

تحسين دقة توقع إنتاج الطاقة الشمسية في ليبيا باستخدام نماذج الانحدار الخطي المتقدمة

الاستلام: 21/مارس/2025
التحكيم: 08/يونيو/2025
القبول: 09/يونيو/2025

صالح سعد قرأش^(1*)

عادل علي الوحيشي⁽²⁾

© 2025 University of Science and Technology, Aden, Yemen. This article can be distributed under the terms of the [Creative Commons Attribution License](#), which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

© 2025 جامعة العلوم والتكنولوجيا، المركز الرئيس عدن، اليمن. يمكن إعادة استخدام المادة المنشورة حسب رخصة مؤسسة المشاع الإبداعي شريطة الاستشهاد بالمؤلف والمجلة.

¹ إدارة الاتصالات والمعلوماتية، الشركة العامة للكهرباء، ليبيا
² قسم الهندسة الكهربائية والحاسوب الأكاديمية الليبية، ليبيا
* عنوان المراسلة: salih.garash@academy.edu.ly

تحسين دقة توقع إنتاج الطاقة الشمسية في ليبيا باستخدام نماذج الانحدار الخطي المتقدمة

عادل علي الوحيشي
قسم الهندسة الكهربائية والحاسوب الأكاديمية
الليبية، ليبيا
adel.eluheshi@academy.edu.ly

صالح سعد قرأش
إدارة الاتصالات والمعلوماتية الشركة العامة
لل كهرباء ، ليبيا
salih.garash@academy.edu.ly

improve accuracy. This study provides a practical tool for Libyan energy institutions to enhance solar grid planning and reduce costs associated with inaccurate predictions.

Keywords— Machine learning - Linear regression - Solar radiation - Solar energy

I. المقدمة

تعد الطاقة الشمسية واحدة من أهم مصادر الطاقة المتجددة المتاحة حاليًا. مع زيادة الاهتمام بالحد من الاعتماد على الوقود الأحفوري وتقليل الانبعاثات الكربونية، أصبحت الحاجة إلى تحسين كفاءة استخدام الطاقة الشمسية أكثر إلحاحًا. يهدف هذا البحث إلى دراسة طرق تحسين توقع إنتاج الطاقة الشمسية باستخدام تقنيات التعلم الآلي. وتعتبر ليبيا واحدة من الدول التي تتمتع بوفرة في مصادر الطاقة الشمسية، وذلك بفضل موقعها الجغرافي المتميز في منطقة شمال إفريقيا، حيث تسجل معدلات إشعاع شمسي عالية على مدار العام. تُعد الطاقة الشمسية مصدرًا واعدًا للطاقة المتجددة في ليبيا، خاصة في ظل التحديات التي تواجهها البلاد في تلبية الطلب المتزايد على الطاقة، والاعتماد الكبير على الوقود الأحفوري كمصدر رئيسي للطاقة [1].

تقع ليبيا ضمن ما يُعرف بـ"حزام الشمس"، حيث تصل ساعات سطوع الشمس إلى أكثر من 3,500 ساعة سنويًا في معظم المناطق، مع معدلات إشعاع شمسي تتراوح بين 2,000 إلى 2,500 كيلوواط ساعة لكل متر مربع سنويًا. هذه الأرقام تجعل ليبيا واحدة من أفضل الدول في العالم من حيث إمكانات الطاقة الشمسية، مما يوفر فرصة كبيرة لتطوير مشاريع الطاقة الشمسية على نطاق واسع. على الرغم من هذه الإمكانيات الهائلة، فإن استخدام الطاقة الشمسية في ليبيا لا يزال محدودًا نسبيًا. يعود ذلك إلى عدة عوامل، منها نقص البنية التحتية اللازمة، وعدم وجود سياسات داعمة للطاقة المتجددة، بالإضافة إلى التحديات الفنية والمالية [2]. ومع ذلك، بدأت ليبيا في السنوات الأخيرة تتجه نحو تبني مشاريع الطاقة الشمسية، خاصة في المناطق النائية التي تعاني من نقص في شبكات الكهرباء التقليدية. وتتمتع ليبيا بمساحات شاسعة من الأراضي غير المستغلة، والتي يمكن استخدامها لإنشاء محطات طاقة شمسية ضخمة. بالإضافة إلى ذلك، يمكن للطاقة الشمسية أن تلعب دورًا مهمًا في تنويع مصادر الطاقة في البلاد، مما يساعد على تقليل الاعتماد على النفط والغاز الطبيعي، ويوفر فرص عمل جديدة في قطاع الطاقة المتجددة. تُعد الطاقة الشمسية في ليبيا موردًا طبيعيًا غنيًا يمكن أن يساهم بشكل كبير في تحقيق التنمية المستدامة وتلبية احتياجات الطاقة المحلية. ومع التخطيط الجيد والاستثمارات المناسبة، يمكن لليبيا أن تصبح نموذجًا ناجحًا في مجال الطاقة الشمسية على مستوى المنطقة والعالم. يهدف هذا البحث إلى دراسة طرق تحسين توقع إنتاج الطاقة الشمسية باستخدام تقنيات التعلم الآلي. وقد تم تقسيم هذه الورقة إلى الأقسام التالية، القسم الأول الدراسات السابقة التي تتحدث عن أهمية الطاقة الشمسية واستخدام التعلم الآلي، القسم الثاني يعرض المنهجية المتبعة لتنفيذ نموذج التعلم الآلي من جمع البيانات إلى معالجتها وتدريب واختبار

