

مقارنة أداء خوارزميتي PSO و HGSO في إيجاد القيمة المثلى لبعض التوابع الرياضية

د. م. محمد عنبر*

(تاريخ الإيداع 2021/ 2 /24 . قُبِلَ للنشر في 6 / 7 / 2021)

□ ملخّص □

تم تطوير العديد من الخوارزميات و الأساليب التي يتم من خلالها إيجاد الحل الأمثل لمسائل مختلفة ذات تطبيقات عملية متعددة. من المعروف أن إيجاد الحل الأمثل في المسائل الهندسية المختلفة هو من أهم الأعمال التي يجب إنجازها بحيث أن إيجاد الحل الأمثل يساعد في تخفيض التكلفة و الزمن. من أهم الخوارزميات التي تم تطويرها و التي تستخدم في حل مسائل إيجاد الحل الأمثل هي خوارزمية أسراب الجزيئات PSO و خوارزمية مستعمرات النمل ACO، خوارزمية تجمع الفيلة EHO و مؤخراً فقد تم تطوير خوارزمية التحسين المعتمدة على قانون هنري للغازات HGSO. تم في هذا البحث تطبيق الخوارزميتين PSO و HGSO على ثلاثة توابع من أجل إيجاد الحل الأمثل لهذه التوابع و الهدف من ذلك اختبار مقدرة هاتين الخوارزميتين على إيجاد الحل الأمثل لهذه التوابع و الطريقة التي تعمل بها تمهيداً لاستخدامها في تطبيقات أكثر أهمية. تمت نمذجة عمل الخوارزميتين باستخدام برنامج Matlab 2017 الكلمات المفتاحية: خوارزميات الأسراب (PSO)، خوارزمية التحسين المعتمدة على قانون هنري للغازات (HGSO)، G.Griewank، Branin، Three_Hump_Camel.

*مدرس في قسم هندسة تكنولوجيا المعلومات و الاتصالات - كلية هندسة تكنولوجيا المعلومات و الاتصالات - جامعة طرطوس - سوريا

Comparison between PSO and HGSO in finding optimal solutions for some important functions

Dr. Mohammad Anbar *

(Received 24 / 2 / 2021 . Accepted 6 / 7 / 2021)

□ ABSTRACT □

It is well-known that finding optimal solution in different engineering problems is one of the most important tasks to be accomplished. Many algorithms and methods have been developed for finding the optimal solution of problems with different applications. The most important algorithms for used for this purpose are Particle Swarm Optimization(PSO), Ant Colony Optimization (ACO), elephant herding algorithm (EHO) and recently Henry Gas Solubility Optimization (HGSO). In this research, both PSO and HGSO have been applied on three functions for finding their optimal solutions. The algorithms have been simulated using Matlab 2017.

Keywords Particle Swarm Optimization (PSO), Henry Gas Solubility Optimization (HGSO), Three_Hump_Camel, Branin, Griewank

*Teacher, department of telecommunication technology engineering, college of information and telecommunication technology engineering, Tartous university

1. مقدمة

تعرف عملية إيجاد الحل الأمثل بأنها عملية إيجاد القيم المثلى لبارامترات معينة في نظام محدد من أجل تحقيق متطلبات تصميمية معينة آخذين بعين الاعتبار الكلفة الاقتصادية الأقل. يمكن أن توجد مسائل التحسين (إيجاد الحل الأمثل) في كل حقول العلم حيث أن تطوير خوارزميات تحسين جديدة تعتبر تحدياً في مجالات البحث. من وجهة نظر أخرى، فإن خوارزميات التحسين التقليدية لها بعض المقيدات مثل الاعتماد على حل مفرد و التقارب إلى حل أمثل محلي و مشاكل فضاء البحث غير المعلوم كما هو مذكور في [1]. من أجل التغلب على هذه المقيدات، قام العديد من الباحثون بتطوير العديد من خوارزميات البحث عن الحل الأمثل من أجل حل مسائل معقدة أو غير محلولة مسبقاً في العقود الأخيرة [2].

اكتسبت أساليب إيجاد الحل الأمثل أو ما يسمى بالأدلة العليا (metaheuristics) شهرة كبيرة [3,4,5]. يمكن أن تقسم الأدلة العليا إلى قسمين: الخوارزميات المعتمدة على حل وحيد أو الخوارزميات المعتمدة على مجموعة من الحلول [6]. تعرف هذه الخوارزميات على أنها خوارزميات معتمدة على المسألة و التي يتم استغلالها من أجل إيجاد حلول مثلى تقريبية لمسائل غير خطية و معقدة [7] و التي لا يوجد لها طريقة محددة قادرة على الحل ضمن زمن مقبول. خصائص خوارزميات التحسين ذات الأدلة العليا بالمقارنة مع الخوارزميات التقليدية و التي جعلت هذه الخوارزميات مشهورة جداً في التطبيقات العلمية و الهندسية هي كما يلي [8]: 1. سهلة الفهم و التنفيذ، 2. لا تحتاج تعميم على عدة متحولات، 3. يتم تجنب الحل الأمثل المحلي و 4. يمكن تطبيقها في مجال واسع من المسائل في حقول متنوعة.

معظم خوارزميات البحث ذات الأدلة العليا و خاصة المعتمدة منها على حلول متعددة تتشارك خاصية عامة في عملية البحث وذلك اعتماداً على خاصيتين هامتين و هما: الاكتشاف و الاستغلال. تحاول معظم خوارزميات الأدلة العليا الموازنة بين اكتشاف و استغلال فضاء البحث من أجل تحقيق فعالية جيدة. طور الاستغلال باختصار مسؤول عن توليد حلول مشابهة من أجل تحسين الحل المكتشف مسبقاً و يقود هذا الأسلوب إلى تقارب جيد. تولد عملية الاكتشاف حلول جديدة في فضاء البحث من أجل تجنب الحل الأمثل المحلي [9,10]. من الجدير بالذكر بأنه لا توجد خوارزمية تحسين واحدة قادرة على حل جميع المسائل التي تتطلب إيجاد حل أمثل. لذلك يجب اختيار خوارزمية تلائم المسألة المطروحة ولذلك فقد تم في هذا البحث نمذجة اثنتين من هذه الخوارزميات و تطبيقها على بعض التوابع الرياضية ذات التطبيقات الهامة.

تم تنظيم ما تبقى من هذا البحث على الشكل التالي: القسم الثاني يحتوي على الدراسات المرجعية التي تبحث في نفس المجال، القسم الثالث يحتوي هدف البحث والقسم الرابع يتضمن طرائق البحث و موادها بينما يحتوي القسم الخامس على التوابع الرياضية المستخدمة في الاختبارات و القسم السادس و السابع يحتويان تطبيق هاتين الخوارزميتين بشكل عملي على هذه التوابع. القسم الثامن يتضمن مناقشة النتائج التي تم الحصول عليها بينما يحتوي القسم التاسع على التوصيات التي الناتجة من خلال البحث و القسم العاشر يتضمن المراجع التي تم استخدامها في البحث.

