

دراسة مقارنة بين نموذج الشبكات العصبية ذات دالة الأساس الشعاعي وشبكة متعددة الطبقات
ونماذج ARIMA للتنبؤ بحوادث المرور بولاية تلمسان خلال الفترة 2011-2019

Comparison between Neural Network Model of Radial Basis Function,
multilayer perceptron and ARIMA Model to Predict Traffic Accidents
in Tlemcen Region During the Period 2011-2019

عبد القادر ساهد¹، حسن فهوي²

Abdelkader Sahed¹, Hacem Kahoui²

¹ المركز الجامعي مغنية (الجزائر)، مخبر تقييم واستشراف السياسات الاقتصادية واستراتيجيات المؤسسات، sahed14@yahoo.fr

² المركز الجامعي مغنية (الجزائر)، مخبر تقييم واستشراف السياسات الاقتصادية واستراتيجيات المؤسسات، hacenkahwi@gmail.com

تاريخ الاستلام: 2020/09/01 تاريخ القبول: 2021/07/27 تاريخ النشر: 2021/07/29

ملخص:

تهدف هذه الدراسة إلى مقارنة تنبؤ نموذج الشبكات العصبية ذات دالة الأساس الشعاعي RBF مع شبكة متعددة الطبقات MLP ونماذج ARIMA في تحليل السلسلة الزمنية الخاصة بحوادث المرور الشهرية لولاية تلمسان للفترة من 2011 إلى 2019، وقد تم الاعتماد على معيار جدر متوسط مربعات الخطأ (SMSE) للمقارنة بين النماذج الثلاث. ومن خلال البحث تم التوصل إلى مجموعة من النتائج التجريبية أهمها أن النموذج RBF يعطي نتائج أفضل من شبكة متعددة الطبقات MLP ونموذج ARIMA في التنبؤ بحوادث المرور بولاية تلمسان.

كلمات مفتاحية: : حوادث المرور، نموذج RBF، نموذج MLP، الشبكات العصبية، ARIMA.
تصنيفات JEL : C22، C32، C45، C53

Abstract:

This study aims to test the ability of the neural networks radial basis function model to predict road traffic accidents, compared to the LMP neural networks model and the ARIMA model.

The sample included historical data on the number of traffic accidents in the county of Tlemcen, during the period from 2011 to 2019, and we obtained that the RBF model is better than the MLP neural network model and ARIMA model in the prediction of traffic accidents in Tlemcen Region.

¹ المؤلف المرسل: عبد القادر ساهد، الإيميل: sahed14@yahoo.fr

Keywords: traffic accidents, RBF model, MLP model, neural networks, ARIMA.

JEL Classification Codes: C22, C32, C45, C53

1. مقدمة:

تعد ظاهرة حوادث المرور من أكبر المشاكل التي أثقلت كاهل الدول المتقدمة والنامية على حد سواء، حيث أشارت البحوث العلمية على أنها السبب الرئيسي للإصابة والموت في جميع أنحاء العالم (Margie Penden, 2004, p. 19)، والتي ينتج عنها ما يقدر بنحو 1,30 مليون شخص يلقوا حتفهم سنويا في حوادث المرور ويصاب ما بين 20 إلى 50 مليون آخرين سنويا، حيث تقدر تكلفة هذه الأخيرة أكثر من 500 مليار دولار أمريكي في جميع أنحاء العالم (Agyemang, 2013, p. 41)، إضافة إلى أن تقدير تكلفة إصابات المرور على الطرقات في البلدان المنخفضة والمتوسطة الدخل ما يعادل 2% من الناتج المحلي الاجمالي (تتجاوز 100 مليار أمريكي سنويا) (Chukwutoo C. Ihueze, 2018, p. 21)، كما تشير الدراسات أن تكون إصابات المرور على الطرقات السبب الرئيسي السابع للموت بحلول العام 2030 (Manikandan, 2018, p. 3962)، وأن نسبة الوفيات الناجمة عن حوادث المرور ستخفض في الدول المتقدمة والعكس بالنسبة للدول النامية التي سوف تعرف تزايد بنسبة أكثر من 80% (Ali Ahmed Mohammed, 2019, p. 66) لذلك يختلف نمط الوفيات والإصابات الناجمة من حوادث المرور على الطرقات في البلدان النامية عن مثيلاتها في البلدان المتقدمة.

