

Intelligent Dynamic Resource Management In The Cloud Radio Access Networks (C-RAN) With Bio-inspired Algorithms

Dr. Hiba Haider *

Ibaa Ali **

(Received 17 / 6 / 2023. Accepted 1 / 8 / 2023)

□ ABSTRACT □

Cloud Radio Access Networks (C-RANs) has been proposed as an effective solution for supporting the fifth generation (5G) requirements by achieving centralized resource management, costs reduction, increasing energy efficiency, spectral efficiency, and cooperative processing by aggregating Baseband Units (BBUs) in a centralized cloud Center. However, the high-density deployment of small cells supporting macro cells increases the resource management difficulty, making it a NP-hard optimization problem that requires suitable algorithms to address the problem nature while ensuring quality of service (QoS). Given the flexibility of Bio-inspired Algorithms and their ability to adapt to traffic demand changes, we study one such algorithm, namely the hybrid SA-PSO algorithm composed of two stages: a dynamic Active Remote Radio Heads (RRHs) selection using the Simulated Annealing (SA) algorithm, and a second stage where the Particle Swarm Optimization (PSO) algorithm forms clusters of RRHs and connects them to cloud BBU pool to ensure load balancing between these units. We take into consideration the dynamic changes in users traffic domain over 24 hours to study the Tidal effects. Simulation results show that the SA-PSO algorithm outperforms the Heuristic Dynamic Switch Off (HDSO) algorithm in Average number of Active RRHs by 13.81% in low traffic periods and 14.36% during peak hours, while maintaining the required QoS.

Keywords: 5G, Cloud Radio Access Network, Resource Allocation, Bio-inspired Algorithm.

Copyright



:Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

* Assistant Professor, Department of Systems and Computer Networks, Faculty of Information Engineering, Tishreen University, Lattakia, Syria.

** Master student, Department of Systems and Computer Networks, Faculty of Information Engineering, Tishreen University, Lattakia, Syria. ibaa.ali@tishreen.edu

إدارة الموارد الديناميكية الذكية في شبكات النفاذ إلى الراديو السحابية باستخدام الخوارزميات المستوحاة من الطبيعة

د. هبة حيدر*

إباء علي**

(تاريخ الإيداع 17 / 6 / 2023. قَبْلُ للنشر في 1 / 8 / 2023)

□ ملخص □

طرحت شبكات النفاذ إلى الراديو السحابية كحل واعد لدعم متطلبات الجيل الخامس بتحقيق الإدارة المركزية، وتقليل التكاليف، وزيادة كفاءة الطاقة، والكفاءة الطيفية، والمعالجة التعاونية من خلال تجميع وحدات معالجة النطاق الأساسي Baseband Unit (BBU) في تجمع مركزي سحابي، غير أن النشر عالي الكثافة للخلايا الصغيرة Small cells الداعمة للخلايا الماكروية Macro cells، يزيد صعوبة إدارة الموارد، ويجعل منها مشكلة تحسين من النوع NP-hard يحتاج حلها إلى اختيار خوارزميات مناسبة تلائم طبيعة المشكلة من جهة، وتحقق جودة الخدمة من جهة أخرى، ونظراً لمرونة الخوارزميات الذكية المستوحاة من الطبيعة، وقدرتها على التكيف مع تغير حركة بيانات المستخدمين، ندرس إحداها ألا وهي خوارزمية SA-PSO الهجينة المؤلفة من مرحلتين مرحلة الاختيار الديناميكي للرؤوس الراديوية النشطة باستخدام خوارزمية (SA) Simulated Annealing، ثم مرحلة تجميع الرؤوس الراديوية البعيدة (RRHs) Remote Radio Heads، وربطها بتجمعات BBU السحابية بما يضمن موازنة الحمولة بين هذه الوحدات، وذلك باستخدام خوارزمية أسراب الطيور (PSO) Particle Swarm Optimization. نأخذ بعين الاعتبار التغير الديناميكي في حركة بيانات المستخدمين خلال أربع وعشرين ساعة بهدف دراسة تأثير المد والجزر Tidal Effects على أداء الخوارزميات المدروسة. أظهرت النتائج تفوق خوارزمية SA-PSO على خوارزمية (HDSO) Heuristic Dynamic Switch off الديناميكية من حيث تخفيض معدل استخدام الرؤوس الراديوية بما يقارب 13.81% عند انخفاض حركة البيانات و 14.36% في ساعات الذروة مع تحقيق جودة الخدمة المطلوبة.

الكلمات المفتاحية: الجيل الخامس، شبكات النفاذ إلى الراديو السحابية، إدارة الموارد، الخوارزميات المستوحاة من الطبيعة.



حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص

CC BY-NC-SA 04

* مدرس- قسم النظم والشبكات الحاسوبية- كلية الهندسة المعلوماتية- جامعة تشرين- اللاذقية- سورية.

** طالبة دراسات عليا(ماجستير)- قسم النظم والشبكات الحاسوبية- كلية الهندسة المعلوماتية- جامعة تشرين- اللاذقية- سورية.

ibaa.ali@tishreen.edu

مقدمة:

يزداد عدد الأجهزة المتصلة بالإنترنت، وتعتمد أغلب التطبيقات ما لم نقل معظمها على الشبكة وخدماتها، مما يجعل تقاسم موارد الشبكة بين الأعداد المتزايدة من المستخدمين وأجهزتهم أمراً بالغ الأهمية قد يؤدي إلى نجاح الشبكة في تحقيق أهدافها، وقد يسبب فشلها وانهارها أمام الزيادة المستمرة في أعداد المستخدمين، من هنا جاءت أهمية شبكات النفاذ إلى الراديو السحابية باعتبارها بيئة مهيأة لإدارة الموارد المركزية ومقللة للتكاليف، تحقق معدلات نقل بيانات عالية، تقلل التأخير والتداخل، وتزيد الموثوقية من خلال فصل وحدات معالجة النطاق الأساسي (BBU) عن الرؤوس الراديوية البعيدة (RRHs)، وتجميع هذه الوحدات في تجمع مركزي سحابي [1].

زادت أهمية شبكات النفاذ السحابية، ودعت الحاجة إلى استخدامها عند الانتقال إلى النشر عالي الكثافة للجيل الخامس، فلم يعد استخدام المعمارية السابقة Distributed Radio Access Network (D-RAN) التي تتوزع فيها وحدات معالجة النطاق الأساسي على كل موقع خلوي أمراً ممكناً سيما مع زيادة استخدام التطبيقات الحرجة التي تفرض قيوداً صارمة على معدل نقل البيانات، ومستوى التأخير، وجودة الخدمة. تعيق العوامل السابقة النشر الفعال لشبكات الجيل الخامس، وتضيف المزيد من الأهمية لشبكات النفاذ إلى الراديو السحابية C-RAN التي لن تصل إلى أهدافها ما لم تعتمد على خوارزميات فعالة لإدارة موارد الشبكة، تمنع التأخير والاستهلاك الزائد للطاقة، تحقق المعالجة بالزمن الحقيقي [2]، وتتعامل مع الأعداد الكبيرة جداً من الموارد والمستخدمين بتوزيع موارد الشبكة بشكل ديناميكي متغير وفقاً لحركة البيانات وبما يراعي شروط جودة الخدمة، ساهمت العوامل السابقة في زيادة استخدام تقنيات التحسين والخوارزميات الذكية في إدارة الموارد لمرونتها وقدرتها على التكيف مع التغير الديناميكي في حركة بيانات المستخدمين ومواقعهم [3].

