

التنبؤ بشدة خطورة الحوادث المرورية في مدينة اللاذقية باستخدام تقنيات الذكاء الصناعي

الدكتورة شذى ابراهيم أسعد*

□ الملخص □

يشكل ارتفاع معدل الإصابات الناجمة عن حركة المرور على الطرق مشكلةً صحيةً عامةً متنامية في مختلف أنحاء العالم، واستناداً إلى تقرير لمنظمة الصحة العالمية، فإنَّ الإصابات الناجمة عن حوادث المرور بعد عام 2020 سوف تكون السبب الرئيسي الثالث للوفيات في العالم. لا تتشأ الحوادث بطريقة عشوائية بحتة، بل يتأثر حدوثها بالعديد من العوامل، مثل الظروف المادية للسائقين، وأنواع السيارات، وسرعة القيادة، وحالة المرور، وهندسة الطرق، والطقس، ومن دراسة سجلات الحوادث التاريخية وبياناتها، يمكننا فهم العلاقات (التي قد تكون سببية) بين هذه العوامل وبين حوادث الطرق، والتي من شأنها أن تسمح لنا بدورها ببناء متنبئ بالحوادث، لتقدير عدد الحوادث والوفيات والإصابات.

تمَّ التوصل في البحث إلى وضع نموذج رياضي للتنبؤ بشدة الإصابات الناجمة عن الحوادث المرورية في مدينة اللاذقية، يعتمد على عدد من العوامل المتعلقة بالحوادث المرورية، وأما الهدف الرئيسي فهو تخفيض عدد الحوادث المرورية المتوقعة مستقبلاً على الشوارع الرئيسية في المدينة، حيث تمَّت الدراسة على شوارع مختلفة فيها من حيث أهميتها ومن حيث عدد الحوادث المرورية المسجلة عليها، ومن حيث تنوع خصائصها هندسياً، وذلك من أجل الإلمام الكافي بظروف الحركة المرورية في المدينة اعتماداً على أسباب مختلفة.

تم الاعتماد على برنامج MATLAB والأدوات الملحقة به (nftool) The Neural Network Fitting Tool نظراً لكفاءته العالية في مجال التنبؤ، وعلى خوارزمية (LM) Levenberg–Murquardt ذات الانتشار العكسي للخطأ، حيث تعد خوارزمية تدريب سريعة لشبكة ذات حجم قابل للتحديث وذات ذاكرة مختزلة، ويمكن الاستفادة منها في التدريبات التي تتطلب بيانات ضخمة.

الكلمات المفتاحية: التنبؤ - الإصابات - نموذج - الحوادث المرورية - الذكاء الصناعي

*أستاذ مساعد - قسم هندسة المواصلات والنقل - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية

Predicting the severity of traffic accidents in Lattakia using artificial intelligence techniques

Dr. Shaza Assaad*

□ Abstract □

The high rate of road traffic injuries is a growing public health problem worldwide, according to a WHO (World Health Organization) report, road traffic injuries by 2020 will be the third leading cause of death in the world. Accidents do not arise in a purely random manner, but are affected by many factors, such as physical conditions of drivers, types of cars, speed of driving, traffic condition, road engineering and weather. From studying historical accident records and data, we can understand the (potentially causal) relationships between these factors and road accidents, which, in turn, would allow us to build a predictor of accidents, to estimate the number of accidents, deaths and injuries.

A mathematical model has been developed in this research for predicting of traffic accidents severity in the city of Lattakia, based on a number of external factors, which are related to traffic accidents data. As for its main goal, it is to reduce the number of traffic accidents expected in the future on the main streets in the city, as the study was conducted on various arterial streets in them in terms of their importance and in terms of the number of traffic accidents recorded on them, and in terms of the diversity of their engineering characteristics, in order to have sufficient familiarity with the traffic conditions in the city for various reasons.

MATLAB has been relied upon, And The New Network Attached Tools due to its high efficiency in forecasting, and on the Levenberg-Murquardt algorithm with reverse error diffusion, a fast training algorithm is developed for a network of an updated size, and it has a reduced memory, and they can be used for exercises that require substantial data.

Key words: Prediction, severity, model, traffic accidents, Artificial intelligence.

*Lecturer at Transportation Engineering Department – Civil Engineering Faculty - Tishreen University – Lattakia – Syria.

مقدمة:

في عالم يلقي فيه أكثر من مليون شخص حتفهم، ويُصاب أكثر من 50 مليوناً آخرين سنوياً في حوادث المرور على الطرق، تبرز ضرورة تضافر جهود المؤسسات والهيئات العالمية، للتصدي لحوادث المرور باعتبارها مشكلة عالمية، حيث أنّ أكثر من نصف ضحايا حوادث المرور في سن العمل. وتتسبب حالات الوفاة والإصابات الناجمة عن حوادث المرور في جميع أنحاء العالم، في تكلفة سنوية تصل إلى مئات المليارات من الدولارات، بالإضافة إلى التسبب في معاناة بشرية لا حصر لها بسبب الحوادث.

في البلدان منخفضة ومتوسطة الدخل، تتجاوز تلك التكلفة قيمة المساعدات التنموية التي يتلقونها [1]، حيث تشير الإحصاءات المرورية، بأنّ نسبة الوفيات والإصابات من جزاء الحوادث المرورية المسجلة بالدول العربية، تُعد بصفة عامة مرتفعةً بالمقارنة مع الدول المتقدمة، وهذا يُحتّم ضرورة إعداد استراتيجيات للسلامة المرورية وتضافر الجهود، من أجل التصدي لتلك الحوادث، كمسؤولية جماعية مشتركة تقع على عاتق مختلف فئات المجتمع، وكذلك الأجهزة والمؤسسات الحكومية وغير الحكومية، وبحسب تقرير للاسكوا عام 2016، فإنّ الحوادث المرورية كانت سبباً بوفاة 1.35 مليون شخصاً حول العالم، وعانى 50 مليون شخصاً من الإصابات، كما وبيّنت الإحصائيات المسجلة أنّ الفئة العمرية الأبرز والتي لاقت حتفها بسبب حوادث المرور، كانت الأشخاص الذين تتراوح أعمارهم بين (5-29) سنة، ولذلك فإنّ للسلامة على الطرق أهمية اجتماعية، واقتصادية، وتنموية وصحية على المستوى العالمي، ولأنّ عدد السيارات على الطرق في تزايد مستمر في الكثير من البلدان، فقد تتفاقم المشكلة بشكل أسرع، وبالتالي سيكون هناك حاجة ملحة لبذل المزيد من الجهد، للحدّ من هذه الوفيات والإصابات التي يمكن التقليل منها أو تفاديها.

يُعتبر التنبؤ بالحوادث هو أحد أهم جوانب السلامة على الطرق، حيث يمكن التنبؤ بالحادثة قبل وقوعه فعلاً، ومن ثمّ يمكن اتخاذ التدابير الوقائية لتجنبه أو للتقليل من شدة خطورته. ولهذا الغرض، تحظى نماذج التنبؤ بالحوادث بشعبية في تحليل السلامة على الطرق، ويستخدم الذكاء الصناعي في العديد من التطبيقات، وخاصةً عندما لا تكون النتائج والبيانات واحدة طوال الوقت، أو عندما تتأثر بحدوث تغيرات عشوائية. تشكّل حوادث الطرق نسبة كبيرة من عدد الإصابات الخطيرة المبلّغ عنها كل عام، ومع ذلك، كثيراً ما يكون من الصعب تحديد الظروف المحددة

التي تؤدي إلى مثل هذه الأحداث، مما يزيد من صعوبة معالجة المعنيين في الإدارة المحلية لمشكلة حوادث الطرق وشدتها، وقد أدى تنفيذ التدخلات الفعالة في البلدان المرتفعة الدخل، إلى تخفيف وتقليل حوادث المرور ومشاكل الإصابات. ولكن هذه المشكلة تتطلب اهتماماً خاصاً في البلدان ذات الدخل المنخفض والمتوسط، وسوف ترتفع الوفيات والإصابات الناجمة عن حركة المرور بنسبة تصل إلى 80% بين عامي 2000 و2020، استناداً إلى معلومات التنبؤ المنقذة في البلدان ذات الدخل المنخفض والمتوسط، وباستخدام تقييم اتجاهات البيانات وأساليب التنبؤ، يمكن أن يحسن ذلك الاتصال بين العلماء وصانعي السياسات، وأن يؤدي في نهاية المطاف إلى تحسين التخطيط واتخاذ القرارات، كما يمكن أن توفر المعلومات التنبؤية عن وفيات الحوادث معلومات هامة عن التغييرات المقبلة في اتجاهات الحوادث.

أثارت النماذج الإحصائية أو الطريقة الإحصائية للتنبؤ بتقييم تأثير مختلف العوامل ومتغيراتها على معدل الحوادث، مما أدى إلى تقييم كفاءة التدابير المقترحة لتحسين السلامة على الطرق، ولكن تسعى حالياً العديد من الحكومات العالمية لتوظيف تطبيقات الذكاء الصناعي في مجال مراقبة الطرق والإشارات الضوئية وممرات المشاة، بهدف وضع آليات وقائية للتنبؤ بالحوادث المرورية والازدحام المروري، ويهدف تعزيز السلامة العامة على الطرقات. ويتم العمل على دراسة وتطبيق جميع الوسائل التحسينية المتاحة لضمان توفير عوامل السلامة العامة للطرقات، حيث تساهم الحلول التقنية والذكاء الآمن في خفض معدلات الحوادث والوفيات الناتجة عنها، وتزيد من مستويات الأمن والسلامة وانسيابية الحركة على الطرقات.

