

## تحسين أداء شبكات VANET باستخدام تقنيات الذكاء الصناعي للتنبؤ

\* علي أحمد

\*\* آلاء أكرم سرحان

(تاريخ الإيداع ٢٠٢٣/٦/١ . قبل للنشر في ٢٠٢٤/٢/٦)

□ ملخص □

تتطور شبكات VANET (Vehicular Ad-Hoc Network) بشكل كبير جداً وخاصة في مجال أمان الطرقات، حيث تلعب هذه الشبكات دوراً هاماً في الحفاظ على أرواح الناس من خلال تتبع المركبات ضمن شبكة VANET في حال حدوث انجرافات في الطرقات أو حوادث، ليقوم السائق باتخاذ القرار المناسب. بما أن شبكات VANET هي عبارة عن شبكات ذات ديناميكية عالية وبالتالي فإن عدد المركبات يختلف بشكل مستمر بسبب الحركية المستمرة لها، وبالتالي فإن تأخير وصول الرسائل الهامة أمر بالغ في الخطورة وينبغي تقليل تأخير إرسال هذه الرسائل قدر الإمكان. في هذا البحث كانت مهمتنا التنبؤ بزمن الإرسال الكلي من أجل تقليل تأخير الإرسال ضمن هذه الشبكات، حيث قمنا بعملية التنبؤ من خلال الشبكات العصبونية، ففي هذا البحث صممنا نموذج شبكة عصبونية قادر على التنبؤ بزمن الإرسال الكلي واعتمدنا على برنامج الماتلاب في عملية التصميم وإظهار النتائج، حيث أظهر النموذج المصمم كفاءته وحقق دقة عالية بلغت ٩٥% .

الكلمات المفتاحية: شبكات VANET-الذكاء الصناعي-تقنيات التنبؤ.

\* استاذ في هندسة تكنولوجيا المعلومات والاتصالات- اختصاص الأمواج الميكروية  
\*\*طالب ماستر في هندسة تكنولوجيا المعلومات والاتصالات- اختصاص هندسة الاتصالات

## Improving performance of AVNET using Artificial intelligence for predication

Ali Ahmad \*  
Alaa Serhan \*\*

(Received 1/6/2023 . Accepted 6/2/2024)

### □ ABSTRACT □

VANET (Vehicular Ad-Hoc Network) networks are evolving significantly, especially in the field of road safety, where these networks play a crucial role in preserving people's lives by alerting vehicles within the VANET network in case of road drifts or accidents, allowing the driver to make appropriate decisions.

Since VANET networks are highly dynamic networks, the number of vehicles constantly varies due to their continuous mobility. Therefore, the delay in the arrival of important messages is highly critical, and it is necessary to minimize the delay in sending them as much as possible.

In this research, our task was to predict the total transmission time in order to reduce the transmission delay within these networks. We carried out the prediction process through neural networks. In this research, we designed a neural network model capable of predicting the total transmission time and we relied on the MATLAB program in the design process and showing the results. The designed model demonstrated its efficiency and achieved a high accuracy of 95%.

**Keywords:** VANET, prediction, artificial intelligence.

---

\* Professor of Information and Communication Technology Engineering - Microwave Specialization

\*\*Master student in Information and Communication Technology Engineering- Communication department

## ١- مقدمة:

تعد شبكات Ad-hoc عبارة عن شبكات مؤقتة تُنشئ نفسها بنفسها، لا يوجد فيها بنية تحتية محددة، ولا يوجد وقت للإنشاء وتتمتع بديناميكية عالية. ومن أهم الأمثلة على هذه الشبكات هي شبكات VANET، حيث تتكون هذه الشبكات من مجموعة من المركبات التي تتحرك بشكل مستمر، وتلعب هذه الشبكات دور هام جداً في أمان الطرقات حيث ترسل رسائل إنذار إلى المركبات، هذه الرسائل لا تتحمل تأخير وعلى أساسها يتم اتخاذ القرار المناسب من قبل المركبة بتخفيف السرعة أو تغيير الطريق.

## ٢- مشكلة البحث:

تكمن مشكلة البحث في :

١. شبكات SDN تتضمن تأخير .
٢. العمليات الحسابية تستهلك ذاكرة كبيرة وطاقة كبيرة.
٣. رغم استخدام تقنيات الجيل الخامس مازال التأخير في الإرسال بين العقد البعيدة.
٤. استخدام البروتوكولات لا يحقق كفاءة عالية لأن الطبولوجيا متغيرة باستمرار .

## ٣- هدف البحث:

يهدف البحث إلى :

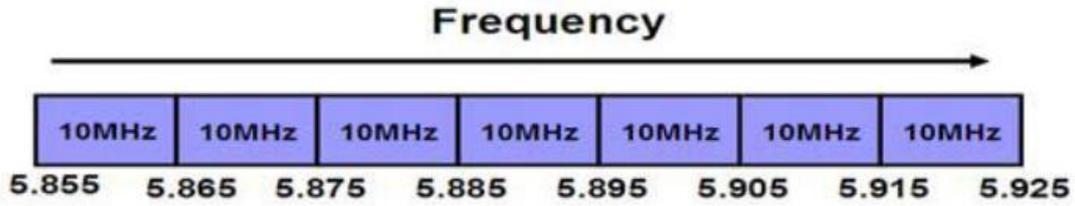
- تحليل بيانات تم تجميعها خلال فترات زمنية لشبكة مركبات و بناء نموذج ذكاء صناعي وتدريبه واختباره على هذه البيانات.
- الحصول على نموذج دقيق في التنبؤ عن تأخير الاتصالات و تقييم النظام من خلال حساب عدة بارامترات.
- النظام الناتج قادر على التنبؤ بشكل مسبق بزمان الإرسال الكلي وبالتالي يسمح لنا بتطبيق سياسية استباقية لتقليل التأخير.

