



## تعزيز دقة التنبؤ المناخي في مدينة الزاوية باستخدام تعلم الآلة دراسة تطبيقية للغابات العشوائية وشبكات LSTM

أشرف محمد عبدالله مرقب

قسم الجغرافيا - كلية الآداب - جامعة الزاوية - ليبيا

البريد الإلكتروني

a.mergb@zu.edu.ly

Received: 02-06-2025; Revised: 02-07-2023; Accepted: 17-07-2025; Published: 10-10-2025

### المخلص:

تواجه مدينة الزاوية الساحلية في ليبيا، كغيرها من المناطق الساحلية حول العالم، تحديات مناخية متزايدة تتمثل في ارتفاع درجات الحرارة، تغير أنماط هطول الأمطار، وزيادة وتيرة الظواهر الجوية المتطرفة. يهدف هذا البحث الشامل إلى استكشاف وتوسيع إمكانيات الذكاء الاصطناعي في تحسين دقة التنبؤات المناخية ودعم استراتيجيات التكيف المحلية. تم في هذا الإطار تحليل بيانات مناخية تاريخية ممتدة من عام 1981 إلى 2024، تم الحصول عليها من مشروع NASA POWER. تم تطبيق منهجية موسعة تضمنت نماذج أساس (Persistence) و (Climatology) للمقارنة، بالإضافة إلى نموذجين رئيسيين لتعلم الآلة: الغابات العشوائية (Random Forest) وشبكات الذاكرة طويلة قصيرة المدى (LSTM)، بهدف التنبؤ بدرجة الحرارة اليومية. أظهرت النتائج التجريبية تقوفاً واضحاً لنماذج الذكاء الاصطناعي على نماذج الأساس، مع أداء متميز لنموذج الغابات العشوائية ( $R^2=0.94$ ) مقارنة بنموذج LSTM ( $R^2=0.91$ ) في سياق البيانات المستخدمة. تناقش الدراسة الأنماط المناخية المكتشفة، وتقرن أداء النماذج الذكية بالنماذج التقليدية، وتعرض التحديات المحلية مثل نقص البيانات والبنية التحتية. كما يقدم البحث قسماً مفصلاً لتحليل الأخطاء والانحرافات، ويحدد بوضوح حدود الدراسة ومسارات البحث المستقبلية. وتختتم الورقة بتقديم توصيات عملية ومحدثة لتطوير نظم إنذار مبكر، بناء القدرات الوطنية، ودمج تحليلات الذكاء الاصطناعي في صنع القرار، مؤكدة على أن تبني هذه التقنيات يعد ضرورة استراتيجية لتعزيز صمود ليبيا في مواجهة التغيرات المناخية.

الكلمات المفتاحية: التغير المناخي، الذكاء الاصطناعي، تعلم الآلة، التنبؤ المناخي، الغابات العشوائية، شبكات LSTM، مدينة الزاوية، ليبيا، استراتيجيات التكيف، تحليل الأخطاء.

### 1. المقدمة

يشهد العالم اليوم تغيرات مناخية متسارعة وغير مسبوقة، تتجلى في ارتفاع درجات الحرارة العالمية، تغير أنماط هطول الأمطار، وزيادة تواتر وشدة الظواهر الجوية المتطرفة كالفيضانات والجفاف والعواصف. هذه التغيرات لا تمثل تهديداً بيئياً فحسب، بل تشكل تحدياً وجودياً يؤثر على الأمن الغذائي والمائي، والصحة العامة، والاستقرار الاقتصادي والاجتماعي في جميع أنحاء العالم. تعد منطقة الشرق الأوسط وشمال إفريقيا، بما في ذلك ليبيا، من أكثر المناطق عرضة لتداعيات هذه التغيرات، نظراً لطبيعتها الجافة وشبه الجافة، ومحدودية مواردها المائية، واعتمادها الكبير على الزراعة المتأثرة بالمناخ (World Bank Group, 2025).

في ليبيا، تتفاقم آثار التغيرات المناخية بسبب عوامل متعددة، منها التصحر المتزايد، وارتفاع منسوب سطح البحر على طول السواحل، وتكرار الفيضانات المدمرة كما حدث مؤخراً في بعض المدن الليبية، بالإضافة إلى الأنماط المناخية غير المنتظمة التي تؤثر سلباً على القطاعات الحيوية (Gnedi & Robaa, 2024).

فمدينة الزاوية، بموقعها الاستراتيجي على الساحل الغربي للبلاد، ليست بمنأى عن هذه التحديات، حيث تتعرض لمخاطر مباشرة مرتبطة بارتفاع درجات الحرارة وتغير نظم الأمطار، مما يهدد بنيتها التحتية، ومواردها المائية، وأنشطتها الزراعية والاقتصادية. لمواجهة هذه التحديات المعقدة، تبرز الحاجة الملحة لتبني تقنيات حديثة ومبتكرة يمكنها تعزيز قدرتنا على فهم هذه التقلبات المناخية والتنبؤ بها بدقة، ومن ثم تطوير استراتيجيات تكيف فعالة. يُعد الذكاء الاصطناعي (AI) إحدى هذه التقنيات الواعدة، حيث يوفر أدوات تحليلية متقدمة وقدرات نمذجة فائقة تمكننا من معالجة كميات هائلة من البيانات المناخية المعقدة، والكشف عن الأنماط الخفية، وتحسين دقة التنبؤات الجوية والمناخية. من خلال تطبيقاته المتنوعة، يمكن للذكاء الاصطناعي أن يلعب دورًا محوريًا في تعزيز نظم الإنذار المبكر، وتحسين إدارة الموارد الطبيعية، ودعم صانعي القرار في صياغة سياسات تكيف مستنيرة (Mokhtar et al., 2023).

