

## دراسة تأثير استخدام الخوارزميات التطورية في تخفيض استهلاك الطاقة في أنظمة الزمن الحقيقي

\* أ.د. محمد حجازية

\*\* م. يوسف نتيفة

### المخلص

تم في هذا البحث استخدام الخوارزميات التطورية للبحث عن أقل قيمة تردد عمل لمعالج في نظام زمن حقيقي لتخفيض استهلاك الطاقة مع الحفاظ على أداء النظام، وتم التركيز على ثلاث خوارزميات تطورية متشابهة، الخوارزمية الجينية GA وخوارزمية تحسين سرب الجسيمات PSO وخوارزمية التطور التفاضلي DE. ثم تم تقديم لمحة موجزة عن كل من الخوارزميات التطورية الثلاث وتم التركيز على الإجراءات الحسابية المتعلقة بالأداء كما تمت مناقشة أوجه الاختلاف والتباين بين الخوارزميات وفقاً لبساطة خطوات العمل وسرعة الوصول للنتائج، ثم تم اختبار الخوارزميات الثلاث في البحث عن أقل قيمة تردد عمل للمعالج وتبين أن خوارزمية PSO هي الأبسط والأسرع بالوصول لنتائج جيدة بما يساعد في تخفيض استهلاك النظام للطاقة.

### الكلمات المفتاحية

الخوارزمية التطورية، الخوارزمية الجينية، خوارزمية تحسين سرب الجسيمات، خوارزمية التطور التفاضلي.

\*أستاذ في قسم هندسة الحاسبات والتحكم الآلي - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين.

الإيميل: [mohammed.hejazieh2016@gmail.com](mailto:mohammed.hejazieh2016@gmail.com)

\*\*طالب دكتوراه في قسم هندسة الحاسبات والتحكم الآلي - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين.

الإيميل: [youssef.ntefeh@gmail.com](mailto:youssef.ntefeh@gmail.com)

# Studying The Effect Of Using Evolutionary Algorithms In Reducing Energy Consumption In Real-Time Systems

\* Prof.Dr. Mohammed Hijazieh

\*\* Eng. Youssef Ntefeh

## **Abstract.**

In this paper, evolutionary algorithms were used to search for the lowest frequency value that maintains system performance and reduce power consumption. Three similar evolutionary algorithms were focused on: the Genetic Algorithm (GA), the Particle Swarm Optimization algorithm (PSO) and the Differential Evolution algorithm (DE). A brief overview of each of the three evolutionary algorithms was presented, and the focus was on the computational procedures related to performance. The differences and variances between the algorithms were also discussed, according to the simplicity of implementation, the speed of reaching solutions. Then the three algorithms were tested in searching for the lowest frequency. It was found that the PSO algorithm was the simplest and fastest to reach a good results, which helps in reducing system power consumption.

## **Keywords**

Evolutionary Algorithm, Genetic Algorithm, Particle Swarm Optimization, Differential Evolution Algorithm.

## 1. مقدمة

تستخدم خوارزميات التحسين بشكل واسع في مختلف التطبيقات ونظراً لمحدودية قدرة الخوارزميات الكلاسيكية على التعامل مع العمليات الرياضية المعقدة فقد توجه الباحثون نحو خوارزميات التحسين المستوحاة من الطبيعة، وفي هذا النوع من الخوارزميات تتم تهيئة مجموعة من الحلول عشوائياً وتقوم الخوارزمية بتقييم ملاءمتهم ومن ثم دفعهم باتجاه الحل الأمثل، ومنذ أن نشر Holland كتابه [1] عن الخوارزمية الجينية عام 1975، إحدى أهم خوارزميات التحسين الحديثة، قدم الباحثين خوارزميات عديدة من الخوارزميات مثل Tabu Search [2] عام 1986، وخوارزمية تحسين سرب الجسيمات PSO [3,4] وخوارزمية التطور التفاضلي DE [5] عام 1995 وخوارزمية مستعمرة النمل ACO [6] عام 1999.

قارن الباحثون في الدراسات السابقة [7,8,9] بين مختلف خوارزميات التحسين ولكن كان التركيز في أغلبها على المقارنة التجريبية باستخدام اختبارات أداء صناعية أو تطبيقات محددة ولم يفسر الباحثون سبب أداء بعض الخوارزميات بشكل جيد في أحد التطبيقات دون الآخر ولم يحددوا الخصائص التي جعلت خوارزمية معينة تتفوق على أخرى.

أكد الباحثون في [10] أنه لا يوجد خوارزمية كاملة ولكل منها محاسن ومساوئ، وبالنتيجة فإن الخوارزميات تكون فعالة في حل بعض وليس كل مشاكل التحسين مما يجعل عملية المقارنة ضرورية لمعرفة أي الخوارزميات تناسب حالة معينة، وبناء عليه تمت دراسة ثلاث خوارزميات في هذا البحث وهم الخوارزمية الجينية وخوارزمية تحسين سرب الجسيمات وخوارزمية التطور التفاضلي، وبسبب طبيعتها في إنتاج حلول في مجال قيم مستمرة، حظيت خوارزمتا تحسين سرب الجسيمات والتطور التفاضلي باهتمام أكبر

مؤخراً بسبب قابليتها للتطبيق على مجالات أوسع وأكثر محاكاةً للأمثلة الطبيعية من الخوارزمية الجينية.

تتمحور هذه الدراسة حول إجراء مقارنة نوعية عامة للخوارزميات التطورية الثلاثة بناءً على ثلاثة معايير وهي جودة الحل وسرعة الوصول إليه وبساطة الخوارزمية، وتم التركيز على عناصر العمليات المطلوبة وتأثيرها على قدرات التنويع والتكثيف الخاصة بكل خوارزمية.

تم ترتيب بقية البحث على الشكل التالي: وصف مفهوم الخوارزميات التطورية بشكل عام لتسليط الضوء على العناصر المشتركة بين جميع الخوارزميات ثم وصف الخوارزميات الثلاث محل الدراسة وإبراز أوجه التشابه والاختلاف في الفصل الثالث تمت المقارنة النظرية وإجراء التجارب للمقارنة العملية، وفي القسم الرابع و الأخير تمت مناقشة النتائج و التوصيات.

## 1.1 مشكلة البحث

تعتمد أغلب أنظمة الزمن الحقيقي الحديثة المحمولة في تشغيلها على مصدر طاقة محدود [11] وبالتالي يجب تصميم النظام بحيث يحقق أكبر استغلالاً للطاقة المتوفرة، ولتقليل استهلاك الطاقة الديناميكية في معالج النظام يجب تخفيض تردد العمل إلى أقل قيمة ممكنة دون أن يتأثر أداء النظام.

## 2.1 أهمية البحث

إن المقارنة التي تم إجراؤها في هذا البحث حددت معايير تقييم ومقارنة الخوارزميات التطورية وتم تحديد نقاط القوة والضعف لكل من الخوارزميات المدروسة ومدى تأثير البارامترات العشوائية لكل خوارزمية على كثافة وتنوع أجيال الحلول وطريقة ضبطها لتناسب الحالة المدروسة.

