

A Hybrid ARIMA and Artificial Neural Networks (ANN) Model for Daily Maximum and Minimum Temperature Forecast

Dr. Ghatfan Ammar^{*}
Jomana Khoder Eskandar^{**}

(Received 24 / 6 / 2019. Accepted 5 / 12 / 2019)

□ ABSTRACT □

Prediction of the daily maximum and minimum temperatures is one of the most important topics in climate research and all vital areas. It can help managements in the economic and strategic planning and decision-making.

This research use time series single models of linear Box- Jenkins ARIMA (p,d,q) and non-linear ANN models and then integrates them into the ARIMA-ANN model, assuming series includes linear component estimated using a Box- Jenkins (ARIMA) model, and a non-linear component represented by model errors (Residual) can be estimated using ANN models to obtain the best and most accurate future prediction for time series.

The selected model to present daily minimum temperature serie In Al-Basel Station including linear model ARIMA (1,1,1) and non- linear model ANN (1-26-1); while model ARIMA (0,1,2) and model ANN (1-17-1) were selected to present daily maxmum temperature serie, The results showed that (ARIMA-ANN) model was superior to other models according criteria of accuracy check (R, RMSE, MAE, MAPE).

Keywords: Time series models, Forecasting, Box-Jenkins (ARIMA), ANN.

* Professor, Department of Water Engineering and irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria. Email: ghatfan62@gmail.com

** Postgraduate Student, Department of Water Engineering and irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.
Email: Jomeaska777@gmail.com

نموذج هجين من ARIMA والشبكات العصبية الاصطناعية (ANN) للتنبؤ بدرجات الحرارة العظمى والصغرى اليومية

د. غطفان عبد الكريم عمار*

جمانة خضر اسكندر**

(تاريخ الإيداع 24 / 6 / 2019. قُبِلَ للنشر في 5 / 12 / 2019)

□ ملخص □

التنبؤ بدرجات الحرارة العظمى والصغرى من الموضوعات الهامة في المناخ لكافة المجالات الحيوية، إذ يساعد الإدارات في التخطيط الاقتصادي والاستراتيجي واتخاذ القرارات المستقبلية. تناول هذا البحث دراسة لاستخدام نماذج مفردة من: نماذج بوكس-جينكنز (ARIMA (p,d,q) الخطية، ونماذج الشبكات العصبية الاصطناعية (ANN) اللاخطية، ومن ثم الدمج بينهما في نموذج (ARIMA-ANN)، على فرض أن السلسلة تضم مركبة خطية يتم تقديرها باستخدام نموذج (ARIMA)، ومركبة غير خطية ممثلة بأخطاء النموذج (Residual) يمكن تقديرها باستخدام نماذج (ANN)، وذلك للحصول على أفضل وأدق التنبؤات المستقبلية للسلاسل الزمنية. النموذج المُختار لتمثيل درجة الحرارة الصغرى في محطة سد الباسل يتضمن نموذج خطي (ARIMA (1,1,1) ونموذج غير خطي (ANN(1-26-1)، بينما اختير نموذج (ARIMA (0,1,2)، ونموذج ANN(1-17-1) لتمثيل درجة الحرارة العظمى، وأظهرت النتائج تفوق نموذج (ARIMA-ANN) على النماذج الأخرى وفق معايير ضبط الدقة (R, RMSE, MAE, MAPE).

الكلمات المفتاحية: نماذج السلاسل الزمنية، التنبؤ، ANN، Box-Jenkins (ARIMA).

* أستاذ- قسم الهندسة المائية والزري- كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية. Email: ghatfan62@gmail.com

** طالبة دراسات عليا (ماجستير) - قسم الهندسة المائية والزري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

Email: Jomeaska777@gmail.com

مقدمة:

إن إجراء التنبؤات بدرجة الحرارة ماهي إلا تقدير للتغيرات التي تحصل بدرجات الحرارة خلال فترة زمنية محددة، وتقسم أساليب التنبؤات إلى قسمين وهما [1]:

- الأساليب غير النظامية التي تعتمد على الخبرة والتقدير الذاتي باستخدام أساليب التناظر، وآراء ذوي الخبرة.
- أما الأساليب النظامية فهي تتسم بالموضوعية بحيث تعطي نفس المعلومات المستخدمة في تفسير أي ظاهرة من قبل عدة أشخاص أي نتائج متماثلة، والتي تنقسم بدورها أيضاً إلى:

○ نماذج سببية: تقوم على استجابة العنصر (متغير تابع) لتأثير ظواهر أخرى (متغيرات مستقلة)، التي تعتبر الشبكات العصبية الاصطناعية رائدة في ذلك، حيث بدأ الباحثون خلال الثلاثين سنة الماضية بتحليل التقلبات والتغيرات في درجة حرارة الهواء ودراستها من خلال تحديد اتجاه هذا التغير ومقداره، ومحاولة التنبؤ بالطقس لـ 24 ساعة لاحقة وبدلالة عناصر مناخية مختلفة [2]، أو التنبؤ بدرجة حرارة الهواء الوسطية مع درجتي الحرارة العظمى والصغرى اللتان تعتبران أكثر دلالة وأهمية مناخية للمنطقة في المجال الزراعي [3]، وخاصة درجة الحرارة العظمى في أشهر الصيف (حزيران؛ تموز؛ آب) [4]، ودرجات الحرارة الصغرى في الأشهر الباردة من السنة [5]، أو الاهتمام بالتنبؤ بكليهما معاً خلال أشهر (كانون الثاني؛ آذار؛ أيلول) [6].

○ ونماذج غير سببية: تقوم على أسلوب تفكيك السلاسل الزمنية إلى مركباتها، الذي يعتبر أكثر الأساليب دقة وشيوعاً إذا ماتم تطبيقه وتحقيقه للفروض الإحصائية قدر الإمكان، ومن أبرزها نماذج (ARIMA) وفق نظرية بوكس جينكنز للسلاسل الزمنية [1, 7].

ومن جهة أخرى ظهرت بحوث ودراسات أخرى تؤيد فكرة دمج النموذج الخطي (Linear Model) مع النموذج غير الخطي (Non-Linear Model) لإنتاج نموذج هجين (Hybrid Models) جديد، واستخدامه في إيجاد تنبؤات أكثر دقة، على افتراض أن النموذج المفرد ربما يكون غير كافٍ لتشخيص جميع خواص ومميزات السلسلة الزمنية التي تتضمن كلتا المركبتين الخطية وغير الخطية وذلك خلال مدة من الزمن [8].

قام (Fengxia & Shouming; 2011) بالدمج بين نماذج الانحدار الذاتي (AR) والنماذج العصبية ذات الأساس الشعاعي (Radial Basis Function) RBF، وأشارت النتائج إلى أن النموذج المختلط ينتج عنه تباين خطأ أقل، وهذا يمكن أن يقلل من عدم اليقين الذي يحدث عادة في الاستدلال الإحصائي والتنبؤ بالسلاسل الزمنية [8].

كما استخدم (Faruk, D. Ö., 2010) النهج المختلط بين (ARIMA) والشبكات العصبية أمامية التغذية ذات الانتشار الخلفي (Feed Forward Back Propagation) FFBP للتنبؤ بالسلسلة الزمنية باستخدام قراءات حول نوعية المياه (درجة حرارة الماء وتركيز البورون والأوكسجين المنحل)، وأظهرت نتائج النماذج المختلطة إيجاباً للنموذج (معاملات ارتباط 0.902، 0.893، 0.909 على الترتيب) قادراً على التقاط الطبيعة غير الخطية للسلسلة الزمنية المعقدة، وبالتالي إنتاج تنبؤات أكثر دقة [9].

اقترح (Hippert, H. S; et al., 2000) نظام تنبؤ هجين يجمع بين النماذج الخطية (ARIMA) والشبكات العصبية متعددة الطبقات (ANN) للتنبؤ بدرجات الحرارة الساعية، وأشارت نتائج المقارنة مع القياسات الحقيقية أن كلا النهجين يحتوي على عيوب، فالنهج الأول (ANN) يحتاج إلى بارمترات كثيرة لبناء النموذج، والنهج الثاني (ARIMA) قد ينتج عنه توقعات عشوائية، لذلك عمد البحث إلى تجاوز العيوب السابقة من خلال التحسين على النهج الثاني بنماذج هجينة من النوع (ARIMA-ANN) [10].

