

التنبؤ المستقبلي بدرجات الحرارة في محافظة نينوى باستخدام النموذج
الهجين (AR-ANN)

أ.د. علي مهدي جواد الدجيلي

الجامعة العراقية / كلية الآداب / قسم الجغرافية

ali.al-dujaili@aliraqia.edu.iq

م.م. خالد رائد نافع فتحي

مركز الليزر والفوتونيات، قسم التحسس والفوتونيات النانوية، جامعة الحمدانية

Khaled.r.nafea@uhamdaniya.edu.iq



*Future Forecasting of Temperature in Nineveh Governorate Using the Hybrid
AR-ANN Model.*

Prof. Dr. Ali Mahdi Jawad Al-Dujaili

Iraqi University / College of Arts / Department of Geography

Khaled Raed Nafea

Laser and Photonics Center, Department of Sensing and Nanophotonics, Al-Hamdaniya

University



المستخلص

يهدف هذا البحث الى التنبؤ المستقبلي بدرجات الحرارة في محافظة نينوى باستخدام النموذج الهجين (AR-ANN) من خلال دمج التحليل الإحصائي الخطي مع تقنيات الذكاء الاصطناعي لمعالجة التعقيد الزمني في السلاسل المناخية . اعتمدت الدراسة على بيانات درجات الحرارة العظمى والصغرى المسجلة في (7) محطات المناخية المختارة للفترة التاريخية (1994-2024) ، الصادرة عن الهيئة العامة للأواء الجوية والرصد الزلزالي ، لغرض تحليل الاتجاهات المناخية وبناء نموذج تنبؤي للفترة المستقبلية (2025-2034) ، تم في المرحلة الأولى بناء نموذج الانحدار الذاتي (AR) لتحديد البنية الخطية للسلسلة الزمنية اعتمادا على تحليلي (ACF) و (PACF) ومعايير (AIC, BIC) ، ثم استخدمت القيم الزمنية الناتجة كمدخلات لشبكة عصبية اصطناعية متعددة الطبقات (MLP) لمعالجة المكونات غير الخطية المتبقية ، ل يتم بعد ذلك دمج النموذجين ضمن اطار هجين (ANN-AR) . جرى تقييم كفاءة النماذج باستخدام مقاييس دقة إحصائية أهمها (RMSE) و (MAPE) .

أظهرت النتائج تفوق النموذج الهجين على النموذج الخطي التقليدي من حيث خفض قيم الخطأ وتحسين دقة التنبؤ في جميع المحطات تقريبا ، مع وجود تباين مكاني في الأداء يعكس الخصائص المحلية لكل محطة . كما بينت التوقعات المستقبلية وجود اتجاه تصاعدي طفيف الى متوسط في درجات الحرارة العظمى ، وارتفاع أكثر انتظاما في درجات الحرارة الصغرى ، خاصة اشهر الشتاء ، مما يشير الى ميل نحو تقليل المدى الحراري اليومي وزيادة الاحترار الليلي .

تؤكد الدراسة ان اعتماد النماذج الهجينة يمثل اطارا منهجيا أكثر ملاءمة لتمثيل السلوك الزمني المعقدة للعناصر المناخية في البيئات شبه الجافة ، ويوفر أساسا علمية داعما للتخطيط المناخي وإدارة الموارد في محافظة نينوى .
الكلمات المفتاحية :

درجة الحرارة ، التنبؤ المناخي ، النموذج الهجين (ANN-AR) ، الشبكات العصبية الاصطناعية ، محافظة نينوى .

Abstract

This research aims to predict future temperatures in Nineveh Governorate using the AR-ANN hybrid model by combining linear statistical analysis with artificial intelligence techniques to address the temporal complexity of climate series. The study relied on maximum and minimum temperature data recorded at seven selected climate stations for the historical period 1994-2024 , Issued by the General Authority for Meteorology and Seismic Monitoring, for the purpose of analyzing climate trends and building a predictive model for the future period (2025-2034), in the first stage, an autoregressive (AR) model was built to determine the linear structure of the time series based on the analyses of (ACF) and (PACF) and the criteria of (AIC, BIC), The resulting time values were then used as inputs to a multi-layer artificial neural network (MLP) to process the remaining nonlinear components, after which the two models were combined within a hybrid framework (ANN-AR). The efficiency of the models was evaluated using statistical accuracy measures, the most important of which are RMSE and MAPE.

The results showed the hybrid model's superiority over the traditional linear model in terms of reducing error values and improving forecast accuracy at almost all stations, with spatial variation in performance reflecting the local characteristics of each station. Future projections also indicated a slight to moderate upward trend in maximum temperatures , A more consistent rise in minimum temperatures, especially during the winter months, indicates a trend toward a narrowing of the daily temperature range and an increase in nighttime warming.

The study confirms that adopting hybrid models represents a more suitable methodological framework for representing the complex temporal behavior of climatic elements in semi-arid environments, and provides a scientific basis for supporting climate planning and resource management in Nineveh Governorate.

Keywords: Temperature, climate forecasting, hybrid model (ANN-AR), artificial neural networks, Nineveh Governorate.

بسم الله الرحمن الرحيم

المقدمة :

تعد درجة الحرارة الهواء احد اهم العناصر المناخية المؤثرة في النظم البيئية والموارد المائية والأنشطة الزراعية والتنمية الحضرية , نظر لارتباطها المباشر بتوازن الطاقة على سطح الأرض وبالدورة الهيدرولوجية ومعدلات التبخير -النتح (Robinson et al2021) , وقد شهد العقود الأخير تصاعدا ملحوظا في الاتجاهات الحرارية على المستويين العالمي والإقليمي , الامر الذي أدى الى زيادة تواتر الظواهر المناخية المتطرفة مثل موجات الحر والجفاف والاجهاد البيئي ، ولاسيما في الإقليم شبه الجافة التي تتسم بحساسية مناخية مرتفعة (Coumou,&Rahmstorf 2012) . ويمثل التنبؤ المستقبلي بدرجات الحرارة أداة علمية محورية في إدارة المخاطر المناخية وتخطيط الموارد المائية وتنظيم الأنشطة الزراعية ، وتقدير الطلب على الطاقة ودعم استراتيجيات التكيف مع التغير المناخي (AghaKouchak et al2020) ، في البيئات شبه الجافة ، قد تؤدي الزيادات الطفيفة في المعدلات الحرارية الى تضاعف معدلات التبخير -النتح ، وتسريع استنزاف رطوبة التربة ، وتعميق شدة الجفاف ، مما ينعكس سلبا على الإنتاج والاستقرار البيئي (Scheff et al2014) ومن هنا تبرز الحاجة الى تطوير نماذج تنبؤية دقيقة وقادرة على تمثيل السلوك الزمني المعقد للسلاسل المناخية . وتعد محافظة نينوى من الإقليم ذات مناخ شبه الجاف , حيث تتميز بصيف حار جاف وشتاء بارد نسبيا ، نتيجة موقعها الجغرافي ضمن الصفيحة العربية وتأثرها بأنظمة ضغط جوي متباينة تؤدي الى تباين موسمي واضح في الخصائص الحرارية (أحمد علي الحمداني ٢٠١٦) ، وقد أظهرت البيانات المناخية خلال السنوات الأخيرة وجود نزعة ارتفاع تدريجي في درجات الحرارة ، مصحوبة بزيادة

في عدم اليقين المناخي والضغط على الموارد الطبيعية الامر الذي يتطلب اعتماد اطر نمذجة اكثر تقدما لاستشراف المستقبل الحراري للإقليم . تقليديا استخدمت النماذج الإحصائية الخطية ، مثل نماذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة (ARIMA) في التنبؤ بدرجات الحرارة اعتمادا على قدرتها في تمثيل الاعتماد الزمني الخطي داخل السلسلة الزمنية (Khashei& Bijari2011) . الا ان السلاسل المناخية غالبا ما تتسم بسلوك غير خطي وتذبذبات غير منتظمة وتحويلات هيكلية لا يمكن للنماذج الخطية تمثيلها بصورة كاملة ، وفي المقابل اثبتت الشبكات العصبية الاصطناعية (ANN) كفاءة عالية في النقاط العلاقات غير الخطية والانماط المعقدة داخل البيانات المناخية ، غير ان استخدامها يشكل منفرد قد يواجه مشكلات تتعلق بعد الاستقرار او فرط التكيف او ضعف التفسير التنبوي للنتائج (Zhang 2003) . وفي ضوء ذلك برزت النماذج الهجينة بوصفها اتجاها حديثا يجمع بين قوة البنية الإحصائية للنماذج الخطية ومرنة تقنيات التعلم الالي . يهدف النموذج الهجين AR-ANN الى فصل المكون الخطي عن غير الخطي في سلسلة الزمنية بحيث يتولى نموذج الانحدار الذاتي (AR) تمثيل البنية الزمنية الخطية ، بينما الشبكة العصبية بنمذجة المكونات غير الخطية المتبقية . ويسهم هذا التكامل في تحسين دقة التنبؤ وتقليل عدم اليقين وتعزيز استقرار النتائج مقارنة بالنماذج المنفردة . وعلى الرغم من تعدد الدراسات التي تناولت التنبؤ بدرجات الحرارة في العراق باستخدام نماذج إحصائية او تقنيات تعلم الي ، الا ان معظمها ركز على مؤشرات الدقة التنبؤي قصيرة الأمد دون دمج منهجي بين التحليل الاتجاهات المناخية طويل الأمد ، كما ان تطبيق النموذج الهجين AR-ANN على مستوى محافظة نينوى وبصورة موجهة للتنبؤ المستقبلي بعيد المدى لا يزال محدود في الادبيات المناخية المحلية ، وانطلاقا من

هذه الفجوة المنهجية ، تهدف الدراسة الى بناء اطار تنبؤي هجين يعتمد على نموذج AR-ANN للتنبؤ المستقبلي بدرجات الحرارة في محافظة نينوى من خلال دمج التحليل الزمني الخطي مع النمذجة غير الخطية ، بما يعزز الدقة التنبؤية ويوفر أساسا علمي اكثر موثوقية لدعم التخطيط المناخي واستراتيجيات التكيف في البيئات شبه الجافة .