أهمية البحث وأهدافه:

تأتي أهمية البحث في تقديم مساهمة كبيرة لتحسين وضبط سلامة المرور على شوارع مدينة اللاذقية، مما سيساعد في وضع أسس للتخطيط المستقبلي لها، كما أن استخدام منهج الشبكات العصبونية الصناعية في التنبؤ، يُعدّ من الأساليب الحديثة التي يتم اعتمادها في مجال السلامة المرورية، حيث أنّ القاعدة الأساسية للشبكات العصبونية الصناعية تكمن في أنّها ذات تركيب ديناميكي، يتيح في المستقبل تحديثاً مستمراً لها ببيانات جديدة، وذلك بهدف الوصول إلى نتائج أدقّ وأحدث، كما يهدف البحث أيضاً إلى بناء نموذج للتنبؤ بشدة الإصابات الناجمة عن الحوادث المرورية، باستخدام الشبكات العصبونية الصناعية على الطرق المدينية، لتقدير الأضرار الناجمة عن الحوادث المرورية، وبالتالي وضع منهجية للتقليل من شدة خطورتها. يمكن أن توفر

النتائج الدقيقة لتحليل البيانات المتعلقة بالحوادث، معلومات حاسمة لسياسة الوقاية من الحوادث على الطرق.

طرائق البحث ومواده:

لقد تمّ التوجه إلى استخدام طرق الذكاء الصناعي في الآونة الأخيرة، وهو قطاع علمي تُستخدم أبحاثه للوصول إلى مرحلة يقوم فيها الكمبيوتر بأعمال تشابه ما يفعله العقل البشري، مثل الأنظمة الخبيرة والنظام الضبابي والشبكات العصبونية الصناعية، حيث أثبتت هذه الطرق دقتها في مجال التنبؤ بشدة الإصابات الناجمة عن الحوادث المرورية، وفي القدرة على نمذجة جميع المتغيرات التي تسهم في وقوع الحوادث. ولقد أُجريت العديد من الدراسات لبناء وتطوير نماذج للتنبؤ بالحوادث المرورية، حيث قام الباحثون (Moghaddam, F. et al. 2011) في مدينة طهران الإيرانية، بتدريب عدة نماذج للشبكات العصبونية الصناعية باستخدام برمجية Neurosolutions5 للتنبؤ بالحوادث المرورية، وكان النموذج الأفضل هو النموذج ذو خوارزمية تدريب MLP (شبكة حسية متعددة الطبقات)، وقد خلُصت الدراسة إلى أنّ أهم العوامل التي لعبت دوراً أساسياً في حساسية النموذج التنبؤي، كانت عدم تقدير المسافة الجانبية بشكل دقيق، وعرض الطريق، ونسبة الدراجات الهوائية والنارية في تركيب التيار المروري [2].

كما قام (Kunt, M. et al. 2011) في تركيا بتطوير وتطبيق نماذج الذكاء الصناعي للتنبؤ بالإصابات الناجمة عن الحوادث المرورية على الطرق الحرة، بعد أن استخدم الباحثان نماذج الشبكات العصبونية الصناعية ANN والنماذج المعتمدة على النظرية الجينية GA، وقد تمّ اعتماد مدخلات تشمل عمر السائق وجنسه، استخدام السائق لحزام الأمان، نوع المركبة وحالة الطقس، وسطح الرصف ومعدل السرعة، وكيفية وقوع الحادث، والغزارة المرورية، وتمّ بناء النموذج باستخدام بيانات 1000 حادث تمّ تسجيله عام 2007 على طريق Tehran-Ghom، وبعد مقارنة نتائج النموذجين اعتماداً على قيم R, MSE, SSE, MAE، خلُصت الدراسة إلى أنّ نماذج ANN هي الأفضل للتنبؤ بالحوادث المرورية، حيث كانت قيمة الارتباط 87% [3].

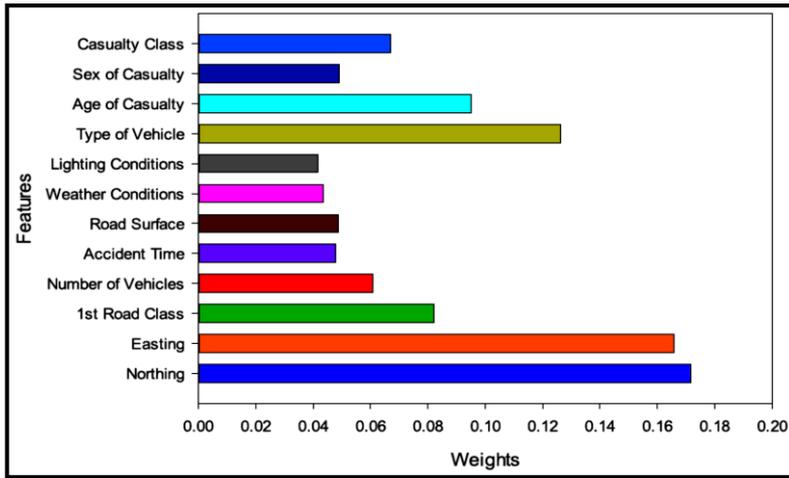
وفي الهند أعدّ الباحث Kumar, C. et al. عام 2014 دراسة لنمذجة الحوادث المرورية على الطرق السريعة خارج المدينة، باستخدام الشبكات العصبونية الصناعية ونماذج التنبؤ الإحصائية التقليدية، وأكّدت النتائج التي توصل إليها الباحث، بأنّ نماذج التنبؤ بالحوادث المرورية باستخدام الشبكات العصبونية هي أكثر دقةً من نماذج التنبؤ الإحصائية التقليدية [4].

كما وطوّرت (Alkherer, Sh. et al. 2016) نموذج تنبؤي بالأضرار الناجمة عن الحوادث المرورية باستخدام بيانات 5973 حادثاً مرورياً سُجِّل في إمارة أبو ظبي خلال الأعوام (2008 وحتى 2013)، باستخدام تعلّم الآلة (ML)، حيث تمّ بناء النموذج بالاعتماد على 16 مدخل، كما وتمّ تصنيف الإصابات ضمن أربع فئات (طفيفة، متوسطة، شديدة، وفاة)، وخُلصت الدراسة إلى أنّ نتائج الشبكة العصبونية الصناعية كانت أدقّ بنسبة 74.6%، وبالمقابل لم تتجاوز دقة نتائج النموذج المطوّر باستخدام Probit model 59.5%. [5]

وفي الولايات المتحدة الأمريكية، درس الباحث (Abdulhafedh, A. 2016) تردّدات الحوادث المرورية على الطرق السريعة، حيث قدّم نموذجاً لتحديد المناطق الخطيرة والمعرّضة لوقوع الحوادث، والذي يساعد منظمات وهيئات المواصلات لإيجاد مقاييس ومعايير لتفادي وقوع الحوادث، وقد كان الهدف من الدراسة تحليل ومقارنة نتائج التنبؤ بالحوادث المرورية بين نموذج انحدار بواسون، ونموذج الانحدار السلبي ذي الحدين، ونموذج الشبكات العصبونية الصناعية لتحليل الحوادث، بين عامي 2008-2012 للطريق السريع I-90 بولاية مينيسوتا، في الولايات المتحدة الأمريكية. بعد مقارنة نتائج كل نموذج توصلت الدراسة إلى أنّ نموذج الشبكات العصبونية الصناعية هو النموذج الفعّال مقارنةً بطرق التنبؤ الأخرى [6].

وفي الصين، قام (Zheng, M et al 2019) ببناء نموذج للتنبؤ بالإصابات الناجمة عن الحوادث المرورية باستخدام convolutional neural network (CNN)، ويوضّح الجدول (1) أوزان مدخلات النموذج التنبؤي المؤثرة على شدة الإصابات الناجمة عن الحوادث المرورية. [7]

الجدول (1): أوزان مدخلات النموذج التنبؤي



وفي بريطانيا قام الباحثون (Assi, Kh. et al 2020)، بتطوير نماذج للتنبؤ بشدة الإصابات الناجمة عن الحوادث المرورية، باستخدام تعلم الآلة (Machine Learning (ML)، حيث تم تطوير أربع نماذج تنبؤية:

(feed-forward neural networks (FNN), support vector machine (SVM), fuzzy C-means clustering based feed-forward neural network (FNN-FCM), and fuzzy c-means).

تم اعتماد 15 مدخل لبناء كل نموذج، وتم ترميزها كما هو موضح في الجدول (2)، [8].

الجدول (2): ترميز مدخلات نماذج التنبؤ

Input Variables	Data Type	No. of Categories
Vehicle attributes		
Number of vehicles involved	Numeric	-
Vehicle type	Nominal	12
Road condition attributes		
Road type	Nominal	5
Junction type	Nominal	9
Junction control	Nominal	5
Light	Nominal	5
Weather	Nominal	9
Road surface condition	Nominal	7
Area type	Nominal	2
Speed limit	Numeric	-
Road class	Nominal	6
Crash attributes		
Number of casualties	Numeric	-
Day of the week	Numeric	7

تُعرّف الشبكات العصبونية الصناعية بأنها عبارة عن نظام لمعالجة المعلومات بشكل يشابه ويحاكي طريقة عمل الجملة العصبية البيولوجية للإنسان، لأنها تتّصف بنفس خصائصها التي تعتمد على فكرة تخزين المعلومات وتعلّمها، والاستفادة منها لاحقاً.

