

تطوير خوارزمية النحل واستخدامها في إيجاد الحلول المثلى للدوال

إياد هاللي، وزيد سالم

قسم هندسة الحواسيب، كلية الهندسة الكهربائية والإلكترونية، جامعة حلب،

حلب، الجمهورية العربية السورية

iyadhe@gmail.com

(قدم للنشر في ١٤٣٤/٦/٣هـ؛ وقبل للنشر في ١٤٣٥/٤/١٧هـ)

الكلمات المفتاحية: خوارزمية النحل، الحلول المثلى، الحلول المثلى للدوال، الذكاء الصناعي.

ملخص البحث. هناك العديد من خوارزميات الذكاء الصناعي التي تهتم بمسألة إيجاد الحلول المثلى للمسائل المتعددة، ومن أشهر هذه الخوارزميات خوارزمية النحل. تعتمد هذه الخوارزمية على مبدأ عمل خلية النحل في العثور على حقول الأزهار لجمع الرحيق، وقد استُخدمت في إيجاد الحلول المثلى وأعطت نتائج مقبولة. يركز هذا البحث على تحسين أداء خوارزمية النحل من خلال إيجاد طريقتين جديدتين لتعيين بعض الوسائط الهامة في هذه الخوارزمية، والمتمثلة في تحديد المجتمع الأولي لعدد النحللات الباحثة وما يرتبط به من عدد النحللات الفضلى وعدد النحللات المرسل إلى جوار كل نحلة من النحللات الممتازة (النخبة)، حيث تعتمد الطريقة الافتراضية للخوارزمية على تهيئة هذه الوسائط بقيم عشوائية. يقدم هذا البحث طريقتين لتعيين هذه الوسائط، ثم يطبق هاتين الطريقتين في مسألة إيجاد الحلول المثلى الدنيا لبعض الدوال الرياضية، ويقارن النتائج والأداء مع الخوارزمية الأصلية.

المقدمة

خوارزميات إيجاد الحلول المثلى، مثل مسألة إيجاد الحلول المثلى للدوال (Zaidi, 2006)، حيث يكون عدد الحلول المراد البحث فيها كبيراً جداً. يوجد العديد من الخوارزميات المستخدمة في هذا المجال، مثل الخوارزمية الجينية Genetic Algorithm (Goldberg, 1989)، وخوارزمية النمل Ant Algorithm (Dorigo et al., 1996)،

يُعتبر علم الذكاء الصناعي من أهم وأحدث الفروع في مجال المعلوماتية، وقد تم التركيز عليه بشكل كبير في الآونة الأخيرة نتيجة التطورات الهائلة في مجال العتاد الصلب وضخامة البيانات وتعدد المشاكل ذات الحلول الكثيرة، ولعل من أهم فروع الذكاء الصناعي

القسم الرابع مزايا هذه الخوارزمية ونقاط ضعفها، ويتناول القسم الخامس شرحاً مفصلاً للوسيط n والوسائط الأخرى المرتبطة به، ويعرض القسم السادس الطريقتين الجديديتين المنجزتين في هذا البحث لاختيار هذه الوسائط، أما القسم السابع فيعرض النتائج والمقارنات التي تم الحصول عليها من تطبيق الخوارزمية الأصلية والمطورة لإيجاد الحلول المثلى لمجموعة دوال رياضية، ويعرض القسم الثامن الخلاصة والأعمال المستقبلية.

خوارزمية النحل

عبارة عن خوارزمية إيجاد الحل الأمثل، وفكرتها مأخوذة من سلوك النحل المتبع لجمع الرحيق.

مبدأ عمل النحل في الطبيعة

يمكن تلخيص عمل النحل للحصول على الرحيق بالخطوات التالية :

- 1- تستطيع خلية النحل توسيع بحثها ليمتد عبر مسافات طويلة (أكثر من ١٠ كم) وفي اتجاهات مختلفة في نفس الوقت لاستكشاف أكبر عدد من مصادر الطعام (الرحيق). حيث يتم إرسال عدد كبير من النحل إلى المناطق الغنية بالأزهار، أما المناطق الفقيرة بالأزهار فيتم إرسال عدد قليل من النحل إليها.