وعليه يمكن تمثيل مشكلة البحث بالتساؤلات التالية:

إلى أي مدى يمكن لنماذج بوكس جينكنز (ARIMA) تمثيل بيانات السلاسل الزمنية لدرجة الحرارة من حيث الخطية وعدم الخطية؟ وما هي المزايا والإخفاقات المحتملة في النموذج المبني بهذه الأساليب؟ وكيف يمكن للنماذج العصبية الاصطناعية أن تقلل من عيوب وتباين أخطاء النماذج الخطية من خلال نماذج هجينه (ARIMA-ANN).

أهمية البحث وأهدافه:

تؤثر درجة حرارة الهواء بصورة مباشرة أو غير مباشرة في العناصر الجوية الأخرى، مثل التبخر والتكاثف وهطول الأمطار والضغط الجوي، وخاصة درجات الحرارة العظمى والصغرى الأكثر دلالة مناخية وأهمية للمنطقة، وذلك من خلال إعطاء مؤشرات يمكن الاستفادة المستقبلية منها في اتخاذ قرارات إدارية واقتصادية على مستوى المنطقة. يهدف هذا البحث إلى اختبار النماذج الهجينة (ARIMA-ANN) في تحسين التنبؤات بدرجة الحرارة الصغرى والعظمى على المدى القصير في محطة سد الباسل (محافظة طرطوس) بالاعتماد على جملة من المعايير الإحصائية المناسبة.

طرائق البحث ومواده:

1. نماذج بوكس - جينكنز (Box-Jenkins Method)

تُبنى نماذج السلاسل الزمنية عادةً على خصائص أساسية متمثلة بالاستقرارية (Stationarity)، والخطية (Linearity) والطبيعية (Normality)، علماً أن أغلب السلاسل الزمنية قد لا تتبع التوزيع الطبيعي، لذلك فإن دراسة السلاسل الزمنية تشتمل على هذه الافتراضات وكيفية معالجة السلاسل الزمنية غير المستقرة [11]. باستطاعة مستخدم هذه الطريقة أن يخصص نموذجاً مؤقتاً يعتقد أنه ملائم لنمط البيانات، ثم يقوم باختبار الدقة التنبؤية للنموذج المقترح اعتماداً على القيمة الاحتمالية (P-Value) لفرضيات النموذج، فإذا كانت القيمة الاحتمالية أقل من مستوى المعنوية (Significance Levels=0.05) فإن الفرضية الصفرية H_0 (Null Hypothesis) تُرفض، ونقبل الفرضية البديلة H_1 (Alternative Hypothesis) بوجود التأثير المعنوي والعكس صحيح، وبهذا الإجراء التكراري يمكن الوصول إلى نموذج تنبؤي بأقل الأخطاء الممكنة ويمثل السلسلة الزمنية المدروسة [12].

1.1 تمثيل المركبة الخطية للسلسلة الزمنية باستخدام نموذج (ARIMA)

تعد نماذج بوكس جينكنز من الأساليب الإحصائية المستخدمة لتمثيل بيانات سلسلة لظاهرة معينة، والتنبؤ بقيمها المستقبلية، وتصنف إلى نوعين وفق استقرارية السلسلة الزمنية [13]:

1.1.1 نماذج السلاسل الزمنية المستقرة:

أنموذج الانحدار الذاتي والأوساط المتحركة (Autoregressive Moving Average Model) ARMA(p,q) يستخدم هذا النموذج من أجل الوصول إلى مرونة أكبر في ملائمة النماذج للسلاسل الزمنية الفعلية Z_t ، حيث يشمل هذا النوع من النماذج على قسم الانحدار الذاتي ذي الدرجة (p)، وقسم المتوسط المتحرك ذي الدرجة (q)، والصيغة العامة لهذا الأنموذج كالآتي [13]:

$$Z_t = \delta + (\phi_1 * Z_{t-1} + \dots + \phi_p * Z_{t-p}) + (a_t - \theta_1 * a_{t-1} - \dots - \theta_q * a_{t-q}) \quad \dots \dots \dots (1)$$

حيث: ϕ_1, \dots, ϕ_p : تمثل معاملات أنموذج الانحدار الذاتي (p: رتبة الانحدار الذاتي).

- $\theta_1, \dots, \theta_q$: تمثل معاملات أنموذج الأوساط المتحركة (q: رتبة المتوسطات المتحركة).

- δ : ثابت النموذج.

- a_t : يمثل الخطأ العشوائي المستقل عن قيم Z_t السابقة الذي يتبع التوزيع الطبيعي بمتوسط صفر وتباين (σ_a^2) ، ويدعى بالضجّة البيضاء (White noise).

2.1.1. نماذج السلاسل الزمنية غير المستقرة:

أتمودج الانحدار الذاتي والأوساط المتحركة التكاملية **ARIMA(p,d,q)**:

عندما تكون السلسلة الزمنية غير مستقرة يمكن تحويلها إلى سلسلة مستقرة بأخذ الفروقات من الدرجة (d) التي تدعى بدرجة التكامل (Integrated) عندئذ يرمز له بالرمز **ARIMA(p,d,q)** وتكتب معادلته [13]:

$$\phi(B)(1-B)^d * Z_t = \theta(b) * a_t \quad \dots \dots \dots (2)$$

إذ أن: d: درجة الفرق المأخوذة للسلسلة الزمنية؛ B: عامل الارتداد الخلفي.

2.1. خصائص نموذج السلسلة الزمنية: من الخصائص الجوهرية للسلسلة الزمنية التي تخضع لهذا النوع من النماذج نذكر:

1.2.1. استقرارية السلسلة الزمنية: السلسلة الزمنية تكون مستقرة عندما يكون المتوسط والتباين ثابتين مع الزمن. وفي حال غياب صفة الاستقرار فإن الانحدار الذي نحصل عليه بين متغيرات السلسلة الزمنية غالباً ما يكون انحداراً زائفاً أو وهمياً [14].

وعموماً يتطلب استقرار السلسلة أن يكون معامل الارتباط الذاتي مساوٍ للصفر أو لا يختلف جوهرياً عن الصفر أو بعبارة أخرى وقوع معاملات الارتباط الذاتي ضمن حدود الثقة $\left[\frac{-1.96}{\sqrt{n}}, \frac{+1.96}{\sqrt{n}} \right]$.

○ اختبار جذر الوحدة (Unit Root) - اختبار ديكي فولر (Augmented Dickey-Fuller 1981):

يعتبر من أفضل الاختبارات الإحصائية لاختبار استقرارية السلسلة الزمنية وتحديد درجة التكامل، ويعتمد على ثلاث صيغ رياضية [15]، أي ثلاثة نماذج (A, B, C) وباستخدام طريقة المربعات الصغرى العادية (OLS) يتم إيجاد معاملات النماذج الثلاث. ونميز الفرضيات الآتية:

- الفرضية الصفرية H_0 : يوجد جذر واحد/ يوجد اتجاه عام عشوائي في السلسلة الزمنية والسلسلة غير مستقرة، ويمكن أخذ الفرق الأول (First Difference) وإعادة الاختبار.

- الفرضية البديلة H_1 : لا يوجد جذر واحد/ لا وجود لمركبة الاتجاه العام والسلسلة مستقرة.

ويمكن اعتبار السلسلة المدروسة غير مستقرة في حال تحقق الفرضية الصفرية في أحد النماذج الثلاث.

3.1. مراحل بناء النموذج (Model Building Stages): تتألف مراحل بوكس-جينكنز في بناء نماذج السلاسل الزمنية من أربع مراحل:

(1) **مرحلة التعرف على النموذج (التشخيص - Identification)**: عندما تصبح البيانات مستقرة، يتم تشخيص الرتبة (P) لنموذج الانحدار الذاتي والرتبة (q) لنموذج المتوسط المتحرك من خلال النظر إلى الارتباط الذاتي والارتباطات الذاتية الجزئية للبيانات التي تم أخذ الفروق لها [13]، وعند فشل الأساليب النظرية في تشخيص النموذج نلجأ إلى الاعتماد على معايير المفاضلة بين النماذج [16]، ونعتمد منها: معيار أكاي (AIC) Akaike Information؛ معيار معلومات بيز (Bayesian Information Criterion (BIC)؛ معيار حنان وكوين (H-Information) Hannan-Quinn Criterion (Q).

(2) **مرحلة تقدير معاملات النموذج P و q (Estimation)**: بعد إتمام التعرف على النموذج أو مجموعة النماذج التي قد تلائم بيانات السلسلة المدروسة، نقوم بإيجاد قيم تقديرية لمعاملات هذه النماذج باستخدام مجموعة من

الطرائق وأشهرها: طريقة المربعات الصغرى (Ordinary Least Squares Method)؛ وطريقة الإمكان الأعظم (Maximum Likelihood Method) المستخدمة في الدراسة.

