

## فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة في WSN

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

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

جامعة دمشق، سوريا. [AretaKhalee@Damascusuniversity.edu.sy](mailto:AretaKhalee@Damascusuniversity.edu.sy)

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

جامعة دمشق، سوريا. [MohammadAl-ussein@Damascusuniversity.edu.sy](mailto:MohammadAl-ussein@Damascusuniversity.edu.sy)

### المخلص:

تعزيز عمر الشبكة هو الهدف الأساسي للباحثين في شبكات الاستشعار اللاسلكية. تعتبر الطاقة المستثمرة في التوجيه واختيار رأس المجموعة من بين الخيارات المختلفة لتقليل استهلاك الطاقة، ومن افضل الآليات الفعالة. تم اعتبار كلتا المهمتين صعبة للغاية ويصعب الحصول على الحل الفعال. نظرًا لأنه من الصعب على الأساليب التقليدية تلبية المتطلبات والصعوبات، فإن الحل وفق خوارزميات الميتاهستيرية الذي يركز على طرق الحساب الطبيعية قد وفر البساطة. يقترح العمل مواجهة هذه التحديات باستخدام الذكاء الحسابي وخاصة التطور التفاضلي Differential Evolution و Genetic Algorithm GA الجينية. تم تصميم طريقة موفرة للطاقة في الشبكة الديناميكية مع اختلافات في DE، وتم اكتشاف طرق سريعة وقابلة للتكيف للشبكات التي تخضع للتغيرات. تم تصميم DE القائم على المعرفة اعتمادًا على المعرفة السابقة لإعادة تحديد طرق جديدة لتغيير الشبكة. تم تصميم إستراتيجية الطفرات الهجينة بموجب DE القياسي لاختيار رأس المجموعة التي توفر خصائص تقارب أسرع. تم تنفيذ الحلول المقترحة في ظل بيئة MATLAB وأظهرت النتائج أن الحلول المقترحة تعمل بشكل أفضل لتكوينات الشبكات المختلفة. حقق اكتشاف المسار الديناميكي باستخدام Knowledge based (KDE Differential Evolution) توفيرًا للطاقة بنسبة 9.83 إلى 49.2 بالمائة مقارنة بـ Redefinition of population in Differential Evolution (RDE) و 6.7 إلى 29.5 بالمائة مقارنة بـ random Perturbations in Differential Evolution (PDE). كما أن توفير الطاقة الذي تم تحقيقه في اختيار رأس المجموعة باستخدام Hybrid mutation strategy based DE (HMDE) هو 10 إلى 33 بالمائة أفضل مقارنة بـ different algorithm dynamic weighted PSO (dyPSO) و 5 إلى 10 بالمائة أفضل مقارنة بـ standard DE (SDE).

**الكلمات المفتاحية:** شبكة الاستشعار اللاسلكية، استهلاك الطاقة، التوجيه، رأس العقنود، التطور التفاضلي

تاريخ الايداع: 2023/2/20

تاريخ القبول: 2023/3/6



حقوق النشر: جامعة دمشق - سورية،

يحتفظ المؤلفون بحقوق النشر بموجب CC

BY-NC-SA

## Effectiveness of modified evolution algorithm to improve network lifetime in WSN

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

\*<sup>1</sup>. PhD student, Department of communication and electronic engineering, Faculty of mechanical and electrical Engineering, Damascus University, Damascus, Syria.

[AretaKhaleel@Damascusuniversity.edu.sy](mailto:AretaKhaleel@Damascusuniversity.edu.sy)

<sup>2</sup>. Prof, Dr, Eng, Department of communication and electronic engineering, Faculty of mechanical and electrical Engineering, Damascus University, Damascus, Syria.

[MohammadAl-ussein@Damascusuniversity.edu.sy](mailto:MohammadAl-ussein@Damascusuniversity.edu.sy)

### Abstract:

Enhancing network lifetime is the primary goal of wireless sensor network researchers. Among the various options for reducing energy consumption, the energy invested in steering and group head selection is one of the most effective mechanisms. Both tasks were deemed too difficult and the effective solution difficult to obtain. Since it is difficult for traditional methods to meet the requirements and difficulties, the solution according to meta-algorithms focusing on natural arithmetic methods has provided simplicity. The work proposes to face these challenges by using computational intelligence, especially DE Differential Evolution and GA Genetic Algorithm. An energy-efficient method discovery was designed for dynamic network with variations in DE, and fast and adaptive methods for networks undergoing changes were designed. Knowledge-based DE is designed drawing on prior knowledge to redefine new ways to change the network. The strategy of hybrid mutagenesis under standard DE is designed to select the head of the cluster that provides faster convergence characteristics. The proposed solutions were implemented under the MATLAB environment and the results showed that the proposed solutions work best for different network configurations. Dynamic path detection using KDE achieved energy savings of 9.83 to 49.2 percent compared to RDE and 6.7 to 29.5 percent compared to PDE. The energy savings achieved in group head selection with the proposed HMDE are 10 to 33 percent better compared to dyPSO and 5 to 10 percent better compared to SDE.

**Keywords:** wireless sensor network, power consumption, routing, head of cluster, differential evolution.

**Received:** 20/2/2023

**Accepted:** 26/6/2023



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

## المقدمة:

تتكون شبكة المستشعرات اللاسلكية ( Wireless Sensor Network WSN) من الكثير من أجهزة الاستشعار الصغيرة التي تكتشف البيئة فيما يتعلق بالمعلومات ذات الأهمية. يوفر الحجم الصغير لأجهزة الاستشعار، والتكلفة المنخفضة، والاستهلاك الصغير للطاقة، والاتصالات السهلة مع حيرانهم مزايا وظيفية بينما الانتشار في مناطق معادية يجعل الوضع شبه مستحيل لتوفير إعادة شحن الطاقة. [pralhad,2022] استهلاك الطاقة في عقد الاستشعار، وعمر الشبكة الطويل، ونقل البيانات السريع، والاستقرار كلها متطلبات مهمة لتطبيقات WSN من أجل الحفاظ على الطاقة في عقد الاستشعار وبالتالي زيادة عمر الشبكة. تواجه WSN مشكلة في نطاق التغطية وعمر الشبكة والتقارب وتجميع البيانات بسبب القيود المختلفة في عقد المستشعر بطريقة معينة اعتمادًا على التطبيق، بالإضافة إلى محطة قاعدية ( Base Station BS) داخل نطاق الراديو. يشتمل تكوين WSN على عدد كبير من المستشعرات التي تم توزيعها عشوائيًا باستخدام دالة التوزيع الاحتمالي أو تم تنظيمها بطريقة معينة اعتمادًا على التطبيق، بالإضافة إلى محطة قاعدية موجودة داخل النطاق الراديوي. ترسل المحطة القاعدية استعلامات إلى عقد الاستشعار القريبة، والتي تكتشف الاستعلام وتستجيب له بالبيانات. تعد كفاءة نهج التوجيه من أهم العوامل المحددة لنجاح الشبكة بشكل عام في جميع أشكال الشبكات [mohammed, 2022, johi 2021]. في شبكة WSN، تحول خصائص الهيكل الديناميكي التوجيه إلى تحدي تحسين فعال [sharawi 2013]. للعثور على أفضل حل، من الضروري أن يكون قابلاً للتكيف. يمكن وصف مشكلة التوجيه في الظروف المعقدة على النحو التالي: بالنسبة لزوج من العقد التي تعمل كنقاط نهاية في شبكة لاسلكية مع تأخير، ابحث عن المسار الأقل تكلفة في

