

تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL)

بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات إنترنت الأشياء

م. محمد الهلامي* د. أكرم مرعي** د. ماهر عباس***

كلية الهندسة المعلوماتية- جامعة حمص

ملخص

يجب أن يضمن تصميم شبكة إنترنت الأشياء كفاءة الطاقة والسرعة والموثوقية لضمان الاستدامة طويلة الأجل لإنترنت الأشياء. اقترحت مجموعة عمل (IETF Roll) بروتوكول توجيه (RPL) للشبكات منخفضة الطاقة والتي تعاني من الخسارة كمعيار توجيه فعلي مع مراعاة استدامة شبكات إنترنت الأشياء المقيدة. تم تصميم بروتوكول RPL القياسي لاختيار أفضل مسار بناءً على مقياس جودة رابط واحد مثل عدد القفزات (Hop) أو عدد الإرسال المتوقع (ETX)، وبالتالي فإن اختيار المسارات غير الموثوقة يؤدي إلى إهدار موارد الشبكة وزيادة حالات إعادة إرسال البيانات والحمل غير المتوازن بين العقد.

نهدف في هذا البحث إلى استخدام إمكانيات تقنية التعلم الآلي الخاضع للإشراف لتحسين عملية التوجيه داخل البروتوكول (RPL)، قمنا بدمج التعلم الآلي الخاضع للإشراف داخل بروتوكول التوجيه المخصص للشبكات منخفضة الطاقة والتي تعاني من الخسارة (RPL) أدى هذا العمل إلى نسخة مقترحة من البروتوكول يسمى HUML_RPL يعتمد على تقنية التعلم الآلي الخاضع للإشراف من أجل اختيار المسارات وتحسين عملية التوجيه. النسخة المقترحة يستخدم نموذج شجرة القرار (Decision Tree) للتدريب على مجموعة بيانات التدريب التي تم توليدها ويتنبأ باحتمالية الوصول بنجاح إلى أفضل عقدة أب، تم دمج هذا النموذج داخل كل العقد في الشبكة وذلك من أجل اختيار المسار الأفضل لتوصيل الحزم بفعالية. تم اختبار أداء النسخة المقترحة

تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL)
بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات إنترنت الأشياء

من البروتوكول (HUML_RPL) في محاكي الشبكات Cooja لنظام التشغيل Contiki Os وتقييم أدائه لشبكات ذات كثافات متفاوتة. أظهرت نتائج المحاكاة أن النسخة المقترحة (HUML_RPL) يتفوق على الخوارزمية الأساسية داخل بروتوكول (RPL)، والتي تسمى (MORHF_ETX,OF0)، من خلال تحسين استهلاك الطاقة وتقليل رسائل التحكم وتحسين معدل تسليم الحزم وخفض زمن الوصول في الشبكة.

الكلمات المفتاحية: البروتوكول RPL، إنترنت الأشياء، التابع الوظيفي (MORHF)، التعلم الآلي الخاضع للإشراف

*طالب دكتوراه في قسم النظم والشبكات الحاسوبية - كلية الهندسة المعلوماتية - جامعة حمص.
**استاذ مساعد - قسم النظم والشبكات الحاسوبية - كلية الهندسة المعلوماتية - جامعة حمص.
***استاذ مساعد - قسم النظم والشبكات الحاسوبية - كلية الهندسة المعلوماتية - جامعة حمص

Improving Link Quality Selection in Routing Protocol (RPL)

Using Supervised Machine Learning Technologies in IOT Networks

Eng. Mohammad alholami* Dr. Akram almorei** Dr. Maher abbas***

Abstract

The design of the iot network must ensure energy efficiency, speed and reliability to ensure the long-term sustainability of the IoT. The IETF ROLL working group proposed the internet protocol version_6 (ipv6) Routing protocol for Low power Lossy Networks (RPL) as de-facto routing standard keeping in mind the sustainability of constrained IoT networks.

The standard RPL protocol is designed to choose the best path based on a single link quality metric such as hop count or expected transmission number so Choosing unreliable paths leads to wasted network resources, increased data retransmission and unbalanced load.

In This research explores the potential of Supervised Machine Learning technology to enhance IoT routing protocol, we integrated Machine Learning into the well-established Routing Protocol for Low-Power and Lossy Networks (RPL), resulting in an advanced (new) version called HUML_RPL based on Supervised Machine Learning technology.

The new version uses decision tree model for trained on a dataset of routing metrics, predicts the probability of successfully reaching a destination node and Each node in the network uses this model to choose the route with the highest probability of effectively delivering packets.

The new version of protocol (HUML_RPL) is tested in the COOJA simulator of Contiki OS. The performance evaluated for networks of varying density. The simulation results showed that the new version of (HUML_RPL) outperforms the basic algorithm within the (RPL) protocol, which is called (MORHF_ETX), by improving energy consumption, reducing control messages, and improving the packet delivery rate and lowers latency in a network.

Keywords: RPL protocol, Internet of Things (IOT), MORHF, supervised machine learning.

**PhD Student in the Department of Systems & Computer Networks of Faculty of Informatics –Homs University.*

***Associated Professor in the Department of Systems & Computer Networks of Faculty of Informatics - Homs University.*

****Associated Professor in the Department of Systems & Computer Networks of Faculty of Informatics - Homs University.*

(1 مقدمة:

يتم ربط مليارات الأجهزة مثل عدادات الطاقة والمياه، والأجهزة المنزلية، والأجهزة القابلة للارتداء، والمستشعرات، والمشغلات بالإنترنت لتكوين شبكة اتصالات ضخمة تُعرف بالإنترنت الأشياء. من المتوقع أنه بحلول عام 2030، سيكون هناك أكثر من 27 مليار اتصال بالإنترنت الأشياء. ستحدث إنترنت الأشياء تحولاً في مجالات مراقبة الطقس، والمدن الذكية، والرعاية الصحية، والأتمتة الصناعية، والأتمتة المنزلية[1]. تتكون شبكات إنترنت الأشياء وهو الجيل الجديد من شبكات الحساسات اللاسلكية من مستشعرات تعمل بالبطاريات تستخدم متحكمات دقيقة مثل (MSP430)[2] وتتمتع بسعة تخزين محدودة. بخلاف الشبكات التقليدية، يمكن أن تكون حركة المرور في هذه الشبكات واحد إلى واحد أو واحد إلى متعدد أو متعدد إلى متعدد. كما أن شبكة الاتصالات هذه تعاني من عدة عيوب مثلاً عدم الاستقرار ومعدلات البيانات المنخفضة وفقدان حزم البيانات العالي ونطاق الإرسال المحدود وتغير طوبولوجيا الشبكة الديناميكي وبسبب هذه القيود العديدة على الأجهزة وتكنولوجيا الاتصالات الأساسية، يتم تصنيف شبكات إنترنت الأشياء

IOT (Internet Of Things) كشبكات منخفضة الطاقة وفائدة البيانات (Low Power Lossy) [27] LNN (Network) ونظراً لأن بروتوكول التوجيه هو أحد دعائم هيكلية الشبكة وهو المسؤول عن قرارات التوجيه حيث أن القرارات الخاطئة سوف تسبب هدراً لموارد الشبكة ، صمم البروتوكول (RPL) من أجل الشبكات ذات الضياع والطاقة المنخفضة والشبكات التي تحتوي عدداً كبيراً جداً من الأجهزة الذكية والقادرة على الاتصال بالمستخدمين عبر شبكة الانترنت حيث أهتم الباحثون بدراسة وتطوير البروتوكول (RPL) الذي يعتمد على الوظائف الغرضية (Objective Function) OF من أجل إنشاء المسارات داخل الشبكة وتشكيل طوبولوجيا الشبكة. على الرغم من أن بروتوكول RPL كان قادراً على حل المشاكل الرئيسية، إلا أنه لا يزال هناك بعض القيود التي تحتاج إلى معالجة على سبيل المثال، يتخذ بروتوكول (RPL) القياسي قرار التوجيه معتمداً على مقياس جودة وصلة اتصال وحيد، مما يؤدي إلى اختيار مسارات غير مثالية وبالتالي تقليل عمر الشبكة [3].

في هذا البحث، نقتراح نسخة جديدة محسنة من بروتوكول التوجيه (RPL) يسمى HUML_RPL (HOMS_Univercity_MachineLearning_RPL)، يقوم البروتوكول باختيار أفضل مسار لعقدة الاب بناءً على تقنية التعلم الآلي الخاضع للإشراف وبالاعتماد على معايير جودة وصلة اتصال متعددة. ينجح هذا النهج في التغلب على قيود مقياس جودة وصلة الاتصال الواحد في بروتوكول (RPL) القياسي. تم اختيار كل من عدد القفزات HC (Hop Count) ، العدد المتوقع لإعادة الإرسال ETX (Expected Transmission Count) ، الطاقة المتبقية (Residual Energy) ، معدل تمرير الرزم (packet forwarding ratio) كمعايير لتدريب نموذج التعلم الآلي الخاضع لإشراف وذلك من أجل اختيار الأب الأمثل وباستخدام برنامج WEKA تم تدريب واختبار أربعة نماذج (Model) من خوارزميات التعلم الآلي الخاضع للإشراف وهي (شجرة القرار Decision Tree) ، الانحدار الخطي متعدد الحدود (multinomial logistic regression) ، الخلايا العصبية متعددة الطبقات (MultiLayer_Artificial_Neural_Network) ، آلة المتجهات الداعمة (Support vector machine) على بيانات تدريبية تقدر بـ (43600 عينة) تم توليدها عن طريق محاكي الشبكات COOJA ، حيث يقوم النموذج المدرب بحساب درجة جودة لكل عقدة أب مرشحة واختيار أفضل أب يحصل على أعلى درجة جودة كأب مفضل نحو عقدة الجذر وبعد

عملية التدريب وأجراء المقارنة باستخدام مقاييس التقييم لخوارزميات التعلم الآلي تم دمج أفضل خوارزمية وهي شجرة القرار (Decision Tree) داخل بنية بروتوكول التوجيه (RPL) وبعدها تم مقارنة النتائج مع كل من التوابع الوظيفية الأساسية (MORHF,OF0)، أظهرت النتائج تحسن في عملية استهلاك الطاقة وتحسين معدل تسليم الرزم والتقليل من التأخير الزمني بالإضافة إلى التقليل من رسائل التحكم.

(2) مشكلة البحث:

أهتم الباحثون بدراسة وتطوير البروتوكول (RPL) الذي يعتمد على الوظائف الغرضية (OF) من أجل إنشاء المسارات داخل الشبكة وتشكيل طوبولوجيا الشبكة على الرغم من أن بروتوكول (RPL) كان قادراً على حل المشاكل الرئيسية، إلا أنه لا يزال هناك بعض القيود التي تحتاج إلى معالجة على سبيل المثال يتخذ بروتوكول (RPL) القياسي قرار التوجيه معتمداً على مقياس جودة وصلة اتصال واحدة داخل الوظائف الغرضية مما يؤدي إلى اختيار مسارات غير مثالية وتحتوي على ضياعات وتشكيل ما يسمى بالنقاط الساخنة والتي يمكن تعريفها بـ (عقدة داخل الشبكة تعاني من الاختناق الشديد في مسألة تمرير الطرود وتبقى طوال الوقت مشغولة) وتسبب هذه النقاط الساخنة عملية تقليل عمر الشبكة ككل.

(3) الهدف من البحث:

نهدف في هذا البحث إلى تحسين أداء التوجيه واستهلاك الطاقة في شبكات أنترنت الأشياء وذلك من خلال تطوير بروتوكول التوجيه (RPL) الخاص بشبكات أنترنت الأشياء وذلك بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف.