## ٤- أهمية البحث:

التنبؤ بزمان الإرسال في شبكات الفانيت هو أمر بالغ الأهمية بسبب الديناميكية العالية للمركبات علماً أن هذه المركبات تتبادل معلومات هامة غير محتملة التأخير مثل تحذيرات الأمان وإرسال هذه المعلومات يتعرض لعدة عوامل كحركة المركبة وازدحام الشبكة وظروف الطقس الذي يؤدي الى تأخير غير متوقع وبالتالي من المهم جداً بناء نظام اتصالات موثوق يقوم بالتنبؤ بدقه بزمان الإرسال الكلي وبالتالي نحصل على استراتيجية مسبقة لتطبيق السياسات اللازمة لتقليل التأخير وزيادة فعالية وأمان اتصالات المركبات.

## ٥- الدراسات المرجعية :

في البحث [1] يعتمد معيار DSRC مبدأ القنوات المتعددة حيث يزود المعيار سبع قنوات ضمن المجال الترددي من 5.850GHz إلى 5.925GHz كل قناة بعرض حزمة 10MHz كما في الشكل (3-1). الهدف من معيار DSRC جعل الاتصال متاح بين العربات بعضها البعض وبين العربات ووحدات الاتصال الطرقية تُستخدم كل من القنوات 172 و 184 من أجل الرسائل المتعمقة بالأمان أما القنوات 174 و 176 و 180 و 182 تستخدم من أجل الرسائل غير المتعلقة بالأمان (رسائل الخدمات)، تُستخدم القناة 178 والتي تسمى قناة التحكم غالباً من أجل التطبيقات المتعمقة بالأمان ورسائل البث العام وخدمات التأشير.



الشكل (3-1): سبع قنوات ضمن المجال الترددي من 5.850 GHz إلى 5.925 GHz.

**الاقتراح الأول:** يقترح الباحث الانتقال إلى قناة أخرى عندما يقوم المهاجم بالتشويش على أية قناة من القنوات السابقة، يفترض الباحث حل مشكلة هجوم حجب الخدمة ولكنه لم يتم بتجريب الطريقة و اظهار نتائج. **الاقتراح الثاني:** تستخدم شبكات VANET العديد من تقنيات الاتصال لتأمين الاتصال بين مكونات الشبكة، يقترح الباحث التبديل بين تقنيات الاتصال عند حدوث هجوم مما يصعب على المهاجم اكتشاف تقنية الاتصال المستخدمة والتشويش عليها .

**الاقتراح الثالث:** استخدام تقنية الطيف الترددي المنثور FHSS لأنها تستخدم مفاتيح ورموز خاصة بالإضافة لاستخدام عدد من الترددات الراديوية .تستخدم هذه التقنية فترات زمنية لإرسال البيانات إضافة إلى تسلسل عشوائي مزيف بهدف زيادة الأمان في الشبكة . عندما يقوم المهاجم بالهجوم تقوم العربة بخيار القفز إلى تردد آخر بطريقتين بطيئة وسريعة.

في الدراسة [2] قدم الباحثون عام 2013 طريقة تعتمد على وحدات الاتصال الطرقية لكشف الهجوم والتصدي له . إذ تراقب RSU الاتصالات بين العربات نفسه (V2V) والاتصالات بين العربات والبنية التحتية V2I وتحاول كشف هوية العربات التي ترسل معلومات خاطئة .يقوم المهاجم بتغيير محتوى الرسالة وتميرها إلى عربة أخرى وبذلك تنتقل المعلومات الخاطئة بشكل مستمر مع البيانات المتدفقة .تصل رسائل العقد المهاجمة إلى RSU التي تقوم بدورها بحجب نشاطها وعزلها وتقوم بمعالجة المعلومات المتضررة بتأثير الهجوم .طرح الباحث عدة سيناريوهات الأول يعرض المعلومات المرسمة في فترات الازدحام أما الثاني فيعرض المعلومات المحذوفة بتأثير الهجوم .استخدم الباحث محاكي الشبكات NS 2.31 لبناء سيناريو المحاكاة وتحليل النتائج . في البحث [3] تم بث المعلومات بشكل فعال في شبكات VANET من خلال نظام ضبابي أيضاً حيث يتم إعادة بث المعلومات عن طريق عقدة ويعتمد النظام الضبابي على العديد من بارمترات الإدخال مثل الاتصال والانتقال وتغطية العقدة . في البحث [4] بسبب الطبولوجيا المتغيرة والتنقل العالي للمركبات، هدفت الدراسة إلى تقليل تأخير الإرسال وذلك من خلال استخدام التعلم الآلي للتنبؤ بحركة المركبات عن طريق الاحتفاظ بمعلومات الطريق RSU واختيار الطريق الأكثر كثافة . في البحث [5] تم اختيار المسار

الأفضل لتوصيل الرسالة بأقل وقت ممكن باستخدام خوارزميات التعلم الآلي المحسن من خلال المسارات التي تتضمن عقد حرجة. استخدمت الدراسة [6] خوارزمية RLS من أجل التنبؤ بتنقل المستخدم حيث أثبتت الدراسة أن الشبكات العصبونية هي نهج أقوى من التعلم الآلي في حل مشاكل التصنيف والتنبؤ.

