



التنبؤ بالسلسلة الزمنية لجرائم القتل العمد في العراق باستعمال النموذج الهجين ARIMA-ANN

م. د. قصي احمد طه غرب الجبوري

إعدادية النيل للبنين/ مديرية تربية نينوى/ وزارة التربية

الخلاصة:

تشير الأنشطة البحثية الحديثة في التنبؤ باستعمال الشبكات العصبية الاصطناعية (ANNs) إلى إمكانية أن تكون نماذج (ANNs) بديلاً جيداً للطرق الخطية التقليدية. في هذا البحث تم تطبيق أسلوب هجين يجمع بين نموذجي (ARIMA) و (ANN) للاستفادة من قوة النمذجة الخطية وغير الخطية، إذ تشير الاستنتاجات التي تم التوصل إليها من خلال تحليل مجموعة البيانات الخاصة بجرائم القتل العمد بسبب المشاحنات الأنية والنزاعات العشائرية في العراق للفترة من (2019-2023) الى فعالية النموذج الهجين (ARIMA-ANN) في تحسين دقة التنبؤ مقارنة بالنموذج الفردي.

الكلمات المفتاحية: نموذج (ARIMA-ANN)، السلاسل الزمنية، الشبكات العصبية الاصطناعية (ANNs).

1- المقدمة

يعد نموذج (ARIMA) أحد أهم نماذج السلاسل الزمنية وأكثرها استعمالاً، وترجع أهميته إلى خصائصه الإحصائية بالإضافة إلى منهجية (Box-Jenkins) المعروفة في عملية بناء النموذج، كما تعد دقة التنبؤ بالسلاسل الزمنية أمراً أساسياً للعديد من عمليات اتخاذ القرار، ومن ثم فإن البحث عن تحسين فعالية نماذج التنبؤ لم يتوقف أبداً. وعلى الرغم من أن نماذج (ARIMA) مرنة للغاية من حيث أنها يمكن أن تمثل عدة أنواع مختلفة من السلاسل الزمنية، أي سلاسل الانحدار الذاتي (AR) والمتوسطات المتحركة (MA) والسلاسل المركبة (ARMA)، فإن القيد الرئيس لها هو الشكل الخطي المفترض مسبقاً للنموذج، أي أنه يتم افتراض بنية ارتباط خطية بين قيم السلاسل الزمنية ومن ثم لا يمكن التقاط أنماط غير خطية بواسطة نموذج (ARIMA). (McKenzie, 1984, p. 335)

في الآونة الأخيرة، تم توظيف الشبكات العصبية الاصطناعية (ANNs) على نطاق واسع واستعمالها في التنبؤ بالسلاسل الزمنية، حيث قدم الباحثون مراجعة حديثة في هذا المجال، مثل دراسة (Zhang) عام (2012) ركزت هذه الدراسة على مراجعة للتطورات الأخيرة في التنبؤ بالسلاسل الزمنية باستعمال الشبكات العصبية، وسلطت الضوء على مزايا الشبكات العصبية مقارنة بنماذج التنبؤ التقليدية وناقشت التطبيقات الحديثة في مجالات مختلفة. ودراسة (Hewamalage) وآخرون عام (2020) التي تقدم هذه الدراسة التجريبية إرشادات وأفضل الممارسات لاستعمال

الشبكات العصبية المتكررة (RNNs) في التنبؤ. وهي تتضمن إطار عمل برمجياً مفتوح المصدر لتطوير هياكل الشبكات العصبية المتكررة. ودراسة (Abdulkarim & Engelbrecht) عام (2021) وتبحث هذه الدراسة في تطبيق خوارزميات تحسين سرب الجسيمات (PSO) لتدريب الشبكات العصبية للتنبؤ بالسلاسل الزمنية في البيانات الديناميكية، وتُظهر النتائج أن خوارزميات تحسين سرب الجسيمات الديناميكية تتفوق على خوارزميات تحسين سرب الجسيمات القياسية والانتشار الخلفي المرن (Rprop) في تطبيقات التنبؤ في العالم الحقيقي. ودراسة (Song) وآخرون عام (2024) التي تستعرض التطورات في نماذج التنبؤ القائمة على التعلم العميق من عام 2014 إلى عام 2024. وتفحص قدرات هذه النماذج في النقاط الارتباطات خلال الزمن وتقيم فعاليتها في مهام التنبؤ أحادية المتغير ومتعددة المتغيرات.

تكمن الميزة الرئيسة للشبكات العصبية هي قدرتها المرنة على النمذجة غير الخطية، ولا توجد حاجة لتحديد شكل نموذج معين عند استعمالها، بل يتم تشكيل النموذج بشكل تكيفي بناءً على الميزات المقدمة من البيانات، هذا النهج القائم على البيانات مناسب للعديد من مجموعات البيانات التجريبية حيث لا تتوفر إرشادات نظرية لاقتراح عملية مناسبة لتوليد البيانات. (Mbuva, 2017, p. 7)

نادراً ما تكون السلاسل الزمنية خطية أو غير خطية تماماً وغالباً ما تحتوي على أنماط خطية وغير خطية معاً، في هذه الحالة لن تكون (ARIMA) ولا الشبكات العصبية (ANN) كافية لنمذجة وتوقع السلاسل الزمنية نظراً لأن نموذج (ARIMA) لا يمكنه التعامل مع العلاقات غير الخطية بينما لا يستطيع نموذج (ANN) وحده التعامل مع الأنماط الخطية وغير الخطية على قدم المساواة. ومن ثم من خلال الجمع بين نموذج (ARIMA) ونموذج (ANN) يمكن نمذجة مركبات الارتباط الذاتي المعقدة في البيانات بدقة أكبر. وقد أشار الكثير من الباحثين إلى أن الجمع بين النماذج المختلفة يمكن أن يعزز دقة التنبؤ بما يتجاوز دقة النماذج الفردية، حيث يتضمن النموذج الهجين المزيد من المعلومات المرتبطة بالتغيرات المستقبلية المحتملة. (Chae et al., 1989, p. 186-187)