تأتي هذه الورقة العلمية الموسعة لتسليط الضوء على إمكانيات الذكاء الاصطناعي في التنبؤ بالتقلبات المناخية ودعم جهود التكيف معها، مع التركيز على دراسة حالة مدينة الزاوية في ليبيا. تم اختيار الزاوية نظرًا لموقعها الساحلي وتأثيرها بالعديد من الظواهر المناخية المتطرفة، مما يجعلها نموذجًا مناسبًا لدراسة كيفية تطبيق تقنيات الذكاء الاصطناعي في سياق محلي محدد. تهدف هذه الدراسة إلى تقديم تحليل شامل للتحديات المناخية التي تواجهها المدينة، واستعراض أبرز تطبيقات الذكاء الاصطناعي التي يمكن توظيفها، واقتراح منهجية عملية ومفصلة لتطبيق هذه التقنيات، وصولاً إلى توصيات تساهم في بناء قدرة الزاوية وليبيا بشكل عام على الصمود في وجه التغيرات المناخية.

## 2. الإطار النظري والدراسات السابقة

شهد مجال التنبؤ المناخي تطورًا كبيرًا بفضل إدماج تقنيات الذكاء الاصطناعي. استعرضت العديد من الدراسات الحديثة قدرة نماذج تعلم الآلة على تحسين دقة التنبؤات مقارنة بالطرق الإحصائية التقليدية. على سبيل المثال، أظهرت دراسات أن نماذج مثل شبكات الذاكرة طويلة قصيرة المدى (LSTM) تحقق دقة عالية في التنبؤ بالمتغيرات المناخية الشهرية (Guo et al., 2024). كما تم استخدام نماذج هجينة مثل CNN-LSTM لتحليل الأنماط المكانية والزمانية المعقدة في البيانات المناخية، مما أدى إلى تحسينات ملحوظة في دقة التنبؤ (Zhao et al., 2024).

في سياق إقليمي، تم تطبيق نماذج إحصائية مثل ARIMA للتنبؤ بكميات الأمطار في مدن عربية مثل رفح ومرسى مطروح، مما يؤكد على أهمية تطبيق هذه الأدوات في بيئات مناخية مشابهة لليبيا (المجلة المصرية للاقتصاد الزراعي، 2023). كما ركزت أبحاث أخرى على استخدام خوارزميات الغابات العشوائية (Random Forest) ليس فقط للتنبؤ، بل أيضًا لتحديد العوامل المناخية والبشرية الأكثر تأثيرًا على التغيرات البيئية (Yuan et al., 2017). هذه الجهود البحثية مجتمعة تؤكد على الإمكانيات الهائلة للذكاء الاصطناعي وتوفر أساسًا متينًا لتطبيق هذه التقنيات في سياق مدينة الزاوية.

تؤكد دراسة حديثة أجراها (Materia et al., 2024) على أن الذكاء الاصطناعي يقدم فرصًا غير مسبوقة للتنبؤ بالظواهر المناخية المتطرفة، ولكنه يواجه تحديات تتعلق بجودة البيانات وقابلية تفسير النماذج. وفي دراسة أخرى حول التنبؤ بدرجة حرارة سطح البحر في البحر الأبيض المتوسط، أظهرت نماذج مثل LSTM و Random Forest أداءً تنافسيًا مقارنة بالنماذج الديناميكية التقليدية، خاصة في التنبؤات قصيرة المدى. هذه النتائج تدعم فرضية بحثنا بأن تطبيق هذه النماذج على بيانات مدينة الزاوية يمكن أن يوفر أداة فعالة للتنبؤ المحلي.

## 2.1. مفاهيم أساسية في الذكاء الاصطناعي للتنبؤ المناخي

### 2.1.1. الذكاء الاصطناعي وتعلم الآلة

الذكاء الاصطناعي (AI) هو فرع من علوم الحاسوب يهدف إلى تطوير أنظمة قادرة على محاكاة القدرات الذهنية البشرية مثل التعلم، حل المشكلات، والتعرف على الأنماط. أما تعلم الآلة (Machine Learning)، فهو فرع من الذكاء الاصطناعي يركز على تطوير خوارزميات تمكن الحواسيب من "التعلم" من البيانات دون أن تكون مبرمجة بشكل صريح في سياق التنبؤ المناخي، يكتسب

تعلم الآلة أهمية بالغة لقدرته على التعامل مع البيانات الضخمة Big Data والمعقدة، وتحسين دقة التنبؤات عبر النقاط العلاقات غير الخطية، والتعلم المستمر من البيانات الجديدة، والكشف عن الظواهر المتطرفة، ودعم اتخاذ القرار المستنير. (Al-Haddad, 2023)

### 2.1.2. خوارزميات الذكاء الاصطناعي المستخدمة في الدراسة

تتعدد خوارزميات الذكاء الاصطناعي التي يمكن توظيفها في مجال التنبؤ المناخي. في هذه الدراسة، سنركز على أربع خوارزميات رئيسية أثبتت كفاءتها في هذا المجال، بالإضافة إلى نموذجين أساسيين للمقارنة.

#### أ. الغابات العشوائية (Random Forest)

تُعد خوارزمية Random Forest من خوارزميات التعلم المجمع (Ensemble Learning) التي تعتمد على بناء عدد كبير من أشجار القرار (Decision Trees) ودمج نتائجها للحصول على تنبؤ أكثر دقة واستقرارًا من مزاياها أنها قوية ضد البيانات الشاذة (Outliers) وتوفر مقياسًا لأهمية الميزات (Feature Importance)، مما يساعد على فهم المتغيرات المناخية الأكثر تأثيرًا (Yuan et al., 2017)

تعمل الخوارزمية عن طريق إنشاء أشجار قرار متعددة على عينات فرعية مختلفة من مجموعة البيانات واستخدام المتوسط أو التصويت لأشجار القرار الفردية كنتاج نهائي.

#### ب. شبكات الذاكرة طويلة قصيرة المدى (Long Short-Term Memory – LSTM)

تُعد شبكات LSTM نوعًا خاصًا من الشبكات العصبية المتكررة (Recurrent Neural Networks – RNNs) المصممة خصيصًا لمعالجة البيانات المتسلسلة. تتميز بقدرتها على تعلم الاعتماديات طويلة المدى في البيانات، مما يجعلها مثالية للسلاسل الزمنية المناخية مثل درجات الحرارة اليومية. تتغلب LSTM على مشكلة "تلاشي المشتقة" (Vanishing Gradient) التي تعاني منها شبكات RNN التقليدية، وذلك بفضل هيكلها المعقد الذي يتضمن "بوابات" (gates) للتحكم في تدفق المعلومات، مما يسمح لها بتذكر المعلومات لفترات طويلة وهذا يجعلها مناسبة للتنبؤ بالظواهر التي تتأثر بقيمة سابقة بعيدة في الزمن.

