

تقييم أداء خوارزميات الجدولة الاستدلالية العليا لتوفير الطاقة في شبكات انترنت الأشياء الخضراء المستندة إلى السحابة

* د.م علي معين إسماعيل

* م. ايمن محمد إسماعيل

(تاريخ الإيداع ٢٠٢٤/١١/٢٤ . قبل للنشر في ٢٠٢٥/٤/٢٣)

□ ملخص □

بدأ الاعتماد على شبكات وتقنيات انترنت الأشياء الأخضر (Green IOT)، نتيجة لما تسببه شبكات انترنت الأشياء الحالية -مع انتشارها الواسع- من انبعاثات ثاني أكسيد الكربون و البصمات الإلكترونية ولما تستهلكه هذه الشبكات من طاقة. هذا الانتشار الواسع لها رافقه تزايد في حركة مرور بيانات هذه الشبكات، وانتقلت هذه الشبكات للعمل على عناوين (IPv6)، مما أدى لقصور في التقنيات الحالية من حيث كمية الطاقة المتاحة، إذ تحول التركيز اليوم نحو حلول فعالة في استخدام الطاقة. وأصبح عنق الزجاجة اليوم في تصميم الأنظمة الحديثة ليس فقط القدرات الحسابية، وإنما يشمل أيضاً محدودية الطاقة.

تزايد الاهتمام من قبل الباحثين والأوساط الأكاديمية خلال السنوات العشر الأخيرة بنخفيض كمية الطاقة التي تستهلكها شبكات انترنت الأشياء، حيث كان لجدولة أجهزة انترنت الأشياء من حيث أوقات عملها والمهام المسندة إليها تأثير كبير في مقدار استهلاك هذه الشبكات للطاقة، لذا يهدف هذا البحث لتقييم أداء تقنيات الجدولة الحديثة التي تعتمد على خوارزميات التحسين والاستدلال العليا (Metaheuristic) لتقليل استهلاك الطاقة في بيئات انترنت الأشياء، وذلك من خلال محاكاة عملية لهذه البيئة الشبكية باستخدام (MATLAB R2022a)، إذ يتضح من خلال نتائجها المقدار الكبير من الطاقة الذي يتفاوت نسبة توفير استهلاكه بين الخوارزميات الثلاث (SSA, HHO, PSO).

الكلمات المفتاحية: انترنت الأشياء الأخضر - جدولة المهام - جدولة نوم الأجهزة - كفاءة الطاقة - استهلاك الطاقة - الخوارزميات الاستدلالية العليا (خوارزمية سرب الملاحات، خوارزمية سرب الجسيمات التحسينية، خوارزمية طيور هاريس التحسينية).

* أستاذ مساعد، قسم هندسة النظم والشبكات الحاسوبية، كلية الهندسة المعلوماتية، جامعة اللاذقية، اللاذقية، سوريا.

** طالب دراسات عليا (ماجستير)، قسم هندسة النظم والشبكات الحاسوبية، كلية الهندسة المعلوماتية، جامعة اللاذقية، اللاذقية، سوريا.

ayman.ismail.713@gmail.com

Evaluating the performance of Meta-heuristic Scheduling Algorithms for Energy Saving in Cloud-Based Green IoT Networks

Dr. Ali Moen Ismail*

Eng. Ayman Mohammed Ismail**

(Received 24/11/2024 . Accepted 23/4/2025)

□ ABSTRACT □

The reliance on Green IoT networks and technologies has began, as a result of what current Internet of Things networks cause and its wide spread of carbon emissions and electronic footprint, and the power that consumed in this networks. This wide spread was accompanied by an increase in the data traffic of these networks, so these networks started to work on (IPv6) addresses, which cause to deficiencies in the current technologies in terms of the amount of power that used for this networks. So the major focus today has moved towards energy-efficient solutions. Today's bottleneck in up-to-date system design is not only computational capabilities or transmission rate, but also power limitations.

Over the past ten years, there has been increasing interest of researchers and academia in reducing the amount of energy consumed by Internet of Things networks, where scheduling the sleep and tasks of Internet of Things devices had a significant impact on the whole of energy consumption of these networks. Therefore, this research aims to continue evaluating the performance of latest scheduling techniques that used optimization and metaheuristic algorithms to reduce energy consumption in Internet of Things environments, this will done by a practical simulation of this network environment using (MATLAB R2022a), as its results show the large amount of energy that varies in its consumption savings between the three algorithms (SSA, HHO, PSO).

Keywords: Green Internet of Things (Green IOT) - Task Scheduling - Device sleep scheduling - Energy efficiency - Power consumption - Optimization algorithms: Salp Swarm Algorithm (SSA), Harris Hawks Optimization (HHO), Particle Swarm Optimization (PSO).

* Assistant Professor, Department of System and Computer Networks, Faculty of Information Engineering, Latakia University, Latakia, Syria.

** Postgraduate Student, Department of System and Computer Networks, Faculty of Information Engineering, Latakia University, Latakia, Syria. ayman.ismail.713@gmail.com

مقدمة:

يتطلب الوصول لمفهوم انترنت الأشياء الأخضر (الصديق للبيئة) البحث والتقصي في الطرق والتقنيات التي تمكننا من تخفيض استهلاك الطاقة والانبعاثات الكربونية لشبكات انترنت الأشياء الحالية. فكما نعلم انترنت الأشياء (IOT) هو شبكة من الكائنات المادية (Physical Objects) التي ندعوها بالأشياء حيث يتم دمج هذه الكائنات مع مستشعرات (Sensors) معينة وبروتوكولات برمجية مسؤولة عن عملها ومحولات الشبكة (Network Adapters) لتمكين الاتصال الداخلي / البيئي لهذه الكائنات (الأشياء) [1]. ويفضل معرفاتها الفريدة، يمكن لهذه الكائنات الارتباط ببعضها البعض وجمع البيانات ونقلها وتبادلها عبر الانترنت بشكل صحيح ودقيق دون الحاجة إلى أي تفاعل بشري. لذلك، يتيح لنا انترنت الأشياء الاستشعار عن بعد والتحكم في الأجهزة / الكائنات عبر الانترنت من خلال البنية التحتية للشبكة الحالية. وبالتالي، يتمتع انترنت الأشياء بإمكانية كبيرة لزيادة الكفاءة والدقة والأرباح المالية في كل مجال من مجالات الحياة تقريباً، حيث إنه يسهل التكامل المباشر للعالم المادي مع الأنظمة القائمة على الكمبيوتر. فوفقاً لـ Cisco بعد حلول عام ٢٠٢٢ ستمثل اتصالات انترنت الأشياء أكثر من نصف جميع الأجهزة والوصلات العالمية المتصلة. حيث تتوقع Cisco أن تصل حركة المرور الناتجة عن الأجهزة التي تدعم انترنت الأشياء إلى ٦٪ من حركة مرور IP العالمية بعد عام ٢٠٢٢ [2].

لكن هذا الانتشار الواسع لشبكات انترنت الأشياء وزيادة الكبيرة في عدد أجهزتها فرض على الشركات التقنية والمصنعة لهذه الأجهزة ضرورة التحول للعبء عبر (IP v6) وذلك لأن تقنيات الانترنت أحد الأجزاء المهمة في انترنت الأشياء، حيث من خلالها يتم الوصول إلى الأجهزة مباشرة وتحديد الجهاز المخاطب من خلال معرفه أو مراقبتها أو التحكم فيها، لكن عناوين (IP v4) لم تعد قادرة على تخديم وعنونة هذا الكم من الأجهزة والشبكات إذ شكّل هذا التحول قصور في موارد الطاقة فعلاوة عما كانت تسببه هذه الشبكات من استهلاك للطاقة وانبعاثات كربونية أصبحت موارد الطاقة المخصصة لهذه الشبكات تعاني من قصور في تخديم هذه الأجهزة لتصبح اليوم كمية الطاقة التي تستخدمها هذه الشبكات محوراً بحثياً هاماً [3].

وبناءً على ما تم ذكره سنركز في هذا البحث على دراسة استهلاك الطاقة في شبكات انترنت الأشياء المبنية في السحابة وتقييم أداء التقنيات الحديثة للجدولة المعتمدة على خوارزميات الاستدلال العليا (SSA, PSO, HHO) التي تم إنشائها وتطويرها لتساهم في إيجاد حلول للمشاكل التي يصعب حلها بزمن كثير الحدود (NP-hard) وسنسخر قدرات هذه الخوارزميات في توفير الطاقة وزيادة العمر الافتراضي ضمن هذه الشبكات وسيتضمن البحث دراسة لنتائج هذه المحاكاة نستخلص منها العديد من التوصيات والاستنتاجات التي ستساهم في الانتقال الآمن لشبكات انترنت الأشياء الأخضر ضمن بيئة السحابة.

أهمية البحث وأهدافه:

توضح النقاط الآتية أهمية البحث وما يهدف إليه:

- يبين هذا البحث تأثير الجدولة في مشكلة الطاقة ضمن شبكات انترنت الأشياء، ويساهم في رسم طريق الوصول لشبكات انترنت الأشياء الأخضر المعتمدة على السحابة ويوضح دور السحابة في توفير الطاقة المستهلكة في هذه الشبكات.

