



استعمال الأنموذج الهجين (SARIMA – LSTM) للتنبؤ بالسلاسل الزمنية مع التطبيق

موسى نعمة جميل حسين

أ.م ببداء اسماعيل عبد الوهاب

جامعة بغداد – كلية الإدارة والاقتصاد

musa.nimah2201@coadec.uobaghdad.edu.iq

المستخلص:

يُعد التنبؤ بالسلاسل الزمنية أداة أساسية في قطاع الطاقة، إذ تسهم التقديرات الدقيقة لاستهلاك الكهرباء في دعم التخطيط وإدارة الموارد بكفاءة. تهدف هذه الدراسة إلى تطوير إطار هجين يجمع بين نموذج SARIMA وشبكة LSTM للتنبؤ بالاستهلاك الشهري للكهرباء في الولايات المتحدة الأمريكية، بالاعتماد على (552) مشاهدة شهرية تغطي المدة من يناير 1980 إلى ديسمبر 2025.

يعتمد الإطار المقترح على استخدام نموذج SARIMA لتمثيل الأنماط الخطية والموسمية، في حين تُستخدم شبكة LSTM للنمذجة المكونات غير الخطية من خلال بواقي النموذج. وقد جرى تقييم أداء النموذج الهجين ومقارنته بنموذجي SARIMA و LSTM المنفردين باستخدام معيار الجذر التربيعي لمتوسط مربع الخطأ (RMSE). أظهرت النتائج تفوق النموذج الهجين SARIMA–LSTM من حيث الدقة والاستقرار مقارنة بالنماذج المنفردة، مما يؤكد فاعلية دمج الأساليب الإحصائية وتقنيات التعلم العميق في التنبؤ بالسلاسل الزمنية الموسمية المعقدة. كما تشير النتائج إلى إمكانية توظيف هذا الإطار في تطبيقات أخرى تتضمن بيانات زمنية طويلة الأجل وذات أنماط موسمية. الكلمات المفتاحية: التنبؤ بالسلاسل الزمنية، استهلاك الكهرباء، النموذج الهجين (SARIMA–LSTM)، شبكة LSTM، السلاسل الزمنية الموسمية، RMSE.

Research Title: Using the Hybrid (SARIMA–LSTM) Model for Time Series Forecasting with Application

Researcher's Name: Mousa Neamah Jameel

Email address : musa.nimah2201@coadec.uobaghdad.edu.iq

Abstract

Time series forecasting plays a vital role in the energy sector, where accurate electricity consumption predictions support planning and resource management. This study develops a hybrid SARIMA–LSTM framework for forecasting monthly electricity consumption in the United States using 552 observations from January 1980 to December 2025.

The proposed approach employs SARIMA to model linear and seasonal patterns, while LSTM captures nonlinear structures through the model residuals. Forecasting performance was evaluated against standalone SARIMA and LSTM models using RMSE.

Results show that the hybrid SARIMA–LSTM model outperformed the individual models in terms of accuracy and stability, demonstrating the value of combining statistical and deep learning methods for forecasting complex seasonal time series. The framework also shows potential for broader applications involving long-term seasonal data.

Keywords: Time Series Forecasting, Electricity Consumption, SARIMA–LSTM, LSTM, Seasonal Time Series, RMSE.



الفصل الأول

المقدمة:

تُعد السلاسل الزمنية من الأدوات الإحصائية الأساسية لتحليل الظواهر المتغيرة عبر الزمن والتنبؤ بقيمها المستقبلية (Shumway & Stoffer, 2017)؛ (Wei, 2006) ويُستخدم نموذج SARIMA لتمثيل الاتجاهات والموسمية في البيانات الزمنية (Box et al., 2016)، إلا أن قدرته محدودة في معالجة العلاقات غير الخطية.

في المقابل، تتميز شبكات LSTM بكفاءة عالية في نمذجة الاعتماديات الزمنية المعقدة واللاخطية (Hochreiter & Schmidhuber, 1997)؛ (Goodfellow et al., 2016) لذلك اتجهت الدراسات الحديثة إلى تطوير نماذج هجينة تجمع بين SARIMA و LSTM للاستفادة من مزايا كل منهما، بهدف تحسين دقة التنبؤ في تحليل السلاسل الزمنية (Zhang, 2003؛ Khashei & Bijari, 2011)

مشكلة البحث:

تواجه نماذج السلاسل الزمنية المنفردة، سواء الخطية أو غير الخطية، صعوبة في تمثيل الخصائص الكاملة للسلسلة الزمنية لاحتوائها على مكونات خطية وغير خطية في آن واحد

(Chatfield, 2004, Hamilton, 1994)

ويحد هذا القصور من دقة التنبؤ وكفاءة النمذجة، مما يستدعي تطوير منهجية هجينة تجمع مزايا النماذج الخطية وغير الخطية ضمن إطار موحد بهدف تحقيق تمثيل أكثر واقعية للسلسلة الزمنية وتحسين دقة التنبؤ

(Zhang, 2003؛ Khashei & Bijari, 2011)

هدف البحث:

يهدف البحث إلى تقييم كفاءة نمودجي SARIMA و LSTM في التنبؤ بالسلاسل الزمنية (Box et al., 2016)؛ (Hochreiter & Schmidhuber, 1997) من خلال اختيار أفضل نموذج من كل منهما. كما يسعى إلى تطوير نموذج هجين يجمع الخصائص الخطية وغير الخطية لتحسين دقة التنبؤ. (Zhang, 2003) ويعتمد البحث على مقاييس إحصائية مثل RMSE و MAE و MAPE لتقييم الأداء (Hyndman & Koehler, 2006)، وذلك لتحديد النموذج الأكثر دقة وكفاءة.

