



مجلة وعي للعلوم الإنسانية

العدد الثالث / ٢٠٢٦، الصفحة: ٢٦-٥٨



التنبؤ المستقبلي لدرجات الحرارة في محافظة النجف باستخدام الذكاء الاصطناعي

Future Temperature Forecasting in Najaf Governorate

Using Artificial Intelligence Techniq

م.م.تبارك طالب عبد الحسن طليب/الجامعة العراقية/ كلية التربية للبنات /شعبة الدراسات والتخطيط

Tabarak Talib Abdulhassan

tabarak.t.abdulhassan@aliraqia.edu.iq

م.م خالد رائد نافع فتحي/مركز الليزر والفوتونيات، قسم التحسس والفوتونيات النانوية، جامعة الحمدانية، نينوى

Khaled Raed Nafea

Khaled.r.nafea@uhamdaniya.edu.iq

الكلمات المفتاحية الملخص

درجات الحرارة،
الذكاء الاصطناعي،
التنبؤ، محافظة
النجف.
تعد درجات الحرارة من أهم العناصر المناخية المؤثرة في الأنظمة البيئية والأنشطة البشرية، ولا سيما في المناطق الجافة وشبه الجافة التي تتسم بارتفاع معدلاتها الحرارية وتذبذبها الزمني. وتزداد أهمية دراسة الاتجاهات الحرارية في ظل التغيرات المناخية العالمية التي أدت إلى ارتفاع ملحوظ في معدلات درجات الحرارة في العديد من مناطق العالم، بما في ذلك العراق. تهدف هذه الدراسة إلى تحليل الاتجاهات الزمنية لدرجات الحرارة العظمى والصغرى في محافظة النجف وبناء نموذج تنبؤي لتقدير القيم المستقبلية اعتماداً على البيانات المناخية التاريخية للفترة (1980-2024).

اعتمدت الدراسة على تحليل السلاسل الزمنية للبيانات المناخية المسجلة في أربع محطات مناخية هي (النجف، العباسية، المشخاب، الشبكة)، باستخدام مجموعة من أدوات تحليل البيانات وتقنيات الذكاء الاصطناعي. وتم تنفيذ عمليات معالجة البيانات وتحليلها باستخدام لغة البرمجة Python ضمن بيئة Jupyter Notebook بالإضافة إلى برنامج Orange، مع توظيف عدد من المكتبات البرمجية المتخصصة مثل Pandas و NumPy و Scikit-learn فضلاً عن

Matplotlib و Seaborn لإظهار الأنماط المناخية والاتجاهات الزمنية.

وقد تم تقسيم البيانات إلى مجموعتي تدريب واختبار من أجل تقييم أداء النموذج التنبؤي، كما تم استخدام عدد من المؤشرات الإحصائية لقياس دقة التنبؤ، من أبرزها معامل التحديد (R^2)، والجذر التربيعي لمتوسط مربع الخطأ (RMSE)، ومتوسط الخطأ المطلق (MAE). أظهرت النتائج وجود اتجاه تصاعدي عام في درجات الحرارة خلال فترة الدراسة، إذ بلغ معدل التغير السنوي لدرجات الحرارة العظمى ما بين (٠.٠٠٨-٠.٠٠٩) درجة مئوية سنوياً، في حين تراوح معدل التغير السنوي لدرجات الحرارة الصغرى بين (٠.٠٠٥-٠.٠٠٦) درجة مئوية سنوياً.

كما أظهرت نتائج التنبؤ استمرار الاتجاه التصاعدي في درجات الحرارة خلال الفترة المستقبلية (٢٠٢٥-٢٠٣٥)، مع زيادة ملحوظة في معدلات درجات الحرارة العظمى والصغرى، ولا سيما خلال أشهر الصيف. وتشير هذه النتائج إلى احتمال تزايد شدة موجات الحر في منطقة الدراسة خلال السنوات القادمة. وتؤكد الدراسة أهمية توظيف تقنيات الذكاء الاصطناعي في تحليل البيانات المناخية والتنبؤ بالمتغيرات المناخية، لما لها من دور مهم في دعم التخطيط البيئي والزراعي وإدارة الموارد الطبيعية في المناطق الجافة.

KEY WORD

Temperatures,
artificial
intelligence,
forecasting,
Najaf
Governorate.

Abstract

Temperature is one of the most important climatic elements affecting ecosystems and human activities, particularly in arid and semi-arid regions characterized by high and fluctuating temperatures. The study of temperature trends is becoming increasingly important in light of global climate change, which has led to a significant rise in temperatures in many parts of the world, including Iraq. This study aims to analyze the time trends of maximum and minimum temperatures in Najaf Governorate and to build a predictive model to estimate future values based on historical climate data for the period (1980-2024).

The study relied on the analysis of time series data from four meteorological stations (Najaf, Abbasia, Mishkhab, and Shabka), using a range of data analysis tools and artificial intelligence techniques. Data processing and analysis were performed using the Python programming language within the Jupyter Notebook environment, in addition to the Orange software, With the use of several specialized software libraries such as Pandas, NumPy, and Scikit-learn, as well as Matplotlib and Seaborn, to show climate patterns and time trends.

The data were divided into training and test sets to evaluate the predictive model's performance. Several statistical indicators were used to measure prediction accuracy, most notably the coefficient of determination (R^2), root mean square error (RMSE), and mean absolute error (MAE). The results showed a general upward trend in temperatures during the study period, The average annual change in maximum temperatures was between (0.08–0.09) degrees Celsius per year, while the average annual change in minimum temperatures was between (0.05–0.06) degrees Celsius per year. The forecast results also showed a continued upward trend in temperatures during the future period (2025–2035), with a significant increase in average maximum and minimum temperatures, particularly during the summer months. These results indicate a likely increase in the intensity of heat waves in the study area in the coming years. The study confirms The importance of employing artificial intelligence technologies in analyzing climate data and predicting climate changes, due to their important role in supporting environmental and agricultural planning and managing natural resources in arid regions.

تعد درجات الحرارة من أهم العناصر المناخية التي تؤثر في العديد من الظواهر الطبيعية والأنشطة البشرية، إذ ترتبط ارتباطاً مباشراً بالأنظمة البيئية ودورات المياه والإنتاج الزراعي والطاقة والموارد الطبيعية^(١). كما تمثل درجة الحرارة أحد المؤشرات الرئيسية التي يعتمد عليها العلماء في دراسة التغيرات المناخية العالمية وتحليل اتجاهاتها المستقبلية^(٢). وقد شهدت العديد من مناطق العالم خلال العقود الأخيرة ارتفاعاً ملحوظاً في معدلات درجات الحرارة نتيجة التغيرات المناخية العالمية، الأمر الذي أدى إلى زيادة تكرار موجات الحر وارتفاع متوسطات درجات الحرارة السنوية في العديد من المناطق الجافة وشبه الجافة^(٣)، وتعد منطقة الشرق الأوسط من أكثر المناطق تأثراً بظاهرة الاحترار العالمي، إذ تشير العديد من الدراسات المناخية إلى تزايد واضح في معدلات درجات الحرارة خلال العقود الأخيرة، وهو ما انعكس على العديد من الجوانب البيئية والاقتصادية، مثل زيادة معدلات الجفاف وارتفاع الطلب على الموارد المائية والطاقة^(٤) ويعد العراق من الدول التي تتعرض لتأثيرات واضحة للتغيرات المناخية، حيث يتميز مناخه بارتفاع درجات الحرارة صيفاً وانخفاضها شتاءً مع وجود تباين حراري واضح بين الفصول^(٥).

تقع محافظة النجف في الجزء الأوسط من العراق، وتتميز بمناخ صحراوي حار يتسم بارتفاع درجات الحرارة خلال فصل الصيف وانخفاضها خلال فصل الشتاء، فضلاً عن التباين الموسمي الكبير في القيم الحرارية.

وتشكل دراسة السلوك الحراري في هذه المنطقة أهمية علمية كبيرة، لما لها من دور في فهم التغيرات المناخية المحلية والإقليمية وتحديد الاتجاهات المستقبلية لدرجات الحرارة^(٦).

1 Hansen, J., Sato, M., & Ruedy, R. (2010). Global surface temperature change. *Reviews of Geophysics*, 48(4).

2 Trenberth, K. E., Fasullo, J. T., & Shepherd, T. G. (2015). Attribution of climate extreme events. *Nature Climate Change*, 5(8), 725–730. DOI: <https://doi.org/10.1038/nclimate2657>

3 Perkins-Kirkpatrick, S. E., & Lewis, S. C. 2020 Increasing trends in regional heatwaves. *Nature Communications*, 11(1).

4 Lelieveld, J., Proestos, Y., Hadjinicolaou, P., Tanarhte, M., Tyrllis, E., & Zittis, G. (2016). Strongly increasing heat extremes in the Middle East and North Africa (MENA) in the 21st century. *Climatic Change*, 137, 245–260.

5 Al-Ansari, N., Ali, A., & Knutsson, S. (2014). Present conditions and future challenges of water resources problems in Iraq. *Journal of Water Resource and Protection*, 6, 1066–1098.

إن التنبؤ بدرجات الحرارة يمثل أحد الموضوعات المهمة في الدراسات المناخية، إذ يسهم في دعم عمليات التخطيط البيئي والزراعي وإدارة الموارد الطبيعية^(١). وقد اعتمدت الدراسات التقليدية في هذا المجال على مجموعة من الأساليب الإحصائية لتحليل السلاسل الزمنية للبيانات المناخية، إلا أن الطبيعة المعقدة وغير الخطية للبيانات المناخية تجعل من الصعب تمثيلها بدقة باستخدام الأساليب التقليدية فقط. وفي السنوات الأخيرة، شهدت دراسات التنبؤ المناخي تطوراً ملحوظاً نتيجة استخدام تقنيات الذكاء الاصطناعي والتعلم الآلي^(٢)، التي تمتاز بقدرتها العالية على تحليل كميات كبيرة من البيانات واكتشاف الأنماط المعقدة والعلاقات غير الخطية بين المتغيرات المناخية. وقد أثبتت العديد من الدراسات أن نماذج الذكاء الاصطناعي، مثل الشبكات العصبية الاصطناعية ونماذج التعلم الآلي المختلفة، تحقق دقة تنبؤية أعلى مقارنة بالأساليب الإحصائية التقليدية

وانطلاقاً من ذلك، تهدف هذه الدراسة إلى تحليل الاتجاهات الحرارية في محافظة النجف وبناء نموذج تنبؤي لدرجات الحرارة باستخدام تقنيات الذكاء الاصطناعي وتحليل السلاسل الزمنية، من خلال توظيف البيانات المناخية التاريخية للفترة (١٩٨٠-٢٠٢٤)، ومن ثم إنتاج توقعات مستقبلية لدرجات الحرارة حتى عام (٢٠٣٥). كما تسعى الدراسة إلى تقييم دقة النماذج المستخدمة ومقارنتها من أجل تحديد النموذج الأكثر كفاءة في تمثيل السلوك الحراري في منطقة الدراسة.

مشكلة البحث:

ما مدى إمكانية التنبؤ بدرجات الحرارة المستقبلية في محافظة النجف اعتماداً على تحليل السلاسل الزمنية للبيانات المناخية واستخدام تقنيات الذكاء الاصطناعي؟

هل تسهم تقنيات التعلم الآلي في تحسين دقة التنبؤ بدرجات الحرارة مقارنة بالأساليب الإحصائية التقليدية؟

الفرضية البحث:

تفترض الدراسة أن استخدام تقنيات الذكاء الاصطناعي ونماذج التعلم الآلي في تحليل السلاسل الزمنية لدرجات الحرارة يسهم في تحسين دقة التنبؤ بالقيم المستقبلية لدرجات الحرارة في محافظة النجف مقارنة بالأساليب الإحصائية التقليدية.

