

استخدام تحليل السلاسل الزمنية الإحصائية وخوارزميات التعلم العميق في التنبؤ بالإشعاع الشمسي وسرعة الرياح

أ.د. محسن داود *

د. سامر سليمان **

م. رشوان أمون ***

(تاريخ الإيداع ٢٠٢٣/٥/١٠ . قُبِلَ للنشر في ٢٠٢٤/١/٣١)

□ ملخص □

يعرض هذا البحث عمليات التنبؤ بكل من الإشعاع الشمسي وسرعة الرياح باستخدام تحليل السلاسل الزمنية الإحصائية وخوارزميات التعلم العميق لمدينة حمص في سورية، وذلك استناداً إلى بيانات مأخوذة كل ساعة للإشعاع الشمسي وسرعة الرياح. تفيد هذه التنبؤات في تقدير الطاقة المولدة من الخلايا الكهروضوئية والعنفات الريحية لزمن محدد عند تصميم أنظمة التحكم الخاصة بأنظمة الطاقة المتجددة الهجينة. استخدم في عمليات التنبؤ عدة طرق تعتمد جميعها على تحليل السلاسل الزمنية، وأجريت عمليات المقارنة فيما بينها لتحديد الخوارزمية والمنهجية التي تعطي نتائج أفضل باستخدام برنامج Jupyter. استخدمت في البداية طريقة نموذج الانحدار الذاتي المتكامل المتحرك (ARIMA) وبيّنت النتائج أنها قادرة على التنبؤ ولكن ضمن فترة زمنية قصيرة. ثم استخدمت طريقة (FbProphet) Facebook Prophet التي أثبتت قدرتها على التنبؤ لفترات زمنية أطول. أخيراً استخدمت خوارزميات التعلم العميق في تحليل السلاسل الزمنية مثل الشبكات العصبية المتكررة ذات الذاكرة طويلة وقصيرة المدى (LSTM)، والشبكات العصبية المتكررة ذات البوابات (GRU)، والشبكات العصبية الالتفافية (CNN). أعطت هذه الخوارزميات نتائج أكثر دقة من طريقتي Arima و FbProphet وكانت قادرة على التنبؤ لفترات زمنية طويلة وبدقة أفضل.

الكلمات المفتاحية: الأنظمة الهجينة، الإشعاع الشمسي، سرعة الرياح، السلاسل الزمنية، التعلم العميق.

*أستاذ في قسم هندسة الميكاترونيك - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين.

**مدرس في قسم هندسة الحاسبات - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين.

*** طالب دراسات عليا (دكتوراه) - قسم هندسة الميكاترونيك - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين.

Using Statistical Time Series Analysis and Deep Learning Algorithms for Predicting Solar Radiation and Wind Speed

Prof. Mohsen Daood^{*}

Dr .Samer Sulaiman^{**}

Rashwan Ammon^{***}

(Received 10/5/2023 . Accepted 31/1/2024)

□ ABSTRACT □

This paper deals with the predictions of solar radiation and wind speed using statistical time series analysis and deep learning algorithms. The dataset used in this paper based on hourly data for solar radiation and wind speed for Homs city in Syria. These predictions are useful for estimating the power generated by photovoltaic cells and wind turbines at a specific time for designing the hybrid renewable energy control systems. Different forecasting methods are used, based on time series analysis. To determine the algorithm and methodology that gives the best results, analytical comparisons are done between them by using Jupyter program. The first proposed method is the auto regressive integrated moving average (ARIMA) method. The results show that, it is able to predict within only a short period of time. The second one is Facebook Prophet (FbProphet) method, which proves its ability to predict longer periods of time. The last method is the deep learning algorithms based in Analysing time series such as Long and Short Term Memory Recurrent Neural Networks (LSTM), Gated Recurrent Neural Networks (GRU), and Convolutional Neural Networks (CNN). These algorithms give more accurate and precision results than other investigated methods and are able to predict long time periods.

Keywords: Hybrid Systems, Solar Radiation, Wind Speed, Time Series, Deep Learning.

^{*}Professor-Department of Mechatronic Engineering- Faculty of Mechanical and Electrical Engineering-Tishreen University.

^{**}Univwersity Teacher-Department of computers Engineering- Faculty of Mechanical and Electrical Engineering-Tishreen University.

^{***}Postgraduate Student-Department of Mechatronic Engineering- Faculty of Mechanical and Electrical Engineering-Tishreen University.

١- مقدمة :

دفع تغير المناخ والاحتباس الحراري والتلوث الحاصل في جميع أنحاء العالم العلماء والباحثين إلى البحث عن خيارات طاقة تكون نظيفة بيئياً، كما أن صعوبة تأمين الوقود الأحفوري شجع الدول إلى الاتجاه نحو مصادر طاقة مستدامة لا تتضرب مع الزمن، فكانت مصادر الطاقة المتجددة البديل المناسب لحل هاتين المشكلتين. تعتبر الطاقة الشمسية وطاقة الرياح أهم مصدرين من مصادر الطاقة المتجددة، وذلك لأنه يمكن الاستفادة منها بشكل فعال والحصول منها على كميات طاقة كبيرة نسبياً مقارنة بالمصادر الأخرى، ولكن استخدام هذه المصادر ليس بالأمر السهل وذلك لطبيعتها المتغيرة والعشوائية مع الزمن، وهذا ما دفع الكثير من الباحثين إلى البحث عن سبل يمكن من خلالها التنبؤ ببارامترات الطقس كالإشعاع الشمسي وسرعة الرياح لمعرفة كمية الطاقة التي يمكن توليدها خلال زمن محدد، وبالتالي الاستفادة من هذه المعرفة المسبقة عند تصميم أنظمة التحكم لنظم الطاقة المتجددة الهجينة بشكل خاص [1]. يقدم هذا البحث عدة طرق ومنهجيات تعتمد على تحليل السلاسل الزمنية الإحصائية وخوارزميات التعلم العميق لتحقيق تنبؤ دقيق لكل من الإشعاع الشمسي وسرعة الرياح في مدينة حمص في سوريا .

يمكن تقسيم هذا البحث إلى ثلاثة محاور: يعالج المحور الأول بعض الدراسات المرجعية ذات الصلة، بينما يعالج المحور الثاني الطرق والخوارزميات المستخدمة في عمليات التنبؤ. نوقش في المحور الثالث نتائج كل طريقة من الطرق المقترحة في هذا البحث، وقورنت هذه النتائج من حيث دقة التنبؤ ومدة التنبؤ. تُختم هذه الدراسة بتقديم بعض الاستنتاجات والتوصيات المستقبلية .

