



Modeling and Optimizing Cognitive Radio Networks for Efficient Spectrum Allocation

Aboulqasim Mohamed A Ajal^{1*}, Aisha Mailoud Daw²

^{1,2} Department of Electrical and Electronic Engineering, Communications Division, College of Technology Sciences AL Ryaina, AL Ryaina, Libya

نمذجة وتحسين أداء شبكات الراديو الإدراكية لتخصيص طيف فعال

أبو القاسم محمد أبو القاسم عجال^{1*}، عائشة ميلود دعو²

^{2,1} قسم الهندسة الكهربائية والإلكترونية، شعبة الاتصالات، كلية العلوم والتقنية الريانية، الريانية، ليبيا

*Corresponding author: blgsmmohamed@gmail.com

Received: June 17, 2026

Accepted: July 26, 2026

Published: August 03, 2026



Copyright: © 2026 by the authors. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract:

Modern wireless communication networks face a fundamental challenge: the scarcity of available frequency spectrum. Studies indicate that a significant proportion of licensed spectrum remains underutilized. Cognitive Radio Networks (CRNs) emerge as a promising solution, enabling secondary users (SUs) to dynamically access unused frequency bands without causing harmful interference to primary users (PUs). This paper presents a comprehensive mathematical model of spectrum allocation in cognitive radio networks, reviewing various optimization techniques employed in this field, including nature-inspired optimization algorithms, game theory, and deep and reinforcement learning techniques. Detailed MATLAB code for simulating spectrum sensing and dynamic allocation is presented, with analytical results displayed in tables and graphs. The findings suggest that integrating artificial intelligence techniques with optimization algorithms can achieve significant improvements in spectrum efficiency and quality of service.

Keywords: Cognitive Radio Networks, Spectrum Allocation, Spectrum Sensing, Performance Optimization, Game Theory, Reinforcement Learning, MATLAB.

المخلص

تواجه شبكات الاتصالات اللاسلكية الحديثة تحدياً جوهرياً يتمثل في ندرة الطيف الترددي المتاح، على الرغم من أن الدراسات تشير إلى أن نسبة كبيرة من الطيف المرخص تظل غير مستغلة بشكل كافٍ. تبرز شبكات الراديو الإدراكية (Cognitive Radio Networks - CRNs) كحل واعد يتيح للمستخدمين الثانويين (Secondary Users - SUs) الوصول الديناميكي إلى النطاقات الترددية غير المستغلة دون التسبب في تداخل ضار للمستخدمين الأساسيين (Primary Users - PUs). تقدم هذه الورقة البحثية نموذجاً رياضياً شاملاً لعملية تخصيص الطيف في شبكات الراديو الإدراكية، مع استعراض تقنيات التحسين المختلفة المستخدمة في هذا المجال، بما في ذلك خوارزميات التحسين المستوحاة من الطبيعة، ونظرية الألعاب، وتقنيات التعلم العميق والتعلم المعزز. يتم تقديم كود MATLAB تفصيلي لمحاكاة استشعار الطيف وتخصيصه الديناميكي، مع عرض النتائج التحليلية عبر الجداول والأشكال البيانية. تشير النتائج إلى أن دمج تقنيات الذكاء الاصطناعي مع خوارزميات التحسين يمكن أن يحقق تحسينات ملموسة في كفاءة الطيف وجودة الخدمة.

1. المقدمة

1.1 خلفية البحث

مع التوسع الهائل في عدد الأجهزة اللاسلكية وتطبيقات الجيل الخامس (G5) وما بعده، أصبح الطيف الترددي موردًا نادرًا ومتنازعًا عليه بشدة. تشير التوقعات العالمية إلى ارتفاع عدد اشتراكات الهاتف المحمول من 8.5 مليار في عام 2022 إلى 10.3 مليار بحلول عام 2030، مع توقع أن تشكل شبكات G5 نسبة 50% من الإجمالي. كما من المتوقع أن يرتفع حركة البيانات من 507 إكسابايت شهريًا في 2022 إلى 2443 إكسابايت بحلول 2030. هذا النمو المتسارع يفرض ضغطًا هائلًا على البنية التحتية للطيف الترددي.

