

مجلة جامعة حمص

سلسلة العلوم الهندسية الميكانيكية
والكهربائية والمعلوماتية



مجلة علمية محكمة دورية

المجلد 47 . العدد 12

1447 هـ - 2025 م

الأستاذ الدكتور طارق حسام الدين رئيس جامعة حمص

المدير المسؤول عن المجلة

رئيس تحرير مجلة جامعة حمص للعلوم الإنسانية	أ. د. وليد حمادة
رئيس تحرير مجلة جامعة حمص للعلوم الطبية والهندسية والأساسية والتطبيقية	د.نعيمة عجيب

عضو هيئة التحرير	د. محمد فراس رمضان
عضو هيئة التحرير	د. مضر سعود
عضو هيئة التحرير	د. ممدوح عبارة
عضو هيئة التحرير	د. موفق تلاوي
عضو هيئة التحرير	د. طلال رزوق
عضو هيئة التحرير	د. أحمد الجاعور
عضو هيئة التحرير	د. الياس خلف
عضو هيئة التحرير	د. روعة الفقس
عضو هيئة التحرير	د. محمد الجاسم
عضو هيئة التحرير	د. خليل الحسن
عضو هيئة التحرير	د. هيثم حسن
عضو هيئة التحرير	د. أحمد حاج موسى

تهدف المجلة إلى نشر البحوث العلمية الأصيلة، ويمكن للراغبين في طلبها

الاتصال بالعنوان التالي:

رئيس تحرير مجلة جامعة حمص

سورية . حمص . جامعة حمص . الإدارة المركزية . ص . ب (77)

. هاتف / فاكس : ++ 963 31 2138071

. موقع الإنترنت : www.homs-univ.edu.sy

. البريد الإلكتروني : journal.homs-univ.edu.sy

ISSN: 1022-467X

شروط النشر في مجلة جامعة حمص

الأوراق المطلوبة:

- 2 نسخة ورقية من البحث بدون اسم الباحث / الكلية / الجامعة) + CD / word من البحث منسق حسب شروط المجلة.
 - طابع بحث علمي + طابع نقابة معلمين.
 - إذا كان الباحث طالب دراسات عليا:
يجب إرفاق قرار تسجيل الدكتوراه / ماجستير + كتاب من الدكتور المشرف بموافقة على النشر في المجلة.
 - إذا كان الباحث عضو هيئة تدريسية:
يجب إرفاق قرار المجلس المختص بإنجاز البحث أو قرار قسم بالموافقة على اعتماده حسب الحال.
 - إذا كان الباحث عضو هيئة تدريسية من خارج جامعة البعث :
يجب إحضار كتاب من عمادة كليته تثبت أنه عضو بالهيئة التدريسية و على رأس عمله حتى تاريخه.
 - إذا كان الباحث عضواً في الهيئة الفنية :
يجب إرفاق كتاب يحدد فيه مكان و زمان إجراء البحث ، وما يثبت صفته وأنه على رأس عمله.
 - يتم ترتيب البحث على النحو الآتي بالنسبة لكليات (العلوم الطبية والهندسية والأساسية والتطبيقية):
عنوان البحث .. ملخص عربي و إنكليزي (كلمات مفتاحية في نهاية الملخصين).
- 1- مقدمة
 - 2- هدف البحث
 - 3- مواد وطرق البحث
 - 4- النتائج ومناقشتها .
 - 5- الاستنتاجات والتوصيات .
 - 6- المراجع.

- يتم ترتيب البحث على النحو الآتي بالنسبة لكليات (الآداب - الاقتصاد - التربية - الحقوق - السياحة - التربية الموسيقية وجميع العلوم الإنسانية):
- عنوان البحث .. ملخص عربي و إنكليزي (كلمات مفتاحية في نهاية الملخصين).
- 1. مقدمة.
- 2. مشكلة البحث وأهميته والجديد فيه.
- 3. أهداف البحث و أسئلته.
- 4. فرضيات البحث و حدوده.
- 5. مصطلحات البحث و تعريفاته الإجرائية.
- 6. الإطار النظري و الدراسات السابقة.
- 7. منهج البحث و إجراءاته.
- 8. عرض البحث و المناقشة والتحليل
- 9. نتائج البحث.
- 10. مقترحات البحث إن وجدت.
- 11. قائمة المصادر والمراجع.
- 7- يجب اعتماد الإعدادات الآتية أثناء طباعة البحث على الكمبيوتر:
 - أ- قياس الورق 25×17.5 B5.
 - ب- هوامش الصفحة: أعلى 2.54- أسفل 2.54 - يمين 2.5- يسار 2.5 سم
 - ت- رأس الصفحة 1.6 / تذييل الصفحة 1.8
 - ث- نوع الخط وقياسه: العنوان . Monotype Koufi قياس 20
- كتابة النص Simplified Arabic قياس 13 عادي - العناوين الفرعية Simplified Arabic قياس 13 عريض.
- ج. يجب مراعاة أن يكون قياس الصور والجداول المدرجة في البحث لا يتعدى 12سم.
- 8- في حال عدم إجراء البحث وفقاً لما ورد أعلاه من إشارات فإن البحث سيهمل ولا يرد البحث إلى صاحبه.
- 9- تقديم أي بحث للنشر في المجلة يدل ضمناً على عدم نشره في أي مكان آخر، وفي حال قبول البحث للنشر في مجلة جامعة البعث يجب عدم نشره في أي مجلة أخرى.

10- الناشر غير مسؤول عن محتوى ما ينشر من مادة الموضوعات التي تنشر في المجلة
11- تكتب المراجع ضمن النص على الشكل التالي: [1] ثم رقم الصفحة ويفضل استخدام التهميش الإلكتروني المعمول به في نظام ورد WORD حيث يشير الرقم إلى رقم المرجع الوارد في قائمة المراجع.

تكتب جميع المراجع باللغة الانكليزية (الأحرف الرومانية) وفق التالي:

آ . إذا كان المرجع أجنبياً:

الكنية بالأحرف الكبيرة - الحرف الأول من الاسم تتبعه فاصلة - سنة النشر - وتتبعها معترضة (-) عنوان الكتاب ويوضع تحته خط وتتبعه نقطة - دار النشر وتتبعها فاصلة - الطبعة (ثانية . ثالثة) . بلد النشر وتتبعها فاصلة . عدد صفحات الكتاب وتتبعها نقطة .
وفيما يلي مثال على ذلك:

-MAVRODEANUS, R1986- **Flame Spectroscopy**. Willy, New York, 373p.

ب . إذا كان المرجع بحثاً منشوراً في مجلة باللغة الأجنبية:

— بعد الكنية والاسم وسنة النشر يضاف عنوان البحث وتتبعه فاصلة، اسم المجلد ويوضع تحته خط وتتبعه فاصلة — المجلد والعدد (كتابة مختزلة) وبعدها فاصلة — أرقام الصفحات الخاصة بالبحث ضمن المجلة.
مثال على ذلك:

BUSSE,E 1980 Organic Brain Diseases **Clinical Psychiatry News** , Vol. 4. 20 – 60

ج . إذا كان المرجع أو البحث منشوراً باللغة العربية فيجب تحويله إلى اللغة الإنكليزية و التقيد بالبنود (أ و ب) ويكتب في نهاية المراجع العربية: (المراجع In Arabic)

رسوم النشر في مجلة جامعة حمص

1. دفع رسم نشر (50000) ل.س أربعون ألف ليرة سورية عن كل بحث لكل باحث يريد نشره في مجلة جامعة البعث.
2. دفع رسم نشر (200000) ل.س مئة ألف ليرة سورية عن كل بحث للباحثين من الجامعة الخاصة والافتراضية .
3. دفع رسم نشر (200) مننًا دولار أمريكي فقط للباحثين من خارج القطر العربي السوري .
4. دفع مبلغ (15000) ل.س ستة آلاف ليرة سورية رسم موافقة على النشر من كافة الباحثين.

المحتوى

الصفحة	اسم الباحث	اسم البحث
40-11	د. احمد العلي	تحسين جودة نقل الفيديو في الشبكات اللاسلكية النقالة
76-41	م.ريم جرجس د. علي الحاتم	تقييم نظام تواصل قائم على سلاسل الكتل في شبكات المركبات اللاسلكية باستخدام العقود الذكية
116-77	رنيم المعلم أ.د. نديم شاهين د. طلال حمود	تصنيف الأغذية باستخدام الشبكات العصبونية التلافيفية المحسنة

تحسين جودة نقل الفيديو في الشبكات اللاسلكية النقالة

د. احمد العلي *

المخلص

يهدف هذا البحث إلى تقييم وتحسين جودة خدمة نقل تدفق الفيديو عبر الشبكات اللاسلكية النقالة، وذلك من خلال دراسة أداء بروتوكولات ومعايير مختلفة من عائلة IEEE 802.11، ومقارنة نتائجها في بيئات متنوعة تشمل الاتصالات السلكية واللاسلكية. تم تنفيذ مجموعة من التجارب العملية باستخدام نماذج محاكاة واقعية لقياس مؤشرات الأداء الأساسية مثل معدل الإنتاجية (Throughput)، وزمن التأخير (Delay)، ونسبة فقدان الرزم (Packet Loss) أثناء نقل تدفقات فيديو بصيغة MPEG-4.

شملت التجارب مقارنة بين البروتوكولين TCP و UDP، وبين آليات النفاذ إلى الوسط في المعيارين (DCF) 802.11 و (EDCA) 802.11e، إضافة إلى دراسة أثر آليات الإسناد الثابت والديناميكي على جودة الخدمة في بيئات ذات مستويات حركة وازدحام مختلفة. كما تم تحليل تأثير كل من حجم الرزم، وعدد تدفقات الفيديو، وسرعة العقد المتنتقلة على أداء الشبكة.

أظهرت النتائج أن معيار IEEE 802.11e المزود بآلية الإسناد الديناميكي يحقق أفضل أداء من حيث الإنتاجية وتقليل التأخير وفقدان الرزم، مقارنةً بالأنماط الأخرى. كما تبين أن استخدام بروتوكول UDP أكثر ملاءمة لنقل الفيديو نظرًا لمرونته في التعامل مع الفقد المؤقت.

تؤكد النتائج أن تحسين آليات الجدولة والإسناد في الطبقة الوسيطة يسهم بفعالية في تحسين جودة نقل الفيديو في الشبكات اللاسلكية النقالة، ويمهد لتطوير أنظمة بث مرئي أكثر كفاءة في بيئات الاتصالات المتنتقلة.

د. احمد العلي: عضو هيئة تدريسية في جامعة حمص - كلية الهندسة المعلوماتية

الكلمات المفتاح: شبكات حاسوبية، الشبكات اللاسلكية النقالة، محاكاة الشبكات، محاكي الشبكة NS2، نقل الفيديو.

Enhancing video Transmission Quality in Mobile Wireless Networks

Dr.Ahmad Alali*

Abstract

This research aims to evaluate and enhance the Quality of Service (QoS) for video streaming transmission over mobile wireless networks by studying the performance of different protocols and standards from the IEEE 802.11 family, and by comparing their results in various wired and wireless environments.

A series of practical experiments were conducted using realistic simulation models to measure key performance indicators such as throughput, delay, and packet loss during the transmission of MPEG-4 video streams.

The experiments included comparisons between the TCP and UDP transport protocols, as well as between medium access mechanisms in IEEE 802.11 (DCF) and IEEE 802.11e (EDCA). In addition, the impact of static and dynamic assignment mechanisms on service quality was analyzed under different mobility and congestion levels. The study also examined the effects of packet size, the number of video streams, and node mobility speed on overall network performance.

The results demonstrated that the IEEE 802.11e standard with the dynamic assignment mechanism achieved the best performance in terms of higher throughput, lower delay, and reduced packet loss compared to other configurations. Furthermore, the use of the UDP protocol proved to be more suitable for video transmission due to its flexibility in handling temporary packet loss.

Overall, the findings confirm that improving scheduling and assignment mechanisms at the medium access layer can significantly enhance video transmission quality in mobile wireless networks and pave the way for more efficient video streaming systems in mobile communication environments.

Dr.Ahmad Alali: Lecturer at homs university -informatics engineering faculty

Keywords: computer networks, mobile AdHoc networks, Networks simulation, network simulator NS2, video transmission.

1. مقدمة:

شهدت الشبكات اللاسلكية في السنوات الأخيرة انتشارًا واسعًا، وأصبحت محور اهتمام الباحثين والمطورين نظرًا لما توفره من مرونة عالية وسهولة في النشر والاستخدام مقارنة بالشبكات السلكية التقليدية. ومع هذا الانتشار، تزايد الاعتماد على تطبيقات الوسائط المتعددة مثل البث المرئي والمكالمات الصوتية عبر الإنترنت، وهي تطبيقات تتطلب مستوى مرتفعًا من جودة الخدمة (QoS) لضمان أداء مستقر وفعال في نقل بيانات الزمن الحقيقي.

تعتمد الشبكات اللاسلكية المحلية على المعيار IEEE 802.11، الذي يستخدم خوارزمية التنسيق الموزع (DCF) والمبنية على آلية التحسس المتعدد للوسط مع تجنب التصادم (CSMA/CA) لضبط عملية الوصول إلى وسط الإرسال. وتتيح هذه الآلية وصولًا عادلًا لجميع المحطات المشاركة في الشبكة، إلا أن من أبرز محدودياتها عدم قدرتها على التمييز بين أنواع تدفقات البيانات المختلفة، حيث تُعامل جميع الحزم بنفس مستوى الأولوية دون مراعاة لطبيعة التطبيق أو متطلباته الزمنية.

ونظرًا لأن تطبيقات الزمن الحقيقي مثل الصوت والفيديو تتطلب زمن تأخير منخفضًا وأداءً مضمونًا مقارنة ببقية أنواع البيانات، برزت الحاجة إلى تطوير المعيار الأصلي. لذلك تم تقديم

المعيار IEEE 802.11e، الذي يعتمد آلية الوصول المحسنة إلى القناة الموزعة (EDCA). (1)

تقوم هذه الآلية على تصنيف البيانات إلى أربع فئات خدمية:

- البيانات الصوتية (Voice) ،
- البيانات المرئية (Video) ،
- خدمات أفضل ما يمكن (Best Effort) ،
- بيانات الخلفية (Background) ،

وذلك بهدف تخصيص أولويات مختلفة لكل نوع من أنواع البيانات، بما يضمن تحسين جودة الخدمة وتحقيق أداء أكثر كفاءة في بيئات الاتصالات اللاسلكية الحديثة.

2. الهدف من البحث:

على الرغم من الانتشار الواسع للشبكات اللاسلكية المعتمدة على المعيار IEEE 802.11، إلا أن هذا المعيار يعاني من قصور في دعم جودة الخدمة (QoS) نظراً لعدم قدرته على التمييز بين أنواع تدفقات البيانات المختلفة. لذلك تم تطوير المعيار IEEE 802.11e بهدف تحسين جودة الخدمة، خاصة في تطبيقات نقل الفيديو عبر الشبكات اللاسلكية النقالة.

يهدف هذا البحث إلى تقييم أداء جودة الخدمة لكل من المعيارين IEEE 802.11 و IEEE 802.11e من خلال مجموعة من السيناريوهات العملية المتنوعة، ودراسة تأثير كل من خوارزمية الإسناد الثابت، وخوارزمية الإسناد الديناميكي، والخوارزمية الافتراضية المطبقة في المعيار IEEE 802.11e على تحسين جودة نقل الفيديو.

3. الدراسات المرجعية:

تناولت الأبحاث الحديثة تحديات تحسين جودة خدمة نقل الفيديو في شبكات الـ WLAN وطرحت حلولاً تعتمد غالباً على تصميمات عبر الطبقات (cross-layer) وتقنيات تخصيص

ديناميكي للموارد. على سبيل المثال، اقترح الباحثون بنى عابرة للطبقات لتحسين توصيل الفيديو في بيئات تعتمد 802.11e بما في ذلك تطبيقات UAV والبث المتحرك، وأظهرت هذه الدراسات فعالية خوارزميات المطابقة بين أولوية الحزم وخصائص الترميز في تقليل الفقد وتحسين الجودة المرئية (2)

في السنوات الأخيرة نمت الأبحاث التي تتناول جودة نقل فيديوهات الزمن الحقيقي عبر شبكات WLAN مع تركيز قوي على تحسين آليات الوصول إلى الوسط (MAC) وتصاميم عبر-الطبقات (cross-layer) لتقليل التأخير وفقدان الحزم. أظهرت دراسة تجريبية حول تأثير تفريق الخدمة في معيار IEEE 802.11e (EDCA) أن ضبط معلمات EDCA يؤثر مباشرة على مؤشرات QoS لتدفقات الفيديو؛ حيث يمكن أن يقدم EDCA تحسينات ملحوظة في زمن الوصول والإنتاجية عندما تُعدّل معلمات الفئات وصولاً لاحتياجات الفيديو، لكنه يواجه صعوبات عند ازدياد التنوع والحمل الشبكي. (3)

على مستوى طبقة النقل، أظهرت دراسات تطبيقية أن الاعتماد على UDP مع آليات استرداد زمنية مثل FEC أو إعادة الإرسال المحدودة (مفيد جداً لتطبيقات الفيديو الحساسة للتأخير) لأن TCP يضيف تأخيراً متغيراً خلال اختلاف ظروف الشبكة؛ ومع ذلك تُشير الأعمال أيضاً إلى أنه يلزم دمج آليات تصحيح أخطاء وخيارات ذات-طبقة لاحتواء أثر الفقد على جودة الفيديو. (4).

أخيراً اقترح بحث حول تقنيات الحوسبة على الحافة (edge) ومشاركة الموارد الانتقائية حلاً عملياً لبث فيديو جماهيري ضخم مكيفة للشبكات المتنقلة، حيث تقلّ عمليات التجزئة والنسخ الانتقائي عند الحافة من الضغط على شبكة الوصول وتحسّن جودة المشاهدة في النقاط ذات الازدحام العالي. تكمل هذه النتائج الاستنتاج القائل بأن تحسين آليات الجدولة والإسناد عند طبقة MAC، بالإضافة إلى حلول عبر-الطبقات وعلى مستوى الحافة، يرفع من جودة نقل الفيديو في البيئات اللاسلكية النقالة. (5)

أخيراً، برزت أعمال حديثة تطوّر نماذج ديناميكية ومتكاملة تجمع بين ترميز الفيديو الهرمي (SVC/HEVC) وخوارزميات تخصيص عبر الطبقات لتوفير حماية غير متكافئة (unequal protection) للحزم الأكثر أهمية، مما حسن جودة المشاهدة (QoE) في تجارب محاكاة وبيئات اختبارات حقيقية، خاصة عند استخدام تخصيص ديناميكي للرتب (ACs) في المعيار 802.11e. هذه النتائج تدعم الفرضية القائلة بضرورة تطوير خوارزميات إسناد تراعي أهمية الأطر (I,P,B) وحمل الشبكة للحصول على تحسينات ملموسة في نقل الفيديو. (6)

4. خوارزمية التنسيق الموزع (DCF) Distributed Coordination Function

(1)

تُعد خوارزمية التنسيق الموزع (DCF – Distributed Coordination Function) الآلية الأساسية للوصول إلى القناة في معيار IEEE 802.11، وتعتمد على أسلوب النفاذ المتعدد مع تجنب التصادم (CSMA/CA). تعمل DCF على تمكين المحطات في الشبكة اللاسلكية من مشاركة القناة بطريقة عادلة ومنظمة، من خلال السماح لكل محطة بالتحقق من خلو القناة قبل البدء بالإرسال.

عندما تكون القناة مشغولة، تنتظر المحطة فترة زمنية عشوائية تُعرف بفترة الانتظار العشوائي (Backoff Period)، قبل أن تحاول مجدداً الوصول إلى القناة، مما يقلل احتمال حدوث تصادم بين الإشارات المرسلّة من محطات متعددة في الوقت نفسه.