(3) **مرحلة الفحص والتدقيق (Diagnostic Checking):** يتم في هذه المرحلة اختبار مدى صلاحية النماذج المختارة على مرحلتين:

(a) **اختبار معنوية معالم النموذج:** إذا كان احتمالية اختبار ستيدونت: ($P < 0.05$) فإننا نرفض فرضية العدم، ونقبل الفرض البديل القائل بأن معلمة الأنموذج تختلف معنوياً عن الصفر، وبالتالي تبقى في النموذج، وفي حال أحد المعالم غير معنوي لا بد من استبعاد أحد رتب النموذج (AR) أو النموذج (MA) أو استبعاد النموذج.

(b) **تحليل البواقي (Residual analysis):** أو حد الخطأ العشوائي للنموذج، والذي يُفترض أنه يتبع التوزيع الطبيعي بمتوسط صفر وتباين ثابت، وعندئذ يسمى بالتشويش الأبيض، ويستخدم لذلك عدة اختبارات [17] نذكر منها:

✓ **اختبار التوزيع الطبيعي للبواقي:** ويتم ذلك من خلال:

- **الرسم البياني لشكل المدرج التكراري للبواقي، والاحتمال الطبيعي (Normal Probability Plot) وفق الاختبار اللامعلمي للبواقي K-S (Kolmogorov-Smirnov).**

✓ **اختبار الاستقلال الذاتي البواقي (Independence of Residuals):** وذلك من خلال:

- **فحص معاملات الارتباط الذاتي للبواقي:** والتي يجب أن تقع ضمن حدود الثقة باحتمال (95%) أي أن:

$$-\frac{1.96}{\sqrt{n}} \leq \rho_k(\hat{\epsilon}) \leq \frac{1.96}{\sqrt{n}}$$

✓ **اختبار تجانس البواقي Homoscedasticity (اختبار ثبات التباين):** والمقصود اختبار عشوائية البواقي وذلك من خلال:

- **شكل انتشار البواقي مع القيم الاتجاهية،** بمعنى لا يمكن رصد نمط أو شكل محدد لهذه البواقي (أي أنها ليست متزايدة أو متناقصة أو تقع في جانب واحد) لذا نحكم هنا بثبات التباين.

- **اختبار التعاقب (Runs Test):** يستخدم اختبار التعاقب أو الدورات لمعرفة أن البواقي ناتجة عن تولد عشوائي أم لا، وذلك من خلال حساب عدد القيم العشوائية الأعلى والأدنى من قيمة متوسط صفر.

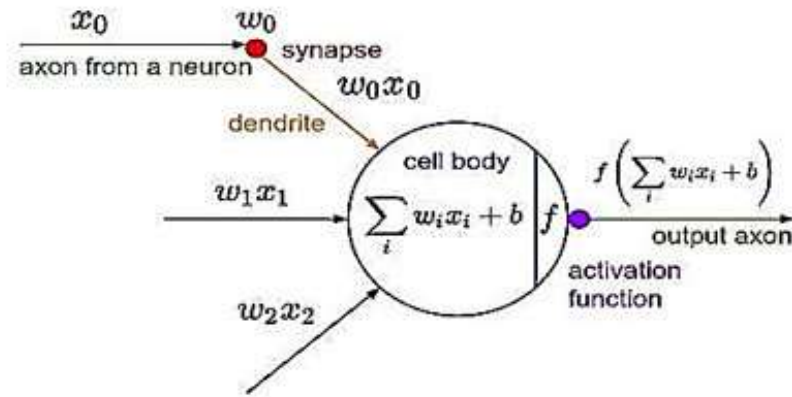
(4) **مرحلة التنبؤ (Forecasting):** بعد أن يتم تشخيص النموذج وتقدير معلماته وفحصه وتدقيقه، يتم استخدامه في التنبؤ بالقيم المستقبلية للسلسلة الزمنية، وذلك عن طريق استخدام القيم الحالية والماضية للمتغير التابع (y_t) والبواقي (\hat{a}_t) كقيم تقديرية لحد الخطأ وذلك للحصول على القيمة الأولى المنتبأ بها (Z_{t+1})، وهو ما يسمى بالتنبؤ لفترة واحدة ويمكن الحصول على القيمة المستقبلية (Z_{t+2}) باستخدام القيمة المستقبلية الأولى (Z_{t+1}) في معادلة التنبؤ مع افتراض أن حد الخطأ خارج العينة يساوي الصفر، وهكذا حتى نصل إلى الفترة المطلوبة.

2. الشبكات العصبية الاصطناعية ANNs (Artificial Neural Networks)

تتميز الشبكات العصبية الاصطناعية في قدرتها على معالجة البيانات دون الحاجة إلى صياغة مسبقة أو معرفة طبيعة العلاقة بين المتغيرات، بالإضافة إلى القدرة على تحليل البيانات المشوشة التي تحتوي على قيم متطرفة، وإمكانية التحليل والتعلم من بيانات السلسلة الزمنية، وهي تحاكي في بنائها وعملها آلية الجهاز العصبي عند الإنسان [18, 19]، ويبقى العيب الوحيد الذي يميز البرامج الإحصائية عنها هو عدم القدرة على تطبيق الاختبارات الجوهرية الإحصائية للنماذج المقترحة والمعلمات المقدرة، وبالرغم من ذلك فقد أظهرت الدراسات قدرة الشبكات على حل غالبية

المشاكل بكفاءة أعلى من الطرائق الإحصائية التقليدية. وبشكل عام فإن تصميم الشبكات العصبية يمر بنفس المراحل التي تتطلبها عملية النمذجة التقليدية والتي تتضمن: اقتراح هيكلية الشبكة (البنية المناسبة) من حيث عدد الطبقات الخفية (Hidden layer)؛ عدد العصبونات (Neurons) في كل طبقة ونوع دوال التفعيل (Activation) [20] (Function)؛ مرحلة التدريب (Training)؛ مرحلة التحقق (Validation) وتشخيص الأخطاء من خلال معايرة النموذج؛ مرحلة الاختبار والفحص (Testing).

تتألف الشبكة العصبية أمامية التغذية (FFNN) الموضحة بالشكل (1) من ثلاث طبقات: هي طبقة المدخلات (Input Layer) ومهمتها استقبال البيانات من مصدر خارجي ثم إرسالها إلى الطبقة الثانية وهي الطبقة الخفية التي تحتوي على وحدات المعالجة (العصبونات) والتي يتم فيها معالجة البيانات، ومن ثم إرسالها إلى الطبقة الثالثة وهي طبقة المخرجات (Output Layer)، وفيها يتم مقارنة مخرجات النموذج مع القيم الحقيقية والحصول على معدل مربع الخطأ أو ما يعرف بتباين الخطأ (MSE)، ليتم بعد ذلك انتشار الخطأ عكسياً طبقة بعد طبقة ابتداءً من طبقة المخرجات باتجاه طبقة المدخلات، وفي هذه المرحلة يتم تعديل الأوزان (Weights) وحسابه باستخدام خوارزمية الانتشار العكسي (Back Propagation) للخطأ، وتعدّ خوارزمية (Levenberg–Marquardt (LM أشهرها لقدرتها على معالجة البيانات الضخمة بسرعة وفعالية حتى يتم تصغير الخطأ وتوقف التدريب [21].



الشكل (1): آلية التغذية الأمامية للعصبون ثم مرحلة احتساب الخطأ وانتشاره عكسياً لتعديل الأوزان.