### 3.1 أهداف البحث

تهدف الدراسة إلى إيجاد الخوارزمية التطورية الأفضل من بين ثلاث خوارزميات (GA, PSO, DE) للبحث عن أقل قيمة تردد يمكن للمعالج في نظام الزمن الحقيقي العمل بها بما يحقق تخفيض استهلاك الطاقة دون أن يتراجع أداء النظام وذلك بمقارنة عدد المهام التي تفشل بتحقيق الحد الزمني النهائي لها. وتم اعتماد معيار الأفضلية من خلال بساطة العمليات الرياضية للخوارزمية وقدرتها على الوصول إلى حل مقبول بأقل عدد تكرارات وذلك بهدف تقليل زمن تشغيل المعالج لتوفير الطاقة المستهلكة.

### 4.1 فرضيات البحث

- إن تقليل تردد عمل المعالج يؤدي إلى تقليل استهلاك الطاقة في النظام.
- يمكن استخدام الخوارزميات التطورية لإيجاد أقل تردد عمل للمعالج يضمن الحفاظ على أداء النظام.
- خوارزمية جدولة المهام LLREF هي الأقل استهلاكاً للطاقة عند العمل على منصة متعددة المعالجات.

### 5.1 مواد و طرق البحث

تم استخدام برنامج Matlab2018 لبناء النموذج الرياضي للنظام وتوليد مجموعة مهام نظام الزمن الحقيقي واختبار أداء الخوارزميات التطورية المدروسة [12].

تم الاختبار على معالج Intel Core i5-2410M ثنائي النوى بتردد أعظمي 2.6 GHz وذاكرة وصول عشوائي 8Gb.


## 2. وصف عام للخوارزميات التطورية

تتشترك الخوارزميات التطورية بوجود ثلاث مراحل رئيسية، حيث تبدأ المرحلة الأولى بالتهيئة، وهي التوليد العشوائي للجيل الأول من الأفراد وفقاً لشروط ابتدائية تختلف باختلاف الخوارزمية، ويمثل الفرد أحد الحلول المقترحة بشكل مباشر أو غير مباشر ومهما كان مدى بعده عن الجواب الأمثل فهو لا يزال يعتبر حلاً ولكن بنسبة خطأ كبيرة. إذا تم اعتماد التمثيل غير المباشر فإذاً يجب ترميز الأفراد بشكل حلول الخوارزمية ثم يعاد فك ترميزها بعد انتهاء عمل الخوارزمية. يتم في المرحلة الثانية تقييم كل حلول الجيل الأول باستخدام تابع ملائمة خاص بالمسألة المدروسة، ويمكن استخدام قيم الملائمة الفردية إما لاستنتاج قيمة ملائمة الجيل ككل أو لتقييم مدى ملائمة الأفراد بغرض الاختيار في ما بينها. المرحلة الثالثة والأخيرة هي توليد جيل جديد عن طريق خلق اضطراب معين في الجيل الأول [13]. يوضح الشكل (1) المراحل الثلاث للخوارزمية التطورية.

يتم تقييم أفراد الجيل الأول بعد التهيئة ثم يتم فحص شروط التوقف فإذا لم يتحقق أي منها يتم توليد جيل جديد، وتكرر العملية حتى تحقق أحد شروط التوقف التي قد تكون إما ساكنة مثل عدد تكرارات معين، أو ديناميكية مثل وصول نسبة معينة من الحلول إلى القيمة المثلى للجيل الحالي.

عند استخدام الخوارزميات التطورية في مسائل إيجاد الحل الأمثل، يجب في البداية تحديد كيفية تمثيل الحل وفقاً لعناصر الخوارزمية التطورية المتبعة، قد تنتج عملية التهيئة وتوليد الأجيال الجديدة حلولاً غير مجدية، لذلك يجب اختيار تمثيل للحلول يكون أكثر ترجيحاً لإنتاج أجيال من الحلول المجدية، ويعتبر تمثيل الحل من عوامل التصميم المشتركة بين كل الخوارزميات التطورية. يمكن أن يكون تمثيل الحلول مباشراً أو غير مباشر والاعتبار

الأهم في التصميم هو أن تكون كلاً من الحلول المولدة قابل دائماً لفك ترميزه إلى حلول مجدية. يستخدم التمثيل غير المباشر في المسائل المعقدة إلى جانب إجراءات فك الترميز لتحويل التمثيل غير المباشر إلى حل مجدي وبمجرد فك ترميز الحل يمكن حساب ملائمة الحلول. بالإضافة إلى تمثيل الحل يجب تحديد بارامترات إضافية عند التهيئة، وهي حجم الجيل والعدد الأعظمي للتكرارات، واختيار هذين العنصرين تأثيراً كبيراً على نوعية الحلول وزمن الوصول لها، ويتم عادة تحديد قيم هذه العناصر من خلال التجربة.




الشكل (1): مخطط تدفقي لخوارزمية تطورية

## 1.2 الخوارزمية الجينية (Genetic Algorithm (GA))

تعود أصول اكتشاف الخوارزمية الجينية إلى العام 1975 بواسطة Holland [1] الذي قدمها بشكل مبسط وبأسلوب قابل للتطبيق العملي على مسائل رياضية، ويوضح الشكل (2) المخطط التدفقي للخوارزمية.

بداية يتم اختيار زوج من العناصر للتزاوج من الجيل الحالي بناءً على قيم ملائمتهم، حيث يزداد احتمال الارتباط للعناصر الأكثر ملائمة لتكون الآباء التي تنتج أبناء (كروموسومات) جديدة، وتتم عملية الاختيار باستخدام الترتيب النسبي لقيم الملاءمة، وبمجرد اختيار الكروموسومات الآباء يجمع عامل التصالب بين الوالدين لتوليد عنصرين أبناء بتطبيق العمليات الجينية ويتم وضع العنصرين الجدد في الجيل الجديد ويتكرر الجمع بين الآباء حتى وصول عدد الجيل الجديد إلى عدد الجيل الأب فيستبدل الجيل الأب بالجيل الابن ويتم تكرار جميع الخطوات السابقة منذ البداية وحتى تحقق أحد شروط التوقف، وعلى اعتبار أن عملية الاختيار تكون دائماً للعناصر الأكثر ملائمة، تميل الأجيال الجديدة إلى التشابه بعد عدة تكرارات وينخفض التنوع وقد يؤدي إلى ركود في أجيال الأبناء مما يستدعي إدخال طفرات على الأبناء لتحفيز التنوع.