هدف البحث :

يهدف البحث الى تحليل السلوك الزمني التاريخي لدرجات الحرارة في منطقة الدراسة والكشف عن اتجاهاتها العامة وانماطها الموسمية ، وبناء انحدر ذاتي (AR) لتمثيل البنية الخطية للسلسلة الزمنية ، ثم تصميم الشبكة العصبية الاصطناعية متعددة الطبقات لمعالجة المكونات غير الخطية المتبقية وصولا الى تطوير نموذج هجين يجمع بين الطريقتين لتحسين دقة التنبؤ المستقبلي ، كما يسعى البحث الى تقييم كفاءة النموذج المقترح باستخدام مقاييس الدقة الإحصائية RMSE و MAPE ، وتحليل التباين المكاني في أداء التنبؤ بين المحطات المناخية المختلفة داخل محافظة نينوى. مشكلة البحث :

تكمن مشكلة البحث ان معظم الدراسات المناخية في محافظة نينوى على نماذج خطية تقليدية لا تستطيع تمثيل التعقيد الزمني واللاخطية في السلاسل المناخية بدقة كافية ، ونظر لطبيعة العناصر المناخية المركبة وتداخل مكوناتها الخطية وغير الخطية ، تتبرز مشكلة البحث الحاجة الى نموذج يجمع بين البيانات الخطية وغير خطية من هنا جاءت تساؤلات

١- هل يحقق النموذج الهجين (AR-ANN) دقة تنبؤية اعلى من النماذج

التقليدية ؟

٢- ما مدى التباين المكاني في كفاءة النموذج بين المحطات المناخية المختلفة ؟

٣- هل تعكس التوقعات المستقبلية اتجاهها مناخية تصاعديا ذا دلالة إقليمية ؟
فرضية البحث :

ان دمج نموذج الانحدار الذاتي (AR) مع الشبكات العصبية (ANN) ضمن اطار هجين يؤدي الى تحسين ملحوظ في دقة التنبؤ بدرجات الحرارة في محافظة نينوى مقارنة باستخدام كل نموذج على حدة من هنا إجابة عن تساؤلات الفرضية :

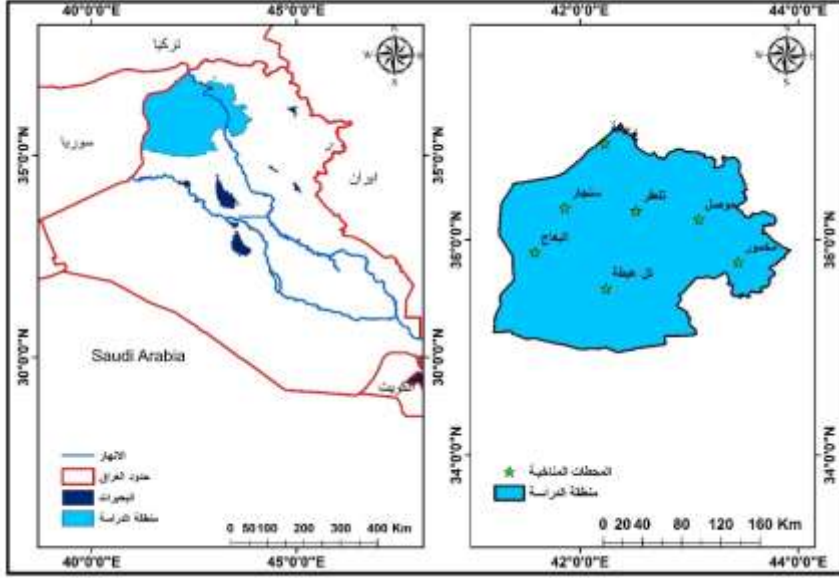
١- توجد فروق ذات دلالة إحصائية في دقة التنبؤ النموذج الهجين (AR-ANN) والنماذج التقليدية ، لصالح النموذج الهجين من حيث انخفاض قيم RMSE و MAPE .

٢- يوجد تباين مكاني في كفاءة النموذج الهجين بين المحطات المناخية المختلفة في محافظة نينوى، يعكس اختلاف الخصائص المناخية المحلية لكل محطة .

٣- تشير التنبؤ المستقبلية الى وجود اتجاه مناخي تصاعدي معنوي ، بما يعكس استجابة إقليمية للتغيرات المناخية .
موقع منطقة الدراسة :

تقع محافظة نينوى بين دائرتي عرض $37^{\circ} 06' 3.5''$ - $34^{\circ} 52' 25''$ شمالا ، وبين خطي طول $43^{\circ} 42' 50''$ - $41^{\circ} 10' 21''$ شرقا ، وتبلغ مساحتها 35.152 كم². يحدها من الشمال محافظة دهوك ومن الشرق محافظتا أربيل وكركوك ، ومن الجنوب محافظتا صلاح الدين والانبار ، من الغرب الجمهورية العربية السورية ، كما موضح في خريطة (١) (محمد موسى، وخالد صطم عطية ٢٠٢٢).

خريطة (١) العراق موضحاً فيها موقع منطقة الدراسة وتوزيع محطات الرصد المناخي المختارة.



المصدر : بالاعتماد على ، وزارة الموارد المائية ، المساحة العامة ، شعبة نظم المعلومات الجغرافية ٢٠٢٠ ، باستخدام برنامج (Arc Map 10.8) .

يوضح جدول (١) موقع المحطات المناخية المختارة في منطقة الدراسة وارتفاعاتها عن مستوى سطح البحر تختلف من محطة الى أخرى تبعا لتباين الخصائص التضاريسية لمنطقة الدراسة .

جدول (١) المحطات المناخية المختارة في منطقة الدراسة

المحطات	رقم المحطة	ارتفاع عن مستوى سطح البحر (م)	دائرة العرض	خط الطول
موصل	608	223	36.19	43.09
سنجار	604	583	36.2	41.50
ربيعة	602	382	36.47	42.06
البعاج	610	321	36.02	41.44
تلعفر	603	373	36.22	42.29
تل عبطة	609	200	35.55	42.34
مخمور	619	270	35.45	43.36

المصدر : جمهورية العراق ، وزارة النقل ، الهيئة العامة للأنواء الجوية والرصد الزلزالي ، قسم المناخ ، بيانات غير منشورة .

منهجية البحث :

اعتمدت الدراسة المنهج الكمي التحليلي السلاسل الزمنية لدرجة الحرارة في محافظة نينوى وبناء نموذج تنبؤي مستقبلي باستخدام الأسلوب الهجين (AR-ANN) . تم في المرحلة الأولى معالجة البيانات المناخية التاريخية وفحصها احصائياً ، ثم بناء نموذج انحدار ذاتي (AR) لتمثيل المكون الخطي للسلسلة الزمنية ، وفي المرحلة الثانية تم تصميم شبكة عصبية اصطناعية متعددة الطبقات (MLP) لمعالجة الأنماط غير الخطية المتبقية ، بعد ذلك تم دمج النموذجين ضمن اطار هجين لتحسين الدقة التنبؤية . وتم تقييم أداء النماذج باستخدام مقاييس RMSE و MAPE ومقارنة نتائج النموذج الهجين بالنموذج التقليدي للتحقق من كفاءته .

أولاً: النموذج الانحداري الذاتي (AR) :

لانشاء نموذج AR-ANN الهجين ، يجب بناء نموذج AR أولاً من خلال مراقبة مخططي (ACF,PACF) لتحديد الرتبة المناسبة للنموذج ، يجب أن يُظهر مخطط الارتباط الذاتي (ACF) نمطاً يتلاشى تدريجياً ، بينما يُظهر مخطط الارتباط الذاتي الجزئي (PACF) نمطاً ينقطع بشكل واضح لتحديد عدد الرتب المهمة في نموذج AR، تم حذف شرط الثبات في هذه المرحلة ، لان نموذج AR يستخدم فقط لتحديد بنية طبقة ادخال ANN (Tatinati & Veluvolu 2013) ، اعتمدت هذه الدراسة على النموذج الانحداري الذاتي من الرتبة الثالثة (AR(3)) ، حيث تم اختيار الرتبة $p = 3$ استناداً إلى نتائج تحليل دالة الارتباط الذاتي الجزئي (PACF) ومعايير المعلومات الإحصائية (AIC و BIC)، والتي أشارت إلى أن النموذج ذي الثلاثة إزاحات زمنية يحقق أفضل تمثيل للبيانات المناخية. تم بناء نموذج AR باستخدام برنامج

MINITAB 18، وEXCEL الذي يوفر أدوات متقدمة لتحليل السلاسل الزمنية وتقدير معاملات النماذج الانحدارية.