الشبكة الذي لا يتضمن الحلقات. عندما تكون هناك تغييرات في الشبكة، سيكون الهدف الأساسي هو العثور على مسار أمثل جديد بأقل تكلفة يخدم متطلبات التأخير للتطبيق من وجهة نظر توفير الطاقة. تتكون شبكات WSN عادةً من عقد مستشعر تم نشرها وتكوينها وفقاً لسياقات التطبيق، بالإضافة إلى محطة قاعدية موضوعة بالقرب نسبياً منها أو ضمن نطاق إرسال الشبكة. ترسل المحطة القاعدية الطلبات إلى العقد المجاورة، والتي تقوم بإجراء الاستشعار وإعادة البيانات إلى المحطة كاستجابة للاستعلام. تستخدم عقد الاستشعار في WSN مستوى كبير من الطاقة في الاستشعار والتشفير والتواصل، وتختلف كمية طاقة البطارية المستخدمة في إرسال حزمة تبعاً لبعدها عن عقد الإرسال والاستقبال، وبالتالي يفضل نقل البيانات متعدد القفزات باستخدام التوجيه الهرمي، الذي ينظم مجموعة من العقد في مجموعات لإطالة عمر شبكة الاستشعار، لإرسال البيانات. ثم يتم تحديد رأس الكتلة (Cluster Head CH) لكل كتلة، تقوم رؤوس الكتل بتجميع البيانات من أعضائها وتنقلها إلى المحطة القاعدية بأقل تكلفة ممكنة للإرسال متعدد القفزات. التجميع في كتل (Clustering) هو أحد تقنيات التوجيه الهرمي الفعالة للغاية في تقليل الطاقة المستخدمة بواسطة عقد الاستشعار [sekran, 2020, R.V. kuttarn, 2011]. للاتصال يتم إرسال البيانات المجمعة من رؤوس الكتل إلى المحطة القاعدية البعيدة إما مباشرة أو عبر رؤوس كتل وسيطة. لكي تكون على دراية بالتغييرات في البيانات أو بدء الحدث، يتم توصيل المحطة القاعدية بالشبكة العامة مثل الإنترنت (عبر WiFi). يمكن تضمين مزايا مختلفة مع التجميع في WSN مثل تجاهل البيانات الزائدة عن طريق تمكين تجميع البيانات على مستوى رأس الكتلة، والحفاظ على تدفق البيانات المطلوب. حددت [nabravi 2022] جودة اختيار رأس الكتلة جودة الحفاظ على الطاقة وبالتالي

فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....

كانت هناك حاجة إلى عملية فعالة في هذا الاختيار. عانى النهج الكلاسيكي للتحسين من ضعف الكفاءة خاصة مع زيادة حجم الشبكة. ينصب التركيز الرئيسي للعمل البحثي على البدء بإيجاد طريق موفر للطاقة في ظل السلوك الديناميكي للعقد في الشبكة. بالإضافة إلى تصميم وتطبيق خوارزميات تطويرية طبيعية للذكاء الحسابي لتغيير الشبكات ديناميكياً للحصول على مسارات أفضل وقابلة للتكيف بسرعة، لتصميم وتطبيق شكل هجين من الحلول للعثور على اختيار رأس الكتلة الموفر للطاقة باستخدام DE. أخيراً، يعتبر التحليل المقارن لجميع الخوارزميات بمثابة فترة استقرار للمسار المعاد تعريفه للشبكات الديناميكية والطاقة المستهلكة لاختيار رؤوس الكتل. فيما يلي ملخص للعمل الذي تمت مناقشته في هذه الورقة: تم الوصول إلى الأعمال ذات الصلة في القسم 2، وتم النمذجة الإحصائية للتوجيه، في القسم 3. وفي القسم الرابع تم إيجاد النتائج التجريبية التفصيلية للتوجيه. تمت مناقشة نمذجة مشكلة رأس العقود والمتغير المطبق لـ DE في القسم 5 بينما تم عرض النتائج التجريبية في القسم 6. وتم تقديم الاستنتاج في النهاية.

## 1- العمل ذات الصلة:

تم تنفيذ خوارزميات التوجيه الذكية باستخدام تقنيات الحوسبة [johi, 2021, sharawi, 2013, uppal. 2018] التي تعمل على تحسين أداء الشبكة بالإضافة إلى إطالة عمر الشبكة. إن الحل عبارة عن حل هجين يستخدم خوارزمية جينية من خلال نموذج متقاطع لتحديد أفضل الطرق مع المنطق الضبابي لتقدير تكاليف الاتصال. يتم تحديد تكلفة الاتصال بين العقد المجاورة، مع مراعاة الطاقة المتبقية للعقدة، والمسافة من المحطة الأساسية من أجل تحسين التوجيه. يتم تحديد تكاليف ارتباط العقد المجاورة باستخدام آلية منطق ضبابي، ويتم التعبير عن التكاليف في مصفوفة تكلفة الارتباط التي تتم مراجعتها بعد كل تكرار. يقترح [vinodhini,2020] خوارزمية اليعسوب ( Dragonfly Algorithm DA) باعتبارها تقنية تحسين ذكاء السرب الموفرة للطاقة لجمع رؤوس الكتلة. تُستخدم خوارزمية تحسين Glow-worm Swarm Optimization GSO) للتوجيه

خليل، الحسين

الفعال.في [shafiq, 2020]، تم إجراء مراجعة مفصلة للتوجيه الفعال لـ WSN. يقدم [qaboushe, 2021] بروتوكول التوجيه الثابت الهجين الموفر للطاقة (Hybrid Energy Efficient Static Routing Protocol)، والذي يجمع بين إستراتيجيات التوجيه العنقودي والتوجيه متعدد القفزات. يكتسب إنترنت الأشياء ( Internet of Things (IoT) الاهتمام بمعدل سريع. في الغالبية العظمى من الحالات، يُطلب من شبكات WSN ربط أجهزة إنترنت الأشياء. ويواجه الباحثون تحدياً كبيراً في تنفيذ الشبكات المستقرة لعقد الاستشعار ذات الموارد المحدودة في WSN. ولتحسين قابلية التوسع، تعد بروتوكولات التوجيه الهرمية مناسبة لتجميع العقد في شبكات WSN. تستخدم خوارزمية التجميع الأساسية (low energy adaptive clustering hierarchy LEACH) جولات عشوائية وتجميعاً موحداً لرؤوس المجموعات القريبة لتعزيز قابلية التوسع وكفاءة الشبكة [R.V.kuttkarn,2011]. تم تمديد عمر الشبكة باستخدام بروتوكول تجميع موزع هجين موفر للطاقة (Hybrid Energy-Efficient Distributed HEED) والذي حدد التجميع واختيار رأس المجموعة بناءً على الطاقة المتبقية في عقدة الاستشعار وتكلفة الاتصال من المصدر إلى الوجهة [k.n.dattatraya,2019]. تم اقتراح التكتل الهرمي الموفر للطاقة ( Energy Efficient Hierarchical Clustering EEHC) في [2022 k. halamuge]، مما يطيل من عمر شبكة المستشعرات. يتسبب التجميع الهرمي في زيادة الحمل على رؤوس المجموعات ويقلل من قدرتها بشكل أسرع من العقد الأخرى. اقترحت الورقة [n.m.latiff, 2007] مخطط لتخصيص رأس الكتلة الذي يقلل من تبديد الطاقة مع تقليل التكرار غير الضروري ويطيل عمر الشبكة مقارنةً بـ LEACH الحالي. لتقليل الاستهلاك العام للتوجيه والاستغلال الفعال لتوافر الطاقة، اقترحت الورقة [prabharan,2019] استراتيجية توجيه متعددة المسارات تكيفية ذات كفاءة في استخدام الطاقة، وفي [rathore,2021] تم تجميع المنطقة الخاضعة للمراقبة في مجموعات من العقد المجاورة مع مجموعة مختارة من رأس

فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....