#### ج. آلات المتجهات الداعمة (Support Vector Machines – SVM)

هي خوارزمية قوية تستخدم للتصنيف والانحدار (Regression). هدفها الرئيسي هو إيجاد "مستوى فاصل" (Hyperplane) أمثل يفصل بين فئات البيانات المختلفة بأكبر هامش ممكن في حالة الانحدار (SVR)، تحاول الخوارزمية إيجاد مستوى فاصل يناسب أكبر عدد ممكن من نقاط البيانات ضمن هامش معين. هي فعالة بشكل خاص في المساحات عالية الأبعاد. (Igwebuike et al., 2024)

#### د. أشجار القرار (Decision Trees)

هي خوارزمية بسيطة وفعالة تعمل عن طريق تقسيم مجموعة البيانات إلى مجموعات فرعية أصغر بشكل متزايد بناءً على معايير معينة. من مزاياها أنها سهلة الفهم والتفسير، ولكنها قد تكون عرضة للتجهيز الزائد (Overfitting)، حيث يصبح النموذج معقدًا جدًا ويتعلم الضوضاء في بيانات التدريب بدلاً من النمط الأساسي غالبًا ما تستخدم كجزء من خوارزميات التعلم المجمع مثل الغابات العشوائية للتغلب على هذا القصور.

### 3. إشكالية الدراسة وأهدافها

#### 3.1. إشكالية الدراسة

تتمثل الإشكالية الرئيسية التي تتناولها هذه الدراسة في ضعف نظم التنبؤ التقليدية بالتقلبات المناخية في ليبيا، وخاصة في المدن الساحلية مثل الزاوية، في مواجهة التزايد المستمر في وتيرة وشدة الظواهر المناخية المتطرفة تعتمد هذه النظم غالبًا على نماذج إحصائية وعددية قد لا تكون كافية للنقاط التعقيدات والتفاعلات غير الخطية للأنظمة المناخية المتغيرة هذا الضعف يؤدي إلى قصور في القدرة على التنبؤ الدقيق بالفيضانات، والجفاف، وموجات الحر، والعواصف، مما يعيق جهود التخطيط والتكيف ويزيد من حجم الخسائر البشرية والمادية والاقتصادية.

بالإضافة إلى ذلك، تعاني ليبيا من نقص في البيانات المناخية الدقيقة والحديثة، وضعف في البنية التحتية التقنية والبشرية اللازمة لتطبيق التقنيات المتقدمة في هذا المجال، مما يزيد من تعقيد الإشكالية. لذا، فإن هناك فجوة معرفية وتطبيقية واضحة تتمثل في كيفية الاستفادة من التطورات الهائلة في مجال الذكاء الاصطناعي لتجاوز قصور النماذج التقليدية وتقديم حلول تنبؤية دقيقة وموثوقة تتناسب مع السياق الليبي.

### 3.2 . أهداف الدراسة

تهدف هذه الدراسة إلى تحقيق مجموعة من الأهداف المترابطة، وهي:

إبراز إمكانيات الذكاء الاصطناعي في التنبؤ بالمناخ : استعراض وشرح كيف يمكن لتقنيات الذكاء الاصطناعي، مثل تعلم الآلة والشبكات العصبية، أن توفر حلولاً متقدمة لتحسين دقة التنبؤات المناخية.

تحليل تطبيقات الذكاء الاصطناعي على واقع مدينة الزاوية : دراسة كيفية تطبيق خوارزميات الذكاء الاصطناعي المحددة مثل ( Random Forest و LSTM ) على البيانات المناخية لمدينة الزاوية للتنبؤ بالمتغيرات المناخية الرئيسية، ومقارنة أدائها بنماذج الأساس.

اقترح حلول علمية وتكنولوجية للتكيف : تقديم توصيات عملية ومستتيرة تهدف إلى تعزيز قدرة مدينة الزاوية وليبيا على التكيف مع آثار التغيرات المناخية.

توفير إطار مرجعي : تقديم ورقة علمية شاملة تكون بمثابة مرجع للباحثين وصناع القرار في ليبيا والمنطقة، وتوضح بالتفصيل منهجية تطبيق هذه التقنيات الحديثة.

تحليل الأخطاء وتحديد القيود : إجراء تحليل معمق لأخطاء النماذج وتحديد مصادرها، بالإضافة إلى تحديد حدود الدراسة الحالية واقتراح مسارات للتحسين في الأبحاث المستقبلية.

### 4 . منهجية البحث

تعتمد هذه الدراسة على منهجية تحليلية تطبيقية تهدف إلى استعراض كيفية توظيف تقنيات الذكاء الاصطناعي في التنبؤ بالتقلبات المناخية، مع تطبيق عملي مفصل على بيانات مدينة الزاوية، ليبييا تم تصميم المنهجية لتكون شاملة وقابلة للتكرار، وتتكون من الخطوات التالية:

#### 4.1 . جمع البيانات ومصادرها

لإجراء التحليل والتنبؤ، تم الاعتماد على بيانات مناخية تاريخية يومية لمدينة الزاوية (خط عرض 32.75 شمالاً، خط طول 12.72 شرقاً) وتم الحصول على هذه البيانات من مشروع "التنبؤ بالطاقة المتجددة على مستوى العالم (POWER) التابع لوكالة ناسا (NASA) يتيح هذا المشروع الوصول إلى بيانات أرصاد جوية وسطحية مشتقة من الأقمار الصناعية ونماذج المحاكاة، وهو مصدر موثوق للبيانات المناخية خاصة في المناطق التي تفتقر إلى محطات رصد أرضية كافية تم جمع البيانات للفترة الممتدة من 1 يناير 1981 إلى 31 ديسمبر 2024، وشملت المتغيرات المناخية الرئيسية التالية:

درجة الحرارة على ارتفاع 2 متر: (T2M) متوسط درجة حرارة الهواء اليومية (بالدرجة المئوية)

الرطوبة النسبية على ارتفاع 2 متر: (RH2M) متوسط الرطوبة النسبية اليومية (%).