1 Benali, A., Carvalho, A. C., Nunes, J. P., Carvalhais, N., & Santos, A. (2012)

2 Voyant, C., Notton, G., Kalogirou, S., et al. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105, 569–

582. DOI: <https://doi.org/10.1016/j.renene.2016.12.095>

أهمية البحث:

تكمن أهمية هذه الدراسة في تحليل الاتجاهات الزمنية لدرجات الحرارة في محافظة النجف والتنبؤ بالقيم المستقبلية لها، لما لدرجات الحرارة من تأثير مباشر في الأنظمة البيئية والأنشطة البشرية. كما تسهم الدراسة في توظيف تقنيات الذكاء الاصطناعي وتحليل السلاسل الزمنية لتحسين دقة التنبؤ بالمتغيرات المناخية. وتوفر نتائج البحث مؤشرات علمية يمكن الاستفادة منها في دعم التخطيط البيئي والزراعي وإدارة الموارد الطبيعية في المناطق الجافة. تكمن أهمية هذه الدراسة في تحليل الاتجاهات الزمنية لدرجات الحرارة في محافظة النجف والتنبؤ بالقيم المستقبلية لها، لما لدرجات الحرارة من تأثير مباشر في الأنظمة البيئية والأنشطة البشرية. كما تسهم الدراسة في توظيف تقنيات الذكاء الاصطناعي وتحليل السلاسل الزمنية لتحسين دقة التنبؤ بالمتغيرات المناخية. وتوفر نتائج البحث مؤشرات علمية يمكن الاستفادة منها في دعم التخطيط البيئي والزراعي وإدارة الموارد الطبيعية في المناطق الجافة.

هدف البحث:

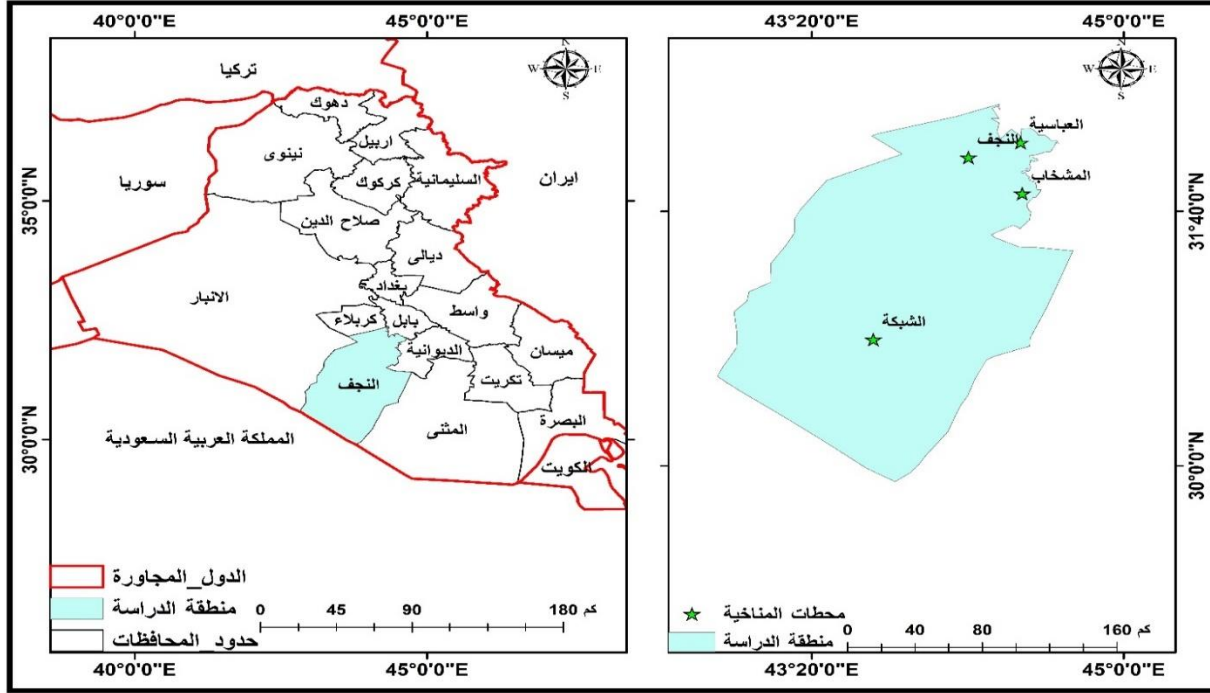
يهدف هذا البحث إلى تطوير إطار نمذجة زمنية للتنبؤ بدرجات الحرارة (العظمى والصغرى) في محافظة النجف اعتماداً على بيانات شهرية للفترة (1980-2024). ويعتمد البحث على تطبيق أربع خوارزميات تعلم آلي هي XGBoost و CatBoost و Random Forest و LSTM، ثم دمج مخرجاتها ضمن نموذج تجميعي من نوع Stacking Ensemble بأوزان (بوصفه النموذج المعتمد لإنتاج التنبؤات النهائية). كما يهدف البحث إلى مقارنة أداء النماذج الفردية بالنموذج التجميعي باستخدام مؤشرات الدقة الإحصائية) مثل R^2 و RMSE و MAE) لتحديد النموذج الأعلى كفاءة في التنبؤ بدرجات الحرارة المستقبلية في منطقة الدراسة.

حدود منطقة الدراسة:

تقع محافظة النجف الأشرف ضمن منطقة الفرات الأوسط في الجزء الجنوبي الغربي من العراق، وتمتد فلكياً بين دائرتي عرض ($15^{\circ}29' - 28^{\circ}32'$ شمالاً) وخطي طول ($33^{\circ}03' - 44^{\circ}49'$ شرقاً)، الأمر الذي يجعلها ضمن نطاق العروض شبه المدارية^(١) ويحدها من الشمال محافظة كربلاء ومن الشمال الشرقي محافظة بابل ومن الشرق محافظة القادسية ومن الجنوب الشرقي محافظة المثنى ومن الشمال الغربي محافظة الأنبار، في حين تحدها المملكة العربية السعودية من الجنوب الغربي^(٢) كما موضح على الخريطة (١):

١ عبد الرزاق محمد الجميلي، جغرافية العراق الطبيعية، دار صفاء للنشر والتوزيع، عمان، ٢٠١٣، ص ٣٣
٢ علي حسين جاسمالخفاجي، الخصائص المناخية لمحافظة النجف الأشرف وأثرها في النشاط الزراعي، رسالة ماجستير، كلية التربية للعلوم الإنسانية، جامعة الكوفة، ٢٠١٧، ص ٦٦

خريطة (١) موقع محافظة النجف



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

الأدوات والوسائل المستخدمة في البحث:-

اعتمدت هذه الدراسة على مجموعة من الأدوات والوسائل العلمية والتقنية لغرض تحليل البيانات المناخية والتنبؤ بدرجات الحرارة في محافظة النجف، ومن أهمها ما يأتي:

١- البيانات المناخية:

تم الاعتماد على بيانات درجات الحرارة (العظمى والصغرى) الشهرية المسجلة في عدد من المحطات المناخية كما موضح في جدول (١)، وذلك للفترة الزمنية (1980-2024).

جدول (١) موقع المحطات

خط العرض	خط الطول	المحطات
30.83	43.66	الشبكة
32.12	44.45	العباسية
31.78	44.46	المشخاب
32.02	44.17	النجف

<https://app.climateengine.org/climateEngine>

٢- البرمجيات الإحصائية وبرامج تحليل البيانات:

تم استخدام لغة البرمجة Python ضمن بيئة Jupyter Notebook لمعالجة البيانات المناخية وتحليلها، بالإضافة إلى استخدام برنامج Orange Data Mining لتطبيق نماذج التعلم الآلي وبناء النماذج التنبؤية.

٣- نماذج التعلم الآلي المستخدمة:

اعتمدت الدراسة على تطبيق أربعة نماذج من نماذج التعلم الآلي وهي: Random Forest و XGBoost و CatBoost و LSTM، وذلك لتحليل السلاسل الزمنية لدرجات الحرارة والتنبؤ بالقيم المستقبلية لها، ثم تم مقارنة أداء هذه النماذج لتحديد النموذج الأكثر دقة في عملية التنبؤ.

٤- المؤشرات الإحصائية لتقييم النماذج:

تم تقييم كفاءة النماذج التنبؤية باستخدام عدد من المؤشرات الإحصائية مثل: معامل التحديد (R^2)، ومتوسط الخطأ المطلق (MAE)، والجذر التربيعي لمتوسط مربع الخطأ (RMSE).

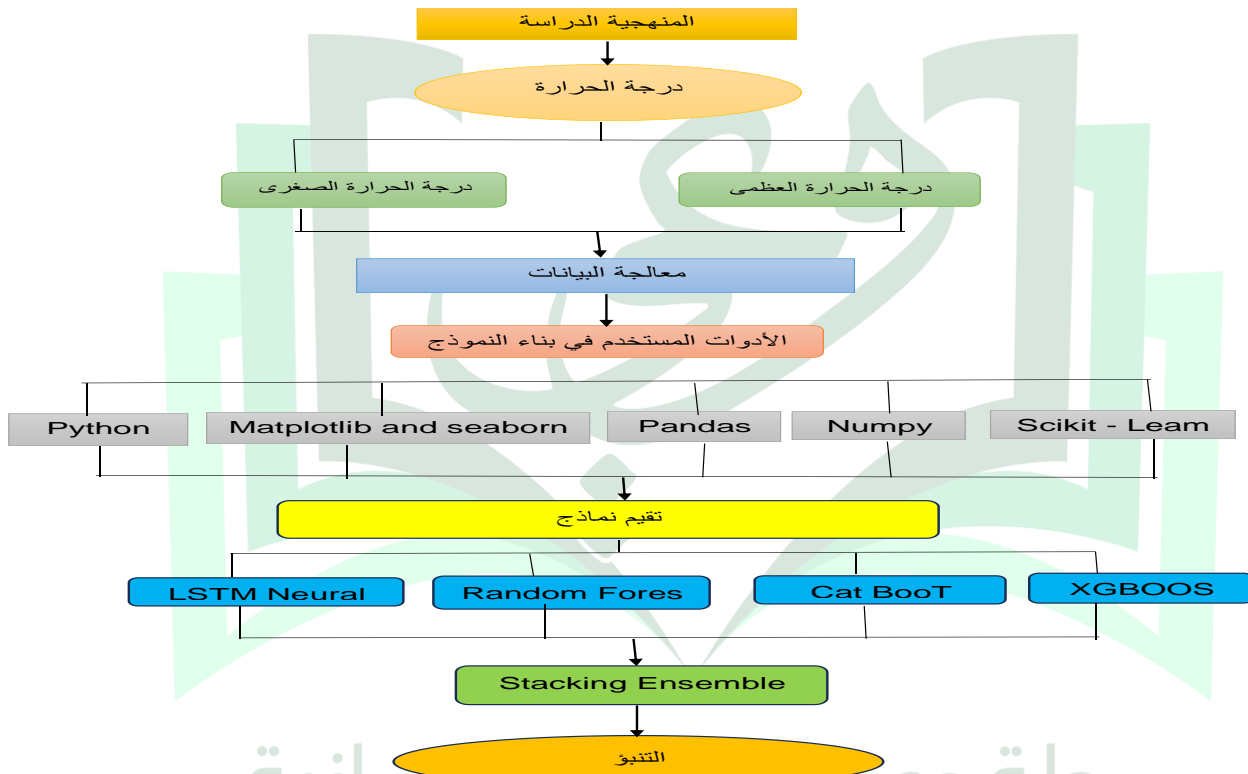
منهجية البحث:-

اعتمدت هذه الدراسة على منهجية تحليل السلاسل الزمنية للبيانات المناخية بهدف التنبؤ بدرجات الحرارة في محافظة النجف. وقد تم استخدام مجموعة من تقنيات التعلم الآلي لتحليل البيانات المناخية وبناء نماذج تنبؤية قادرة على تقدير القيم المستقبلية لدرجات الحرارة اعتماداً على البيانات التاريخية. في البداية تم جمع البيانات المناخية الخاصة بدرجات الحرارة من المحطات المناخية الواقعة في منطقة الدراسة، والتي تضمنت بيانات درجات الحرارة الشهرية للفترة الزمنية (1980-2024). وبعد ذلك تم إجراء مجموعة من عمليات معالجة البيانات وتنظيمها باستخدام لغة البرمجة Python ضمن بيئة Jupyter Notebook، وذلك بهدف إعداد البيانات للاستخدام في بناء النماذج التنبؤية.