بناءً على ما سبق، نسعى إلى دراسة مشكلة تخصيص الموارد في شبكات النفاذ إلى الراديو السحابية ضمن الجيل الخامس، ونقيم أداء الخوارزميات الذكية المستوحاة من الطبيعة في حل هذه المشكلة من خلال مقارنتها مع خوارزمية ديناميكية إرشادية Heuristic Algorithm، بهدف صياغة مجموعة من الاستنتاجات والتوصيات المساعدة في حل مشكلة إدارة الموارد في شبكات الجيل الخامس التي تستخدم تقنية C-RAN.

أهمية البحث وأهدافه:

تحظى إدارة الموارد في شبكات الجيل الخامس باهتمام كبير لتأثيرها المباشر في أداء الشبكة وتجربة المستخدمين، ولدورها في زيادة معدل نقل البيانات والإنتاجية وتقليل التأخير والازدحام بالاستفادة من الاستخدام الفعال للموارد المتاحة بما يشمل الطيف، البنية التحتية للشبكة، والموارد الحسابية، وتحسين جودة الخدمة (QoS) وتجربة المستخدمين بضمان حصولهم على خدمات موثوقة ومستمرة بغض النظر عن الموقع والوقت، وزيادة المرونة وقابلية التوسع بالاستفادة من التخصيص الديناميكي للموارد المعتمد على الطلب (On Demand) [4]. وفقاً لذلك، نجد أنّ العامل الأساسي في ضمان جودة الخدمة والنشر الفعال للجيل الخامس هو الاستفادة القصوى من الموارد المتاحة دون الإخلال بقيود جودة الخدمة التي تحتاجها الشبكة. لذا نهدف في هذا البحث إلى تقييم أداء الخوارزميات الذكية المستوحاة من الطبيعة في عملية إدارة الموارد ضمن شبكات النفاذ إلى الراديو السحابية في الجيل الخامس من خلال مقارنتها مع

الخوارزميات الديناميكية التي تعتمد على تابع جدوى Utility Function، والتأكد من قدرة هذه الخوارزميات على تحقيق جودة الخدمة المطلوبة.

طرائق البحث ومواده:

استخدم البحث منهجيتين أساسيتين الأولى دراسة نظرية تشمل استعراض الأساسيات اللازمة لفهم بنية شبكات النفاذ إلى الراديو السحابية، وآلية عملها، والوقوف عند مشكلة البحث، والتركيز على أسبابها، ومناقشة الحلول الممكنة لها، بينما يركز الجانب الآخر على دراسة الخوارزميات المستخدمة في القسم العملي من البحث، واعتماد النمذجة الحاسوبية لمقارنة أداء هذه الخوارزميات، ثم مناقشة النتائج بهدف صياغة الاستنتاجات والحلول. استخدم برنامج MATLAB لتحقيق أهداف البحث وهو عبارة عن منصة برمجية مصممة لتحليل وتصميم الأنظمة، يعتمد على لغة MATLAB القائمة على المصفوفات والعلاقات الرياضية الحاسوبية [5].

الدراسات المرجعية

استخدم Fakhri وآخرون خوارزمية أسراب الطيور المتقطعة (DPSO) Discrete Particle Swarm Optimization لإدارة الموارد في شبكات C-RAN السحابية، تهدف الخوارزمية إلى إدارة الموارد وموازنة الحمولة من خلال عنقدة الرؤوس الراديوية وتوزيع أعباء معالجة الإشارات القادمة إليها على وحدات BBU، حققت DPSO أداءً مثاليًا في الشبكات الصغيرة، وأداءً قريب من المثالي في الشبكات الكبيرة، وتميزت بكونها أكثر مرونة وأقل تعقيداً من خوارزمية Exhaustive Search كما ساهمت DPSO بزيادة الإنتاجية بمقدار 45.53% و 42.102%، وخفضت معدل رفض المكالمات إلى 23.149% و 20.903% عند استخدام خوارزميات الجدولة Proportional Fair (PF) و Round Robin (RR) [6].

تهمل الدراسة السابقة موضوع التكامل بين عمل المحطات القاعدية، وهنا نقصد بالتكامل التعاون بين المحطات القاعدية لتأمين جودة الخدمة، وتسهيل انتقال المستخدمين من خلية إلى أخرى، وتقادي فجوات التغطية المسببة لرفض المكالمات، بناء على ذلك استخدم Chen ومجموعة من الباحثين خوارزمية عنقدة مقيدة بالمسافة-distance constraint clustering لإيجاد أفضل طريقة لتجميع المحطات القاعدية، اعتمدت الخوارزمية على استخدام بيان موزون لتمثيل درجة التكامل بين المحطات، فكل عنقدة تمثل محطة قاعدية والوصلات بين هذه العقد موزونة تعبر عن درجة التكامل بين المحطات. تم تقييم الأداء بالاعتماد على مجموعة بيانات حقيقية جُمعت خلال شهرين في مدينة ميلان الإيطالية مؤلفة من معلومات حول موقع وتغطية المحطات القاعدية النشطة، تقلل الخوارزمية المقترحة من تكلفة النشر بمقدار 12.88% كما تخفض استهلاك الطاقة بنسبة 9.45% مقارنة مع المعمارية التقليدية وخوارزمية [7].


Baseline

درس Zhu وآخرون إدارة الموارد في شبكات C-RAN السحابية الهجينة المؤلفة من نوعين من الخلايا ماكروية أساسية Macro cells وخلايا pico داعمة لها في حواف الخلية ومناطق الازدحام hot points، تمت الإدارة على مستويين الأول اختيار الرؤوس الراديوية، والثاني الربط مع وحدات BBU السحابية، في المستوى الأول استخدمت خوارزمية Weighted Minimum Mean Square Error (WMMSE) لاختيار الرؤوس الراديوية، واعتمدت المرحلة الثانية على خوارزمية bin packing تستخدم Best Fit Decreasing (BFD)، تفوقت الخوارزمية المقترحة على خوارزميات First-Fit-Decreasing و Max-Min و Next-Fit [8].

