

## دراسة تأثير المجال الأعظمي المعقول للتغطية على أداء خوارزميات الكشف عن سوء السلوك في شبكات VANET

\* أ.د. غسان محمد

\*\* د. ناجي ابراهيم محمد

\*\*\* م. ازدهار شفيق شاليش

(تاريخ الإيداع ٢٠٢٥/٦/١٦ . قبل للنشر في ٢٠٢٥/٨/١٨)

### □ ملخص □

يُعد المجال الأعظمي المعقول للتغطية في شبكات العربات (VANETS) هو النطاق الذي تتمكن فيه العربات من تبادل رسائل beacons لتحذير السائقين من ظروف الطريق. ورغم أن توسيع هذا المجال يسمح باستقبال رسائل أكثر من عربات متعددة، إلا أنه لا يضمن موثوقية هذه الرسائل، مما قد يفتح الباب لهجمات خبيثة تؤثر على سلامة القيادة. كما يمثل مجال الظهور المفاجئ حالة تظهر فيها عربة بشكل مفاجئ داخل مجال عربة أخرى دون تبادل تدريجي للرسائل، مما يعزز فرص الهجوم أو التشويش. لمعالجة هذه التحديات، نقترح خوارزمية الثقة القائمة على متوسط الموزون للفحص (TrustWeightCheck) التي تعتمد على دمج الثقة مع أوزان ديناميكية للفحوصات، بحيث يُعزز وزن الفحص الفاشل ويُقلل وزن الفحص الناجح دون إهمال أي نتيجة. وقد تم تقييم أداء الخوارزمية ضمن قيمتين للمجال ٤٢٠م و ٦٠٠م. أظهرت النتائج أن زيادة المجال تؤثر بشكل طفيف على أداء الكشف، من خلال ارتفاع بسيط في زمن الاكتشاف وانخفاض محدود في مقاييس F1-Score، إلا أن الخوارزمية المقترحة تفوقت من حيث سرعة الكشف، حيث حققت متوسط زمن اكتشاف بلغ ٠.١٣ ثانية، إلى جانب معدل F1-Score مرتفع بلغ ٥٨٪. وعلى الرغم من ارتفاع الانتروبيا في تحديد العربة المهاجمة نتيجة تغيير الأسماء المستعارة لتقليل إمكانية التتبع، فقد أظهرت الخوارزمية توازناً جيداً في الاعتماد على جميع الفحوصات، مقارنة بخوارزميات تعتمد على معيار واحد أو ثقة الجوار أو على تنبؤات أولية بنوع الهجوم.

**الكلمات المفتاحية:** الكشف عن سوء السلوك، شبكات VANETS، هجوم، اختبارات، إنذارات كاذبة .

\*أستاذ دكتور، كلية هندسة تكنولوجيا المعلومات والاتصالات، جامعة طرطوس، طرطوس، سورية.

\*\*أستاذ مساعد كلية هندسة تكنولوجيا المعلومات والاتصالات، جامعة طرطوس، طرطوس، سورية.

\*\*\*طالبة دراسات عليا(دكتوراه)، قسم تكنولوجيا الاتصالات، كلية هندسة تكنولوجيا المعلومات والاتصالات، جامعة طرطوس، طرطوس، سورية

## Studying the Impact of the Maximum Plausible Coverage Range on the Performance of Misbehavior Detection Algorithms in VANETs

Prof. Dr. Ghassan Mohammed \*

Dr. Naji Ibrahim Mohammad\*\*

Eng. Izdihar Chafick Chalich\*\*\*

(Received 16/6/2025 . Accepted 18/8/2025)

### □ ABSTRACT □

The maximum plausible coverage range in Vehicular Ad Hoc Networks (VANETs) is the distance within which vehicles can exchange beacon messages to warn drivers about road conditions. Although extending this range allows receiving messages from multiple vehicles, it does not guarantee the reliability of these messages, which may open the door to malicious attacks that affect driving safety. The sudden appearance range represents a situation where a vehicle suddenly appears within the range of another vehicle without a gradual exchange of messages, increasing the chances of attacks or interference.

To address these challenges, we propose a trust-based algorithm relying on a weighted average for inspection (TrustWeightCheck), which integrates trust with dynamic weights for checks, such that the weight of a failed check is increased while the weight of a successful check is reduced without neglecting any result. The algorithm's performance was evaluated under two coverage ranges: 420 meters and 600 meters. The results showed that increasing the range slightly affects detection performance, with a minor increase in detection time and a limited decrease in F1-Score metrics. However, the proposed algorithm outperformed others in detection speed, achieving an average detection time of 0.13 seconds along with a high F1-Score rate of 58%. Despite higher entropy in identifying the attacking vehicle due to pseudonym changes that reduce traceability, the algorithm demonstrated a good balance by relying on all checks compared to algorithms based on a single criterion, neighbor trust, or preliminary attack type predictions.

**Key Words:** Misbehavior detection, VANETs, attack, checks false positives.

---

\*Professor, Faculty of Information and Communication Technology Engineering, Tartous University, Tartous, Syria.

\*\*Assistant Professor, Faculty of Information and Communication Technology Engineering, Tartous University, Tartous, Syria.

\*\*\*Postgraduate Student, Department of Communication Technology, Faculty of Information and Communication Technology Engineering, Tartous University, Tartous, Syria<sup>2</sup>

## ١ - مقدمة

تعد شبكات العربات اللاسلكية (Vehicular Ad-hoc Networks - VANETs) من المكونات الأساسية لأنظمة النقل الذكية (Intelligent Transport Systems - ITS) ، إذ تلعب دوراً محورياً في تعزيز السلامة المرورية، وتحسين التنقل، وتقليل الازدحام في المدن والريف. تعتمد هذه الشبكات على تبادل معلومات لحظي بين العربات (Vehicular to Vehicular-V2V) وبين العربات والبنية التحتية المحيطة مثل وحدات الطريق الجانبية (Vehicular to Infrastructure-V2I)، عبر رسائل تعرف برسائل السلامة الأساسية (Beacon) تحتوي هذه الرسائل على معلومات مهمة عن حالة العربة وموقعها وسرعتها وتسارعها، ما يساعد في اتخاذ قرارات فورية لتفادي الحوادث والتكيف مع الظروف المرورية [1].

تعتمد فعالية VANETs بشكل كبير على دقة وموثوقية البيانات المتبادلة. غير أن الطبيعة المفتوحة للشبكة واعتمادها على الاتصال اللاسلكي يعرضها لهجمات سيبرانية تهدد خصوصية وسلامة المستخدمين. من هنا ظهرت أهمية تطوير آليات لكشف السلوكيات المشبوهة أو الخبيثة داخل الشبكة [22],[26].

تتعرض رسائل التبيين لنوعين رئيسيين من الهجمات:

هجمات الخصوصية: يحاول المهاجم تتبع حركة العربات عبر ربط المعرفات الزائفة (Pseudonyms) ، ما يشكل تهديداً مباشراً لخصوصية السائقين. رغم وجود آليات تغيير دوري للأسماء المستعارة، إلا أن تغيير الهوية يجب أن يتم في أوقات وأماكن مناسبة لضمان فاعليته، ولهذا ظهرت استراتيجيات مثل تغيير الهوية في مناطق المزج (Mix-Zones) أو مناطق الصمت (Silent Periods) [24].

هجمات سلامة البيانات: تشمل إرسال بيانات كاذبة من مهاجمين يمتلكون شهادات رقمية وأسماء مستعارة قانونية، مثل هجمات الموقع المزيف، السرعة غير المنطقية، التزاحم المزيف، وهجوم Sybil. تهدف هذه الهجمات إلى تضليل العربات المجاورة مما قد يسبب حوادث خطيرة [25].

للتصدي لهذه التهديدات، تستخدم منظومات توقيع رقمي تعتمد على بنية المفاتيح العامة (PKI) لضمان صداقية الرسائل. ولكن، بما أن المهاجم قد يستخدم شهادات مسروقة أو صالحة، فإن التحقق من التوقيع وحده غير كافٍ. هنا يبرز دور أنظمة كشف سوء السلوك (Misbehavior Detection Schemes - MBDS) ، التي تحلل محتوى الرسائل لرصد أي سلوك غير طبيعي.

اعتمدت معظم أنظمة الكشف عن سوء السلوك على قيام العقدة بعدة فحوصات منها فحوصات المعقولة التي تختبر هل قيم الرسالة الواردة ضمن حدود المعقولة أو لا، حيث يتم تطبيق فحوصات المعقولة على رسالة beacon واحدة على خلاف فحوصات التطابق والتي تستدعي تقييم القيم على رسالتين beacons الحالية والسابقة وذلك لمعرفة هل حدث اختلاف أم لا في القيم، وتعتبر خوارزمية العتبة Threshold Algorithm [22] من أولى الخوارزميات التي اعتمدت على هذه فحوصات وتعتبر الخوارزمية أن فشل إحدى هذه الفحوصات يشير إلى أن رسالة سيئة السلوك، لكن في الحقيقة ليس من الضروري أن يكون الفشل إحدى الفحوصات مؤشر لوجود سلوك سيء. لذلك اقترحت خوارزمية القيم التجمعية أن يتم تجميع القيم لكل فص في سجل متضمن n قيمة لكل فص ومن ثم يحسب متوسط حسابي لهم، ثم مقارنة النتيجة مع عتبة ثابتة في حال كانت أقل من العتبة، يتم اعتبار الرسالة سيئة السلوك. على الرغم من فعالية هذه الخوارزمية إلا أنها ستفشل في بداية المحاكاة والسبب يعود إلى أنها ستبقى قيمة القيمة المجمعة

