

Optimizing 5G Deployment in Resource-Constrained Environments: A Real-World Multi-Criteria Optimization Study Using GA and PSO

تحسين تخطيط نشر الجيل الخامس في البيئات محدودة الموارد: دراسة تحسين متعددة المعايير قائمة على بيانات PSO و GA واقعية باستخدام خوارزميتي

ياسر المفعلااني : مصطفى الدقاق المعهد العالي للعلوم التطبيقية والتكنولوجيا، دمشق_سورية

د.كادان الجمعة: الجامعة السورية الخاصة، دمشق_سورية

عنوان التواصل: kadan.aljoumaa@spu.edu.sy - Mustapha.dakkak@hiast.edu.sy - yasser.almofaalani@hiast.edu.sy

تاريخ التسليم: ٢١ أيار ٢٠٢٦ - تاريخ القبول: ٨ تموز

ABSTRACT

This paper presents a comprehensive and practical optimization framework for the phased integration of fifth generation (5G) cellular networks over existing heterogeneous infrastructures (2G/3G/4G), utilizing the Syrian national cellular network as a large-scale real-world case study. The research is built upon a massive operational dataset collected, integrated, and geolocalized from the main network operators (Syriatel and MTN) after undergoing extensive preprocessing, cleaning, and geospatial filtering. The primary contribution lies in formulating the multi-criteria optimization problem into a unified scalar objective function using the Weighted Sum Scalarization method and designing and developing two parallel metaheuristic optimization algorithms to solve it: a proposed Adaptive Genetic Algorithm (AGA) and a proposed Binary Particle Swarm Optimization (BPSO), incorporating a robust mathematical constraint repair mechanism. The evaluation framework focuses on three crucial conflicting objectives: maximizing population coverage, minimizing capital expenditure (CAPEX), and optimizing annual energy consumption. Both models were evaluated on a real-world dataset containing over 79,000 active cellular sites (cells). Empirical results demonstrate that BPSO achieves superior performance in computational convergence speed, running 16% faster than AGA, and provides better annual energy savings. Conversely, AGA demonstrates higher statistical stability and lower standard deviation of solutions across multiple randomized runs. These findings validate the proposed approaches as highly effective, reliable decision-support tools for strategic network planning in developing countries with restricted capital budgets, aligning perfectly with recent ITU standards and 5G-Advanced specification.

Keywords: Network Planning, Advanced 5G, Adaptive Genetic Algorithm (AGA), Particle Swarm Optimization (PSO), Multi-Criteria Optimization, Energy Efficiency, Algorithm Comparison

المخلص

تقدم هذه الدراسة إطاراً منهجياً وعملياً متكاملًا لتخطيط دمج شبكات الجيل الخامس (5G) بشكل تدريجي ضمن البنى التحتية الخلوية غير المتجانسة القائمة (2G/3G/4G)، مع اعتماد الشبكة الخلوية الوطنية في الجمهورية العربية السورية كحالة دراسية واقعية تطبيقية. يستند البحث إلى قاعدة بيانات تشغيلية ضخمة واسعة النطاق تم جمعها وتوحيدها ودمجها جغرافياً من مشغلي الاتصالات الرئيسيين (سيريئل و MTN)، وذلك بعد إخضاعها لعمليات تنظيف ومعالجة مكانية مكثفة. تكمن المساهمة الأساسية لهذه الدراسة في صياغة مسألة التحسين متعدد المعايير كدالة هدف موحدة باستخدام أسلوب المجموع الموزون (Weighted Sum Scalarization)، وتصميم وتطوير خوارزميتين تحسينيتين متوازيتين لحلها: الخوارزمية الجينية التكيفية المقترحة (AGA) وخوارزمية سرب الجسيمات الثنائية المقترحة (BPSO)، مع دمج آلية رياضية فعالة لإصلاح القيود الهندسية والتشغيلية المباشرة. يركز إطار المقارنة الشامل على ثلاثة أهداف استراتيجية رئيسية متناقضة: تعظيم نسبة التغطية الجغرافية السكانية، وتقليل التكاليف الاستثمارية الرأسمالية (CAPEX)، وتحسين كفاءة استهلاك الطاقة. تم تطبيق كلا النموذجين واختبارهما عملياً على قاعدة بيانات حقيقية تتجاوز 79,000 خلية شبكية

نشطة. أظهرت النتائج التجريبية تقوفاً واضحاً لخوارزمية سرب الجسيمات الثنائية (BPSO) في سرعة التقارب الحسابي بنسبة 16% وكفاءة توفير الطاقة السنوية، بينما أظهرت الخوارزمية الجينية التكيفية (AGA) انحرافاً معيارياً أقل وموثوقية أكبر في تكرار النتائج عبر التشغيلات العشوائية المتعددة. تؤكد هذه النتائج فاعلية المنهجية المقترحة كأداة هندسية موثوقة لدعم اتخاذ القرار وتخطيط الترتيبات الشبكية في البيئات النامية ذات الموارد والتمويل المحدود، بما يتوافق بالكامل مع معايير الاتحاد الدولي للاتصالات (ITU) ومواصفات الجيل الخامس المتقدم (5G-Advanced).

الكلمات المفتاحية: تخطيط شبكات، الجيل الخامس المتقدم، الخوارزمية الجينية التكيفية، خوارزمية سرب الجسيمات، التحسين متعدد المعايير، كفاءة الطاقة، المقارنة الخوارزمية.

المقدمة

في السنوات الأخيرة، يشهد قطاع الاتصالات الخلوية نمواً متسارعاً في حجم البيانات والطلب على الخدمات الرقمية المتقدمة، مدفوعاً بالانتشار الواسع لتطبيقات النطاق العريض، وظهور متطلبات جديدة مثل الاتصالات فائقة الاعتمادية منخفضة الكمون (URLLC)، بالإضافة إلى التوسع الكبير في إنترنت الأشياء (IoT) [1, 10]. في هذا السياق، لم تعد شبكات الجيل الرابع (LTE/4G) قادرة بمفردها على تلبية هذه المتطلبات المتزايدة، مما يجعل الانتقال إلى شبكات الجيل الخامس (5G) ضرورة تقنية واستراتيجية. ومع ذلك، فإن استبدال البنية التحتية الحالية بشكل كامل (Greenfield Deploy-ment) يُعد خياراً مكلفاً وصعب التطبيق، خاصة في الدول النامية التي تمتلك استثمارات كبيرة في الشبكات القائمة. لذلك، تتجه شركات الاتصالات إلى اعتماد أسلوب الترقية التدريجية، خصوصاً من خلال نموذج المعمارية غير المستقلة (Non-Standalone - NSA) [2, 3]، الذي يسمح بتشغيل خدمات الجيل الخامس اعتماداً على البنية الأساسية لشبكات الجيل الرابع القائمة. في الحالة السورية، تزداد هذه التحديات تعقيداً بسبب الطبيعة غير المتجانسة لتوزيع الشبكة الخلوية، حيث تتداخل مناطق ذات كثافة حضرية عالية مع مناطق ريفية واسعة ومتباعدة. إضافة إلى ذلك، تواجه عملية التخطيط قيوداً مالية وتشغيلية واضحة ناجمة عن الأوضاع الاقتصادية، مما يجعل قرارات ترقية المواقع الخلوية عملية حساسة تتطلب توازناً دقيقاً بين الكلفة والعائد [8]، [9]. في مجال حل مسائل التحسين الشبكي المعقدة، تبرز خوارزمتان ما وراء تجريبيتان (Meta-heuristic) رئيسيتان: الخوارزمية الجينية (GA) المستوحاة من التطور البيولوجي، وخوارزمية سرب الجسيمات (PSO) المستوحاة من السلوك الاجتماعي للأسراب [26, 30]. كلتا الخوارزمتين أثبتتا فعاليتهما في مسائل التحسين الكبيرة، غير أن مقارنتهما المنهجية في سياق تخطيط شبكات 5G الحقيقية لا تزال حاجة بحثية غير مُستوفاة. انطلاقاً من هذه التحديات، تقدم هذه الدراسة إطاراً متكاملاً يجمع بين التحليل البياني واسع النطاق والنمذجة الرياضية المتقدمة، بهدف دعم قرارات التخطيط المرحلي لشبكات الجيل الخامس في سوريا. وتعتمد الدراسة على تطبيق كلتا الخوارزمتين على نفس مجموعة البيانات الحقيقية، وإجراء مقارنة أداء منهجية وشاملة بينهما عبر ثلاثة محاور: التغطية، والتكلفة، وكفاءة الطاقة [7].