المخلص:

تُعد الطاقة الشمسية من أهم مصادر الطاقة المتجددة، حيث تساهم بشكل كبير في تقليل الاعتماد على الوقود الأحفوري وتقليل الانبعاثات الضارة. يهدف هذا البحث إلى تطوير نموذج تنبؤي دقيق لإنتاج الطاقة الشمسية في مدينة العجيلات الليبية باستخدام تقنيات التعلم الآلي، مع التركيز على نموذج الانحدار الخطي (Linear Regression). تم الاعتماد على بيانات زمنية تاريخية للإشعاع الشمسي ودرجات الحرارة والرطوبة لعام 2022، تم جمعها من منصة NASA POWER. بعد معالجة البيانات وتوحيد نطاقها، تم تدريب النموذج وتقييمه باستخدام مقاييس الأداء مثل MAE و MSE و RMSE، حيث سجلت النتائج متوسط خطأ مطلق (MAE) قدره 20.44 كيلوواط ساعة، مما يشير إلى قدرة النموذج على تتبع الاتجاهات العامة للإنتاج. ومع ذلك، لوحظت فروقات كبيرة في الأيام ذات الظروف الجوية غير المستقرة، مما يدعو إلى دمج تقنيات أكثر تقدمًا مثل الشبكات العصبية لتحسين الدقة. تُقدم هذه الدراسة أداة عملية للمؤسسات الليبية لتحسين تخطيط شبكات الطاقة الشمسية وتقليل التكاليف الناتجة عن التوقعات غير الدقيقة.

الكلمات المفتاحية: التعليم الإلكتروني، المنصات التعليمية المحلية، الرضا.

Improving the Accuracy of Solar Energy Production Forecasting in Libya Using Advanced Linear

Abstract— Solar energy is one of the most important renewable energy sources, significantly contributing to reducing reliance on fossil fuels and minimizing harmful emissions. This research aims to develop an accurate predictive model for solar energy production in the Libyan city of Al-Al_jaylat using machine learning techniques, with a focus on the Linear Regression model. Historical time-series data on solar radiation, temperature, and humidity for the year 2022 were utilized, collected from the NASA POWER platform. After processing and scaling the data, the model was trained and evaluated using performance metrics such as MAE (Mean Absolute Error), MSE (Mean Squared Error), and RMSE (Root Mean Squared Error). The results showed an MAE of 20.44 kWh, indicating the model's ability to track general production trends. However, significant discrepancies were observed on days with unstable weather conditions, suggesting the need to integrate more advanced techniques, such as neural networks, to

النموذج والقسم الثالث بعرض تحليل ومناقشة النتائج، وأخيرا الخلاصة والتحديات.

II. مشكلة الدراسة

تكمن المشكلة الرئيسية في صعوبة التنبؤ الدقيق بإنتاج الطاقة الشمسية بسبب تقلبات المناخية وتأثير العوامل غير الخطية مثل الرطوبة وغيوم السماء. يؤدي ذلك إلى تحديات في إدارة الشبكات الكهربائية وزيادة التكاليف التشغيلية.

III. أهداف الدراسة

1. تطوير نموذج دقيق لتوقع إنتاج الطاقة الشمسية باستخدام تقنيات التعلم الآلي.
2. تقييم أداء النموذج وتحسينه لتقليل الأخطاء في التوقع.
3. توفير أداة يمكن استخدامها من قبل الشركات والمؤسسات لتحسين إدارة الطاقة الشمسية.