لكل فص أقل من العتبة حتى يمتلئ السجل أو قد تغادر العربة المرسله مجال تغطية العربة المستقبلية قبل امتلاء السجل بالقيم . استفادت خوارزمية السلوكية من فحوصات المعقولية والتطابق من أجل مراقبة سلوك العربة عن طريق اعطاؤها مهلة زمنية , في حال تجاوزت المهلة ومازال سلوكها سيء , تعتبرها عربة مهاجم , على رغم من أن آلية عمل الخوارزمية تعتبر جيدة كونها لا تحكم على الرسالة إنها قادمة من عربة مهاجمة مباشرة وإنما بعد مرور انتهاء المهلة الزمنية , لكنها غير مناسبة في شبكات VANET , كون العربة تتحرك وقد تصبح خارج منطقة تغطيتها قبل انتهاء المدة الزمنية . رغم أن الخوارزميات السابقة تملك عيوب ولكنها لا تقارن في عيوب خوارزمية التعاونية التي يعتمد قرارها على حساب ثقة الجيران وثقتها بالرسالة الواردة اليها , وخاصة عند تنفيذ هجوم Sybil, لذلك تعتبر خوارزميات التي يعتمد قرارها على نفسها أفضل . على اعتبار أن المتوسط الموزون يعطي أوزاناً لقيم معينة عن غيرها وذلك حسب أهميتها , لذلك اقترحت الدراسة [29] الاستفادة من المتوسط الموزون وتطبيقه على الفحوصات, إلا أنها تستدعي هذه الخوارزمية معرفة مسبقة بنوع الهجوم المقام ليتم زيادة وزن الفحوصات و يتم حساب متوسط الموزون لفحوصات الهجوم المتوقع فقط ومن ثم مقارنة القيمة النهائية للمتوسط الموزون بعتبة ثابتة بغض النظر عن بقية الفحوصات , استفادت الدراسة [28] من المبدأ المعتمد في الدراسة السابقة لكنها أدخلت المتوسط الموزون في معادلة تعزز أو تخفض قيمة الثقة تدريجياً , لكن أيضاً ارتبطت الثقة بنوع الهجوم المتوقع دون الأخذ بعين الاعتبار بقية الفحوصات. لذلك تم اقتراح خوارزمية تربط بين مفهوم الأوزان الديناميكية للفحوصات ومعادلة الثقة من خلال منح كل فص وزناً متغيراً يتأثر مباشرة بالقيمة التي ينتجها الفص نفسه, دون ربط مسبق بنوع معين من الهجوم. هذا التكيف الديناميكي يسمح بتحسين دقة التصنيف والتعامل بمرونة أكبر مع سيناريوهات الهجومات المتغيرة. لقد حققت الخوارزمية المقترحة قدرة على تصنيف رسائل الهجوم بشكل صحيح بنسبة ٣٥.١٨% مقارنة مع خوارزميات العتبة و السلوكية والقيم التجمعية وتعاونية وخوارزمية الثقة القائمة المتوسط الموزون للهجوم , بالإضافة إلى تحقيق نسبة أقل من Negative False والتي تشير إلى عدد الرسائل الهجومية التي لم تكتشف بنسبة ١٤.٤١% مقارنة ببقية الخوارزميات , كانت سريعة في الاكتشاف بمتوسط زمني قدره ٠.١٣ ثانية مقارنة ببقية الخوارزميات, لكنها عانت من نسبة عالية من الإنذارات الكاذبة بنسبة ٣٥.٧٠% والسبب في ذلك الى أن وجود فحص واحد فقط قيمته منخفضة بشكل دائم سيرتفع وزنه وبالتالي زيادة المتوسط الموزون وانخفاض الثقة اتجاه اعتبار أن الرسالة رسالة هجومية حتى لو كانت بقية الفحوصات سليمة .

## 2-هدف البحث

هدف هذا البحث إلى تحليل أداء الخوارزمية المقترحة ضد هجوم Data Replay Sybil وذلك في حال تم أخذ قيمتين للمجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ ٤٢٠ متر و ٦٠٠ متر ومقارنة أدائها مع الخوارزميات السابقة .

## 3- طرائق البحث و مواد

تم إجراء المحاكاة باستخدام إطار VEINS , وهو إطار متكامل لمحاكاة الاتصالات بين العربات, يعتمد على نموذج محاكاة ثنائي التفاعل يجمع بين محاكي الشبكات القائم على الأحداث (Objective Modular Network Testbed in C++) (OMNeT++) (Simulation of Urban Mobility) (SUMO) ومحاكي حركة المرور (Mobility) وتم اختيار VEINS نظراً لقدرة على محاكاة الطبقات الكاملة لشبكات الاتصال ١١.٢٠٠٨ p و (IEEE 1609.4 (DSRC/WAVE).

### ١-٣ أنواع المهاجمين في شبكات VANET [28]

في شبكات العربات المتنقلة (VANET)، تختلف أنواع المهاجمين حسب موقعهم في الشبكة وطبيعة نشاطهم، مما يؤثر على قدرتهم في تنفيذ أنواع الهجمات المختلفة. يمكن تصنيف المهاجمين إلى:

- المهاجم الداخلي (Internal Attacker): عضو مصادق داخل الشبكة، يملك صلاحيات وإمكانات تمكنه من إرسال وتعديل الرسائل، مما يجعله قادراً على تنفيذ هجمات معقدة تشمل تزوير الهوية والبيانات والتشويش على القناة.

- المهاجم الخارجي External Attacker: كيان خارج النظام، يعمل كمراقب أو متطفل يحاول التشويش أو اعتراض الرسائل، لكنه محدود في قدرته على تعديل البيانات أو انتحال الهوية.

- المهاجم النشط Active Attacker: يشارك بشكل مباشر في الشبكة عن طريق إرسال رسائل مزورة أو تعديل الرسائل الأصلية أو حقن رسائل خبيثة، مما يشكل تهديداً مباشراً.

- المهاجم السلبي Passive Attacker: يقتصر دوره على التنصت على الاتصالات دون تعديل أو التفاعل مع البيانات.

- المهاجم المحلي Local Attacker: ينفذ هجمات في نطاق جغرافي محدود أو ضمن مجموعة عربات محددة.

- المهاجم العام Global Attacker: يمتلك نطاق تغطية واسع، قادر على مراقبة أو مهاجمة الشبكة عبر مناطق متعددة.

- تختلف قدرة كل نوع من المهاجمين على تنفيذ الهجمات حسب هدف الهجوم، ويوضح الجدول (١) أبرز هذه الهجمات:

- الهجمات على قناة الاتصال Channel-based Attacks: يمكن للمهاجمين الداخليين والخارجيين النشطين تنفيذ هجمات إغراق القناة أو التشويش عليها، بينما المهاجم السلبي يقتصر على المراقبة فقط. وتكون هذه الهجمات ممكنة على نطاق محلي أو عام.

- الهجمات على البيانات Data-based Attacks: تنفذ عادة بواسطة مهاجمين داخليين ونشطين قادرين على تزوير أو تعديل الرسائل مثل الموقع والسرعة. المهاجم الخارجي لا يملك عادة صلاحية تعديل البيانات، والمهاجم السلبي يراقب فقط.

- الهجمات على الهوية Identity-based Attacks: غالباً ما يقوم بها مهاجمون داخليون ونشيطون يمتلكون صلاحيات انتحال هويات متعددة. المهاجمون الخارجيون يواجهون صعوبة في انتحال الهوية بسبب عدم امتلاكهم هوية معتمدة. المهاجم السلبي غير قادر على تنفيذ هجمات الهوية.

الجدول (١) تصنيف هجمات شبكات VANET وأنواعها

وصف الهجوم	اسم الهجوم	تصنيف الهجوم
يغمر القناة اللاسلكية برسائل متكررة لتعطيل الاتصال.	DoS Attack	Channel-based
يرسل محتوى عشوائي في فواصل زمنية عشوائية لتشويش الشبكة.	DoS Random	
يعيد المهاجم بث رسائل من جيران عشوائيين بتردد عالٍ	Disruptive DoS	

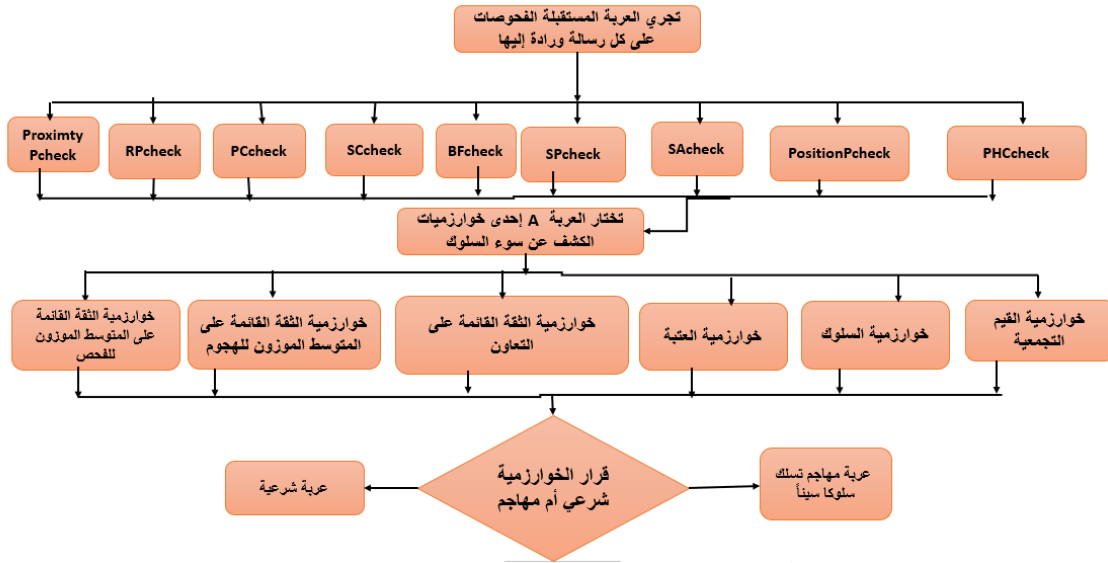
يتم إرسال رسائل تحتوي على قيم عشوائية بتردد مرتفع باستخدام هويات مزيفة مختلفة في كل رسالة.	DoSRandomSybil	Channel + Identity
يتم بث رسائل تم استقبالها من جيران مختلفين باستخدام اسم مستعار جديد لكل رسالة	DoSDisruptiveSybil	
يقوم المهاجم بإعادة إرسال الرسائل المستلمة من جار مستهدف معين، بعد توقيعها بشهادته الخاصة	Data Replay	
يعيد المهاجم بث الرسائل التي تم استقبالها من جيران مختلفين	Disruptive Attack	
يتصرف المهاجم في البداية كعربة طبيعية، ثم يبدأ ببث موضع ثابت وسرعة صفرية وكأنه توقف فعلياً في مكان ما.	Eventual Stop Attack	Data-based
ينشئ المهاجم ازدحاماً غير واقعي عن طريق توليد عربات وهمية بمعدّات مزيفة تبث رسائل معقولة بتردد طبيعي من موقع محدد	Traffic Congestion Sybil	Identity-based
يعيد المهاجم بث رسائل مستلمة من جار معين باستخدام عقدة سبيل	DataReplaySybil	Identity + Data