من ناحية أخرى، استخدم Ari وآخرون نموذجاً هجيناً لإدارة موارد C-RAN، وأطلقوا عليه Bee-Ant-CRAN، يبحث النموذج بداية عن أفضل طريقة ممكنة لتخصيص الرؤوس الراديوية للمستخدمين، ثم أفضل طريقة ممكنة لاستخدام وحدات BBU من خلال دراسة خوارزميات الربط بينها وبين الرؤوس الراديوية RRHS، يتألف النموذج من مرحلتين الأولى خوارزمية Artificial Bee Colony معدلة لتحسين عملية اختيار الرؤوس الراديوية البعيدة، والثانية Ameliorated Ant Colony لعنقدة الرؤوس الراديوية وربطها بتجمعات BBU السحابية، يحسن النموذج السابق من استخدام الموارد، ويزيد الانتاجية مع معدل ضياع حزم واستهلاك طاقة أقل من النماذج السابقة [9]. اتجه الباحثون أيضاً في الدراسة [10] إلى استخدام الخوارزميات الذكية المعتمدة على ذكاء السرب Swarm Intelligence لمرونتها وقدرتها على التعلم من التجارب السابقة، فاستخدم Rao وآخرون خوارزمية أسراب الطيور PSO لربط الرؤوس الراديوية البعيدة بوحدات BBU السحابية ضمن تجمع BBU pool بهدف تحسين استخدام الموارد، تقلل الخوارزمية المستخدمة من استهلاك الطاقة بنسبة 90٪، وتزيد كفاءة استخدام BBU بنسبة 100٪. بناءً على الدراسات المرجعية سابقة الذكر، سنركز على مقارنة أداء الخوارزميات التي تستخدم التحسين المشترك لإدارة الموارد من خلال اختيار الرؤوس الراديوية أولاً ثم ربطها بوحدات معالجة النطاق الأساسي ثانياً ضمن نموذج هجين يستخدم الخوارزميات الذكية المستوحاة من الطبيعة.

1- شبكات النفاذ إلى الراديو السحابية (C-RAN)

تمثل المرحلة الثالثة من تطور شبكات النفاذ الراديوية، تقسم فيها المحطة القاعدية التقليدية إلى مجموعة من الرؤوس الراديوية (RRHs) المتصلة بتجمع معالجة النطاق الأساسي (BBU pool) عبر الوصلة الأمامية Fronthaul. يعتمد المبدأ الأساسي لمعمارية C-RAN على نقل جزء من وظائف الشبكة الخلوية المتمثل بعمليات معالجة النطاق الأساسي إلى السحابة [11]. تزيد هذه المعمارية من مرونة الشبكة وقابليتها للتوسع نتيجة استخدام وحدات BBU الافتراضية (vBBU) Virtual Baseband Unit. تقلل هذه المعمارية من التكاليف المادية والتشغيلية لأنها تسهل عمليات الصيانة والإصلاح، وتحافظ على وحدات المعالجة في تجمع واحد مما يقلل تكلفة التبريد واستئجار المواقع على خلاف المعمارية السابقة الموزعة D-RAN التي توزع وحدات المعالجة على كل محطة قاعدية [2].



الشكل (1): معمارية شبكات النفاذ إلى الراديو السحابية [2]

2- مكونات شبكات النفاذ إلى الراديو السحابية

1-2 الرؤوس الراديوية البعيدة (RRHs)

تتألف من مجموعة من الهوائيات، والمضخمات، ومحول تماثلي إلى رقمي A / D ومحول رقمي إلى تماثلي D / A، ومضخم ضجيج منخفض (LNA) Low Noise Amplifier. تعد RRH المكون المسؤول عن عمليات الإرسال والاستقبال، وتحويل الإشارة، وتضخيمها، وترشيحها، وإخراجها عبر الهوائي [12].

2-2 تجمع معالجة النطاق الأساسي (BBU pool)

تجمع مركزي مشترك افتراضي يعمل كمركز لمعالجة البيانات، يسمح بتكديس وحدات BBU الافتراضية معاً، يمكن أن يدعم كل تجمع BBU عدد من رؤوس الراديو البعيدة RRHs، تتكون وحدات BBU من معالجات قابلة للبرمجة ذات أداء عالي، تطبق هذه الوحدات تقنيات المحاكاة الافتراضية في الزمن الحقيقي حيث تثبت BBU على الآلات الافتراضية (VMs) في مركز البيانات السحابي. تقوم وحدات BBU بعمليات جدولة ومعالجة الإشارات الواردة من المواقع الخلوية المختلفة إلى المحطة الأساسية الافتراضية [11-12].

2-3 الوصلة الأمامية Fronthaul link

حلقة الوصل بين الرؤوس الراديوية RRHs ووحدات معالجة النطاق الأساسي BBUs الموجودة في مركز البيانات السحابي، توفر الوصلة الأمامية نطاقاً ترددياً عالياً، وروابط ذات زمن استجابة منخفض، يمكن أن تمتد إلى ما يقارب 40 كم، يتم إعدادها باستخدام تقنيات مختلفة كالألياف الضوئية أو الاتصالات الخلوية أو الأمواج المليمترية (mmWave) [11-12].

3- الخوارزميات المستخدمة

1-3 خوارزمية أسراب الطيور Particle Swarm Optimization

خوارزمية بحث ذكية مستوحاة من سلوك أسراب الحيوانات كالطيور أو الأسماك تسعى لإيجاد حل لمسألة معطاة من خلال التحسين المتكرر للحل وفق تابع كلفة معين. تستخدم هذه الخوارزمية عدد من العناصر (العملاء) التي تشكل سرباً يتحرك بشكل متناغم ضمن فضاء البحث بحثاً عن الحل الأفضل. يعدل كل عنصر من السرب حركته في فضاء الحلول بالاستفادة من تجربته الخاصة أي ما مر به خلال حركته، إضافة إلى خبرة العناصر الأخرى [13]، تتضمن الخوارزمية خطوات مختلفة تبدأ بتحديد عدد RRHs و BBUs وحجم السكان أو العملاء Population size ومعاملات التسارع وعدد التكرارات الأعظمي. تهيئاً بعدها مواقع العملاء والسرعة بشكل عشوائي، وتحسب القيمة الأولية للدالة الهدف، ليتم بعدها تحديث أفضل قيمة محلية (PBest) وأفضل قيمة عالمية (GBest) لكل عميل. نغير سرعة العميل في كل تكرار باستخدام عوامل التسارع وقيم كل من PBest وGBest، وذلك باستخدام العلاقة التالية [13]:

$$v_{id} = w * v_{id} + c_1 * r_1 * (P_{id} - x_{id}) = c_2 * r_2 * (P_{gd} - x_{id}) \quad (1)$$

v_{id} : سرعة العميل. x_{id} : الموقع الحالي للعميل. w : معامل Inertia يسمح للسرعة السابقة بالتأثير على السرعة الحالية. r_1 و r_2 : أرقام عشوائية بين 0 و 1. c_1 و c_2 : معاملات التسريع. تحدث الخوارزمية موقع كل العميل عن طريق إضافة متجه السرعة الخاص به، فينتقل العميل من الموقع x_i إلى موقع جديد x_{i+1} ضمن فضاء البحث وفقاً للعلاقة التالية [13]:

$$x_{i+1}(t+1) = x_i(t) + v_i(t+1) \quad (2)$$

$x_i(t)$: الموقع السابق للعميل i في اللحظة t . $v_i(t+1)$: سرعة العنصر في الانتقال من الموقع x_i إلى الموقع x_{i+1} . يمكن تلخيص الخطوات الأساسية لعمل هذه الخوارزمية اعتماداً على الشيفرة المزيفة التالية الخاصة بخوارزمية PSO المعيارية المعروفة بـ GBest Particle Swarm Optimization:

Inputs: number of RRHs, number of BBUs, population size, acceleration factors c_1 and c_2 , and maximum number of iterations.