حيث تم تحقيق مقياس جودة وصلة اتصال جديد يعتمد على الوظيفية الغرضية الجديدة (HUML_OF) والتي تعتمد على نموذج تعلم آلي يعتمد على تقنية شجرة القرار (Decision Tree) وذلك من أجل اختيار عقدة الـ أب الأفضل من بين مجموعة العقد المرشحة لتكون عقدة أب مفضلة للعقدة الحالية.

(4) أدوات وطرائق البحث:

في هذا البحث تم استخدام حاسوب شخصي يحتوي على معالج من نوع (corei7-4th_generation) ومقدار ذاكرة عشوائية تقدر بـ (8GB) ونظام تشغيل من نوع (Ubuntu)

يحتوي نظام التشغيل الخاص بأنترنت الأشياء (Contiki_Os) بالإضافة إلى المحاكى الخاص بنظام التشغيل الخاص بأنترنت الأشياء (Cooja Simulator) مع تنزيل كل من برنامج التعلم الآلي (Weka) وبرنامج (EmbML) من أجل توليد نموذج تعلم آلي مدرب متوافق مع محدودية موارد العقد داخل الشبكة.

5) بروتوكول التوجيه للشبكات منخفضة الطاقة والتي تحتوي فقدان لرزم (RPL):

يعد بروتوكول التوجيه هو المسؤول عن اتخاذ قرار التوجيه الذكي عن طريق اختيار المسار الأفضل بين عدة مسارات[4]. يعد التوجيه في شبكات (LLN) أحد التحديات الرئيسية ليس فقط بسبب الضياع الذي يكون في الوسط الراديوي والموارد المحدودة لعقد الحساسات ولكن أيضا بسبب متطلبات التوجيه المختلفة [5] ، لذلك ركزت مجموعة العمل الخاصة بشبكات منخفضة الطاقة والتي يكون فيها ضياع Routing Over Low Power and Lossy Networks (ROLL) على عملية تصميم بروتوكول توجيه جديد يتناسب مع القيود المفروضة على هذه الشبكات حيث قامت مجموعة العمل (ROLL) [4] بتوجيه من قبل مجموعة مهندسي مهام الانترنت (IETF) Engineering Task Force بإعتماد وإنشاء بروتوكول التوجيه (RPL) كبروتوكول توجيه معياري لشبكات (LLN) وتم توصيفه بالملف (RFC 6550)[6] كبروتوكول معياري يستند إلى النسخة المقترحة من بروتوكول عنوان الشبكات (IPv6) للعقد المقيّدة بالموارد وأصبح بروتوكول التوجيه الفعلي لشبكات (IOT) كما يدعم متطلبات التوجيه الدنيا من خلال بناء طوبولوجيا قوية عبر الروابط التي يكون فيها ضياعات، كما تم تطويره وأصبح معياراً أساسياً لبروتوكولات توجيه البيانات وتم استخدامه في العديد من أنظمة التشغيل مثل Contiki OS ، TinyOS ، كبروتوكول توجيه قياسي[5] .


❖ رسائل التحكم في الـ (RPL):

تم اقتراح أنواع جديدة من رسائل التحكم داخل البروتوكول (RPL) [3] لبناء طوبولوجيا شبكة (DODAG Destination Oriented Directed Acyclic Graph) وتتكون رسالة التحكم في (RPL) من [7] [26]:

✓ ترويسة (ICMPV6 Internet Control Message Protocol) والتي تتألف من ثلاثة حقول (type, code, CRC checksum) .

✓ متن الرسالة التي تحتوي على نص الرسالة وبعض الخيارات.

يتم تمييز نوع طرود التحكم بواسطة حقل الشيفرة (code) كما في الشكل رقم (1)، تتألف هذه الطرود من أربعة أنواع وهي:



الشكل رقم (1) بنية رسائل التحكم في بروتوكول (RPL)

• رسالة المعلومات DODAG Information Object (DIO):

بداية يقوم جذر (DODAG) ببث رسالة (DIO) باتجاه هابط إلى عقد الجوار من أجل تمكين حركة المرور من نقطة إلى عدة نقاط في اتجاه تنازلي. تحتوي رسائل (DIO) على معرف جذر شجرة (DODAG_ID)، معرف مثيل (RPL_Instance_ID) ومجموعة من المقاييس منها (مقاييس التوجيه، رتبة العقدة، الوظيفة الغرضية (OF)) تُرسل هذه الرسائل بشكل دوري مع رقم تسلسلي تراكمي من أجل بدء عملية اختيار الأب الأفضل للعقد [7].

• رسالة التماس المعلومات DODAG Information Solicitation (DIS):

يتم استخدام رسالة التحكم (DIS) بواسطة أي عقدة لجلب رسائل تحكم من نوع (DIO) بشكل صريح من العقد المجاورة، وتُستخدم أيضاً من أجل انضمام العقد إلى شجرة (DODAG) وفي حال لم تتمكن من تلقي رسائل من نوع (DIO) بعد فاصل زمني محدد مسبقاً يتم إعادة بث هذه الرسالة من جديد [7].

• رسالة إعلان الوجهة Destination Advertisement Object (DAO):

تخدم هذه الرسائل أساساً غرض نشر معلومات الوجهة في الاتجاه الصاعد نحو جذر الشبكة، تُستخدم هذه المعلومات لبناء المسارات الصاعدة بين العقد المرتبطة وجذر (DODAG) [7].

• الإقرار باستلام رسالة إعلان الوجهة (DAO-ACK):


عند استلام رسائل تحكم من نوع (DAO)، يمكن للعقدة إرسال رسالة (DAO-ACK) إلى مرسل رسالة (DAO) للاعتراف باستلام الرسالة بشكل صحيح وللإقرار باستعداد العقدة للعمل كقفزة تالية باتجاه جذر [7].

❖ طريقة تشكيل الطوبولوجيا داخل البروتوكول (RPL):

يقوم RPL بإنشاء طوبولوجيا الشبكة من خلال مخطط يسمى رسم بياني موجه (Directed Acyclic Graph DAG) والذي يتكون من واحد أو أكثر من الرسم البياني والذي يدعى رسم بياني لا حلقي موجه إلى الوجهة [6] (DODAG)، يمثل كل (DODAG) شجرة توجيه تم إنشاؤها بواسطة عقدة الجذر (Root Node) والمعروفة أيضا باسم عقدة مستقبل معلومات الشبكة. عند البدء بتهيئة المسارات وتشكيل البنية، تبدأ عقدة الجذر بتكوين الشبكة وبناء (DODAG) عن طريق بث رسالة تحكم من نوع (DIO) كما يوضح الشكل رقم (2)، تحتوي هذه الرسالة على العديد من المعلومات مثل معلومات رتبة العقدة (للسماح للعقد بأخذ مواقعها في DODAG ولمنع حلقات التوجيه) [3]، نمط التشغيل والوظائف الغرضية (OF)، تقوم العقد المجاورة لهذه العقدة بالاستماع إلى هذه الرسالة وإعادة إرسالها إلى العقد المجاورة لها وتحديد فيما إذا كانت تريد الانضمام إلى هذه البنية أم لا، وتقرر ذلك بناءً على قيود محددة، في الوقت الذي تصبح به هذه العقدة جزءاً من البنية، فسيكون لها مسار للأعلى نحو الجذر وعندها تحسب العقدة رتبته وتقوم بتحديث جدول الجيران الخاص بها، وتختار الأب الأفضل الذي سيتم استخدامه لإعادة توجيه الرسائل إلى جذر (DODAG) وعادة يكون الأب الأفضل هو الجار الذي يملك الرتبة الأدنى المحسوبة وفقاً للوظيفة الغرضية الصفرية (OF_0)، وبعد ذلك تقوم هذه العقدة بإعادة إرسال رسائل التحكم إلى العقد المجاورة وبهذه الطريقة تستمر العملية حتى بناء كامل الشبكة [7]. يدعم بروتوكول (RPL) وجود عدة بنى ضمن الشبكة الواحدة والتي من الممكن أن تكون تابعة لعقدة جذر أو أكثر وتدعى هذه البنية (DAG Instance) ويمكن لعقدة واحدة أن تنتمي إلى بنية واحدة أو أكثر بنفس الوقت حيث يكون لكل عقدة (ID Instance) واحد لكل بنية تنتمي إليها، تكمن فائدة هذه الخاصية في بناء مسارات حسب الهدف المطلوب من التطبيق مثلاً: مسارات للبيانات العادية يتجنب العقد

تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL) بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات إنترنت الأشياء

التي تعمل على البطارية، ومسار لبيانات ذات الأهمية القصوى والذي يكون فيه التأخير بحدوده الدنيا وتسلك مسارات ذات وثوقية عالية وطاقة عقدة كبيرة[3].



الشكل رقم (2) شجرة DODAG

❖ الوظائف الغرضية في بروتوكول الانترنت (RPL):

تعتمد عملية إنشاء شجرة (DODAG) على الوظائف الغرضية (OF) بشكل أساسي والتي تأخذها الشبكة بعين الاعتبار [6] ، يعتمد استخدام الوظيفة الغرضية بواسطة بروتوكول التوجيه (RPL) على ثلاث مكونات:

- المقياس المحدد، والذي يمثل المقياس الذي تستخدمه العقدة من أجل إنشاء المسار بين العقد.
- تكلفة المسار والذي يمثل جودة مسار الاتصال من بين مجموعة من المسارات بين العقد ويعتمد على المقياس المحدد.
- أفضل أب والذي يمثل أفضل مسار بين عقدة أبن وعقدة أب من حيث جودة وصلة الاتصال أو الطاقة المتبقية بالعقدة الاب أو العقدة الأقل من حيث كمية استقبال وأرسال البيانات. وضع الباحثون [7] [3] الوظائف الغرضية المعيارية في (RPL) كما يلي:

✓ الوظيفة الغرضية الصفرية (OF_0) :

تعتمد على عدد القفزات كمقياس لتكلفة المسار. يتم اختيار الأب المرشح الذي لديه أقل عدد من القفزات، مما يعني أن العقدة الأقرب إلى الجذر ستختار كأب مفضل. تلائم هذه الوظيفة الغرضية (OF0) الشبكات منخفضة الطاقة والتي يكون فيها ضياع. لكن مقياس العقدة هذا قد يؤثر جودة روابط سيئة لأن العقد تختار المسار مع الحد الأدنى لعدد القفزات حتى لو كان غير موثوق [7] ، وبالتالي تزداد عمليات إعادة الإرسال وضياع المزيد من الطرود.

✓ الوظيفة الغرضية (MORHF Based On ETX):

تستخدم الوظيفية الغرضية (ETX_OF) مقياس جودة وصلة الاتصال والذي يسمى عدد الإرسال المتوقع (ETX) كمقياس توجيه لتحديد أفضل مسار من بين مجموعة مسارات، ويعرف بالحد الأقصى لعدد عمليات إعادة الإرسال اللازم حتى يتم إقرار لاستلام الطرود بنجاح [3]. يمثل هذا المقياس بمعنى آخر كمية الضياعات في المسار بحيث كلما كانت كمية الضياعات كبيرة ازدادت قيمة المقياس ويكون المسار سيئ وكلما انخفضت قيمة (ETX) يكون هناك ضياعات قليلة ويكون المسار أفضل، تحسب قيمة (ETX) بالعلاقة رقم (1) [5]:

$$ETX = \frac{1}{dF * dR} \quad (1)$$

حيث:

dF: تمثل نسبة التسليم وتعرف احتمال الطرود الواردة الناجحة من المصدر إلى الوجهة.
dR: تمثل نسبة التسليم العكسي وهو احتمال الإقرار الوارد الناجح من الوجهة إلى المصدر.
تُقاس جودة الرابط من حيث الموثوقية من خلال قيمة (ETX)، تشير كلفة (ETX) المنخفضة إلى أن الروابط في الشبكة أكثر موثوقية.