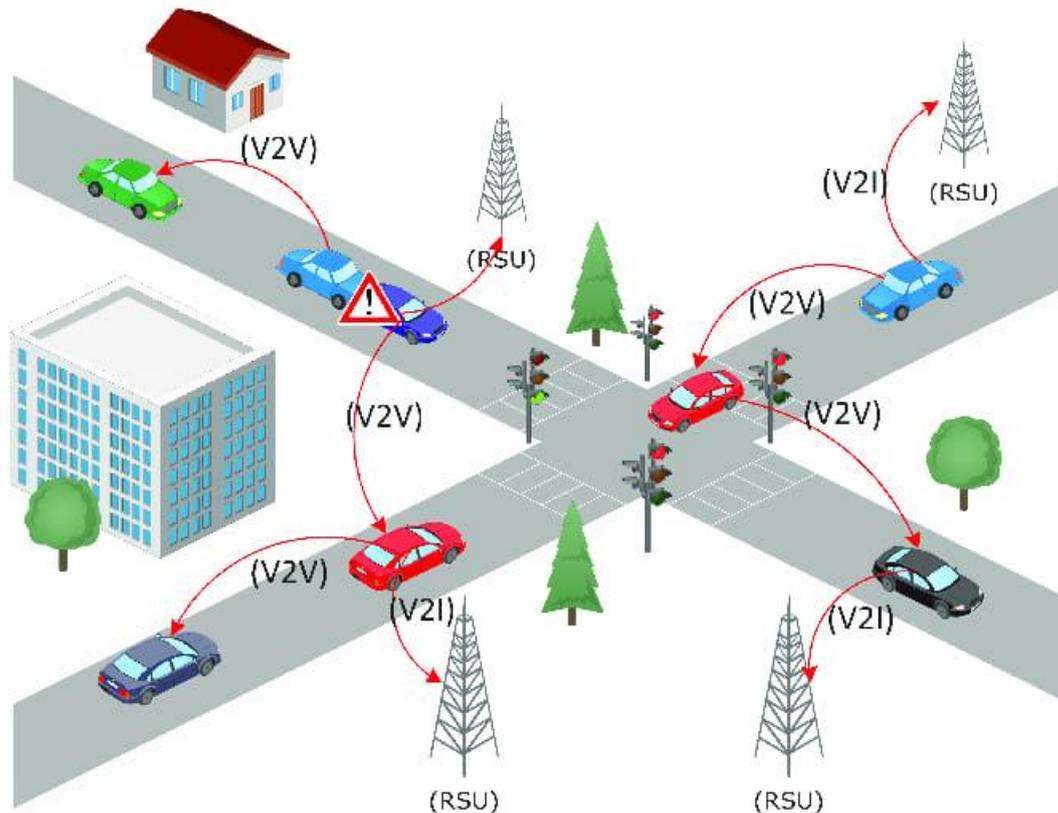
#### الخلاصة:

في هذا البحث نحن لم نحسن على بحث أو دراسة سابقة إنما اقترحنا منهجية و نموذج شبكة عصبونية مختلف وقمنا بالتنبؤ ببارامتر غير البارامترات الموجودة في الدراسات السابقة وسيوضح ذلك فيما بعد حيث تم التنبؤ بزمن الإرسال الكلي .

#### طرائق البحث ومواده:

##### ٦-١ شبكات المركبات المتنقلة VANET

شبكة المركبات المتحركة VANET ، هي التكنولوجيا التي تستخدم سيارات متحركة في الشوارع (مدن أو خطوط سريعة) كالعقد في شبكة لاسلكية لإنشاء شبكة لاسلكية متنقلة [7]. تقوم شبكة Vehicular ad-hoc بتحويل كل سيارة مشاركة في الشبكة إلى موجه لا سلكي Router أو عقدة لاسلكية node، مما يسمح للسيارات التي تبعد عن بعضها البعض ما يقارب من ١٠٠ حتى ٣٠٠ متر للتواصل، وبالتالي، إنشاء شبكة اتصال مع مجموعة واسعة النطاق. تصبح بعض السيارات ونتيجة الحركة (mobility) خارج نطاق إشارة الاتصال وبالتالي يتسبب هذا بالانقطاع عن الشبكة، ولكن من الممكن ان تأتي سيارات أخرى تنظم الشبكة وتقوم بربط المركبات مع بعضها البعض بحيث يتم إنشاء اتصال إنترنت عبر هذه الشبكة المتنقلة.



الشكل (1): بنية شبكات الفانيت

## 6-2 الذكاء الصناعي

يشير الذكاء الاصطناعي (AI) إلى محاكاة الذكاء البشري في الآلات المبرمجة للتفكير والتعلم مثل البشر. إنه مجال واسع للدراسة والممارسة يتضمن تطوير أنظمة كمبيوتر قادرة على أداء المهام التي تتطلب عادةً ذكاءً بشرياً [8]. يشمل الذكاء الاصطناعي مجموعة واسعة من التقنيات والخوارزميات والأساليب التي تمكن الآلات من الإدراك والاستنتاج والتعلم واتخاذ القرارات. تتضمن هذه التقنيات التعلم الآلي ومعالجة اللغة الطبيعية ورؤية الكمبيوتر والأنظمة الخبيرة والروبوتات والمزيد.

الهدف من الذكاء الاصطناعي هو إنشاء آلات ذكية يمكنها محاكاة أو تكرار القدرات المعرفية البشرية، مثل فهم اللغة الطبيعية، والتعرف على الأشياء والأنماط، وحل المشكلات المعقدة، واتخاذ القرارات، والتكيف مع المواقف الجديدة. يمكن لأنظمة الذكاء الاصطناعي تحليل كميات هائلة من البيانات، واكتشاف الأنماط والاتجاهات، وتقديم تنبؤات أو توصيات بناءً على المعلومات التي تعالجها.