1. Initialize the population and velocity vectors randomly.
2. Calculate the initial objective function value.
3. Set the personal best (PBest) vector equal to the initial population and set the global best (GBest) vector equal to the individual with the lowest objective function value.
4. Begin the search loop for the specified number of iterations.
5. For each individual in the population, update its velocity using the acceleration factors and the personal and global best positions.
6. Update each individual's position by adding its velocity vector while Ensuring that all positions are within the bounds of the number of BBUs.
7. Calculate the objective function value for each individual
8. Update each individual's personal best position if its objective function value is lower than its previous best.
9. Update the global best position if a new individual has a lower objective function value than the current global best.

Simulated Annealing 2-3

خوارزمية ذكية مستوحاة من عملية تليدين المعدن، ويقصد به تسخين المعدن ثم تبريده ببطء وصولاً إلى درجة حرارة أكثر استقراراً، وبالمثل تبدأ خوارزمية (SA) عملها بحل ابتدائي C انطلاقاً من درجة حرارة T ثم تكرر مجموعة من الخطوات طالما أنّ الحرارة أعلى من عتبة معينة. فتولد حلاً جديداً N بتطبيق تعديل عشوائي أو طفرة على الحل الحالي، يلي ذلك حساب فرق الطاقة بين الحل الجديد والحل الحالي (ΔE). إذا كان الحل الجديد أفضل (أي ذو تكلفة أقل) من الحل الحالي، يتم اعتباره الحل الحالي الجديد، وإلا فإننا نحتفظ بالحل السابق بناءً على درجة الحرارة وفرق الطاقة، وقبل الانتقال إلى التكرار التالي تتغير درجة الحرارة T اعتماداً على معدل التبريد α ، تهدف الخوارزمية في دراستنا إلى استخدام أقل عدد ممكن من الرؤوس الراديوية لتخديم المستخدمين مع المحافظة على جودة الخدمة. تبدأ الخوارزمية عملها بالبحث عن الحل المثالي باستخدام حل ابتدائي عشوائي يمثل بشعاع ذو حجم مساو للعدد الأعظمي للرؤوس الراديوية، يملك هذا الشعاع قيم ثنائية تعبر عن حالتي On/ Off، تمثل 1 حالة RRH تعمل، والقيمة 0 حالة RRH مطفأة. لتوليد حلول جديدة تعدّل الخوارزمية في هذا الشعاع على كامل فترة عمل المحطات القاعدية حسب المتطلبات الراهنة، يمكن للخوارزمية اختبار عدة طرق لتخصيص الموارد بكفاءة وفعالية، واكتشاف أفضل طريقة ممكنة بناءً على الحالة الحالية للشبكة وعبء العمل، اعتماداً على جودة الإشارة ومعامل التبريد α وعدد التكرارات الأعظمي. تبدأ الخوارزمية عملها بتهيئة درجة الحرارة الابتدائية T_0 ومعامل التبريد α وعدد التكرارات الأعظمي، والحل الحالي C بقيم عشوائية، وتضبط التكلفة إلى ما لا نهاية، تولد الخوارزمية حلاً جديداً N في كل تكرار يقترب من

الحل الحالي C، قد يكون الحل الجديد أفضل من الحل الحالي وقد يكون أسوأ منه ونعتمد في عملية التقييم هذه على فرق الطاقة بين العقدة الجديدة والحالية، والذي يعطى بالعلاقة (3) [14]:

$$\Delta E = Cost(n) - Cost(c) \quad (3)$$

يقيم التابع Cost موقع العقدة التالية مقارنة بالحالية بحسب طبيعة التابع الهدف ففي مسائل التحسين من النوع minimization يجب أن تقلل العقدة التالية من قيمة التابع الهدف، يتم اختيار العقدة التالية بشكل عشوائي من الجيران القريبة من العقدة الحالية ثم حساب احتمال هل كان الخيار صحيحاً أم لا اعتماداً على العلاقة التالية [14]:

$$P(c, n) = \frac{1}{1 + e^{-\Delta E/T}} \quad (4)$$

حيث $P(c, n)$: تمثل احتمالية إجراء الخطوة والانتقال من العقدة الحالية إلى التالية. T: درجة الحرارة المؤثرة في تحديد هل سنقوم بالخطوة التالية أم لا، وتبدأ الخوارزمية باختيار درجة حرارة عالية جداً لاختار عشوائي للجيران ثم تتخفف درجة الحرارة تدريجياً لتنتقل الخوارزمية إلى اختيارات جديدة تكون نسبة الخطأ فيها قليلة. تسمح الخوارزمية بقبول مبدئي لبعض الخطوات الأسوأ وياحتمال معين وصولاً إلى الحل الأفضل وهذا ما يجعل خوارزمية SA من أفضل الخوارزميات في تجاوز مشكلة Local Optima واستكشاف مناطق مختلفة من مساحة الحل، نلخص خطوات عمل الخوارزمية في الشيفرة المزيفة التالية [14]:

```

Initialize solution C
Initialize temperature T
Initialize cooling rate r
while T > 0:
  for i in range(num_ iterations):
    Generate a new solution N
    Calculate the energy difference dE = cost(N) - cost(C)
    if dE <= 0 or exp(-dE/T) > rand():
      Accept C_new as the current solution
    Update C, Update temperature T according to cooling rate r
  Return best solution found
    
```

(HDSO) Heuristic Dynamic Switch Off Algorithm 3-3

خوارزمية ديناميكية تحسن استخدام الموارد من خلال إطفاء المحطات القاعدية الصغيرة التي يمكن الاستغناء عنها، ونقل مستخدميها إلى الخلايا الصغيرة والماكروية المجاورة، تستخدم هذه الخوارزمية القواعد Rules والخطوط البيانية الإرشادية لاتخاذ قرارات بشأن تخصيص الموارد، فتعتمد على التجربة والخطأ لإيجاد الحل وصولاً إلى أفضل تخمين "Best guess" [15]. تعتمد عملية إطفاء المحطة القاعدية على تابع الجدوى Utility Function يعرف بالعلاقة التالية:

$$u_x = \frac{\epsilon \frac{R_x}{R_{max}} + \beta \frac{P_x}{P_{max}} + G \frac{N_x}{N_{max}}}{\frac{I_x}{I_{max}}} \quad (5)$$