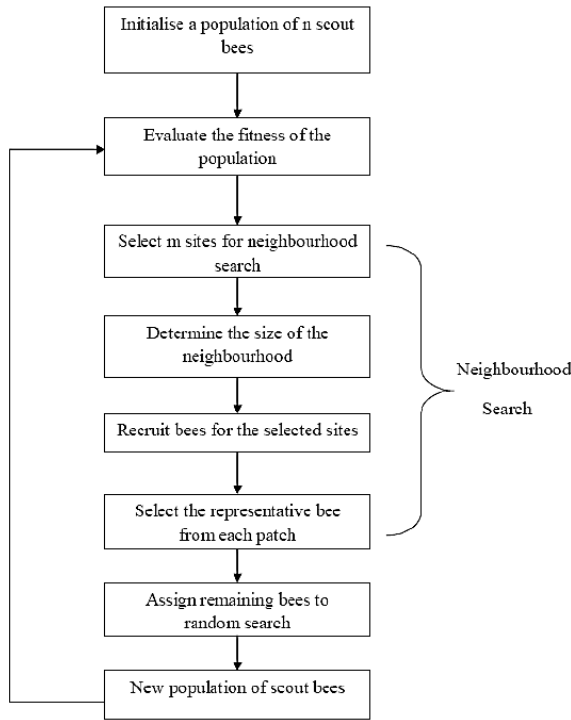
وخوارزمية النحل Bees Algorithm. يركّز هذا البحث على خوارزمية النحل التي طُورت في جامعة كارديف عام ٢٠٠٥م من قبل مجموعة من الباحثين (Pham, 2005)، وتعتمد على مبدأ عمل النحل في الطبيعة لجمع الرحيق. تتميز هذه الخوارزمية بمقدرتها على إيجاد الحلول المثلى بفعالية عالية دون الوقوع في مشكلة النهاية المحلية Local Minima (Zhao et al., 2009). إلا أن لها بعض نقاط الضعف، تتمثل باحتوائها على عدد وسائط كبير نسبياً، كما أن اختيار قيم هذه الوسائط يتم بشكل عشوائي. ومن هنا جاءت فكرة هذا البحث الذي يعمل على تطوير هذه الخوارزمية من خلال إنشاء طريقتين جديديتين لاختيار بعض أهم وسائط هذه الخوارزمية المتمثلة بحجم مجتمع النحل n ، وما يرتبط به من عدد النحل الفضلى m ، وعدد النحل المرسل إلى جوار كل نحلة من النحل الممتازة (أفضل قيم في النحل الفضلى) n_2 ، وذلك بدلاً من اختيارها بشكل عشوائي، سيتم من خلال هذا البحث تطبيق الخوارزمية المطورة لإيجاد القيم المثلى لبعض الدوال الرياضية الشهيرة ومقارنة النتائج مع الخوارزمية الأصلية.

نُظّم هذا البحث كما يلي : يعرض القسم الثاني خوارزمية النحل من حيث مبدأ عمل النحل في الطبيعة لجمع الرحيق، وخوارزمية النحل المحضرة اعتماداً على مبدأ عمل النحل في الطبيعة. أما القسم الثالث فيعرض بعض تطبيقات خوارزمية النحل، في حين يتناول

- ٢- تبدأ عملية جمع الرحيق من الخلية حيث يتم إرسال مجموعة من النحللات الكشافة (الباحثة) للبحث عن الرحيق، وتتحرك النحللات الباحثة من موقع إلى آخر بشكل عشوائي.
- ٣- تُقيم النحللات الباحثة المواقع المزارعة حسب وفرة الغذاء فيها.
- ٤- تتجه النحللات الباحثة إلى أرض الرقص لإنجاز رقص دوراني Round Dance للمسافات القريبة، ورقص اهتزازي Waggle Dance للمسافات البعيدة.
- ٥- تفهم النحللات هذا الرقص الذي يحتوي على المعلومات التالية (Sahran, 2006):
- اتجاه مواقع الغذاء.
 - بعد المواقع عن الخلية.
 - معدل جودة المواقع (وفرة الغذاء).
- خوارزمية النحل المقترحة**
- أولاً يجب تهيئة الخوارزمية بالوسائط التالية:
- حجم المجتمع (عدد النحللات الباحثة) n .
 - عدد المواقع الفضلى m مأخوذة من n .
 - عدد المواقع الممتازة (النخبة) e مأخوذة من m .
 - عدد النحللات المرسله للمواقع e الممتازة (n_2) nep .
 - عدد النحللات المرسله للمواقع $m-e$ وهي (n_1) nsp .
 - حجم منطقة الجوار ngh التي تتضمن الموقع والمنطقة المجاورة له.
- عدد مرات تكرار خطوات الخوارزمية $imax$ ، كما يمكن تكرار الخوارزمية حتى يتحقق شرط ما، مثلاً القيمة المطلقة للخطأ بين الحل المطلوب والحل الناتج عن تطبيق الخوارزمية أقل من قيمة معينة، ويمكن دمج أكثر من شرط معاً.
- ونقدم فيما يلي شرحاً لخطوات الخوارزمية:
- ١- تهيئة عدد مجتمع النحللات الباحثة Population بقيمة n عشوائية: تبدأ الخوارزمية بتهيئة عدد عشوائي مقداره n نحلة باحثة وتوزيع هذه النحللات بشكل عشوائي في فضاء الحلول للمسألة المدروسة.
- ٢- تقييم مجتمع النحللات الباحثة: يتم هنا تقييم المواقع التي تمت زيارتها من قبل النحللات الباحثة من خلال دالة تقييم $fitness$ تتعلق بالمسألة المدروسة.
- ٣- طالما كان شرط التوقف غير محقق فسيتم تشكيل مجتمع جديد وفق الخطوات من ٤ إلى ٧.
- ٤- اختيار جوار للبحث مقداره ngh : يتم في هذه الخطوة اختيار النحللات التي تمتلك الملاءمة الفضلى m وجعلها النحللات المختارة، كما يتم اختيار جوار لهذه النحللات مقداره ngh للبحث فيه.
- ٥- تجنيد نحللات للمواقع الفضلى (نحللات أكثر عددها n_2 للمواقع الممتازة e ، ونحللات أقل

1. Initialise population with random solutions.
2. Evaluate fitness of the population.
3. While (stopping criterion not met)
//Forming new population.
4. Select best m sites for neighbourhood search.
5. Recruit bees for selected sites (more bees for elite e sites) and evaluate the fitness.
6. Select the fittest bee from each patch.
7. Assign remaining bees to search randomly and evaluate their fitness.
8. End While.

الشكل رقم (١). الكود الزائف لخوارزمية النحل (Ghanbarzadeh, 2007).



الشكل رقم (٢). المخطط النهجي لخوارزمية النحل (Ahmad, 2012).

عددها $n1$ لباقي المواقع الفضلى) وتقييم ملاءمة النحل.

