

التنبؤ بالحوادث المرورية في مدينة اللاذقية باستخدام الشبكات العصبونية الصناعية

د. شذى أسعد*

نورا حمدان**

(تاريخ الإيداع 20 / 10 / 2020. قُبل للنشر في 11 / 1 / 2021)

□ ملخص □

تشكّل هذه الدراسة خطوة تمهيدية لوضع موديل رياضي للتنبؤ بالحوادث المرورية في مدينة اللاذقية، يعتمد على عدد من العوامل الخارجية، والتي تشمل كلاً من الخصائص الهندسية، والغزارات المرورية، وبيانات الحوادث المرورية. وأما هدفها الرئيسي فهو تخفيض عدد الحوادث المرورية المتوقعة مستقبلاً على الشوارع الرئيسية في المدينة، حيث تمت الدراسة على شوارع شريانية 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، لا تعتمد على السلوك الإنساني للسائقين أو على خصائص العربة.

تم إجراء تحليل إحصائي لبيانات الحوادث المرورية للأعوام 2014 و 2015 و 2016 و 2017 على الشوارع المدنية في مدينة اللاذقية، حيث تم تصنيف الحوادث حسب خطورتها وزمن حدوثها ومكان وقوعها، وتم جمع البيانات اللازمة ورقمنتها ضمن بيئة برمجية في برنامج Microsoft Excel، ومن ثم بناء نموذج التنبؤ باستخدام أداة الشبكات العصبونية الصناعية في برنامج الماتلاب MATLAB، حيث تم إدخال بيانات 319 حادثاً مرورياً كانت قد سُجّلت في الأعوام 2015 و 2016 و 2017، والتي تم تقسيمها في ثلاث مجموعات (التدريب والتحقق والاختبار). أعطت الشبكة العصبونية ذات الهيكلية (1-10-10) قيمة عالية لمعامل الارتباط، حيث بلغت قيمة R الكلية خلال المراحل الثلاث 0.931236، وهي قيمة قريبة جداً من الواحد، وبالتالي الشبكة المصممة مثالية وتحقق الاستجابة للتنبؤ بالحوادث المرورية شهرياً وبدقة عالية جداً.

الكلمات المفتاحية: التنبؤ - موديل - الحوادث المرورية - الشبكات العصبونية الصناعية.

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

** طالب دراسات عليا (ماجستير) - قسم هندسة المواصلات والنقل - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

البريد الإلكتروني: nour.577@hotmail.com

Predicting of Traffic Accident in Lattakia City Using Artificial Neural Networks

Dr Shaza Assaad*
Noura Hamdan**

(Received 20 / 10 / 2020. Accepted 11 / 1 / 2021)

□ ABSTRACT □

This study constitutes a preliminary step to develop a mathematical model for predicting traffic accidents in the city of Lattakia, based on a number of external factors, which include engineering characteristics, traffic incursions, and traffic accident 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, does not depend on the human behavior of the drivers or on the characteristics of the vehicle.

A statistical analysis of traffic accident data for the years 2014, 2015, 2016 and 2017 was conducted on urban streets in Lattakia, where accidents were classified according to their severity, time of occurrence and place of their occurrence, and the necessary data were collected and digitized within a software environment in Microsoft Excel, and then a model was built Predicting the use of the artificial neural networks tool in the MATLAB program, in which data for 319 traffic accidents that were recorded in the years 2015, 2016 and 2017, were entered, which were divided into three groups (training, validation and testing). The structural neural network (10-10-1) gave high values of the correlation coefficient, as the total R value during the three stages was 0.931236, which is very close to one, and therefore the designed network is ideal and achieves the response to predict traffic accidents monthly with very high accuracy.

Keywords: Prediction , model , traffic accidents , artificial neural networks.

* Associate Professor, Transportation Engineering Department, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria

** Postgraduate Student, Transportation Engineering Department, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.E-mail: nour.577@hotmail.com

مقدمة:

تعدّ مشكلة الحوادث المرورية من أكبر المشاكل التي تعاني منها جميع دول العالم لما تسببه هذه الحوادث من أضرار وخسائر اجتماعية واقتصادية، كما أصبحت السلامة المرورية بمفهومها الواسع من أولى اهتمامات الحكومات العالمية، حيث تتضافر جهود المنظمات والهيئات العالمية لتبني كافة الخطط والبرامج واللوائح المرورية والإجراءات الوقائية للحدّ من أو لمنع وقوع الحوادث المرورية، ضماناً لسلامة الإنسان وممتلكاته، وحفاظاً على أمن البلاد ومقوماتها البشرية والاقتصادية [1]. وحالياً تسعى العديد من الحكومات العالمية لتوظيف تطبيقات الذكاء الصناعي في مجال مراقبة ممرات المشاة والطرق والإشارات الضوئية، بهدف وضع آليات وقائية للتنبؤ بالحوادث المرورية والازدحام المروري، وبهدف 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 الآمنة في خفض معدلات الحوادث والوفيات الناتجة عنها، وتزيد من مستويات الأمن والسلامة وانسيابية الحركة على الطرقات.

لقد أثبتت دراسات عديدة أن حوادث المرور تتأثر بعوامل كثيرة ليست دائماً هي عوامل مرتبطة بعلاقة خطية أو واضحة المعطيات، إذ تُعتبر حوادث المرور ظاهرة عشوائية، ولهذا فإن العلاقة المفترضة بين المتغيرات التابعة والمستقلة للتنبؤ يمكن أن تكون غير صحيحة، مما يوضّح الطبيعة الاحتمالية للحوادث، وبالتالي عدم القدرة على التنبؤ بها من خلال النماذج الإحصائية [2].

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 بالحوادث المرورية والقدرة على نمذجة جميع المتغيرات التي تسهم في وقوع الحوادث. وقد أجريت العديد من الدراسات لبناء وتطوير نماذج للتنبؤ بالحوادث المرورية، حيث قام (Akgüngör, A. et al. 2009) في تركيا بتطوير وتطبيق نماذج الذكاء الاصطناعي للتنبؤ بالحوادث المرورية، بعد أن استخدم الباحثان نماذج الشبكات العصبونية الصناعية والنماذج المعتمدة على النظرية الجينية، وبعد مقارنة نتائج النموذجين خلّصت الدراسة إلى أنّ نماذج ANN هي الأفضل للتنبؤ بالحوادث المرورية، لذلك تمّ اعتمادها للتنبؤ بالحوادث والإصابات والوفيات للأعوام 2006-2020 [3].

كما 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 خوارزمية تدريب MLP، وقد خلّصت الدراسة إلى أنّ أهم العوامل التي لعبت دوراً أساسياً في حساسية النموذج التنبؤي كانت عدم تقدير المسافة الجانبية، وعرض الطريق، ونسبة الدراجات الهوائية والنارية في تركيبة التيار المروري [4].