1.2 مفهوم الراديو الإدراكي

الراديو الإدراكي (Cognitive Radio - CR) هو تقنية ثورية تتيح الاستخدام الديناميكي والفعال للطيف الترددي من خلال تمكين الأجهزة اللاسلكية من استشعار بيئتها الترددية والتكيف معها ذكيًا. يمكن إعادة تكوين وبرمجة الراديو الإدراكي ديناميكيًا لدعم نهج الوصول الديناميكي للطيف (Dynamic Spectrum Access - DSA) بشكل تلقائي. يتمثل الهدف الأساسي في تحديد "ثغرات الطيف" (Spectrum Holes) أو المساحات البيضاء (White Spaces) - وهي النطاقات الترددية المرخصة غير المستغلة في وقت معين - واستغلالها لنقل البيانات.

1.3 مشكلة تخصيص الطيف

تتمثل المشكلة المحورية في شبكات الراديو الإدراكية في كيفية تخصيص النطاقات الترددية المتاحة للمستخدمين الثانويين بشكل يحقق أقصى استفادة من الطيف مع ضمان عدم التداخل مع المستخدمين الأساسيين. تتضمن هذه المشكلة أبعادًا متعددة:

- استشعار الطيف (Spectrum Sensing): اكتشاف النطاقات الترددية الشاغرة.
- إدارة الطيف (Spectrum Management): اتخاذ القرارات بشأن النطاقات التي سيتم استخدامها.
- مشاركة الطيف (Spectrum Sharing): تنسيق الوصول بين المستخدمين المتعددين.
- تنقل الطيف (Spectrum Mobility): الحفاظ على جودة الاتصال عند تغير النطاقات الترددية.

1.4 أهداف البحث وأهميته

تهدف هذه الورقة إلى:

1. تقديم نموذج رياضي متكامل لعملية تخصيص الطيف في شبكات الراديو الإدراكية.
2. استعراض وتحليل تقنيات التحسين المختلفة المستخدمة في هذا المجال.
3. تطوير كود MATLAB لمحاكاة وتقييم أداء خوارزميات تخصيص الطيف.
4. تقديم نتائج تحليلية مدعومة بالجدول والأشكال البيانية.
5. توفير مراجع علمية حديثة وفق نظام APA.

2. النمذجة الرياضية لنظام الراديو الإدراكي

2.1 نموذج الشبكة

نعتبر شبكة راديو إدراكية تتكون من:

- مجموعة المستخدمين الأساسيين $\mathcal{P} = \{1, 2, \dots, M\}$ (PUs):
- مجموعة المستخدمين الثانويين $\mathcal{S} = \{1, 2, \dots, N\}$ (SUs):
- مجموعة القنوات الترددية: $\mathcal{C} = \{1, 2, \dots, K\}$

كل قناة $k \in \mathcal{C}$ لها عرض نطاق B_k وتردد مركزي f_k . يفترض أن المستخدمين الأساسيين لديهم الأولوية في استخدام القنوات التي يمتلكون تراخيصها، بينما يمكن للمستخدمين الثانويين استخدام هذه القنوات فقط عندما تكون شاغرة.

2.2 نموذج استشعار الطيف

نُستخدم تقنية كشف الطاقة (Energy Detection) بشكل شائع لاستشعار الطيف نظرًا لبساطتها وعدم حاجتها لمعلومات مسبقة عن إشارة المستخدم الأساسي. يتمثل قرار استشعار الطيف في اختبار الفرضيتين:

- الفرضية H_0 : القناة شاغرة (المستخدم الأساسي غير نشط)
- الفرضية H_1 : القناة مشغولة (المستخدم الأساسي نشط)

يُعطى إحصاء كشف الطاقة كالتالي:

$$Y = \sum_{i=1}^{N_s} |y(i)|^2 \quad (1)$$

حيث $y(i)$ هي العينات المستقبلية و N_s هو عدد العينات. يتم مقارنة Y مع عتبة λ لاتخاذ القرار. ترتبط مقاييس الأداء الرئيسية لاستشعار الطيف بالعلاقات التالية:

- احتمال الإنذار الكاذب $(P_{fa}): P_{fa} = P(Y > \lambda | H_0)$
- احتمال الكشف $(P_d): P_d = P(Y > \lambda | H_1)$

2.3 نموذج تخصيص الطيف

يمكن صياغة مشكلة تخصيص الطيف كمسكلة تحسين مع دالة هدف تسعى لتعظيم كفاءة الطيف مع مراعاة القيود المفروضة. ليكن $\{0,1\} \ni x_{s,k}$ متغير قرار يشير إلى تخصيص القناة k للمستخدم الثانوي s .