ثانيا : الشبكات العصبية الاصطناعية (ANN Approach) :

سميت الشبكات العصبية بهذا الاسم لأنها تتكون من وحدات مترابطة تشبه في عملها خلايا الأعصاب في الدماغ البشري، ذكر أن الشبكات العصبية تعد فرعا من الذكاء الاصطناعي (Artificial Intelligence - AI) ، وهو مجال واسع يضم تخصصات متعددة مثل الفلسفة، وعلم النفس، والرياضيات، والإحصاء، وعلوم الحاسوب. ويهدف هذا المجال إلى محاكاة القدرات الإدراكية للإنسان من خلال إنشاء أنظمة ذكية قادرة على التعلم، التفكير، واتخاذ القرارات بطرق مشابهة للسلوك البشري (هاشم محمد ظاهر ٢٠٢١). وقد ظهر مصطلح الذكاء الاصطناعي في خمسينيات القرن العشرين بعد أن توصل العلماء إلى إمكانية بناء أنظمة وبرامج تحاكي آلية التفكير البشري باستخدام نماذج رياضية وإحصائية دقيقة. ومن أبرز الأهداف التي يسعى إليها الذكاء الاصطناعي تطوير آلات وبرامج قادرة على الاستنتاج والتعلم الذاتي، بحيث تمتلك قدرة تكيفية في التعامل مع المشكلات الجديدة دون الحاجة لتدخل بشري مباشر ، كان (Donald Hebb, 1964) دونالد هيب أول من بحث في إمكانية استخدام الشبكات العصبية الاصطناعية (ANN) في التنبؤ بالطقس ، وقد تلت ذلك العديد من الدراسات التي تناولت استخدام الشبكات العصبية في التنبؤ بالبيانات المناخية عموماً، يتمثل الهدف الرئيسي من استخدام الشبكات العصبية الاصطناعية ليس فقط في إجراء عملية التنبؤ، وإنما أيضاً في تحسين دقة التنبؤ، لا سيما لبيانات المناخية وغيرها من السلاسل الزمنية غير الخطية من خلال معالجة مشكلة اللاخطية في البيانات (Johansson et al 1991) ،


يمكن للشبكة العصبية الاصطناعية أن تحتوي على طبقة واحدة أو عدة طبقات ، أما الشبكة المقترحة في هذه الدراسة فقد صممت بحيث تتمكن من معالجة اللاخطية الموجودة في بيانات المناخية ، مما أدى إلى تحسين دقة التوقع بشكل ملحوظ ، النوع الأساسي من الشبكات العصبية هو الشبكة متعددة الطبقات الإدراكية (Multilayer Perceptron - MLP)، وهي شبكة تغذية أمامية (Feedforward Neural Network) تحتوي على طبقة أو أكثر مخفية (Hidden Layers) بين طبقة الإدخال (Input Layer) وطبقة الإخراج (Output Layer) ، تُستخدم خوارزمية التغذية الأمامية (Feedforward Algorithm) لحساب المخرجات بناءً على المدخلات، أي أن البيانات تمرر في اتجاه واحد من طبقة الإدخال إلى طبقة الإخراج فقط . ويتم تدريب هذا النوع من الشبكات باستخدام خوارزمية الانتشار العكسي ، وتعد الشبكة متعددة الطبقات ذات التغذية الأمامية مع الانتشار العكسي هي النموذج الأساسي والأكثر استخدامًا ضمن تطبيقات الشبكات العصبية الاصطناعية (Hagan & Menhaj 1994) .

ويمكن التعبير عن مُدخل دالة النقل (SUM) في الدالة f كما يلي (Tien Bui et al 2012):

$$SUM = \sum_{i=1}^M \sum_{j=1}^R w_{i,j} Z_j + b$$

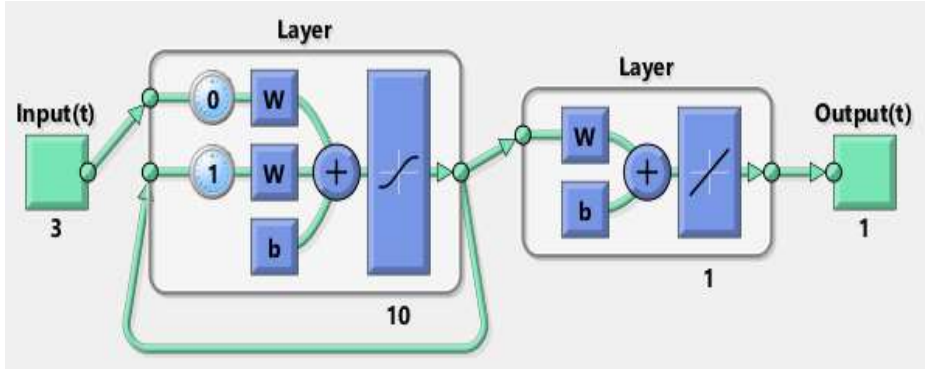
تعد دوال النقل (Transfer Functions) من العناصر الأساسية في تصميم الشبكات العصبية الاصطناعية، إذ تتحكم في طبيعة العلاقة بين متغيرات الإدخال والإخراج داخل الشبكة. ومن أكثر دوال النقل استخدامًا في الطبقات المخفية وطبقات الإخراج هي دالة (tan-sigmoid)، ودالة (log-sigmoid)، والدالة الخطية (linear) ، عمل دالة tan-sigmoid على تحويل المخرجات إلى نطاق يتراوح بين -1 و +1،

وهي مناسبة عندما تكون البيانات المستخدمة في التدريب تحتوي على قيم موجبة وسالبة، إذ تساعد على تحقيق استقرار في عملية التعلم وتوازن في توزيع القيم داخل الشبكة. أما دالة log-sigmoid فتولّد مخرجات تقع بين 0 و1، وتُستخدم عادةً عندما تكون البيانات موجبة فقط أو عندما تكون المسألة ذات طبيعة احتمالية، كحالات التصنيف الثنائي، لأنها تتيح تفسير المخرجات على أنها احتمالات. في المقابل، تُستخدم الدالة الخطية (linear) عندما تكون العلاقة بين المدخلات والمخرجات علاقة مباشرة وغير مقيدة، إذ تنتج قيما خطية ضمن نطاق -1 إلى +1، وتعدّ مناسبة للمسائل التي تتطلب تنبؤات كمية مستمرة مثل التقدير أو التنبؤ الزمني كما موضح في شكل (1) (Yonaba et al2010).



شكل (1) أنواع دالة النقل للشبكات العصبية الاصطناعية (ANN) إن اختيار دالة النقل الملائمة لكل من الطبقة المخفية وطبقة الإخراج يعد خطوة حاسمة في بناء الشبكة العصبية، إذ يؤثر هذا الاختيار بشكل مباشر في كفاءة عملية التدريب ودقة النتائج النهائية، ويعتمد القرار في ذلك على طبيعة البيانات ونوع المشكلة البحثية، سواء كانت خطية أو غير خطية، تصنيفية أو تنبؤية.

يوضح الشكل (٢) بنية شبكة عصبية (ANN) صممت للتنبؤ بالعناصر المناخية، تبدأ الشبكة بمدخلات الزمن الحالي $Input(t)$ المكوّنة من ثلاثة متغيرات مناخية رئيسة ، تُغذى إلى طبقة مخفية تحتوي على عشر خلايا عصبية (Layer) ترتبط بمدخلات الشبكة من خلال أوزان تدريب (W) تحدد أثناء عملية التعلم لتقدير تأثير كل متغير مناخي، ويُضاف إليها انحياز (b) لتحسين دقة الاستجابة.



شكل (٢) الهيكل العام للشبكة العصبية

تمر الإشارات الناتجة بعد الجمع الخطي (+) عبر دالة تفعيل غير خطية \tan لإدخال اللاخطية الضرورية لتمثيل العلاقات المناخية المعقدة، تمتاز البنية بوجود اتصال راجع من مخرجات الطبقة ، المخفية إلى مدخلاتها، ما يمنح النموذج قدرة على الاحتفاظ بالمعلومات الزمنية السابقة واستخدامها مع القيم الحالية ، مما يكسبه ذاكرة زمنية تمكنه من تمثيل الأنماط المناخية المتتابة.

تنتقل مخرجات الطبقة المخفية إلى الطبقة الثانية، وهي طبقة إخراج تتكون من خلية واحدة فقط ذات وزن وانحياز جديدين، لتوليد القيمة المتوقعة ($Output(t)$) التي تمثل

العنصر المناخي المستقبلي ([Caballero & Fernández 2008](#)).

ثالثاً: الطريقة الهجينة (AR – ANN) :

يعد استخدام السلاسل الزمنية الممثلة لمتغيرات نموذج الانحدار الذاتي (AR) أحد الأساليب الإحصائية الحديثة التي أثبتت فاعليتها في بناء هيكل الإدخال (Input Structure) للشبكات العصبية الاصطناعية (ANN) ، دون الحاجة إلى الأخذ في الاعتبار قيم معاملات النموذج أو إشاراتها. ويعرف هذا النهج باسم النموذج الهجين (AR-ANN)، إذ يقوم على استبدال نموذج ARIMA بنموذج AR لتبسيط البنية الرياضية وتقليل التعقيد الحسابي للشبكة، مع المحافظة في الوقت نفسه على دقة التوقع وكفاءة الأداء. وقد أكدت دراسات كل من (Liu وChen and Yu (2014) و (Tatinati and Veluvolu (2013) et al (2012) أن نموذج الانحدار الذاتي يتميز بقدرته على تمثيل العلاقات الزمنية المباشرة بين القيم المتتالية للسلسلة، مما يسهم في تعزيز دقة التوقعات وتقليل الأخطاء الناتجة عن الإفراط في النمذجة، ويجعل من الشبكات العصبية أداة مرنة وفعالة في معالجة البيانات المناخية ذات الطبيعة غير الخطية (Tatinati & Veluvolu 2013) ، تستخدم القيم الزمنية السابقة للسلسلة كمدخلات أساسية في بناء نموذج الشبكة العصبية الاصطناعية، إذ يعتمد النموذج على هذه القيم لتوليد التوقع المستقبلية من خلال العلاقة الرياضية التي تربط بين القيم الماضية والقيمة الحالية للسلسلة الزمنية. وتُسمى المخرجات الناتجة من هذا النموذج بـ النموذج الهجين (AR-ANN) ، الذي يجمع بين القدرة التنبؤية للنموذج الإحصائي والدقة الحسابية للشبكات العصبية. ونظراً لطبيعة غير الخطية للبيانات المناخية في محافظة نينوى، يصبح من الضروري توظيف دالة نقل غير خطية في الطبقة المخفية (Hidden Layer) للشبكة، وذلك لمعالجة الأنماط المعقدة في البيانات وتحسين كفاءة النموذج في التوقع المستقبلي . وفي المقابل، يُفضل استخدام

دالة نقل خطية في طبقة الإخراج (Output Layer) لتحقيق توازن بين مرونة الشبكة في التعلم ودقة النتائج النهائية، بما يضمن بناء نموذج متكامل قادر على تمثيل التغيرات المناخية بدقة عالية وتقديم تقديرات موثوقة لظروف الطقس المستقبلية في المحافظة.