• يستعرض هذا البحث مشكلة جدولة المهام في شبكة إنترنت الأشياء السحابية ويختار ثلاث تقنيات استدلال عليا (Metaheuristic) وهي (SSA, PSO, HHO) موضحاً طريقة عمل هذه الخوارزميات، ومسخرًا إياها لحل مشكلة جدولة المهام بكفاءة من حيث الطاقة.

• يقدم هذا البحث تقييم لأداء الخوارزميات (SSA, PSO, HHO) في توفير الطاقة وعمر الشبكة الافتراضي من خلال جدولة هذه الخوارزميات لمهام الشبكة على أجهزتها الطرفية (الحساسات)، ويوضح دور وأهمية هذه الخوارزميات في حل مشكلة الطاقة في شبكة إنترنت أشياء مبنية في السحابة وتعمل على تنظيم حركة النقل والمرور في شارع مزدحم.

منهجية البحث ومواده:

تم إعداد هذا البحث وفق منهجيتين أساسيتين هما:

- منهجية عامة تشمل الدراسة النظرية والاستعراض للدراسات السابقة ولأساسيات مشكلة البحث بما في ذلك دور السحابة ضمن شبكات إنترنت الأشياء الأخضر وأثر الجدولة بمستوياتها -جدولة المهام وجدولة نوم الأجهزة- في مشكلة توفير الطاقة ضمن شبكات إنترنت الأشياء.
- منهجية خاصة تتضمن دراسة لخوارزميات الاستدلال العليا (Metaheuristic) وتسخيرها للمساهمة في حل مشكلة البحث من خلال محاكاة عملية لشبكة إنترنت أشياء مبنية في بيئة السحابة باستخدام (MATLAB R2022a) وتم من خلالها تحليل الأداء الذي قدمته كل خوارزمية واستخلاص الاستنتاجات.

١- أساسيات نظرية ودراسات مرجعية:

١-١- تعريف إنترنت الأشياء الأخضر (Green IOT) وأهدافه:

يشير مصطلح إنترنت الأشياء الأخضر (Green IOT) إلى نموذجاً ناشئاً من شبكات إنترنت الأشياء يهدف إلى تصميم وتطوير ونشر أنظمة وتقنيات إنترنت الأشياء مع التركيز على الاستدامة البيئية وذلك خلال كفاءة الطاقة وتقليل الانبعاثات الكربونية الناتجة عن هذه الشبكات [1] ويهدف إلى:

- ١- تقليل استهلاك الطاقة والبصمة الكربونية لأجهزة وشبكات إنترنت الأشياء.
- ٢- الاستفادة من مصادر الطاقة المتجددة لتشغيل البنية التحتية لإنترنت الأشياء.
- ٣- تنفيذ عمليات التصنيع الخضراء لأجهزة إنترنت الأشياء وتعزيز إعادة التدوير

والتخلص الآمن منها.

- ٤- الاستفادة من تطبيقات إنترنت الأشياء لتمكين المراقبة والأتمتة الصديقة للبيئة

لمختلف القطاعات.

١-٢- دور الجدولة في تخفيض الطاقة ضمن شبكات إنترنت الأشياء الأخضر:

تعدّ الجدولة أحد الحلول المفصلية ذات الأفق المستقبلية الكبيرة في عالم إنترنت الأشياء الأخضر فسابقاً لم يؤخذ دور الجدولة في توفير الطاقة بعين الاعتبار فخوارزميات الجدولة التقليدية لا تكثر بتوفير الطاقة بل هي صممت لتراعي قيود زمنية أو حسابية وليس قيود للطاقة مما جعل من الجدولة محط أنظار كثير من الباحثين للاستفادة منها كحلول تفيدي في تقليل استهلاك الطاقة في شبكات إنترنت الأشياء حيث تدرج الجدولة ضمن حلول

الاتصالات والشبكات منخفضة الطاقة حيث عمل الباحثون على دراسة توفير الطاقة في شبكات انترنت الأشياء بالاعتماد على حلول الجدولة ضمن مستويين هما جدولة النوم وجدولة المهام [1].

١-٢-١- جدولة نوم الأجهزة (Devices Sleep Sheduling):

في شبكات انترنت الأشياء اللاسلكية تبقى الأجهزة بوضع الاستماع (Listening) كي لا تفوت أي حزم مخصصة لها وعلى الرغم من أن هذا النهج يحقق إنتاجية عالية في الشبكة وزمن انتقال منخفض إلا أنه يتسبب في استهلاك كمية كبيرة من الطاقة وغالباً ما تبقى الأجهزة مستيقظة لذا تُعتبر جدولة نوم الأجهزة في شبكات انترنت الأشياء أمراً بالغ الأهمية وتشمل جدولة النوم هذه تحديد فترات استيقاظ ونوم الأجهزة في الشبكة وتحديد أنماط عمل هذه الأجهزة بالإضافة للعمل على إنشاء دورة عمل فعالة في الشبكة.

- تناول الباحثون في [4] مشكلة جدولة نوم الأجهزة من خلال تحسين فترات الإرسال والاستقبال المنقطعة (Discontinuous Reception/Transmission) DTX / DRX لكائنات انترنت الأشياء من خلال التساؤل عن كيفية زيادة فترات سكون الأجهزة مع ضمان جودة الخدمة الخاصة (QOS) بها، وذلك عبر السماح لهذه الأجهزة بإيقاف تشغيل واجهات الراديو الخاصة بها (Radio Interface) والسكون في أنماط مختلفة من شأنها تخفيف استهلاك الطاقة لهذه الأجهزة. إذ اقترح الباحثون في هذه الدراسة مخططات فعالة لتحسين معلمات DTX / DRX (Tokens) وجدولة حزم الأجهزة مع المحطة الأساسية، مما أدى للسماح لمستخدمي الأجهزة بالذهاب إلى وضع السكون عندما لا يتم انتهاك أوقات الاستجابة لطلب الخدمة وحقق هذه المخططات المقترحة تحسين في استهلاك الطاقة مقارنة مع تقنيتي MTD&CDD المعياريتين.

- اهتم الباحثون في [5] بجدولة نوم الأجهزة أيضاً، إذ قاموا بتطوير نموذج تحليلي جديد يأخذ بالحسبان أنماط حركة المرور لاتصالات من نوع (M2M)، وتم اقتراح خوارزمية جديدة (Offset Listen-Interval) OLI تعزز آليات توفير الطاقة الحالية مع إطالة عمر شبكة اتصالات آلة لآلة ضمن إزاحات محسوبة، حيث أدى هذا التوزيع لحركة المرور في شبكات M2M بالتساوي عبر جدولة فترات نوم الأجهزة لتقليل حالات التصادم و المنافسة على عرض الحزمة للقناة مما ساهم في توفير الطاقة ضمن هذه الشبكات مقارنة بمعايير ٨٠٢,١١ القياسية (PSMP&APSD).

- قام الباحثون في [6] بصياغة مشكلة جدولة نوم الخلايا الصغيرة كمسألة تحسين غير خطية (non-linear optimization problem) وقدموا اقتراحاً لخوارزمية استدلال عليا (Metaheuristic) لحل المشكلة في زمن كثير الحدود، إذ قاموا بدايةً ضمن الخوارزمية المقترحة (MHGA) بتحديد أربع حالات لكل خلية صغيرة في الشبكة (-Sleep//ON Awake//Deep-sleep//OFF) وتم اعتبار النموذج التحليلي المقترح صعب الحل أي مشكلة (NP) بالنسبة لشبكة كبيرة، وتم تصميم الخوارزمية بشكل جيني وحقق تفوقاً في توفير الطاقة ضمن شبكات الجيل الخامس مقارنة ب الخوارزميات المستخدمة حالياً (All-On//On-Off//Sleep-Awake).

١-٢-٢- جدولة مهام الشبكة (Network Tasks Scheduling):

جدولة المهام في شبكات انترنت الأشياء مسؤولة عن إسناد مهمة ما للجهاز المناسب لإنجازها في الشبكة أو جدولة ترتيب المهام لأدائها في الشبكة بحسب أولوياتها أو قيودها الزمنية أو الحسابية أو تبعاً للجهاز القادر على إنجاز المهمة وانطلاقاً من هذا الصدد فإن الجدولة الملائمة للمهام ضمن شبكات انترنت الأشياء من شأنها

أن تلعب دور حاسم في تقليل استهلاك طاقة الشبكة، وإرسال واستقبال المهام يتطلب من الجهاز أن يكون بوضع استيقاظ وجاهز للإرسال أو الاستقبال ومدة الإرسال والاستقبال وبعد الجهاز (مسافة المسار الذي ستسلكه المهمة من المجدول للجهاز) ستؤثر بشكل كبير على مقدار الطاقة المستهلكة لإنجاز المهمة.

- لاحظ الباحثون في [7] أن خوارزميات جدولة المهام تراعي فقط ميزات طبقة التطبيق للرسائل (مثل وقت انتهاء الصلاحية) ولم يتم التطرق كثيراً للتعامل مع الجدولة في مشكلة كفاءة الطاقة، فقدموا اقتراح لخوارزمية جدولة للرسائل مدركة للطاقة (Short Process Time) مع مراعاة إخفاق العقدة، إذ أدى تحليل فترات رسائل المستشعر الواردة من أجهزة الاستشعار و جدولة مهامه من خلال الخوارزمية المقترحة لتوفير مزيداً من الطاقة مقارنة بحالة عدم استعمال الخوارزمية المقترحة.