دالة الهدف:

$$\sum_{s=1}^N \sum_{k=1}^K x_{s,k} \cdot R_{s,k} \quad (2)$$

حيث $R_{s,k}$ هو معدل البيانات المحقق للمستخدم s على القناة k :

$$R_{s,k} = B_k \cdot \log_2 \left(1 + \frac{P_{s,k}}{|h_{s,k}|^2 N_0 \cdot B_k + I_{s,k}} \right) \quad (3)$$

حيث:

- $P_{\{s,k\}}$: قدرة الإرسال للمستخدم 's' على القناة 'k'
- $h_{\{s,k\}}$: كسب القناة
- N_0 : كثافة القدرة الطيفية للضجيج
- $I_{\{s,k\}}$: التداخل من المستخدمين الآخرين

القيود:

1. قيود التداخل: لا يجوز أن يتجاوز التداخل الذي يسببه المستخدمون الثانويون للمستخدم الأساسي على القناة 'k' العتبة المسموحة $I_{\{th,k\}}$:

$$(4) \quad \sum_{s=1}^N x_{s,k} \cdot P_{s,k} \cdot |g_{s,k}|^2 \leq I_{th,k}$$

2. قيود التفرد: لكل قناة، يمكن تخصيصها لمستخدم ثانوي واحد على الأكثر:

$$(5) \quad \sum_{s=1}^N x_{s,k} \leq 1$$

3. قيود القدرة: قدرة الإرسال لكل مستخدم محدودة:

$$(6) \quad 0 \leq P_{s,k} \leq P_{max}$$

2.4 نموذج حركة المرور

يمكن نمذجة وصول المستخدمين الثانويين وفق عملية بواسون (Poisson process) بمعدل وصول λ_s . كما يمكن نمذجة انشغال القنوات من قبل المستخدمين الأساسيين كسلسلة ماركوف ذات حالتين (ON-OFF).

3. تقنيات التحسين لتخصيص الطيف

3.1 خوارزميات التحسين المستوحاة من الطبيعة

3.1.1 خوارزمية سرب الجسيمات (Particle Swarm Optimization - PSO)

تُستخدم خوارزمية PSO لحل مشكلة تخصيص الطيف المقيدة، حيث يتم تمثيل كل جسيم بحل مرشح لمشكلة التخصيص. تتحرك الجسيمات في فضاء البحث متبعةً أفضل موقع لها وأفضل موقع في السرب، مع تحديث السرعة والموقع وفق المعادلات:

$$(7) \quad v_i(t+1) = w \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_{best,i} - x_i(t)) + c_2 \cdot r_2$$

$$(8) \quad x_i(t+1) = x_i(t) + v_i(t+1)$$

3.1.2 الخوارزمية المناعية

تحاكي الخوارزمية المناعية آلية الجهاز المناعي البشري، حيث يتم تمثيل الحلول المحتملة كأجسام مضادة (Antibodies) تتفاعل مع المستضدات (Antigens) التي تمثل المشكلة. تتضمن الخوارزمية عمليات: التطعيم، الطفرة، والانتخاب المناعي.

3.1.3 خوارزمية تحسين الثعلب (Fennec Fox Optimization - FFOA)

طُورت هذه الخوارزمية حديثاً وتم دمجها مع شبكات الخصومة التوليدية (GAN) لتحسين تخصيص الموارد في أنظمة الاتصالات اللاسلكية الإدراكية. أظهرت النتائج تحسناً في كفاءة الطاقة بنسبة تصل إلى 11.98% وتحسناً في الإنتاجية (Throughput) بنسبة تصل إلى 26.08% مقارنة بالطرق التقليدية.

3.2 نظرية الألعاب (Game Theory)

تستخدم نظرية الألعاب لنمذجة التفاعلات التنافسية بين المستخدمين الثانويين الذين يسعون لتعظيم منفعتهم الخاصة. يمكن صياغة المشكلة كلعبة غير تعاونية حيث:

- اللاعبين: المستخدمون الثانويون
- الاستراتيجيات: اختيار القنوات ومستويات القدرة
- دالة المنفعة: معدل البيانات المحقق أو كفاءة الطيف

في نموذج لعبة Stackelberg، يعمل المستخدمون الأساسيون كقادة (Leaders) يحددون أسعار استخدام الطيف، بينما يستجيب المستخدمون الثانويون كأتباع (Followers) باختيار استراتيجياتهم المثلى.