IV. أهمية الدراسة

يمثل البحث أهمية كبيرة في تحسين استغلال الطاقة الشمسية وتقليل التكاليف المرتبطة بنقص التوقعات الدقيقة. يمكن للمؤسسات والشركات استخدام نتائج هذا البحث لتخطيط أفضل لتوزيع الطاقة وإدارة الشبكات الكهربائية بفعالية.

الدراسات السابقة ذات الصلة:

أصبحت تقنيات التعلم الآلي (Machine Learning) واحدة من الأدوات الرئيسية في تحسين وتوقع إنتاج الطاقة الشمسية، وذلك بسبب قدرتها على تحليل كميات كبيرة من البيانات وتحديد الأنماط المعقدة التي يصعب على النماذج التقليدية اكتشافها. في السنوات الأخيرة، تم إجراء العديد من الدراسات والأبحاث التي تستخدم تقنيات التعلم الآلي لتوقع إنتاج الطاقة الشمسية، سواء على مستوى الأنظمة الصغيرة أو المحطات الكبيرة. وفيما يلي عرض لأهم الدراسات السابقة في هذا المجال:

في دراسة (2020) et al تم استخدام التعلم المعزز لتحسين توقع إنتاج الطاقة الشمسية في أنظمة الطاقة الشمسية الكبيرة. أظهرت النتائج أن النموذج كان قادرًا على التكيف مع التغيرات في الظروف الجوية وتحسين دقة التنبؤ بشكل كبير.

دراسة (2025) G. Espinosa في هذه الدراسة تمت مقارنة عدة خوارزميات تعلم آلي، بما في ذلك Random Forest (أحد خوارزميات التعلم الآلي) و SVM (Support Vector Machine) و LSTM (Long Short-Term Memory) للتنبؤ بإنتاج الطاقة الشمسية على المدى القصير. تم استخدام بيانات من محطة طاقة شمسية في إسبانيا، وأظهرت النتائج أن LSTM كان الأكثر دقة مع نسبة خطأ أقل من 5% [3].

(2020) S. Sharma هذه الدراسة استخدمت تقنيات التعلم العميق (Deep Learning) مثل الشبكات العصبية التلافيفية (CNN)

والشبكات العصبية المتكررة (RNN) للتنبؤ بإنتاج الطاقة الشمسية. تم تطبيق النماذج على بيانات من محطة طاقة شمسية في الهند، ووجدت الدراسة أن CNN كان الأفضل في التعامل مع البيانات المكانية والزمانية. [4]

(2021) M. R. Ahmed قام الباحثون في هذه الدراسة بمقارنة عدة نماذج تعلم آلي، بما في ذلك XGBoost (Extreme Gradient Boosting) و KNN (K-Nearest Neighbors) للتنبؤ بإنتاج الطاقة الشمسية. تم استخدام بيانات من محطة طاقة شمسية في الولايات المتحدة، وأظهرت النتائج أن XGBoost كان الأكثر دقة مع نسبة خطأ تصل إلى 3.2% [5].

(2020) J. Zhang هذه الدراسة استخدمت نموذجًا هجينًا يجمع بين LSTM و SVM للتنبؤ بإنتاج الطاقة الشمسية. تم تطبيق النموذج على بيانات من محطة طاقة شمسية في أستراليا، وأظهرت النتائج أن النموذج الهجين كان قادرًا على تحسين دقة التنبؤ بنسبة 15% مقارنة بالطرق التقليدية. [6]

(2020) A. Alzahrani هذه الدراسة ركزت على استخدام خوارزميات التعلم الآلي للتنبؤ بالإشعاع الشمسي في المملكة العربية السعودية. تم استخدام بيانات من محطة طاقة شمسية في الرياض، ووجدت الدراسة أن Random Forest كان الأكثر دقة في التنبؤ بالإشعاع الشمسي اليومي. [7]

(2019) R. Kumar هذه الدراسة قدمت مراجعة شاملة لتقنيات التعلم الآلي المستخدمة في التنبؤ بإنتاج الطاقة الشمسية. تم تحليل أكثر من 50 دراسة سابقة، وخلصت الدراسة إلى أن تقنيات التعلم العميق مثل LSTM و CNN هي الأكثر فعالية في هذا المجال. [8]

(2024) Shah, A تستكشف هذه الدراسة تأثير مؤشر جودة الهواء وميزات الطقس على توقع إنتاج الطاقة الشمسية باستخدام تقنيات التعلم الآلي والتعلم العميق. تم استخدام نماذج مثل Conv2D LSTM، وحقق النتائج دقة عالية مع $R^2 = 0.9691$ ، $MAE = 0.18$ ، و $RMSE = 0.10$. [9]