### ٣-١-١ نموذج المهاجم ضمن العمل

يعد المهاجم الداخلي من أخطر التهديدات الأمنية في شبكات العربات الذكية (VANET)، نظراً لامتلاكه شهادات رقمية وأسماء مستعاراً سليمة تخوله التصرف كعربة شرعية داخل الشبكة. وبفضل هذه الامتيازات، يمكنه إرسال بيانات مزيفة أو التلاعب بعربات أخرى لتنفيذ هجماته، مما يصعب اكتشافه بالاعتماد على تقنيات المصادقة التقليدية فقط. ومن أبرز هذه الهجمات هجوم Data Replay [27][23] Sybil، الذي يصف كهجوم مركب يجمع بين إعادة بث رسائل حقيقية تم التقاطها سابقاً، واستعمال هويات مزيفة متعددة لإيهام النظام بوجود عدة عربات. يهدف هذا الهجوم إلى خلق صورة زائفة لحالة المرور، مما قد يؤدي إلى قرارات خاطئة مثل تغيير المسار أو تقليل السرعة بشكل غير مبرر. ونتيجة لذلك، يعد هذا الهجوم تهديداً مباشراً للسلامة العامة ويقلل من فعالية أنظمة كشف السلوكيات الشاذة في الشبكة.

### ٣-٢ خوارزميات الكشف عن سوء السلوك

يظهر الشكل (١) المنهجية العامة المستخدمة في الكشف عن سوء السلوك في شبكات VANET والمعتمدة على فحوصات المعقولة والمتطابق، حيث تجري كل عربة مستقبلة الفحوصات على كل رسالة تصلها وتدخل نتائج الفحوصات التي تكون عبارة عن قيم تتراوح بين الصفر والواحد، إلى خوارزميات الكشف المستخدمة، حسب آلية عمل كل خوارزمية يتم اتخاذ القرار بسوء سلوك أو لا. علماً أن نتيجة الفحص كلما اقتربت من الصفر تشير إلى فشل الفحص وكلما اقتربت من الواحد، يعتبر الفحص ناجحاً [22]. تقوم العربة المستقبلة بتشغيل إحدى خوارزميات الكشف المبرمجة ضمنها وفق ما يحدده ملف التشغيل .omnet.ini



الشكل (1) آلية اكتشاف سوء السلوك في VANET

### 3-2-1 خوارزمية القيم التجميعية Aggregated Values Algorithm [22]

تقوم العربة بحساب قيمة مجمعة لكل فص بناء على سجلات الفحوصات السابقة والقيمة الحديثة. تقارن القيمة المجمعة بالعتبة المحددة لاتخاذ قرار حول مصداقية الرسالة وفق المعادلة التالية :

$$IF V_{aggi} = \frac{\sum_i^n V_i + V_{curr_i}}{n + 1} < Threshold \rightarrow Misbehavior \quad (1)$$

حيث إن:  $V_{aggi}$ : القيمة المجمعة للفص الناتجة عن التحديث،  $V_{curr_i}$ : القيمة الحالية للفص أ. تعتمد هذه الخوارزمية بشكل أساسي على أن فشل إحدى الفحوصات المجمعة هو احتمال إلى وجود سوء سلوك.

### 3-2-2 خوارزمية الكشف السلوكي Behavior Algorithm [22]

تستخدم مهلة الانتظار الزمنية (Timeout Misbehavior Observation-TMO) كأداة رئيسية لمراقبة سلوك كل عربة في الشبكة. يتم حساب عامل الثقة الأدنى (minFactor) الذي يعكس موثوقية رسالة العقدة، ثم يتم تحديث قيمة TMO الخاصة بالعقدة تدريجياً وفق المعادلة (2) مع كل رسالة يتم استقبالها، حيث تكون قيمتها في البداية هي صفر :

$$TMO_i = TMO_i + TMO_{add} \quad (2) \text{ where } TMO_{add} = \alpha e^{\beta(1-minFactor)}$$

ثم تقارن القيمة  $TMO_i$  مع عتبة ثابتة، في حال تجاوز العتبة، يتم اعتبار العربة مشبوهة و يتم تفعيل الإبلاغ عنها. حيث إن  $\alpha$ : تمثل معامل ثابت يمثل القيمة الأساسية للإضافة الزمنية،  $\beta$  معامل التضخيم الأسّي، وبالتالي الهدف من التحديث التدريجي هو تراكم الشك تجاه العربة.

### 3-2-3 خوارزمية العتبة Threshold Algorithm [22]

تصف خوارزمية العتبة العربة كمهاجم إذا فشلت أي فصر بفض النظر عن نجاح بقية الفحوصات وكانت نتيجة الفص  $C_i$  أقل من العتبة المحددة  $\theta$  وفق العلاقة (3):

$$\text{For } C_i < \text{Threshold } \text{Misbehavior } \{ \text{where } C_i \in \{C_1, C_2, \dots\} \} \quad (3)$$

### [22] Cooperative Algorithm ٤-٢-٣ خوارزمية القائمة على الثقة التعاونية

تدمج الثقة المحسوبة ذاتيا والثقة المستلمة من الجيران لتقدير موثوقية العقدة كما هو واضح بالمعادلتين (٤) (٥). إذا كانت الثقة أقل من الحد المسموح به، تصف العربة كمشبوهة ويتم الإبلاغ عنها.

$$\text{Trust level}_{\text{now}} = - \frac{e^{(10(1-C_{\min}))} + 1}{2 * 10^4} \quad (4)$$

$$\text{Trust level} = \text{Trust level}_{\text{now}} + \text{Trust level}_{\text{neighbors}} < \theta \text{ Misbehavior} \quad (5)$$

حيث إن  $C_{\min}$  تمثل قيمة أصغر فص من بين مجموعة الفحوصات التي تجريها العربة.

### ٥-٢-٣ خوارزمية الثقة القائمة على المتوسط الموزون للهجوم: Trust weighted attack

[28]

تطبق فحوص متعددة على كل رسالة، وتحسب الثقة باستخدام متوسط موزون، حيث يعطى كل فص وزناً مختلفاً حسب نوع الهجوم المكتشف. تم الاستفادة من الدراسة المرجعية [29] في توزيع الوزن وفق هجوم المقام وإدخال المتوسط الموزون الناتج إلى معادلة الثقة. يتم حساب مستوى الثقة بالمعادلة (٧) مستخدماً معادلة متوسط الموزون للهجوم (٦):

$$\text{Weight Average} = \frac{\sum_{i=1}^n w_i * x_i}{\sum_{i=1}^n w_i} \quad (6)$$

حيث إن  $x_i$ : قيمة الفص  $i$ ،  $w_i$ : وزن الفص  $i$  حسب الهجوم المقام.

$$\text{Trust level} = - \frac{e^{(10(1-\text{Weight Average}_{\text{attack}}))} + 1}{2 * 10^4} < \theta \text{ Misbehavior} \quad (7)$$

### ٦-٢-٣ خوارزمية الثقة القائمة على المتوسط الموزون للفحص المقترحة: Trust weighted

Check

الخوارزمية المقدمه هي جزء من نظام كشف سوء السلوك في شبكات العربات الذكية (VANETs) باستخدام آلية غير تعاونية تعتمد على فحوصات متعددة وأوزان ديناميكية لتقييم موثوقية الرسائل المستلمة من العربات الأخرى. تبدأ الخوارزمية بتجميع نتائج الفحوصات (مثل تقارب الموقع، اتساق السرعة، كشف التوقف المفاجئ) لكل رسالة BSM واردة. يتم تمثيل نتيجة كل فص بالمتغير  $C_i \in [0, 1]$  والتي تعكس درجة مصداقية الرسالة حسب ذلك الفص، كما تم تخصيص وزن ديناميكي لكل فص يرمز له بـ  $w_i \in [0, 1]$ . يحسب المتوسط الموزون لجميع الفحوصات باستخدام المعادلة (٦). تعدل الأوزان المرتبطة بالفحوصات اعتماداً على فعاليتها في كشف حالات سوء السلوك كما في العلاقة (٨)؛ فإذا أسفر الفحص عن نتائج منخفضة، مما يشير إلى دوره في الكشف، يعزز وزنه. أما إذا كانت نتائجه مرتفعة باستمرار، فيخفض وزنه نظراً لضعف مساهمته في عملية الكشف.

$$\text{if } \left\{ \begin{array}{l} C_i \leq \theta_{\text{low}} \quad w_i \rightarrow w_i + \Delta w \\ C_i > \theta_{\text{high}} \quad w_i \rightarrow w_i - \delta w \end{array} \right\} \text{ where } \theta_{\text{low}} = 0.5, \theta_{\text{high}} = 0.8, \Delta w = 0.05, \delta w = 0.02 \quad (8)$$

حيث إن  $\Delta w$  تمثل قيمة زيادة الوزن، بينما  $\delta w$  قيمة خض الوزن، و  $\theta_{\text{high}}$  و  $\theta_{\text{low}}$  هما حدود لتقييم الفحص. ثم تحسب معادلة الثقة وفق العلاقة (٩)، وإذا كان مستوى الثقة أقل من عتبة محددة (Threshold)، تعتبر العربة عربية مهاجم. تم اعتماد التقييم السابقة وفقاً للتجربة.

$$\text{Trust level} = - \frac{e^{(10(1-\text{Weight Average}_{check}) + 1)}{2 * 10^4} < \theta \quad \text{Misbehavior} \quad (9)$$

علماً أن الفرق بين خوارزمية الثقة القائمة على متوسط الموزون للفصو وبين المعتمدة على متوسط الموزون للهجوم، كلاهما يستخدم المتوسط الموزون وادخال قيمته إلى معادلة الثقة، لكن الخوارزمية المقترحة تعدل الأوزان ديناميكياً بناءً على أداء كل فص بمرور الوقت وليست بحاجة لمعرفة نوع الهجوم، بينما خوارزمية الثقة القائمة على المتوسط الموزون للهجوم تستخدم أوزاناً ثابتاً محددة مسبقاً حسب نوع الهجوم المتوقع مما يجعلها أقل تكيفاً.