إن الجزائر مثلها مثل بقية الدول تعاني وبشدة من حوادث المرور على الطرقات، حيث تحتل المرتبة 98 في التصنيف العالمي لحوادث المرور، إفريقيا تحتل المرتبة 42، حيث تكلف حوادث المرور من الناحية المادية الخزينة العمومية على ما لا يقل 100 مليار سنويا، بالإضافة إلى الخسائر البشرية التي تتضمن كل من حالة الوفاة والإصابة، حيث عرفت سنة 2016 و2017 و2018 تسجيل انخفاض في نسبة حوادث المرور مقارنة مع سنة 2015، وهذا من خلال الإجراءات التي قامت بها الدولة ورغم كل هذا لا تزال حوادث المرور تشكل تهديدا كبيرا في الجزائر.

تعد ولاية تلمسان إحدى ولايات الجزائر والتي بدورها تعاني من مشكل حوادث المرور على الطرقات، حيث أحصت مصلحة الامن العمومي لولاية تلمسان خلال سنة 2018، 528 حادث مقارنة بسنة 2017 أين تم تسجيل 552 حادث، إذ نلاحظ أن هناك انخفاض في عدد حوادث المرور

مقارنة بالسنة المنصرمة، وهذا بفضل الجمهور المبذولة من طرف مصالح الشرطة للوقاية من حوادث المرور زد إلى ذلك الحملات التحسيسية والتوعوية.

إن التنبؤ بحوادث المرور مهم لوضع الخطط الوقائية ويساعد من خلاله مراقبة حركة المرور على الطرقات، والتي من شأنها إعطاء معلومات لصانعي القرار لإيجاد الحلول ووضع السياسات اللازمة لذلك (Levis, 2005, p. 1009). يعد تحليل السلسلة الزمنية مؤخرًا اتجاه مهمًا في التنبؤ بحوادث حركة المرور (Xing, 2019, p. 2). لقد تم تطوير العديد من التقنيات للتنبؤ بسلوك سلسلة معينة في المستقبل، وتعتبر نماذج ARIMA من بين الأساليب الأكثر استخدامًا وشيوعًا في تحليل السلسلة الزمنية، كما أكد العديد من الباحثين أن استخدام ARIMA يمكن الحصول على نتائج جيدة وأكثر دقة (Haviluddina, 2015, p. 15)، وعلى الرغم من ذلك إلا أنها لا تزال تواجه بعض العقبات عند تطبيقها على البيانات الغير خطية، ولهذا حاول العديد من الباحثين أيضًا تطبيق الشبكات العصبية الاصطناعية العادية لتحسين دقة التنبؤ باستخدام بيانات غير خطية، حيث بينت النتائج قدرتها على التقاط مثل هذه الأنماط، إلا أن إحدى المشكلات المهمة في الشبكات العصبية الاصطناعية العادية هي تدريب أو تعليم الشبكات للحصول على مجموعة من معلمات الشبكة المثلى، ولتصدي لهذه المشكلة تم التطرق إلى الشبكات العصبية ذات دالة الأساس الشعاعي تتميز بالسرعة العالية في التدريب (Wang, 2006, p. 4).

1.1 إشكالية الدراسة: انطلاقًا مما سبق ارتأينا طرح الإشكالية التالية:

كيف يمكن ادراج نموذج الشبكات العصبية ذات دالة الأساس الشعاعي للتنبؤ بحوادث المرور بولاية تلمسان للفترة من 2011 إلى 2019 مقارنة بنماذج شبكة متعددة الطبقات ونماذج ARIMA؟

2.1 فرضيات الدراسة: للإجابة على إشكالية الدراسة تم وضع الفرضية التالية:

- نماذج الشبكات العصبية ذات دالة الأساس الشعاعي هي أفضل نموذج يسمح بنمذجة والتنبؤ بحوادث المرور بولاية تلمسان للفترة 2011 إلى 2019.

3.1 أهمية الدراسة: تبرز أهمية الدراسة من خلال العلاقة بين عشوائية حوادث المرور والتنبؤ، فكلما زادت العشوائية زادت أهمية التنبؤ بحوادث المرور من خلال استخدام أساليب حديثة على رأسها نماذج الشبكات العصبية، وهذا من أجل زيادة دقة التنبؤ، وذلك من أجل وضع الخطط الوقائية التي تساعد

حركة المرور على الطرقات، والتي من شأنها إعطاء معلومات لصانعي القرار لإيجاد الحلول ووضع السياسات اللازمة لذلك.