اعتمدت الدراسة على تطبيق أربعة نماذج من نماذج التعلم الآلي وهي Random Forest و XGBoost و CatBoost و LSTM، وذلك لغرض تحليل السلاسل الزمنية لدرجات الحرارة واستخلاص الأنماط الزمنية الموجودة في البيانات. وقد تم تدريب هذه النماذج باستخدام بيانات التدريب، في حين تم استخدام جزء من البيانات لاختبار أداء النماذج وتقييم قدرتها على التنبؤ بالقيم المستقبلية.

كما تم اعتماد أسلوب النموذج التجميعي (Stacking Ensemble) لدمج مخرجات النماذج الفردية من أجل تحسين دقة التنبؤ، حيث تم دمج نتائج النماذج الأربعة للحصول على نموذج تنبؤي أكثر كفاءة. ولتقييم أداء النماذج التنبؤية تم استخدام مجموعة من المؤشرات الإحصائية، من أهمها معامل التحديد (R^2)، ومتوسط الخطأ المطلق (MAE)، والجذر التربيعي لمتوسط مربع الخطأ (RMSE). وقد ساعدت هذه المنهجية في تحليل السلوك الزمني لدرجات الحرارة في منطقة الدراسة وتحديد النموذج الأكثر كفاءة في التنبؤ بالقيم المستقبلية لدرجات الحرارة كما موضح شكل (١).

الشكل (١) مخطط منهجية الدراسة



أولاً: تحليل المعدلات الشهرية والسنوية لدرجات الحرارة في محافظة النجف (1980-2024) :

تُظهر البيانات المناخية الخاصة بمعدلات درجات الحرارة العظمى والصغرى في محطات الدراسة (الشبكة، العباسية، المشخاب، والنجف) للفترة (١٩٨٠-٢٠٢٤) كما موضح في جدول (٣،٢)، تبايناً موسمياً واضحاً في القيم الحرارية على مدار أشهر السنة. إذ تسجل درجات الحرارة العظمى أدنى قيمها خلال أشهر الشتاء، ولاسيما في شهر كانون الثاني حيث تتراوح بين (١٦.٤-١٧.٢) درجة مئوية في محطات الدراسة، ثم تبدأ بالارتفاع التدريجي مع تقدم فصل الربيع لتصل إلى أعلى قيمها

خلال أشهر الصيف، وبخاصة في شهري تموز وآب، حيث تتجاوز (44°C) في معظم المحطات، وهو ما يعكس التأثير الواضح للمناخ الصحراوي الحار السائد في منطقة الدراسة.

أما فيما يتعلق بدرجات الحرارة الصغرى، فتظهر البيانات أيضاً انخفاضاً ملحوظاً خلال أشهر الشتاء، حيث تسجل أدنى قيمها في شهر كانون الثاني، إذ تتراوح بين ($4.6-5.3$) درجة مئوية في محطات الدراسة. ثم ترتفع هذه القيم تدريجياً خلال فصلي الربيع والصيف لتبلغ أعلى مستوياتها في شهري تموز وآب، حيث تتراوح بين ($26.4-28.2$) درجة مئوية.

كما تشير المعدلات السنوية لدرجات الحرارة العظمى إلى أن محطة العباسية ومحطة النجف سجلتا أعلى معدل سنوي بلغ نحو (32.0°C)، في حين سجلت محطة الشبكة أدنى معدل سنوي بلغ (30.9°C). أما بالنسبة لدرجات الحرارة الصغرى، فقد سجلت محطة العباسية ومحطة النجف أعلى معدل سنوي بلغ (17.1°C)، في حين سجلت محطة الشبكة أدنى معدل سنوي بلغ (15.9°C). ويعكس هذا التباين المكاني البسيط تأثير الخصائص الجغرافية المحلية في توزيع القيم الحرارية ضمن منطقة الدراسة.

جدول (٢) معدل درجة الحرارة العظمى للمدة من (١٩٨٠-٢٠٢٤)

المحطات	كانون الثاني	شباط	آذار	نيسان	أيار	حزيران	تموز	آب	أيلول	تشرين الأول	تشرين الثاني	كانون الأول	المعدل السنوي
الشبكة	16.4	19.4	24.1	29.9	36.8	41.8	44.2	44.1	40.1	32.7	23.5	18.3	30.9
العباسية	16.8	20.4	25.4	31.6	38.4	43.1	45.0	45.1	41.2	34.0	24.3	18.9	32.0
المشخاب	17.2	20.2	24.8	30.8	38.1	42.4	43.5	43.6	38.5	33.3	24.4	19.0	31.3
النجف	16.8	20.4	25.4	31.6	38.4	43.1	45.0	45.1	41.2	34.0	24.3	18.9	32.0

المصدر: <https://app.climateengine.org/climateEngine>.

جدول (٣) معدل درجة الحرارة الصغرى (١٩٨٠-٢٠٢٤)

المعدل السنوي	كانون الأول	تشرين الثاني	تشرين الأول	أيلول	اب	تموز	حزيران	أيار	نيسان	آذار	شباط	كانون الثاني	المحطات
15.9	5.6	10.3	17.4	22.5	26.4	27.2	24.9	21.1	14.8	9.8	6.4	4.6	الشبكة
17.1	6.6	10.9	18.4	23.6	27.3	28.2	26.4	22.8	16.5	11.3	7.7	5.3	العباسية
16.1	6.6	10.8	17.0	20.6	25.5	26.4	25.5	22.6	15.6	10.6	7.3	5.3	المشخاب
17.1	6.6	10.9	18.4	23.6	27.3	28.2	26.4	22.8	16.5	11.3	7.7	5.3	التجف

المصدر: <https://app.climateengine.org/climateEngine>

ثانياً: نموذج Stacking Ensemble

يعد نموذج Stacking Ensemble أحد الأساليب المتقدمة في التعلم الآلي التي تعتمد على دمج مخرجات عدة نماذج تنبؤية من أجل تحسين دقة التنبؤ. ويقوم هذا الأسلوب على فكرة استخدام مجموعة من النماذج الأساسية (Base Models) التي يتم تدريبها على البيانات نفسها، ثم يتم دمج مخرجاتها باستخدام نموذج آخر يُعرف بالنموذج الفوقي (Meta Model)، والذي يعمل على تعلم أفضل طريقة لدمج تنبؤات النماذج المختلفة للحصول على تنبؤ نهائي أكثر دقة^(١). في هذه الدراسة تم تطبيق أربعة نماذج من نماذج التعلم الآلي وهي Random Forest و XGBoost و CatBoost و LSTM، حيث تم تدريب كل نموذج بشكل منفصل على بيانات درجات الحرارة. وبعد ذلك تم استخدام أسلوب Stacking Ensemble لدمج نتائج هذه النماذج من خلال إنشاء نموذج تجميعي يقوم بتحليل مخرجات النماذج الفردية وتحديد الوزن المناسب لكل نموذج، بهدف الحصول على تنبؤ نهائي أكثر كفاءة ودقة.

وقد ساعد استخدام هذا الأسلوب في تقليل أخطاء التنبؤ وتحسين أداء النموذج النهائي، إذ إن دمج عدة نماذج تنبؤية يسمح بالاستفادة من نقاط القوة لكل نموذج، مما يؤدي إلى تحقيق نتائج أكثر موثوقية في التنبؤ بدرجات الحرارة المستقبلية في منطقة الدراسة.

1 - Wolpert, D. H. (1992). *Stacked generalization*. Neural Networks 5(2), 241-259.
[https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1)

ثالثاً: مؤشرات تقييم أداء النماذج (Model Evaluation Metrics) :

من أجل تقييم كفاءة نماذج التعلم الآلي المستخدمة في التنبؤ بدرجات الحرارة، تم الاعتماد على مجموعة من المؤشرات الإحصائية الشائعة في تقييم النماذج التنبؤية. وتساعد هذه المؤشرات في قياس مدى دقة النماذج في تمثيل البيانات الفعلية وتقليل أخطاء التنبؤ. ومن أهم هذه المؤشرات ما يأتي:

١- معامل التحديد (R^2) :

يعد معامل التحديد من أهم المؤشرات المستخدمة في تقييم أداء النماذج التنبؤية، إذ يقيس مدى قدرة النموذج على تفسير التباين في البيانات الفعلية. وتتراوح قيمته بين (٠ - ١)، وكلما اقتربت القيمة من الواحد الصحيح دلّ ذلك على قدرة أعلى للنموذج في تمثيل البيانات بدقة (Kim et al 2010).

$$R = \frac{\sum_{i=1}^n (y_i^{obs} - y_{obs}^{mean}) (y_i^{sim} - y_{sim}^{mean})}{\sqrt{\sum_{i=1}^n (y_i^{obs} - y_{obs}^{mean})^2 (y_i^{sim} - y_{sim}^{mean})^2}} \quad (1)$$

٢- متوسط الخطأ المطلق (MAE) :

يقيس هذا المؤشر متوسط الفروق المطلقة بين القيم المتنبأ بها والقيم الفعلية. ويعد من المؤشرات المهمة في تقييم دقة التنبؤ، حيث تشير القيم الأقل إلى أداء أفضل للنموذج (Latif et al 2023).

$$MAE = \frac{\sum_{i=1}^n |y_i^{sim} - y_i^{obs}|}{n} \quad (2)$$

٣- جذر التربيعي لمتوسط مربع الخطأ (RMSE) :

يستخدم هذا المؤشر لقياس حجم الخطأ في التنبؤ، ويعطي وزناً أكبر للأخطاء الكبيرة مقارنة بالمؤشرات الأخرى. وكلما انخفضت قيمة RMSE دلّ ذلك على تحسن دقة النموذج التنبؤي.

1 Latif, M.S., Ahmed, R.A., 2023a. A review of deep learning and machine learning techniques for hydrological inflow forecasting. Environment, Development and Sustainability, 25(11), 12189-12216. <https://doi.org/10.1007/s10668-023-03131-1>

2Latif, M.S., Ahmed, R.A., 2023a. A review of deep learning and machine learning techniques for hydrological inflow forecasting. Environment, Development and Sustainability, 25(11), 12189-12216. <https://doi.org/10.1007/s10668-023-03131-1>

$$RMSE = \sqrt{\frac{1}{n} + \sum_{i=1}^n (e_i)^2} \quad (3)$$

تشير نتائج مقاييس الأداء الإحصائي إلى وجود تباين في دقة النماذج التنبؤية بين محطات الدراسة كما في جدول (٤). فقد سجلت محطة النجف أعلى قيمة لمعامل التحديد (R^2) لكل من درجات الحرارة العظمى (٠.٨٢) والصغرى (٠.٩١)، مما يدل على قدرة النموذج على تفسير نسبة كبيرة من التباين في البيانات الفعلية. في المقابل سجلت محطة الشبكة أقل قيمة لمعامل التحديد لدرجات الحرارة العظمى (٠.٥٣)، بينما سجلت محطة المشخاب أدنى قيمة لدرجات الحرارة الصغرى (٠.٥٧). كما تراوحت قيم RMSE بين (٠.٥-٠.٨) وقيم MAE بين (٠.٤-٠.٨)، وهي قيم تشير إلى مستوى مقبول من الدقة في التنبؤ بدرجات الحرارة في محطات الدراسة.