R_x معدل البيانات Data Rate المطلوب من قبل RRHx، R_{max} معدل البيانات الأعظمي، I_x مقدار التداخل الناتج عن RRHx، I_{max} التداخل الأعظمي، P_x حمولة البيانات، P_{max} حمولة البيانات الأعظمي، N_x عدد مستخدمين ال RRH، N_{max} عدد المستخدمين الكلي، ϵ و β و G أوزان تأخذ القيم الثابتة التالية 0.1، 0.6، 0.3 على الترتيب. يستخدم تابع الجدوى المجموع الموزون لقيم كل من التداخل، وحمولة البيانات، ومعدل نقلها إضافة إلى

أعداد المستخدمين المقبولين في كل محطة قاعدية، وينتج عن تطبيقه قيمة Utility value تمثل جدوى المحطة القاعدية، يمكن توضيح آلية عمل الخوارزمية باستخدام الشيفرة المزيفة التالية:

1. Initialize system parameters and small base station information.
2. Calculate interference caused by each small base station and determine the maximum interference value.
3. Calculate the maximum value of the W, which is a function of the number of users served and blocked by each small base station.
4. Calculate Y, which is a combination of the data rate and traffic load at each small base station.
5. Calculate X, which is the interference caused by each small base station divided by the maximum interference value.
6. Calculate the overall utility of each small base station using a weighted sum of Y, W, and X. The weights for Y, W, and X are defined by the constants E, B, and G respectively.
7. Sort the small base stations in descending order of their utility values.
8. Allocate the small base stations with the highest utility values until the available resources are exhausted.
9. Turn off the remaining small base stations to save energy.
10. Repeat steps 2-9 periodically to adapt to changes in network conditions.
11. End algorithm.

النتائج والمناقشة:

لتقييم أداء الخوارزميات المدروسة افترضنا وجود شبكة نفاذ إلى الراديو سحابية هجينة مؤلفة من مستويين 2-tier HetNet خلية ماكروية مدعومة بـ 10 خلايا صغيرة تملك كل خلية ماكروية كانت أم صغيرة 10 رؤوس راديوية بعيدة (RRHs) ليكون بذلك عدد الرؤوس الراديوية البعيدة 10 في الخلية الماكروية نشير إليها للسهولة بـ MRRH و 100 في الخلايا الصغيرة نشير إليها بـ SRRH تتصل المحطات القاعدية مع تجمع BBU pool السحابي المؤلف من 6 وحدات معالجة نطاق عريض BBUs ، استخدمنا في المحاكاة عرض حزمة 18 MHz و طاقة إرسال 33 dBm للرؤوس الراديوية الصغيرة و 46 dBm للرؤوس الماكروية، تم توليد قنوات اتصال تتوافق مع النموذج (ECC-33) 33 - Electronic Communication Committee، أجرينا المحاكاة لمدة 24 ساعة لمقارنة أداء خوارزمية SA-PSO و HDSO وقدرتها على التعامل مع تغير حركة بيانات المستخدمين خلال ساعات اليوم من جهة، وتغير حمولة البيانات من جهة أخرى وذلك بتنفيذ ثلاث سيناريوهات استخدمنا فيها أعداد مختلفة من المستخدمين 1500، 1000، 500 مستخدم.

الجدول (1): متغيرات عملية المحاكاة


| MRRH | SRRH | البرامترات |
|--|--|---------------------------------|
| 18 MHz | 18 MHz | عرض الحزمة |
| 10 | 10 | عدد الرؤوس الراديوية البعيدة |
| 46 dBm | 33 dBm | طاقة إرسال المحطة القاعدية |
| 1000 m | 150 m | مجال تغطية الرأس الراديوي |
| $C * \log_2(1 + \text{SINR})$ | $C * \log_2(1 + \text{SINR})$ | معدل نقل البيانات (DR) |
| $\text{Round } 1 + \frac{7}{13} (\text{SINR} + 6)$ | $\text{Round } 1 + \frac{7}{13} (\text{SINR} + 6)$ | Channel Quality Indicator (CQI) |

الجدول (2): السيناريوهات العملية

| حمولة البيانات | السيناريو |
|----------------|------------------|
| 500 مستخدم | السيناريو الأول |
| 1000 مستخدم | السيناريو الثاني |
| 1500 مستخدم | السيناريو الثالث |


1- تأثير المد والجزر على متوسط الرؤوس الراديوية النشطة

تعبّر ظاهرة تأثير المد والجزر Tidal Effects في الاتصالات الخلوية عن حالة تغير حركة بيانات المستخدمين خلال فترات اليوم بين طلب عالٍ للبيانات في أوقات العمل وعند المساء، مقابل انخفاض حركة البيانات في الصباح المبكر، وقد تنتج هذه الظاهرة عن انتقال المستخدمين من مكان إلى آخر كتجمع المستخدمين في أماكن العمل والشركات صباحاً وفي المراكز التجارية والأسواق مساءً، مما يسبب تفاوتاً في عدد الموارد المستخدمة بين فترات الذروة وفترات انخفاض حركة البيانات، وهنا تأتي أهمية خوارزميات إدارة الموارد الديناميكية في الموازنة بين الحالتين ومراعاة التغيرات الديناميكية التي تحدث في الشبكة على خلاف الخوارزمية التقليدية التي تقوم بتخصيص الموارد اعتماداً على معدل طلب البيانات في ساعات الذروة. ندرس في هذا القسم تأثير ظاهرة المد والجزر على أداء الخوارزميات المدروسة من خلال تحديد متوسط عدد الرؤوس الراديوية النشطة في شبكات النفاذ إلى الراديو السحابية، فنركز على تمييز سلوك الشبكة عند انخفاض حركة البيانات وسلوكها في ساعات الذروة، فقد نجد أن بعض استراتيجيات إدارة الموارد تلائم العمل في الحالة الأولى أكثر منها في الحالة الثانية والعكس صحيح. نضيف إلى ذلك أن الشبكة تعمل بطاقتها القصوى في ساعات الذروة مما يزيد صعوبة مراقبة تأثير المد والجزر على استخدام موارد الشبكة، بالمقابل عند انخفاض حركة البيانات ومن أجل عدد قليل من المستخدمين وعدد كبير من الموارد المتاحة يكون من الأسهل مراقبة آلية عمل الخوارزميات والتحقق من عدم وجود استخدام غير ضروري لبعض الموارد، افترضنا نموذج لحركة بيانات المستخدمين يعتبر أن الساعات من الثانية ليلاً حتى العاشرة صباحاً تمثل ساعات انخفاض حركة البيانات حيث يقل نشاط المستخدمين لأنها تمثل ساعات الصباح المبكرة السابقة لأوقات العمل، بينما نعتبر أن الساعات من الثانية عشرة ظهراً حتى الحادية عشرة ليلاً ساعات الذروة حيث تزداد حركة البيانات في الشبكة.