كل من الوظيفتين الغرضيتين (OF0, MORHF) لهما القصور نفسه وذلك بسبب اعتمادهم على مقياس واحد فقط من أجل اختيار المسار [27]. تفنقر هذه الوظائف إلى النهج الشمولي الضروري لاختيار المسار الأفضل من حيث التأخير الزمني أو تجاوز العقد ذات الازدحام العالي. للتغلب على ذلك وتوفير حلول تؤمن جودة الخدمة (QoS)، قدمت مواصفات (RPL) المرنة للمصمم لإدراج المزيد من المقاييس في عملية اتخاذ القرار وسنرى في الأجزاء اللاحقة كيف يمكن تحقيق ذلك.

6) التعلم الآلي (Machine Learning (ML:

يعتبر مجال التعلم الآلي واحد من أهم مجالات الذكاء الاصطناعي الأربعة وهي: تعلم الآلة، معالجة اللغات الطبيعية، الرؤية الحاسوبية، ومجال الروبوتات، ان الهدف الاساسي من مجال التعلم الآلي هو تصميم نموذج آلي تستطيع الآلة من خلاله التصرف والتفكير والرؤية والتكلم مثل الإنسان. وذلك بناء على البيانات التي يتم تدريب هذه الآلة عليها.


يمكن تعريف مجال التعلم الآلي على أنه مجال في علم الحاسوب يستند على الإحصاء والتقنيات البرمجية حيث يكمن الغرض الرئيسي من هذا المجال في تطوير أنظمة ذكية تستطيع تحسين نفسها تدريجياً وبشكل آلي عندما تتعرف على البيانات والتجارب الجديدة بدون الحاجة للإعداد اليدوي [8].

6-1 التعلم الآلي الخاضع للإشراف Supervised ML :

يعد التعلم الآلي الخاضع للإشراف من الأقسام المهمة في التعلم الآلي إن لم يكن أهمها، حيث يتم تدريب خوارزميات هذا النوع على البيانات المصنفة، مما يعني أن البيانات تتضمن متغيرات الإدخال (features) ومتغير الإخراج المقابل لها (السمة)، الهدف من التعلم الخاضع للإشراف هو بناء نموذج يمكنه التنبؤ بدقة بمتغير المخرجات في ضوء بيانات الإدخال الجديدة كما يمكن تقسيم مهام هذا التعلم عند التقسيم في البيانات إلى نوعين رئيسيين هما التصنيف والتنبؤ. التصنيف هو نوع من خوارزميات التعلم الآلي التي يمكن استخدامها للتنبؤ بمتغير فئوي بناءً على واحد أو أكثر من متغيرات التنبؤ، حيث يتم تدريب النموذج على مجموعة من البيانات المصنفة ثم يتم استخدامه للتنبؤ بالبيانات الجديدة غير المرئية و بشكل عام، تعد خوارزميات التصنيف أداة قوية للتنبؤات ويمكن استخدامها في مجموعة واسعة من الصناعات والتطبيقات، بينما يستخدم التنبؤ لفهم العلاقة بين المتغيرات التابعة والمستقلة وبشكل عام يتم استخدامه من أجل التنبؤ بالتوقعات، مثل إيرادات المبيعات لنشاط تجاري معين، ومن أهم خوارزميات التعلم الآلي المستخدمة حالياً [9][8]:

6-1-1 شجرة القرار (Decision Tree) : تُستخدم خوارزمية أشجار القرار بهدف إنشاء نموذج يتنبأ بقيمة المتغير


المستهدف، إذ يتم تعلم قواعد القرار البسيطة التي تم استنتاجها من ميزات البيانات و يبدأ عمل هذه الخوارزمية من عقدة الجذر كما يبين الشكل (3) التي تطرح سؤالاً محدداً حول البيانات، ووفقاً للإجابة تُوجه البيانات إلى مختلف الفروع ومنها إلى العقد الداخلية والتي تطرح المزيد من الأسئلة وتوجه البيانات إلى الفروع اللاحقة، وتبقى هذه العملية مستمرة حتى تصل إلى عقدة النهاية التي لا تتفرع مرة أخرى [8].



الشكل (3) يبين بنية أشجار القرار [8]

2-1-6 خوارزمية آلة المتجهات الداعمة (Support Vector Machine): عبارة عن أسلوب يجمع بين النظرية


الإحصائية والتعلم الموجه، وتمتلك هذه الخوارزمية طريقتها الفريدة في التنفيذ مقارنة بخوارزميات التعلم الآلي الأخرى وفي الآونة الأخيرة، أصبحت شائعة للغاية بسبب قدرتها على التعامل مع العديد من المتغيرات المستمرة والقوية ويمكن استخدامها في مسائل التصنيف (Classification) أو الانحدار (Regression) [8]. الفكرة الرئيسية لعمل هذه الخوارزمية كما يبين الشكل (4) هي إيجاد أفضل مستوى فاصل (separating Hyperplane) الذي يفصل بين المجموعات (classes) وذلك عن طريق المحاولة لجعل الهامش (margin) أكبر ما يمكن والهامش (margin) هي المسافة بين بيانات المختلفة المراد تصنيفها والتي تعتبر محور عملية التدريب في آلة المتجهات الداعمة [8].



الشكل (4) خوارزمية آلة المتجهات الداعمة [8]

3-1-6 الشبكات العصبية الاصطناعية متعددة الطبقات (Multilayer Artificial Neural Network): تتكون

الشبكات العصبية الاصطناعية متعددة الطبقات (Multilayer ANN) من طبقات من العقد، حيث تحتوي على طبقة للمدخلات، وطبقة مخفية واحدة أو أكثر، وطبقة للمخرجات. كل عقدة، أو خلية عصبية اصطناعية، ترتبط بأخرى ويكون لها حمل وحد مرتبطين بها. إذا كانت مخرجات أي عقدة فردية أعلى من قيمة الحد المحددة، فإنه يتم تفعيل هذه العقدة، وإرسال البيانات إلى الطبقة التالية من الشبكة، خلاف ذلك لن يتم تمرير أي بيانات إلى الطبقة التالية من الشبكة. يمكن اعتبار كل عقدة على أنها نموذج انحدار خطي خاص بها، يتكون من بيانات المدخلات والأوزان والميل (أو الحد) والمخرجات، وبشكل عام تتكون الشبكة العصبية من ثلاث طبقات هي طبقة الإدخال، الطبقة المخفية وطبقة الإخراج [8]، في هذا البحث سوف يتم استخدام الشبكات العصبية القائمة على التغذية الأمامية، أو المستقبلات ذات الطبقات المتعددة (MultiLayer Precptron) MLP ويوضح الشكل (5) بنية عمل الشبكة العصبية.




الشكل (5) يبين طبيعة عمل الشبكة العصبية [8]

4-1-6 الانحدار اللوجستي متعدد الحدود (Multinomial Logistic Regression):

الانحدار اللوجستي المتعدد الحدود هو أسلوب تصنيف يعمم الانحدار اللوجستي (Logistic Regression) على المشاكل متعددة الفئات، أي مع أكثر من نتيجتين منفصلتين محتملتين، أي أنه نموذج يستخدم للتنبؤ باحتمالات النتائج المختلفة لمتغير تابع موزع تصنيفياً، مع الأخذ في

الاعتبار مجموعة من المتغيرات المستقلة (والتي قد تكون ذات قيمة حقيقية، أو ثنائية، أو تصنيفية) [24] [9]، ونلاحظ من الشكل (6) طريق تصنيف البيانات عن طريق هذا المقياس.



الشكل (6) الانحدار متعدد الحدود [24]

2-6 مقاييس تقييم أداء نموذج التعلم الآلي:

في هذا الجزء من البحث، سنناقش بعض مقاييس التقييم الأكثر شيوعاً المستخدمة في تقييم نماذج التعلم الآلي وذلك لتأكد من صحة نتائج الخوارزمية ومنها:

2-6-1 مصفوفة الارتباك (Confusion Matrix): تستخدم مصفوفة الارتباك لتقييم أداء نموذج

التصنيف [16] حيث

توضح عدد التنبؤات الصحيحة والغير الصحيحة التي قدمها النموذج مقارنة بالنتائج الفعلية. عادة ما يتم تمثيل المصفوفة على شكل جدول كما يبين الشكل (7) حيث يتم حساب هذه المكونات بناء على توقعات النموذج والنتائج الفعلية [16]:

✓ **إيجابية صحيحة (TP):** هذه القيمة تعبر عن عدد الحالات الإيجابية الفعلية التي توقعها النموذج بشكل صحيح على أنها إيجابية.

✓ **سلبية صحيحة (TN):** تعبر عن عدد الحالات السلبية الفعلية التي توقعها النموذج بشكل صحيح على أنها سلبية.

✓ **إيجابية خاطئة (FP):** تعبر عن عدد الحالات السلبية الفعلية التي توقعها النموذج بشكل غير صحيح على أنها إيجابية.

✓ **سلبية خاطئة (FN):** تعبر عن عدد الحالات الإيجابية الفعلية التي توقعها النموذج بشكل غير صحيح على أنها سلبية.

		PREDICTED classification				
		Classes	a	b	c	d
ACTUAL classification	a	TN	FP	TN	TN	
	b	FN	TP	FN	FN	
	c	TN	FP	TN	TN	
	d	TN	FP	TN	TN	

يبين الشكل (7) مصفوفة الارتباك [16]

2-2-6 الدقة (Accuracy): الدقة هي مقياس التقييم الأكثر استخداماً في مسائل التعلم الآلي

الخاضع للإشراف

حيث تقيس نسبة نقاط البيانات المصنفة بشكل صحيح من إجمالي عدد نقاط البيانات ويتم

حسابها بالعلاقة [16] رقم (2):

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

3-2-6 الانضباط (Precision): يعرف بأنه نسبة التنبؤات الإيجابية الحقيقية من جميع

التوقعات الإيجابية حيث يقيس قدرة النموذج على التنبؤ بالعينات الإيجابية بشكل صحيح ويتم

حسابه بالعلاقة [16] رقم (3):

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

4-2-6 الاستدعاء (Recall): ويعرف أيضاً باسم الحساسية، هو نسبة التنبؤات الإيجابية

الصحيحة من جميع العينات الإيجابية الفعلية، كذلك يقيس قدرة النموذج على تحديد العينات

الإيجابية بشكل صحيح ويتم حسابه بالعلاقة [16] رقم (4):

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

6-2-5 درجة (F1): ويعبر عنه بالمتوسط التوافقي للدقة والاستدعاء كذلك يعتبر هذا المقياس شائع الاستخدام عندما

يكون كل من الدقة والاستدعاء مهمين يتم حساب درجة (F1) بالعلاقة رقم [16] (5):

$$F1_{Score} = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (5)$$

حيث:

✓ TP هو عدد الإجابات الحقيقية.

✓ TN هو عدد السلبات الحقيقية.

✓ FP هو عدد الإجابات الخاطئة.

✓ FN هو عدد السلبات الخاطئة.