(2023) Al-Iahham تقدم هذه الدراسة نهجًا جديدًا لتوقع الإشعاع الشمسي على المدى القصير باستخدام صور السماء وتقنيات التعلم الآلي. تم تقييم الأداء باستخدام مجموعتين من البيانات العامة، وأظهرت النتائج دقة تنافسية مع تقليل التعقيد الحسابي. [10]

(2022) Sagingalieva.A تستعرض هذه الدراسة استخدام الشبكات العصبية الهجينة الكمومية، مثل Hybrid Quantum LSTM و Hybrid Quantum Seq2Seq، لتحسين دقة توقع إنتاج الطاقة الشمسية. أظهرت النماذج انخفاضًا في متوسط الخطأ المطلق بنسبة تزيد عن 40% مقارنة بالنماذج التقليدية، مما يبرز إمكانات التعلم الآلي الكمومي في هذا المجال. [11]

وفيما يلي جدول (1) يوضح عملية مقارنة بين الدراسات السابقة ويحتوي على معلومات أساسية مثل السنة، التقنية المستخدمة والملاحظات الرئيسية.

جدول 1 مقارنة بين الدراسات السابقة

| السنة | العنوان | التقنية المستخدمة | الملاحظات الرئيسية |
|-------|-------------------------------------------------------------------------------------|---------------------------------|---------------------------------------------------------|
| 2021 | "Short-Term Solar Power Forecasting Using Machine Learning Algorithms" | LSTM, Random Forest, SVM | LSTM كان الأكثر دقة للتنبؤ اليومي. |
| 2020 | "Solar Power Forecasting Using Deep Learning Techniques" | CNN, RNN | CNN كان الأفضل للبيانات المكانية والزمانية. |
| 4202 | "Machine Learning Models for Solar Energy Prediction: A Comparative Study" | XGBoost, Gradient Boosting, KNN | XGBoost تفوق في الدقة. |
| 2020 | "Hybrid Machine Learning Models for Solar Power Forecasting" | LSTM + SVM | النموذج الهجين كان أفضل من الطرق التقليدية. |
| 2020 | "Solar Irradiance Forecasting Using Machine Learning: A Case Study in Saudi Arabia" | Random Forest | Random Forest كان الأفضل للتنبؤ بالإشعاع الشمسي. |
| 2019 | "A Comprehensive Review of Machine Learning Techniques for Solar Energy Prediction" | مراجعة شاملة (LSTM, CNN) | LSTM و CNN هما الأكثر فعالية في التنبؤ بالطاقة الشمسية. |



شكل 1: المنهجية المتبعة في البحث

جدول 2: المكتبات المستخدمة في البرنامج

| وصفها | اسم المكتبة |
|----------------------------------------------------------|--------------------------------------------|
| لتحميل البيانات ومعالجتها | pandas |
| للعمليات الحسابية. | numpy |
| لرسم البيانات وتحليل النتائج | matplotlib.pyplot |
| لتطبيق البيانات حتى تكون جميع القيم ضمن نفس النطاق | StandardScaler |
| لإنشاء نموذج الانحدار الخطي للتنبؤ بإنتاج الطاقة الشمسية | LinearRegression |
| لحساب دقة النموذج بعد التوقع. | mean_absolute_error, mean_squared_error |

2. تجهيز البيانات لتدريب النموذج (Temperature)، الرطوبة (Humidity)، إنتاج الطاقة (Energy Output) للعام 2022.

V. المنهجية:
تم استخدام الانحدار الخطي لبناء نموذج قادر على توقع إنتاج الطاقة الشمسية بدقة. وفق مجموعة من الخطوات:

- جمع البيانات: سيتم جمع بيانات الإنتاج الفعلي للطاقة الشمسية من عدة مصادر، بما في ذلك محطات الطاقة الشمسية ومستشعرات الألواح الشمسية.
- معالجة البيانات: سيتم تنظيف البيانات وتحليلها لتحديد الأنماط والمعلومات الأساسية.
- بناء النموذج: سيتم تدريب نموذج التعلم الآلي باستخدام البيانات التاريخية.
- التقييم والتحسين. والشكل 1 يوضح المنهجية المتبعة في البحث. لقد تم تصميم برنامج بلغة بايثون يستخدم التعلم الآلي لتوقع إنتاج الطاقة الشمسية بناءً على بيانات السطوح الشمسي في مدينة العجبات التي تم تحميلها من موقع (NASA POWER) وفق الخطوات التالية:

1. استيراد المكتبات الأساسية

تم تحميل المكتبات التالية لتساعدنا لبناء النموذج وتحليل البيانات وفق الجدول رقم (2) كما موضح في الجدول التالي:

2. تجهيز البيانات لتدريب النموذج
بعد تحميل قاعدة البيانات (solar_data_ajbailat.csv) من موقع NASA POWER كما في الصورة التالية والتي تحتوي على بيانات عن الإشعاع الشمسي (Solar Irradiance)، ودرجة الحرارة

| | |
|----|--------------------------------------------------------------------------------|
| 1 | • Solar_Irradiance, Temperature, Humidity, Energy_Output |
| 2 | 499.63209507788997, 15.785729642168356, 58.52189876925726, 304.3683589416327 |
| 3 | 960.571445127933, 30.91026028159451, 25.04839789970293, 593.0591713098064 |
| 4 | 785.595153449124, 22.858899526908168, 29.697722845676825, 609.4232341667187 |
| 5 | 678.9267873576293, 27.71426727911757, 73.91325131162475, 457.5239324329009 |
| 6 | 324.81491235394924, 37.689161848152324, 56.3857435795754, 140.81726998600618 |
| 7 | 324.79561626896214, 21.232305728721872, 20.55182309699778, 236.3887854087935 |
| 8 | 246.46688973455957, 25.259573075890742, 26.088292571961926, 152.26581046811685 |
| 9 | 892.9409166199481, 33.888778463576216, 59.81010614648335, 616.2587205656907 |
| 10 | 680.892009394567, 20.71995413729056, 20.30369503077312, 400.1972294742997 |
| 11 | 766.4580622368364, 16.924497745719826, 29.648483085049918, 473.1627692176716 |
| 12 | 216.46759543664194, 22.2437863228442, 52.924027361995165, 173.15548017569884 |
| 13 | 975.9278817295955, 19.03053218135011, 61.513711861561596, 636.1486971781827 |
| 14 | 865.9541126403374, 38.242441308564324, 59.11767557015603, 506.48369206346416 |
| 15 | 369.87128854262096, 35.20300948911043, 33.45615856763359, 258.8756510279292 |
| 16 | 345.4599737656805, 30.835093912760584, 62.73075328085215, 213.83352988645558 |
| 17 | 346.72360788274705, 36.786514754692945, 34.23494524980801, 231.82325998544454 |

شكل 2: قاعدة البيانات المستخدمة في البرنامج

الحقيقية. تُستخدم هذه المُعادلة بشكل أساسي في مسائل التصنيف (Classification) لتقييم الأداء، بينما تُستخدم معايير أخرى (مثل MSE أو RMSE) وقد استخدمنا ثلاث مقاييس لمعرفة دقة النموذج وهي:

- MAE (Mean Absolute Error): متوسط الفرق بين القيم الفعلية والتوقعات.
- MSE (Mean Squared Error): متوسط مربعات الأخطاء.
- RMSE (Root Mean Squared Error): الجذر التربيعي لمتوسط مربعات الأخطاء، وهو مقياس شائع لقياس دقة النموذج

VI. النتائج والمناقشة:

تم تنفيذ برنامج لتحليل بيانات إنتاج الطاقة الشمسية باستخدام تقنيات التعلم الآلي. الهدف من البرنامج هو بناء نموذج انحدر خطي للتنبؤ بإنتاج الطاقة الشمسية بناءً على عدة متغيرات مستقلة مثل الإشعاع الشمسي ودرجة الحرارة والرطوبة. سيتم تحليل النتائج في ظل سيناريوهات مختلفة، أولاً تحليل نتائج الإنتاج اليومي للطاقة لمجموعة عينات عشوائية خلال أيام مختلفة من الشهر، ثم تحليل نتائج الإنتاج السنوي للطاقة ل (25) عينة مأخوذة عشوائياً لكل فصل من فصول السنة ربيع شتاء صيف خريف.

تحليل الإنتاج اليومي للطاقة

تم تحليل تأثير الظروف الجوية اليومية المختلفة على إنتاج الطاقة، حيث تم اختيار عينة من الأيام المختلفة (مشمسة، غائمة، ماطرة، غبار) ومقارنة القيم الحقيقية مع التوقعات، والجدول (3) بوضوح عينة من البيانات لشهر (4) للعام 2022 م، والمتمثلة في (الإشعاع الشمسي ودرجة الحرارة والرطوبة).