رابعا : مقياس أخطاء التوقعات المستقبلية :

في ضوء أهداف الدراسة التوقع المناخي لمحافظة نينوى، تم اعتماد عدة أساليب ومقاييس إحصائية لقياس دقة النماذج المستخدمة ومقارنة أدائها، سواء من حيث الجانب الإحصائي الكمي أو من حيث التحليل البياني البصري ، وتُعدّ المقاييس الإحصائية من أهم الأدوات التي تساعد في تقييم كفاءة النماذج وتحديد مدى قدرتها على تمثيل الظواهر المناخية بدقة، ومن أكثرها استخدامًا في الدراسات الحديثة متوسط الجذر التربيعي للخطأ (RMSE) ومتوسط الخطأ النسبي المطلق (MAPE) ، حيث استُخدما على نطاق واسع في أغلب الأبحاث الخاصة بالتنبؤ المناخي والبيئي لتقييم أداء النماذج وقياس مدى انحراف التنبؤات عن القيم الفعلية ، قياس مقياس MAPE متوسط النسبة المئوية للخطأ المطلق بين القيم المتوقعة والقيم الحقيقية، ويُحسب رياضياً على النحو الآتي (Kim & Pachepsky2010) :

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{Z_i} \right| \times 100$$

أما مقياس RMSE فيعبّر عن الجذر التربيعي لمتوسط مربعات الأخطاء، ويُعد من أكثر المقاييس دقة في تقدير الانحراف بين القيم المتوقعة والفعلية، ويُكتب على النحو الآتي (Palit& Popovic 2006) :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i)^2}$$

وبعدها نقوم باختيار القيمة اقل خطأ من كل شبكة والتي مجموعها 14 شبكة حسب احتمالات الدوال وفي النهاية يمكننا اختيار افضل شبكة منها وهي التي تحمل اقل قيمة خطأ .

خامسا : التنبؤ المستقبلي لدرجات الحرارة في منطقة الدراسة :

١- معدل درجة الحرارة العظمى :

عند تحليل درجة الحرارة العظمى يتضح أن القيم التاريخية المسجلة لمحطة الموصل، على سبيل المثال، تظهر أن المعدل السنوي لدرجة الحرارة العظمى خلال الفترة التاريخية يقع بحدود 27.1-29.5 °م، حيث تسجل أشهر الصيف ولاسيما حزيران وتموز وآب قيماً تاريخية مرتفعة تتراوح تقريباً بين 40.2-43.6 °م، في حين تنخفض القيم خلال أشهر الشتاء إلى حدود 13.4 - 16 °م، وهو نمط موسمي واضح ومستقر نسبياً عبر السلسلة الزمنية التاريخية، أما عند الانتقال إلى جدول (2) وشكل (3) المتوقع بها فيلاحظ أن المعدلات السنوية المتوقعة تبقى ضمن النطاق نفسه تقريباً ولكن مع ميل تصاعدي طفيف، إذ تتراوح المعدلات السنوية المتوقعة بها بين نحو 28.7 و29.8 °م، أي بزيادة مقدارها تقارب 0.2-0.6 °م مقارنة بمتوسط القيم التاريخية، وهي زيادة عددية محدودة لكنها منتظمة، وعند التحليل الشهري تظهر الفروقات بصورة أوضح في أشهر الصيف، حيث ترتفع القيم المتوقعة بها في شهر تموز من قيم تاريخية بحدود 42-43 °م إلى قيم متوقعة تصل إلى نحو 43.5-44.3 °م في بعض السنوات، أي بزيادة تقارب 0.5 - 1.2 °م، كما تُسجل أشهر حزيران وآب زيادات تتراوح بين 0.3 - 0.9 °م مقارنة بالقيم التاريخية، في المقابل تبقى الزيادات في أشهر الشتاء محدودة، إذ ترتفع القيم من حدود 14.5 - 15.5 °م تاريخياً إلى ما يقارب 15-16 °م في المتوقع بها ، أي بفارق لا يتجاوز 0.3 - 0.6 °م،

وعند المقارنة المكانية بين المحطات يتضح أن محطات مثل مخمور وتل عبطة تسجل أعلى قيم متنبأ بها لدرجات الحرارة العظمى، حيث تتجاوز القيم الصيفية فيها 44° م في بعض السنوات، بينما تبقى القيم في محطات مثل الموصل وربيعة أقل نسبياً وبفروقات عددية أصغر، وعليه فإن المقارنة الرقمية الدقيقة بين البيانات التاريخية و البيانات المتوقع بها تؤكد وجود اتجاه تصاعدي ضعيف إلى متوسط الشدة في درجة الحرارة العظمى، يتمثل بزيادة طفيفة في المعدلات السنوية وزيادة أوضح في القيم الصيفية القصوى، وهو اتجاه لا يمكن اعتباره تذبذباً عشوائياً بل يمثل تحولاً تدريجياً في المستوى الحراري الأعلى للسلسلة الزمنية، مع بقاء الزيادة ضمن حدود أقل حدة مقارنة بدرجة الحرارة الاعتيادية، لكنه ذو دلالة مناخية عند النظر إلى تطور القيم القصوى. يظهر تحليل مقاييس الأداء الإحصائي لبيانات درجة الحرارة العظمى أن النماذج الهجينة من نوع AR-ANN، إذ سجلت قيماً أقل لكل من RMSE و MAPE في مرحلتي التدريب والاختبار، مما يدل على قدرتها الأعلى في تمثيل السلوك غير الخطي لدرجات الحرارة العظمى، فعلى مستوى فصل الشتاء مثلاً انخفضت قيم RMSE للاختبار في محطة الموصل باستخدام نموذج AR-ANN1 إلى نحو 5.39 مع MAPE بحدود 0.24 مقارنة بقيم أعلى 2.30 بكثير في نموذج AR تجاوزت 11.86 و على التوالي، وهو نمط متكرر في محطات سنجار وتلعفر وربيعة، حيث بقيت قيم الخطأ في النماذج الهجينة أقل من نصف مثيلاتها في نموذج AR، أما في فصل الربيع فقد أظهرت محطات مثل تلعفر وربيعة أدنى قيم للخطأ، إذ سجلت محطة تلعفر باستخدام AR-ANN1 قيمة RMSE للاختبار بحدود 5.19 و MAPE تقارب 0.13، في حين تجاوزت قيم الخطأ في نموذج AR 10.64 و 3.17، مما يعكس عدم كفاءة النموذج الخطي في تمثيل التغيرات الانتقالية

لهذا الفصل، وفي فصل الصيف، الذي يتسم باستقرار حراري نسبي في القيم العظمى، انخفضت قيم RMSE للاختبار إلى أقل من 1.0 في بعض الحالات مثل محطة الموصل باستخدام AR-ANN1، وهو ما يشير إلى سهولة نمذجة هذا الفصل مقارنة ببقية الفصول، بينما استمر نموذج AR بتسجيل قيم أعلى نسبياً، أما فصل الخريف فقد سجل أعلى قيم للخطأ في أغلب المحطات، حيث ارتفعت قيم RMSE و MAPE بشكل ملحوظ حتى في النماذج الهجينة، كما في محطة الموصل التي سجلت RMSE للاختبار بحدود 6.48 باستخدام AR-ANN1، ويعزى ذلك إلى الطبيعة الانتقالية وعدم الاستقرار الحراري لهذا الفصل.

جدول (2) نتائج التوقعات المستقبلية لدرجة الحرارة العظمى لمحطات الدراسة للمدة من (2025-2034)

محطات	السنة	كانون الثاني	شباط	آذار	نيسان	أيار	حزيران	تموز	أب	أيلول	تشرين الأول	تشرين الثاني	كانون الأول	المعدل السنوي
الشمس	2025	14.9	15.2	26.6	28.3	31.2	41.9	43.2	43.1	37.2	30.1	23.1	15.6	29.2
	2026	15.0	15.3	24.2	28.3	32.1	40.9	43.6	43.3	38.2	29.6	23.1	15.4	29.1
	2027	15.0	15.2	25.3	26.3	29.9	42.3	44.1	42.8	36.2	30.2	22.3	15.3	28.7
	2028	14.9	15.0	26.0	28.3	30.1	42.1	44.3	43.4	36.8	30.6	23.4	15.4	29.2
	2029	15.0	15.3	25.4	28.6	31.2	41.5	42.7	41.3	36.9	30.1	25.2	15.5	29.1
	2030	15.1	15.2	26.2	29.6	31.4	41.4	43.6	44.0	37.1	30.1	22.3	15.2	29.3
	2031	15.1	15.3	25.5	29.1	32.1	40.9	43.1	42.8	36.8	29.6	22.4	15.2	29.0
	2032	15.0	15.2	26.3	29.9	33.1	40.5	44.9	43.1	35.6	29.6	23.1	15.4	29.3
	2033	15.0	15.2	25.5	29.3	31.2	40.8	43.9	43.8	36.9	29.8	26.3	15.2	29.4
	2034	15.0	15.2	26.6	29.8	32.1	42.1	44.5	43.2	37.1	29.6	24.3	15.2	29.6
معدل الشهري	2034-2025	15.0	15.2	25.8	28.8	31.4	41.4	43.8	43.1	36.9	29.9	23.6	15.4	29.2
الشمس	2025	14.2	15.2	22.3	25.0	29.6	39.4	42.1	42.3	28.2	24.3	22.5	14.2	26.6
	2026	13.8	15.2	22.4	25.3	30.0	40.2	42.3	41.6	28.3	25.4	23.4	14.1	26.8
	2027	15.1	15.5	22.5	24.6	29.2	40.5	43.2	41.3	28.1	25.0	23.1	14.9	26.9
	2028	13.8	13.8	23.0	26.2	29.8	40.1	42.5	41.3	28.6	25.5	22.6	14.2	26.8
	2029	14.2	15.3	22.9	25.6	29.9	40.6	44.2	42.3	28.7	25.4	22.9	14.0	27.2
	2030	15.1	16.3	23.5	26.1	30.2	40.5	42.3	42.3	28.0	25.1	23.3	14.0	27.2
	2031	13.9	13.9	22.5	26.5	30.2	40.2	42.3	41.1	28.8	25.1	22.7	14.0	26.8
	2032	14.0	14.0	23.6	25.9	29.9	40.6	43.1	40.6	29.0	25.7	22.8	14.0	27.0
	2033	14.3	15.1	23.6	25.9	30.1	40.3	42.6	41.8	28.0	24.6	23.3	13.9	27.0
	2034	13.9	15.3	24.1	25.3	31.1	40.6	42.5	41.1	28.7	24.9	22.7	14.2	27.0
معدل الشهري	2034-2025	14.2	15.1	23.0	25.6	30.0	40.3	42.7	41.6	28.4	25.1	22.9	14.2	26.9
الشمس	2025	14.2	14.9	20.3	23.6	30.2	40.4	41.7	39.5	29.1	25.3	22.3	13.2	26.2
	2026	14.3	14.7	21.3	23.6	31.2	40.8	44.4	38.5	30.1	29.6	23.1	14.5	27.2
	2027	14.0	14.8	19.6	24.4	31.4	40.4	42.1	36.8	32.2	28.6	24.1	14.4	26.9
	2028	13.9	14.5	20.1	25.6	31.6	37.6	42.6	42.7	32.1	26.8	22.3	14.4	27.0
	2029	14.3	14.7	19.9	26.3	31.2	42.1	42.3	43.8	30.2	28.6	22.3	14.2	27.5
	2030	13.8	14.7	22.3	26.3	32.1	41.4	42.9	43.3	31.2	28.6	23.1	14.0	27.8
	2031	14.6	14.6	20.3	25.4	31.2	41.2	42.7	42.9	30.2	27.9	23.5	14.3	27.4
	2032	14.4	14.8	20.3	26.6	31.2	41.7	41.9	42.1	31.2	27.6	22.3	13.9	27.3