6-2-6 متوسط الخطأ المطلق (Mean absolute error): يستخدم لقياس دقة

النموذج وبالتالي حساب معدل

الخسارة (loss) وذلك عن طريق إيجاد متوسط الفروقات بين القيم الحقيقية والمتوقعة باستخدام النموذج. كلما قلت القيمة الناتجة من الدالة كلما زادت دقة النموذج، ويكون استخدامه مفيداً في حالة قياس دقة النماذج المطبقة على البيانات التي تحتوي على قيم شاذة أو متطرفة وبحسب بالعلاقة [17] رقم (6):

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (6)$$

6-2-7 جذر متوسط الخطأ التربيعي (Root Mean Squared Error): يعد خطأ الجذر

التربيعي المتوسط في

التعلم الآلي مقياساً شائعاً يستخدم لقياس دقة النموذج التنبئي فهو يقيس الاختلافات بين القيم المتوقعة والقيم الفعلية، ويربع الأخطاء، ويأخذ المتوسط، ثم يجد الجذر التربيعي. يوفر خطأ الجذر التربيعي المتوسط فهماً واضحاً لأداء النموذج، حيث تشير القيم المنخفضة إلى دقة تنبؤية أفضل وبحسب بالعلاقة [17] رقم (7):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}} \quad (7)$$

حيث:

(n) حجم العينة.

(y) القيمة الحقيقية.

(x) القيمة المتوقعة.


3-6 برنامج تدريب نماذج التعلم الآلي (Weka):

هي أداة برمجية مفتوحة المصدر وشائعة الاستخدام في استخراج البيانات وتطبيق خوارزميات التعلم الآلي، والتي تم تطويرها في جامعة (Waikato University) في نيوزيلندا، تم تصميم برنامج (Weka) لتوفير مجموعة شاملة من الأدوات من أجل تحليل البيانات والنمذجة التنبؤية وهي حالياً تحظى بشعبية كبيرة في البيئات الأكاديمية والبحثية بسبب مرونتها وسهولة استخدامها. تم تصميمها لمساعدة المستخدمين على تحليل مجموعات البيانات الكبيرة وتطبيق خوارزميات التعلم الآلي المختلفة مثل التجميع (Clustering) والتصنيف (Classification) والانحدار (Regression) واستخراج البيانات [20].

4-6 برنامج (EmbML):

هي أداة لتحويل النماذج المدربة إلى ملفات كود مصدر بلغة (C, C++) بحيث يمكن دمج وتشغيل النموذج المحول داخل الأنظمة المضمنة، كما تقبل هذه الأداة مجموعة من النماذج المدربة باستخدام برنامج WEKA أو برنامج Scikit-Learn ، وذلك لأنها شائعة ومفتوحة المصدر وتوفر مجموعة واسعة من خوارزميات التعلم الآلي.

يوضح الشكل (8) تسلسل خطوات عملية تحويل نموذج التعلم الآلي المولد باستخدام برنامج (Weka) إلى ملفات كود مصدرية [21].



الشكل (8) خطوات استخدام برنامج [21] EmbML

5-6 كيفية عمل التنبؤ في نموذج التعلم الآلي الخاضع للإشراف:

تحتاج نماذج التعلم الآلي إلى تدريب نفسها قبل أن تتمكن من التنبؤ بدقة جيدة تنقسم مجموعة البيانات المستخدمة للتنبؤات إلى مجموعتين: مجموعة اختبار ومجموعة تدريب، تتكون مجموعة التدريب من بيانات مُسمّاة تُستخدم لتدريب نموذج التعلم الآلي وزيادة دقة التنبؤ بينما تحتوي مجموعة الاختبار على بيانات ربما لم يراها نموذج التعلم الآلي المُدرَّب من قبل، والتي تُستخدم لقياس مدى قوة تنبؤات النموذج في تجاربنا تكون نسبة الانقسام 80% لمجموعة التدريب و20% لمجموعة الاختبار.

7) الدراسة المرجعية:

نوضح في هذا الجزء من البحث دراسة استقصائية عن أبحاث تحسين أداء جودة وصلة الاتصال والتوابع الوظيفية المتوفرة في (RPL) وذلك باستخدام تقنيات التعلم الآلي الخاضع للإشراف، تهدف معظم الحلول إلى تحسين أداء التوجيه وفعالية الطاقة وإدارة موارد العقدة وتحسين معدل تسليم الرزم وتقليل من التأخير الزمني.

المؤلفون في [10] استخدموا تقنية التعلم الآلي الخاضع للإشراف وتم استخدام خوارزمية (Neighborhood-Based Nonnegative Matrix) وذلك من أجل تقييم جودة وصلة الاتصال، تم استخدام برنامج (MATLAB) من أجل تدريب النموذج المقترح كما تم تقييم أداء الخوارزمية عن طريقة مجموعة من المقاييس (recall-accuracy-F1_score) أظهرت النتائج زيادة في عدد معدل تسليم الرزم، الدراسة لم تذكر نوع البروتوكول الذي تم استخدامه كما تم تدريب النموذج فقط عن طريق برنامج (MATLAB) مع توفر الكثير من البرنامج التي تستخدم في تدريب واختبار النموذج بشكل أكثر سهولة.

اقترح الباحثون في [11] تحسين اختيار جودة وصلة الاتصال عن طريق استخدام تقنية التعلم الآلي حيث اقترحوا استخدام ثلاثة من خوارزميات التعلم وهي (الغابات العشوائية) Random (Forst)، الانحدار المنطقي (Logistic Regression)، آلة المتجهات الداعمة (SVM)، آلة المتجهات الداعمة الخطية (Linear SVM) وذلك من أجل تدريب نموذج تعلم يحوي على مقياسين من مقاييس جودة الاتصال وهي (قوة الإشارة المستقبلية) (RSSI)، ومعدل تسليم الرزم (Packet Delivery) PDR Ratio، تم تقييم أداء الخوارزميات المقترحة عن طريقة كل من الدقة ومصفوفة التشويش، اقترحت

الدراسة استخدام خوارزمية الغابات العشوائية (Random Forest) في عملية التنبؤ بجودة وصلات الاتصال، الدراسة لم توضح قياس الأداء للبروتوكول المستخدم ومقارنة النتائج عند استخدام تقنية التعلم الآلي أو طريقة دمج خوارزمية الغابات العشوائية داخل بنية البروتوكول.

المؤلفون في الدراسة المرجعية [12] استخدموا تقنية التعلم الآلي الخاضع للإشراف من أجل تدريب نموذج تعلم آلي يحوي على أربعة ميزات (Feature) وهي (الطاقة المتبقية، والتأخير، عدد القفزات، مقياس عدد الارسل المتوقع) وذلك من أجل ثلاثة من خوارزميات التعلم وهي (الغابات العشوائية (Random Forst)، الانحدار الخطي (Linear Regression)، خوارزمية أقرب جار (K-Nearest Neighbor) تم استخدام برنامج (Scikit Learn) من أجل تدريب واختبار النموذج، تم تقييم أداء الخوارزميات عن طريق مقياس الدقة (Accuracy) وزمن التدريب (Training Time) وزمن الحساب (Computation time)، أعطت النتائج الدقة الأفضل لخوارزمية اقرب الجيران تم دمج وتحقيق الخوارزمية اقرب الجيران (k-nearest neighbor) داخل بروتوكول التوجيه (RPL) وأظهرت النتائج تحسن كل من مقياس معدل تسليم الرزم وكمية الطاقة المستهلكة وذلك بالمقارنة مع كل من التابع الوظيفي (MORHF, OF0) وذلك من اجل عدد عقد مختلفة.

الورقة البحثية [13] ناقشت عملية تحسين اختيار العقدة الاب الأفضل داخل بروتوكول التوجيه (RPL) وذلك عن طريق استخدام نموذج التعلم الآلي الخاضع للإشراف من أجل تدريب نموذج يحتوي على ثمانية ميزات (Feature) وهي (عدد الارسل المتوقع، عدد القفزات، قوة الإشارة المستقبلية، جودة القناة، كثافة الشبكة، معدل ضياع البيانات على مستوى طبقة النقل، مقدار الحمل على رتل العقدة، عدد الرزم المسلمة) تم استخدام خوارزمية تعزيز التدريب (GRADIENT BOOSTING) من أجل تدريب واختبار النموذج، تم دمج النموذج المدرب داخل البروتوكول (RPL) تم استخدام محاكي الشبكات (OMNET++) من أجل دمج النموذج المدرب و تقييم النتائج باستخدام مقاييس التقييم (معدل تسليم الرزم، معدل تأخر وصول البيانات، حمل رسائل التحكم) ، نتائج المقارنة أعطت تحسن معدل تسليم الرزم وتقليل من معدل تأخر وصول البيانات وتقليل من رسائل التحكم، الورقة البحثية لم تأخذ مقياس كمية الطاقة عند استخدام النموذج المقترح

كما تم استخدام خوارزمية تعزيز التدرج (GRADIENT BOOSTING) بشكل مباشر دون مقارنتها مع بعض الخوارزميات باستخدام مقاييس تقييم إداء خوارزميات التعلم الآلي المعروفة. المؤلفون في الورقة البحثية [14] اقترحوا تحسين اختيار جودة وصلة الاتصال داخل البروتوكول (RPL) باستخدام الخوارزميات الجينية الفوضوية وتم إنشاء نسخة محسنة تسمى (RPL_CGA) (Chaotic Genetic Algorithm) وذلك بالاعتماد على كل من (حجم رتل الانتظار داخل العقدة (Queue Length)، عدد القفزات (HOPS)، عدد الارسل المتوقع (ETX)، التأخير الزمني من النهاية للنهاية (End-To-End Delay)، الطاقة المتبقية) حيث تم إعطاء لكل مقياس وزن معين وباستخدام الخوارزمية الجينية الفوضوية (CGA) تم اختيار أفضل عقدة أب من أجل القفزة التالية (Next Hop) والتي تملك افضل جودة لوصلة الاتصال وباستخدام محاكي الشبكات (OPNET) تم محاكاة العمل وأعطت النتائج تحسن كل من معدل تسليم الرزم (PDR) والتقليل من متوسط التأخير الزمني (Average End-to-End Delay) بالمقارنة مع البروتوكول التابع الوظيفي الأساسي (MORHF).

الدراسة المرجعية [15] اقترحت استخدام الشبكات العصبونية الاصطناعية من أجل تحسين عملية التوجيه. اقترحت الدراسة إنشاء تابع وظيفي (ANN_OF_RPL) جديد يعتمد على الشبكات العصبونية متعددة الطبقات من أجل اختيار جودة وصلة الاتصال الأفضل من بين مجموعة من الوصلات المقترحة تم استخدام كل من مقاييس (عدد القفزات، الطاقة المتبقية، عدد الارسل المتوقع، التأخير الزمني من النهاية للنهاية) من أجل تدريب الخوارزمية العصبونية والتي تقوم بحساب درجة جودة لكل عقدة أب مفضلة وذلك بالاعتماد على قيم المقاييس المقترحة وباستخدام محاكي الشبكات (COOJA) تم تقييم النتائج مع التوابع الوظيفية الاساسية (MORHF,OF_0) أعطت النتائج تحسين في عملية تسليم الرزم وتحسين كمية استهلاك الطاقة والتخفيف من التأخير الزمني.