2. الدراسات المرجعية

تقوم خوارزميات التحسين ذات الأدلة العليا بحل مسائل التحسين [11,12] عن طريق محاكاة الظواهر الطبيعية و الفيزيائية [13]. يوجد في الدراسات المرجعية تصنيفات مختلفة مثل [14]، حيث تم تصنيف هذه الخوارزميات إلى صنفين و هما الخوارزميات التطورية و خوارزميات ذكاء القطيع. في [15] تم تصنيفها إلى ثلاثة أصناف: الخوارزميات التطورية و خوارزميات ذكاء القطيع و الخوارزميات الفيزيائية. في [16] تم تصنيفها إلى: إما معتمدة على حل وحيد أو معتمدة على مجموعة من الحلول. وبالتالي لا يوجد تصنيف وحيد لخوارزميات الأدلة العليا على الرغم من أن معيار التصنيف الأكثر شهرة تؤكد على المصادر المختلفة من الإلهام. بناء على المصادر التي ألهمت هذه الخوارزميات، يمكن تصنيفها إلى أربع أصناف رئيسية كما يلي:

1. الخوارزميات المعتمدة على ذكاء القطيع، 2. الخوارزميات الملهمة من الطبيعة و التي يشار إليها أحياناً بالخوارزميات التطورية، 3. الخوارزميات المعتمدة على العلوم الطبيعية، 4. الخوارزميات المعتمدة على الظواهر الطبيعية. تقوم الخوارزميات Sis بتقليد السلوك الاجتماعي للأسراب، الطيور، الحشرات و مجموعات الحيوانات. بعض الخوارزميات SI الشهيرة التي تم تطويرها هي PSO [17] و ACO [18]، و خوارزمية اليعسوب [19] و EHO [20]. الصنف الثاني من الخوارزميات BIAS يشار إليه أيضاً بـ EAS تم استلهامها من قوانين التطور الطبيعي البيولوجي باستثناء Sis. في BIA، يتم توليد مجموعة حلول عشوائية أول مرة من أجل بدء عملية البحث. ثم يتم تقييم ملاءمة الأفراد باستخدام تابع الملاءمة. في الأجيال التالية، تتطور الأفراد باتجاه الحل الشامل الأفضل. تتم هذه العملية حتى وصول العدد الأعظمي من التكرارات أو إيجاد الحل الأقرب للحل الأمثل. بعض الخوارزميات الشهيرة: الخوارزميات الجينية GA [21] و الاستراتيجيات التطورية ESS [22]. الصنف الثالث: NSAS يقوم بتقليد ظاهرة فيزيائية معينة أو قوانين كيميائية (مثل الجاذبية، حركة الأيونات، نظام النهر، الخ). أهم الخوارزميات التي تندرج تحت هذا الصنف هي خوارزمية التخمير المحاكي (SA) [23,24]، خوارزمية بحث الجاذبية (GSA) [25]، خوارزمية تحسين رد الفعل الكيميائي الاصطناعي (ACROA) [26]، بحث الحويل الحراري [27]، تحسين حركة الغازات البراونية [28]. أما الصنف الرابع NPAS فإنه يحاكي خصائص متعددة (مثل: المجتمع البشري، ظاهرة طبيعية و خصائص إحساسية). الخوارزميات الأكثر شهرة هي خوارزمية بحث مستعمرة الفايروسات [29] و عملية البحث بالملاحقة [30].

3. هدف البحث

يهدف البحث إلى نمذجة و اختبار خوارزميتي PSO و HGSO في إيجاد الحل الأمثل لعدد من التوابع الهامة و المقارنة بين أداء هاتين الخوارزميتين في إيجاد الحل الأمثل والبحث في إمكانية تطبيق هاتين الخوارزميتين على بعض المسائل التي تحتاج إيجاد الحل الأمثل لاحقاً. تم اختيار هاتين الخوارزميتين نظراً لأهميتهما و سهولة التعامل معهما.

4. طرائق البحث و مواده

4.1 خوارزميات التحسين باستخدام الأسراب PSO

ذكاء السرب هو نموذج ذكي لحل مشاكل التحسين الصعبة. يعتمد على سلوك الحشرات الاجتماعية مثل قطعان الطيور وسرب الأسماك ومستعمرة النمل وما إلى ذلك، حيث تغير الأنواع الفردية موقعها وسرعتها اعتماداً على حركة جيرانها. يتم ذلك عن طريق محاكاة سلوك المخلوقات داخل أسرابها أو مستعمراتها. خوارزمية التحسين باستخدام الأسراب (PSO) عبارة عن خوارزمية تعتمد على ذكاء السرب. إنها أداة تحسين تعتمد على مجموعة من الحلول. القوة الرئيسية لـ PSO هي التقارب السريع الذي يمكن من خلاله تحقيق الحل الأمثل لمشكلة معينة بسرعة كبيرة نظراً لمنطقها وإجراءاتها المنظمة جيداً. تشترك PSO في العديد من النقاط المشتركة مع الخوارزمية الجينية (GA). تبدأ كلتا الخوارزميتين بمجموعة من الحلول التي يتم إنشاؤها عشوائياً ولكل منهما تابع ملاءمة من أجل تقييم هذه الحلول. أيضاً ، كلا منهما يقوم بتحديث مجموعة الحلول والبحث عن الحل الأمثل باستخدام تقنيات عشوائية [31]. بعض المسائل الصعبة يمكن تحويلها إلى مسائل تحسين و يجب حلها باستخدام خوارزميات التحسين مثل PSO أو GA الخ.

نموذج PSO هو سرب من الأفراد يسمى الجسيمات. يتم تهيئة الجسيمات بحلول عشوائية. تتحرك هذه الجسيمات في فضاء البحث عبر العديد من التكرارات من أجل إيجاد حل جديد وأفضل للمشكلة المطروحة. يتم تمثيل كل جسيم بعاملين أحدهما هو الموضع x حيث يكون لكل جسيم موضع محدد وفي البداية يتم تهيئته كموضع أولي. العامل الآخر هو السرعة v ، حيث يتحرك كل جسيم في فضاء البحث وفقاً لسرعة معينة. خلال وقت التكرار t ، تقوم الجسيمات بتحديث موقعها وسرعتها (x و v).