هطول الأمطار: (PRECTOTCORR) إجمالي هطول الأمطار اليومي (مم/يوم)

تم اختيار هذه المتغيرات لأهميتها المباشرة في تحديد الظروف المناخية وتأثيرها على الأنشطة البشرية والزراعية.

#### 4.2 المعالجة المسبقة للبيانات وهندسة الميزات

قبل البدء في بناء النماذج، تم إجراء سلسلة من خطوات المعالجة المسبقة لضمان جودة البيانات وملاءمتها للتحليل. هذه الخطوات ضرورية لأن نماذج تعلم الآلة حساسة لجودة وشكل البيانات المدخلة.

**1 التحقق من البيانات وتنظيفها :** تم فحص البيانات للتأكد من عدم وجود قيم مفقودة أو غير منطقية نظرًا لجودة بيانات NASA POWER، لم يتم العثور على فجوات كبيرة تتطلب معالجة معقدة.

**2 هندسة الميزات (Feature Engineering):** تم إنشاء ميزات إضافية من البيانات الأصلية بهدف تزويد النماذج بمعلومات سياقية قد تساعد في تحسين دقة التنبؤ. شملت الميزات الجديدة الميزات الزمنية : تم استخلاص السنة، الشهر، اليوم من السنة، ويوم الأسبوع من التاريخ. هذه الميزات تساعد النموذج على التقاط الأنماط الموسمية والسببية.

**الميزات المتأخرة (Lag Features)** تم إنشاء ميزات تمثل قيم المتغيرات (درجة الحرارة، الرطوبة، الأمطار (في الأيام السابقة (مثلًا، درجة حرارة اليوم السابق 'T-1'، واليوم الذي قبله 'T-2'، وهكذا) هذه الميزات بالغة الأهمية لأن الظروف الجوية الحالية تعتمد بشكل كبير على الظروف في الماضي القريب.

**3 تطبيع البيانات (Data Scaling):** نظرًا لأن المتغيرات لها مقاييس مختلفة (مثلًا، درجة الحرارة تتراوح بين 10-40، بينما الرطوبة بين 0-100)، تم تطبيع جميع الميزات العددية لتكون في نطاق محدد (عادة بين 0 و 1) تم استخدام 'Min Max Scalar' لهذه المهمة. التطبيع يضمن أن جميع الميزات تساهم بشكل متساوٍ في تدريب النموذج ويساعد على تسريع عملية تقارب النماذج (خاصة الشبكات العصبية)

### 4.3 تقسيم البيانات

لتقييم أداء النماذج بشكل موضوعي، تم تقسيم مجموعة البيانات الكاملة (1981-2024) ترتيبًا زمنيًا إلى ثلاث مجموعات منفصلة. هذا التقسيم الزمني ضروري لمحاكاة سيناريو واقعي حيث يتم تدريب النموذج على البيانات التاريخية واستخدامه للتنبؤ بالمستقبل. **مجموعة التدريب 80% (Training Set):** من البيانات من 1981 إلى 2015 تستخدم هذه المجموعة لتدريب نماذج تعلم الآلة لتعلم الأنماط والعلاقات في البيانات.

**مجموعة الاختبار 20% (Testing Set):** المتبقية من البيانات من 2016 إلى 2024 تستخدم هذه المجموعة لتقييم الأداء النهائي للنماذج على بيانات لم ترها من قبل، مما يعطي مؤشرًا واقعيًا على مدى جودة تعميم النموذج.

### 4.4 اختيار النماذج وتدريبها

تم اختيار مجموعة متنوعة من النماذج لتقييم فعالية الذكاء الاصطناعي مقارنة بالأساليب البسيطة.

#### 4.4.1 نماذج الأساس (Baseline Models)

تم تطوير نموذجين أساسيين لتوفير خط أساس يمكن مقارنة أداء نماذج الذكاء الاصطناعي به إذا لم تتمكن النماذج المعقدة من التفوق على هذه النماذج البسيطة، فإن فائدتها تكون موضع شك.

**نموذج الاستمرارية (Persistence Model):** هو أبسط نموذج للتنبؤ بالسلاسل الزمنية. يفترض هذا النموذج أن الظروف المستقبلية ستكون ماثلة للظروف الحالية للتنبؤ بدرجة حرارة الغد، يفترض النموذج أنها ستكون نفس درجة حرارة اليوم. **نموذج المناخ (Climatology Model):** يتنبأ هذا النموذج بالقيمة المتوسطة التاريخية لليوم المحدد من السنة. على سبيل المثال، للتنبؤ بدرجة الحرارة في يوم 15 يوليو، يستخدم النموذج متوسط درجات الحرارة المسجلة في جميع أيام 15 يوليو في مجموعة التدريب.

#### 4.4.2 نماذج الذكاء الاصطناعي

تم اختيار نموذجين رئيسيين يمثلان نهجين مختلفين في تعلم الآلة.

**نموذج الغابات العشوائية (Random Forest):** تم تدريب نموذج 'RandomForestRegressor' باستخدام مكتبة 'scikit-learn' تم ضبط المعلمات الفائقة (Hyper parameters) باستخدام البحث الشبكي (Grid Search) لتحديد أفضل تركيبة. تم تدريب النموذج النهائي باستخدام 100 شجرة قرار ('n\_estimators=100').

نموذج الذاكرة طويلة قصيرة المدى (LSTM) تم بناء نموذج LSTM باستخدام مكتبة Tensor Flow/Keras تكون النموذج من طبقة LSTM واحدة تحتوي على 50 وحدة (units)، تليها طبقة كثيفة (Dense) لإخراج التنبؤ. تم تدريب النموذج لمدة 50 حقبة (epochs) مع حجم دفعة 32 (batch size)

#### 4.5 مقاييس التقييم

لتقييم ومقارنة أداء النماذج المختلفة، تم استخدام ثلاثة مقاييس إحصائية شائعة:

**متوسط الخطأ المطلق (Mean Absolute Error – MAE):** يقيس متوسط الفروق المطلقة بين القيم المتوقعة والقيم الفعلية. يعطي فكرة عن حجم الخطأ بالوحدة الأصلية (درجة مئوية)

**جذر متوسط مربع الخطأ (Root Mean Square Error – RMSE):** يشبه MAE ولكنه يعطي وزنًا أكبر للأخطاء الكبيرة لأنه يربع الفروق قبل حساب المتوسط وهو أيضًا بنفس وحدة المتغير المستهدف.