٢-الدراسات المرجعية:

أشار الباحثون في المرجع [1] إلى أن التغير في الإشعاع الشمسي له تأثير على استقرار الأنظمة الكهروشمسية، لذلك يعد التنبؤ الدقيق بالطاقة الشمسية أمراً بالغ الأهمية لتكامل نظام الطاقة. استخدم في هذا البحث نموذج الشبكات العصبية المتكررة ذات الذاكرة طويلة وقصيرة المدى LSTM (Long and Short Term Memory) و نموذج الشبكات العصبية الالتفافية CNN (Convolutional Neural Networks) للتنبؤ بالإشعاع الشمسي في مدينة أبو ظبي في الإمارات العربية المتحدة، وأشار الباحثون إلى تفوق خوارزميات التعلم العميق، حيث أظهرت نتائجهم أن نموذج LSTM تميز بأداء أفضل من نموذج CNN .

قُدّم في المرجع [2] عدة نماذج باستخدام السلاسل الزمنية بغرض التنبؤ بالاستهلاك المستقبلي لمادة الغراء اللاصقة. كان الهدف هو دراسة إمكانية استخدام البيانات مع هذه النماذج لتحسين إدارة المخزون. اعتمد في هذا البحث بشكل أساسي على نموذج ARIMA (Auto Regressive Integrated Moving Average) و نموذج FbProphet (Facebook Prophet) ونموذج LSTM وأجري الاختبار على نوعين من البيانات، الأولى أخذت عيناتها بدقة يوم واحد، بينما أخذت العينات في النوع الثاني بدقة ثلاث ساعات، وخلصت النتائج إلى أن البيانات بدقة يوم واحد كانت كافية للتنبؤ الجيد بالاستهلاك، وقد قدمت جميع هذه النماذج نتائج مرضية .

أشار الباحث في المرجع [3] إلى أنه يمكن النظر في التنبؤ بطاقة الرياح بشكل عام على أنها مسألة تحليل سلسلة زمنية أحادية المتغير. كما أشار إلى أنه قد يكون من الصعب نمذجة أنماط سرعة الرياح باستخدام نماذج السلاسل الزمنية القياسية مثل ARIMA، وأكد على أن الخوارزميات القائمة على الشبكات العصبية تستطيع التعامل مع هذه الصعوبات بشكل أكثر كفاءة، حيث أظهرت نتائج التقييم أن نهج الشبكات العصبية يعمل بشكل أفضل، وأشار أيضاً إلى أن تنبؤات نموذج FbProphet كانت أيضاً واعدة.

تعامل المرجع [4] مع أربعة نماذج مختلفة لتحليل السلاسل الزمنية، وهي نموذج ARIMA ، ونموذج FbProphet ، ونموذج الذاكرة طويلة وقصيرة المدى (LSTM)، ونموذج المحول (Transformer) ، لتحديد النموذج الذي يمتلك الأداء الأفضل للتنبؤ باتجاهات الحالة المستقبلية (صعوداً أو هبوطاً) لمرض COVID-19 في ستة بلدان، وأظهرت النتائج أن نموذج LSTM بشكل عام لديه أفضل أداء لجميع البلدان، أما نموذج المحول فلديه ثاني أفضل أداء مع نتائج مرضية للغاية في بعض البلدان، والنماذج الأخرى لديها أداء ضعيف.

قدم الباحثون في المرجع [5] دراسة كان الهدف الرئيسي منها هو التنبؤ بسرعة الرياح باستخدام نموذج LSTM ، وأجريت المقارنة التحليلية مع نموذج SVM (Support Vector Machine)، وأشار الباحثون إلى أن كلاً من هذين النموذجين يتبعان لنهج التعلم الآلة، ولكن لهما وظائف مختلفة مقارنة ببعضهما البعض، أجريت هذه المقارنة للحصول على النموذج الأفضل الذي يمكن تطبيقه فيما بعد على كمية بيانات أكبر لتصميم نموذج تنبؤ دقيق لسرعة الرياح، وبينت النتائج أن نموذج LSTM أكثر فعالية من نموذج SVM.

قدم الباحثون في المرجع [6] دراسة من أجل تقييم مستويات تلوث الهواء والتنبؤ بكميات غاز أحادي أكسيد الكربون، حيث استخدمت بيانات لغاز أحادي أكسيد الكربون بفواصل زمنية مقدارها ست ساعات، وطبقت خوارزميتي ARIMA و LSTM، وتوصل الباحثون بعد مقارنة النتائج أن منهجية ARIMA كانت أكثر دقة في التنبؤات من منهجية LSTM.

يلاحظ من الدراسات المرجعية السابقة أن معظم الدراسات أشارت إلى أن نماذج التعلم العميق في تحليل السلاسل الزمنية كانت أكثر كفاءة من الطرق الإحصائية، مع وجود بعض الاستثناءات في بعض الدراسات، وهذا يعود لاختلاف طبيعة البيانات المدروسة وحجمها، وأيضاً يعود إلى خبرة الباحث في ضبط بارامترات كل نموذج .

٣- أهمية البحث وأهدافه:

يهدف هذا البحث إلى تقديم أفضل الطرق للتنبؤ بالإشعاع الشمسي وسرعة الرياح باستخدام السلاسل الزمنية الإحصائية وخوارزميات التعلم العميق، حيث استخدم برنامج Jupyter ولغة بايثون لتحقيق ذلك، وتأتي أهمية هذه التنبؤات بأنها تساعد في تحديد كمية الطاقة المولدة من الخلايا الكهروضوئية والعنفات الريحية في أنظمة الطاقة المتجددة الهجينة، مما يساعد في تحقيق الاستغلال الأمثل لموارد أنظمة الطاقة المتجددة الهجينة .

٤- طرائق البحث ومواده :

أخذت بيانات الإشعاع الشمسي وسرعة الرياح لمدينة حمص السورية من موقع Solar Radiation Data الذي يعطي بيانات مقاسة عن طريق وكالة الفضاء ناسا[7]. أخذت عينات البيانات كل ساعة لحساب تنبؤات دقيقة لمدة ثلاث سنين، ثم استخدم برنامج Jupyter ولغة بايثون لتحقيق خوارزميات التنبؤ، وقد اتبع في هذا البحث نهج الطريقة التحليلية في تحليل السلاسل الزمنية بالإضافة إلى النهج الاستقرائي في الحصول على القيم المتنبأ بها .