تبعاً لخوارزمية PSO، يوجد نوعان من القيم الأفضل: أحدهما هو $Pbest$ وهو أفضل موقع محلي لكل جسيم في السرب ويجب تحديثه اعتماداً على قيمة تابع الملاءمة لكل جسيم. ثاني أفضل قيمة هي $Gbest$ وهي أفضل قيمة شاملة في السرب بشكل عام. يجب التحقق من هذه القيمة في كل تكرار واستبدالها بـ $Pbest$ لأي فرد في السرب إذا كانت قيمة تابع الملاءمة لـ $Pbest$ عند التكرار الحالي أفضل من قيمة تابع الملاءمة لـ $Gbest$ في التكرار السابق (اعتماداً على ذاكرة البحث).

يمكن تلخيص خطوات خوارزمية PSO على الشكل التالي:

الخطوة 1: تهيئة موقع السرب العشوائي وسرعته

المواقع البدائية و السرعات البدائية لكل الجسيمات يتم توليدها بشكل عشوائي. يعتبر الموقع الحالي لكل جسيم هو الأفضل حالياً أي $Pbest$. يتم اختيار $Gbest$ على أنه أفضل $Pbest$ من بين كل الـ $Pbests$ في السرب.

الخطوة 2: تحديث السرعة

من أجل كل جسيم في السرب، يجب أن نقوم بتحديث سرعة هذا الجسيم كما في المعادلة (1).

$$V_j^{k+1} = w.V_j^k + c1.r1.(Pbest_j^k - X_j^k) + c2.r2.(Gbest^k - X_j^k) \quad (1)$$

حيث أن:

w وزن القصور الذاتي للسرب و تتغير قيمته حسب طبيعة المسألة المطروحة

$r1, r2$ عددين عشوائيين تتغير قيمة كل منهما بين 0 و 1

$c1, c2$ عوامل التسارع التي تحدد جذب كل جسيم باتجاه $Pbest$ و

$Bbest$ و عادة تكون قيمة كل منهما 2

V_j^{k+1} سرعة الجسيم z في التكرار $k+1$

V_j^k سرعة الجسيم z في التكرار k

$Pbest_j^k$ أفضل موقع للجسيم z حتى الآن

X_j^k الموقع الحالي للجسيم z في التكرار k

$Gbest^k$ أفضل موقع للسرب حتى الآن

الخطوة 3: تحديث الموقع

يقوم كل جسيم بتحديث موقعه وفق المعادلة 2.

$$X_j^{k+1} = X_j^k + V_j^k \cdot \Delta t \quad (2)$$

حيث أن: Δt هي الخطوة الزمنية و عادة تساوي 1 ثانية

الخطوة 4: تحديث $Pbest$ لكل جسيم

يجب أن يتم تقييم تابع الملاءمة من أجل كل جسيم. إذا كان موقع الجسيم z في التكرار $k+1$ أفضل

من الموقع الأفضل لهذا الجسيم عند التكرار k فإن الموقع الأفضل لهذا الجسيم يجب أن يتم تحديثه بحيث يأخذ

الموقع الحالي عند التكرار $k+1$ حسب ما يلي:

$$\text{If } (\text{fitness value } (P_j^{K+1}) > \text{fitness value } (Pbest_j^K)) \text{ then } Pbest_j^{K+1} = P_j^{K+1}.$$

الخطوة 5: تحديث $Gbest$

من أجل كل الجسيمات في السرب، إذا كانت قيمة تابع الملاءمة عند أي $Pbest$ لأي جسيم أفضل من

القيمة السابقة ل $Gbest$ فإن $Gbest$ يجب أن يتم تحديثها وقيمتها الجديدة هي $Pbest$ للجسيم الذي له أفضل

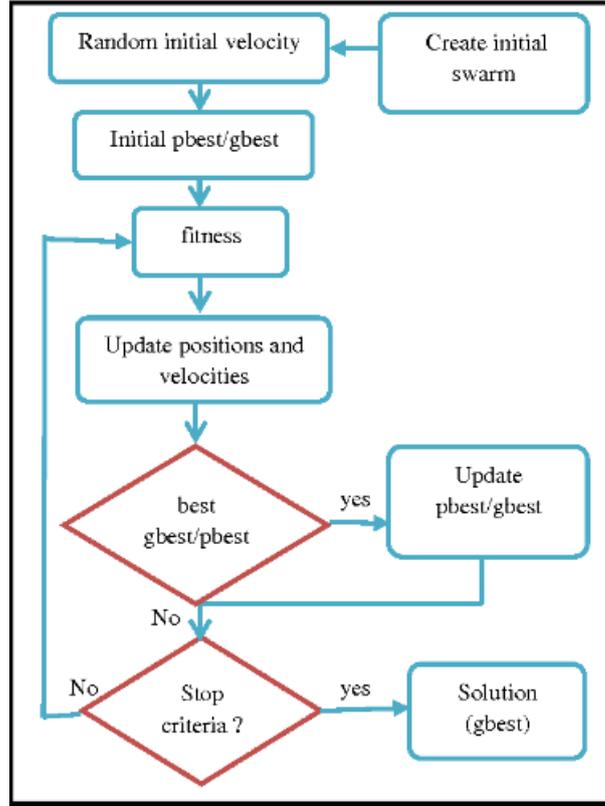
قيمة لتتابع الملاءمة عند $Pbest$ و وفق الشرط التالي:

$$\text{If } (\text{fitness value } (Pbest_j^{K+1}) > \text{fitness value } (Gbest^k)) \text{ then } Gbest^{k+1} =$$

$$Pbest_j^{K+1}$$

الخطوة 6: تكرار الخطوات من 2 إلى 5 حتى تقارب الحلول. يظهر الشكل 1 المخطط التدفقي لهذه

الخوارزمية.



الشكل 1 المخطط التدفقي لخوارزمية PSO

خوارزمية PSO لها العديد من التطبيقات في مجال إيجاد الحل الأمثل (Optimization) و في هذا البحث تم اختبار هذه الخوارزمية على مجموعة من التوابع الرياضية الهامة من أجل اختبار مقدرتها على إيجاد الحل الأمثل لهذه التوابع من أجل توسيع تطبيقها على مسائل مستقبلية هامة.