أهمية البحث:

تتبع أهمية الدراسة من أهمية التنبؤ بالسلاسل الزمنية في دعم التخطيط واتخاذ القرار. (Wei, 2006) وتتمثل أهميتها العلمية في تطوير نموذج هجين يجمع بين SARIMA و LSTM لتمثيل المكونات الخطية وغير الخطية بكفاءة أعلى (Khashei & Bijari, 2011).

أما أهميتها التطبيقية فتتمثل في تطبيق النموذج على بيانات استهلاك الطاقة الكهربائية في الولايات المتحدة (U.S. Energy Information Administration, 2023)، مما يعزز دقة التنبؤ ودعم إدارة الطلب.

حدود البحث:

- حدود موضوعية: تقتصر على تطوير وتقييم النموذج الهجين (SARIMA–LSTM) (Zhang, 2003).
- حدود زمنية: بيانات شهرية للفترة 1980–2025 بعدد (552) مشاهدة .
- حدود مكانية: استهلاك الطاقة الكهربائية في الولايات المتحدة (U.S. Energy Information Administration, 2023).



- حدود بيانية: تعتمد على بيانات الاستهلاك فقط دون متغيرات خارجية .
- حدود منهجية: تستخدم مقاييس MAE و RMSE و MAPE (Hyndman & Koehler, 2006)

الفصل الثاني

المقدمة:

يتناول هذا الفصل الأسس النظرية والمنهجية لتحليل السلاسل الزمنية والتنبؤ بها، من خلال عرض المفاهيم الإحصائية الأساسية والنماذج التقليدية والحديثة المستخدمة في توصيف البيانات الزمنية وبناء النماذج التنبؤية. (Shumway & Stoffer, 2017؛ Wei, 2006)

السلسلة الزمنية:

السلسلة الزمنية هي مجموعة من المشاهدات المرتبة زمنياً والمسجلة عند فترات منتظمة، بحيث ترتبط القيم المتعاقبة فيما بينها بعلاقات زمنية تسمح بدراسة سلوك الظاهرة وتحليل تطورها عبر الزمن (Chatfield, 2004) وتنقسم السلاسل الزمنية إلى:

- سلاسل متقطعة تُسجل عند فترات زمنية منفصلة وثابتة.
 - سلاسل مستمرة تُعرّف على مدى زمني متصل.
- كما يمكن النظر إلى السلسلة الزمنية باعتبارها تحققاً لعملية عشوائية، الأمر الذي يوفر إطاراً احتمالياً لدراسة خصائصها الإحصائية والتنبؤ بقيمها المستقبلية (Hamilton, 1994)

الاستقرارية:

تُعد الاستقرارية من أهم الخصائص التي يجب التحقق منها قبل بناء نماذج السلاسل الزمنية (Box et al., 2016)، إذ تعتمد غالبية النماذج الإحصائية على افتراض ثبات الخصائص الإحصائية للسلسلة عبر الزمن، ولاسيما المتوسط والتباين والتغاير.

وتوصف السلسلة بأنها مستقرة عندما لا تتغير هذه الخصائص مع مرور الزمن. وفي حالة عدم الاستقرار في المتوسط نتيجة وجود اتجاه عام، يتم استخدام الفروق الزمنية لإزالة الاتجاه وتحقيق الاستقرار، بينما تُستخدم التحويلات الرياضية المناسبة لمعالجة عدم ثبات التباين. (Wei, 2006) وتُعد عملية تحويل السلسلة إلى حالة مستقرة خطوة ضرورية لضمان صحة التقديرات ودقة التنبؤات الناتجة عن النماذج الإحصائية

اختبارات التحقق من الاستقرارية:

وللتحقق من استقرارية السلسلة الزمنية تُستخدم مجموعة من الاختبارات الإحصائية، يأتي في مقدمتها اختبار ديكي-فولر المطور واختبار (KPSS) (Dickey & Fuller, 1979) اختبار ديكي فولر المطور:

يعتمد اختبار ADF على فحص وجود جذر الوحدة في السلسلة الزمنية، إذ تشير الفرضية الصفرية إلى وجود جذر وحدة وعدم استقرارية السلسلة، بينما تشير الفرضية البديلة إلى استقرارها. (Dickey & Fuller, 1979)

اختبار (KPSS):

أما اختبار KPSS فيتبنى فرضية صفرية معاكسة تفترض استقرار السلسلة، في حين تشير الفرضية البديلة إلى وجود عدم استقرار. (Kwiatkowski et al., 1992)

ويساعد الجمع بين الاختبارين في تعزيز دقة الحكم على طبيعة السلسلة وتقليل احتمالات الوصول إلى استنتاجات مضللة بشأن خصائصها الإحصائية.