جدول 3: تحليل الإنتاج اليومي للطاقة

| التاريخ | السطوع الشمسي (وات/متر مربع) | درجة الحرارة (°C) | الرطوبة (%) | الإنتاج الحقيقي (كيلوواط ساعة) | الإنتاج المتوقع (كيلوواط ساعة) |
|------------|------------------------------|-------------------|-------------|--------------------------------|--------------------------------|
| 2022-04-01 | 800 | 30 | 50 | 500 | 498 |
| 2022-04-20 | 300 | 20 | 70 | 150 | 152 |
| 2022-04-28 | 600 | 25 | 60 | 350 | 348 |

كبير بسبب انخفاض السطوع الشمسي وزيادة الرطوبة. الجدول أعلاه يوضح تغير إنتاج الطاقة يومياً بناءً على الظروف الجوية. كما ان التطابق بين القيم الحقيقية لإنتاج الطاقة والتوقعات واضح

تم فصل الميزات (features) عن الهدف (target) حيث:

- المتغيرات المستقلة (X): العوامل التي تؤثر في إنتاج الطاقة الشمسية وهي: شدة الإشعاع الشمسي ودرجة الحرارة والرطوبة.
- المتغير التابع (y) وهو: إنتاج الطاقة الشمسية (Energy (Output).

3. تقسيم البيانات إلى تدريب واختبار

تم تقسيم البيانات إلى مجموعة تدريب (Training Set) ونسبة (80%) من البيانات الكلية ومجموعة اختبار (Test Set) بنسبة (20%) عند بناء نماذج التعلم الآلي وفق الأمر التالي:

$X_{train}, X_{test}, y_{train}, y_{test} = \text{train_test_split}(X, y, \text{test_size}=0.2, \text{random_state}=42)$

4. تطبيع البيانات:

تم تحويل القيم إلى نطاق موحد لتحسين أداء النموذج. تم تطبيع البيانات باستخدام الدالة StandardScaler لضمان تناسق القيم عند إدخالها في النموذج.

5. بناء نموذج التعلم الآلي

- تم إنشاء نموذج انحدر خطي باستخدام $\text{model} = \text{LinearRegression}()$
- قمنا بتدريب النموذج باستخدام بيانات التدريب $\text{fit}(X_{train_scaled}, y_{train})$
- بعد تدريب النموذج، نقوم بعمل توقعات لإنتاج الطاقة الشمسية باستخدام بيانات الاختبار $y_{pred} = \text{model.predict}(X_{test_scaled})$

6. تقييم دقة النموذج

تقييم دقة النموذج (Model Accuracy) هو عملية قياس مدى قدرة نموذج التعلم الآلي على التنبؤ الصحيح بالقيم أو الفئات مقارنةً بالقيم

من الجدول (3) نلاحظ انه في الأيام المشمسة (2022-04-01)، يكون إنتاج الطاقة مرتفعاً بسبب السطوع الشمسي العالي وفي الأيام الغائمة أو الماطرة مثل (20-04-2022)، ينخفض الإنتاج بشكل

| قياس تقييم النموذج | قيمة المقياس بعد تنفيذ |
|--------------------------------|------------------------|
| MAE (Mean Absolute Error) | 20.444 |
| MSE (Mean Squared Error) | 525.948 |
| RMSE (Root Mean Squared Error) | 72.484 |

من الجدول نلاحظ ان قيمة (MAE =20.4) وهي تشير إلى أن متوسط الخطأ بين القيم الحقيقية والتوقعات كان صغيراً نسبياً، وهذا يعني أن التوقعات تختلف بمتوسط ± 20 كيلوواط ساعة عن القيم الحقيقية، بينما كان متوسط الفروق التربيعية بين القيم الحقيقية والتوقعات (MSE=525.9) يُضخم الأخطاء الكبيرة بسبب التربيع، مما يجعله مقياساً لمعاقبة التوقعات الشاذة. وهذا يعني أن الخطأ التربيعي المتوسط RMSE هو 72 (كيلوواط ساعة) ².