الكتلة الأقرب إلى المحطة القاعدية، وقامت خوارزمية PSO (Particle Swarm Optimization) في [j.kenndy,1995] بحل فعال لمشاكل الأمثلة الصعب NP-hard. وفقاً لمؤلفي [fxiangning, 2007, n.lattif,2007]، فإن أداء PSO أفضل بكثير من LEACH من حيث مدة الشبكة ومتوسط تدفق البيانات. تم اقتراح مخطط لجمع البيانات المتنقلة في WSN باستخدام اختيار رأس الكتلة القائم على الحوسبة الناعمة وتجميعها لحل مشكلة الطاقة [Prabaharan, G. et al, 2019]. وتعمل مجموعة رأس الكتلة الذكية، بالإضافة إلى جمع البيانات، على تقليل وقت التحميل وإهدار الطاقة. نتيجة لانخفاض فقدان الطاقة، تم تمديد عمر الشبكة. في [Vijayalakshmi, K. et al, 2019]، تمت مناقشة أفضل طريق للاختيار في التوجيه لزيادة عمر الشبكة واستخدام الطاقة. تم استخدام العديد من الأساليب التجريبية بنجاح، بما في ذلك تحسين سرب الجسيمات (PSO)، ولكن مع تحسين محلي ضعيف. اقترح [Rathore, P.S. et al, 2021] مخطط اختيار رأس الكتلة على أساس مسافة العقدة وسعة العقدة. يهدف اختيار رأس المجموعة إلى تقليل استهلاك الطاقة وزيادة عمر الشبكة إلى أقصى حد من خلال تطبيق نظرية عقدة ترحيل أقصر مسار. يتم إطلاق مجموعة المسار المختارة لتلبية استهلاك الطاقة المتوفرة عندما يتم تحميل عدد قليل من عقد الكتلة الفرعية بشكل كبير.

يتم نقل عقدة المستشعر ذات الوزن العالي إلى المجموعات المناسبة. وبالتالي، سيتصرف هذا المستشعر كعضو كتلة تحت رأس كتلة معين وينقل معلوماته إلى المحطة الأساسية من خلال هذا الرأس. يتم اختبار تجربة الخوارزمية المقترحة في السيناريوهات المختلفة لعقد المستشعر من خلال تغيير عدد عقد الاستشعار ورؤوس الكتل. لتحليل فعالية العمل المقترح، يتضح من المراجعات أنه تم تجربة العديد من الاتجاهات الجديدة لتحسين المسار والحصول على نتائج أفضل أيضاً. على الرغم من وجود العديد من الطرق لتحسين عمر الشبكة، إلا أنه هناك مجالاً لإيجاد طرائق موفرة للطاقة واختيار رؤوس مجموعات أفضل لا يزال

خليل، الحسين

بإمكانها توفير الطاقة باستخدام التطور التفاضلي والخوارزميات الجينية. تتمثل فكرة العمل البحثي المقترح في تطبيق الأشكال المعدلة لخوارزميات الذكاء الحسابي لتقليل تكلفة العثور على المسار واختيار رأس المجموعة بحيث يتم تحقيق تحسين في أداء الشبكة.

2- توجيه فعال للطاقة وفقاً للشبكة الديناميكية WSN

اقترح توجيه الإرسال الأحادي بين عقدتين في الرسم البياني (graph)  $G(V, E)$  حيث  $V$  هو مجموعة العقد  $v_i$ ، بينما  $E$  مجموعة الأزواج  $(v_i, v_j)$

و  $1 < i, j < N$ ، وحد أقصى للتأخير  $\Delta$ . تتمثل عملية

التوجيه في العثور على عدد من المسارات

$$\{O_i | i \in \{0, 1, \dots\}\}$$

بالتتابع على مجموعة من الرسوم البيانية

$$G_i | i \in \{0, 1, \dots\}$$

مع استيفاء قيود التأخير الواردة في المعادلة 1 وتوفير

المسار الأقل تكلفة الوارد في المعادلة 2.

$$\Delta(O_i) = \sum_{l \in O_i(s,r)} d_l \leq \Delta \quad (1)$$

$$CF(O_i) = \min_{O \in G_i} \left\{ \sum_{l \in O_i(s,r)} CF_l \right\} \quad (2)$$

من الناحية العملية، تميل التطبيقات أو الأنظمة التي تم إنشاؤها باستخدام شبكات WSN إلى التغيير لأن الشبكة ديناميكية بطبيعتها، لذلك فإن إيجاد الحل الأمثل في بيئة ديناميكية يمثل تحدياً كبيراً. من الأهمية بمكان استكشاف المشهد المتغير بسرعة من أجل إيجاد الحل الأمثل وتتبع التغيرات البيئية. تتميز مناهج الحوسبة الطبيعية بدرجة عالية من القدرة على التكيف مضمنة لأنها تستند إلى نماذج طبيعية. ذكاء السرب معروف جيداً وقد تم توضيحه في عدد من التطبيقات باستخدام تقنيات البرمجة الطبيعية مثل الحساب التطوري.

### 3- الحل المقترح:

يُنظر إلى التطور التفاضلي كواحد من أصعب الكيانات في الحساب التطوري، تظهر العملية المنطقية للتطور التفاضلي في الشكل 1. يتم استخدام ناقل ذو بُعد  $D$  لأفراد  $NP$  في هذه الخوارزمية. يستخدم DE الطفرات لبناء ناقل مانه

فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....

$V_i$  (donor) يبعد  $D$ . لكل ناقل، خلال كل جيل يتم تعريف الناقل المانح عن طريق مجموعة متنوعة من المنهجيات. في هذه الدراسة، تم استخدام منهجية DE/rand/1، كما هو موضح في المعادلة 3. تم تصميم ناقل تجريبي لمشغل التقاطع  $u_{ij}$  كما هو موضح في المعادلة 4. يتم تمثيل احتمالية إنشاء معلومات للناقل التجريبي من ناقل الطفرة بواسطة CR، وهو معامل تحكم التقاطع أو معامل في المجال  $[0, 1]$ . يتم اختيار الدليل  $j_{rand}$  عشوائياً من المجموعة  $[0, NP]$ . بعد ذلك، وفقاً للمعادلة 5، تختار عملية الانتخاب لنواقل الجيل التالي إما من الناقل المستهدف ( $x_i$ ) أو من النواقل التجريبية المقابلة.

$$V_i^{(G)} = A_{r1}^{(G)} + F \times (A_{r2}^{(G)} - A_{r3}^{(G)}) \quad (3)$$

$$u_{ij}^{(G)} = \begin{cases} v_{ij}^{(G)} & \text{if } rand(0,1) \leq CR \text{ or } j = j_{rand} \\ x_{ij}^{(G)} & \text{otherwise} \end{cases} \quad (4)$$

$$x_{ij}^{(G)} = \begin{cases} u_{ij}^{(G)} & \text{if } f(u_{ij}^{(G)}) \leq f(x_{ij}^{(G)}) \\ x_{ij}^{(G)} & \text{otherwise} \end{cases} \quad (5)$$

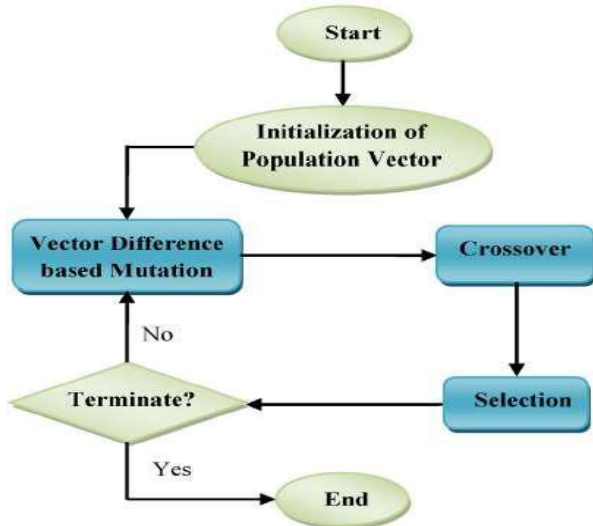
قمنا بتصميم أنواعاً مختلفة من الخوارزميات الجينية، مثل إعادة تعريف السكان في التطور التفاضلي (Redefinition of population in Differential Evolution RDE) والاضطرابات العشوائية في التطور التفاضلي (random Perturbations in Differential Evolution PDE) والتطور التفاضلي القائم على المعرفة (Knowledge based Differential Evolution KDE) للحصول على أقصر مسافة توجيه. يمكن أن يحدث الهيكل الديناميكي في مجموعة متنوعة من التطبيقات، مثل نظام تتبع الحيوانات، واستراتيجية الجندي في ساحة المعركة، وما إلى ذلك. التطور هو المثال المثالي للتكيف في البيئات الطبيعية، ولهذا السبب تم إنشاء التطبيقات باستخدام إطار عمل الخوارزمية الجينية. ومع ذلك، فإن الصعوبة الحالية تكمن في التحديد السريع لأفضل اتصال للتحويل الهيكلي. تم بناء ثلاث تقنيات متميزة في هذا التحليل لمواجهة التحديات المذكورة أعلاه: (أ) توظيف مجموعة حلول جديدة تماماً للحدث (ب) الحفاظ على قدر صغير من الاضطرابات في