4.1 أهداف الدراسة:

- من بين أهداف الدراسة التي تسعى هذه الورقة البحثية إلى تسليط الضوء عليها هي:
- بناء نموذج الشبكات العصبية ذات دالة الأساس الشعاعي للتنبؤ بحوادث المرور بولاية تلمسان.
- تطبيق نموذج MLP للتنبؤ بحوادث المرور بولاية تلمسان.
- استخدام نموذج ARIMA للتنبؤ بحوادث المرور بولاية تلمسان.
- التحقق من مدى دقة وفعالية نموذج الشبكات العصبية ذات دالة الأساس الشعاعية مقارنة بنموذج MLP ونموذج ARIMA وذلك وفقا لمعيار دقة التنبؤ وممثل في جذر متوسط مربعات الأخطاء RMSE.

4.1 المنهج المتبع:

للإجابة على اشكالية الدراسة سيتم الاعتماد على المنهجين الوصفي والتطبيقي، فقد تم عرض نماذج التنبؤ المختلفة بدءا بنماذج ARIMA ونماذج الشبكات العصبية والمثلة في نماذج متعددة الطبقات MLP ونماذج الشبكات العصبية ذات الأساس الشعاعي RBF. ثم التطبيق الكمي من خلال استخدام النماذج الثلاث في التنبؤ بحوادث المرور، استنادا إلى بيانات شهرية لحوادث المرور بولاية تلمسان من سنة 2011 إلى سنة 2019. ذلك من أجل إيجاد النموذج الامثل للتنبؤ بحوادث المرور.

2. أدبيات الدراسات السابقة:

سوف نستعرض أهم الدراسات التي عاجلت موضوع التنبؤ بحوادث المرور فيما يلي:

دراسة ل (Liu, 2010) بعنوان نموذج التنبؤ بحوادث المرور على أساس شبكة BP العصبية المحسنة، هدفت هذه الدراسة إلى اقتراح نموذج تنبؤ قائم على تحسين BP، حيث يقوم من خلاله دمج العوامل التي تؤثر على حركة المرور. يستخدم نموذج التنبؤ بحوادث المرور للكثافة السكانية وشبكة الطرق، وكثافة السيارات، كمدخلات لخلايا عصبية وخلايا عصبية ناتجة عن وفيات شاملة لحوادث الطرق، وأظهرت النتائج أن شبكة BP العصبية المحسنة مناسبة تماما للتنبؤ بحوادث المرور.

دراسة ل (MENG, 2012) بعنوان نموذج التنبؤ لحوادث المرور على أساس الشبكات العصبية RBF، هدفت هذه الدراسة إلى طرح نموذج تنبؤي يستخدم الشبكة العصبية RBF عن طريق بيانات الحوادث المرورية للفترة الممتدة من 1990 إلى 2009 في الصين، ثم تصميم نموذج تنبؤ باستخدام

RBF للتنبؤ بحوادث المرور التي تحدث في الفترة الممتدة من 2000 إلى 2010، حيث بينت النتائج أن النموذج المعتمد، يعتمد عليه.

دراسة ل (Avuglah, 2014) بعنوان تطبيق نماذج ARIMA على حوادث المرور وعلى الطرق "حالة غانا". حيث هدفت هذه الورقة إلى استخدام نماذج ARIMA للتنبؤ بحوادث المرور على الطرق في غانا للمدة الزمنية الممتدة من 1991 إلى 2011، حيث أظهرت النتائج أن النموذج المقترح $(0, 2, 1)$ ARIMA أعطى أفضل النتائج وخلال التنبؤ لمدة خمس سنوات أظهرت أن حالات حوادث المرور في غانا ستستمر في الزيادة.

دراسة (Jadaan, 2014) بعنوان التنبؤ بحوادث المرور على الطرق في الأردن باستخدام الشبكة العصبية الاصطناعية حيث هدفت الدراسة إلى التنبؤ بحوادث المرور في الأردن للمدة الممتدة من 1990 إلى 2011 باستخدام الشبكات العصبية الاصطناعية، حيث تبين من خلال النتائج أن التنبؤ باستخدام ANN يعطي نتائج قريبة لحوادث المرور الفعلية وبالتالي يمكن الاعتماد عليها للتنبؤ بحوادث المرور المستقبلية في الأردن.

دراسة (Manikandan, 2018) بعنوان التنبؤ بالوفيات الناجمة عن حوادث المرور في الهند باستخدام نموذج SARIMA، حيث هدفت هذه الورقة إلى التنبؤ بالوفيات الناجمة عن حوادث المرور في الهند للفترة الممتدة من 2001 إلى 2012 باستخدام نموذج SARIMA، ومن خلال النتائج تم اختيار نموذج SARIMA المناسب $(1,0,0)$ $(2,1,0)$ بناءً على الحد الأدنى من قيم AIC وBIC.