وقدم (Semeidaa, A. et al. 2011) دراسة لتقصّي العوامل المسببة لوقوع الحوادث المرورية على الطرق الريفية في مصر باستخدام الشبكات العصبونية الصناعية، من خلال تطبيق ثلاثة نماذج للشبكات العصبونية الصناعية ANN على البيانات باستخدام برنامج NerroSolution6,2008 وهي: نموذج متعدد طبقات المستقبلات MLP، نموذج التغذية الأمامية FF، ونموذج Elman. تمت مقارنة نتائج النماذج الثلاثة لاختيار النموذج الأنسب، من خلال قيم الخطأ المتوسط التربيعي MSE، جذر الخطأ المتوسط التربيعي RMSE، قيمة الخطأ المتوسط المطلق MAE، وتوصلت الدراسة إلى أنه وكنتيجة للتدريب والتحقق، كانت أهم العوامل المؤثرة على عدد الحوادث الكلي هي طول القطاع المدرس L، ومعدل المرور اليومي السنوي AADT، وعرض الكتف اليميني SW، وجود الأراضي القاحلة المجاورة

للطريق وحقول DF، والدراجات الهوائية BIKES، والمركبات الثقيلة HV، وبمقارنة نتائج النماذج التنبؤية الثلاثة المستخدمة في هذه الدراسة، كانت نتائج النموذج التنبؤي باستخدام الشبكات العصبونية الصناعية MLP هي الأدق [5]. وفي الهند أعد الباحثون (Kumar, C. et al. 2014) دراسة لنمذجة الحوادث المرورية على الطرق السريعة غير المدنية باستخدام الشبكات العصبونية الصناعية، و أكدت النتائج التي توصل إليها الباحثون، بأن نماذج التنبؤ بالحوادث المرورية باستخدام الشبكات العصبونية هي أكثر دقة من نماذج التنبؤ الإحصائية التقليدية [6].

كما وقدم (Codur, M. et al. 2014) في تركيا نموذج تنبؤي بالحوادث المرورية على الطرق السريعة باستخدام الشبكات العصبونية الصناعية وتحديد أكثر العوامل المسببة للحوادث، وخأصت الدراسة إلى أنه كان هناك ثمانية متغيرات ذات تأثير كبير بوقوع الحوادث وهي: السنة، قطاع الطريق السريع، طول القطاع km، معدل المرور اليومي AADT، درجة الإنحناء الأفقية، درجة الإنحناء الشاقولية، الحوادث المرورية مع العربات الثقيلة، ونسبة وقوع الحوادث في فصل الصيف [7].

وفي الولايات المتحدة الأمريكية، درس الباحث (Abdulhafedh, A. 2016) ترددات الحوادث المرورية على الطرق السريعة، حيث قدم نموذج لتحديد المناطق الخطرة والمعرضة 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 أن نموذج الشبكات العصبونية الصناعية هو النموذج الفعال مقارنة بطرق التنبؤ الأخرى [8].

وفي دراستنا اعتمدنا على الشبكات العصبونية الصناعية في الماتلاب MATLAB لبناء النموذج التنبؤي بالحوادث المرورية في مدينة اللاذقية، حيث تعتبر أداة فعالة للتعامل مع الظواهر العشوائية، إذ أن استخدام تقنيات الشبكات العصبونية الصناعية هو المفضل للتعامل مع الظواهر ذات الطبيعة العشوائية، وإيجاد العلاقة بين متغيرات مستقلة كمسببات الحوادث المرورية، حيث ترتبط بعدد من العوامل المستقلة.

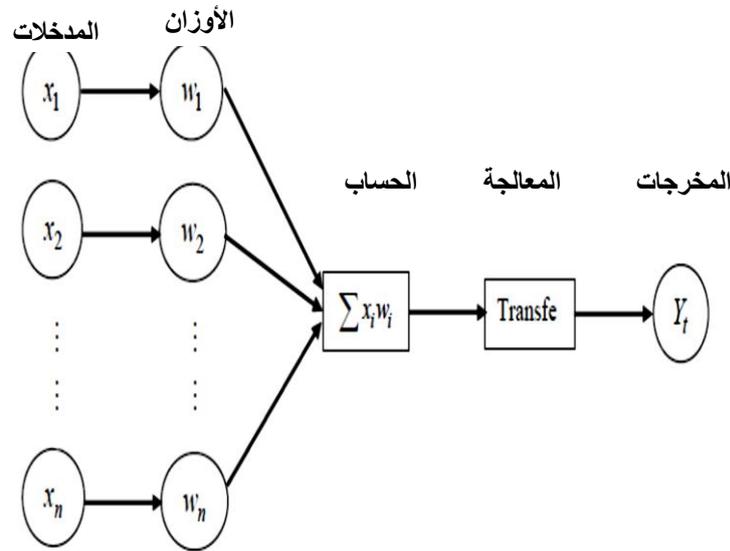
أهمية البحث وأهدافه:

تأتي أهمية البحث في أنه سيقدم مساهمة في تحسين وضبط سلامة المرور في مدينة اللاذقية، مما سيساعد في وضع أسس للتخطيط المستقبلي لها، كما أن استخدام منهج الشبكات العصبونية الصناعية في التنبؤ يعدّ من الأساليب الحديثة التي يتم اعتمادها للتنبؤ بالحوادث المرورية، حيث أن القاعدة الأساسية للشبكات العصبونية الصناعية تكمن في أنها ذات تركيب ديناميكي يتيح في المستقبل تحديث مستمر لها ببيانات جديدة، وذلك بهدف الوصول إلى نتائج أدق وأحدث. و يهدف البحث إلى بناء نموذج للتنبؤ بالحوادث المرورية باستخدام الشبكات العصبونية الصناعية على الطرق المدنية، للحدّ من إمكانية وقوع حوادث مستقبلية، وذلك بإدخال العوامل المؤلدة للحوادث على الطرق المدروسة، وبالتالي ستساعد نتائج التنبؤ في حل مشكلة سلامة المرور من خلال كشف خطورة الطرق المدروسة في أوقات محدّدة، وبالتالي تحسين وضبط سلامة المرور في المدينة.

وقد نشأ الاهتمام العام بالشبكات العصبونية الصناعية بسبب الخصائص المميزة لها، وقدرتها على تجاوز محددات الحل التقليدي، ومن خصائص هذه الشبكات تميزها بخاصة التوازي (Parallelism)، وهو أساس الشبكات العصبونية الصناعية، إذ أنّ كل العصبونات في الشبكة تعمل بتزامن، أي أنّ التوازي يمثل قدرة الشبكات على معالجة البيانات بسرعة عالية جداً مهما كانت ضخامة تلك البيانات.