خليل، الحسين

السكان (ج) تطبيق المعلومات المكتسبة من الحلول المعززة مسبقاً على السكان الحاليين. تتم محاكاة الشبكة عن طريق نشر عقد الاستشعار، مع توزيع عشوائي منتظم على إحداثيات  $X$  و  $Y$  ضمن منطقة محددة. يتم تحديد الاتصال بين العقد باستخدام المسافة الإقليدية المحسوبة على نطاق اتصال العقد.

#### 4-1 التطور التفاضلي مع إعادة تعريف السكان في الوقت المحدد (RDE):

من أجل التعامل مع التغيرات التي تحدث، تمت إضافة مجموعة سكانية جديدة تماماً بدرجة عالية من التنوع في لحظة التحولات المرصودة. تتلخص خطوات RDE وفق التالي: 1- تهيئة السكان. 2- استخدم مشغلي التقاطع والطفرة لتوليد النسل. 3- تطبيق الاختيار بين الوالدين والنسل. 4- إذا حدث تغيير في الشبكة: فإن الجيل الحالي = إنشاء مجتمع جديد آخر وإلا الجيل الحالي = الجيل القادم. 5- العودة إلى الخطوة 1 إذا لم يتم الوصول إلى النهاية.



الشكل (1) المخطط التدفقي لخوارزمية التطور التفاضلي

#### 4-2 التطور التفاضلي مع اضطراب مستمر: [PDE]:

للحصول على تنوع كافٍ في السكان، تم إدخال عضو جديد إلى السكان، مما أدى إلى تنوع أكبر، وإذا نشأ موقف

خليل، الحسين

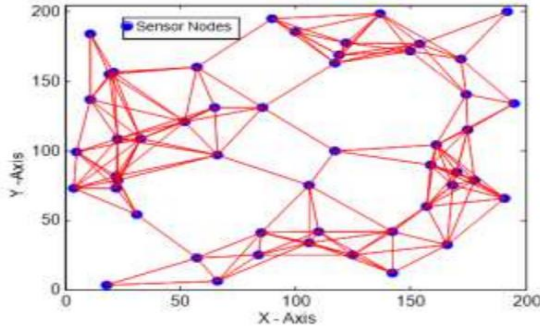
مشغلي التقاطع والطفرة. 3- تطبيق الاختيار بين الوالدين والنسل. POPN-4: الجيل القادم من السكان.

5-

الخطوة (2) احصل على هويات جميع الجيران المحتملين. الخطوة (3) حدد مستشعراً متصلاً من الجيران المحتملين باستخدام إجراء عشوائي موحد.


الخطوة (4): أضف العقدة المحددة كعقدة تالية في مسار التوجيه إذا لم تكن هي مستشعر الوجهة.

الخطوة 5: كرر من الخطوة 2، حتى يلتقي المصدر والوجهة



الشكل (2) نمذجة شبكة مع 50 عقدة

بالنسبة للشبكة المحاكاة أعلاه الموضحة في الشكل 2، تم تطبيق ثلاثة أحداث مختلفة على الشبكة وتم ملاحظة التغييرات في الهيكل. الشكل 3 يصور الطوبولوجيا المقابلة للحالة الثالثة. حدثت هذه الاختلافات في الطوبولوجيا في الوحدات الزمنية العاشرة، والعشرون، والثلاثون. لتحديد مسار التوجيه بين العقدتين 11 و 49، تم استخدام خوارزميات مختلفة مثل RDE و PDE و PDE.



الشكل (3) تغيير طوبولوجيا الشبكة في الحالة الثالثة

فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....

ديناميكي، فإن هذا التنوع سيسهل اكتشاف البدائل. تسمح هذه الطريقة بمعالجة أسهل للمشكلات الديناميكية مع تجنب الحاجة إلى اكتشاف الأحداث. يمكن تلخيص خطوات PDE وفق التالي: 1- تهيئة السكان. 2- لتوليد النسل، استخدم

$$Pos_{min} = f_{min}(NPOP)$$
$$NPOP(POS) = A \text{ new solution}$$

6- ارجع إلى الخطوة 1 إذا لم يتم الوصول إلى الإنهاء

4-3- التطور التفاضلي مع تبادل المعرفة (KDE)

إذا كان من الممكن تطبيق الخبرة من أفضل حلول الأجيال السابقة على أفضل الحلول للجيل الحالي، فهناك فرصة معقولة لأن يكونوا قادرين على إدارة الهيكل الديناميكي بكفاءة لأنهم سيعرفون الآن كيفية التعامل مع تغييرات الهيكل بمرور الوقت. بالتالي يمكن تحقيق الحلول المثلى في وقت أقل، مع احتمال أقل بكثير للفشل. تتلخص خطوات KDE وفق التالي: 1- تهيئة السكان. 2- توظيف مشغلي التبادل والطفرة لتوليد النسل. 3- تطبيق الاختيار على أساس اللياقة بين الوالدين والنسل. 4- قم بتخزين أفضل عضو من NPOP في  $SB_i$  5- استبدل أفضل عضو من NPOP بالحل متاح في  $SB_{i-1}$  6- في حالة عدم حدوث الإنهاء، انتقل إلى الخطوة 1.

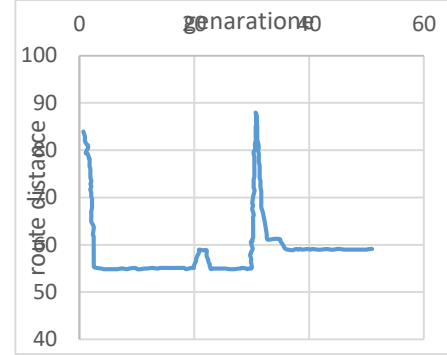
## 5- تصميم تجريبي لتوجيه الطاقة بكفاءة:

تم إجراء تجارب المحاكاة في بيئة MATLAB. تم نشر مجموعة من 50 عقدة في مساحة  $200 \times 200$  وحدة مربعة. يتم تعيين كل عقدة في المحاكاة على نطاق اتصال من 50 وحدة، يتم تعيين حجم السكان ويتم تحديد الاتصال الطوبولوجي عن طريق حساب المسافة الإقليدية بين كل عقدة وكذلك جميع العقد الأخرى. أثناء تهيئة السكان في المرحلة الأولية، يتم تحديد مسار التوجيه بين المصدر والوجهة المختارة باستخدام مفهوم قائم على القيد. تم تمثيل الكروموسومات باتباع الخطوات التالية:

الخطوة (1) تعيين رقم بداية لمستشعر المصدر.