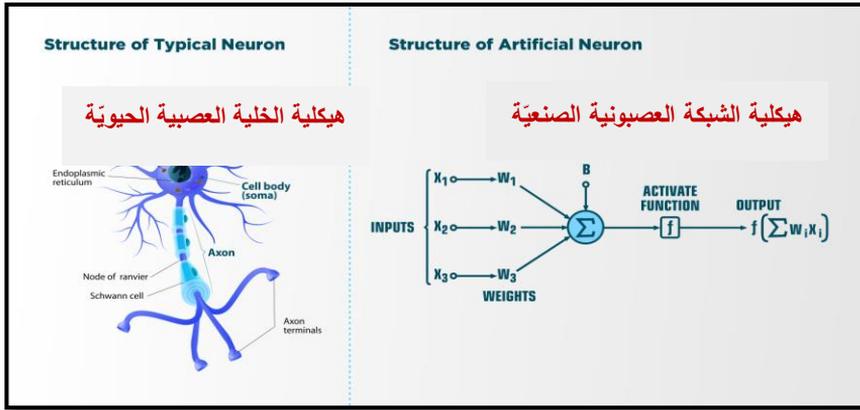
وقد نشأ الاهتمام العام بالشبكات العصبونية الصناعية بسبب الخصائص المميزة لها، وبسبب قدرتها على تجاوز محدّدات الحلّ التقليدي، والتي من أهمّ خصائصها، تميّزها بخاصية التوازي (Parallelism)، وهو أساس الشبكات العصبونية الصناعية، إذ أنّ كل العصبونات في الشبكة تعمل بتزامن، أي أنّ التوازي يمثّل قدرة الشبكات على معالجة البيانات بسرعة عالية جداً، مهما كانت ضخامة تلك البيانات.

يمكن للشبكات العصبونية أن تتيح لنفسها تعلّم الحالة غير الخطية (non – linear Behavior)، أو أن تتيح لنفسها تعلّم السلوك الديناميكي (Dynamic Behavior)، من خلال المعطيات المقاسة [9]، وترتبط الخلية العصبونية الصناعية المتكوّنة من مجموعة من العصبونات مع بعضها بواسطة ارتباطات موزونة، إذ أنّ كل عصبون هو عبارة عن عنصر معالجة (Process Element) يؤدي وظيفة ما، وينتج وحدة إخراج واحدة، ويوضّح الجدول (3) مقارنة بين مكوّنات الخلية العصبية الحيوية، وبين مكوّنات الخلية العصبونية الصناعية.

الجدول (3): مقارنة بين مكوّنات الخلية العصبية الحيوية ومكوّنات الوحدة العصبونية الصناعيّة

الخلية العصبونية الصناعيّة	الخلية العصبية الحيويّة
طبقة المدخلات (Input layer)	العقد العصبية (synapses)
الارتباطات الوزنية (Weight Connections)	الألياف العصبية للمدخل (Dendrites)
تجميع المدخلات الموزونة وتفعيلها (Summation and Activation Zone)	جسم الخلية (Soma)
المخرجات (Output layer)	الليف العصبي للمخرج أو المحور (Axon)

كما يوضّح الشكل (1) مقارنة بين هيكلية الخلية العصبونية الحيوية والشبكة العصبونية الصناعيّة.



الشكل (1): مقارنة بين الخلية العصبونية الحيوية والشبكة العصبونية الصناعية

كما وتُصنّف الشبكات العصبونية الصناعية تبعاً لطريقة عملها إلى صنفين:

- i. الشبكات العصبونية الصناعية ذات التغذية الأمامية Feed forword ANNs: أي انتشار البيانات الداخلة إلى الشبكة باتجاه الأمام دائماً من طبقة الإدخال باتجاه طبقة الإخراج، ويُعدّ هذا النوع من الشبكات العصبونية الصناعية الأكثر شيوعاً.
- ii. الشبكات العصبونية الصناعية ذات التغذية الراجعة Feedback ANNs: حيث تُعاد البيانات الخارجة من الشبكة، ويحوّل اتجاهها لتصبح مدخلات، ولهذا فإنّ المخرجات تعتمد على المدخلات والمخرجات، ويُسمّى هذا النوع من الشبكات بالشبكات المرتدة (Recurrent Network).

ويتمّ تدريب الشبكات العصبونية الصناعية بواسطة خوارزميات متخصصة، تدعى خوارزميات التدريب (Training Algorithms)، التي تتولّى تعديل أوزان الشبكة لتحسين أدائها، ولتقليل إشارة الخطأ فيها (Error Signal)، استناداً إلى مقياس معلوم (معدّل مربع الخطأ MSE في هذه الدراسة)، للوصول إلى تحديد قيم عددية لأوزان الشبكة، بحيث يمكن من خلالها تحقيق نتيجة مقارنة النتائج المرصودة. ويمكن تصنيف طرائق تدريب الشبكات العصبونية الصناعية في ثلاثة أنواع رئيسية:

✓ خوارزميات التدريب تحت الإشراف: (Supervised Learning Algorithms)

في هذه الطريقة من المفترض وجود معلّم أو مراقب خلال عملية التدريب، حيث تُدرّب الشبكة في هذه الخوارزمية على سلسلة من المدخلات التي ترافقها مخرجات مرتبطة بها، إذ تُعدّل أوزان

الشبكة اعتماداً على الفرق بين المخرجات الحقيقية (Output) والمخرجات المأمولة أي الهدف (Target)، ويُمثل الفرق (Output- Target) إشارة الخطأ، حيث تُعاد تغذية الشبكة به، لغرض تحويل أوزان الشبكة والحصول على أقل خطأ ممكن، وتعدّل إشارة الخطأ المتحصلة بعد كل دورة تدريب (epochs)، إلى أن تصل قيمة الخطأ أو عدد محاولات التدريب إلى القيمة المحددة مسبقاً من المدرب، وعندئذ يتوقف التدريب، وتعدّ هذه الطريقة من أكثر الطرائق شيوعاً في تدريب الشبكات.

✓ خوارزميات تدريب التقوية: (Reinforcement Learning Algorithms)

وفي هذه الطريقة من المفترض أيضاً وجود المعلم، لكن الجواب الصحيح لا يكون في الشبكة، وبدلاً من ذلك تمثل الشبكة فقط بمؤشر، فيما إذا كان جواب المخرج صحيحاً أو خاطئاً.

✓ خوارزميات التدريب دون إشراف: (Unsupervised Learning Algorithms)

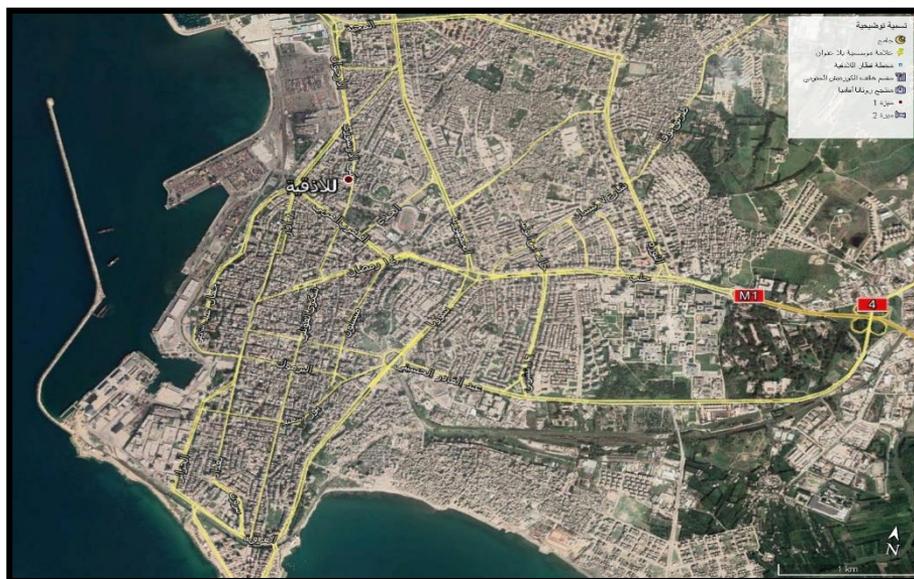
في هذه الطريقة ليس لدى الشبكة تغذية عكسية على الجواب الصحيح أو المرغوب به، وليس هناك معلم مندوب يمثل الأشكال المرغوبة، لذلك يجب على النظام أن يتعلم، بواسطة اكتشاف وملاءمة الخصائص في أشكال المدخلات، وتتلخص هذه الطريقة بتدريب سلسلة من متجهات الإدخال دون وجود متجهات الإخراج [10].

التحليل والمناقشة:

لاستكشاف العوامل التي تساهم في شدة إصابات السائقين في حوادث المرور، كانت نماذج الانحدار البارامتريّة، مثل نماذج الانحدار المتعدد الجنسيات (MNL) أو نماذج الانحدار وفق الاحتمالية المطلوبة، هي التي تُطبّق عادةً لسنوات عديدة، غير أنّ لهذه النماذج البارامتريّة افتراضات نموذجية خاصة بها وعلاقات أساسية محددة سلفاً بين المتغيرات المعتمدة والمستقلة، وإذا انتهكت هذه الافتراضات، يمكن أن تودّي النماذج إلى تقدير خاطئ لاحتمال الإصابة. تمّ الاعتماد في هذا البحث على الشبكات العصبونية الصناعية في الماتلاب MATLAB لبناء النموذج التنبؤي، بشدة الأضرار الناجمة عن الحوادث المرورية في مدينة اللاذقية، حيث تُعتبر أداة فعّالة للتعامل مع الظواهر العشوائية، وتمّ الاعتماد من خلال الدراسات السابقة على تحديد الطريقة المناسبة للنمذجة، والمتحوّلات الخاصة بموديل التنبؤ.

للوصول إلى الهدف المطلوب من الدراسة، فقد تطلّب الأمر تجميع مجموعة واسعة جداً من البيانات المتعلّقة بالحوادث المرورية، حيث تمّ إجراء الدراسة على شوارع مختلفة التصنيف وظيفياً ومتنوّعة هندسياً في مدينة اللاذقية، ويوضح الشكل (2) الموقع العام للمدينة وشبكة الشوارع فيها، كما يوضّح الجدول (4) الشوارع الرئيسية التي شملتها الحوادث المرورية، والتي تمّ تجميع بياناتها لمدة 5 أعوام (2014-2015-2016-2017-2018).