8) مقاييس جودة وصلة الاتصال المستخدمة في تدريب نماذج التعلم الآلي:

من أجل تحسين أداء التوجيه وحل مشكلة توزع الحمل داخل عقد الشبكة تم استخدام كل من مقاييس جودة وصلة الاتصال وذلك من أجل توليد بيانات تدريبية لخوارزميات التعلم الآلي ومن هذه المقاييس:

1-8 الطاقة المتبقية (Residual Energy): يتم حساب الطاقة المتبقية للعقدة المرشحة حتى تكون عقدة أب بالعلاقة رقم (8) [18] [1]:

$$E_{res}(n) = E_{ini}(n) - E_{cons}(n) \quad (8)$$

حيث:

E_{res} : يشير إلى الطاقة المتبقية للعقدة (n).

E_{ini} : يشير إلى الطاقة الابتدائية للعقدة (n).

E_{cons} : يشير إلى كمية الطاقة المستهلكة للعقدة (n).

2-8 معدل إعادة توجيه الرزم (packet forwarding ratio):

لضمان توازن الحمل بين عقد الشبكة وعدم اختيار عقد ذات حمل عالي تشكل نقاط ساخنة داخل الشبكة وتؤدي إلى تدمير البيانات وزيادة كمية إعادة الإرسال واستنزاف طاقة العقدة بشكل كبير، تم اقتراح مقياس جديد يسمى معدل تمرير الرزم داخل العقدة ويقصد به كمية الرسائل التي تقوم باستقبالها عقدة ما وتقوم بإعادة تمرير هذه الرزم إلى عقدة أخرى ذات مستوى أعلى داخل الشبكة حيث تكون هذه العقدة مشغولة دائماً بعملية استقبال وتمرير رزم البيانات طوال الوقت ويمكن حساب معدل تمرير الرزم للعقدة المرشحة كعقدة أب خلال فترة زمنية معينة بالعلاقة المقترحة رقم (9) .

$$packet\ forwarding = (\sum packet_{receive} - \sum packet_{send}) / 100 \quad (9)$$

$packet_{send}$: يشير كمية البيانات المرسلة من قبل العقدة نفسها والتي تم تحسبها.

$packet_{receive}$: يشير إلى كمية البيانات المستقبلية من قبل العقدة التي تشكل أبناء لهذه العقدة.

3-8 عدد الإرسال المتوقع (ETX): من أجل جودة عالية للروابط وتجنب فقدان الطرود، يتم

حساب عدد الإرسال المتوقع بالعلاقة [4] (1).

4-8 عدد القفزات (Hop): يتم حساب عدد القفزات التي تسلكها رسالة ال (DIO) حتى الوصل

للعقدة التي يتم

حساب تكلفة مسارها، حيث يتم زيادة عدد القفزات بمقدار (1) عند كل عقدة تسلكها رسالة ال

(DIO) [19] .

9 توليد البيانات التدريبية (Trace Set):

تم توليد بيانات تدريبية تقدر ب (43180) عينة لنموذج شبكة مؤلف من (40) عقدة اتصال موزعة بشكل عشوائي لمدة (45) دقيقة مع برنامج مؤلف من نموذج تطبيق UDP Contiki يتألف من ملفين الملف (udp-client.c) وهو الملف الذي تم تنزيله على جميع عقد الشبكة (client node) بحيث تقوم العقدة (client node) بإرسال رسالة نصية ضمن فاصل زمني محدد الى موجه الشبكة أو جذر الشبكة (DODAG ROOT) والذي يحوي على الملف (udpserver.c) عند وصول المعلومات المرسله من عقدة الزبائن (client node) يقوم موجه الشبكة بأعلام العقدة التي تم استلام المعلومات منها بأن المعلومات تم استلامها بشكل صحيح، كما تم تقسيم جميع قيم مقاييس جودة وصلة الاتصال إلى درجات بحيث يعطي درجة جودة لكل مقياس تبعاً للقيم المولدة خلال فترة جميع بيانات تدريب النموذج ودرجة جودة نهائية لجميع مقاييس جودة وصلة الاتصال، كما يبين الجدول رقم (1).

✓ تم تقسيم قيم المقياس عدد الارسل المتوقع (ETX) الى أربع مستويات تمثل جودة المقياس (250,200,150,100).

✓ تم تقسيم قيم مقياس الطاقة المتبقية إلى ثلاثة مستويات تمثل الطاقة المتبقية بالعقدة وهي (250,170,100).

✓ تم تقسيم مقياس معدل توجيه البيانات إلى ثلاثة مستويات تمثل كمية البيانات التي تم إعادة توجيهها وهي (250,175,100).

✓ تم تقسيم مقياس عدد القفزات إلى ثلاثة مستويات تمثل مقدار القفزات للوصول على عقدة الجذر وهي (250,170,90).

كما تم تقسيم درجة الجودة النهائية لوصلة الاتصال أو ما يسمى بال (Class) إلى خمسة مستويات تمثل قيم الجودة النهائية وهي (الأسوأ، سيئة، جيدة، جيدة جداً، الأفضل) والتي تمثل القيم التالية على الترتيب (1000,800,700,500,300).

**تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL)
بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات إنترنت الأشياء**

الجدول رقم (1) يبين قيم مقاييس جودة وصلة الاتصال

ETX	Forwarding ratio	Hop count	Residual Energy	درجة الجودة النهائية (quality)
250	250	250	250	1000
250	250	250	90	800
200	175	250	250	700
100	250	250	170	500
150	100	250	250	300

كما يوضح الشكل (9) عينة من ملف البيانات التدريبية المولدة (Trace set)

```

trace_num_quality.arff
1 @relation 'etx_trace'
2 @attribute etx numeric
3 @attribute forwarding numeric
4 @attribute hop numeric
5 @attribute renergy numeric
6 @attribute class {'1000','800','700','500','300'}
7 @data
8 200,250,250,250,1000
9 100,250,250,90,500
10 200,250,250,250,1000
11 100,250,250,90,500
12 100,250,250,90,500
13 200,250,250,250,1000
14 200,250,250,250,1000
15 100,250,250,90,500
16 100,250,250,90,500
17 100,250,250,90,500
18 100,250,250,90,500
19 100,250,250,90,500
20 100,250,250,90,500
21 200,250,250,250,1000
22 200,250,250,250,1000
23 200,250,250,250,1000
24 100,250,250,90,500
25 200,250,250,250,1000
26 200,250,250,250,1000
27 100,250,250,90,500
28 200,250,250,250,1000

```

الشكل (9) عينة من ملف البيانات التدريب

بعد الحصول على ملف البيانات التدريبية (Trace set) تم استخدام برنامج (Weka) من أجل تدريب خوارزميات التعلم الآلي الخاضع للإشراف باستخدام تقنية التصنيف فكانت النتائج كما يبين الشكل (10).

Accuracy=1

classified	best	very_good	good	bad	worst
best	444	0	0	0	0
very_good	0	67	0	0	0
good	0	0	427	0	0
bad	0	0	0	7143	0
worst	0	0	0	0	554

مصفوفة التشويش لخوارزمية شجرة القرار

Accuracy=0.9386

classified	best	very_good	good	bad	worst
best	444	0	0	0	0
very_good	0	67	0	0	0
good	0	0	427	0	0
bad	0	0	0	7079	94
worst	0	0	0	217	337

مصفوفة التشويش لخوارزمية المتجهات الداعمة

Accuracy=0.870

classified	best	very_good	good	bad	worst
best	444	0	0	0	0
very_good	0	67	0	0	0
good	0	0	427	0	0
bad	0	0	0	6888	255
worst	0	0	0	217	337

مصفوفة التشويش لخوارزمية الانحدار اللوجستي متعدد الحدود

Accuracy=0.968


classified	best	very_good	good	bad	worst
best	444	0	0	0	0
very_good	0	67	0	0	0
good	0	0	427	0	0
bad	0	0	0	7049	94
worst	0	0	0	0	554

مصفوفة التشويش لخوارزمية الشبكات العصبونية ذات طبقتين

الشكل (10) مصفوفة التشويش لخوارزميات التعلم الآلي


نلاحظ من خلال مصفوفة التشويش أن خوارزمية أشجار القرار تفوقت على بقية الخوارزميات من حيث دقة الكشف، وبالنسبة لزمّن تدريب واختبار النماذج على البيانات التدريبية كانت النتائج كما يبين الشكل (11)

تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL)
بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات أنترنت الأشياء




الشكل (11) يبين زمن اختبار النموذج

نلاحظ من الشكل (11) أن زمن التدريب كان أقل ما يمكن بالنسبة لخوارزمية شجرة القرار (Decision Tree) وذلك بالمقارنة مع بقية الخوارزميات إما بالنسبة لزمن اختبار النموذج على بيانات الاختبار حققت خوارزمية الشبكات العصبونية (ML_ANN) أقل زمن بمقارنة مع خوارزمية (Multinomial Logistic Regression, Decision Tree) ولكن سيئة هذه الخوارزمية احتياجها لزمن تدريب كبير جداً وبالنسبة لكل من مقياس دقة كشف على بيانات الاختبار كانت النتائج كما يبين الشكل (12):



الشكل (12) يبين نسبة دقة الكشف لنماذج التعلم الآلي


نلاحظ من الشكل (12) تفوق خوارزمية شجرة القرار في عملية الكشف عن البيانات والتي تدخل في عملية تقييم وكشف صلات الاتصال متغيرة السمات، حيث نلاحظ من الشكل أن خوارزمية شجرة القرار تفوقت وأعطت نسبة كشف صحيحة (100%).
إما بالنسبة لمقاييس حساسية النموذج وهي (الانضباط (Precision)، الاستدعاء (Recall)، ودرجة (F1_Measure)) كانت النتائج كما يبين الشكل (13).



الشكل (13) مقاييس حساسية خوارزميات التعلم الآلي

نلاحظ من الشكل (13) تفوق خوارزمية شجرة القرار بالنسبة للمقاييس الحساسية حيث كل ما كانت القيمة أقرب إلى الـ (1) كانت حساسية النموذج في عملية التمييز بين البيانات التدريبية أكثر دقة وبالنسبة لدقة النموذج التنبؤي من أجل قوة الكشف كانت النتائج كما يبين الشكل رقم (14) وذلك لكل من مقياسي التنبؤ (MAR, RMSR).

تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL) بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات أنترنت الأشياء



الشكل (14) يبين الدقة التنبؤية لخوارزميات التعلم الآلي

نلاحظ من الشكل (14) أن خوارزمية شجرة القرار أعطت أفضل النتائج وذلك بالنسبة لكل من القياس (MAR RMSR) حيث أعطت الخوارزمية قيم صفرية وهذا يدل على أن دقة التنبؤ والكشف على بيانات الاختبار كانت بنتيجة عالية.

❖ الاستنتاجات:

- ✓ بالنسبة لزمن التدريب والاختبار ودقة الكشف (Accuracy) تفوقت خوارزمية شجرة القرار على بقية الخوارزميات المدروسة بشكل كبير.
- ✓ بالنسبة لطريقة عمل الخوارزمية في كشف جودة وصلات الاتصال في شبكات أنترنت الأشياء حققت خوارزمية شجرة القرار أعلى دقة بالمقارنة مع بقية الخوارزميات المدروسة وهذا ما بينه الشكل (12).
- ✓ بالمقارنة بين الخوارزميات المدروسة عن طريق مقاييس الأداء نلاحظ أن تفوق خوارزمية شجرة القرار بشكل كبير وهذا مناسب لدراستنا عن طريق عمل تصنيف (Classification) لوصلات الاتصال وكشف الوصلات ذات الموثوقية العالية عن الوصلات السيئة.