حدود الدراسة

تتلخص حدود الدراسة الحالية في النقاط التالية: (1) تركز الدراسة على نموذج شبكات الجيل الخامس غير المستقلة (NSA) المعتمد على ترقية البنية التحتية القائمة للجيل الرابع (4G)، ولا تشمل تخطيط نشر الشبكات المستقلة بالكامل (SA) التي قد تتطلب بناء مواقع جديدة بالكامل. (2) تعتمد دالة الهدف على أوزان تم ضبطها بالتعاون مع مهندسي التخطيط لدى المشغلين بما يعكس الأولويات

التشغيلية الفعلية، في حين أن أي تغيير في هذه الأوزان قد يفرز حلولاً مختلفة. (3) تفترض النمذجة الحالية متطلبات حركة مرور (Traffic Demand) ثابتة بناءً على البيانات التاريخية، دون محاكاة التغيرات الديناميكية الآنية. (4) أخيراً، ونظراً لاتفاقيات السرية وحقوق الملكية الخاصة بالمشغلين، فإن البيانات التشغيلية حصرية لهم وتخضع لاتفاقيات سرية ولا يمكن نشرها أو مشاركتها للتحقق العلمي المباشر.

الدراسات السابقة

شهدت أبحاث تخطيط شبكات الجيل الخامس (5G) تطوراً ملحوظاً خلال السنوات الأخيرة، حيث انتقلت من التركيز على الجوانب النظرية الأساسية إلى تطوير نماذج تحسين متقدمة تأخذ بعين الاعتبار القيود الواقعية للشبكات الحديثة. ويمكن تصنيف هذه الدراسات ضمن أربعة محاور رئيسية:

1. الدراسات المبكرة التي ركزت على فهم الخصائص الأساسية لانتشار الإشارة.
 2. دراسات تخطيط السعة وتلبية الكثافة المرورية للبيانات.
 3. نماذج ترشيد استهلاك الطاقة والاستدامة البيئية في الشبكات.
 4. خوارزميات التحسين الذكي متعدد المعايير لنشر المحطات.
- ركزت الدراسات المبكرة (المحور الأول) على فهم الخصائص الأساسية لانتشار الإشارة في الترددات العالية وتأثير العوائق الفيزيائية على جودة الخدمة، مستخدمة نماذج هندسية تقليدية لتقدير الخسارة في المسار (Path Loss). ومع ذلك، افترقت تلك النماذج إلى المرونة الكافية للتعامل مع تغيرات الحركة المرورية الديناميكية، فقد تناولت أعمال مثل دراسة Jeffrey G. Andrews وزملائه [10] طبيعة شبكات 5G والتحديات المرتبطة بها، بينما قدمت أبحاث Theo-dore S. Rappaport [11] توصيفاً دقيقاً لخصائص الانتشار في النطاقات المليمترية (mmWave)، والتي تُعد من الركائز الأساسية لزيادة السعة في شبكات الجيل الخامس. وقد وُفّر نموذج 3GPP للقناة الراديوية [4] الأساس التقني القياسي لنمذجة خسائر المسار في نطاقات الترددات من 0.5 إلى 100 غيغاهرتز. كما ساهمت دراسات Afif Osseiran [12] و Francesco Boccardi [13] و Ian F. Akyildiz [14] في تطوير الرؤية العامة لشبكات الجيل الخامس، حيث أكدت على أن الانتقال إلى 5G لا يقتصر على تحسين الأداء، بل يتطلب إعادة التفكير في بنية الشبكة بشكل شامل، بما يشمل تقنيات تقسيم الشبكة (Network Slicing) [15] وحوسبة الحافة [16] (MEC). ورغم الأهمية الكبيرة لهذه الأعمال، إلا أنها اعتمدت في الغالب على نماذج هندسية مبسطة وافتراسات مثالية، مما يحد من قابليتها للتطبيق المباشر في البيئات الواقعية المعقدة [4]. ومع ازدياد تعقيد مسألة تخطيط الشبكات، توجهت العديد من الدراسات إلى استخدام نماذج التحسين الرياضي، وخاصة البرمجة

صياغة نموذج رياضي يأخذ بعين الاعتبار ثلاثة أهداف متعارضة — تعظيم التغطية، تقليل التكاليف الاستثمارية (CAPEX)، وتحسين كفاءة استهلاك الطاقة — ضمن إطار موحد وقابل للتطبيق عملياً مع قيود الميزانية والطاقة [21].

- تطبيق وتقييم خوارزميتين مستقلتين (GA و PSO): يُعد هذا البحث من الدراسات القليلة التي تُطَبِّقُ كلا من الخوارزمية الجينية التكيفية وخوارزمية سرب الجسيمات الثنائية [26]، [29] على نفس مجموعة البيانات الحقيقية الواسعة لشبكات 5G، مع إجراء مقارنة أداء منهجية وشاملة بين أدائهما.
- دراسة مقارنة شاملة على بيانات حقيقية: تم اختبار كلا النموذجين وفق سيناريوهات اختبار مختلفة، مع مقارنة منهجية مع أساليب مرجعية [17]، [19]، مما يثبت كفاءة النماذج المقترحة.

المواد والطرائق

تعتمد هذه الدراسة على قاعدة بيانات تشغيلية حقيقية للمواقع الخلوية النشطة في الجمهورية العربية السورية، تم جمعها وتوحيدها في عام 2024 بالتعاون المباشر مع مشغلي الاتصالات الخلوية الرئيسيين (سيريتل و MTN). ونظراً للأهمية الاستراتيجية والأمنية الفائقة لمواقع وعناوين محطات الاتصالات الخلوية الوطنية، وتماشياً مع اتفاقيات عدم الإفصاح (NDAs) الموقعة تحت إشراف المعهد العالي للعلوم التطبيقية والتكنولوجيا (HIAST)، فإن هذه البيانات تعتبر سرية وحصرية بالكامل لمشغلي الخدمة ولا يمكن تزويد الباحثين بنسخة منها أو إتاحتها للعامة بأي شكل من الأشكال. ولذلك، تم تنفيذ كافة التجارب وتطبيق خوارزميات التحسين والمحاكاة مباشرة على بيانات العمل ومخدمات شركتي الاتصالات (MTN وسيريتل) دون نقل أو استخراج أي بيانات خام خارج نطاقها الآمن لضمان الامتثال التام للأنظمة الأمنية المعتمدة. تتضمن البيانات خصائص هندسية وتشغيلية لكل موقع، مثل الإحداثيات الجغرافية، وارتفاع الهوائيات، وبعض المعلومات الفنية المرتبطة بالتغطية، وفق إطار نموذج القناة الراديوية المعتمد في [4] 3GPP، وقد تم استخدام هذه البيانات كأساس لبناء نموذج التخطيط المقترح. ونظراً لطبيعة البيانات المجمعة من مصادر متعددة، فقد احتوت على اختلافات في التنسيق وبعض القيم غير المكتملة أو غير الدقيقة. لذلك، تم تنفيذ عملية تنظيف بيانات شاملة تضمنت:

- توحيد أسماء الحقول والمعايير المستخدمة بين المشغلين
- تصحيح القيم غير المنطقية أو الناقصة
- التأكد من دقة الإحداثيات الجغرافية وتوافقها مع الحدود الإدارية السورية
- إزالة التكرارات والسجلات غير الصالحة

ساهمت هذه الخطوات في تحسين جودة البيانات وجعلها مناسبة للاستخدام في نماذج التحسين. ومن أجل ضمان أعلى معايير الدقة في التحليل المكاني، خضعت مجموعة البيانات الأولية لسلسلة من المعالجات الجغرافية المتقدمة. تم أولاً توحيد الإسناد المكاني لجميع المواقع الخلوية باستخدام نظام الإحداثيات الجغرافي العالمي (WGS 1984 UTM Zone 37N) المناسب للمنطقة السورية، لضمان أعلى دقة ممكنة في حسابات المسافات ومساحات التغطية الراديوية. ثم تم تنفيذ عمليات التصفية والتحليل المكاني بالاعتماد على بيئة برمجيات نظم المعلومات الجغرافية المتقدمة (ArcGIS Pro) حيث استُخدمت أداة الربط المكاني (Spatial Join) لمقاطعة إحداثيات المحطات الخلوية مع طبقة مضلعات الحدود الإدارية الرسمية للمحافظات والمناطق السورية، مما أتاح التصفية التلقائية واستبعاد أي نقاط شاذة (Outliers) أو بيانات مسجلة بخطاء بشري تقع خارج النطاق الجغرافي المدروس. ولمعالجة التحديات المرتبطة