لقد تمّ تجميع البيانات المتعلقة بالحوادث المرورية لـ 32 شارعاً من الشوارع الرئيسية في مدينة اللاذقية، من قسم شرطة المرور في محافظة اللاذقية، وقد بلغ عددها 2436 حادثاً، تمّ تفرّيقها وتحليل بياناتها من حيث تاريخ الحادث ونوعه والأشخاص المشاركين به، بالإضافة إلى شدّة الإصابات المسجلة في التقارير، وتمّ ترتيب البيانات ورقمنتها ضمن بيئة برمجية في برنامج Microsoft Excel، لبناء النموذج باستخدام أداة الشبكات العصبونية الصناعية في برنامج الماتلاب MATLAB.



الشكل (2): صورة لمدينة اللاذقية (موقع عام)

الجدول(4): البيانات الهندسية للشوارع المدروسة في مدينة اللاذقية

اسم الشارع	الحركة	اتجاه الشارع	الطول / متر	السرعة المسموحة، Km/h	عدد الحارات	عرض الشارع/ متر
بغداد	اتجاه واحد	جنوب - شمال	1050	45	3	12
8 آذار	اتجاه واحد	جنوب - شمال	1275	45	5	20

التنبؤ بشدة خطورة الحوادث المرورية في مدينة اللاذقية باستخدام تقنيات الذكاء الصناعي

الفوتلي	اتجاه واحد	شمال - جنوب	362	45	3	12
عمر بن الخطاب	اتجاه واحد	شمال - جنوب	1837	45	3	12
المغرب العربي	اتجاهين	شرق - غرب	903	45	6	24
14 رمضان	اتجاهين	شرق - غرب	840	45	3	12
أنطاكية	اتجاه واحد	جنوب - شمال	669	45	3	12
أبو فراس	اتجاه واحد	شمال - جنوب	472	45	3	12
العروبة	اتجاهين	شمال - جنوب - غرب	2577	45	6	24
بيروت	اتجاهين	جنوب - غرب	536	45	6	24
اليرموك	اتجاه واحد	شرق - غرب	395	45	3	12
عبد الرحمن الغافقي	اتجاه واحد	غرب - شرق	992	45	3	12
القدس	اتجاه واحد	شرق - غرب	365	45	4	15
بور سعيد	اتجاهين	شمال - جنوب - غرب	1505	45	6	24
جمال عبد الناصر	اتجاهين	شمال - جنوب	1959	45	6	24
سوريا	اتجاهين	شمال - جنوب	788	45	8	28
نديم حسن	اتجاهين	جنوب - شمال	680	45	6	24
المدينة المنورة	اتجاهين	شرق - غرب	446	45	6	24
عبد القادر الحسيني	اتجاهين	شرق - غرب	1090	60	8	30
16 تشرين	اتجاهين	شمال - جنوب	1050	45	6	20
حلب	اتجاهين	شرق - غرب	1290	45	8	30
طرابلس	اتجاهين	شرق - غرب	320	45	6	28
الجمهورية	اتجاهين	شمال - جنوب	2190	45	6	30
الثورة	اتجاهين	شمال - جنوب	1920	60	8	40
الشيخ صالح العلي	اتجاهين	شرق - غرب	1610	60	6	32
المحبة	اتجاهين	شرق - غرب	400	45	6	32
عسان حرفوش	اتجاهين	شمال - جنوب	1260	45	6	28
زكي الأرسوزي	اتجاهين	شمال - جنوب	1300	45	6	24
الأرجوان	اتجاهين	شمال - جنوب	780	60	6	22
الجزائر	اتجاهين	شمال - جنوب	350	45	6	28
السابع من نيسان	اتجاه واحد	جنوب غربي	1320	45	3	10
علي بن أبي طالب	اتجاه واحد	شرق - غرب	360	45	3	12

يبين الجدول (5) نموذجاً عن تفريغ البيانات ضمن الجداول لأحد هذه الشوارع (شارع الجمهورية)، لسنة واحدة من السنوات 2014، كما يبين الجدول (6) تفريغ بيانات الحوادث من حيث الموقع ونوع المركبات وشدة الإصابات كنموذج من عام 2018.

الجدول (5): نموذج عن تفريغ بيانات الحوادث يبين فيه العدد الإجمالي للحوادث على كل شارع وفي كل عام

عدد الحوادث الكلية سنوياً	عدد الحوادث الكلية	الأضرار			كيفية وقوع الحادث				جنس السائق			تاريخ وقوع الحادث		الموقع
		وفاة	جسدية	مالية	تدهور	صدم سيارة أثناء ركابها	صدم مشاة	اصطدام	أنثى - أنثى	ذكور - ذكور	أنثى - ذكور	السنة	الشهر	
99	9	0	3	7	1	1	2	5	0	2	7	2014	1	شارع الجمهورية
	12	1	1	10	1	1	2	8	0	2	10	2014	2	شارع الجمهورية
	8	0	3	6	0	1	2	5	0	1	7	2014	3	شارع الجمهورية
	9	0	2	7	0	0	2	7	0	0	9	2014	4	شارع الجمهورية
	5	0	0	5	0	2	0	3	0	0	5	2014	5	شارع الجمهورية
	9	1	1	8	0	2	1	6	0	0	9	2014	6	شارع الجمهورية
	7	0	1	6	0	1	1	5	0	0	7	2014	7	شارع الجمهورية
	8	0	3	8	0	0	0	8	0	0	8	2014	8	شارع الجمهورية
	7	0	3	5	0	0	4	3	0	0	7	2014	9	شارع الجمهورية
	8	1	1	6	0	1	2	5	0	1	7	2014	10	شارع الجمهورية
	8	0	1	7	0	0	1	7	0	1	7	2014	11	شارع الجمهورية
	9	0	3	8	1	0	1	7	0	0	9	2014	12	شارع الجمهورية

الجدول (6): نموذج عن تفريغ بيانات الحوادث يبين فيه نوع المركبة والموقع وشدة خطورة الحوادث

ملاحظات	كيفية وقوع الحادث	الأضرار						الموقع	نوع المركبة	تاريخ وقوع الحادث			
		اصطدام	صدم مشاة	صدم سيارة أثناء ركابها	تدهور	مالية	جسدية			وفاة	السنة	الشهر	اليوم
دوار المحطة	1	0	0	0	0	1	0	0	سوريا	سياحية - شاحنة	2018	2	13
إشارة البحرية	1	0	0	0	0	1	0	0	أوتوستراد الثورة	سياحية - ميكروباص	2018	2	15

التنبؤ بشدة خطورة الحوادث المرورية في مدينة اللاذقية باستخدام تقنيات الذكاء الصناعي

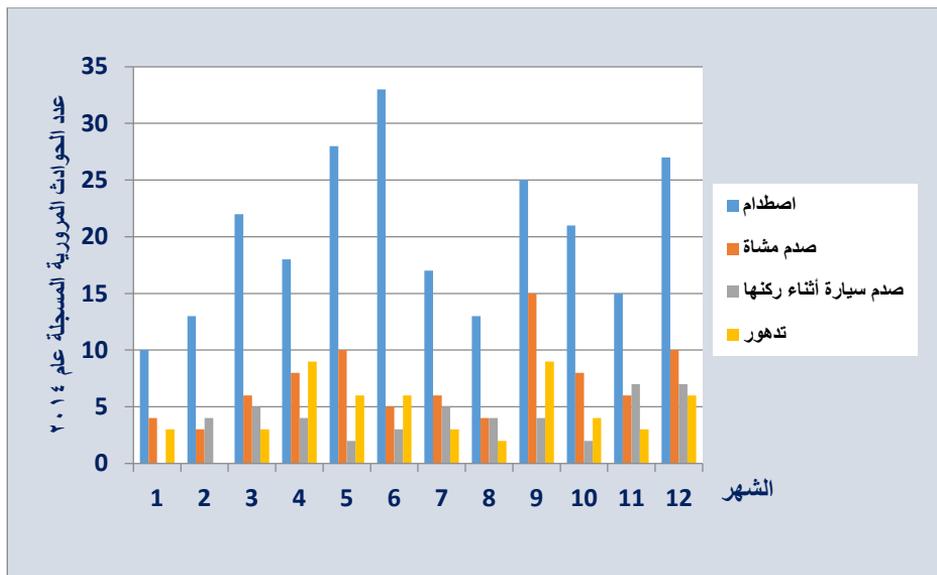
قرب كازية حيدرة	0	0	1	0	1	0	0	الجمهورية	سياحية	2018	2	18
أمام فرع الشرطة	0	1	0	0	0	1	0	الحسيني	سياحية	2018	2	18

من خلال تحليل بيانات الحوادث المرورية المسجلة للشوارع الرئيسية في مدينة اللاذقية للأعوام 2014 و 2015 و 2016 و 2017 و 2018، والمبيّنة في الشكل (3)، نلاحظ تفاوت وعشوائية هذه القيم، حيث سُجلت أعلى قيمة لعدد الحوادث المرورية المسجلة في المدينة عام 2014، بينما كان عدد الحوادث المسجلة عام 2017 أقلها، وهو 386 حادثاً مرورياً.