جدول (٤) مؤشرات تقييم أداء النماذج

المحطات	درجة الحرارة العظمى R2_	درجة الحرارة العظمى RMSE_	درجة الحرارة العظمى MAE_	درجة الحرارة الصغرى R2_	درجة الحرارة الصغرى RMSE_	درجة الحرارة الصغرى MAE_
الشبكة	0.53	0.7	0.5	0.710	0.7	0.5
العباسية	0.64	0.7	0.7	0.610	0.8	0.4
المشخاب	0.59	0.8	0.4	0.570	0.5	0.6
النجف	0.82	0.7	0.8	0.910	0.7	0.4

المصدر: استنادا إلى مخرجات نموذج Stacking Ensemble.

رابعاً: نتائج التنبؤ بدرجات الحرارة للفترة (2025-2035):

تشير نتائج النماذج التنبؤية إلى وجود اتجاه تصاعدي في معدلات درجات الحرارة في محطات الدراسة خلال الفترة (٢٠٢٥-٢٠٣٥) في جدول (٥). فقد تراوحت المعدلات السنوية المتنبأ بها لدرجات الحرارة العظمى بين نحو (٣١.٣-٣٢.٦م) في محطة الشبكة، وبين (٣٢.٥-٣٣.٨م) في محطتي العباسية والنجف، في حين سجلت محطة المشخاب معدلات تراوحت بين (٣١.٧-٣٣.٠م). وتظهر القيم الشهرية أن أعلى درجات الحرارة المتوقعة ستحدث خلال أشهر الصيف، ولا سيما في شهري تموز وآب حيث تتجاوز (٤٦م) في معظم المحطات.

جدول (٥) درجة الحرارة العظمى منتبأ بها المدة (٢٠٢٥-٢٠٣٥) المحطات الدراسة

المحطات	السنة	كانون الثاني	شباط	آذار	نيسان	أيار	حزيران	تموز	أب	أيلول	تشرين الأول	تشرين الثاني	كانون الأول	المعدل السنوي
الشبكة	20	1	2	2	3	3	42	4	4	4	23	34	1	32
	25	8.3	0.6	6.4	3.0	7.7	.7	7.4	6.4	0.4	.4	.6	8.7	.5
الشبكة	20	1	1	2	3	3	43	4	4	4	24	33	1	31
	26	8.0	8.3	3.3	0.3	6.7	.4	4.1	3.6	3.0	.4	.4	7.4	.3
الشبكة	20	1	2	2	3	3	42	4	4	4	25	32	1	31
	27	7.0	1.0	4.1	1.6	7.3	.7	4.6	7.9	1.1	.4	.4	7.7	.9
الشبكة	20	1	1	2	3	3	43	4	4	3	23	32	2	31
	28	8.0	8.3	3.9	1.4	9.1	.3	5.3	5.1	9.2	.9	.9	0.8	.8
الشبكة	20	1	1	2	3	3	43	4	4	4	24	33	2	32
	29	8.2	8.6	6.2	0.7	7.3	.9	6.8	6.8	0.1	.4	.4	0.7	.3
الشبكة	20	1	2	2	2	3	45	4	4	4	24	33	2	32
	30	7.2	0.8	4.3	9.6	9.3	.0	5.4	6.9	1.7	.0	.0	1.5	.5
الشبكة	20	1	2	2	3	3	42	4	4	4	26	34	1	32
	31	7.8	3.1	2.4	2.3	8.4	.8	5.7	3.0	1.0	.4	.4	8.8	.2
الشبكة	20	1	2	2	3	3	43	4	4	4	24	33	1	32
	32	6.9	0.4	7.1	1.7	7.6	.9	5.7	7.0	0.4	.5	.5	7.6	.1
الشبكة	20	1	2	2	3	3	42	4	4	4	27	34	1	32
	33	8.4	1.5	5.9	1.0	6.5	.7	5.2	4.7	1.1	.5	.5	9.8	.4
الشبكة	20	1	2	2	3	3	46	4	4	4	26	32	2	32
	34	8.3	1.1	3.4	1.3	8.5	.6	5.4	6.2	1.4	.5	.5	0.6	.6
الشبكة	20	1	2	2	2	3	46	4	4	4	22	33	1	32
	35	9.1	0.0	7.8	9.6	9.2	.3	4.4	5.1	1.6	.4	.4	9.8	.4

33	1	24	35	4	4	4	44	3	3	2	2	1	20	العباسية
.6	9.3	.4	.8	1.6	7.4	8.3	.0	9.3	4.8	7.8	1.7	8.7	25	
32	1	25	34	4	4	4	44	3	3	2	1	1	20	العباسية
.5	8.1	.1	.8	4.2	4.5	5.0	.8	8.3	2.0	4.7	9.4	8.5	26	
33	1	26	33	4	4	4	44	3	3	2	2	1	20	العباسية
.0	8.4	.2	.8	2.3	8.9	5.4	.0	8.9	3.3	5.5	2.1	7.4	27	
32	2	24	34	4	4	4	44	4	3	2	1	1	20	العباسية
.9	1.5	.5	.3	0.4	6.1	6.1	.7	0.8	3.1	5.3	9.4	8.5	28	
33	2	25	34	4	4	4	45	3	3	2	1	1	20	العباسية
.4	1.4	.6	.9	1.3	7.8	7.7	.3	8.9	2.4	7.6	9.7	8.7	29	
33	2	25	34	4	4	4	46	4	3	2	2	1	20	العباسية
.6	2.2	.7	.5	2.9	7.9	6.3	.3	0.9	1.4	5.7	1.9	7.7	30	
33	1	27	35	4	4	4	44	4	3	2	2	1	20	العباسية
.3	9.5	.2	.8	2.2	4.0	6.5	.2	0.0	4.1	3.7	4.2	8.3	31	
33	1	24	35	4	4	4	45	3	3	2	2	1	20	العباسية
.3	8.3	.8	.0	1.6	8.0	6.6	.3	9.3	3.5	8.5	1.5	7.3	32	
33	2	27	36	4	4	4	44	3	3	2	2	1	20	العباسية
.5	0.5	.8	.0	2.4	5.7	6.1	.1	8.1	2.8	7.3	2.6	8.8	33	
33	2	26	33	4	4	4	48	4	3	2	2	1	20	العباسية
.8	1.3	.9	.9	2.6	7.2	6.3	.0	0.1	3.1	4.8	2.2	8.8	34	
33	2	23	34	4	4	4	47	4	3	2	2	1	20	العباسية
.6	0.5	.4	.9	2.8	6.1	5.3	.7	0.9	1.3	9.3	1.1	9.6	35	
32	1	24	35	3	4	4	43	3	3	2	2	1	20	المشخب
.8	9.3	.4	.0	8.9	5.9	6.7	.3	9.0	3.9	7.1	1.5	9.0	25	

31	1	25	34	4	4	4	44	3	3	2	1	1	20	المشخب
.7	8.1	.2	.0	1.5	3.0	3.4	.1	8.0	1.2	4.0	9.2	8.7	26	
32	1	26	33	3	4	4	43	3	3	2	2	1	20	المشخب
.3	8.4	.2	.0	9.6	7.4	3.9	.3	8.6	2.5	4.8	1.9	7.7	27	
32	2	24	33	3	4	4	44	4	3	2	1	1	20	المشخب
.1	1.5	.6	.5	7.6	4.6	4.6	.0	0.4	2.3	4.6	9.2	8.8	28	
32	2	25	34	3	4	4	44	3	3	2	1	1	20	المشخب
.7	1.4	.7	.1	8.5	6.3	6.1	.6	8.6	1.6	6.9	9.5	9.0	29	
32	2	25	33	4	4	4	45	4	3	2	2	1	20	المشخب
.9	2.2	.8	.6	0.2	6.4	4.7	.7	0.6	0.5	5.0	1.6	7.9	30	
32	1	27	35	3	4	4	43	3	3	2	2	1	20	المشخب
.6	9.5	.3	.0	9.5	2.5	5.0	.5	9.7	3.3	3.0	4.0	8.6	31	
32	1	24	34	3	4	4	44	3	3	2	2	1	20	المشخب
.5	8.3	.8	.2	8.9	6.5	5.0	.6	8.9	2.6	7.8	1.3	7.6	32	
32	2	27	35	3	4	4	43	3	3	2	2	1	20	المشخب
.7	0.5	.9	.2	9.6	4.1	4.5	.4	7.8	1.9	6.6	2.4	9.1	33	
33	2	27	33	3	4	4	47	3	3	2	2	1	20	المشخب
.0	1.3	.0	.1	9.8	5.6	4.7	.3	9.8	2.3	4.1	2.0	9.1	34	
32	2	23	34	4	4	4	47	4	3	2	2	1	20	المشخب
.8	0.4	.4	.0	0.1	4.5	3.7	.0	0.5	0.5	8.6	0.9	9.8	35	
33	1	24	35	4	4	4	44	3	3	2	2	1	20	التجف
.6	9.3	.4	.8	1.6	7.4	8.3	.0	9.3	4.8	7.8	1.7	8.7	25	
32	1	25	34	4	4	4	44	3	3	2	1	1	20	التجف
.5	8.1	.1	.8	4.2	4.5	5.0	.8	8.3	2.0	4.7	9.4	8.5	26	

33	1	26	33	4	4	4	44	3	3	2	2	1	20	التنجف
.0	8.4	.2	.8	2.3	8.9	5.4	.0	8.9	3.3	5.5	2.1	7.4	27	
32	2	24	34	4	4	4	44	4	3	2	1	1	20	التنجف
.9	1.5	.5	.3	0.4	6.1	6.1	.7	0.8	3.1	5.3	9.4	8.5	28	
33	2	25	34	4	4	4	45	3	3	2	1	1	20	التنجف
.4	1.4	.6	.9	1.3	7.8	7.7	.3	8.9	2.4	7.6	9.7	8.7	29	
33	2	25	34	4	4	4	46	4	3	2	2	1	20	التنجف
.6	2.2	.7	.5	2.9	7.9	6.3	.3	0.9	1.4	5.7	1.9	7.7	30	
33	1	27	35	4	4	4	44	4	3	2	2	1	20	التنجف
.3	9.5	.2	.8	2.2	4.0	6.5	.2	0.0	4.1	3.7	4.2	8.3	31	
33	1	24	35	4	4	4	45	3	3	2	2	1	20	التنجف
.3	8.3	.8	.0	1.6	8.0	6.6	.3	9.3	3.5	8.5	1.5	7.3	32	
33	2	27	36	4	4	4	44	3	3	2	2	1	20	التنجف
.5	0.5	.8	.0	2.4	5.7	6.1	.1	8.1	2.8	7.3	2.6	8.8	33	
33	2	26	33	4	4	4	48	4	3	2	2	1	20	التنجف
.8	1.3	.9	.9	2.6	7.2	6.3	.0	0.1	3.1	4.8	2.2	8.8	34	
33	2	23	34	4	4	4	47	4	3	2	2	1	20	التنجف
.6	0.5	.4	.9	2.8	6.1	5.3	.7	0.9	1.3	9.3	1.1	9.6	35	

المصدر: اعتماد على نموذج Stacking Ensemble.