### 3-6 الشبكات العصبونية متعددة الطبقات :

تعتبر الشبكات العصبونية الاصطناعية على أنها نظام حسابي مكون من عدد من وحدات المعالجة المترابطة مع بعضها وتتصف بطبيعتها الديناميكية والمتوازية في معالجة البيانات الداخلة إليها وتعتبر الخلية العصبية الاصطناعية هي وحدة بناء الشبكة العصبونية الاصطناعية. تتكون الخلية من وحدة حسابية متعددة المداخل وإشارة خرج ولكل إشارة خرج هنالك وزن يعمل على تعديل إشارة الدخل ويعمل على تحفيز الخلية لإنتاج إشارة رد عندما تكون قيمة موجبة أو إخمادها عندما تكون قيمته سالبة . تعد الشبكات العصبونية متعددة الطبقات ذات فعالية أكثر من الشبكات العصبونية وحيدة الطبقة وخاصة في التطبيقات المعقدة علماً أن معظم الشبكات العصبونية المستخدمة لا تملك أكثر من ثلاث طبقات إلا في حالات نادرة جداً .

## 6- المنهجية المتبعة :

قمنا بالتنبؤ بزمن الإرسال الكلي (Time Period) بين المرسل والمستقبل ضمن شبكات Vanet باستخدام الشبكات العصبونية الاصطناعية وهي إحدى تقنيات الذكاء الصناعي فكان الهدف من هذا التنبؤ هو أن يكون زمن الإرسال الكلي أقل ما يمكن وذلك من أجل أن نقلل تأخير الإرسال فكلما كان زمن الإرسال أقل كلما كان تأخير الإرسال أقل. كما تم الأخذ بعين الاعتبار أولوية الحزم المرسله ضمن قاعدة البيانات التي سيتم تدريب الشبكة العصبونية عليها وذلك من أجل حالات الطوارئ أيضاً التي قد تحصل. وتم الأخذ بالحسبان أيضاً ضمن قاعدة البيانات كل من عدد الحزم المرسله والمسافة بين المرسل والمستقبل وذلك لما لها تأثير على زمن الإرسال وبالتالي تأثيرها على زمن تأخير الإرسال .

ففي هذا البحث تم تصميم نظام قادر على التنبؤ بزمن الإرسال الكلي باستخدام أحد تقنيات الذكاء الاصطناعي وهي الشبكات العصبونية، فصمنا شبكة عصبونية متعددة الطبقات باستخدام برنامج ماتلاب واعتمدنا في منهجيتنا هذه على شبكة متعددة الطبقات لأنها مناسبة لمشكلتنا وقادرة على المعالجة وإعطاء نتائج أفضل من الشبكة أحادية الطبقة أو البسيطة كشبكة بيرسبترون مثلاً.

أما بالنسبة لتتابع النقل فهناك طيف واسع من دوال النقل التي يمكن استخدامها في الشبكات العصبونية الاصطناعية . يتم اختيار دالة النقل اعتماداً على طبيعة المشكلة التي تستخدم الشبكة العصبونية لحلها . اعتمدنا في نظامنا على التابعين الآتيين :

- Log–Sigmoid Transfer Function.
- PureLin Transfer Function .

يستخدم هذا النوع من الدوال عادة مع الشبكات العصبونية المتعددة الطبقات ومع التطبيقات المعقدة وهذه الدوال أيضاً مناسبة لحل المشكلة المقترحة. فعلى سبيل المثال، لو اعتمدنا تابع النقل hardlim فإن النتائج ستكون سيئة لأنه غير ملائم لمشاكل التصنيف والتنبؤ هذه . أما بالنسبة لعدد الطبقات فبعد التجربة اعتمدنا على ثلاث طبقات مما أعطانا نتائج جيدة، مع الأخذ بعين الاعتبار أن زيادة عدد الطبقات بشكل كبير قد يكون في بعض الأحيان خياراً سيئاً ولا يحقق الهدف المرجو من عملية التصنيف أو التنبؤ. أما بالنسبة لعدد العصبونات لكل طبقة من الطبقات المخفية للشبكة العصبونية، فبعد التجربة وجدنا أيضاً أن ١٠ عصبونات في كل طبقة كافية لحل المشكلة، حيث أن زيادة عدد العصبونات بشكل كبير ليس أمراً إيجابياً، لأن النتائج ستكون جيدة فقط للعينات المدربة، على عكس العينات غير المدربة، وبالتالي سنحصل على نتائج سيئة.