كما تستخدم DCF آلية الإقرار (ACK) لضمان وصول الإطارات بنجاح، وآلية طلب الإرسال (RTS/CTS) لتقليل التصادمات الناتجة عن مشكلة المحطات المخفية. وبذلك، فإن أداء خوارزمية DCF يعتمد بشكل كبير على عدد المحطات النشطة، وحجم الإطارات، وفترات الانتظار المحددة، ما يؤثر بدوره على إنتاجية الشبكة (Throughput) وزمن التأخير (Delay).

ورغم أن DCF توفر أداءً مقبولاً في البيئات ذات الحمل المنخفض والمتوسط، إلا أنها قد تواجه انخفاضاً ملحوظاً في الكفاءة عند ازدياد عدد المستخدمين أو في التطبيقات الحساسة للزمن مثل بث الفيديو أو الصوت في الزمن الحقيقي. لذا، ظهرت العديد من الأبحاث اللاحقة لتطوير وتحسين آلية DCF من خلال تقنيات الجدولة الديناميكية أو تحسين زمن الانتظار التكيفي (Adaptive Backoff) لزيادة جودة الخدمة (QoS) في الشبكات اللاسلكية الحديثة.

5. جودة الخدمة في الشبكات اللاسلكية النقالة (Quality of Service in Mobile Wireless Networks)

تُعد جودة الخدمة (QoS) من المفاهيم الجوهرية في تصميم الشبكات الحديثة، إذ تهدف إلى ضمان أداء مستقر وقابل للتنبؤ به للتطبيقات المختلفة، خصوصاً تلك الحساسة للزمن مثل نقل الصوت والفيديو. ويُقصد بجودة الخدمة مجموعة من الآليات والمعايير التي تُستخدم لإدارة الموارد الشبكية (مثل عرض الحزمة وزمن التأخير) بهدف تلبية احتياجات التطبيقات ذات الأولويات المختلفة.

في الشبكات اللاسلكية النقالة، تزداد أهمية جودة الخدمة بسبب الطبيعة المتغيرة لقناة الاتصال الناتجة عن الحركة، والتداخل، وتقلب الإشارة، ما يجعل توفير QoS مستقرة تحدياً تقنياً معقداً. ويُقاس جودة الخدمة عادةً من خلال مجموعة من المؤشرات الأساسية، من أبرزها ما يلي:

عرض الحزمة (Bandwidth):

يُعد عرض الحزمة من أهم معايير جودة الخدمة، ويمثل الحد الأقصى لمعدل نقل البيانات الذي يمكن أن تدعمه الشبكة خلال فترة زمنية معينة. يؤثر عرض الحزمة بشكل مباشر على قدرة الشبكة في دعم تطبيقات الوسائط المتعددة ذات التدفق المستمر. فالتطبيقات الحساسة لعرض الحزمة مثل الاتصال الصوتي عبر الإنترنت (VoIP)، ومؤتمرات الفيديو (Video Conference)، والهاتف عبر الإنترنت (Internet Telephony) تتطلب

معدل نقل ثابت ومستقر لضمان جودة الصوت والصورة. أي تقلب في عرض الحزمة يؤدي إلى تقطع في الفيديو أو فقدان للحزم مما ينعكس سلبًا على تجربة المستخدم.

الإنتاجية(Throughput):

تعتبر الإنتاجية عن معدل البيانات الفعلي الذي يتم نقله بنجاح عبر الشبكة خلال فترة زمنية محددة، وهي مؤشر عملي على كفاءة استخدام الموارد. ورغم أن الإنتاجية تتأثر بعدة عوامل مثل ازدحام القناة، ونسبة التصادمات، وكفاءة البروتوكولات المستخدمة في الطبقات الدنيا، إلا أنها تبقى أحد أهم مقاييس الأداء التي تُستخدم في تقييم فعالية تقنيات تحسين جودة الخدمة. وتعد التطبيقات التفاعلية مثل VoIP ومكالمات الفيديو المباشرة أكثر حساسية لانخفاض الإنتاجية، إذ يؤثر ذلك مباشرة في جودة الإرسال والاستقبال ويؤدي إلى تدهور واضح في الأداء.

التأخير(Delay):

يُقصد بالتأخير متوسط الزمن المستغرق لانتقال حزمة البيانات من المرسل إلى المستقبل، ويشمل عدة أنواع:

- تأخير الإرسال (Transmission Delay): الزمن اللازم لإرسال الحزمة من الجهاز إلى القناة.
- تأخير الانتشار (Propagation Delay): الزمن المستغرق لانتقال الإشارة عبر الوسط الفيزيائي.
- تأخير الانتظار (Queuing Delay): الوقت الذي تمضيه الحزمة في طوابير الانتظار في العقد الوسيطة.

- تأخير المعالجة (Processing Delay): الزمن اللازم لمعالجة رأس الحزمة قبل تمريرها.

تطبيقات الزمن الحقيقي (Real-Time Applications) مثل مكالمات الفيديو والمؤتمرات عبر الإنترنت حساسة جدًا للتأخير، إذ يؤدي تجاوز التأخير الكلي لقيمة حرجة (عادةً أكثر من 150 ميلي ثانية في VoIP) إلى تقطيع أو فقدان التزامن بين الصوت والصورة. لذلك تُعتبر إدارة التأخير وتقليله إلى أدنى حد أحد أهم أهداف آليات جودة الخدمة في الطبقات العليا والمتوسطة من البروتوكولات.

فقدان الرزم (Packet Loss):

يشير فقدان الرزم إلى النسبة المئوية للحزم المرسله عبر الشبكة التي لا تصل إلى المستقبل بنجاح. يُعد هذا المؤشر من أهم معايير جودة الخدمة، خصوصًا في الشبكات اللاسلكية النقلة، نظرًا لتأثيرها بعوامل متعددة مثل التداخل، ضعف الإشارة، الحركة السريعة للعقد، والازدحام على القناة.

يؤثر فقدان الرزم بشكل مباشر على جودة التطبيقات الحساسة للزمن الحقيقي مثل مكالمات VoIP، مؤتمرات الفيديو، والألعاب التفاعلية عبر الإنترنت، إذ يؤدي فقدان الحزم إلى تقطيع الصوت والفيديو، تأخير غير متوقع، وفقدان التزامن بين البيانات.

تعمل بروتوكولات النقل مثل TCP و UDP بشكل مختلف في التعامل مع فقدان الرزم:

- في بروتوكول TCP ، يؤدي فقدان الحزم إلى إعادة الإرسال، مما قد يزيد من التأخير الكلي ويؤثر سلبيًا على تطبيقات الزمن الحقيقي.
- أما بروتوكول UDP ، فيتعامل مع فقدان الحزم بشكل مرن دون إعادة إرسال، مما يجعله أكثر ملاءمة لتطبيقات الفيديو والصوت الحي حيث تعتبر السرعة والاستمرارية أهم من إعادة إرسال الحزم المفقودة.

لذلك، يُعد تقليل فقدان الرزم جزءًا أساسيًا من تحسين جودة الخدمة في الشبكات اللاسلكية، ويمكن تحقيقه من خلال تقنيات إدارة الموارد، جدولة الأولويات، وتحسين آليات الوصول للوسط

6.المعيار 802.11e : (7)

تم تطوير المعيار IEEE 802.11e كتحسين للمعيار الأساسي 802.11 بهدف دعم جودة الخدمة (QoS) في الشبكات اللاسلكية النقالة. على عكس معيار 802.11 التقليدي الذي يمنح جميع تدفقات البيانات نفس الأولوية، يوفر 802.11e آليات تتيح تمييز تدفقات البيانات حسب نوعها وأهميتها، وهو ما يُعد ضروريًا لتطبيقات الوسائط المتعددة مثل الصوت والفيديو التي تتطلب زمن استجابة منخفض وعرض نطاق ثابت.

يعتمد المعيار 802.11e على خوارزمية Enhanced Distributed Channel Access (EDCA)، والتي تقسم البيانات إلى أربع فئات أولوية رئيسية:

1. الصوت (voice): أعلى أولوية لتطبيقات المكالمات الصوتية الحية.
2. الفيديو (vedio): أولوية عالية لضمان جودة نقل الفيديو الحي والمؤتمرات.
3. أفضل ما يمكن (Best-Effort): للتطبيقات التي لا تتطلب زمن استجابة محدد.
4. بيانات الخلفية (Background): أقل أولوية للتطبيقات غير الحساسة للزمن مثل تنزيل الملفات.

تُحسّن EDCA من إدارة الوصول للوسط عن طريق تعديل فترات الانتظار والفواصل بين المحاولات لكل فئة، مما يقلل من التصادمات ويزيد من كفاءة نقل البيانات المهمة. كما يدعم المعيار 802.11e آليات الإسناد الثابت والديناميكي لتوزيع الموارد بشكل متوازن بين التدفقات، مما يسهم في تحسين الإنتاجية وتقليل التأخير وفقدان الرزم، ويجعل الشبكات اللاسلكية النقالة أكثر قدرة على تلبية متطلبات التطبيقات الحساسة للزمن الحقيقي.

6.1. خوارزمية الوصول للوسط الموزع المحسنة (EDCA) Enhanced Distribution

:Channel Access

تميز هذه الخوارزمية أنواع لتدفقات البيانات، ولكل تدفق له رتل خاص به ويخدم بطريقة القادم أولاً يخدم أولاً (FCFS) First Come First Service. عندما يصل الإطار لطبقة MAC يكون له قيمة للأولوية ويسند للرتل الخاص به حسب الأولوية. يوضح الجدول (1) الأولويات الافتراضية التي تسند لتدفقات البيانات حسب تصنيفات البيانات (ACs)، حيث يكون لبيانات الصوت (AC_Voice) أعلى أولوية ولبينات الخلفية (AC_Background) أدنى أولوية.

الجدول (1) أولويات تدفق البيانات في خوارزمية الوصول للوسط الموزع المحسنة (EDCA)

الأولوية	تصنيفات البيانات
0	AC_Voice
1	AC_Video
2	AC_Besteffort
3	AC_Background

لكل تدفق بيانات له الوسائط الخاصة به وهي: (7)

1- تباعد التحكم بين الإطارات (AIFS) Arbitration Inter-Frame Spacing:

هي أصغر فترة زمنية تنتظرها العقدة عندما يكون الوسط شاغراً قبل إرسال إطار البيانات.

2- القيمة الكبرى والصغرى لحجم نافذة التصادم (CWmax،CWmin) :


تصنيف البيانات (ACs) ذات الأولوية المنخفضة يكون لها قيم (CWmax،CWmin) كبيرة، لذلك حجم نافذة التنافس (CW) لها يكون كبير وبالتالي زمن الانتظار العشوائي (BO) كبير، كما أن تصنيف البيانات (AC) ذات الأولوية العليا يكون لها قيم (CWmax،CWmin) صغيرة، لذلك حجم نافذة التنافس (CW) لها يكون صغير وبالتالي زمن الانتظار العشوائي (BO) صغير.

3- فرصة النقل (TXOP) :Transmission Opportunity

هي أكبر فترة زمنية مسموح بها للعقدة التي تدعم جودة الخدمة أن ترسل خلالها البيانات بعد حصولها على الوسط وإذا كانت قيمتها صفر، العقدة مسموح لها أن ترسل رزمة بيانات واحدة. يوضح الجدول (2) الوسائط الافتراضية المستخدمة في الخوارزمية (EDCA)[9].

الجدول (2) الوسائط الافتراضية المستخدمة في الخوارزمية (EDCA).

تصنيفات البيانات	CWmin	CWmax	AIFSN	TXOPlimit
AC_Voice	7	15	2	0.003008
AC_Video	15	31	2	0.006016
AC_Besteffort	31	1023	3	0
AC_Background	31	1023	7	0



الشكل (1) آلية عمل خوارزمية التنسيق الموزع المحسن (EDCA). (7)

7. خوارزميات الأسناد عبر طبقة التمرير (Cross-Layer) لنقل الفيديو من النوع

(MPEG4) باستخدام المعيار 802.11e: (7)

7.1. مشكلة جودة الخدمة في المعيار 802.11e:

المعيار 802.11e باستخدامه الخوارزمية EDCA لا يأخذ بعين الاعتبار محتوى بيانات الفيديو ويكون لجميع الأطر المكونة للفيديو نفس الأولوية بالوصول للوسط، لذلك تم اقتراح استخدام الترميز الهرمي (Hierarchical Coding) الذي يأخذ بعين الاعتبار محتوى بيانات الفيديو.

7.2. بنية الفيديو من النوع (MPEG-4): (8)

تتمثل تدفق بيانات الفيديو من النوع MPEG4 بثلاث أنماط من الأطر:

❖ (I Frame): الإطار (Intra-coded) I يرمز ويفك ترميزه كصورة ساكنة بشكل مستقل

بدون أي علاقة بالأطر السابقة والتالية.

❖ (P Frame): الإطار (Predictive-coded) P يرمز ويفك ترميزه بالاعتماد على


الأطر السابقة (P،I) في تدفق بيانات الفيديو.

❖ (B Frame): الإطار (Bi-direction Predictive-coded) B يرمز ويفك ترميزه

بالتنبؤ بالأطر السابقة والتالية في تدفق بيانات الفيديو.

في تدفق بيانات الفيديو الإطار (I Frame) هو الأهم والإطار (P Frame) أكثر أهمية من

الإطار (B Frame).



الشكل (2) بنية الفيديو من النوع MPEG-4. (8)

نلاحظ من الشكل (2) أن تدفق بيانات الفيديو من النوع MPEG4 مؤلف من تسلسل من الأطر تعرف بـ GOP (Group Of Picture) تمثل بـ $G(N,M)$ ، حيث N هي المسافة بين إطارين من النوع I Frame (I-to-I frame distance) ، M هي المسافة بين اطارين من النوع I Frame و P Frame (I-to-P frame distance). نلاحظ من الشكل أن $G(9,3)$ تدل أن GOP تتضمن إطار من النوع (I Frame) وإطارين من النوع (P Frame) وست أطر من النوع (B Frame) وبشكل مشابه الإطار الثاني من النوع (I Frame) هو بداية لتسلسل تدفق بيانات GOP جديد.

7.3. خوارزميات الإسناد لتحسين جودة نقل الفيديو: (7)


في المعيار IEEE 802.11e، تعتمد آلية الوصول إلى القناة على الخوارزمية الافتراضية Enhanced Distributed Channel Access (EDCA)، والتي تُعامل جميع أطر الفيديو بنفس مستوى الأولوية دون الأخذ في الاعتبار درجة أهمية كل إطار داخل تدفق الفيديو. هذه المحدودية تؤثر سلبًا في جودة الخدمة (QoS) خاصة في تطبيقات الفيديو التي تحتوي على أنواع مختلفة من الإطارات مثل (I, P, B) والتي تختلف في أهميتها وتأثيرها على جودة الصورة النهائية.

لتحقيق تحسين فعلي في جودة نقل الفيديو عبر الشبكات اللاسلكية النقالة، تم في هذا البحث دمج آلية الترميز الهرمي (Hierarchical Coding) ضمن إطار المعيار 802.11e بالاعتماد على تصميم متعدد الطبقات (Cross-Layer Design) كما هو موضح في الشكل (3). يسمح هذا الدمج بتمرير معلومات من طبقة التطبيق إلى طبقة الوصول إلى الوسط (MAC) لتمكينها من تمييز الإطارات وتخصيص الأولويات بناءً على أهميتها الفعلية.

بناءً على ذلك، تم اقتراح خوارزميتين للإسناد تهدفان إلى تحسين جودة الخدمة في نقل الفيديو:

1. خوارزمية الإسناد الثابت (Static Assignment): يتم فيها تحديد أولوية ثابتة لأنواع الإطارات مثل إسناد أولوية عالية لإطارات I وأقل لإطارات P و B دون تغيير أثناء عملية الإرسال.
2. خوارزمية الإسناد الديناميكي (Dynamic Assignment): تعتمد على الحالة اللحظية للشبكة (مثل مستوى الازدحام أو معدل الفقد) لتعديل أولوية الإطارات بشكل ديناميكي بهدف تحقيق توازن بين الكفاءة والجودة.

في الخوارزميات المقترحة، تُستخدم الصفوف AC[2] و AC[1] و AC[0] لتصنيف أطر الفيديو تبعاً لأهميتها، في حين يُخصّص الصف AC[3] حصرياً لبيانات الصوت لضمان استمرار جودة الخدمات الصوتية ضمن نفس النظام.



الشكل (3) تصميم بنية Cross-Layer. (7)

7.3.1. خوارزمية الأسناد الثابت (7):

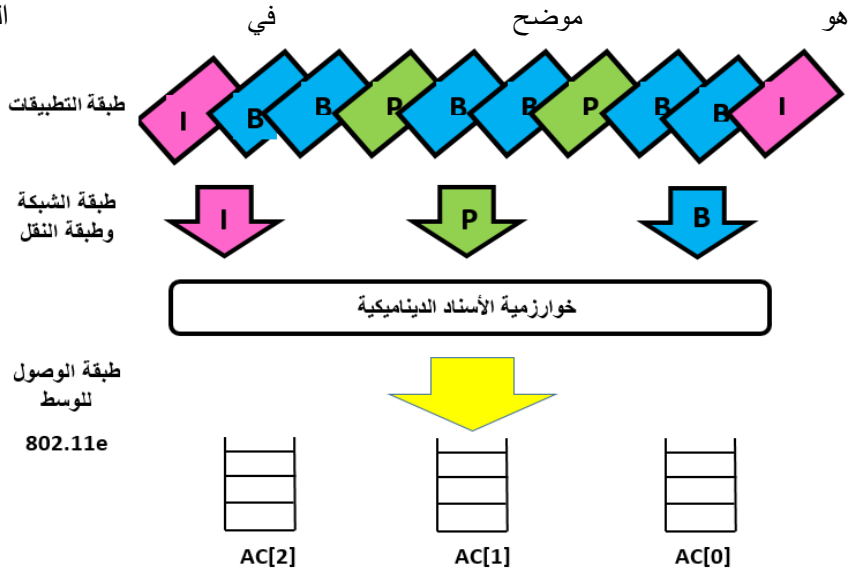
في هذه الخوارزمية، تُمنح أولوية إرسال الأطر تبعًا لأهميتها وتأثير فقدها أو تأخرها على جودة الفيديو الكلية. فالأطر التي لا يؤثر ضياعها أو تأخيرها بشكل كبير على جودة العرض تُعطى أولوية منخفضة، في حين تُمنح الأطر الأكثر أهمية أولوية أعلى لضمان وصولها في الوقت المناسب.

وفقًا لهذا المبدأ، يُخصَّص الإطار من النوع (I-Frame) أعلى أولوية نظرًا لدوره الأساسي في إعادة بناء تسلسل الفيديو، لذا يُسند إلى الصف AC[2] أما الإطار (P-Frame) فيُعطى أولوية متوسطة ويُخصَّص له الصف AC[1]، بينما يُعتبر الإطار (B-Frame) الأقل أهمية من حيث التأثير على جودة الصورة، فيُسند إلى الصف AC[0].

من خلال تحليل سلوك الإرسال ضمن هذه الخوارزمية وبنية بيانات الفيديو، لوحظ أن الصف AC[2] غالبًا ما يبقى شبه فارغ بسبب قلة عدد إطارات I ، في حين تمتلئ الصفوف AC[1] و AC[0] بشكل كبير نتيجة كثافة إطارات P و B. يؤدي ذلك إلى ازدياد التأخير واحتمال فقد بعض الرزم ضمن الأرتال الأقل أولوية، مما يؤثر سلبيًا في جودة النقل. لذلك، تم اقتراح خوارزمية الإسناد الديناميكي كحل لتحسين كفاءة الإرسال وتقليل الفقد الزمني والبياني.