- أسهم الباحثون في [8] بتطوير جدولة المهام لأجهزة انترنت الأشياء في بيئة الضباب الحسابية من خلال اقتراحهم لخوارزمية (AEOSSA Artificial Ecosystem-based Optimization Salp swarm Algorithm) التحسينية الذكية التي استوحيت طريقة عملها من النظام البيئي الطبيعي، حيث ضمن الخوارزمية المقترحة (AEOSSA) المكون الأهم بدايةً هو Fog-Broker الذي يتم تثبيته في طبقة العقد الضبابية ويحوي على (مدير مهام ،خدمة مراقبة للموارد، جدولة ذكية للمهام) وتم الاستناد إلى التحسين القائم على النظام الإيكولوجي (AEO) من خلال ثلاث مراحل (الإنتاج، الاستهلاك، التحلل)، إذ أدى استعمال خوارزمية جدولة المهام المقترحة والمطورة لتحسين كبير في أداء الشبكة مقارنة بعدة خوارزميات ذكية أخرى (SSA, PA, AEO).

٣-١ - خوارزميات الاستدلال العليا (Metaheuristic):

يمكن توصيف هذا النوع من الخوارزميات على أنها خوارزميات استدلالية ذكية وحسابية تعمل على استكشاف حلول وتحسينها مع كل تكرار، وتستخدم في إيجاد الحلول لمشاكل التحسين المعقدة من نوع (NP & NP-hard) وذلك بالاعتماد على مشغلات (Operators) خاصة لكل خوارزمية ومحددات تجعل أداء كل خوارزمية مختلف عن الأخرى بالإضافة للتوابع الرياضية الحسابية التي تضمنها هذه الخوارزميات كتابع التطوير (Fitness Function) الخاص بكل خوارزمية الذي يتم من خلاله إيجاد قيمة التطوير (Fitness Value) التي تحدد مدى جودة الحل الذي يتغير مع كل تكرار لعمل الخوارزمية [9].

٣-١-١ - آلية عمل خوارزميات الاستدلال العليا:

تتميز هذه الخوارزميات بقدرات كبيرة في إيجاد وتحسين الحلول للمشاكل من نوع (NP & NP-hard) وذلك بسبب طبيعة عملها المعقدة والتكرارية والمناسبة لطبيعة هذه المشاكل، إذ يقوم مبدأ عمل هذه الخوارزميات على طبيعة مشغلاتها وتوابعها الحسابية التي تقايس بين مفهومين أساسيين في عمل هذه الخوارزميات هما:

* الاستكشاف (Exploration): يمثل الاستكشاف قدرة الخوارزمية على توليد مساحة بحث أكبر للحلول، أي توليد مزيد من الحلول مع كل تكرار لتنفيذ الخوارزمية وبناءً عليه تكون القدرة الاستكشافية الأكبر للخوارزمية تجعلها أكثر كفاءة للعمل مع المشاكل التي تتطلب حلولاً عالمية (Global Solutions) واسعة النطاق.

* الاستغلال (Exploitation): يمثل الاستغلال قدرة الخوارزمية على التقاط الحلول الأفضل ضمن مساحة البحث المستكشفة، أي قدرة الخوارزمية على تجنب الوقوع في مشاكل الحلول المحلية وبناءً عليه تكون القدرة الاستغلالية العالية للخوارزمية أكثر كفاءة للعمل مع المشاكل التي تتطلب حلولاً محلية (Local Solutions) أو حلولاً عالمية (Global Solutions) صغيرة النطاق.

إن فهم طبيعة المشكلة وتعقيدها يعد أساساً لضبط المشغلات والمتغيرات العشوائية والتوابع الحسابية لخوارزمية الاستدلال العليا (الميتاهورستية) للحصول على أفضل الحلول، إذ تضبط طبيعة المشكلة ومتطلباتها محددات الخوارزمية أو نوعها لتكون مناسبة للمشكلة من ناحية قدرتها الاستكشافية والاستغلالية. وكون هذه الخوارزميات الذكية أقرب لأن تكون استدلالية فهي بحاجة لتوابع حسابية أساسية تحدد لها طريقة عملها وطريقة استكشافها للحلول واستغلالها وفي هذا الصدد ليس هناك أفضل من البيئة لنستنبط منها أساليب بحث عن حلول واصطيادها لذا نلاحظ أن أغلب خوارزميات الاستدلال العليا تستنبط مبادئ عملها من الطبيعة وتسمى باسم ما استنبطت منه. يتم تحديد توابعها الحسابية وتوابع مشغلاتها بناءً على سلوكيات مستوحاة من الطبيعة ترسم لها طريقة عملها في كل من مرحلتي الاستكشاف والاستغلال.

١-٣-٢- خوارزميات الاستدلال العليا التي تمت دراستها ضمن هذا البحث:

تم انتقاء ثلاث من أحدث وأكثر الخوارزميات الاستدلالية العليا استخداماً ضمن بيئة السحابة لحل مشكلة الجدولة وهم (SSA Salp Swarm Algorithm, PSO Particle Swarm Optimization, HHO Harris Hawks Optimization) وعلى اعتبار أن هذه التقنيات تتشابه بطبيعة عملها التكرارية والمعتمدة على التوابع الحسابية والمعادلات الرياضية التي تساعد باكتشاف مساحة حلول أكبر مع المحافظة على الحل الأمثل المكتشف في آخر تكرار فستعمق في دراسة طبيعة عمل واحدة من هذه الخوارزميات الثلاث وهي (HHO).

- يشرح الباحثون في [10] طريقة عمل تقنية طيور هاريس التحسينية (Harris Hawks Optimization) التكرارية ويوضحون مراحل عملها واستراتيجياتها المتعددة في الاستكشاف والاستغلال المتمثلة بمشغلات هذه الخوارزمية ومعادلاتها الرياضية، فهي تستوحي طبيعة عملها من السلوك التعاوني لطيور الهاريس في اصطياد فريستها، فالطيور هنا تمثل حلول محتملة للمشكلة وتتشارك هذه الطيور المعلومات مع جيرانها لتحديد بعدها عن الفريسة التي تمثل الحل الأفضل في مساحة البحث وفي كل تكرار وبناءً على بعد الطيور عن الفريسة، أي بعد الحلول المرشحة عن أفضل حل مكتشف أو قيمة محددة مسبقاً للخوارزمية يتم تحديد طبيعة الحركة لهذه الطيور وتغيير مواقعها في التكرار التالي بناءً على استراتيجيتين:

١- حصار ناعم (Soft besiege): أي تغيير الطيور مواقعها من أجل الاقتراب من الفريسة بشكل أكبر وزيادة مساحة البحث وذلك عند تحقق شرط أن تكون طاقة الفريسة التي تمثل الحل الأمثل ($E < 1$) أي لا تزال بعيدة نسبياً وقيمة المتغير العشوائي ($r \geq 0.5$) إذ يحدد هذا المتغير المرحلة التي سيتم تنفيذها بالخوارزمية (استغلال أو استكشاف) وذلك بناءً على قيمته التي يتم ضبطها بدايةً ضمن مرحلة تهيئة الخوارزمية وتغيير خلال التكرارات ضمن المجال $[0,1]$ ، ستقوم الطيور التي تمثل حلول محتملة في كل تكرار بتغيير مواقعها وفقاً للمعادلة الرياضية التالية:

$$intra_{sum} = \sum_{j=1}^K \|X_{pj} - P_j\|$$

حيث من خلال هذه المعادلة الرياضية يتم تحديث موقع كل طائر أي كل حل مكتشف من خلال طرح بعد مركز تجمع (Cluster) الحلول المكتشفة إلى هذا التكرار وهو (P_j) من موقع الطائر القديم (X_{pj}) وجمع هذه الفروقات ضمن المتحول ($intra_{sum}$) الذي تستخدمه معادلات رياضية أخرى لحساب طاقة الفريسة في التكرار القادم.

٢- حصار قوي (Hard besiege): أي تحاول بعض الطيور القريبة الإجهاز على الفريسة (تنتقل لموقع الفريسة التي تمثل الحل الأفضل) وبعضها الآخر يغير مواقعها لزيادة مساحة البحث وذلك عند تحقق شرط أن تكون طاقة الفريسة التي تمثل الحل الأمثل ($E < 0.5$) أي الفريسة قريبة نسبياً من موقع أفضل حل مكتشف وقيمة المتغير العشوائي ($r \geq 0.5$) وذلك وفقاً للمعادلة الرياضية التالية:

$$X(t+1) = \begin{cases} X_{rand}(t) - r_1|X_{rand}(t) - 2r_2| & q \geq 0.5 \\ (X_{rabbit}(t)) - r_3(LB + r_4(UB - LB)) & q < 0.5 \end{cases}$$

إذ يمثل الشعاع (X_{t+1}) موقع الصقور الجديد للتكرار التالي والذي يتم تحديثه وفق إحدى المعادلتين بناءً على قيمة (q) التي تمثل متغير عشوائي ثانوي تضبط قيمته خلال مرحلة تهيئة الخوارزمية بقيمة ضمن $[0,1]$ إذ يستخدم هذا المتغير لاختيار الآلية الداخلية للخوارزمية في كل مرحلة ففي حال كانت ($q \geq 0.5$) يتم تغيير موقع الحلول المحتملة الحالية بالاعتماد على شعاع الموقع السابق للطائر ($X_{rand}(t)$) والمتغيرين العشوائيين (r_1, r_2)، أما في حال كانت قيمة ($q < 0.5$) بالتالي يتم الحصول على شعاع موقع الطائر الأقرب للفريسة للتكرار القادم من خلال قيمة الموقع الحالي للطائر الأقرب للفريسة ($X_{rabbit}(t)$) وقيم الحدود الدنيا والعليا لعوامل المشكلة (LB, UB) بالإضافة للمتغيرين العشوائيين (r_3, r_4).