ويمكن 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].

ترتبط الخلية العصبونية الصناعية المتكونة 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، كما هو موضح في الشكل (2).



الشكل (2): الشبكة العصبونية الصناعية.

حيث أنّ:

X_n : المدخلات، W_n : أوزان المدخلات، n : عدد المدخلات، f : تابع التفعيل المستخدم، Y_i : المخرجات.

ويوضّح الجدول (1) مقارنة بين مكونات الخلية العصبونية الحيوانية ومكونات الخلية العصبونية الصناعية.

الجدول(1): مقارنة بين مكونات الخلية العصبونية الحيوانية ومكونات الوحدة العصبونية الصناعية

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

كما وتُصنّف الشبكات العصبونية الصناعية تبعاً لطريقة عملها إلى صنفين:

- i. **الشبكات العصبونية الصناعية ذات التغذية الأمامية Feed forward ANNs:** يقصد بالتغذية الأمامية انتشار البيانات الداخلة إلى الشبكة باتجاه الأمام دائماً من طبقة الإدخال باتجاه طبقة الإخراج، ويعدّ هذا النوع من الشبكات العصبونية الصناعية الأكثر شيوعاً.
- ii. **الشبكات العصبونية الصناعية ذات التغذية الراجعة Feedback ANNs:** في هذه الشبكات تعاد البيانات الخارجة من الشبكة، ويحوّل اتجاهها لتصبح مدخلات، ولهذا فإنّ المخرجات تعتمد على المدخلات والمخرجات، ويسمى هذا النوع من الشبكات بالشبكات المرتدة (Recurrent Network).
- **تدريب الشبكات العصبونية:**

يتمّ تدريب الشبكات العصبونية الصناعية بواسطة خوارزميات متخصصة، تدعى خوارزميات التدريب (Training Algorithms)، تتولى تعديل أوزان الشبكة لتحسين أدائها وتقليل إشارة الخطأ فيها (Error Signal)، استناداً إلى مقياس معلوم (معدل 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 معلم أو مراقب خلال عملية التدريب، حيث تُدرّب الشبكة في هذه الخوارزمية على سلسلة من المدخلات التي ترافقها مخرجات مرتبطة بها، إذ تعدّل أوزان الشبكة اعتماداً على الفرق بين المخرجات الحقيقية (Output) والمخرجات المأمولة أي الهدف (Target)، ويمثل الفرق (Output- Target) إشارة الخطأ، حيث تعاد تغذية الشبكة به لغرض تحويل أوزان الشبكة والحصول على أقل خطأ ممكن، وتعدّل إشارة الخطأ المستحصلة بعد كل دورة تدريب (epochs) إلى أن تصل قيمة الخطأ أو عدد محاولات التدريب إلى القيمة المحددة مسبقاً من المدرب، وعندئذ يتوقف التدريب. تعدّ هذه الطريقة من أكثر الطرائق شيوعاً في تدريب الشبكات.

✓ خوارزميات تدريب التقوية: (Reinforcement Learning Algorithms)

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

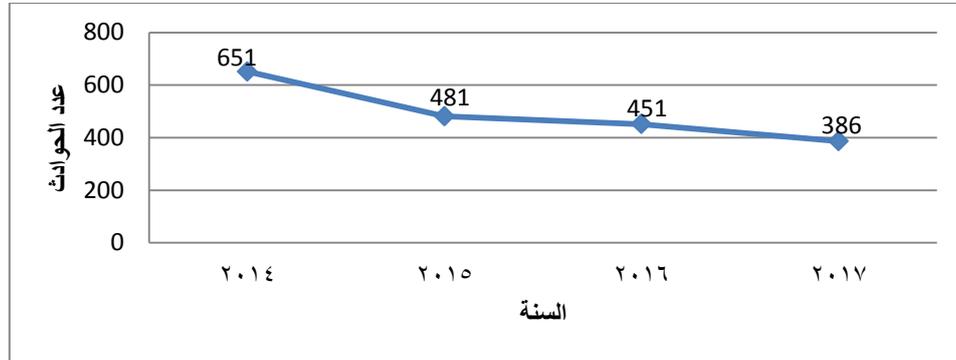
✓ خوارزميات التدريب دون إشراف: (Unsupervised Learning Algorithms)

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].

النتائج والمناقشة:

من خلال تحليل بيانات الحوادث المرورية للشوارع المدنية في مدينة اللاذقية للأعوام 2014 و 2015 و 2016 و 2017، والمبيّنة في الشكل (3)، نلاحظ أنّ عدد الحوادث المرورية ينخفض سنوياً في مدينة اللاذقية، حيث انخفض عدد الحوادث المرورية في عام 2015 بمعدل حوالي 26% مقارنةً بعام 2014، وفي عام 2016 انخفض بمعدل 6%،

وفي عام 2017 انخفض بمعدل حوالي 16% ، مقارنةً بعدد الحوادث المرورية المسجلة عام 2016، ويمكن تبرير ذلك لعودة الأمن والأمان لمدينة حلب ومدن ومناطق سورية أخرى، والتي شهدت سابقاً أعداد كبيرة من حركات النزوح باتجاه مدينة اللاذقية، وبالتالي انخفض عدد المركبات القادمة من المدن الأخرى تدريجياً، مما خفّف من الازدحام في مدينة اللاذقية، وبالتالي قلّت احتمالية وقوع الحوادث المرورية، تبين الجداول (2) و(3) بيانات الحوادث في مدينة اللاذقية.



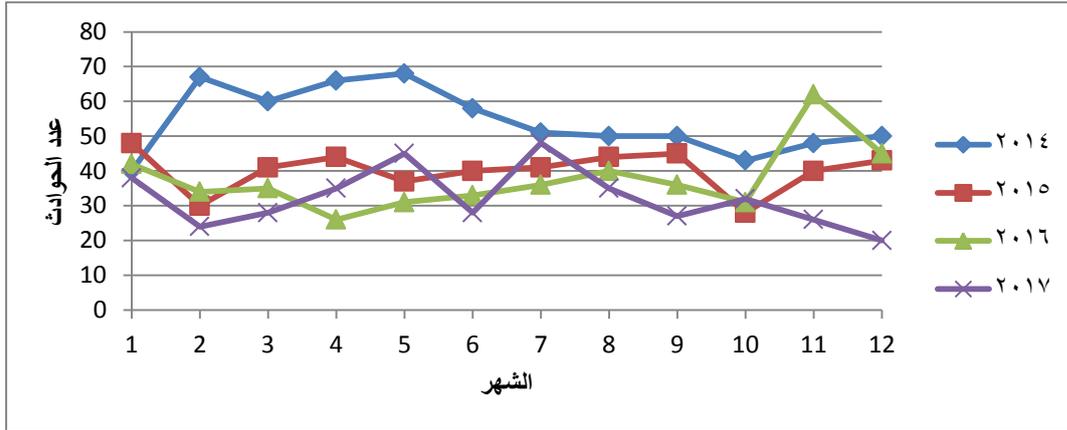
الشكل (3): عدد الحوادث المرورية المسجلة على الشوارع المدنية الرئيسية في مدينة اللاذقية.
الجدول (2): بيانات الحوادث المرورية للشوارع المدنية الرئيسية في مدينة اللاذقية.