٦- اختيار النحلة الأنسب من كل موقع (ذات الملاءمة fitness الأفضل) لتشكيل المجتمع النحلي التالي. ولا يوجد مثل هذا القيد في الطبيعة، ولكن وضع هنا لإنقاص عدد النقاط المطلوب اكتشافها.

٧- إسناد النحل المتبقية في المجتمع بشكل عشوائي ضمن فضاء الحلول للمسألة المدروسة وتقييم نتائجها.

٨- يتم تكرار الخطوات من ٣ إلى ٧ حتى يتحقق شرط التوقف (مثلاً انتهاء عدد مرات التكرار $imax$).

وفي نهاية كل مرحلة، تمتلك الخلية جزأين تستخدمهما في المجتمع الجديد هما: نحللات فضلى مأخوذة من المجتمع السابق مع الجوار، ونحللات باحثة أخرى عددها $n-m$ تُوجه إلى عمليات بحث عشوائية جديدة ضمن فضاء حلول المسألة المدروسة.

يبين الشكل رقم (١) الكود الزائف pseudocode لخوارزمية النحل، ويبين الشكل رقم (٢) المخطط النهجي لهذه الخوارزمية.

- ١- تحسين وسائط الشبكة العصبونية SVM من أجل حل مشكلة شوائب الخشب Wood Defect (Otri S, 2007).
- ٢- تجميع البيانات: حل مشكلة النهايات المحلية لخوارزمية التجميع K-means (Al-Jabbouli, 2007).

تطبيقات خوارزمية النحل

تعتبر خوارزمية النحل من الخوارزميات الحديثة المستخدمة في مجال إيجاد الحلول المثلى، ومن أهم تطبيقاتها:

يعتبر حجم المجتمع n من الوسائط الأساسية والهامة في خوارزمية النحل. حيث يؤدي إنقاص عدد النحل إلى فرص أقل في الوصول إلى الحل الأمثل من أجل عدد تكرارات معينة (التقارب البطيء من الحل)، أما زيادة عدد النحل إلى شكل كبير فيؤدي إلى الوصول للحل بشكل أسرع، ولكنه يؤدي إلى زيادة عدد مرات التقييم (بطئ الخوارزمية نتيجة زيادة حسابات التقييم)، فمثلاً من أجل ١٠٠٠ تكرار وبتنفيذ الخوارزمية عدة مرات، فإن عملية فشل الخوارزمية في الوصول إلى الحل الأمثل مع حجم مجتمع صغير تكون أكبر منها في حالة حجم مجتمع كبير. كما أنّ هناك علاقة عكسية بين عدد النحل إلى الباحث و عدد مرات تكرار خطوات الخوارزمية، فكلما زاد عدد النحل إلى الباحث أمكن الوصول إلى الحل بعدد مرات تكرار أقل، وكلما قل عدد النحل إلى الباحث زاد عدد مرات التكرار للوصول إلى الحل. يبين الشكل رقم (٣) العلاقة بين حجم المجتمع وعدد مرات التكرار k . كما يُظهر الشكل رقم (٤) العلاقة الطردية بين حجم المجتمع ومتوسط عدد مرات تقييم الدالة، ويتضح من هذا الشكل أنّ زيادة حجم المجتمع تؤدي إلى زيادة عدد مرات التقييم (دالة الملاءمة).

ولتحقيق أداءٍ عالٍ (موثوقية) للخوارزمية، يجب أن يتم اختيار حجم المجتمع أقل ما يمكن مع تحقيق أقل حالات من الفشل كما هو مبين في الشكل رقم

- ٣- تحسين أداء تدريب الشبكات العصبونية كشبكة LVQ (Koc, 2006) وشبكة Perceptron (Otri, 2006).
- ٤- التصميم الإلكتروني (التوزيع الأمثل لعناصر الدارات المطبوعة) (Haj Darwish, 2007).
- ٥- تعيين أقل زمن لحركة ذراع روبوت (Ang, 2009).
- ٦- الحلول المثلى للدوال.
- ٧- جدولة الوظائف (Phruksanant, 2007).
- ٨- تحميل الحاويات (Dereli, 2010).

مزايا خوارزمية النحل ونقاط ضعفها

مزايا خوارزمية النحل

- ١- ذات فعالية عالية في إيجاد الحلول المثلى.
- ٢- تتغلب على مشاكل النهايات المحلية.

نقاط ضعف خوارزمية النحل

- ١- تمتلك العديد من الوسائط.
- ٢- الصعوبة في تحديد القيم المناسبة للوسائط، حيث تكون عملية اختيار القيم عشوائية.

اختيار حجم المجتمع (الوسيط) n

تعتمد الطريقة الافتراضية في اختيار حجم مجتمع النحل إلى الباحث على اختيار عدد ثابت عشوائي n . ويتم تهيئة قيم تلك النحل بشكل عشوائي ضمن فضاء حلول المسألة المدروسة، ثم تقييم كل حل باحثة من خلال دالة ملائمة fitness function.

وللوصول إلى الحل الأمثل مع عدد مرات تكرار أقل ما يمكن، يجب أن يكون حجم المجتمع كبيراً نوعاً ما. ولكي يتم الحصول على حجم معقول من عدد مرات التقييم، يجب أن يكون حجم المجتمع صغيراً قدر الإمكان. ومع هذه المعايير الأربعة (أداء الخوارزمية، وعدد مرات التكرار، وعدد مرات استدعاء دالة التقييم، وزمن التنفيذ)، يجب أن يتم تحديد مجال لاختيار حجم مجتمع مناسب.