٥- نمذجة السلاسل الزمنية:

تعد نمذجة السلاسل الزمنية مجال بحث ديناميكي لجذب انتباه الباحثين على مدى العقود القليلة الماضية، حيث يكون الهدف الرئيسي من نمذجة السلاسل الزمنية جمع العينات السابقة لسلسلة زمنية ودراساتها بدقة لتطوير نموذج مناسب يصف الهيكل الأساسي للسلسلة، ليتم استخدامه في توليد القيم المستقبلية للسلسلة. يمكن وصف التنبؤ بالسلاسل الزمنية بأنه فعل التنبؤ بالمستقبل من خلال فهم الماضي. تستخدم السلاسل الزمنية في العديد من المجالات العملية مثل الطب والاقتصاد والعلوم والهندسة، وبسبب أهمية هذه العلوم ودقتها ينبغي العمل على تكوين نموذج يلائم السلسلة الزمنية المدروسة لأن التنبؤ الناجح للسلسلة يعتمد بشكل أساسي على إعداد نموذج مناسب، لذلك بذل الباحثون الكثير من الجهود على مدار سنوات عديدة لتطوير نماذج فعالة لتحسين دقة التنبؤ، ونتيجة لذلك طورت نماذج مهمة للتنبؤ بالسلاسل الزمنية [2].

تتأثر السلسلة الزمنية بشكل عام بأربع مكونات رئيسية وهي الاتجاه (Trend)، والموسمية (Seasonal)، والدورية (Cyclical)، والخطأ (Irregular). يُطلق على التوجه العام لسلسلة زمنية - أي الزيادة أو النقصان أو الركود لفترة زمنية طويلة - اسم الاتجاه، أما الموسمية في سلسلة زمنية فهي التقلبات التي يمكن ملاحظتها في عام وتكون هذه التقلبات غالباً بسبب اختلاف فصول السنة، بينما تصف التباينات الدورية في سلسلة زمنية التغيرات متوسطة المدى في السلسلة الناتجة عن الظروف، والتي تتكرر في دورات تمتد على مدى فترة زمنية أطول، عادة ما تكون عامين أو أكثر. يشير مكون الخطأ إلى الاختلافات غير المنتظمة أو العشوائية في سلسلة زمنية التي تكون ناتجة عن تأثيرات غير متوقعة، وهي ليست منتظمة ولا تتكرر أيضاً في نمط معين [2].

٥-١-١ نموذج الانحدار الذاتي المتكامل المتحرك (ARIMA):

يعتبر هذا النموذج أحد نماذج السلاسل الزمنية العشوائية الأكثر شيوعاً والأكثر استخداماً. إن الافتراض الأساسي لهذا النموذج هو أن السلاسل الزمنية المدروسة خطية وتتبع توزيعاً إحصائياً معروفاً مثل التوزيع الطبيعي [3]. يحتوي نموذج ARIMA على فئات فرعية من النماذج الأخرى مثل نموذج الانحدار التلقائي (AR)، ونموذج متوسط المتحرك (MA)، ونموذج متوسط الانحدار التلقائي (ARMA)، ونموذج (SARIMA) الذي يتعلق بالتنبؤ بالسلاسل الزمنية الموسمية. يعد نموذج ARIMA تعميماً لنموذج ARMA ليشمل حالة عدم الاستقرار أيضاً. يتم جعل السلاسل الزمنية غير المستقرة في نماذج ARIMA لتصبح مستقرة من خلال تطبيق فروق لنقاط البيانات. يمكن تصور مفهوم استقرار العملية الإحصائية العشوائية كشكل من أشكال التوازن الإحصائي [2]. تكون الخصائص الإحصائية لعملية مستقرة، مثل المتوسط (mean) والتباين (variance) والتغاير (covariance)، ثابتة ولا تتغير بتغير الزمن، والذي يعتبر شرط ضروري لبناء نموذج سلسلة زمنية يكون مفيداً للتنبؤ في المستقبل، بالإضافة إلى أنه يقلل التعقيد الرياضي للنموذج [2,4].

٥-١-١-١ اختبار Dickey-Fuller المُعزَّز (ADF):

يمكن استخدام هذا الاختبار على سلسلة زمنية للتحقق من استقرارها، وهو قادر على التعامل مع مواقف أكثر تعقيداً من اختبار Dickey-Fuller الأصلي. يوفر الاختبار طريقة لتحديد ما إذا كانت السلسلة ذات جذر وحدة (unit root)، أي إذا كان معامل الانحدار بين عيّنتين (Y_t و Y_{t-1}) يساوي الواحد، مما يعني أنها ليست مستقرة، ويمكن أن تسبب نتائج غير متوقعة عند التنبؤ بهذه السلسلة [2]. تتطلب جميع النماذج تقريباً أن تكون البيانات مستقرة، لذلك فهي خطوة مهمة جداً في التنبؤ بالسلاسل الزمنية. تُعتمد هنا فرضية عدم لاختبار استقرار السلسلة الزمنية، ويكون ذلك عن طريق فرض أن السلسلة الزمنية

ذات جذر وحدة، وبالتالي فهي غير مستقرة والعمل على برهان نقض الفرضية، مما ينتج أن السلسلة مستقرة . تعتمد هذه الطريقة على حساب قيمة إحصائية تكون قيمتها سالبة، وبالتالي كلما كانت هذه القيمة أكثر سلبية زادت الثقة في أن الفرضية التي تم اختيارها خاطئة . تعتمد هذه الفرضية أيضاً على قيمة عددية أخرى يرمز لها بـ P ، حيث تعتبر هذه القيمة مقياساً آخر . من المتوقع أن تكون قيمة p بالنسبة للسلاسل الزمنية المستقرة أقل من ٠.٠٥ . تعتبر السلسلة الزمنية مستقرة إذا اتفقت قيمة كل من الرقم الإحصائي والقيمة p على هذا الأمر [2,4].

٥-١-٢- دالة الارتباط التلقائي ACF:

يقصد به إيجاد معامل ارتباط كل قيمة بعدد من القيم السابقة لها، وتوضح هذه الدالة فيما إذا كان الارتباط إيجابياً أم سلبياً أم صفرياً أي لا يوجد أي ارتباط [4].