أما بالنسبة لدرجات الحرارة الصغرى، فقد تراوحت المعدلات السنوية متنبأ بها بين (١٦.٣-١٧.٥م) في محطة الشبكة، وبين (١٧.٦-١٨.٨م) في محطتي العباسية والتنجف، بينما سجلت محطة المشخاب قيماً تراوحت بين (١٦.٧-١٧.٩م). وتشير النتائج في جدول (٦) إلى أن أدنى القيم المتوقعة ستسجل خلال أشهر الشتاء، ولا سيما في شهري كانون الثاني وكانون الأول

جدول (٦) درجة الحرارة الصغرى منتبأ بها للمدة (٢٠٢٥-٢٠٣٥)

المحطات	السنة	كانون الثاني	شباط	اذار	نيسان	أيار	حزيران	تموز	اب	أيلول	تشرين الأول	تشرين الثاني	كانون الأول	المعدل السنوي
الشبكة	20	6.	7.	11	17	21	25.	30	28	23	19	10	5.	17.
	25	1	4	.6	.5	.9	8	.1	.5	.1	.0	.6	9	3
الشبكة	20	5.	5.	9.	15	21	26.	27	26	25	18	11	4.	16.
	26	9	5	0	.2	.1	5	.3	.1	.3	.2	.2	9	3
الشبكة	20	5.	7.	9.	16	21	25.	27	29	23	17	12	5.	16.
	27	0	8	7	.3	.6	8	.7	.8	.7	.3	.1	1	8
الشبكة	20	5.	5.	9.	16	23	26.	28	27	22	17	10	7.	16.
	28	9	5	5	.2	.1	4	.3	.4	.1	.7	.7	8	7
الشبكة	20	6.	5.	11	15	21	26.	29	28	22	18	11	7.	17.
	29	1	8	.4	.5	.6	9	.7	.8	.9	.2	.6	7	2
الشبكة	20	5.	7.	9.	14	23	27.	28	29	24	17	11	8.	17.
	30	2	6	9	.7	.3	8	.4	.0	.3	.9	.7	4	3
الشبكة	20	5.	9.	8.	17	22	26.	28	25	23	19	13	6.	17.
	31	7	6	2	.0	.5	0	.7	.6	.6	.1	.0	1	1
الشبكة	20	4.	7.	12	16	21	27.	28	29	23	18	10	5.	17.
	32	9	3	.2	.5	.9	0	.7	.0	.1	.3	.9	1	1
الشبكة	20	6.	8.	11	15	20	25.	28	27	23	19	13	7.	17.
	33	2	2	.2	.9	.9	9	.3	.0	.8	.2	.5	0	3
الشبكة	20	6.	7.	9.	16	22	29.	28	28	24	17	12	7.	17.
	34	2	9	1	.1	.6	2	.5	.3	.0	.4	.7	6	5
الشبكة	20	6.	7.	12	14	23	29.	27	27	24	18	9.	6.	17.
	35	8	0	.9	.6	.3	0	.6	.4	.2	.2	.7	9	3
العباسية	20	6.	8.	13	19	23	27.	31	29	24	20	11	7.	18.
	25	9	8	.3	.4	.7	4	.2	.5	.3	.1	.2	0	6
العباسية	20	6.	6.	10	17	22	28.	28	27	26	19	11	5.	17.
	26	7	8	.6	.0	.8	1	.4	.1	.6	.3	.9	9	6
العباسية	20	5.	9.	11	18	23	27.	28	30	24	18	12	6.	18.
	27	8	2	.3	.1	.4	4	.8	.9	.9	.4	.8	2	1
العباسية	20	6.	6.	11	18	24	28.	29	28	23	18	11	8.	18.
	28	7	9	.1	.0	.9	0	.4	.4	.3	.8	.4	9	0
العباسية	20	6.	7.	13	17	23	28.	30	29	24	19	12	8.	18.
	29	9	1	.1	.3	.4	6	.7	.9	.0	.3	.3	8	5

18.	9.	12	19	25	30	29	29.	25	16	11	9.	6.	20	العباسية
6	5	.4	.0	.5	.0	.5	5	.1	.4	.5	0	0	30	
18.	7.	13	20	24	26	29	27.	24	18	9.	11	6.	20	العباسية
4	2	.7	.2	.8	.6	.8	6	.3	.8	8	.0	6	31	
18.	6.	11	19	24	30	29	28.	23	18	13	8.	5.	20	العباسية
4	2	.6	.4	.3	.1	.8	6	.7	.3	.9	7	7	32	
18.	8.	14	20	25	28	29	27.	22	17	12	9.	7.	20	العباسية
5	1	.3	.3	.0	.1	.3	6	.7	.7	.9	6	0	33	
18.	8.	13	18	25	29	29	30.	24	18	10	9.	7.	20	العباسية
8	8	.5	.6	.2	.4	.6	9	.4	.0	.7	3	0	34	
18.	8.	10	19	25	28	28	30.	25	16	14	8.	7.	20	العباسية
6	1	.4	.4	.4	.4	.7	6	.1	.4	.6	4	7	35	
17.	7.	11	18	21	27	29	26.	23	18	12	8.	6.	20	المشخب
7	0	.2	.7	.3	.8	.4	6	.6	.5	.6	4	9	25	
16.	6.	11	17	23	25	26	27.	22	16	9.	6.	6.	20	المشخب
7	0	.8	.9	.6	.3	.6	3	.7	.1	9	5	7	26	
17.	6.	12	17	21	29	27	26.	23	17	10	8.	5.	20	المشخب
2	3	.7	.0	.9	.1	.0	6	.2	.3	.6	8	8	27	
17.	8.	11	17	20	26	27	27.	24	17	10	6.	6.	20	المشخب
1	9	.3	.4	.3	.7	.6	2	.8	.1	.4	5	7	28	
17.	8.	12	17	21	28	28	27.	23	16	12	6.	6.	20	المشخب
6	9	.2	.9	.1	.1	.9	7	.2	.5	.4	8	9	29	
17.	9.	12	17	22	28	27	28.	25	15	10	8.	6.	20	المشخب
7	6	.3	.6	.5	.3	.7	6	.0	.6	.8	6	0	30	
17.	7.	13	18	21	24	27	26.	24	17	9.	10	6.	20	المشخب
5	3	.7	.8	.9	.9	.9	8	.2	.9	1	.7	6	31	
17.	6.	11	18	21	28	28	27.	23	17	13	8.	5.	20	المشخب
5	2	.6	.1	.4	.3	.0	8	.5	.4	.2	3	7	32	
17.	8.	14	18	22	26	27	26.	22	16	12	9.	7.	20	المشخب
6	1	.2	.9	.0	.3	.5	7	.6	.8	.2	3	0	33	
17.	8.	13	17	22	27	27	30.	24	17	10	8.	7.	20	المشخب
9	8	.4	.2	.2	.6	.7	1	.3	.1	.0	9	0	34	
17.	8.	10	18	22	26	26	29.	25	15	13	8.	7.	20	المشخب
7	1	.4	.0	.4	.7	.9	8	.0	.6	.9	0	7	35	
18.	7.	11	20	24	29	31	27.	23	19	13	8.	6.	20	النجف

6	0	.2	.1	.3	.5	.2	4	.7	.4	.3	8	9	25	
17.	5.	11	19	26	27	28	28.	22	17	10	6.	6.	20	النجف
6	9	.9	.3	.6	.1	.4	1	.8	.0	.6	8	7	26	
18.	6.	12	18	24	30	28	27.	23	18	11	9.	5.	20	النجف
1	2	.8	.4	.9	.9	.8	4	.4	.1	.3	2	8	27	
18.	8.	11	18	23	28	29	28.	24	18	11	6.	6.	20	النجف
0	9	.4	.8	.3	.4	.4	0	.9	.0	.1	9	7	28	
18.	8.	12	19	24	29	30	28.	23	17	13	7.	6.	20	النجف
5	8	.3	.3	.0	.9	.7	6	.4	.3	.1	1	9	29	
18.	9.	12	19	25	30	29	29.	25	16	11	9.	6.	20	النجف
6	5	.4	.0	.5	.0	.5	5	.1	.4	.5	0	0	30	
18.	7.	13	20	24	26	29	27.	24	18	9.	11	6.	20	النجف
4	2	.7	.2	.8	.6	.8	6	.3	.8	8	.0	6	31	
18.	6.	11	19	24	30	29	28.	23	18	13	8.	5.	20	النجف
4	2	.6	.4	.3	.1	.8	6	.7	.3	.9	7	7	32	
18.	8.	14	20	25	28	29	27.	22	17	12	9.	7.	20	النجف
5	1	.3	.3	.0	.1	.3	6	.7	.7	.9	6	0	33	
18.	8.	13	18	25	29	29	30.	24	18	10	9.	7.	20	النجف
8	8	.5	.6	.2	.4	.6	9	.4	.0	.7	3	0	34	
18.	8.	10	19	25	28	28	30.	25	16	14	8.	7.	20	النجف
6	1	.4	.4	.4	.4	.7	6	.1	.4	.6	4	7	35	

المصدر: اعتماد على نموذج Stacking Ensemble.

كما أظهرت نتائج تحليل الاتجاه العام وجود زيادة تدريجية في درجات الحرارة في جميع محطات الدراسة، حيث بلغ معدل التغير السنوي لدرجات الحرارة الصغرى نحو (٠.٠٥-٠.٠٦ م/سنة)، في حين تراوح معدل التغير السنوي لدرجات الحرارة العظمى بين (٠.٠٨-٠.٠٩ م/سنة). وتشير القيم الاحتمالية (P-value) التي تراوحت بين (٠.٧٧-٠.٨١) إلى أن الاتجاه العام لارتفاع درجات الحرارة لا يتمتع بدلالة إحصائية قوية عند مستوى (٠.٠٥) كما في جدول (٧)، إلا أنه يعكس ميلاً عاماً نحو زيادة القيم الحرارية في منطقة الدراسة.

جدول (٧) معدل التغير السنوي لدرجة الحرارة لكل محطات والقيمة الاحتمالية (p-value)

العنصر	المحطة	معدل التغير السنوي (م/سنة)	القيمة الاحتمالية P-value
درجة الحرارة الصغرى	الشبكة	0.06	0.80
درجة الحرارة الصغرى	العباسية	0.06	0.80

0.81	0.05	المشخاب	درجة الحرارة الصغرى
0.80	0.06	النجف	درجة الحرارة الصغرى
0.77	0.08	الشبكة	درجة الحرارة العظمى
0.77	0.09	العباسية	درجة الحرارة العظمى
0.78	0.08	المشخاب	درجة الحرارة العظمى
0.77	0.09	النجف	درجة الحرارة العظمى

المصدر: اعتماد على نتائج نموذج Stacking Ensemble.

تشير نتائج المقارنة بين البيانات التاريخية والمتنبأ بها إلى وجود اتجاه عام نحو ارتفاع درجات الحرارة العظمى والصغرى في جميع محطات الدراسة خلال المدة (٢٠٢٥-٢٠٣٥) كما في جدول (٩،٨) والخريطة (٣،٢). فقد تراوح التغير السنوي في المعدل العام لدرجات الحرارة العظمى بين نحو (٠.٤-١.٧م°)، في حين تراوح التغير السنوي لدرجات الحرارة الصغرى بين (٠.٤-١.٧م°)، مع تركيز أعلى الزيادات خلال أشهر الصيف، ولا سيما حزيران وتموز وآب. ورغم ظهور بعض القيم السالبة في أشهر محدودة، فإن النمط العام يعكس غلبة الزيادة الحرارية على الانخفاض، بما يؤكد استمرار النزعة الاحترارية في منطقة الدراسة. وتبرز محطتا النجف والعباسية بوصفهما الأكثر تعرضاً لارتفاع الحرارة، وهو ما يشير إلى تنامي احتمالات الإجهاد الحراري واتساع أثر التغيرات المناخية في البيئة المحلية خلال السنوات المقبلة.