دالة الارتباط الذاتي و دالة الارتباط الذاتي الجزئي:



وتستخدم دوال الارتباط الذاتي والارتباط الذاتي الجزئي بوصفها من أهم الأدوات التشخيصية في تحليل السلاسل الزمنية. (Box et al., 2016)

دالة الارتباط الذاتي:

إذ تقيس دالة الارتباط الذاتي (ACF) درجة الارتباط بين القيم الحالية والقيم السابقة عند إبطاءات زمنية مختلفة، وتستخدم في الكشف عن طبيعة الاعتماد الزمني وتحديد بعض خصائص النماذج المناسبة. (Chatfield, 2004)

دالة الارتباط الذاتي الجزئي:

أما دالة الارتباط الذاتي الجزئي (PACF) فتتمثل مقدار الارتباط المباشر بين قيمتين تفصل بينهما فترة زمنية معينة بعد استبعاد تأثير القيم الوسيطة، وتعد أداة أساسية في تحديد رتبة نماذج الانحدار الذاتي واختيار النموذج الأنسب (Box et al., 2016).

منهجية بوكس-جينكنز:

تعد منهجية بوكس-جينكنز من أكثر المناهج الإحصائية استخداماً في بناء نماذج السلاسل الزمنية والتنبؤ بقيمها المستقبلية. (Box et al., 2016)

وتعتمد هذه المنهجية على نماذج ARIMA التي تجمع بين مكونات الانحدار الذاتي والمتوسطات المتحركة والتكامل. وتتكون عملية بناء النموذج وفق هذه المنهجية من أربع مراحل رئيسية تتمثل في تحديد النموذج المناسب، وتقدير معالمته، وإجراء الفحص التشخيصي، ثم استخدامه في التنبؤ. (Box et al., 2016)

وقد أثبتت هذه المنهجية كفاءتها في العديد من التطبيقات الاقتصادية والمالية والاجتماعية بسبب قدرتها على توصيف البنية الزمنية للبيانات وتقديم تنبؤات دقيقة.

تحديد النموذج المناسب:

انموذج الانحدار الذاتي العام AR(p):

يمثل نموذج الانحدار الذاتي AR أحد أبسط نماذج السلاسل الزمنية وأكثرها استخداماً (Hamilton, 1994)، إذ يفترض أن القيمة الحالية للمتغير تعتمد على مجموعة من القيم السابقة له بالإضافة إلى مركبة عشوائية. ويتميز هذا النموذج بقدرته على تمثيل الاعتماد المباشر بين القيم المتعاقبة، كما تستخدم دالة PACF في تحديد الرتبة المناسبة له. (Chatfield, 2004).

انموذج الاوساط المتحركة العام MA:

أما نموذج المتوسطات المتحركة MA فيفترض أن القيمة الحالية للسلسلة تتحدد من خلال مجموعة من الأخطاء العشوائية الحالية والسابقة. (Wei, 2006)

ويختلف عن نموذج الانحدار الذاتي في اعتماده على تأثير الصدمات العشوائية السابقة بدلاً من القيم السابقة للسلسلة نفسها. وتمتاز نماذج المتوسطات المتحركة بقدرتها على توصيف التأثيرات قصيرة الأجل للأخطاء العشوائية، حيث تتلاشى آثار هذه الأخطاء تدريجياً مع مرور الزمن.

انموذج الانحدار الذاتي والمتوسطات المتحركة (ARMA):

ويجمع نموذج ARMA بين خصائص نماذج الانحدار الذاتي والمتوسطات المتحركة ضمن إطار واحد، مما يسمح بتمثيل السلاسل الزمنية المستقرة بصورة أكثر كفاءة. (Box et al., 2016)

ويتكون النموذج من جزء يعبر عن الاعتماد على القيم السابقة للسلسلة وجزء آخر يمثل تأثير الأخطاء العشوائية السابقة ويستخدم هذا النموذج عندما تكون السلسلة مستقرة ولا تتطلب إجراء فروق زمنية.

انموذج الانحدار الذاتي المتكامل والمتوسطات المتحركة (ARIMA):

أما نموذج ARIMA فيُعد امتداداً لنموذج ARMA، إذ يضيف عنصر التكامل من خلال استخدام الفروق الزمنية لتحويل السلاسل غير المستقرة إلى سلاسل مستقرة (Wei, 2006)

ويتكون النموذج من ثلاثة معالم أساسية تمثل رتبة الانحدار الذاتي، وعدد مرات التقريب، ورتبة المتوسطات المتحركة. ويُعد ARIMA من أكثر النماذج شيوعاً في التنبؤ بالسلاسل الزمنية نظراً لمرونته وقدرته على التعامل مع البيانات التي تحتوي على اتجاهات زمنية.



انموذج الانحدار الذاتي المتكامل والمتوسطات المتحركة الموسمي (SARIMA):

وعندما تتضمن السلسلة الزمنية أنماطاً موسمية متكررة، يصبح من الضروري استخدام نموذج SARIMA الذي يمثل تطويراً لنموذج ARIMA من خلال إضافة مكونات موسمية تسمح بتمثيل التأثيرات الدورية طويلة الأجل (Box et al., 2016).

ويتضمن النموذج فروقاً موسمية ومعلمات انحدار ذاتي ومتوسطات متحركة موسمية إلى جانب المكونات غير الموسمية.

ويتيح هذا النموذج تمثيل الاتجاه العام والأنماط الموسمية والاعتماد الزمني قصير وطويل الأمد ضمن إطار إحصائي موحد، الأمر الذي يجعله من أكثر النماذج استخداماً في تحليل الظواهر ذات السلوك الموسمي.