بالنسبة لخوارزمية التدريب فقد استخدمنا خوارزمية التدريب Levenberg–Marquardt ، وهي نسخة معدلة من خوارزمية نيوتن، مما يجعلها مناسبة لتدريب الشبكات العصبونية متعددة الطبقات، ولهذا اخترناها لعملية التدريب. يعتمد مبدأ عمل هذه الخوارزمية على أنه عند تطبيق كل قيمة من قيم الدخل ، يتم حساب الخرج الفعلي للشبكة ومقارنته بالهدف المرجو . وبالتالي تكون قد قامت الخوارزمية بضبط بارامترات الشبكة لتقليل القيمة التربيعية المتوسطة للخطأ على النحو التالي [14] :

$$F(x)=E[e^2]=E[(t-a)]^2$$

علماً أن :

e : قيمة الخطأ:

T: الهدف المرجو

a : الخرج الفعلي:

X: متجه الأوزان والانحياز للشبكة

## ٧- خوارزمية العمل :



## قاعدة البيانات :

- تم إنشاء مجموعة البيانات هذه من محاكاة لمدينة بولونيا في إيطاليا. تحتوي مجموعة البيانات على الحقول التالية:
- زمن البدء: الزمن بالثواني عند وصول الطلب.
  - زمن الانتهاء: الزمن بالثواني عند الانتهاء من الطلب.
  - زمن الإرسال: زمن الانتهاء - زمن البدء
  - الحزم: عدد الحزم المطلوبة بموجب هذا الطلب.
  - معدل الحزم: عدد الحزم مقسوما على زمن الإرسال ، الحزم في الثانية
  - المسافة الفعلية: المسافة بالمتري بين المرسل والمستقبل.
  - الأولوية : تمثل شدة الطلب.
- يوضح الشكل (2) جزء من قاعدة البيانات المستخدمة :

1	Start time	End time	Packets	RatePacket	ActualDist	Severity	TimePeriod
2	87	168	806	9.829268	208.8145	30000	82
3	87	94	65	8.125	226.1085	20000	8
4	87	93	57	8.142857	282.3983	20000	7
5	87	118	312	9.75	88.38643	40000	32
6	87	172	845	9.825581	199.465	30000	86
7	87	113	260	9.62963	206.3746	30000	27
8	87	186	991	9.91	261.9233	20000	100
9	87	93	60	8.571429	327.2293	20000	7
10	87	106	187	9.35	322.7113	20000	20
11	87	170	830	9.880952	200.2189	30000	84
12	87	143	562	9.859649	267.0043	30000	57
13	87	143	562	9.859649	94.13139	30000	57
14	87	162	745	9.802632	175.2694	40000	76
15	87	127	396	9.658537	235.9288	20000	41
16	87	138	509	9.788462	277.712	30000	52
17	87	158	710	9.861111	153.0795	40000	72
18	87	100	127	9.071429	366.4857	20000	14
19	87	186	990	9.9	176.7614	30000	100
20	87	137	497	9.745098	134.0702	40000	51

الشكل (2) : جزء من قاعدة البيانات المستخدمة.

للوصول إلى قاعدة البيانات من خلال الرابط :

<https://github.com/IhabMoha/datasets-for-VANET>

### خوارزمية التدريب Levenberg-Marquardt:

والمعروفة أيضاً بخوارزمية L-M وهي طريقة تحسين تكرارية لحل مسائل المربعات الصغرى غير الخطية تم تطويرها بواسطة Kenneth Levenberg and Donald Marquardt في الستينات ومنذ ذلك الوقت أصبحت خياراً أكثر شيوعاً للعديد من التطبيقات .

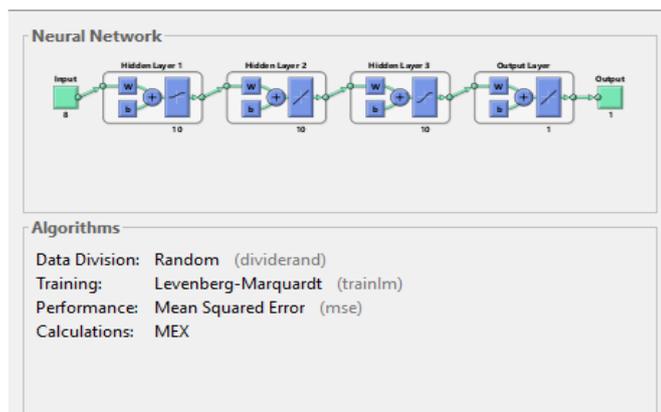
تجمع هذه الخوارزمية بين مزايا كل من طريقة نيوتن و طريقة الهبوط المنحدر، حيث تحقق هذه الخوارزمية توازناً بين كفاءة طريقة نيوتن واستقرار طريقة الهبوط المنحدر . توفر خوارزمية Levenberg-Marquardt العديد من المزايا فإنها تتقارب بشكل أسرع من طريقة الهبوط المنحدر وأكثر كفاءة من الناحية الحسابية من طريقة نيوتن . وهي طريقة قوية ومستخدمة على نطاق واسع لحل مسائل المربعات الصغرى والمشاكل المعقدة وذلك من خلال ضبط النموذج بشكل متكرر لتحقيق الهدف المرجو منه .

### النتائج والمناقشة :

تم استخدام شبكة عصبية متعددة الطبقات. تتكون هذه الشبكة من ثلاث طبقات مخفية، حيث تحتوي كل طبقة مخفية على ١٠ عصبونات، وبالتالي تحتوي الشبكة على ٣٠ عصبون. أما توابع النقل الخاصة بالشبكة فهي :

- Log-Sigmoid Transfer Function.
- PureLin Transfer Function .