الصحيحة المختلطة (MILP)، لما توفره من دقة في تمثيل القيود مثل التكاليف والسعة. على سبيل المثال، قدمت دراسة Lei Zhao [17] نموذجاً فعالاً لتخطيط نشر محطات 5G مع مراعاة الكلفة، in حين اقترح Pacheco [19] و Pedrosو نهجاً ثنائي المرحلة لنشر محطات الاتصال الأساسية في الشبكات غير المتجانسة. إلا أن هذه النماذج تواجه تحديات عملية كبيرة عند تطبيقها على نطاق واسع، بسبب ما يُعرف بالانفجار التركيبي، حيث يزداد عدد الحلول الممكنة بشكل هائل مع زيادة عدد المواقع. وللتغلب على هذه المشكلة، تم تبني الخوارزميات ما وراء التجريبية (Metaheuristic) مثل الخوارزميات الجينية (GA) [31] وخوارزميات سرب الجسيمات (PSO) [26, 28]، والتي تتميز بقدرتها على استكشاف فضاءات حلول كبيرة بكفاءة عالية. في هذا السياق، ظهرت النماذج الهجينة كحل واعد يجمع بين مزايا الطريقتين؛ ومن أبرزها عمل [18] Rui J. Silva، الذي دمج بين الخوارزميات التطورية وتقنيات التحسين المقيد، وحقق نتائج متميزة في التوازن بين التغطية والسعة. في مجال تخطيط الشبكات الخلوية وتحسين نشر المحطات، طَبَّقَ Alvi وزملاؤه [27] خوارزمية PSO لاختيار المواقع المثلى للمحطات الخلوية، حيث أظهرت النتائج كفاءة خوارزمية PSO في تحسين تغطية الشبكة وسعة الخلايا مقارنة بالطرق التقليدية. في هذا الإطار، تشير تقارير International Telecommuni-cation Union (ITU) [5, 6] 3rd Generation Partnership Project إلى أهمية دمج مفاهيم مثل: كفاءة الطاقة (Energy Efficiency) [21, 22]

- الأتمتة باستخدام الذكاء الاصطناعي [22]
- التقسيم الديناميكي للشبكة (Network Slicing) [15, 23, 25]
- الحوسبة الطرفية متعددة الوصول (Multi-Access Edge Computing - MEC) [16]

كما تؤكد تقارير [9] GSMA و [8] Ericsson أن استراتيجيات النشر في الدول النامية ستعتمد بشكل أساسي على الترقية التدريجية للبنية التحتية الحالية، وليس الاستبدال الكامل. ويتوافق هذا التوجه مع متطلبات إدارة حركة المرور التكيفية التي ناقشها Guo و [24] Xie في سياق تخطيط شبكات 5G/6G. وعلى الرغم من التقدم الكبير في هذا المجال، لا تزال هناك فجوة واضحة في الدراسات التي تجمع بين الأهداف الثلاثة في آنٍ واحد:


- تعظيم التغطية
- تقليل التكلفة
- تحسين استهلاك الطاقة

ضمن نموذج تحسين موحد وقابل للتطبيق على بيانات حقيقية واسعة النطاق، خاصة في البيئات متعددة المشغلين. علاوة على ذلك، تقتصر الأدبيات إلى مقارنات منهجية موثوقة بين GA و PSO في سياق تخطيط شبكات 5G الحقيقية، لا سيما في البيئات ذات الموارد المحدودة كالسياق السوري. فمعظم الدراسات إما تركز على النماذج النظرية، أو تعتمد على بيانات محاكاة [17, 18, 19]. لذلك، تبرز الحاجة إلى تطوير إطار عملي يدمج هذه العوامل بشكل متوازن وواقعي. تقدم هذه الدراسة إطاراً متكاملاً لتخطيط الترقية المرحلية لشبكات الجيل الخامس في بيئات متعددة الأجيال، مع تطبيق عملي على الشبكة الخلوية السورية. ويمكن تلخيص أهم مساهماتها فيما يلي:

- بناء قاعدة بيانات تشغيلية موحدة واسعة النطاق: تم تطوير خط معالجة بيانات متكامل لدمج وتنظيف بيانات حقيقية من عدة أجيال شبكية (2G/3G/4G) ولمشغلين مختلفين (MTN وسيريتل)، مما أتاح إنشاء قاعدة بيانات موثوقة تتجاوز 79,000 موقع خلوي وتدعم اتخاذ القرار على مستوى وطني [8]، [9].
- تطوير نموذج تحسين متعدد المعايير ذي قيود واقعية: تمت

المستقلة [3] Non-Standalone (NSA). ثم بعد الانتهاء من جميع مراحل المعالجة، تم الحصول على قاعدة بيانات نظيفة تضم أكثر من 79,000 موقع خلوي. وتشمل هذه البيانات توزيعاً واسعاً عبر الأجيال المختلفة والمشغلين، مما يوفر أساساً واقعياً لتطبيق نماذج التحسين المقترحة وإجراء المقارنات الأدائية بينها. كما تم اعتماد مواقع الجيل الرابع كمرشحين أساسيين لعمليات الترقية، نظراً لكونها تمثل البنية التحتية الأكثر جاهزية لدعم تقنيات الجيل الخامس وفق معايير [3]، [2] 3GPP. (انظر الشكل 1) الذي يوضح توزيع السجلات الشبكية حسب المشغل والجيل التقني.

بالتداخل المكاني (Spatial Overlap) أو التوافق شبه التام في إحداثيات بعض المواقع الموروثة (Co-located sites) بين أجيال (2G/3G)، تم تطبيق خوارزميات التجميع المكاني (Spatial Clustering) لدمج المواقع التي تقع ضمن مسافة تسمح (Tolerance) ضئيلة جداً، وتوحيد سجلاتها لتفادي التكرار الحسابي وتضخم التكاليف ضمن دالة الهدف الخاصة بالنموذج. سمح هذا التنظيم المكاني الموحد والموثوق للبيانات بإجراء تحليل دقيق ومناسب للعمليات. بالإضافة إلى ذلك، تم توحيد توصيف الأجيال التقنية، بحيث تم اعتماد الجيل الرابع (LTE/4G) كقاعدة أساسية للترقية إلى شبكات الجيل الخامس ضمن نموذج المعمارية غير



الشكل ١: توزيع السجلات الشبكية المعتمدة حسب المشغل والجيل التقني

نفترض وجود مجموعة من المواقع الخلوية المرشحة للترقية N ، والتي تمثل بشكل أساسي مواقع الجيل الرابع القائمة. الهدف هو اختيار مجموعة فرعية منها لترقيتها إلى الجيل الخامس بحيث يتم تحقيق أفضل توازن ممكن بين ثلاثة أهداف متعارضة. هذه المسألة تنتمي إلى فئة المسائل NP-hard [17]، مما يجعل الخوارزميات ما وراء التجريبية ضرورة وليس خياراً. نعرف: N : مجموعة المواقع المرشحة للترقية، x_i : متغير قرار ثنائي، حيث: $x_i=1$: إذا تم اختيار الموقع i للترقية. $x_i=0$: خلاف ذلك. يتم تعريف دالة الهدف كمسألة تحسين متعددة المعايير تشمل ثلاثة محاور متكاملة [21]: 1- تعظيم التغطية: تهدف إلى زيادة مساحة التغطية الجغرافية والسكانية عبر الخلايا المختارة. لحساب التغطية، يتم اعتماد نموذج انتشار الإشارة القياسي 3GPP TR 38.901 لتقدير خسارة المسار (Path Loss - PL) كدالة في المسافة d بين الخلية والمستقبل. وتُحسب طاقة الإشارة المستلمة P_{rx} عند أي نقطة بالمعادلة:

وتُرد الإحصائيات التفصيلية لمجموعة البيانات المستخدمة في الدراسة في الجدول (3).

جدول 3: إحصائيات مجموعة البيانات	
المؤشر	القيمة
إجمالي عدد الخلايا الشبكية (Network Cells)	79,268
عدد خلايا الجيل الثاني (2G (Cells)	21,356
عدد خلايا الجيل الثالث (3G (Cells)	27,902
عدد خلايا الجيل الرابع (4G (Cells) المرشحة للترقية	30,010
عدد المشغلين	2
نسبة المواقع الحضرية	62%
نسبة المواقع الريفية	38%

[1]. بناءً على ذلك، تُصاغ دالة الهدف الموحدة على النحو التالي:

$$\max F = w_1 \cdot \text{Coverage}(X) - w_2 \cdot \text{Cost}(X) - w_3 \cdot \text{Energy}(X)$$

حيث تمثل w_1, w_2, w_3 أوزاناً تعكس الأهمية النسبية لكل هدف ضمن عملية التحسين الموزونة، وتحقق المجموع $w_1 + w_2 + w_3 = 1.0$. تم اختيار هذه الأوزان بالتعاون مع مهندسي التخطيط لدى المشغلين بما يعكس الأولويات التشغيلية الفعلية في بيئات الشبكات محدودة الموارد، حيث أعطيت الأولوية للتغطية $w_1 = 0.5$ ثم للتكلفة $w_2 = 0.3$ ثم لكفاءة الطاقة $w_3 = 0.2$ للحد من النفقات التشغيلية والتعامل مع فترات انقطاع الطاقة الكهربائية وترد القيم العددية لهذه الأوزان وأسس اختيارها في الجدول (16).