4.2 خوارزمية التحسين اعتماداً على قانون هنري للغازات HGSO

تعتمد هذه الخوارزمية على قانون هنري للغازات الذي قام العالم ويليام هنري بوضعه عام 1803 [68] و الذي ينص على أن " عند درجة حرارة ثابتة، فإن كمية غاز معروف التي تتحلل في نوع معروف و حجم معروف من سائل تتناسب طردياً مع الضغط الجزئي لذلك الغاز الطافي فوق السائل". وبالتالي فإن قانون هنري يعتمد على درجة الحرارة [32] و يقترح أن انحلالية الغاز S_g تتناسب طردياً مع الضغط الجزئي للغاز P_g كما في المعادلة التالية:

$$S_g = H \times P_g \quad (3)$$

حيث أن H هو ثابت هنري و الذي يكون محدد من أجل نوع معين من الغاز القابل للانحلال عند درجة حرارة معطاة. تتغير ثوابت هنري مع تغير درجة الحرارة وهذا ما يتم وصفه باستخدام معادلة فانت هوف كما يلي:

$$\frac{d \ln H}{d \left(\frac{1}{T} \right)} = \frac{-\nabla_{sol} E}{R} \quad (4)$$

حيث أن $\nabla_{sol} E$ الانتالبي (المحتوى الحراري)، R هو ثابت الغاز . يمكن التعبير عن المعادلة (3) على الشكل

التالي:

$$H(T) = \exp \left(\frac{B}{T} \right) \times A \quad (5)$$

حيث أن A,B بارامترين يعبران عن اعتماد درجة الحرارة على H. و H تابع للبارامترين A,B. يمكن التعبير عن H عند درجة الحرارة المرجعية T=298.15 K كما يلي:

$$H(T) = H^{\theta} \times \exp\left(\frac{-V_{sol}E}{R}\left(\frac{1}{T} - \frac{1}{T^{\theta}}\right)\right) \quad (6)$$

يكون قانون فانط هوف صالحاً عندما يكون المحتوى الحراري(الانتالبي) ثابتاً وبالتالي يتم التعبير عن المعادلة (6) على الشكل التالي:

$$H(T) = \exp\left(-C \times \left(\frac{1}{T} - \frac{1}{T^{\theta}}\right)\right) \times H^{\theta} \quad (7)$$

وبالتالي باستخدام المعادلات من (1) إلى (5) يمكن أن يستخدم قانون هنري لتحديد انحلالية الغازات قليلة الانحلالية في السوائل.

درجة الحرارة و الضغط هما العاملان اللذان يؤثران على انحلالية الغاز حيث أن الغازات تصبح أقل انحلالية عند درجات حرارة عالية أما بالنسبة للضغط، فإن انحلالية الغازات تزداد مع زيادة الضغط.

يمكن تلخيص خطوات خوارزمية PSO على الشكل التالي:

الخطوة 1: عملية التهيئة

عدد الغازات (مجموعة الحلول N) و مواقع الغازات يتم تهيئتها اعتماداً على المعادلة التالية:

$$X_i(t+1) = X_{min} + r \times (X_{max} - X_{min}) \quad (8)$$

حيث أن موقع الغاز رقم i في مجموعة الحلول N يشار إليه ب X_i و r عدد عشوائي بين 0 و 1 و X_{min} , X_{max} هي حدود المسألة المفروضة و t زمن التكرار. يتم تهيئة كل من ثابت هنري للغاز من النوع z و الضغط الجزئي للغاز i في العنقود z و المحتوى الحراري و الثابت من النوع z و هو C_i وفق المعادلة التالية:

$$H_j(t) = l_1 \times rand(0,1), P_{i,j} = l_2 \times rand(0,1), C_j = l_3 \times rand(0,1) \quad (9)$$

حيث أن l_1 , l_2 , l_3 معرفة كثوابت بقيم مساوية وهي على الشكل التالي: $1E - 02, 100, 1E - 02$

02

الخطوة 2: عملية العنقدة

يتم تقسيم الغازات المتشابهة في عناقيد ولها نفس ثابت هنري.

الخطوة 3: التقييم

يتم تقييم كل عنقود من أجل تعريف الغاز الأفضل والذي يحقق حالة التوازن الأعلى من الغازات الأخرى من نفس النوع. ثم يتم اعطاء الغازات ترتيباً من أجل الحصول على الغاز المثالي في المجموعة الكاملة.

الخطوة 4: تحديث ثابت هنري

يتم تقييم ثابت هنري وفق المعادلة التالية:

$$H_j(t+1) = H_j(t) \times \exp\left(-C_j \times \left(\frac{1}{T(t)} - \frac{1}{T^{\theta}}\right)\right), T(t) = \exp\left(-\frac{t}{iter}\right) \quad (10)$$

الخطوة 5: تحديث الانحلالية

يتم تحديث الانحلالية وفق المعادلة التالية:

$$S_{i,j}(t) = K \times H_j(t+1) \times P_{i,j}(t) \quad (11)$$

حيث أن $S_{i,j}$ هي انحلالية الغاز i من العنقود z و $P_{i,j}$ هي الضغط الجزئي للغاز i في العنقود z بينما K ثابت.

الخطوة 6: تحديث الموقع

يتم تحديث الموقع وفق المعادلة التالية:

$$X_{i,j}(t+1) = X_{i,j}(t) + F \times r \times \gamma \times (X_{i,best}(t) - X_{i,j}(t)) + F \times r \times \alpha \times (S_{i,j}(t) \times X_{best}(t) - X_{i,j}(t)) \quad (12)$$

حيث أن:

$$\gamma = \beta \times \exp\left(-\frac{F_{best}(t) + \varepsilon}{F_{i,j}(t) + \varepsilon}\right), \varepsilon = 0.05 \quad (13)$$

γ هي قابلية الغاز i من العنقود z على التفاعل مع الغازات في نفس العنقود، α هي تأثير الغازات الأخرى على الغاز i في العنقود z . بالمقابل F_{best} هو قيمة الملاءمة لأفضل غاز في كامل النظام. F هو العلم الذي يغير اتجاه عميل البحث من - إلى +. أما $X_{i,best}$ و X_{best} هما بارامتران مسؤولان عن توازن إمكانيات الاستكشاف و الاستغلال بالتحديد: $X_{i,best}$ هي الغاز الأفضل في العنقود z و X_{best} هي الغاز الأفضل في المجموعة ككل.

5. التوابع الرياضية المستخدمة في الاختبار

يوجد العديد من التوابع الرياضية التي تستخدم من أجل اختبار خصائص خوارزميات التحسين مثل معدل التقارب و الدقة و المتانة و الأداء العام. بعض هذه التوابع المستخدمة في هذا البحث [32] هي:

5.1 تابع Three-Hump Camel

الصيغة الرياضية لهذا التابع هي

$$f(x, y) = 2x^2 - 1.05x^4 + \frac{x^6}{6} + xy + y^2 \quad (14)$$

لهذا التابع قيمة أصغرية شاملة عند (0,0). يستخدم لاختبار خوارزميات إيجاد الحل الأمثل حيث تطبق كل خوارزمية على هذا التابع و يتم إيجاد القيم المثلى التي تعطيها هذه الخوارزميات و تتم المقارنة بين أداء هذه الخوارزميات كما تم في هذا البحث.