٥-١-٣- دالة الارتباط الجزئي PACF :

يقيس الارتباط الجزئي في نظرية الاحتمالات والإحصاء معامل الارتباط بين اثنين من المتغيرات العشوائية مع إزالة تأثير المتغيرات العشوائية الأخرى. يعطي معامل الارتباط التلقائي نتائج غير دقيقة في حال كان الاهتمام بإيجاد علاقة عددية بين متغيرين مهمين إذا كان هناك متغيراً آخر مرتبطاً عددياً بهذين المتغيرين. ويمكن تجنب هذه المشكلة عن طريق التحكم في تأثير هذا المتغير، ويمكن ذلك عن طريق حساب معامل الارتباط الجزئي [2,4,6].
تكمُن أهمية الدالة التي الارتباط التلقائي والجزئي أنه يمكن من خلالهما تحديد نوع النموذج ودرجته، ونقصد بدرجته أي عدد التحويلات التي نجريها على النموذج لجعل السلسلة مستقرة [6].

٥-٢- نموذج FbProphet :

يستخدم في هذا النموذج السلاسل الزمنية مع ثلاث مكونات نموذجية رئيسية، وهي الاتجاه والموسمية والإجازات، ويتم دمجها في المعادلة الآتية [7]:

$$y(t) = g(t) + s(t) + h(t) + e(t) \quad (1)$$

حيث تمثل $y(t)$ خرج نموذج FbProphet، وتمثل $g(t)$ دالة الاتجاه التي تعبر عن التغيرات غير الدورية في قيمة السلسلة الزمنية، بينما تمثل $s(t)$ التغيرات الدورية مثل الموسمية الأسبوعية والسنوية، وتمثل $h(t)$ تأثيرات الإجازات، ويمثل مصطلح الخطأ $e(t)$ أي تغييرات خاصة لا يشملها النموذج.
لا يلزم في هذا النموذج أن تكون القياسات المأخوذة متباعدة بانتظام على عكس نماذج ARIMA ، ولسنا بحاجة إلى إزالة القيم المتطرفة، لأنه في هذا النموذج تتم الملاءمة بشكل سريع وفعال [2,8].

٥-٢-١- توقعات التشبع (saturating) :

يستخدم نموذج الـ Prophet تابعاً خطياً لتوقعاته عند التنبؤ بالنمو. وعادة ما يكون هناك حد أقصى يمكن تحقيقه كإجمالي حجم السوق وإجمالي حجم السكان، على سبيل المثال، وهذا ما يسمى القدرة الاستيعابية، ويجب أن تكون التوقعات مشبعة في هذه المرحلة. ويتيح تطبيق نموذج الـ Prophet إمكانية التنبؤ باستخدام نموذج نمو لا خطي أو خطي اتجاهي مع قدرة استيعابية محددة [8].

٥-٢-٢- نقاط تغيير الاتجاه (change points) :

معظم السلاسل الزمنية الحقيقية تحتوي على تغييرات مفاجئة في مساراتها، ويكتشف نموذج الـ Prophet تلقائياً نقاط التغيير هذه، ويسمح للاتجاه بالتكيف بشكل مناسب. يعطي نموذج الـ Prophet العديد من التعديلات للبيانات المدخلة للحصول على تحكم أكثر دقة [4,8].

٥-٢-٣-نمذجة الإجازات والمناسبات الخاصة:

يتيح نموذج ال Prophet إمكانية نمذجة إجازات أو أحداث أخرى متكررة، وذلك عن طريق إنشاء إطار بيانات لها. يجب أن يتضمن النموذج جميع تكرارات الإجازات، سواء في الماضي أو في المستقبل. وبالتالي تظهر تأثيرات الإجازات أيضاً في مخطط المكونات [4,8].

٥-٢-٤-الموسمية (seasonality):

يتناسب نموذج ال Prophet بشكل افتراضي مع المواسم الأسبوعية والسبوعية، كما أنها تتناسب الموسمية اليومية لسلسلة زمنية فرعية يومية. كما يتيح إمكانية إضافة مواسم أخرى (شهرية، ربع سنوية، كل ساعة) [8].

٥-٢-٥- فترات عدم اليقين (Uncertainty):

يعيد نموذج ال Prophet فترات عدم اليقين للتنبؤات. وهناك ثلاثة مصادر لعدم اليقين في التنبؤ، وهي عدم اليقين في الاتجاه، وعدم اليقين في تقديرات الموسمية، وضجيج العينات الإضافية. إن أكبر مصدر لعدم اليقين في التوقعات هو احتمال تغير الاتجاه في المستقبل. تُظهر السلاسل الزمنية الحقيقية تغيرات واضحة في الاتجاه في البيانات في الماضي. ويكون نموذج ال Prophet قادر على اكتشافها وملاءمتها، حيث يفترض أن المستقبل سيشهد تغيرات مماثلة في الاتجاه مثل التغيرات الحاصلة في الماضي [4,8,9].

٥-٣- استخدام خوارزميات التعلم العميق في تحليل السلاسل الزمنية:

٥-٣-١: الشبكات العصبية الالتفافية (Convolutional Neural Networks CNN):

إن شبكات CNN بشكل عام هي شبكات عصبية مع عملية محددة تشبه ترشيح الصورة في مجال رؤية الآلة. تنفذ عملية الترشيح من الناحية الرياضية بشكل مشابه لعملية انطواء (التفاف) مقطع، لذلك سميت شبكات عصبية الالتفافية [10]. يوجد لهذه الشبكات ثلاثة أنواع مستخدمة، وهي 1D و 2D و 3D. إن النوع الأول يستخدم بشكل رئيسي مع البيانات الجدولية، وهذا النوع هو المستخدم في هذا البحث، بينما النوعين الثاني والثالث غالباً ما يستخدم في مهام تصنيف الصور والفيديو [10,11].

٥-٣-٢: الشبكات العصبية المتكررة (Recurrent Neural Networks RNN):

يمكن أن يكون التتابع الموجود في البيانات ذا أهمية كبيرة في كثير من الحالات، مثل معالجة اللغات الطبيعية والتعرف على الكلام والتعرف على خط اليد أو حتى توقع أسعار البورصات [5]. لكن في الشبكات العصبية العادية يمكن أن تنتقل معلومات كل طبقة فقط إلى الطبقة التالية، وتكون معالجة المعلومات لكل خطوة زمنية مستقلة، وبالتالي لا يمكنها نمذجة المعلومات المتتابعة، لحل هذه المشكلة طرحت الشبكات العصبية المتكررة RNN. تعالج هذه الشبكات عنصراً واحداً من سلسلة مدخلات متتابعة في كل مرة وبخطوات زمنية منفصلة، وتختلف بذلك عن الشبكات العصبية العادية وعن الشبكات الالتفافية [5,12].