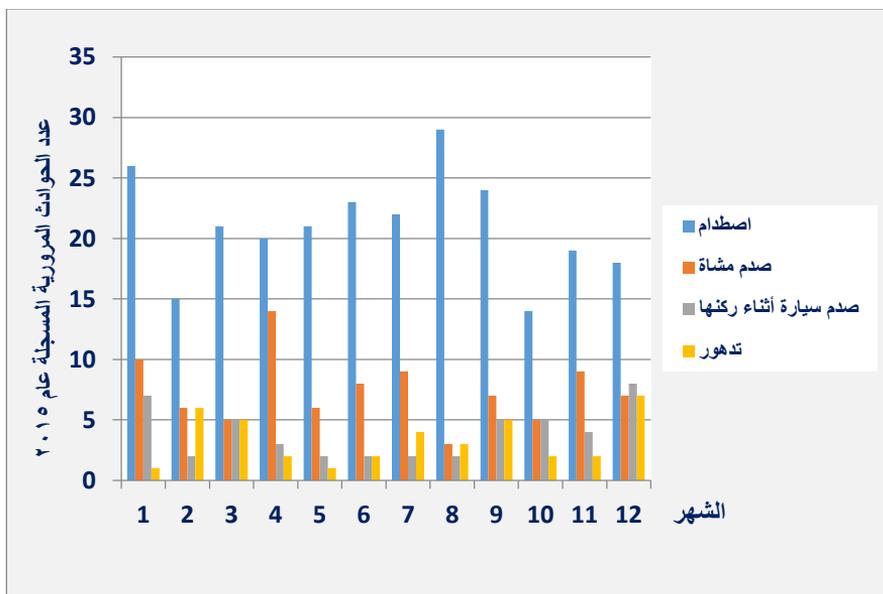
الشكل (3): عدد الحوادث المرورية المسجلة سنوياً على الشوارع الرئيسية في مدينة اللاذقية

كما ويبين الشكل (4) تصنيفات الحوادث المسجلة شهرياً لعام 2014 في مدينة اللاذقية، حيث بلغت أعلى قيمة لعدد حوادث الاصطدام المسجلة في شهري أيار وحزيران، إذ بلغ عدد الحوادث 28 حادثاً في شهر أيار، و 33 حادثاً في شهر نيسان، كما وبلغ عدد حوادث صدم المشاة المسجلة في شهر أيلول 15 حادثاً، وفي شهري نيسان وأيلول، وقد سُجلت أعلى قيمة لحوادث التدهور في المدينة، حيث بلغت 8 حوادث تدهور.



الشكل (4): الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2014

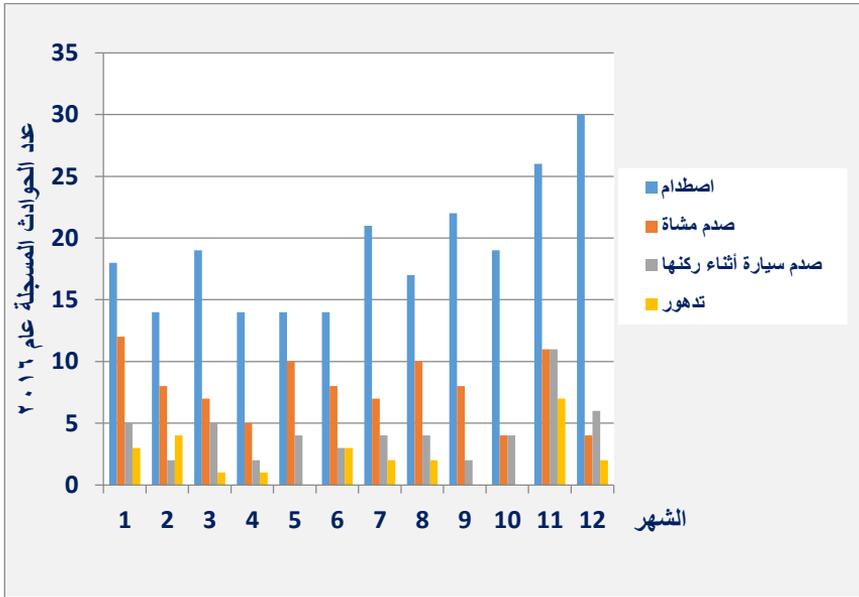
ويظهر الشكل (5) تصنيفات الحوادث المسجلة شهرياً لعام 2015 في مدينة اللاذقية، حيث بلغت أعلى قيمة لعدد حوادث الاصطدام المسجلة في شهر آب، كما وبلغت أعلى قيمة لعدد حوادث صدم المشاة المسجلة في شهر نيسان، وفي شهر كانون الأول سجلت أعلى قيمة لحوادث التدهور في المدينة، حيث بلغت 7 حوادث تدهور.



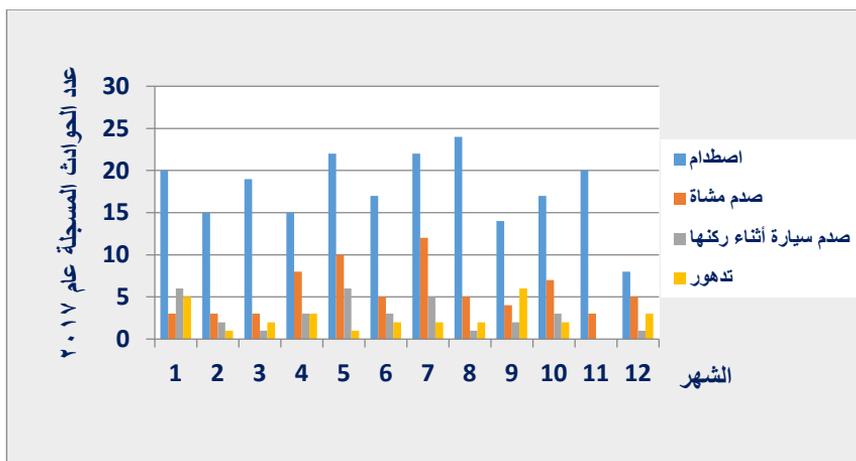
الشكل (5): الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2015

تظهر تصنيفات الحوادث المسجلة شهرياً عام 2016 في مدينة اللاذقية، أعلى قيمة لعدد حوادث الاصطدام المسجلة في شهر آب، كما وبلغت أعلى قيمة لعدد حوادث صدم المشاة المسجلة في شهر نيسان، وفي شهر كانون الأول سُجّلت أعلى قيمة لحوادث التدهور في المدينة، حيث بلغت 7 حوادث تدهور، كما هو مبين في الشكل (6).

ويبين الشكل (7) تصنيفات الحوادث المسجلة شهرياً لعام 2017 في مدينة اللاذقية، حيث بلغ عدد حوادث الاصطدام المسجلة في شهر آب 24 حادثاً، كما وبلغت أعلى قيمة لعدد حوادث صدم المشاة المسجلة في شهر تموز، وفي شهر أيلول سُجّلت أعلى قيمة لحوادث التدهور في المدينة، حيث بلغت 6 حوادث تدهور.

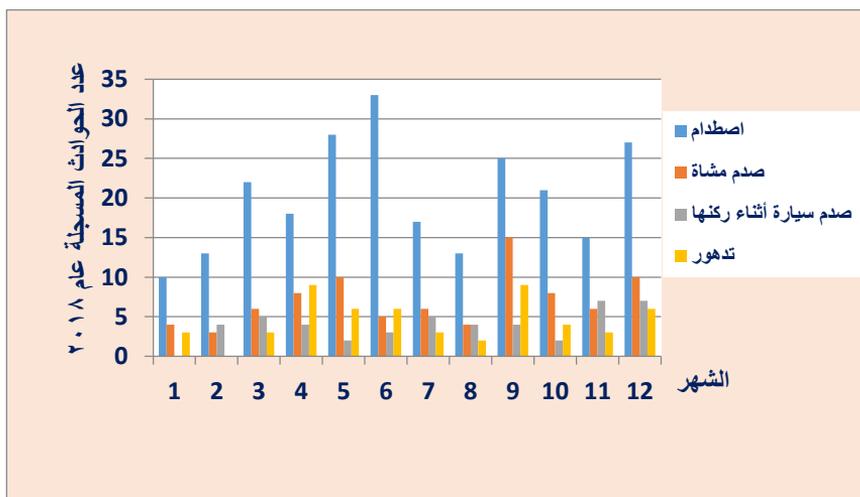


الشكل (6): الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2016



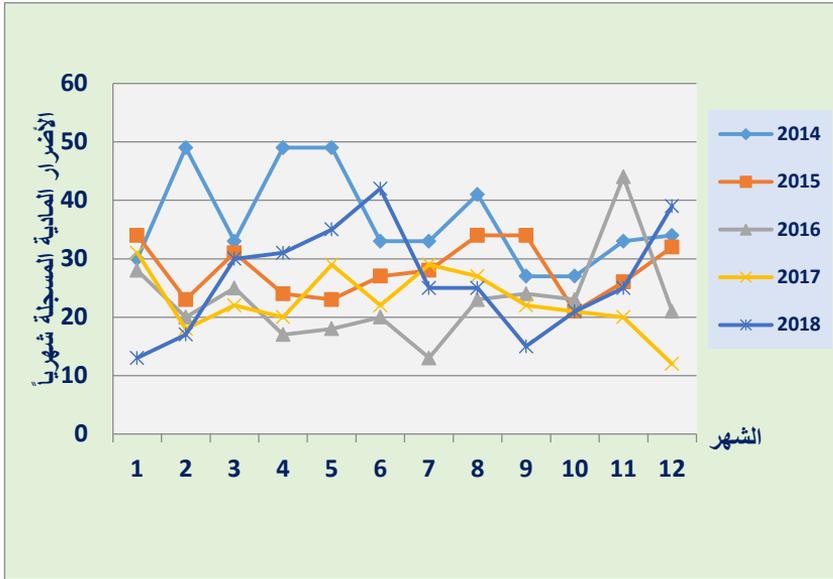
الشكل (7): الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2017

كما وتظهر تصنيفات الحوادث المسجلة شهرياً عام 2018 في مدينة اللاذقية، أعلى قيمة لعدد حوادث الاصطدام المسجلة في شهر آب، كما وبلغت أعلى قيمة لعدد حوادث صدم المشاة المسجلة في شهر نيسان، وفي شهر كانون الأول سُجلت أعلى قيمة لحوادث التدهور في المدينة، حيث بلغت 7 حوادث تدهور، كما هو مبين في الشكل (8).