عدد الحوادث الكلي	الأضرار			كيفية وقوع الحادث				السنة
	وفاة	جسدية	مادية	تدهور	صدم سيارة أثناء ركنها	صدم مشاة	اصطدام	
651	8	153	519	66	63	124	398	2014
481	7	110	390	50	47	92	295	2015
451	11	118	323	36	53	99	263	2016
386	5	85	317	44	34	72	241	2017

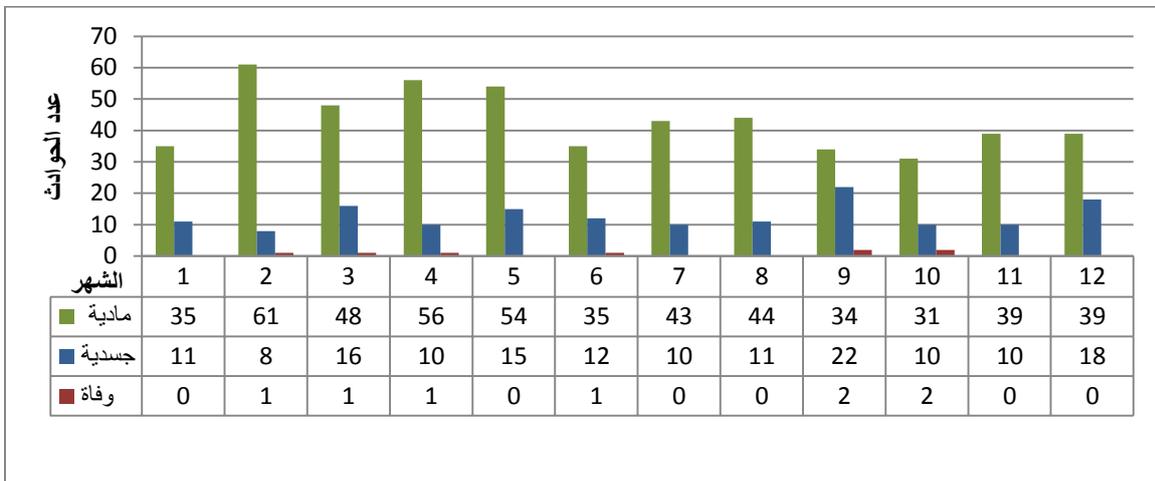
الجدول (3): عدد الحوادث المرورية المسجلة شهرياً على الشوارع الرئيسية في مدينة اللاذقية.

السنة	كانون الثاني	شباط	آذار	نيسان	أيار	حزيران	تموز	آب	أيلول	تشرين الأول	تشرين الثاني	كانون الأول
2014	40	67	60	66	68	58	51	50	50	43	48	50
2015	48	30	41	44	37	40	41	44	45	28	40	43
2016	42	34	35	26	31	33	36	40	36	31	62	45
2017	38	24	28	35	45	28	48	35	27	32	26	20

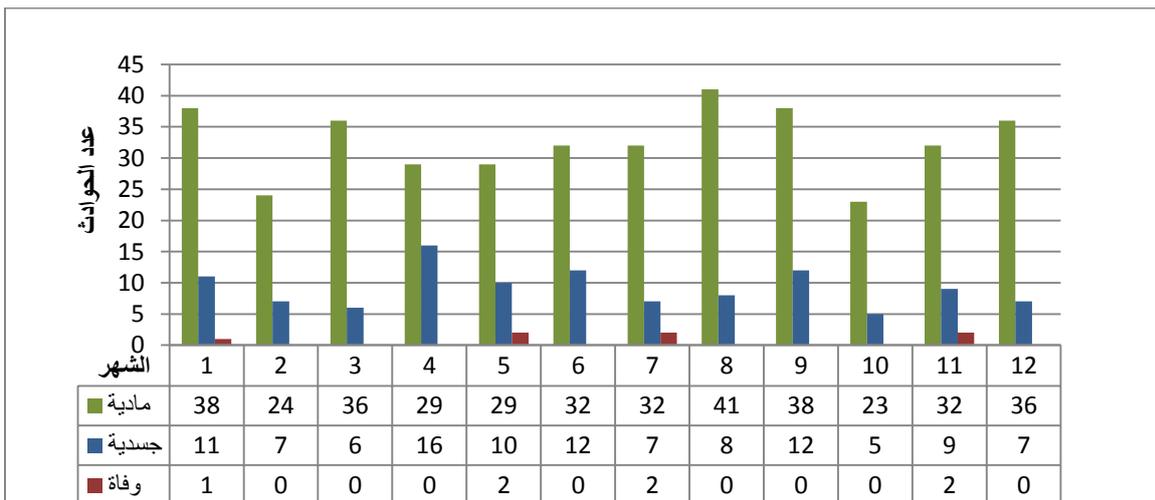
ومن خلال تحليل أعداد الحوادث المرورية المسجلة شهرياً نلاحظ تفاوت وعشوائية القيم المسجلة، كما هو واضح في الشكل (4)، كما تبين الأشكال (5) و(6) و(7) و(8) الأضرار الناجمة عن الحوادث المرورية المسجلة في المدينة.