الشكل (2): مخطط تدفقي للخوارزمية الجينية

تحتوي الخوارزمية على عدد من بارامترات التحكم مثل حجم الجيل، وأكبر عدد من التكرارات، وطريقة الانتقاء التي تعتمد على تابع الملاءمة لضمان توازن تنوع الجيل الجديد وتطور الحلول نحو قيم مجدية. تحتوي الدراسات السابقة [14] على العديد من طرق الانتقاء وأكثرها شهرةً هي طريقة Roulette wheel وطريقة Tournament وطريقة Elitist. أما المجموعة الثانية من البارامترات فهي طريقة التصالب والثالثة هي طريقة حقن الطفرات بحيث تساعد في الحفاظ على تنوع الجيل وذلك بحقن عناصر جديدة في الكروموسومات، ويتم ضبط هذه البارامترات الثلاث عن طريق التجربة.


بناءً على ما سبق يتبين أن الخوارزمية الجينية هي عملية تكرارية تنتج جيلاً جديداً في كل تكرار، ويقترح الباحثون في [15] أن يكون عدد الأجيال أو التكرارات بين (50-500) ثم يتم فحص قيم ملائمة أفضل الكروموسومات فإذا لم تحقق الملائمة المطلوبة يعاد تشغيل الخوارزمية.

## 2.2 خوارزمية تحسين سرب الجسيمات (Particle Swarm Optimization (PSO))

عند دراسة القواعد التي يتبعها سرب الأسماك أو سرب الطيور والتي تسمح لهم بالقيام بحركات متزامنة دون الاصطدام ببعضها، تبين وجود مشاركة للمعلومات بين أفراد السرب مما يشير إلى ميزة تطورية، وكانت هذه هي الفكرة الرئيسية التي أوحى للباحثين بتطوير خوارزمية تحسين سرب الجسيمات PSO.

تلا نشر الدراسات [3,4] التي قدمت أول نموذج لخوارزمية PSO في عام 1995 العديد من الدراسات التي بحثت في تطبيقات ناجحة للخوارزمية لحل مشاكل الأمثلة الصعبة وقد جذبت خوارزمية PSO الباحثين بسبب بساطتها وقلة التعقيد الحسابي فيها وقد سهل فهمها عند تشبيهها لسرب من الطيور تبحث عن هدف معين كالغذاء. يوضح الشكل (3) مراحل الخوارزمية.

يتم تمثيل الحلول في خوارزمية PSO على شكل جسيمات ويطلق على الجيل اسم سرب الجسيمات يتم تهيئتها عشوائياً وتركها لتبحث بحرية في فضاء الحلول متعدد الأبعاد، ولكل جسيم خاصيتين أساسيتين هما الموقع والسرعة، يتحرك كل جسيم نحو الموقع الجديد بواسطة شعاع السرعة وبمجرد وصول الجسيم إلى الموقع الجديد يتم تحديث قيم أفضل موقع لكل جسيم وأفضل موقع للسرب، ثم يتم تعديل اتجاه شعاع السرعة بناءً على ذاكرة معطيات الجسيم وتكرر العملية حتى تحقق أحد شروط التوقف.



الشكل (3) المخطط التدفقي لخوارزمية تحسين سرب الجسيمات PSO

تكون المرحلة الأولى في خوارزمية تحسين سرب الجسيمات متشابهة في جميع الخوارزميات التطورية وهي مرحلة توليد القيم المبدئية والتي يتم بواسطتها إيجاد سرب الجسيمات الأول. يتم إسناد قيم مبدئية عشوائية لموقع وسرعة كل جسيم ويتم تقييم كل جسيم بواسطة تابع ملازمة ثم مقارنته بأفضل قيمة ملازمة سابقة للجسيم وبأفضل قيمة ملازمة سابقة للسرب كاملاً فإذا كانت أعلى من أفضل قيمة ملازمة سابقة تصبح الملازمة الحالية هي أفضل ملازمة للجسيم ويتم تعديل قيمة الملازمة العامة للسرب في

الجيل الحالي بنفس الطريقة. يتم تحديث السرعة والموقع وإنشاء سرب جديد طالما أن شروط التكرار ما زالت قائمة وذلك عن طريق استخدام أفضل قيمة ملائمة للجسيم وأفضل قيمة ملائمة للسرب بالإضافة إلى السرعة السابقة لتحديث قيمة السرعة الحالية.

إن تحديث قيمة الموقع وتحديث قيمة السرعة هما العمليتان الرئيسيتان في الخوارزمية ولكل من هذه العوامل وزن ثابت مرافق لها. يتم تكرار هذه الخطوات لإنتاج سرب جديد ويتم إيقاف الخوارزمية بعد عدد محدد مسبقاً من التكرارات أو عند فشل الخوارزمية في تحقيق تحسن بعد ثبات ملائمة السرب لعدد محدد من التكرارات.

من الخواص الهامة للخوارزمية أنها لا تحتوي ترتيب قيم الملائمة للجسيمات في أي من خطوات عملها مما يمنحها أولوية وميزة حسابية على حساب الخوارزمية الجينية، وخصوصاً عندما يكون حجم الجيل كبيراً، كما أن عملية تحديث قيم السرعة والموقع ليست معقدة حسابياً. تتحرك مجموعة الجسيمات في فضاء بحث عن القيمة الأفضل ملائمة ويمكن وصف حركة الجسيم  $i$  بواسطة المعادلتين التاليتين اللتين تنظمان موقع الجسيم وسرعته [3,4]:

$$v_i(t) = w \cdot v_i(t-1) + c_1 \cdot rand().(BP_i - P_i(t-1)) + c_2 \cdot rand().(BGP_i - P_i(t-1)) \quad (1)$$

$$P_i(t) = P_i(t-1) + v_i(t) \quad (2)$$

حيث إن  $v_i(t)$  هي سرعة الجسيم و  $P_i(t)$  هي موقع الجسيم في التكرار الحالي و  $w, c_2, c_1$  عوامل القصور الذاتي وهي ثوابت موجبة، أما التابع  $rand$  فهو تابع توليد قيمة عشوائية بين  $(0 - 1)$  و  $BP$  هو قيمة أفضل ملائمة للجسيم في جمع التكرارات حتى الآن، و  $BGP$  هو قيمة أفضل ملائمة لجسيم في السرب كاملاً. يتم استخدام عوامل

القصور الذاتي لضبط حركة الجسيمات أثناء عملية البحث، حيث إن  $W$  هو وزن القصور الذاتي يستعمل لضبط حركة الجسيمات الانفجارية كي لا تتجاوز فضاء البحث وينقصانه تميل الخوارزمية إلى البحث المحلي، وينصح الباحثون في الدراسات السابقة [16] باعتماد قيمة كبيرة في بداية عملية البحث وتتناقص بالعثور على منطقة ذات ملائمة عالية للبحث بداخلها وينصح بالبدء من قيمة 0.9 وتتناقص خطياً حتى 0.4 وتشير الدراسات السابقة أن  $c_1$  معامل التعلم الذاتي و  $c_2$  معامل التعلم الجماعي يجب ألا يتجاوز مجموعهما 4 أي أن  $0 < c_1 + c_2 < 4$  عندما يكون البحث في فضاء ثنائي البعد، وأن ضبطهم يتحكم بالمفاضلة بين توسيع رقعة البحث وبين التجمع حول أفضل الجسيمات.