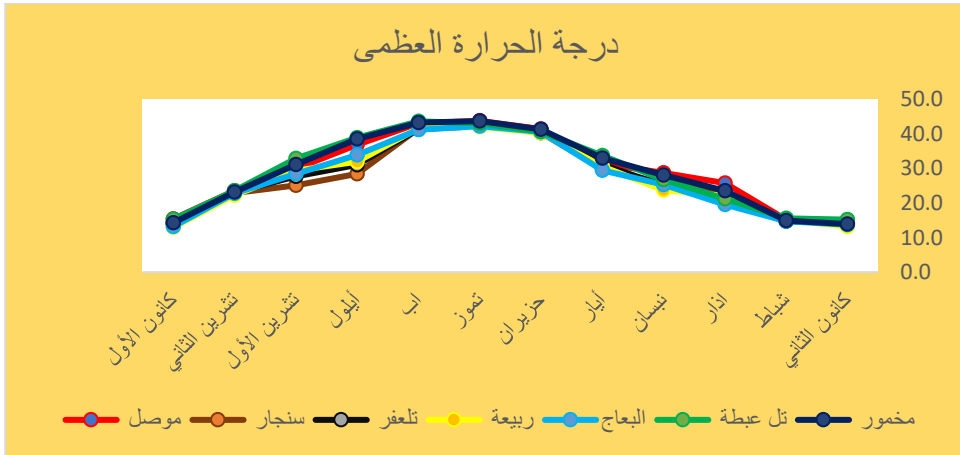
التنبؤ المستقبلي بدرجات الحرارة في محافظة نينوى باستخدام النموذج الهجين (AR-ANN)

27.1	14.0	22.6	25.3	30.3	42.9	41.1	42.9	31.2	25.9	20.3	14.9	13.9	2033	
27.3	14.2	25.1	28.4	33.6	42.0	40.7	41.9	29.9	22.3	19.3	15.2	14.4	2034	
27.2	14.1	23.1	27.7	31.0	41.4	42.2	41.0	31.1	25.0	20.4	14.8	14.2	2034-2025	معدل الشهري
27.2	12.9	21.7	30.2	34.3	42.6	41.2	40.3	29.1	22.9	21.9	15.4	13.4	2025	
26.8	12.9	23.7	30.7	31.3	42.3	43.2	37.0	29.0	22.3	21.8	14.9	13.0	2026	
27.2	13.1	26.9	28.9	32.3	42.0	42.2	37.7	30.2	22.2	22.3	14.9	13.4	2027	
27.2	12.9	23.2	29.8	30.2	42.0	43.2	40.8	31.2	22.1	21.9	15.4	13.4	2028	
27.4	12.9	22.3	30.1	32.5	41.8	40.3	42.0	31.2	25.3	22.3	15.1	12.8	2029	
27.2	13.1	20.1	28.5	33.6	41.8	43.5	39.3	30.9	24.6	21.9	15.3	13.3	2030	البيانات
26.7	12.9	20.1	26.5	30.2	41.6	42.3	40.6	31.2	23.6	22.6	15.1	13.3	2031	
26.7	13.2	21.1	28.9	30.5	40.8	41.2	41.8	29.1	24.3	21.8	14.9	13.0	2032	
27.4	12.7	20.3	30.2	33.5	41.6	41.2	42.2	31.5	24.6	22.4	15.5	13.2	2033	
27.4	13.2	23.1	29.6	31.2	41.0	42.2	40.9	32.1	25.1	22.0	14.9	13.2	2034	
27.1	13.0	22.3	29.3	32.0	41.7	42.1	40.3	30.6	23.7	22.1	15.2	13.2	2034-2025	معدل الشهري
27.1	13.2	26.6	27.8	32.1	42.2	42.2	40.2	28.6	25.2	19.3	14.6	13.0	2025	
26.5	13.2	21.7	28.4	30.2	40.4	41.3	40.0	28.9	25.3	19.6	14.5	13.9	2026	
26.8	13.5	23.1	28.2	32.3	40.1	41.5	41.6	29.5	24.6	19.3	14.5	13.7	2027	
27.3	13.5	22.8	28.4	33.5	42.5	43.2	41.2	28.3	25.3	19.3	15.1	14.0	2028	
26.9	12.9	22.4	28.7	33.6	40.6	42.3	39.5	29.5	26.3	19.5	14.0	13.4	2029	
27.3	13.2	22.4	28.5	33.5	41.6	43.5	41.5	29.8	25.4	19.4	14.8	14.1	2030	البيانات
27.2	13.0	22.0	28.7	34.2	41.9	42.1	39.7	30.1	26.3	20.1	14.7	13.5	2031	
27.1	12.9	22.1	28.7	36.4	40.5	42.1	40.4	29.6	24.3	19.5	14.8	13.6	2032	
27.4	12.8	21.8	28.8	36.7	41.7	42.3	41.8	30.1	24.8	19.6	14.9	13.7	2033	
27.5	13.3	23.2	28.3	36.7	40.6	42.1	40.5	30.2	25.7	19.8	15.2	14.1	2034	
27.1	13.2	22.8	28.4	33.9	41.2	42.3	40.6	29.5	25.3	19.5	14.7	13.7	2034-2025	معدل الشهري
29.5	15.0	22.6	30.2	35.3	44.1	43.2	40.3	37.2	31.4	24.0	15.7	14.7	2025	
29.4	15.3	22.5	32.2	40.9	44.3	43.5	40.2	35.3	25.2	22.6	15.5	15.3	2026	
28.3	15.4	22.5	25.0	33.2	43.6	44.2	40.1	35.1	28.7	21.2	15.3	15.5	2027	البيانات
28.5	15.1	23.3	33.5	36.5	42.3	43.2	40.6	29.3	25.7	22.1	15.5	15.4	2028	
29.5	15.1	23.3	35.9	40.2	43.8	43.2	40.4	31.2	26.6	23.5	15.5	15.3	2029	
28.9	15.3	23.5	32.3	39.6	43.7	41.7	40.4	33.8	25.3	20.1	15.6	15.4	2030	

29.5	15.2	24.6	35.6	40.3	43.8	43.7	41.0	31.5	25.6	21.2	15.8	15.2	2031	
29.2	15.5	23.2	33.2	40.3	43.8	43.2	40.6	35.0	27.6	17.1	15.6	14.9	2032	
29.8	15.8	24.3	34.8	41.3	43.6	42.2	41.1	36.7	26.3	20.6	15.6	15.0	2033	
29.5	15.5	25.3	36.1	41.3	43.6	42.3	41.8	32.1	25.3	20.3	15.4	15.2	2034	
29.2	15.3	23.5	32.9	38.9	43.7	43.0	40.7	33.7	26.8	21.3	15.5	15.2	2034-2025	معدل الشهري
29.6	13.9	23.5	29.8	38.6	43.5	43.5	43.2	40.9	28.1	22.2	13.8	13.7	2025	المعدل
29.2	15.0	25.6	32.5	39.6	43.4	43.2	41.1	31.5	26.7	23.5	15.0	13.9	2026	
28.7	13.8	21.5	29.8	39.6	43.3	43.2	41.2	32.3	29.8	23.8	13.7	12.9	2027	
28.7	14.1	23.4	29.8	38.4	43.5	44.3	41.0	31.3	26.9	22.3	15.3	14.3	2028	
29.2	14.0	24.1	32.5	38.6	43.4	43.2	40.2	32.8	26.9	24.0	15.3	14.7	2029	
28.7	13.7	23.2	32.1	37.9	43.4	43.6	41.2	30.2	25.5	23.6	15.3	14.1	2030	
29.3	14.8	24.3	31.9	38.8	43.3	44.0	41.2	32.1	28.5	23.7	15.3	14.2	2031	
29.2	14.6	22.5	32.4	38.6	43.1	43.5	41.3	33.0	28.8	23.5	15.3	13.7	2032	
29.1	14.7	21.3	31.5	37.5	43.1	44.5	41.3	32.9	29.2	24.5	15.3	13.1	2033	
29.2	14.7	22.6	29.5	37.5	43.0	44.3	41.3	32.7	30.4	24.1	15.5	14.3	2034	
29.1	14.3	23.2	31.2	38.5	43.3	43.7	41.3	33.0	28.1	23.5	15.0	13.9	2034-2025	معدل الشهري

مصدر : اعتماد على بيانات ، جمهورية العراق ، وزارة النقل ، الهيئة العامة للأتواء الجوية والرصد الزلزالي ، قسم المناخ ، بيانات غير منشورة ، يستخدم برنامج ماتلاب ٢٠٢١.