5.2 تابع Branin

الصيغة الرياضية لهذا التابع تعطى بالمعادلة التالية:

$$f(x) = \left(x_2 - \frac{5.1}{4\pi^2}x_1^2 + \frac{5}{\pi}x_1\right)^2 + 10\left(1 - \frac{1}{8\pi}\right)\cos(x_1) + 10 \quad (15)$$

5.3 تابع Griewank

الصيغة الرياضية لهذا التابع تعطى بالمعادلة التالية:

$$f(x) = 1 + \frac{1}{200} \sum_{i=1}^2 x_i^2 - \prod_{i=1}^2 \cos\left(\frac{x_i}{\sqrt{i}}\right) \quad (16)$$

6. تطبيق خوارزمية PSO

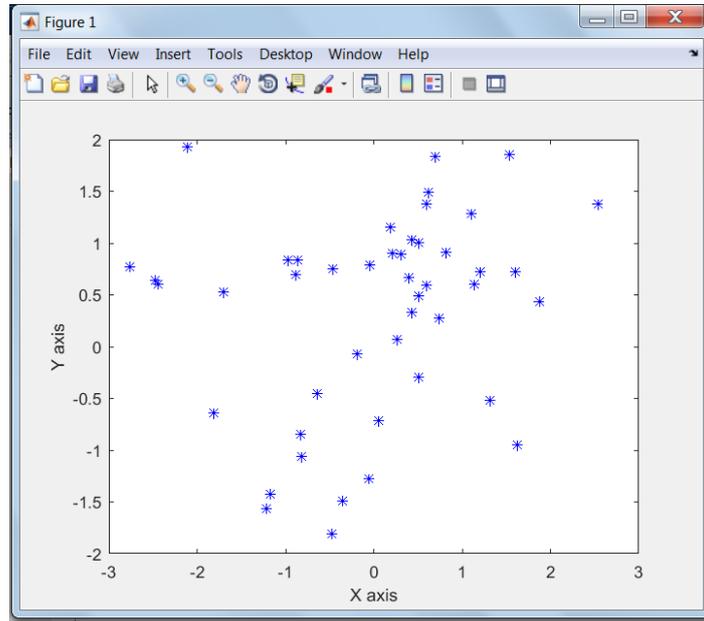
تمت كتابة برامج تنفيذ خوارزمية الاختبار للتتابع الثلاثة السابقة باستخدام Matlab 2017. تمت تجربة بارامترات الخوارزمية PSO من أجل التتابع السابقة. يظهر الشكل 1 كيفية تصرف السرب أثناء تطبيق خوارزمية PSO على التابع Three-Hump Camel من أجل البارامترات:

iterations = 50;

w = 0.5;

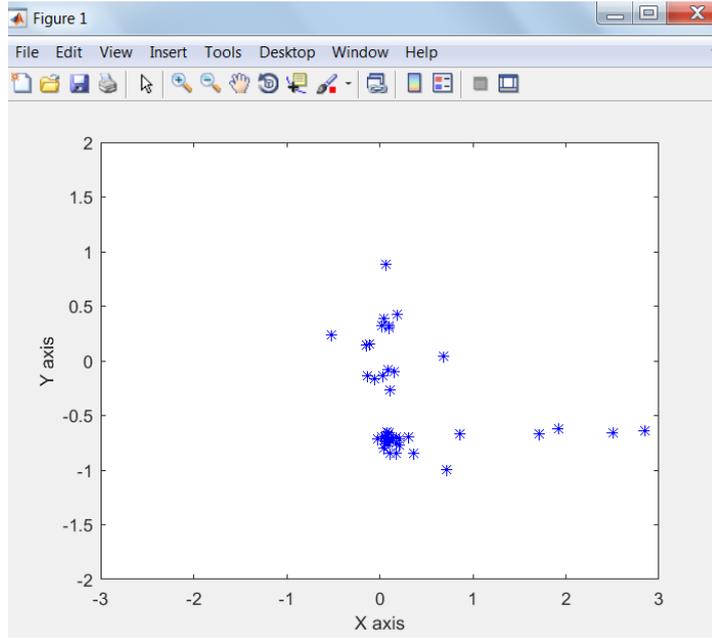
c_factor = 2;

swarm_size = 49;



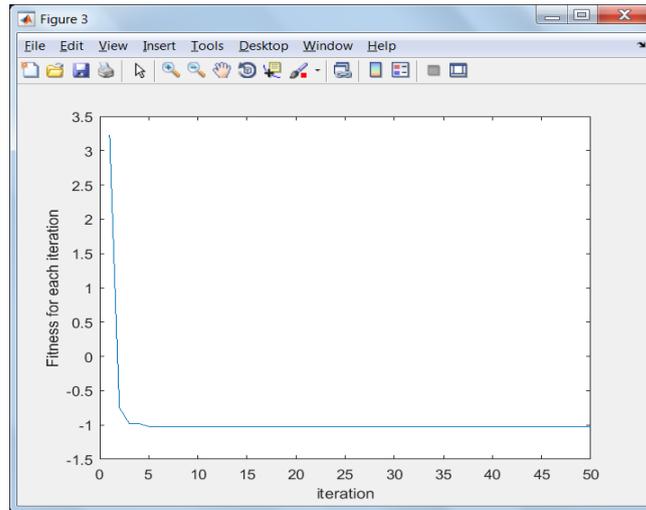
الشكل 2 بدء السرب بالبحث عن القيمة المثالية

الشكل 2 يظهر طريقة تصرف السرب الذي يتألف من عدد من الأفراد وقد تم تمثيل هذه الأفراد على شكل (*) و المحورين X و Y يحددان فضاء البحث لهذه الأفراد أو للسرب بشكل كامل. يظهر الشكل 3 كيف يتقارب السرب بعد اكتمال عملية البحث حسب البارامترات السابقة



الشكل 3 تقارب السرب باتجاه الحل الأمثل

يظهر الشكل 4 النتائج النهائية لإيجاد القيمة الأفضل للتابع Three_Hump_Camel



الشكل 4 النتائج النهائية لعملية البحث لتابع Three_Hump_Camel

يظهر الشكل 5 القيم التي تم الوصول إليها بعد تنفيذ برنامج النمذجة المكتوب بلغة Matlab حيث تظهر ال workspace أن القيمة المثلى للتابع هي -1.316 و هي القيمة المثلى المعروفة للتابع.

Name	Value
swarm	49x4x2 double
swarm_size	49
temp	-1.0316
val	0.0041
x	-0.0562
y	-0.0537

الشكل 5 القيمة المثالية للتابع Three_Hump_Camel وهي - 1.0316

بعد أن تم إظهار عملية البحث للسرب بالنسبة للتابع Three-Hump Camel بالنسبة لاختبار التتابع البقية تم إظهار النتائج النهائية عند البحث عن القيمة الأفضل.