ومن خلال هاتين الاستراتيجيتين تحقق تقنية طيور هاريس التحسينية (HHO) قدرة متوازنة بين الاستكشاف والاستغلال وتنتقل في مراحل عملها بناءً على قيم المتغيرات العشوائية التي تضبط بها خلال مرحلة تهيئة الخوارزمية بحسب طبيعة وتعقيد المشكلة التي تعمل على حلها.

يوضح الشكل (١-١) التالي الشيفرة المزيفة الخاصة بالخوارزمية (HHO).

Algorithm 1 Pseudo-code of HHO algorithm

Inputs: The population size N and maximum number of iterations T

Outputs: The location of rabbit and its fitness value

Initialize the random population $X_i (i = 1, 2, \dots, N)$

while (stopping condition is not met) **do**

 Calculate the fitness values of hawks

 Set X_{rabbit} as the location of rabbit (best location)

for (each hawk (X_i)) **do**

 Update the initial energy E_0 and jump strength J

$\triangleright E_0 = 2 \cdot \text{rand}() - 1, J = 2(1 - \text{rand}())$

 Update the E using Eq. (3)

if ($|E| \geq 1$) **then**

\triangleright Exploration phase

 Update the location vector using Eq. (1)

if ($|E| < 1$) **then**

\triangleright Exploitation phase

if ($r \geq 0.5$ and $|E| \geq 0.5$) **then**

\triangleright Soft besiege

 Update the location vector using Eq. (4)

else if ($r \geq 0.5$ and $|E| < 0.5$) **then**

\triangleright Hard besiege

 Update the location vector using Eq. (6)

else if ($r < 0.5$ and $|E| \geq 0.5$) **then**

\triangleright Soft besiege with progressive rapid dives

 Update the location vector using Eq. (10)

else if ($r < 0.5$ and $|E| < 0.5$) **then**


\triangleright Hard besiege with progressive rapid dives

 Update the location vector using Eq. (11)

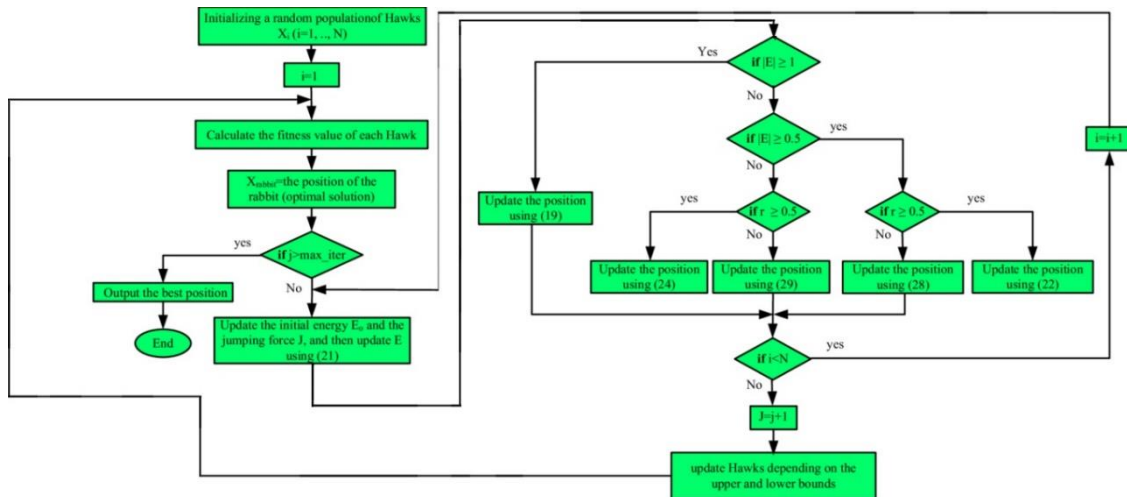
Return X_{rabbit}

الشكل (١-١): الشيفرة المزيفة خوارزمية (HHO)

وكما يوضح الشكل (١-٢) الشروط التي تتعلق بالمتغيرات العشوائية (E, r, q) التي من خلال قيمها ستحدد الخوارزمية المرحلة التي ستعمل بها والآلية المناسبة التي ستستخدمها في كل مرحلة من المراحل بناءً على القيم التي ستأخذها المتغيرات السابقة في كل تكرار من تكرارات الخوارزمية. في حين يوضح الشكل (١-٣) الآتي المخطط التدفقي لخوارزمية طيور هاريس التحسينية.



الشكل (١-٢): مراحل العمل المختلفة التي تمر بها خوارزمية (HHO)



الشكل (١-٣): المخطط التدفقي لخوارزمية (HHO)

- يصف الباحثون في [11] خوارزمية (SSA Salp Swarm Algorithm) على أنها تقنية استدلالية لحل المشاكل ذات التعقيد ($NP-hard$) وطريقة عمل هذه الخوارزمية التحسينية متشابهة مع طريقة عمل الخوارزمية السابقة من حيث التكرارية وتحسين الحلول إلا أنها تستوحي أسلوب عملها من سلوك الاحتشاد لأسراب الملاحات

(Salps) إذ تتحرك في البحر بأسلوب متتابع على شكل سلسلة من الأتباع (Followers) التابعين لقائد (Leader) لهم، وتم استخدام هذه التقنية في كثير من مشاكل التحسين ومشكلة جدولة المهام في الشبكة واحدة منها وأبدت نتائج هذه التقنية تحسناً كبيراً في حل مشكلة الجدولة ضمن بيئة السحابة، إذ حققت كفاءة زمنية مع توفير لاستهلاك الطاقة والموارد الحسابية. إذ تتمتع هذه التقنية بفعالية ضعيفة نسبياً من ناحية الاستكشاف وفعالية عالية من حيث الاستغلال لمساحة البحث مما يقلل من احتمالية تقديمها لحلول منشارية أو عكسية التحسن وذلك بناءً على محاكاة سلوك أسراب الملاحات (Salps).

- يوضح لنا الباحثون في [12] أن الخوارزميات الميتاهورستية تتشابه في طبيعتها التكرارية وخطوات عملها الأساسية في حين تختلف فيما بينها بسلوك مشغلاتها ومبدأ عمل هذه المشغلات الذي يختلف شكل استيحائه من تقنية لأخرى، فمبدأ عمل مشغلات (Operators) خوارزمية سرب الجسيمات التحسينية (Particle Swarm Optimization) مستوحى من الحركة العشوائية للجسيمات في فضاء متعدد الأبعاد. إذ أن طبيعة هذه الحركة العشوائية للجسيمات بسرعات مختلفة تمثل مبدأ العمل الأساس لهذه التقنية، مما يكسبها قدرة عالية جداً على اكتشاف مساحة الحل واستغلالها فكل جسيم في هذه التقنية بموقعه العشوائي بدايةً يمثل لنا حلاً مقترحاً ومن خلال التنفيذ التكراري لهذه الخوارزمية ستجتمع هذه الجسيمات حول موقع موحد يمثل الحل الأفضل في مساحة البحث المكتشفة بناءً على تقييم قيمة صلاحية (Fitness Value) هذا الموقع عبر تابع التطوير (Fitness Function) الخاص بهذه التقنية.

١-٣-٣- لماذا تستخدم هذه الخوارزميات للجدولة في بيئة السحابة:

تقدم لنا بيئة السحابة المرنة والميزات التي تنشأ من طبيعة هذه البيئة المتغيرة وذات التعقيد الكبير الذي يتطلب استراتيجيات وآليات عمل مختلفة للخوارزميات التي سيتم استخدامها ضمن هذه البيئة، ذلك يجعل من الخوارزميات التقليدية والمستعملة في البيئات الأخرى لحل المشاكل ذاتها ذات قدرات محدودة ولا تتماشى مع بيئة الحوسبة السحابية لذا الخوارزميات الذكية والمتكيفة هي الأكثر ملائمة لبيئة الحوسبة والأكثر اهتماماً في الأوساط الأكاديمية من حيث الدراسة والتطوير انطلاقاً من الأسباب الآتية أيضاً:

- ١- إن الطبيعة الديناميكية لهذه الخوارزميات تجعلها قادرة على التكيف مع بيئة السحابة المتغيرة بمرور الوقت فالطبيعة الديناميكية لبيئة السحابة تتطلب خوارزميات ديناميكية أيضاً لإيجاد حلول لمشاكلها ذات التعقيد العالي.
- ٢- إن طبيعة عمل هذه التقنيات تسمح بانتقاء قيمة تابع التطوير (Fitness Function) بناءً على متطلبات المشكلة بالتالي يمكن التحكم في هدف هذه الخوارزميات بحسب المشكلة إذ يمكن ضبط توابعها الحسابية لتقوم بالوظيفة المطلوبة ضمن الشبكة وبشكل قابل للتغير.
- ٣- في يومنا هذا تُعد هذه الخوارزميات الميتاهورستية أكثر التقنيات اعتماداً وأحدثها لجدولة المهام ضمن بيئات الحوسبة السحابية حيث يتم اللجوء لها لحل كثير من المشاكل في الشبكات المبنية في بيئة السحابة.