2- المشكلة وهدف البحث

في أدبيات التنبؤ لا توجد طريقة واحدة هي الأفضل في جميع الحالات ويرجع هذا إلى حقيقة مفادها أن المشكلات غالباً ما تكون معقدة بطبيعتها، وقد لا يكون أي نموذج معين قادر على التقاط أنماط مختلفة (خطية وغير خطية) بشكل جيد. على سبيل المثال، عند التنبؤ بالسلاسل الزمنية باستعمال الشبكات العصبية الاصطناعية (ANNs) تستعمل معظم الدراسات نماذج (ARIMA) كمعيار لاختبار فعالية نموذج الشبكات العصبية الاصطناعية بنتائج مختلفة. لذلك، يهدف البحث إلى تطبيق نهجاً هجيناً للتنبؤ بالسلاسل الزمنية باستعمال كل من نموذجي (ARIMA) و (ANN) معاً، للاستفادة من قوة النموذج الهجين في النمذجة الخطية وغير الخطية ولتحسين دقة التنبؤ، بحيث تكون أفضل من تلك التي تحققها أي من النماذج المستخدمة بشكل منفصل.

3- الذكاء الاصطناعي والإحصاء


تعتمد منتجات الذكاء الاصطناعي (artificial intelligence) القائمة على الرؤية الحاسوبية على تعاون قوي بين الإنسان والآلة من خلال خوارزميات التعلم العميق (deep learning) التي صممها باحثون والبيانات التي انشئت يدوياً، وتشترك أبحاث الذكاء الاصطناعي الحالية على التعاون بين الإنسان والآلة سواء في مرحلة توليد البيانات أو تصميم الخوارزمية واختبارها، وتشمل الأمثلة البارزة لتطبيقات الذكاء الاصطناعي السيارات ذاتية القيادة والتشخيصات

الطبية الآلية ويعتمد كلا التطبيقين على الخوارزميات الحاسوبية التي تعتمد على البيانات المولدة يدوياً. (Yu & Kumbier, 2018, p.7)

تلعب الإحصاءات دوراً حاسماً في تطوير وتطبيق الذكاء الاصطناعي حيث يعتمد الذكاء الاصطناعي في جوهره على البيانات وتوفر الإحصاءات الأدوات اللازمة لتحليل هذه البيانات وتفسيرها بشكل فعال، كما تستعمل الأساليب الإحصائية لتدريب نماذج التعلم الآلي وتقييم أدائها وضمان موثوقيتها. علاوة على ذلك، تساعد الإحصاءات في فهم عدم اليقين والتباين في تنبؤات الذكاء الاصطناعي، إذ تسمح النماذج الاحتمالية لأنظمة الذكاء الاصطناعي باتخاذ القرارات في ظل عدم اليقين. من ناحية أخرى يعمل الذكاء الاصطناعي على تعزيز مجال الإحصاء بشكل كبير من خلال أتمتة تحليل البيانات وكشف الأنماط التي قد تفوتها الطرق التقليدية، حيث تستعمل تقنيات الذكاء الاصطناعي، مثل التعلم الآلي والتعلم العميق، والشبكات العصبية الاصطناعية لبناء نماذج تنبؤية وإجراء تحليلات معقدة للبيانات، إذ يمكن لهذه النماذج التعامل مع مجموعات البيانات الكبيرة وتحديد العلاقات المعقدة داخل البيانات. بالإضافة إلى ذلك، يساعد الذكاء الاصطناعي في تحسين دقة وكفاءة الأساليب الإحصائية. ولا يعمل دمج الذكاء الاصطناعي في الإحصاء على تسريع معالجة البيانات فحسب، بل يوفر أيضاً رؤى أعمق، مما يؤدي إلى اتخاذ قرارات أكثر استنارة. (Friedrich et al, 2022, pp.827-82)

4- الشبكات العصبية الاصطناعية

نماذج حسابية مستوحاة من الدماغ البشري تتكون من عقد مترابطة أو خلايا عصبية (Neurons) تعمل معاً لمعالجة المعلومات والتعلم من البيانات، كما يمكن اعتبار الشبكات العصبية الاصطناعية (ANNs) نماذج إحصائية معقدة متعددة المتغيرات، ويمكن تفسير الأوزان في الشبكات العصبية الاصطناعية كمعاملات يتم تقديرها باستعمال الأساليب الإحصائية. إن نظام الشبكة العصبية عبارة عن مجموعة من طبقات الإدخال والإخراج وطبقة مخفية تحول طبقة الإدخال إلى معلومات مفيدة لطبقة الإخراج، وعادةً ما يتم تنفيذ عدة طبقات مخفية في شبكة عصبية اصطناعية، ويوضح الشكل (1) الآتي نظام شبكة عصبية يتكون من طبقتين مخفيتين. (O'Shea, 2015, pp. 4-5)




شكل (1) نظام شبكة عصبية يتكون من طبقتين مخفيتين

تلعب الشبكات العصبية الاصطناعية (ANNs) دوراً مهماً في الإحصاء وخاصة في مجالات التعرف على الأنماط والتصنيف وتحليل الانحدار، ويمكن للشبكات العصبية الاصطناعية تقريب الدوال المعقدة غير الخطية، ونمذجة العلاقة بين متغيرات الإدخال (المتنبئات) ومتغيرات الإخراج (الاستجابات) بطريقة مرنة وفعالة. كما تعدّ خوارزميات التعلم