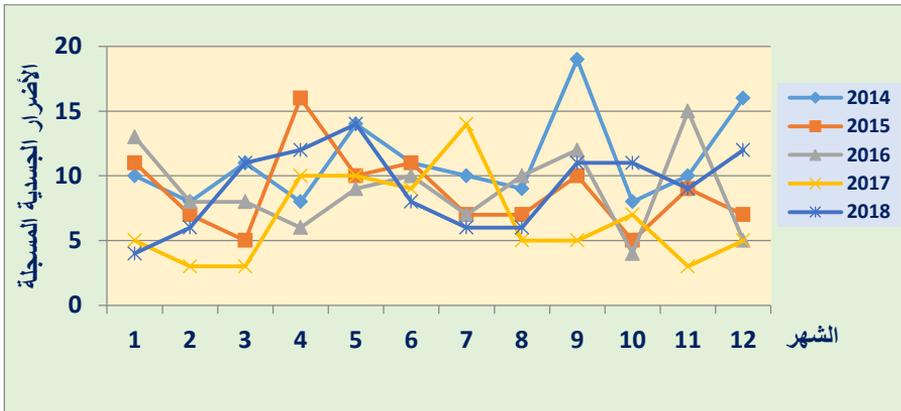
الشكل (8): الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2018

ومن خلال تحليل الأضرار المادية المسجلة شهرياً، نلاحظ عشوائية وتغير هذه القيم، حيث بلغت أعلى قيمة للأضرار المادية المسجلة في عام 2014 في شهر شباط ونيسان وأيار، بينما كانت أخفض قيمة لها في شهر كانون الأول ل عام 2017، كما هو واضح في الشكل (9).



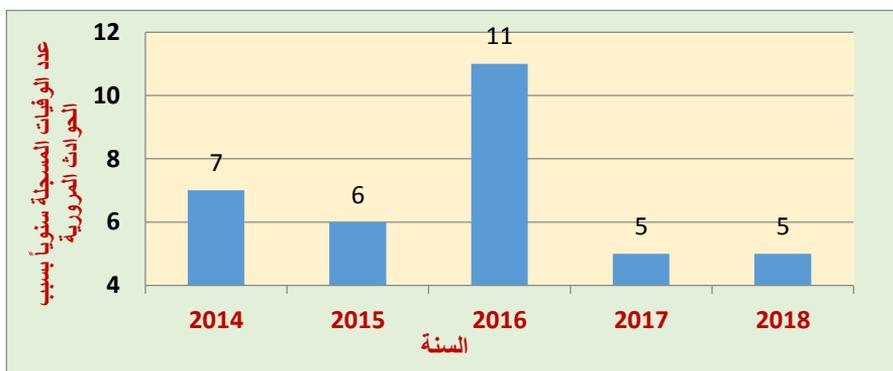
الشكل (9): الأضرار المادية الناجمة عن الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية

ويبين الشكل (10) الإصابات الجسدية المسجلة شهرياً في مدينة اللاذقية، حيث بلغت أعلى قيمة للإصابات الجسدية في شهر أيلول لعام 2014، بينما كانت أقل قيمة مسجلة للأضرار الجسدية في شهر تشرين الثاني لعام 2017.



الشكل (10): الأضرار الجسدية الناجمة عن الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية

ويبين الشكل (11) عدد الوفيات المسجلة في مدينة اللاذقية بسبب الحوادث المرورية، حيث بلغت أعلى قيمة للوفيات عام 2016.



الشكل (11): الوفيات الناجمة عن الحوادث المرورية في مدينة اللاذقية

- بناء النموذج التنبؤي باستخدام الشبكات العصبونية الصناعية:

لبناء النموذج التنبؤي بالأضرار الناجمة عن الحوادث المرورية في مدينة اللاذقية، باستخدام أداة الشبكات العصبونية الصناعية في برنامج MATLAB، وبعد أن تمّ تفريغ بيانات الحوادث المرورية المتوفرة لدى قسم شرطة المرور في مدينة اللاذقية، في الفترة الممتدة بين عامي (2014-2018)، فقد تمّ ترميز الحوادث ضمن بيئة برمجية في برنامج Microsoft Excel، كما هو موضح في الجداول (7)، (8)، (9)، (10)، علماً أنّ عام وقوع الحادث المروري تمّ إدخاله دون ترميز للأعوام 2014، 2015، 2016، 2017، 2018.

الجدول (7): ترميز أشهر السنة

الشهر	كانون الثاني	شباط	آذار	نيسان	أيار	حزيران	تموز	آب	أيلول	تشرين أول	تشرين ثاني	كانون أول
ترميز الشهر	1	2	3	4	5	6	7	8	9	10	11	12

الجدول (9): ترميز كيفية وقوع الحادث

الجدول (8): ترميز جنس السائق

ترميذه	جنس السائق
1	ذكر-ذكر
2	أنثى-ذكر

أثنى-أثنى	3
كيفية وقوع الحادث	ترميزه
اصطدام	1
صدم مشاة	2
صدم سيارة أثناء ركنها	3
تدهور	4

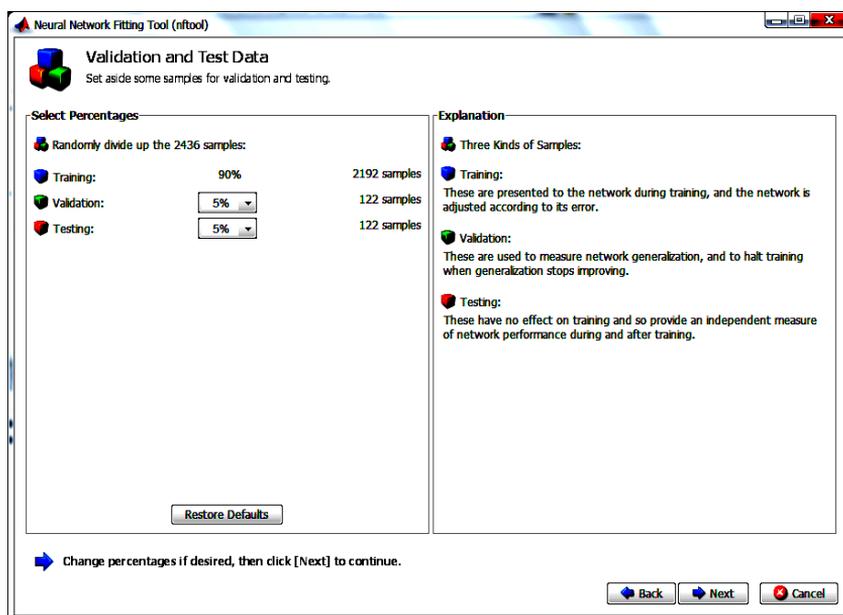
الجدول (10): ترميز الأضرار

الناجمة

الأضرار	ترميزه
مادية	1
جسدية	2
وفاة	3
مادية - جسدية	4

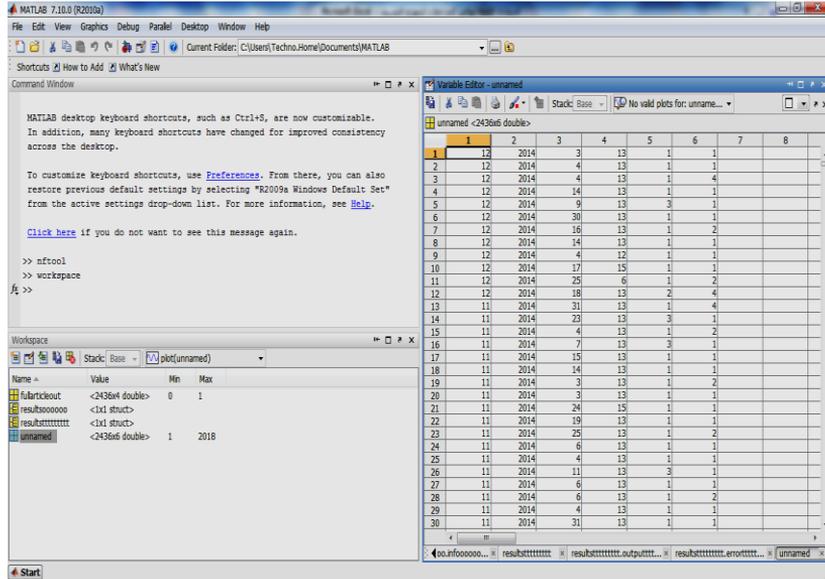
استخدم برنامج الماتلاب MATLAB وحزم الأدوات الملحقة به في عملية بناء الشبكات العصبونية الصناعية ANN وتدريبها، حيث أُجري عدد كبير جداً من التجارب على شبكات عصبونية ذات بنى مختلفة، من خلال التغيير في عدد العصبونات في الطبقة الخفية، وتوابع التفعيل المستخدمة في كل من الطبقة الخفية وطبقة الخرج للشبكة، وكذلك من خلال التغيير في الخوارزميات المستخدمة في تدريب الشبكة، وبالاستناد للدراسات المرجعية ومراقبة أداء الشبكة، ومن خلال مقارنة قيم متوسط مربعات الأخطاء MSE، ومعامل الارتباط R لكل نموذج، تمّ الاعتماد على نموذج الشبكات العصبونية الصناعية ANN من خلال The Neural (nftool) Network Fitting Tool، انتشار عكسي للخطأ Back-Propagation، مع خوارزمية التدريب Levenberg-Murquardt (LM)، حيث يبيّن الجدول (11) قيم R و MSE لأنماط المدخلات لمجموعة بيانات التدريب والتحقق والاختبار، بعد أن تمّ إدخال بيانات 2436 حادثاً مرورياً، كانت قد سُجلت بين عامي (2014 وحتى 2018)، والتي تمّ تقسيمها في ثلاث مجموعات، حيث استخدمت بيانات 2192 حادثاً لتدريب الشبكة، و122 حادثاً للتحقق من نتائجها، و122 حادثاً لاختبارها، كما هو موضح في الشكل (12)، علماً أنّ تحديد عدد العصبونات المخفية اللازمة لتدريب الشبكة، يُعتبر الجملة الأصعب في التدريب والبناء، بسبب عدم وجود طريقة عامة لإيجادها، لذا فإنّ هيكلية نماذج ANN يتمّ استقرارها بعد عملية

التجربة والخطأ (Trial and Error) ، وبعد مراقبة أداء الشبكة، حيث تمّ اعتماد هيكلية لشبكة عصبونية مع 6 مدخلات (شهر وقوع الحادث، السنة، اسم الشارع -الموقع-، نوع المركبة، جنس السائق، طبيعة الحادث)، و 4 مخرجات هي نوع الإصابة الناجمة عن الحادث المروري (مادية، جسدية، مادية-جسدية، وفاة) ، كما يبيّن الشكل (13) واجهة ترميز مجموعات بيانات الحوادث كمدخلات في أداة الشبكة العصبونية الصناعية في الماتلاب، وفي الجدول (11) نتائج تدريب نماذج الشبكات العصبونية الصناعية بعد عدد من تكرارات دورات التدريب.