٢- النتائج والمناقشة:

٢-١- تهيئة وتوصيف بيئة العمل:

اختيرت الشبكة التي تم تنفيذ التجارب العملية عليها بحيث تكون خدمية تتبع لقطاع النقل وذات صلة بالدراسة التي يتناولها البحث من حيث المكونات والتقنيات التي تعمل بها والبيئة المبنية ضمنها فالشبكة المدروسة تمثل شبكة انترنت أشياء تعتمد على السحابة ووظيفتها مراقبة الازدحام وتنظيم السير ضمن أوتوستراد مركز مدينة يعاني من اختناق السير على مدار اليوم. ستحقق نظام مؤتمت ومتكامل يرسل الإشعارات والمعلومات للسائقين والسيارات الذكية ومراكز المرور وذلك من خلال شبكة واسعة من الحساسات ذات الحركية المحدودة والموزعة على الأجزاء الأربعة الرئيسية من هذا الأوتوستراد، إذ تقوم هذه الحساسات بمهام الشبكة من حيث المراقبة والقياس وإرسال الإشعارات والمعلومات وتبادلها فيما بينها بشكل دوري ومتواصل ولكي تُتم هذه الشبكة مهامها فهي تتألف من المكونات الشبكية الآتية:

- الحساسات (Sensors): تحوي الشبكة المدروسة (١٠٠) حساس موزعين ضمن أربع أجزاء رئيسية من شارع المدينة الرئيسي وتتصل هذه الحساسات في كل جزء من الشبكة فيما بينها بتقنية البلوتوث الموفرة للطاقة (BLE)، وتتبادل فيما بينها بأبعاد مختلفة وتعمل جميع هذه الحساسات على البطاريات ذات جهد (٣,٧ فولت).

- عقد التغطية (Convergent node): وهي عبارة عن أربع عقد ذات قدرات حسابية متقدمة ومتصلة فيما بينها بتقنية البلوتوث الموفرة للطاقة (BLE) إذ يوجد واحدة منها في كل جزء من أجزاء الشبكة وستقوم هذه العقد بتحقيق الاتصال بين مجموعة الحساسات في كل جزء من الشبكة.

- البوابات (Gateway): تتضمن هذه الشبكة بوابتين (Gateway) تحققان الاتصال بين حساسات الشبكة ومركز بيانات السحابة من خلال اتصالها بعقد التغطية الأربع عبر تقنية المدى الطويل الموفرة للطاقة (Lo-Ra)، واتصالها بمركز البيانات من خلال تقنية الجيل الخامس (5G) مما يضمن تخفيف الحمل عن مركز البيانات وتنظيم عمله من خلال فلترة وتوجيه البيانات التي سيرسلها ويستقبلها مع باقي أجزاء الشبكة.

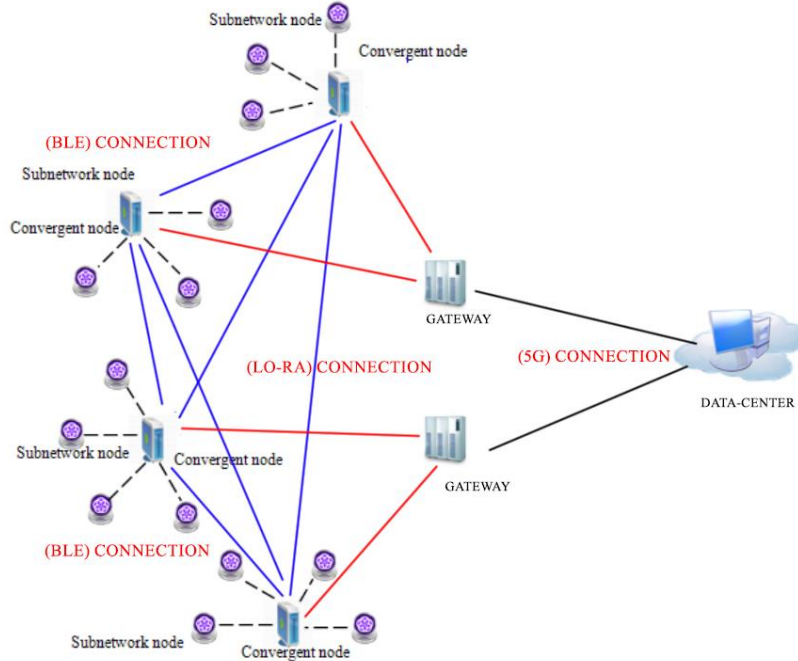
- مركز بيانات (Data-Center): تتضمن هذه الشبكة مركز بيانات (Data-Center) واحد وهو المكون الذي سيقوم بإدارة ومعالجة بيانات هذه الشبكة التي يتلقاها من الطرف الآخر في الشبكة وهو ضروري الوجود نتيجة لتعقيد الوظائف التي ستقوم بها هذه الشبكة والتي يصعب على العقد الطرفية القيام بها وكما سيكون مسؤول عن جدولة وإدارة المهام والوظائف التي ستقوم بها الشبكة.

- مهام الشبكة (Network Tasks): في كل سيناريو من المحاكاة سيتم بناءه مع (٢٠٠٠) مهمة موزعة على حساسات الشبكة وتشمل هذه المهام إرسال هذه الحساسات للإشعارات لحساسات أخرى أو مركبات ذكية أو مراكز الإدارة المرورية (Communication) وكما أن هذه المهام ممكن أن تكون مهام لجمع المعلومات من البيئة المحيطة (Data collection) أو معالجة جزئية لبعض البيانات (Data processing) وكما تتصف هذه المهام ضمن الشبكة بكونها:

○ مستقلة: نظراً لطبيعة الشبكة ووظيفتها فالمهام ضمنها غير مترابطة حسابياً أو زمنياً لذا لا يعتمد تنفيذ أحدها على أخرى.

○ غير استباقية: كون الشبكة هي شبكة لتحسين حركة السير ومراقبتها فإن جميع المهام ضمن الشبكة ذات أولوية واحدة وغير محددة بقيود زمنية.

ترتبط جودة عمل هذه الشبكة ارتباطاً وثيقاً بعمرها الافتراضي، أي الوقت الذي سيمر على هذه الشبكة وأجهزتها دون الحاجة للصيانة أو الاستبدال وذلك لكونها تعتمد في عملها على تجهيزات وعقد طرفية تعمل على البطارية لذا مقياس الطاقة في هذه الشبكة هو مقياس هام وحاسم ويعتبر أولوية قصوى بالنسبة لهذه الشبكة. يوضح الشكل (٢-١) طبولوجيا الشبكة التي تم توصيفها.



الشكل (٢-١): طبولوجيا الشبكة المدروسة

ستتم محاكاة الشبكة السابقة من خلال برنامج ماتلاب (MATLAB R2022a) وذلك بالاعتماد على تطوير إطار عمل (Framework) [8] يمثل هذه الشبكة بأجزائها بالإضافة للاستعانة بصناديق الأدوات والمكاتب الموجودة ضمن ماتلاب والتي تتضمن تحقيق التقنيات التي تعتمد عليها هذه الشبكة ضمن تجهيزاتها. ومن ثمّ ستتم جدولة المهام ضمن ملف إطار عمل هذه الشبكة عبر الخوارزميات الميتاهورستية الثلاث (SSA, PSO, HHO) من خلال الأكواد البرمجية المكتوبة بلغة (MATLAB) والتي تمثل برمجة هذه الخوارزميات لتكون مسؤولة عن جدولة المهام ضمن الشبكة التي تتم محاكاتها.

٢-٢- المحور الأول: تقييم الأداء لخوارزميات (SSA, PSO, HHO) من حيث كفاءة الطاقة ضمن

الشبكة المدروسة:

تتطلب طبيعة الشبكة التي تمت دراستها وبناء محاكاتها والوظائف التي تقوم بها هذه الشبكة تقنيات توفر الطاقة في هذه الشبكة مما يطيل عمرها الافتراضي وعمر بطاريات الحساسات التي تتضمنها هذه الشبكة، وجدولة مهام الشبكة على الحساسات سيشكل فارق كبير في استهلاك الطاقة ضمن هذه الشبكة فإسناد المهمة على الحساس المناسب من حيث قرينه لمركز البيانات ومن حيث انشغالية الحساس ووضعيتها عمله (استيقاظ-نوم-عميق-استماع) وقرينه من الوظيفة التي سينفذها عبر هذه المهمة سيكون له دور حاسم في كمية الطاقة التي سيتم استهلاكها في الشبكة من تنفيذ المهمة المطلوبة.

يوضح الجدول الآتي بارامترات البيئة السحابية التي بنيت الشبكة ضمنها وسيتم اعتمادها في سيناريوهات المحاكاة:

الجدول (٢-١): بارامترات البيئة السحابية.