المستخدمة لتدريب الشبكات العصبية الاصطناعية تقنيات إحصائية بطبيعتها، على سبيل المثال يعد الانتشار الخلفي وهو خوارزمية تعلم شائعة في الأساس طريقة انحدار تستعمل لتقليل دالة الخطأ. وظهر التعلم العميق (*deep learning*) وهو مجموعة فرعية من الشبكات العصبية الاصطناعية نجاحا ملحوظا في التطبيقات المختلفة، ومن وجهة نظر إحصائية غالباً ما تنطوي أساليب التعلم العميق على التنظيم الضمني (*implicit regularization*) ويمكنها التعامل مع البيانات عالية الأبعاد بشكل فعال. (López-Díaz et al, 2021, p. 598)

وتتلخص فكرة تدريب الشبكات العصبية الاصطناعية (ANNs) بافتراض وجود خلية عصبية اصطناعية أو العصبون الاصطناعي وهو الوحدة الأساسية في (ANNs)، ويتكون العصبون الاصطناعي من عدة أجزاء رئيسية تشبه إلى حد ما الخلية العصبية البيولوجية، وكما موضح بالشكل (2) الآتي:



شكل (2) الأجزاء الرئيسية للعصبون الاصطناعي¹

حيث تمثل المدخلات (*Inputs*) الإشارات أو البيانات التي يتم إدخالها إلى العصبون الاصطناعي، وان كل مدخل يتم وزنه بقيمة معينة تسمى الوزن (*Weight*) والأوزان هي القيم التي تضرب بها المدخلات لتحديد أهميتها، حيث عدلت الأوزان (w_i) خلال عملية التعلم لتحسين أداء الشبكة، ويمكن حساب (w_i) وفق الصيغة (1) الآتية:

$$\therefore w_i(m+1) = w_i(m) + \lambda \cdot y(m) \cdot x_i^{\oplus}(m) \quad (1)$$

حيث يمثل (m) عدد مرات التدريب (*iteration number*)، ويمثل (λ) معدل التعلم.

ويمثل الرمز (Σ) المجموع المرجح الناتج من ضرب المدخلات بأوزانها، حيث يتم جمع هذه القيم للحصول على المجموع المرجح. ويمثل الرمز (Ω) دالة التفعيل (*activation function*) يتم تطبيق هذه الدالة على المجموع المرجح لتحويله إلى قيمة الإخراج (y) وهي النتيجة النهائية التي ينتجها العصبون بعد تطبيق دالة التفعيل (Ω) على المجموع المرجح (Σ). (Chatterjee et al., 1998, pp. 319-320)

¹المصدر: [Artificial Neural Network - Basic Concepts](#)

5- نماذج التنبؤ بالسلاسل الزمنية

السلسلة الزمنية هي عبارة عن سلسلة من نقاط البيانات التي جُمعت أو سُجلت على مُدد زمنية متتالية ومتساوية في كثير من الأحيان، واستعمل هذا النوع من البيانات؛ لتتبع التغيرات بمرور الوقت، ويمكن تحليلها لتحديد الاتجاهات والأنماط والاختلافات الموسمية. إذ تساعد طريقة تحليل السلاسل الزمنية (وهو أسلوب إحصائي يستخدم لتحليل سلسلة من نقاط البيانات التي تم جمعها أو تسجيلها في مُدد زمنية محددة) في تحديد الأنماط الأساسية والاتجاهات والاختلافات الموسمية داخل البيانات، ومن خلال فحص نقاط البيانات المرتبة زمنياً يمكن للمحللين اتخاذ قرارات مستنيرة وتوقعات دقيقة، وموثوقة بعملية التنبؤ بالسلسلة الزمنية. وتعدُّ نماذج التنبؤ بالسلاسل الزمنية ضرورية للتنبؤ بالقيم المستقبلية استناداً إلى البيانات التاريخية، وهناك عدة طرق مختلفة لنمذجة السلاسل الزمنية منها النماذج الإحصائية التقليدية بما في ذلك المتوسطات المتحركة (*moving average*) والتمهيد الأسّي (*exponential smoothing*) ونموذج المتوسطات المتحركة المتكامل الانحدار الذاتي (ARIMA)، هذه النماذج تكون خطية حيث تقتصر التنبؤات بالقيم المستقبلية على دوال خطية للملاحظات السابقة، ونظراً لبساطتها النسبية في الفهم والتنفيذ كانت النماذج الخطية هي محور البحث الرئيس والأدوات التطبيقية خلال العقود القليلة الماضية. وللتغلب على قيود النماذج الخطية وتفسير بعض الأنماط غير الخطية التي يتم ملاحظتها في المشكلات الحقيقية، تم اقتراح عدة أنواع من النماذج غير الخطية في الأدبيات الإحصائية وتشمل هذه النموذج الخطي الثنائي (*bilinear model*) ونموذج الانحدار الذاتي العتبي (TAR) ونموذج الانحدار الذاتي غير المتجانس الشرطي (ARCH). تم اقتراح الشبكات العصبية الاصطناعية مؤخراً كنهج بديل للتنبؤ بالسلاسل الزمنية، إذ تكمن الميزة الأساسية للشبكات العصبية الاصطناعية في قدرتها على نمذجة الأنماط غير الخطية التي يمكن تمييزها.