دراسة ل (Chukwutoo, 2018) بعنوان نماذج التنبؤ بحوادث المرور لولاية أنامبرا (نيجيريا)، حيث هدفت هذه الدراسة إلى تحليل حوادث الطرق المرورية في ولاية أنامبرا بقصد تطوير نماذج تنبؤية دقيقة وهذا باستخدام نموذج ARIMA وARIMAX للفترة الممتدة من 1 جانفي 2005 إلى 31 ديسمبر 2015 (132 شهرا)، حيث بينت النتائج أن نموذج ARIMAX هو الأنسب للتنبؤ بحوادث المرور.

دراسة ل (الشمراي، 2018) بعنوان دراسة مقارنة بين استخدام الشبكات العصبية ونماذج ARIMA للتنبؤ بأعداد المصابين من حوادث الطرق بمدينة مكة المكرمة، استخدمت الدراسة المنهج الوصفي التحليلي، وتكونت عينة الدراسة من عدد الحوادث المرورية وأعداد المصابين، كما توصلت الدراسة

إلى أن أفضل نموذج (4.0.2) ARIMA. كما توصلت الدراسة إلى أن نموذج الشبكات العصبية الافضل في التنبؤ عن نموذج أربما، وهذا بالاعتماد على معايير التنبؤ. من خلال الدراسات السابقة التي تم التطرق إليها توصلنا إلى أن مساهمة الدراسة الحالية المتمثلة في دراسة مقارنة بين ثلاث أنواع من النماذج الحديثة في مجال التنبؤ ومثلة في نماذج الشبكات العصبية ذات الاساس الشعاعي RBF ونماذج متعددة الطبقات MLP ونماذج ARIMA. في حين نجد أن معظم الدراسات السابقة قد ركزت أحد من هذه النماذج الثلاث.

3. منهجية البحث:

في هذه الدراسة تم الاعتماد على بيانات شهرية لحوادث المرور بولاية تلمسان من الفترة الممتدة من 2011 إلى 2019، حيث تم الحصول على مصادر البيانات من مديرية الامن بولاية تلمسان، إذ تم تحويل البيانات السنوية إلى بيانات شهرية عن طريق البرنامج EVIEWS 10، ووفقا لذلك تم تقسيم البيانات إلى ثلاث عينات، الأولى كان الغرض منها التدريب والثانية الغرض منها الاختبار، أما الثالثة الممتدة من جانفي إلى سبتمبر 2019 كان الغرض منها التنبؤ.

1.3 نموذج ARIMA:

يعود اقتراح نماذج ARIMA إلى كل من Box and Jenkins في سنة (1979)، والتي تتكون من نماذج الانحدار الذاتي $AR(p)$ ذات الرتبة (p) ونماذج المتوسطات المتحركة $MA(q)$ ذات الرتبة (q) ، وجزء يدعى بالفروق ذات الرتبة (d) ، وبذلك تكتب بالشكل المختصر $ARIMA(p,d,q)$ ، لتأخذ المعادلة التالية:

$$y_t = \theta_0 + \theta_1 y_{t-1} + \dots + \theta_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

وتتضمن هذه المنهجية ثلاث مراحل، المرحلة الاولى تدعى بالتعرف، حيث يتم فيها تحديد الرتب (p,q) وهذا بالاعتماد على الرسم البياني لدالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئية، أما في المرحلة الثانية فيتم تقدير النموذج المتعرف باستخدام إما طريقة المربعات الصغرى أو طريقة الامكان الاكبر، بعد ذلك نمر إلى المرحلة الثالثة ومثلة في تشخيص النموذج وهذا بالاعتماد على تذبذبة كمية المعلومات ل AIC و BIC والتي تعطى العلاقة التالية (7) (Akhter et al, 2020, p. 7):

$$AIC = -2l(\theta/y) + 2m$$

$$BIC = -2l(\theta/y) + 2 \log N$$

m : عدد الملمات

$l(\theta/y)$: لوغاريتم الاحرجية

N : حجم العينة

2.3 الشبكات العصبية الاصطناعية MLP:

تعد الشبكات العصبية الاصطناعية نوع من أنواع الذكاء الاصطناعي الحديثة، كما تعتبر نظام حاسوبي مصمم لمعالجة المعلومات، يتكون من عدد كبير جدا من عناصر المعالجة المترابطة فيما بينها أدوات طبيعة ديناميكية، وظيفتها هي التقسيم المتوازي لحساب الشبكة، وتتكون الشبكة العصبية من عدد وحدات المعالجة المتداخلة و المتجانسة كل وحدة بمفردها اداة حسابية يمكن نمذجة سلوكها بصيغ رياضية بسيطة (مثينة عبدالله مصطفى، 2007، صفحة 180).