شكل (3) المعدل السنوي درجة الحرارة العظمى^(٥) لمحطة الدراسة المدة 2034-2025



مصدر: من عمل الباحث باعتماد على جدول (2)

٢- معدل درجة الحرارة الصغرى :

يبين من التحليل البيانات درجة الحرارة الصغرى أن السلسلة الزمنية التاريخية (2024 -1994-) تتسم بسلوك موسمي واضح مع معدلات سنوية مستقرة نسبياً، إذ يتراوح المعدل السنوي التاريخي لدرجة الحرارة الصغرى في محطة الموصل حول -15.5 (13) °م مع تذبذبات سنوية محدودة، حيث تسجل أدنى القيم خلال أشهر الشتاء ولاسيما كانون الثاني وكانون الأول بحدود (3-5) °م، بينما ترتفع القيم خلال أشهر الصيف لتصل إلى نحو (24-25.7) °م في تموز وآب، أما بيانات التوقعات المستقبلية للفترة (2025-2034) فنُظهِر انتقالاً تصاعدياً واضحاً في المستوى الحراري العام، إذ يرتفع المعدل السنوي المتوقع به تدريجياً من نحو (14) °م في السنوات الأولى إلى ما يقارب (14.7) °م في نهاية فترة التنبؤ، أي بزيادة سنوية تراكمية تقارب (0.2-0.3) °م مقارنة بالمعدل التاريخي العام، وعند التحليل الشهري يتضح أن أشهر الشتاء تسجل الزيادة النسبية الأعلى، حيث ترتفع درجات الحرارة الصغرى في كانون الثاني من قيم تاريخية تقارب (4 -4.5) °م إلى قيم متوقع بها بحدود (5 -5.3) °م، أي بزيادة مقدارها نحو (0.7) °م، كما تُظهر أشهر تشرين الثاني وكانون الأول زيادات مماثلة تتراوح بين (0.5-0.9) °م، في حين تكون الزيادة أقل نسبياً خلال أشهر الصيف، إذ ترتفع القيم في تموز وآب من نحو (24-24.3) °م تاريخياً إلى قرابة 24.3-25.6 °م في بعض سنوات التوقع ، مما يدل على أن الاحترار الليلي المتوقع سيكون أكثر وضوحاً خلال الفصول الباردة مقارنة بالفصول الحارة، وعند المقارنة السنوية يتبين أن جميع المتوقع بها تقع في الجزء الأعلى من نطاق التوزيع التاريخي وتتجاوزه في عدد من السنوات، وهو ما يؤكد أن الزيادة في درجة الحرارة الصغرى ليست ناتجة عن تذبذب طبيعي قصير الأمد بل تمثل اتجاهاً

تصاعدياً حقيقياً في المستوى الحراري، وبالمقارنة مع نتائج درجة الحرارة والعظمى يتضح أن ارتفاع درجة الحرارة الصغرى يتميز بانتظام أكبر وميل واضح نحو تقليل المدى الحراري اليومي، الأمر الذي يُعد مؤشراً مناخياً مهماً مرتبطاً بظاهرة الاحتراز العالمي وزيادة تأثير الاحتباس الحراري الليلي، وعليه فإن المقارنة المباشرة بين جدولي البيانات التاريخية والمتوقع بها تؤكد أن درجة الحرارة الصغرى في منطقة الدراسة مرشحة لارتفاع تدريجي ومستمر خلال الفترة المستقبلية، مع تباين موسمي واضح وزيادة أكثر بروزاً خلال أشهر الشتاء. كما موضح في جدول (3) وشكل (4).

جدول (3) نتائج التوقعات المستقبلي درجة الحرارة الصغرى لمحطات الدراسة للمدة من (2034-2025)

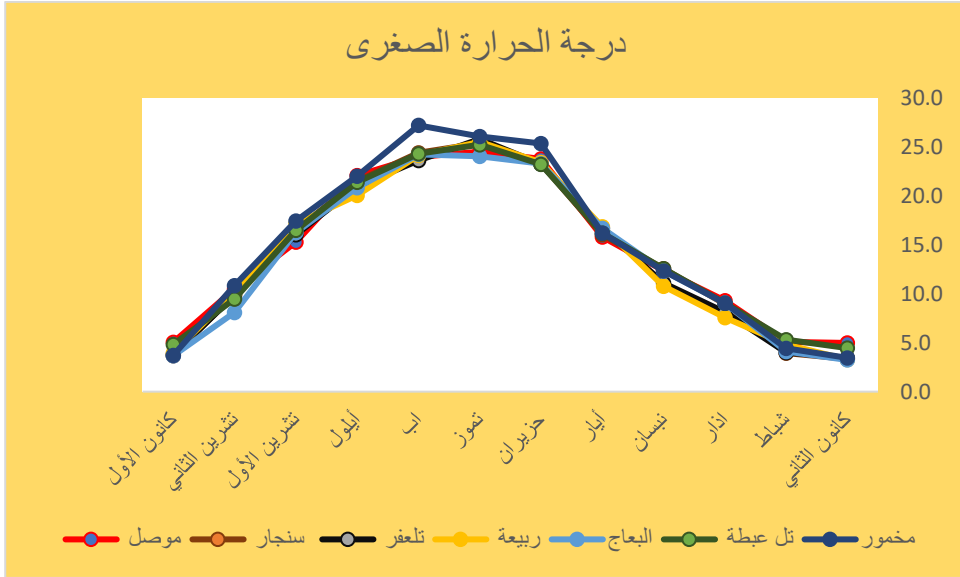
محطات	السنة	كانون الثاني	شباط	آذار	نيسان	أيار	حزيران	تموز	أب	أيلول	تشرين الأول	تشرين الثاني	كانون الأول	المعدل السنوي
3	2025	5.0	5.0	9	12.3	15.6	23.8	24.3	23.7	20.6	14.9	9.6	5.1	14.1
	2026	4.9	5.0	9.3	13.2	16	24.0	24.1	23.6	20.5	14.3	9.5	5.1	14.1
	2027	5.1	5.1	7.9	11.2	15.6	23.9	25.6	23.9	23.9	20.8	15.6	10.2	5.1
	2028	5.1	5.3	8.9	11.9	15.7	23.8	24.3	24.2	21.6	15.2	10.3	4.9	14.3
	2029	5.0	5.1	9.2	12.3	15.8	23.7	24.4	24.1	21.5	15.2	10.3	4.9	14.3
	2030	4.9	5.1	9.6	12.5	15.9	23.4	25.3	24.3	22.3	15.1	10.6	5.2	14.5
	2031	5.1	5.3	9.7	11.9	15.9	23.8	24	23.7	23.4	15.4	11.3	5.1	14.5
	2032	5.0	5.0	8.9	11.6	15.2	23.9	24.3	24.1	23.7	15.2	10.9	5.0	14.4
	2033	4.8	5.0	10.3	13.2	16.4	24	24.5	24	24.3	16.2	11.6	5.1	15.0
	2034	4.9	5.1	10.2	13.6	16.2	23.7	24.4	24.2	22.3	15.8	10.6	5.2	14.7
معدل الشهري	2034-2025	5.0	5.1	9.3	12.4	15.8	23.8	24.5	24.0	22.1	15.3	10.5	5.1	14.4
3	2025	2.9	3.4	8.1	12.2	15.6	22.3	25.3	24.1	21.3	16.5	9.3	4.5	13.8
	2026	2.9	3.6	7.9	12.3	15.8	22.4	25.1	23.8	20.9	16.5	9.8	3.5	13.7
	2027	3.3	4	8.3	12.1	16.3	23.5	25.0	24.2	21.5	17.1	9.9	3.7	14.1
	2028	3.2	4.4	7.9	12.4	15.9	23.2	25.2	24.7	22.3	17.2	10.6	3.3	14.2
	2029	3.2	3.6	8.3	12.7	15.8	23.3	25.0	24.8	21.5	16.5	9.7	3.4	14.0
	2030	3.3	3.8	9.3	12.6	15.6	23.6	25.2	24.5	22.3	16.8	10.2	3.6	14.2
	2031	3.5	4	9.5	12.4	16.1	23.6	25.1	24.8	20.2	16.2	9.6	3.4	14.0
	2032	3.5	3.8	9.4	12.3	16.2	23.6	25.1	24.9	21.3	15.9	9.8	3.7	14.1
	2033	3.7	4.4	10.5	13.2	16.5	24.3	26.6	24.1	22.3	16.2	10.1	3.7	14.6
	2034	4	4.3	10.4	13.5	16.5	23.6	26.3	24.3	21.3	16.1	10.3	4	14.5
معدل الشهري	2034-2025	3.4	3.9	9.0	12.6	16.0	23.3	25.4	24.4	21.5	16.5	9.9	3.7	14.1
3	2025	3.2	4.2	7.5	9.3	15.6	23.4	25.3	22.8	20.6	16.6	8.6	3.6	13.4
	2026	3.9	4.1	7.7	10.3	15.2	23.4	26.3	24.6	20.9	17.1	9.6	3.9	13.9
	2027	3.9	4.1	7.8	10.3	16.5	23.7	25.9	24.3	21.6	17.6	9.9	3.8	14.1
	2028	3.6	4.3	7.9	11.1	16.8	23.3	26.4	24.3	20.9	15.1	8.6	3.9	13.8
	2029	3.3	4.1	8.1	10.4	16.5	23.5	26.5	22.3	21.3	14.9	9.7	3.9	13.7
	2030	3.6	3.8	8.2	12.3	17.8	22.7	24.0	24.3	20.6	16.5	10.1	3.7	14.0
	2031	2.9	3.9	8.6	10.9	16.7	23.1	26.4	22.5	20.3	15.2	10.2	3.9	13.7
	2032	3.3	3.8	8.4	12.4	17.9	23.9	27.1	24.3	21.3	15.3	10.4	3.8	14.3