(Kirchgässner et al., 2013, p. 565)

6- نموذج (ARIMA)

نموذج المتوسطات المتحركة المتكامل الانحدار الذاتي (ARIMA) هو أداة تحليل إحصائي شائعة تستعمل في تحليل السلاسل الزمنية لفهم البيانات أو التنبؤ بالنقاط المستقبلية في السلسلة الزمنية، وهو يجمع بين ثلاث مكونات: الانحدار الذاتي (AR)، والتكامل (I) الذي يتضمن الاختلافات بين المشاهدات لجعل السلسلة الزمنية ثابتة مما يعني أن خصائصها الإحصائية لا تتغير بمرور الوقت، والمتوسطات المتحركة (MA). وتعدُّ نماذج (ARIMA) مفيدة بشكل خاص للتنبؤ وتستعمل على نطاق واسع في مجالات مختلفة مثل الاقتصاد والعلوم البيئية وغيرها. (Shumway, 2017, p.75)

إن القيم المستقبلية المتغيرات في نموذج (ARIMA) عبارة عن دالة خطية من المشاهدات السابقة والأخطاء العشوائية، ومن ثم فإن العملية الأساسية التي تولد السلسلة الزمنية لها الشكل الآتي:

$$y_t = \theta_0 + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2)$$

حيث أن (y_t) و (ε_t) هما القيمة الفعلية والخطأ العشوائي في الفترة الزمنية (t) على التوالي، وان (ϕ_i) و (θ_j) هما معالم النموذج، وان p و q هما عددان صحيحان وغالباً ما يشار إليهما كرتب للنموذج. ويُفترض أن تكون الأخطاء العشوائية (ε_t) موزعة بشكل مستقل ومتماثل بمتوسط مساوٍ إلى صفر وتباين ثابت (σ^2) . وتتضمن المعادلة (1) عدة حالات خاصة مهمة من عائلة نماذج (ARIMA)، فإذا كان $(q = 0)$ فإن المعادلة (2) تصبح نموذج انحدار ذاتي (AR) من الدرجة p ، وعندما تكون $(p = 0)$ يتحول النموذج إلى نموذج متوسطات متحركة (MA) من الدرجة q . أن

إحدى المهام الأساسية لبناء نموذج (ARIMA) هي تحديد ترتيب النموذج المناسب (p, q) ، لذلك طور الباحثان (Box) و (Jenkins) نهجاً عملياً لبناء نماذج (ARIMA) والذي له التأثير الأساسي على تحليل السلاسل الزمنية وتطبيقات التنبؤ، وتتضمن منهجية (Box-Jenkins) ثلاث خطوات تكرارية لتحديد النموذج وتقدير المعلمات وتشخيص النموذج. أن الفكرة الأساسية لتشخيص النموذج هي أنه إذا تم إنشاء سلسلة زمنية من عملية (ARIMA) فيجب أن يكون لها بعض خصائص الارتباط الذاتي النظرية، ومن خلال مطابقة نماذج الارتباط الذاتي التجريبية مع النماذج النظرية يمكن تحديد نموذج واحد أو عدة نماذج محتملة للسلسلة الزمنية المعطاة. (Box & Jenkins, 2015, p.79)

في خطوة التشخيص غالباً ما تكون هناك حاجة إلى تحويل البيانات لجعل السلسلة الزمنية مستقرة (stationary)، وتعد الاستقرارية شرط ضروري في بناء نموذج (ARIMA) مفيد للتنبؤ، إذ تتمتع السلسلة الزمنية المستقرة بأن خصائصها الإحصائية مثل المتوسط وبنية الارتباط الذاتي ثابتة بمرور الوقت. وعندما تمتلك السلسلة الزمنية اتجاهًا عامًا وعدم تجانس في التباين (heteroscedasticity)، فإنه غالباً ما يتم أخذ الفروقات وتحويل القوة على البيانات لإزالة الاتجاه العام وتثبيت التباين قبل أن يتم تنفيذ نموذج (ARIMA). وبمجرد تحديد نموذج مبدئي يصبح تقدير معلمات النموذج أمراً مباشراً، يتم تقدير المعلمات بحيث يتم تقليل مقياس الأخطاء الإجمالي ويمكن القيام بذلك من خلال إجراء تحسين غير خطي (nonlinear optimization). الخطوة الأخيرة في بناء النموذج هي الفحص التشخيصي لملاءمة النموذج ويتمثل هذا في الأساس في التحقق مما إذا كانت افتراضات النموذج حول الأخطاء (ε_t) قد تحققت، ويمكن استعمال الكثير من الإحصائيات التشخيصية والمخططات للوقاي لفحص مدى ملاءمة النموذج المتخذ للبيانات وإذا لم يكن النموذج مناسب فيجب تحديد نموذج جديد، والذي يتبعه مرة أخرى خطوات تقدير المعلمات والتحقق من النموذج، وقد تساعد المعلومات التشخيصية في اقتراح نماذج بديلة. تتكرر عملية بناء النموذج المكونة من ثلاث خطوات عادةً عدة مرات حتى يتم اختيار نموذج مرضٍ في النهاية ومن ثم يمكن استعمال النموذج النهائي المُختار لأغراض التنبؤ. (Deb et al., 2017, p.906)