نستنتج مما سبق أن المطلوب هو تحديد حجم مجتمع أقل ما يمكن بحيث يحقق أداءً عالياً للخوارزمية (عدد مرات فشل أقل ما يمكن) مع عدد مرات تقييم أقل ما يمكن.

الطريقتان الجديدتان

المنجزتان في هذا البحث


طريقة الإنقاص الخطي للوسيط n (Bees-n-Linear)

تعتمد على بدء تنفيذ الخوارزمية بعدد نحلات كبير نسبياً، ثم إنقاص عدد النحلات بشكل خطي أثناء تكرار الخوارزمية مع المحافظة على الشروط التالية:


- (1) $n > m$
- (2) $m > e$
- (3) $n_2 > n_1$

وعليه يتم تعديل الكود الزائف ليصبح كما هو مبين في الشكل رقم (٦) (إضافة الخطوة ٨).


(٥)، حيث تمثل حالة الفشل عدم الوصول إلى الحل الأمثل المطلوب.



الشكل رقم (٣). العلاقة بين n و k (Otri, 2011).




الشكل رقم (٤). العلاقة بين n ومتوسط عدد مرات تقييم الدالة (Otri, 2011).



الشكل رقم (٥). عدد مرات فشل الخوارزمية مع تغيير n من أجل ١٠٠٠ تكرار (Otri, 2011).

- حيث إنه لا يتم إنقاص n و m و n_2 حتى تتحقق عدة شروط (قيود):
 - تحقيق نصف متوسط عدد مرات التكرار في كل مرة قبل أن تتم عملية الإنقاص ($k > \text{avg_itr_now}/2$)، حيث يتم تغيير المتوسط بعد كل تنفيذ للخوارزمية، وستقوم بتنفيذ الخوارزمية ١٠٠ مرة وأخذ المتوسط، لأن الخوارزمية تعتمد على القيم التجريبية.

يبين الشكل رقم (٧) العلاقة الخطية السابقة بين n و k ، حيث إن القيم الابتدائية: $k=1$ ، $m=10$ ، $n=100$.



الشكل رقم (٧). العلاقة بين n و k وفق طريقة الإنقاص الخطي.

طريقة الإنقاص التكيفي للوسيط n (Bees-n-Adaptive) تعتمد على بدء تنفيذ الخوارزمية بعدد نحللات كبير نسبياً، ويتم اختبار عدم تغير أفضل حل للخوارزمية بعد تكرار الحلقة (الخوارزمية) عدد محدد من المرات $\text{num_movement}=3$ ، وفي حالة تحقق عدم تغير الحل الأمثل لعدد مرات التكرار num_movement بالإضافة إلى تحقق الشروط (القيود) المذكورة في الطريقة السابقة، يتم عند ذلك إنقاص عدد النحللات وفق العلاقات (٥) و (٦) و (٧) مع المحافظة على الشروط المذكور في العلاقات (١) و (٢) و (٣):

```

1. Initialise population with random solutions.
2. Evaluate fitness of the population.
3. While (stopping criterion not met)
   //Forming new population.
4. Select best  $m$  sites for neighbourhood search.
5. Recruit bees for selected sites (more bees for elite  $e$  sites) and evaluate the fitness.
6. Select the fittest bee from each patch.
7. Assign remaining bees to search randomly and evaluate their fitness.
8. if (((n-1)>m)&&(av2<av1)&&(k>avg_itr_now/2))
   n=(n-1);
   if(m-1>e)
     m=m-1;
   end
   if(n2-1>n1)
     n2=n2-1;
   end
end
9. End While.

```

الشكل رقم (٦). الكود الزائف المعدل لخوارزمية النحل مع طريقة الإنقاص الخطي.

- الشروط الممثلة في العلاقات من ١ إلى ٣.
- التقارب من الحل بأن يصغر الخطأ $av_2 < av_1$ ، إذ يمثل av_1 الخطأ السابق، و av_2 يمثل الخطأ الحالي، ويُعطى الخطأ بالعلاقة التالية:

$$av = \text{abs}(\text{best} - \text{bees_best}) \quad (4)$$

وتمثل الفرق بالقيمة المطلقة بين الحل المرغوب تحقيقه best ، وأفضل حل bees_best ناتج من تطبيق الخوارزمية.

استخدام حاسوب بمعالج Intel Core i3 2 GHz وذاكرة بسعة 4 GB DDR3 وبرنامج MATLAB R2011a.

$$n=m+e \quad (5)$$

$$m=e+1 \quad (6)$$

$$n2=n1+1 \quad (7)$$

كما تم تطبيق الوسائط المبنية في الجدول رقم (٢) لخوارزمية النحل على الدوال المبنية في الجدول رقم (١). مع العلم أن الوسيط $e_threshold$ يمثل عتبة الخطأ، حيث تتوقف الخوارزمية عندما يصبح الخطأ الناتج من العلاقة (٤) أقل من عتبة الخطأ، أو عندما يتم تكرار خطوات الخوارزمية ٣٠٠٠ دورة. كما تم تنفيذ الخوارزمية الأصلية وكل طريقة من أجل كل دالة ١٠٠ مرة وأخذ القيم المتوسطة في النهاية. يعرض الجدول رقم (٣) نتائج تنفيذ الطرق المختلفة على الدوال المدروسة وفيه:

- Success: عدد مرات النجاح في الوصول إلى الحل الأمثل من أجل ١٠٠ تكرار.
- Mean Eval: متوسط عدد مرات التقييم (كلما كان أقل كان أفضل)، حيث يتم حساب جميع عمليات استدعاء الدالة المدروسة (دالة التقييم) من أجل النحلات الباحثة والفضلى والمرسلة إلى الجوار.