٥-٣-١-٢- الشبكات المتكررة ذات الذاكرة طويلة وقصيرة المدى (long-short term LSTM):

:(memory)

اقترحت بنية هذه الشبكات في عام ١٩٩٧ لمنع مشكلة التبعية طويلة المدى لشبكة عصبية متكررة عادية. تقوم وحدة LSTM بنمذجة المعلومات بناءً على وحدة RNN عادية لكن تكمن الاختلافات في هذه البنية أن المعلومات تتدفق عبر خلية الحالة كما لو أنها تتدفق عبر حزام ناقل. هناك ثلاثة مكونات أخرى أيضاً وهي بوابة النسيان وبوابة الدخل وبوابة الخرج. تحدد بوابة النسيان القيم التي يجب تخزينها أو نسيانها [4,12,13]، ويعبر عنها بالمعادلة الآتية [13]:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

حيث تمثل f_t بوابة النسيان، σ : تابع التفعيل (sigmoid)، W_f : أوزان بوابة النسيان، b_f : مقدار الإزاحة في بوابة النسيان، h_{t-1} : حالة الطبقة المخفية السابقة، $x(t)$: قيم الدخل الحالي .

كما تحتوي على بوابة الدخل التي هي عبارة أيضاً عن تابع sigmoid تكون وظيفته تحديد القيم التي يجب أن تحدث وهي تعطى بالمعادلة الآتية [13]:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

حيث تمثل i_t بوابة الدخل، σ : تابع التفعيل (sigmoid)، W_i : أوزان بوابة الدخل، b_i : مقدار الإزاحة في بوابة الدخل، h_{t-1} : حالة الطبقة المخفية السابقة، $x(t)$: قيم الدخل الحالي .

وتحتوي بوابة الدخل أيضاً على تابع الظل الزائدي $\tanh$ الذي يوجد شعاع آخر $\tilde{c}_t$ يحدد القيم الجديدة المرشحة للعبور وهو يعطى بالمعادلة الآتية [13]:

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

حيث W_c و b_c هي إزاحات وأوزان خلية الذاكرة الحالية على التوالي.

تحتسب القيم الفعلية التي يجب أن تحدث بالمعادلة الآتية [13]:

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (5)$$

حيث تمثل c_t حالة الخلية الحالية، وتمثل c_{t-1} حالة الخلية السابقة، ونحصل على f_t من بوابة النسيان، ونحصل على i_t من بوابة الدخل.


في النهاية توجد بوابة الخرج التي تحسب حالة الطبقة المخفية الحالية h_t عن طريق حساب حالة الخرج o_t التي تحسب بدورها باستخدام تابع الظل الزائدي ($\tanh$) كما هو موضح في المعادلتين (6) و (7) [13]، وقد أضيفت هذه البوابات الثلاثة للتحكم في إزالة وإضافة المعلومات [4,13].

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

حيث W_o و b_o هي إزاحات وأوزان بوابة الخرج على التوالي.

$$h_t = o_t * \tanh(c_t) \quad (7)$$


يوضح الشكل (١) بنية خلية LSTM التي تشمل البوابات الثلاث التي تم ذكرها.



الشكل (١) بنية خلية LSTM واتجاه تتدفق المعلومات [2].

٥-٣-٢- الشبكات العصبية المتكررة ذات البوابات (Gated Recurrent Units GRU):


طرح هذا النموذج في عام ٢٠١٤. تدمج في هذا النموذج كل من بوابتي النسيان والدخل ببوابة وحيدة تسمى بوابة التحديث. يكون هذا النموذج بشكل عام أبسط من الشبكات المتكررة ذات الذاكرة طويلة وقصيرة المدى (LSTM)، وتوفر الكثير من الوقت عندما تكون بيانات التدريب كبيرة [9,14]. يبين الشكل (٢) نموذج الشبكة العصبية ذات البوابات (GRU).




الشكل (٢) بنية خلية الشبكة العصبية ذات البوابات (GRU) [9].

٦- البيانات المستخدمة:

يبين الشكلين (٣) و (٤) كل من مخططي الإشعاع الشمسي وسرعة الرياح لبيانات مدينة حمص السورية، البيانات مقاسة كل ساعة منذ بداية عام ٢٠٠٤ إلى نهاية عام ٢٠٠٦ وهي بيانات قديمة بعض الشيء ولكنها استخدمت في هذا البحث لأنها متوفرة بشكل مجاني وتفي بالغرض [7]. نلاحظ من هذه البيانات عدم وجود اتجاه لها، وأن التباين والتغاير ثابتين تقريباً، وبالتالي في الغالب ستكون هاتين السلسلتين مستقرتين كما سنرى لاحقاً. ستستخدم هذه البيانات في تدريب النماذج المقترحة.



الشكل (٣) الإشعاع الشمسي لمدينة حمص السورية.



الشكل (٤) سرعة الرياح لمدينة حمص السورية.


٧- النتائج والمناقشة :

تم مناقشة نتائج تطبيق نماذج ARIMA و FbProphet و CNN1D و LSTM و GRU على بيانات الإشعاع الشمسي وسرعة الرياح لمدينة حمص المعروضة في الشكلين (٣) و (٤) .


١-٧- نتائج تطبيق نموذج ARIMA:

أ- الإشعاع الشمسي :

يجرى اختبار الاستقرار (Dickey-Fuller) للسلسلة الزمنية الخاصة بالإشعاع الشمسي فتنتج قيمة $p=0.01$ أقل من ٠.٠٠٥، أي أن السلسلة مستقرة، وللتأكد من ذلك يرسم مخطط ACF الذي يظهر في الشكل (٥)، حيث يشير المحور الأفقي (Lag) إلى العينات السابقة، يلاحظ الشكل الموجي للعينات المهمة وأنه يوجد عدة عينات مهمة، وهذا يعني أنه يجب استخدام إما نموذج ARMA أو ARIMA، وبالتالي تؤخذ قيمة $d_A=0$ حيث يعبر الرمز d_A فيما إذا كانت السلسلة مستقرة أم تحتاج إلى تحويل من خلال تطبيق فروق لنقاط البيانات لتصبح مستقرة، وهنا أخذت القيمة صفر أي أن السلسلة مستقرة ولا تحتاج إلى عملية تحويل، ومن ثم من مخطط PACF المبين في الشكل (٦) تحدد قيمة كل من $p_A=q_A=2$ لأنه يوجد عینتين مهمتين فقط غير العينة الأولى التي تحدد ارتباط العينة مع نفسها، حيث يحدد الرمز p_A عدد العينات السابقة المرتبطة مع القيمة الحالية ارتباطاً موجباً، بينما يحدد الرمز q_A عدد العينات السابقة المرتبطة مع القيمة الحالية ارتباطاً سالباً، وللتأكد من صحة هذه القيم تم تمرير قيم مختلفة لكل من d_A ضمن المجال (0-3) و p_A, q_A ضمن المجال (0-5) ، وذلك لتحديد القيم الأفضل التي تجعل قيمة الخطأ أقل ما يمكن، فكانت النتائج مطابقة للقيم السابقة أي أن $d_A=0$ ، $p_A=q_A=2$.