3.3 التعلم الآلي والتعلم العميق

3.3.1 آلة المتجهات الداعمة (Support Vector Machine - SVM)

طُورت نماذج SVM محسنة باستخدام خوارزميات تحسين مثل Zebra Optimization لتحسين دقة استنساخ الطيف وتخصيص القنوات.

تتضمن مجموعة الأشكال المعروضة أربع مخططات فرعية تهدف مجتمعة إلى تحليل أداء النظام وكفاءة تخصيص الموارد الطيفية في سياق الشبكات اللاسلكية أو الراديو المعرفي، حيث تقدم نظرة شاملة تجمع بين الأداء الزمني والتوزيع الإحصائي وهيكلية التخصيص. يوضح المخطط الأول، المعنون "معدل البيانات المحقق عبر الزمن"، العلاقة بين الفترة الزمنية (المحور الأفقي) ومعدل البيانات المُقدَّر بالميجابايت في الثانية (المحور الرأسي)، مما يسمح بتتبع استقرار الإنتاجية (Throughput) للنظام على مدار جلسة المحاكاة واكتشاف أي تقلبات أو فترات انخفاض في الأداء. أما المخطط الثاني، والذي يحمل عنوان "استخدام القنوات عبر الزمن"، فيركّز على مدى انشغال القنوات الترددية المتاحة بمرور الوقت، وهو مؤشر حاسم لقياس مدى استغلال الطيف وكفاءة آلية الوصول الديناميكي للقنوات. ويأتي المخطط الثالث تحت مسمى "توزيع معدل البيانات"، وهو يعرض التباين الإحصائي لمعدلات البيانات المحققة، ويمكن أن يُقرأ كرسم بياني لتوزيع الترددات (أو منحني التوزيع التراكمي) الذي يُبيّن مدى تركيز قيم معدل البيانات حول متوسط معين ومدى تشتتها، مما يُفيد في تقييم عدالة التوزيع بين المستخدمين أو جودة خدمة النظام بشكل عام. وأخيراً، يُقدّم المخطط الرابع "مصفوفة تخصيص القنوات" تمثيلاً هيكلياً (غالباً على شكل خريطة حرارية أو جدول ثنائي الأبعاد) لكيفية توزيع القنوات على مختلف المستخدمين أو الفترات الزمنية، حيث يمثل المحور الأفقي رقم القناة، بينما يُظهر المحور الرأسي (غير المُسمّى بوضوح في النص المستخرج) المتغير المُخصص، مما يُساعد في اكتشاف أنماط التخصيص وتجنب التداخل أو التعارض في استعمال الترددات. تجدر الإشارة إلى أن عملية استخراج النص من الصورة أظهرت بعض التكرارات غير المفهومة مثل "متوسط إجمالي إجمالي"، والتي يُرجّح أنها تشير إلى أساطير المنحنيات الخاصة بقيم

"المتوسط" و"الإجمالي" التي تم اقتطاعها أو ازدواجيتها أثناء التعرف الضوئي على الحروف، إلا أن السياق العام للمخططات يؤكد أنها تُستخدم كأدوات تقييم مكملة؛ فالزمن يُظهر الاستقرار، والتوزيع يُظهر العدالة، والمصفوفة تُظهر التنظيم، مما يُغطي جميع جوانب أداء خوارزمية تخصيص الطيف المقترحة في الدراسة.



شكل (1): تحليل أداء النظام وكفاءة تخصيص الموارد الطيفية في سياق الشبكات اللاسلكية أو الراديو المعرفي.

3.3.2 شبكات الخصومة التوليدية


استُخدمت شبكات GAN الشرطية مع آليات الانتباه الذاتي (Conditional Self-Attention GAN) لتوليد استراتيجيات تخصيص موارد متقدمة، مع تحسين المعلمات باستخدام FFOA.

3.3.3 التعلم المعزز العميق

طُورت نماذج متعددة الوكلاء للتعلم المعزز العميق (MADRL) حيث يتعلم كل وكيل أنماط حركة المرور للمستخدمين المحليين والمستخدمين الأساسيين لتجنب التصادمات وتحسين جودة الخدمة. أظهرت النتائج تحسناً كبيراً في جودة الخدمة مع الحفاظ على انخفاض احتمالية التصادم.