- Std (standard deviation): الانحراف المعياري لعدد مرات التقييم عن القيمة المتوسطة (كلما كان أقل كان أفضل).
- Mean time (sec): متوسط زمن التنفيذ للخوارزمية (كلما كان أقل كان أفضل).

وعليه يتم تعديل الكود الزائف ليصبح كما هو مبين في الشكل رقم (٨) (إضافة الخطوة ٨).

```

1. Initialise population with random solutions.
2. Evaluate fitness of the population.
3. While (stopping criterion not met)
//Forming new population.
4. Select best m sites for neighbourhood search.
5. Recruit bees for selected sites (more bees for elite e sites) and evaluate the fitness.
6. Select the fittest bee from each patch.
7. Assign remaining bees to search randomly and evaluate their fitness.
8. if
((n>m+e)&&(av2<av1)&&(k>avg_itr_now/2))&&(rep>=num_movement)
n=m+e;
if(m-1>e)
m=e+1;
end
if(n2-1>n1)
n2=n1+1;
end
end
9. End While.

```

الشكل رقم (٨). الكود الزائف المُعدّل لخوارزمية النحل مع طريقة الإنقاص التكيفي.

النتائج والمقارنة

بناءً على الفقرات السابقة وللتحقق من أداء الطريقتين الجديديتين، فقد تم تجريب الخوارزمية الأصلية والطريقتين الجديديتين على مجموعة دوال قياسية Benchmark مبنية في الجدول رقم (١)، وتم

الجدول رقم (١). دوال قياسية benchmark (Castellani, 2009) و (Ahmad, 2012).

No	Function Name	Interval	Function	Global Optimum
1	Peaks (2D)	[-10, 10]	$f(x, y) = 3(1 - x)^2 e^{-(x^2 - (y+1)^2)} - 10\left(\frac{x}{5} - x^3 - y^5\right) e^{-(x^2 - y^2)} - 1/3 e^{-(x+1)^2 - y^2}$	$x(0.2249, -1.626)$ $f=-6.5511$
2	Goldstein & Price (2D)	[-2, 2]	$A(x_1, x_2) = 1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)$ $B(x_1, x_2) = 30 + (2x_1 - 3x_2)^2(18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)$ $f((x_1, x_2)) = AB$	$x(0, -1)$ $f=3$
3	Branin (2D)	[-5, 10]	$f(x1, x2) = a * (x(2) - b * x(1)^2 + c * x(1) - d)^2 + e * (1.0 - ff) * \cos(x(1)) + e$ $a = 1.0; d = 6.0; e = 10.0; b = 5.1 / (4.0 * \pi^2);$ $c = 5.0 / \pi; ff = 1.0 / (8.0 * \pi);$	$x(-22/7, 12.275)$ $x(22/7, 2.275)$ $x(66/7, 2.475)$ $f=0.3977272$
4	Rosenbrock (2D)	[-10, 10]	$f(x1, x2) = 100 * (x(1) - x(2))^2 + (1 - x(1))^2$	$X(1, 1)$ $f=0$
5	Griewank (4D)	[-600, 600]	$f(x) = \frac{1}{4000} \sum_{i=1}^{i=4} (x_i)^2 \prod_{i=1}^{i=4} \cos\left(\frac{x_i}{\sqrt{i+1}}\right) + 1$	$x_i=0$ $f=0.3977272$
6	Rosenbrock (4D)	[-50, 50]	$f(x) = \sum_{i=1}^{i=4} 100(x_{i+1} - x_i^2)^2 + (1 - x_i)^2$	$x(1)$ $f=0$
7	Schwefel (10D)	[-500, 500]	$f(x) = - \sum_{i=1}^{i=10} x_i \sin(\sqrt{ x_i })$	$X_i = 420.9687$ $f = -418.9829$
8	Hypersphere (10D)	[-100, 100]	$f(x) = \sum_{i=1}^{i=10} x_i^2$	$x_i=0$ $f=0$

الجدول رقم (٢). وسائط خوارزمية التحل المطبقة على الدوال المدروسة.

Function Parameter	1	2	3	4	5	6	7	8
n	30	30	30	30	60	60	100	100
m	10	10	10	10	25	25	50	50
e	5	5	5	5	10	10	25	25
nep (n2)	15	15	15	15	30	30	60	60
nsp (n1)	8	8	8	8	15	15	30	30
ngn	0.02	0.001	0.1	0.024	10	0.1	0.01	0.1
e threshold	0.0001	0.00001	0.0002	0.00002	0.05	0.02	0.0001	0.05

الجدول رقم (٣). نتائج تنفيذ الطرق المختلفة على الدوال القياسية المدروسة.