7- أسلوب (ANN) لنمذجة السلاسل الزمنية

تعد الشبكات العصبية الاصطناعية (ANNs) أحد هذه النماذج القادرة على تقريب الكثير من الظواهر غير الخطية في البيانات، ويمكن تعريفها بأنها أطر حوسبة مرنة تستعمل لنمذجة مجموعة واسعة من المشكلات غير الخطية. أن المعالجة المتوازية للمعلومات من البيانات هي مصدر قوة نماذج (ANNs)، إذ لا يتطلب افتراض مسبق لشكل النموذج في عملية بناء النموذج. بدلاً من ذلك، يتم تحديد نموذج الشبكة العصبية من خلال خصائص البيانات، ويتميز النموذج بشبكة من ثلاث طبقات من وحدات المعالجة البسيطة المتصلة بروابط غير دورية، حيث يمكن تمثيل العلاقة بين المخرجات (y_t) والمدخلات $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ رياضياً بالصيغة (3) الآتية:

$$y_t = \alpha_0 + \sum_{j=1}^q \alpha_j c \left(\beta_{0j} + \sum_{i=1}^p \beta_{ij} y_{t-i} \right) + \varepsilon_t \quad \dots (3)$$

حيث يمثل (j) معلمات النموذج والتي تسمى غالباً أوزان الاتصال (connection weight)، وان (p) هو عدد عقد الإدخال و (q) هو عدد العقد المخفية. كما نلاحظ من الصيغة (3) وجود عقدة إخراج واحدة في طبقة الإخراج والتي تستعمل عادةً للتنبؤ بخطوة واحدة للأمام، أن الشبكة العصبية الاصطناعية البسيطة المعطاة بالصيغة (3) قوية بشكل جيد

من حيث أنها قادرة على تقريب دالة عشوائية حيث أن عدد العقد المخفية (q) كبير بدرجة كافية. (Akouemo & Povinelli, 2017, p.3354)

إلى جانب، اختيار عدد مناسب من العقد المخفية فإن المهمة الأخرى في نمذجة الشبكات العصبية الاصطناعية للسلسلة زمنية هي اختيار عدد المشاهدات المتأخرة (p) وهو يُعد متجه الإدخال، الذي يؤدي دوراً رئيساً في تشخيص بنية الارتباط الذاتي غير الخطية للسلسلة الزمنية. مع ذلك، لا توجد نظرية يمكن استعمالها لاختيار (p)، وغالباً ما تُجرى التجارب لاختيار (p) المناسب بالإضافة إلى (q). وغالباً ما تستعمل الدالة اللوجستية كدالة نقل للطبقة المخفية، أي أن:

$$c(x) = \frac{1}{1 + \exp(-x)} \quad \dots \dots (4)$$

ومن ثم، فإن نموذج الشبكات العصبية الاصطناعية (ANN) المبين في المعادلة (3) يقوم في الواقع برسم خرائط الدوال غير خطية من المشاهدات السابقة ($y_{t-1}, y_{t-2}, \dots, y_{t-p}$) إلى القيمة المستقبلية أو المخرجات (y_t)، أي أن:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}, w) + \varepsilon_t \quad \dots \dots (5)$$

حيث يمثل الرمز (w) متجه المعلمات ويمثل الرمز (f) دالة يتم تحديدها بواسطة بنية الشبكة وأوزان الاتصال. ومن ثم، فإن الشبكة العصبية تعادل نموذج الانحدار الذاتي غير الخطي (nonlinear autoregressive). (Zhang, 2012, p.463)

بمجرد أن يتم تحديد بنية الشبكة (p, q) فإنها تصبح جاهزة للتدريب (أي عملية تقدير المعلمات) كما هو الحال في بناء نموذج (ARIMA) إذ يتم تقدير المعلمات بحيث يتم تقليل معيار المقارنة، يتم ذلك مرة أخرى باستعمال بعض خوارزميات التحسين غير الخطية الفعالة بخلاف خوارزمية تدريب الانتشار الخلفي الأساسية (basic backpropagation)، أحد هذه الخوارزميات هي خوارزمية التدرج المخفض المعمم (generalized reduced gradient) والتي تم توظيفها في هذا البحث. (Dalal et al., 2016, p.349)

يتم تقييم النموذج المقدر باستعمال عينة منفصلة غير معرّضة لعملية التدريب وهذه الممارسة تختلف عن تلك المستخدمة في بناء نموذج (ARIMA) حيث تستعمل عينة واحدة لتشخيص النموذج وتقديره وتقييمه، ويكمن السبب في حقيقة أن الشكل العام الخطي لنموذج (ARIMA) محدد مسبقاً ثم يتم تقدير النموذج من البيانات. مع الشبكات العصبية الاصطناعية يجب تقدير النموذج (غير الخطي) وترتيب النموذج من البيانات ومن ثم فإن نموذج (ANN) يكون أكثر ملاءمة للبيانات. (Zhuang et al., 2015, p.108)

8- النموذج الهجين (ARIMA-ANN)

مع صعوبة معرفة خصائص بيانات معينة بشكل كامل في دراسة مشكلة حقيقية أصبح استعمال نموذج هجين أو الجمع بين عدة نماذج ممارسة شائعة لتحسين دقة التنبؤ، إذ تكمن الفكرة الأساسية لدمج النماذج في التنبؤ هي استعمال مميزات كل نموذج لالتقاط أنماط مختلفة في البيانات، حيث تشير كل من النهايات النظرية والتجريبية إلى أن الجمع بين طرق

مختلفة يمكن أن يكون وسيلة فعالة وكفوة لتحسين التنبؤات. ويمكن التعبير عن السلسلة الزمنية التي تتألف من مكون ارتباط ذاتي خطي وغير خطي بالصيغة الآتية:

$$y_t = L_t + N_t \quad (6)$$

حيث يشير الرمز (L_t) إلى المكون الخطي ويشير الرمز (N_t) إلى المكون غير الخطي، يجب تقدير هذين المكونين من البيانات من خلال السماح لنموذج (ARIMA) بنمذجة المكون الخطي، ثم ستحتوي البواقي من النموذج الخطي على العلاقة غير الخطية فقط. ولنفرض أن (e_t) يشير إلى المتبقي عند الزمن (t) من النموذج الخطي فأن: (Zhang, 2012, p.464)

$$e_t = y_t - \hat{L}_t \quad (7)$$

حيث $(\hat{L}_t)$ تمثل القيمة المتوقعة عند الزمن (t) .