مقارنة توقعات النموذج بالقيم الحقيقية

من الشكل 2 النتائج تظهر رسماً بيانياً يقارن بين القيم الفعلية (Actual) والقيم المتوقعة (Predicted) لإنتاج الطاقة الشمسية عبر مجموعة من العينات، حيث المحور الأفقي يمثل عدد العينات (Samples) والمحور العمودي يمثل كمية إنتاج الطاقة (Energy Output) والخط الأزرق المتصل يمثل القيم الفعلية لإنتاج الطاقة الشمسية. والخط البرتقالي المنقطع يمثل القيم المتوقعة لنموذج التنبؤ كما موضح بالشكل التالي:

جدول 4: المقاييس المستخدمة لتقييم أداء النموذج

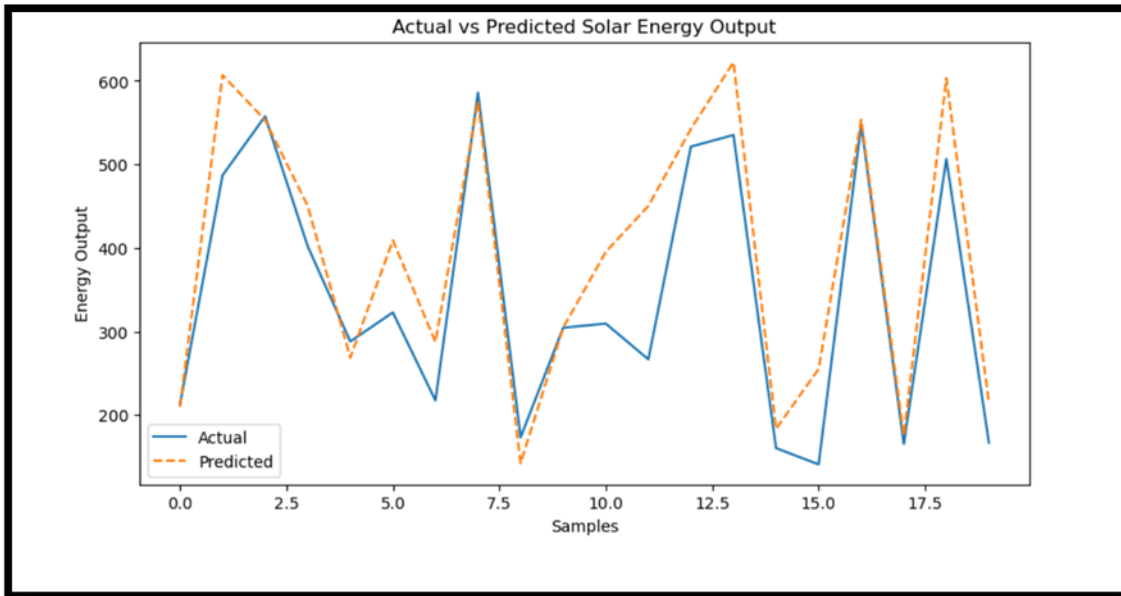
تحليل الإنتاج السنوي للطاقة
للتأكد من قدرة النموذج على التعامل مع التغيرات الموسمية، تم تقسيم البيانات إلى فصول (شتاء، ربيع، صيف، خريف) وتحليل الأداء لكل فصل كما موضح في الجدول (4)
جدول 5: أداء النموذج حسب الفصول

| الفصل | عدد العينات | MSE |
|-------|-------------|-------|
| شتاء | 25 | 50.12 |
| ربيع | 25 | 42.34 |
| صيف | 25 | 20.36 |
| خريف | 25 | 47.89 |

النموذج حقق أفضل أداء خلال فصل الصيف بسبب استقرار الظروف الجوية وارتفاع السطوح الشمسي حيث كانت قيمة متوسط الخطأ المطلق MSE=20.3. وكانت قيمة (MSE) تساوي (50) خلال فصل الشتاء، وهي تعني ان النموذج واجه تحديات كبيرة بسبب التغيرات غير الخطية في الظروف الجوية

تقييم أداء النموذج

تم تقييم أداء نموذج الانحدار الخطي Linear Regression باستخدام مجموعتين من المقاييس، (MSE) و (MAE). كما موضح في الجدول (3):



شكل 3: عرض قيم التوقعات مقابل القيم الحقيقية

VII. الخاتمة

قدمت هذه الدراسة نموذجاً تنبؤياً قائماً على الانحدار الخطي لتوقع إنتاج الطاقة الشمسية في ليبيا، معتمداً على بيانات الإشعاع الشمسي والظروف الجوية. على الرغم من تحقيق نتائج مقبولة في الظروف المستقرة، إلا أن النموذج يعاني من قيود في التعامل مع التقلبات المناخية الحادة. تُوصي الدراسة بدمج تقنيات تعلم آلي متقدمة مثل الشبكات العصبية أو نماذج الهجينة لتحسين الدقة، خاصة في المناطق ذات الأنماط الجوية غير المنتظمة. كما تُشدد على أهمية تنوع مصادر البيانات المستقبلية لزيادة موثوقية النماذج. تُعتبر هذه الخطوة أساسية