Function No	Standard Algorithm				Bees-n-Linear				Bees-n-Adaptive			
	Success	Mean eval	Mean std	Mean t (sec)	Success	Mean eval	Mean std	Mean t (sec)	Success	Mean eval	Mean std	Mean t (sec)
1	100	2279.1	816.6	0.118	100	2059.9	662.3	0.096	100	1660.4	482.7	0.096
2	100	5147.8	1556.9	0.197	100	4539	1123.1	0.187	100	3825.5	1112.1	0.171
3	100	1982.1	1149.1	0.114	100	1932.6	1122.9	0.102	100	1851.5	1092.1	0.096
4	100	10404.7	3555.3	0.583	100	8765.9	3039.9	0.414	100	7721.3	2432.7	0.43
5	100	171084	95626	10.75	100	156037	98262	10.245	100	155134	91852	9.07
6	100	285246	97214	17.49	100	270532	96494	16.71	100	251403	95315	11.91
7	100	22916	11951	3.528	100	20076	11399.7	2.57	100	12134	6817.3	2.08
8	100	161330	17333.8	19.85	100	148214	13360.6	15.8	100	108603	11391.7	10.68

والخوارزمية الأصلية، وفيه نلاحظ أن أفضل نسبة تحسين في متوسط عدد مرات التقييم كانت من أجل الدالة Schwefel وباستخدام طريقة الإنقاص التكييفي حيث بلغت 47.05%. أما بالنسبة لأفضل نسبة تحسين في متوسط الانحراف المعياري فكانت من أجل الدالة Schwefel وباستخدام طريقة الإنقاص التكييفي حيث بلغت 42.9%. في حين كانت أفضل نسبة تحسين في متوسط زمن التنفيذ من أجل الدالة Hypersphere وباستخدام طريقة الإنقاص التكييفي حيث بلغت 46.2%.

يعرض الشكل رقم (٩) مخططاً لمقارنة متوسط عدد مرات التقييم للطرق المختلفة على الدوال ثنائية البعد 2D، حيث يمثل المحور x رقم الدالة، والمحور y متوسط عدد مرات التقييم، أما الأعمدة فتعرض قيم الخوارزمية الأصلية والطريقتين الجديتين، كما يعرض الشكل رقم (١٠) مخططاً لمقارنة متوسط عدد مرات التقييم للطرق المختلفة على الدوال المتبقية (ذات أربعة، وخمسة، وعشرة أبعاد)، وفي كلا الشكلين نجد أن الطريقتين الجديتين حققتا أداءً أفضل من الطريقة الأصلية.


كما تم وضع أفضل قيمة من أجل كل وسيط بخط غامق Bold ومظلل. فعلى سبيل المثال نجد أن أفضل قيمة لمتوسط عدد مرات التقييم للدالة Peaks هي 1660.4 باستخدام طريقة الانقاص التكييفي، في حين تم الحصول على قيمة قدرها 2279.1 باستخدام الطريقة القياسية، أي أن هناك تحسناً نسبته 27% تقريباً. وبالنسبة لمتوسط للانحراف المعياري std فقد تم الحصول على أفضل قيمة باستخدام طريقة الانقاص التكييفي ومقدارها 482.7، في حين تم الحصول على قيمة مقدارها 816.6 من أجل الطريقة القياسية، وهذا يعني أن هناك تحسناً نسبته 41% تقريباً.

أما بالنسبة لمتوسط زمن التنفيذ فقد تم الحصول على أفضل قيمة باستخدام طريقة الإنقاص التكييفي ومقدارها 0.096 ثانية، في حين تم الحصول على قيمة مقدارها 0.118 ثانية من أجل الطريقة القياسية، وهذا يعني أن هناك تحسناً نسبته 19% تقريباً. يعرض الجدول رقم (٤) مقارنة تبين نسب التحسين في متوسط عدد مرات التقييم ومتوسط الانحراف المعياري ومتوسط زمن التنفيذ بين الطريقتين الجديتين

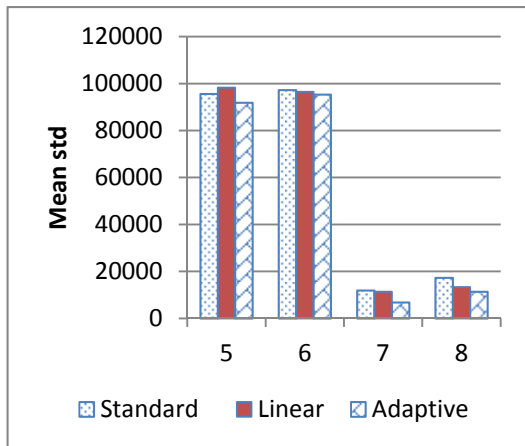
الجدول رقم (٤). نسب تحسين الطريقتين الجديتين مقارنة مع الخوارزمية الأصلية على الدوال القياسية المدروسة.

Function No	Bees-n-Linear			Bees-n- Adaptive		
	Mean eval	Mean std	Mean time	Mean eval	Mean std	Mean time
1	9.6%	18.9%	19%	27%	40.9%	19%
2	11.8%	27.9%	5.1%	25.7%	28.6%	13.2%
3	2.5%	2.3%	10.5%	6.6%	5%	15.8%
4	15.8%	14.5%	29%	25.8%	31.6%	26.2%
5	8.8%	-2.7%	4.7%	9.3%	3.9%	15.6%
6	5.2%	0.7%	4.5%	11.9%	1.9%	31.9%
7	12.4%	4.6%	27.2%	47.05%	42.9%	41%
8	8.1%	22.9%	20.4%	32.7%	34.3%	46.2%


للطرق المختلفة على الدوال المتبقية، وفي كلا الشكلين نجد أيضاً أن الطريقتين الجديتين حققتا أداءً أفضل من الطريقة الأصلية.



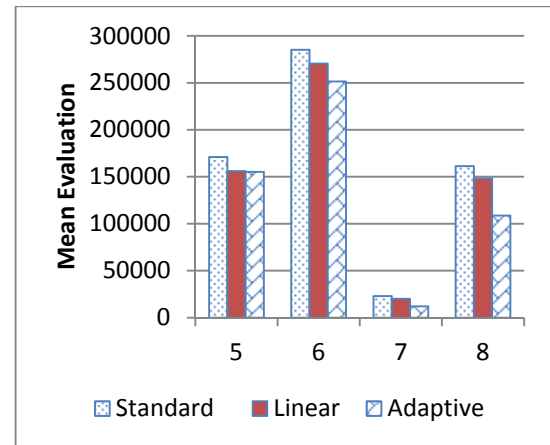
الشكل رقم (١١). مخطط لمقارنة متوسط الانحراف المعياري للطرقتين المختلفتين على الدوال 2D.