تم إنشاء الشبكة باستخدام تعليمات newff وتحديد جميع بارامتراتهما بما في ذلك مصفوفة الإدخال والهدف ووظائف النقل وعدد العصبونات والطبقات المخفية. يوضح الشكل (3) الشبكة العصبونية التي تم إنشاؤها باستخدام MATLAB ويوضح أيضاً عملية تدريب الشبكة. تم تدريب الشبكة باستخدام خوارزمية التدريب (Levenberg-Marquardt) ، واحتاجت الشبكة لتدريبها إلى ١٠٠٠ خطوة:



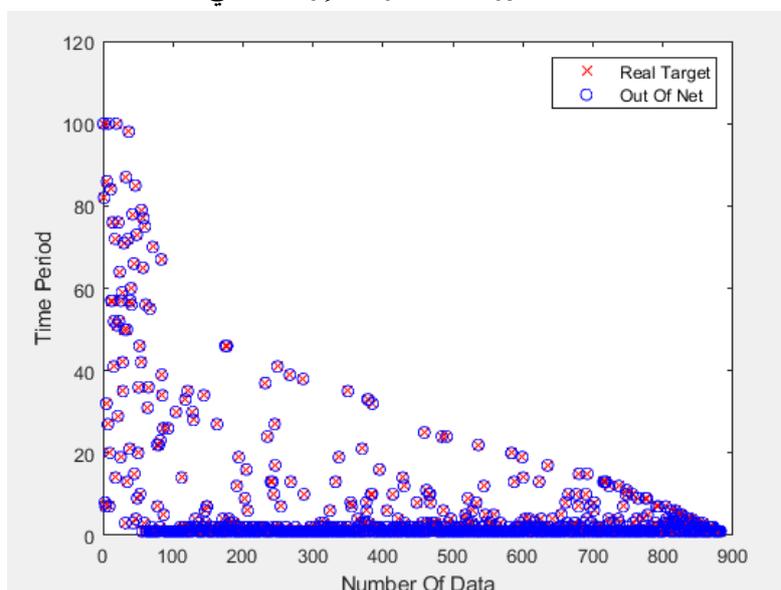
الشكل (3): الشبكة العصبونية التي تم إنشاؤها باستخدام MATLAB

كما نلاحظ من الشكل (3) أن هذه النافذة توفر لنا الكثير من المعلومات من خوارزمية التدريب و طريقة تقسيم الداتا بالإضافة إلى بنية الشبكة العصبونية من عدد الطبقات المخفية وتوايح النقل عدد العصبونات .

تم تقسيم البيانات إلى مجموعتين فرعيتين :

مجموعة التدريب: تم إعطاء هذه المجموعة ٩٠% من بيانات دخل الشبكة. تستخدم هذه المجموعة لتحديث الأوزان وحساب تدرج الشبكة .

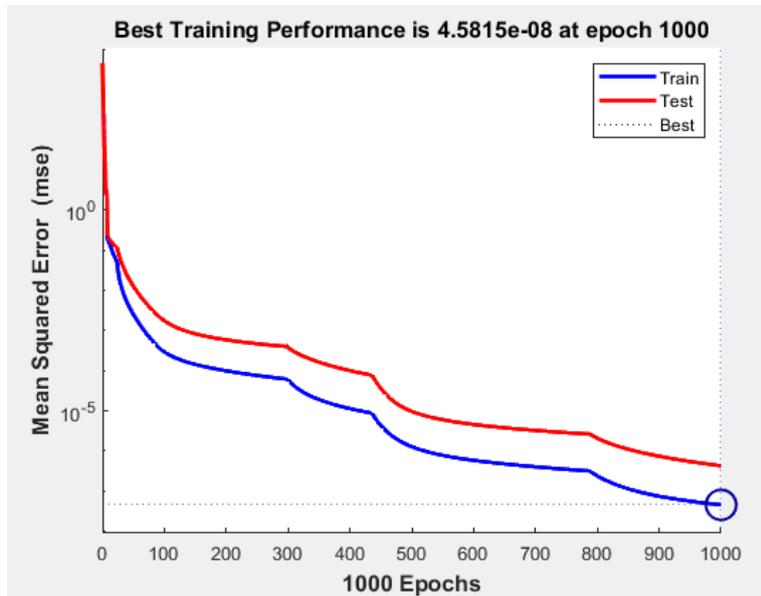
مجموعة الاختبار : تم إعطاء مجموعة الاختبار ١٠% من بيانات دخل الشبكة، ولا يتم استخدام هذه المجموعة أثناء التدريب. قمنا برسم كل من عينات الخرج الفعلي والهدف المرجو وقمنا بمقارنتها، كما يوضح الشكل (4) أن الخرج الفعلي ينطبق على الهدف المرجو وبالتالي تكون الشبكة قد حققت ما هو مطلوب منها . ويمثل المحور X عدد البيانات ضمن قاعدة البيانات ، بينما يحدد المحور Y يمثل زمن الإرسال الكلي .



الشكل (4): الخرج الفعلي و الهدف المرجو.

نلاحظ في الشكل (4) أن الشبكة قد حلت مشكلة التنبؤ ، حيث نلاحظ أن ناتج الشبكة ينطبق على الهدف، ، وبالتالي حققت الشبكة المطلوب منها بأقل قيمة خطأ ويمكننا اعتبارها شبكة مثالية.

يوضح الشكل (5) أداء الشبكة ( القيمة المتوسطة التربيعية للخطأ) ويعطي أفضل قيمة لها في خطوة التدريب الأخيرة (١٠٠٠):



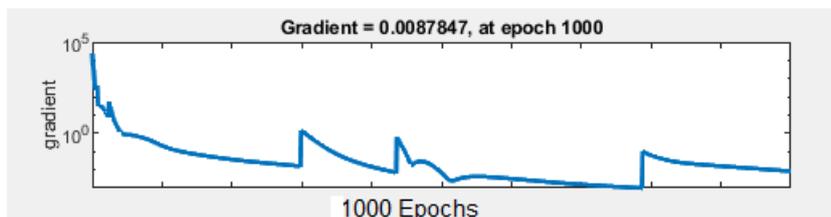
الشكل (5): أداء الشبكة ( القيمة المتوسطة التربيعية للخطأ).