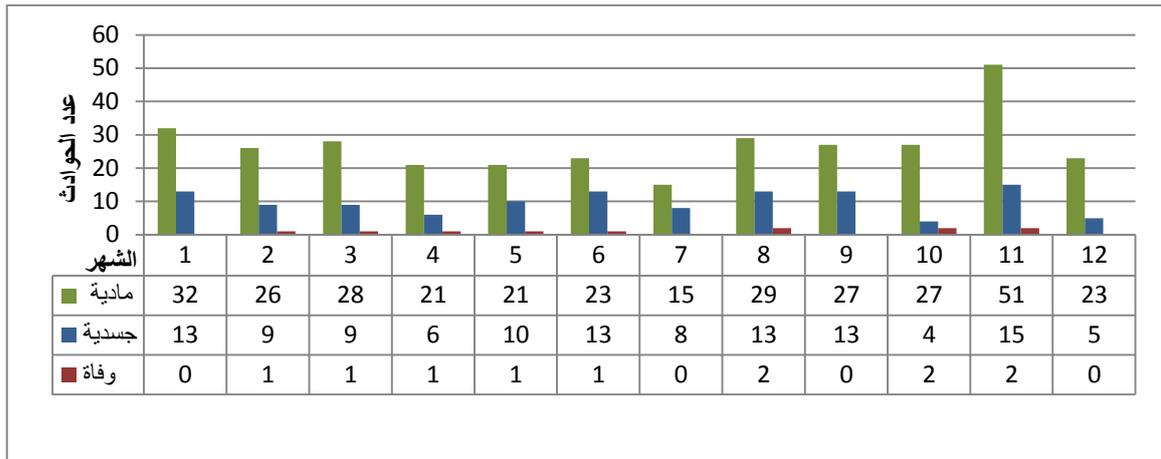
الشكل (4): عدد الحوادث المرورية المسجلة شهرياً على الشوارع الرئيسية في مدينة اللاذقية.



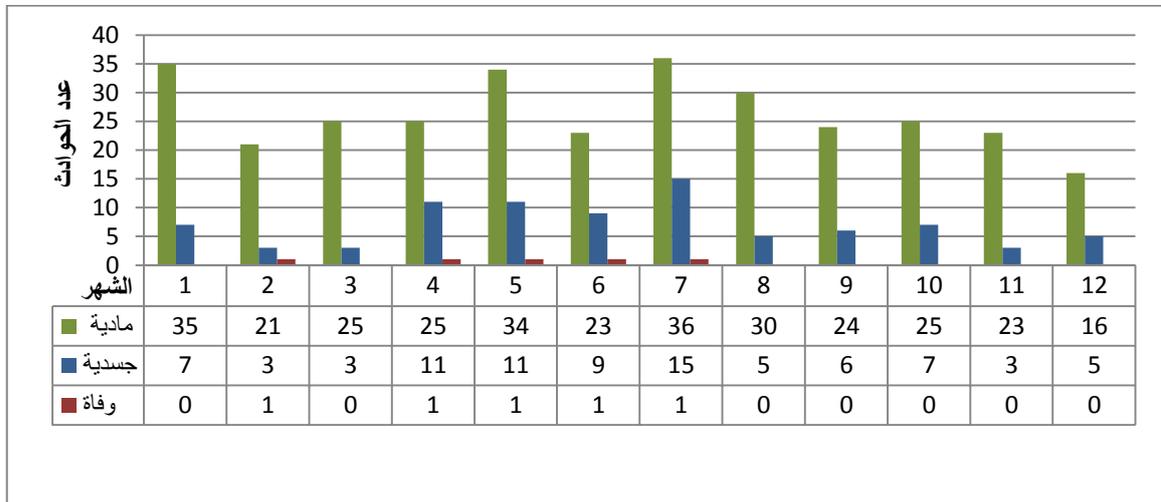
الشكل (5): الأضرار الناجمة عن الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2014



الشكل (6): الأضرار الناجمة عن الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2015



الشكل (7): الأضرار الناجمة عن الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2016



الشكل (8): الأضرار الناجمة عن الحوادث المرورية المسجلة شهرياً في مدينة اللاذقية عام 2017

- بناء النموذج التنبؤي باستخدام الشبكات العصبونية الصناعية:

تمّ تحديد عدد من الشوارع المدنية في مدينة اللاذقية لبناء النموذج التنبؤي بعدد الحوادث المرورية شهرياً، باستخدام أداة الشبكات العصبونية الصناعية في برنامج MATLAB، وتمّ الاختيار بناءً على اختلاف تصنيف الشوارع المدروسة من حيث أهميتها وعدد الحوادث المرورية المسجلة فيها، وتنوعها هندسياً، حيث جُمعت بيانات الخصائص الهندسية والمرورية وبيانات الحوادث المرورية لسبع شوارع شريانية رئيسية وهي: سوريا، العروبة، نديم حسن، جمال عبد الناصر، المغرب العربي، المدينة المنورة، بورسعيد. لقد تمّ ترميز اسم الشارع وبيانات الخصائص الهندسية والمرورية، كما هو موضح في الجداول (4) (5) (6) (7) (8).

الجدول (5): ترميز أطوال الشوارع

ترميزه	الطول m
1	<1000
2	1000<=length<2000
3	>=2000

الجدول (4): ترميز أسماء الشوارع

الترميز كموقع	اسم الشارع
1	سوريا
2	العروبة
3	نديم حسن
4	جمال عبد الناصر
5	المغرب العربي
6	المدينة المنورة
7	بور سعيد

الجدول (6): ترميز عدد المداخل والمخارج لكل شارع

ترميز	عدد المداخل والمخارج
1	<10
2	10<=in-out<20
3	<=20

الجدول (7): ترميز عرض الشوارع

ترميزه	العرض m
1	24
2	28

الجدول (8): ترميز متوسط قيم الغزارة المرورية

الترميز	متوسط قيم الغزارة المرورية Pc/H
1	<3400
2	>=3400

تم الحصول على بيانات الحوادث المرورية المتوقعة لدى قسم شرطة المرور في مدينة اللاذقية في الفترة الممتدة بين عامي (2015-2017)، ثم تم ترميزها ضمن بيئة برمجية في برنامج Microsoft Excel، كما هو موضح في الجداول (9) (10) (11) (12)، علماً أنّ عام وقوع الحادث المروري تمّ إدخاله دون ترميز للأعوام (2015، 2016، 2017).

