl. Soft Comput.* 49 (2016) 81–93, <https://doi.org/10.1016/j.asoc.2016.07.032>.
10. A.D. Mehr, V. Nourani, E. Kahya, B. Hrnjica, A.M. Sattar, Z. M. Yaseen, Genetic programming in water resources engineering: A state-of-the-art review, *J. Hydrol.* 566 (2018) 643–667, <https://doi.org/10.1016/j.jhydrol.2018.09.043>.
11. S. Li, Q. Gu, W. Gong, B. Ning, An enhanced adaptive differential evolution algorithm for parameter extraction of photovoltaic models, *Energy Convers. Manage.* 205 (2020), <https://doi.org/10.1016/j.enconman.2019.112443>.
12. O. Montiel, O. Castillo, P. Melin, A.R. Dı'az, R. Sepúlveda, Human evolutionary model: A new approach to optimization, *Inf. Sci.* 177 (10) (2007) 2075–2098, <https://doi.org/10.1016/j.ins.2006.09.012>.
13. H. Yu, Y. Tan, J. Zeng, C. Sun, Y. Jin, Surrogate-assisted hierarchical particle swarm optimization, *Inf. Sci.* 454 (2018) 59–72, <https://doi.org/10.1016/j.ins.2018.04.062>.
14. J. Uthayakumar, N. Metawa, K. Shankar, S. Lakshmanaprabu, Financial crisis prediction model using ant colony optimization, *Int. J. Inf. Manage.* 50 (2020) 538–556, <https://doi.org/10.1016/j.ijinfomgt.2018.12.001>.
15. J. Chen, W. Yu, J. Tian, L. Chen, Z. Zhou, Image contrast enhancement using an artificial bee colony algorithm, *Swarm Evol. Comput.* 38 (2018) 287–294, <https://doi.org/10.1016/j.swevo.2017.09.002>.
16. H. Wang, W. Wang, X. Zhou, H. Sun, J. Zhao, X. Yu, Z. Cui, Firefly algorithm with neighborhood attraction, *Inf. Sci.* 382 (2017) 374–387, <https://doi.org/10.1016/j.ins.2016.12.024>.
17. T.V. Luu, N.S. Nguyen, Parameters extraction of solar cells using modified JAYA algorithm, *Optik* 203 (2020), <https://doi.org/10.1016/j.ijleo.2019.164034> 164034.

18. A.K. Shukla, P. Singh, M. Vardhan, An adaptive inertia weight teaching-learning-based optimization algorithm and its applications, *Appl. Math. Model.* 77 (2020) 309–326, <https://doi.org/10.1016/j.apm.2019.07.046>.
19. Q. Askari, I. Younas, M. Saeed, Political Optimizer: A novel socio-inspired meta-heuristic for global optimization, *Knowl.- Based Syst.* 195 (2020), <https://doi.org/10.1016/j.knosys.2020.105709>.
20. Z.-K. Feng, S. Liu, W.-J. Niu, S.-S. Li, H.-J. Wu, J.-Y. Wang, Ecological operation of cascade hydropower reservoirs by eliteguide gravitational search algorithm with Levy flight local search and mutation, *J. Hydrol.* 581 (2020), <https://doi.org/10.1016/j.jhydrol.2019.124425>.
21. B. Xing, W.-J. Gao, Electromagnetism-like Mechanism Algorithm, *Innovative Computational Intelligence: A Rough Guide to 134 Clever Algorithms*, Springer 2014, pp. 347–354. 10.1007/978-3-319-03404-1\_21.
22. R. Storn, K. Price, Differential Evolution – A Simple and Efficient Heuristic for global Optimization over Continuous Spaces, *J. Global Optim.* 11 (4) (1997) 19, <https://doi.org/10.1023/A:1008202821328>.
23. K. Price, R.M. Storn, J.A. Lampinen, *Differential evolution: a practical approach to global optimization*, Springer Science & Business Media, 2006.
24. A.K. Qin, V.L. Huang, P.N. Suganthan, Differential evolution algorithm with strategy adaptation for global numerical optimization, *IEEE Trans. Evol. Comput.* 13 (2) (2008) 398–417, <https://doi.org/10.1109/TEVC.2008.927706>.