التقدير (Estimation):

بعد تحديد النموذج المناسب، تأتي مرحلة تقدير المعلمات التي تهدف إلى الحصول على القيم المثلى لمعاملات النموذج وتُعد (Akaike, 1974) طريقة الإمكان الأعظم من أكثر الطرائق شيوعاً في تقدير معلمات نماذج السلاسل الزمنية، إذ تعتمد على تعظيم احتمال الحصول على البيانات المشاهدة في ظل النموذج المقترض.

وتسهم هذه الطريقة في توفير تقديرات تنسم بالكفاءة والاتساق وتدعم بناء نماذج ذات قدرة تفسيرية وتنبؤية مرتفعة.

فحص الانموذج:

وتتبع مرحلة التقدير عملية الفحص التشخيصي التي تهدف إلى التحقق من ملاءمة النموذج للبيانات.

ويتم ذلك من خلال دراسة البواقي الناتجة عن النموذج والتأكد من تصرفها كسلسلة عشوائية لا تحتوي على ارتباطات ذاتية معنوية (Ljung & Box, 1978).

فإذا أظهرت البواقي خصائص الضوضاء البيضاء أمكن قبول النموذج، أما إذا بقيت أنماط زمنية غير مفسرة فإن ذلك يشير إلى ضرورة إعادة تحديد النموذج أو تعديل مكوناته.

التنبؤ:

يمثل التنبؤ الهدف النهائي لتحليل السلاسل الزمنية (Hyndman & Athanasopoulos, 2021)، إذ يُستخدم النموذج المقدر لاستشراف القيم المستقبلية اعتماداً على المعلومات المتوافرة حتى الزمن الحالي. وتختلف آلية التنبؤ باختلاف النموذج المستخدم، إلا أنها تستند بصورة عامة إلى حساب التوقع الشرطي للقيم المستقبلية اعتماداً على القيم التاريخية والمعلمات المقدر. وتُستخدم النماذج الزمنية في العديد من المجالات التطبيقية التي تتطلب التخطيط واتخاذ القرار استناداً إلى توقعات مستقبلية دقيقة.

تقييم أداء التنبؤ:

ولغرض الحكم على كفاءة النماذج التنبؤية، يتم تقييم أدائها من خلال دراسة الأخطاء التنبؤية الناتجة عن الفرق بين القيم الفعلية والقيم المقدر.

(Hyndman & Koehler, 2006)

وتعتمد عملية التقييم على مجموعة من المقاييس الإحصائية التي تقيس حجم الانحراف بين القيم المتنبأ بها والقيم الحقيقية، مما يسمح بالمفاضلة بين النماذج المختلفة واختيار النموذج الأكثر دقة وملاءمة لطبيعة البيانات.

الشبكات العصبية الاصطناعية:

وفي إطار التطورات الحديثة في مجال الذكاء الاصطناعي، برزت الشبكات العصبية الاصطناعية بوصفها من أهم أدوات النمذجة غير الخطية وتستند هذه الشبكات إلى محاكاة آلية عمل الدماغ البشري من خلال مجموعة من الوحدات الحسابية المترابطة التي تتعلم الأنماط الكامنة في البيانات عبر تعديل الأوزان الداخلية.

(Haykin, 2009؛ Bishop, 2006)

مكونات الشبكات العصبية الاصطناعية:

وتتكون الشبكات العصبية من طبقة إدخال وطبقة أو أكثر مخفية وطبقة إخراج، وترتبط هذه الطبقات عبر أوزان عديدة يتم تحديثها أثناء عملية التدريب بهدف تقليل الخطأ وتحسين القدرة التنبؤية.

وتعتمد الشبكات العصبية على مجموعة من المكونات الأساسية تشمل المدخلات والأوزان والانحيازات ودوال التجميع ودوال التنشيط ودوال الإخراج.

(Goodfellow et al., 2016) وتسهم هذه العناصر مجتمعة في تمكين الشبكة من تمثيل العلاقات المعقدة وغير الخطية بين المتغيرات.



كما تُستخدم خوارزميات تعلم مختلفة لتحديث الأوزان وتحسين أداء النموذج استناداً إلى البيانات التدريبية المتاحة. **الشبكات العصبية طويلة الذاكرة (LSTM):**

ومن بين أكثر نماذج التعلم العميق استخداماً في تحليل السلاسل الزمنية نموذج الذاكرة طويلة وقصيرة الأمد (LSTM)، وهو تطوير للشبكات العصبية المتكررة يهدف إلى معالجة مشكلة تلاشي التدرجات التي تواجه النماذج التقليدية. (Hochreiter & Schmidhuber, 1997) ويعتمد هذا النموذج على بنية خاصة تتكون من خلايا ذاكرة وبوابات للتحكم في تدفق المعلومات، بما يسمح بالاحتفاظ بالمعلومات المهمة لفترات زمنية طويلة ونسيان المعلومات غير الضرورية. ويمتلك نموذج LSTM قدرة عالية على اكتشاف الأنماط غير الخطية والاعتماديات الزمنية طويلة المدى، مما يجعله فعالاً في تطبيقات التنبؤ المعقدة.

النموذج الهجين SARIMA-LSTM

ونظراً لأن السلاسل الزمنية الواقعية غالباً ما تتضمن مكونات خطية وغير خطية في الوقت نفسه، فقد ظهرت النماذج الهجينة التي تجمع بين النماذج الإحصائية التقليدية ونماذج الذكاء الاصطناعي (Zhang, 2003؛ Panicker, 2024)، (Zhang, 2003؛ Khashei & Bijari, 2011).