(10) تطوير بروتوكول التوجيه (RPL) باستخدام خوارزمية أشجار القرار (Decision Tree):

في هذه الجزء من البحث تم استخدام برنامج (EmBML) وذلك لتحويل النموذج المدرب باستخدام خوارزمية أشجار القرار المولد عن طريق برنامج (WEKA) إلى برنامج متوافق مع موارد المتحكمات الصغيرة بلغة (C) وتم دمج هذا البرنامج مع بنية البروتوكول (RPL) داخل نظام التشغيل (Contiki OS)، كما تم التعديل على الملف (make File) الخاص بروتوكول (RPL) وذلك مع أجل إضافة الملف الخاص بالنموذج المولد حيث يصبح الملف بالشكل التالية:

```
CONTIKI_SOURCEFILES += rpl.c rpl-dag.c rpl-icmp6.c rpl-timers.c  
huml_rpl.c rpl-ext-header.c micro_tree.c
```

بعد عملية دمج الملف داخل بروتوكول التوجيه (RPL) وتشغيل المحاكى يمكننا تلخيص الخطوات الرئيسية المستخدمة في عملية اختيار المسار الأمثل باستخدام تقنية شجرة القرار (Decision Tree) بما يلي:

1. عند استلام رسالة (DIO) للاحد العقد داخل الشبكة، يتم استخراج قيم مقاييس جودة وصلة الاتصال (ETX, Remain Energy, Hop Forwarding ratio)
2. يتم إضافة عقدة مرسل رسالة (DIO) إلى قائمة الآباء المرشحين.
3. يتم استدعاء التابع (classify) الخاص بخوارزمية أشجار القرار لتحديد الأب الأنسب من بين قائمة الآباء المرشحين حيث يقوم التابع بحساب درجة الجودة لكل عقدة أب.
4. يتم اختيار عقدة الأب التي تملك أعلى درجة جودة ومقارنته بدرجة جودة عقدة الأب الحالية.
5. نتحقق إذا كانت درجة الجودة للعقدة المرشحة كأب أفضل تتجاوز درجة جودة عقدة الأب الحالية بقيمة عتبة معينة تم تحديدها بقيمة أكبر من (150) وهي القيمة التي تعبر عن قيمة الزيادة في درجة جودة الاب وتم اختيارها بالاعتماد على متوسط قيم التصنيف.
6. إذا كانت درجة الجودة للعقدة المرشحة زائد قيمة العتبة أكبر من درجة جودة العقدة الحالية، يتم اختيار هذه العقدة كأفضل عقدة أب أو تبقى عقدة الأب الحالي كأفضل عقدة أب.
7. نقوم بحساب رتبة عقدة الأب الجديدة باستخدام معادلة الرتبة بالعلاقة (11,12,13). من أجل المحافظة على ترتيب العقد داخل طوبولوجيا الشبكة [19].

$$RANK(N) = RANK(PN) + RankIncrease \quad (11)$$

$$RankIncrease = MinHopRankIncrease * step \quad (12)$$

$$Step = \alpha_1 * ETX(N, PN) + \alpha_2 * fw_ratio \quad (13)$$

$$\alpha_i \in R^+, i \in \{1,2\} \text{ and } \sum_{i=1}^3 \alpha_i = 1$$

8. أرسل رسائل DAO للعقدة المجاورة من أجل أعلامها بالتغيرات.

9 مقاييس تقييم الأداء في بروتوكول التوجيه (RPL):

في هذا البحث استخدمنا خمسة مقاييس أداء قياسية [19] وذلك من أجل تقييم أداء جودة اختيار المسار داخل البروتوكول (RPL) وذلك من أجل تقييم خوارزمية التعلم الآلي المقترحة بالمقارنة مع الوظائف الغرضية الأساسية (MORHF, OF0)، وهذه المقاييس هي:

✓ وقت تقارب الشبكة (Network Convergence Time):

تحتاج العقد في شبكة إنترنت الأشياء إلى تشكيل طوبولوجيا من أجل التواصل بين العقد. لذلك فإن وقت إعداد الشبكة هو مقياس حاسم يجب تقييمه لأي بروتوكول توجيه، يتم تعريف وقت التقارب في لـ (RPL DAG) على أنه مقدار الوقت الذي تحتاجه جميع العقد التي يمكن الوصول إليها (من حيث الراديو) في الشبكة للانضمام إلى طوبولوجيا (DAG). يجب اعتبار هذا التقارب بمثابة وقت التقارب الأولي في شبكة RPL ذات العقد الثابتة من أجل الحصول على وقت التقارب في شبكة RPL، نحدد وقت إرسال DIO الأول من عقد العميل وانضمام DIO الأخير إلى DAG. يتم الحصول على وقت التقارب عن طريق طرح وقت انضمام DIO الأخير من وقت إرسال DIO الأول إلى DAG كما بالعلاقة رقم (14)[19].

$$\text{Convergence}_{\text{Time}} = (\text{Last_DIO_Join_DAG}) - (\text{First}_{\text{DIO}}_{\text{Send}}) \quad (14)$$

✓ حمل رسائل التحكم (Control Traffic Overhead) للشبكة:

يشمل هذه المقياس على رسائل DIO و DIS و DAO التي يتم إنشاؤها بواسطة كل عقدة، ومن الضروري حصر مقياس الحمل مع مراعاة الموارد النادرة في شبكات (LLN)، يتحكم بروتوكول (RPL) في رسائل التحكم الزائدة عن الحاجة من خلال استخدام مؤقتات التدفق. الهدف من هذا المقياس هو تحليل حمل الخوارزمية المقترحة المذكورة في استخدام موارد العقدة ويمكن حساب حمل رسائل التحكم عن طريق العلاقة رقم (15)[19]:

$$\text{control_traffic_overhead} = \sum_{i=1}^n \text{DIO}(I) + \sum_{i=1}^m \text{DIS}(k) + \sum_{i=1}^z \text{DAO}(i) \quad (15)$$

✓ استهلاك الطاقة (Energy Consumption):

من أجل حساب استهلاك الطاقة سوف نستخدم آلية نظام Power trace المتاحة في نظام التشغيل (ContikiOS) وهو نظام لتحديد ملامح الطاقة على مستوى الشبكة للشبكات اللاسلكية منخفضة الطاقة التي تقدر استهلاك الطاقة لوحدة المعالجة المركزية ونقل الحزم والاستماع. تحتفظ هذه الآلية بجدول للمدة الزمنية التي كان فيها مكون مثل وحدة المعالجة المركزية وجهاز الإرسال اللاسلكي قيد التشغيل. بناءً على هذا الحساب، يتم حساب الطاقة المستهلكة بالميلي وات عن طريق العلاقة رقم (16,17) حيث فولت التغذية (3 فولت) كما يلي [1][22]:

$$power(mW) = Current * voltage \quad (16)$$

ومن أجل حساب التيار المستهلك نستخدم العلاقة رقم (13)

$$Current = \frac{tx * current_{tx} + Rx * current_{rx} + Cpu * Current_{cpu} + Cpu_{idel} * Current_{cpuidel}}{Rtimer_ARCH_Second} \quad (17)$$

حيث قيم:

TX: زمن تشغيل المرسل الراديوي في العقدة بوحدة أجزاء الساعة (نبضة).

RX: زمن تشغيل المستقبل الراديوي في العقدة بوحدة أجزاء الساعة (نبضة).

CPU: زمن تشغيل وحدة المعالجة المركزية بوحدة أجزاء الساعة (نبضة).

cpu_{idel}: زمن تشغيل وحدة المعالجة المركزية في وضع الطاقة المنخفض بوحدة أجزاء الساعة (نبضة).

Rtimer_ARCH_Second: وهو عدد نبضات المعالج في الثانية الواحدة (32768 نبضة).

نبين في الجدول رقم (3) قيم التيارات المأخوذة من النشرة التعريفية للعقدة (Sky Mote) [23] وهي كما يلي:

الجدول (3) قيم التيارات المأخوذة من النشرة التعريفية للعقدة.

نوع الوحدة	كمية الاستهلاك
current _{cpu}	1.8 mA
current _{rx}	21.8 mA
current _{tx}	19.5 mA
current _{idel}	54.5 μ A

✓ زمن تأخر وصول الحزمة (Packet Latency):

يتم تعريف زمن الوصول على أنه مقدار الوقت الذي تستغرقه حزمة البيانات المرسل من عقدة ما للوصول إلى العقدة الهدف أو عقدة مصب الشبكة (Sink Node) حيث نقوم بحساب متوسط زمن الوصول لجميع حزم البيانات في الشبكة من جميع العقد إلى عقدة الجذر ويتم حساب قيمة المقياس عن طريق العلاقة رقم (18) وحساب معدل زمن وصول الحزمة بالعلاقة (19) [19].

$$\text{Total_Latency} = \sum_{i=1}^n (\text{recv_time}(i) - \text{send_time}(i)) \quad (18)$$

$$\text{Averagy_Latency} = \text{Total_Latency} / \text{Total_packets_received} \quad (19)$$

حيث (n) هو العدد الإجمالي للحزم المستلمة بنجاح.

✓ متوسط معدل تسليم الحزمة (PDR Average):

ويتم تعريفه على أنه عدد الحزم المستلمة في عقدة مصب الشبكة (sink node) إلى عدد الحزم المرسل إلى مصب الشبكة من بقية العقد حيث نقوم بأخذ متوسط قيمة (PDR) لجميع الحزم التي تم استلامها بنجاح في عقدة المصب (Sink) ولحساب متوسط نسبة تسليم الحزمة (PDR)، نقيس عدد الحزم المرسل من جميع العقد إلى عقدة المصب (Sink) ونقسمها على عدد الحزم المستلمة بنجاح في عقدة المصب (Sink) كما تبين بالعلاقة رقم (20) [19].

$$\text{Average PDR} = \left(\frac{\text{Total_packet_received}}{\text{Total_packet_send}} \right) * 100 \quad (20)$$

10 القسم العملي:

تركز معظم الأبحاث على المحاكاة بدلاً من التجارب وذلك بسبب توفر العتاد البرمجي وسهولة الوصول إليه، على الرغم من أن التقييم المعتمد على عمليات المحاكاة لا يعكس الواقع لأنه لا يأخذ بعين الاعتبار مجموعة من القيود مثل تغير المناخ والعوائق الطبيعية والتفاعلات البشرية ولكنه الخيار الوحيد المتوفر في كثير من الأحيان للطلبة والباحثين [25].

1-10 نظام التشغيل (Contiki_OS):

يعتبر نظام التشغيل (ContikiOS) والذي تم تطويره من قبل المعهد السويدي لعلوم الكمبيوتر البرنامج المستخدم على نطاق واسع في شبكات IoT وWSN وذلك لأنه مفتوح المصدر، وهو نظام التشغيل الأكثر استخداماً في مجال الأبحاث الخاصة بشبكات الحساسات اللاسلكية وشبكات إنترنت الأشياء، كما يستخدم (Contiki) في العديد من الأنظمة، مثل المراقبة الصناعية وأنظمة الإنذار ومراقبة المنزل عن بعد ومراقبة الإشعاعات [26] [19].

10-2 محاكي الشبكات (COOJA):

سوف نستخدم محاكي الشبكات (COOJA) وذلك بسبب كونه المحاكي الأكثر استخداما في الابحاث وأجراء التجارب في شبكات منخفضة الطاقة بنسبة تصل إلى (61%) وهو محاكي قائم على لغة (java) ويعتمد على نظام التشغيل (ContikiOS) بشكل أساسي ويمكن اعتباره أداة هجينة تُستخدم كأداة محاكاة للعقد الافتراضية (Simulator) وأداة محاكاة للأجهزة الحقيقية (Emulator) بمعنى آخر أن أدائه أقرب للواقع لأنه يقوم بتشغيل حقيقي للأجهزة الموجودة في الشبكة مما يجعل النتائج التي نحصل عليها دقيقة أكثر وتحاكي الواقع [7].