نلاحظ من الشكل (5) متوسط القيمة التربيعية للخطأ ، وهو نفسه مؤشر الأداء ، ويعتبر أحد بارامترات القياس في الشبكات العصبونية التي نستخدمها لقياس أداء الشبكة ويعطى بالعلاقة [14]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \widehat{Y})^2$$

و ينخفض مؤشر الأداء (متوسط الخطأ التربيعي) وفقا لعدد التكرارات لمجموعة البيانات (التدريب والاختبار). حيث نلاحظ في الشكل (5) أن أفضل وأصغر قيمة لمؤشر الأداء تساوي  $4.5815 \cdot 10^{-8}$  عند خطوة التدريب الأخيرة ١٠٠٠.

يوضح الشكل (6) قيمة التدرج:

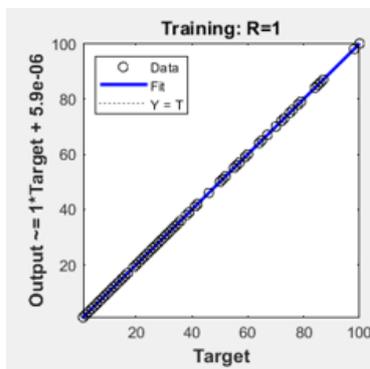


الشكل (6): قيمة التدرج.

تظهر قيمة التدرج في الشبكة في الشكل (6) ، حيث يمثل التدرج مشتقات الدرجة الأولى لمؤشر الأداء ، ويتم الإشارة إلى التدرج بالرمز  $\nabla$ . يتم تعريف التدرج من خلال العلاقة التالية [14] :

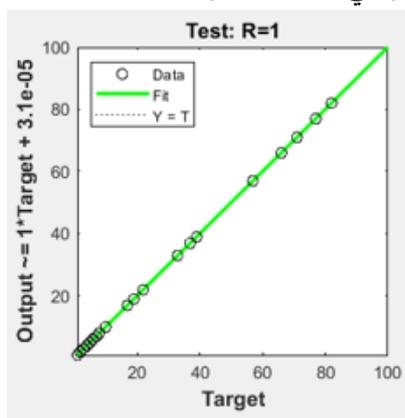
$$\nabla F(x) = \left[ \frac{\partial F(x)}{\partial x_1} \quad \frac{\partial F(x)}{\partial x_2} \quad \dots \quad \frac{\partial F(x)}{\partial x_n} \right]$$

يلعب التدرج دوراً مهماً في فهم سطح الأداء ، وكلما كان التدرج أصغر ، كان الأداء أفضل. كانت أفضل قيمة للتدرج 0.0087847 في خطوة التدريب الأخيرة .  
يوضح الشكل (7) تحليل الانحدار في حالة التدريب :



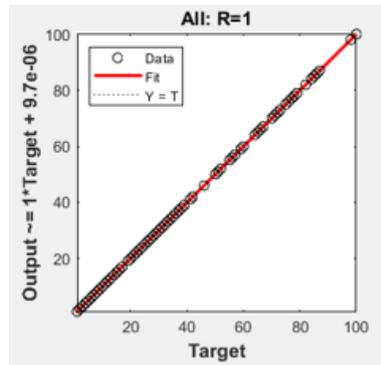
الشكل(7) : تحليل الانحدار في حالة التدريب.

يوضح الشكل (8) تحليل الانحدار في حالة الاختبار :



الشكل(8) : تحليل الانحدار في حالة الاختبار.

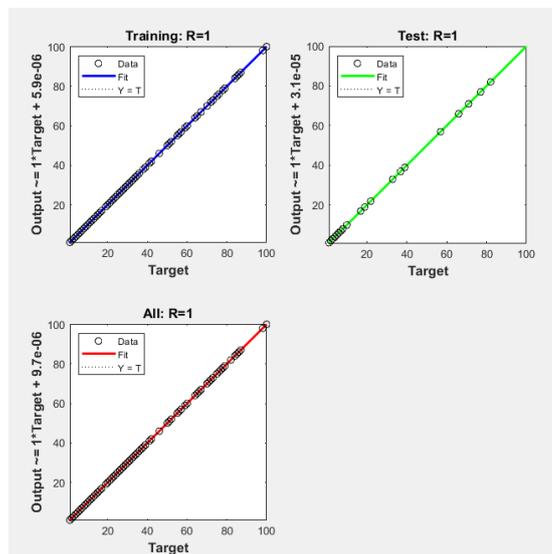
يوضح الشكل (9) تحليل الانحدار في كلتا الحالتين (حالة التدريب & حالة الاختبار ) :



الشكل (9): تحليل الانحدار في كلتا الحالتين (حالة التدريب & حالة الاختبار).

يوضح الشكل (10) تحليل الانحدار بحالة التدريب وحالة الاختبار وكلتا الحالتين ( علاقة الخرج الفعلي مع

الهدف المرجو):



الشكل(10) : تحليل الانحدار ( علاقة الخرج الفعلي مع الهدف المرجو ).

يستخدم تحليل الانحدار من أجل تحليل أداء الشبكة العصبونية بعد أن تنجز الشبكة العصبونية عملية

التدريب.

ويعطى بالعلاقة التالية [14]:

$$a_q = mt_q + c + \varepsilon_q$$

حيث يمثل  $a_q$  الخرج الفعلي للشبكة أما  $t_q$  يمثل الهدف المرجو من الشبكة في حين يمثل  $m$  ميل مستقيم الانحدار ويمثل  $c$  الانزياح للمعادلة الخطية أما  $\varepsilon_q$  فيمثل قيمة الخطأ الباقي للانحدار.