الشكل رقم (١٢). مخطط لمقارنة متوسط الانحراف المعياري للطرقتين المختلفتين على الدوال المتبقية.



الشكل رقم (٩). مخطط لمقارنة متوسط عدد مرات التقييم للطرق المختلفة على الدوال 2D.



الشكل رقم (١٠). مخطط لمقارنة متوسط عدد مرات التقييم للطرق المختلفة على الدوال المتبقية.

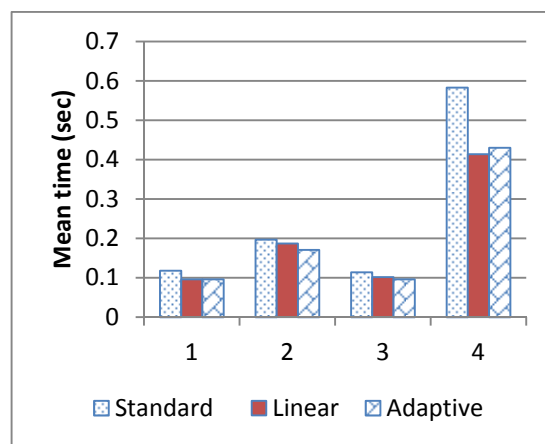
يعرض الشكل رقم (١١) مخططاً لمقارنة متوسط الانحراف المعياري للطرق المختلفة على الدوال ثنائية البعد، حيث يمثل المحور x رقم الدالة، والمحور y متوسط الانحراف المعياري، في حين يعرض الشكل رقم (١٢) مخططاً لمقارنة متوسط الانحراف المعياري

الخلاصة والعمل المستقبلي

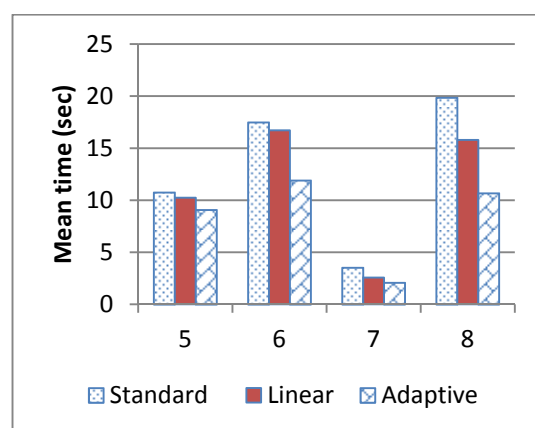
الخلاصة

تعتبر خوارزمية النحل من أهم خوارزميات علم الذكاء الصناعي المختصة بإيجاد الحلول المثلى، وتمتلك العديد من التطبيقات والمزايا، إلا أن لها بعض نقاط الضعف أهمها اختيار قيم وسائط الخوارزمية حيث يتم بشكل عشوائي وبالتجريب. ويعتبر الوسيط n (عدد النحل الباحث) من أهم وسائط هذه الخوارزمية الذي يحدد حجم مجتمع النحل حيث يؤدي إنقاص عدد النحل الباحث إلى فرص أقل في الوصول إلى الحل الأمثل من أجل عدد تكرارات معينة، أما زيادة عدد النحل الباحث بشكل كبير فيؤدي إلى الوصول للحل بشكل أسرع، ولكنه يؤدي إلى زيادة عدد مرات التقييم. وقد تم استخدام طريقتين جديدتين تؤديان إلى بدء تنفيذ الخوارزمية باختيار رقم كبير نسبياً للوسائط n و m و $n2$ ، ثم إنقاصها وفق إحدى الطريقتين الجديدتين السابقتين مع المحافظة على تحقق العلاقات من (١) إلى (٧)، وقد أعطت الطريقتان الجديدتان نتائج جيدة من حيث إنقاص متوسط عدد مرات التقييم ومتوسط الانحراف المعياري ومتوسط زمن تنفيذ الخوارزمية، مما أدى إلى تحسين ملحوظ في أداء الخوارزمية الأصلية. وقد طبقت الطريقة القياسية والطريقتان الجديدتان على عدة دوال قياسية، وأخذت النتائج وبلغت أعلى نسبة تحسين في متوسط عدد مرات التقييم $47,05\%$ ، في حين بلغت

يعرض الشكل رقم (١٣) مخططاً لمقارنة متوسط الزمن بالثانية للطرق المختلفة على الدوال ثنائية البعد، حيث يمثل المحور x رقم الدالة، والمحور y متوسط الزمن بالثانية، في حين يعرض الشكل رقم (١٤) مخططاً لمقارنة متوسط الزمن بالثانية للطرق المختلفة على الدوال المتبقية، وفي كلا الشكلين نجد أيضاً أن الطريقتين الجديدتين حققتا أداءً أفضل من الطريقة الأصلية.



الشكل رقم (١٣). مخطط لمقارنة متوسط الزمن بالثانية للطرق المختلفة على الدوال 2D.



الشكل رقم (١٤). مخطط لمقارنة متوسط الزمن بالثانية للطرق المختلفة على الدوال المتبقية.

Applied Soft Computing Journal 11(2), (2010), pp. 2854-2862.