25. M. Pant, H. Zaheer, L. Garcia-Hernandez, A. Abraham, Differential Evolution: A review of more than two decades of research, *Eng. Appl. Artif. Intell.* 90 (2020), <https://doi.org/10.1016/j.engappai.2020.103479>.
26. F. Neri, V. Tirronen, Recent advances in differential evolution: a survey and experimental analysis, *Artif. Intell. Rev.* 33 (1) (2010) 61–106, <https://doi.org/10.1007/s10462-009-9137-2>.
27. P. Xiao, D. Zou, Z. Xia, X. Shen, Multi-strategy different dimensional mutation differential evolution algorithm, in: *AIP Conference Proceedings*, AIP Publishing LLC, 2019, p. 020102.
28. S. Rahnamayan, H.R. Tizhoosh, M.M. Salama, A novel population initialization method for accelerating evolutionary algorithms, *Comput. Math. Appl.* 53 (10) (2007) 1605–1614, <https://doi.org/10.1016/j.camwa.2006.07.013>.
29. A.B. Ozer, CIDE: chaotically initialized differential evolution, *Expert Syst. Appl.* 37 (6) (2010) 4632–4641, <https://doi.org/10.1016/j.eswa.2009.12.045>.
30. V.V. de Melo, A.C.B. Delbem, Investigating smart sampling as a population initialization method for differential evolution in continuous problems, *Inf. Sci.* 193 (2012) 36–53, <https://doi.org/10.1016/j.ins.2011.12.037>.
31. W. Zhu, Y. Tang, J.-A. Fang, W. Zhang, Adaptive population tuning scheme for differential evolution, *Inf. Sci.* 223 (2013) 164–191, <https://doi.org/10.1016/j.ins.2012.09.019>.
32. D. Bajer, G. Martinovic, J. Brest, A population initialization method for evolutionary algorithms based on clustering and Cauchy deviates, *Expert Syst. Appl.* 60 (2016) 294–310, <https://doi.org/10.1016/j.eswa.2016.05.009>.
33. S.M. Islam, S. Das, S. Ghosh, S. Roy, P.N. Suganthan, An adaptive differential evolution algorithm with novel mutation and crossover strategies for global numerical optimization, *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)* 42 (2) (2011) 482–500, <https://doi.org/10.1109/TSMCB.2011.2167966>.
34. W. Gong, Z. Cai, Differential evolution with ranking-based mutation operators, *IEEE Trans. Cybern.* 43 (6) (2013) 2066–2081, <https://doi.org/10.1109/TCYB.2013.2239988>.
35. Q. Fan, X. Yan, Self-adaptive differential evolution algorithm with discrete mutation control parameters, *Expert Syst. Appl.* 42 (3) (2015) 1551–1572, <https://doi.org/10.1016/j.eswa.2014.09.046>.

36. M.Z. Ali, N.H. Awad, P.N. Suganthan, Multi-population differential evolution with balanced ensemble of mutation strategies for large-scale global optimization, *Appl. Soft Comput.* 33 (2015) 304–327, <https://doi.org/10.1016/j.asoc.2015.04.019>.
37. S. Wang, Y. Li, H. Yang, Self-adaptive mutation differential evolution algorithm based on particle swarm optimization, *Appl. Soft Comput.* 81 (2019), <https://doi.org/10.1016/j.asoc.2019.105496> 105496.
38. G. Sun, Y. Lan, R. Zhao, Differential evolution with Gaussian mutation and dynamic parameter adjustment, *Soft. Comput.* 23 (5) (2019) 1615–1642, <https://doi.org/10.1007/s00500-017-2885-z>.
39. M. Attia, M. Arafa, E. Sallam, M. Fahmy, An enhanced differential evolution algorithm with multi-mutation strategies and self-adapting control parameters, *Int. J. Intell. Syst. Appl.* 10 (4) (2019) 26, <https://doi.org/10.5815/ijisa.2019.04.03>.
40. S.-M. Guo, C.-C. Yang, Enhancing differential evolution utilizing eigenvector-based crossover operator, *IEEE Trans. Evol. Comput.* 19 (1) (2014) 31–49, <https://doi.org/10.1109/TEVC.2013.2297160>.