البارامترات التجريبية لاختبار التابع Branin تم الحصول عليها بالتجريب فكانت على الشكل التالي:

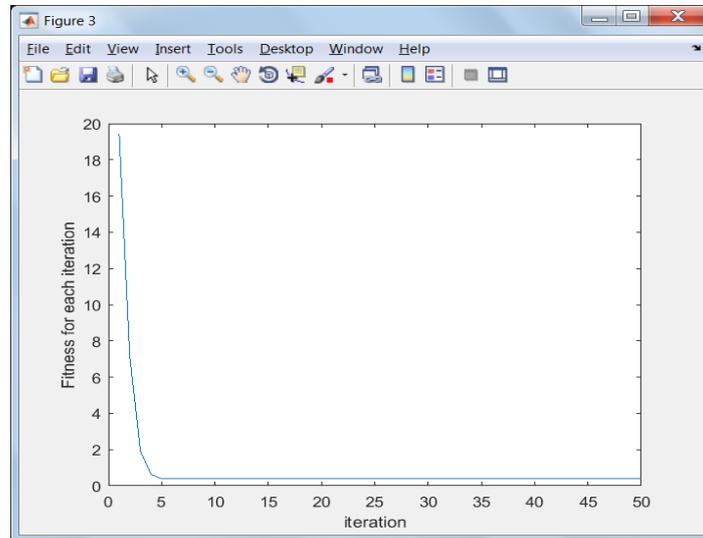
iterations = 50;

w = 0.5;

c_factor = 2;

swarm_size = 49;

الشكل 6 يظهر النتائج النهائية للبحث عن القيمة الأفضل للتابع Branin.



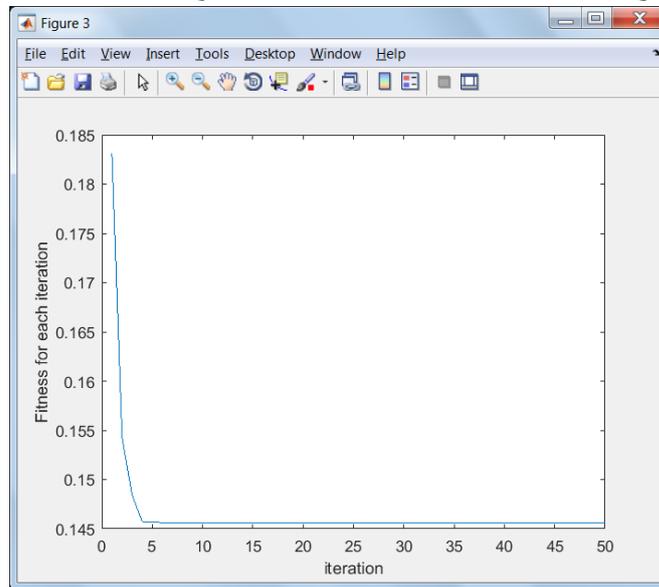
الشكل 6 إيجاد القيمة الأفضل لتابع Branin

الشكل 7 يظهر القيم التي تم الحصول عليها بعد تنفيذ الخوارزمية PSO على التابع Branin

Workspace	
Name ▲	Value
swarm	49x4x2 double
swarm_size	49
temp	0.3979
val	20.5129
x	6.5220
y	-3.7973

الشكل 7 القيمة المثالية للتابع 0.3979 التي تم الحصول عليها

يظهر الشكل 8 النتائج النهائية لتطبيق خوارزمية PSO على التابع Griewank



الشكل 8 النتائج النهائية لتطبيق خوارزمية PSO على التابع Griewank

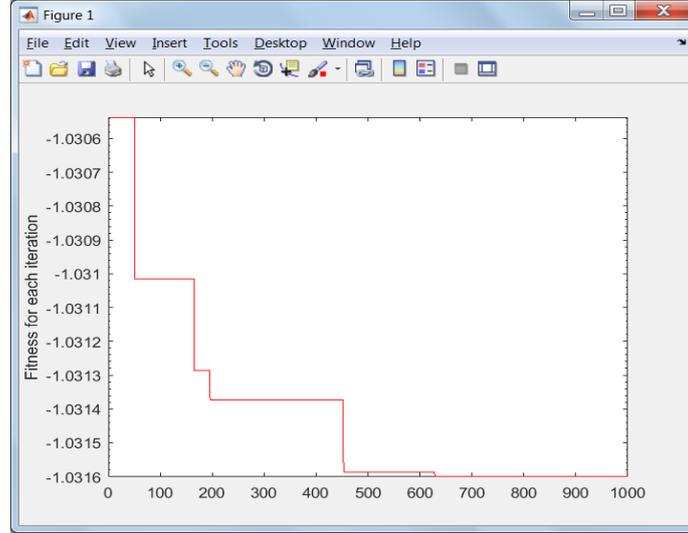
من الملاحظ من قيم ال workspace لبرنامج Matlab في الشكل 9 أن القيمة المثالية للمتحوّل temp التي تمثل القيمة المثالية المنشودة هي 0.1456 بينما من المعلوم أن القيمة المثالية للتابع Griewank هي 0. إذاً نستنتج فشل الخوارزمية PSO في الوصول إلى القيمة المثالية لهذا التابع.

Workspace	
Name ▲	Value
swarm	49x4x2 double
swarm_size	49
temp	0.1456
val	1.8106
x	6.8725
y	5.9606

الشكل 9 القيمة المثالية التي أوجدتها خوارزمية PSO هي 0.1456

7. تطبيق خوارزمية HGSO

تم اختبار أداء خوارزمية HGSO أيضاً على التتابع الثلاثة السابقة. تم تصميم واجهة رسومية من أجل إدخال البارامترات. تابع **Three_Hump_Camel**: من المعلوم أن التابع له قيمة مثلى بين -0.0898 و 0.7126 و قد قامت خوارزمية HGSO بإيجاد هذه القيمة وهي: -1.316 كما هو واضح في الشكل 10



الشكل 10 تطبيق خوارزمية HGSO على التابع Three_Hump_Camel

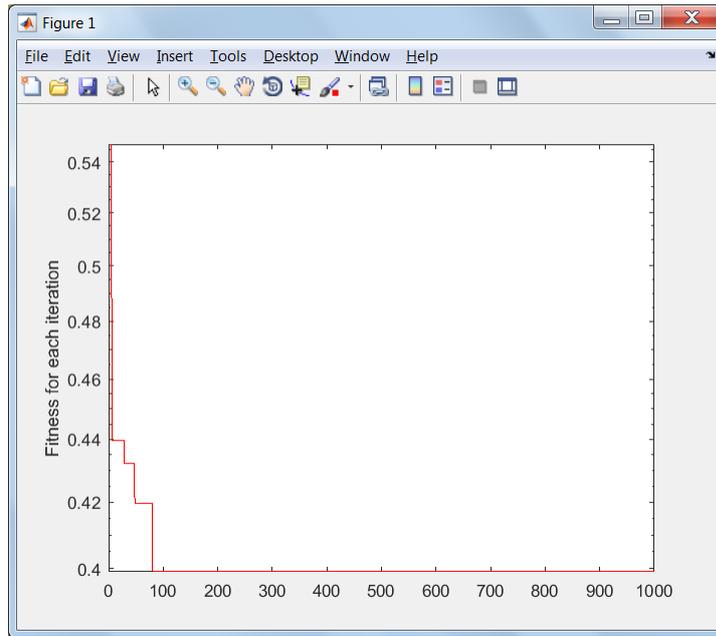
يظهر الشكل 11 قيمة Gbest التي تم الحصول عليها للتابع Three_Hump_Camel وهي -1.0316 وهي نفسها التي أوجدتها الخوارزمية PSO وهي مطابقة للقيمة المثالية المعروفة للتابع.