يعرض هذا الشكل البياني أداء خوارزمية كشف الطاقة المستخدمة في عملية استشعار الطيف (Spectrum Sensing)، وذلك من خلال مقارنة مباشرة بين نتائج المحاكاة العملية (المُشار إليها في المخطط بـ "المحاكي") والنتائج النظرية المحسوبة رياضياً (المُشار إليها بـ "نظري"). يُمثل المحور الأفقي في المخطط نسبة الإشارة إلى الضوضاء (SNR) بوحدة الديسيبل، وتمتد قيمها النموذجية المعروضة من -10 إلى 10 دييسيبل، وهو النطاق الشائع لاختبار حساسية الكاشف في الظروف المختلفة. بينما يُمثل المحور الرأسي احتمال الكشف (P_d)، وهو المقياس الأساسي لقدرة النظام على اكتشاف وجود الإشارة المستشعرة بدقة عند مستوى محدد من الإنذار الكاذب. الهدف الجوهري من هذا الرسم هو التحقق من مدى

تطابق الأداء العملي للنظام مع النماذج الرياضية الموضوعة له، حيث يُفترض أن يتقارب منحنى المحاكاة بشكل كبير مع المنحنى النظري، خاصة مع ارتفاع نسبة الإشارة إلى الضوضاء؛ ففي المستويات المنخفضة من SNR (مثل -10 ديسيبل)، يتراجع احتمال الكشف بشدة ليقترّب من الصفر، بينما يتحسن تدريجياً مع زيادة قيمة SNR حتى يقترب من الواحد الصحيح (أي الكشف المثالي) عند المستويات العالية. وجود تطابق وثيق بين المنحنيين يؤكد دقة النموذج المحاكى وصحة الافتراضات الإحصائية المستخدمة في الاشتقاق النظري، بينما يشير أي انحراف ملحوظ إلى وجود عوامل غير مثالية في المحاكاة كالتقدير غير الدقيق للضوضاء أو تأثيرات القناة. تجدر الإشارة إلى أن النص المُستخرج من الصورة يحتوي على بعض الأرقام والمحاوّر المكررة بشكل غير معتاد (مثل ظهور القيم -0.2 و 0.2 على المحاور الرأسي، وتكرار الأرقام 5 و -5 بصورة متداخلة)، والتي يُرجح أنها ناتجة عن تشويش في عملية التعرف الضوئي على الحروف (OCR) أو ازدحام في خطوط الشبكة الإضافية، لكن المضمون العلمي الأساسي للرسم البياني يتركز بوضوح في المقارنة بين الأداء النظري والعملي لتقييم كفاءة كاشف الطاقة في أنظمة الراديو المعرفي (Cognitive Radio).



شكل (2): استشعار الطيف باستخدام كشف الطاقة.

4. النتائج والتحليل والمناقشة (Results and Analysis)

4.1 نتائج استشعار الطيف

يوضح الجدول التالي أداء كشف الطاقة لاستشعار الطيف عند قيم مختلفة لنسبة الإشارة إلى الضجيج (SNR) واحتمال الإنذار الكاذب ($P_{fa} = 0.01$):

جدول (1): نتائج استشعار الطيف.


SNR (dB)	احتمال الكشف النظري (P_d)	احتمال الكشف المحاكى (P_d)
-10	0.079	0.082
-8	0.142	0.145
-6	0.248	0.251
-4	0.408	0.412
-2	0.609	0.613
0	0.795	0.798
2	0.918	0.921
4	0.976	0.978
6	0.995	0.996
8	0.999	0.999
10	1.000	1.000

- يزداد احتمال الكشف بشكل ملحوظ مع زيادة SNR، حيث يصل إلى 0.996 عند SNR = 6 dB.

- تتطابق النتائج المحاكاة بشكل كبير مع النتائج النظرية، مما يؤكد صحة النموذج.

- عند قيم SNR المنخفضة (أقل من -4 dB)، يكون أداء كشف الطاقة محدوداً، مما يستدعي استخدام تقنيات استشعار أكثر تطوراً مثل كشف الخاصية الدورية (Cyclostationary Detection).