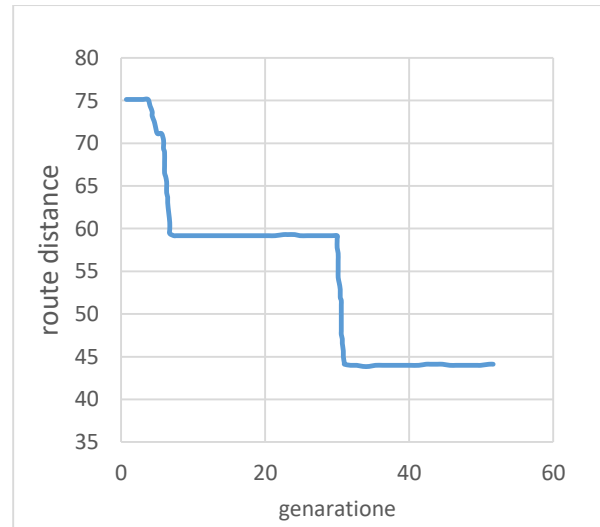


فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....




الشكل (4) خصائص تقارب التوجيه القائمة على RDE

تعرضت جميع الخوارزميات لتغيرات طوبولوجية في نفس الوقت. شوهدت جوانب التقارب في الشكل 4 إلى الشكل 6 وفقاً للطوبولوجيا 3. تظهر نتائج الحصول على مسار التوجيه لكل من الهياكل الثلاثة المرتبطة بحالات مختلفة في الجدول 1. وفقاً لملاحظات المحاكاة، في ظل RDE لجميع المسارات التي تم الحصول عليها بأعلى تكلفة للمسار، يتم أخذ مزيد من الوقت للوصول إلى القيمة النهائية. تظهر التجارب أن RDE يستغرق وقتاً أطول للوصول إلى الحلول المثلى وخلال هذا الوقت، قد تؤدي زيادة فرصة التغيرات في الهيكل إلى أسوأ حالة والنتيجة التي تم الحصول عليها غير مجدية. قد يكون من المستحيل على PDE إيجاد الحلول المثلى ضمن اطار زمني إذا كانت هناك درجة كبيرة من الاختلاف في الهيكل. في كل حدث، تفوقت KDE على المنافسة من حيث القدرة على التكيف.



الشكل (5) خصائص تقارب التوجيه القائم على PDE

خليل، الحسين



الشكل (6) خصائص التقارب للتوجيه القائم على KDE

وسرعة اكتشاف الحلول العالمية. وذلك لأن تجربة الحالة السابقة تساعد في التنقل بشكل صحيح في حدث حالي. الجدول (1) يعرض أداء الشبكة عبر طوبولوجيا مختلفة تم إنشاؤها بواسطة أحداث مختلفة.

طوبولوجيا على أساس الحدث	النهج الحسابي	قيمة التكلفة قبل الحدث	قيمة التكلفة في الحدث	التكلفة القصوى لاحقاً بعد الحدث	مدة الاستقرار (وحدة زمنية)
حدث 1	RDE	59	59	81	5
حدث 1	PDE	59	59	59	0
حدث 1	KDE	55	55	55	0
حدث 2	RDE	61	61	73	6
حدث 2	PDE	59	59	59	0
حدث 2	KDE	55	55	55	0
حدث 3	RDE	55	55	67	5
حدث 3	PDE	59	59	44	1
حدث 3	KDE	55	55	31	1

الجدول (2) توفير الطاقة في التوجيه للشبكة الديناميكية

حدث	KDE أفضل مع RDE	KDE أفضل مع PDE
1	%9.83	%6.78
2	0	%6.70
3	%49.20	%29.50

للعثور على أفضل مسار للشبكة في ظل بيئة ديناميكية، من الضروري العثور على المسار بسرعة قبل أن تخضع الشبكة لتغيير جديد. من أجل الحصول على طرق قابلة للتكيف في وقت قصير وأيضاً الحفاظ على استقرار المسار داخل مشغلات الأحداث الجديدة، يتم التعامل مع KDE والذي بدوره يعتمد على المعرفة المكتسبة من أفضل النتائج السابقة



فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....

للتكرارات مما يجعله أقل وقتًا مطلوبًا للعثور على المسار الجديد. من الجدول 1، يمكن رؤية تحليل إحصائي مختلف تم إجراؤه فيما يتعلق بالأحداث التي تم إطلاقها في الشبكة. من الجدول 2 يمكن ملاحظة أن توفير الطاقة في التوجيه تحت KDE أفضل مقارنة بكل من RDE و PDE. ويرجع ذلك إلى أن KDE تستفيد من جميع السكان لإنشاء أجيال جديدة، ولكن في كل حدث يتم بدء التشغيل باستخدام أفضل الحلول التي تم اكتشافها حتى وقوع الحدث.

5. الكشف عن الرأس العنقودي باستخدام استراتيجية الطفرة الهجينة في DE.

### 5-1 نموذج الطاقة:

تكون مسافة الانتشار (d) أقل من مسافة العتبة  $d_0$  في نموذج الطاقة الخاص ب WSN، فإن استهلاك الطاقة للعقدة يتناسب مع  $d_2$ ، وإلا فإنه يتناسب مع  $d_4$ . يتم تحديد إجمالي الطاقة المستهلكة لإرسال حزمة بت لكل عقدة في الشبكة في المعادلة 6.

$$E_{tr}(l,d) = \begin{cases} l \times E_{elect} + l \times \varepsilon_{fs} \times d^2 & \text{if } d < d_0 \\ l \times E_{elect} + l \times \varepsilon_{mp} \times d^4 & \text{if } d \geq d_0 \end{cases} \quad (6)$$

حيث،  $E_{elect}$ : مقدار الطاقة المشتتة لكل بت لتشغيل دائرة المرسل أو المستقبل، والتي يتم تحديدها بواسطة عدد من العوامل بما في ذلك التشفير الرقمي والتشكيل والتصفية ونشر الإشارة.  $\varepsilon_{fs}$ : طاقة لتضخيم الإشارة في نموذج الفضاء الحر.  $\varepsilon_{mp}$ : طاقة لتضخيم الإشارة في نموذج متعدد المسارات.  $d_0$ : حد مسافة الإرسال وبالمثل فإن استهلاك الطاقة من قبل المستقبل لبيانات بت قد أعطته المعادلة 7.

$$E_{rvc}(l) = l \times E_{elect} \quad (7)$$

هناك بعض الافتراضات التي تم إجراؤها على النحو التالي مع الشبكة (1) عقد المستشعرات ثابتة في طبيعتها. (2) يوجد نوعان من العقد: عقد الاستشعار لاستشعار المعلمة ذات الأهمية، وعقد المحطة الأساسية، والتي كانت موجودة في قلب الشبكة. (3) حملت كل عقدة حساسة رقم تعريف مميز (ID) وطاقة أولية ذات نطاق مماثل. (4) العقدة مطلوبة لاستخدام مستويات مختلفة من طاقة الإرسال اعتمادًا على المسافة إلى العقدة المستهدفة. (5) ترسل BS بشكل

خليل، الحسين

دوري رسالة طلب قائمة على الرزم إلى رئيس المجموعة من أجل الحصول على بيانات أخذ العينات من أجهزة الاستشعار. (6) التوصيلات متناظرة ولاسلكية. (7) عدد المستشعرات يفوق عدد CHs.

### 5-2 الحل المقترح للكشف عن رأس الكتلة:

استراتيجية الطفرات الهجينة القائمة على DE (HEDM) تم استخدام شكل مختلف من استراتيجية الطفرة في الطريقة المقترحة، التي حملت مجموعة من المتجهات التفاضلية التي تشكلت في ظل البيئة الاحتمالية من خلال الاختلاف بين أفضل الحلول وحل تم اختياره عشوائيًا أو الاختلاف بين اثنين من أعضاء الحل المختارين عشوائيًا. المتجه التفاضلي المتشكل في النهج الأول يزيد من سرعة التقارب بينما يدعم النهج الثاني الاستكشاف. العملية الكاملة لاستراتيجية الطفرة المحددة أدناه أثناء إجراء عملية الانتقال والاختيار العادية على النحو المحدد في النموذج القياسي ل ED. قيمة عتبة  $(T) > 0.5$ .