41. S. Hui, P.N. Suganthan, Ensemble and arithmetic recombination-based speciation differential evolution for multimodal optimization, *IEEE Trans. Cybern.* 46 (1) (2015) 64–74, <https://doi.org/10.1109/TCYB.2015.2394466>.
42. Y. Xu, J.-A. Fang, W. Zhu, X. Wang, L. Zhao, Differential evolution using a superior–inferior crossover scheme, *Comput. Optimiz. Appl.* 61 (1) (2015) 243–274, <https://doi.org/10.1007/s10589-014-9701-9>.
43. Q. Fan, Y. Zhang, Self-adaptive differential evolution algorithm with crossover strategies adaptation and its application in parameter estimation, *Chemometr. Intell. Lab. Syst.* 151 (2016) 164–171, <https://doi.org/10.1016/j.chemolab.2015.12.020>.
44. L.-B. Deng, S. Wang, L.-Y. Qiao, B.-Q. Zhang, DE-RCO: rotating crossover operator with multiangle searching strategy for adaptive differential evolution, *IEEE Access* 6 (2017) 2970–2983, <https://doi.org/10.1109/ACCESS.2017.2786347>.
45. M. Alswaitti, M. Albughdadi, N.A.M. Isa, Variance-based differential evolution algorithm with an optional crossover for data clustering, *Appl. Soft Comput.* 80 (2019) 1–17, <https://doi.org/10.1016/j.asoc.2019.03.013>.
46. K.M. Sallam, S.M. Elsayed, R.A. Sarker, D.L. Essam, Landscape-based adaptive operator selection mechanism for differential evolution, *Inf. Sci.* 418 (2017) 383–404, <https://doi.org/10.1016/j.ins.2017.08.028>.
47. B. Qu, J.J. Liang, Y. Zhu, P.N. Suganthan, Solving dynamic economic emission dispatch problem considering wind power by multi-objective differential evolution with ensemble of selection method, *Nat. Comput.* 18 (4) (2019) 695–703, <https://doi.org/10.1007/s11047-016-9598-6>.
48. P. Rakshit, Improved differential evolution for noisy optimization, *Swarm Evol. Comput.* 52 (2020) 100628, <https://doi.org/10.1016/j.swevo.2019.100628>.
49. Charillogis, V.; Tsoulos, I.G.; Tzallas, A.; Karvounis, E. Modifications for the Differential Evolution Algorithm. *Symmetry* **2022**, *14*, 447. <https://doi.org/10.3390/sym14030447>
50. Zhenyu Wang, Zijian Cao, Zhiqiang Du, Haowen Jia, Binhui Han, Feng Tian, Fuxi Liu, "Differential Evolution with Autonomous Selection of Mutation Strategies and Control Parameters and Its Application", *Complexity*, vol. 2022, Article ID 7275088, 18 pages, 2022. <https://doi.org/10.1155/2022/7275088>
51. K. Mason, J. Duggan, E. Howley, A multi-objective neural network trained with differential evolution for dynamic economic emission dispatch, *Int. J. Electr. Power Energy Syst.* 100 (2018) 201–221, <https://doi.org/10.1016/j.ijepes.2018.02.021>.
52. J. Kumar, A.K. Singh, Workload prediction in cloud using artificial neural network and adaptive differential evolution, *Future Generation Comput. Syst.* 81 (2018) 41–52, <https://doi.org/10.1016/j.future.2017.10.047>.

53. A. Dahou, M.A. Elaziz, J. Zhou, S. Xiong, Arabic sentiment classification using convolutional neural network and differential evolution algorithm, *Computat. Intell. Neurosci.* 2019 (2019), <https://doi.org/10.1155/2019/2537689>.
54. C.M. Saporetti, L. Goliatt, E. Pereira, Neural network boosted with differential evolution for lithology identification based on well logs information, *Earth Sci. Inf.* 14 (1) (2021) 133–140, <https://doi.org/10.1007/s12145-020-00533-x>.