### 3.2 الخوارزمية التطورية التفاضلية ((Differential Evolution (DE))

تم طرح الخوارزمية لأول مرة سنة 1995 بواسطة Storn و Price للتحسين العام في مساحة بحث مستمرة [5]. تعتبر مراحل الخوارزمية بسيطة نسبياً وتتطلب عدداً محدوداً من متغيرات التحكم، ولم تتل خوارزمية DE شهرة خوارزمية PSO في البداية ولكنها بدأت تظهر مؤخراً في العديد من الدراسات وأظهرت تفوقاً في تطبيقات عديدة.

تستخدم الخوارزمية DE بشكل خاص عندما يكون التابع المراد تحسينه متعددة الوسائط وغير قابل للفصل، وتتجز الخوارزمية اضطراب أفراد الجيل من خلال تدريج الفروقات بين الأفراد الآخرين الذين تم اختيارهم عشوائياً مما يلغي الحاجة إلى استخدام آلية خاصة لزيادة توزع الحلول وتكون حلول الجيل الأول منتشرة على نطاق واسع في فضاء البحث ولديها قدرة استكشاف أكبر، وأثناء التحسين تميل الحلول إلى التركيز على مناطق البحث التي تحتوي أفضل القيم، أي أن عملية البحث تتركز تلقائياً حول الحلول الواعدة.

يتم تمثيل الحلول في خوارزمية DE على شكل شعاع متعدد الأبعاد، وكما في جميع الخوارزميات التطورية، يبدأ إنشاء الجيل الأول بقيم عشوائية وبحجم N شعاع متعدد الأبعاد والفرق بين خوارزمية DE وخوارزميتي PSO و GA هو في آلية توليد الأجيال الجديدة وتتم عبر دمج عدة حلول مع حل منتخب (هدف) وتتطور الأجيال المتتالية من الحلول من خلال تكرار ثلاث معاملات رئيسية وهي الطفرات والتصالب والانتقاء وهي ليست العمليات ذاتها الموجودة في الخوارزمية الجينية رغم تشابه الأسماء.


يتم إنشاء أفراد جدد في الخوارزمية التفاضلية من خلال دمج أفراد الجيل الحالي لتشكيل الشعاع المتحول mutant vector من ثلاثة أشعة يتم اختيارها عشوائياً  $X_{r1}$ ,  $X_{r2}$ ,  $X_{r3}$  ، باستثناء شعاع الهدف، من خلال القانون التالي [5]:

$$V_i = X_{r1} + F(X_{r2} - X_{r3}) \quad (3)$$

حيث إن F معامل التحجيم هو بارامتر رئيسي في الخوارزمية وله تأثير كبير على أدائها وتتراوح قيمته بين (1 - 0.4) وتعتبر عملية إنشاء الشعاع المتحول هي عملية الطفرة وهي مختلفة تماماً عن الطفرة في الخوارزمية الجينية. بعد إنشاء الشعاع المتحول من القانون (3) يتم إنشاء الشعاع التجريبي trial vector من تصالب كل شعاع في الجيل الحالي مع الشعاع المتحول، ويتم استعمال إحدى طريقتين للتصالب هما الأكثر انتشاراً التصالب ثنائي الدرجة والتصالب الأسّي فينتج الشعاع  $U_i$  :

$$U_{i,j} = \begin{cases} V_{i,j} & \text{if } (rand_{i,j} \leq C_r \text{ or } j = j_{rand}) \\ X_{i,j} & \text{otherwise} \end{cases}$$

أي أن المكون j من الشعاع المتحول i تم إنشاؤه بواسطة تصالب من الدرجة الثانية و  $rand_{i,j}$  هو رقم عشوائي بين (0-1) و  $C_r$  هو معدل التصالب و  $j_{rand}$  هو بعد يتم اختياره عشوائياً.



الشكل (4) المخطط التدفقي لخوارزمية التطور التفاضلي DE

بعد تشكيل الشعاع التجريبي تجري عملية انتقاء بينه وبين الشعاع الهدف وذلك للحفاظ على الشعاع ذي الملاءمة الأعلى أي قد يتم الحفاظ على الشعاع الهدف إذا كان الشعاع التجريبي أقل منه ملائمة وإلا فإن الشعاع الهدف يستبدل بالشعاع التجريبي ويصبح شعاع الهدف الجديد جاهزاً للتصالب مع شعاع متحول جديد لتشكيل الشعاع التجريبي التالي وتعتبر هذه العملية من أهم ميزات الخوارزمية التفاضلية حيث إن أي تحسين يطرأ

على أحد الحلول يؤثر مباشرةً في باقي الحلول دون انتظار كامل الجيل لينتهي عملية التحديث[5]. يلخص الشكل (4) المخطط التدفقي للخوارزمية التفاضلية.

تبدأ الخوارزمية عند توليد جيل من الحلول يدعى الأشعة ويتم تقييم ملائمة كل شعاع منها يكون إما مرشح أو هدف وبمقابل كل شعاع هدف يتم تشكيل شعاع تجريبي ثم يتم اختيار الشعاع الأكثر ملائمة ما بين الشعاع التجريبي والشعاع الهدف بواسطة عملية الانتقاء، ويعاد استعمال الشعاع الذي تم اختياره في التكرار التالي بينما يتم تجاهل الشعاع الآخر.

يقترح الباحثون في الدراسات السابقة [16] قيمة البارامترات التالية:

- حجم الجيل: أن يكون أكبر من 4 للتأكد أن عدد الأشعة كافٍ للانتقال من جيل لآخر.
- ثابت التحول  $F$ : بين 0.4 و 1 واعتبار أن 0.5 اختياراً مبدئياً جيداً ولكن إذا حصل تقارب مبكر يجب زيادة قيمة  $F$ .
- ثابت التصالب  $C_r$ : قيمته بين 0.3 و 0.9 يزداد التقارب سرعة ومجازفة بازدياده، وتوصي الدراسات السابقة بقيمة 0.9 إلى 1 كقيمة مبدئية في حال الرغبة بسرعة الحصول على النتائج بينما قيمة 0.1 ستبطئ التقارب ولكن البحث سيكون أكثر شمولاً.

### 3. نتائج المقارنة بين الخوارزميات

تم إجراء المقارنة بين الخوارزميات من ناحيتين نظرية وعملية، تم في المقارنة النظرية دراسة خواص وخطوات وبارامترات الخوارزمية التي لا تحتاج لبرهان عددي وهي المقارنة من ناحية (توليد الحلول الجديدة - تكثيف وتوزيع الحلول - تأثير إعادة التهيئة - تأثير البحث المحلي - تأثير التجمع الفرعي - بساطة التطبيق) أما المقارنة العملية

فتم إجرائها للخواص التي لا تمكن معرفتها إلا بالتجربة العددية (دقة الحل - زمن التشغيل).