الشكل (٥) مخطط ACF للإشعاع الشمسي.



الشكل (٦) مخطط PACF للإشعاع الشمسي.

يبين الشكل (٧) نتيجة التوقعات للإشعاع الشمسي لـ ١٤ ساعة باستخدام نموذج ARIMA ، حيث يمثل الخط الأحمر القيم الفعلية والخط الأزرق القيم المتوقعة. يظهر تقارب الخطين نسبياً ولا بد من الإشارة إلى صعوبة التوقعات ببارامترات الطقس بشكل عام في السلاسل الزمنية الإحصائية.




الشكل (٧) توقعات الإشعاع الشمسي لـ ١٤ ساعة باستخدام نموذج ARIMA.

تم حساب خطأ متوسط جذر المربعات (Root Mean Square Error) وكانت قيمته $RMSE = 210.595$. يبين

الشكل (٨) توقعات الإشعاع الشمسي لـ ٢٠٠ ساعة بواسطة نموذج ARIMA، وبحساب قيمة $RMSE$ تكون 338.123


وبلاحظ أنها أكبر بشكل ملحوظ من القيمة السابقة، ومنه نستنتج ضعف هذه النماذج في التنبؤ لفترات طويلة في المستقبل، ولذلك يكون هذا النوع جيد للتنبؤ بفترات قصيرة فقط.




الشكل (٨) توقعات الإشعاع الشمسي لـ ٢٠٠ ساعة باستخدام نموذج ARIMA.

ب- سرعة الرياح :

يجرى اختبار الاستقرار للسلسلة الزمنية الخاصة بسرعة الرياح فتكون قيمة $p=0.04$ أيضاً أقل من ٠.٠٥ أي أن السلسلة مستقرة، وللتأكد من ذلك يرسم مخطط ACF الذي يظهر في الشكل (٩)، وبالتالي تؤخذ قيمة $d_A=0$ ، ومن ثم من مخطط PACF المبين في الشكل (١٠) يحدد قيمة كل من $p_A=q_A=3$ لأنه يوجد ثلاث عينات مهمة، وبالتالي تكون قد حددت بارامترات نموذج ARIMA، وبنفس الطريقة الموضحة سابقاً تم التأكد من صحة هذه القيم.




الشكل (٩) مخطط ACF لسرعة الرياح.




الشكل (١٠) مخطط PACF لسرعة الرياح.

يبين الشكل (١١) نتيجة التوقعات لسرعة الرياح لـ ١٤ ساعة باستخدام نموذج ARIMA ، حيث يظهر تقارب الخطئين نسبياً، وبحساب خطأ متوسط جذر المربعات تكون قيمته $RMSE = 1.114$.



الشكل (١١) توقعات سرعة الرياح لـ ١٤ ساعة باستخدام نموذج ARIMA.

يبين الشكل (١٢) توقعات سرعة الرياح لـ ٢٠٠ ساعة بواسطة نموذج ARIMA، وبحساب قيمة $RMSE$ تكون 1.926. ويلاحظ أنها أكبر من القيمة السابقة، ومنه نستنتج ضعف هذه النماذج في التنبؤ لفترات طويلة في المستقبل، ولذلك يكون هذا النوع جيد للتنبؤ بفترات قصيرة فقط.




الشكل (١٢) توقعات سرعة الرياح لـ ٢٠٠ ساعة باستخدام نموذج ARIMA.

٢-٧ - نتائج تطبيق نموذج FbProphet :

تم ضبط هذا النموذج ليأخذ تابع نمو من النوع (Logistic)، وضبط بارامتر (interval-width) الذي يمثل نسبة فترات عدم اليقين في الاتجاه والموسمية ليأخذ القيمة 0.95، وتم تحديد مجال وجود نقاط تغير الاتجاه (change point range) بقيمة ٠.٦، وضبط البارامتران (daily-seasonality) و (yearly-seasonality) اللذان يمثلان التغيرات الدورية اليومية والسنوية ليأخذ القيمة True، وضبط بارامتر (changepoint.prior.scale) الذي يعطي مرونة لاختيار نقاط تغير الاتجاه بشكل تلقائي ليأخذ القيمة ٠.٠٥، وضبط بارامتر (seasonality.prior.scale) الذي يعبر عن مدى كمية وجود تغيرات موسمية ليأخذ القيمة ١١ حيث كلما زاد هذا الرقم دل ذلك على زيادة وجود تغيرات موسمية.

أ- الإشعاع الشمسي :


يظهر الشكل (١٣) نتائج التنبؤ بالإشعاع الشمسي لمدة ٢٠٠ ساعة. يلاحظ من هذا الشكل أن نموذج FbProphet استطاع أن يتنبأ بفترة زمنية طويلة، وبحساب قيمة RMSE تكون مساوية لـ 133.658. يلاحظ أن هذه القيمة أقل من قيمة RMSE لنموذج ARIMA عند التنبؤ بالإشعاع الشمسي، وهذا ما يؤكد على أن دقة هذا النموذج في التنبؤات أفضل من نموذج ARIMA.



الشكل (١٣) توقعات الإشعاع الشمسي لمدة ٢٠٠ ساعة باستخدام نموذج FbProphet.

ب- سرعة الرياح :

يظهر الشكل (١٤) نتائج التنبؤ بسرعة الرياح لمدة ٢٠٠ ساعة، ويلاحظ هنا أن هذا النموذج استطاع أيضاً أن يتنبأ بالقيم لمدة طويلة وبدقة أفضل من نموذج ARIMA، وبحساب قيمة RMSE تكون قيمته ١.٥٤٢، أي أقل من نموذج ARIMA عند التنبؤ لمدة ٢٠٠ ساعة .



الشكل (١٤) توقعات الإشعاع الشمسي لمدة ٢٠٠ ساعة باستخدام نموذج FbProphet.