وكما واضح بالشكل فإن الخط الغامق يمثل معادلة الانحدار الخطية ، والخط الرفيع يمثل خط التطابق

التام بين الخرج الفعلي والهدف المرجو أما الدوائر الصغيرة فتتمثل نقاط المعطيات .

ونلاحظ من الشكل(10) أن الخرج الفعلي يتطابق مع الهدف المرجو بشكل كامل لذلك نجد أن قيمة

معامل الارتباط  $R=1$ .

## ١٢-الاستنتاجات و التوصيات :

- في هذا البحث ، تمكنا من تحقيق عملية التنبؤ بزمن الارسال الكلي باستخدام شبكة عصبونية متعددة الطبقات وتحقيق الهدف المرجو من نموذج الشبكة العصبونية الخاص بنا.
- استنتجنا أيضاً بعض السلبيات التي اعترضتنا أثناء العمل ومنها زياد عدد العصبونات، حيث أن زيادة عدد العصبونات بشكل كبير ليس أمراً إيجابياً، لأن النتائج ستكون جيدة فقط للعينات المدربة، على عكس العينات غير المدربة، وبالتالي سنحصل على نتائج سيئة.
- كما أن زيادة عدد الطبقات بشكل كبير أيضاً قد لا يوصلنا إلى الهدف المرجو من الشبكة ويتم اكتشاف ذلك من خلال عملية التجريب والتحقق من أداء الشبكة وفي حال كان الشخص لديه خبرة كبيرة في مجال الشبكات العصبونية فهو قادر من البداية تحديد عدد الطبقات المناسب لحل المشكلة أو تحقيق عملية التنبؤ وأغلب التطبيقات تكفي بثلاث طبقات مخفية كحد أقصى والتطبيقات التي تحتاج عدد أكثر من الطبقات نادرة جداً .
- و بعد الدراسة والتحليل ، نوصي بما يلي:
- ١- تحقيق عملية التنبؤ لتقليل زمن الارسال باستخدام أحد أنواع الذكاء الاصطناعي مثل التعلم العميق أو المنطق الضبابي بدلاً من الشبكات العصبونية.
  - ٢- استخدام نوع آخر من الشبكات العصبية كالشبكات التنافسية أو CNN.

## ١٣-المراجع:

1. HASBULLAH, H. SOOMRO, I. and MANAN, J. —Denial of Service (DOS) Attack and Its Possible Solutions in VANET," *International Science*, Vol.4, No.5, 2010, 348-352.
2. PATHRE, A. AGRAWAL, CH. and GAIN, A. A Novel Defense Scheme against DDoS Attack in VANET“ Tenth International Conference of Wireless and Optical Communications Networks (WOCN), , IEEE 2013.
3. S. A. Soleymani, A. H. Abdullah, M. Zareei, M. H. Anisi, C. Vargas-Rosales, M. K. Khan, and S. Goudarzi, “A Secure Trust Model Based on Fuzzy Logic in Vehicular Ad Hoc Networks With Fog Computing,” *IEEE Access*, vol. 5, pp. 15619–15629, 2017.
4. Lai, W. K., Lin, M. T., & Yang, Y. H. (2015). A machine learning system for routing decision-making in urban vehicular ad hoc networks. *International Journal of Distributed Sensor Networks*, 11(3), 374391.
5. Ravikumar, K., Thiyagarajan, R., Saravanan, M., & Parthasarathy, P. (2021). Effective Routing in Vehicular Adhoc Network (VANET) using an Bio-inspired Algorithm: Enhanced Deep Reinforcement Learning (EDRL) for Secure Wireless Communication.
6. Shen, X., Mark, J. W., & Ye, J. (2000). User mobility profile prediction: an adaptive fuzzy inference approach. *Wireless Networks*, 6(5), 363-374.
7. Cooper, C., Franklin, D., Ros, M., Safaei, F., & Abolhasan, M. (2016). A comparative survey of VANET clustering techniques. *IEEE Communications Surveys & Tutorials*, 19(1), 657-681.
8. Collins, G. S., & Moons, K. G. (2019). Reporting of artificial intelligence prediction models. *The Lancet*, 393(10181), 1577-1579.
9. Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2017, September). Stock price prediction using LSTM, RNN and CNN-sliding window model. In *2017 international conference on advances in computing, communications and informatics (icacci)* (pp. 1643-1647). IEEE.
10. Nelson, D. M., Pereira, A. C., & De Oliveira, R. A. (2017, May). Stock market's price movement prediction with LSTM neural networks. In *2017 International joint conference on neural networks (IJCNN)* (pp. 1419-1426). Ieee.
11. Tratar, L. F., & Strmčnik, E. (2016). The comparison of Holt–Winters method and multiple regression method: A case study. *Energy*, 109, 266-276.
12. Ulpe, A. C., Bauerfeind, K. C., Granone, L. I., Arimi, A., Megatif, L., Dillert, R., ... & Bredow, T. (2020). Photo electrochemistry of ferrites: theoretical predictions vs. experimental results. *Zeitschrift für Physikalische Chemie*, 234(4), 719-776.
13. Sharshembiev, K., Yoo, S. M., & Elmahdi, E. (2021). Protocol misbehavior detection framework using machine learning classification in vehicular Ad Hoc networks. *Wireless Networks*, 27(3), 2103-2118.
14. Simon Haykin, “**Neural Networks and Learning Machines**”, Edition, Prentice-Hall, Pearson Education, 2009.