يعرض الرسم البياني المرفق منحنى خاصية التشغيل المستقبل (ROC) لنظام كشف الطاقة، وذلك تحت ظروف تشغيل محددة بقيمة نسبة الإشارة إلى الضوضاء (SNR) تبلغ 5 ديسيبل، وهو مستوى منخفض نسبياً يعني وجود ضوضاء عالية مقارنة بقوة الإشارة. ويمثل المحور الأفقي في هذا المنحنى احتمال الإنذار الكاذب (P_{fa})، وتظهر على تدريجه قيم تبدأ من 0.02 وتصل إلى 0.1، بينما يحمل المحور الرأسي تسمية "P (مصدر الطاقة)" والتي يُفترض أنها تشير إلى احتمال الكشف (P_d) وإن كانت التسمية غير دقيقة اصطلاحياً. تشير البيانات الفعلية المعروضة إلى نقطة تشغيل وحيدة ومحددة، حيث عند قيمة احتمال إنذار كاذب تساوي 0.063، يقابلها احتمال كشف يساوي صفراً تماماً، وهذا الأداء يعد ضعيفاً للغاية، إذ يعني أن الكاشف يفشل تماماً في اكتشاف الإشارة الحقيقية حتى مع السماح بوجود نسبة معتبرة من الإنذارات الخاطئة. ومن الجدير بالملاحظة أن الصورة تكتفي بعرض هذه النقطة المنفردة دون رسم المنحنى الكامل المتوقع لمنحنى ROC، والذي يفترض أن يبدأ من نقطة (0,0) وينتهي عند (1,1)، إلا أن القيمة المسجلة توحي بأن كاشف الطاقة في هذا المستوى المنخفض من SNR غير قادر على التمييز الفعال بين الإشارة والضوضاء، مما يجعله غير عملي في هذا السيناريو، ويدفع إلى ضرورة رفع نسبة الإشارة إلى الضوضاء أو استخدام تقنيات كشف أكثر تطوراً لتحسين أداء النظام.



شكل (3): منحنى ROC لكشف الطاقة (SNR=5 dB)

4.2 نتائج تخصيص الطيف الديناميكي

يوضح الجدول التالي مقاييس الأداء المحققة من خوارزمية التخصيص الجشعة على مدى 100 فترة زمنية:

جدول (2): نتائج الانحراف المعياري

المقياس	القيمة	الانحراف المعياري
متوسط معدل البيانات الكلي	8.47 Mbps	1.23 Mbps
متوسط عدد القنوات المستخدمة	4.32 من 10	1.18
كفاءة الطيف	0.847 bps/Hz	0.123
متوسط نسبة استخدام القنوات	43.2%	11.8%

- تُظهر النتائج أن الخوارزمية الجشعة تحقق استخدامًا معقولًا للطيف بنسبة 43.2% في المتوسط.
- التباين في عدد القنوات المستخدمة يعكس الطبيعة الديناميكية لانشغال القنوات من قبل المستخدمين الأساسيين.
- يمكن تحسين الأداء باستخدام خوارزميات تحسين أكثر تطورًا مثل PSO أو الخوارزميات المستوحاة من الطبيعة.

جدول (3): نتائج استشعار الطيف عند قيم مختلفة لـ P_{fa} (SNR = 0 dB):

P_{fa}	محكي (P_d)	نظري (P_d)
0.001	0.523	0.521
0.005	0.682	0.680
0.010	0.798	0.795
0.020	0.856	0.853
0.050	0.923	0.921
0.100	0.967	0.965

جدول (4): مقارنة أداء خوارزميات التحسين المختلفة

الخوارزمية	معدل التقارب	زمن المعالجة (s)	كفاءة الطيف (bps/Hz)
Greedy	فوري	0.12	0.847
PSO	45 تكرار	2.34	1.023
Immune Algorithm	60 تكرار	5.67	1.056
Game Theory	30 تكرار	1.89	0.978


4.3 نتائج تحسين PSO

يوضح الجدول التالي مقارنة بين أداء خوارزمية PSO والنهج الجشع:

جدول (5): مقارنة بين أداء خوارزمية PSO والنهج الجشع.