### 3-3 اختبارات المعقولة والتطابق [11]:

تقوم كل عربة عند استقبال رسالة Beacon بإجراء سلسلة من فحوصات المعقولة والتطابق للتحقق مما إذا كانت الرسالة الواردة تعكس سلوكاً سليماً أم سلوكاً سيئاً. في إطار دراسة هجوم Data Replay Sybil، تم التركيز بشكل خاص على فحسي معقولة المجال الأعظمي والظهور المفاجئ، نظراً لتأثيرهما المباشر على اكتشاف هذا النوع من الهجمات. يوضح الجدول (2) البارامترات الخارجية التي تؤثر على نتائج الفحوصات، والتي بدورها تلعب دوراً حاسماً في دقة اتخاذ القرار من قبل خوارزميات الكثف، اعتماداً على نوع الهجوم المحتمل [29] كما هو موضح في الجدول (3).

الجدول (2) البارامترات الثابتة المؤثرة على نتيجة الفحص

الفحص	الاختصار	البارامترات التي تؤثر على الفحص	دلالة البارامتر
فحص معقولة التقارب <i>Proximity Plausibility Check</i>	Proximity Pcheck	MAX_PROXIMITY_RANGE_L	تشير إلى المسافة القصوى في الاتجاه الطولي.
		MAX_PROXIMITY_RANGE_W	تشير إلى المسافة القصوى في الاتجاه العرض
		MAX_PROXIMITY_DISTANCE	تشير إلى المسافة القصوى التي يمكن أن يتفاعل فيها كائنين أو أكثر في النظام
فحص معقولة المجال <i>Range Plausibility Check</i>	RPcheck	MAX_PLAUSIBLE_RANGE	تشير إلى مجال التغطية الأعظمي المعقول
فحص تطابق الموقع <i>Position Consistency Check</i>	PCcheck	MAX_PLAUSIBLE_SPEED	تشير إلى السرعة القصوى المعقولة والمسموح بها على الطريق.

			العربة المرسله السابق والحالي , في حال كانت المسافة أقل من جداء السرعة القصوى المعقولة في الزمن , فموقع العربة منطقي و العربة تتحرك بشكل منطقي.
التسارع الاعظمي المعقول المسموح به	MAX_PLAUSIBLE_ACCEL	SCcheck	فحص تطابق السرعة <b>Speed Consistency Check</b> يتحقق من أن السرعة متطابقة وغير متغيرة بشكل غير منطقي.
التباطؤ الأعظمي المعقول المسموح به.	MAX_PLAUSIBLE_DECEL		
تشير الى السرعة القصوى المعقولة والمسموح بها على الطريق.	MAX_PLAUSIBLE_SPEED	SPcheck	فحص معقولية السرعة <b>Speed Plausibility Check</b> تحقق من أن السرعة المعلنة لا تتجاوز حدود السرعة الفيزيائية الممكنة.
مجال الظهور المفاجئ الاعظمي.	MAX_SA_RANGE	SAcheck	فحص الظهور المفاجئ <b>Sudden Appearance Check</b> يكشف عن العربات التي تظهر فجأة في النطاق دون اشعار سابق بوجودها داخل مجال التغطية للعربة.
الحد الأقصى للسرعة التي يمكن اعتبارها معقولة إذا كانت العربة خارج المسار المحدد	MAX_NON_ROUTE_SPEED	PositionPcheck	فحص معقولية الموقع <b>Position Plausibility Check</b> يتحقق من أن الموقع المعلن يتوافق مع الواقع ولا يحتوي على قفزات غير منطقية
حد أقصى لمسافة يمكن اعتبار العربة عندها قريبة بما يكفي من المسار المتوقع	MAX_DISTANCE_FROM_ROUTE		

تردد Beacon الأعظمي المسموح به	MAX_BEACON_FREQUENCY	BFcheck	فحص تردد beacon <i>Beacon Frequency Check</i> تحقق من أن العربة ترسل رسائل Beacon بتردد مقبول وغير مفرط.
الزمن المسموح به لتغيير اتجاه العربة.	POS_HEADING_TIME	PHCcheck	فحص تطابق اتجاه الموقع <i>Position Heading Consistency Check</i> يتحقق من تطابق اتجاه الحركة مع تغيير الموقع الفعلي للعربة
زاوية تغيير الاتجاه الأعظمي المسموح بها.	MAX_HEADING_CHANGE		

يوضح الجدول (٣) الفحوصات التي تكشف الهجوم [23]

الفحوصات التي تكشف الهجوم	الهجوم
فحص تطابق الموقع وتردد رسالة Beacon	DoS, DoS Random Attack
فحص معقولية السرعة و معقولية المجال الأعظمي وفحص الظهور المفاجئ	DoS Random Sybil Attack
فحص معقولية الموقع	Disruptive Attack
فحص تطابق الموقع و فحص التقاطع و تردد رسالة beacon	Dos Disruptive Attack
معقولية الموقع و فحص التقاطع	Data Replay
معقولية السرعة و معقولية المجال الأعظمي والظهور المفاجئ و فحص التقاطع.	Data Replay Sybil, Dos Disruptive Sybil Attack
فحص الظهور المفاجئ و فحص معقولية التقارب	Eventual Stop
معقولية الموقع و معقولية السرعة و فحص التقاطع	Traffic Congestion Sybil

أن هذه البارامترات تأخذ قيم ثابتة في ملف التشغيل omnet.ini، لكن لم يتم دراسة فعالية هذه القيم ومدى تأثيرها على دقة الكشف، تمت دراسة تأثير مجال الأعظمي المعقول ومجال الظهور المفاجئ على أداء الخوارزميات في هذه الدراسة بحالة تنفيذ هجوم Data Replay Sybil.

٣-٤ مقاييس الكشف: [22][29][28][23]

٣-٤-١ التأخير المطلق لكل هجوم (Absolute Latency Per Attack)

هو الزمن المستغرق من لحظة بداية الهجوم (أو لحظة رصده/إرساله) حتى لحظة اكتشافه أو الاستجابة له. تعطى علاقته كما في معادلة (١٠):

$$= \frac{\text{Absolute Latency Per Attack} * \text{reportAttackerNum} + \text{deltaTime}}{\text{reportAttackerNum} + 1} \quad (10)$$

يمثل attackerAverageReportDelay المتوسط الحالي لزمان الإبلاغ عن الهجوم. حيث يدل reportAttackerNum على عدد المهاجمين الذين تم الإبلاغ عنهم حتى الآن، بينما deltaTime هو الزمن الجديد الذي يضاف، وهو الوقت المستغرق للإبلاغ عن هجوم جديد. تعتبر خوارزمية الكنف فعالة عندما يكون الزمن الكلي للاستجابة للهجوم (Absolute Latency Attack) منخفضاً، مما يدل على سرعة الكشف، وتتأثر هذه القيمة بنوع الهجوم وكفاءة الخوارزمية.

### ٣-٤-٣ F1-Scor

هو المتوسط التوافقي للPrecision، Recall، يمكن استخدامه كمقياس واحد لتقييم أداء النظام، حيث تعطى نفس الأهمية للPrecision، Recall.

$$F1 - Score = 2 * \frac{Recall * Precision}{Recall + Precision} \quad (11)$$

### ٣-٤-٣ الانتروبيا

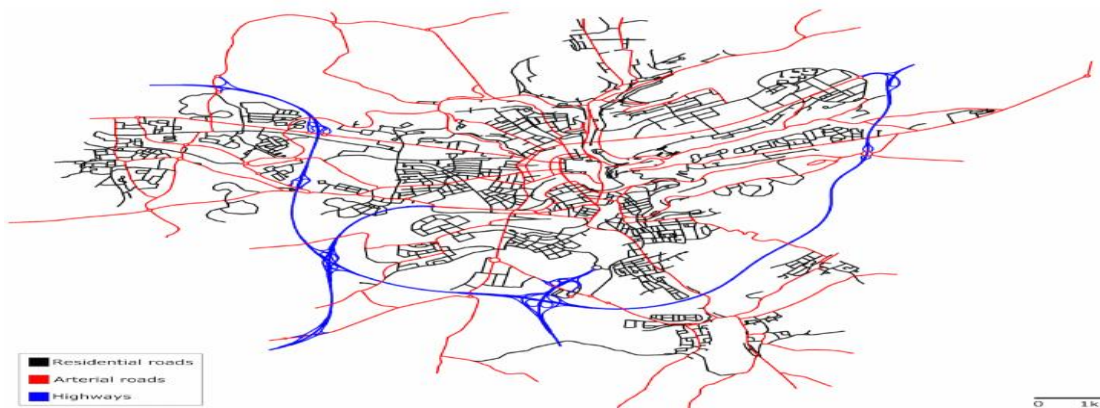
لفهم مقدار الشك (Entropy) لدى الخوارزمية في تصنيف العربات (هل هي شرعية أم مهاجمة)، نستخدم مفهوم الانتروبيا من نظرية المعلومات، والتي تحسب على الشكل التالي:

$$H = -P_1 \log_2(P_1) - P_2 \log_2(P_2) \quad (12)$$

حيث تمثل  $P_1$ : نسبة العربات التي تم الإبلاغ عنها على أنها شرعية إلى إجمالي العربات،  $P_2$ : نسبة العربات التي تم الإبلاغ عنها على أنها مهاجم إلى إجمالي العربات. تمثل قيمة الإنتروبيا درجة العشوائية أو الارتباك في عملية التصنيف، فكلما كانت القيمة أكبر، دل ذلك على وجود شك عالي في تمييز العربات الشرعية من المهاجمة، مما يشير إلى أداء تصنيف أقل دقة. أما القيم الأقل من الإنتروبيا فتدل على ثبات ودقة أعلى في التصنيف، مما يعكس وضوحاً أكبر في تمييز الفئات.