الجدول (11): ترميز فصول السنة

ترميزه	الفصل
1	الخريف
2	الشتاء
3	الربيع
4	الصيف

الجدول (10): ترميز أشهر السنة

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

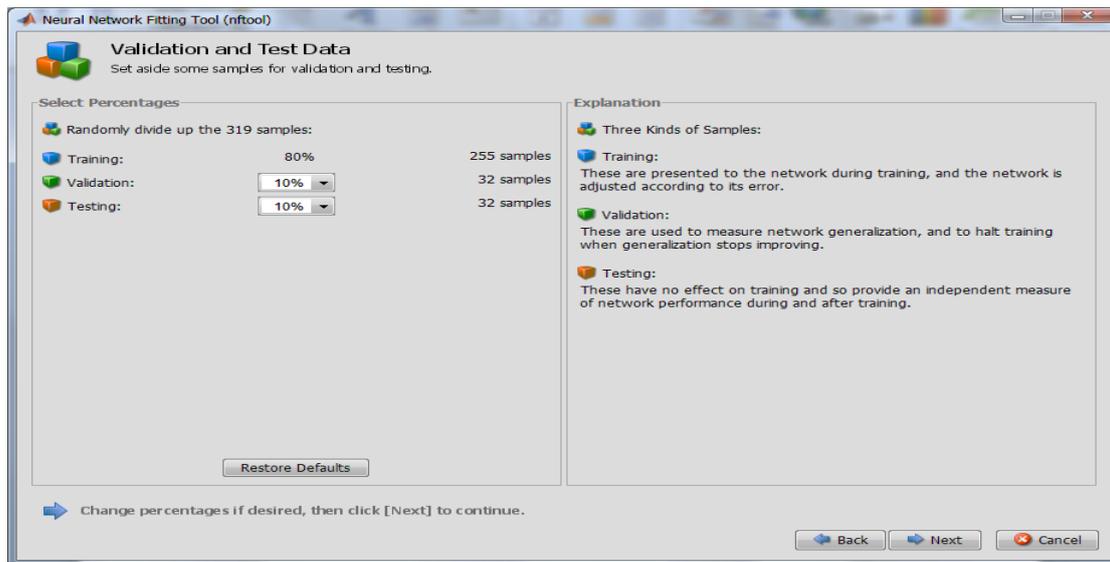
الجدول (9): ترميز أيام الأسبوع

ترميزه	أيام الأسبوع
1	السبت
2	الأحد
3	الاثنين
4	الثلاثاء
5	الأربعاء
6	الخميس
7	الجمعة

الجدول (12): ترميز كيفية وقوع الحادث

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

استُخدم 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 من خلال مقارنة قيم متوسط مربعات الأخطاء MSE، ومعامل الارتباط R لكل نموذج، تم الاعتماد على نموذج الشبكات العصبونية الصناعية ANN من خلال The Neural Network Fitting Tool (nftool) ذات التغذية الخلفية Back-Propagation، مع خوارزمية التدريب Levenberg-Murquardt (LM)، حيث يبيّن الجدول (13) قيم R و MSE لأنماط المدخلات لمجموعة بيانات التدريب والتحقق والاختبار، بعد أن تم إدخال بيانات 319 حادثاً مرورياً كانت قد سجلت في الأعوام 2015 و 2016 و 2017، والتي تم تقسيمها في ثلاث مجموعات، حيث استخدمت بيانات 255 حادثاً لتدريب الشبكة و 32 حادثاً للتحقق من نتائجها و 32 حادثاً لاختبارها، كما هو موضح في الشكل (9)، علماً أن تحديد عدد العصبونات المخفية اللازمة لتدريب الشبكة يُعتبر الجملة الأصعب في التدريب والبناء، بسبب عدم وجود طريقة عامة لإيجادها، لذا فإن هيكليّة نماذج ANN يتم استقراؤها بعد عملية التجربة والخطأ (Trial and Error) وبعد مراقبة أداء الشبكة، حيث تم اعتماد هيكليّة لشبكة عصبونية مع 10 مدخلات، والتي تم تفصيل ترميزها سابقاً، ومخرج واحد فقط هو عدد الحوادث المسجلة شهرياً لكل شارع.



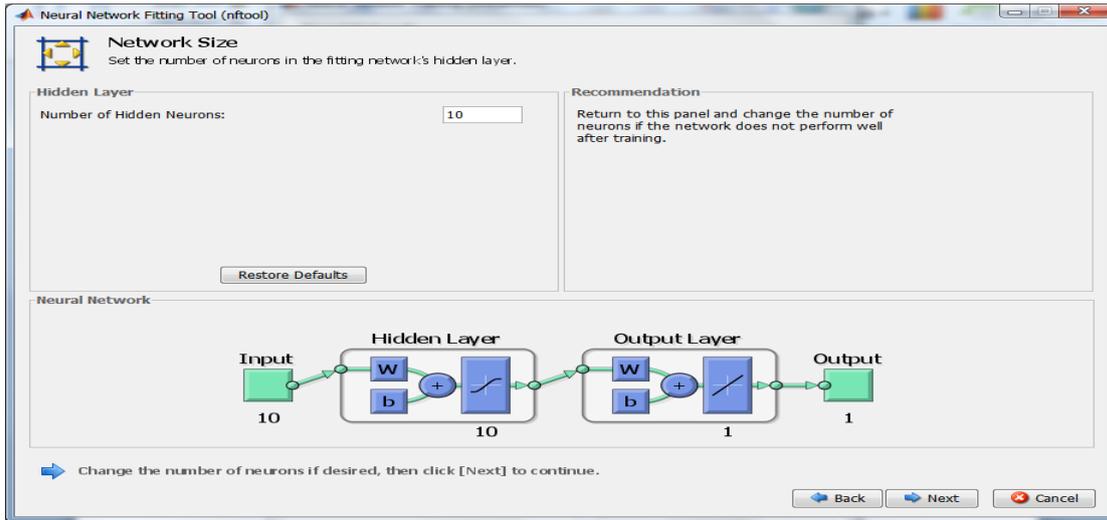
الشكل (9): واجهة تقسيم مجموعات بيانات الحوادث المدخلة في أداة الشبكة العصبونية الصناعية في الماتلاب.

الجدول (13): نتائج تدريب نماذج الشبكات العصبونية الصناعية بعد عدد من تكرارات دورات التدريب.

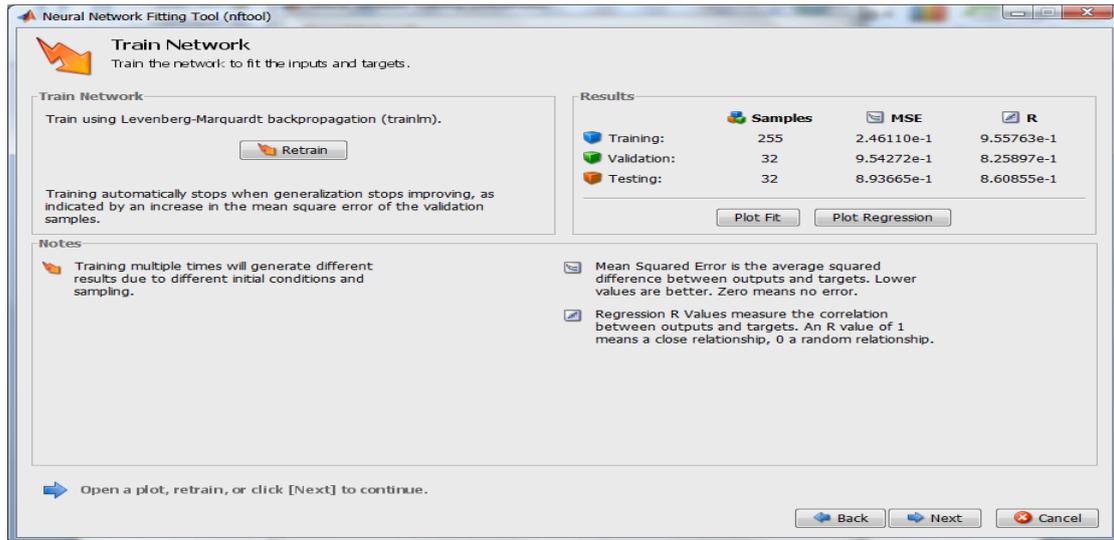
عدد العصبونات	التدريب Training		التحقق Validation		الاختبار Testing		الكل All	
	MSE	R	MSE	R	MSE	R	MSE	R
2	1.64226	0.681639	1.36188	0.620846	1.10611	0.681726	1.56035	0.673202
4	1.15420	0.757512	1.39039	0.767528	1.36881	0.785336	1.19942	0.761517
6	0.6831016	0.867748	0.789756	0.843245	1.39206	0.810586	0.764851	0.855869
8	0.849122	0.827493	0.856376	0.822063	1.64235	0.803642	0.929422	0.822399
10	0.246110	0.955767	0.954272	0.825897	0.893665	0.860855	0.382106	0.931236