3. الأنموذج الهجين (ARIMA-ANN)

الأنموذج الهجين الذي سيتم دراسته ناتج ومتولد عن دمج نموذج خطي (ARIMA) مع آخر غير خطي (ANN) للسلسلة، وذلك لغرض تحسين التنبؤات المستقبلية للسلسلة على افتراض أن السلسلة الزمنية Z_t مؤلفة من مركبتين الأولى خطية (L) والثانية غير خطية (N) Non-Linear [22]، كما هو موضح بالمعادلة:

$$Z_t = L + N \quad , (t = 1,2,3, \dots) \quad (3)$$

ونميز مرحلتين لبناء النموذج الهجين:

✓ **المرحلة الأولى:** سيتم استخدام أحد نماذج (ARIMA) لتمثيل الجزء الخطي للسلسلة الزمنية ومن ثم حساب التنبؤات، ومن ثم استخدام أحد النماذج العصبية (ANN) لتمثيل الجزء غير الخطي المتمثل بالأخطاء العشوائية (بواقي النموذج a_t) المقدرة بواسطة (ARIMA)، والتي تكون ضرورية جداً لتدقيق وتشخيص النموذج الخطي، ويمكن تمثيلها بالعلاقة:

$$N = f(a_t, a_{t-1}, \dots, a_{t-p}) + \varepsilon_t, (a_t = Z_t - \hat{Z}_t) \dots \dots \dots (4)$$

✓ المرحلة الثانية: يتم الحصول على القيمة المتوقعة النهائية بواسطة النموذج الهجين، بجمع القيم التي تم التنبؤ بها بواسطة (ARIMA) مع قيم الأخطاء المتنبأ بها بواسطة نموذج (ANN)، كما في المعادلة:

$$\hat{Z}_t = \hat{L} + \hat{N} \dots \dots \dots (5)$$

4. تقييم أداء النماذج في التقدير والتنبؤ:

هناك عدة معايير متبعة لكشف فعالية وكفاءة النموذج المقترحة من خلال قياس مقدار الخطأ المصاحب لنموذج التنبؤ المستخدم، وعليه يمكن اختيار النموذج الذي يملك أقل قيمة لهذه المعايير ومنها [23]:

○ الجذر التربيعي لمتوسط مربعات الخطأ (Root mean square error) RMSE: ويمثل الجذر التربيعي لمتوسط مربع الأخطاء (الانحراف المعياري للخطأ)، وذلك حسب العلاقة التالية:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum (Y_t - \hat{Y}_t)^2}{n}} \dots \dots \dots (6)$$

حيث: n : عدد المشاهدات؛ Y_t : يمثل المشاهدات الحقيقية؛ \hat{Y}_t : يمثل المشاهدات المتوقعة.

○ متوسط الخطأ المطلق (Mean Absolute Error) MAE: ويحسب بقسمة مجموع الانحرافات المطلقة للقيم الحقيقية عن القيمة المقدرة على عدد الفترات، وذلك حسب العلاقة التالية:

$$MAE = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n} \dots \dots \dots (7)$$

كلما اقترب مؤشر RMSE، MAE من الصفر يعني هذا أن كفاءة النماذج عالية في التنبؤ.

○ متوسط الخطأ النسبي المطلق (Mean Absolute Percentage Error) MAPE: يمكن حساب المؤشر السابق بشكل نسبي وفق العلاقة الآتية:

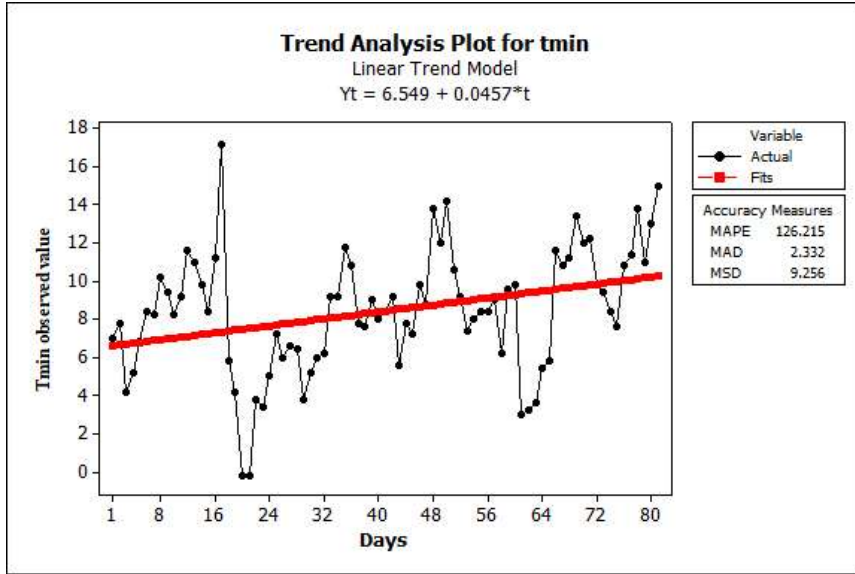
$$MAPE = \frac{1}{n} * \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| * 100 \dots \dots \dots (8)$$

• الأدوات المستخدمة في معالجة البيانات: هي مجموعة من البرامج لتقدير واختبار النموذج الملائم للبيانات وفق طريقة بوكس جينكنز وأسلوب الشبكات العصبية الاصطناعية، بالإضافة لإعداد نتائج الاختبارات، وهي: (Matlab 2014a, Alyuda Neurointelligence, Minitab 16, Eviews 10, Excel 2010).

النتائج والمناقشة:

1. تحليل سلسلة درجات الحرارة الصغرى اليومية (Tmin) خلال فصل الشتاء والتنبؤ بها:

للبحث في استقرار السلسلة الزمنية خلال الفترة (2014/12/21-2015/3/21)، لابد من عرض الشكل البياني لقيم السلسلة مع الزمن خلال الفترة (2014/12/21-2015/3/11) مع ترك القيم العشرة الأخيرة لمرحلة اختبار النموذج. حيث نلاحظ عند استخدام نموذج الانحدار الخطي البسيط (Linear Trend Model) الموضح بالشكل (2)، بأن السلسلة غير مستقرة (غير متجانسة)، لكن الاختبار البياني غير كافٍ ولا بد من إجراء مجموعة من الاختبارات الإحصائية.



الشكل (2): المنحني البياني الممثل لسلسلة درجات الحرارة اليومية الصغرى (Tmin)

- فحص دالة الارتباط الذاتي والذاتي الجزئي: يتم من خلال رسم معاملات دالة الارتباط الذاتي لسلسلة العودة لعدد من الفروق الزمنية ((lag (1) to lag(15)) كما هو موضح بالشكل(3) باستخدام برنامج (Eviews 10).

Sample: 12/21/2014 3/11/2015
Included observations: 81

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
0.662	0.662	1	0.662	36.777	0.000
0.452	0.025	2	0.452	54.144	0.000
0.243	-0.116	3	0.243	59.214	0.000
0.067	-0.106	4	0.067	59.603	0.000
-0.014	0.014	5	-0.014	59.621	0.000
-0.070	-0.025	6	-0.070	60.059	0.000
-0.067	0.023	7	-0.067	60.470	0.000
-0.014	0.071	8	-0.014	60.489	0.000
0.044	0.053	9	0.044	60.673	0.000
0.028	-0.093	10	0.028	60.747	0.000
-0.002	-0.054	11	-0.002	60.747	0.000
-0.120	-0.173	12	-0.120	62.161	0.000
-0.214	-0.092	13	-0.214	66.707	0.000
-0.194	0.100	14	-0.194	70.478	0.000
-0.174	0.015	15	-0.174	73.572	0.000

الشكل (3): دالة الترابط الذاتي والذاتي الجزئي لسلسلة (Tmin) من أجل تباطؤ (k=15)

من خلال ملاحظة قيم معاملات الارتباط الذاتي (ACF) نجد أنها معنوية عند مستوى دلالة (5%) لعدد كبير من الإزاحات ولا تهبط مباشرة إلى الصفر بل تتناقص أسيًا، مما يوحي بوجود مركبة اتجاه عام وبالتالي السلسلة غير مستقرة، ويمكن التأكد من ذلك بتطبيق اختبار ديكي فولر الموسع (ADF) الموضح بالجدول (1).

الجدول (1): اختبار ديكي فولر الموسع (ADF) لسلسلة درجات الحرارة الصغرى (Tmin)

Model		A	B	C
Exogenous:		Constant	Constant, Linear Trend	None
t*_test:		t-Statistic	t-Statistic	t-Statistic
Augmented Dickey-Fuller test statistic:		-4.038	-4.322	<u>-1.261</u>
Prob.*		0.002	0.005	0.190
Test critical values:	1% level	-3.505	-4.063	-2.591
	5% level	-2.894	-3.461	<u>-1.944</u>
	10% level	-2.584	-3.156	-1.614
*MacKinnon (1996) one-sided p-values				

نلاحظ من الجدول (1) أن السلسلة تقبل جذر الوحدة من أجل النموذج (C) حيث قيمة احتمالية اختبار (t) هي: (Pvalue=0.190) أكبر من مستوى (0.05)، وبالتالي نقبل الفرضية الصفرية بوجود جذر الوحدة والسلسلة غير مستقرة.

- نأخذ الفروقات من الدرجة الأولى ($\nabla Y = Y_t - Y_{t-1}$) لإزالة الاتجاه العام، ونعيد رسم دالتي الترابط الذاتي والذاتي الجزئي كما هو موضح بالشكل (4)، حيث نلاحظ أن معاملات الارتباط الذاتي المحسوبة للفترات ($k = 1, 2, \dots, 15$) تساوي أو قريبة من الصفر وتقع جميعها داخل الحدود الصفرية لمجال الثقة $\left[\frac{-1.96}{\sqrt{n}}, \frac{+1.96}{\sqrt{n}} \right]$ ، والسلسلة أصبحت مستقرة، وللتأكد من استقرارية السلسلة الزمنية للفروقات الأولى يمكن تطبيق اختبار ديكي فولر (ADF) الموضح بالجدول (2).