Name	Value
correction_fac...	2
G_best	-1.0316
G_best_iter	1x1000 double
gbest	16
gbest_matrix	50x3 double
i	49

الشكل 11 القيمة المثالية هي -1.0316 وقد تم الوصول إليها

تابع Branin

يظهر الشكل 12 سلوك الخوارزمية HGSO في إيجاد القيمة المثالية للتابع Branin. من الملاحظ أنه بالنسبة لهذا التابع و للتتابع الأخرى يتم البدء من البحث من قيم ابتدائية يتم تهيئتها في بداية عملية البحث.



الشكل 12 تطبيق الخوارزمية HGSO على التابع Branin

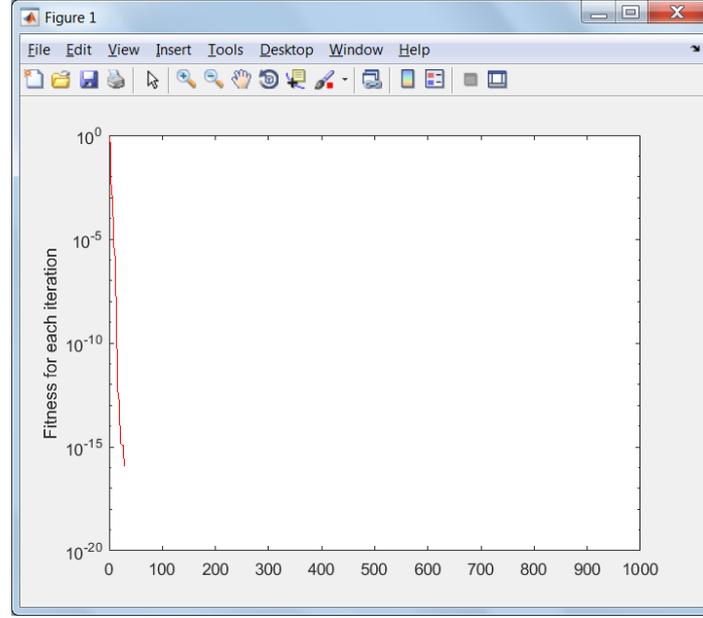
من المعلوم أن هذا التابع له قيمة مثلى هي 0.397887 و قد قامت الخوارزمية HGSO بإيجاد قيمة قريبة من هذه القيمة المثلى و هي: 0.3890 كما يظهر من الشكل 13.

Name	Value
correction_fac...	2
G_best	0.3985
G_best_iter	1x1000 double
gbest	16
gbest_matrix	50x3 double
i	49

الشكل 13 القيمة الأمثل التي نتجت من تطبيق خوارزمية HGSO للتابع

تابع Griewank

يظهر الشكل 14 تطبيق خوارزمية HGSO على هذا التابع و إيجاد القيمة الأمثل له.



الشكل 14 تطبيق الخوارزمية HGSO على التابع Griewank

يظهر الشكل 15 قيم المتحولات التي تم الحصول عليها و من بين هذه المتحولات هي القيمة المثلى للتابع و هي 0 و هي بالفعل القيمة المثلى المعروفة لهذا التابع. إذاً من الملاحظ الدقة للخوارزمية HGSO في إيجاد هذه القيمة

Name	Value
correction_fac...	2
G_best	0
G_best_iter	1x1000 double
gbest	16
gbest_matrix	50x3 double
i	49

الشكل 15 القيمة المثالية هي 0 و قد تم الوصول إليها

8. المناقشة و الاستنتاجات

من خلال الدراسة النظرية و التحليل الرياضي و التطبيق العملي للخوارزميتين HGSO و PSO تبين ما يلي:

1. تقوم كلا الخوارزميتين بإيجاد الحل الأمثل لمسألة عن طريق البحث و ذلك وفقاً لبارامترات تختلف حسب المسألة المطروحة.
2. يمكن استخدام كلا الخوارزميتين و تطبيقهما على طيف واسع من المسائل التي تحتاج إيجاد الحل الأمثل.
3. يختلف أداء الخوارزميتين من مسألة إلى أخرى و حسب البارامترات التي تؤثر على عمل كل منهما.

4. من الملاحظ أن خوارزمية HGSO تعطي نتائج أدق من خوارزمية PSO حيث أنه بالنسبة للتابع Griewank أعطت الخوارزمية HGSO القيمة المتوقعة و 0 بينما أعطت PSO قيمة أكبر من 0.
5. بالنسبة للتابع branin أعطت الخوارزمية PSO القيمة 0.3979 و هي أدق من القيمة التي أعطتها HGSO و هي 0.3985 حتى ولو كانت القيمتان متقاربتا جداً ولكن بعض التطبيقات قد تطلب دقة مماثلة لهذه الدقة.
6. خوارزمية PSO أسرع في التقارب و إيجاد الحل الأمثل حيث أنه يكفي 50 تكرار للتقارب بينما الملاحظ أن خوارزمية HGSO قد تأخذ أحياناً أكثر من 500 تكرار كما هو الحال في تابع Three_Hump_Camel.
7. يمكن القول أن هناك تبادل بين الدقة لصالح HGSO و السرعة لصالح PSO.
8. يمكن من خلال تغيير بعض البارامترات مثل inertia الحصول على دقة أفضل لخوارزمية PSO ولكن ذلك سيؤثر على سرعة هذه الخوارزمية حيث أن زيادة قيمة inertia تؤدي إلى زيادة فضاء البحث و بالتالي هذا يتطلب تكرارات أكثر.