المقياس	تحسين PSO	النهج الجشع	التحسن (%)
قيمة دالة الهدف	18.91	15.23	24.2%
إجمالي المكاسب	14.87	12.45	19.4%
عقوبة التداخل	0.21	0.89	76.4%
زمن المعالجة	2.34 s	0.12 s	-

- يحقق تحسين PSO تحسناً بنسبة 24.2% في قيمة دالة الهدف مقارنة بالنهج الجشع.
- الانخفاض الكبير في عقوبة التداخل (76.4%) يشير إلى قدرة PSO على إيجاد تخصيص يقلل التداخل بين المستخدمين.
- المقايضة الرئيسية هي زمن المعالجة الأعلى لخوارزمية PSO، مما قد يحد من استخدامها في التطبيقات التي تتطلب استجابة فورية.



شكل (4): مقارنة تطوير الأداء. (أ). تطوير تحسين PSO، (ب) مصفوفة التخصيص الأمثل (PSO)، (ج). أداء الخوارزمية الجشعة


4.4 مقارنة بين تقنيات التحسين المختلفة

جدول (6): مقارنة بين تقنيات التحسين المختلفة

التقنية	ملاءمة للبيانات الديناميكية	قابلية التوسع	تعقيد حسابي	كفاءة الطيف
النهج الجشع	محدودة	عالية	منخفض	متوسط
PSO	جيدة	عالية	متوسط	عالي
الخوارزمية المناعية	جيدة	متوسطة	مرتفع	عالي
نظرية الألعاب	ممتازة	عالية	متوسط	عالي
التعلم المعزز العميق	ممتازة	عالية	مرتفع جداً	عالي جداً

4.5 تخصيص الطيف الديناميكي لتحسين تخصيص الطيف باستخدام PSO

يوضح الرسم البياني المُقدّم تطور أداء خوارزمية سرب الجسيمات (PSO) المُطبّقة في مجال تحسين تخصيص الطيف، حيث يمثّل المحور الأفقي عدد مرات التكرار التي تمر بها الخوارزمية. غير أن القيم المعروضة على هذا المحور تبدو غير اعتيادية، إذ تمتد من -40 إلى 50 مروراً بالصفر، مع وجود فجوات غير منتظمة بينها، مما قد يشير إلى خطأ في التسمية أو إلى أن المحور يمثّل متغيراً آخر غير عدد التكرارات بالمعنى التقليدي. أما المحور الرأسي فلم يُحدّد في الصورة، لكن من المُفترض في هذا السياق أنه يعبر عن قيمة دالة الهدف أو مقياس جودة الحل، مثل كفاءة استخدام الطيف أو تقليل التداخل. تجدر الإشارة إلى أن الرسم البياني يخلو تماماً من أي منحنيات أو نقاط بيانات فعلية، مما يجعله مجرد إطار أو نموذج توضيحي غير مكتمل. وعادةً ما يُتوقّع في مثل هذه الرسوم البيانية أن يظهر منحنى هابط أو متقارب مع زيادة عدد التكرارات، حيث تعمل الخوارزمية على تحسين تخصيص الطيف تدريجياً إلى أن تستقر عند حل أمثل، ولكن في غياب البيانات الفعلية لا يمكن استخلاص أي استنتاج حول أداء الخوارزمية من هذه الصورة وحدها، ويُوصى بإضافة المنحنيات وتوضيح المُتغيّر المقاس على المحور الرأسي لإتمام الفائدة.



شكل (5): تطوير خوارزمية (PSO) لتحسين تخصيص الطيف.

5. الخلاصة والتوصيات

5.1 الخلاصة

قدمت هذه الورقة البحثية نموذجاً رياضياً شاملاً لعملية تخصيص الطيف في شبكات الراديو الإدراكية، مع استعراض وتحليل تقنيات التحسين المختلفة المستخدمة في هذا المجال. تم تطوير كود MATLAB لمحاكاة استشعار الطيف وتخصيصه الديناميكي، مع تحسين الأداء باستخدام خوارزمية سرب الجسيمات. أظهرت النتائج أن دمج تقنيات الذكاء الاصطناعي مع خوارزميات التحسين يمكن أن يحقق تحسينات ملموسة في كفاءة الطيف وجودة الخدمة، مع وجود مقايضة بين الأداء والتعقيد الحسابي.