10-3 تهيئة الشبكة والتجارب:

في هذه التجارب سوف نستخدم عقد من نوع (sky mote) [23] والتي تتميز بمعدل نقل عالي للبيانات (250kb/s) وذاكرة دائمة ب(128KB) وذاكرة وصول عشوائي تقدر (35kb)، قمنا بالتعديل على بعض هذه الملفات داخل البروتوكول (RPL) وإضافة توابع جديدة على الملفات ومن هذه الملفات نذكر:

RPL.h, RPL-icmp6.c, RPL-)

(conf.h, HUML_OF.C, energest.c, RPLdag.c, uip6.c, microtree.c

ولأجراء التجارب قمنا باستخدام طوبولوجيا عشوائية مؤلفة من نموذج تطبيق UDP Contiki يتألف من ملفين الملف (udp-client.c) وهو الملف الذي تم تنزيله على جميع عقد الشبكة (client node) بحيث تقوم العقدة (client node) بإرسال رسالة نصية ضمن فاصل زمني محدد الى موجه الشبكة أو جذر الشبكة (DODAG ROOT) والذي يحوي على الملف (udpserver.c) عند وصول المعلومات المرسله من عقدة الزبائن (client node) يقوم موجه الشبكة بأعلام العقدة التي تم استلام المعلومات منها بأن المعلومات تم استلامها بشكل صحيح ومن أجل اختبار الخوارزمية المقترحة تم إجراء التجارب على شبكات مختلفة الكثافة :



- ✓ منخفضة الكثافة (20 عقد) كما يبين الشكل (15).
- ✓ متوسطة الكثافة (40 عقدة) كما يبين الشكل (16).
- ✓ عالية الكثافة (60 عقدة) كما يبين الشكل (17).

**تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL)
بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات أنترنت الأشياء**


وللإدخال الضياع في الوسط اللاسلكي استخدمنا النموذج (UDGM) والذي يعرف الضياع بناء على المسافات النسبية بين العقد في الوسط الراديوي [27]، يمكننا من خلاله ضبط نسبة الإرسال والاستقبال، حيث قمنا بالمحافظة على نسبة الإرسال (TX-100%) (لأننا نهتم بالضياع عند طرف المستقبل، بينما قمنا بتغيير نسبة الاستقبال (RX) والتي تُعرف بأنها نسبة نجاح استقبال الطرود عند المستقبل على نسبة (RX 80%)، ونشير إلى الضياع في الوسط اللاسلكي، كما تم تحديد نطاق الإرسال على 30 متر ونطاق التداخل على 50 متر، تم استخدام كل من التطبيق الملحق مع المحاكى (Cooja) المسمى (Contiki Simulation Script Editor) لقياس وقت المحاكاة وإيقاف المحاكاة بعد الوقت المحدد، ينشئ هذا البرنامج المساعد ملف سجل (COOJA_log file) لجميع مخرجات المحاكاة والتي سنقوم بتحليلها في نهاية المحاكاة باستخدام برنامج نصي مكتوب بلغة (Perl) وباستخدام برنامج (MS Excel) نقوم برسم المخططات البيانية. قمنا بتشغيل المحاكاة لمدة (45) دقيقة لكل سيناريو وتم إعادته لمدة أربع مرات وأخذ متوسط النتائج، يوضح الجدول رقم (3) المعاملات المستخدمة في التجارب المختلفة.

جدول رقم (3) ضبط بارامترات التجارب

Parameters	Description
No of Nodes	20,40,60
Simulation Model	UDGM (Unit Disk Graph Model)
Simulation time	45 Mins.
Data Rate	250kps
Node Arrangement Random	Random
Operating System	Contiki2.7
Simulator	Cooja
OF	MORHF_ETX, OF0, HUML_OF
DIO Min	12
DIO Doublings	8
Radio Duty-Cycling Interval	16HZ
RX Ratio	80%
TX Ratio	100%
TX Range	30m
Interference Range	50m
Packet Analyzer	Perl code



الشكل رقم (15) توزيع العقد العشوائي (20 عقدة).
 الشكل رقم (16) توزيع العقد العشوائي (40 عقدة).




الشكل رقم (17) توزيع العقد العشوائي (60 عقدة).

4-10 مناقشة النتائج:

✓ معدل استهلاك الطاقة:

تم تحليل النتائج وتسجيل قيم معدل استهلاك الطاقة كما يبين الشكل (18). بالنسبة لمقياس معدل استهلاك الطاقة نلاحظ بالنسبة للمقياس الجديد (HUML_RPL) كانت كمية استهلاك أقل من المقياس (MORHF_ETX, OF_0) من أجل جميع السيناريوهات نلاحظ تفوق المقياس الجديد المقترح في عملية التقليل من استهلاك الطاقة وذلك بسبب اختيار مسارات ذات وثوقية عالية وتحوي معدل تمرير رزم أقل كما أن عملية اختيار المسارات تتم بصورة أسرع من الوظيفة الغرضية


(MORHF) وذلك بسبب حذف بعض التوابع التي تقوم بمقارنة الأبناء المفضلين بشكل كامل مما يخفض من عملية استهلاك الطاقة بالشبكة ككل.



الشكل رقم (18) يوضح معدل استهلاك الطاقة لجميع العقد.

✓ مقياس حمل رسائل التحكم:


بالنسبة لمقياس حمل رسائل التحكم، كانت النتائج كما يبين الشكل (19) نلاحظ تفوق المقياس الجديد في تقليل من عدد رسائل التحكم (DIS,DIO,DAO) وذلك من أجل عدد عقد مختلف وتوزع عشوائي وذلك يعود بسبب اختيار المقياس مسارات أكثر وثوقيه واختيارها عقدة ذات طاقة كبيرة وتجاوز العقد ذات حركة البيانات الكثيفة والطاقة المنخفضة والتي تؤدي إلى خروج بعض العقد عن الخدمة بسبب نفاذ طاقتها وزيادة عدد رسائل التحكم بسبب تغير الأبناء المفضلين بشكل دائم.



الشكل رقم (19) يبين حمل رسائل التحكم.

✓ زمن تأخر وصول الرزم:

بالنسبة لمقياس متوسط معدل تأخر الرزم كانت النتائج كما يبين الشكل (20)، نلاحظ تفوق المقياس المقترح في التقليل من معدل زمن التأخير في عملية تسليم البيانات وذلك من أجل عدد عقد مختلفة، وذلك يعود إلى تجاوز العقد ذات معدل تمرير الرسائل العالي والذي يزيد من زمن انتظار الرسائل في ذاكرة العقدة حتى وصولها إلى العقدة الجذر، كما أن عملية اختيار مسارات لا تحتوي على عقد تشكل عنق زجاجة أو تحتوي على معدل تمرير بيانات عالي الذي بدوره يقلل من زمن الوصول الرسائل إلى العقد الجذر.




الشكل رقم (21) يبين متوسط معدل تأخر الرزم.

✓ مقياس متوسط معدل تسليم الرزم:

بالنسبة لمقياس متوسط معدل تسليم الرزم كانت النتائج كما يبين الشكل (22)، نلاحظ تفوق المقياس الجديد في عملية تسليم الرزم بالمقارنة مع كل الوظائف الغرضية (OF_0, MORHF_ETX) وذلك من أجل عدد عقد مختلفة وذلك بسبب وثوقية اختيار المسارات وتجاوز العقد المشغولة والتي تزيد من ضياع حزم البيانات وتزيد التأخير الزمني .


تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL)
بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات إنترنت الأشياء



الشكل رقم (22) يوضح متوسط معدل تسليم الرزم.

✓ مقياس وقت تقارب الشبكة:


بالنسبة لمقياس وقت تقارب الشبكة كانت النتائج كما يبين الشكل (23)، نلاحظ أن المقياس الجديد يقلل من زمن تقارب الشبكة بمقدار (2-4 ثانية) بالمقارنة مع الوظائف الغرضية الأساسية للبروتوكول (RPL) وذلك بالنسبة لعدد عقد مختلفة، ويرجع ذلك إلى اعتماد المقياس الجديد على خوارزمية تعلم آلي تعمل بشكل أسرع من الخوارزمية التقليدية والتي تحتاج إلى استدعاء أكثر من تابع وظيفي من أجل الانضمام للطوبولوجيا داخل الشبكة مما يساهم ذلك في عملية التقليل في وقت التقارب داخل الشبكة بشكل كامل.



الشكل رقم (23) يبين وقت تقارب الشبكة

5-10 مقارنة المقياس الجديد (HUML_RPL) مع بعض الدراسات السابقة:


في هذه الفقرة قمنا بعمل مقارنة مع بعض الدراسات السابقة التي اقترحت تقنيات إنشاء توابع وظيفية ومقاييس جودة وصلة اتصال مركبة تعتمد على خوارزميات التعلم الآلي الخاضع للإشراف كما تم قياس أداء الأعمال المقترحة بنفس مقاييس الأداء وذلك من أجل عدد عقد ثابت (70 عقدة) وطوبولوجيا عشوائية، ومن هذه الأعمال الدراسة المرجعية رقم [12] التي اقترحت إنشاء بروتوكول توجيه محسن (ML_RPL) يعتمد على خوارزمية أقرب الجيران (K-Nearest Neighbor)، كما اقترحت الدراسة المرجعية رقم [14] تحسين عملية اختيار وصلات الاتصال داخل عقد الشبكة وتم طرح نسخة محسنة تسمى (CGA-RPL) تعتمد على الخوارزمية الجينية إما الدراسة المرجعية [15] اقترحت استخدام الشبكات العصبونية الصناعية (ANN_RPL) من أجل تحسين عملية اختيار العقدة الأب الأفضل داخل الشبكة فكانت النتائج كما توضح الأشكال رقم (24,25,26,27)



الشكل رقم (24) يوضح معدل استهلاك الطاقة (70 عقدة).


✓ بالنسبة لمعدل استهلاك الطاقة كما يبين الشكل (24) كانت النتائج متقاربة بمقارنة مع كل من المقاييس (HUML_RPL, ANN_RPL, CGA_RPL) إما بالنسبة للمقياس (ML_RPL) الذي يعتمد على خوارزمية أقرب الجيران كانت عملية استهلاك الطاقة بشكل أعلى.

تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL)
بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات إنترنت الأشياء




الشكل رقم (25) يبين حمل رسائل التحكم ل(70) عقدة.

✓ بالنسبة لمقياس حمل رسائل التحكم كما يوضح الشكل (25) اعطى المقياس المقترح (HUML_RPL) أفضل النتائج في عملية التقليل من رسائل التحكم والتي تسبب زيادة استهلاك الطاقة وزيادة حركة البيانات داخل الشبكة مما يؤدي الى زيادة الضياعات وزيادة تأخر وصول رزم البيانات داخل الشبكة حيث ساعد المقياس المقترح في عملية اختيار مسارات ذات ثباتيه عالية من حيث كمية الطاقة ومعدل إعادة تمرير الرزم مما ساعد في عملية التخفيف في عملية تبديلات المسارات والذي بدوره يقلل من رسائل التحكم.



الشكل رقم (26) يوضح متوسط معدل تسليم الرزم ل (70) عقدة.