ويُعد النموذج الهجين SARIMA-LSTM من أبرز هذه النماذج، إذ يقوم أولاً باستخدام نموذج SARIMA لاستخلاص وتمثيل المكونات الخطية والموسمية في السلسلة الزمنية، ثم تُستخدم البواقي الناتجة عن هذا النموذج بوصفها مدخلات إلى شبكة LSTM لتعلم الأنماط غير الخطية المتبقية. وفي المرحلة الأخيرة يتم دمج تنبؤات النموذجين للحصول على التنبؤ النهائي. ويتميز هذا الأسلوب بقدرته على الاستفادة من مزايا كل من النماذج الإحصائية التقليدية والشبكات العصبية العميقة، مما يؤدي إلى تحسين دقة التنبؤ وتمثيل السلوك الديناميكي المعقد للسلاسل الزمنية بصورة أكثر كفاءة.

الفصل الثالث

التمهيد:

يتناول هذا الفصل التحليل التطبيقي لسلسلة زمنية شهرية لاستهلاك الطاقة الكهربائية في الولايات المتحدة الأمريكية خلال المدة من كانون الثاني 1980 إلى كانون الأول 2025، وبعدد 552 مشاهدة. ويهدف إلى دراسة الخصائص الإحصائية الأولية للسلسلة، وبناء نماذج تنبؤية تعتمد على نماذج السلاسل الزمنية التقليدية SARIMA، ثم توظيف التعلم العميق من خلال LSTM على بواقي النموذج، وصولاً إلى بناء نموذج هجين SARIMA-LSTM.

كما اعتمد التقييم النهائي على معيار الخطأ التنبؤي MAE MAPE RMSE لتحديد النموذج الأكثر كفاءة، باستخدام برمجيات تحليل إحصائي متعددة مثل Python spss EViews MATLAB R

التحليل الاولي للسلسلة الزمنية :

تمثل البيانات سلسلة زمنية شهرية لاستهلاك الكهرباء خلال (1980-2025). وقد أظهرت الإحصاءات الوصفية ما يلي:

المؤشر	القيمة
n	552
Mean	1998.07
Std. Dev	593.00
Median	1977.48
Skewness	0.0058



المؤشر	القيمة
Kurtosis	-1.0602
Max	3220.08
Min	744.95

تشير النتائج في الجدول إلى تباين مرتفع في الاستهلاك، مع تقارب المتوسط والوسيط مما يدل على تماثل تقريبي في التوزيع، بينما يشير الالتواء القريب من الصفر إلى تماثل شبه تام. أما التقلطح السلبي فيدل على توزيع مقلطح أقل انتشاراً من التوزيع الطبيعي كما أظهر الرسم البياني للسلسلة وجود اتجاه تصاعدي واضح وموسمية سنوية منتظمة، مما يشير إلى عدم استقرار السلسلة في المتوسط والتباين.

تحليل ACF و PACF :

أظهر تحليل الارتباط الذاتي (ACF) وجود ارتباطات ممتدة وتناقص بطيء مع قمم موسمية عند (12، 24، 36)، مما يؤكد وجود موسمية سنوية وعدم استقرار أما PACF فقد أظهر انقطاعاً نسبياً بعد عدد محدود من الإبطاءات، مما يشير إلى وجود مكونات AR مهمة ضمن النموذج.

اختبار الاستقرار:

تم استخدام اختبارين ADF و KPSS

Test	Statistic	p-value
ADF	0.3141	0.9779
KPSS	3.5281	0.01

تشير النتائج إلى عدم استقرار السلسلة عند المستوى، مما يستلزم تطبيق الفرق غير الموسمي.

الفرق غير الموسمي:

تم تطبيق الفرق الأول: $\Delta Y_t = Y_t - Y_{t-1}$ وبعد ذلك أصبحت السلسلة مستقرة إحصائياً كما يلي:

Series	Test	Statistic	p-value
d1	ADF	-17.8951	2.96E-30
d1	KPSS	0.005497	0.1

وبذلك تم اعتماد: $d = 1$

تحديد الموسمية:

عن طريق استخدام تحليل STL اظهرت النتائج :

s	Seasonal Strength	التفسير
4	0.01299	ضعيفة
6	0.05838	متوسطة



s	Seasonal Strength	التفسير
12	0.91210	قوية جداً

تم اعتماد $s = 12$:

الفرق الموسمي: تم اختبار اذا كان النموذج الموسمي يحتاج فرق موسمي ام لا بواسطة الاختبارين :

s	Test	D	النتيجة
12	OCSB	0	OK
12	CH	0	OK

أي ان : $D = 0$ و معنى ذلك ان الانموذج لا يحتاج الى فرق موسمي .

بناء نموذج SARIMA:

تم اختبار 255 نموذجاً، وتم اختيار النموذج الأفضل وفق معايير AIC BIC HQIC

SARIMA(3,1,0)(3,0,0)[12]

المعيار	الانموذج المختار	AIC	BIC	HQIC
AIC	SARIMA(3,1,0)(3,0,0)[12]	5732.586	5762.255	5744.216
BIC	SARIMA(3,1,0)(3,0,0)[12]	5732.586	5762.255	5744.216
HQIC	SARIMA(3,1,0)(3,0,0)[12]	5732.586	5762.255	5744.216

جميع المعايير أجمعت على نفس النموذج.