Sample: 12/21/2014 3/11/2015
Included observations: 80

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.181	-0.181	2.7070	0.100
		2 0.013	-0.020	2.7214	0.256
		3 -0.088	-0.092	3.3794	0.337
		4 -0.118	-0.157	4.5901	0.332
		5 -0.030	-0.090	4.6698	0.457
		6 -0.054	-0.099	4.9258	0.553
		7 -0.085	-0.161	5.5724	0.590
		8 -0.025	-0.131	5.6285	0.689
		9 0.113	0.033	6.7979	0.658
		10 -0.007	-0.042	6.8019	0.744
		11 0.151	0.094	8.9612	0.625
		12 -0.059	-0.028	9.2971	0.677
		13 -0.160	-0.194	11.813	0.543
		14 0.002	-0.078	11.813	0.621
		15 -0.063	-0.085	12.212	0.663

الشكل (4): دالة الترابط الذاتي والذاتي الجزئي من أجل سلسلة الفروقات من الدرجة الأولى (dTmin)

الجدول (2): اختبار ديكي فوللر (ADF) لسلسلة الفروقات من الدرجة الأولى (dTmin)

Model		A	B	C
Exogenous:		Constant	Constant, Linear Trend	None
t*_test:		t-Statistic	t-Statistic	t-Statistic
Augmented Dickey-Fuller test statistic:		-11.096	-11.032	-11.161
Prob.*		0.000	0.000	0.000
Test critical values:	1% level	-3.505	-4.064	-2.591
	5% level	-2.894	-3.461	-1.944
	10% level	-2.584	-3.15	-1.6147
*MacKinnon (1996) one-sided p-values				

نقوم بتحديد النموذج الإحصائي المناسب للبيانات من خلال معايير المفاضلة المعتمدة والموضحة في الجدول (3)، حيث نجد أن النموذج ARIMA (1,1,1) يوافق أقل قيمة لمعيار (AIC*) ولبقية المعايير (BIC،HQ) أيضاً.

الجدول (3): يمثل قيم معايير المفاضلة بين النماذج المرشحة.

Model (p,1,q)	AIC*	BIC	HQ
(1,1)(0,0)	4.672	4.791	4.720
(2,1)(0,0)	4.697	4.846	4.756
(1,2)(0,0)	4.697	4.846	4.756
(3,1)(0,0)	4.705	4.884	4.777
(1,3)(0,0)	4.706	4.884	4.777
(3,3)(0,0)	4.708	4.947	4.804
(0,4)(0,0)	4.711	4.890	4.783
(2,2)(0,0)	4.719	4.898	4.791
(4,1)(0,0)	4.725	4.933	4.808
(2,3)(0,0)	4.725	4.934	4.809

✓ اختبار معنوية معالم النموذج ARIMA (1,1,1): من النتائج الموضحة في الجدول (4) نجد أن قيمة احتمالية الاختبار (P=0.00) لمعاملات النموذج أقل تماماً من مستوى المعنوية (5%) وبالتالي نرفض الفرضية الصفرية، ونقبل الفرضية البديلة الفائزة بأن معالم النموذج ذات تأثير معنوي فيه، بينما القيمة الاحتمالية للحد الثابت تشير إلى عدم معنويته ويمكن حذفه من النموذج.

الجدول (4): نتائج تقدير النموذج ARIMA (1,1,1) على السلسلة الزمنية (Tmin).

Type	Coef	SE Coef	T*	P
AR (1)	0.6378	0.0959	6.65	0.000
MA (1)	0.9891	0.0356	27.74	0.000
Constant	0.01719	0.01590	1.08	0.283

Differencing: 1 regular difference
 Number of observations: Original series 81, after differencing 80
 Residuals: SS = 442.874 (backforecasts excluded)
 MS = 5.752 DF = 77

وعليه يمكن كتابة النموذج المرشح بالشكل:

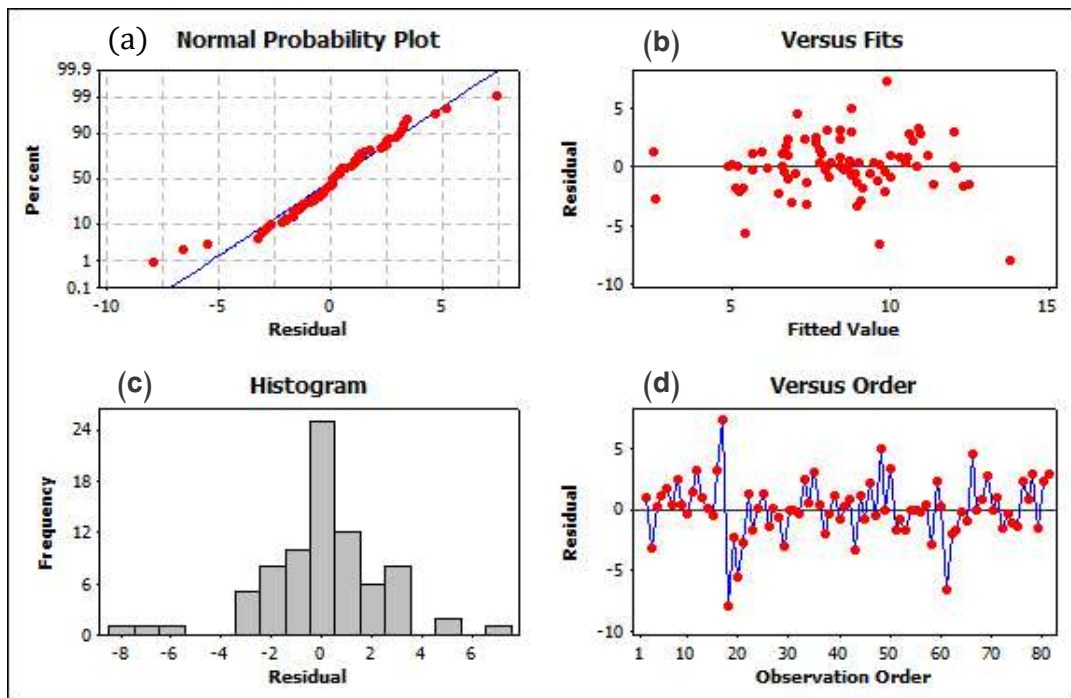
$$Z_t = 0.6378 * Z_{t-1} + a_t + 0.9891 * a_{t-1} \quad a_t \sim N(0, 5.752) \dots \dots \dots (9)$$

وبتعويض $(Z_t = Y_t - Y_{t-1})$ نجد:

$$Y_t = 1.6378 * Y_{t-1} + 0.6378 * Y_{t-2} + a_t + 0.9891 * a_{t-1} \dots \dots \dots (10)$$

تحليل سلسلة البواقي (Residual Analysis) للنموذج ARIMA (1,1,1): يتم من خلال الاختبارات الآتية: ✓

(1) اختبارات التوزيع الطبيعي للبواقي: من خلال مخرجات النموذج الموضحة في الشكل (5).



الشكل (5): (a) الاحتمال الطبيعي (K-S)، (b) مخطط مبغثر للأخطاء، (c) المدرج التكراري، (d) أخطاء النموذج.

الرسم البياني للمدرج التكراري في الشكل (5) يوحي ببعض التناظر وله شكل التوزيع الطبيعي تقريباً، وهذا لا يكفي بل يجب أن ننظر إلى المخطط الاحتمالي الطبيعي (Normal Probability Plot) الذي يوضح مدى اقتراب القيم من الخط الملائم (Fitted Line)، حيث أشارت القيمة الاحتمالية $(P - Value = 0.142)$ الناتجة عن برنامج

(Minitab 16) لاختبار K-S (Kolmogorov-Smirnov) أنها أكبر من (5%)، وبالتالي نقبل الفرضية الصفرية القائلة بأن البواقي طبيعية.


(2) عشوائية البواقي: يوحي المخطط المبعثر في الشكل (5) على جانبي الخط الذي يمثل الصفر (وهو الخط الذي يفصل بين البواقي السالبة والبواقي الموجبة)، حيث أنه لا يمكننا رصد نمط أو شكل معين لتباين هذه البواقي، وهو ما يعني أن هناك تجانس أو ثبات في تباين الأخطاء، وللتأكد تجري اختبار التعاقب (Runs Test) باستخدام برنامج (Minitab 16)، والتي تظهر نتائجه في الجدول (5).