جدول 16: معاملات وأوزان دالة الهدف الموزونة

الوصف والمعنى (Description)	القيمة (Value)	الوزن (Weight Coefficient)
وزن التغطية السكانية والجغرافية	0.5	w1
وزن تكاليف النشر الرأسمالية (CAPEX)	0.3	w2
وزن استهلاك الطاقة السنوي	0.2	w3

تخضع عملية التحسين لعدة قيود واقعية [17]، [18]:
• **قيود الميزانية:** يجب ألا تتجاوز الكلفة الإجمالية الميزانية المتاحة

$$\sum_{i \in N} x_i \cdot \text{Cost}_i \leq B$$

• **قيود عدد المواقع:** يمكن فرض حد أعلى K لعدد المواقع التي يمكن ترقية

$$\sum_{i \in N} x_i \leq K$$

• **قيود التغطية الدنيا:** لضمان مستوى خدمة مقبول، يجب تحقيق حد أدنى من التغطية

$$\text{Coverage}(X) \geq c_{\min}$$

بناءً على ما سبق، يمكن توصيف المسألة على أنها:
• مسألة تحسين غير خطية متعددة المعايير [21]
• ذات متغيرات ثنائية (Binary Decision Variables)
• تنتمي إلى فئة المسائل NP-hard مما يجعل حلها باستخدام الطرق الدقيقة مثل (MILP) [17] غير عملي عند التعامل مع بيانات واسعة النطاق. هنا يأتي دور الخوارزميات ما وراء التجريبية: [31] GA و [26] PSO، كما سيتم توضيحه في القسم التالي [18]، [20]. بسبب الطبيعة المعقدة لمسألة تخطيط ترقية شبكات الجيل الخامس المُصاغة في القسم السابق، تم تطوير وتطبيق خوارزميتين مستقلتين ومقارنة أدائهما بشكل منهجي:
• الخوارزمية الجينية التكيفية (Adaptive Genetic Algorithm -

$$P_{rx}(d) = P_{tx} + G_{tx} + G_{rx} - \text{PL}(d) - L$$

حيث P_{tx} هي طاقة الإرسال، و G_{tx} و G_{rx} هما كسب الهوائيات، و L هي الخسائر المتنوعة. وتعتبر النقطة z مغطاة بالخلية i إذا كانت $P_{rx} \geq P_{\text{threshold}}$ ، حيث تم تحديد عتبة الحساسية الدنيا للمستقبل عند $P_{\text{threshold}} = -100 \text{ dBm}$. يتم حساب التغطية الجغرافية الإجمالية كنسبة مئوية من اتحاد مساحات التغطية الفردية للخلايا النشطة:

$$\text{Coverage}_{\text{geo}}(X) = \frac{\text{Area} \left(\bigcup_{i: x_i=1} A_i \right)}{\text{Total Area}}$$

حيث A_i هي مساحة تغطية الخلية i . ولتجنب تكرار حساب المناطق المتداخلة، يتم حساب اتحاد المساحات مما يضمن معالجة تداخل التغطية تلقائياً. وبالمثل، تُحسب التغطية السكانية بنسبة مئوية للسكان المغطيين في شبكة الخلايا السكنية الموزعة:

$$\text{Coverage}_{\text{pop}}(X) = \frac{\sum_j \left(\text{Pop}_j \cdot \mathbb{I}(\exists i \text{ s.t. } x_i = 1 \text{ and } d_{ij} \leq R_i) \right)}{\text{Total Population}}$$

حيث Pop_j هو عدد السكان في الخلية الشبكية j و $\mathbb{I}(\cdot)$ هي دالة مؤشر ثنائية تساوي 1 في حال توفر التغطية من خلية واحدة على الأقل، و 0 خلاف ذلك، مما يضمن حساب السكان المغطيين مرة واحدة فقط بغض النظر عن عدد الإشارات المتداخلة. 2- تقليل الكلفة: تشمل تكاليف الترقية الرأسمالية (CAPEX) لكل موقع، وفق تقديرات مبنية على معطيات السوق السوري [17]. 3- تحسين كفاءة الطاقة: يتم حساب الاستهلاك التشغيلي السنوي المتوقع للطاقة لكل موقع خلوي تمت تربيته للجيل الخامس بالاعتماد على نموذج استهلاك الطاقة الفعلي للمحطة (gNodeB). يتكون الموقع القياسي من وحدة معالجة النطاق الأساسي (BBU) وثلاث وحدات هوائيات نشطة (AAUs). ويُحسب استهلاك الطاقة للموقع بالمعادلة:

$$P_{\text{site}} = P_{\text{BBU}} + 3 \cdot (P_{\text{static AAU}} + \eta \cdot P_{\text{RF}})$$

حيث P_{BBU} هو استهلاك وحدة المعالجة الرقمية (حوالي 350 واط)، و $P_{\text{static AAU}}$ هو استهلاك الهوائي في الحالة الساكنة (حوالي 250 واط)، و P_{RF} هي طاقة الإرسال الراديوي القصوى (حوالي 200 واط)، و η هي نسبة الحمل المتوسط للشبكة (تم ضبطها عند 0.5 لتمثيل ظروف التشغيل المتوسطة). ويتم حساب الاستهلاك السنوي الإجمالي بضرب القدرة الإجمالية بعدد ساعات السنة وتقسيمها على مليون للحصول على الميغاواط الساعي (MWh). ونظراً للمقياس الحسابي، تمثل القيم المبلغ عنها في النتائج (مثل 76.4 و 80.9 MWh) متوسط الاستهلاك السنوي الإجمالي لمجموعة مرجعية معيارية من 10 خلايا نشطة تمت تربيته، وذلك لتوفير مقياس هندسي واضح للمقارنة بين كفاءة الحلول المقترحة. نظراً لاختلاف طبيعة ووحدات القياس بين الأهداف الثلاثة المستهدفة (نسبة مئوية للتغطية، تكلفة مالية بالدولار، طاقة مستهلكة بالميجاواط الساعي (MWh)) لا يمكن دمجها رياضياً بشكل مباشر. لتجاوز هذه المشكلة، تم تطبيق عملية التوحيد القياسي (Normalization) على جميع المتغيرات باستخدام طريقة Min-Max Scaling لتحويلها إلى قيم لا بُعدية (Dimensionless) محصورة ضمن المجال [0, 1].

```

// Initialization
FOR each particle i from 1 to N:
    Initialize random Position (X_i) and Velocity (V_i)
    Evaluate Fitness(X_i) using the Triple Objective Function
    pBest_i = X_i
END FOR

// Determine the initial leader
gBest = Best(pBest_1, ..., pBest_N)

// Main Optimization Loop
FOR t = 1 TO T:
    FOR each particle i from 1 to N:
        // Update kinematics
        Update Velocity (V_i) using the Modified PSO equation
        Update Position (X_i) using the Sigmoid Function (Binary mapping)

        // Constraint Repair Mechanism
        // Handle Budget Constraint
        WHILE (Total_Cost(X_i) > B):
            Find selected site j where x_ij = 1 with the lowest (Coverage/Cost) ratio
            Set x_ij = 0 (Remove site)
        END WHILE

        // Handle Minimum Coverage Constraint
        WHILE (Total_Coverage(X_i) < C_min):
            Add site j (x_ij = 1) that offers highest coverage/cost benefit
        END WHILE

        // Evaluation and Update
        Evaluate Fitness(X_i)
        IF Fitness(X_i) is better than Fitness(pBest_i):
            pBest_i = X_i
        END IF
    END FOR

    // Update Global Best
    gBest = Best(pBest_1, ..., pBest_N)

    // Parameter Adaptation
    Linearly decrease Inertia Weight (ω)
END FOR
RETURN gBest
END

```

[31] (AGA

• خوارزمية سرب الجسيمات الثنائية (Binary Particle Swarm) [26, 29] (Optimization – BPSO) استُخدمت هذه الآلية بنجاح في مسائل تحسين التغطية ونشر المحطات من قبل Alvi وزملائه [27] لاختيار مواقع المحطات الخلوية. في سياق هذه الدراسة، يمثل كل جسيم ناقل ثنائيًا من قرارات الترقية لمواقع الشبكة، ويتحرك عبر فضاء الحل نحو المزيج الأمثل بين التغطية والتكلفة والطاقة. ويوضح الشكل (2) آلية حركة الجسيمات داخل فضاء البحث أثناء عملية التحسين. ونظراً لأن متغيرات القرار ثنائية (0 أو 1)، يتم اعتماد النسخة الثنائية من PSO كما اقترحها Kennedy و Eberhart [26]. يتم تحويل سرعة الجسيم إلى احتمالية باستخدام الدالة اللوجستية (Sigmoid):

$$P(x_i = 1) = \frac{1}{1 + e^{-v_i}}$$

حيث يتم تحديث سرعة وموضع كل جسيم وفق معادلات Shi و Eberhart [29] المُطوّرة:

$$v_i(t+1) = \omega v_i(t) + c_1 r_1 (pBest_i - x_i(t)) + c_2 r_2 (gBest - x_i(t))$$

$$x_i(t+1) = \begin{cases} 1 & \text{if rand() < Sigmoid}(v_i(t+1)) \\ 0 & \text{otherwise} \end{cases}$$


حيث يتناقص معامل القصور الذاتي ω تدريجياً من 0.9 إلى 0.4 عبر التكرارات لتحقيق التوازن بين الاستكشاف والاستغلال [29]. أما تعريف جميع معاملات BPSO المستخدمة في هذه الدراسة فيرد في الجدول (1).