الشكل (12): واجهة تقسيم مجموعات بيانات الحوادث المدخلة في أداة الشبكة العصبونية الصناعية في الماتلاب

التنبؤ بشدة خطورة الحوادث المرورية في مدينة اللاذقية باستخدام تقنيات الذكاء الصناعي

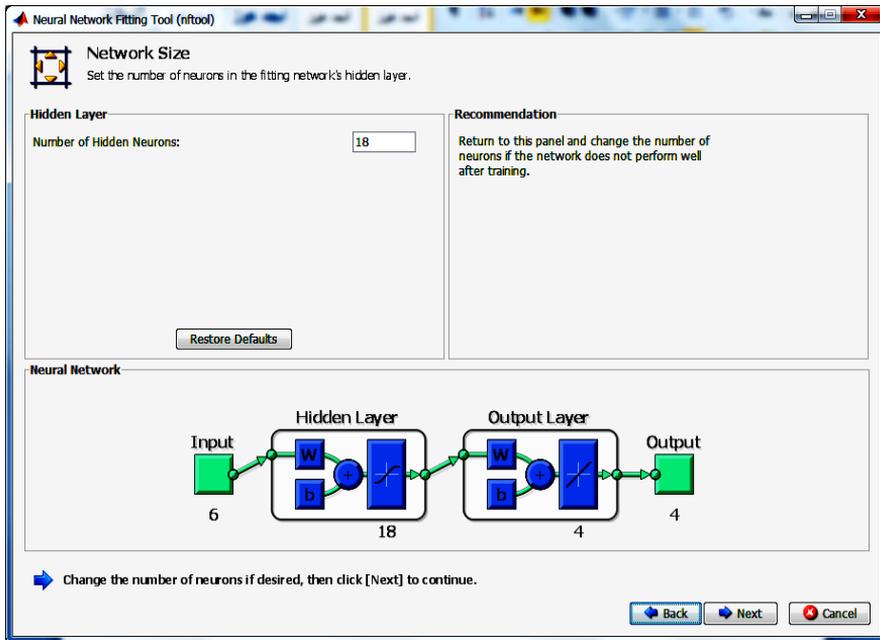


الشكل (13): واجهة ترميز مجموعات بيانات الحوادث كمدخلات في أداة الشبكة العصبونية الصناعية في الماتلاب.

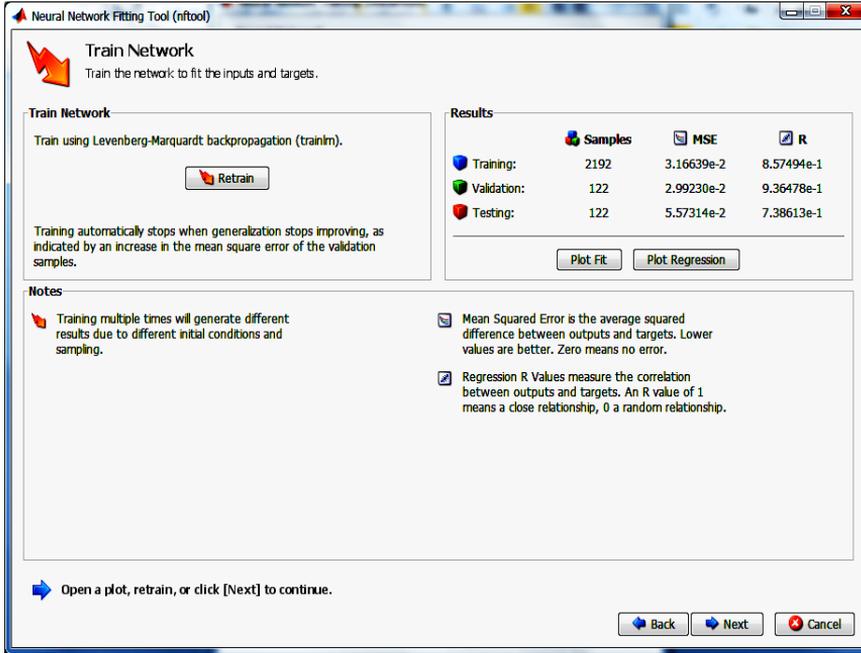
الجدول (11): نتائج تدريب نماذج الشبكات العصبونية الصناعية بعد عدد من تكرارات دورات التدريب

عدد العصبونات	التدريب Training		التحقق Validation		الاختبار Testing		الكل All	
	MSE	R	MSE	R	MSE	R	MSE	R
2	0.0406260	0.838494	0.0361792	0.842894	0.0314075	0.810433	0.0399416	0.806193
4	0.0365497	0.829905	0.0489741	0.831358	0.0389346	0.771630	0.0372914	0.827506
6	0.0384753	0.815495	0.0501820	0.754542	0.0363328	0.855750	0.0389543	0.814451
8	0.0407766	0.802712	0.0167584	0.917056	0.0459494	0.795667	0.0398274	0.807122
10	0.0339522	0.844815	0.0379855	0.863154	0.045823	0.773447	0.0347479	0.841855
12	0.0358296	0.834766	0.0362759	0.86701	0.0313758	0.842918	0.0356289	0.836953
14	0.0388445	0.807985	0.0450296	0.831335	0.0357822	0.882277	0.0390009	0.813073
16	0.0342547	0.842670	0.0358915	0.895225	0.0278303	0.874233	0.034015	0.846933
18	0.0316639	0.857494	0.029923	0.936478	0.0557314	0.738613	0.0327821	0.85627
20	0.035149	0.840940	0.445445	0.779612	0.0270544	0.853600	0.0352284	0.83839
22	0.0337890	0.847714	0.332060	0.874626	0.038788	0.814199	0.0340102	0.847613
24	0.0350774	0.843339	0.030651	0.838049	0.0270836	0.883036	0.034441	0.845130
26	0.0313196	0.862974	0.0432842	0.778714	0.0435222	0.806611	0.032599	0.855524
28	0.0323453	0.856620	0.0370266	0.8589760	0.0364972	0.805856	0.032787	0.854070
30	0.0402102	0.816686	0.0253051	0.8658332	0.0406039	0.803621	0.0394833	0.818476

نلاحظ أن الشبكة العصبونية الصناعية التي تحتوي على عصبونات في الطبقة الخفية (4-18-6) ANN هي الأفضل، حيث كانت قيم متوسط مربعات الأخطاء MSE تساوي خلال مرحلة التدريب **0.0316639**، وتساوي خلال مرحلة التحقق **0.029923**، وتساوي خلال مرحلة الاختبار **0.0557314**، وقد بلغت القيمة الكلية خلال المراحل الثلاث **0.0327821**، بالإضافة إلى ذلك، فقد أعطت الشبكة العصبونية المختارة قيمة عالية لمعامل الارتباط بين القيم الحقيقية والقيم الناتجة عن الشبكة، حيث كانت مراحل التدريب والتحقق والاختبار على الترتيب **(0.857494، 0.936478، 0.738613)**، وقد بلغت القيمة الكلية خلال المراحل الثلاث **0.85627**، وهي قيمة قريبة جداً من الواحد، وبالتالي الشبكة المصممة مثالية، وتحقق الاستجابة للتنبؤ بالأضرار الناجمة عن الحوادث المرورية بدقة عالية جداً. يوضح الشكل (14) هيكلية الشبكة العصبونية الصناعية المثالية التي تم اختيارها، كما يبين الشكل (15) نتائج هذه الشبكة.