رقم عشوائي R تم إنشاؤه من خلال  $U[0,1]$   
BP ← أفضل الحلول الحالية للسكان

إذا كان  $R < T$

أي عضوين ( $Z_1, Z_2$ ) تم اختيارهم بشكل عشوائي من السكان.

المتجه التفاضلي المحدد على النحو التالي:

$$[BM - Z_2] \times mf \rightarrow Dv$$

$$Z_1 + Dv \rightarrow Mv \quad \text{متجه الطفرة}$$

وإلا أي ثلاثة  $Z_1, Z_2$  و  $Z_3$  تم اختيارهم بشكل عشوائي من السكان.

المتجه التفاضلي المعروف على النحو التالي:

$$[Z_3 - Z_2] \times mf \rightarrow Dv$$

$$Z_1 + Dv \rightarrow Mv \quad \text{متجه الطفرة}$$

النهاية:

### 5-3 اختيار مشكلة النمذجة كمسألة التحسين:

لضمان الاختيار الفعال ل HC، يتم أخذها كدالة لعقد الطاقة المتبقية وقياسات المسافة، ويتضمن قياس المسافة متوسط المسافة داخل المجموعة بين عقد المستشعر وعقدة الحوض.

فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....

الهدف الرئيسي من HC هو تقليل المسافة داخل الكتلة وأيضًا لتقليل المسافة من BS إلى جميع sHC في الشبكة المحددة

$$F_1 = \sum_{j=1}^m \frac{1}{l_i} (\sum_{i=1}^{l_j} dis(s_i, CH_j) + dis(CH_j, BS)) \quad (8)$$

يُفضل زيادة الطاقة الإجمالية لرؤوس المجموعة المختارة بالكامل إلى أقصى حد عند اختيار رؤوس المجموعات المثلى كما في المعادلة 9.

$$F_2 = \frac{1}{\sum_{j=1}^m (E_{CHj})} \quad (9)$$

حيث  $E_{CHj}$  طاقة  $j$ ، رأس الكتلة،  $1 \leq j \leq m$  ومن ثم يمكن تعريف وظيفة الهدف النهائية على أنها المعادلة 10

$$\left( F = \gamma \times F_1 + (1 - \gamma) \times F_2 \right) \quad (10)$$

$0 < \gamma < 1$

يجب أن تقلل الوظيفة الموضوعية من أجل الحصول على قيمة أعلى من اللياقة. يُفضل تعظيم إجمالي الطاقة لرؤوس المجموعة المختارة بالكامل عند اختيار رؤوس المجموعة المثلى، مما يستلزم تقليل التبادلية لها على النحو المنصوص عليه.

#### 4-5 تشكيل الكتلة:

تم تطبيق وظيفة مرجحة بواسطة عقد المستشعر للانضمام إلى CH كما هو موضح أدناه

$$CH_W(s_i, CH_j) = \frac{E_{residual\ energy}(CH_j)}{dis(s_i, CH_j) \times dis(CH_j, BS) \times node\ degree(CH_j)} \quad (11)$$

#### 6. النتائج التجريبية لاكتشاف رأس الكتلة:

تم تحميل شبكتان مختلفتان العقدتين 300 و 400 مستشعرات في المنطقة المستهدفة البالغة  $200 \times 200$  متر مربع وذلك للغرض التجريبي. في الشبكة الأولى، تم اعتبار رقمين مختلفين من CHs على أنهما 15 و 30 بينما تم اعتبار 40 CHs للشبكة الثانية. تم تشغيل جميع الخوارزميات التي تم النظر فيها بشكل متكرر لعشر مرات لطبولوجيا الشبكة تحت الملاحظات وتمت مقارنة القيم المتوسطة للكلفة الطاقية. تم تعيين الحجم الأولي للسكان

خليل، الحسين

البالغ 50 لجميع الخوارزميات للتجربة. أنفقت CHs الطاقة في الحصول على البيانات وتجميعها وتوجيهها إلى BS، لذلك تم إجراء تحليل الأداء على إجمالي استخدام الطاقة لعدد معين من الجولات. تم أخذ القيمة على أنها 0.3 بحيث يمكن الحصول على طاقة عالية من CHs. تم عرض معلمة الشبكة المدروسة في الجدول 3. تم تقييم أداء خوارزمية مختلفة من dyPSO PSO و SDE و HMDE عبر شبكة مختلفة وظروف مختلفة. في dyPSO، انخفض الخمول من 1.2 إلى 0.1 مع التكرار بينما تم أخذ قيمة عامل التقييد على أنها 0.72 جنبًا إلى جنب مع معامل التنازل الذي كانت قيمتهم 2. بالنسبة لـ SDE، تم استخدام تنسيق 1/bin/rand. تم عرض أداء الشبكة الأولى بـ 15 CH في الشكل 7. بينما على نفس الشبكة مع CH30، تم عرض أدائها الذي تم الحصول عليه في الشكل 8. يمكن أن يلاحظ أنه بالمقارنة مع dyPSO، كان أداء SDE أفضل ولكن الخوارزمية المقترحة HMDE تفوقت على كل من هذه الخوارزميات. تم عرض مقارنة أداء 40 sHC على الشبكة الثانية في الشكل 9 ولوحظ أن استراتيجية الطفرات الهجينة قد قدمت أداءً فائقًا. ولوحظ أيضًا أنه مع زيادة عدد الجولات، ظهر المزيد من استهلاك الطاقة وكانت فجوة استهلاك الطاقة بين HMDE والخوارزميات الأخرى أوسع وأوسع. وتم توضيح الفوائد المؤيعة التي تم الحصول عليها في توفير الطاقة مقابل dyPSO بواسطة SDE و HMDE في الجدول 4.

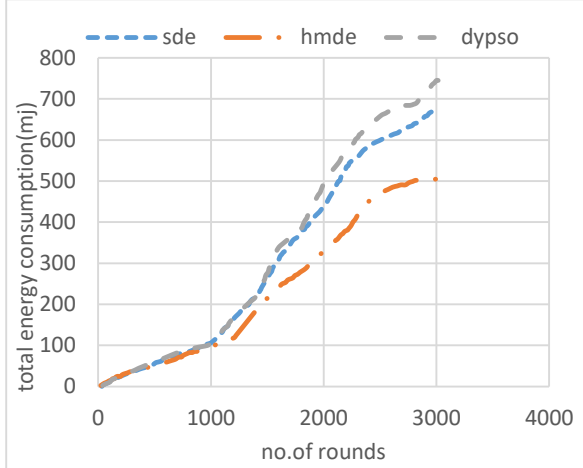
فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....

الجدول (3) بارامترات الشبكة

Network target area	200×200 m <sup>2</sup>
E <sub>elect</sub>	50 nj /bit
$\epsilon_{fs}$	10 pj/bit/m <sup>2</sup>
d <sub>0</sub>	30m
d <sub>max</sub>	100m
Packet length	4000bit
Message size	500bit

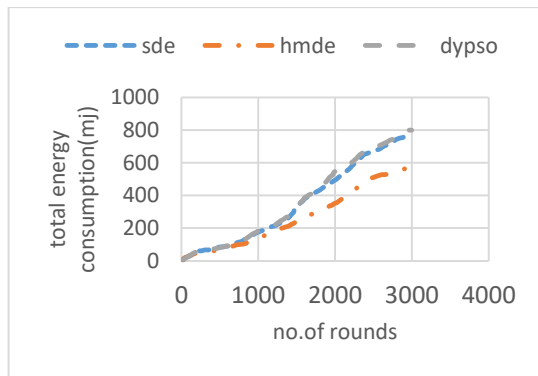
خليل، الحسين

التطور التفاضلي للعثور على رأس كتلة أفضل تحت تكوينات شبكة مختلفة. هناك العديد من الخوارزميات التجريبية الأخرى، بعضها خوارزميات قائمة على التطورية مثل CS و GA و GWO و FFOA وما إلى ذلك.