تعد البواقي مهمة في تشخيص مدى كفاية النماذج الخطية، فمن خلال نمذجة البواقي باستعمال الشبكات العصبية الاصطناعية (ANN) يمكن اكتشاف العلاقات غير الخطية. وبافتراض وجود (n) من عقد الإدخال فأن نموذج (ANN) للبواقي يمكن التعبير عنه بالصيغة (8) الآتية:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (8)$$

تمثل (f) دالة غير خطية يتم تحديدها بواسطة الشبكة العصبية ويمثل (ε_t) الخطأ العشوائي، بالآتي سيكون النموذج التنبؤي بالصيغة (9) الآتية:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (9)$$

يتضمن النموذج الهجين خطوتين، في البداية يتم تطبيق نموذج (ARIMA) لمعالجة الجانب الخطي من المشكلة، وبعد ذلك يتم توظيف نموذج (ANN) لالتقاط الأنماط غير الخطية الموجودة في بواقي نموذج (ARIMA) وذلك لعدم قدرة نموذج (ARIMA) على نمذجة المكونات غير الخطية المتأصلة في البيانات. (Armstrong, 2001, P. 418)


9- وصف بيانات البحث

تُعد جرائم القتل العمد من أخطر الجرائم التي تواجه المجتمع العراقي، هذه الجرائم تتسم بالتخطيط المسبق والنية الواضحة لإزهاق روح الضحية، وتتنوع أسباب جرائم القتل العمد بين المشاحنات والنزاعات العشائرية والتوترات الطائفية وأحيانا الجريمة المنظمة وغيرها. تؤدي هذه الجرائم إلى زعزعة الأمن والاستقرار في المجتمع وتخلق حالة من الخوف وعدم الثقة بين المواطنين. وتعمل الحكومة العراقية بالتعاون مع المنظمات الدولية والمحلية على تعزيز الأمن وتطبيق القانون للحد من جرائم القتل العمد، وتشمل هذه الجهود تحسين كفاءة الأجهزة الأمنية، وتعزيز الثقة بين المواطنين والشرطة، وتطوير النظام القضائي لضمان محاسبة الجناة. وقد تحسّل على بيانات البحث من قاعدة بيانات

إحصاءات جرائم القتل الدولية التابعة لمكتب الأمم المتحدة المعني بالمخدرات والجريمة²، وتمثل البيانات قيد البحث سلسلة جرائم القتل العمد بسبب المشاحنات والنزاعات العشائرية المسجلة في العراق بحسب الأشهر للأعوام 2019-2023م.

10- تحليل البيانات وتفسير النتائج

لمعرفة فيما إذا كانت السلسلة الزمنية الخاصة بجرائم القتل العمد بسبب المشاحنات والنزاعات العشائرية مستقرة في المتوسط والتباين أم لا، تم رسم السلسلة الزمنية وكما مبين في المخطط (1) الآتي:



مخطط (1) السلسلة الزمنية لجرائم القتل العمد بسبب المشاحنات والنزاعات العشائرية.

نلاحظ من المخطط (1) أن السلسلة متذبذبة وتمتلك اتجاهها عاماً، وللتأكد فيما إذا كانت السلسلة مستقرة أم غير مستقرة، تم إجراء اختبار (*Augmented Dickey-Fuller Test*) وكانت النتائج كما يلي:

جدول (1) نتائج اختبار (ADF) لمتغير جرائم القتل العمد بسبب المشاحنات والنزاعات العشائرية.

-1.292	ADF Test Statistic
31.15	Mean
7.985	Standard Deviation
0.061	P-value (ADF -statistic)

نلاحظ أن قيمة الاختبار (ADF) قد بلغت (-1.292) وبمستوى دلالة (0.061) بما يدل على عدم معنوية الاختبار ومن ثم فإن السلسلة الزمنية تمتلك جذر الوحدة (unit root)، واختبار وجود تأثير لمشكلة الارتباط الذاتي في بيانات السلسلة الزمنية تم توظيف اختبار (*Ljung-Box*) والذي يمكن التعبير عنه بالصيغة الآتية:

$$Q_m = n(n+2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{n-k} \sim \chi_{m-p}^2 \quad \dots \dots (10)$$

²موقع قاعدة بيانات إحصاءات جرائم القتل الدولية التابعة لمكتب الأمم المتحدة المعني بالمخدرات والجريمة على الإنترنت:
<https://data.albankaldawli.org/indicator/VC.IHR.PSRC.P5?locations=IQ>

حيث تمثل (n) حجم العينة، وتمثل (m) عدد الازاحات للارتباط الذاتي، وان (p) تمثل عدد المعلمات المقدرة في النموذج، وتمثل $(\hat{\rho}_k^2)$ مقدرات معلمات الارتباط الذاتي لبواقي السلسلة الزمنية. إذ تم حساب معاملات الارتباط الذاتي (AC) والارتباط الذاتي الجزئي (PAC) وكما موضح بالجدول (2) الآتي:

جدول (2) معاملات الارتباط لسلسلة جرائم القتل العمد في العراق.