**معامل التحديد (R-squared – R<sup>2</sup>):** يمثل نسبة التباين في المتغير التابع (درجة الحرارة) التي يمكن التنبؤ بها من المتغيرات المستقلة الميزات تتراوح قيمته بين 0 و 1، حيث تشير القيمة 1 إلى تنبؤ مثالي.

#### 5 النتائج وتحليلها

يقدم هذا القسم عرضًا تفصيليًا للنتائج التي تم الحصول عليها من تطبيق النماذج المختلفة على بيانات مناخ الزاوية. يبدأ بتحليل الأنماط المناخية العامة، ثم يعرض أداء كل نموذج على حدة، وينتهي بمقارنة شاملة وتحليل موسمي للأداء.

##### 5.1 تحليل الأنماط المناخية التاريخية (1981-2024)

قبل تقييم نماذج التنبؤ، من الضروري فهم الخصائص المناخية لمدينة الزاوية. يُظهر تحليل البيانات التاريخية اتجاهات واضحة ومقلقة.



شكل 1: الاتجاه العام لمتوسط درجة الحرارة السنوية في الزاوية (1981-2024) يُظهر الرسم البياني اتجاهًا تصاعديًا

واضحًا، مما يؤكد على ظاهرة الاحترار المحلي.

فمن الشكل (1) يتضح ان هناك ارتفاع ملحوظ في متوسط درجة الحرارة السنوية على مدى العقود الأربعة الماضية، حيث ارتفع المتوسط من حوالي 20 درجة مئوية في أوائل الثمانينيات إلى ما يقرب من 22 درجة مئوية في السنوات الأخيرة والذي يتوافق مع ظاهرة الاحترار العالمي ويؤكد على أن مدينة الزاوية تتأثر بها بشكل مباشر.



## متوسط هطول الأمطار الشهري في الزاوية

هطول الأمطار (مم/يوم)

المتوسط للفترة 2024-1981



شكل 2:

التوزيع الموسمي لمتوسط هطول الأمطار الشهري في الزاوية (1981-2024) يتركز هطول الأمطار بشكل كبير في أشهر الشتاء. أما بالنسبة لهطول الأمطار شكل (2)، فيظهر نمطاً موسمياً واضحاً تتركز غالبية الأمطار في أشهر الشتاء (ديسمبر، يناير، فبراير) بينما تكون أشهر الصيف (يونيو، يوليو، أغسطس) جافة تماماً تقريباً هذا التوزيع غير المتكافئ للأمطار يجعل المنطقة عرضة للجفاف خلال فصل الصيف ويزيد من الضغط على الموارد المائية.

## 5.2 أداء نماذج الأساس (Baseline Models)

تم تقييم نماذج الأساس على مجموعة الاختبار (2016-2024) لتوفير معيار للمقارنة جاءت النتائج كما هو موضح في الجدول التالي:

الجدول (1) تم تقييم المقارنة بين نماذج الاستمرارية ونماذج المناخ

| النموذج                         | MAE درجة مئوية | RMSE درجة مئوية | R <sup>2</sup> |
|---------------------------------|----------------|-----------------|----------------|
| نموذج الاستمرارية (Persistence) | 1.85           | 2.51            | 0.81           |
| نموذج المناخ (Climatology)      | 3.20           | 4.15            | 0.49           |

تُظهر النتائج أن نموذج الاستمرارية الذي يفترض أن درجة حرارة الغد هي نفس درجة حرارة اليوم أفضل بكثير من نموذج المناخ هذا يشير إلى أن درجة حرارة اليوم هي مؤشر قوي لدرجة حرارة الغد. ومع ذلك، لا يزال متوسط الخطأ 1.85 درجة كبيراً نسبياً ستكون هذه النتائج هي خط الأساس الذي يجب على نماذج الذكاء الاصطناعي تجاوزه.

## 5.3 أداء نماذج الذكاء الاصطناعي

## 5.3.1 نتائج نموذج الغابات العشوائية (Random Forest)

أظهر نموذج الغابات العشوائية أداءً قوياً جداً في التنبؤ بدرجة الحرارة اليومية. كانت مقاييس الأداء على مجموعة الاختبار كما يلي:

متوسط الخطأ المطلق (MAE): 0.90 درجة مئوية

جذر متوسط مربع الخطأ (RMSE): 1.24 درجة مئوية

معامل التحديد (R<sup>2</sup>): 0.94

تشير هذه النتائج إلى أن النموذج قادر على تفسير 94% من التباين في درجات الحرارة، مع متوسط خطأ يقل عن درجة مئوية واحدة وهذا تحسن كبير جداً مقارنة بنماذج الأساس.

## أهمية الميزات في نموذج الغابات العشوائية



شكل (3) أهمية الميزات في نموذج الغابات العشوائية. يوضح الشكل أن درجة حرارة اليوم السابق (`temp_lag_1`) هي الميزة الأكثر تأثيرًا في التنبؤ.

كما هو متوقع، يُظهر تحليل أهمية الميزات (شكل 3) أن درجة حرارة اليوم السابق هي العامل الأكثر أهمية بفارق كبير، تليها متغيرات زمنية مثل "يوم السنة" التي تساعد النموذج على فهم الدورة الموسمية، ثم الرطوبة النسبية في اليوم السابق.

### 5.3.2 نتائج نموذج الذاكرة طويلة قصيرة المدى (LSTM)

أظهر نموذج LSTM أيضًا أداءً ممتازًا، مما يؤكد قدرته على التقاط الأنماط الزمنية في البيانات المناخية. كانت مقاييس الأداء على مجموعة الاختبار كما يلي:


متوسط الخطأ المطلق (MAE): 1.12 درجة مئوية

جذر متوسط مربع الخطأ (RMSE): 1.55 درجة مئوية

معامل التحديد ( $R^2$ ): 0.91

على الرغم من أن أداء LSTM كان أقل بقليل من Random Forest في هذه الحالة، إلا أن معامل التحديد البالغ 0.91 لا يزال يشير إلى قدرة تنبؤية عالية جدًا، وهو تحسن هائل مقارنة بنماذج الأساس.