وقد عرفها العالم (Robert Nielsen) على أنها نظام حسابي متكون من عدد من وحدات المعالجة المترابطة فيما بينها وتوصف بطبيعتها الديناميكية المتوازنة في معالجة البيانات الداخلة إليها (Mishra, 2013, p. 2).

وتتكون بنية الشبكة العصبية الاصطناعية من طبقة الإدخال، الطبقة المخفية، طبقة الإخراج (Faridah Othman, 2011, p. 435).

طبقة الإدخال: هي طبقة تتواصل مع البيئة الخارجية تمثل طبقة الإدخال نمطا للشبكة العصبية، وبمجرد تقديم نموذج طبقة الإدخال ستنتج طبقة الإخراج نمطا آخر، كما أنها تمثل الشرط الذي من أجله نقوم بتدريب الشبكة العصبية (Karsoliya, 2012, p. 714).

طبقة الإخراج: طبقة المخرجات للشبكة العصبية هي ما يقدم في الواقع نمطا للبيئة الخارجية يجب أن يرتبط عدد الخلايا العصبية الناتجة ارتباطا مباشرا بنوع العمل الذي يتعين على الشبكة القيام به. طبقة مخفية: الطبقة المخفية للشبكة العصبية هي الطبقة الوسيطة بين طبقة المدخلات والمخرجات تنطبق وظيفة التنشيط على الطبقة المخفية إذا كانت متوفرة، تتكون الطبقة المخفية من العقد المخفية، العقد المخفية أو الخلايا العصبية المخفية هي الخلايا التي لا توجد في طبقة الإدخال ولا طبقة الإخراج.

3.3 الشبكات العصبية ذات دالة الأساس الشعاعي RBF

تعتبر الشبكة العصبية ذات دالة الأساس الشعاعي إحدى شبكات العصبية الاصطناعية التي تم صياغتها من قبل العالمان (Broomhead and Lowe) في عام 1988، حيث لها دور فعال جدا في

عملية تصنيف البيانات التي تحتوي على نسبة من الضوضاء، كما تستخدم الشبكة في نماذج التمثيل الخطي وغير الخطي، حيث تم استخدامها في العديد من المجالات كدالة تقريب في التنبؤ بالسلاسل الزمنية والتصنيف ومراقبة النظام (Jasmina, 2017, p. 2) كما تتميز بخصائص هجينة مقارنة مع الشبكات الأخرى بالإضافة إلى قدرتها على التكيف والتعديل عن طريق التعلم لإيجاد دوال الربط بين المدخلات والمخرجات لإنتاج قرار معين حسب المسألة المراد حلها (Shin, Park, & Choi, 1996, p. 3).

تعتمد شبكة RBF على نوعين من التعليم وهما كالاتي (Mark, 1996, p. 6):

التعليم بغير إشراف: نجد هذا النوع من التعليم في الطبقة المخفية، وتسمى هذه الطريقة بالتعليم الذاتي، أي أن قيم الإخراج الناتجة تكون بصورة مباشرة إدخالات إلى طبقة الإخراج.
التعليم بإشراف: ويوجد هذا النوع في طبقة الإخراج، حيث يتم تدريب الشبكة فيما حتى الوصول أو الحصول على الإخراج المطلوب، والتدريب هنا يكون وفقا لخوارزمية التدريب.
ومن بين أكثر دوال التنشيط استخداما في التطبيقات هي دالة التفعيل Gaussian، وتستعمل في الطبقة المخفية لتأخذ الشكل الرياضي التالي (K. Xu, 2003, p. 258):

$$\mu_j = \exp \left[-\frac{\|X - C_j\|^2}{2\sigma_j^2} \right], \quad j = 1, 2, K, N$$

حيث:

μ_j : الإخراج للخلية (j)، حيث تكون قيمة الإخراج محصورة بين [0، 1]

X : متجه الإدخال للشبكة

C_j : متجه الأوزان المرافقة للمدخلات وهي قيم عشوائية مولدة .


4. النتائج والمناقشة:

من أجل القيام بعملية التنبؤ باستخدام نماذج ARIMA ونماذج MLP ونماذج RBF تم استخدام بيانات السلسلة الزمنية المتعلقة بحوادث المرور الشهرية بولاية تلمسان للفترة 2011 إلى 2019.

1.4 نموذج ARIMA:

من خلال الشكل البياني (1) للسلسلة الحوادث المرور الفعلية يتضح وجود اتجاه عام وتشتت القيم غير ثابت على طول السلسلة قيد الدراسة، هذا يعني أن السلسلة غير مستقرة وبالتالي فإن التوقع غير ثابت وتباين غير ثابت أيضا. لذا سيتم أخذ الفروق الأولى لتثبيت الوسط الحسابي والتباين.