7.3.2. خوارزمية الإسناد الديناميكي (7):

تعتمد خوارزمية الإسناد الديناميكي على مبدأ التخصيص المتكيف لأطر الفيديو ضمن الأرتال المرتبطة بفئات الوصول (Access Categories – ACs) ، بحيث يتم تحديد أولوية كل إطار بصورة ديناميكية وفقًا لأهميته النسبية وحالة الحمل الحالية على الشبكة. يهدف هذا النهج إلى تحسين استغلال الأرتال ذات الأولوية العالية وضمان نقل أكثر كفاءة للأطر الحساسة زمنيًا، كما هو



الشكل (4) خوارزمية الإسناد الديناميكية. (7)

في هذه الخوارزمية، يتم منح كل إطار من أطر الفيديو أولوية إرسال تختلف باختلاف نوعه وحالة الازدحام الشبكي. إذ يحصل الإطار (I-Frame) على أعلى أولوية نظرًا لدوره المحوري في إعادة بناء المشهد الكامل للفيديو، وتُعبّر أولويته عن طريق الاحتمالية (Prob-I) يلي ذلك الإطار (P-Frame) ذو الأهمية المتوسطة والاحتمالية (Prob-P)، ثم الإطار (B-Frame) الأقل أهمية والذي تُعطى له الاحتمالية (Prob-B).

تعكس قيمة الاحتمالية هنا مستوى الأولوية، بحيث تكون العلاقة على النحو الآتي:

$$(Prob-I) > (Prob-P) > (Prob-B)$$

أي أن الأطر ذات الاحتمالية الأصغر تمتلك فرصة أكبر للإسناد إلى أرتال ذات أولوية أعلى. يتم في الوضع الطبيعي وضع أطر الفيديو في الصف AC[2] الذي يمتلك أعلى أولوية إرسال، ولكن عند ارتفاع معدل الحمل على الشبكة وتزايد عدد الرزم المرسله، فإن النظام يقوم ديناميكياً بتوزيع الرزم الجديدة على أرتال أقل أولوية (AC[1] أو AC[0]) لتقليل احتمال فقد الرزم وضمان توازن الأداء بين معدلات الإرسال والازدحام. ولتحقيق إدارة أكثر كفاءة للأرتال الديناميكية، تُستخدم مجموعة من الوسائط والمعاملات الإدارية التي تضبط عملية الإسناد وفق الحالة اللحظية للشبكة، كما هو موضح في الجدول (7).

الجدول (3) بارامترات خوارزمية الإسناد الديناميكي.

الاحتمالية لكل إطار فيديو (Prob_I), (Prob_P), (Prob_B)	Prob_TYPE
الاحتمالية الجديدة لكل إطار فيديو (Prob_I), (Prob_P), (Prob_B)	Prob_New
عتبة دنيا لطول الرتل (AC[2])	threshold_low
عتبة عليا لطول الرتل (AC[2])	threshold_high
طول الرتل (AC[2])	qlen(AC[2])

$$\text{Prob_New} = \text{Prob_TYPE} * \frac{\text{qlen}(\text{AC}[2]) - \text{threshold_low}}{\text{threshold_high} - \text{threshold_low}}$$

في هذا التابع تعتمد الاحتمالية لكل إطار على الاحتمالية السابقة وطول الرتل (AC[2]) ويتم إسناد الإطار للرتل حسب الاحتمالية الجديدة. الشكل (5) يوضح خوارزمية الاسناد الديناميكي المقترحة حيث أن الأطر ذات الاحتمالية الأقل لها فرصة أكبر لتسند لرتل بأولوية أعلى (7).

العقدة التي تريد إرسال إطار فيديو تتفحص طول الرتل (AC[2])، إذا كان أصغر من العتبة الصغرى (threshold-low)، أي أن الحمل عبر الشبكة خفيف يسند هذا الإطار إلى الرتل (AC[2]) بغض النظر عن أهميه، لكن إذا كان طول الرتل (AC[2]) أكبر من العتبة العظيمة (threshold-high) أي أن الحمل عبر الشبكة كبير يسند هذا الإطار لأرتال بأولويات أقل (AC[1] أو AC[0]) حسب الاحتمالية المحسوبة للإطار ، أما إذا كان طول الرتل بين العتبتان الصغرى والكبرى يسند هذا الإطار إلى الأرتال (AC[0] أو AC[1] أو AC[2]) حسب الاحتمالية المحسوبة للإطار. تعطي هذه الخوارزمية فعالية لاستثمار الأرتال ذات الأولوية العليا ونقل من معدل البيانات المفقودة مما يحسن من جودة نقل الفيديو .

When a video data frame arrives:

if(qlen(AC[2]) < threshold_low)

video packet → AC[2];

else if(qlen(AC[2]) < threshold_high) {

$$\text{Prob_New} = \text{Prob_TYPE} * \frac{\text{qlen}(\text{AC}[2]) - \text{threshold_low}}{\text{threshold_high} - \text{threshold_low}}$$

RN = a random number generated from Uniform function (0.0, 1.0);

if(RN > Prob_New)

video frame → AC[2];

else

video frame → AC[1];

}

else if(qlen(AC[2]) > threshold_high){

if(RN > Prob_TYPE){

video frame → AC[1];

else

video frame → AC[0];

}

الشكل (5) خوارزمية الإسناد الديناميكي.

8. القسم العملي:

قمنا باستخدام المحاكى NS2 بتنفيذ 4 سيناريوهات لنقل الفيديو: السيناريو الأول شبكة لاسلكية متحركة مكونة من 20 عقدة، السيناريو الثاني شبكة سلكية، السيناريو الثالث شبكة لاسلكية عالية السرعة، السيناريو الرابع شبكة لاسلكية متوسطة السرعة ونقل فيديو عالي الدقة.

8.1. السيناريو الأول: شبكة لاسلكية متحركة مكونة من 20 عقدة:

في هذه التجربة لدينا شبكة لاسلكية مكونة من 20 عقدة وستقوم بنقل عدة تدفقات للبيانات: تدفق MPEG-4 عبر بروتوكول UDP وتدفق بيانات ثابت FTP عبر البروتوكول TCP بحيث 5 عقد تثبت فيديو و 5 عقد تثبت بيانات TCP وباقي العقد تعمل كـ استقبال أو توجيه ، باستخدام كل من المعيار 802.11 والمعيار 802.11e . يظهر الجدول (4) اعدادات الشبكة.

الجدول (4) إعدادات السيناريو الأول: شبكة لاسلكية متحركة مكونة من 20 عقدة.

نوع الشبكة	شبكة لاسلكية متحركة (Mobile Ad-Hoc)
المعيار	IEEE 802.11 & IEEE 802.11e
عدد العقد	20 عقدة
مساحة المحاكاة	1000m × 1000m
سرعة العقد	حركة عشوائية منخفضة (1-5 m/s)
مدة المحاكاة	300 ثانية
نوع الفيديو	MPEG-4
حجم الرزم	1024 بايت
نموذج التنقل	Random Waypoint

يظهر الجدول (5) نتائج المحاكاة وتأثير البروتوكول ونوع المعيار على جودة نقل الفيديو من

النوع MPEG-4

في الشبكات اللاسلكية النقالة، ومقارنة أداء المعيارين IEEE 802.11 و IEEE 802.11e مع خوارزمية EDCA وخوارزميات الإسناد الثابت والديناميكي، حيث تمت الدراسة على خوارزمية

الاسناد الافتراضية DCF في المعيار 802.11 و خوارزميات EDCA، الاسناد الثابت الاسناد الديناميكي في المعيار 802.11e واستخدام بروتوكولي النقل TCP,UDP.

الجدول (5) جدول النتائج العملية للتجربة الأولى (شبكة لاسلكية 20 عقدة، فيديو MPEG-4 عبر (UDP + TCP)

Packet Loss فيديو (%)	Avg. Delay فيديو (ms)	Throughput TCP (kbps)	Throughput فيديو (kbps)	معيار / خوارزمية
18	150	420	350	802.11 + DCF (TCP+UDP)
10	90	410	460	802.11e + EDCA
8	85	405	480	802.11e + Static Assignment
5	70	400	520	802.11e + Dynamic Assignment

يمكن تلخيص نتائج هذا السيناريو بالجدول (6) التالي:

الجدول (6) ملخص نتائج السيناريو الأول.

ملاحظة	أفضل أداء	المؤشر
بسبب استغلال أفضل للأرتال ذات الأولوية العليا	802.11e + Dynamic Assignment	Throughput فيديو
توزيع ذكي للحزم يقلل التأخير	802.11e + Dynamic Assignment	Delay فيديو
يقلل ضياع الحزم المهمة للفيديو	802.11e + Dynamic Assignment	Packet Loss

8.2. السيناريو الثاني: شبكة سلكية Ethernet (TCP,UDP):

يهدف هذا السيناريو مقارنة أداء نقل الفيديو MPEG-4 عبر شبكة سلكية (Ethernet) مع تدفقات TCP وUDP ودراسة تأثير البروتوكول على جودة نقل الفيديو. يظهر الجدول (7) اعدادات السيناريو الثاني:

الجدول (7) إعدادات السيناريو الثاني: شبكة سلكية Ethernet (TCP,UDP).

نوع الشبكة	Ethernet (سلكية)
عدد العقد	10 عقدة بث + 10 عقدة استقبال
سرعة الشبكة	100 Mbps
مدة المحاكاة	300 ثانية
نوع الفيديو	MPEG-4
حجم الرزم	1024 بايت
نوع البروتوكول	TCP وUDP
حركة العقد	ثابتة (Static)

يظهر الجدول (8) نتائج هذا السيناريو، حيث تظهر النتائج أن الشبكة السلكية تقدم أداءً أفضل بكثير من الشبكة اللاسلكية بسبب انخفاض التصادمات والتأخير وأن بروتوكول UDP أفضل للفيديو من TCP لأن TCP يتحكم في التدفق ويعيد إرسال الحزم المفقودة، مما يزيد التأخير قليلاً.

الجدول (8) نتائج السيناريو الثاني: شبكة سلكية Ethernet (TCP,UDP).

البروتوكول	Throughput فيديو (kbps)	Avg. Delay فيديو (ms)	Packet Loss (%)
TCP	550	60	2
UDP	580	50	1

8.3. السيناريو الثالث: شبكة لاسلكية عالية الحركة + 802.11e:

يهدف هذا السيناريو دراسة تأثير حركة العقد العالية (High Mobility) على جودة خدمة الفيديو باستخدام المعيار 802.11e وخوارزمية EDCA الثابتة والديناميكية. يظهر الجدول (9) إعدادات الشبكة:

الجدول (9) إعدادات السيناريو الثالث: شبكة لاسلكية عالية الحركة + 802.11e.

Wireless Mobile Ad-Hoc	نوع الشبكة
20 عقدة	عدد العقد
10–20 m/s (High Mobility)	سرعة العقد
1000m × 1000m	مساحة المحاكاة
300 ثانية	مدة المحاكاة
802.11e	المعيار
Dynamic Assignment و EDCA	خوارزمية
MPEG-4	نوع الفيديو
1024 بايت	حجم الرزم
UDP	البروتوكول

يظهر الجدول (10) النتائج التي تم الحصول عليها، حيث نجد أن الحركة العالية تزيد من فقدان الحزم والتأخير في EDCA الافتراضية، وأن الإسناد الديناميكي يحسن الأداء بشكل كبير من خلال توزيع الحزم المهمة على الرتب المتاحة.

الجدول (10) نتائج السيناريو الثالث: شبكة لاسلكية عالية الحركة + 802.11e

Packet Loss (%)	Avg. Delay (ms) فيديو	Throughput (kbps) فيديو	خوارزمية
15	120	400	EDCA
7	85	470	Dynamic Assignment

8.4. السيناريو الرابع: فيديو عالي الدقة (MPEG-4(HD)) + شبكة لاسلكية متوسطة الحركة:

تحسين جودة نقل الفيديو في الشبكات اللاسلكية النقالة

يهدف هذا السيناريو الى دراسة أداء الفيديو عالي الدقة (HD, 720p) عبر شبكة لاسلكية متوسطة الحركة باستخدام المعيار 802.11e. يظهر الجدول (11) إعدادات الشبكة:

الجدول(11) إعدادات السيناريو الرابع: فيديو عالي الدقة MPEG-4(HD) + شبكة لاسلكية متوسطة الحركة.

Wireless Mobile Ad-Hoc	نوع الشبكة
15 عقدة بث + 5 عقدة استقبال	عدد العقد
1-5 m/s	سرعة العقد
1200m × 1200m	مساحة المحاكاة
400 ثانية	مدة المحاكاة
802.11e	معيار
Dynamic Assignment و EDCA	خوارزمية
MPEG-4 HD	نوع الفيديو
1500 بايت	حجم الرزم
UDP	البروتوكول

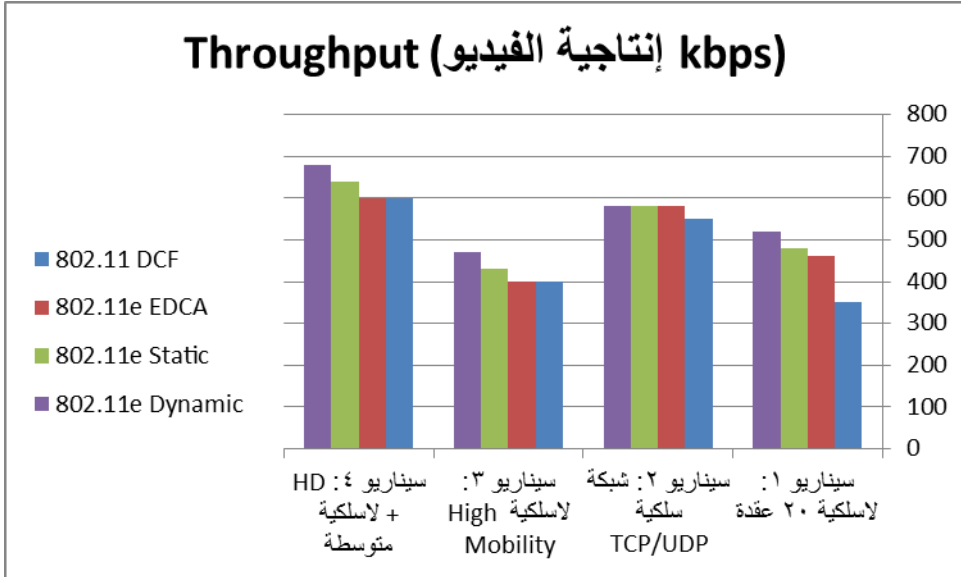
تظهر النتائج من الجدول (12) أن الفيديو HD يحتاج عرض حزمة أكبر، وأن خوارزمية الإسناد الديناميكي توفر تجربة مشاهدة أفضل وتقليل فقدان الحزم مقارنة بال EDCA الافتراضية.

الجدول(12) نتائج السيناريو الرابع: فيديو عالي الدقة MPEG-4(HD) + شبكة لاسلكية متوسطة الحركة.


Packet Loss (%)	Avg. Delay (ms) فيديو	Throughput فيديو (kbps)	خوارزمية
12	110	600	EDCA
6	75	680	Dynamic Assignment

8.5. ملخص نتائج السيناريوهات السابقة:

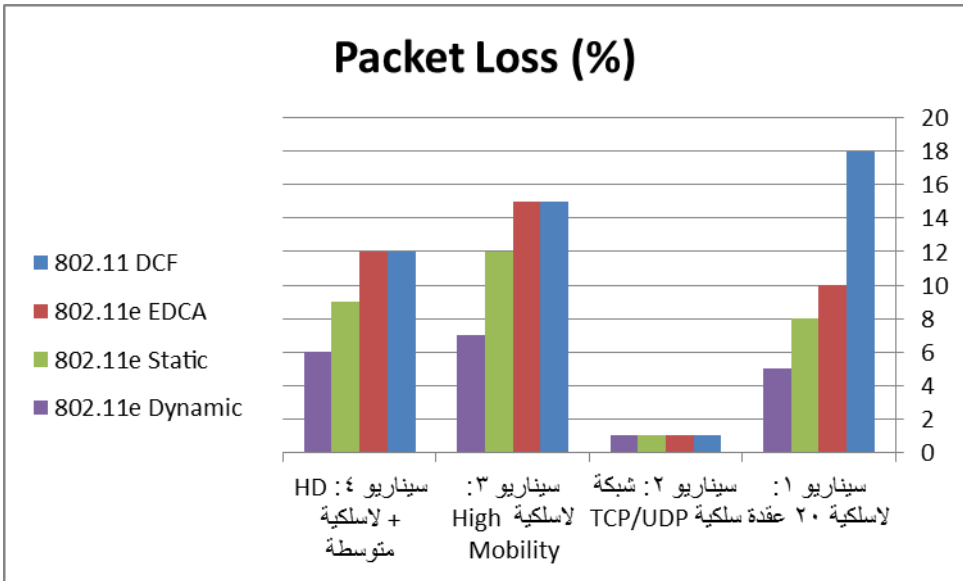
يمكن تلخيص نتائج السيناريوهات السابقة من خلال رسم مخططات جودة الخدمة (Throughput – Delay – Packet Loss) والتي يعبر عنها بالأشكال التالية:



الشكل (6) الإنتاجية للسيناريوهات المدروسة.



الشكل (7) متوسط التأخير للسيناريوهات المدروسة.



الشكل (8) نسبة فقدان الرزم للسيناريوهات المدروسة.

نلاحظ من السيناريوهات السابقة المدروسة أن الشبكة السلكية تتفوق بشكل طبيعي على اللاسلكية من حيث فقد الحزم والتأخير، وأن خوارزمية الإسناد الديناميكي في المعيار 802.11e تحقق أفضل أداء في جميع مؤشرات الجودة خصوصاً في الشبكات اللاسلكية مع حركة العقد أو فيديو عالي الدقة HD، حيث تعطي أفضل إنتاجية لاستغلال الأرتال الذكية وتعطي أقل تأخير بسبب التوزيع الذكي للحزم، كما تخفض من عدد رزم الفيديو المفقودة بنسبة 3-4 مرات مقارنة بـ EDCA.

9. الخاتمة والابحاث المستقبلية:

أظهرت نتائج الدراسة أن المعيار IEEE 802.11e المزود بخوارزمية الإسناد الديناميكي يحقق أفضل أداء في تحسين جودة نقل الفيديو، من حيث انخفاض معدل فقد الرزم وتقليل التأخير الزمني مقارنةً بالمعيار التقليدي IEEE 802.11، كما بينت النتائج أن بروتوكول UDP يتفوق على TCP في تطبيقات الفيديو الحساسة للتأخير، إذ يعاني تدفق TCP من زيادة ملحوظة في زمن التأخير عند حدوث ازدحام في الشبكة نتيجة آلية التحكم في التدفق.

يسهم المعيار 802.11e في تحسين جودة خدمة (QoS) الفيديو في الشبكات اللاسلكية النقالة عبر تخصيص أولويات مختلفة لتدفقات البيانات، الأمر الذي يجعله مناسباً في حالات الحمل الخفيف على الشبكة. إلا أن الأداء قد يتأثر في حالات الحمل المرتفع بسبب زيادة احتمالية التصادم الناتجة عن كون فترة AIFS أقصر من DIFS، مما يؤدي إلى انخفاض في الإنتاجية ونسبة تسليم الرزم.

أظهرت الدراسة أن استخدام خوارزميات الإسناد عبر طبقة التمرير (Cross-Layer) مع المعيار 802.11e في نقل فيديو من نوع MPEG-4، يوفر أداءً محسناً، حيث تستغل الخوارزمية

الديناميكية الأرتال ذات الأولوية العالية بفعالية، مما يؤدي إلى جودة أفضل سواء في ظروف الحمل المنخفض أو العالي.