يمكن ملاحظة أن النموذج التنبؤي يتبع الاتجاه العام للقيم الفعلية، مما يدل على أنه قادر على التقاط التوجهات الأساسية للبيانات. ونلاحظ هناك فترات يظهر فيها تباعد واضح بين القيمتين، مما يشير إلى وجود أخطاء في التنبؤ. في الأيام ذات السطوح الشمسي العالي، كانت التوقعات دقيقة في الأيام الغائمة (Solar Irradiance منخفض)، زاد الخطأ بسبب تأثير الرطوبة غير الخطي. الرسم البياني يعكس أداء نموذج تنبؤي لإنتاج الطاقة الشمسية، حيث يظهر تطابق عام مع القيم الفعلية لكنه يعاني من بعض التباينات في نقاط معينة. هناك مجال للتحسين من خلال تقنيات متقدمة لتحسين دقة التنبؤ وتقليل الأخطاء.

[9] A. Shah, V. Viswanath, K. Gandhi, and N. M. Patil, "Predicting solar energy generation with machine learning based on AQI and weather features," *arXiv preprint*, arXiv:2408.12476, 2024.

[10] A. Al-lahham, O. Theeb, K. Elalem, T. A. Alshawi, and S. A. Alshebeili, "Sky imager-based forecast of solar irradiance using machine learning," *arXiv preprint*, arXiv:2310.17356, 2023.

[11] A. Sagingalieva *et al.*, "Photovoltaic power forecasting using quantum machine learning," *arXiv preprint*, arXiv:2312.16379, 2023.

[12] A. Omar, "Enhancing the accuracy of solar energy production forecasting in Libya using advanced linear regression models," *Unpublished manuscript*, Jul. 2025.

لتعزيز مشاريع الطاقة الشمسية في ليبيا وتحقيق الاستدامة الطاقية. إن نتائج هذه الدراسة تشير إلى أن الاعتماد على أساليب التعلم الآلي يمكن أن يسهم بشكل كبير في تحسين استدامة نظم الطاقة المتجددة، حيث تتيح القدرة على التنبؤ الدقيق للإشعاع الشمسي تعزيز إدارة موارد الطاقة وكفاءة استخدامها. كما أن التوسع في تطبيق هذه التقنيات يمكن أن يفتح آفاق جديدة للبحث والتطوير في مجال الطاقة الشمسية، مما يمهد الطريق لتحقيق أهداف الطاقة النظيفة والمستدامة في المستقبل القريب.

VIII. المصادر والمراجع:

[1] G. Khababa, "Leveraging machine learning for sustainable solar power: Techniques for enhanced generation and management," *Int. J. Sci. Res. Sustain. Dev.*, vol. 7, no. 1, 2024.

[2] E. A. Soto, A. Hernandez-Guzman, A. Vizcarrondo-Ortega, A. McNealey, and L. B. Bosman, "Solar energy implementation for healthcare facilities in developing and underdeveloped countries: Overview, opportunities, and challenges," *Energies*, vol. 15, no. 22, p. 8602, 2022. doi: [10.3390/en15228602](https://doi.org/10.3390/en15228602)

[3] G. Espinosa, J. R. Trapero, and D. Sáez, "Short-term solar power forecasting using machine learning algorithms," *IEEE Trans. Sustain. Energy*, vol. 11, no. 3, pp. 1645–1653, 2020.

[4] S. Sharma, P. Kakkar, and A. Sharma, "Solar power forecasting using deep learning techniques," *Renew. Energy*, vol. 156, pp. 547–558, 2020.

[5] M. R. Ahmed, M. S. Hossain, and M. A. Rahman, "Machine learning models for solar energy prediction: A comparative study," *Energy Reports*, vol. 7, pp. 704–712, 2021.

[6] J. Zhang, Y. Zhao, and L. Zhang, "Hybrid machine learning models for solar power forecasting," *Appl. Energy*, vol. 280, p. 115955, 2020.

[7] A. Alzahrani, M. Shamsi, and P. Ferdowsi, "Solar irradiance forecasting using machine learning: A case study in Saudi Arabia," *Renew. Sustain. Energy Rev.*, vol. 131, p. 109968, 2020.

[8] R. Kumar, S. Aggarwal, and J. Sharma, "A comprehensive review of machine learning techniques for solar energy prediction," *Energy Convers. Manage.*, vol. 199, p. 111953, 2019.