55. J.-H. Zhang, Y. Zhang, Y. Zhou, Path planning of mobile robot based on hybrid multi-objective bare bones particle swarm optimization with differential evolution, *IEEE Access* 6 (2018) 44542–44555, <https://doi.org/10.1109/ACCESS.2018.2864188>.
56. R. Boks, H. Wang, T. Ba" ck, A modular hybridization of particle swarm optimization and differential evolution, in: *Proceedings of the 2020 Genetic and Evolutionary Computation Conference Companion*, 2020, pp. 1418–1425.
57. J. Dash, B. Dam, R. Swain, Design and implementation of sharp edge FIR filters using hybrid differential evolution particle swarm optimization, *AEU-Int. J. Electron. Commun.* 114 (2020), <https://doi.org/10.1016/j.aeue.2019.153019>
58. Z.C. Choi, K.M. Ang, W.H. Lim, S.S. Tiang, C.K. Ang, M.I. Solihin, M.R.M. Juhari, C.E. Chow, Hybridized Metaheuristic Search Algorithm with Modified Initialization Scheme for Global Optimization, *Advances in Robotics, Automation and Data Analytics: Selected Papers from ICITES 2020* 1350 (2021) 172. 10.1007/978-3-030-70917-4\_17.
59. D.K. Sahoo, R.K. Sahu, G.C. Sekhar, S. Panda, A novel modified differential evolution algorithm optimized fuzzy proportional integral derivative controller for load frequency control with thyristor controlled series compensator, *J. Electr. Syst. Inf. Technol.* 5 (3) (2018) 944–963, <https://doi.org/10.1016/j.jesit.2016.12.003>.
60. A. Dixit, A. Mani, R. Bansal, Image Segmentation using Hybrid Differential evolution algorithm with Fuzzy Entropy, 2018 4th International Conference on Computing Communication and Automation (ICCCA), IEEE, 2018, pp. 1-6.
61. R. Sharma, V. Vashisht, U. Singh, EEFCM-DE: energyefficient clustering based on fuzzy C means and differential evolution algorithm in WSNs, *IET Commun.* 13 (8) (2019) 996–1007, <https://doi.org/10.1049/iet-com.2018.5546>.
62. A. Karimi, T.J. Gandomani, Software development effort estimation modeling using a combination of fuzzy-neural network and differential evolution algorithm, *Int. J. Electr. Comput. Eng.* (2088-8708) 11(1) (2021). 10.11591/ijece.v11i1.pp707-715.
63. W.-F. Gao, L.-L. Huang, J. Wang, S.-Y. Liu, C.-D. Qin, Enhanced artificial bee colony algorithm through differential evolution, *Appl. Soft Comput.* 48 (2016) 137–150, <https://doi.org/10.1016/j.asoc.2015.10.070>
64. C. Haohao, Q.i. Xiaohui, Y. Sen, Obstacle Avoidance and Path Planning for Quadrotor based on Differential EvolutionArtificial Bee Colony Algorithm, *J. Phys.: Conference Series*, IOP Publishing 1087 (2018) 022030, <https://doi.org/10.1088/1742-6596/1087/2/022030>.
65. E. Zorapacı, S.A. O" zel, Differentially private IR classification algorithm using artificial bee colony and differential evolution, *Eng. Appl. Artif. Intell.* 94 (2020), <https://doi.org/10.1016/j.engappai.2020.103813> 103813.
66. G. Xiong, J. Zhang, X. Yuan, D. Shi, Y. He, G. Yao, Parameter extraction of solar photovoltaic models by means of a hybrid differential evolution with whale optimization algorithm, *Sol. Energy* 176 (2018) 742–761, <https://doi.org/10.1016/j.solener.2018.10.050>.
67. S. Dhabal, D.K. Saha, Image enhancement using differential evolution based whale optimization algorithm, *Emerging Technology in Modelling and Graphics*, Springer, 2020, pp. 619–628. 10.1007/978-981-13-7403-6\_54.

68. S. Sarbazfard, A. Jafarian, A hybrid algorithm based on firefly Igorithm and differential evolution for global optimization, *Int. J. Adv. Comput. Sci. Appl.* 7(6) (2016) 95–106. 10.14569/ijacsa.2016.070612.