### ٣-٥ النتائج والمناقشة

من أجل اختبار أداء الخوارزميات السابقة في الزمن الحقيقي، تم اختيار إحدى المدن التي توفر معلومات مرورية مباشرة، إضافة لتحقيق درجة التعقيد والمحاكاة الحقيقية للأداء وبناء عليه تم تحميل مدينة لوكسمبورغ على محاكي Sumo [12]، باستخدام بارامترات المحاكاة الموضحة في الجدول (٤). تم اختيار كثافة الهجوم بحدود ٥٠٪ من مجمل الاتصالات الموجودة في الشبكة خلال مدة المحاكاة ٤ ساعات بحيث تشمل التوقيت بين الساعة ٨ صباحاً وحتى ١٢ ظهراً، حيث تحاكي كثافة مرورية عالية إلى متوسطة تقريبا خلال هذه الفترة.



الشكل (٢) محاكاة لوكمبيوترغ [12]

الجدول(٤) بارامترات المحاكاة المستخدمة في OMNET

Module	Parameter	Value
Veins	Transmission Power	20mW
	Bit Rate	6Mbps
	Packet Header length	80bit
	Beacon Payload length	100 byte
	Beacon rate	1 HZ
Attacks Parameters	كثافة الهجوم	50%
Detection Parameters	MAX_PLAUSIBLE_RANGE	600.420 m
	MAX-sudden-RANGE	600,420 m

يجب أن يكون مجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ متساويين القيمة ، وذلك لأنه إذا كان مجال الظهور المفاجئ أكبر من المجال الأعظمي المعقول للتغطية، ستفرض الرسائل الشرعية لأنها تبدو وكأنها جاءت من بعيد رغم أنها ضمن مجال الظهور المفاجئ .

تمت محاكاة جميع الخوارزميات التي تم طرحها في الفقرة (٣-٢) ومقارنتها بالخوارزمية المقترحة. تمت المحاكاة بالزمن الحقيقي , لذلك تم أخذ قيم متوسط حسابي لكل من الاندرو بيا و F1-Score وزمن اكتشاف الهجوم. يوضح الجدول (٥) نتائج المحاكاة للخوارزميات المدروسة .

الجدول (٥) نتائج المحاكاة للخوارزميات المدروسة .

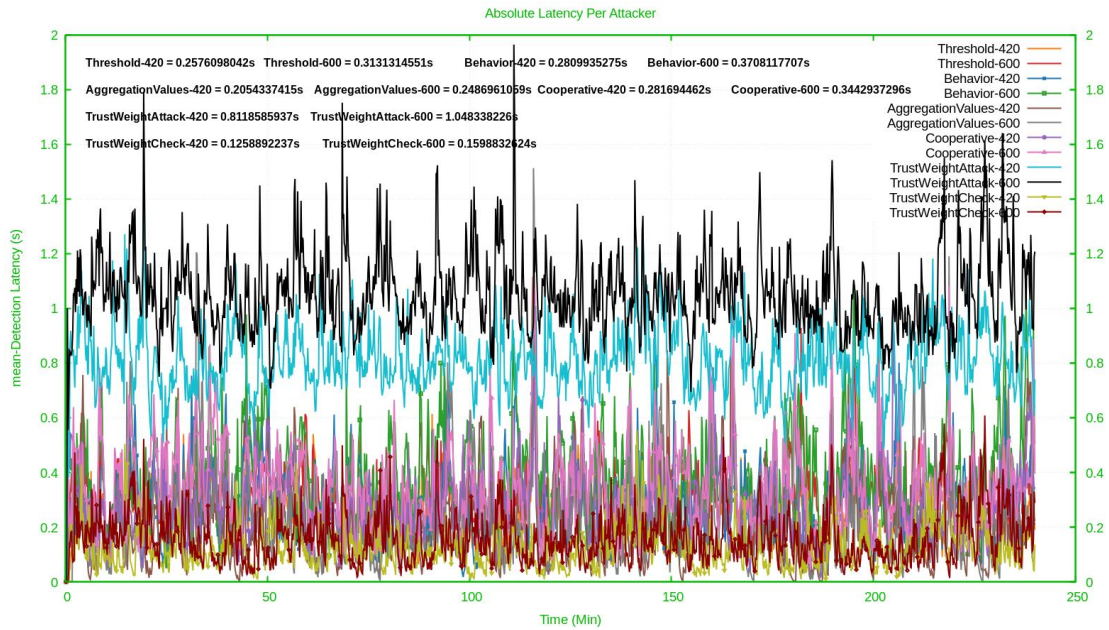
Algorithm	FP%	TN%	TP%	FN%	Average Entropy	Average F1-Score	Average Detection Latency (s)
Threshold_420	0.52	٤٩,٨٨	١٤,٧٢	٣٤,٨٨	٠,٨٩	٠,٤٦	٠,٢٦
Threshold_600	٠,٤٩	٤٩,٩١	١٢,٥٤	٣٧,٠٦	٠,٩٣	٠,٤١	٠,٣١
Behavior_420	١,٩٨	٤٨,٤٢	١٠,١٤	٣٩,٤٧	٠,٨٥	٠,٣٣	٠,٢٨
Behavior_600	١,٦٤	٤٨,٧٨	٧,٨٤	٤١,٧٤	٠,٩١	٠,٢٧	٠,٣٧
AggerationValues_420	٠,٠٩	٥٠,٣	١٢,١٨	٣٧,٤١	٠,٥٣	٠,٤١	٠,٢١
AggerationValues_600	٠,٠٧	٥٠,٣٣	٩,٨٤	٣٩,٧٥	٠,٥٧	٠,٣٤	٠,٢٥
Cooperative_420	٧,٩٣	٤٢,٤٧	٢١,٢٨	٢٨,٣١	٠,٨٦	٠,٥٥	٠,٢٨
Cooperative_600	٧,٤١	٤٣	١٧,٦٧	٣١,٩٢	٠,٩١	٠,٤٨	٠,٣٤
TrustWeightAttack_420	٣٤,١	١٦,٢٤	١٧,٤٧	٣٢,١١	٠,٨٧	٠,٣٤	٠,٨١
TrustWeightAttack_600	٢٩,٦ ١	٢٠,٧٨	١٣,٣٨	٣٦,٢١	٠,٧٨	٠,٢٩	١

TrustWeightCheck_420 المقترحة	٣٥,٧ ٠	١٤,٧٠	٣٥,١ ٨	١٤,٤ ١	٠,٩٧	٠,٥٨	٠,١٣
TrustWeightCheck_600 المقترحة	٣١,٠ ٧	١٩,٣٤	٣٠,٨٢	١٨,٧٧	٠,٩٦	٠,٥٥	٠,١٦

يوضح الشكل (٣) زمن اكتشاف الهجوم لكل خوارزمية مدروسة؛ حيث يمثل المحور الأفقي (X) الزمن، بينما يمثل المحور العمودي (Y) زمن اكتشاف الهجوم، كلما اقتربت قيمة زمن الاكتشاف من الصفر، كانت الخوارزمية أسرع في اكتشاف الهجوم. تم رسم هذا المخطط باستخدام بيانات من الزمن الحقيقي، مع احتساب المتوسط الحسابي لتقييم كل خوارزمية خلال فترة المحاكاة. تشير النتائج إلى أن زيادة المجال الأقصى المقبول للتغطية أو لمجال الظهور المفاجئ تؤدي إلى زيادة في زمن اكتشاف الهجوم، نتيجة تزايد عدد الرسائل المستلمة عند مسافة ٦٠٠ متر مقارنة بـ ٤٢٠ متر. كما يظهر في الشكل، جميع الخوارزميات تظهر تنديباً في زمن الاكتشاف، ويعزى ذلك إلى طبيعة شبكة VANET الديناميكية، حيث قد تصف الخوارزمية رسالة معينة على أنها صادرة من عربة شرعية في لحظة معينة، ثم تكتشف بعد فترة أن الرسالة التالية من نفس العربة تحتوي سلوكاً هجومياً، مما يرفع زمن الاكتشاف.

وقد عانت خوارزمية الثقة القائمة على المتوسط الموزون للهجوم TrustWeightAttack، من تأخير مرتفع للكشف عن الهجوم في حالتي ٤٢٠ متر و ٦٠٠ متر، نظراً لاعتمادها على تحديد نوع الهجوم أولاً ثم تعيين الأوزان المناسبة. أما خوارزميتي Behavior و Cooperative، فقد أظهرتا زمن اكتشاف متقارب عند مجال ٤٢٠ متر، وذلك بسبب إعطاء خوارزمية Behavior مهلة للعربة لتحديد سلوكها، بينما تعتمد الخوارزمية التعاونية على تقييم ثقة الجوار بالإضافة إلى حساب الثقة الذاتية، مما يزيد من زمن الاكتشاف. بشكل عام، كلما زاد المجال ازداد معه زمن اكتشاف الهجوم.

تعد الخوارزمية المقترحة TrustWeightCheck الأسرع بين جميع الخوارزميات في اكتشاف الهجوم، ويعزى ذلك إلى اعتمادها على آلية ذكية لتعديل الأوزان بشكل ديناميكي وفعال.