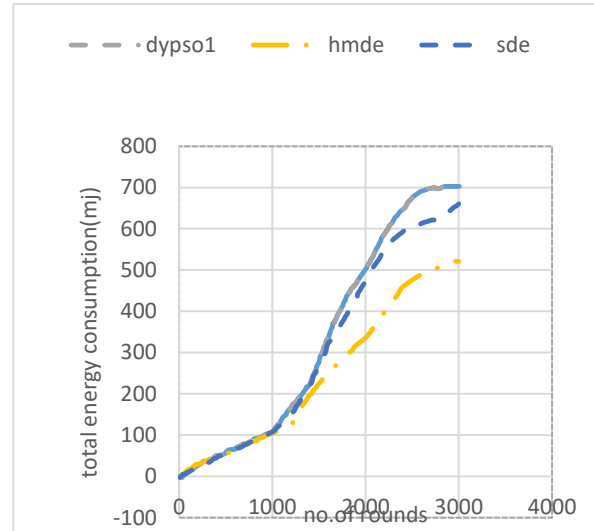


الشكل (8) مقارنة إجمالي استهلاك الطاقة للشبكة الأولى (30) CHs

يتم تشغيل عمليات المحاكاة لشبكات مختلفة وعدد CHs يكون 15 و 30 و 40 CH تم تنفيذها لـ 1000 و 1500 و 2000 و 2500 و 3000 تكرار، في جميع الطاقة المستهلكة للعثور على CHS يتم قياسها للخوارزميات المذكورة أعلاه وكذلك تحت SPyDO و SDE و HMDE.




الشكل (9) مقارنة إجمالي استهلاك الطاقة للشبكة الثانية (40) CHs



الشكل (7) مقارنة إجمالي استهلاك الطاقة للشبكة الأولى (15) CHs

تلعب طاقة العقد داخل الكتلة دوراً رئيسياً في تنفيذ عمليات الشبكة في ظل التوجيه الهرمي. يحتاج التوجيه إلى النظر في نقل البيانات من العقد إلى المحطة الأساسية، إذا كانت العقد في موقع بعيد، فيجب اتباع التوجيه متعدد المسارات الذي يمكن أن يؤدي إلى مشكلة نقطة فعالة ومشكلة عزل الشبكة. لذلك في التسلسل الهرمي يتم تشكيل العقد في مجموعات وسيكون لكل مجموعة رأس عنقودية، وستقوم العقدة عالية الطاقة بجمع البيانات من العقد العنقودية وإرسالها إلى المحطة الأساسية. تعتبر مهمة العثور على CH فعالة مهمة صعبة تقلل من تكلفة النقل الإجمالية. في هذه الدراسة، تم النظر في استراتيجية طفرة هجينة في ظل

فعالية خوارزمية التطور المعدلة لتحسين عمر الشبكة.....



الشكل (10) استهلاك الطاقة لخوارزميات مختلفة

الجدول (4) النسبة المئوية (%) توفير الطاقة بواسطة خوارزميات

مختلفة مقابل خوارزمية dyPSO

رقم الجملة	الشبكة الاولى CHs 15		الشبكة الثانية CHs 30		الشبكة الثالثة CHs 40	
	SD E	HM DE	SDE	HM DE	SD E	HM DE
400	6.0	16.0	8.3	16.7	4.2	26.4
800	5.6	10.0	5.7	10.2	3.3	19.0
1200	12.4	29.4	2.4	31.7	1.4	14.3
1600	5.9	28.2	7.1	29.6	0.8	29.7
2000	5.6	33.8	11.89	34.3	9.3	35.7
2400	8.7	29.9	8.9	29.8	3.9	26.5
3000.0	6.4	26.1	8.8	32.6	3.9	27.5

## 7- أهم مميزات خوارزمية Hybrid mutation

DE strategy based ومقارنتها مع KDE,

:RDE, PDE

خوارزمية HMDE هي خوارزمية معدلة لخوارزمية التطور

التفاضلي، وتتميز بعدة مميزات من بينها:

1- تستخدم استراتيجيات تحول مختلفة للتحسين، مثل

استراتيجية القفز العشوائي واستراتيجية التحول الحالي

خليل، الحسين

واستراتيجية التحول العشوائي. وهذا يساعد على زيادة التنوع في المجموعة وتحسين جودة الحلول المرشحة.

2- تستخدم خوارزمية التحسين اللامراقبة (Unsupervised Learning)، حيث تقوم بتحسين الحلول المرشحة بشكل تلقائي دون الحاجة إلى معرفة مسبقة للمشكلة المطلوب حلها.

3- تعتمد الخوارزمية بشكل كبير على العناصر العشوائية في عملية التحسين، مما يعزز التنوع في المجموعة ويقلل احتمال الوقوع في الحلول المحلية.

مقارنة بين خوارزمية HMDE والخوارزميات الأخرى المعدلة لخوارزمية التطور التفاضلي:

1- مقارنة مع RDE: تستخدم خوارزمية RDE تعديلاً على عملية تحديث مجموعة الحلول المرشحة، بينما تستخدم HMDE استراتيجيات تحول متعددة لتحسين الحلول، مما يزيد من فعالية الخوارزمية في تحقيق أفضل الحلول.

2- مقارنة مع KDE: تستخدم خوارزمية KDE المعرفة المسبقة للمشكلة في عملية التحسين، بينما تعتمد HMDE على العناصر العشوائية في عملية التحسين. وبالتالي، يمكن أن تكون HMDE أكثر فعالية في حالة عدم وجود معرفة مسبقة للمشكلة.

3- مقارنة مع PDE: تستخدم خوارزمية PDE زيادة عشوائية في الحلول المرشحة، بينما تستخدم HMDE استراتيجيات تحول مختلفة. وبالتالي، يمكن أن تكون HMDE أكثر فعالية في تحسين جودة الحلول المرشحة وتقليل احتمال الوقوع في الحلول المحلية.

بشكل عام، تعتبر خوارزمية HMDE خوارزمية معدلة فعالة في تحسين جودة الحلول المرشحة وتقليل احتمال الوقوع في الحلول المحلية. وتستخدم الخوارزمية استراتيجيات تحول مختلفة وتعتمد على العناصر العشوائية في عملية التحسين، مما يزيد من التنوع في المجموعة ويحسن من جودة الحلول المرشحة. ومقارنة بالخوارزميات الأخرى المعدلة لخوارزمية التطور التفاضلي، تعتبر HMDE أكثر فعالية في بعض الحالات، حيث تستخدم العناصر العشوائية في عملية التحسين بدلاً من المعرفة المسبقة للمشكلة، كما أنها تستخدم

استراتيجيات تحول متعددة لتحسين الحلول بدلاً من تعديل عملية تحديث مجموعة الحلول المرشحة، مما يجعلها خياراً جيداً في حالة عدم وجود معرفة مسبقة للمشكلة. ومع ذلك، فإن الخوارزميات المذكورة الأخرى مثل RDE و KDE و PDE لها مزاياها الخاصة ويمكن استخدامها بنجاح في حالات معينة.

## 8. الخاتمة:

يتمثل التحدي الرئيسي مع WSN في إطالة عمر الشبكة من خلال وجود توجيه موفر للطاقة واختيار فعال لرأس المجموعة، وهو ما تم تناوله في هذا العمل. تم اعتبار التطور التفاضلي بمثابة منصة الحل لكلتا القضيتين بينما تم اقتراح متغيرات مختلفة لتحسين جودة النموذج القياسي لـ DE. تم حل تعقيد التوجيه في الشبكة الديناميكية بكفاءة باستخدام المعرفة السابقة المكتسبة. مع التغيير الجديد في البنية، فإن إعادة التوجيه من البداية والتي استهلكت المزيد من الوقت ليس فقط أنه يمكن أن تكون هناك فرصة لتغيير جديد في البنية مما قد يتسبب في إهدار الجهد السابق المطبق. ومن ثم فإن النهج القائم على المعرفة يستخدم المعلومات التي تم الحصول عليها مسبقاً للحصول على التوجيه الأمثل في غضون فترة زمنية أقل. لقد وفر اكتشاف رأس الكتلة وسيلة لتوفير الكثير من الطاقة ولكن تم حل مشكلة التعقيد العالية بكفاءة من خلال توفير استراتيجية طفرة هجينة كان لها توازن أفضل بين الاستكشاف والاستغلال. وقد لوحظ أن HMDE قد قدمت الكثير من الكفاءة.