كما أظهر التقييم أن القيم المقدرة تتبع القيم الفعلية بشكل جيد مع بعض الانحرافات في الفترات المتقلبة

تقديرات معاملات انموذج SARIMA :

بعد تحديد الانموذج الأمثل، تم تقدير معلمته الإحصائية، وكانت النتائج كما يأتي:
و كما موضح في الجدول ادناه :

Parameter	Coefficient	Std. Error	P-value
ϕ_1	-0.75987	0.042801	1.61E-70
ϕ_2	-0.45449	0.05223	3.26E-18
ϕ_3	-0.18202	0.044573	4.43E-05
Φ_1	0.269798	0.044056	9.12E-10
Φ_2	0.330724	0.042816	1.12E-14



Parameter	Coefficient	Std. Error	P-value
Φ_3	0.355345	0.042834	1.08E-16

جميع المعلمات معنوية إحصائياً ($p\text{-value} < 0.05$) ، مما يؤكد قوة النموذج في تفسير السلسلة.

التشخيص الإحصائي: بواسطة Ljung-Box
تم استخدام اختبار Ljung-Box للتحقق من وجود ارتباط ذاتي في بواقي الانموذج و كما موضح في الجدول ادناه :

Test	Statistic	p-value
LB	62.7028	7.22E-09

تشير النتائج إلى وجود ارتباط ذاتي في البواقي، مما يدل على عدم اكتمال تمثيل النموذج للبيانات.

بناء النموذج الهجين SARIMA-LSTM :

بسبب وجود ارتباط في البواقي، تم تطوير نموذج هجين:

$$\hat{Z}_t = \hat{Z}_{\text{SARIMA},t} + \hat{e}_{\text{LSTM},t}$$

حيث ان :

- SARIMA يمثل المكونات الخطية والموسمية
- LSTM يمثل المكونات غير الخطية في البواقي .

تقييم أداء نموذج التنبؤ: لتقييم كفاءة النماذج، تمت مقارنة أداء الانموذج الموسمي SARIMA مع الانموذج الهجين SARIMA-LSTM باستخدام مجموعة من مقاييس دقة التنبؤ الإحصائية، وهي: متوسط الجذر التربيعي للخطأ (RMSE) ومتوسط الخطأ المطلق (MAE) و متوسط نسبة الخطأ المطلق المئوية (MAPE)

Model	RMSE	MAE	MAPE
SARIMA	63.87	51.42	2.61
Hybrid	57.55	46.84	2.38

يتضح تفوق النموذج الهجين في جميع مؤشرات الدقة.

التشخيص النهائي: بعد تحديد الانموذج الأفضل (SARIMA-LSTM) ، تم إجراء مجموعة من الاختبارات التشخيصية باستخدام اختباري Ljung-Box و ARCH-LM للتحقق من صلاحية الانموذج ، وكما يوضح الجدول الاتي :

Test	Statistic	p-value
Ljung-Box	13.74	0.317
ARCH-LM	9.55	0.654

تشير النتائج إلى: عدم وجود ارتباط ذاتي و عدم وجود عدم تجانس تباين و صلاحية النموذج الهجين

**التنبؤ:**

تم إجراء التنبؤ خارج العينة لأفق زمني يبلغ 12 شهراً، وهو ما يمثل دورة موسمية كاملة للسلسلة الزمنية الشهرية. وكما موضح بالجدول ادناه:

	Hybrid_Forecast	LSTM_Future_Residual	SARIMA_Forecast	Date
1	3087.131864	2.864043236	3084.267821	2026-01-01
2	3196.978246	8.001381874	3188.976864	2026-02-01
3	3160.672344	-4.468541145	3165.140886	2026-03-01
4	3239.249775	2.276772976	3236.973003	2026-04-01
5	3135.912692	10.0917635	3125.820929	2026-05-01
6	3006.876228	7.285551071	2999.590677	2026-06-01
7	2892.777965	0.409330189	2892.368635	2026-07-01
8	2808.601703	6.010737896	2802.590965	2026-08-01
9	2839.447083	-16.95641327	2856.403496	2026-09-01
10	2839.040612	-3.020555735	2842.061168	2026-10-01
11	2960.589362	2.180876493	2958.408486	2026-11-01
12	3070.814478	4.255891323	3066.558587	2026-12-01

أظهرت النتائج استمرار الاتجاه التصاعدي والموسمية، مع تفوق النموذج الهجين في استقرار التنبؤات ونعومتها.

تحليل النتائج:

تشير النتائج إلى:

- وجود اتجاه تصاعدي طويل الأمد وموسمية سنوية واضحة دون تغيرات هيكلية حادة .
- تفوق النموذج الهجين نتيجة دمج SARIMA لالتقاط الأنماط الخطية والموسمية مع LSTM لتمثيل الأنماط غير الخطية، مما حسن دقة التنبؤ.