13.8	3.9	11.0	16.2	20.3	22.6	24.5	23.1	16.4	11.6	8.5	3.9	3.5	2033	معدل الشهري	
14.2	3.8	10.3	15.9	21.6	24.3	25.9	22.5	17.6	12.3	8.7	3.9	3.4	2034		
13.9	3.8	9.8	16.0	20.9	23.6	25.8	23.3	16.7	11.1	8.1	4.0	3.5	2034- 2025		
13.9	3.3	9.6	17.7	19.3	24.1	25.3	23.3	17.0	10.5	7.7	5.4	3.1	2025		
13.8	4.5	10.1	17.6	18.2	24.2	25.5	23.3	16.6	10.7	7.0	4.6	3.2	2026		
14.2	3.7	10.6	19.5	20.1	24.1	26.3	23.9	16.8	10.7	6.9	4.7	3.2	2027		
14.1	4.7	10.2	17.3	19.8	24.5	26.3	23.3	16.5	10.6	7.3	5.2	3.5	2028		
13.9	3.6	11.0	16.5	19.8	24.1	25.3	23.3	16.8	10.7	7.7	4.4	3.1	2029		
13.6	3.2	10.1	15.6	20.2	23.3	25.4	23.6	16.6	10.5	7.2	4.4	3.1	2030		
14.0	3.4	10.4	16.9	20.4	25.2	25.1	23.5	17.1	11.0	7.3	4.1	3.1	2031		
14.3	4.5	9.6	18.1	21.0	24.1	25.3	23.1	17.1	10.9	8.6	5.4	3.5	2032		
14.1	4.1	9.8	15.6	21.3	24.3	25.3	24.1	17.1	11.0	8.3	4.7	3.5	2033		
14.0	4.5	9.9	16.7	20.6	23.6	25.5	22.9	17.1	11.2	7.7	5.3	3.5	2034		
14.0	4.0	10.1	17.2	20.1	24.2	25.5	23.4	16.9	10.8	7.6	4.8	3.3	2034- 2025	معدل الشهري	
14.0	3.5	8.0	17.6	20.9	24.3	24.0	23.1	17.1	13.2	8.3	4.5	3.1	2025	معدل الشهري	
14.1	3.5	7.9	17.6	21.3	24.2	24.1	23.3	15.9	14.0	9.9	3.8	3.2	2026		
13.6	3.7	8.1	14.1	20.3	24.5	24.2	23.1	17.9	12.3	8.6	3.8	3.2	2027		
13.8	3.7	8.0	16.8	21.9	24.5	24.0	23.5	16.3	10.5	9.5	3.6	3.2	2028		
14.0	3.8	8.0	17.1	21.6	24.6	24.6	23.3	16.7	12.5	8.6	3.9	3.2	2029		
13.6	3.8	8.0	15.6	20.3	24.1	24.3	23.0	16.0	11.6	8.7	3.9	3.5	2030		
13.5	3.6	7.9	12.4	19.9	24.3	23.8	23.5	16.9	12.5	9.6	4.5	3.2	2031		
13.8	3.6	8.3	17.2	20.6	24.1	23.7	23.7	16.5	11.3	8.9	4.2	3.1	2032		
14.1	3.7	8.3	17.4	21.3	24.3	24.6	23.3	16.7	13.0	9.1	4.3	3.3	2033		
13.9	3.8	8.5	16.8	20.3	23.7	23.3	23.4	17.1	12.5	9.3	4.5	3.4	2034		
13.8	3.7	8.1	16.3	20.8	24.3	24.1	23.3	16.7	12.3	9.0	4.1	3.2	2034- 2025		معدل الشهري
14.0	5.2	9.3	16.3	20.3	23.7	25.0	23.3	15.7	12.3	7.1	5.4	4.9	2025		معدل السنوي
14.2	5.3	9.1	16.3	21.3	23.9	25.0	22.5	15.3	11.9	9.3	5.2	5.1	2026		
14.2	5.2	8.9	15.9	19.9	23.5	25.1	24.4	16.5	12.6	8.5	5.3	5.1	2027		
14.5	5.2	9.5	16.8	21.3	24.1	25.3	23.1	16.5	12.6	9.5	5.1	4.7	2028		
14.9	5.4	10.3	17.5	23.6	24.0	25.2	23.6	16.5	13.2	9.3	5.2	5.1	2029		
14.8	5.2	9.9	16.5	24.3	24.4	25.3	22.9	16.6	12.5	9.2	5.3	5.1	2030		

14.4	4.9	9.9	17.1	21.3	24.6	25.4	22.8	16.5	12.4	7.9	5.5	4.0	2031	معدل الشهري
14.4	4.2	9.5	16.9	21.3	25.1	25.3	23.0	15.9	12.5	9.9	5.3	3.5	2032	
14.2	3.8	9.4	15.3	20.3	25.0	25.3	23.2	16.0	12.8	9.7	5.6	3.5	2033	
14.3	3.9	8.9	16.4	20.5	25.0	25.5	23.6	16.4	12.9	9.9	5.3	3.4	2034	
14.4	4.8	9.5	16.5	21.4	24.3	25.2	23.2	16.2	12.6	9.0	5.3	4.5	2034- 2025	معدل الشهري
14.3	4.1	10.6	17.3	20.3	27.1	26.1	24.3	15.3	11	7.7	3.9	3.6	2025	معدل السنوي
15.2	3.3	10.9	17.4	21.3	27.2	26.4	24.2	19.3	15.3	10	4.2	3.2	2026	
14.5	3.6	11.2	17.3	21.3	26.5	27.2	24.8	15.3	11.5	8.3	4.3	3.2	2027	
14.7	3.9	11.2	17.3	22.3	26.7	26.1	25.0	15.6	11.8	8	4.5	3.6	2028	
14.7	4.1	10.5	16.9	20.3	27.3	26.7	25.8	16.1	12.3	8.9	4.6	3.3	2029	
14.9	3.9	10.8	17.5	21.3	27.4	25.7	24.9	16.5	12.1	9.7	5.1	3.5	2030	
14.8	3.4	10.6	17.8	23.5	28.1	24.8	25.9	15.3	11.8	8.9	4.2	3.2	2031	
15.0	3.9	10.6	17.6	23.6	27.3	25.6	26.3	15.7	12.2	8.9	4.2	3.8	2032	
15.3	3.3	11.1	17.9	23.5	27.5	26.8	26.8	16.3	12.2	10.2	4.4	3.6	2033	
15.2	3.7	10.9	17.5	22.9	27.0	25.6	25.6	16.8	13.3	10	5.1	3.5	2034	
14.9	3.7	10.8	17.5	22.0	27.2	26.1	25.4	16.2	12.4	9.1	4.4	3.5	2034- 2025	معدل الشهري

مصدر : اعتماد على بيانات ، جمهورية العراق ، وزارة النقل ، الهيئة العامة للأنواء الجوية والرصد
الزلزالي ، قسم المناخ ، بيانات غير منشورة ، يستخدم برنامج ماتلاب ٢٠٢١.

شكل (4) معدل السنوي درجة الحرارة الصغرى^(٥) لمحطة الدراسة للمدة 2034-2025



ان تحليل مقاييس الخطأ الإحصائية لبيانات درجة الحرارة الصغرى أن النماذج الهجينة ، إذ سجلت قيماً أقل لكل من RMSE و MAPE، مما يدل على قدرتها الأعلى في تمثيل السلوك الليلي غير الخطي لدرجات الحرارة الصغرى، ففي فصل الشتاء مثلاً سجلت محطة الموصل باستخدام نموذج AR-ANN2 قيمة RMSE للاختبار بحدود 1.83 مع MAPE تقارب 0.53 مقارنة بقيم أعلى في نموذج AR بلغت 8.78 و 1.44 على التوالي، كما أظهرت محطة تلعفر في الفصل نفسه انخفاضاً ملحوظاً في الخطأ باستخدام AR-ANN2 حيث بلغت قيمة RMSE للاختبار نحو 2.01 و MAPE بحدود 0.45 مقابل قيم أعلى في النموذج التقليدي، وفي فصل الربيع استمر هذا التفوق بصورة أوضح، إذ سجلت محطة تلعفر أقل قيم للخطأ بين جميع المحطات باستخدام AR-ANN2 حيث بلغت قيمة RMSE للاختبار نحو 1.25 و MAPE بحدود 0.33، وهو ما يعكس كفاءة عالية للنموذج في تمثيل التغيرات الانتقالية لدرجات الحرارة الصغرى، بينما سجل نموذج AR قيماً مرتفعة تجاوزت 10 في بعض المحطات مثل الموصل وربيعية، أما في فصل الصيف، والذي يتسم بانتظام أكبر في السلوك الحراري الليلي، فقد انخفضت قيم RMSE للاختبار في معظم المحطات إلى ما دون 2.5 عند استخدام النماذج الهجينة، كما في محطتي الموصل وسنجار وتلعفر، في حين بقيت قيم الخطأ في نموذج AR أعلى نسبياً، وفي فصل الخريف ارتفعت قيم الخطأ في جميع النماذج نتيجة عدم الاستقرار الحراري الليلي، إلا أن النماذج الهجينة حافظت على تفوقها، حيث سجلت محطة سنجان باستخدام AR-ANN1 قيمة RMSE للاختبار بحدود 2.06 و MAPE نحو 0.35 مقارنة بقيم أعلى بكثير في النموذج التقليدي، ومن حيث التباين المكاني يتضح أن محطات تلعفر وسنجار وتل عبطة سجلت أفضل أداء التوقع لدرجة الحرارة الصغرى في أغلب

الفصول، ولاسيما عند استخدام نموذج AR-ANN2، في حين أظهرت محطات مثل ربيعة والموصل قيماً أعلى نسبياً للخطأ في بعض الفصول، وبصورة عامة تؤكد هذه النتائج أن نمذجة درجة الحرارة الصغرى تتطلب نماذج قادرة على التقاط السلوك الليلي غير الخطي والتذبذبات الموسمية الدقيقة، وأن النماذج الهجينة AR-ANN تمثل الخيار الأكثر دقة وموثوقية مقارنة بالنموذج الخطي التقليدي AR، وهو استنتاج منسجم منهجياً ونتائجياً مع ما تم التوصل إليه في تحليل درجة الحرارة الاعتيادية ودرجة الحرارة العظمى، ضمن هذه الدراسة.