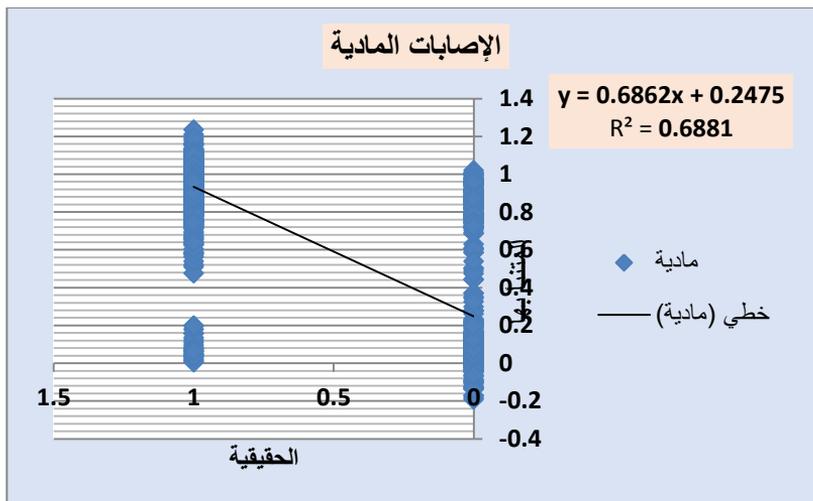


الشكل (14): هيكلية الشبكة العصبونية الصناعية المثالية المختارة

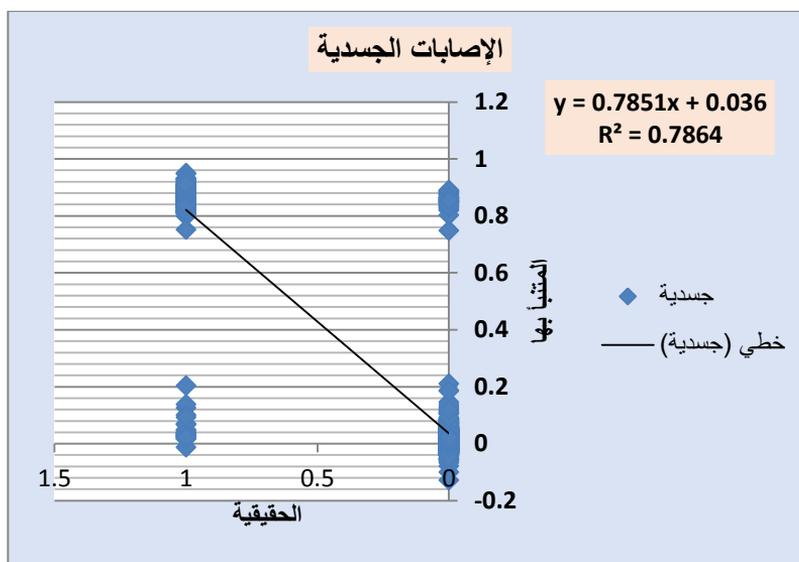


الشكل (15): نتائج الشبكة العصبونية الصناعية المختارة

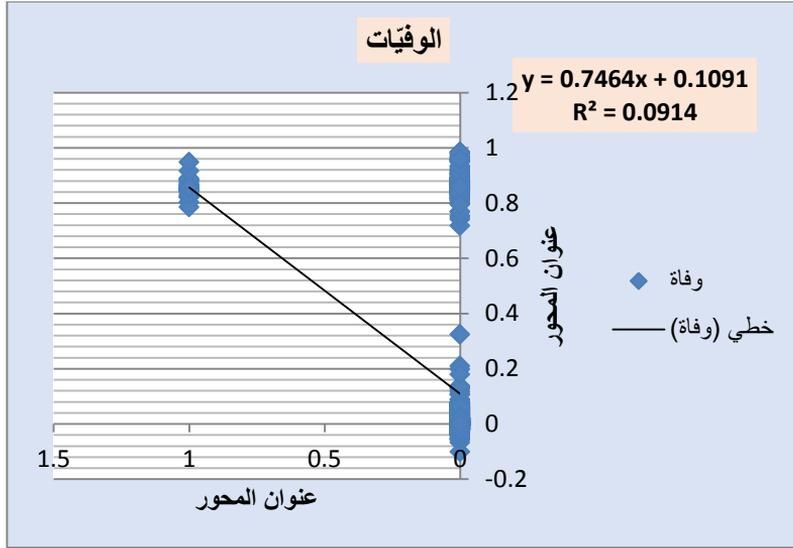
توضّح الأشكال (16) و(17) و (18)، القيم الحقيقية والقيم التي تمّ التنبؤ بها، والخاصّة بالإصابات المادية والإصابات الجسدية والوفيات، إذ كانت درجة الارتباط 68.8% للإصابات المادية، والقيمة 78.6% للإصابات الجسدية، وهي قيم ارتباط جيّدة بالنظر إلى عدد السنوات الخمس، التي تمّ تفرّغ بيانات الحوادث الخاصّة بها، أمّا بالنسبة لعامل الارتباط الضعيف الخاصّ بالوفيات، فإننا يمكن أن نعزو ذلك إلى العدد القليل للوفيات من العدد الإجمالي للحوادث المسجّلة، وبالتالي تصبح العينات اللازمة للتدريب والاختبار قليلة، ولا يمكن بناء علاقة ذات معامل ارتباط كبير منها، إذ أنّ الشبكة التي تمّ اختيارها، هي الشبكة المناسبة بشكل كليّ للتصنيفات، لكن مع التخصّص ومع زيادة عدد العينات، تصبح هيكلية بناء الشبكة أدقّ، بالإضافة إلى زيادة المدخلات وبيانات الحوادث التفصيلية من خصائص هندسية ومرورية وأطوال قطاعات.



الشكل (16): مقارنة القيم التي تم التنبؤ بها للإصابات المادية مع القيم الحقيقية



الشكل (17): مقارنة القيم التي تم التنبؤ بها للإصابات الجسدية مع القيم الحقيقية



الشكل (18): مقارنة القيم التي تم التنبؤ بها للوفيات مع القيم الحقيقية

الاستنتاجات:

- تم تسجيل أكبر عدد من الحوادث سنوياً في عام 2014، حيث تم تسجيل 651 حادثاً، يليه 481 حادثاً في عام 2015، من أصل 2436 حادثاً خلال الخمس أعوام المتتالية.
- شهد عام 2016 تسجيل أكبر عدد من الوفيات الناتجة عن الحوادث، وتم تسجيل أكبر عدد من الإصابات الجسدية في عام 2014.
- أثبتت الشبكة العصبونية الصناعية ذات الهيكلية (4-18-6) وذات معامل الارتباط الكلي 0.85627، وبمتوسط مربعات الأخطاء 0.0327821 لمجموعة البيانات الكلية، أثبتت قدرتها على التنبؤ بالأضرار والإصابات الناجمة عن الحوادث المرورية في مدينة اللاذقية.
- أعطت الشبكة العصبونية المختارة قيمةً عاليةً لمعامل الارتباط بين القيم الحقيقية والقيم الناتجة عن الشبكة، وقد بلغت القيمة الكلية خلال المراحل الثلاث 0.85627، وهي قيمة قريبة جداً من الواحد، وبالتالي الشبكة المصممة مثالية.

- أظهرت النتائج الموثوقة العالية للشبكات العصبونية الصناعية في عملية التنبؤ بالأضرار والإصابات، من جزاء الحوادث المرورية في مدينة اللاذقية.

التوصيات:

- التأكيد على استخدام نماذج عصبونية صناعية أخرى، وإدخال بيانات مستقبلية جديدة للشوارع في المدينة، مع إدخال عدد أكبر من السنوات لزيادة الدقة.
- التأكيد على ضرورة تطوير منهجية واضحة لإعداد تقارير الحوادث المرورية من قبل شرطة المرور، والعمل على رقمنة بيانات الحوادث المرورية، لسهولة إدخالها في النماذج الرياضية، بهدف رفع مستوى السلامة المرورية للمدينة.
- التأكيد على استخدام برامج وتطبيقات الذكاء الصناعي في مجال هندسة المرور، لما يعود بنتائج دقيقة تحاكي واقع الحركة المرورية في المدينة، وبهدف تحقيق الغاية المرجوة منها في تأمين بيئة آمنة للنقل.

المراجع:

1. WHO-World Health Organization, 2010.
2. F. REZAIIE MOGHADDAM, SH. AFANDIZADEH, M. ZIYADI. *Prediction of accident severity using artificial neural networks*. International Journal of Civil Engineering, Vol. 9, No. 1, March 2011
3. M. Metin Kunt, I. Aghayan, Nima Noii. *Prediction for Traffic Accident Severity: Comparing The Artificial Neural Network, Genetic Algorithm, Combined Genetic Algorithm And Pattern Search Methods*. Vilnius Gediminas Technical University (VGTU) Press Technika. ISSN 1648-3480 online 2011 Volume 26(4): 353–366. Vilnius Gediminas Technical University (VGTU) Press Technika. <http://www.tandfonline.com/TRAN>
4. C. NAVEEN KUMAR, DR. MANORANJAN PARIDA, DR. S. JAIN. *Neural Network Paradigms In Crash Modeling On Non-Urban Highways In India*. / Blucher Mechanical Engineering Proceedings. May 2014, vol. 1, num.1.
5. SHARAF ALKHEDER, MADHAR TAAMNEH, SALAH TAAMNEH. *Severity Prediction of Traffic Accident Using an*

- Artificial Neural Network*. Journal of Forecasting, J. Forecast. (2016), Published online in Wiley Online Library (wileyonlinelibrary.com) DOI: 10.1002/for.2425.
6. AZAD ABDULHAFEDH *Crash Frequency Analysis*. Journal of Transportation Technologies, 2016, 6, 169-180 Published Online July 2016 in SciRes. <http://www.scirp.org/journal/jtts>
 7. Fang Zong, Huiyong Zhang, Hongguo Xu, Xiumei Zhu, and LuWang. Predicting Severity and Duration of Road Traffic Accident. Hindawi Publishing Corporation Mathematical Problems in Engineering Volume 2013, Article ID 547904, 9 pages <http://dx.doi.org/10.1155/2013/547904>
 8. Khaled Assi, Syed Masiur Rahman, Umer Mansoor and Nedat Ratrou. *Predicting Crash Injury Severity with Machine Learning Algorithm Synergized with Clustering Technique: A Promising Protocol*. Int. J. Environ. Res. Public Health 2020, 17, 5497; doi:10.3390/ijerph17155497. www.mdpi.com/journal/ijerph
 9. BASHEER, I, A; HAJMEER, M. *Artificial neural networks:fundamentals, computing, design, and application*. Journal of Microbiological Methods 43,2000, 3–31.
 10. DEMUTH, H; BEALE, M; HAGAN, M. *Neural Network Toolbox for Use With MATLAB*. User Guide, Version 6.0, The MathWorks, Inc; MA; 2003, <http://www.mathworks.com>