## القيم الفعلية مقابل المتوقعة (عينة من يوليو 2024)



شكل 4: مقارنة بين القيم الفعلية لدرجة الحرارة وتنبؤات نموذج الغابات العشوائية (RF) على عينة من مجموعة الاختبار. يُظهر الرسم البياني تطابقًا كبيرًا بين الخططين.



يوضح الشكل (4) مدى دقة تنبؤات نموذج الغابات العشوائية الأفضل أداءً مقارنة بالقيم الفعلية. نلاحظ أن النموذج يتبع التقلبات اليومية والموسمية لدرجة الحرارة بشكل وثيق جدًا.

#### 5.4 مقارنة شاملة للنماذج وتحليل موسمي

يقدم الجدول التالي مقارنة شاملة لجميع النماذج التي تم تقييمها في هذه الدراسة.

الجدول (2) المقارنة الشاملة بين النماذج

| النموذج                            | MAE درجة مئوية | RMSE درجة مئوية | R <sup>2</sup> |
|------------------------------------|----------------|-----------------|----------------|
| نموذج المناخ<br>(Climatology)      | 3.20           | 4.15            | 0.49           |
| نموذج الاستمرارية<br>(Persistence) | 1.85           | 2.51            | 0.81           |
| LSTM                               | 1.12           | 1.55            | 0.91           |
| Random Forest                      | 0.90           | 1.24            | 0.94           |

ظهر الجدول بوضوح التفوق الكبير لنموذجي الذكاء الاصطناعي (LSTM و RF) على نماذج الأساس يتفوق نموذج الغابات العشوائية بشكل طفيف على نموذج LSTM في جميع المقاييس لهذه المجموعة من البيانات قد يُعزى هذا التفوق إلى أن البيانات الجدولية المنظمة والميزات المصممة بعناية مثل الميزات المتأخرة تتناسب طبيعة خوارزميات التعلم المجمع مثل Random Forest بشكل ممتاز في المقابل، قد يتطلب نموذج LSTM المزيد من البيانات أو بنية أكثر تعقيدًا لإطلاق كامل إمكاناته في النقاط الاعتماديات الزمنية الدقيقة.

#### 6 تحليل الأخطاء والانحرافات

للحصول على فهم أعمق لأداء النموذج، لا يكفي النظر إلى مقاييس الأداء الإجمالية. يهدف هذا القسم إلى تحليل أخطاء النموذج (الأفضل) الغابات العشوائية (لتحديد نقاط قوته وضعفه).

##### 6.1 تحليل البقايا (Residuals Analysis)

البقايا هي الفروق بين القيم الفعلية والقيم المتوقعة (الخطأ = الفعلي - المتوقع). (يساعد تحليل توزيع البقايا في التحقق مما إذا كان النموذج يعاني من تحيز منهجي).

#### مخطط انتشار البقايا (الأخطاء)



شكل 5: مخطط انتشار البقايا الأخطاء مقابل القيم المتوقعة لنموذج الغابات العشوائية التوزيع العشوائي حول خط الصفر يشير إلى عدم وجود تحيز منهجي كبير.

يوضح الشكل (5) أن البقايا تتوزع بشكل عشوائي إلى حد كبير حول خط الصفر. هذا مؤشر جيد، حيث يعني أن النموذج لا يميل إلى المبالغة في التقدير (under-prediction) أو التقليل من التقدير (over-prediction) بشكل منهجي عبر نطاق درجات الحرارة. ومع ذلك، يمكن ملاحظة أن تشتت الأخطاء يزداد قليلاً عند درجات الحرارة الأعلى في الصيف مما يشير إلى أن النموذج يجد صعوبة أكبر في التنبؤ الدقيق خلال فترات الحر الشديد.

## 6.2 التحليل الموسمي للأخطاء

لتأكيد الملاحظة السابقة، تم حساب متوسط الخطأ المطلق (MAE) لكل فصل من فصول السنة.

| متوسط الخطأ المطلق (MAE) | الفصل                    |
|--------------------------|--------------------------|
| 0.85 درجة مئوية          | الشتاء (ديسمبر - فبراير) |
| 0.88 درجة مئوية          | الربيع (مارس - مايو)     |
| 1.05 درجة مئوية          | الصيف (يونيو - أغسطس)    |
| 0.82 درجة مئوية          | الخريف (سبتمبر - نوفمبر) |

يؤكد الجدول (3) أن أداء النموذج يكون أفضل في فصلي الخريف والشتاء، بينما يرتفع الخطأ بشكل طفيف في فصل الصيف. يمكن تفسير ذلك بأن الظروف الجوية في الصيف قد تكون أكثر تقلباً على المدى القصير مثل موجات الحر المفاجئة أو تتأثر بعوامل لم يتم تضمينها بشكل كافٍ في النموذج مثل تأثير نسيم البحر بشكل دقيق. بشكل عام، تظل الأخطاء في جميع الفصول منخفضة ومقبولة.

## 6.3 تحليل حالات الأخطاء الكبيرة

تم تحديد الأيام التي تجاوز فيها خطأ التنبؤ 3 درجات مئوية لتحليل أسبابها. وُجد أن معظم هذه الأخطاء الكبيرة تحدث خلال الفترات الانتقالية بين الفصول أواخر الربيع وأوائل الخريف أو عند حدوث تغيرات جوية مفاجئة وغير موسمية. على سبيل المثال، قد يواجه النموذج صعوبة في التنبؤ بانخفاض حاد ومفاجئ في درجة الحرارة ناتج عن عاصفة غير متوقعة. هذا يسلط الضوء على أن النماذج التي تعتمد بشكل أساسي على البيانات التاريخية قد تواجه تحدياً في التنبؤ بالأحداث النادرة وغير المسبوقة.