9. التوصيات

- لقد أثبتت هذه الدراسة أهمية الخوارزميتين PSO و HGSO في إيجاد الحل الأمثل لعدد من المسائل الرياضية الشهيرة و المعروفة وبالتالي يمكن التوصية بما يلي:
1. استخدام خوارزميتي HGSO و PSO و تطبيقهما على مسائل عملية هامة تتطلب إيجاد الحل الأمثل على سبيل المثال مسائل تصميمية في المجالات الهندسية المختلفة.
 2. مقارنة أداء هاتين الخوارزميتين مع خوارزميات تحسين أخرى لها نفس مبدأ العمل مثل خوارزمية النمل، و الخوارزميات الجينية من أجل الوصول إلى خوارزمية أفضل.
 3. انشاء إطار عمل يضم جميع الخوارزميات التي تعمل على إيجاد الحل الأمثل و تطبيق هذه الخوارزميات على مسائل مختلفة من أجل إيجاد الفوارق بين هذه الخوارزميات واستخدام الأفضل.

10. المراجع

- [1] A.R. Simpson, G.C. Dandy, L.J. Murphy, *Genetic algorithms compared to other techniques for pipe optimization*, J. Water Resour. Plan. Manag. 120 (4) (1994) 423–443.
- [2] C. James, *Introduction to Stochastics Search and Optimization*, John Wiley and Sons, Hoboken, NJ, 2003.
- [3] M.N. Ab Wahab, S. Nefti-Meziani, A. Atyabi, *A comprehensive review of swarm optimization algorithms*, PLoS One 10 (5) (2015) e0122827.
- [4] I. Boussaid, J. Lepagnot, P. Siarry, *A survey on optimization metaheuristics*, Inf. Sci. 237 (2013) 82–117.
- [5] X.-S. Yang, *Nature-inspired algorithms and applied optimization*, Vol. 744, Springer, 2017.
- [6] Z. Beheshti, S.M.H. Shamsuddin, *A review of population-based metaheuristic algorithms*, Int. J. Adv. Soft Comput. Appl 5 (1) (2013) 1–35.
- [7] O. Bozorg-Haddad, *Advanced Optimization by Nature-Inspired Algorithms*, Springer, 2018.
- [8] S. Mirjalili, A. Lewis, *The whale optimization algorithm*, Adv. Eng. Softw. 95 (2016) 51–67.
- [9] O. Olorunda, A.P. Engelbrecht, *Measuring exploration/exploitation in particle swarms using swarm diversity*, in: *Evolutionary Computation, 2008. CEC 2008.(IEEE World Congress on Computational Intelligence)*. IEEE Congress on, IEEE, 2008, pp. 1128–1134.
- [10] L. Lin, M. Gen, *Auto-tuning strategy for evolutionary algorithms: balancing between exploration and exploitation*, Soft Comput. 13 (2) (2009) 157–168.
- [11] W. Dong, M. Zhou, *A supervised learning and control method to improve particle swarm optimization algorithms*, IEEE Trans. Syst. Man Cybernet. Syst. 47 (7) (2017) 1135–1148.
- [12] T. Mareda, L. Gaudard, F. Romerio, *A parametric genetic algorithm approach to assess complementary options of large scale windsolar coupling*, IEEE/CAA J. Automat. Sinica 4 (2) (2017) 260–272.
- [13] A.A. Ismaeel, I.A. Elshaarawy, E.H. Houssein, F.H. Ismail, A.E. Hassanien, *Enhanced elephant herding optimization for global optimization*, IEEE Access 7 (2019) 34738–34752.
- [14] S. Mirjalili, *Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm*, Knowl.-Based Syst. 89 (2015) 228–249.
- [15] A.O. Topal, O. Altun, *A novel meta-heuristic algorithm: Dynamic virtual bats algorithm*, Inform. Sci. 354 (2016) 222–235.
- [16] J. Zhao, S. Liu, M. Zhou, X. Guo, L. Qi, *Modified cuckoo search algorithm to solve economic power dispatch optimization problems*, IEEE/CAA J. Automat. Sinica 5 (4) (2018) 794–806.
- [17] R. Eberhart, J. Kennedy, *A new optimizer using particle swarm theory*, in: *Micro Machine and Human Science, 1995. MHS'95.*, Proceedings of the Sixth International Symposium on, IEEE, 1995, pp. 39–43.
- [18] M. Dorigo, G. Di Caro, *Ant colony optimization: a new meta-heuristic*, in: *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)*, Vol. 2, IEEE, 1999, pp. 1470–1477.

- [19] S. Mirjalili, Dragonfly algorithm: *a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems*, Neural Comput. Appl. 27 (4) (2016) 1053–1073.
- [20] G.-G. Wang, S. Deb, X.-Z. Gao, L.D.S. Coelho, *A new metaheuristic optimisation algorithm motivated by elephant herding behaviour*, Int. J. Bio-Inspired Comput. 8 (6) (2016) 394–409.
- [21] J.H. Holland, *Genetic algorithms*, Sci. Amer. 267 (1) (1992) 66–73.
- [22] I. Rechenberg, *Evolutionsstrategien*, in: *Simulationmethoden in der Medizin und Biologie*, Springer, 1978, pp. 83–114.
- [23] S. Kirkpatrick, C.D. Gelatt, M.P. Vecchi, *Optimization by simulated annealing*, science 220 (4598) (1983) 671–680.
- [24] E. Aarts, J. Korst, *Simulated Annealing and Boltzmann Machines*, John Wiley and Sons Inc., New York, 1988.
- [25] E. Rashedi, H. Nezamabadi-Pour, S. Saryazdi, *Gsa: a gravitational search algorithm*, Inf. Sci. 179 (13) (2009) 2232–2248.
- [26] B. Alatas, *Acroa: artificial chemical reaction optimization algorithm for global optimization*, Expert Syst. Appl. 38 (10) (2011) 13170–13180.
- [27] V.K. Patel, V.J. Savsani, *Heat transfer search (hts): a novel optimization algorithm*, Inform. Sci. 324 (2015) 217–246.
- [28] M. Abdechiri, M.R. Meybodi, H. Bahrami, *Gases brownian motion optimization: an algorithm for optimization (gbmo)*, Appl. Soft Comput. 13 (5) (2013) 2932–2946.
- [29] M.D. Li, H. Zhao, X.W. Weng, T. Han, *A novel nature-inspired algorithm for optimization: Virus colony search*, Adv. Eng. Softw. 92 (2016) 65–88.
- [30] P. Civicioglu, *Backtracking search optimization algorithm for numerical optimization problems*, Appl. Math. Comput. 219 (15) (2013) 8121–8144.
- [31] M. Anbar and D. P. Vidyarthi, *Router CPU Time Management in Cellular IP Network using PSO*, International Journal of Advancements in Computing Technology (IJACT), vol. 1, no. 2, 2009, pp. 48-55.
- [32] Fatma A. Hashim a, Essam H. Houssein b, Mai S. Mabrouk c, Walid Al-Atabany a, Seyedali M, d, *Henry gas solubility optimization: A novel physics-based algorithm*, Future Generation Computer Systems 101 (2019) 646–667.