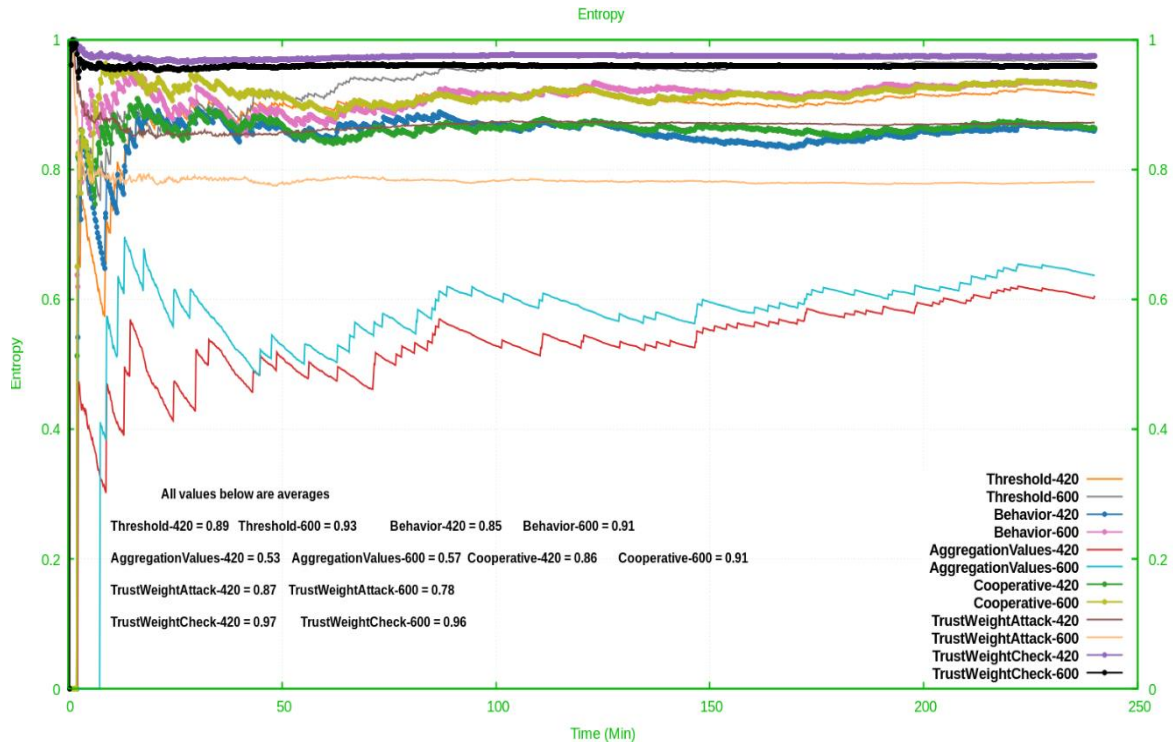
الشكل (٣) زمن اكتشاف الهجوم لخوارزميات الكشف عن سوء السلوك بحالة مجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ ٢٠٤٠ و ٦٠٠ متر

يوضح الشكل (٤) مقدار الشك الناتج عن تصنيف العربية سواء كانت شرعية أو مهاجمة للخوارزميات المدروسة خلال مدة المحاكاة.

في بداية المحاكاة، تعاني جميع الخوارزميات من مستوى مرتفع من الاندرو بيا نظراً لقلة البيانات وتضارب المؤشرات، إلا أن هذا الشك ينخفض تدريجياً مع مرور الوقت نتيجة تراكم المعلومات وتحسن عملية التقييم. مع توسع المجال الأعظمي المعقول للتغطية و مجال الظهور المفاجئ، يزداد تدفق الرسائل في الشبكة، مما يرفع مستوى الشك بالنسبة لمعظم الخوارزميات. ويستثنى من ذلك الخوارزميات المعتمدة على الأوزان، حيث تظهر سلوكاً معاكساً؛ فمع اتساع المجال، تنخفض الاندرو بيا نتيجة اعتمادها على الأوزان التي يتم تعيينها إما حسب الهجوم أو حسب قيمة الفحص. لكنها مازالت تبدي الخوارزمية المقترحة أعلى مستويات الاندرو بيا مقارنة بباقي الخوارزميات، بسبب لجوء العربية إلى الصول أولاً على ثقة من خلال اتباع سلوكاً طبيعياً في البداية وبعد مرور فترة زمنية معينة تبدأ تدريجياً ببيت سلوك سيئاً عن طريق إعادة ارسال الرسائل التي استقبلتها في الشبكة من عربات شرعية لكن بأسماء مستعارة جديدة .

تظهر خوارزمية الثقة القائمة على المتوسط الموزون للهجوم مستوى أقل من الاندرو بيا مقارنة بالخوارزمية المقترحة ، كونها تعطي أوزاناً أعلى للفحوصات التي ساهمت في كشف الهجوم، بدلاً من التعامل مع جميع الفحوصات بنفس الأهمية كما تفعل الخوارزمية المقترحة. أما الخوارزمية التعاونية، فتتأثر بدرجة ثقة الجوار في تحديد هوية العربية. ومع اتساع المجال، تزداد احتمالات تضارب الآراء بين العربات المجاورة، مما يؤدي إلى ارتفاع في مستوى الشك.

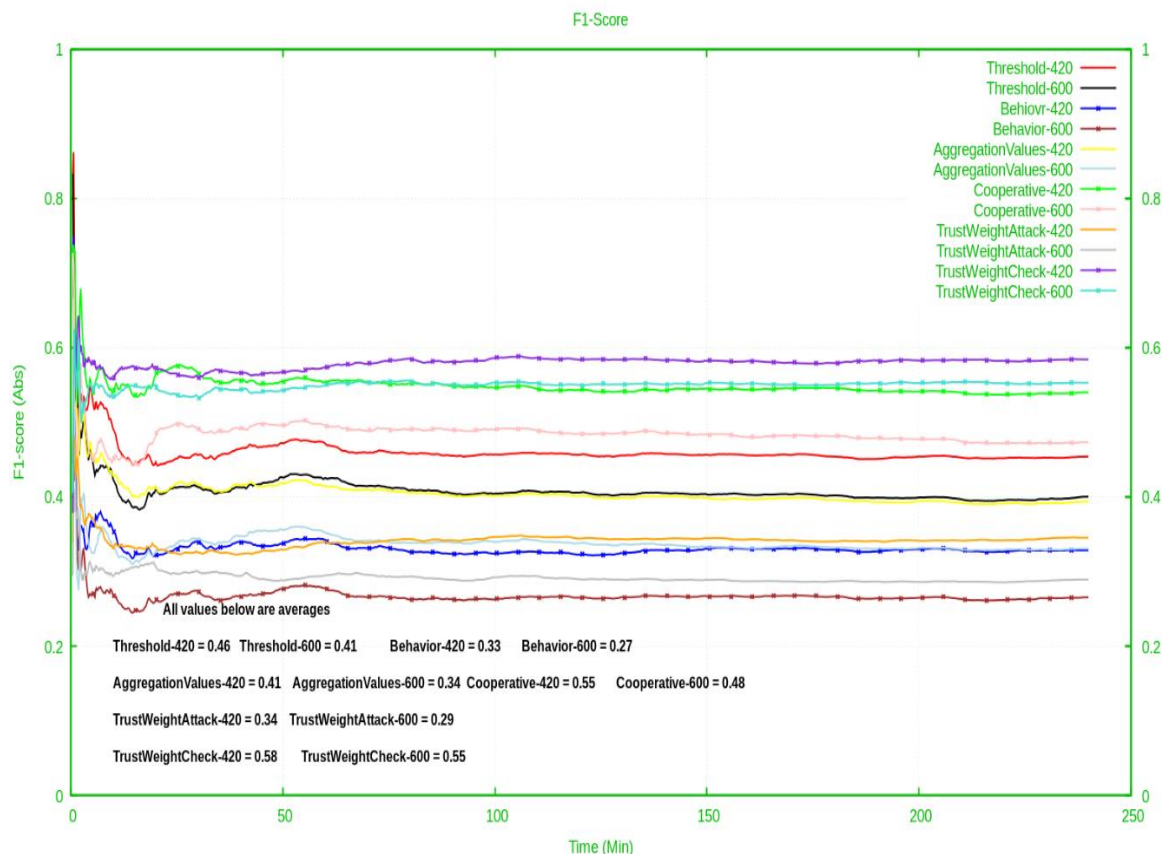
تعد خوارزمية القيم التجميعية الأقل شكاً من بين الخوارزميات، نظراً لاعتمادها على سجل ثابت للقيم الخاصة بكل فص ومقارنتها مع عتبة محددة. هذا النهج الثابت في التحليل يساعد على تقليل التذبذب وبالتالي خفض الاندرو بيا.



الشكل (٤) الانتروبيا لخوارزميات الكشف عن سوء السلوك بحالة مجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ ٢٠ و ٤٠ متر يعرض الشكل (٥) قيم مقياس F1-Score للخوارزميات المدروسة ضمن بيئة المحاكاة أثناء الزمن الحقيقي. تظهر النتائج أن جميع خوارزميات الكشف تبدأ بـ F1-Score مرتفعة في بداية المحاكاة، ثم تنخفض تدريجياً مع مرور الوقت. يعزى هذا الانخفاض إلى ازدياد تعقيد البيانات وتداخل سلوكيات العربات في بيئة VANET الديناميكية.

كما لوحظ أن F1-Score ينخفض مع زيادة كل من المجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ يعود السبب في ذلك إلى زيادة عدد الرسائل المستلمة من قبل العربة المتلقية، مما يؤدي إلى ارتفاع عدد الرسائل التي لم تصف بدقة، وبالتالي حدوث اختلال في التوازن بين مقاييسي الدقة (Precision) والاسترجاع (Recall).