٧-٥ - نتائج تطبيق نموذج CNN1D:

يمكن أن يستفاد من خصائص السلسلة الدورية عند تطبيق خوارزميات التعلم العميق، لذلك يحسب تابع الـ sine و الـ cosine لكل من الأيام والسنين وتؤخذ كمداخل إضافة لبارامترات الإشعاع الشمسي وسرعة الرياح، لذلك تعتبر السلسلة الزمنية في هذه الحالة متعددة المتغيرات. يضبط هذا النموذج بحيث يتكون من طبقة مدخلات، ثم طبقة التلافية conv1D تتألف من ٦٤ خلية، ويكون حجم النافذة المتحركة (Kernel_size) مساو لـ ٢، وتابع التفعيل (activation) هو من النوع Relu، ثم طبقة flatten للحصول على شعاع ببعد واحد، ثم طبقة أخرى (Dense) بثمان خلايا وتابع تفعيل من النوع Relu، ثم طبقة

أخرى (Dense) وهي تمثل طبقة الخرج، وتتكون من خليتين واحدة للتنبؤ بالإشعاع الشمسي والأخرى للتنبؤ بسرعة الرياح، ويكون تابع التفعيل لها من النوع Linear. أخذت نسبة التدريب (learning rate) مساوية للقيمة ٠.٠٠٠٠١، وقيمة التكرارات (epochs) مساوية لـ ١٠.

أ- الإشعاع الشمسي :

يبين الشكل (١٥) تنبؤات الإشعاع الشمسي عند تطبيق نموذج CNN1D على بيانات الإشعاع الشمسي:




الشكل (١٥) توقعات الإشعاع الشمسي لـ ٢٠٠ ساعة باستخدام نموذج CNN1D.

يلاحظ أن قيم التنبؤ قريبة جداً من القيم الفعلية والنموذج تنبأ لمدة ٢٠٠ ساعة، وبحساب قيمة RMSE تكون مساوية لـ 17.921، يلاحظ أن هذه القيمة أقل بكثير من قيم RMSE لنموذجي ARIMA و FbProphet، أي أن هذا النموذج تفوق على النموذجين السابقين.

ب- سرعة الرياح:

يبين الشكل (١٦) تنبؤات سرعة الرياح عند تطبيق نموذج CNN1D على بيانات سرعة الرياح:



الشكل (١٦) توقعات سرعة الرياح لـ ٢٠٠ ساعة باستخدام نموذج CNN1D.


يبين هذا الشكل كفاءة هذا النموذج مقارنة بالنموذجين السابقين، فالقيم المتوقعة قريبة جداً من القيم الفعلية وتكون قيمة RMSE مساوية لـ 0.259 وهي أقل من قيم RMSE لنموذجي ARIMA و FbProphet.

٣-٧ - نتائج تطبيق نموذج LSTM:

يُضبط هذا النموذج بحيث يتكون من طبقة مدخلات، ثم طبقة شبكة عصبية ذاكرة طويلة وقصيرة المدى (LSTM) تتألف من ٦٤ خلية، ثم طبقة أخرى (Dense) بثمان خلايا، وتابع تفعيل من النوع Relu، ثم طبقة أخرى (Dense) وهي تمثل طبقة الخرج، وتتكون من خليتين واحدة للتنبؤ بالإشعاع الشمسي والأخرى للتنبؤ بسرعة الرياح، ويكون تابع التفعيل لها من النوع Linear. أخذت نسبة التدريب (learning rate) مساوية للقيمة ٠.٠٠٠٠١، وقيمة التكرارات (epochs) مساوية لـ ١٠.

أ- الإشعاع الشمسي :

يبين الشكل (١٧) نتيجة تطبيق نموذج LSTM على الإشعاع الشمسي.




الشكل (١٧) توقعات الإشعاع الشمسي لـ ٢٠٠ ساعة باستخدام نموذج LSTM.

يلاحظ أن نموذج LSTM تمكن من التنبؤ بكفاءة بقيم الإشعاع الشمسي، حيث يبين الشكل (١٥) أن القيم المتوقعة قريبة جداً من القيم الفعلية مع إمكانية التنبؤ لفترات زمنية طويلة وتكون قيمة RMSE مساوية لـ 12.365 أي أنها أفضل من نموذج CNN1D.

ب- سرعة الرياح:

يبين الشكل (١٨) نتيجة تطبيق نموذج LSTM على سرعة الرياح .



الشكل (١٨) توقعات سرعة الرياح لـ ٢٠٠ ساعة باستخدام نموذج LSTM.


يلاحظ أيضاً أن قيم التنبؤ قريبة جداً من القيم الفعلية عند التنبؤ بسرعة الرياح، وقد تمكن النموذج من التنبؤ لفترات طويلة أيضاً وتكون قيمة RMSE مساوية لـ 0.274 وهي أكبر بقليل من قيمة RMSE لنموذج CNN1D، وبالتالي حقق نموذج CNN1D نتيجة أفضل عند التنبؤ بسرعة الرياح.

٧-٤ - نتائج تطبيق نموذج GRU:

يُضبط هذا النموذج بحيث يتكون من طبقة مدخلات، ثم طبقة شبكة عصبية متكررة ذات البوابات (GRU) تتألف من ٦٤ خلية، ثم طبقة أخرى (Dense) بثمان خلايا وتابع تفعيل من النوع Relu، ثم طبقة أخرى (Dense) وهي تمثل طبقة الخرج، وتتكون من خليتين واحدة للتنبؤ بالإشعاع الشمسي والأخرى للتنبؤ بسرعة الرياح، ويكون تابع التفعيل لها من النوع Linear. أخذت نسبة التدريب (learning rate) مساوية للقيمة ٠.٠٠٠٠١، وقيمة التكرارات (epochs) مساوية لـ ١٠.

أ - الإشعاع الشمسي :

يبين الشكل (١٩) تنبؤات الإشعاع الشمسي عند تطبيق نموذج GRU على بيانات الإشعاع الشمسي:




الشكل (١٩) توقعات الإشعاع الشمسي لـ ٢٠٠ ساعة باستخدام نموذج GRU.

يلاحظ أيضاً أن قيم التنبؤ قريبة جداً من القيم الفعلية على كامل الفترة الزمنية، وهذا ما يؤكد أيضاً كفاءة هذا النموذج وتكون قيمة RMSE مساوية لـ 13.610 . ومنه نستنتج أن نموذج GRU أفضل من نموذج CNN1D ولكنه أقل كفاءة بقليل من نموذج LSTM عند التنبؤ بالإشعاع الشمسي .

ب- سرعة الرياح:

يبين الشكل (٢٠) تنبؤات سرعة الرياح عند تطبيق نموذج GRU على بيانات سرعة الرياح:



الشكل (٢٠) توقعات سرعة الرياح لـ ٢٠٠ ساعة باستخدام نموذج GRU.