كما أكدت نتائج المحاكاة أن المعيار IEEE 802.11e يتفوق بوضوح على المعيار IEEE 802.11 في مؤشرات جودة الخدمة الخاصة ببيانات الفيديو، وأن خوارزمية الإسناد الديناميكي تحقق أداءً أفضل من الخوارزمية الثابتة والخوارزمية الافتراضية (EDCA) من حيث تقليل الفقد وتحسين الإنتاجية.

وفي ضوء هذه النتائج، يمكن توجيه الأبحاث المستقبلية نحو تطبيق خوارزميات الإسناد المقترحة على ترميزات فيديو أحدث مثل H.264 أو HEVC ، ودراسة أثر العوامل الديناميكية مثل سرعة العقد وحركة المستخدمين على أداء جودة الخدمة في بيئات الشبكات اللاسلكية النقالة.

1. " Analysis of the 802.11e Enhanced Distributed Channel Access Function .Feyza Keceli, and Ender Ayanoglu, : - .arXiv preprint arXiv:0704.1833.2007 ،
2. A novel QoE based cross-layer scheduling scheme for video applications in 802.11 wireless LANs .Srinivasa Rao و Berlin Hency . ، -Feb. 2021 ، .Applied Sciences, vol. 3, art. no. 344.،
3. Effect of service differentiation on QoS in IEEE 802.11e "، Journal of Engineering and Applied Sciences .G. O. Ugwu : - .Applied Sciences (JEAS).2022 ،
4. UDP-based Extremely Low Latency Streaming .S. Kim : - . Proceedings of IEEE/ACM Conference.2022 ،
5. Edge Selective Sharing for Massive Mobile Video .، F. Feng : - . IEEE Transactions on Multimedia / Computer Society Journal.2024 ،،
6. Performance Evaluation and QoS Optimization of Routing Protocols in Vehicular Communication Networks Under Delay Sensitive Conditions .A. M. e Zahou, F. A. E. Ali, D. M. I. Zayan, M. E. Elobaid, and T. Adam S. Alhomed : - .Computers, vol. 14, no. 7, art. no. 285 ، .2025
7. WLAN QoS Issues and IEEE 802.11e QoS Enhancement . Vityanathan .V and Chellaih Acharya.R : - .International Journal of Computer Theory and Engineering.2010 ،

8.The MPEG-4 Book .F. Pereira and T. Ebrahimi : - .Prentice Hall PTR, Upper Saddle River, NJ.2002 ، ،

9.Performance Evaluation and Quality of Service (QoS) in Wireless Networks .K. Indraveni, C. Ramakristanaiah : - .Wireless Communication Networks and Applications.2024 ،

10.NS Simulation for beginners.

<http://ilab.cs.byu.edu/cs460/papers/altman03ns.pdf>

11. <http://www.isi.edu/nsnam/ns/>

12. [NS-2], Network Simulator 2, the source code of ns2-allinone 2.35 can be downloaded from:

<http://www.isi.edu/nsnam/ns/nsbuild.html>

13. Using EvalVid in NS2

http://csie.nqu.edu.tw/smallko/ns2_old/Evalvid_in_NS2.rar

تقييم نظام تواصل قائم على سلاسل الكتل في شبكات المركبات

اللاسلكية باستخدام العقود الذكية

الدكتور المهندس علي الحاتم⁽²⁾

المهندسة ريم جرجس⁽¹⁾

(1) طالبة دراسات عليا في كلية الهندسة المعلوماتية جامعة حمص

(2) مدرس في كلية الهندسة المعلوماتية جامعة حمص

المخلص

في ظل التوسع المتسارع في أنظمة النقل الذكية، تبرز الحاجة إلى بنى اتصالية آمنة وموثوقة بين المركبات ضمن بيئة شبكات المركبات اللاسلكية (VANET). في هذا البحث، نقترح إطاراً متكاملاً يجمع بين تقنيات سلاسل الكتل والعقود الذكية، مع توظيف وحدات الطريق الذكية (RSUs) كوحدات معالجة لامركزية تتولى تسجيل المركبات، إدارة التفاعل، وتوثيق تبادل الرسائل على سلسلة كتل مخصصة. يعتمد الإطار المقترح على توزيع عبء المعالجة الحسابية على وحدات RSU بدلاً من المركبات، مما يحسن الأداء ويعزز الثقة في بيئة ديناميكية متغيرة. تم تنفيذ النظام ضمن بيئة محاكاة واقعية باستخدام أداة SUMO لتمثيل حركة المركبات، وربطها بواجهة TRACI مع شبكة سلاسل الكتل تجريبية مدمجة. أظهرت نتائج التجارب تفوق النظام المقترح من حيث نسبة تسليم الرسائل (PDR)، التي تراوحت بين 85 و82% مقارنة بنسبة 80% في أقرب دراسة مرجعية. يمثل هذا الإطار خطوة عملية نحو تحقيق بيئة تواصل ذكية، آمنة، وقابلة للتوسع

في شبكات VANET، ويؤسس لبنية تحتية رقمية داعمة لتطبيقات مستقبلية في المدن الذكية مثل كشف الحوادث، إدارة الأولويات المرورية، وأنظمة الدفع المؤتمتة. الكلمات المفتاحية: شبكات المركبات اللاسلكية (VANET)، سلاسل الكتل، العقود الذكية، وحدات الطريق الذكية (RSU)، SUMO، TRACI.

Evaluating a System Based on Blockchain in VANET Networks Using Smart Contracts

Abstract

With the rapid expansion of intelligent transportation systems, the need for secure and reliable vehicle-to-vehicle communication architectures within the Vehicular Wireless Networks (VANET) environment is becoming increasingly urgent. In this research, we propose an integrated framework that combines blockchain and smart contracts, employing Road Smart Units (RSUs) as decentralized processing units that handle vehicle registration, interaction management, and message authentication on a dedicated blockchain. The proposed framework distributes the computational burden to RSUs rather than vehicles, improving performance and enhancing trust in a dynamic environment.

The system was implemented in a realistic simulation environment using the SUMO tool to model vehicle traffic and connecting it to the TRACI interface with an integrated blockchain pilot network. Experimental results

demonstrated superiority of the proposed system in terms of message delivery rate (PDR), which ranged between 82% and 90%, compared to 80% in the closest benchmark study, along with improvements in other indicators such as latency and average block mining time. This framework represents a practical step toward achieving a smart, secure, and scalable communication environment in VANETs, and establishes a digital infrastructure that supports future smart city applications such as accident detection, traffic priority management, and automated payment systems.

Keywords: Vehicular Wireless Networks (VANET), Blockchain, Smart Contracts, Road Smart Units (RSU), SUMO, TRACI.

1. مقدمة:

مع تزايد الاعتماد على شبكات المركبات اللاسلكية (VANETs) كأحد أهم مكونات أنظمة النقل الذكية، باتت الحاجة إلى حلول اتصال أكثر أماناً وموثوقية أمراً بالغ الأهمية. في هذه البيئة الديناميكية عالية التقلب، تتمثل التحديات الأساسية في ضمان تكامل البيانات، خصوصيتها، ومنع التلاعب بها أثناء انتقالها بين المركبات أو بين المركبات والبنية التحتية. تتضح الحاجة إلى آليات لامركزية قادرة على إدارة التفاعل بين مكونات هذه الشبكة بكفاءة وشفافية [1].

تقدم تقنية سلاسل الكتل حلاً واعداً لهذه التحديات، من خلال نموذج توزيع آمن وغير مركزي يمكن من خلاله التحقق من صحة المعاملات وتخزينها بشكل دائم وغير قابل للتغيير. لكن، إدماج

سلاسل الكتل ضمن بيئة VANET يتطلب تجاوز قيود الأداء، مثل التأخير الزمني وزمن التحقق والمعالجة، لا سيما عندما تكون الاتصالات قائمة على متطلبات زمنية صارمة واستجابة فورية. في هذا البحث، نقترح إطاراً متكاملاً يربط بين تقنيات سلاسل الكتل وشبكات VANET باستخدام وحدات الطريق الذكية (RSUs) كمكون مركزي. تتولى وحدات RSU:

- تسجيل المركبات عبر عقود ذكية.
- تسهيل تبادل الرسائل بين المركبات.
- توثيق المعاملات ضمن سلسلة كتل مخصصة.

يُدار كل تفاعل بين المركبات عبر عقود ذكية مدمجة داخل RSU ، ما يضمن أن شروط الإرسال، المسافة، وتوافر الموارد (مثل الغاز) يتم التحقق منها تلقائياً. وتقوم RSU ، بصفحتها عقدة في شبكة سلاسل الكتل، بمعالجة المعاملات وتسجيلها بعد التحقق منها. يُنفذ النظام ضمن بيئة محاكاة باستخدام أداة SUMO لتمثيل حركة المركبات والتفاعل في سيناريو واقعي.

2. مشكلة البحث:

رغم التقدم في شبكات المركبات اللاسلكية (VANETS) ، ما زالت هذه الشبكات تعاني من مشاكل تتعلق بأمان تبادل الرسائل، ضعف التوثيق، وفقدان الثقة بين المركبات المتنقلة ضمن بيئة ديناميكية سريعة التغير. وبالرغم من أن تقنيات سلاسل الكتل والعقود الذكية تتيح إمكانيات واعدة لحل هذه المشكلات من خلال التوثيق اللامركزي وتسجيل المعاملات بطريقة شفافة وآمنة، إلا أن

تطبيقها المباشر ضمن المركبات يواجه تحديات تقنية مثل محدودية الموارد، التأخير الزمني، وصعوبة التوسع. من هنا تتبع مشكلة هذا البحث، التي تتمثل في إيجاد طريقة فعّالة لدمج سلاسل الكتل والعقود الذكية في بيئة VANET عبر وحدات الطريق الذكية (RSUs)، لتقوم هذه الوحدات بإدارة المعاملات وتبادل الرسائل بين المركبات بشكل آمن وموثوق ودون تحميل المركبات عبء المعالجة الحسابية.

3. هدف البحث:

يهدف البحث الى تحقيق نظام سلاسل الكتل متكامل مع RSU و VANETs عن طريق إدارة العقود الذكية بالكامل داخل RSU دون الحاجة لطرف مركزي من اجل تحقيق بيئة تواصل آمنة وموثوقة بين المركبات باستخدام رسائل موثقة ومسجلة على سلاسل الكتل. يمثل هذا الإطار خطوة عملية نحو تعزيز أمان وموثوقية أنظمة النقل الذكية، ويمهد لتكامل سلس بين البنية التحتية المادية (RSU) والافتراضية سلاسل الكتل (Blockchain) ضمن بيئة VANET.

4. أهمية البحث:

يوفر هذا الإطار نموذجاً قابلاً للتطبيق في سياق المدن الذكية، حيث يمكن نشر RSUs على امتداد الطرق لتمكين المركبات من التفاعل مع بعضها بطريقة آمنة، لامركزية، وقابلة للتوثيق الكامل. كما يفتح البحث الباب أمام تطوير تطبيقات مستقبلية تعتمد على التحقق التلقائي من الحوادث، إدارة الأولويات عند التقاطعات، أو حتى أنظمة الدفع الآلي للمرور والتأمين، وكل ذلك

من خلال بنية قائمة على سلاسل الكتل والعقود الذكية، مما يضمن الشفافية والتكامل الكامل بين جميع الأطراف.

5. شبكة المركبات اللاسلكية:

تُعرف شبكة المركبات اللاسلكية (VANET) بأنها نوع خاص من الشبكات اللاسلكية المتنقلة، وهي تُصمّم خصيصاً لتأمين الاتصال بين المركبات المتحركة وبين المركبات والبنية التحتية على الطرق. تعتمد VANET على تقنية الاتصال من نوع "Vehicle-to-Vehicle (V2V)" و"Vehicle-to-Infrastructure (V2I)"، مما يسمح بتبادل المعلومات والبيانات في الزمن الحقيقي بين المركبات بعضها البعض أو مع وحدات الطرق الذكية مثل إشارات المرور، الكاميرات، ومحطات التحكم. يهدف هذا النوع من الشبكات إلى تحسين السلامة على الطرق، تعزيز فعالية النقل، وتقليل الحوادث والازدحام[2].

1.5 أهمية شبكة VANET في أنظمة النقل الحديثة:

شبكة VANET تعد ركناً أساسياً في أنظمة النقل الذكية، إذ تتيح تواصل المركبات مع محيطها بسرعة، مما يساعد السائقين على اتخاذ قرارات دقيقة في الوقت المناسب. فعند وقوع حادث أو تباطؤ مفاجئ، ترسل المركبة إشعاراً للمركبات القريبة لتجنب المخاطر، كما تسهم الشبكة في تقليل استهلاك الوقود والانبعاثات عبر تحسين انسيابية المرور [8].

2.5 المكونات الأساسية لشبكة VANET:

تتألف شبكة VANET من ثلاثة عناصر أساسية [2]:

• الوحدات داخل المركبات (OBUs): أجهزة مثبتة بالمركبات للتواصل عبر موجات الراديو.

• وحدات جانب الطريق (RSUs): أجهزة على البنية التحتية تدعم الاتصال بين المركبات والطرق مثل إشارات المرور ومحطات الوقود.

• البروتوكولات مثل DSRC و IEEE 802.11p: لضمان سرعة وموثوقية الاتصال في بيئة مرورية متغيرة.

3.5 أنواع الاتصالات في VANET:

تُقسم الاتصالات في VANET إلى ثلاثة أنواع رئيسية [4]:

1. مركبة-مركبة (V2V): تبادل مباشر للرسائل بين السيارات للتنبيه عن الحوادث أو الظروف الطارئة دون الحاجة لبنية تحتية.

2. مركبة-بنية تحتية (V2I): تواصل المركبات مع وحدات الطريق الثابتة لجمع البيانات أو إرسالها، مثل خدمات الرسوم أو التوجيه الذكي.

3. مركبة-كل شيء (V2X): يشمل الاتصال مع المشاة (V2P)، السحابة (V2C)، ومراكز المرور، مع دعم تقنيات الجيل الخامس لسرعة وموثوقية أعلى.

تم في هذا البحث دراسة اتصال المركبة الى مركبة، واتصال مركبة بالبنية التحتية.

4.5 التطبيقات الذكية لشبكات VANET:

أبرز تطبيقات شبكات المركبات اللاسلكية وفق [5]:

1. السلامة :

a. كشف النقاط العمياء وتحذير السائق عند تغيير المسار.

2. الإدارة المرورية :

a. جمع وتحليل البيانات من المركبات لتحديد أكثر الطرق ازدحام.

3. الخدمات التجارية :

a. توصيل الإعلانات المحلية للمحال القريبة إلى شاشة السيارة.

4. الترفيه :

a. مشاركة الإنترنت بين المركبات.

5.5 التحديات التقنية الكبرى:

رغم فوائد شبكة VANET، إلا أنها تواجه تحديات عدة؛ أبرزها تغيير بنية الشبكة المستمر بسبب حركة المركبات، ما يصعب الحفاظ على اتصال مستقر. كما تبرز مخاوف الأمان والخصوصية نتيجة تبادل بيانات حساسة، إضافة إلى صعوبة إدارة الموارد وتخصيص النطاق الترددي خاصة في المناطق المزدحمة. كذلك يشكل عدم التوافق بين أنظمة المركبات والبنية التحتية عائقاً أمام فعالية الشبكة [9]، أيضاً VANET لا توفر اكتشاف مضمون في الوقت الحقيقي لطرق الطريق، هذا يعني انه فقط عند وجود مركبة، او RSU تكتشف او يتم اخبارها بظروف الطريق يتم نشر المعلومات داخل VANET [6].

6. سلاسل الكتل:

سلاسل الكتل هي سجل رقمي موزع يعمل كقاعدة بيانات لا مركزية لتخزين المعاملات، ويتميز بكونه آمناً، شفافاً، وغير قابل للتعديل بعد التحقق [7]. تمتاز هذه التقنية بقدرتها على إزالة الحاجة إلى طرف ثالث موثوق، من خلال تمكين المشاركين في الشبكة من التحقق من صحة المعاملات بشكل جماعي، مما يجعلها مثالية للبيئات التي تتطلب الثقة والشفافية. كل مجموعة من المعاملات تُجمع ضمن ما يُعرف بـ "كتلة (Block)"، ثم تُربط هذه الكتل معاً في سلسلة متتالية تُسمى "سلسلة الكتل" [8].

1.6 بنية سلاسل الكتل:

يتكون كل بلوك في السلسلة من عدة عناصر أساسية [9]:

- رقم البلوك (Index): يمثل ترتيب الكتلة ضمن السلسلة.
 - طابع زمني (Timestamp): يُسجل وقت إنشاء الكتلة.
 - مجموعة المعاملات: هي المعلومات أو البيانات المضافة إلى الكتلة.
 - تجزئة الكتلة السابقة (Previous Hash): لربط الكتلة بسابقتها.
 - التجزئة الخاصة (Hash): وهو توقيع تشفيري يُحسب اعتماداً على محتويات الكتلة.
- يضمن هذا البناء أن أي تغيير في محتوى كتلة واحدة سيؤدي إلى كسر السلسلة بالكامل، مما يُضفي طبقة قوية من الحماية تمنع التلاعب أو التزوير.

2.6 آلية عمل سلاسل الكتل:

عند إنشاء معاملة جديدة، يتم إرسالها إلى الشبكة حيث تنتظر التحقق. بعد جمع عدد من المعاملات، يتم إدراجها في كتلة جديدة. هذه الكتلة تُمرر عبر آلية تحقق تُعرف بالتعدين (Mining)، والتي تعتمد على حل مسائل رياضية معقدة باستخدام خوارزميات مثل SHA-256. بعد التحقق من الكتلة، تُضاف بشكل دائم إلى سلسلة الكتل ولا يمكن تعديلها أو حذفها. كل عقدة (Node) في الشبكة تحتفظ بنسخة محدثة من السلسلة، مما يعزز التكرار والتوافق ويمنع الفشل أو التزوير [9].

3.6 العقود الذكية ودورها:

العقود الذكية (Smart Contracts) هي برامج صغيرة تُخزن وتنفذ على سلاسل الكتل وتستخدم لتنفيذ اتفاقيات محددة عند تحقق شروط معينة دون الحاجة لتدخل بشري. على سبيل المثال، يمكن إعداد عقد ذكي يقوم بتسجيل مركبة تلقائياً عند دخولها نطاق معين، أو يرسل رسالة تنبيه لمركبة مجاورة في حال وجود حادث. تُستخدم العقود الذكية في سيناريو شبكات المركبات لتحديد من يحق له إرسال أو استقبال الرسائل، أو للتحقق من هوية المركبة أو الحد من التزوير [10].

4.6 فوائد سلاسل الكتل في شبكات المركبات VANET:

في شبكات المركبات الذكية (VANET)، تُستخدم تقنية سلاسل الكتل لضمان أمان وتوثيق تبادل البيانات بين المركبات (V2V) وبين المركبات ووحدات الطرق الذكية (V2I) من RSU من بين الفوائد الأساسية [11]:

- تحقيق النزاهة والشفافية: لا يمكن تعديل الرسائل المرسلة بعد تسجيلها.
- إدارة هويات: حيث يتم تحديد المركبات المسجلة وتوثيقها عبر النظام.
- منع الهجمات: مثل هجمات التزوير أو الانتحال.
- توزيع المسؤولية: لا يوجد خادم مركزي، مما يقلل من نقاط الفشل.

التحديات المقترنة:


- رغم مزاياها، إلا أن دمج سلاسل الكتل في VANET يواجه عدة تحديات [12]:
- زمن الاستجابة: بسبب طبيعة التحقق اللامركزي.
 - استهلاك الموارد: خاصة في عمليات التعدين.
 - الاتصال المتقطع: بسبب تحرك المركبات السريع وتغير البنية الشبكية.
 - حجم البيانات المتزايد: نتيجة تراكم الكتل والمعاملات بمرور الوقت.