جدول (٨) مقدار التغير الشهري والسنوي لدرجة الحرارة العظمى بين البيانات المتنبأ بها و

البيانات التاريخية

المحطات	السنة	كانون الثاني	شباط	اذار	نيسان	أيار	حزيران	تموز	اب	أيلول	تشرين الأول	تشرين الثاني	كانون الأول	المعدل السنوي
الشبكة	20	1.	1	2	3.	0	0.9	3	2	0	1.	0.	0.	1.5
	25	8	.3	.3	1	.9	.2	.3	.3	.3	7	1	4	
الشبكة	20	1.	-	-	0.	-	1.6	-	-	2	0.	0.	-	0.4
	26	5	1.0	0.8	4	0.1	0.1	0.1	0.5	.9	7	9	0.9	
الشبكة	20	0.	1	0	1.	0	0.9	0	3	1	-	1.	-	1.0
	27	5	.7	.0	7	.5	.4	.4	.8	.0	0.3	9	0.6	
الشبكة	20	1.	-	-	1.	2	1.5	1	1	-	0.	0.	2.	0.8
	28	6	1.0	0.2	5	.3	.1	.1	.0	0.9	2	3	5	
الشبكة	20	1.	-	2	0.	0	2.2	2	2	0	0.	1.	2.	1.4

	4	4	8	.0	.7	.6		.4	8	.1	0.7	8	29	
1.5	3.	1.	0.	1	2	1	3.2	2	-	0	1	0.	20	الشبكة
	2	4	4	.7	.8	.2		.4	0.3	.2	.4	8	30	
1.2	0.	2.	1.	0	-	1	1.0	1	2.	-	3	1.	20	الشبكة
	5	9	7	.9	1.1	.5		.5	4	1.7	.7	4	31	
1.2	-	0.	0.	0	2	1	2.2	0	1.	3	1	0.	20	الشبكة
	0.7	5	9	.3	.9	.5		.8	8	.0	.1	4	32	
1.4	1.	3.	1.	1	0	1	1.0	-	1.	1	2	1.	20	الشبكة
	5	6	9	.1	.6	.0		0.4	1	.8	.1	9	33	
1.7	2.	2.	-	1	2	1	4.8	1	1.	-	1	1.	20	الشبكة
	3	6	0.2	.3	.1	.2		.6	5	0.7	.7	9	34	
1.5	1.	-	0.	1	1	0	4.5	2	-	3	0	2.	20	الشبكة
	5	0.9	7	.5	.0	.2		.4	0.3	.7	.7	6	35	
1.6	0.	0.	1.	0	2	3	0.9	0	3.	2	1	1.	20	العباسية
	4	1	8	.4	.3	.2		.9	2	.4	.3	9	25	
0.4	-	0.	0.	3	-	0	1.7	-	0.	-	-	1.	20	العباسية
	0.8	8	8	.0	0.5	.0		0.1	4	0.7	1.0	6	26	
1.0	-	1.	-	1	3	0	0.9	0	1.	0	1	0.	20	العباسية
	0.5	9	0.3	.1	.9	.4		.5	7	.1	.8	6	27	
0.9	2.	0.	0.	-	1	1	1.6	2	1.	-	-	1.	20	العباسية
	6	2	2	0.8	.0	.1		.3	5	0.1	1.0	7	28	
1.4	2.	1.	0.	0	2	2	2.2	0	0.	2	-	1.	20	العباسية
	5	3	8	.1	.7	.7		.5	8	.2	0.7	9	29	
1.6	3.	1.	0.	1	2	1	3.3	2	-	0	1	0.	20	العباسية
	3	4	4	.7	.9	.3		.5	0.2	.3	.5	8	30	
1.3	0.	2.	1.	1	-	1	1.1	1	2.	-	3	1.	20	العباسية
	6	9	8	.0	1.1	.5		.6	5	1.7	.9	5	31	
1.3	-	0.	0.	0	2	1	2.2	0	1.	3	1	0.	20	العباسية
	0.6	5	9	.4	.9	.6		.8	9	.1	.2	5	32	
1.5	1.	3.	2.	1	0	1	1.0	-	1.	1	2	2.	20	العباسية

	6	6	0	.2	.6	.0		0.3	2	.9	.2	0	33	
1.7	2.	2.	-	1	2	1	4.9	1	1.	-	1	2.	20	العباسية
	4	6	0.1	.4	.1	.3		.7	5	0.6	.8	0	34	
1.5	1.	-	0.	1	1	0	4.6	2	-	3	0	2.	20	العباسية
	6	0.9	8	.6	.0	.3		.5	0.3	.9	.7	7	35	
1.5	0.	0.	1.	0	2	3	0.9	0	3.	2	1	1.	20	المشخاب
	4	0	8	.4	.3	.2		.9	1	.4	.3	9	25	
0.4	-	0.	0.	3	-	-	1.7	-	0.	-	-	1.	20	المشخاب
	0.9	8	8	.0	0.6	0.1		0.1	4	0.8	1.0	6	26	
1.0	-	1.	-	1	3	0	0.9	0	1.	0	1	0.	20	المشخاب
	0.6	8	0.3	.1	.8	.4		.5	7	.1	.7	6	27	
0.8	2.	0.	0.	-	1	1	1.6	2	1.	-	-	1.	20	المشخاب
	5	2	2	0.9	.0	.1		.3	5	0.1	1.0	6	28	
1.4	2.	1.	0.	0	2	2	2.2	0	0.	2	-	1.	20	المشخاب
	4	3	8	.0	.7	.7		.5	7	.1	0.7	8	29	
1.6	3.	1.	0.	1	2	1	3.3	2	-	0	1	0.	20	المشخاب
	2	4	4	.7	.8	.2		.5	0.3	.2	.5	8	30	
1.3	0.	2.	1.	1	-	1	1.1	1	2.	-	3	1.	20	المشخاب
	5	9	8	.0	1.1	.5		.6	4	1.7	.8	4	31	
1.2	-	0.	0.	0	2	1	2.2	0	1.	3	1	0.	20	المشخاب
	0.7	4	9	.4	.9	.6		.8	8	.0	.1	4	32	
1.5	1.	3.	1.	1	0	1	1.0	-	1.	1	2	1.	20	المشخاب
	5	5	9	.1	.5	.0		0.3	1	.9	.2	9	33	
1.7	2.	2.	-	1	2	1	4.9	1	1.	-	1	1.	20	المشخاب
	4	6	0.1	.3	.1	.3		.7	4	0.7	.8	9	34	
1.5	1.	-	0.	1	0	0	4.6	2	-	3	0	2.	20	المشخاب
	5	1.0	8	.6	.9	.2		.4	0.4	.8	.7	7	35	
1.6	0.	0.	1.	0	2	3	0.9	0	3.	2	1	1.	20	النجف
	4	1	8	.4	.3	.2		.9	2	.4	.3	9	25	
0.4	-	0.	0.	3	-	0	1.7	-	0.	-	-	1.	20	النجف

	0.8	8	8	.0	0.5	.0		0.1	4	0.7	1.0	6	26	
1.0	-	1.	-	1	3	0	0.9	0	1.	0	1	0.	20	النجف
	0.5	9	0.3	.1	.9	.4		.5	7	.1	.8	6	27	
0.9	2.	0.	0.	-	1	1	1.6	2	1.	-	-	1.	20	النجف
	6	2	2	0.8	.0	.1		.3	5	0.1	1.0	7	28	
1.4	2.	1.	0.	0	2	2	2.2	0	0.	2	-	1.	20	النجف
	5	3	8	.1	.7	.7		.5	8	.2	0.7	9	29	
1.6	3.	1.	0.	1	2	1	3.3	2	-	0	1	0.	20	النجف
	3	4	4	.7	.9	.3		.5	0.2	.3	.5	8	30	
1.3	0.	2.	1.	1	-	1	1.1	1	2.	-	3	1.	20	النجف
	6	9	8	.0	1.1	.5		.6	5	1.7	.9	5	31	
1.3	-	0.	0.	0	2	1	2.2	0	1.	3	1	0.	20	النجف
	0.6	5	9	.4	.9	.6		.8	9	.1	.2	5	32	
1.5	1.	3.	2.	1	0	1	1.0	-	1.	1	2	2.	20	النجف
	6	6	0	.2	.6	.0		0.3	2	.9	.2	0	33	
1.7	2.	2.	-	1	2	1	4.9	1	1.	-	1	2.	20	النجف
	4	6	0.1	.4	.1	.3		.7	5	0.6	.8	0	34	
1.5	1.	-	0.	1	1	0	4.6	2	-	3	0	2.	20	النجف
	6	0.9	8	.6	.0	.3		.5	0.3	.9	.7	7	35	

المصدر: اعتماد على نتائج نموذج Stacking Ensemble و البيانات التاريخية .

جدول (٩) مقدار التغير الشهري والسنوي لدرجة الحرارة الصغرى بين البيانات متنبأ بها و

البيانات التاريخية

المحطات	السنة	كانون الثاني	شباط	اذار	نيسان	أيار	حزيران	تموز	اب	أيلول	تشرين الأول	تشرين الثاني	كانون الأول	المعدل السنوي
الشبكة	20	1.	1.0	1	2.	0	0.9	2	2	0	1.	0.	0.	1.4
	25	5	.8	.8	7	.8		.9	.1	.6	6	2	3	
الشبكة	20	1.	-	-	0.	-	1.6	0	-	2	0.	0.	-	0.4
	26	3	1.0	0.8	4	0.1		.1	0.3	.8	8	9	0.7	
الشبكة	20	0.	1.4	-	1.	0	0.9	0	3	1	-	1.	-	0.9