### 1.3 المقارنة النظرية للخوارزميات من ناحية توليد الحلول الجديدة

يتم اختيار الحلول الجديدة في خوارزمية DE فقط إذا كانت أكثر ملاءمة وبالتالي فإن ملاءمة الجيل إما أن تكون مساوية أو أعلى في كل تكرار جديد، وإن أي تحسن في الحلول قابل للدخول مباشرة في عملية الطفرة لتشكيل الشعاع المتحول وهذا الفرق يميز خوارزمية DE عن خوارزمية PSO التي لا يحدث التحسين فيها إلا بعد انتهاء جميع حلول الجيل من حساباتها [16].

بعكس الخوارزمية الجينية فإن خوارزمية DE تختار الحلول الآباء اعتماداً على ملاءمتها [17]، وباعتبار أن كل حل في الجيل يتخذ دور الشعاع الهدف وبالتالي كل الأشعة ستكون آباء، والاب الثاني هو الشعاع المتحول الذي يتكون من ثلاثة أشعة أي أن الشعاع التجريبي ينتج عن أربعة أشعة مختلفة وسيستخدم مكان الشعاع الهدف فقط إذا كان أكثر ملاءمة منه وإلا يتم إقصاؤه، تتم عملية التبديل بين الشعاع التجريبي والهدف فوراً دون انتظار باقي حلول الجيل لتكتمل حساباتها. الشعاع الناتج يكون جاهزاً مباشرة للمشاركة في عملية الاختيار العشوائي التي تساهم في تشكيل الشعاع المتحول الجديد.

### 2.3 المقارنة النظرية للخوارزميات من ناحية تكثيف وتوزيع الحلول

تختلف آلية توليد الجيل الجديد من الحلول في الخوارزميات التي تمت مناقشتها وتولد هذه الآليات المختلفة مجموعة من الحلول ذات توازن مختلف بين التكثيف والتوزيع، ويمكن توقع السلوك الديناميكي للجيل من الطريقة المستخدمة لإنشاء الجيل التالي. يتم ترتيب الحلول في الخوارزمية الجينية بناءً على قيم الملاءمة ويتم اختيار الآباء اعتماداً على احتمالية إنتاجهم أبناء أفضل، لذلك فإن عملية التصالب تنتج أبناء تحتوي على جزء من

الآباء وتكون مشابهة لها جزئياً وبناء عليه فإن الخوارزمية الجينية تميل إلى توليد حلول تتجمع حول الحلول الجيدة، ولتحقيق التنوع في الخوارزمية الجينية يتم إحداث الطفرة والتي تقوم بحقن بعض الاختلاف في الحلول [18].

يتم إنشاء السرب الجديد في خوارزمية PSO بواسطة معادلات تحديث السرعة والموقع وهو ما يضمن أن تكون حلول الجيل التالي مختلفة تماماً عن حلول الجيل الحالي، وباعتبار أن الخوارزمية تعتمد على عمليات رياضية بأرقام ذات فواصل عشرية فبإمكانها توليد كل القيم الممكنة في فضاء البحث أي أن كثافة الحلول الناتجة أعلى بكثير من الخوارزمية الجينية، كما أن أفضل جسيم في السرب يؤثر بطريقه إلى الهدف على جميع جسيمات السرب مما يسرع من عملية التجمع حول أفضل الجسيمات خصوصاً إذا كان هناك تباين واضح في قيم الملاءمة [19].

تحقق خوارزمية DE كثافة في الحلول بشكل مشابه لخوارزمية PSO بسبب اعتمادها على عمليات رياضية بأرقام عشرية ولكن التنوع في الخوارزمية التفاضلية أعلى لأن أفضل حلول الجيل الحالي ليس له أي تأثير على باقي الحلول بالإضافة إلى أن الشعاع المتحول لا ينتمي إلى الجيل الأصلي أي أن عملية التصلب في الخوارزمية التفاضلية تكون دائماً بين أحد حلول الجيل وحل تم توليده حديثاً، ويتقدم عملية البحث تتجمع الحلول تدريجياً حول الحلول الجيدة، قد يؤدي هذا التجمع إلى تقارب الجيل نحو حل معين، وإذا حصلت هذه العملية بسرعة كبيرة قد يصاب الجيل بالركود التطوري ويصبح احتمال التحسين ضعيفاً [20].

### 3.3 المقارنة النظرية للخوارزميات من ناحية تأثير إعادة التهيئة

يكون تأثير التجمع أقل فاعلية في الخوارزمية الجينية ولكن تميل أفضل الكروموسومات إلى التشابه فيما بينها ويمكن حقن الاختلاف فيها لتحسين التنوع [21] و يكون التجمع في أقل مستوياته في خوارزمية DE ولا تأثير مهم لعملية إعادة التهيئة.

تتجمع الحلول في خوارزمية PSO بأعلى سرعة بين الخوارزميات الثلاثة مما قد يسهل إصابة الجيل بالركود، وللتخلص من هذه العقبة تم طرح عدة تقنيات للتجميع لتقليل تأثير أفضل جسيم ، كما يمكن تطبيق مفهوم بديل أكثر بساطة وهو الإبقاء على أفضل جسيم وإعادة توليد كل أو بعض الجسيمات المتبقية مما ينشأ تأثير يشابه توليد سرب جديد ولكن باعتبار أفضل جسيم كأحد الجسيمات البقية وتسمى هذه العملية إعادة التهيئة [22].

### 4.3 المقارنة النظرية للخوارزميات من ناحية تأثير البحث المحلي

إن كثافة الحلول في فضاء بحث الخوارزمية الجينية منخفضة وبالتالي لا يمكن لمعاملات الخوارزمية إنتاج كل الحلول الممكنة، ويستعمل البحث المحلي لحل هذه المشكلة، وهو التقصي عن إمكانية وجود حلول أفضل حول الحلول الحالية وهي عملية مكلفة زمنياً وتزداد كلفتها بازدياد عدد أفراد الجيل [23].

يكون لأفضل جسيم في كل جيل في خوارزمية PSO تأثير مسيطر على السرب بكامله وبتطبيق عملية البحث حول الجسيم الأفضل يمكن اختصار الزمن وتحسين الحلول بفاعلية، وتم إثبات أن هذه الاستراتيجية مفيدة في جدولة الإنتاج حسب الطلب [24].

لا تؤثر تقنية البحث المحلي على خوارزمية DE باعتبار أن لا تأثير لأفضل حل فيها على باقي حلول الجيل.