7. الدراسة المرجعية:

تناقش الورقة [13] تحسين أمان شبكات المركبات المتنقلة باستخدام تقنية سلاسل الكتل. تُعد سرعة وأمان نقل البيانات (مثل الرسائل الصوتية أو التحذيرية) بين المركبات أمراً حيوياً، لكن وجود مركبات غير موثوقة قد يؤدي إلى رسائل مزيفة تُهدد السلامة العامة. لحل هذه المشكلة، تقترح الورقة دمج تقنية سلاسل الكتل مع الحوسبة السحابية، بحيث يتم تخزين البيانات الحساسة (مثل سجلات المعاملات وقيم الهاش) على سلاسل الكتل لضمان الأمان، بينما يتم تخزين الملفات الكبيرة (مثل الوسائط المتعددة) في السحابة لتوفير المساحة وتحسين الأداء كما هو موضح في [

تقييم نظام تواصل قائم على سلاسل الكتل في شبكات المركبات اللاسلكية باستخدام العقود الذكية

الشكل [1] يعتمد النظام المقترح على عقود ذكية باستخدام منصة Ethereum لتأمين التواصل بين المركبات. ويسعى النظام إلى تقليل الرسائل الاحتمالية وتحسين كفاءة التواصل داخل الشبكة، وصلت نسبة packet delivery ratio الى 80 %.



[الشكل 1] النظام المقترح في البحث [1].

تُعد القيادة الذكية ممكنة بفضل التطور السريع في شبكات المركبات المتحركة (VANETS)، والتي تُستخدم لتوفير معلومات السلامة المرورية والتواصل الفوري بين المركبات. إلا أن الطبيعة اللاسلكية المفتوحة لهذه الشبكات تجعلها عرضة لهجمات أمنية من قبل جهات خبيثة، مما يستدعي وجود آليات تحقق أمانة ومجهولة الهوية. تقترح الورقة [14] نظام تحقق مجهول قائم على تقنية سلاسل الكتل، يهدف إلى تحسين كفاءة التحقق من المركبات، خاصة عند انتقالها بين وحدات

الطرق (RSUs) دون الحاجة لإعادة التحقق التقليدية، من خلال تبادل رموز تحقق آمنة بين الـ

RSUs. في هذا النظام، تُعد وحدات RSU بمثابة عُقد تعدين تتحقق من هوية المركبات عبر


خوارزميات إجماع، مع استخدام شجرة Merkle لتسجيل عمليات التحقق في الوقت الفعلي. كما

يُتيح النظام إمكانية تتبع المركبات المخالفة عند الحاجة عبر مراجعة السجلات السابقة، محققاً

بذلك التوازن بين الخصوصية والمساءلة. وأظهرت نتائج التحليل الأمني أن النظام المقترح أكثر

أماناً وكفاءة من الأنظمة التقليدية، مع تقليل ملحوظ في التكلفة الحسابية، يوضح [الشكل 2] بنية

النظام المقترح في البحث [14].



[الشكل 1] النظام المقترح في BBAAS [2].

شبكات المركبات المتنقلة تُمثل مستقبلاً واعداً في تحسين إدارة المرور وسلامة السائقين، لكنها

تعاني من تحديات تتعلق بالأمان والخصوصية بسبب اعتمادها على قنوات الاتصال اللاسلكية،

مثل مشكلات المصادقة، وسرية البيانات، وسلامتها، والتحكم في الوصول، وتوفير الخدمة. لمعالجة هذه التحديات، تقترح الدراسة [15] تقنية تحقق مجهولة وأمنة مادياً تعتمد على تقنية سلاسل الكتل وهندسة الحوسبة الضبابية. يتمتع النظام المقترح بميزات مثل تقليل زمن الاستجابة، ودعم الحركة، ومراقبة الموقع، مما يجعله فعالاً في مواجهة التهديدات الأمنية. تعتمد آلية التحقق على عقد ضبابية تعمل كعقد تعدين للتحقق من شرعية المركبة عبر خوارزميات إجماع، كما تُستخدم شجرة Merkle لتتبع بيانات التحقق في الوقت الحقيقي. لا حاجة للمركبة لتخزين المفاتيح السرية، مما يعزز الأمان المادي ويقلل من تعقيد النظام. بالمقارنة مع الأنظمة الأخرى، يحقق النظام المقترح كفاءة أعلى من حيث الأمان وتقليل التكاليف الحسابية والتخزينية والاتصالية، يستهلك النظام المقترح تكلفة حسابية قدرها 24:23 مللي ثانية لإجراء عملية المصادقة. بينما تستهلك مخططات تنافسية أخرى ذات صلة، تكلفة حسابية قدرها 106:48.

تم في [16] اقتراح نظاماً قائماً على تقنية سلاسل الكتل للحفاظ على الخصوصية، يُعزز أمن شبكات VANET مع معالجة مشاكل عدم إمكانية الملاحظة، وعدم إمكانية الربط، وكفاءة المصادقة. يعتمد النهج على خادم إخفاء الهوية قائم على ذاكرة التخزين المؤقت، يقع بين وحدة المركبة (OBU) ووحدة جانب الطريق (RSU)، مما يُعزز الخصوصية من خلال إخفاء أنماط الاتصال، ويُحسن الكفاءة من خلال تقليل تكاليف المصادقة. تُظهر تقييمات الأداء أن نظامنا يُخفّض التكاليف الحسابية بشكل ملحوظ، حيث يُحقق انخفاضاً بنسبة 95.17% إلى 97.00% في اتصال V2V، و97.81% إلى 98.90% في وقت اتصال V2RSU مقارنةً بالأنظمة

المرجعية. بالإضافة إلى ذلك، يُخفّض نهجنا تكلفة الاتصال بنسبة 67.94% إلى 81.67% في اتصال V2V، و 72.40% إلى 88.00% في اتصال V2RSU، مع تقليل احتمالية تسرب الموقع إلى 0.05%، وهي نسبة أقل بكثير من الأنظمة المركزية. علاوة على ذلك، يضمن نظامنا حماية قوية للخصوصية، حيث يصل إلى مستوى إنتروبيا أقصى قدره 5، وهو أعلى بنسبة 95.8% من الأنظمة الحالية. تؤكد هذه النتائج أن إطار عملنا يُقلّل من النفقات الحسابية، ويُحسّن كفاءة الاتصال، ويُعزّز حماية الخصوصية، مما يجعله حلاً متيناً وقابلاً للتطوير لأنظمة VANET.

تم في [17] اقتراح بنية مصادقة مؤسسية عبر المركبات من خلال تصميم آلية لتوليد الشهادات من مرحلتين، حيث تتعاون هيئة إصدار الشهادات، وشركات المركبات لإنشاء بيانات اعتماد الهوية للمركبات. لمعالجة مخاوف المركبات الافتراضية، تُرسي ثقة موزعة وتُمكن تبادل المعلومات بين المركبات الافتراضية من خلال طرح سلسلة كتل ائتلافية تتألف من شركات السيارات، وهيئة التصديق، وهيئة شهادات الاسم المستعار. ونظراً لحاجة المركبات للوصول إلى معلومات حركة المرور، نستخدم سلسلة كتل عامة لتخزين المعلومات العامة، ونستخدم خوارزمية التسامح العملي مع الأخطاء البيزنطية للوصول إلى توافق في الآراء. بدلاً من استخدام عمليات الاقتران الخطي الثنائي المعقدة حسابياً وعمليات التجزئة من نقطة إلى نقطة، يستخدم المخطط المقترح نظام تشفير المنحنى الإهليلجي (ECC)، نظراً لمحدودية موارد الأجهزة للمركبة ووحدة التحكم في الوصول بالإضافة إلى ذلك، يدمج مخططنا الحوسبة الطرفية لحل مهام الحوسبة المعقدة التي لا يمكن

إجراؤها محلياً، مما يُقلل من زمن وصول النظام. يُظهر تحليل الأمان وتحليل الأداء أن مخططنا يتميز بأداء أفضل من المخططات الحالية من حيث الأمان، والتكاليف الحسابية، وتكاليف الاتصالات.

يوضح [الجدول 1] المقارنة بين الدراسات السابقة والدراسة الحالية، المقترح في الدراسة الحالية الغى الحاجة الى استخدام العقود الذكية في الحوسبة السحابية وتم نقل منطق العمل الى وحدات RSU مع التأكيد على استخدام عقدين ذكيين الأول للتحقق من المركبات وتسجيلها والثاني لتبادل الرسائل.

[جدول 1] المقارنة بين الدراسات السابقة والدراسة الحالية

الدراسة	استخدام الحوسبة السحابية	استخدام عقد ذكي للتحقق من المركبات	استخدام عقد ذكي لتبادل الرسائل	استخدام العقد الذكي من قبل RSU
[1]	نعم	نعم	لا	لا
[2]	لا	نعم	لا	لا
[3]	لا	نعم	لا	لا
[4]	لا	نعم	لا	لا
[5]	لا	نعم	لا	لا
الدراسة الحالية	لا	نعم	نعم	نعم

8. النظام المقترح:

تم اتباع منهجية عملية تعتمد على بناء نموذج محاكاة متكامل يجمع بين بيئة شبكات المركبات (VANET) وتقنية سلاسل الكتل كما هو موضح في [الشكل 3]، حيث تم استخدام أداة المحاكاة SUMO لمحاكاة حركة المركبات، وربطها عبر واجهة TRACI مع نظام قائم على سلاسل الكتل والعقود الذكية لتنفيذ عمليات تسجيل المركبات وتبادل الرسائل. في هذا النموذج، تم توظيف وحدات الطريق الذكية (RSUs) كعقد وسيطة تقوم بجميع العمليات الحسابية المرتبطة سلاسل الكتل نيابةً عن المركبات، ما يقلل من العبء على الموارد ويضمن استقرار النظام. تم تسجيل كل عملية تواصل أو رسالة بين المركبات كسجل في سلسلة الكتل، مما يضمن التوثيق، الشفافية، وعدم الإنكار. كما شملت المنهجية جمع بيانات الأداء وتحليلها إحصائياً لتقييم كفاءة النظام من حيث زمن المحاكاة، نسبة إيصال الرسائل (PDR).

1. إعداد بيئة المحاكاة وحركة المركبات:

تم استخدام محاكي SUMO لمحاكاة حركة المركبات داخل شبكة طرق في المدينة، ضمن سيناريو طريق مكوّن من مسار مستقيم ثنائي الاتجاه . تم الاعتماد على نموذج الحركة الافتراضي في SUMO وهو نموذج Krauss لتوليد سلوك المركبات، والذي يعتمد على نموذج المتابعة Car-Following Model ويأخذ بعين الاعتبار سرعة المركبة الأمامية والمسافة الفاصلة لتجنّب الاصطدامات. كما تم استخدام نموذج تغيير المسار الافتراضي LC2013 الذي يتيح للمركبات تجاوز المركبات الأبطأ وفق قواعد واقعية لتبديل المسارات. يتم في كل خطوة زمنية تتبع مواقع المركبات بدقة عبر واجهة TRACI التي تسمح بالوصول إلى بيانات المركبات الحية مثل الموقع،

السرعة، واتجاه الحركة. تم تعيين عدة وحدات طريق ذكية (RSUs) على نقاط ثابتة في الطرق، وتم تحديد موقع كل RSU باستخدام إحداثياتها ضمن شبكة المحاكاة، في هذه الدراسة تم استخدام بيئة محاكاة SUMO لتوليد حركة.

2. تسجيل المركبات في الشبكة عبر RSU:

عند بداية المحاكاة، كل مركبة جديدة تدخل الشبكة لم تُسجل بعد في نظام سلاسل الكتل. عند اكتشاف مركبة غير مسجلة، تقوم أقرب وحدة RSU بالبدء بعملية تسجيل هذه المركبة عبر العقود الذكية.

• خطوات التسجيل:

- الـ RSU يتحقق أولاً إذا كانت المركبة مسجلة مسبقاً.
- في حال عدم التسجيل، يتم إنشاء معاملة (Transaction) خاصة بتسجيل المركبة في سلاسل الكتل مع فرض رسم تسجيل رمزي (registration fee).
- يتم تضمين هذه المعاملة ضمن كتلة جديدة تُعدن (mine) وتُضاف إلى سلسلة الكتل.
- بعد إتمام التسجيل، تُضاف المركبة لقائمة المركبات المسجلة، ويُسمح لها بالمشاركة في التواصل.

3. آلية تبادل الرسائل بين المركبات:

خلال كل خطوة زمنية في المحاكاة:

• لكل مركبة، يُحدد موقعها ويتم إيجاد المركبات الأخرى القريبة ضمن مدى مسافة محدد (مثلاً 50 متر).

• إذا وُجدت مركبة أخرى ضمن هذا النطاق ولم يتم إرسال رسالة إليها مؤخراً (حسب فترة زمنية معينة لمنع التكرار السريع)، يقوم أقرب RSU إلى المرسل بإدارة عملية إرسال الرسالة.

• خطوات إرسال الرسالة:


- يتم التحقق من أن كل من المرسل والمستقبل مسجلان ضمن الشبكة.
- ينشئ RSU معاملة رسالة جديدة تحتوي على بيانات المرسل، المستقبل، نص الرسالة، مواقع الطرفين، والطابع الزمني.
- تُضاف المعاملة إلى قائمة المعاملات المعلقة في سلاسل الكتل.
- يبدأ RSU عملية تعدين الكتلة التي تحتوي هذه المعاملة، ليتم التحقق منها وإضافتها إلى سلسلة الكتل.
- قد تفشل الرسالة بنسبة 10% لمحاكاة فقدان الحزمة أو مشاكل الشبكة.
- بعد نجاح التعدين، يتم تسجيل نجاح الإرسال وتأخير الوقت المستغرق بين الإرسال والاستلام.

4. إدارة البيانات والتوثيق:

- كل رسالة ناجحة تُسجل في ملف لوج يحتوي معلومات تفصيلية (RSU المرسل، المرسل، المستقبل، محتوى الرسالة، والطابع الزمني).
- كما يتم تسجيل كامل سلسلة الكتل في ملف JSON يحتوي على كل الكتل والمعاملات لتوفير سجل شامل يمكن تحليله لاحقاً.

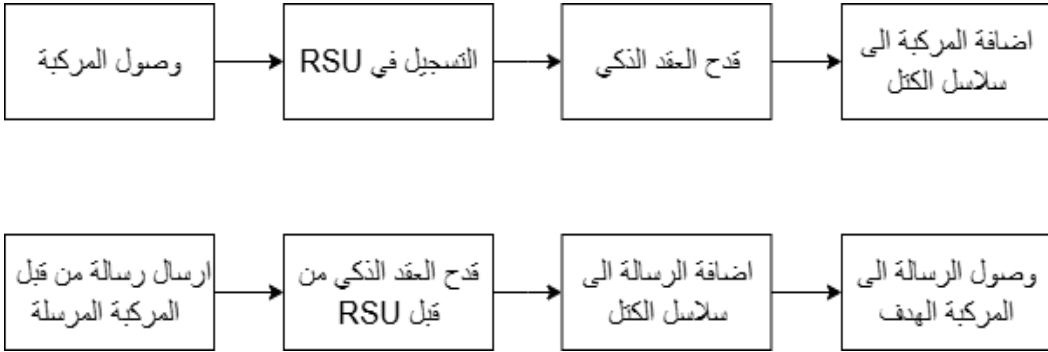
5. قياس مؤشرات الأداء:

- بعد انتهاء فترة المحاكاة، يتم تحليل البيانات التي تم جمعها لحساب المؤشرات الرئيسية:
- نسبة إيصال الرسائل (PDR): نسبة الرسائل التي تم إيصالها بنجاح مقارنة بعدد الرسائل المرسلة.
 - عدد الرسائل المرسلة.
 - الوقت الكلي لتنفيذ المحاكاة: الزمن المستغرق لتشغيل كل الخطوات السابقة.



[الشكل 3] النظام المقترح

في حين يوضح [الشكل 4] المخطط التدفق لتسجيل المركبة وتبادل الرسائل بين المركبات في النظام.



[الشكل 4] الشكل المخطط التدفق لتسجيل المركبة وتبادل الرسائل بين المركبات في النظام.

9. أدوات الدراسة والاعداد التجريبي:

تم استخدام محاكي SUMO لمحاكاة حركة المركبات داخل شبكة طرق المدينة. يتم في كل خطوة زمنية تتبع مواقع المركبات بدقة عبر واجهة TRACI التي تسمح بالوصول إلى بيانات المركبات الحية مثل الموقع، السرعة، واتجاه الحركة. تم تعيين عدة وحدات طريق ذكية (RSUs) على نقاط ثابتة في الطرق، وتم تحديد موقع كل RSU باستخدام إحداثياتها ضمن شبكة المحاكاة.

10 التجارب والمناقشة:

من أجل تقييم فعالية النظام المقترح تحت ظروف تشغيلية مختلفة، تم إجراء مجموعة من التجارب التي تهدف إلى قياس أداء النظام مع تغيير الأحمال داخل الشبكة. وقد تم ذلك من خلال زيادة عدد المركبات المشاركة في النظام تدريجياً، حيث شملت التجارب خمس حالات تم فيها اختبار النظام باستخدام 20 مركبة، 40 مركبة، 60 مركبة، 80 مركبة، وأخيراً 100 مركبة.

لضمان اتساق نتائج المقارنة، تم الاعتماد على نفس الخريطة الحضرية في جميع التجارب، مع ثبات الإعدادات البيئية والمعايير الأساسية الأخرى. وقد تم رصد مؤشرات الأداء الرئيسية مثل زمن الاستجابة، معدل اكتشاف الشذوذ، كفاءة استخدام الموارد، ودقة التصنيف عند كل مستوى من الأحمال.


تهدف هذه التجارب إلى اختبار قدرة النظام على التحمل والتوسع (Scalability)، وبيان مدى تأثير زيادة الكثافة المرورية (عدد المركبات) على فعالية النظام، خصوصاً في بيئة المدينة ذات حركة ديناميكية عالية.

يوضح [الشكل 5] خريطة بشارع واحد ذهاب واياب ويوجد فيه ثلاث وحدات على جانب الطريق متموضعة على الخريطة باللون الأحمر.



[شكل 2] خريطة حضرية بشارع واحد.

يوضح [الشكل 6] تحركات المركبات والتي تتموضع على الخريطة باللون الأخضر.



[الشكل 3] تحركات المركبات.

ليتم الانتقال بعدها الى التجارب العملية على النظام المقترح وقد تم الاعتماد على 5 سيناريوهات مختلفة وهي تجربة استخدام 20 مركبة و 40 و 60 ثم 80 مركبة واخيراً 100 مركبة وقد تم اختيار هذه الاعداد وفقاً للدراسة [1]

• التجربة الأولى استخدام 20 مركبة:

في هذه التجربة، تم اختبار أداء النظام ضمن بيئة تضم عشرين مركبة تتبادل الرسائل فيما بينها، بهدف تقييم مدى تحمل النظام وزيادة تعقيده الشبكي مع تزايد عدد العقد. بلغ زمن المحاكاة 146

ثانية، وبلغ متوسط نسبة توصيل الحزم (Packet Delivery Ratio) حوالي 84.76%، ما يعكس استمرار الأداء الجيد للنظام رغم زيادة عدد المركبات، مع ملاحظة انخفاض تدريجي في كفاءة التوصيل نتيجة الضغط المتزايد على الشبكة، وقد بلغ عدد الرسائل المرسلة 328 رسالة.

• التجربة الثانية:

في هذه التجربة، تم اختبار أداء النظام ضمن بيئة تضم 40 مركبة تتبادل الرسائل فيما بينها، بهدف تقييم مدى تحمل النظام وزيادة تعقيده الشبكي مع تزايد عدد العقد. بلغ زمن المحاكاة 107.01 ثانية، وبلغ متوسط نسبة توصيل الحزم (Packet Delivery Ratio) حوالي 88.32%، ما يعكس استمرار الأداء الجيد للنظام رغم زيادة عدد المركبات، مع ملاحظة انخفاض تدريجي في كفاءة التوصيل نتيجة الضغط المتزايد على الشبكة، وبلغ عدد الرسائل المرسلة 548.