الجدول (5): نتائج اختبار التعاقب (Runs Test) على سلسلة بواقي النموذج (1,1,1) ARIMA

Runs Test:	RESI1
Runs above and below K =	0
The observed number of runs =	43
The expected number of runs =	40.6
44 observations above K;	36 below
P-value =	0.585

نلاحظ من الجدول (5) أن القيمة الاحتمالية للاختبار ($P - Value = 0.142$) أكبر من مستوى المعنوية (5%)، وبالتالي نقبل الفرضية الصفرية القائلة بأن البواقي ذات تولد عشوائي وتتبع توزيع الضجة البيضاء.

(3) اختبار استقلالية البواقي: وذلك من خلال رسم دالتي (ACF) و (PACF) كما هو موضح بالشكل (6).

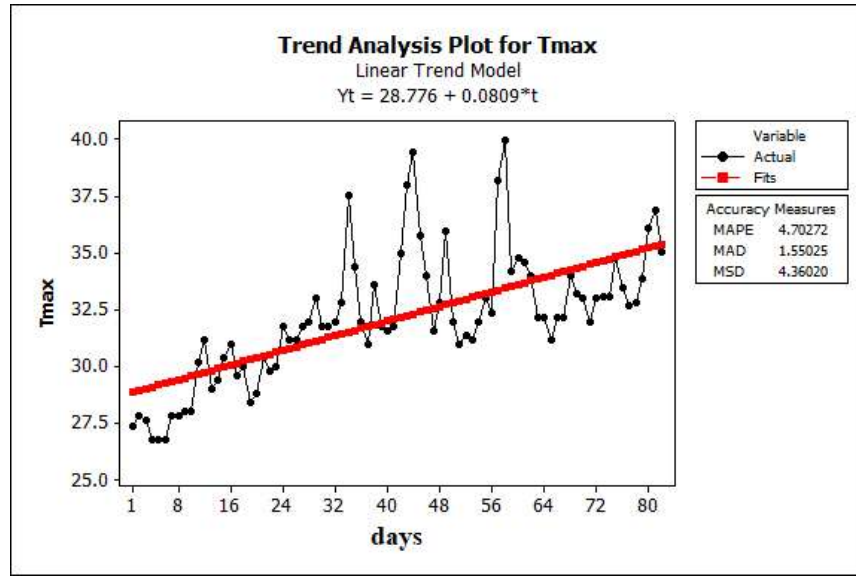


الشكل (6): اختبار دالة الترابط الذاتي والذاتي الجزئي من أجل بواقي النموذج (1,1,1) ARIMA

من خلال الشكل (6) نلاحظ أن معاملات الارتباط الذاتي تقع جميعها داخل مجال الثقة $\left[\frac{-1.96}{\sqrt{n}}, \frac{+1.96}{\sqrt{n}} \right]$ ، وعليه نقبل النموذج ويمكن اعتباره مستقرًا.

2. تحليل سلسلة درجات الحرارة العظمى اليومية (Tmax) خلال فصل الصيف والتنبؤ بها:

عند اخذ السلسلة الزمنية لدرجات الحرارة العظمى اليومية خلال الفترة (2015/6/21-2015/9/20)، وتمثيل القيم بيانياً خلال الفترة (2015/6/21-2015/9/10)، كما هو موضح بالشكل (7)، تبين وجود مركبة اتجاه عام والسلسلة غير مستقرة.



الشكل (7): المنحني البياني الممثل لسلسلة درجات الحرارة العظمى (Tmax)


- نأخذ الفروقات من الدرجة الأولى كما هو موضح في الشكل (8)، ونرسم دالة الارتباط الذاتي والذاتي الجزئي لسلسلة الفروقات فنلاحظ أنها تقع جميعها ضمن الحدود الصفرية ويمكن اعتبار السلسلة مستقرة.

Included observations: 81

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.036	-0.036	0.1081	0.742
		2	-0.289	-0.291	7.2218	0.027
		3	-0.119	-0.156	8.4437	0.038
		4	-0.008	-0.124	8.4491	0.076
		5	0.045	-0.055	8.6291	0.125
		6	0.057	-0.002	8.9221	0.178
		7	-0.276	-0.328	15.854	0.026
		8	-0.041	-0.113	16.011	0.042
		9	0.167	-0.040	18.628	0.029
		10	-0.001	-0.152	18.629	0.045
		11	0.005	-0.047	18.631	0.068
		12	-0.111	-0.224	19.840	0.070
		13	0.015	-0.056	19.864	0.099
		14	0.155	-0.045	22.262	0.073
		15	0.171	0.113	25.224	0.047

الشكل (8): دالة الترابط الذاتي والذاتي الجزئي من أجل سلسلة الفروقات من الدرجة الأولى (dTmax).

- **مرحلة التعرف على النموذج (تشخيص النموذج):** من خلال ملاحظة الشكل (9) الذي يبين قيم (AIC^*) لـ (20) نموذج، نجد أن النموذج المرشح والموافق لأقل قيمة للمعيار هو النموذج $ARIMA(1,1,2)$. ويمكن الانتقال إلى المرحلة التالية التي تتضمن فحص معنوية النموذج وفرضية التوزيع الطبيعي للبواقي.



الشكل (9): معيار اكيي (AIC) للمفاضلة بين (20) نموذج لسلسلة $(dTmax)$.

- ✓ **اختبار معنوية معالم النموذج:** من خلال الجدول (6) الذي يوضح نتائج المفاضلة بين النماذج المرشحة وعند فحص معنوية معالم النماذج المقترحة بالترتيب وفق معيار (AIC) الأقل مع مراعاة شرط التوزيع الطبيعي للبواقي، توصلنا إلى النموذج $ARIMA(0,1,2)$ وفق المعيار المعتمد والفرضيات الإحصائية.

الجدول (6): نتائج تقدير معالم النماذج على السلسلة الزمنية (Tmax).

Model	Coefficients	P-value	AIC*	BIC	HQ
(1,2)	$\phi_1 = 0.5041$ $\theta_1 = 0.7281$ $\theta_2 = 0.2946$ Const. = 0.043887	0.000 0.000 0.000 0.000	-3.162	-3.015	-3.103
(2,1)	$\phi_1 = -0.0157$ $\phi_2 = -0.0382$ $\theta_1 = -0.9799$ Const. = 0.2036	0.000 0.745 0.000 0.3966	-3.159	-3.011	-3.100
(0,2)	$\theta_1 = 0.2942$ $\theta_2 = 0.4796$ Const. = 0.09013	0.004 0.000 0.040	-3.150	-3.032	-3.103
(3,3)	$\phi_1 = -0.9178$ $\phi_2 = 0.1843$ $\phi_3 = 0.3509$ $\theta_1 = -0.7330$ $\theta_2 = 0.8442$ $\theta_3 = 0.9323$ Const. = 0.09847	0.000 0.244 0.019 0.000 0.000 0.000 0.000	-3.156	-2.919	-3.061

وبالتالي يمكن كتابة النموذج ARIMA (0,1,2) بالشكل:


$$Z_t = 0.09013 + a_t + 0.2942 * a_{t-1} + 0.4796 * a_{t-2} ; a_t \sim N(0; 2.715) \dots \dots \dots (11)$$

وبتعويض ($Z_t = Y_t - Y_{t-1}$) نجد:

$$Y_t = Y_{t-1} + 0.09013 + a_t + 0.2942 * a_{t-1} + 0.4796 * a_{t-2} \dots \dots \dots (12)$$

تحليل سلسلة البواقي (Residual Analysis) للنموذج ARIMA (0,1,2): ✓

(1) اختبارات التوزيع الطبيعي للبواقي: من خلال اختبار K-S المبين بالشكل (10)، نجد أن القيمة الاحتمالية ($P - Value = 0.128$) لا اختبار أكبر من (5%)، وبالتالي نقبل الفرضية الصفرية القائلة بأن البواقي طبيعية.



الشكل (10): اختبار (Kolmogorov-Smirnov) لطبيعة البواقي.

(2) اختبار عشوائية البواقي للنموذج $ARIMA(0,1,2)$: من خلال مخرجات اختبار التعاقب المبينة في الجدول (7) نجد أن القيمة الاحتمالية للاختبار ($P - Value = 0.916$) أكبر من 5%، وبالتالي نقبل الفرضية الصفرية القائلة بأن البواقي ذات تولد عشوائي وتتبع توزع الضجة البيضاء.