## 7 المناقشة

تقدم هذه الدراسة تحليلاً شاملاً للبيانات المناخية التاريخية لمدينة الزاوية وتُظهر الإمكانيات الواعدة لتطبيقات الذكاء الاصطناعي في مجال التنبؤ المناخي المحلي. أظهرت البيانات اتجاهات واضحة لارتفاع درجات الحرارة وتغير أنماط هطول الأمطار، مما يؤكد تعرض المنطقة لتأثيرات التغير المناخي، وهو ما يتوافق مع تقارير أوسع حول ليبيا ومنطقة البحر المتوسط (UNDP Libya, n.d.).

### 7.1 مقارنة نماذج الذكاء الاصطناعي بالنظم التقليدية

تتفوق نماذج الذكاء الاصطناعي التي تم اختبارها Random Forest و LSTM بشكل كبير على نماذج الأساس البسيطة الاستمرارية والمناخ. هذا يثبت أن هذه النماذج قادرة على التقاط علاقات معقدة وغير خطية في البيانات المناخية تتجاوز مجرد الاعتماد على قيمة اليوم السابق أو المتوسط التاريخي بالمقارنة مع النماذج الإحصائية التقليدية مثل ARIMA، التي تفترض غالباً وجود علاقات خطية، تتميز نماذج تعلم الآلة بقدرتها على التعلم مباشرة من البيانات دون الحاجة إلى افتراضات مسبقة حول توزيعها. كما تشير الدراسات المقارنة، تتفوق نماذج مثل Random Forest و LSTM على ARIMA في مهام التنبؤ المناخي المعقدة بسبب قدرتها على تعلم الأنماط المعقدة التي تعجز النماذج الخطية عن التقاطها (Ahmadi et al., 2024).

إن التفوق الطفيف لنموذج الغابات العشوائية على LSTM في هذه الدراسة يمكن أن يُعزى إلى عدة أسباب أولاً، طبيعة البيانات الجدولية مع الميزات المهندسة بعناية (Lag features, time features) تناسب خوارزميات الأشجار بشكل مثالي. ثانياً، قد تكون الاعتماديات الزمنية طويلة المدى في بيانات درجة الحرارة اليومية أقل أهمية من التأثير المباشر للأيام القليلة الماضية، وهو

ما تستطيع خوارزمية الغابات العشوائية التقاطه بكفاءة عالية ومع ذلك، فإن الأداء القوي لنموذج LSTM يؤكد على قدرته الكبيرة، وقد يتفوق في مهام أخرى تتطلب ذاكرة أطول، مثل التنبؤ بالجفاف أو هطول الأمطار على مدى أسابيع.

## 7.2 التحديات والفرص في سياق الزاوية وليبيا

على الرغم من الإمكانيات الواعدة، يواجه تطبيق الذكاء الاصطناعي في سياق مدينة الزاوية وليبيا بشكل عام تحديات حقيقية تتطلب حلولاً عملية ومن أهم هذه التحديات:

**نقص البيانات المحلية الدقيقة :** تعتمد هذه الدراسة على بيانات الأقمار الصناعية، وهي ممتازة ولكنها قد تفتقر إلى الدقة المكانية لمحطات الرصد الأرضية. إن إنشاء شبكة وطنية من محطات الرصد الجوي وتوفير بياناتها بشكل مفتوح هو خطوة حاسمة. **ضعف البنية التحتية التقنية :** يتطلب تدريب النماذج المعقدة وتشغيلها في الوقت الفعلي قدرات حاسوبية عالية وبنية تحتية رقمية مستقرة. **نقص الكوادر البشرية المتخصصة :** هناك حاجة ماسة للاستثمار في بناء القدرات الوطنية في مجالات علوم البيانات، تعلم الآلة، والذكاء الاصطناعي وتطبيقاتها في مجال المناخ.

في المقابل، تشكل هذه التحديات فرصاً استراتيجية. يمكن أن يكون تطوير نظام إنذار مبكر تجريبي في الزاوية حافزاً للاستثمار في البنية التحتية للبيانات، وتعزيز التعاون البحثي بين الجامعات والجهات الحكومية، وتطوير برامج تدريبية متخصصة.

## 8.2 مجالات التحسين المستقبلية

بناءً على الحدود المذكورة، يمكن توجيه الأبحاث المستقبلية في الاتجاهات التالية: **تطوير نماذج متعددة المتغيرات :** بناء نماذج تتنبأ بمتغيرات مناخية متعددة في وقت واحد مثل الحرارة والأمطار والرطوبة لفهم العلاقات المتبادلة بينها.

**التنبؤ بالظواهر المتطرفة :** تحويل التركيز من التنبؤ بالقيم المتوسطة إلى التنبؤ باحتمالية وقوع أحداث متطرفة مثل موجات الحر، العواصف الشديدة، أو هطول الأمطار الغزيرة. هذا يتطلب تقنيات نمذجة مختلفة مثل نماذج التصنيف. **استخدام نماذج هجينة ومتقدمة :** استكشاف أداء النماذج الهجينة التي تجمع بين قدرة CNN على استخلاص الميزات المكانية وقدرة LSTM على فهم الأنماط الزمنية، بالإضافة إلى نماذج Transformers التي أثبتت نجاحاً كبيراً في معالجة التسلسلات. **التحليل المكاني والزمني :** توسيع نطاق الدراسة لتشمل مناطق جغرافية أوسع مثل الساحل الليبي بأكمله واستخدام بيانات شبكية (Gridded Data) لتحليل الأنماط المكانية للتغيرات المناخية.

**تطوير نظام إنذار مبكر عملي :** الانتقال من البحث النظري إلى التطبيق العملي من خلال بناء وتجربة نظام إنذار مبكر قائم على الذكاء الاصطناعي يمكنه توفير تنبؤات آنية وتنبهات للسلطات المحلية والجمهور.

**تحليل قابلية التفسير (Explainable AI – XAI) :** تطبيق تقنيات مثل SHAP XAI أو LIME لفهم الصندوق الأسود لنماذج الذكاء الاصطناعي بشكل أفضل، مما يزيد من ثقة صانعي القرار في مخرجاتها.