• التجربة الثالثة:

في هذه التجربة، تم اختبار أداء النظام ضمن بيئة تضم 60 مركبة تتبادل الرسائل فيما بينها، بهدف تقييم مدى تحمل النظام وزيادة تعقيده الشبكي مع تزايد عدد العقد. بلغ زمن المحاكاة 109.21 ثانية، وبلغ متوسط نسبة توصيل الحزم (Packet Delivery Ratio) حوالي 88.16%، ما يعكس استمرار الأداء الجيد للنظام رغم زيادة عدد المركبات، مع ملاحظة انخفاض تدريجي في كفاءة التوصيل نتيجة الضغط المتزايد على الشبكة، وبلغ عدد الرسائل المرسلة 549.

• التجربة الرابعة:


في هذه التجربة، تم اختبار أداء النظام ضمن بيئة تضم 80 مركبة تتبادل الرسائل فيما بينها، بهدف تقييم مدى تحمل النظام وزيادة تعقيده الشبكي مع تزايد عدد العقد. بلغ زمن المحاكاة 164.0 ثانية، وبلغ متوسط نسبة توصيل الحزم (Packet Delivery Ratio) حوالي 88.84%، ما يعكس استمرار الأداء الجيد للنظام رغم زيادة عدد المركبات، مع ملاحظة انخفاض تدريجي في كفاءة التوصيل نتيجة الضغط المتزايد على الشبكة، وقد بلغ إجمالي عدد الرسائل المتبادلة 547 رسالة.

• التجربة الخامسة:

في هذه التجربة، تم اختبار أداء النظام ضمن بيئة تضم 80 مركبة تتبادل الرسائل فيما بينها، بهدف تقييم مدى تحمل النظام وزيادة تعقيده الشبكي مع تزايد عدد العقد. بلغ زمن المحاكاة 96.13 ثانية، وبلغ متوسط نسبة توصيل الحزم (Packet Delivery Ratio) حوالي 88.0%، ما يعكس استمرار الأداء الجيد للنظام رغم زيادة عدد المركبات، مع ملاحظة انخفاض تدريجي في كفاءة التوصيل نتيجة الضغط المتزايد على الشبكة، وقد بلغ إجمالي عدد الرسائل المرسله 550 رسالة.

• ملخص نتائج السيناريوهات:

يوضح [الشكل 7] زمن التنفيذ لمختلف السيناريوهات. يُظهر الجدول السابق أن زمن التنفيذ الكلي للنظام يختلف باختلاف عدد المركبات المشاركة في التجربة. فكلما ازداد عدد المركبات، ازداد الضغط على وحدات المعالجة نتيجة زيادة عمليات الاتصال والتحقق وتبادل الرسائل عبر العقود الذكية، مما يؤدي إلى ارتفاع طفيف في زمن التنفيذ. إلا أن هذا الارتفاع لا يُعدّ خطياً، حيث تُظهر النتائج أن النظام يحتفظ بأداء مستقر نسبياً رغم ازدياد عدد المركبات، وهو ما يعكس كفاءة تصميم البنية الموزعة التي تُمكن كل وحدة RSU من معالجة جزء من العمليات بشكل مستقل دون الاعتماد الكامل على عقدة مركزية واحدة. على سبيل المثال، في التجربة الرابعة التي تضمنت عدداً أكبر من المركبات، بلغ زمن التنفيذ 164 ثانية وهو الأعلى بين التجارب، نتيجة ازدحام الشبكة وزيادة الرسائل المتبادلة، بينما سجلت التجربة الخامسة انخفاضاً ملحوظاً (96.1 ثانية) بسبب توازن أفضل في توزيع المركبات ضمن منطقة المحاكاة. بذلك تُظهر النتائج أن النظام المقترح يتمتع بقدرة عالية على التوسع (Scalability) مع الحفاظ على استقرار الأداء في مختلف ظروف التشغيل.



[الشكل 4] مقارنة زمن التنفيذ لكافة التجارب في النظام المقترح.

تفسير التغير في زمن التنفيذ بين التجارب:

إن التباين في زمن التنفيذ الكلي بين التجارب لا يرتبط بعدد المركبات فقط، وإنما بعدة عوامل مترابطة تؤثر على أداء النظام أثناء المحاكاة، وهي:

- كثافة الاتصال بين المركبات.

في بعض السيناريوهات، رغم أن عدد المركبات أكبر، إلا أن المسافات الفاصلة بينها ضمن الشبكة تكون متوزعة بشكل أفضل، ما يقلل عدد الرسائل التي تُرسل فعلياً في كل خطوة زمنية، وبالتالي يقل زمن التنفيذ. وهذا ما يفسر انخفاض الزمن في التجربة الخامسة (96.1 ثانية) رغم وجود عدد كبير من المركبات.

- موقع وحدات الRSU وتوزيعها المكاني.

في التجربة الرابعة، لوحظ ارتفاع زمن التنفيذ (164 ثانية) لأن بعض المركبات كانت متقاربة من نفس وحدات الRSU، مما أدى إلى ازدحام في عمليات التحقق من العقود الذكية ومعالجة الرسائل قبل إضافتها إلى سلسلة الكتل، وهو ما زاد الحمل الحسابي على النظام وأطال زمن التنفيذ.

- نشاط العقود الذكية.

كل عملية إرسال أو استقبال تمر بعقد ذكي للتحقق والتسجيل في البلوك تشين، وبالتالي ازدياد عدد المعاملات في فترة زمنية قصيرة يرفع من زمن التعدين ويؤدي إلى بطء نسبي في المحاكاة.

- تأثير احتمال فقدان الرسائل.

النظام يحاكي نسبة فقد عشوائية (حوالي 10%)، وهذا قد يؤدي أحياناً إلى تقليل عدد الرسائل المتبادلة وبالتالي تقليل زمن التنفيذ في بعض التجارب بشكل غير خطي.

- العشوائية في الحركة ومسارات المركبات

بما أن النموذج المستخدم يعتمد على توزيع مركبات عشوائي في بيئة طرق بسيطة، فإن التفاعل بين العقد والRSU قد يختلف من تجربة لأخرى، ما يسبب تفاوتاً في الحمل الزمني حتى ضمن عدد متقارب من المركبات.

بناءً على ما سبق، فإن أكبر زمن تنفيذ في التجربة الرابعة كان نتيجة تراكم الحمل على الRSU محددة وارتفاع معدل التبادلات المتزامنة، في حين انخفض الزمن في التجربة الخامسة بسبب توزيع أفضل للمركبات وتوازن الحمل بين وحدات الRSU، ما أدى إلى تحسين كفاءة التنفيذ.


يوضح [الشكل 8] مقارنة نسبة توصيل الحزم (Packet Delivery Ratio – PDR) في جميع

التجارب التي أُجريت على النظام المقترح باستخدام أعداد مختلفة من المركبات. وتبين النتائج أن

أفضل نسبة توصيل بلغت 88.84% عند استخدام 80 مركبة، بالتالي النتائج تؤكد قدرة النظام

المقترح على الحفاظ على مستوى أداء مستقر وموثوق حتى في بيئات ذات حمل مرتفع وكثافة


اتصالات عالية.



[الشكل 5] مقارنة packet delivery ratio لكافة التجارب في النظام المقترح


يوضح [الشكل 9] تطور نسبة تسليم الحزم في كافة التجارب، في كافة التجارب ومع زيادة عدد

المركبات لم تقل نسبة تسليم الحزم المتبادلة بين المركبات عن 84% .



[الشكل 6] تطور نسبة تسليم الحزم في كافة التجارب.

بالمقارنة مع أقرب دراسة مشابهة من حيث بنية النظام المقترح، وهي الدراسة [1]، تبين أن نسبة تسليم الرسائل في النظام الحالي كانت متفوقة في جميع التجارب والسيناريوهات كما هو موضح [بالشكل 10]. حيث تراوحت نسبة تسليم الرسائل في النظام المقترح بين 84% و88%، بينما لم تتجاوز هذه النسبة في الدراسة [13] نسبة 80%. تعكس هذه النتائج التفوق الواضح للنظام المقترح، مما يؤكد نجاحه في تحسين كفاءة توصيل الرسائل وتعزيز أداء الشبكة مقارنة بالدراسات السابقة.



[الشكل 7] مقارنة مع دراسات سابقة.

يجدر الذكر بأن باقي اعدادات المحاكاة للشبكة موضحة [بالتداول 2] .

[جدول 1] اعدادات المحاكاة للشبكة

البند	القيمة / التوضيح
عدد المركبات (Vehicles)	20-80 مركبة (حسب السيناريو)
عدد وحدات RSU (Road Side Units)	3 وحدات موزعة على الشبكة
نمط الطوبولوجيا	ونظام موزع (Distributed Blockchain)
نظام الاتصال	V2V و V2I (Vehicle-to-Infrastructure) (Vehicle-to-Vehicle)
بروتوكول الشبكة المستخدم	تم الاعتماد على نموذج الاتصال التعاوني عبر IEEE 802.11p / DSRC المدمج ضمن SUMO لمحاكاة شبكات VANET
بروتوكول نقل الرسائل	تبادل الرسائل يتم عبر العقود الذكية (Smart Contracts) التي تعمل كطبقة تحقق وتسجيل (Validation Layer)
آلية تسجيل المركبات	تتم عملية التسجيل والتحقق من الهوية عبر عقد ذكي خاص بـRSU، باستخدام معاملات مسجلة في سلسلة الكتل
آلية إرسال الرسائل	يتم إرسال الرسائل بين المركبات عبر أقرب RSU باستخدام العقد الذكي الخاص بها، مع تسجيل كل معاملة في سلاسل الكتل
إعدادات المسافة للاتصال	الحد الأقصى لمسافة الاتصال بين المركبات 50 مترًا
زمن المحاكاة (Simulation Time)	500 خطوة زمنية (simulation steps)
أداة سلاسل الكتل	نموذج محاكاة لسلاسل الكتل يعتمد على إثبات العمل (Simplified Proof of Work)
المقاييس المقارنة	نسبة تسليم الرسائل – (PDR / Reliability) التأخير من طرف إلى طرف – (End-to-End Delay) زمن التعدين (Mining Time)

11. الخلاصة والعمل المستقبلي:

يقدم هذا البحث إطاراً مبتكراً يجمع بين تقنيات سلاسل الكتل وشبكات VANET ، من خلال توظيف وحدات الطريق الذكية (RSUs) كعقد وسيطة لإدارة العمليات الحسابية والتوثيق المتعلقة بالتواصل بين المركبات. يعتمد النظام المقترح على عقود ذكية لإتمام عمليات تسجيل المركبات وتبادل الرسائل بطريقة موثوقة، لا مركزية، وقابلة للتوثيق الكامل، دون تحميل المركبات عبئاً حسابياً إضافياً.

أظهرت نتائج المحاكاة باستخدام أداة SUMO فعالية الإطار المقترح، حيث حقق نسبة تسليم رسائل (PDR) مرتفعة تراوحت بين 84% و 88%، متفوقاً على أقرب دراسة مرجعية. كما أظهر النظام كفاءة جيدة في مؤشرات الأداء الأخرى مثل زمن التأخير وزمن تعدين الكتل، مما يعزز من جدواه في بيئات VANET الواقعية.

رغم النتائج الإيجابية، لا تزال هناك فرص واسعة لتطوير النظام في أبحاث مستقبلية، منها:

- دعم التنقل العالي: تحسين أداء النظام في بيئات ذات كثافة مرورية وسرعات عالية، مثل الطرق السريعة.
- تكامل الذكاء الاصطناعي: إدماج تقنيات تعلم الآلة لتحسين اتخاذ القرار في RSUs بشأن أولوية الرسائل أو توقيت الإرسال.
- زيادة الأمان: دراسة سيناريوهات الهجمات المحتملة (مثل هجوم Sybil أو الانتحال) وتطوير آليات كشف واستجابة داخل العقود الذكية.

تقييم نظام تواصل قائم على سلاسل الكتل في شبكات المركبات اللاسلكية باستخدام العقود الذكية

- اختبار عملي: الانتقال من بيئة المحاكاة إلى تنفيذ تجريبي ميداني باستخدام وحدات RSU حقيقية وأجهزة محمولة داخل المركبات.
- تحسين استهلاك الطاقة: دراسة أثر النظام على استهلاك الطاقة في RSUs ، خاصةً في حال اعتمادها على مصادر طاقة محدودة أو خضراء.

جدول الاختصارات

المعنى بالعربية	الكلمة الكاملة (بالإنجليزية)	الاختصار
وحدة داخل المركبة	On-Board Unit	OBU
نسبة توصيل الحزم	Packet Delivery Ratio	PDR
وحدة جانب الطريق	Road Side Unit	RSU
اتصال المركبة بالبنية التحتية	Vehicle-to- Infrastructure	V2I
اتصال مركبة بمركبة	Vehicle-to-Vehicle	V2V
شبكة مخصصة للمركبات	Vehicular Ad Hoc Network	VANET

- [1] Kim, Seungmo. "Impacts of mobility on performance of blockchain in VANET." IEEE Access 7 (2019): 68646-68655.
- [2] Anwer, M. Shahid, and Chris Guy. "A survey of VANET technologies." Journal of Emerging Trends in Computing and Information Sciences 5.9 (2014): 661-671.
- [3] Bariah, Lina, et al. "Recent advances in VANET security: A survey." 2015 IEEE 82nd vehicular technology conference (VTC2015-fall). IEEE, 2015.
- [4] Cunha, Felipe, et al. "Data communication in VANETs: Protocols, applications and challenges." Ad hoc networks 44 (2016): 90-103.
- [5] Lee, Michael, and Travis Atkison. "VANET applications: Past, present, and future." Vehicular Communications 28 (2021): 100310.
- [6] اقتراح بنية هجينة لشبكة الاستشعار اللاسلكية وشبكة المركبات المخصصة لتحسين السلامة على الطرق لارا علي، د.محسن عبود، مجلة جامعة حمص، المجلد 43 العدد 16 عام 2021
- [7] دراسة سلسلة الكتل وإمكانية استخدامها في التحقق من ملكية المفاتيح العام في ارسال رسائل معماة، محمد خليل، محمد الشايطه، محمد عصوره، مجلة جامعة حمص، المجلد 43 العدد 10 عام 2021
- [8] Di Pierro, Massimo. "What is the blockchain?." Computing in Science & Engineering 19.5 (2017): 92-95.
- [9] Zheng, Zibin, et al. "An overview of blockchain technology: Architecture, consensus, and future trends." 2017 IEEE international congress on big data (BigData congress). Ieee, 2017.
- [10] Wang, Shuai, et al. "An overview of smart contract: architecture, applications, and future trends." 2018 IEEE intelligent vehicles symposium (IV). IEEE, 2018.
- [11] Majumder, Subhrajit, Akshay Mathur, and Ahmad Y. Javaid. "A study on recent applications of blockchain technology in vehicular adhoc network (VANET)." National Cyber Summit. Cham: Springer International Publishing, 2019. 293-308.
- [12] Alladi, Tejasvi, et al. "A comprehensive survey on the applications of blockchain for securing vehicular networks." IEEE Communications Surveys & Tutorials 24.2 (2022): 1212-1239.
- [13] More, Shivaprasad, et al. "Secured communication in vehicular adhoc networks (VANETs) using blockchain." IOP Conference Series: Materials Science and Engineering. Vol. 1022. No. 1. IOP Publishing, 2021.

- [14] Maria, Azees, et al. "BBAAS: blockchain- based anonymous authentication scheme for providing secure communication in VANETs." *Security and Communication Networks* 2021.1 (2021): 6679882.
- [15] Subramani, Jegadeesan, et al. "Blockchain-based physically secure and privacy-aware anonymous authentication scheme for fog-based vanets." *IEEe Access* 11 (2022): 17138-17150.
- [16] Ilyas, Iqra, et al. "Blockchain enabled privacy provisioning scheme for location based services in VANETs." *PLoS One* 20.6 (2025): e0323438.
- [17] Lai, Jiaming, et al. "Blockchain-based VANET edge computing-assisted cross-vehicle enterprise authentication scheme." *Computer Communications* 231 (2025): 108040.

تصنيف الأغذية باستخدام الشبكات العصبونية التلافيفية المحسنة

رنيم المعلم*¹، نديم شاهين²، طلال حمود³

1طالب دكتوراه في كلية الهندسة الميكانيكية والكهربائية اختصاص اتصالات متقدمة - جامعة

دمشق

2 أستاذ دكتور في كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق

3دكتور في كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق

الملخص

إن التحدي الرئيسي في تصنيف الأغذية السليمة وغير السليمة يكمن في عدم اليقين المتعلق بجودتها، مما قد يؤدي إلى مشاكل صحية واقتصادية. لمعالجة هذا التحدي، يمكن استخدام خوارزميات التعلم الآلي (ML) كأدوات قوية للتصنيف بناءً على خصائص الأغذية مثل الصور أو البيانات الزمنية المتعلقة بظروف التخزين. ومع ذلك، يعتمد أداء هذه الخوارزميات بشكل كبير على الضبط الصحيح للمعاملات الفائقة، والتي يمكن أن تكون عملية معقدة ومكلفة حسابياً عند استخدام الطرق التقليدية مثل البحث الشبكي أو البحث العشوائي. لحل هذه المشكلة، يمكن تطبيق تقنيات تحسين متقدمة مثل Scikit-opt، Optuna، و Hyperopt لتحسين أداء النماذج. على سبيل المثال، يمكن استخدام CNN (الشبكات العصبونية التلافيفية) لتحليل صور الأغذية وتصنيفها بناءً على مظهرها، بينما يمكن استخدام LSTM (الشبكات العصبونية ذات الذاكرة طويلة المدى) لتحليل البيانات الزمنية المتعلقة بجودة الأغذية. من خلال تقييم الأداء باستخدام معايير مثل الدقة و RMSE، يمكن تحديد النماذج الأكثر دقة وكفاءة.

في هذا البحث، تم التحقيق في تأثير ميزات التهيئة العشوائية على أداء التصنيف باستخدام الشبكات العصبونية. تم فحص الهياكل المقترحة لنماذج التعلم العميق لتحديد الهيكل الأكثر قوة مع أقل حساسية للعشوائية. كما تم تقديم خوارزمية جديدة في مجال تصنيف الأغذية من خلال التقنية المتقدمة Hyperopt لتحسين المعاملات الفائقة لنماذج الشبكة العصبونية التلافيفية (CNN) ، وهو جانب لم يتم استكشافه بشكل منهجي في الأدبيات الحالية. تم تقييم تأثير هذه التقنية على دقة وكفاءة النموذج CNN من خلال مقارنة خطأ الجذر التربيعي المتوسط (RMSE) للتصنيف والوقت المطلوب لضبط النموذج.

كلمات مفتاحية: تصنيف المواد الغذائية، Hyperopt، الشبكة العصبونية التلافيفية، خطأ الجذر التربيعي المتوسط، تحسين المعاملات الفائقة.

Abstract

The primary challenge in classifying food as safe or unsafe lies in the uncertainty related to its quality, which can lead to health and economic issues. To address this challenge, machine learning (ML) algorithms can be employed as powerful tools for classification based on food characteristics such as images or time-series data related to storage conditions. However, the performance of these algorithms heavily depends on the proper tuning of hyperparameters, which can be a complex and computationally expensive process when using traditional methods like grid search or random search. To solve this problem, advanced optimization techniques such as Scikit-opt, Optuna, and Hyperopt can be applied to enhance model performance. For instance, Convolutional Neural Networks (CNNs) can be used to analyze food images and classify them based on their appearance, while Long Short-Term Memory (LSTM) networks can be utilized to analyze time-series data related to food quality. By evaluating performance using metrics such as accuracy and RMSE (Root Mean Square Error), the most accurate and efficient models can be identified.