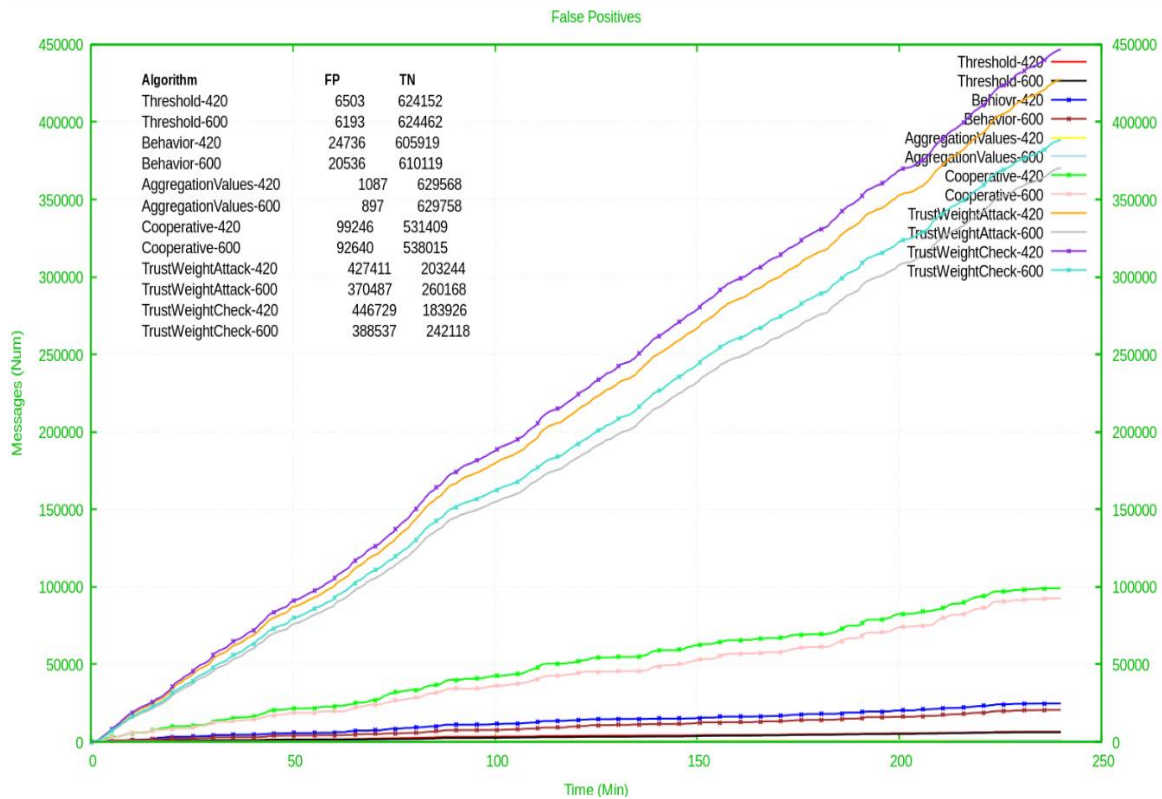
حققت الخوارزمية المقترحة TrustWeightCheck أعلى قيمة لمقياس F1-Score، مما يدل على استقرار أدائها النسبي مقارنة بالخوارزميات الأخرى. ويعزى هذا التفوق إلى اعتماد الخوارزمية على آلية ذكية في توزيع الأوزان على نتائج الفحوصات، إضافة إلى منح كل فص نفس الأهمية، دون الاعتماد على مهلة زمنية محددة، أو على نتيجة فص واحدة، أو على الجوار الذين قد يكون لبعضهم سلوك عدائي أو تصنيف هجومي خاطئ. هذا النهج يقلل من فرص إعطاء تقديرات ثقة خاطئة، مما يساهم في الحفاظ على مستوى مرتفع من F1-Score.



الشكل (٥) مقياس F1-SCOR لخوارزميات الكشف عن سوء السلوك بحالة مجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ ٢٠ و ٦٠٠ متر


يوضح الشكل (6) تطور عدد الإنذارات الكاذبة (False Positives) المكتشفة خلال الزمن الحقيقي، حيث تبدأ بقيمة صفرية ثم تزداد تدريجياً مع تقدم المحاكاة. عند زيادة كل من مجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ من 420 متر إلى 600 متر أي بزيادة قدرها نحو 42.86%، لوحظ انخفاض في معدل الإنذارات الكاذبة، حيث تراوحت نسبة الانخفاض من 0.03% في خوارزمية العتبة إلى 4.63% في الخوارزمية المقترحة TrustWeight Check.

بالمقابل، أدى هذا التوسيع في المجال إلى تحسن في معدل تصنيف الرسائل الصادرة من عربات شرعية بشكل صحيح (True Negative)، إذ زادت النسبة ما بين 0.03% لخوارزمية العتبة وحتى 4.64% للخوارزمية المقترحة. والسبب عائد إلى اعتماد الخوارزمية المقترحة TrustWeightCheck على تحديث الأوزان التراكمية لكل عربة مرسل بناء على الفحوصات المتعددة المستلمة مع مرور الوقت، بحيث يتم تقييم كل رسالة جديدة بناء على مدى توافقها مع التقييم السابقة، مما يسمح للنظام ببناء ثقة تدريجية في أن الرسائل الواردة من عربات شرعية. على العكس من ذلك، تعتمد خوارزميات أخرى مثل العتبة أو السلوكية على فحص منفرد أو مهلة زمنية أو تذبؤ نوعي للهجوم أو على التعاون فقط، مما يقلل من دقة التصنيف في تلك الحالات.



الشكل (٦) قيم FP للخوارزميات الكشف عن سوء السلوك بحالة مجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ ٤٢٠ و ٦٠٠ متر يوضح الشكل (٧) تطور قيم True Positives (TP) للخوارزميات المدروسة خلال الزمن الحقيقي، حيث تبدأ هذه القيم بالزيادة تدريجياً مع تقدم فترة المحاكاة، وهذا يعكس تحسن الخوارزميات في الكشف عن الهجمات أو السلوكيات المشبوهة بمرور الوقت. عند زيادة مجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ من ٤٢٠ متر إلى ٦٠٠ متر، لوحظ انخفاض في قيم TP بنسب تتراوح بين ٢.١٨٪ في خوارزمية العتبة وحتى ٤.٣٦٪ في الخوارزمية المقترحة TrustWeightCheck، يعود ذلك إلى أن زيادة المجال تسمح باستقبال رسائل أكثر من عربات شرعية، مما يجعل الخوارزميات أكثر تحفظاً في إطلاق الإنذارات، فيقل بذلك عدد TP بالمقابل، زادت قيم FN (عدد الرسائل الهجومية التي لم يتم اكتشافها) بنفس نسب الانخفاض في TP، وهذا متوقع لأن انخفاض TP يعني وجود المزيد من الهجمات التي لم يتم كشفها. هذا التوازن يعكس أثر تحديث الأوزان التراكمية في الخوارزمية المقترحة TrustWeightCheck. عانت الخوارزمية المقترحة TrustWeightCheck من زيادة ملحوظة في قيم TP مقارنةً ببقية الخوارزميات، السبب عائد إلى اعتمادها على قيمة كل فص، حيث استقرار الفص يجعلها تخفض وزنه و بالتالي التأثير على قيمة المتوسط الموزون ومنه التأثير على قيمة الثقة المحسوبة ومنه على القرار المتخذ بحق الرسالة ومقارنة مع العتبة التي تتخذ القرار وفق قيمة فصدون أهميته التراكمية لذلك ستزيد قيم FP لديها بشكل أعلى مقارنةً ببقية الخوارزميات، لكن خوارزمية القيم التجميعية AggerationValues رغم اعتمادها على فكرة تراكمية القيم لكل فص واتخاذ القرار وفقاً لفشل إحدى تراكميات الفحوصات إلا إنها كانت أقل خوارزمية تصنف بشكل صحيح و تعاني من عدم قدرتها على تصنيف رسائل الهجومية بنسبة عالية 39.75% مقارنةً ببقية

الخوارزميات، هذا الأمر قد يؤثر سلباً على سلامة الشبكة كونها تمرر نسبة عالية من الرسائل الهجومية وتعتبرها رسائل شرعية .



الشكل (٧) قيم TP للخوارزميات الكشف عن سوء السلوك بحالة مجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ ٢٠٤ و ٦٠٠ متر

#### ٤ - الاستنتاجات والتوصيات

تمت محاكاة أداء عدة خوارزميات تشمل: خوارزمية العتبة Threshold، الخوارزمية السلوكية Behavior، خوارزمية القيم التجميعية AggregationValues الخوارزمية التعاونية Cooperative، خوارزمية الثقة القائمة على المتوسط الموزون للهجوم TrustWeightAttack، والخوارزمية المقترحة (خوارزمية الثقة القائمة على المتوسط الموزون للفحص) TrustWeightCheck وذلك ضمن حالتي مجال التغطية الأعظمي المعقول ومجال الظهور المفاجئ بقيمة ٤٢٠ متر و ٦٠٠ متر.

أظهرت النتائج أن زيادة المجال من ٤٢٠م إلى ٦٠٠م أدت إلى ارتفاع طفيف في تأخير اكتشاف الهجمات (Detection Latency) في جميع الخوارزميات، باستثناء خوارزمية الثقة القائمة على المتوسط الموزون للهجوم، حيث بلغ مقدار الزيادة في التأخير حوالي 0.19 ثانية، ويعزى ذلك إلى اعتماد هذه الخوارزمية على توقع نوع الهجوم أولاً ثم توزيع الأوزان وفقاً له.

كذلك، لوحظ انخفاض بسيط في قيمة F1-Score مع ازدياد المجال، إلا أن الانخفاض كان أقل ما يمكن في الخوارزمية المقترحة TrustWeightCheck، مما يشير إلى حفاظها على توازن جيد بين معدلات الكشف والدقة. أما من حيث الانتروبيا (Entropy)، فقد أظهرت الخوارزميات التقليدية ازدياداً في قيم الشك مع زيادة المجال، بينما أظهرت الخوارزميات المعتمدة على الأوزان، انخفاضاً في الانتروبيا بمقدار 0.01 للخوارزمية المقترحة مقابل 0.09 في خوارزمية الثقة القائمة على المتوسط الموزون للهجوم، مما يشير إلى تحسن في استقرار الثقة

بالقرارات. كذلك تأثرت مؤشرات التصنيف بزيادة المجال ، حيث أدت الزيادة إلى انخفاض عدد الرسائل الهجومية المكتشفة بشكل صحيح نتيجة زيادة عدد العربات داخل المجال وازدياد حجم الرسائل. بالإضافة الى انخفاض طفيف في قيم الانذارات الكاذبة FP ، زيادة في عدد الرسائل الشرعية المصنفة بشكل صحيح TN وزيادة عدد رسائل الهجومية التي لم تكتشف. والسبب عائد إلى ازدياد حجم التبادل داخل المجال الموسع، مما يعزز استلام رسائل صحيحة لكنه يقلل من وضوح مؤشرات الهجوم.