جدول 1: متغيرات خوارزمية BPSO ووصفها	
المتغير	الوصف
ω	معامل القصور الذاتي (Weight Inertia) – يتناقص تدريجياً
c1	معامل التعلم الشخصي (Coefficient Cognitive)
c2	معامل التعلم الاجتماعي (Coefficient Social)
r1, r2	أرقام عشوائية موزعة بشكل منتظم في 0,1
pBest	أفضل موضع سابق للجسيم (ذاكرة فردية)
gBest	الموضع الأمثل العالمي للسرب (ذاكرة جماعية)

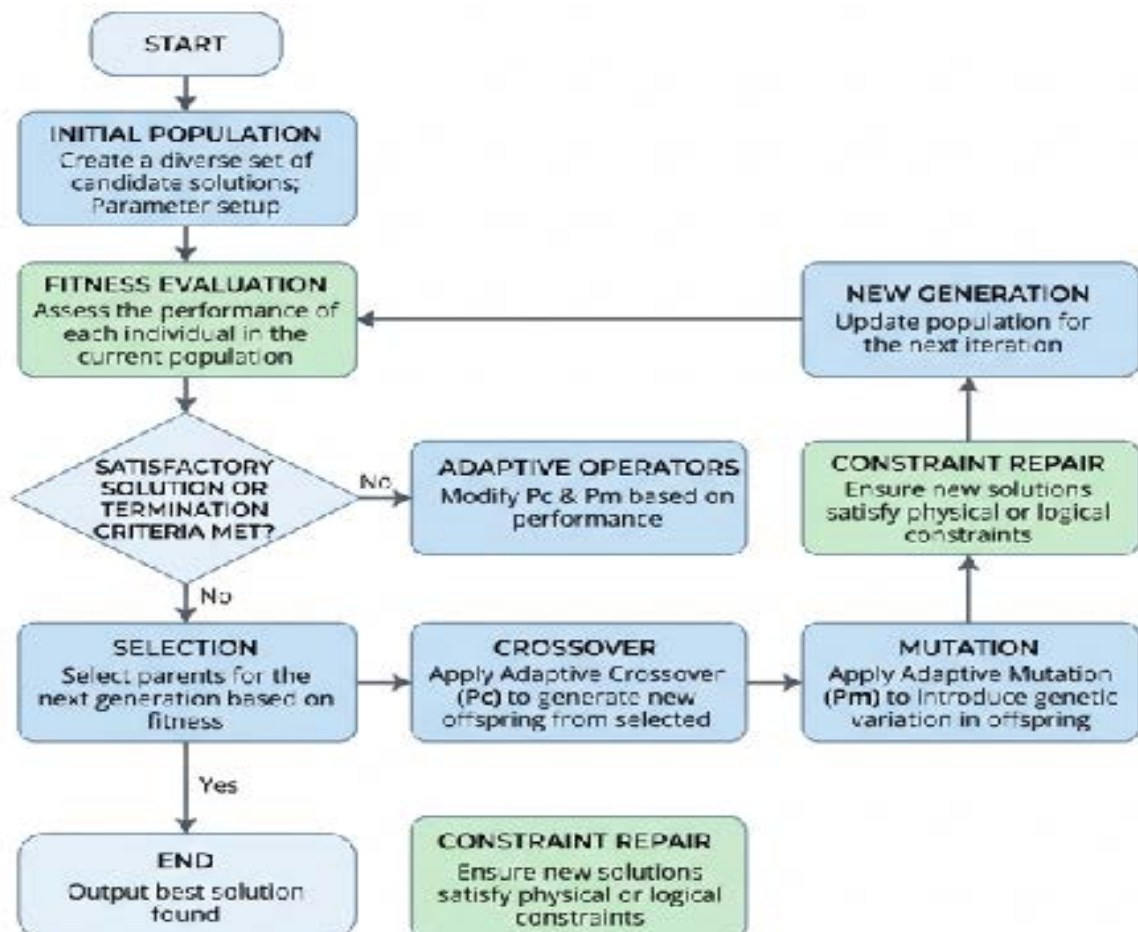
الخوارزمية 1: خوارزمية سرب الجسيمات الثنائية (Binary PSO) [26, 29] المدخلات:

- N : مجموعة المواقع المرشحة
- B : الميزانية المتاحة
- T : عدد التكرارات الأقصى
- S : حجم السرب
- المخرجات:
- gBest : أفضل حل عالمي
- خطوات الخوارزمية:

Algorithm: Modified PSO with Constraint Handling
 Input: Population size (N), Max iterations (T), Budget (B), Minimum Coverage (C_min)
 Output: Global Best solution (gBest)
 BEGIN



الشكل ٢: مفهوم سرب الجسيمات في فضاء تحسين شبكات الجيل الخامس



الشكل ٣: سير الخوارزمية الجينية التكيفية (AGA) ومخططات العمل

- B: الميزانية المتاحة
- T: عدد التكرارات الأقصى
- P: حجم المجتمع (noitalupoP)
- المخرجات:
- أفضل حل X

جدول 4: معاملات الخوارزمية الجينية التكيفية (AGA)	
القيمة	المعامل
150	حجم المجتمع P
300	عدد التكرارات T
0.85	معدل التزاوج
0.08 ← 0.02 تكيفي	معدل الطفرة
(3=k) Tournament	نوع الانتقاء
Two-Point Crossover	نوع التزاوج

خطوات الخوارزمية:

Algorithm: Adaptive Genetic Algorithm with Constraint Handling

Input: Population size (P), Max generations (T), Budget (B), Min Coverage (C_min)

Output: Best Solution (X_best)

BEGIN

// Initialization

Generate initial population of P solutions randomly

Evaluate all solutions using the Triple Objective

Function

// Evolution Loop

FOR t = 1 TO T:

// Selection

Perform Tournament Selection to choose parents

// Reproduction

Apply Crossover to generate offspring

Apply Adaptive Mutation based on population

diversity

// Constraint Repair Mechanism

FOR each new offspring solution:

// Handle Budget Constraint

WHILE (Total_Cost > B):

Identify selected site i where $x_i = 1$ with the lowest (Coverage/Cost) ratio

Set $x_i = 0$ (Deselect site)

END WHILE

// Handle Minimum Coverage Constraint

IF (Total_Coverage < C_min):

Add sites ($x_i = 1$) using a greedy benefit-cost approach until C_min is met

وترد القيم العددية لجميع معاملات تنفيذ خوارزمية BPSO في الجدول (5) تستوحي الخوارزمية الجينية مبدأها من نظرية التطور البيولوجي لداروين، حيث تتطور الحلول عبر أجيال متعاقبة من الانتقاء الطبيعي والتزاوج والطفرة [31]. في هذا البحث، تم تطوير نسخة تكيفية تجمع بين الخوارزمية الجينية وآلية إصلاح القيود (Constraint Repair Mechanism) [18]، لضمان جودة الحلول والالتزام بالقيود الواقعية في آن واحد. كما تعتمد الفكرة الأساسية على تطوير مجموعة من الحلول المرشحة بشكل تدريجي عبر أجيال متعاقبة، مع تعديل معاملات الخوارزمية بشكل ديناميكي أثناء التنفيذ، وتصحيح الحلول غير المقبولة بدلاً من استبعادها. يساهم هذا النهج في تحقيق توازن فعال بين استكشاف فضاء الحلول والالتزام بالصارم بالقيود الواقعية، مما يجعله مناسباً للتطبيق على بيانات واسعة النطاق [20].

جدول 5: معاملات خوارزمية سرب الجسيمات الثنائية (BPSO)	
القيمة	المعامل
150	حجم السرب S
300	عدد التكرارات T
0.4 ← 0.9	معامل القصور الذاتي ω
2.0	معامل التعلم الشخصي c1
2.0	معامل التعلم الاجتماعي c2
6.0	السرعة القصوى max_V

ويوضح الشكل (3) مخطط سير عمل الخوارزمية الجينية التكيفية (AGA). يتم تمثيل كل حل (كروموسوم) كناقل ثنائي [31] $X = [x_1, x_2, \dots, x_N]$ حيث:

• $x_i = 1$: الموقع i سيتم ترقيته.

• $x_i = 0$: الموقع غير مختار.