الاستنتاجات :

١- أظهرت السلاسل الزمنية التاريخية لدرجات الحرارة في محافظة نينوى وجود نمط موسمي واضح يتمثل بارتفاع القيم خلال فصل الصيف وانخفاضها شتاء مع اتجاه عام نحو الارتفاع التدريجي خلال السنوات الأخيرة مما يعكس تأثير المنطقة بالتحويلات المناخية الإقليمية .

٢- اثبت النموذج الهجين (ANN-AR) كفاءة تنبؤية أعلى مقارنة بالنموذج الخطي التقليدي (AR) إذ سجل قيماً أقل لكل من RMSE و MAPE في مرحلتي التدريب والاختبار، مما يؤكد قدرة النموذج الهجين على تمثيل السلوكين الخطي وغير الخطي للسلسلة الزمنية بدقة أكبر .

٣- تبين من نتائج وجود تباين مكاني في أداء النموذج بين المحطات المناخية المختلفة، حيث سجلت بعض المحطات مثل مخمور وتل عبطة قيماً حرارية أعلى واتجاهاً تصاعدياً أكثر وضوحاً مقارنة بمحطات أخرى، وهو ما يعكس تأثير الخصائص التضاريسية والموقع الجغرافي لمنطقة الدراسة .

٤- أشارت التنبؤات المستقبلية للفترة (2025-2034) الى وجود اتجاه تصاعدي طفيف الى متوسط في درجة الحرارة العظمى ، ويقابله ارتفاع اكثر انتظاما في درجات الحرارة الصغرى ، مما يدل على ميل نحو تقليل المدى الحراري اليومي وزيادة واضحة في الاحترار الليلي .

٥- تبين ان فصلي الشتاء والخريف يسجلان تذبذبا اعلى في الخطأ التنبؤي مقارنة بفصل الصيف ، ويعزى ذلك الى الطبيعة الانتقالية وعدم الاستقرار النسبي للأنظمة الجوية خلال تلك الفترات .

٦- تؤكد النتائج ان دمج البنية الإحصائية للنموذج الانحداري الذاتي مع الشبكات العصبية الاصطناعية يمثل اطارا منهجيا فعالا لتحسين دقة التنبؤات المناخية في البيئات شبه الجافة ، ويوفر أساسا علمية داعما لعمليات التخطيط المناخي وإدارة الموارد .

المصادر :

١. أحمد علي الحمداني ، الخصائص المناخية لشمال العراق وعلاقتها بالأنظمة الضغطية ، مجلة جامعة تكريت للعلوم الإنسانية.2016, 115-138, 23(4) .

٢. محمد موسى ،خالد صطم عطية. ٢٠٢٢ .استخراج المطر الفعّال في محافظة نينوى . مجلة جامعة تكريت للعلوم الإنسانية، المجلد ٢٩، العدد ٥ (أيار)، ص ١١٧-١٥٠.

<https://doi.org/10.25130/jtuh.29.5.2022.07>

٣. هاشم محمد ظاهر حمد ، تحليل السلاسل الزمنية للتنبؤ بكميات الامطار في مدينة الموصل ، رسالة ماجستير (غير منشور) ، جامعة الموصل ، كلية التربية للعلوم الإنسانية ، قسم الجغرافية ، ٢٠٢١، ص ٧١.

4. AghaKouchak,A.,et al. (2020).

Climate extremes and compound hazards in a warming world. *Annual Review of Earth and Planetary Sciences*, 48, 519-548. DOI: <https://doi.org/10.1146/annurev-earth-071719-055228>.

5. Caballero, J., & Fernández, M. (2008). Artificial neural networks from MATLAB® in medicinal chemistry. Bayesian-regularized genetic neural networks (BRGNN): Application to the prediction of the antagonistic activity against human platelet thrombin receptor (PAR-1). *Current topics in medicinal chemistry*, 8(18), 1580-1605.
6. Coumou, D., & Rahmstorf, S. (2012). A decade of weather extremes. *Nature Climate Change*, 2, 491–496.
<https://doi.org/10.1038/nclimate1452>.
7. Hagan, M. T. and Menhaj, M. B. (1994). Training Feedforward Networks with the Marquardt Algorithm. *Neural Networks, IEEE Transactions on*, 5(6), 989-993.
8. Johansson, E. M., Dowla, F. U. and Goodman, D. M. (1991). Backpropagation Learning for Multilayer Feed-Forward Neural Networks Using the Conjugate Gradient Method. *International Journal of Neural Systems*, 02(04), 291-301.
9. Khashei, M., & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2), 2664–2675.
<https://doi.org/10.1016/j.asoc.2010.10.015>
10. Kim, J.-W., & Pachepsky, Y. A. (2010). Reconstructing missing daily precipitation data using regression trees and artificial neural networks for SWAT streamflow simulation. *Journal of hydrology*, 394(3), 305-314.
11. Palit, A. K., & Popovic, D. (2006). *Computational intelligence in time series forecasting: theory and engineering applications*: Springer Science & Business Media.
12. Robinson, A., Lehmann, J., Barriopedro, D., Rahmstorf, S., & Coumou, D. (2021). *Increasing heat and rainfall extremes now far outside the historical climate*. *npj Climate and Atmospheric Science*, 4, 45.
<https://doi.org/10.1038/s41612-021-00202-w>.
13. Scheff, J., & Frierson, D. (2014). Scaling potential evapotranspiration with greenhouse warming. *Journal of Climate*, 27(4), 1539–1558. DOI: <https://doi.org/10.1175/JCLI-D-13-00233.1>
14. Tatinati, S., & Veluvolu, K. C. (2013). A hybrid approach for short-term forecasting of wind speed. *The Scientific World Journal*, 2013, Article ID 548370. <https://doi.org/10.1155/2013/548370>.

15. Tien Bui, D., Pradhan, B., Lofman, O., Revhaug, I. and Dick, O. B. (2012). Landslide Susceptibility Assessment in the Hoa Binh Province of Vietnam: A Comparison of the Levenberg–Marquardt and Bayesian Regularized Neural Networks. *Geomorphology*, 171–172(0), 12–29.
16. Yonaba, H., Anctil, F. and Fortin, V. (2010). Comparing Sigmoid Transfer Functions for Neural Network Multistep Ahead Streamflow Forecasting. *Journal of Hydrologic Engineering*, 15(4), 275–283.
17. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
[https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0).

References

1. Al-Hamdani, A. A. (2016). *The climatic characteristics of northern Iraq and their relationship to pressure systems*. Tikrit University Journal for Humanities, 23(4), 115–138.
2. Mousa, M., & Atiyah, K. S. (2022). *Extraction of effective rainfall in Nineveh Governorate*. Tikrit University Journal for Humanities, 29(5), 117–150. <https://doi.org/10.25130/jtuh.29.5.2022.07>
3. Hamad, H. M. D. (2021). *Time series analysis for forecasting rainfall amounts in Mosul City* (Unpublished Master's Thesis). College of Education for Human Sciences, University of Mosul, Mosul, Iraq, p. 71.
4. AghaKouchak, A., et al. (2020). Climate extremes and compound hazards in a warming world. *Annual Review of Earth and Planetary Sciences*, 48, 519–548. <https://doi.org/10.1146/annurev-earth-071719-055228>
5. Caballero, J., & Fernández, M. (2008). Artificial neural networks from MATLAB® in medicinal chemistry: Bayesian-regularized genetic neural networks (BRGNN): Application to the prediction of the antagonistic activity against human platelet thrombin receptor (PAR-1). *Current Topics in Medicinal Chemistry*, 8(18), 1580–1605.
6. Coumou, D., & Rahmstorf, S. (2012). A decade of weather extremes. *Nature Climate Change*, 2, 491–496. <https://doi.org/10.1038/nclimate1452>
7. Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989–993.

8. Johansson, E. M., Dowla, F. U., & Goodman, D. M. (1991). Backpropagation learning for multilayer feed-forward neural networks using the conjugate gradient method. *International Journal of Neural Systems*, 2(4), 291–301.
9. Khashei, M., & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2), 2664–2675. <https://doi.org/10.1016/j.asoc.2010.10.015>
10. Kim, J.-W., & Pachepsky, Y. A. (2010). Reconstructing missing daily precipitation data using regression trees and artificial neural networks for SWAT streamflow simulation. *Journal of Hydrology*, 394(3–4), 305–314.
11. Palit, A. K., & Popovic, D. (2006). *Computational intelligence in time series forecasting: Theory and engineering applications*. Berlin: Springer Science & Business Media.
12. Robinson, A., Lehmann, J., Barriopedro, D., Rahmstorf, S., & Coumou, D. (2021). Increasing heat and rainfall extremes now far outside the historical climate. *npj Climate and Atmospheric Science*, 4, 45. <https://doi.org/10.1038/s41612-021-00202-w>
13. Scheff, J., & Frierson, D. M. W. (2014). Scaling potential evapotranspiration with greenhouse warming. *Journal of Climate*, 27(4), 1539–1558. <https://doi.org/10.1175/JCLI-D-13-00233.1>
14. Tatinati, S., & Veluvolu, K. C. (2013). A hybrid approach for short-term forecasting of wind speed. *The Scientific World Journal*, 2013, Article ID 548370. <https://doi.org/10.1155/2013/548370>
15. Tien Bui, D., Pradhan, B., Lofman, O., Revhaug, I., & Dick, O. B. (2012). Landslide susceptibility assessment in Hoa Binh Province of Vietnam: A comparison of the Levenberg–Marquardt and Bayesian regularized neural networks. *Geomorphology*, 171–172, 12–29.
16. Yonaba, H., Anctil, F., & Fortin, V. (2010). Comparing sigmoid transfer functions for neural network multistep-ahead streamflow forecasting. *Journal of Hydrologic Engineering*, 15(4), 275–283.
17. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)