الجدول (7): نتائج اختبار التعاقب (Runs Test) على سلسلة بواقي النموذج $ARIMA(0,1,2)$

Runs Test:	RESI1
Runs above and below K =	0
The observed number of runs =	40
The expected number of runs =	40.4568
34 observations above K;	47 below
P-value =	0.916

(3) تحليل دالة الارتباط الذاتي والجزئي للبواقي: من خلال الشكل (11) نلاحظ عدم وجود ارتباط ذاتي بين البواقي مع احتمالية أكبر من 5% لجميع الفترات، وهذا يدل أن البواقي تتبع أنماط متسلسلة الضجة البيضاء أي أن البواقي متجانسة وغير مرتبطة.

Included observations: 81

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.102	0.102	0.8664	0.352
		2	0.102	0.093	1.7550	0.416
		3	-0.096	-0.117	2.5422	0.468
		4	0.002	0.013	2.5425	0.637
		5	-0.093	-0.075	3.3019	0.654
		6	-0.017	-0.013	3.3290	0.767
		7	-0.267	-0.255	9.8244	0.199
		8	-0.081	-0.047	10.426	0.236
		9	0.067	0.138	10.849	0.286
		10	-0.026	-0.103	10.912	0.364
		11	0.069	0.055	11.364	0.413
		12	-0.029	-0.053	11.448	0.491
		13	0.131	0.125	13.144	0.437
		14	0.149	0.105	15.375	0.353
		15	0.216	0.131	20.129	0.167

الشكل (11): دالة الترابط الذاتي والذاتي الجزئي من أجل بواقي النموذج ARIMA (0,1,2)

3. تقدير قيم درجات الحرارة العظمى والصغرى اليومية باستخدام النماذج (ARIMA-ANN)

يقتصر استخدام الشبكات العصبية (FFNN) على ربط مخرجات النماذج الإحصائية (ARIMA) الخطية مع الأخطاء العشوائية للنموذج وفق الآتي:

- يتم إعداد البيانات بتقسيمها إلى ثلاث مجموعات: تدريب وتحقيق واختبار بنسبة (15:15:70)%, وتمثيلها المدخلات بشكل الثنائي القطب (1,-1)، والمخرجات بالشكل الثنائي (0,1).
- في مرحلة التصميم تم الاعتماد على دالة الظل القطعي (Hyperbolic tangent) كدالة تحفيز في الطبقة الخفية وطبقة المخرجات، كما رشحت مجموعة من التصاميم باستخدام برنامج (Alyuda Neurointelligence) للنتبؤ بكل من درجتي الحرارة الصغرى والعظمى اليومية، وذلك ضمن مجال لعدد العصبونات بين (10) و(30) عصبون في الطبقة الخفية، وحصلنا على النتائج الموضحة بالجدول (8).

الجدول (8): اختيار معمارية نموذج (FFNN)

Minimum temperature	ID	Architecture	# of Weights	Fitness	Train Error	Validation Error	Test Error	AIC*	Correlation	R-Squared
	1	[1-10-1]	31	0.75	1.23	1.14	1.19	-152.00	0.75	0.56
	2	[1-30-1]	91	0.76	1.19	1.17	1.18	-33.85	0.76	0.57
	3	[1-22-1]	67	0.75	1.21	1.14	1.17	-80.87	0.75	0.56
	4	[1-17-1]	52	0.74	1.23	1.15	1.17	-109.61	0.74	0.55
	5	[1-26-1]	79	0.83	1.08	1.14	1.18	-63.02	0.83	0.68
	6	[1-28-1]	85	0.74	1.24	1.15	1.21	-43.45	0.74	0.55
	7	[1-24-1]	73	0.76	1.21	1.16	1.19	-68.95	0.76	0.57
	8	[1-27-1]	82	0.76	1.18	1.15	1.23	-51.96	0.76	0.58
	9	[1-25-1]	76	0.76	1.17	1.16	1.20	-64.42	0.76	0.58
Maximum temperature	ID	Architecture	# of Weights	Fitness	Train Error	Validation Error	Test Error	AIC	Correlation	R-Squared
	1	[1-10-1]	31	0.73	1.00	0.65	0.86	-163.62	0.73	0.53
	2	[1-30-1]	91	0.73	0.99	0.74	0.89	-43.95	0.73	0.53
	3	[1-22-1]	67	0.73	1.01	0.66	0.82	-91.12	0.73	0.53
	4	[1-17-1]	52	0.82	0.75	0.70	0.87	-137.43	0.82	0.68
	5	[1-14-1]	43	0.73	1.01	0.63	0.64	-138.96	0.73	0.53
	6	[1-20-1]	61	0.73	1.02	0.70	0.83	-102.54	0.73	0.53
	7	[1-18-1]	55	0.63	1.19	0.70	0.64	-105.58	0.63	0.33
	8	[1-15-1]	46	0.71	1.03	0.74	0.76	-131.91	0.71	0.51
9	[1-16-1]	49	0.72	1.02	0.63	0.67	-126.48	0.72	0.52	

من الجدول (8) وبالاعتماد على معيار (AIC*) ومعايير الارتباط (Correlation) كمعايير حسم (Fitness) في اختيار هيكلية الشبكة، وجدنا أن أفضل معمارية لتمثيل درجة الحرارة الصغرى اليومية هي (FNNN(1-26-1)، وأفضل معمارية لتمثيل درجة الحرارة العظمى اليومية هي (FNNN(1-17-1).

• بعد تحديد هيكلية الشبكة، يمكن الآن تدريب النماذج المقترحة داخل بيئة برنامج (Matlab 2014a)، وذلك باستخدام خوارزمية الانتشار الخلفي (LM)، مع تثبيت نسبة التعلم (Learning Rate=0.1)، وثابت الزخم (Momentum Constant=0.1)، وعدد التكرارات (Itreaton=2000)، علماً أن تدريب الشبكات المقترحة يتوقف عند الوصول إلى مستوى مقبول إحصائياً وهو ما يحقق أقل خطأ ممكن.

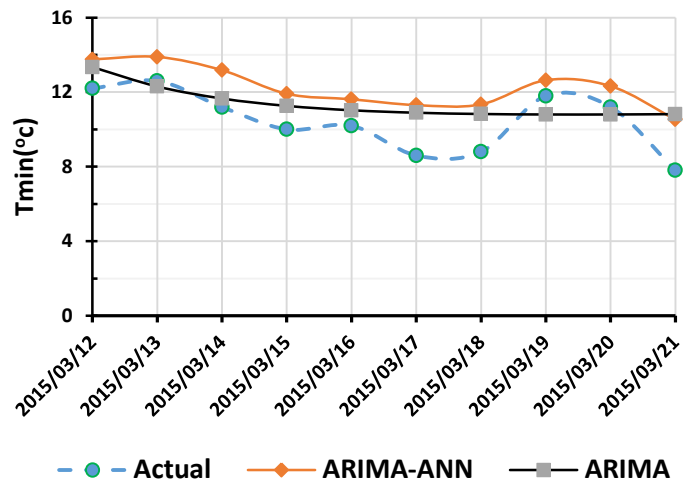
في مرحلة التحقق من مدى ملائمة النموذج (ARIMA-ANN) للسلسلة الزمنية يتم دمج نتائج النموذجين وإعادة التنبؤ بقيم درجة الحرارة العظمى والصغرى في محطة سد الباسل، والجدول (9) يوضح نتائج النموذج الهجين في مرحلة التدريب وإعداد النموذج.

الجدول (9): المعايير الإحصائية لنموذج ARIMA-ANN

Variable	Minimum temperature (°C)		Maximum temperature (°C)	
	ARIMA	ARIMA-ANN	ARIMA	ARIMA-ANN
Included Observations:	80	80	81	81
Root Mean Squared Error	2.39	1.23	1.618	1.05
Mean Absolute Error	1.69	0.93	1.204	0.81
Mean Abs. Percent Error	30.59	5.69	3.623	2.5
Correlation	0.68	0.93	0.82	0.93


النتائج المفصلة في الجدول (9) تشير إلى ارتفاع ملحوظ في قدرة النماذج (ARIMA-ANN) على تمثيل كل من درجة الحرارة الصغرى والعظمى اليومية، حيث بلغت قيمة الجذر التربيعي لمتوسط مربع الخطأ (RMSE) لدرجة الحرارة الصغرى (1.05) درجة مئوية، ودرجة الحرارة العظمى (1.23) درجة مئوية، بمعامل ارتباط (0.93) لكلا النموذجين. المرحلة الأخيرة تتمثل في اختبار قدرة النموذج (ARIMA-ANN) على التنبؤ بكل من درجة الحرارة الصغرى والعظمى خلال الفترتين السابقتين (10 أيام الأخيرة)، ومقارنة النتائج كما هو موضح في الشكل (12)، والشكل (13).