تعتمد الخوارزمية القائمة على المتوسط الموزون للفص على حساب متوسط موزون ديناميكي، حيث يتم تعيين وزن أكبر للفحوص التي تقترب قيمها من الصفر، مما يزيد تأثيرها ويؤدي إلى انخفاض الثقة في الرسالة. أما الفحوص المستقرة والتي تقترب من القيمة 1، فيتم تقليل وزنها دون تجاهلها كلياً، بخلاف خوارزمية الثقة القائمة على المتوسط الموزون للهجوم تعطي الوزن فقط لفحوص محددة حسب نوع الهجوم المتوقع.

وقد حققت الخوارزمية المقترحة:

عدد رسائل المصنفة بشكل صحيح بقيمة 35.18% من مجمل الرسائل الهجومية و بالمقابل تقليل عدد رسائل الهجومية التي لم تكتشفها FN بقيمة 14.41% وبينما كانت عدد الإنذارات الكاذبة بحدود 35.7% ، بينما بلغت عدد رسائل شرعية الصحيحة TN بحدود 14.7% ، أي أن الخوارزمية المقترحة متوازنة لذلك أعطت قيمة f1-Score عالي مقارنة مع بقية الخوارزميات رغم ذلك إلا إنها عانت من شك في تصنيف العربات والسبب عائد الى أن العربة تغير اسمها المستعار للحفاظ على شرط الخصوصية وذلك في المجال الأعظمي المعقول للتغطية ومجال الظهور المفاجئ 420 متر .

يوصى باعتماد خوارزمية الثقة القائمة على المتوسط الموزون للفص TrustWeightCheck كأساس

لنظام كشف الهجمات. بالإضافة إلى :

- إجراء اختبارات إضافية في بيئات محاكاة واقعية لتقييم الأداء بشكل أدق.
- ادخال المرشحات التي تعمل على ازالة القيم الشاذة او اكتشافها إلى خوارزميات الكشف.
- توليد Datasets تكون ناتجة عن دراسة مجمل بارامترات الكشف وإدخالها إلى خوارزميات التعلم الآلي وذلك بهدف تسريع الكشف واتخاذ قرارات دقيقة .

## ٥ - المراجع

- [1] Hamdan, S., Hudaib, A., & Awajan, A. (2021). Detecting Sybil attacks in vehicular ad hoc networks. *International Journal of Parallel, Emergent and Distributed Systems*, 36(2), 69-79.
- [2] Zhou, T., Choudhury, R. R., Ning, P., & Chakrabarty, K. (2007, August). Privacy-preserving detection of sybil attacks in vehicular ad hoc networks. In *2007 Fourth Annual International Conference on Mobile and Ubiquitous Systems: Networking & Services (MobiQuitous)* (pp. 1-8). IEEE.
- [3]Kamel, J., Jemaa, I. B., Kaiser, A., & Urien, P. (2018, December). Misbehavior reporting protocol for c-its. In *2018 IEEE Vehicular Networking Conference (VNC)* (pp. 1-4). IEEE

[4] Sharma, A., & Jaekel, A. (2021). Machine learning based misbehaviour detection in VANET using consecutive BSM approach. *IEEE Open Journal of Vehicular Technology*, 3, 1-14.

[5] Pavithra, T., Nagabhushana, B. S., & Das, S. (2022, August). Study of the Impact of Sybil Attack in VANETs Using F2MD. In *International Conference on Intelligent Cyber Physical Systems and Internet of Things* (pp. 533-543). Cham: Springer International Publishing.

[6] Grover, J., Laxmi, V., & Gaur, M. S. (2012). Misbehavior detection based on ensemble learning in vanet. In *Advanced Computing, Networking and Security: International Conference, ADCONS 2011, Surathkal, India, December 16-18, 2011, Revised Selected Papers* (pp. 602-611). Springer Berlin Heidelberg.

[7] Sonker, A., & Gupta, R. K. (2021). A new procedure for misbehavior detection in vehicular ad-hoc networks using machine learning. *International Journal of Electrical & Computer Engineering* (2088-8708), 11(3).

[8] Khot, A., & Dave, M. (2021). Position falsification misbehavior detection in vanets. In *Mobile Radio Communications and 5G Networks: Proceedings of MRCN 2020* (pp. 487-499). Springer Singapore.

[9] Singh, P. K., Gupta, S., Vashistha, R., Nandi, S. K., & Nandi, S. (2019). Machine learning based approach to detect position falsification attack in VANETs. In *Security and Privacy: Second ISEA International Conference, ISEA-ISAP 2018, Jaipur, India, January, 9–11, 2019, Revised Selected Papers 2* (pp. 166-178). Springer Singapore.

[10] Mangla, C., Rani, S., & Herencsar, N. (2023). A misbehavior detection framework for cooperative intelligent transport systems. *ISA transactions*, 132, 52-60.

[11] Van Der Heijden, R. W., Dietzel, S., Leinmüller, T., & Kargl, F. (2018). Survey on misbehavior detection in cooperative intelligent transportation systems. *IEEE Communications Surveys & Tutorials*, 21(1), 779-811.

[12] Z. Elrewini, K. Sadatsharan, D. F. Selvaraj, S. J. Plathottam, and P. Ranganathan, "Cybersecurity challenges in vehicular communications," *Veh. Commun.*, vol. 23, pp. 1–28, Jun. 2020.

[13] R. Hussain, J. Lee, and S. Zeadally, "Trust in VANET: A survey of current solutions and future research opportunities," *IEEE Trans. Intell. Transp. Syst.*, vol. 22, no. 5, pp. 2553–2571, May 2021.

[14] Kamel, J., Haidar, F., Jemaa, I. B., Kaiser, A., Lonc, B., & Urien, P. (2019, October). A misbehavior authority system for sybil attack detection in c-its. In *2019 IEEE 10th Annual Ubiquitous Computing, \Electronics & Mobile Communication Conference (UEMCON)* (pp. 1117-1123). IEEE

[15] Ali Akbar Pouyan and Mahdiyeh Alimohammadi. Sybil Attack Detection in Vehicular Networks. In *Computer Science and Information Technology 2.4*, pages 197 – 202, 2014. doi: 10.13189/csit.2014.020403.

[16] Shan Chang, Yong Qi, Hongzi Zhu, Jizhong Zhao, and Xuemin Shen. Footprint: Detecting sybil attacks in urban vehicular networks. *IEEE Transactions on Parallel and Distributed Systems*, 23(6):1103–1114, June 2012. ISSN 2161-9883. doi: 10.1109/TPDS.2011.263.

[17] Rens W van der Heijden et al. "Survey on misbehavior detection in cooperative intelligent transportation systems". In: arXiv preprint arXiv:1610.06810 (2016).

[18] Norbert Bißmeyer et al. "Central misbehavior evaluation for vanets based on mobility data

plausibility”. In: 9th ACM Workshop on vehicular inter-networking, systems, and applications. 2012.

[19] Chen Chen, Xin Wang, Weili Han, and Binyu Zang. A robust detection of the sybil attack in urban vanets. In 2009 29th IEEE International Conference on Distributed Computing Systems Workshops, pages 270–276, June 2009. doi: 10.1109/ICDCSW.2009.48

[20] Soyoung Park, Baber Aslam, Damla Turgut, and Cliff C. Zou. Defense against sybil attack in vehicular ad hoc network based on roadside unit support. In MILCOM 2009 - 2009 IEEE Military Communications Conference, pages 1–7, Oct 2009. doi: 10.1109/MILCOM.2009.5379844.

[21] Yong Hao, Jin Tang, and Yu Cheng. Cooperative sybil attack detection for position based applications in privacy preserved vanets. In 2011 IEEE Global Telecommunications Conference - GLOBECOM 2011, pages 1–5, Dec 2011. doi: 10.1109/GLOCOM.2011.6134242.

[22] Clavijo-Herrera, M., Banda-Almeida, J., & Iza, C. (2021, November). Performance evaluation in misbehaviour detection techniques for DoS attacks in VANETs. In Proceedings of the 18th ACM Symposium on Performance Evaluation of Wireless Ad Hoc, Sensor, & Ubiquitous Networks (pp. 73-80).

[23] Sultana, R., Grover, J., Tripathi, M., & Sharma, P. (2024). LA-DETECTS: Local and Adaptive Data-Centric Misbehavior Detection Framework for Vehicular Technology Security. IEEE Open Journal of Vehicular Technology.

[24] Shaleesh, I. S., Almohammed, A. A., Mohammad, N. I., Ahmad, A. A., & Shepelev, V. (2021). Cooperation and radio silence strategy in Mix Zone to Protect Location Privacy of Vehicle in VANET. Tikrit Journal of Engineering Sciences, 28(1), 31-39.

[25] Ayaida, M., Messai, N., Wilhelm, G., & Najeh, S. (2019, June). A novel Sybil attack detection mechanism for C-ITS. In 2019 15th international wireless communications & mobile computing conference (IWCMC) (pp. 913-918). IEEE.

[26] Sangwan, A., Sangwan, A., & Singh, R. P. (2023). A classification of misbehavior detection schemes for VANETs: a survey. Wireless Personal Communications, 129(1), 285-322.

[27] A. Sharma and A. Jaekel, “Machine learning based misbehaviour detection in VANET using consecutive BSM approach,” IEEE Open J. Veh. Technol., vol. 3, pp. 1–14, 2021.

[28] Shaleesh, I., Mohammed, N., & Mohammed, G. (2025). A trust algorithm based on weighted average for determining vehicle behavior in VANET. Tartous University Journal for Research and Scientific Studies, 9(4).

[29] Sultana, R., Grover, J., & Tripathi, M. (2022, November). A data-centric and dynamic-range based misbehavior detection approach for vanet. In TENCON 2022-2022 IEEE Region 10 Conference (TENCON) (pp. 1-6). IEEE.