تعتمد الخوارزمية على مجموعة من العمليات الجينية الأساسية [13]: الانتقاء: يتم اختيار الحلول ذات الأداء الأفضل باستخدام أسلوب الانتقاء بالبطولات (noitceleS tnemanruoT) بحجم $3=k$ التزاوج: يتم دمج حلين باستخدام التقاطع أحادي النقطة (revossorC tniop-elnis) أو ثنائي النقطة (tnioP-owT) لإنتاج حلول جديدة تحمل خصائص الحلين الأبوين [13]. الطفرة: يتم إدخال تغييرات عشوائية بمعدل تكيفي للحفاظ على التنوع وتجنب الوقوع في الحلول المحلية. لتحسين أداء الخوارزمية، يتم اعتماد آلية تكيف ديناميكي لمعدل الطفرة ومعامل التزاوج [81]:

• في المراحل الأولى $t < T/3$: معدل طفرة مرتفع (80.0) لتعزيز الاستكشاف

• في المراحل الوسطى $T/3 \leq t < 2T/3$: تقليل تدريجي

• في المراحل النهائية $t \geq 2T/3$: معدل طفرة منخفض (20.0) لتعزيز الاستقرار

أما القيم العددية لجميع معاملات تنفيذ الخوارزمية الجينية التكيفية فتد في الجدول (٤).

الخوارزمية 2: الخوارزمية الجينية التكيفية الهجينة [13, 81]

المدخلات:

• N: مجموعة المواقع المرشحة

عدد المعاملات	أقل (c1, c2, ω)	أعلى (معدل طفرة، تزاوج، انتقاء)
مقاومة الحلول المحلية	أعلى عبر التنوع الاجتماعي	متوسطة عبر الطفرة
التعقيد الحسابي	(N × S × T) O	(N × P × T) O

END IF
END FOR

// Adaptation and Update
Update Algorithm Parameters (e.g., adjust Adaptive Mutation Rate)
Re-evaluate Fitness for all new solutions

// Environmental Selection
Update Population (Replace old solutions with better offspring – Elitism)
END FOR

// Final Result
RETURN Best Solution (X_best)
END

الجدول 6: سيناريوهات تقييم أداء الخوارزميتين		
السيناريو	عدد المواقع المستهدف	الميزانية
S1	5,000	منخفضة
S2	10,000	متوسطة
S3	15,000	مرتفعة

جدول 7: طرق المقارنة ومراجعتها	
الوصف	الطريقة
الخوارزمية الجينية التكيفية المقترحة مع إصلاح القيود	Proposed AGA (GA + Repair)
خوارزمية سرب الجسيمات الثنائية المقترحة مع إصلاح القيود	Proposed BPSO (PSO + Repair)
خوارزمية جينية تقليدية بدون إصلاح القيود	Standard GA (w/o Repair)
اختيار عشوائي كخط أساس	Random Selection

جدول 8: مقاييس التقييم المستخدمة	
المقياس	الوصف
Coverage(%)	نسبة التغطية الجغرافية
Cost (M\$)	التكلفة الإجمالية بالمليون دولار
Energy (MWh)	استهلاك الطاقة السنوي
Convergence Rate	سرعة التقارب (تكرارات للاستقرار)
Runtime (s)	زمن التنفيذ بالثانية

النتائج

وبالرغم من التفوق الرقمي لـ BPSO في الأداء العام، كشف تحليل الاستقرار الإحصائي المستند إلى 15 تشغيلاً عشوائياً مستقلاً عن تميز الخوارزمية الجينية التكيفية (AGA) بإظهارها انحرافاً معيارياً أقل عبر التشغيلات المتكررة (lower standard deviation across repeated runs) في التغطية (الجدولين 9 و10). مما يشير إلى استقرار أعلى في هذا المؤشر. الجدول (11). ولتقييم ما إذا كانت الفروق بين الخوارزميتين تعكس فروقاً حقيقية أم أنها ناتجة عن التباين العشوائي، تم إجراء اختبار t للعينات المستقلة (Independent t-test) وحساب مجالات الثقة 95% وحجم الأثر بين الخوارزميتين. أظهرت النتائج أن تفوق BPSO في كلٍ من التكلفة المالية واستهلاك

تنوضح الفروق الجوهرية بين الخوارزميتين عند إجراء مقارنة نظرية شاملة مستوحاة من الأدبيات المرجعية [62, 82, 03, 13]؛ حيث تعتمد الخوارزمية الجينية التكيفية (AGA) على آلية تطور الأفراد عبر الأجيال المتعاقبة بالاستعانة بذاكرة جيل السكان الحالي فقط، وتتحكم في فضاء الاستكشاف عبر عمليتي الطفرة والتزاوج محققةً تقارباً متدرجاً وأكثر استقراراً بالرغم من كثرة معاملاتها المتمثلة في معدلات الطفرة والتزاوج ونوع الانتقاء. في المقابل، تبرز خوارزمية سرب الجسيمات الثنائية (OSPB) من خلال حركة الجسيمات الحرة في الفضاء الحسابي بالاعتماد على الذاكرة الفردية $pBest_i$ والذاكرة الجماعية $gBest$ لكل جسيم، مما يمنحها سرعة تقارب عالية في المراحل الأولى وقدرة أكبر على مقاومة الحلول المحلية بفضل التنوع الاجتماعي، فضلاً عن قلة معاملاتها الحسابية مثل معامل القصور الذاتي ومعامل التعلم الشخصي والاجتماعي، حيث يتفوق هذا المنظور المقارن لـ OSPB على AGA من حيث البساطة الحسابية وقلة عدد المعاملات استناداً إلى دراسة gnaY المرجعية [03]. كما تتساوى الخوارزميتان في التعقيد الحسابي البالغ $O(T \times P \times N)$ بالنسبة لخوارزمية AGA، و $O(T \times S \times N)$ بالنسبة لخوارزمية OSPB. مما يشير إلى أن AGA أظهرت انحرافاً معيارياً أقل عبر التشغيلات المتكررة (lower standard deviation across repeated runs) عند إعادة تشغيل الخوارزمية تحت نفس الظروف. ويلخص الجدول (2) المقارنة النظرية الكاملة بين الخوارزميتين، وقد تم تنفيذ جميع التجارب وفق ثلاثة سيناريوهات تقييم مختلفة موضحة في الجدول (6)، كما يوضح الجدول (7) الطرق المرجعية المستخدمة في المقارنة مع الخوارزميات المقترحة، أما مقاييس الأداء المعتمدة في التقييم فتورد في الجدول (8).

جدول 2: مقارنة نظرية بين AGA و BPSO		
المعيار	BPSO سرب الجسيمات	AGA الخوارزمية الجينية
آلية العمل	حركة الجسيمات في الفضاء	تطور الأفراد عبر أجيال
نوع الذاكرة	pBest و gBest لكل جسيم	جيل السكان الحالي فقط
الاستكشاف	عبر التوازن بين c1 و c2	عبر الطفرة والتزاوج
التقارب	أسرع في المراحل الأولى	متدرج وأكثر استقراراً

الجدول 12: مقارنة بين نسبة تغطية كل من الخوارزميتين

الميزانية (\$M)	AGA Coverage (%)	Coverage BPSO (%)
80	88.7	89.4
100	91.9	92.8
120	93.8	94.5
140	94.8	95.1

المناقشة

أما على صعيد الكفاءة الزمنية وإدارة الموارد الحسابية، فقد أثبتت النتائج أن خوارزمية BPSO المقترحة تفوقت في السرعة التشغيلية على AGA؛ حيث استقرت عند زمن متوسط قدره 117.8 ثانية مقابل 142.4 ثانية لـ AGA و 118.6 ثانية لخوارزمية GA التقليدية (انظر الجدول 13). وقد تم قياس هذه الأزمنة بشكل موحد تحت نفس الظروف التشغيلية حيث نُفذت التجارب على المخدمات الخاصة بشركات الاتصالات الخلوية السورية (HP ProLiant DL380 Gen10) المزودة بمعالجات Intel Xeon Gold 6230 (يتردد 2.1 GHz و 20 نواة معالجة فيزيائية لكل معالج)، وبذاكرة عشوائية قدرها 64 GB RAM. وقد تمت برمجة الخوارزميات بالكامل باستخدام لغة Python 3.10 مع مكتبات NumPy الحسابية، وجرى تشغيلها بشكل تسلسلي (Sequential execution) على نواة معالجة واحدة لقياس كفاءة الخوارزميات الحسابية الأساسية دون تأثير المعالجة المتوازية. ويعزى تفوق BPSO الحسابي إلى البساطة الهيكلية للنموذج وقلة عدد معاملاته واعتماده على آلية الذاكرة الجماعية القائمة على القائد (gBest) التي تختصر الخطوات الحسابية، بخلاف AGA التي تستهلك زمناً أطول في عمليات إعادة تقييم المجتمع بأكمله وتنفيذ عمليات العبور والطفرة المتكررة عبر الأجيال، وهو ما ينسجم بصورة عامة مع التحليلات المقارنة للخوارزميات المستوحاة من الطبيعة الواردة في أبحاث Yang المرجعية [30]. تم تنفيذ جميع التجارب ضمن بيئات التخطيط الراديوي التشغيلية المستخدمة فعلياً لدى مشغلي الاتصالات الخلوية في سورية خلال عام 2024، حيث استخدمت منصة Atoll لدى شركة سيريتل ومنصة mPlanet لدى شركة MTN سوريا، وتمثل هذه المنصات أدوات التخطيط الراديوي الرسمية والمعتمدة لدى المشغلين. وقد تم تشغيل الخوارزميات مباشرة ضمن هذه البيئات على البيانات التشغيلية الحقيقية المستخدمة في عمليات التخطيط والتحسين الشبكي.