### 5.3 المقارنة النظرية للخوارزميات من ناحية تأثير التجمع الفرعي

التجمع الفرعي هو استراتيجية بسيطة لتأخير التجمع المبكر للحلول، ويمكن تحقيقه في الأجيال المتجانسة والمتغايرة، حيث يشير مصطلح الأجيال المتجانسة إلى الأجيال التي تستخدم بارامترات متطابقة في إنتاج الأجيال الجديدة في كل تكرار، أما الأجيال المتغايرة فهي الأجيال التي تسمح للحلول التي تنتمي إلى مجموعات فرعية

متخلفة باستعمال قيم معاملات وبارامترات مختلفة مما يزيد من تنوع عملية البحث. يسمح التجمع الفرعي في الخوارزمية الجينية وخوارزمية PSO بالتخلص من تأثير الحلول المسيطرة ويسمح للمجموعات الفرعية من الجيل بالبحث في مناطق مختلفة من فضاء الحلول، أما بالنسبة لخوارزمية DE لا يوجد تأثير مهم للتجمع الفرعي للحلول باعتبار أن أفضل حل لا تأثير له على باقي الحلول.

يحقق التغيير الديناميكي في سلوك الجيل تأثيرات مشابهة لاستخدام الجيل المتغير، عند استخدام أكثر من استراتيجية بحث يمكن لخوارزمية البحث تحديد الاستراتيجية التي تؤدي إلى التحسين المستمر للحلول وعند توقف التحسين بعد عدد من التكرارات يمكن للخوارزمية استبدال خوارزمية البحث بأخرى [25].

### 6.3 المقارنة النظرية للخوارزميات من ناحية البساطة في التطبيق

تبين بعد المقارنة أن الفرق الأساسي بين الخوارزميات الثلاث هو أن PSO لا تحتوي عمليات ومعاملات جينية مثل التصلب والطفرات حيث تقوم الجسيمات بتحديث قيمها بواسطة سرعتها الذاتية كما أنها تمتلك ذاكرة وآلية لتبادل المعلومات المختلفة ويشارك أفضل جسيم فقط معلومات حركته لبقية الجسيمات مما يؤدي إلى تقارب الحلول حول القيم المثلى بشكل سريع وبالمقارنة مع الخوارزميات الأخرى فإن PSO هي الأبسط تمثيلاً وتحتوي عدداً أقل من البارامترات للتحكم به.

### 7.3 نتائج المقارنة النظرية للخوارزميات

تم توضيح المقارنات والنتائج التي تم التوصل إليها في الدراسة في الجدول (1)، حيث تمت المقارنة في عدد من الدراسات السابقة [26] بين أداء الخوارزميات التطورية محل الدراسة في حل مشاكل بحث عن الحل الأمثل في مختلف المجالات ولكن المنهجية كانت غير مباشرة وذلك لأن الباحثين استخدموا تمثيلاً مختلفاً للبيانات بالإضافة إلى أن

استراتيجيات البحث المحلي كانت مختلفة لذلك لم يكن واضحاً إن كان التأثير على الأداء سببه نوع الخوارزمية التطورية أم من اختلاف تمثيل الحلول واستراتيجيات البحث.

الجدول (1) ملخص المقارنة النظرية بين الخوارزميات التطورية المدروسة

| الخوارزمية |        |       | مجال المقارنة                                |
|------------|--------|-------|----------------------------------------------|
| DE         | PSO    | GA    |                                              |
| لا         | لا     | نعم   | بحاجة إلى تصنيف الحلول                       |
| خطي        | خطي    | أسّي  | تأثير حجم الجيل على زمن الحل                 |
| الأقل      | الأعلى | متوسط | تأثير أفضل حل على بقية الحلول                |
| صحيح       | خطأ    | خطأ   | متوسط قيمة الملاءمة لا ينخفض                 |
| الأقل      | الأعلى | متوسط | الميل إلى التقارب المبكر                     |
| أكثر       | أكثر   | أقل   | استمرارية وكثافة مساحة البحث                 |
| أكثر       | أكثر   | أقل   | القدرة على الوصول لحل جيد دون إجراء بحث محلي |
| لا         | نعم    | نعم   | تجمع الحلول المتجانسة يحسن التقارب           |

#### 4. التجربة العملية وقياس الأداء

تمت محاكاة تشغيل النظام عبر برنامج Matlab بتوليد مجموعة مهام بالنسب التالية (70% مهام دورية - 20% مهام عشوائية - 10% مهام لا دورية) وتمت جدولتها بواسطة خوارزمية LLREF وتمت دراسة أثر تغيير تردد العمل على مدة تنفيذ المهام تحت حمل خفيف إلى متوسط (0.2 - 0.5) حيث يكون هناك إمكانية لزيادة مدة تنفيذ المهام دون فشل النظام. يوضح الجدول (2) مواصفات التجربة التي تم اختيارها لقياس أداء الخوارزميات المدروسة.

الجدول (2) مواصفات التجربة العملية وقيم بارامترات الخوارزمية المدروسة

| البارامتر               | القيمة                                   | تفاصيل                                    |
|-------------------------|------------------------------------------|-------------------------------------------|
| عدد مجموعات المهام      | 10                                       |                                           |
| عدد تكرارات التجربة     | 30                                       |                                           |
| عدد المهام في كل مجموعة | 100                                      | 70% دورية - 20% عشوائية<br>- 10% لا دورية |
| خوارزمية جدولة المهام   | LLREF                                    | -                                         |
| الحمل Utilization       | 0.5 - 0.2                                | خفيف إلى متوسط                            |
| عدد النوى               | 2                                        | -                                         |
| زمن التشغيل             | 1 ثانية                                  | تتم جدولة المهام ضمن مدة 1 ثانية          |
| عدد التكرارات           | 20                                       | -                                         |
| قيم حدود البحث          | الحد الأدنى = 0.8<br>الحد الأعلى = 2.5   | قيمة تردد المعالج ( MHz )                 |
| بارامترات GA            | Mutation rate=0.1<br>Crossover rate= 0.8 |                                           |
| بارامترات PSO           | C1=2, C2=2,<br>W=(0.4-0.9)               | -                                         |
| بارامترات DE            | F=0.5, $C_r = 0.7$                       | -                                         |


#### 1.4 خوارزمية LLREF (Largest Local Remaining Execution time First)

تبين الدراسات السابقة أن خوارزمية LLREF مثالية (أي أنها تحقق كل القيود الزمنية Deadlines بشرط أن يكون مجموع نسب استخدام المهام للمعالج utilization لا يزيد عن عدد المعالجات) لجدولة مهام أنظمة الزمن الحقيقي التي تعمل على منصة متعددة المعالجات [27]، كما أنها الأقل استهلاكاً للطاقة [28]، وتنقسم الأحداث في هذه الخوارزمية إلى قسمين هما: الأحداث الرئيسية (إطلاق مهمة - إنهاء تنفيذ مهمة) والأحداث الثانوية (نفاذ سماحية تأخير تنفيذ المهمة - وجود زمن إضافي للتنفيذ نتيجة انتهاء المهمة). تعتمد الخوارزمية بشكل أساسي على بارامتر هو مخطط Time and Local execution time Plane، وتسعى في جدولتها للمهام من الاقتراب قدر الإمكان من التنفيذ التدفقي دون استخدام الفترات الزمنية Time slices باستخدام نسخ متعاقبة من مخططات TL-Plane حيث إن ضمان قابلية الجدولة ضمن كل منها يؤدي إلى قابلية الجدولة لمجموعة المهام بشكل كلي.