الشكل 1: سلسلة حوادث المرور بولاية تلمسان




المصدر: من إعداد الباحثين

ولجعل السلسلة مستقرة تم أخذ الفروق للسلسلة الاصلية. ومن أجل التعرف على نموذج ARIMA، قمنا برسم دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئية الشكل (2)، (3)، وبعد المفاضلة بين عدد من نماذج ARIMA وهذا بالاعتماد على معيار أكايك وشيوارز، تبين أن النموذج $ARIMA(3,1,0)$ هو الأفضل.

الشكل 2: دالة الارتباط الذاتي للسلسلة الفروق



الشكل 3: دالة الارتباط الجزئي للسلسلة الفروق



المصدر: من إعداد الباحثين

بعدما تم التعرف على نموذج ARIMA الملائم للتنبؤ بحوادث المرور، تأتي مرحلة التقدير النموذج مستخدمين في ذلك طريقة الامكان الاكبر وكانت النتائج ممثل في الجدول (1):


الجدول 1: تقدير النموذج ARIMA(3,1,0)

ARIMA Model Parameters					Estimate	SE	t	Sig.
AC- Model_1	AC	No Transformation	AR	Lag 1	-0.346	.096	-3.620	.000
				Lag 2	-0.330	.096	-3.433	.001
				Lag 3	-0.310	.096	-3.216	.002
		Difference			1			

المصدر: من إعداد الباحثين

ومن أجل مقارنة القيم الفعلية لحوادث الطرقات والقيم المقدرة باستخدام النموذج ARIMA(3,1,0)، قمنا برسم ذلك في معلم واحد، والشكل (4) يوضح التقارب بين القيم الفعلية والمتنبأ بها، وهذا يدل على دقة التنبؤ باستخدام نماذج ARIMA.

الشكل 4: القيم الفعلية والمنتبأ بها باستخدام النموذج ARIMA(3,1,0)



المصدر: من إعداد الباحثين

2.4. نموذج الشبكات العصبية MLP.

في البداية قمنا بتقسيم البيانات إلى عينة التدريب والتي تمثل 76 مشاهدة إي بنسبة 74.5% وعينة الاختبار بـ 26 مشاهدة إي بنسبة 25.5%.


بعد ذلك قمنا بتحويل البيانات الاصلية إلى بيانات معيارية باستخدام الدرجة المعيارية التالية:

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

ومن اجل الحصول على الشبكة العصبية المثلي، فقد تم تجريب عدد المدخلات من (1,2,.....,10,11,12)، وفي كل مرة يتم تغيير عدد العقد في الطبقة الخفية، وفي نفس يتم استخدام دالة التنشيط المناسب لذلك، لأجل الحصول على الاوزان المثلي التي تعطي أقل مجموع مربع الاخطاء،

لذلك، فإن معمارية المثلي للشبكة العصبية مكون من 3 مدخلات (yt-3، yt-2، yt-1)، وطبقة مخفية مكونة من عقدتين، أما في يخص دالة التنشيط فقد تم اختيار دالة Hyperbolic tangent ، ومخرج واحد. وأن مجموع مربعات الاخطاء بالنسبة لعينة التدريب يساوي 25.637، أما بالنسبة لعينة الاختبار فيساوي 21.980. حيث يوضح الشكل (5) المقارنة بين القيم الفعلية والمنتبأ بها باستخدام نموذج ANN(3,2,1).

الشكل 5: مقارنة بين القيم الفعلية المتنبأ بها باستخدام نموذج ANN(3,2,1)




المصدر: من إعداد الباحثين

3.4. نموذج الشبكات العصبية ذات دالة الاساس الشعاعي RBF

يظهر لنا الشكل (6) أن نموذج RBF يتكون من ثلاث طبقات، طبقة المدخلات ومكونة من ثلاث مدخلات وهي $(Y_{t-3}, Y_{t-2}, Y_{t-1})$ ، وطبقة المخفية مكونة من عقدين وطبقة المخرجات مكونة من مخرج واحد يمثل في عدد الحوادث الطرقات المتنبأ بها.

الشكل 7: معمارية RBF



المصدر: من اعداد الباحثين

ومن خلال الجدول (2) يظهر لنا أن مجموع مربعات الاخطاء في عينة التدريب تقدر بـ 25,637 وأن دالة التنشيط المستخدم هي من النوع Normalized radial basis fonction، وأن مجموع مربعات الاخطاء في عينة الاختبار تقدر بـ 21,980.