12	0.563703	0.900346	1.37265	0.742610	0.560310	0.849986	0.644511	0.881902
14	0.674229	0.875281	0.963579	0.842801	1.03533	0.760507	0.739479	0.86085
16	0.422357	0.915444	1.67560	0.722764	0.154490	0.816890	0.71254	0.87751
18	0.820616	0.843791	1.95963	0.700269	1.33323	0.712699	1.13421	0.80978
20	1.22092	0.771578	1.68604	0.709556	1.41460	0.726742	1.15061	0.75878
22	0.524076	0.891057	1.77990	0.743438	2.29323	0.738004	0.53208	0.84320
24	1.47247	0.724972	0.997800	0.710556	1.23899	0.70498	1.40143	0.718088

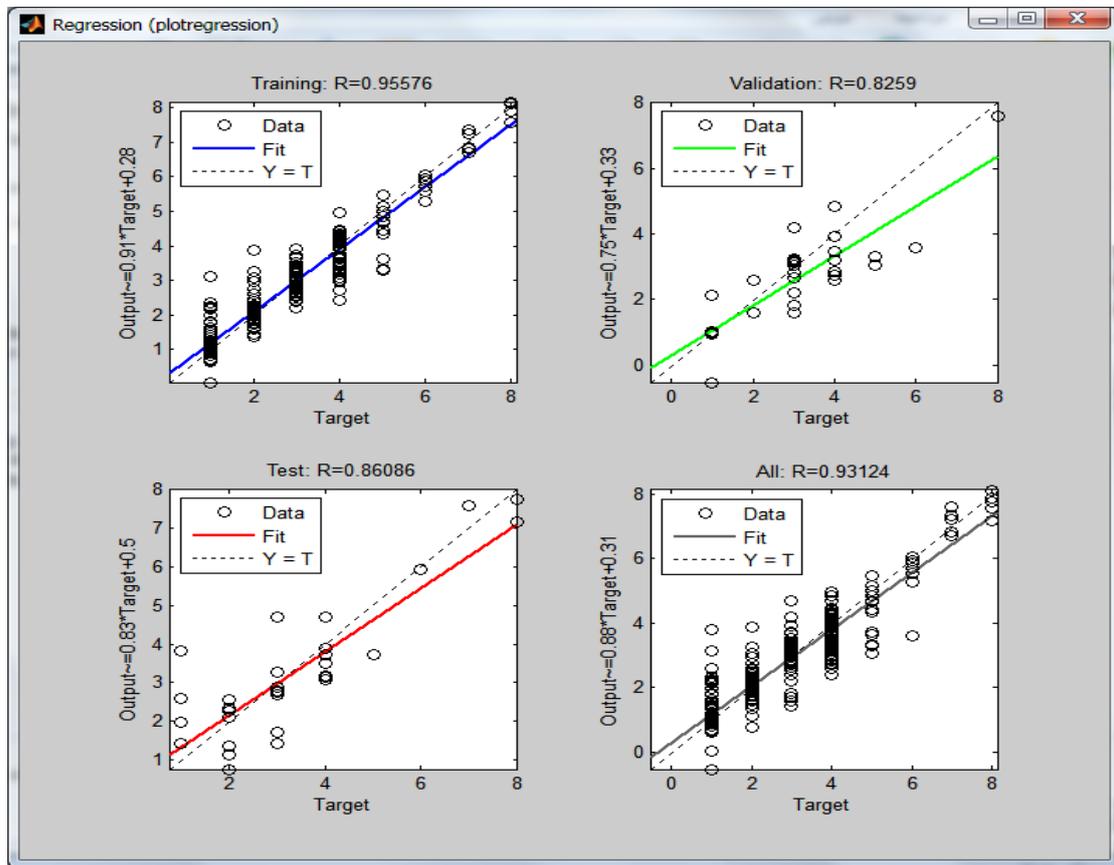
نلاحظ أن الشبكة العصبونية الصناعية ANN التي تحتوي على عصبونات في الطبقة الخفية (1-10-10) هي الأفضل، حيث كانت قيم متوسط مربعات الأخطاء MSE تساوي خلال مرحلة التدريب 0.246110 ، وتساوي خلال مرحلة التحقق 0.954272 ، وتساوي خلال مرحلة الاختبار 0.893665، وقد بلغت القيمة الكلية خلال المراحل الثلاث 0.382106. وبالإضافة إلى ذلك فقد أعطت الشبكة العصبونية ذات الهيكلية (1-10-10) قيمة عالية لمعامل الارتباط بين القيم الحقيقية والقيم الناتجة عن الشبكة، حيث كانت مراحل التدريب والتحقق والاختبار على الترتيب (0.955767 ، 0.825897 ، 0.860855)، حيث بلغت القيمة الكلية خلال المراحل الثلاث 0.931236 ، وهي قيم قريبة جداً من الواحد، وبالتالي الشبكة المصممة مثالية، وتحقق الاستجابة للتنبؤ بالحوادث المرورية شهرياً بدقة عالية جداً.



الشكل (10): هيكلية الشبكة العصبونية الصناعية المثالية المختارة.