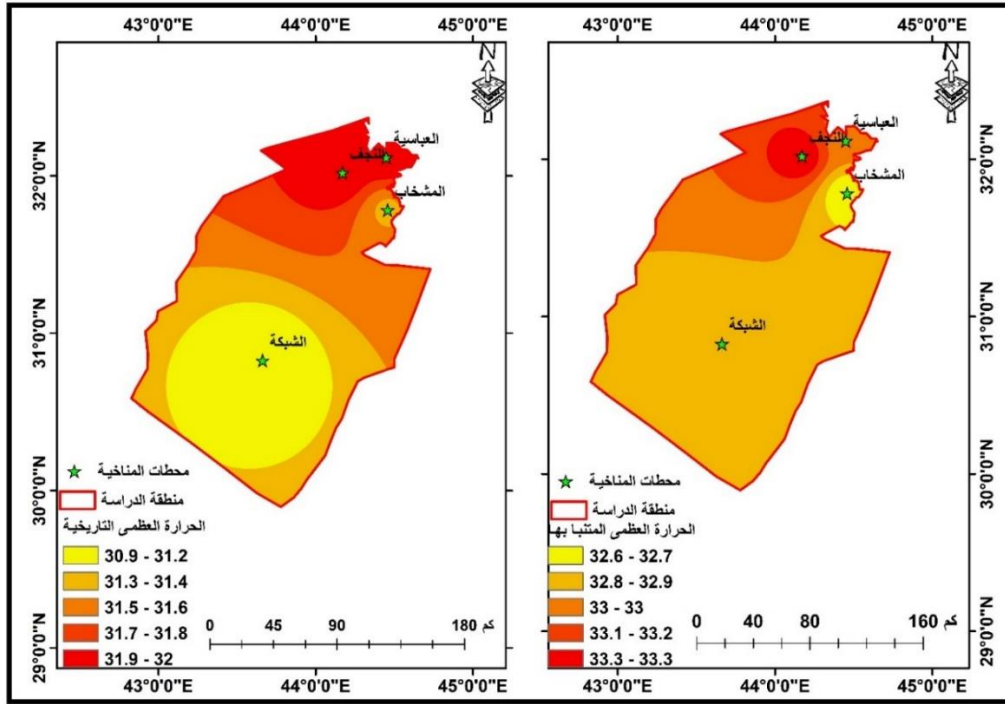
	0.5	8	0.1	.2	.4	.5		.5	5	0.1		4	27	
0.8	2.	0.	0.	-	1	1	1.5	2	1.	-	-	1.	20	الشبكة
	2	4	3	0.5	.0	.1		.0	3	0.3	0.9	3	28	
1.3	2.	1.	0.	0	2	2	2.0	0	0.	1	-	1.	20	الشبكة
	1	3	8	.3	.4	.4		.5	7	.6	0.7	5	29	
1.4	2.	1.	0.	1	2	1	2.9	2	-	0	1.2	0.	20	الشبكة
	8	4	5	.7	.6	.2		.2	0.2	.0		6	30	
1.2	0.	2.	1.	1	-	1	1.1	1	2.	-	3.2	1.	20	الشبكة
	5	7	7	.1	0.8	.4		.4	2	1.6		1	31	
1.1	-	0.	0.	0	2	1	2.0	0	1.	2	0.9	0.	20	الشبكة
	0.5	6	9	.6	.6	.5		.7	6	.4		3	32	
1.3	1.	3.	1.	1	0	1	1.0	-	1.	1	1.8	1.	20	الشبكة
	4	2	8	.2	.6	.0		0.2	0	.4		6	33	
1.5	2.	2.	0.	1	1	1	4.3	1	1.	-	1.4	1.	20	الشبكة
	1	4	1	.4	.9	.2		.5	3	0.7		6	34	
1.4	1.	-	0.	1	1	0	4.0	2	-	3	0.5	2.	20	الشبكة
	3	0.6	9	.6	.0	.4		.1	0.2	.1		2	35	
1.5	0.	0.	1.	0	2	3	1.0	0	2.	2	1.1	1.	20	العباسية
	4	4	7	.7	.2	.0		.9	9	.0		6	25	
0.5	-	1.	0.	3	-	0	1.7	0	0.	-	-	1.	20	العباسية
	0.6	0	9	.0	0.3	.2		.1	5	0.7	0.9	4	26	
1.0	-	1.	0.	1	3	0	1.1	0	1.	0	1.5	0.	20	العباسية
	0.3	9	0	.3	.6	.6		.6	6	.0		5	27	
0.9	2.	0.	0.	-	1	1	1.6	2	1.	-	-	1.	20	العباسية
	3	5	4	0.3	.1	.2		.2	5	0.2	0.8	4	28	
1.4	2.	1.	0.	0	2	2	2.2	0	0.	1	-	1.	20	العباسية
	3	4	9	.4	.6	.5		.6	8	.8	0.6	6	29	
1.5	3.	1.	0.	1	2	1	3.1	2	-	0	1.3	0.	20	العباسية
	0	5	6	.9	.7	.3		.4	0.1	.2		7	30	
1.3	0.	2.	1.	1	-	1	1.2	1	2.	-	3.4	1.	20	العباسية

	7	9	8	.2	0.7	.6		.6	3	1.5		3	31	
1.3	-	0.	1.	0	2	1	2.2	0	1.	2	1.0	0.	20	العباسية
	0.4	8	1	.7	.8	.6		.9	8	.6		5	32	
1.5	1.	3.	1.	1	0	1	1.2	-	1.	1	1.9	1.	20	العباسية
	5	4	9	.4	.8	.1		0.1	2	.6		8	33	
1.7	2.	2.	0.	1	2	1	4.5	1	1.	-	1.6	1.	20	العباسية
	2	6	2	.6	.1	.4		.7	5	0.6		8	34	
1.5	1.	-	1.	1	1	0	4.3	2	-	3	0.7	2.	20	العباسية
	5	0.5	0	.8	.1	.5		.3	0.1	.3		4	35	
1.5	0.	0.	1.	0	2	3	1.1	1	2.	2	1.1	1.	20	المشخاب
	4	4	8	.7	.2	.0		.0	9	.0		6	25	
0.5	-	1.	0.	3	-	0	1.8	0	0.	-	-	1.	20	المشخاب
	0.6	0	9	.0	0.2	.2		.1	5	0.7	0.9	4	26	
1.0	-	1.	0.	1	3	0	1.1	0	1.	0	1.5	0.	20	المشخاب
	0.3	9	0	.3	.6	.6		.6	6	.0		5	27	
0.9	2.	0.	0.	-	1	1	1.7	2	1.	-	-	1.	20	المشخاب
	3	5	4	0.3	.2	.2		.2	5	0.1	0.8	4	28	
1.4	2.	1.	1.	0	2	2	2.2	0	0.	1	-	1.	20	المشخاب
	3	5	0	.5	.6	.6		.6	9	.8	0.5	6	29	
1.6	3.	1.	0.	1	2	1	3.1	2	0.	0	1.3	0.	20	المشخاب
	0	5	6	.9	.7	.3		.4	0	.2	7	30		
1.3	0.	2.	1.	1	-	1	1.3	1	2.	-	3.4	1.	20	المشخاب
	6	9	8	.3	0.7	.6		.6	3	1.5		3	31	
1.3	-	0.	1.	0	2	1	2.3	0	1.	2	1.0	0.	20	المشخاب
	0.4	8	1	.8	.8	.6		.9	8	.6		5	32	
1.5	1.	3.	2.	1	0	1	1.2	0	1.	1	2.0	1.	20	المشخاب
	5	4	0	.4	.8	.2		.0	2	.6		8	33	
1.7	2.	2.	0.	1	2	1	4.6	1	1.	-	1.6	1.	20	المشخاب
	2	6	2	.6	.1	.4		.7	5	0.5		8	34	
1.5	1.	-	1.	1	1	0	4.3	2	-	3	0.7	2.	20	المشخاب

	5	0.4	0	.8	.2	.5		.4	0.1	.3		4	35		
	1.5	0.	0.	1.	0	2	3	1.0	0	2.	2	1.1	1.	20	النجف
		4	4	7	.7	.2	.0		.9	9	.0		6	25	
	0.5	-	1.	0.	3	-	0	1.7	0	0.	-	-	1.	20	النجف
		0.6	0	9	.0	0.3	.2		.1	5	0.7	0.9	4	26	
	1.0	-	1.	0.	1	3	0	1.1	0	1.	0	1.5	0.	20	النجف
		0.3	9	0	.3	.6	.6		.6	6	.0		5	27	
	0.9	2.	0.	0.	-	1	1	1.6	2	1.	-	-	1.	20	النجف
		3	5	4	0.3	.1	.2		.2	5	0.2	0.8	4	28	
	1.4	2.	1.	0.	0	2	2	2.2	0	0.	1	-	1.	20	النجف
		3	4	9	.4	.6	.5		.6	8	.8	0.6	6	29	
	1.5	3.	1.	0.	1	2	1	3.1	2	-	0	1.3	0.	20	النجف
		0	5	6	.9	.7	.3		.4	0.1	.2		7	30	
	1.3	0.	2.	1.	1	-	1	1.2	1	2.	-	3.4	1.	20	النجف
		7	9	8	.2	0.7	.6		.6	3	1.5		3	31	
	1.3	-	0.	1.	0	2	1	2.2	0	1.	2	1.0	0.	20	النجف
		0.4	8	1	.7	.8	.6		.9	8	.6		5	32	
	1.5	1.	3.	1.	1	0	1	1.2	-	1.	1	1.9	1.	20	النجف
		5	4	9	.4	.8	.1		0.1	2	.6		8	33	
	1.7	2.	2.	0.	1	2	1	4.5	1	1.	-	1.6	1.	20	النجف
		2	6	2	.6	.1	.4		.7	5	0.6		8	34	
	1.5	1.	-	1.	1	1	0	4.3	2	-	3	0.7	2.	20	النجف
		5	0.5	0	.8	.1	.5		.3	0.1	.3		4	35	

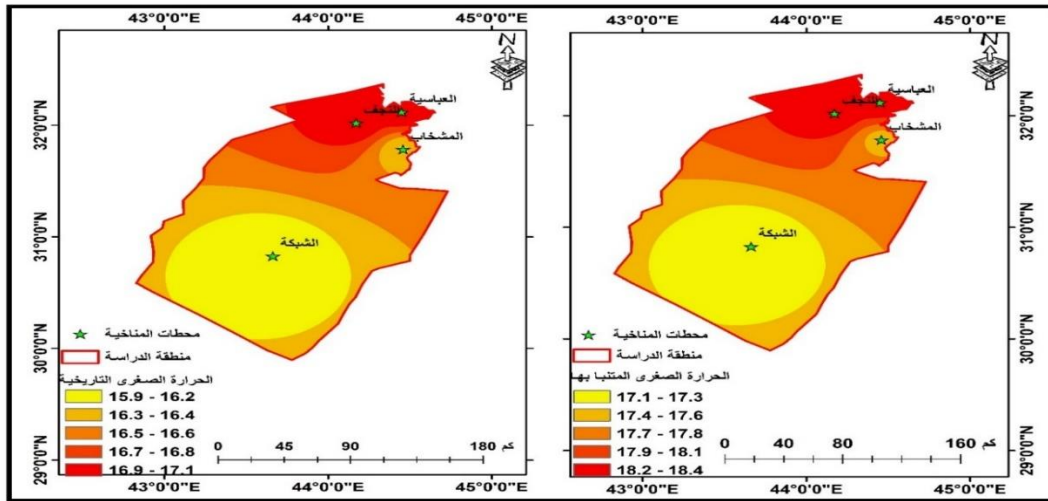
المصدر: اعتماد على نتائج نموذج Stacking Ensemble و البيانات التاريخية .

خريطة (٢) معدل السنوي الدرجة الحرارة العظمى بين البيانات متنبأ بها والتاريخية



المصدر: اعتماد على البيانات الحرارة التاريخية ومنتبأ بها وتحليلها مكانيا باستخدام GIS.

خريطة (٣) معدل السنوي الدرجة الحرارة الصغرى بين البيانات متنبأ بها والتاريخية



المصدر: اعتماد على البيانات الحرارة التاريخية ومنتبأ بها وتحليلها مكانيا باستخدام GIS.