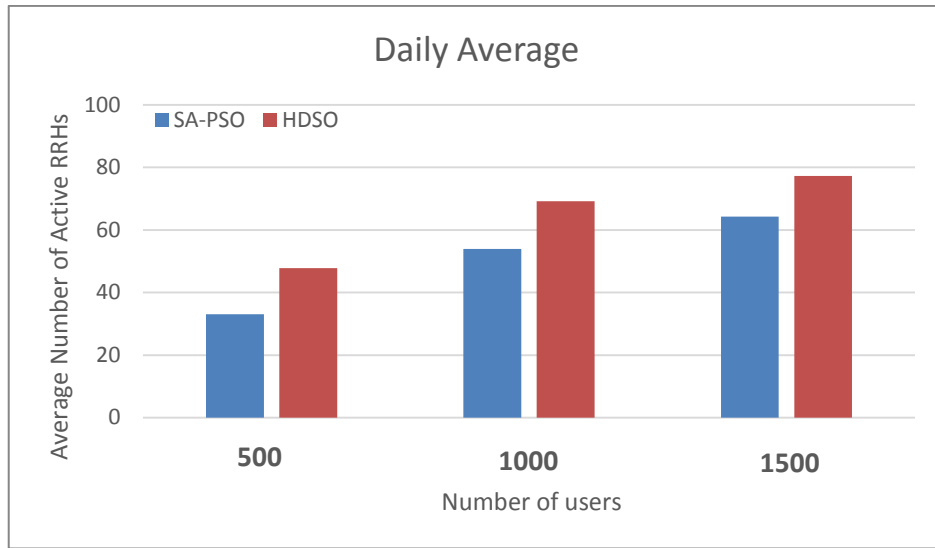
الشكل (2) : متوسط الرؤوس الراديوية النشطة في ساعات انخفاض حركة البيانات

يوضح الشكل (2) متوسط عدد الرؤوس الراديوية النشطة بين الساعتين الثانية بعد منتصف الليل والعاشر صباحاً أي عند انخفاض حركة البيانات مع زيادة أعداد المستخدمين من 500 إلى 1000 ثم 1500، تظهر النتائج زيادة متوسط RRH النشطة مع زيادة عدد المستخدمين نتيجة ازدياد الطلب على الموارد والحاجة إلى إضافة المزيد من RRH لزيادة سعة الشبكة ونلاحظ أيضاً أن خوارزمية SA-PSO تحقق أداء أفضل من خوارزمية HDSO وتحافظ SA-PSO على أدائها مع زيادة عدد المستخدمين، فهي تستخدم عدداً أقل من الرؤوس الراديوية يبلغ متوسطها 11، 31، 45 رأس راديوي من أجل 500، 1000، 1500 مستخدم على الترتيب مقابل 21، 58، 61 رأس راديوي يتم تشغيله من قبل HDSO مما يعني أن SA-PSO تقوم بإطفاء عدد أكبر من الرؤوس الراديوية، إذ تبلغ نسبة إطفاء الرؤوس الراديوية البعيدة 88% عند استخدام خوارزمية SA-PSO و79% عند استخدام HDSO وذلك في ساعات انخفاض حركة البيانات.



الشكل (3) : متوسط الرؤوس الراديوية النشطة في ساعات الذروة

مع زيادة عدد المستخدمين في ساعات الذروة من 500 إلى 1000 ثم 1500 يزداد متوسط RRHs النشطة ليبلغ وفقاً للشكل (3) القيم 64، 83، 87 رأس راديوي على الترتيب عند استخدام HDSO و46، 67، 77 على الترتيب من أجل SA-PSO. ورغم أن كلتا الخوارزميتين تعملان على التكيف مع تغير حركة بيانات المستخدمين بشكل ديناميكي إلا أن خوارزمية SA-PSO تتفوق على خوارزمية HDSO بمعدل 14.36% في ساعات الذروة، نظراً لأن خوارزمية HDSO تستخدم تابع جدوى لا يأخذ تغير مواقع المستخدمين بعين الاعتبار ويعتمد على الأوزان مما يقلل مرونة الخوارزمية ويستدعي ضبط هذه الأوزان بشكل صحيح وبما يلائم كل حالة، بالمقابل تتميز الخوارزميات الذكية المستوحاة من الطبيعة بمرونتها وقدرتها على الاستفادة من التجارب السابقة في الوصول إلى أفضل حل ممكن مما يساعد خوارزمية SA الذكية على اختيار العدد الأمثل من الرؤوس الراديوية متكيفة مع التغيرات المختلفة التي تحدث في الشبكة وبدل أن يكون القرار معتمد على تابع جدوى كما في HDSO يكون الاعتماد على آلية تدعم قبول الحلول الأسوأ باحتمالية معينة، يتم التحكم فيها بواسطة معامل درجة الحرارة مما يسمح باستكشاف فضاء البحث بشكل أوسع ويسهل تعامل الخوارزمية مع قيود مشكلة التحسين.




الشكل (4) : معدل الاستخدام اليومي للرؤوس الراديوية

يشير معدل الاستخدام اليومي Daily Average إلى متوسط عدد الرؤوس الراديوية المستخدمة في اليوم، ويعتبر واحدا من مقاييس الأداء الهامة عند دراسة إدارة الموارد. يظهر الشكل (4) معدل الاستخدام اليومي كتابع لعدد المستخدمين، وثبتت النتائج تفوق خوارزمية SA-PSO في السيناريوهات الثلاثة من أجل 500، 1000، 1500 مستخدم بتقليل عدد الرؤوس الراديوية المستخدمة واستغلال الموارد المتاحة بشكل أكبر، إذ يقل المتوسط اليومي لاستخدام SA-PSO للرؤوس الراديوية بمقدار 15% عن المتوسط اليومي لاستخدام الرؤوس الراديوية من قبل خوارزمية HDSO، ليكون المتوسط اليومي من الرؤوس الراديوية النشطة 48، 69، 77 بالنسبة لخوارزمية HDSO من أجل 500، 1000، 1500 مستخدم، مقابل 33، 54، 64 بالنسبة لخوارزمية SA-PSO. استنادا إلى ما سبق، أظهرت دراسة ظاهرة المد والجزر على السيناريوهات الثلاثة تفوق خوارزمية SA-PSO على HDSO بتقليل عدد الموارد المستخدمة سيما في ساعات انخفاض حركة البيانات نتيجة انخفاض طلب المستخدمين على موارد الشبكة لأن عدد المستخدمين الواجب تخدمهم أقل مما هو عليه في حالة الذروة، وهذا يعني أن عدداً قليلاً من موارد الشبكة سيكون كافياً لتخدم المستخدمين، من جهة أخرى تتفوق خوارزمية SA-PSO بمعدل 13.81% على خوارزمية HDSO في حالة انخفاض حركة البيانات وبمعدل 14.36% في ساعات الذروة، وذلك عند أخذ متوسط النتائج التي حصلنا عليها في السيناريوهات الثلاثة، ويمكن تعليل النتائج السابقة بأن خوارزمية SA-PSO تجمع في عملها بين خوارزمية Simulated Annealing وخوارزمية أسراب الطيور PSO مستفيدة من نقاط القوة في كلتا الخوارزميتين لتحسين عملية تخصيص الموارد، لاسيما خوارزمية SA المستخدمة في جزئية اختيار الرؤوس الراديوية، والتي تتجنب الوقوع في مشكلة الـ local optima من خلال السماح بالقبول المبدئي لحلول أسوأ من الحل الحالي يمكن أن تؤدي إلى حلول أفضل في المستقبل [14]، كما تسمح خوارزمية PSO بالاستفادة من تجارب العملاء في عملية تخصيص الموارد وصولاً إلى الحل الأفضل، مما يجعل خوارزمية SA-PSO أكثر مرونة وقابلية للتكيف من خوارزمية HDSO التي تستخدم تابع تكلفة مرهون بدقة اختيار الأوزان والبرامترات الداخلة في تعريف هذا التابع، فهي تحسب جدوى بقاء كل رأس من الرؤوس الراديوية في حالة عمل من خلال تابع جدوى يستخدم المجموع الموزون لقيم كل من التداخل وحمولة البيانات ومعدل نقلها وأعداد المستخدمين المقبولين، غير أنها لا تأخذ