Cloud Entity	Parameter	Value
Data centre	Number of Data centre	1
Gateways	Number of Gateways	2
Connectivity	Technology	5G
	NR Operating Band	n78
	Downlink/Uplink	3.5GHz
	Bandwidth	100MHz
	Sub-Carrier Spacing	30KHz
	Throughput	up-to 1.7Gb/s

بينما يوضح الجدول الآتي بعض بارامترات الشبكة من طرف الحساسات:

الجدول (٢-٢): بارامترات شبكة (IOT) الحساسات ضمن بيئة المحاكاة

IOT Network	Parameter	Value
Sensors	Number of Sensors	100
	Number of sensors in Cell	25
	Radius of Cell	1.15Km
	Distance between Sensors	50-100m
	Transmit Sensor power	12dBm(decibel milliwatts)
Connectivity	Mobility	Limited
	Technology	BLE
	Bandwidth	2.4GHz
	Throughput	up-to 1.9Mb/s
	Max-Range	100m
Convergent node	Number of nodes	4
	Distance between nodes	1-3.75Km
	Transmit node power	27dBm≈500mW
Connectivity	Technology	Lo-RA
	Bandwidth	2.4GHz
	Throughput	up-to 0.25Mb/s
	Max-Range	4.75Km

٢-٢-١- تقييم أداء خوارزميات (SSA, PSO, HHO) من حيث استهلاك الطاقة ضمن العقدة:

يُحسب استهلاك الطاقة ضمن هذا السيناريو من المحاكاة فقط ضمن عقد الحساسات في الشبكة التي تعمل على البطاريات، كونها المكونات الأكثر محدوية للطاقة ضمن الشبكة وسيتم ذلك بناءً على حلول الجدولة التي تولدها الخوارزميات الثلاث في كل تكرار لها والتي سيتم تنفيذها ضمن مركز بيانات سحابي. في هذا السيناريو، يلعب موقع الحساس وبعده عن مركز البيانات السحابي المسؤول عن جدولة المهام دوراً حاسماً في استهلاكه للطاقة والمهام المختلفة النوع والحجم التي سترسل سيتم تنفيذها في الحساسات بناءً على إسناد الخوارزميات المهام على الحساسات الموزعة في الأجزاء الأربعة من الشبكة ونهايةً سيشكل تحسين استهلاك

الطاقة في هذا السيناريو إطالة من عمر بطاريات الحساسات دون الحاجة لاستبدالها مما سينشئ عنه شبكة أكثر استقراراً وموثوقية.

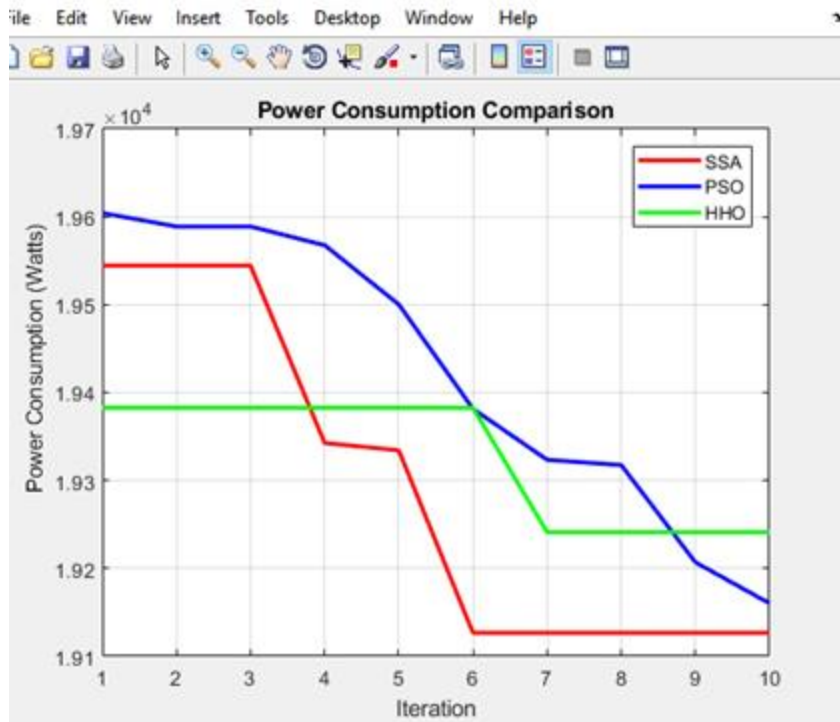
يتضمن الجدول الآتي بعض محددات المحاكاة ضمن هذا السيناريو:

الجدول (٢-٣): بارامترات المهام (Tasks) والخوارزميات (SSA, PSO, HHO) ضمن المحاكاة.

Object	Parameter	Value
Tasks	Number of tasks	٢٠٠٠
	Type of tasks	(data collection, data processing, data processing)
	Size of tasks	10-1400KB
(SSA, PSO, HHO)	Iterations	10/50
	Number of slaps	50
	Acceleration coefficient	1
	Time of simulation	72sec
	Fitness function	Power consumption in sensors

العامل الأهم لضبط المحاكاة هو تابع تطوير (Fitness Function) الخوارزميات الميتاهورستية الذي سيتم تنفيذه بالاعتماد على قيمة الطاقة المصروفة ضمن الحساسات بناءً على تنفيذ كل منها للمهام التي ستسند إليه، لذا ستسجل المحاكاة فقط مقدار الطاقة المصروفة في الحساس وسيلعب كل من بعد الحساس عن موقع المهمة التي سينفذها وبعده عن موقع عقدة التغطية (Convergent node) التي سترسل له المهمة لتنفيذها دوراً حاسماً في الطاقة المصروفة ضمن الحساس. وبناءً على قيم صلاحية الحل (Fitness value) التي سيتم تسجيلها في حلقات تكرار سيتم تحسين الحلول وتشغيل الخوارزميات الثلاث بالاعتماد على هذه القيم في كل تكرار من تكرارات تنفيذ الخوارزميات والتي سيتم تحديدها ضمن المحاكاة بعشر (١٠) تكرارات في الحالة الأولى وخمسين (٥٠) تكرار في الحالة الثانية وذلك من أجل الوصول لنتائج أكثر دقة وتنوع فمن المهم تقييم أداء هذه الخوارزميات في حالات التكرار القليلة وحالات تكرارها الكبيرة لتحديد الخوارزمية الأكثر ملاءمة والتي تقدم أفضل حلول بعدد تكرارات معين بناءً على طبيعة المشكلة وقيود الموارد المفروضة.

يظهر الشكل (٢-٢) نتائج المحاكاة من حيث استهلاك الطاقة ضمن حساسات الشبكة وذلك خلال عشر تكرارات من تنفيذ الخوارزميات.



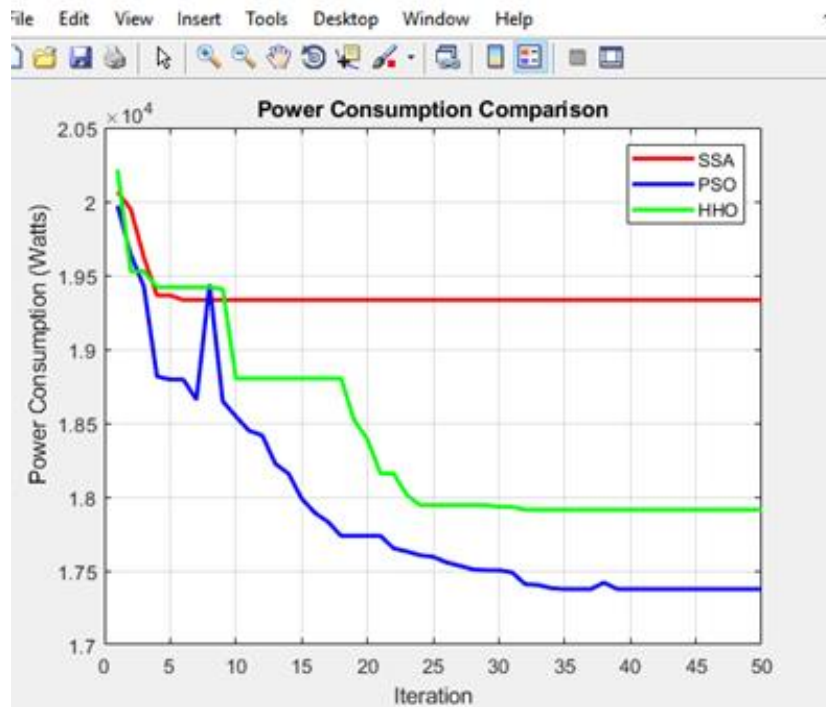
الشكل (٢-٢): نتائج محاكاة السيناريو الأول من حيث استهلاك الطاقة مع عشر تكرارات

تبين لنا نتائج المحاكاة قدرة كل خوارزمية على تحسين وإيجاد الحلول المبنية على تقليل استهلاك الطاقة في كل تكرار لها ونلاحظ من هذه النتائج ما يتوافق مع الدراسة التحليلية للخوارزميات الثلاث (SSA, PSO, HHO).