#### 2.4 المقارنة العملية للخوارزميات من ناحية زمن التشغيل

يتزايد زمن الحل في الخوارزمية الجينية بشكل لا خطي بازدياد حجم الجيل بسبب الحاجة لترتيب الحلول. تعاني خوارزمية PSO من الركود أي أنه عندما تتمركز الحلول حول القيم الجيدة الملاءمة يصبح من الصعب الحصول على أية تحسينات إضافية مهما زادت التكرارات بينما خوارزمية DE فإنها دائماً ما تصل إلى حلول أفضل عند منحها مزيداً من الوقت وهي أكثر فاعلية في إيجاد الحلول المثالية عند التعامل مع مسائل معقدة يمكن فيها تحسين عدة متحولات معا ويسمح فيها بعدد كبير من التكرارات، ولكن عندما يكون الوقت قيماً جداً ويجب الوصول لقيم مقبولة في أقل عدد من التكرارات


فإن خوارزمية PSO هي الأكثر ملاءمة للوصول للحل بسرعة كما يوضح الشكل (5) بالإضافة إلى أن PSO تتجز عمليات بحث موجهة أي في فضاء بحث ثنائي البعد مثل عملية البحث عن التردد الأفضل لمعالج، فهي الأنسب لعملية تحسين لقيمة واحدة فقط بينما الخوارزمية التفاضلية فتستعمل في مجالات البحث الاستكشافية التي تحتوي عدداً من البارامترات متساوية الأهمية ويجب تحسينهم معاً.



الشكل (5) مقارنة زمن بحث الخوارزميات التطورية المدروسة

### 3.4 المقارنة العملية للخوارزميات من ناحية دقة الحل

تمكنت خوارزمية PSO من الوصول إلى أفضل قيمة في متوسط اختبارات التجربة العملية مقارنة بباقي الخوارزميات كما هو موضح في الشكل (6) وتتناقص جودة الحل بشكل بسيط عند DE لتصبح أقلها في الخوارزمية الجينية.



الشكل (6) مقارنة أفضل قيمة تردد عمل توصلت لها الخوارزميات التطورية المدروسة

عادةً ما تكون دقة الحل هي أهم معايير تقييم الخوارزمية، ولكن في هذا البحث وباعتبار أن الهدف هو الوصول لأقل قيمة تردد للمعالج لتقليل استهلاك الطاقة في النظام فمن غير المجدي أن تستغرق عملية البحث عن التردد المطلوب مدة أطول من اللازم. توضح النتائج في الشكل (5) أن زمن تشغيل خوارزمية PSO للوصول لنتيجة مقبولة هو الأقصر.

##### 5. مناقشة نتائج المقارنة النظرية والعملية للخوارزميات المدروسة

- تصنف خوارزمية DE بأنها الأفضل من ناحية الفرق بين الأجيال المتعاقبة وأن قيمة ملائمة الجيل تزداد بعد كل تكرار للخوارزمية وذلك لأنه لا يتم الاحتفاظ بأفراد الجيل الجديد إلا إذا كانوا أعلى ملائمة من أفراد الجيل السابق.

- إن كثافة الحلول في خوارزمية PSO و DE أعلى من الخوارزمية الجينية كون العمليات الرياضية تحتوي أرقاماً ذات فواصل عشرية.
  - إن خوارزمية DE هي الأعلى تنوعاً في الحلول وذلك لأن الحل الأفضل في الجيل الحالي ليس له أي تأثير على باقي الحلول.
  - تحتاج خوارزمية PSO إلى عملية إعادة تهيئة للتخلص من الركود أما الخوارزمية الجينية وخوارزمية DE لا تحتاجان لعملية إعادة تهيئة.
  - تستفيد خوارزمية GA و PSO من البحث المحلي والتجمع الفرعي بينما لا حاجة لهما في خوارزمية DE.
  - إن زمن تشغيل خوارزمية PSO للوصول لنتيجة مقبولة هو الأقصر كون الخوارزمية لا تحتاج عدداً كبيراً من التكرارات لتتجمع الحلول حول أفضل الجسيمات في السرب.
  - إن خوارزمية PSO هي الأبسط والأقل عمليات رياضية من باقي الخوارزميات والشيفرة البرمجية الخاصة بها هي الأصغر كونها لا تحتوي عمليات ترتيب عناصر مثل الخوارزمية الجينية وليست بحاجة لعدد كبير من التكرارات للوصول لحل مقبول مثل خوارزمية DE.
  - يمكن لخوارزمية DE الوصول إلى حلول أفضل عند منحها مزيداً من الوقت، ولكن عندما يكون مطلوب الوصول لقيم مقبولة في أقل وقت ممكن فإن خوارزمية PSO هي الأكثر ملاءمة للوصول للحل بسرعة.
- بناءً على ما سبق يقترح الباحث في هذه الدراسة استخدام خوارزمية PSO للبحث عن أقل قيمة تردد عمل للمعالج تضمن المحافظة على أداء نظام زمن حقيقي أثناء جدولة المهام بخوارزمية LLREF.

### 1.5 التوصيات

- دراسة خوارزميات جدولة مهام في نظام زمن حقيقي مختلفة عن LLREF لدراسة تأثيراتها المحتملة.
- اختبار منصات عمل مختلفة عما سبق ذكره في الدراسة لمعرفة تأثير العتاد الصلب الأكثر تعقيداً في تقليل زمن البحث.
- دراسة الطرق والتعديلات على خوارزمية DE لجعلها أبسط وأسرع وصولاً للحل كونها أفضل ببقية مجالات المقارنة.

## الخاتمة

الخوارزميات التطورية مستوحاة من الطبيعة ورغم الإثبات بأنها أداة فعالة في حل مشاكل التحسين إلا أنها ليست الحل الشامل الحاسم رغم قوتها الظاهرية ويجب اختيار قيم مناسبة للبارامترات والمتغيرات تضمن نجاحها.