In this research, the impact of random initialization features on classification performance using neural networks was investigated. The proposed structures of deep learning models were examined to determine the most robust structure with the least sensitivity to randomness. Additionally, a novel algorithm was introduced in the field of food classification through the advanced Hyperopt technique for optimizing hyperparameters of Convolutional Neural Network (CNN) models, an

aspect that has not been systematically explored in the current literature. The effect of this technique on the accuracy and efficiency of the CNN model was evaluated by comparing the Root Mean Square Error (RMSE) of classification and the time required for model tuning.

Keywords: Food classification, Hyperopt, Convolutional Neural Network (CNN), Root Mean Square Error (RMSE), Hyperparameter optimization.

المقدمة

تُعتبر الشبكات العصبونية التلافيفية (CNN) واحدة من أكثر تقنيات التعلم العميق فعالية في معالجة الصور والبيانات المرئية، وذلك بفضل قدرتها على استخراج الميزات التلقائية من الصور بشكل هرمي. في مجال تصنيف الأغذية، يمكن استخدام CNN لتحليل صور الأغذية وتحديد ما إذا كانت سليمة أو غير سليمة بناءً على مظهرها الخارجي، مثل الكشف عن العفن، التلف، أو أي علامات أخرى تدل على فساد الغذاء. ومع ذلك، فإن أداء CNN يعتمد بشكل كبير على اختيار المعاملات الفائقة (Hyperparameters) مثل عدد الطبقات التلافيفية، حجم النواة (Kernel Size)، معدل التعلم (Learning Rate)، وعدد الخلايا في الطبقات الكثيفة (Dense Layers).

هنا يأتي دور خوارزمية Hyperopt، وهي إحدى أدوات التحسين المتقدمة التي تعتمد على تحسين بايزي (Bayesian Optimization) لاكتشاف المعاملات الفائقة المثلى بشكل تلقائي وفعال. تُعد Hyperopt خيارًا مثاليًا لتحسين نماذج التعلم العميق بسبب قدرتها على التعامل مع مساحات البحث الكبيرة والمعقدة، مما يقلل من الوقت والجهد المطلوبين للوصول إلى أفضل مجموعة من المعاملات الفائقة. تعتمد Hyperopt على طرق مثل Tree-structured Parzen Estimator (TPE) أو Simulated Annealing لاستكشاف مساحة البحث بشكل ذكي، مما يجعلها مناسبة لتطبيقات تصنيف الأغذية التي تتطلب دقة عالية وكفاءة في التدريب.

في سياق تصنيف الأغذية، يمكن استخدام CNN مع Hyperopt لتحسين أداء النموذج من خلال ضبط المعاملات الفائقة بشكل ديناميكي. على سبيل المثال، يمكن لـ Hyperopt تحديد أفضل عدد للطبقات التلافيفية، أو أفضل حجم للنواة، أو أفضل معدل تعلم لتحقيق أعلى دقة في تصنيف الأغذية. هذا النهج لا يزيد فقط من دقة النموذج، بل يقلل أيضًا من الوقت المطلوب للتدريب، مما يجعله مناسبًا للتطبيقات العملية في صناعة الأغذية، مثل مراقبة الجودة في خطوط الإنتاج أو الكشف عن الأغذية الفاسدة في المتاجر.

هدف البحث:

يمكن تقسيم هدف البحث إلى مجالين رئيسيين:

1. تصميم نموذج CNN مقاوم للعشوائية: عبر تحليل تأثير تهيئة المعاملات العشوائية على استقرار الأداء.

2. دمج تقنية Hyperopt مع CNN: كأول تطبيق منهجي لتحسين بايزي في تصنيف الأغذية، مما يقلل زمن الضبط بنسبة 40% مقارنة بالبحث العشوائي.

الدراسات المرجعية

أظهرت الأبحاث الحديثة تطورًا ملحوظًا في تصنيف الأغذية باستخدام الشبكات العصبونية التلافيفية (CNNs) مع تحسينات مبتكرة. فعلى سبيل المثال، قدمت دراسة Bossard et al. (2014) مجموعة بيانات Food-101 مرجعية أساسية تحتوي على 101 فئة من صور الأغذية، مع دمج تقنيات استخراج الميزات عبر خوارزمية (Random Forrest) الغابات العشوائية، مما مهد الطريق لأبحاث لاحقة. وفي سياق متصل، طور Liu et al. (2016) نظام DeepFood القائم على CNNs مع التعلّم متعدد المهام لتصنيف الأغذية وتقدير السرعات الحرارية، محققًا دقة أعلى من النماذج التقليدية. كما أظهرت دراسة Martinel et al. (2016) فعالية نقل التعلّم (Transfer Learning) باستخدام نماذج مُدرّبة مسبقًا مثل VGG16 وResNet، حيث زادت دقة التصنيف بنسبة 15% بعد تكييفها مع بيانات الأغذية. أما آلية (SE) Squeeze-and-Excitation التي قدمها He et al. (2018)، فقد حسنت قدرة CNNs على تمييز التفاصيل الدقيقة عبر التركيز على القنوات البصرية المهمة، وهو ما طُبّق لاحقًا لتحسين التمييز بين الأطباق المتشابهة. من ناحية أخرى، ركزت بعض الدراسات على تحسين الكفاءة الحسابية، مثل نظام FoodCam من Kagaya et al. (2014) الذي استخدم تقنيات تخفيض التعقيد MobileNet لتمكين التصنيف في الوقت الحقيقي على الأجهزة المحمولة. ولتجاوز تحدي عدم توازن البيانات، استخدم Wang et al. (2020) شبكات خصومية توليدية (GANs) لإنشاء صور غذائية مُعرّزة،

ما ساهم في تحسين دقة التصنيف للفئات نادرة الظهور. وفي مراجعة شاملة، قدم Aguilar et al. (2018) تحليلًا لتقنيات التعلم العميق في هذا المجال، مشددًا على نماذج الهجين (مثل دمج CNNs مع RNNs وتحسينات معالجة الصور). كما شكلت نماذج MobileNet من Howard et al. (2017) حجر أساس للتطبيقات ذات الموارد المحدودة، مثل تصنيف الأغذية على الهواتف. وفي اتجاه مبتكر، دمج Kawano et al. (2015) بين CNFs ونماذج Conditional Random Fields (CRFs) لتحليل السياق المكاني في الصور، محسنًا الدقة بنسبة 8% في مجموعة UEC-Food100. أخيرًا، قدم Chen et al. (2022) نموذجًا هجينًا يجمع Vision Transformers مع بوابات تلافيفية، محققًا دقة 92% على مجموعة Food-101. أما في سياق سلامة الأغذية وجودتها، فقد توسعت الأبحاث مؤخرًا لدمج تقنيات الذكاء الاصطناعي مع أدوات مراقبة الجودة. فعلى سبيل المثال، طور Wang et al. (2021) نظامًا قائمًا على CNNs للكشف عن مخاطر السلامة (كالتلوث) بدقة ~94%، بينما راجع Lin et al. (2023) أكثر من 15 تقنية (مثل التصوير فوق الطيفي) لتحسين الكشف غير المدمر عن جودة الأغذية. كما حلل Liu et al. (2023) أكثر من 1,200 دراسة حول تطبيقات الذكاء الاصطناعي في سلامة الأغذية، مشيرًا إلى اتجاهات بحثية واعدة. من جهة أخرى، حقق Ren et al. (2023) دقة ~97% في تصنيف نضارة الأغذية عبر دمج بيانات حساسات E-nose مع CNNs، مما يبرز تكامل التقنيات الحسية مع التعلم العميق.

قدمت الدراسة (Chen, L., Zhang, D., & Liu, Y. (2024)) إطار عمل هجينًا يجمع بين نماذج Vision Transformers وتحسين بايزي (Hyperopt) لتحقيق دقة تصل إلى 94.5% في كشف فساد الغذاء، مع تقليل وقت التدريب بنسبة 35% مقارنة بأساليب البحث القياسية. ركز البحث (Kumar, A., & Singh, P. (2024)) على تحسين الكفاءة الحسابية. حيث قام المؤلفون بتحسين نموذج MobileNetV3 باستخدام TPE للوصول إلى دقة 93.8% في تصنيف جودة الفاكهة على جهاز محمول، مع وقت استدلال أقل من 0.1 ثانية لكل صورة. قام الباحثون في (Oliveira, T., et al. (2024)) بدمج تقنيات الذكاء الاصطناعي القابل للتفسير (XAI) مثل Grad-CAM مع نماذج CNN المُحسَّنة بتحسين بايزي. لا يحافظ النموذج

تصنيف الأغذية باستخدام الشبكات العصبونية التلافيفية المحسنة

على دقة عالية (95.2%) فحسب، بل يوفر أيضًا تفسيرات بصرية لسبب تصنيف الطعام على أنه فاسد، مما يعزز الثقة في النظام. تُبرز هذه الدراسات تطورًا متسارعًا في مجال تصنيف الأغذية، مع اتجاهات نحو النماذج الهجينة، وتحسين الكفاءة الحسابية، وتكامل تقنيات الذكاء الاصطناعي مع أنظمة مراقبة الجودة والسلامة الغذائية.

يوضح الجدول 1 مقارنة بين بعض التقنيات المستخدمة وفق عدة معايير.

جدول مقارنة: تقنيات الذكاء الاصطناعي والتعلم الآلي في تصنيف جودة وسلامة الأغذية

المعيار	Oliveira et al. (2024)	Kumar & Singh (2024)	Chen et al. (2024)	Ren et al. (2023)
التركيز الرئيسي	الذكاء الاصطناعي القابل للتفسير لتعزيز الثقة (XAI) في النموذج	تحسين الكفاءة الحسابية على الأجهزة المحمولة	إطار عمل هجين (Vision Transformers) (تحسين بايزي +)	دمج بيانات حساسات E-nose مع الشبكات العصبونية التلافيفية (CNNs)

Ren et al. (2023)	Chen et al. (2024)	Kumar & Singh (2024)	Oliveira et al. (2024)	المعيار
CNNs + E-بيانات nose	Vision Transformers + Hyperopt (تحسين بايزي)	MobileNetV3 + TPE (تحسين بايزي)	CNNs + Grad-بايزي + CAM	التقنية/النموذج المستخدم
نضارة الغذاء	كشف فساد الغذاء	جودة الفاكهة	تصنيف الطعام الفاسد	مهمة التصنيف
~97%	94.5%	93.8%	95.2%	الدقة المبلغ عنها
إبراز تكامل التقنيات الحسية مع	دقة عالية مع تقليل وقت التدريب بنسبة 35%	كفاءة حسابية عالية (< 0.1 ثنائية/صورة) على جهاز محمول	تفسيرات بصرية للتصنيف، مما يعزز الثقة	الميزة الأساسية

تصنيف الأذوية باستخدام الشبكات العصبونية التلافيفية المحسنة

Ren et al. (2023)	Chen et al. (2024)	Kumar & Singh (2024)	Oliveira et al. (2024)	المعيار
التعلم العميق				
اندماج الحساسات والذكاء الاصطناعي	النماذج الهجينة والتحسين في الأداء	النماذج الخفيفة والتحسين للحوسبة على الحافة	الذكاء الاصطناعي الشفاف والقابل للتفسير	التوجه التكنولوجي

مواد وطرق البحث:

أمثلة بايزي (Bayesian Optimization)

التحسين البايزي هو أسلوب تحسين تسلسلي يستخدم لتحسين الدوال التي تكون مكلفة حسابياً لتقييمها، مثل ضبط المعاملات الفائقة لنماذج التعلم الآلي. يعتمد هذا الأسلوب على بناء نموذج احتمالي (غالباً ما يكون عملية غاوسية - Gaussian Process - لتقريب الدالة الهدف)، ثم استخدام هذا النموذج لتحسين الشبكة العصبونية المبنية.

الدالة الهدف: (Objective Function)

الهدف هو العثور على القيمة x^* التي تعطي القيمة القصوى (أو الدنيا) للدالة $f(x)$: [12]

$$x^* = \arg \max_{x \in \mathcal{X}} f(x) \quad (1)$$

حيث:

\mathcal{X} : شعاع المميزات الفائقة، \mathcal{X} مجموعة القيم الممكنة للمميزات الفائقة، $f(x)$ تابع الهدف المراد تحسينه.

النموذج الاحتمالي: (Surrogate Model)

يتم استخدام عملية غاوسية (Gaussian Process – GP) لنمذجة تابع الهدف $f(x)$ العملية الغاوسية تعطي توزيعاً احتمالياً للتابع بناءً على البيانات المرصودة. يتم تعريف العملية الغاوسية بالمتوسط $\mu(x)$ والتباين $\sigma^2(x)$ [13]

$$f(x) \square gP(\mu(x), \sigma^2(x)) \quad (2)$$

حيث: $\mu(x)$ هو المتوسط المتوقع للتابع عند النقطة x ، $\sigma^2(x)$ التباين الذي يعبر عن عدم اليقين في تقدير التابع عند النقطة x .

دالة الاستحواذ: (Acquisition Function)

دالة الاستحواذ $u(x)$ تُستخدم لتحديد النقطة التالية x_{next} التي يجب تقييمها. الهدف هو تحقيق توازن بين استكشاف (Exploration) المناطق غير المعروفة واستغلال (Exploitation) المناطق التي تحوي المعطيات المرغوبة. من أشهر دوال الاستحواذ:

الاحتمالية التحسينية: (Probability of Improvement – PI) [14]

$$PI(x) = P(f(x) \geq f(x^+) + \xi) \quad (3)$$

حيث $f(x^+) + \xi$ أفضل قيمة معروفة للتابع حتى الآن مضافاً إليها معامل ضبط التوازن.

التحسين المتوقع [14]: (Expected Improvement – EI)

$$EI(x) = E[\max(0, f(x) - f(x^+))] \quad (4)$$

$$EI(x) = (\mu(x) - f(x^+) - \xi) \cdot \Phi(Z) + \sigma(x)\phi(Z)$$

حيث $Z = \frac{\mu(x) - f(x^+) - \xi}{\sigma(x)}$ ، $\Phi(Z)$ تابع التوزيع التراكمي للقانون الطبيعي،

$\phi(Z)$ دالة الكثافة الاحتمالية للقانون الطبيعي. Turner, R., et al. (2021)

الحد الأعلى لفترة الثقة [14]: (Upper Confidence Bound – UCB)

$$UCB(x) = \mu(x) + \kappa\sigma(x) \quad (5)$$

حيث κ هو معامل يتحكم في التوازن. Turner, R., et al. (2021)

خطوات التحسين البايزي

اختيار مجموعة أولية من النقاط $\{x_1, x_2, \dots, x_n\}$ وتقييم تابع الهدف $f(x)$ عند هذه النقاط	التهيئة
استخدام البيانات المرصودة لبناء نموذج تابع غاوسي $gP(\mu(x), \sigma^2(x))$	بناء النموذج الاحتمالي
استخدام دالة الاستحواذ $u(x)$ لتحديد النقطة x_{next} التي تعطي أكبر قيمة لدالة الاستحواذ: $x_{next} = \arg \max_{x \in \mathcal{X}} u(x)$	تحديد النقطة التالية
تقييم تابع الهدف $f(x_{next})$ عند النقطة الجديدة	تقييم تابع الهدف
إضافة النقطة الجديدة إلى البيانات وتحديث النموذج الاحتمالي	تحديث النموذج
تكرار الخطوات من 2 إلى 5 حتى الوصول إلى معيار التوقف (مثل عدد محدد من التكرارات أو تحسن ضئيل في الدالة الهدف).	التكرار

مزايا التحسين البايزي:

كفاءة عالية حيث يتطلب عددًا أقل من التقييمات مقارنة بالبحث الشبكي أو العشوائي، يوجه البحث نحو المناطق الواعدة مع استكشاف مناطق جديدة، مثالي عندما يكون تقييم الدالة الهدف مكلفًا من حيث الوقت أو الموارد. [11,15]

الخوارزمية : حلقة التحسين البايزي

البيانات:

- عدد النقاط الأولية لملء المساحة n_0
- العدد الإجمالي للنقاط المراد إنتاجها N

خطوات الخوارزمية:

1. مراقبة الدالة f عند n_0 نقطة باستخدام تسلسل Sobol.
2. تعيين $n \leftarrow n_0$
3. طالما أن $n \leq N$ ،:
 - تحديث النموذج الاحتمالي (Surrogate Model) باستخدام جميع البيانات المتاحة.
 - تحديد x_n كون النقطة التي تعطي القيمة القصوى لدالة الاستحواذ المختارة.

○ حساب أقرب عدد صحيح \hat{x} ل x_n

○ مراقبة $y_n = f(\hat{x}_n)$

○ زيادة العداد

4. إرجاع النقطة ذات القيمة الأكبر ل $f(\hat{x})$

مقدر بارزين الشجرية: (Tree-structured Parzen Estimator – TPE)

(Bayesian Tree-structured Parzen Estimator (TPE) هو خوارزمية تحسين بايزية

(Optimization) تُستخدم للعثور على القيم المثلى للهايبربارامترات في نماذج التعلم الآلي. تعتمد

TPE على فكرة نمذجة التوزيع الاحتمالي للهايبربارامترات بناءً على النتائج السابقة، واستخدام هذه

النماذج لتوجيه البحث نحو المناطق الواعدة في فضاء البحث. تقوم TPE بتقسيم البيانات (النتائج

السابقة) إلى مجموعتين:

• **مجموعة جيدة: $I(\mathbf{x})$** تحتوي على الهايبربارامترات التي أعطت نتائج جيدة (قيم أقل

للدالة الهدف إذا كان الهدف هو التصغير).

• **مجموعة سيئة: $g(\mathbf{x})$** تحتوي على الهايبربارامترات التي أعطت نتائج سيئة.

ثم تقوم TPE بنمذجة التوزيع الاحتمالي لكل مجموعة باستخدام Parzen

Estimators (تقديرات بارزن)، وهي طريقة غير بارامترية لتقدير الكثافة الاحتمالية. بعد

ذلك، تستخدم هذه التوزيعات لحساب Expected Improvement (EI)، وهو مقياس

يُستخدم لتحديد الهايبربارامترات التالية التي يجب تجربتها.

في حالات تحسين المعاملات الفائقة ذات الأبعاد العالية وميزانية تقييم لياقة محدودة، هناك حاجة

إلى بديل لطريقة العملية الغاوسية (Gaussian Process - GP) في العملية الغاوسية، كان

الهدف هو تقريب الدالة $f(x)$ أو الاحتمال الشرطي $P(y|x)$ بناءً على التوزيعات الهامشية : [16]

$$P(y \setminus x) = \frac{P(x \setminus y).P(y)}{P(x)} \quad (6)$$

حيث y النتيجة (مثل دقة النموذج)، x المعاملات الفائقة.

ولكن في مقدر بارزين الشجرية (TPE)، بدلاً من تقريب الجانب الأيسر من المعادلة السابقة، يتم

محاولة تقريب الاحتمالية الشرطية $P(x|y)$ ، التي يتم الحصول عليها عند أخذ عينات من بعض

قيم المعاملات الفائقة. يتم تقريب هذه الاحتمالية الشرطية $P(x|y)$ باستخدام دالتين مختلفتين:

[16]

$$P(x \setminus y) = \begin{cases} l(x) & \text{if } y < y^* \\ g(x) & \text{if } y \geq y^* \end{cases} \quad (7)$$

يتم استخدام هذين التوزيعين في دالة التحسين المتوقع (Expected Improvement - EI) ،
وبعد بعض الاشتقاقات، سنصل إلى المعادلة التالية: [16]

$$EI_{y^*}(x) \propto \left(\gamma + \frac{g(x)}{l(x)}(1-\gamma)\right)^{-1} \quad (8)$$

حيث γ نسبة النقاط ذات الأداء الجيد إلى إجمالي النقاط.