الجدول 13: زمن التنفيذ المتوسط لكل طريقة

الطريقة	زمن التنفيذ (ثانية)
Proposed BPSO	117.8
Proposed AGA	142.4
Std. GA) w/o Repair(	118.6
Random	25

الاستنتاجات والتوصيات

تمت صياغة المسألة كنموذج تحسين متعدد المعايير باستخدام دالة هدف موزونة ومعالجتها عبر خوارزميتين مستقلتين: AGA و BPSO مع آلية مشتركة لإصلاح القيود [18]. أظهرت النتائج التجريبية المبينة على 79,268 موقعاً خلويًا حقيقياً أن BPSO تتفوق على AGA في:

- **التغطية:** 95.14% مقابل 94.90% (+0.24%)
- **التكلفة:** 130.5 مقابل 139.6 مليون دولار، بعبارة أخرى

الطاقة كان ذا دلالة إحصائية عالية؛ إذ بلغ $p = -9.20$, $t(28) = 0.0001$ < للتكلفة، مع مجال ثقة 95% للفرق بين المتوسطين [-11.13, -7.07] مليون دولار، وحجم أثر كبير جداً ($d = -3.36$). كما أظهرت نتائج استهلاك الطاقة فرقاً ذا دلالة إحصائية ($t(28) = -6.30$, $p < 0.0001$) مع مجال ثقة [-5.96, -3.04] MWh وحجم أثر كبير ($d = -2.30$)، مما يؤكد أن الانخفاض في التكلفة والطاقة الذي حققته BPSO لا يُعزى إلى التباين العشوائي بين التشغيلات. في المقابل، لم يُظهر اختبار t فرقاً ذا دلالة إحصائية في نسبة التغطية ($t(28) = 1.68$, $p = 0.104$)، حيث شمل مجال الثقة 95% للفرق بين المتوسطين القيمة الصفرية [-0.05%, 0.53%]، مما يشير إلى أن أداء الخوارزميتين في تحقيق التغطية متقارب من الناحية الإحصائية. ومع ذلك، فإن الانحراف المعياري الأقل الذي حققته AGA يدل على أن نتائجها كانت أكثر استقراراً واتساقاً عبر التشغيلات المتكررة، رغم عدم وجود فرق معنوي في متوسط نسبة التغطية، ويظهر الجدول (15) نتائج الاختبارات الإحصائية المقارنة بين خوارزميتي BPSO و AGA (بناءً على 15 تشغيلاً مستقلاً)، كما يبين الشكل (4) منحنيات تقارب خوارزميتي AGA و BPSO عبر 300 تكرار، موضحاً سرعة وصول كل خوارزمية إلى الحلول المستقرة، ويعرض الجدول (12) نسبة التغطية المحققة عند مستويات الميزانية المختلفة لكل من AGA و BPSO، ويبين الشكل (5) العلاقة غير الخطية بين الميزانية المرصودة ونسبة التغطية التي تحققها كل من الخوارزميتين.

الجدول 9: نتائج الاستقرار الإحصائي للخوارزمية الجينية (AGA)

المقياس	الانحراف المعياري	المتوسط
Coverage (%)	0.36	94.90
Cost (Million USD)	2.5	139.6
Energy (MWh)	1.8	80.9

الجدول 10: نتائج الاستقرار الإحصائي لخوارزمية سرب الجسيمات (BPSO)

المقياس	الانحراف المعياري	المتوسط
Coverage (%)	0.42	95.14
Cost (Million USD)	2.9	130.5
Energy (MWh)	2.1	76.4

الجدول 11: مقارنة أداء النماذج — النتائج الشاملة للسيناريو S2

الطريقة	Energy (MWh)	Cost (M\$)	Coverage (%)
BPSO (Proposed)	76.4	130.5	95.14
AGA (Proposed)	80.9	139.6	94.90
Std. GA (w/o Repair)	84.1	143.8	94.75
Random Selection	91.5	150.3	88.35

جدول 14: الملخص الشامل لمقارنة AGA و BPSO

المعيار	BPSO	AGA
التغطية	95.14%	94.90%
التكلفة	\$M 130.5	139.6 M\$
كفاءة الطاقة	76.4 MWh	80.9 MWh
سرعة التقارب	أسرع	أبطأ
الاستقرار الإحصائي في التغطية (الانحراف المعياري)	أقل	أعلى
زمن التنفيذ	118 ثانية	142 ثانية

توفير قدره 6.5% ≈


- كفاءة الطاقة: 76.4 مقابل 80.9 MWh أي توفير مقداره 5.5% ≈

- زمن التنفيذ: 118 مقابل 142 ثانية أي أداء أسرع بـ 16%


وبلخص الجدول (14) المقارنة النهائية بين أداء الخوارزميتين في جميع مؤشرات التقييم. في المقابل، أبدت AGA استقراراً إحصائياً أعلى عبر التشغيلات المتعددة (انحراف معياري أقل)، مما يجعلها خياراً مناسباً للتطبيقات ذات الحساسية العالية للتكرارية والموثوقية [31]، وعليه تشير هذه النتائج إلى إمكانية تحقيق تقدم وظيفي وتوفير مالي كبير في خطط الاستحداث والترقية للشبكات ضمن بيئات محدودة الموارد واعتماداً على مناهج التحسين المتقدمة، وذلك وفق معايير ITU [5, 6] و 3GPP [1, 7].

جدول 15: نتائج الاختبارات الإحصائية المقارنة بين خوارزميتي BPSO و AGA بناءً على 15 تشغيلاً مستقلاً

المقياس (Metric)	قيمة اختبار t	درجات الحرية (df)	القيمة الاحتمالية (p-value)	مجال الثقة 95% للفرق	حجم الأثر (Cohen's d)	الدالة الإحصائية
التغطية السكانية الجغرافية (%)	1.68	28	0.104	[-0.05%, 0.53%]	0.61	غير دالة إحصائياً عند مستوى 5%
التكلفة الإجمالية (مليون دولار)	-9.20	28	< 0.0001	[-11.13, -7.07]	-3.36	دالة إحصائياً بشكل كبير لصالح BPSO
استهلاك الطاقة السنوي (MWh)	-6.30	28	< 0.0001	[-5.96, -3.04]	-2.30	دالة إحصائياً بشكل كبير لصالح BPSO



الشكل 4: مقارنة منحنيات التقارب بين AGA و BPSO عبر 300 تكرار



شكل ٥: العلاقة غير الخطية بين الميزانية المرصودة ونسبة التغطية المحققة لـ BPSO و AGA

[2] (SA) ومتطلباته التخطيطية المختلفة عن NSA.

- تحسين أداء كلتا الخوارزميتين باستخدام الحوسبة الموازية (Parallel Computing) لمعالجة مجموعات بيانات أضخم والوصول إلى نتائج أسرع.
- استكشاف خوارزميات بديلة مثل خوارزمية المستعمرة النملية (ACO) [30] وخوارزمية التبريد المحاكى (Simulated Annealing) للمقارنة الموسعة.
- تطبيق الإطار على شبكات دول نامية أخرى ذات بنية تحتية مشابهة للتحقق من قابلية التعميم [9].

بيان توفر البيانات

تم تنفيذ الدراسة على بيانات تشغيلية حقيقية تخص مشغلي الاتصالات الخلوية في سورية خلال عام 2024. ونظراً لاتفاقيات السرية وحقوق الملكية الخاصة بالمشغلين، لا يمكن نشر البيانات الخام أو مشاركتها. وقد تم تنفيذ الخوارزميات مباشرة ضمن بيئات التخطيط التابعة للمشغلين دون الحصول على نسخ مستقلة من قواعد البيانات. كما أن المؤلفين لم يحصلوا على نسخ مستقلة من قواعد البيانات التشغيلية الخاصة بالمشغلين.