يلاحظ من الشكل (٢٠) أن النموذج قد تمكن من التنبؤ بقيم سرعة الرياح بكفاءة عالية ولمدة طويلة وتكون قيمة RMSE مساوية لـ 0.240 أي أنه أعطى نتيجة أفضل بقليل من النموذجين LSTM و CNN1D.

الاستنتاجات والتوصيات :

- تمكّن نموذج ARIMA من التنبؤ بالإشعاع الشمسي وسرعة الرياح ولكن لفترات زمنية محدودة .
- حقّق نموذج FbProphet تنبؤات بالإشعاع الشمسي وسرعة الرياح لفترات زمنية طويلة وبدقة جيدة، حيث تحسنت الدقة عن نموذج ARIMA بمقدار ٦٠.٤٧% بالنسبة للإشعاع الشمسي ونسبة ١٩.٩٤% بالنسبة لسرعة الرياح .
- قدّمت خوارزميات التعلم العميق (LSTM,GRU,CNN1D) تنبؤات دقيقة وفترات زمنية طويلة، وأثبتت أنها أكثر كفاءة من طريقتي ARIMA و FbProphet .
- حسنت خوارزمية CNN1D دقة التنبؤ بنسبة ٩٤.٦٩٩% عن خوارزمية ARIMA، ونسبة ٨٦.٥٩% عن خوارزمية FbProphet عند التنبؤ بالإشعاع الشمسي، وحسنت دقة التنبؤ بنسبة ٨٦.٥٥% عن خوارزمية ARIMA، ونسبة ٨٣.٢٠% عن خوارزمية FbProphet عند التنبؤ بسرعة الرياح.
- حسنت خوارزمية LSTM دقة التنبؤ بنسبة ٩٦.٣٤% عن خوارزمية ARIMA، ونسبة ٩٠.٧٥% عن خوارزمية FbProphet، ونسبة ٣١% عن خوارزمية CNN1D عند التنبؤ بالإشعاع الشمسي، وحسنت دقة التنبؤ

بنسبة ٨٥.٧٧% عن خوارزمية ARIMA، وبنسبة ٨٢.٢٣% عن خوارزمية FbProphet، ولكن كانت دقة التنبؤ أقل كفاءة من خوارزمية CNN1D بنسبة ٥.٧٩% عند التنبؤ بسرعة الرياح.

- حسنت خوارزمية GRU دقة التنبؤ بنسبة ٩٥.٩٧% عن خوارزمية ARIMA، وبنسبة ٨٩.٨٢% عن خوارزمية FbProphet، وبنسبة ٢٤.٠٥٥% عن خوارزمية CNN1D، ولكنها كانت أقل كفاءة من خوارزمية LSTM بنسبة ١٠.٠٦٨% عند التنبؤ بالإشعاع الشمسي، وحسنت دقة التنبؤ بنسبة ٨٧.٥٣٨% عن خوارزمية ARIMA، وبنسبة ٨٤.٤٣٥% عن خوارزمية FbProphet، و بنسبة ٧.٣٣٥% عن خوارزمية CNN1D، وبنسبة ١٢.٤٠٨% عن خوارزمية LSTM عند التنبؤ بسرعة الرياح.

- حققت خوارزمية LSTM أفضل دقة عند التنبؤ بالإشعاع الشمسي، بينما كانت خوارزمية GRU أكثر دقة عند التنبؤ بسرعة الرياح .

نوصي باستخدام خوارزميات التعلم العميق في تحليل السلاسل الزمنية عند التنبؤ بالإشعاع الشمسي وسرعة الرياح، والاستفادة من هذه التنبؤات في تصميم نظام تحكم قادر على التنبؤ بشدة الإشعاع الشمسي وسرعة الرياح لإدارة نظام طاقة هجين (ريحي _ شمسي _ احفوري) لتحديد كمية الطاقة المنتجة من الشبكة العامة التي تعمل على الطاقة الأحفورية من أجل أمثلة إدارة الموارد، والتي يمكن أن تكون موضوع لبحث قادم.

المراجع :

1. MICHAEL,N,E; MISHRA,M; HASAN,S; AL-DURRA,A.2022, *Short-Term Solar Power Predicting Model Based on Multi-Step CNN Stacked LSTM Technique*. Energies . Switzerland.Vol.15,1-20.
2. ARVIDSSON,E.2021, *Improving on Inventory Management Using Time Series Forecasting*. Sweden,48.
3. DAS,S.2020, *Forecasting the Generation of Wind Power in the Western and Southern Regions of India: Comparative Approach*. Ireland,30.
4. XU,C.2021, *A Comparative Study:Time-Series Analysis Methods for Predicting COVID-19 Case Trend*. Sweden,60.
5. GANGWAR,S; BALI,V; KUMAR,A.2020, *Comparative Analysis of Wind Speed Forecasting Using LSTM and SVM*. EAI Endorsed Transactions. Vol.7,NO.25,1-9.
6. SPYROU,E; TSOULOS,I; STYLIOU,C.2022, *Applying and Comparing LSTM and ARIMA to Predict CO Levels for a Time-Series Measurements in a Port Area*. Signals. Vol.3 , 235-248.
7. Nasa,Helioclim-3Archives*Demo*,available: "www.soda-pro.com", last access: 15-١٢-202٢.
8. TAYLOR,S,J; LETHAM,B.2017, *Forecasting at Scale*. PeerJ Preprints. California, United States,25.
9. VELASQUEZ,R,M.2022, *A case study of NeuralProphet and nonlinear evaluation for high accuracy prediction in short-term forecasting in PV solar plant*. Heliyon.Vol.8,1-11.
10. CAI,C; LI,Y; SU,Z; ZHU,T; HE,Y.2022, *Short-Term Electrical Load Forecasting Based on VMD and GRU-TCN Hybrid Network* . Applied sciences.Vol.12,No.2,1-16.
11. WANG,H; SONG,K; CHENG,Y.2022, *A Hybrid Forecasting Model Based on CNN and Informer for Short-Term Wind Power*. Frontiers in Energy Research.Vol.9,1-11.
12. PARASYRIS,A;ALEXANDRAKIS,G;KOZYRAKIS,G;SPANOUDAKI,K; KAMPANIS,N.2022, *Predicting Climatic Variables on Local Level with SARIMA,LSTM and Hybrid Techniques*. Preprints.Vol.1,1-22.
13. LU,H.2019, *A Lower Limb Specialized Motor Intent Recognition System Using Neural Networks* .Master's thesis university of Groningen.
14. SUN,Y; XIE,Z; CHEN,Y; HU,Q.2022, *Accurate Solar Wind Speed Prediction with Multimodality Information*. Science & Technology. Vol. 14, No. 2,1-13.