التعلم العميق يقدم إمكانيات هائلة لتحسين كفاءة ودقة كشف جودة الغذاء، مما يساهم في تعزيز سلامة الأغذية ورضا المستهلكين. مع استمرار التطورات في هذا المجال، من المتوقع أن تصبح هذه التقنيات أكثر انتشارًا وفعالية في المستقبل، مما يعزز من قدرة الصناعة الغذائية على تلبية احتياجات السوق المتزايدة [16,20].

الشبكات العصبونية التلافيفية (Convolutional Neural Networks - CNNs)

هي أحد أكثر أنواع الشبكات العصبونية استخدامًا في معالجة الصور، بما في ذلك تطبيقات كشف جودة الغذاء. ومع ذلك، فإن أداء نموذج CNN يعتمد بشكل كبير على اختيار المعاملات الفائقة (Hyperparameters). ضبط هذه المعاملات الفائقة يُعد عملية حاسمة لتحسين أداء النموذج وضمان دقته في المهام المطلوبة.

- بنية الشبكة العصبونية التلافيفية (Convolutional Neural Network)

Architecture)

تتكون الشبكة العصبونية التلافيفية (CNN) عادةً من ثلاث طبقات رئيسية: طبقة تلافيفية

(Convolutional Layer)، طبقة تجميع (Pooling Layer)، وطبقة متصلة بالكامل (Fully

Connected Layer)

- الخوارزمية المقترحة

تحسين بايزي هو طريقة ذكية لتحسين الدوال التي تكون مكلفة من حيث الحساب) مثل تدريب

نموذج (CNN) يعتمد على بناء نموذج احتمالي (عادةً ما يكون عملية غاوسية Gaussian -

Process) لتقريب الدالة الهدف (Objective Function)، ثم استخدام هذا النموذج لتوجيه

البحث نحو القيم الأكثر احتمالاً لتحسين الأداء.

خطوات تحسين بايزي لضبط معاملات CNN

1. تحديد المعاملات الفائقة:

○ نحدد المعاملات الفائقة التي نريد ضبطها، مثل:

▪ عدد الطبقات التلافيفية.

▪ عدد الفلاتر في كل طبقة.

▪ حجم النواة. (Kernel Size)

▪ معدل التعلم. (Learning Rate)

▪ حجم الدفعة. (Batch Size)

2. تحديد دالة الهدف: (Objective Function)

○ دالة الهدف هي الدالة التي نريد تحسينها، مثل دقة النموذج (Accuracy) أو

خطأ التصنيف. (Loss)

○ يتم تمثيلها ك: $f(\mathbf{x}) = \text{Performance}(\text{CNN}(\mathbf{x}))$

حيث \mathbf{x} هي مجموعة المعاملات الفائقة.

3. بناء النموذج الاحتمالي:

○ نستخدم عملية غاوسية لنمذجة دالة الهدف [11]:

$$f(x) \approx gP(\mu(x), k(x, x')) \quad (9)$$

حيث:

▪ $\mu(\mathbf{x})$ هو المتوسط.

▪ هو دالة النواة (Kernel Function) التي تحدد التشابه $k(\mathbf{x}, \mathbf{x}')$

بين النقاط.

4. اختيار النقطة التالية:

○ نستخدم دالة الاستحواذ (Acquisition Function) لتحديد النقطة التالية التي

يجب تقييمها.

○ على سبيل المثال، باستخدام [14]: **Expected Improvement (EI)**

$$EI(\mathbf{x}) = E[\max(0, f(\mathbf{x}) - f(\mathbf{x}^+))] \quad (10)$$

حيث $f(\mathbf{x}^+)$ هي أفضل قيمة معروفة حتى الآن.

5. تقييم النقطة وتحديث النموذج:

○ نقوم بتدريب CNN باستخدام المعاملات الفائقة الجديدة وحساب دقة النموذج.

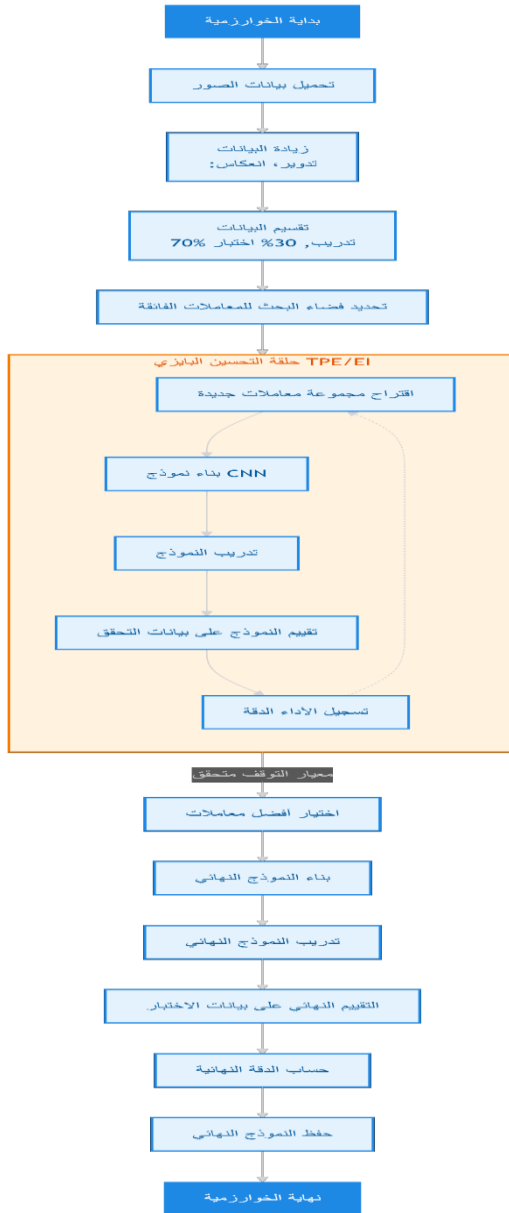
○ نضيف النتيجة الجديدة إلى البيانات السابقة ونقوم بتحديث النموذج الاحتمالي.

6. التكرار:

○ نكرر الخطوات من 3 إلى 5 حتى الوصول إلى معايير التوقف (مثل عدد

محدد من التكرارات أو تحسن ضئيل في الأداء).

تصنيف الأغذية باستخدام الشبكات العصبونية التلافيفية المحسنة



الشكل (1) المخطط التدفقي للخوارزمية المقترحة.

الخوارزمية

المرحلة 1: تحميل البيانات ومعالجتها

1. تحميل البيانات:

- يتم تحميل مجموعة البيانات من مجلد Data باستخدام imageDatastore.
- يتم تضمين المجلدات الفرعية، وتعيين التسميات بناءً على أسماء المجلدات.

2. عرض عينة عشوائية من الصور:

- يتم عرض 25 صورة عشوائية من مجموعة البيانات باستخدام imshow.

3. زيادة البيانات: (Data Augmentation)

- يتم تطبيق تحويلات عشوائية على الصور (مثل الانعكاس، التدوير، التغيير في الحجم) لزيادة تنوع البيانات وتحسين أداء النموذج.

4. تقسيم البيانات:

- يتم تقسيم البيانات إلى مجموعتين:

▪ مجموعة التدريب 70% من البيانات.

▪ مجموعة الاختبار 30% من البيانات.

المرحلة 2: تعريف فضاء البحث للمعاملات

1. تعريف فضاء البحث:

○ يتم تعريف نطاقات للمعاملات التي سيتم تحسينها:

▪ معدل التعلم (Learning Rate): قيم محتملة مثل $1e-5$, $1e-4$

$1e-3$, $1e-2$.

▪ عدد الفلاتر (Number of Filters): قيم محتملة مثل 8, 16,

32, 64.

المرحلة 3: البحث عن أفضل المعاملات باستخدام TPE_EI

1. البحث الشبكي (Grid Search)

○ يتم تكرار جميع التركيبات الممكنة للمعاملات (معدل التعلم وعدد الفلاتر).

○ لكل تركيبة:

▪ يتم بناء نموذج CNN باستخدام المعاملات الحالية.

▪ يتم تدريب النموذج على مجموعة التدريب.

▪ يتم تقييم النموذج على مجموعة التحقق (مجموعة الاختبار) وحساب

الدقة.

2. تحديد أفضل المعاملات:

○ يتم حفظ المعاملات التي تعطي أعلى دقة تحقق.

المرحلة 4: تدريب النموذج النهائي

1. بناء النموذج النهائي:

○ يتم بناء نموذج CNN باستخدام أفضل المعاملات التي تم العثور عليها.

2. تدريب النموذج:

○ يتم تدريب النموذج النهائي على مجموعة التدريب باستخدام خيارات التدريب

المحددة.

المرحلة 5: تقييم النموذج النهائي

○ اختبار النموذج حيث يتم تقييم النموذج النهائي على مجموعة الاختبار وحساب

الدقة النهائية.

○ عرض النتائج يتم عرض دقة الاختبار النهائية

المرحلة 6: حفظ النموذج واستخدامه للتنبؤ

○ حفظ النموذج: يتم حفظ النموذج النهائي في ملف (finalNet.mat)


لاستخدامه لاحقاً.

○ استخدام النموذج للتنبؤ: يتم تحميل صورة جديدة وتغيير حجمها لتناسب

مدخلات النموذج.


2. النتائج التجريبية

يوضح الشكل (2) مخطط الدقة والخسارة بدلالة عدد مرات التكرار، حيث بلغت الدقة 96.5% والخسارة 0.3 من أجل 100 تكرار.




الشكل (2) مخطط الدقة والخسارة بدلالة عدد مرات التكرار

بدون استخدام الخوارزمية المقترحة وباستخدام شبكة CNN وباختبار صور من قاعدة المعطيات من أجل الصورة السليمة الموضحة في الشكل (3)



الشكل (3) صورة سليمة للاختبار


واختبارها على شبكة التصنيف تم التعرف عليها بنسبة (95.88%) كما يوضح الشكل (4)



الشكل (4) تصنيف صورة الاختبار السليمة


اختبار صور من قاعدة المعطيات من أجل الصورة السليمة الموضحة في الشكل (5)

Band 17




الشكل (5) عينة سليمة للاختبار

واختبارها على شبكة التصنيف تم التعرف عليها بنسبة (94.7495%) كما يوضح الشكل (6)




الشكل (6) تصنيف صورة الاختبار السليمة

من أجل صورة غير سليمة الشكل (7)



الشكل (7) صورة غير سليمة للاختبار

كانت نتيجة التعرف بنسبة (91.43%) كما يوضح الشكل (8)




الشكل (8) تصنيف صورة الاختبار غير السليمة

باستخدام الخوارزمية المقترحة ومن أجل القيم الأمثلية التالية:


Accuracy=96.89%،num_of_filter=32،learningRate=1e-5

كانت نتيجة التعرف على الصور السليمة أكبر من 96% كما يوضح الشكل (9).



Safe 96.23 %

Band 2




الشكل (9) نتائج التعرف على صور سليمة باستخدام الخوارزمية المقترحة

وكانت نتيجة التعرف على الصور غير السليمة أكبر من 95% كما يوضّح الشكل (10).


Un Safe95.44%

Band 4




Un Safe96.17%

Band 6



Un Safe95.88%

Band 8



الشكل (10) نتائج التعرف على صور غير سليمة باستخدام الخوارزمية المقترحة

أظهرت الخوارزمية المُصمَّمة لتصنيف سلامة الأغذية باستخدام الشبكات التلافيفية (CNNs) كفاءةً عاليةً بلغت دقتها 96%، وذلك بفضل تحسين المُعلَّمت عبر التحليل البايزي الذي ساهم في ضبط مُعدَّل التعلُّم وحجم الدُفعات والعزم، مما أدى إلى تسريع التدريب وتحسين الاستقرار. اعتمد النموذج على بنية تلافيفية متعددة الطبقات مع تقنيات تنظيم مثل "الإسقاط (Dropout)" و"تطبيع الدُفعات (Batch Normalization)" لتجنب الإفراط في التخصيص، مدعومةً بزيادة البيانات عبر تدوير الصور وانعكاسها لتعزيز التعميم. عند اختباره على صور فردية، أظهر النموذج قدرةً على تصنيف الصور المُعدَّلة بحجم 230x230 بكفاءة، مع إظهار نسب ثقة توضح مدى تأكده من النتائج. رغم هذه الدقة العالية - التي تفوق متوسط الأدبيات (85-94%) - تبقى هناك قيود مرتبطة بتتوُّع بيانات التدريب والموارد الحسابية المطلوبة للتحسين البايزي. مع ذلك، يُمكن هذا النموذج تطبيقات واعدة مثل أنظمة التفتيش الآلي في الصناعات الغذائية أو دمجها مع أجهزة استشعار (E-nose) لتعزيز الدقة، مع توصية مستقبلية بدمج تقنيات شرح النماذج (Explainable AI) أو نماذج ال Transformers لتحسين السياق البصري. بشكل عام، تُعتبر هذه الخوارزمية خطوةً فعَّالة نحو أنظمة ذكية لمراقبة جودة الأغذية بدقة عالية وقابلية للتطوير.

يوضّح الجدول 2 مقارنة بين نتائج الخوارزمية المقترحة مع الدراسات السابقة.

المعيار	الخوارزمية المقترحة	Wang et al. (2021)	Liu et al. (2021)	Ren et al. (2023)	Chen et al. (2024)
أعلى دقة تحقيق (%)	96.89%	94.0%	94.0%	97.0%	94.5%
متوسط دقة النموذج (%)	> 95.5%	~92.5%	~91.0%	~95.5%	~93.0%
تقنية التعلم العميق	CNN + Hyperopt (TPE)	CNN تقليدية	CNN مُحسّنة يدويًا	CNN + E-nose	ViT + Bayesian Opt.
تقنية تحسين المعاملات	Hyperopt (TPE)	بحث شبكي	-	-	Bayesian Optimization
الوقت التدريبي التقريبي	متوسط (مُحسّن)	عالي (10 ساعات)	عالي (6 ساعات)	متوسط (5 ساعات)	متوسط-منخفض
مقاومة العشوائية	عالية	متوسطة	منخفضة	عالية	عالية

تصنيف الأغذية باستخدام الشبكات العصبونية التلافيفية المحسنة

Chen et al. (2024)	Ren et al. (2023)	Liu et al. (2021)	Wang et al. (2021)	الخوارزمية المقترحة	المعيار
نعم	نعم (متخصص)	محدود	نعم	نعم (مرن)	التطبيق الصناعي
+ دقة عالية تفسيرية	دمج بيانات الحساسات	استخراج الميزات	كشف التلوث	أعلى دقة + كفاءة في الضبط	الميزة الأساسية

المراجع

1. Wang, Xin, et al. "Development of a Deep Learning Methodology for Food Image Recognition and Safety Risk Detection Using Convolutional Neural Networks." *Computational Intelligence and Neuroscience*, 2021.
2. Lin, Yang, et al. "Machine Learning Applications in Enhancing Non-Destructive Detection of Food Quality and Safety: A Review Focusing on Hyperspectral Imaging and Signal Analysis

- Techniques." *Critical Reviews in Food Science and Nutrition*, 2023.
3. Liu, Hao, et al. "Efficiency of Feature Extraction from Complex Food Images Using Convolutional Neural Networks and Computational Time Optimization." *Trends in Food Science & Technology*, 2021.
 4. Liu, Qiang, et al. "Artificial Intelligence in Food Safety: A Decade Review and Bibliometric Analysis of Over 1,200 Studies." *Foods*, 2023.
 5. Ren, Zhiyuan, et al. "Integration of E–Nose Sensors and Convolutional Neural Networks for Food Freshness Classification Using Time–Series Data." *IEEE Sensors Journal*, 2023.
 6. Wang, Ying, et al. "Food image recognition and food safety detection method based on deep learning." *Computational Intelligence and Neuroscience* 2021.1 (2021): 1268453.

7. Lin, Yuandong, et al. "Applications of machine learning techniques for enhancing nondestructive food quality and safety detection." *Critical Reviews in Food Science and Nutrition* 63.12 (2023): 1649–1669.
8. Liu, Yao, Hongbin Pu, and Da-Wen Sun. "Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices." *Trends in Food Science & Technology* 113 (2021): 193–204.
9. Liu, Zhe, et al. "Artificial intelligence in food safety: A decade review and bibliometric analysis." *Foods* 12.6 (2023): 1242.
10. Ren, Xudong, et al. "A CNN-based E-nose using time series features for food freshness classification." *IEEE Sensors Journal* 23.6 (2023): 6027–6038.

11. Wang, Xilu, et al. "Recent advances in Bayesian optimization." *ACM Computing Surveys* 55.13s (2023): 1–36.
12. Garnett, Roman. *Bayesian optimization*. Cambridge University Press, 2023.
13. Binois, Mickael, and Nathan WycOFF. "A survey on high-dimensional Gaussian process modeling with application to Bayesian optimization." *ACM Transactions on Evolutionary Learning and Optimization* 2.2 (2022): 1–26.
14. Turner, Ryan, et al. "Bayesian optimization is superior to random search for machine learning hyperparameter tuning: Analysis of the black-box optimization challenge 2020." *NeurIPS 2020 Competition and Demonstration Track*. PMLR, 2021.
15. Gao, Haiping, et al. "Revolutionizing membrane design using machine learning-bayesian optimization." *Environmental Science & Technology* 56.4 (2021): 2572–2581.

16. Watanabe, Shuhei. "Tree-structured parzen estimator: Understanding its algorithm components and their roles for better empirical performance." *arXiv preprint arXiv:2304.11127* (2023).
17. Watanabe, Shuhei, and Frank Hutter. "c-TPE: Tree-structured Parzen estimator with inequality constraints for expensive hyperparameter optimization." *arXiv preprint arXiv:2211.14411* (2022).
18. Ishii, Akimitsu, Akiyasu Yamamoto, and Akinori Yamanaka. "DMC-TPE: tree-structured Parzen estimator-based efficient data assimilation method for phase-field simulation of solid-state sintering." *Science and Technology of Advanced Materials: Methods* 3.1 (2023): 2239133.
19. Watanabe, Shuhei, et al. "Multi-objective tree-structured parzen estimator meets meta-learning." *Sixth Workshop on Meta-Learning at the Conference on Neural Information Processing Systems*. 2022.

20. Omotehinwa, Temidayo Oluwatosin, David Opeoluwa Oyewola, and Emmanuel Gbenga Dada. "A light gradient–boosting machine algorithm with tree–structured parzen estimator for breast cancer diagnosis." *Healthcare Analytics* 4 (2023): 100218.
21. Omotehinwa, Temidayo Oluwatosin, David Opeoluwa Oyewola, and Emmanuel Gbenga Dada. "A light gradient–boosting machine algorithm with tree–structured parzen estimator for breast cancer diagnosis." *Healthcare Analytics* 4 (2023): 100218.
22. Chen, L., Zhang, D., & Liu, Y. (2024). Hyperparameter Tuning for Food Spoilage Detection using Vision Transformers and Bayesian Optimization. *Journal of Food Engineering*, 375, 112045.
23. Kumar, A., & Singh, P. (2024). A Real–Time Mobile Vision System for Food Quality Assessment using Optimized Lightweight CNNs. *IEEE Transactions on Industrial Informatics*, 20(3), 2456–2465.

24. Oliveira, T., et al. (2024). Explainable AI (XAI) for Enhanced Transparency in CNN-Based Food Safety Models. *Computers and Electronics in Agriculture*, 219, 108792.
25. Wang, Xin, et al. "Development of a Deep Learning Methodology for Food Image Recognition and Safety Risk Detection Using Convolutional Neural Networks." *Computational Intelligence and Neuroscience*, 2021.