✓ من الشكل (26) نلاحظ أن المقياس الجديد (HUML_RPL) أعطى أفضل النتائج من حيث عملية معدل تسليم الرزم داخل الشبكة وذلك بمقارنة مع بقية التتابع الوظيفية ويعود ذلك في بسبب اعتماد الحل المقترح على خوارزمية أشجار القرار والتي تعتبر من الخوارزميات سريعة التنفيذ كما أن اختيار مقياس معدل توجيه الرزم يساعد في عملية تجاوز العقد المشغولة والتي تحتوي على كثافة تمرير بيانات عالية مما يؤدي إلى ضياع وتأخير بعض الرزم.



الشكل رقم (27) يبين متوسط معدل تأخر الرزم ل(70) عقدة.

✓ نلاحظ من الشكل (27) أن المقياس الجديد (HUML_RPL) أعطى نتائج أفضل من حيث عملية التقليل من زمن تأخر وصول الرزم وذلك بالمقارنة مع كل (MORHF, OF0, ANN_RPL, ML_RPL, CGA_RPL) ويعود ذلك إلى تجنب المسارات التي تعاني من حركة بيانات عالية مما يخفف ضياع وتأخر البيانات داخل العقد بالإضافة إلى اعتماد الحل المقترح على خوارزمية شجرة القرار والتي تعتبر من خوارزميات التعلم الآلي ذات سرعة تنفيذ عالية.

11 الاستنتاجات والتوصيات المستقبلية:

يعد التوجيه عاملاً مهماً في شبكة انترنت الأشياء لأنه ينفذ قرارات توجيه الطرود حيث أن اختيار المسارات السيئة في التوجيه يسبب المزيد من عمليات إعادة الإرسال وإهدار الموارد، بناءً على نتائج المحاكاة وتحليل الأداء نجد أن المقياس الجديد (HUML_OF) والذي يعتمد على تقنية التعلم الآلي الخاضع للأشراف يقدم أداءً متفوقاً بشكل عام بمقارنة مع الوظائف الغرضية الأساسية (MORHF, OF0) في عملية اختيار جودة وصلة الاتصال التي تصلنا إلى العقد الأب

**تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL)
بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات أنترنت الأشياء**

الأفضل، يأتي هذا التفوق من عملية اختيار المسار الأفضل بالنسبة لكمية الطاقة ومعدل توجيه الرزم الأقل للعقدة الأب والقيمة الأفضل للمقياس (ETX) وعدد القفزات الأقل وبالتالي اختيار أفضل المسارات لتوجيه الطرود وتوزيع الحمل والطاقة بشكل أفضل داخل عقد الشبكة. على الرغم من التحسينات التي أجريت في البحث، إلا أننا يمكننا طرح المزيد من التوقعات لتحسين هذا البحث في المستقبل منها:

1. طرح مقاييس جودة وصلة جديدة تدخل في تدريب نموذج التعلم الآلي.
2. تغيير طريقة اختيار الأب المفضل عن طريق طرح تقنية التعلم الآلي التزايدية (Incremental Learning) الذي يقوم بتدريب نفسه خلال فترة عمل الخوارزمية.
3. يمكن تطوير خوارزمية التعلم باستخدام تقنية التعلم العميق (Deep Learning).
4. دراسة أداء الخوارزمية من أجل مقاييس مختلفة وفي سيناريوهات مختلفة مع زيادة عدد العقد.

12 جدول الاختصارات:

Internet Of Things	IOT	انترنت الأشياء
Ipv6 Routing Protocol For Low-Power And Lossy Networks.	RPL	بروتوكول توجيه الشبكات المنخفضة الطاقة والتي تحتوي ضياعات
HOMS UNIVERSITY RPL	HUML_RPL	بروتوكول التوجيه المحسن خاص بجامعة حمص
Expected Transmission Count	ETX	عدد الإرسال المتوقع
Routing Over Low Power And Lossy Networks	ROLL	مجموعة عمل التوجيه عبر الشبكات منخفضة الطاقة والتي يكون فيها ضياع
Internet Engineering Task Force	IETF	فريق مهام هندسة الانترنت
Low Power And Lossy Network	LNN	الشبكات منخفضة الطاقة والتي يكون فيها ضياع
Objective Function	OF	تابع وظيفي
ZERO Objective Function	Of0	الوظيفة الغرضية الصفرية
Minimum Rank Hysteresis Objective Function	MORHF	الوظيفية الغرضية لاستعادة استقرار الرتبة
Destination Oriented Directed Acyclic Graph	DODAG	رسم بياني لا حلقي موجه إلى الوجهة
Internet Control Message Protocol	ICMPV6	بروتوكول رسائل التحكم الإصدار السادس
DODAG Information Object	DIO	رسالة المعلومات
DODAG Information Solicitation	DIS	رسالة التماس المعلومات
Destination Advertisement Object	DAO	رسالة إعلان الوجهة
Directed Acyclic Graph	DAG	رسم بياني موجه
Support Vector Machine	SVM	آلة المتجهات الداعمة

Artificial Neural Network	ANN	الشبكات العصبية الاصطناعية
MultiLayer Precptron	MPL	خلايا متعدد الطبقات
Multinomial Logistic Regression	MLR	الانحدار المنطقي متعدد الحدود
CHAOTIC GENETIC ALGORITHM	CGA	الخوارزميات الجينية الفوضوية
Packet Delivery Ratio	PDR	معدل تسليم الرزم
Unit Disk Graph Model	UDGM	نموذج رسم بياني لاقطاع القرص الوحدوي

13 المراجع باللغة الإنكليزية:

- [1] Gupta, Neeti, Anuradha Pughat, and Vidushi Sharma, 2021- "A critical analysis of RPL objective functions in internet of things paradigm." *Peer-to-Peer Networking and Applications* 14, no: 2187-2208.
- [2]MSP430, <https://www.ti.com/design-development/embedded-development/msp430-mcus.html>
- [3] Kechiche, Ines, Ines Bousnina, and Abdelaziz Same,2020-"A Review of RPL Objective Function based Enhancement Approaches, *Advances in Science, Technology and Engineering Systems*, vol. 5, no. 5, pp. 201–211, doi: 10.25046/AJ050525
- [4] Dhumane, Amol, Rajesh Prasad, and Jayashree Prasad,2016-"Routing issues in internet of things: a survey." In *Proceedings of the international multicference of engineers and computer scientists*, vol. 1, pp. 16-18.
- [5] Dharmalingaswamy, Anitha, and Pitchai Latha,2023- "Additive metric composition-based load aware reliable routing protocol for improving the quality of service in industrial internet of things." *Int. Arab J. Inf. Technol.* 20, no. 6 :954-964.
- [6] "rfc6550", <http://www.rfc-editor.org/info/rfc6550>
- [7] Mardini, Khalil, and Emad Abdulsamad,2023-"Designing a Novel RPL Objective Function & Testing RPL Objective Functions Performance", *Bachelor Degree Project*.
- [8] Sharma, Himanshu, Ahteshamul Haque, and Frede Blaabjerg,2021- "Machine learning in wireless sensor networks for smart cities: a survey." *Electronics* 10, no. 9 1012.
- [9] Sarumathi, S., M. Vaishnavi, S. Geetha, and P. Ranjetha,2021- "Comparative Analysis of Machine Learning Tools: A Review." *International Journal of Computer and Information Engineering* 15, no. 6: 354-363.
- [10] Zhao, Yuxin, Shenghong Li, and Jia Hou,2015- "Link quality prediction via a neighborhood-based nonnegative matrix factorization model for wireless sensor networks." *International Journal of Distributed Sensor Networks* 11, no. 10: 828493.
- [11] Sindjoung, Miguel Landry Foko, and Pascale Minet,2019- "Wireless link quality prediction in iot networks." In *2019 8th International Conference on Performance Evaluation and Modeling in Wired and Wireless Networks (PEMWN)*, pp. 1-6. IEEE.
- [12] Kuwelkar, Sonia, and Hassanali G. Virani,2023- "RPL protocol enhancement using K-Nearest Neighbor machine learning approach for IoT application", DOI: <https://doi.org/10.21203/rs.3.rs-2392682/v1>.
- [13] Santos, Carlos Lester Duenas, Ahmad Mohamad Mezher, Juan Pablo Astudillo León, Julian Cardenas Barrera, Eduardo Castillo Guerra, and Julian Meng, 2023- "ML-RPL: Machine

تحسين اختيار جودة وصلة الاتصال داخل بروتوكول التوجيه (RPL) بالاعتماد على تقنية التعلم الآلي الخاضع للإشراف في شبكات إنترنت الأشياء

- learning-based routing protocol for wireless smart grid networks. *IEEE Access* 11: 57401-57414.
- [14] Cao, Yanan, and Muqing Wu, 2018- "A novel RPL algorithm based on chaotic genetic algorithm." *Sensors* 18, no. 11 :3647
- [15] Kuwelkar, Sonia, and Hassanali G. Virani, 2023- "Enhancing the RPL Protocol Using an Artificial Neural Network for Sustainable IoT Infrastructure." *Sustainable Industry, Innovation and Infrastructure*: 95
- [16] Krstinic, Damir, Maja Braovic, Ljiljana seric, and Dunja Bozic-stulic, 2020- "multi-label classifier performance evaluation with confusion matrix." *Computer Science & Information Technology* 1:1-14.
- [17] Hodson, Timothy O, 2022- "Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not." *Geoscientific Model Development Discussions*: 1-10.
- [18] K. Venugopal and T. G. Basavaraj, 2022- "A Combined Metric Objective Function for RPL Load Balancing in Internet of Things." *International Journal of Internet of Things*, Vol. no. 1, doi: 10.5923/j.ijit.20221001.02
- [19] Ali, H, 2012- "A performance evaluation of RPL in Contiki: A cooja simulation-based study." *School of Computing, Blekinge Institute of Technology*.
- [20] Bouckaert, Remco R. Eibe Frank, Hall, Richard Kirkby, Peter Reutemann, Alex Seewald, and David Scuse, 2016- "WEKA manual for version 3-9-1." *University of Waikato: Hamilton, New Zealand*: 1-341.
- [21] Silva, Lucas Tsutsui, Vinicius MA Souza, and Gustavo EAPA Batista, 2019- "EmbML Tool: Supporting the use of supervised learning algorithms in low-cost embedded systems." In *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*, pp. 1633-1637. IEEE.
- [22] Subramani, Poorana Senthilkumar, and Subramani Bojan, 2023- "Weighted Sum Metrics–Based Load Balancing RPL Objective Function for IoT." *Annals of Emerging Technologies in Computing (AETiC)* 7, no. 2: 35-55.
- [23] sky mote datasheet, <http://www.crew-project.eu>.
- [24] <https://scikit-learn.org>

14 المراجع باللغة العربية:

- [25] العمر منال، 2022- تحسين أداء خوارزمية التقطير في إنترنت الأشياء، مجلة جامعة البعث سلسلة العلوم الهندسية الميكانيكية والكهربائية والمعلوماتية، المجلد 44، العدد 8، صفحة 65-92.
- [26] الكلزلي طريف، 2023- تحسين زمن تبديل العقد في بروتوكول RPL ضمن نظام التشغيل Contiki، مجلة جامعة البعث سلسلة العلوم الهندسية الميكانيكية والكهربائية والمعلوماتية، المجلد 54، العدد 32، صفحة 73-92.
- [27] الشعار رهن، 2020- تطوير خوارزمية لتحسين أداء التوجيه في إنترنت الأشياء، رسالة ماجستير، المعهد العالي للعلوم التطبيقية والتكنولوجيا، الجمهورية العربية السورية.