## 9 التوصيات العملية والمبادرات المقترحة

- بناءً على التحليل والنتائج المستخلصة، تُقدم هذه الدراسة التوصيات التالية لتعزيز قدرة ليبيا على مواجهة آثار التغير المناخي: **تطوير نظام إنذار مبكر تجريبي في الزاوية :** إطلاق مشروع تجريبي لتطوير نظام إنذار مبكر للظواهر الجوية المتطرفة موجات الحر، الأمطار الغزيرة باستخدام نماذج الذكاء الاصطناعي التي تم اختبارها في هذه الدراسة يمكن أن يكون هذا المشروع نموذجاً يحتذى به في مدن أخرى.
- إنشاء منصة بيانات مناخية وطنية مفتوحة :** العمل على توفير مصدر موحد وموثوق للبيانات المناخية من مصادر متعددة محطات رصد، أقمار صناعية، نماذج وتسهيل الوصول إليها واستخدامها في البحث والتخطيط من قبل الباحثين والمؤسسات.
- برامج بناء القدرات المتخصصة :** تأهيل الكوادر الليبية في مجالات علوم البيانات، تعلم الآلة، والنمذجة المناخية عبر ورش عمل، منح دراسية متخصصة، ودورات تدريبية مكثفة بالتعاون مع الجامعات والمراكز البحثية الدولية.

4. دعم البحث العلمي التطبيقي والشراكات : تخصيص ميزانيات للبحوث التطبيقية في مجال الذكاء الاصطناعي والمناخ، وتشجيع الشراكات بين الجامعات والجهات الحكومية والشركات التقنية لتطوير حلول مبتكرة ومناسبة للسياق المحلي.
5. دمج تحليلات الذكاء الاصطناعي في صنع القرار : ضمان أن تكون القرارات المتعلقة بالسياسات المناخية وإدارة الموارد خاصة المائية والزراعية مبنية على رؤى مستنيرة مستمدة من تحليلات الذكاء الاصطناعي، بدلاً من الاعتماد فقط على التقديرات التقليدية.

## 10 الخاتمة

لقد أثبتت هذه الورقة العلمية الدور الحيوي والمتزايد للذكاء الاصطناعي كأداة لا غنى عنها في مواجهة التحديات المعقدة التي تفرضها التغيرات المناخية من خلال دراسة حالة مدينة الزاوية، حيث استعرضت كيف يمكن لخوارزميات الذكاء الاصطناعي المتطورة أن تُحدث ثورة في قدرتنا على التنبؤ بالظواهر المناخية بدقة غير مسبوقة، متفوقة بشكل واضح على الأساليب التقليدية على الرغم من التحديات القائمة، فإن هذه الدراسة تدعو لتبني هذه التقنيات الحديثة كحل استراتيجي وضروري للتكيف مع آثار التغير المناخي. إن الاستثمار في الذكاء الاصطناعي ليس مجرد خيار تكنولوجي، هو ضرورة استراتيجية لضمان الأمن المناخي، وحماية الموارد الطبيعية، وتعزيز صمود المجتمعات في مواجهة مستقبل مناخي غير مؤكد. إن تجربة الزاوية تقدم نموذجاً يمكن تعميمه على باقي المدن الليبية والمنطقة ككل، مما يمهد الطريق نحو مستقبل أكثر مرونة واستدامة.

## 11 المراجع

- Al-Haddad, M. A. (2023). Artificial Intelligence and Climate Change: Opportunities and Challenges for the MENA Region. Arab Center for Research and Policy Studies.
- Ahmadi, S. M., Balahang, S., & Abolfathi, S. (2024). Predicting the hydraulic response of critical transport infrastructures during extreme flood events. Engineering Applications of Artificial Intelligence, 132, 108573. <https://doi.org/10.1016/j.engappai.2024.108573>
- Bonino, G., Galimberti, G., Masina, S., McAdam, R., & Clementi, E. (2024). Machine learning methods to predict sea surface temperature and marine heatwave occurrence: a case study of the Mediterranean Sea. Ocean Science, 20(2), 417–436. <https://doi.org/10.5194/os-20-417-2024>
- Gnedi, M. D., & Robaa, S. M. (2024). Extreme climate indices over Libya: current and future outlooks. In Hydroclimatic Extremes in the Middle East and North Africa (pp. 3–25). Elsevier.
- Guo, Q., He, Z., & Wang, Z. (2024). Monthly climate prediction using deep convolutional neural network and long short-term memory. Scientific Reports, 14(1), 17896. <https://doi.org/10.1038/s41598-024-68906-6>
- Igwebuike, N., Ajayi, M. O., & Okolie, C. (2024). Application of machine learning and deep learning for predicting groundwater levels in the West Coast Aquifer System, South Africa. Arabian Journal of Geosciences, 17(12), 1623. <https://doi.org/10.1007/s12145-024-01623-w>
- Materia, S., Palma García, L., & van Straaten, C. (2024). Artificial intelligence for climate prediction of extremes: State of the art, challenges, and future perspectives. Wiley Interdisciplinary Reviews: Climate Change, 15(5), e914.

- Mokhtar, A., et al. (2023). Predictive modeling of climate change impacts using Artificial Intelligence. (Referenced in PMC12014821).
- UNDP Libya. (n.d.). Environment and Climate Change. Retrieved October 9, 2025, from <https://www.undp.org/ar/libya/albyyt-waltghyr-almnakhy>
- World Bank Group. (2025). Climate Risk Country Profile: Libya. Climate Change Knowledge Portal. Retrieved October 9, 2025, from
- Yuan, W., et al. (2017). The use of random forest to identify climate and human interference impacts on vegetation changes. Science of The Total Environment, 599–600, 748–757.
- Zhao, D., Liang, L., & Bao, Y. (2024). Prediction of Soil Organic Carbon Content in Complex Vegetation Areas Based on CNN-LSTM Model. Land, 13(7), 915. <https://doi.org/10.3390/land13070915>
- المجلة المصرية للاقتصاد الزراعي. (2023). تقييم نموذج الذكاء الاصطناعي (ARIMA) في التنبؤ بكمية المطر في مدينتي رفح ومرسى مطروح.
- جامعة سرت. (2022). التغيرات المناخية في ليبيا (الاتجاهات والتداعيات). منشورات مركز البحوث والاستشارات.