شكر وتقدير

يتوجه المؤلفون بخالص الشكر والتقدير إلى المعهد العالي للعلوم التطبيقية والتكنولوجيا (HIAST) بدمشق على تقديم التسهيلات الأكاديمية والبحثية لإتمام هذا العمل. كما يتقدم المؤلفون بجزيل الشكر لمشغلي الاتصالات الخلوية في الجمهورية العربية السورية (سيريتل و MTN) على إتاحة البيانات التشغيلية اللازمة للدراسة وتسهيل الوصول إليها، مما ساهم بشكل

توصيات عملية لمخططي الشبكات السورية:

- استخدام BPSO عند إعطاء الأولوية لكفاءة استهلاك الموارد وسرعة الحل وتخفيض النفقات.
- استخدام AGA عند الحاجة إلى نتائج مستقرة وموثوقة ومتكررة في بيانات الإنتاج.
- النظر في الهندسة الهجينة الكلية كتوجه مستقبلي يجمع مزايا الخوارزميتين.

يمكن توسيع هذا العمل في عدة اتجاهات مستقبلية:

- دمج بيانات الطلب الحقيقي على الخدمة (Traffic Demand) لتحسين دقة النموذج [24].
- تطوير خوارزمية هجينة (Hybrid GA-PSO) تجمع بين قدرات الاستكشاف العالمية (Global Exploration) التي توفرها العمليات الجينية في المراحل الأولى من البحث، وقدرات الاستغلال والتقارب السريع (Fast Exploitation and Convergence) التي تتميز بها خوارزمية PSO في المراحل اللاحقة. ومن المتوقع أن يسهم هذا الدمج في تحسين نسبة التغطية، وتقليل التداخل بين الخلايا، مع المحافظة على كفاءة زمن التنفيذ، خاصة في سيناريوهات تخطيط شبكات الجيل الخامس واسعة النطاق.
- دمج إطار التحسين مع نماذج التعلم الآلي (Machine Learning) للتنبؤ بالطلب المستقبلي على الخدمة، وتكييف معاملات الخوارزمية بصورة ديناميكية، بما يسهم في تحسين اختيار مواقع المحطات القاعدية ورفع كفاءة التخطيط في البيئات التشغيلية المتغيرة.
- دراسة سيناريوهات الجيل الخامس المستقل (Standalone 5G)

tions and Networking, vol. 10, pp. 1495-1511, 2026.

[23] M. Li et al., "Optimization of 5G RAN Network Slicing Based on Auction Models," *Computer Networks*, vol. 279, p. 112141, 2026.

[24] Y. Guo and Y. Xie, "Burst Traffic Demand Based Adaptive Network Planning and Optimization Approach for 5G/6G Network," *IEEE Communications Letters*, vol. 29, no. 5, pp. 883-887, 2025.

[25] M. Sulaiman et al., "MicroOpt: Model-Driven Slice Resource Optimization in 5G and Beyond Networks," *IEEE Transactions on Network and Service Management*, vol. 22, no. 5, pp. 4448-4462, 2025.

[26] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of IEEE International Conference on Neural Networks*, Perth, Australia, 1995, vol. 4, pp. 1942-1948.

[27] M. B. Alvi, A. A. Syed, and M. A. Shah, "Cellular Base Station Deployment Optimization Using Particle Swarm Optimization: A Survey and Comparative Analysis," *IEEE Access*, vol. 9, pp. 48721-48738, 2021.

[28] M. Clerc and J. Kennedy, "The Particle Swarm — Explosion, Stability, and Convergence in a Multidimensional Complex Space," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 1, pp. 58-73, Feb. 2002.

[29] Y. Shi and R. Eberhart, "A Modified Particle Swarm Optimizer," in *Proceedings of the IEEE World Congress on Computational Intelligence*, Anchorage, AK, USA, 1998, pp. 69-73.

[30] X.-S. Yang, *Nature-Inspired Optimization Algorithms*, 2nd ed. Academic Press, 2021.

[31] D. E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, 1989.

التمويل: لا يوجد

مساهمات المؤلفين: ياسر المفعلائي: الإطار المفاهيمي: المنهجية الرياضية، تنفيذ الخوارزميات (AGA و BPSO)، إجراء المعالجة الجغرافية والتنظيف للبيانات، الكتابة - المسودة الأصلية.

مصطفى الدقاق: الإشراف العلمي، المراجعة والتحرير، تدقيق الصياغة الرياضية والمقارنات الخوارزمية.

كادان الجمعة: الإشراف العلمي، المراجعة والتحرير، توجيه عملية إعداد التجارب وسيناريوهات النشر.

تضارب المصالح: «يعلن المؤلفون أنه ليس لديهم أي مصالح متضاربة».

توافر البيانات والمواد: «جميع البيانات متوفرة في النص الرئيس أو في المواد التكميلية» أما البيانات التشغيلية الخام المستخدمة في الدراسة فهي مملوكة لمشغلي الاتصالات الخلوية وتخضع لاتفاقيات سرية ولا يمكن نشرها أو مشاركتها.

أساسي في إنجاز هذا البحث وربطه بالواقع التطبيقي العملي.

المراجع

- [1] 3GPP, "TS 22.261: Service Requirements for the 5G System (5GS)," Release 18.
- [2] 3GPP, "TS 23.501: System Architecture for the 5G System (5GS)," Release 18.
- [3] 3GPP, "TS 38.300: NR and NG-RAN Overall Description; Stage-2."
- [4] 3GPP, "TR 38.901: Study on Channel Model for Frequencies from 0.5 to 100 GHz."
- [5] ITU-R, "Recommendation M.2150-3: Detailed Specifications of the Terrestrial Radio Interfaces of IMT-2020," 2022.
- [6] ITU-R, "Recommendation M.2160-0: Framework and Overall Objectives of the Future Development of IMT for 2030 and Beyond," Nov. 2023.
- [7] 3GPP, "TR 21.918: Release 18 Description; Summary of Rel-18 Work Items (5G-Advanced Frameworks)."
- [8] Ericsson, *Ericsson Mobility Report*, Nov. 2025.
- [9] GSMA, *The Mobile Economy Report*, 2026.
- [10] J. G. Andrews et al., "What Will 5G Be?" *IEEE Journal on Selected Areas in Communications*, vol. 32, no. 6, pp. 1065-1082, June 2014.
- [11] T. S. Rappaport et al., *Millimeter Wave Wireless Communications*. Pearson, 2014.
- [12] A. Osseiran et al., "Scenarios for 5G Mobile and Wireless Communications: The Vision of the METIS Project," *IEEE Communications Magazine*, vol. 52, no. 5, pp. 26-35, May 2014.
- [13] F. Boccardi, R. W. Heath, A. Lozano, T. L. Marzetta, and P. Popovski, "Five Disruptive Technology Directions for 5G," *IEEE Communications Magazine*, vol. 52, no. 2, pp. 74-80, Feb. 2014.
- [14] I. F. Akyildiz, S. Nie, S.-C. Lin, and M. Chandrasekaran, "5G Roadmap: 10 Key Enabling Technologies," *Computer Networks*, vol. 106, pp. 17-48, 2016.
- [15] X. Foukas, G. Patounas, A. Elmokashfi, and M. K. Marina, "Network Slicing in 5G: Survey and Challenges," *IEEE Communications Magazine*, vol. 55, no. 5, pp. 94-100, 2017.
- [16] T. Taleb et al., "On Multi-Access Edge Computing: A Survey of the Emerging 5G Network Edge Cloud Architecture and Orchestration," *IEEE Communications Surveys & Tutorials*, vol. 19, no. 3, pp. 1657-1681, 2017.
- [17] L. Zhao, C. Yang, and J. Meng, "Cost-Efficient Deployment and Dimensioning of 5G Base Stations," *IEEE Access*, vol. 8, pp. 104085-104095, 2020.
- [18] R. J. Silva et al., "Hybrid Evolutionary Algorithms for Coverage and Capacity Optimization in Future Cellular Networks," *Computer Communications*, vol. 171, pp. 102-113, 2021.
- [19] E. J. Pacheco and C. M. Pedroso, "A Two-Phase Optimization for Radio Base Station Deployment in Heterogeneous Networks," *IEEE Access*, vol. 14, pp. 27253-27263, 2026.
- [20] J. Li, J. Pang, B. Jiang, Q. Xu, and E. Zhang, "Optimization of 5G Base Station Deployment Based on Quantum Genetic Algorithm in Outdoor 3D Map," *Computer Networks*, vol. 269, p. 111431, 2025.
- [21] J. Tan et al., "Delay-Aware and Energy-Efficient Integrated Optimization System for 5G Networks," *IEEE Transactions on Network and Service Management*, vol. 23, pp. 402-416, 2026.
- [22] S. Masrur, I. Guvenc, and D. Lopez-Perez, "Energy-Efficient Sleep Mode Optimization in 5G mmWave Networks via Multi-Agent Deep Reinforcement Learning," *IEEE Transactions on Green Communica-*