الجدول 2: ملخص عملية التدريب والاختبار للنموذج RBF

	عينة التدريب	عينة الاختبار
مجموع مربعات الاخطاء	25,637	21,980
الخطأ النسبي	0,732	1,045
عدد المدخلات	3	3
عدد العقد في الطبقة الخفية	2	2
دالة التنشيط	دالة الاساس الشعاعية الغوسية	دالة الاساس الشعاعية الغوسية
حجم العينة	71 أي 69.6%	31 أي 30.4%

المصدر: من اعداد الباحثين

ومن أجل مقارنة القيم الفعلية لحوادث الطرقات والقيم المتنبأ بها باستخدام طريقة RBF، تم رسم هذه القيم في معلم واحد، إذ نلاحظ أن القيم المتنبأ بها تقترب من القيم الفعلية، والشكل (8) يوضح ذلك.

الشكل 8: يوضح القيم الفعلية والمتنبأ بها باستخدام نموذج RBF



المصدر: من اعداد الباحثين

5. المقارنة بين النماذج RBF، MLP، ARIMA

ولاختبار جودة التنبؤ بعدد حوادث الطرقات قمنا بحساب التنبؤ خارج العينة، ومن أجل مقارنة دقة التنبؤ بحوادث المرور بين النموذج المقترح ممثلاً في نموذج الشبكات ذات دالة الأساس الشعاعي ونموذج متعدد الطبقات ونموذج ARIMA، ومن خلال الجدول (3) نلاحظ أن نموذج RBF يأخذ أقل قيمة لمعيار جدر متوسط مربعات الاخطاء (RMSE) على عكس نموذج MLP ونموذج ARIMA.

الجدول 3: التنبؤ بعدد حوادث المرور باستعمال نموذج RBF و MLP و ARIMA

DATA	AC	ARIMA(3,1,0)	MLP(3,2,1)	RPF(3,2,1)
1-Jan-19	47	46.32	49.38	44.74
1-Feb-19	52	44.28	47.95	48.45
1-Mar-19	50	50.64	49.46	50.7
1-Apr-19	53	49.97	50.02	50.59
1-May-19	65	51.07	50.76	52.24
1-Jun-19	51	60.47	56.08	53.03
1-Jul-19	62	50.96	53.63	53.02
1-Aug-19	45	59.09	53.52	53.05
1-Sep-19	50	51.6	50.19	52.67
RMSE		8.66	6.68	6.17

المصدر: من إعداد الباحثين

AC: عدد حوادث المرور

6. خاتمة

أوضحت الدراسة الحالية قدرة نماذج الشبكات العصبية ذات الأساس الشعاعي في التنبؤ بحوادث الطرقات بولاية تلمسان مقارنة بنماذج متعددة الطبقات MLP ونماذج ARIMA، ومن بين النتائج التي تم توصل إليها تتمثل فيما يلي:

- تظهر النتائج أن سلسلة عدد حوادث الطرقات غير مستقرة في المستوى وأنها من النوع $ARIMA(3,1,0)$.
- أسفرت نتائج التحليل أن نموذج الشبكات العصبية MLP ونموذج دالة الأساس الشعاعي يأخذان الهيكلية المثلى للشبكة العصبية من النوع $ANN(3,2,1)$.

- من خلال المقارنة بين النماذج الثلاث وبالاعتماد على معيار RMSE تبين أن نموذج الشبكات العصبية ذات دالة الأساس الشعاعي أعطى نتائج أفضل وقدرة عالية في التنبؤ بعدد حوادث الطرقات بولاية تلمسان وذلك لامتلاكه أقل قيمة للمعيار RMSE مقارنة بنموذج MLP ونموذج ARIMA.

من خلال النتائج السابقة يمكننا وضع التوصيات الآتية:

- استخدام مقارنة بين نماذج المعلمية ولا معلمية والمفاضلة بينهما من أجل التوصل إلى أفضل النماذج التي يمكننا من نمذجة والتنبؤ بحوادث المرور.
- استخدام النماذج الهجينة التي تجمع بين الشبكات العصبية ونماذج ARIMA للتنبؤ بحوادث المرور.
- أخذ بعين الاعتبار نماذج الانحدار في تحديد المتغيرات المستقلة التي تحكم ظاهرة حوادث المرور من أجل التشخيص الجيد للعوامل المؤثرة في مشكلة حوادث الطرقات ومعالجتها.