حيث قدرة خوارزمية (SSA) العالية على الاستغلال تتضح في سرعتها بالوصول لحلول تحسينية خلال مرات أقل من التكرار مقارنة بخوارزميتي (PSO, HHO) وذلك يرتبط أيضاً بطبيعة ومحددات مشكلة استهلاك الطاقة في هذا السيناريو حيث نجد أن نتائج خوارزمية (PSO) ذات القدرة العالية في مرحلة الاستكشاف على الرغم من كونها أكثر استهلاكاً للطاقة لكنها لا تعاني من مشاكل الحلول الأفضل محلياً بل تقدم حلول تتحسن بشكل تدريجي في كل تكرار. أما نتائج خوارزمية (HHO) فنتيجة لطبيعة عملها وسلوكها الأكثر تعقيداً وأكثر حاجة للتدريب فهي تتطلب تكرارات أكثر لينسجم سلوكها مع مشكلة الطاقة ضمن هذا السيناريو إذ تعاني من مشاكل الحلول الأفضل المحلية في التكرارات الأولى، لكنها تقدم حلولاً تحسينية جيدة خلال التكرارات الأولى من المحاكاة.

يظهر الشكل (٢-٣) نتائج المحاكاة من حيث استهلاك الطاقة ضمن حساسات الشبكة وذلك خلال خمسين تكراراً من تنفيذ الخوارزميات الثلاث.

إذ يتضح من خلال هذه النتائج المفارقات التي ستمر بها الخوارزميات الثلاث مع ازدياد عدد التكرارات، فقدرة خوارزمية (SSA) العالية في الاستغلال ضمن مشكلة استهلاك الطاقة ستجعل من نتائجها تتوقف عن التحسن بعد عدد تكرارات محدد ولكنها ستصل لمستوى أقل من استهلاك الطاقة بعدد تكرار أقل من قرينتيها (PSO, HHO)،



الشكل (٣-٢): نتائج محاكاة السيناريو الأول من حيث استهلاك الطاقة مع خمسين تكرار

في حين طبيعة عمل خوارزمية (PSO) ذات القدرة الاستكشافية العالية ستجعل من نتائجها مستمرة التحسن مع ازدياد عدد مرات تكرار تنفيذ الخوارزمية لكن سيكون ذلك على حساب الوقت المخصص لتنفيذ تكرارات الخوارزمية ضمن الشبكة كما أنه نتيجة لوجود معامل سرعة الانتقال بين الحلول خلال التكرارات ستقدم الخوارزمية بعض النتائج المنشارية والعكسية التحسن في بعض التكرارات نتيجة للفرق الكبير بين قيمة الصلاحية (Fitness Value) لهذه التكرارات والتكرارات السابقة لها.

أما بالنسبة لخوارزمية (HHO) فإن سلوك عملها القائم على عدة مراحل وعدة استراتيجيات حصار للحل الأفضل يجعلها تستمر بتقديم حلول أفضل، لكنها ستمر أيضاً بمشاكل حلول أفضلية محلية مما يسبب حملاً زمنياً وحسابياً زائداً ضمن الشبكة.

٢-٢-٢- المحور الثاني: تقييم أداء الخوارزميات (SSA, PSO, HHO) من حيث عمر الشبكة

الافتراضي:

يرتبط مقياس استهلاك الطاقة ضمن الشبكة بمفهوم العمر الافتراضي للشبكة فمقدار استهلاك الطاقة ضمن أجهزة الشبكة يتناسب عكساً مع العمر الافتراضي للشبكة الذي يمكن وصفه بأنه الوقت الذي تستغرقه الشبكة بالعمل بالشكل المثالي قبل أن يخرج أحد أجهزتها عن الخدمة (تصبح الشبكة غير قادرة على القيام بوظائفها بالشكل المطلوب). نعتبر عن عمر الشبكة الافتراضي ضمن شبكتنا المدروسة والمحاكاة التي ننفذها وللوصول لنتائج مرتبطة بأداء الخوارزميات التي نعمل على دراستها بأنه يمثل عدد مرات التكرار التي تقوم بها كل من الخوارزميات الثلاث (SSA, PSO, HHO) أثناء جدولتها للمهام قبل أن تصل طاقة أي حساس بالشبكة لـ ٢٠% من طاقة البطارية التي يعمل عليها لذا فإن الزمن الذي تستغرقه الشبكة لوصول طاقة أول حساس ضمن الشبكة لـ ٢٠% يمثل العمر الافتراضي للشبكة ضمن المحاكاة وسيتم تحديد ذلك من خلال حساب رقم التكرار الذي يصل به أول حساس إلى ٢٠%. للقيام بذلك نعيد تشغيل المحاكاة وفي كل تكرار منذ البداية سترسل المهام

للحساسات وسيتم تسجيل النسب المئوية لطاقة كل حساس بعد تنفيذه للمهام المسندة إليه من كل خوارزمية في كل تكرار، إذ سيتم تهيئة كل حساس بطاقة (١٠٠٠ جول وهو ما يعادل 75mAh) تشكل ١٠٠% من نسبة طاقة البطارية الخاصة بكل حساس وفي كل تكرار للخوارزميات الثلاث سيعاد تسجيل الطاقة المتبقية في بطارية كل حساس.

لن يتم تغيير جسم تابع التطوير (Fitness Function) العام للخوارزميات الثلاث عن شكله في السيناريو السابق، إنما سنضيف فقط توابع مساعدة من أجل حساب وتسجيل النسب المئوية من طاقة بطارية كل حساس الناتجة عن تنفيذه المهام في كل تكرار.

```

% Helper functions for power calculations
function power = calculateDataCollectionPower(taskPosition, sensorPosition, dataSize)
    blePower = calculateBLEPower(norm(taskPosition - sensorPosition), dataSize);
    power = blePower;
end

function power = calculateDataProcessingPower(dataSize)
    processingPower = 0.02; % in watts
    power = processingPower * dataSize / 1000;
end

function power = calculateCommunicationPower(taskPosition, sensorPosition, gatewayPositions, datacenterPosition, dataSize)
    distancesToGateways = vecnorm(gatewayPositions - sensorPosition, 2, 2);
    [minDistance, closestGatewayIndex] = min(distancesToGateways);
    loraPower = calculateLoRaPower(minDistance, dataSize);
    distanceToDatacenter = norm(datacenterPosition - gatewayPositions(closestGatewayIndex, :));
    g5Power = calculate5GPower(distanceToDatacenter, dataSize);
    power = loraPower + g5Power;
end

function power = calculateBLEPower(distance, dataSize)
    basePower = 0.01; % in watts
    power = basePower * distance * dataSize / 1000;
end

function power = calculateLoRaPower(distance, dataSize)
    basePower = 0.05; % in watts
    power = basePower * distance * dataSize / 1000;
end

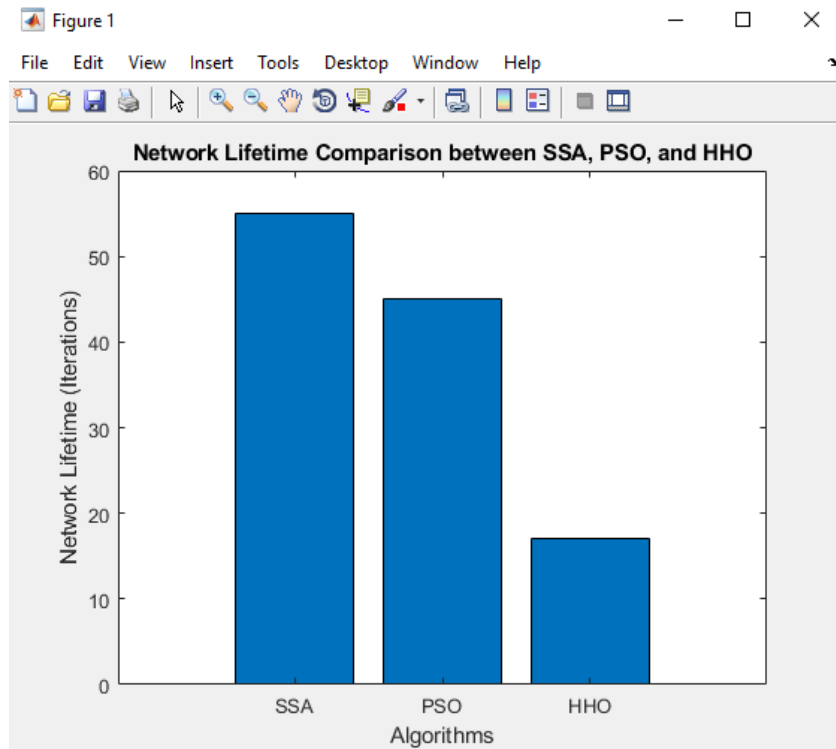
function power = calculate5GPower(distance, dataSize)
    basePower = 0.1; % in watts
    power = basePower * distance * dataSize / 1000;
end

```

الشكل (٤-٢): التوابع المساعدة لتابع تطوير الخوارزميات في سيناريو المحاكاة الثاني

من خلال نتائج هذه التوابع سيتم تسجيل النسب المئوية لبطاريات الحساسات في كل تكرار ومع تسجيل المحاكاة لأول حساس تصل نسبة طاقة بطاريته لـ ٢٠% سيتم عرض رقم التكرار الذي وصلت به طاقته لهذه النسبة.