69. T.K. Ghosh, S. Das, A novel hybrid algorithm based on firefly algorithm and differential evolution for job scheduling in computational grid, *Int. J. Distributed Syst. Technol. (IJDST)* 9 (2) (2018) 1–15, <https://doi.org/10.4018/IJDST.2018040101>.
70. M. Anuradha, V. Ganesan, S. Oliver, T. Jayasankar, R. Gopi, Hybrid firefly with differential evolution algorithm for multi agent system using clustering based personalization, *J. Ambient Intell. Hum. Comput.* 12 (6) (2021) 5797–5806, <https://doi.org/10.1007/s12652-020-02120-w>.
71. M.B. Rosic´, M.I. Simic´, P.V. Pejovic´, An improved adaptive hybrid firefly differential evolution algorithm for passive target localization, *Soft. Comput.* 25 (7) (2021) 5559–5585, <https://doi.org/10.1007/s00500-020-05554-8>.
72. N. Rahmat, N. Aziz, M. Mansor, I. Musirin, Optimizing economic load dispatch with renewable energy sources via differential evolution immunized ant colony optimization technique, *Int. J. Adv. Sci. Eng. Inf. Technol* 7(6) (2017)2012. 10.18517/ijaseit.7.6.2328.
73. A. Trivedi, D. Srinivasan, S. Biswas, T. Reindl, A genetic algorithm–differential evolution based hybrid framework: case study on unit commitment scheduling problem, *Inf. Sci.* 354 (2016) 275–300, <https://doi.org/10.1016/j.ins.2016.03.023>.
74. Y. Li, S. Wang, X. Hong, Y. Li, Multi-objective task scheduling optimization in cloud computing based on genetic algorithm and differential evolution algorithm, 2018 37<sup>th</sup> Chinese Control Conference (CCC), IEEE, 2018, pp. 4489-4494.
75. Rong Hu, Xing Wu, Bin Qian, Jianlin Mao, Huaiping Jin, "Differential Evolution Algorithm Combined with Uncertainty Handling Techniques for Stochastic Reentrant Job Shop Scheduling Problem", *Complexity*, vol. 2022, Article ID 9924163, 11 pages, 2022. <https://doi.org/10.1155/2022/9924163>
76. S. Das, P.N. Suganthan, Differential evolution: A survey of the state-of-the-art, *IEEE Trans. Evol. Comput.* 15 (1) (2010) 4–31, <https://doi.org/10.1109/TEVC.2010.2059031>.
77. X. Liu, Analyzing the impact of user-generated content on B2B Firms' stock performance: Big data analysis with machine learning methods, *Ind. Mark. Manage.* 86 (2020) 30–39, <https://doi.org/10.1016/j.indmarman.2019.02.021>.
78. D. Ding, B. del Pozo Cruz, M.A. Green, A.E. Bauman, Is the COVID-19 lockdown nudging people to be more active: a big data analysis, *BMJ Publishing Group Ltd and British Association of Sport and Exercise Medicine*, 2020.
79. S. Yao, Z. Dong, X. Wang, L. Ren, A multiobjective multifactorial optimization algorithm based on decomposition and dynamic resource allocation strategy, *Inf. Sci.* 511 (2020) 18–35, <https://doi.org/10.1016/j.ins.2019.09.058>.
80. Nathan S. Nichols Paul Sokol, Adrian Del Maestro A Parameter-Free Differential Evolution Algorithm for the Analytic Continuation of Imaginary Time Correlation Functions, arXiv:2201.04155v1 [cond-mat.stat-mech] 11 Jan 2022
81. Chi Che, Application of Differential Evolution Algorithm in the Construction and Simulation of Interactive English Translation Teaching Mode, *Hindawi Advances in Multimedia* Volume 2022, Article ID 6182551, <https://doi.org/10.1155/2022/618255>
82. S.Dash, S.Mishra, Y. Abdelaziz, Optimal Allocation of Distributed Generators in Active Distribution Networks Using a New Oppositional Hybrid Sine Cosine Muted Differential Evolution Algorithm, *Energies* 2022, 15, 2267. <https://doi.org/10.3390/en15062267>