Dorigo, M., Maniezzo, V. and Colorni, A. "Ant system: Optimization by a colony of cooperating agents." IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics 26(1), (1996), pp. 29-41.

Ghanbarzadeh A. "The Bees Algorithm A Novel Optimisation Tool", Cardiff University, (2007).

Goldberg D.E. "Genetic Algorithms in Search, Optimization, and Machine Learning", Massachusetts, USA: Addison-Wesley Publishing Company, Inc. (1989).

Haj Darwish A., Pham D.T., Otri S., "Application of the Bees Algorithm to PCB Assembly Optimization." Proc. 3rd International Virtual Conference on Intelligent Production Machines and Systems (IPROMS 2007).

Koc E., Pham D.T., Otri S., Ghanbarzadeh A., "Application of the Bees Algorithm to the Training of Learning Vector Quantization Networks for Control Chart Pattern Recognition", Proc. Information and Communication Technologies (ICTTA'06). Syria, (2006), 1624-1629.

Otri S., "IMPROVING THE BEES ALGORITHM FOR COMPLEX OPTIMISATION PROBLEMS." PhD thesis, Cardiff University, (2011).

Otri S., Pham D.T., Ghanbarzadeh A., Zaidi M., Mahmuddin M., Ghanbarzadeh A., E. Koc, S. Otri, "Using the Bees Algorithm to Optimize a Support Vector Machine for Wood Defect Classification", Manufacturing Engineering Centre (MEC), Cardiff University, UK, (2007).

Otri S., Pham D.T., Koc E., Ghanbarzadeh A., "Optimization of the Weights of Multi-Layered Perceptions Using the Bees Algorithm", Proc. 5th International Symposium on Intelligent Manufacturing Systems. Turkey, (2006), 38-46.

Pham D.T., Ghanbarzadeh A., Koc E., Otri S., Rahim S., Zaidi M., "The Bees Algorithm. Technical Note", Manufacturing Engineering Centre, Cardiff University, UK, (2005).

أعلى نسبة تحسين في متوسط الانحراف المعياري ٤٢,٩٪، أما أعلى نسبة تحسين في متوسط زمن التنفيذ فبلغت ٤٦,٢٪.

العمل المستقبلي

١- دراسة إمكانية إنقاص عدد وسائط خوارزمية النحل.

٢- ابتكار طرقٍ جديدةٍ لاختيار حجم الجوار المناسب ngh.

٣- تطبيق الطريقتان الجديدتان المدروستان في هذا البحث على مسائل أخرى غير مسألة إيجاد الحلول المثلى للدوال.

المراجع

Ahmad S.A., "A Study of Search Neighbourhood in the Bees Algorithm", Ph.D. Thesis, Cardiff university, (2012).

Al-Jabbouli H., Pham D.T., Otri S., Afify A.A., Mahmuddin M. "Data clustering using the bees algorithm." Proceedings of the 40th CIRP Int. Manufacturing Systems Seminar, Liverpool, UK, (2007).

Ang, M. C., Pham, D. T. and Ng, K. W., "Minimum-time motion planning for a robot arm using the bees algorithm", 2009 7th IEEE International Conference on Industrial Informatics, INDIN 2009, Cardiff, 23-26 June (2009), pp. 487-492.

Castellani M., Pham D.T., "The Bees Algorithm: modeling foraging behavior to solve continuous optimization problems", IMechE Vol. 223 Part c: JMES 1494, (2009).

Dereli, T., Das, G. S., "A hybrid 'bee(s) algorithm' for solving container loading problems",

- Zaidi M., Pham D.T., Ghanbarzadeh A., Koc E., Otri S., Rahim S.** "The Bees Algorithm - A Novel Tool for Complex Optimization Problems." Proceedings of IPROMS Conference, (2006), 454-461.
- Zhao X., Yao Y., Yan L.,** "Learning algorithm for multimodal optimization", Computers & Mathematics with Applications 57(11-12), (2009), pp. 2016-2021.
- Phrueksanant J., Pham D. T., Koç E., Lee, J. Y.** "Using the Bees Algorithm to schedule jobs for a machine", The 8th International Conference on Laser Metrology, CMM and Machine tool performance (LAMDAMAP), Cardiff, UK,(2007), pp. 430-439.
- Sahran S.** "Control Chart Pattern Recognition with Spiking Neural Network", PowerPoint Presentation. MEC, Cardiff University, UK. (2006).

Improving Bees Algorithm and Using it for Finding Functions Optimization Solutions

Iyad Helaly and Ziad Salem

*Computer Engineering Department, Faculty of Electrical and Electronic Engineering, Aleppo University,
Aleppo, Syria Arabic Republic
iyadhe@gmail.com*

(Received 03/06/1434H.; accepted for publication 17/04/1435H.)

Keywords: Bees algorithm, Functions optimization, Optimization solutions, Artificial Intelligent.

Abstract. There are many artificial intelligence algorithms that are concerned with the issue of finding optimization solutions for multiple approaches, and one of the most famous of these algorithms is bees algorithm. This algorithm is based on mimics of the food foraging behavior of swarms of honey bees, and this algorithm has been used in the optimization solutions and gave acceptable results.

This research focuses on improving the performance of the algorithm by finding two new methods to determine values for some important parameters of this algorithm, which represents the number of scout bees population size (n), the number of best sites selected out of n visited sites (m), and the number of bees recruited for elite sites (n_2). The standard method relies on initializing these parameters with a random value.

This research has presented two ways to set these parameters, and applied these methods in finding optimization solutions to some mathematical functions (minimum value), and were compared with the performance of the original algorithm (standard method).