يوضح الشكل (٣-٣) نتائج المحاكاة للسيناريو الثاني من حيث عمر الشبكة الافتراضي بالنسبة للخوارزميات (SSA, PSO, HHO).



الشكل (٥-٢): نتائج محاكاة السيناريو الثاني من حيث عمر الشبكة الافتراضي

يتضح لنا من نتائج تنفيذ المحاكاة أنه تم تسجيل وصول أول حساس لطاقة ٢٠% من بطاريته في التكرار (٥٧) من أجل خوارزمية (SSA) والتكرار (45) من أجل خوارزمية (PSO) والتكرار رقم (١٧) من أجل خوارزمية (HHO). تُعد النتائج السابقة مرتبطة بنتائج استهلاك الطاقة للخوارزميات الثلاث في السيناريو الثاني، إذ أن تكرار الحلول أي وصول الخوارزمية للحل الذي تجده الأفضل لها مبكراً سيسمح للحساس بتنفيذ المهام المتكررة بطاقة أقل، لذا فإن خوارزمية (SSA) التي تصل لحل أفضل ضمن مساحة بحثها المكتشفة سريعاً سيجعل منها الخوارزمية الأكثر كفاءة لمقياس العمر الافتراضي في الشبكة، في حين خوارزمية (PSO) التي تحتاج لتكرارات أكثر لتصل للحل الأفضل ضمن مساحة بحثها سيكون عدد التكرارات التي تنفذ الحساسات جداول توجيهها أقل، فهي تنفذ مهام جديدة وغير متشابهة في كل تكرار تالي لها ليصل أول حساس لطاقة ٢٠% من طاقة بطاريته عند التكرار (٤٥) من تكرارات الخوارزمية، أما خوارزمية (HHO) التي قدمت أفضل نتائج من حيث مجمل استهلاك الطاقة واستمرت بتحسين حلولها لتكرارات متقدمة في سيناريو استهلاك الطاقة، سيؤدي هذا التحسن واختلاف المهام المسندة لكل حساس في كل تكرار تالي إلى وصول أول حساس لطاقة ٢٠% في التكرار (١٧). هذه النتائج المتعلقة بالعمر الافتراضي للشبكة ضمن هذا السيناريو ستكون ذات قيمة وأهمية للشبكة المدروسة فبناءً على ما سيتم فرضه من قيود ومحددات ومميزات لهذه الشبكة سنختار الخوارزمية الأكثر ملائمة لها لجدولة مهامها، ففي حال كانت الشبكة والحساسات التي تحويها تتمتع بقدرة على حصادها للطاقة (طاقة شمسية أو ضوئية أو طاقة حركية) أي إعادة شحن بطارية الحساسات من البيئة المحيطة سيتراجع أهمية مقياس العمر الافتراضي الذي دُرُس ضمن هذا السيناريو مقارنة بمجمل استهلاك الطاقة في الحساسات، أما في حال عدم تجهيز الشبكة بميزة حصاد الطاقة سيكون لهذا المقياس دور هام وفعال ويجب أخذه بالحسبان.

٢-٣- الاستنتاجات والتوصيات:

- خوارزميات الاستدلال العليا خيار مناسب ويوصى به ضمن شبكات انترنت الأشياء المبنية في السحابة وتساهم في تكامل العلاقة بين السحابة وانترنت الأشياء، وذلك يعود لطبيعة عمل هذه الخوارزميات الديناميكية التي تتسجم مع ديناميكية السحابة ويمكن تخصيصها بناءً على طبيعة ومحددات الشبكة التي تعمل هذه التقنيات على تحديدها.

- طبيعة عمل الخوارزمية الميتاهورستية وقوة قدراتها الاستكشافية (Exploration) والاستغلالية (Exploitation) تؤثر على نتائج عمل هذه الخوارزمية، فخوارزمية (PSO) نتيجة لوجود تابع (Velocity) يحدد سرعة انتقالها من حل لآخر يجعلها تبدي نتائج ذات شكل منشاري عند حلها لبعض المشاكل، والخوارزمية (SSA) نتيجة لتفوق قدرتها الاستغلالية بطبيعة عملها على قدرتها الاستكشافية يجعلها تقع بمشاكل الحلول الأفضلية المحلية عند حلها لبعض المشاكل.

- من خلال استخدام الخوارزميات (SSA, PSO, HHO) لحل مشكلة جدولة المهام ضمن الشبكة بما يقلل من استهلاك الطاقة ضمن الأجهزة الطرفية للشبكة نستنتج أن الخوارزمية (SSA) تقدم لنا أفضل أداء بأقل عدد ممكن من التكرارات والخوارزمية (PSO) توصلنا لأفضل النتائج مع تزايد عدد مرات تكرار تشغيل الخوارزميات الثلاث.

- يعتبر العمر الافتراضي للشبكة مقياس هام ويرتبط ارتباط وثيق بمقدار الطاقة المستهلكة في الشبكة، وعند استخدام الخوارزميات (SSA, PSO, HHO) لحل مشكلة جدولة مهام الشبكة بما يحسن من عمرها الافتراضي تحقق الخوارزمية (SSA) النتيجة الأفضل مقارنةً بقرينيتها.

٢-٤- الأعمال المستقبلية:

- اتضح لنا من خلال دراسة هذا النوع من خوارزميات الاستدلال العليا إمكانية تشغيل خوارزمية ما من هذه الخوارزميات من خلال مشغلات (Operators) خوارزمية أخرى، الأمر الذي من شأنه أن يفتح أفق تطويرية كبيرة ومتعددة لزيادة قدرات هذه الخوارزميات على حل المشاكل من خلال دمج ميزات مشغلات أكثر من خوارزمية بخوارزمية ميتاهورستية واحدة.

- من الممكن لنا مستقبلاً العمل على برمجة توابع تطوير عمل هذه الخوارزميات بما يحقق تحسين في حل المشاكل على أكثر من مستوى في آنٍ معاً، كضبط عمل توابع تطوير هذه الخوارزميات الميتاهورستية (Fitness Function) بحيث تحل مشكلة الجدولة في شبكات انترنت الأشياء بالنسبة لاستهلاك الطاقة والكفاءة الزمنية والحسابية في نفس الوقت والسيناريو.

References:

- [1] M. F. Tuysuz is with the Department of Computer Engineering, Harran University, Sanliurfa, Turkey, “From Serendipity to Sustainable Green IoT: Technical, Industrial and Political,” Trestian, 2020.
- [2] Cisco, “Cisco Visual Networking Index: Forecast and Trends,” White Paper Feb. 2019, Accessed: March, 18, (2019).
- [3] R. Want, B. N. Schilit, and S. Jenson, “Enabling the internet of things,” *Computer*, vol. 48, no. 1, pp. 28–35, Jan (2015).
- [4] J.-M. Liang, J.-J. Chen, H.-H. Cheng, and Y.-C. Tseng, “An energyefficient sleep scheduling with qos consideration in 3gpp lte-advanced networks for internet of things,” *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, vol. 3, no. 1, pp. 13–22, (2013).
- [5] R. P. Liu, G. J. Sutton, and I. B. Collings, “Wlan power save with offset listen interval for machine-to-machine communications,” *IEEE Transactions on Wireless Communications*, vol. 13, no. 5, pp. 2552– 2562, (2014).
- [6] Md. Shahin Alom Shuvo, Md. Azad Rahaman Munna a, Sujan Sarker, Tamal Adhikary, Md. Abdur Razzaque, Mohammad Mehedi Hassan, Gianluca Aloï, Giancarlo Fortino, “Energy-efficient scheduling of small cells in 5G: A meta-heuristic approach,” Elsevier Ltd (2021).
- [7] S. Abdullah and K. Yang, “An energy efficient message scheduling algorithm considering node failure in iot environment,” *Wireless personal communications*, vol. 79, no. 3, pp. 1815–1835, 2014.
- [8] Mohamed Abd Elaziz, Laith Abualigah, Ibrahim Attiya, “Advanced optimization technique for scheduling IoT tasks in cloud-fog computing environments,” *Future Generation Computer Systems*, 142–154 (2021).
- [9] Arun Kumar Sangaiah, Michael Sheng, Zhiyong Zhang, “Computational intelligence for multimedia big data on the cloud with engineering applications, chapter7,” School of Computing, 2022.
- [10] Laith Abualigah, Mohamed Abd Elaziz, Mohammad Shehab, Osama Ahmad Alomari, Mohammad Alshinwan, Hamzeh Alabool, and Deemah A: “Hybrid Harris Hawks Optimization with Differential Evolution for Data Clustering,” Springer Nature Switzerland (2021).
- [11] Salp Swarm Algorithm: Theory, Literature Review, and Application in Extreme Learning Machines Hossam Faris, Seyedali Mirjalili, Ibrahim Aljarah, Majdi Mafarja and Ali Asghar Heidari, 2020.
- [12] Hybrid Artificial Intelligence Approaches for Predicting Buckling Damage of Steel Columns Under Axial Compression Lu Minh Le 1 , Hai-Bang Ly 2, Binh Thai Pham 2 , Vuong Minh Le 3, Tuan Anh Pham 2 , Duy-Hung Nguyen 2 , Xuan-Tuan Tran 2 and Tien-Thinh Le 4, 2019.