<i>P-Value</i>	<i>Ljung-Box Q</i>	<i>PACF</i>	<i>ACF</i>	<i>Lag</i>
-	-	1	1	0
0.028	0.6169	0.0989	0.0989	1
0.023	0.6352	-0.0269	-0.0169	2
0.037	2.6728	0.183	0.1767	3
0.025	4.8697	0.1507	0.1819	4
0.048	9.206	-0.2919	-0.2532	5
0.031	10.1105	0.1733	0.1146	6
0.033	11.2817	0.0338	0.1292	7
0.045	12.185	-0.0937	-0.1124	8
0.031	15.5796	-0.1537	-0.2157	9
0.029	15.7777	-0.1799	-0.0516	10
0.049	17.3204	-0.0516	-0.1426	11
0.05	19.9149	-0.0592	-0.183	12
0.043	19.9184	0.0599	0.0067	13
0.047	23.3581	0.2409	0.2062	14
0.05	23.953	-0.0754	-0.0848	15

نلاحظ من الجدول (2) أعلاه أن قيم إحصاء اختبار (Q) لجميع معاملات دالة (AC) ودالة (PAC) كانت معنوية عند مستوى معنوية (0.05) مما يدل على أن بيانات السلسلة الزمنية لجرائم القتل العمد تعاني من مشكلة الارتباط ذاتي (Autocorrelation).

أ- تطبيق نموذج (ARIMA):


جدول (3) قيم معيار أكياكي ومتوسط الانحراف المطلق لسلسلة جرائم القتل العمد لنموذج (ARIMA).

<i>AIC</i>	<i>BIC</i>	<i>MAD</i>	<i>Model</i>
422.995	427.183	56.308	ARIMA (1, 0, 0)
390.698	400.853	56.272	ARIMA (0, 1, 1)
421.899	428.132	66.507	ARIMA (1, 1, 1)
424.835	431.118	68.346	ARIMA (1, 0, 1)
439.413	443.567	96.825	ARIMA (1, 1, 0)

تم تنفيذ جميع نماذج (ARIMA) باستعمال برنامج (SAS v9.4)، كما تم اختيار معيار معلومات أكياكي (AIC) ومتوسط الانحراف المطلق (MAD) كمقياسين لدقة التنبؤ، إذ نلاحظ من الجدول (3) أعلاه أن نموذج ARIMA (0, 1, 1)

1, 1) يمتلك أقل متوسط انحراف مطلق (MAD) حيث بلغ (56.272) وان قيمة معيار معلومات أكياكي (AIC) للنموذج قد بلغت (390.698) وهي القيمة الأقل إذ ما قورنت بقيم (AIC) لبقية النماذج المبينة في الجدول (3)، وهذا يدل على النموذج (0, 1, 1) ARIMA هو الأفضل لملاءمة البيانات قيد الدراسة لأنه يمتلك أقل قيمة لمعيار أكياكي (AIC).

ويوضح المخطط (2) الآتي مخطط التنبؤ للسلسلة الزمنية باستعمال نموذج (0, 1, 1) ARIMA كونه النموذج الأفضل لملاءمة البيانات حيث نلاحظ أن السلسلة الزمنية أصبحت مستقرة في المتوسط والتباين ولا تمتلك اتجاهًا عامًا، كما نلاحظ من المخطط (2) أن هنالك ارتفاع بسيط في نسبة جرائم القتل العمد بسبب المشاحنات والنزاعات العشوائية خلال الأعوام 2024-2026.




مخطط (2) التنبؤ بالسلسلة الزمنية بحسب نموذج (0, 1, 1) ARIMA

ب- تطبيق نموذج الشبكات العصبية الاصطناعية (ANN):

جدول (4) قيم معيار أكياكي ومتوسط الانحراف المطلق لسلسلة جرائم القتل العمد لنموذج (ANN).

<i>AIC</i>	<i>BIC</i>	<i>MAD</i>	<i>Model</i>
383.105	396.294	41.457	ANN

نلاحظ أن قيمة (MAD) لنموذج (ANN) قد بلغت (41.457) وان قيمة معيار (AIC) للنموذج قد بلغت (383.105)، وعند المقارنة مع نموذج (0, 1, 1) ARIMA نلاحظ أن نموذج (ANN) يعطي نتائج أفضل قليلاً من نموذج (ARIMA). ويوضح الشكل (3) الآتي مخطط التنبؤ للسلسلة الزمنية باستعمال نموذج (ANN) حيث نلاحظ أن القيم التنبؤية لسلسلة جرائم القتل العمد تعطي توقعات أفضل إذ ما تمت مقارنتها بنموذج (ARIMA)، وليس هنالك ارتفاع في نسبة الجرائم للأعوام 2024-2026.




مخطط (3) التنبؤ بالسلسلة الزمنية بحسب نموذج ANN

ج- تطبيق النموذج الهجين (ARIMA-ANN):

جدول (5) قيم معيار أكياكي ومتوسط الانحراف المطلق لسلسلة جرائم القتل العمد لنموذج (ARIMA-ANN).

<i>AIC</i>	<i>BIC</i>	<i>MAD</i>	<i>Model</i>
132.652	141.032	31.841	ARIMA-ANN

نلاحظ من الجدول (5) أعلاه أن قيمة متوسط الانحراف المطلق (MAD) لنموذج (ARIMA-ANN) قد بلغت (31.841)، وان قيمة معيار (AIC) قد بلغت (132.652) وهي قيمة منخفضة بدرجة كبيرة إذا ما تمت مقارنتها مع قيم (AIC) لنماذج (ANN) و (ARIMA (0,1,1) بما يدل على أفضلية النموذج الهجين، ويوضح المخطط (4) الآتي مخطط التنبؤ بالسلسلة الزمنية باستعمال النموذج الهجين (ARIMA-ANN) حيث نلاحظ أن القيم التنبؤية تعطي توقعات بانخفاض نسبي لجرائم القتل العمد في العراق خلال الأعوام 2024-2026.