الفصل الرابع**الاستنتاجات:**

- هدفت الدراسة إلى بناء إطار هجين يجمع بين SARIMA و LSTM لتحسين دقة التنبؤ بالسلاسل الزمنية الموسمية المعقدة، وتطبيقه على بيانات استهلاك الكهرباء. وأظهرت النتائج ما يلي:
1. وجود اتجاهات وموسمية واضحة في السلسلة الزمنية استدعت إجراء التحويلات اللازمة لتحقيق الاستقرارية .
 2. أثبتت اختبارات ADF KPSS عدم استقرارية السلسلة قبل التفريق، وبعد تطبيق الفرق الأول أصبحت مستقرة .
 3. أظهر تحليل STL وجود موسمية سنوية (12 شهراً) دون الحاجة إلى فرق موسمي إضافي .
 4. تبين أن النموذج الأمثل من بين نماذج SARIMA هو SARIMA(3,1,0)(3,0,0)₁₂ .
 5. أظهرت اختبارات البواقي وجود ارتباط ذاتي في نموذج SARIMA ، مما يشير إلى عدم قدرته على تفسير جميع الأنماط .
 6. نجح نموذج LSTM المبني على بواقي SARIMA في التقاط العلاقات غير الخطية المتبقية .



7. تفوق النموذج الهجين SARIMA–LSTM على النموذج الفردي في جميع مقاييس الأداء RMSE MAPE MAE

8. أكدت الاختبارات التشخيصية استقرار النموذج الهجين وخلو بواقه من الارتباط الذاتي ومشكلات التباين .

9. أثبت النموذج الهجين كفاءة عالية في تمثيل المكونات الخطية وغير الخطية وتحسين دقة التنبؤ .

التوصيات:

1. التوسع في استخدام النماذج الهجينة في تحليل السلاسل الزمنية .
2. اعتماد نموذج SARIMA–LSTM في تطبيقات الطاقة والأحمال الكهربائية .
3. زيادة حجم البيانات لتحسين أداء نماذج التعلم العميق .
4. استخدام عدة مقاييس تقييم RMSE ، MAE ، MAPE لضمان دقة الحكم على النماذج .
5. تطوير نماذج هجينة متقدمة مثل SARIMA–GRU و SARIMA–BiLSTM و Transformer-based hybrids.
6. اختبار النموذج في مجالات مختلفة مثل الاقتصاد والتمويل والبيئة والأسواق المالية .
7. دراسة تأثير آفاق التنبؤ المختلفة (قصير، متوسط، طويل المدى) على أداء النماذج الهجينة

المصادر

اولا: المراجع العربية:

1. أبو العلاء، محمد. (2020). مدخل إلى الشبكات العصبية وتطبيقاتها في الذكاء الاصطناعي. عمان: دار صفاء للنشر والتوزيع.
2. أبو دحروج، س. ف. ر. (2023). استخدام نموذج SARIMA في التنبؤ بالسلاسل الزمنية الموسمية. المجلة التجارية للبحوث، 45(4)، 1015.997–
3. ببداء، إ. ع.، وهامل، أ. أ. (2022). المقارنة بين انموذجي SARIMA و NARNN مع تطبيق عملي (رسالة ماجستير غير منشورة). جامعة بغداد، العراق.
4. بري، ع. (2009). طرق التنبؤ الإحصائي (الجزء الثاني). جامعة الملك سعود.
5. شعراوي، س. (2005). مقدمة في تحليل السلاسل الزمنية (ط. 1). جامعة الملك عبد العزيز.
6. الشبكات العصبية (Neural Network) (2022، 31 ديسمبر). مبادرة العطاء الرقمي.
7. العبدلي، خالد. (2021). مقدمة في الشبكات العصبية الاصطناعية وخوارزميات التعلم. عمان: دار المسيرة.
8. العبيدي، ع. ح. (2020). نماذج التنبؤ بالسلاسل الزمنية وتطبيقاتها الاقتصادية. بغداد: دار الكتب العلمية.
9. العتوم، محمد. (2018). مدخل إلى الشبكات العصبية الاصطناعية وتطبيقاتها. عمان: دار مسعى للنشر والتوزيع.
10. الغامدي، أحمد بن محمد. (2020). نمذجة السلاسل الزمنية باستخدام منهجية بوكس-جنكنز: دراسة تطبيقية. مجلة الإحصاء والتخطيط، 18(2)، 67.45–
11. الربيعي، علاء حسين. (2021). تحليل السلاسل الزمنية وتطبيقاتها باستخدام النماذج الإحصائية والذكاء. دار الأكاديميون للنشر والتوزيع.
12. فاندل، و. (1999). السلاسل الزمنية من وجهة التطبيقية: نماذج بوكس-جنكنز (ع. ع. عزام، مترجم؛ أ. ح. هارون، مراجعة). دار المريخ للنشر.
13. قدارة، عبد القادر. (2020). الشبكات العصبية الاصطناعية وتطبيقاتها في التنبؤ بالسلاسل الزمنية. الجزائر: دار الخلدونية.
14. عبدالله، حسين محمود. (2021). تحليل السلاسل الزمنية الاقتصادية باستخدام نماذج ARIMA و SARIMA. مجلة البحوث الاقتصادية، 34(1)، 138.112–



15. يوسف، محمود محمد. (2021). النمذجة الإحصائية وتطبيقات الشبكات العصبية في التنبؤ بالسلاسل الزمنية. عمان: دار رسلان.
16. مشهد، آيات أحمد هامل. (2022). المقارنة بين انموذجي SARIMA و NARNN مع تطبيق عملي (رسالة ماجستير، كلية الإدارة والاقتصاد، جامعة بغداد). جامعة بغداد.
17. ثجيل، سجاد ثامر. (2025). استعمال الأنموذج الهجين للتنبؤ مع تطبيق (رسالة ماجستير، كلية الإدارة والاقتصاد، جامعة بغداد). جامعة بغداد.
18. عبد إبراهيم، تبارك يحيى. (2024). استعمال أنموذج هجين للتنبؤ بالسلاسل الزمنية ذات الذاكرة الطويلة مع تطبيق عملي (رسالة ماجستير، كلية الإدارة والاقتصاد، جامعة بغداد). جامعة بغداد.