خامسا: تحليل التغير السنوي والتباين الموسمي لدرجات الحرارة المتنبأ بها في محطات الدراسة


(2025-2035)

تشير نتائج تحليل معامل الانحراف المعياري لدرجات الحرارة العظمى خلال الفترة (٢٠٢٥-

٢٠٣٥) إلى وجود تباين سنوي ملحوظ في القيم الحرارية بين محطات الدراسة، في الشكل (٢). إذ

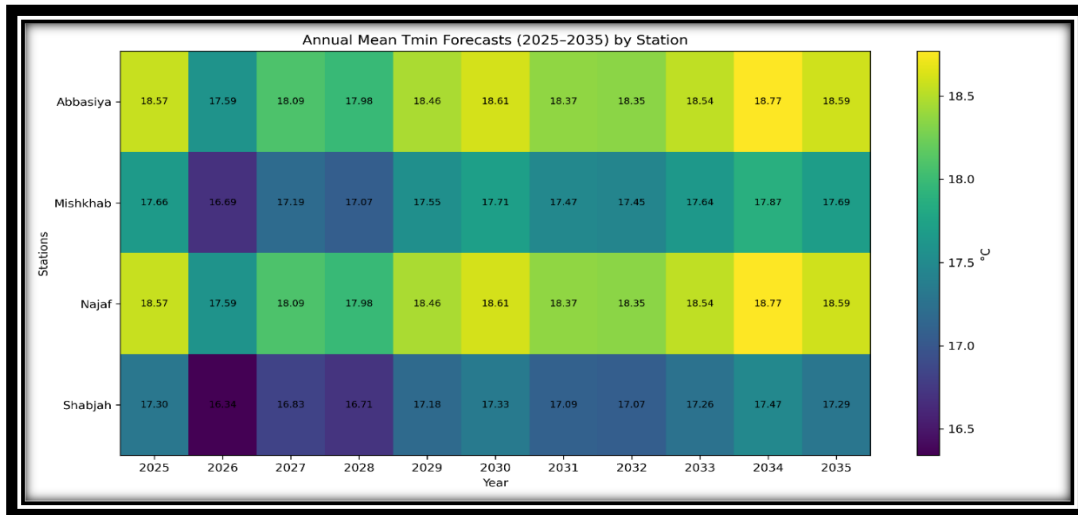
تراوحت قيم التغير السنوي في المتوسط بين نحو 1.7° - 0.4° م، مما يدل على وجود تذبذب حراري بين السنوات. ويعكس ارتفاع الانحراف المعياري في بعض السنوات زيادة التباين في درجات الحرارة العظمى، ولاسيما خلال أشهر الصيف التي تسجل أعلى القيم الحرارية.

الشكل (٢) التغيرات السنوي لمعامل الانحراف المعياري لدرجة الحرارة العظمى في كل المحطات من ٢٠٢٥ إلى ٢٠٣٥



المصدر: اعتماد على نتائج نموذج Stacking Ensemble وتحليل الانحراف المعياري السنوي المحطات منطقة الدراسة للمدة (٢٠٢٥-٢٠٣٤) باستخدام python. أظهرت نتائج تحليل معامل الانحراف المعياري لدرجات الحرارة الصغرى وجود تباين سنوي متوسط في القيم الحرارية خلال فترة الدراسة، كما في الشكل (٣). إذ تراوحت قيم التغير السنوي بين 1.5° - 0.4° م في معظم المحطات، مما يشير إلى وجود تقلبات حرارية بين السنوات ولكن بدرجة أقل مقارنة بدرجات الحرارة العظمى. ويعكس ذلك استقراراً نسبياً في القيم الحرارية الصغرى مقارنة بالقيم العظمى.

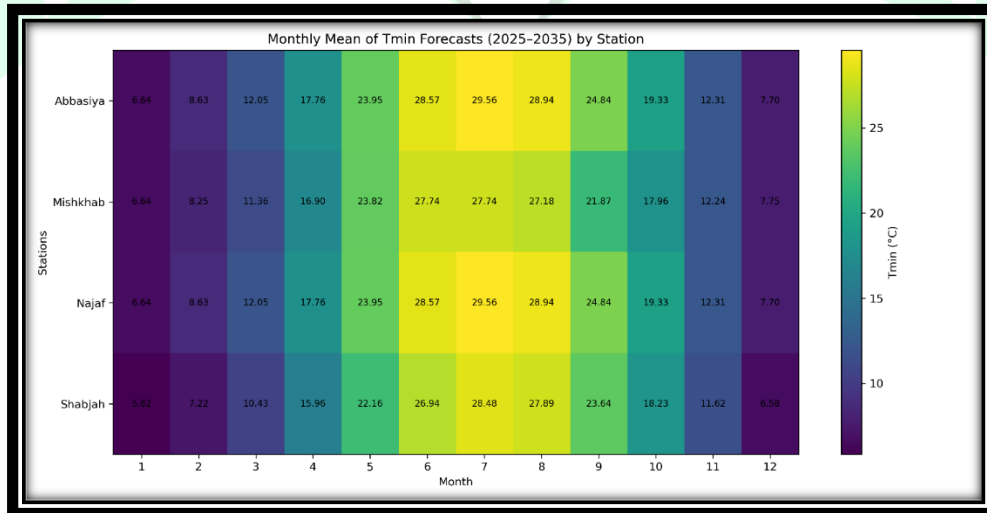
الشكل (٣) التغيرات السنوي لمعامل الانحراف المعياري لدرجة الحرارة الصغرى في كل المحطات من ٢٠٢٥ إلى ٢٠٣٥



المصدر: اعتماد على نتائج نموذج Stacking Ensemble وتحليل الانحراف العياري السنوي المحطات منطقة الدراسة للمدة (٢٠٢٥-٢٠٣٤) باستخدام python.

بينما تشير نتائج التباين الموسمي لدرجات الحرارة العظمى إلى وجود نمط موسمي واضح في جميع محطات الدراسة، الشكل (٤)، حيث تسجل أعلى القيم خلال فصل الصيف، ولا سيما في شهري تموز وآب، بينما تنخفض القيم خلال فصل الشتاء، خاصة في شهري كانون الثاني وكانون الأول. ويعكس هذا النمط تأثير الإشعاع الشمسي المرتفع وطبيعة المناخ الصحراوي الحار في منطقة الدراسة.


الشكل (٤) التباين الموسمي الدرجة الحرارة العظمى الشهري لكل محطات الدراسة



المصدر: اعتماد على نتائج نموذج Stacking Ensemble وتحليل الانحراف العياري الموسمي المحطات منطقة الدراسة للمدة (٢٠٢٥-٢٠٣٤) باستخدام python.

أما تُظهر نتائج التباين الموسمي لدرجات الحرارة الصغرى نمطاً موسمياً مماثلاً لما هو موجود في درجات الحرارة العظمى، حيث تسجل القيم الأدنى خلال أشهر الشتاء، بينما ترتفع تدريجياً خلال فصلي الربيع والصيف لتبلغ أعلى مستوياتها خلال شهري تموز وآب. كما تشير النتائج إلى أن التباين الموسمي لدرجات الحرارة الصغرى أقل وضوحاً مقارنة بدرجات الحرارة العظمى، نتيجة لانخفاض تأثير الإشعاع الشمسي المباشر خلال الليل. كما في الشكل (٥).

شكل (٥) التباين الموسمي الدرجة الحرارة الصغرى الشهري لكل محطات الدراسة



المصدر: اعتماد على نتائج نموذج Stacking Ensemble وتحليل الانحراف العياري الموسمي الاستنتاجات:

١- أظهرت نتائج تحليل البيانات المناخية وجود نمط موسمي واضح لدرجات الحرارة في جميع محطات الدراسة، حيث تسجل القيم العليا خلال أشهر الصيف، ولا سيما في تموز وآب، في حين تنخفض خلال أشهر الشتاء.

٢- بين تحليل الاتجاه العام للسلاسل الزمنية وجود اتجاه تصاعدي تدريجي في درجات الحرارة في محافظة النجف خلال فترة الدراسة، مما يعكس تأثير التغيرات المناخية على الخصائص الحرارية في المنطقة.

٣- أظهرت نتائج النماذج التنبؤية أن درجات الحرارة العظمى تسجل معدلات تغير سنوي أعلى مقارنة بدرجات الحرارة الصغرى، مما يدل على زيادة شدة القيم الحرارية خلال السنوات القادمة.

٤- أظهرت مؤشرات تقييم النماذج الإحصائية (R^2 و RMSE و MAE) أن النماذج المستخدمة تمتلك قدرة مقبولة على التنبؤ بدرجات الحرارة، مع تسجيل أفضل أداء في محطة النجف مقارنة ببقية المحطات.

- ٥- تشير نتائج التنبؤ للفترة (٢٠٢٥-٢٠٣٥) إلى استمرار الاتجاه التصاعدي في درجات الحرارة في جميع محطات الدراسة، مع احتمال تسجيل قيم مرتفعة خلال أشهر الصيف قد تتجاوز (٤٦م°).
- ٦- بين تحليل التغير السنوي والتباين الموسمي وجود تذبذب حراري بين السنوات، إلا أن الاتجاه العام يشير إلى زيادة تدريجية في القيم الحرارية.
- ٧- تؤكد نتائج الدراسة أن استخدام نماذج التعلم الآلي والنماذج التجميعية مثل Stacking Ensemble يسهم في تحسين دقة التنبؤ بالمتغيرات المناخية.

المصادر:-

- ١- الجميلي، عبدالرزاق محمد، ٢٠١٣، جغرافية العراق الطبيعية، دار صفاء للنشر والتوزيع، عمان
- ٢- الخفاجي، علي حسين جاسم، ٢٠١٧، الخصائص المناخية لمحافظة النجف الأشرف وأثرها في النشاط الزراعي، رسالة ماجستير، كلية التربية للعلوم الإنسانية، جامعة الكوفة.
- ٣- السامرائي، سعدي أحمد، ٢٠١٢، مناخ العراق القديم والحديث، دار صفاء للنشر والتوزيع، عمان
- 4- Al-Ansari, N., Ali, A., & Knutsson, S. (2014). Present conditions and future challenges of water resources problems in Iraq. *Journal of Water Resource and Protection*, 6, 1066-1098. <https://doi.org/10.4236/jwarp.2014.612102>.
- 5- Benali, A., Carvalho, A. C., Nunes, J. P., Carvalhais, N., & Santos, A. (2012). Estimating air surface temperature in Portugal using MODIS LST data. *Remote Sensing of Environment*, 124, 108-121.
- 7- Voyant, C., Notton, G., Kalogirou, S., et al. (2017). Machine learning

methods for solar radiation forecasting: A review. *Renewable Energy*, 105, 569–582. DOI: <https://doi.org/10.1016/j.renene.2016.12.095>.

8–Hansen, J., Sato, M., & Ruedy, R. (2010). Global surface temperature change. *Reviews of Geophysics*, 48(4).

DOI: <https://doi.org/10.1029/2010RG000345>.

9–Latif, M.S., Ahmed, R.A., 2023a. A review of deep learning and machine learning techniques for hydrological inflow forecasting. *Environment, Development and Sustainability*, 25(11), 12189–12216. <https://doi.org/10.1007/s10668-023-03131-1>

<https://doi.org/10.1016/j.jhydrol.2010.09.005>.

10–Latif, M.S., Ahmed, R.A., 2023a. A review of deep learning and machine learning techniques for hydrological inflow forecasting. *Environment, Development and Sustainability*, 25(11), 12189–12216.

<https://doi.org/10.1007/s10668-023-03131-1>

11–Lelieveld, J., Proestos, Y., Hadjinicolaou, P., Tanarhte, M., Tyrllis, E., & Zittis, G. (2016).

Strongly increasing heat extremes in the Middle East and North Africa (MENA) in the 21st century.

Climatic Change, 137, 245–260.

12-Perkins-Kirkpatrick, S. E., & Lewis, S. C.2020

Increasing trends in regional heatwaves.

Nature Communications, 11(1).

DOI: <https://doi.org/10.1038/s41467-020-16970-7>.

13-Trenberth, K. E., Fasullo, J. T., & Shepherd, T. G. (2015).Attribution of climate extreme events.

Nature Climate Change, 5(8), 725-730.

DOI: <https://doi.org/10.1038/nclimate2657>.

14-Wolpert, D. H. (1992). *Stacked generalization*. Neural Networks, 5(2), 241-259.

[https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1)