تم في هذه الدراسة استخدام الخوارزميات التطورية للبحث عن أقل قيمة تردد تساعد في تخفيض استهلاك الطاقة مع المحافظة على أداء النظام. تم التركيز على ثلاث خوارزميات تطورية متشابهة وهي الخوارزمية الجينية GA وخوارزمية تحسين سرب الجسيمات PSO وخوارزمية التطور التفاضلي DE. تم في هذه الدراسة تقديم لمحة موجزة عن كل من الخوارزميات التطورية الثلاث وتم التركيز على الإجراءات الحسابية المتعلقة بالأداء واختبار الخوارزميات الثلاث في البحث عن أقل قيمة تردد عمل للمعالج وتبين أن الخوارزمية الجينية هي الأكثر تعقيداً والأقل قدرة على إيجاد حلول في فضاء البحث مستمر القيم أما خوارزمية DE فتبين قدرتها على الوصول لحلول أفضل ولكن على حساب الزيادة في زمن التشغيل بينما خوارزمية PSO هي الأبسط والأسرع بالوصول لنتائج مقبولة، وبمقارنة القيمة التي توصلت إليها PSO مع القيمة التي توصلت إليها DE تبين أن الزيادة في زمن البحث أكثر تأثيراً على استهلاك الطاقة من الفرق بين أفضل قيمة وصلت إليها الخوارزميتين، وعلى اعتبار أن العامل الأهم هو تقليل وقت المعالجة لتوفير استهلاك الطاقة فإن خوارزمية PSO تعتبر الأفضل للبحث عن أقل قيمة تردد عمل للمعالج في نظام زمن حقيقي ذو مصادر طاقة محدودة ويعتمد على خوارزمية LLREF في جدولة المهام.

### المراجع

1. Holland JH. Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. MIT press; 1992 Apr 29.
2. Glover F. Future paths for integer programming and links to artificial intelligence. Computers & operations research. 1986 Jan 1;13(5):533-49.
3. Eberhart R, Kennedy J. A new optimizer using particle swarm theory. InMHS'95. Proceedings of the sixth international symposium on micro machine and human science 1995 Oct 4 (pp. 39-43). IEEE.
4. Kennedy J, Eberhart R. Particle swarm optimization. InProceedings of ICNN'95-international conference on neural networks 1995 Nov 27 (Vol. 4, pp. 1942-1948). IEEE.
5. Storn, R. and Price, K.: Differential Evolution — A Simple and Efficient Adaptive Scheme for Global Optimization Over Continuous Spaces, Technical Report TR-95-012, International Computer Science Institute, Berkeley, CA, USA.
6. Dorigo M, Di Caro G. Ant colony optimization: a new meta-heuristic. InProceedings of the 1999 congress on

- evolutionary computation–CEC99 (Cat. No. 99TH8406) 1999 Jul 6 (Vol. 2, pp. 1470–1477). IEEE.
7. Gao S, Yu Y, Wang Y, Wang J, Cheng J, Zhou M. Chaotic local search–based differential evolution algorithms for optimization. IEEE Transactions on Systems, Man, and Cybernetics: Systems. 2019 Dec 20;51(6):3954–67.
  8. Özsoy VS, Ünsal MG, Örkücü HH. Use of the heuristic optimization in the parameter estimation of generalized gamma distribution: comparison of GA, DE, PSO and SA methods. Computational Statistics. 2020 Dec;35(4):1895–925.
  9. Diveev AI, Konstantinov SV. Study of the practical convergence of evolutionary algorithms for the optimal program control of a wheeled robot. Journal of Computer and Systems Sciences International. 2018 Jul;57(4):561–80.
  10. Wolpert DH, Macready WG. No free lunch theorems for optimization. IEEE transactions on evolutionary computation. 1997 Apr;1(1):67–82.
  11. Baital K, Chakrabarti A. Dynamic scheduling of tasks for multi–core real–time systems based on optimum energy and throughput. IET Computers & Digital Techniques. 2019 Mar 14;13(2):93–100.

- 12.Zheng X. Real-time simulation in real-time systems: Current status, research challenges and a way forward. arXiv preprint arXiv:1905.01848. 2019 May 6.
- 13.Slowik A, Kwasnicka H. Evolutionary algorithms and their applications to engineering problems. Neural Computing and Applications. 2020 Aug;32(16):12363–79.
- 14.Blickle T, Thiele L. A comparison of selection schemes used in evolutionary algorithms. Evolutionary Computation. 1996 Dec;4(4):361–94.
- 15.Roberge V, Tarbouchi M, Labonté G. Comparison of parallel genetic algorithm and particle swarm optimization for real-time UAV path planning. IEEE Transactions on industrial informatics. 2012 May 10;9(1):132–41.
- 16.Vu VT. A comparison of particle swarm optimization and differential evolution. International Journal on soft computing. 2012 Aug 1;3(3):13.
- 17.Hegerty, B., Hung, C. C., & Kasprak, K. A comparative study on differential evolution and genetic algorithms for some combinatorial problems. In Proceedings of 8th Mexican international conference on artificial intelligence.2009 Nov; (Vol. 9, p. 13).
- 18.Scheibenpflug A, Wagner S. An analysis of the intensification and diversification behavior of different operators for genetic algorithms. InInternational Conference

- on Computer Aided Systems Theory 2013 Feb 10 (pp. 364–371). Springer, Berlin, Heidelberg.
19. Lei L, Min X, Xiaokui L. Research on hybrid PSO algorithm with appended intensification and diversification. In Proceedings 2013 International Conference on Mechatronic Sciences, Electric Engineering and Computer (MEC) 2013 Dec 20 (pp. 2359–2363). IEEE.
20. Jain S, Kumar S, Sharma VK, Sharma H. Improved differential evolution algorithm. In 2017 international conference on infocom technologies and unmanned systems (Trends and Future Directions)(ICTUS) 2017 Dec 18 (pp. 627–632). IEEE.
21. Sekaj, I., & Perkacz, J. (2007, September). Some aspects of parallel genetic algorithms with population re-initialization. In 2007 IEEE Congress on Evolutionary Computation (pp. 1333–1338). IEEE.
22. Kennedy DD, Zhang H, Rangaiah GP, Bonilla–Petriciolet A. Particle swarm optimization with re-initialization strategies for continuous global optimization 2013.
23. Yun Y. Hybrid genetic algorithm with adaptive local search scheme. Computers & Industrial Engineering. 2006 Sep 1;51(1):128–41.
24. Chen J, Qin Z, Liu Y, Lu J. Particle swarm optimization with local search. In 2005 International Conference on Neural

- Networks and Brain 2005 Oct 13 (Vol. 1, pp. 481-484).  
IEEE.
- 25.Laishram A, Padmanabhan V. Discovery of user-item subgroups via genetic algorithm for effective prediction of ratings in collaborative filtering. Applied Intelligence. 2019 Nov;49(11):3990-4006.
- 26.Cho H, Ravindran B, Jensen ED. An optimal real-time scheduling algorithm for multiprocessors. In 2006 27th IEEE International Real-Time Systems Symposium (RTSS'06) 2006 Dec 5 (pp. 101-110). IEEE.
- 27.Maier HR, Razavi S, Kapelan Z, Matott LS, Kasprzyk J, Tolson BA. Introductory overview: Optimization using evolutionary algorithms and other metaheuristics. Environmental modelling & software. 2019 Apr 1;114:195-213.
- 28.Youssef Mohammad Ntefeh, Mohammad Hijazieh. (2022). Development of Energy-Efficient Load Balancing Scheduling Algorithm in Real-time Systems. *مجلة العلوم الهندسية و تكنولوجيا المعلومات*, 6(4), 133-150.  
<https://doi.:10.26389/AJSRP.C100222>