بعين الاعتبار حركة بيانات المستخدمين وتغير مواقعهم، ويدخل تحديد الأوزان بشكل مثالي في تحديد جدوى المحطة القاعدية، فقد تكون هذه الأوزان غير مناسبة لجميع السيناريوهات، ويجب تعديلها من سيناريو إلى آخر.

4-2 جودة الخدمة في خوارزميات إدارة الموارد الديناميكية المدروسة

قد يشكل تقليل الموارد المستخدمة خطراً على جودة الخدمة بجعل الموارد الموجودة غير كافية لتلبية متطلبات المستخدمين، لذا ندرس تأثير الخوارزميتين المدروستين على جودة الخدمة، ونأخذ احتمال رفض المكالمات Blocking probability كمعيار للدراسة، ونقصد به عدد المكالمات المرفوضة مقسوماً على العدد الكلي للمكالمات.



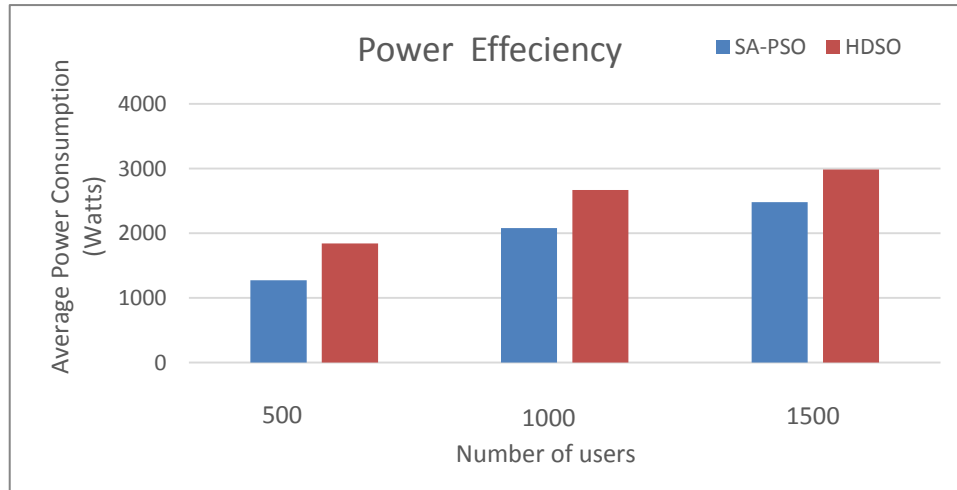
الشكل (5): احتمال رفض المكالمات من أجل 500، 1000، 1500

يمثل الشكل (5) احتمالية رفض المكالمات كتابع لعدد المستخدمين. أظهرت النتائج أن مع زيادة عدد المستخدمين يزداد احتمال رفض المكالمات بسبب زيادة الطلب على موارد الشبكة الراديوية منها والسحابية، ولكن بنسبة قليلة جداً عند استخدام خوارزمية SA-PSO إذ لا تتجاوز الزيادة مقدار 0.00005، كما نلاحظ تفوق خوارزمية SA-PSO على HDSO وقدرتها على المحافظة على احتمال منخفض لرفض المكالمات في السيناريوهات الثلاثة المدروسة، مع وجود تقارب في الأداء من أجل 500 مستخدم، ويعود ذلك لعدة أسباب منها أن خوارزمية HDSO وعند إجراء عملية اختيار الرؤوس الراديوية وإطفاء بعضها لا تأخذ بعين الاعتبار موقع المستخدمين ضمن تابع الجدوى، وتولي اهتماماً أكبر للتداخل وحمولة البيانات دون مراعاة تغير حركة بيانات المستخدمين ومواقعهم عند اتخاذ قرارات التخصيص، مما قد يسبب حدوث ثغوب في التغطية Coverage holes وزيادة احتمال حدوث انقطاعات في الإشارة Signal [3].

في حين تحقق SA-PSO أداء أفضل لأن استخدامها لخوارزمية Simulated Annealing في عملية اختيار الرؤوس الراديوية يسمح لها بالوصول إلى أفضل حل ممكن في الظروف الحالية للشبكة، فباستخدام درجة الحرارة الابتدائية ومعدل التبريد تقبل الخوارزمية بحلول قد تكون أسوأ من الحل السابق بحدود معينة مما يسمح لها بعدم الاكتفاء بحل قد يكون local optima ويفسح المجال لها لمتابعة البحث ضمن فضاء البحث وبالتالي اختيار أفضل حل ممكن، من ناحية أخرى، يساعد استخدام خوارزمية PSO لتجميع وحدات RRH وتوزيع حمولتها على وحدات BBU في تقليل الازدحام المحتمل الحدوث [13]، على خلاف خوارزمية HDSO التي توزيع الاحمال بشكل ثابت على وحدات BBU، كل RRH إلى BBU المخصصة لها.

3-4 كفاءة الطاقة في الخوارزميات المدروسة

يمثل استهلاك الطاقة واحداً من التحديات الأساسية التي تقف عائقاً في وجه نشر شبكات الجيل الخامس، فالزيادة الكبيرة في عدد موارد الشبكة المترافقة مع زيادة كبيرة أيضاً في استهلاك الطاقة يشكل عبئاً على مشغلي الشبكة، ويجعل كفاءة الطاقة واحدة من أهم المعايير الواجب مراعاتها عند دراسة إدارة الموارد سيما في الجيل الخامس، يشمل استهلاك الطاقة طاقة الإرسال والطاقة المستهلكة على الوصلة الأمامية.