مخطط (4) التنبؤ بالسلسلة الزمنية بحسب نموذج (ARIMA-ANN)

تظهر النتائج أن هنالك اختلافاً في دقة التنبؤ عند تطبيق الشبكات العصبية (ANN) وحدها أو عند تطبيق نموذج (ARIMA) لوحده، هذا قد يشير إلى أن نموذج (ANN) أو نموذج (ARIMA) لا يلتقطان جميع الأنماط في البيانات

قيد الدراسة. كما تظهر نتائج النموذج الهجين أنه من خلال الجمع بين نموذجين معاً، يمكن تقليل أخطاء التنبؤ الإجمالية بشكل كبير حيث تكون قيمة مقياس (MAD) في نموذج (ARIMA-ANN) أفضل بكثير.

11- الاستنتاجات

- 1- من خلال استعمال النموذج الهجين (ARIMA-ANN) في التنبؤ بالسلسلة الزمنية لجرائم القتل العمد في العراق يمكن تقليل أخطاء التنبؤ الإجمالية بشكل كبير حيث تكون قيمة متوسط الانحراف المطلق (MAD) لنموذج (ARIMA-ANN) أفضل بكثير.
- 2- استعمل نموذج (ARIMA) الخطي ونموذج (ANN) غير الخطي بشكل مشترك، بهدف النقاط أشكال مختلفة من العلاقات الخطية وغير الخطية في بيانات السلاسل الزمنية، مما يؤدي الى تحسين دقة التنبؤ مقارنة بالنموذج الفردي.
- 3- أظهرت القيم التنبؤية لنتائج النموذج الهجين (ARIMA-ANN) انخفاض نسبي لجرائم القتل العمد في العراق خلال الأعوام 2024-2026، دلالة على تحسن كفاءة الأجهزة الأمنية العراقية، وتطوير النظام القضائي لضمان محاسبة الجناة.

References:

- 1- Abdulkarim, S. A., & Engelbrecht, A. P. (2021). Time series forecasting with feedforward neural networks trained using particle swarm optimizers for dynamic environments. *Neural Computing and Applications*, 33(7), 2667-2683.
- 2- Akouemo, H. N., & Povinelli, R. J. (2017). Data improving in time series using ARX and ANN models. *IEEE Transactions on Power Systems*, 32(5), 3352-3359.
- 3- Armstrong, J. S. (2001). Combining forecasts (pp. 417-439). Springer US.
- 4- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- 5- Chae, Y. T., Horeh, R., Hwang, Y., & Lee, Y. M. (2016). Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. *Energy and Buildings*, 111, 184-194.
- 6- Chatterjee, C., Roychowdhury, V. P., & Chong, E. K. (1998). On relative convergence properties of principal component analysis algorithms. *IEEE Transactions on Neural Networks*, 9(2), 319-329.
- 7- Dalal, S., Dahiya, N., & Jaglan, V. (2018). Efficient tuning of COCOMO model cost drivers through generalized reduced gradient (GRG) nonlinear optimization with best-fit analysis. In *Progress in Advanced Computing and Intelligent Engineering: Proceedings of ICACIE 2016, Volume 1* (pp. 347-354). Springer Singapore.

- 8- Deb, C., Zhang, F., Yang, J., Lee, S. E., & Shah, K. W. (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74, 902-924.
- 9- Friedrich, S., Antes, G., Behr, S., Binder, H., Brannath, W., Dumpert, F., ... & Friede, T. (2022). Is there a role for statistics in artificial intelligence? *Advances in Data Analysis and Classification*, 16(4), 823-846.
- 10- Hewamalage, H., Bergmeir, C., & Bandara, K. (2020). Recurrent neural networks for time series forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388-427.
- 11- Kirchgässner, G., Wolters, J., & Hassler, U. (2013). Autoregressive conditional heteroscedasticity. *Introduction to Modern Time Series Analysis*, 281-310.
- 12- López-Díaz, M., Gil, M. Á., Grzegorzewski, P., Hryniewicz, O., Lawry, J., del Aguila, M. D. M. R., ... & Mota, S. (2004). Neural networks and statistics: A review of the literature. *Soft Methodology and Random Information Systems*, 597-604.
- 13- Mbuviha, R. (2017). Bayesian neural networks for short term wind power forecasting.
- 14- McKenzie, E. D. (1984). General exponential smoothing and the equivalent ARMA process. *Journal of Forecasting*, 3(3), 333-344.
- 15- O'Shea, K. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- 16- Shumway, R. H., Stoffer, D. S., Shumway, R. H., & Stoffer, D. S. (2017). *ARIMA models. Time Series Analysis and Its Applications: With R Examples*, 75-163.
- 17- Song, X., Deng, L., Wang, H., Zhang, Y., He, Y., & Cao, W. (2024). Deep learning-based time series forecasting. *Artificial Intelligence Review*, 58(1), 23.
- 18- Yu, B., & Kumbier, K. (2018). Artificial intelligence and statistics. *Frontiers of Information Technology & Electronic Engineering*, 19(1), 6-9.
- 19- Zhang, G. P. (2012). Neural Networks for Time-Series Forecasting. *Handbook of natural computing*, 1, 4.

- 20- Zhuang, J., Chen, Y., Shi, X., & Wei, D. (2015). Building cooling load prediction based on time series method and neural networks. *International Journal of Grid and Distributed Computing*, 8(4), 105-114.