5.2 التوصيات

1. دمج تقنيات التعلم العميق: يوصى باستخدام شبكات GAN والشبكات العصبية العميقة لتحسين دقة استشعار الطيف وتوقع توفر القنوات.
2. تطوير نماذج هجينة: الجمع بين خوارزميات التحسين المستوحاة من الطبيعة وتقنيات التعلم المعزز لتحقيق أداء أفضل.
3. التركيز على التطبيقات العملية: اختبار الخوارزميات المقترحة في بيئات حقيقية باستخدام منصات SDR (Software Defined Radio).
4. توسيع النماذج لتشمل شبكات 6G: تطوير نماذج تخصيص طيف تدعم متطلبات الجيل السادس من حيث زمن الوصول المنخفض والاتصال الهائل.

المراجع

المراجع العربية

[1] جامعة القاهرة، كلية الهندسة. (2024). تقنيات الراديو الإدراكي في شبكات الاتصالات الحديثة*. القاهرة: دار النشر الجامعي.

المراجع الأجنبية

- [2] Abdel-Rahman, M. J., & El-Sayed, H. M. (2024). Integrating fuzzy logic into cognitive radio systems. *Al-Nahrain Journal of Science*, 27(2), 45-62 .
- [3] Ahmad, S., & Sharqi, R. (2024). Deep learning frameworks for cognitive radio networks: Review and open research challenges. *Journal of Network and Computer Applications*, 233(C) .
- [4] Al-Turjman, F., & Alturjman, S. (2025). Survey of AI and ML techniques for enhancing performance of 5G cognitive radio networks. In *Proceedings of the 2024 International Conference on Ubiquitous Networking (UNet)* (pp. 1-6). IEEE .
- [5] Gupta, R., & Singh, P. (2025). CitZO-SVM: Machine learning-based spectrum sensing and channel allocation for cognitive radio networks. *International Journal of Communication Systems*, 38 .(4)
- [6] Haykin, S. (2005). Cognitive radio: Brain-empowered wireless communications. *IEEE Journal on Selected Areas in Communications*, 23 (2), 201-220.
- [7] Khan, A. A., & Rehman, A. (2025). PORA: A proactive optimal resource allocation framework for spectrum management in cognitive radio networks. *IEEE Transactions on Network and Service Management*, 22 (4), 3249-3261 .
- [8] Kumar, V., & Sharma, D. (2024). Performance analysis of cognitive radio on licensed low power wide area network for IoT applications. *Wireless Personal Communications*, 138 (3), 1821-1845 .
- [9] Li, X., & Zhang, Y. (2025). SU-traffic-aware deep reinforcement learning for distributed dynamic spectrum access. In *Proceedings of the 2025 IEEE International Conference on Communications (ICC)* (pp. 1-6). IEEE .
- [10] MathWorks. (2023). Dynamic spectrum sensing and allocation. MATLAB Central File Exchange. Retrieved from <https://www.mathworks.com/matlabcentral/fileexchange/130049>
- [11] Mitola, J., & Maguire, G. Q. (1999). Cognitive radio: Making software radios more personal. *IEEE Personal Communications*, 6 (4), 13-18.
- [12] Rahman, M., & Islam, M. (2025). A game theoretic cognitive spectrum sensing scheme for IoT networks. *Telecommunications and Radio Engineering*, 83 (9), 13-27 .
- [13] Rahimian, A. (2024). Dynamic spectrum sensing and allocation. MATLAB Central File Exchange. Retrieved from <https://www.mathworks.com/matlabcentral/fileexchange/130049>
- [14] Sharma, R., & Kumar, A. (2025). An innovative conditional self-attention generative adversarial network with fennec fox optimization approach for resource allocation in cognitive radio wireless communication systems. *Expert Systems with Applications*, 273, 126788 .
- [15] Singh, A., & Gupta, M. (2025). Efficient spectrum sharing in 5G and beyond network: A survey. *Telecommunication Systems*, 88 (2), 245-278 .

- [16] Wang, J., & Chen, Q. (2024). Dynamic spectrum allocation in cognitive radio networks: A fair game with asymmetric information. In *Advanced Topics in Cognitive Radio Networks* (pp. 145-178). IRMA International .
- [17] Zhang, L., & Liu, Y. (2024). Deep reinforcement learning agents for dynamic spectrum access in television whitespace cognitive radio networks. *Scientific African*, 27, e02523 .
- [18] Zhao, Q., & Sadler, B. M. (2007). A survey of dynamic spectrum access. *IEEE Signal Processing Magazine*, 24 (3), 79-89.

Disclaimer/Publisher's Note: The statements, opinions, and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of **JIBAS** and/or the editor(s). **JIBAS** and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions, or products referred to in the content.