الشكل (6) متوسط استهلاك الطاقة خلال 24 ساعة

اعتمدنا في حساب مقدار استهلاك الطاقة على النموذج المقترح في المرجع [1] ، وقد تبين لنا زيادة استهلاك الطاقة مع ازدياد أعداد المستخدمين إلا أن خوارزمية SA-PSO تحافظ على كفاءة الطاقة من خلال تقليل استهلاكها بإطفاء المزيد من الرؤوس الراديوية وتقليل الطاقة المستهلكة لتشغيلها والطاقة المستهلكة لنقل البيانات عبر الوصلة الأمامية، هذا وقد تفوقت خوارزمية SA-PSO على HDSO بنسبة وسطية قدرها 33% في السيناريوهات الثلاثة من أجل 500، 1000، 1500 مستخدم ويمكن أن نعلل ذلك بعدة أسباب منها عدم دخول استهلاك الطاقة كعامل مؤثر في حساب تابع الجدوى ضمن خوارزمية HDSO وهذا يعني أن الخوارزمية لا تراعي استهلاك الطاقة عند تخصيص الموارد. من ناحية ثانية، تقلل SA-PSO من استهلاك الطاقة وذلك عن طريق تقليل عدد الرؤوس الراديوية المستخدمة واستغلال الموارد المتاحة بشكل أكبر وذلك بسبب اعتماد خوارزمية اختيار رؤوس راديوية ذكية تستكشف فضاء البحث وصولاً إلى حل قريب من المثالية Global Optima [14]، مع تقليل عدد الرؤوس الراديوية المستخدمة يقل عدد الوصلات الأمامية بين الرؤوس الراديوية ووحدات المعالجة السحابية وبالتالي ينخفض استهلاك الطاقة الكلي.

الاستنتاجات والتوصيات:

في الختام، درسنا أداء خوارزميات إدارة الموارد في شبكات النفاذ إلى الراديو السحابية، فقارنا أداء خوارزمتي SA-PSO و HDSO، وقد أظهرت النتائج أن الخوارزمية الذكية قادرة على تحسين عملية تخصيص الموارد والوصول إلى إدارة موارد ذكية فعالة قادرة على التكيف مع تغير حركة بيانات المستخدمين خلال فترات اليوم أو ما يعرف بـ Tidal Effect متفوقة على الخوارزمية التقليدية HDSO بمعدل 13.81 % في ساعات انخفاض حركة

البيانات، وبمعدل 14.36% في ساعات الذروة، مع المحافظة على جودة الخدمة، وتقليل استهلاك الطاقة بمعدل 33%. يزداد الفرق في أداء الخوارزميتين خلال ساعات الذروة وتبدي الخوارزميات الذكية مرونة أكبر وقدرة على التعامل مع مشاكل التحسين المعقدة ذات الطبيعة الديناميكية المتغيرة بكفاءة أعلى مما يجعلها مناسبة لعملية إدارة الموارد في شبكات النفاذ إلى الراديو السحابية حتى الهجينة منها، كما استطاعت الخوارزميات الذكية أن تقلل متوسط عدد الرؤوس الراديوية المستخدمة وحقت نتائج أفضل في عدة سيناريوهات ومن أجل حمولة بيانات متزايدة وأعداد مستخدمين 500، 1000، 1500.

نقترح بناء على ما سبق دراسة استخدام الخوارزميات الذكية بشكل أوسع في معالجة ودراسة مشكلات تخصيص أخرى كمسألة توزيع وحدات معالجة النطاق الأساسي BBU على الآلات الافتراضية VMs ضمن مراكز البيانات السحابية أو تخصيص الذاكرة والمعالجات في تجمع BBU pool، كما نقترح أيضاً استخدام خوارزميات التعلم الآلي لتحسين أداء خوارزمية SA-PSO من خلال التنبؤ بحركة بيانات ومتطلبات المستخدمين كاستخدام الشبكات العصبونية وشجرة القرار، على أن يترافق هذا الأمر مع تسريع زمن تنفيذ الخوارزمية من خلال تحويلها إلى مجموعة من مشكلات التحسين الصغيرة الجزئية التي يتم حلها بالتدرج.

References:

- [1] Shi Y, Cheng J, Zhang J, Bai B, Chen W, Letaief KB. Smoothed L_p -minimization for green cloud-RAN with user admission control. *IEEE Journal on Selected Areas in Communications*. 2016 Mar 24;34(4):1022-36.
- [2] Checko A, Christiansen H, Berger MS. Evaluation of energy and cost savings in mobile Cloud RAN. In *Proceedings of OPNETWORK Conference 2013 Nov* (p. 8).
- [3] Sigwele T, Hu YF, Susanto M. Energy-efficient 5G cloud RAN with virtual BBU server consolidation and base station sleeping. *Computer Networks*. 2020 Aug 4;177:107302.
- [4] Barahman M, Correia LM, Ferreira LS. A QoS-demand-aware computing resource management scheme in cloud-RAN. *IEEE Open Journal of the Communications Society*. 2020 Oct 29;1:1850-63.
- [5] [www.mathworks.com](https://www.mathworks.com/discovery/what-is-matlab.html#:~:text=MATLAB). (n.d.). *What Is MATLAB?* [online] Available at: <https://www.mathworks.com/discovery/what-is-matlab.html#:~:text=MATLAB> [Accessed 25 Jan. 2023].
- [6] Fakhri ZH, Khan M, Sabir F, Al-Raweshidy HS. A resource allocation mechanism for cloud radio access network based on cell differentiation and integration concept. *IEEE transactions on network science and engineering*. 2017 Oct 17;5(4):261-75.
- [7] Chen L, Liu L, Fan X, Li J, Wang C, Pan G, Jakubowicz J. Complementary base station clustering for cost-effective and energy-efficient cloud-RAN. In *2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI) 2017 Aug 4* (pp. 1-7). IEEE.
- [8] Wang K, Zhou W, Mao S. On joint BBU/RRH resource allocation in heterogeneous cloud-RANs. *IEEE Internet of Things Journal*. 2017 Feb 7;4(3):749-59.
- [9] Ari AA, Gueroui A, Titouna C, Thiare O, Aliouat Z. Resource allocation scheme for 5G C-RAN: a Swarm Intelligence based approach. *Computer Networks*. 2019 Dec 24;165:106957.

- [10] Adiraju PR, Rao VS. Dynamically Energy-Efficient Resource Allocation in 5G CRAN Using Intelligence Algorithm. EMITTER International Journal of Engineering Technology. 2022 Jun 26:217-30.
- [11] Jaber M, Owens D, Imran MA, Tafazolli R, Tukmanov A. *A joint backhaul and RAN perspective on the benefits of centralised RAN functions*. In 2016 IEEE International Conference on Communications Workshops (ICC) 2016 May 23 (pp. 226-231). IEEE.
- [12] Ejaz W, Sharma SK, Saadat S, Naeem M, Anpalagan A, Chughtai NA. *A comprehensive survey on resource allocation for CRAN in 5G and beyond networks*. Journal of Network and Computer Applications. 2020 Jun 15;160:102638.
- [13] Eberhart R, Kennedy J. A new optimizer using particle swarm theory. In MHS'95. Proceedings of the sixth international symposium on micro machine and human science 1995 Oct 4 (pp. 39-43). Ieee.
- [14] Kirkpatrick S, Gelatt Jr CD, Vecchi MP. Optimization by simulated annealing. science. 1983 May 13;220(4598):671-80.
- [15] Han F, Zhao S, Zhang L, Wu J. Survey of strategies for switching off base stations in heterogeneous networks for greener 5G systems. IEEE Access. 2016 Aug 10;4:4959-73.