Variable	Minimum Temperature	
	ARIMA	ARIMA-ANN
Model	ARIMA	ARIMA-ANN
Forecast Sample:	10	10
R	0.63	0.94
R-square	0.4	0.9
RMSE (°C)	1.5	1.9
MAE	1.3	1.8
MAPE (%)	13.7	18.6



الشكل (12): منحنى تقدير القيم الصغرى لدرجة الحرارة اليومية في محطة سد الباسل.

Variable	Maximum Temperature	
Model	ARIM A	ARIMA- ANN
Forecast Sample:	10	10
R	-0.43	0.9
R-squre	0.2	0.81
RMSE (°C)	2.3	1.6
MAE	2.1	1.5
MAPE (%)	6.1	4.3



الشكل (13): منحنى تقدير القيم العظمى لدرجة الحرارة في محطة سد الباسل.

يلاحظ من الشكل (12) والشكل (13) مع المعايير الإحصائية المرافقة مقدار المواءمة بين القيم الحقيقية والقيم الناتجة عن نموذج (ARIMA-ANN) ونموذج (ARIMA)، حيث يعتبر الأخير أن قيمة الخطأ العشوائي خارج حدود العينة هو صفر، وبالتالي انحدار القيم التنبؤية للأعلى أو للأسفل (التنبؤ بمركبة الاتجاه العام للسلسلة)، في حين أن نماذج (ARIMA-ANN) قادرة على تقدير قيمة الخطأ وإضافته إلى القيم المقدره بالنموذج الخطي، وبالتالي تحسين قدرة النموذج وبشكل ملحوظ على توقع الاضطرابات العشوائية الخاصة بالسلسلة، وبالتالي الحصول على تنبؤات أكثر اتساقاً مع السلسلة الفعلية في حالة استخدام نماذج هجينة (ARIMA-ANN).

الاستنتاجات والتوصيات:

الاستنتاجات:

من خلال الدراسة التطبيقية لتحليل السلسلة الزمنية وباستخدام كل من (ARIMA) و (ARIMA-ANN) لغرض التنبؤ بدرجات الحرارة الصغرى والعظمى اليومية في محطة سد الباسل خلال الفترة (2014-2015)، توصلت الدراسة إلى الاستنتاجات التالية:

- إمكانية استعمال النماذج الهجينة من (ARIMA-ANN) في تمثيل قيم درجات الحرارة الصغرى والعظمى اليومية ومحاولة التنبؤ بها على المستقبل القريب، وذلك بكفاءة أعلى من استخدام نماذج (ARIMA) منفردة.

- من خلال تحليل السلسلة الزمنية وإجراء الاختبارات الإحصائية تبين أن النموذج الإحصائي الملائم لسلسلة درجة الحرارة الصغرى اليومية هو $ARIMA(1,1,1)$ بالتوافق مع نموذج الشبكة العصبية الاصطناعية $FNN(1-26-1)$ (1) الممثل لسلسلة البواقي للنموذج الإحصائي، بينما النموذج الملائم لسلسلة درجة الحرارة العظمى اليومية هو $ARIMA(0,1,2)$ بالتوافق مع النموذج $FNN(1-17-1)$ الممثل للأخطاء.

التوصيات:

- من الممكن استخدام طريقة مشابهة في التحليل الإحصائي المقترح لبناء نماذج التنبؤ بدرجات الحرارة في محطات مناخية أخرى، مما يتيح إمكانية تطوير قواعد البيانات والمعلومات الإحصائية لكي تخدم عملية التخطيط بشكل مرض.

References:

1. ABDULLAH, LATIFA. *Prediction of Maximum Temperature Degree For Dohok province in 2011 By Using one of the models ARIMA Model for Theory of Box-Jenkins To Time Series*. Journal of the college of basic education, 2005, Vol. 18, 829-811.
2. MAQSOOD, I.; KHAN, R.M.; HUANG, H.G.; ABDALLA, R. *Application of soft computing models to hourly weather analysis in southern Saskatchewan, Canada*. Elsevier, 2005, Vol. 18, 115-125.
3. USTAOGLU, B.; CIGIZOGLU, H.K.; KARACA, M. *Forecast of daily mean, maximum and minimum temperature time series by three artificial neural network methods*. Meteorological Applications, 2008, Vol. 15, No. 4, 431-445.
4. DE, S. S.; DEBNATH, A. *Artificial Neural Network Based Prediction of Maximum and Minimum Temperature in the Summer Monsoon Months over India*. Applied Physics Research, 2009, Vol. 1, No. 2.
5. ODEH, I. *Temperature Prediction in Jordan using ANN*. International Journal of Computer Science and Information Technologies, 2016, Vol. 7, No. 1, 378-383.
6. MOHAMMAD, A.S. *Weather Temperature Forecasting Using Artificial Neural Network*. Journal of Engineering and Development, 2011, Vol. 15, No. 2, ISSN 1813-7822.
7. ABDSATTAR, ARBAOUI. *Temperature Forecasting for Ouargla Province using Box-Jenkins Time Series methode for the period (2004-2014)*. Master Thesis, Université Kasdi Merbah Ouargla, 2016, 69.
8. ZHENG, F.; ZHONG, S. *Time series forecasting using a hybrid RBF neural network and AR model based on binomial smoothing*. World Academy of Science, Engineering and Technology, 2011, 1471-1475.
9. FARUK, D. Ö. *A hybrid neural network and ARIMA model for water quality time series prediction*. Engineering Applications of Artificial Intelligence, 2010, Vol. 23, No. 4, 586-594.
10. Hippert, H. S.; Pedreira, C. E.; Souza, R. C. *Combining neural networks and ARIMA models for hourly temperature forecast*. In Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium, 2000, Vol. 4, 414-419.
11. AL-OBEIDI, ABDUL GHAFOR JASSIM; AL-HAMDANI, RAAD AWAD. *Study the stability of some harmonic models with the application*. AL-Rafidain Journal of Computer Sciences and Mathematics. 2004, Vol. 7, No. 2, 139-157.

12. HANSEN, J. V.; MCDONALD, J. B.; NELSON, R. D. *Time Series Prediction With Genetic-Algorithm Designed Neural Networks: An Empirical Comparison With Modern Statistical Models*. Computational Intelligence, 1999, Vol. 15, No. 3, 171-184.
13. MASO, AMJAD ABDUL LATIF. *Statistics using MINITAB 15*. First edition, Aleppo, 2008, 502.
14. WAGNER, J. *Estimating the Optimal Scale of Public Investments: The Case of Low-Level Radioactive Waste Disposal Facilities*. Journal of Regulatory Economics, 2000, Vol. 17, No. 2, 173-188.
15. DICKEY, D. A.; FULLER, W. A. *Likelihood ratio statistics for autoregressive time series with a unit root*. Econometrica: Journal of the Econometric Society, 1981, 1057-1072.
16. WILLIAM W.S. WEI. *Time Series Analysis Univariate and Multivariate Methods*, 2nd edition, Temple University, 2006, 167-168.
17. YÜREKLI, K.; KURUNÇ, A.; ÖZTÜRK, F. *Testing the residuals of an ARIMA model on the Cekerek Stream Watershed in Turkey*. Turkish Journal of Engineering and Environmental Sciences, 2005, Vol. 29, No. 2, 61-74.
18. ASCE TASK COMMITTEE on APPLICATION of ARTIFICIAL NEURAL NETWORKS in HYDROLOGY. *Artificial Neural Networks in Hydrology. I: Preliminary concepts*. J. Hydrol. Eng, 2000a, 115-123.
19. ASCE TASK COMMITTEE on APPLICATION of ARTIFICIAL NEURAL NETWORKS in HYDROLOGY. *Artificial Neural Networks in Hydrology. II: Hydrologic applications*. J. Hydrol. Eng, 2000b, 124-137.
20. LOPEZ, G.; RUBIO, M. A.; MARTINEZ, M.; BAHLES, F. J. *Estimation of Hourly Global Photosynthetically Active Radiation Using Artificial Neural Network Models*. Agricultural and Forest Meteorology, 2001, 107:279-291.
21. NAWI NAZRI M.; ABDULLAH KHAN.; REHMAN M. Z. *A new Levenberg Marquardt based back propagation algorithm trained with cuckoo search*. Procedia Technology. 2013, 11: 18-23.
22. ZHANG, G.-P. *Time series forecasting using a hybrid ARIMA and neural network model*. Neurocomputing, 50, 2003, 159-175.
23. WOSCHNAGG, ELISABETH.; CIPAN, JANA. *Evaluating Forecast Accuracy*. UK Ökonometrische Prognose. University of Vienna, Department of Economics, 2004, 1-18.