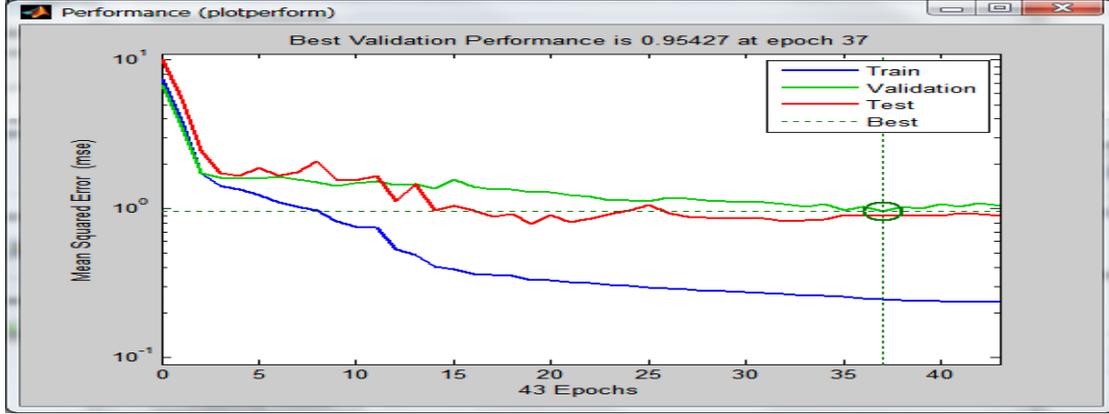


الشكل (11): نتائج الشبكة العصبونية الصناعية المختارة.

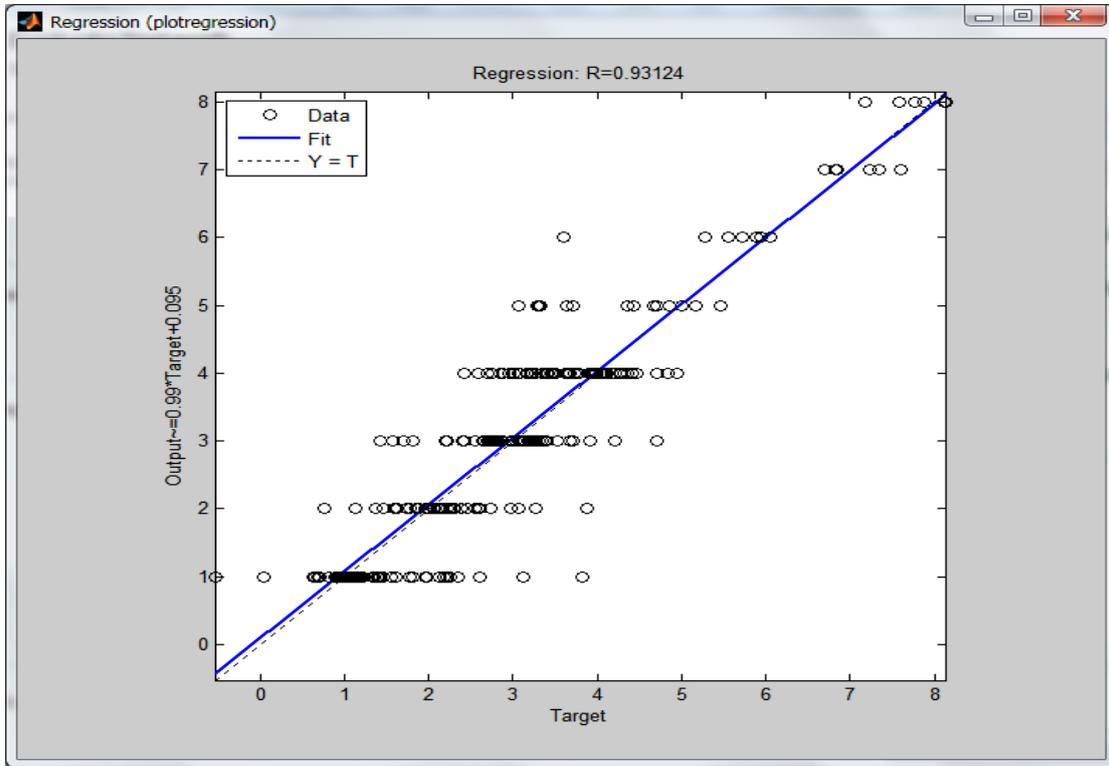


الشكل (12): الارتباط بين الحوادث المسجلة والحوادث المتنبأ بها.

ويظهر الشكل (13) أداء هذه الشبكة والتناقص في قيمة متوسط مربع الخطأ خلال مرحلة تدريب الشبكة واختيار الدورة التكرارية 37 ، التي تقابل أقل قيمة لمتوسط مربع الخطأ المعياري خلال مرحلة التحقق Validation ، كما يبين الشكل (14) الارتباط الكلي بين عدد الحوادث المسجلة شهرياً والقيم المتنبأ بها



الشكل (13): أداء الشبكة (1-10-10) خلال مراحل التدريب والتحقق والاختبار.



الشكل (14): الارتباط الكلي بين عدد الحوادث المسجلة شهرياً والقيم المتنبأ بها.

الاستنتاجات والتوصيات:

- أثبتت الشبكة العصبونية الصناعية ذات الهيكلية (1-10-10) وبمعامل الارتباط الكلي 0.931236 و بمتوسط مربعات الأخطاء 0.382106 لمجموعة البيانات الكلية، قدرتها على التنبؤ بالحوادث المرورية شهرياً في مدينة اللاذقية.
- أظهرت النتائج الموثوقة العالية للشبكات العصبونية الصناعية في عملية التنبؤ بالحوادث المرورية شهرياً في مدينة اللاذقية.
- التأكيد على استخدام نماذج عصبونية صناعية أخرى، وإدخال بيانات مستقبلية جديدة لشوارع أخرى في المدينة وبتصنيفات للشوارع مختلفة.

- التأكيد على ضرورة تطوير منهجية إعداد 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، ويهدف تحقيق الغاية المرجوة منها في تأمين بيئة آمنة للنقل.

1. WHO-World Health Organization, 2010.
2. BERHANU, G. *Models relating traffic safety with road environment and traffic flows on arterial roads in Addis Ababa*. Accident Analysis & Prevention 36, 2004, 697-704.
3. AKGÜNGÖR AP, DOĞAN E. *An application of modified Smeed, adapted Andreassen and artificial neural network accident models to three metropolitan cities of Turkey*. Scientific Research and Essays. 2009 Oct;4(9):906-913
4. 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
5. AHMED SEMEIDA, MOHAMED EL-SHABRAWY . *Investigation of Factors Contributing to Accidents on Rural Roads in Egypt Using Neural Networks*. /PORT SAID ENGINEERING RESEARCH JOURNAL Port Said University Faculty of Engineering. Volume 15 No. 1 pp: 5665..2011.
6. 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.
7. M. Y. ODUR, A. TORTUM: *An Artificial Neural Network Model for Highway Accident Prediction: A Case Study of Erzurum, Turkey*. Promet – Traffic&Transportation, Vol. 27, 2015, No. 3, 217-225.
8. 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>
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>