ثانياً: المراجع الأجنبية

19. Adhikari, R., & Agrawal, R. K. (2013). An introductory study on time series modeling and forecasting using artificial neural networks. *International Journal of Applied Mathematics and Computer Science*, 23(1), 89–102.
20. Aggarwal, C. C. (2018). *Neural networks and deep learning*. Springer.
21. Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723.
22. Bandara, K., Bergmeir, C., & Smyl, S. (2020). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert Systems with Applications*, 140, 112896.
23. Bishop, C. M. (1995). *Neural networks for pattern recognition*. Oxford University Press.
24. Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
25. Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time series analysis: Forecasting and control* (5th ed.). Wiley.
26. Brockwell, P. J., & Davis, R. A. (2016). *Introduction to time series and forecasting* (3rd ed.). Springer.
27. Brownlee, J. (2018). *Deep learning for time series forecasting*. Machine Learning Mastery.
28. Chan, K. S., & Cryer, J. D. (2010). *Time series analysis with applications in R* (2nd ed.). Springer.
29. Chan, N. H. (2022). *Time series: Applications to finance with R and S-PLUS* (2nd ed.). Springer.
30. Chen, S., Billings, S. A., & Grant, P. M. (1990). Nonlinear system identification using neural networks. *International Journal of Control*, 51(6), 1191–1214.
31. Chatfield, C. (2004). *The analysis of time series: An introduction* (6th ed.). Chapman & Hall/CRC.
32. Cilimkovic, M. (2015). *Neural networks and back propagation algorithm*.
33. De Jesus, O., & Hagan, M. T. (2001). Forward perturbation algorithm for a general class of recurrent network. In *Proceedings of the International Joint Conference on Neural Networks* (pp. 2626–2631).
34. Durbin, J., & Koopman, S. J. (2012). *Time series analysis by state space methods* (2nd ed.). Oxford University Press.



35. Egwunatum, S. I. (2024). Exploring a recurrent neural network (RNN) architecture for temporal data modeling. *Scientific Reports*.
36. Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211.
37. Enders, W. (2014). *Applied econometric time series* (4th ed.). Wiley.
38. Fan, J., & Yao, Q. (2003). *Time series: Nonparametric and parametric methods*. Springer.
39. Franses, P. H., van Dijk, D. J. C., & Opschoor, A. (2014). *Time series models for business and economic forecasting* (2nd ed.). Cambridge University Press.
40. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
41. Hagan, M. T., Demuth, H. B., & Beale, M. H. (2014). *Neural network design* (2nd ed.).
42. Hamilton, J. D. (1994). *Time series analysis*. Princeton University Press.
43. Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson.
44. Higham, C. F., & Higham, D. J. (2018). *Deep learning: An introduction for applied mathematicians*. arXiv.
45. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
46. Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.
47. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688.
48. IBM. (2023). What is a recurrent neural network (RNN)?
49. Khashei, M., & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2), 2664–2675.
50. Kock, A. B., & Kretschmer, U. (2021). *Statistical estimation and model selection for time series models*. Cambridge University Press.
51. Lin, T., Horne, B. G., Tino, P., & Giles, C. L. (1996). Learning long-term dependencies in NARX recurrent neural networks. *IEEE Transactions on Neural Networks*, 7(6), 1329–1338.
52. Ljung, G. M., & Box, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297–303.
53. Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *Information*, 15(9), 517.
54. Narendra, K. S., & Parthasarathy, K. (1990). Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks*, 1(1), 4–27.
55. Nielsen, M. A. (2015). *Neural networks and deep learning*. Determination Press.
56. Pereira, F. H., et al. (2018). Nonlinear autoregressive neural network models for prediction of transformer oil dissolved gas concentrations. *Energies*, 11(7).
57. Prince, S. (2023). *Understanding deep learning*. MIT Press.



58. Qin, Y., Song, D., Chen, H., Cheng, W., Jiang, G., & Cottrell, G. (2017). A dual-stage attention-based recurrent neural network for time series prediction. In IJCAI Proceedings (pp. 2627–2633).
59. Rojas, R. (1996). Neural networks: A systematic introduction. Springer.
60. Shumway, R. H., & Stoffer, D. S. (2017). Time series analysis and its applications: With R examples (4th ed.). Springer.
61. Tsay, R. S. (2010). Analysis of financial time series (3rd ed.). Wiley.
62. Wei, W. W. S. (2006). Time series analysis: Univariate and multivariate methods (2nd ed.). Pearson.
63. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
64. Panicker, N. K. P. (2024). A hybrid SARIMA–LSTM approach for improved time series prediction of aerosol optical depth across Delhi, India. *Journal of Theoretical and Applied Information Technology*, 102(11).
65. <https://www.eia.gov/international/> International Energy Agency , U.S. Energy Information Administration