7. قائمة المراجع:

1. مينة عبدالله مصطفى، ص. ي. (2007). مقارنة بين التنقية المكيفة والشبكات العصبية ذات الانتشار العكسي في السلاسل الزمنية. تنمية الرافدين، المجلد 29، العدد 88، ص ص 177-192.
2. محمد موسى الشمراني. (2018). دراسة مقارنة بين استخدام الشبكات العصبية ونماذج اريما (ARIMA) للتنبؤ بأعداد المصابين من حوادث الطرق بمدينة مكة المكرمة للفترة الممتدة من 1425 هـ إلى 1435 هـ. مجلة الشمال للعلوم الاساسية والتطبيقية، المجلد 3، العدد 1، ص ص 1-20.
3. Ali Ahmed Mohammed, K. A. (2019). A Review of the Traffic Accidents and Related Practices Worldwide. *The Open Transportation Journal*, 13(1).
4. Avuglah, R. K. P. (2014). Application of ARIMA models to road traffic accident cases in Ghana. *International journal of statistics and applications* , 4(5), pp.233-239..
5. Brownlee, J. (2011). Cleveralgorithms: nature-inspired programming recipes. Jason Brownlee. <http://creativecommons.org/licenses/by-nc-sa/2.5/au/legalcode>, p21.

6. Chukwutoo C. Ihueze, U. O. (2018). Road traffic accidents prediction modelling: An analysis of Anambra State, Nigeria. *journal homepage: Accident Analysis & Prevention*, 112, pp.21-29..
7. Faridah Othman, M. N. (2011). Reservoir inflow forecasting using artificial neural network. *International journal of physical sciences*, 6(3), pp.434-440.
8. G. C. Mishra, A. S. (2013). A study on forecasting prices of groundnut oil in Delhi by ARIMA methodology and artificial neural networks. *Agris on-line Papers in Economics and Informatics*, 5(665-2016-44959), pp.25-34.
9. Gh.A. Montazera, , R. (2007). Improvement of learning algorithms for RBF neural networks in a helicopter sound identification system. *Neurocomputing*, 71(1-3), pp.167-173.
10. Havaluddina, A. J. (2015). Comparing of ARIMA and RBFNN for short-term forecasting. *International Journal of Advances in Intelligent Informatics*, 15.
11. Jadaan, K. S.-F. (2014). Prediction of road traffic accidents in Jordan using artificial neural network (ANN). *Journal of Traffic and Logistics Engineering*, 2(2).
12. Jasmina, N. &. (2017). Solving medical classification problems with RBF neural network and filter methods. *International Journal of Reasoning-based Intelligent Systems*, 9(2), pp.80-89.
13. K. Xu, M. X. (2003). Application of neural networks in forecasting engine systems reliability. *Applied Soft Computing*, 2(4), pp.255-268.
14. Karsoliya, S. (2012). Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture. *International Journal of Engineering Trends and Technology*, 3(6), pp.714-717.
15. Levis, A. A. (2005). Customer demand forecasting via support vector regression analysis. *Trans IChemE, Part A, Chemical Engineering Research and Design*, 83(8), pp.1009-1018.
16. Liu, W. N. (2010). Forecasting Model of Road Traffic Accident Based on Improved BP Neural Network. *Computer System Application*, pp.177-181.
17. Manikandan, M. P. (2018). Forecasting road traffic accident deaths in India using seasonal autoregressive integrated moving average model. *International Journal Of Community Medicine And Public Heal*, 5(9), p.3962..
18. Margie Penden, R. S. (2004). World report on road traffic injury prevention. *World Health Organization Geneva*, p19.

19. MENG, J. &. (2012). A Forecasting Model for Road Traffic Accident Based on RBF Neural Networks. *Journal of Changshu Institute of Technology*, 2.
- Mark, J. L. (1996). Introduction to radial basis function networks. *Centre for Cognitive Science University of Edinburgh Buccleuch Place Edinburgh EH LW Scotland*, p6.
20. Shin, C. y., Park, S. H., & Choi, Y. H. (1996). Radial Basis Function Network Design for Chaotic Time Series Prediction. *Journal Name: Chongi Hakhoe Nonmunchi (Transactions of the Korean Institute of Electrical Engineers)*, 45, pp.602-611.
21. Wang, Z. H. (2006). A comparison among three neural networks for text classification. *In 8th international Conference on Signal Processing*, Nov 16 (Vol. 3). IEEE. p4.
22. Xing, Y. B. (2019). Large-Scale Traffic Congestion Prediction Based on the Symmetric Extreme Learning Machine Cluster Fast Learning Method . *Symmetry*, 11(6), p.730.
23. Akhter, M. F., Hassan, D., & Abbas, S. (2020). Predictive ARIMA Model for coronal index solar cyclic data. *Astronomy and Computing*, p.100403.