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

## REFERENCES:

1. K. -S. B. Pralhad, C. R. Singla and S. B. Patil, "Design of An Energy Efficient Data Aggregation Method for Secured Routing Protocol in WSN," 2nd Asian Conference on Innovation in Technology (ASIANCON), 2022, pp. 1-6, doi 10.1109/ASIANCON55314.2022.9909403.
2. Mohammed, R. J., Abed, E. A., & El-gayar, M. M.. "Comparative study between metaheuristic algorithms for internet of things wireless nodes localization", International Journal of Electrical and Computer Engineering (IJECE) 12(1) 2022, 660  
<https://doi.org/10.11591/IJECE.V12I1.PP660-668>.
3. Joshi, P., & Raghuvanshi, A. S. "Hybrid Approaches to Address Various Challenges in Wireless Sensor Network for IoT Applications: Opportunities and Open Problems". International Journal of Computer Networks and Applications, 8(3) (2021). 151. <https://doi.org/10.22247/IJCNA/2021/209186>.
4. Sharawi, M., Saroit, I. A., El-Mahdy, H., & Emary, E "Routing Wireless Sensor Networks Based on Soft Computing Paradigms: Survey", International Journal on Soft Computing, Artificial Intelligence and Applications, 2(4) (2013), 21–36. <https://doi.org/10.5121/IJSCAI.2013.2403>.
5. Sekaran, K., Rajakumar, R., Dinesh, K., Rajkumar, Y., Latchoumi, T. P., Kadry, S., & Lim, S. "An energy-efficient cluster head selection in wireless sensor network using grey wolf optimization algorithm", TELKOMNIKA (Telecommunication Computing Electronics and Control), 18(6) (2020), 2822. <https://doi.org/10.12928/TELKOMNIKA.V18I6.15199>.
6. Nabavi, Seyed Reza, Nafiseh Osati Eraghi, and Javad Akbari Torkestani. "Intelligent Optimization of QoS in Wireless Sensor Networks Using Multiobjective Grey Wolf Optimization Algorithm." Wireless Communications and Mobile Computing (2022): 1–15.
7. Uppal R.S "Hybrid Intelligent Algorithm for Energy-Efficient Routing in WSN", In: Urooj S., Virmani J. (eds) Sensors and Image Processing. Advances in Intelligent Systems and Computing, vol 651. (2018),. Springer, Singapore. <https://doi.org/10.1007/978-981-10-6614-619>.
8. Vinodhini R., Gomathy C. (2020) A Hybrid Approach for Energy Efficient Routing in WSN: Using DA and GSO Algorithms. In: Smys S., Bestak R., Rocha Á. (eds) Inventive Computation Technologies. ICICIT 2019. Lecture Notes in Networks and Systems, vol 98. Springer, Cham. <https://doi.org/10.1007/978-3-030-33846-655>.
9. Shafiq, M., Ashraf, H., Ullah, A. et al. Systematic Literature Review on Energy Efficient Routing Schemes in WSN – A Survey. Mobile Netw Appl 25, 882–895 (2020).  
<https://doi.org/10.1007/s11036-020-01523-5>.
10. Qabouche, H., Sahel, A. & Badri, A. Hybrid energy efficient static routing protocol for homogeneous and heterogeneous large scale WSN. Wireless Netw 27, 575–587 (2021).  
<https://doi.org/10.1007/s11276-020-02473-2>.
11. Tabassum A., Sadaf S., Sinha D., Das A.K. Secure Anti-Void Energy-Efficient Routing (SAVEER) Protocol for WSN-Based IoT Network. In: Sahana S., Bhattacharjee V. (eds) Advances in Computational Intelligence. Advances in Intelligent Systems and Computing, vol 988. Springer, (2020).
12. R. V. Kulkarni and G. K. Venayagamoorthy, "Particle swarm optimization in wireless-sensor networks: a brief survey," IEEE Transactions on Systems, Man and Cybernetics Part C, vol. 41,no. 2, pp. 262–267, 2011.

13. T. Kang, J. Yun, and K. Han, "A clustering method for energy efficient routing in wireless sensor networks," in Proceedings of the 6th International Conference on Electronics, Hardware, Wireless and Optical Communications (WSEAS '07), pp. 133–138, Corfu Iceland, Greece, February 2007.
14. K. Halgamuge, and S. Fernando, "Particle swarm optimizers for cluster formation in wireless sensor networks," in Proceedings of the IEEE International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP '05), S. K. Halgamuge, Ed., pp. 319–324, Melbourne, Australia, December 2002.
15. N. M. A. Latiff, C. C. Tsimenidis, and B. S. Sharif, "Energy-aware clustering for wireless sensor networks using particle swarm optimization," in Proceedings of the 18th Annual IEEE International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC '07), pp. 1–5, Athens, Greece, September 2007.
16. Prabakaran, G., Jayashri, S. Mobile cluster head selection using soft computing technique in wireless sensor network. Soft Comput 23, 8525–8538 (2019). <https://doi.org/10.1007/s00500-019-04133-w>.
17. Sudha C., Suresh D., Nagesh A. An Enhanced Dynamic Cluster Head Selection Approach to Reduce Energy Consumption in WSN. In: Saini H.S., Singh R.K., Tariq Beg M., Sahambi J.S. (eds) Innovations in Electronics and Communication Engineering. Lecture Notes in Networks and Systems, vol 107. Springer, Singapore. (2020). [https://doi.org/10.1007/978-981-15-3172-9\\_22](https://doi.org/10.1007/978-981-15-3172-9_22).
18. Rathore, P.S., Chatterjee, J.M., Kumar, A. et al. Energy-efficient cluster head selection through relay approach for WSN. J Supercomput (2021). <https://doi.org/10.1007/s11227-020-03593-4>.
19. J. Kennedy and R. Eberhart, "Particle swarm optimization," in Proceedings of the IEEE International Conference on Neural Networks, vol. 4, pp. 1942–1948, Perth, Australia, November–December 1995.
20. F. Xiangning, and S. Yulin, "Improvement on LEACH protocol of wireless sensor network," 2007 International Conference on Sensor Technologies and Applications, pp. 260–264, 2007.
21. M. Sangeetha, and A. Sabari, "Genetic optimization of hybrid clustering algorithm in mobile wireless sensor networks," Sensor Review, vol. 38, no. 4, pp. 526–533, 2018.
22. Sekaran, Kaushik, and P. Venkata Krishna, "Big Cloud: a hybrid cloud model for secure data storage through cloudspace," International Journal of Advanced Intelligence Paradigms, vol. 8, no. 2, pp. 229–241, 2016.
23. G. Kia, and A. Hassanzadeh, "HYREP: A Hybrid Low-Power Protocol for Wireless Sensor Networks," International Journal of Engineering, vol. 32, no. 4, pp. 519–527, 2019.
24. N. A. Latiff, C. C. Tsimenidis, and B. S. Sharif, "Energy-aware clustering for wireless sensor networks using particleswarm optimization," 2007 IEEE 18th International Symposium on Personal, Indoor and Mobile Radio Communications, pp. 1–5, 2007.
25. K. N. Dattatraya, and K. R. Rao, "Hybrid based cluster head selection for maximizing network lifetime and energy efficiency in WSN," Journal of King Saud University-Computer and Information Sciences, pp. 1–11, 2019.