

## التنبؤ باستهلاك الطاقة الكهربائية في محافظة بغداد باستخدام الأنموذجين SARIMA و Facebook Prophet : دراسة مقارنة

أ.د. سهاد علي شهيد مجيد<sup>(2)</sup>

(الجامعة المستنصرية ، كلية الادارة والاقتصاد ،  
قسم الاحصاء)

محمد عبدالحميد موسى جاسم<sup>(1)</sup>

(الجامعة المستنصرية ، كلية الادارة والاقتصاد ،  
قسم الاحصاء)  
07748763085

[dr.suhadali@uomustansiriyah.edu.iq](mailto:dr.suhadali@uomustansiriyah.edu.iq)

[mohamad.abdalhamid@uomustansiriyah.edu.iq](mailto:mohamad.abdalhamid@uomustansiriyah.edu.iq)

### مستخلص البحث:

تمثل الطاقة الكهربائية العصب المهم والحيوي لكل من الانشطة الاقتصادية والاجتماعية ، إذ يعد استهلاكها من الامور الجوهرية والتي نالت اهمية كبيرة ، كما ويعد مؤشراً مهماً على مستوى التطور في المجتمعات الحديثة ، ومن خلال ذلك هدف هذا البحث الى بناء نماذج تنبؤية ذات دقة عالية لتحليل بيانات استهلاك الطاقة الكهربائية في محافظة بغداد ، إذ اعتمدت هذه الدراسة على بيانات الاستهلاك وعلى اساس يومي وللمدة من 2024/1/1 ولغاية 2024/12/31 تم الحصول عليها من دائرة التشغيل والتحكم في وزارة الكهرباء ، وتم استخدام أنموذجين تنبؤيين لغرض تحقيق هدف البحث شملت كل من : انموذج SARIMA وأنموذج Facebook Prophet (FB Prophet) ، ولغرض المقارنة بين اداء كل من الانموذجين تم استخدام معايير المقارنة الاتية : متوسط الخطأ المطلق (MAE) ، ومتوسط الخطأ النسبي (MAPE) ، وجذر متوسط مربعات الاخطاء (RMSE) ، وقد اظهرت النتائج تفوق أنموذج SARIMA إذ حصل على اقل القيم من معايير المقارنة اعلاه ، وعليه فقد تم التنبؤ بالقيم المستقبلية لبيانات استهلاك الطاقة الكهربائية في محافظة بغداد من قبل انموذج SARIMA .

**الكلمات المفتاحية :** أنموذج SARIMA ، أنموذج Facebook Prophet ، التنبؤ ، استهلاك الطاقة الكهربائية .

### 1. المقدمة

يعتبر التنبؤ باستهلاك الطاقة الكهربائية من الامور المهمة والجوهرية التي نالت أهمية كبيرة نتيجة للزيادة المستمرة في الطلب على الكهرباء ، وازدياد التحديات التي تواجه قطاع الطاقة الكهربائية ، لاسيما في البلدان النامية ، ومن هذا المنطلق جاءت هذه الدراسة، إذ تهدف الى عملية بناء نماذج تنبؤية لتقدير استهلاك الطاقة الكهربائية والتنبؤ بالقيم المستقبلية لها . وتُعد المنهجية التي قدمها كل من العالمين ( بوكس وجينكينز ) ( box and jenkins ) والمتمثلة بأنموذج SARIMA و ARIMA وغيرها من النماذج ، من أساليب التنبؤ الكلاسيكية المعتمدة على نطاق واسع نظراً لفعاليتها في نمذجة البيانات الاقتصادية والصناعية والاجتماعية ، كما ويعتبر أنموذج Facebook Prophet الذي أكتشفته شركة Meta ، كأنموذج مضاف معمم حديث وفعال لتحليل السلاسل الزمنية والتنبؤ بها ، لما يمتلك من قدرة على التعامل مع البيانات ذات الموسمية المتعددة ، واتجاهات طويلة الامد ، كما وله القدرة على التعامل مع القيم المفقودة والمتطرفة ، وسيتم استعمال هذين النهجين في عملية تحليل بيانات استهلاك

الطاقة الكهربائية في محافظة بغداد واستخراج القيم التقديرية لها ، والمقارنة بين دقة هذه القيم لكلا النهجين لاختيار افضلهما، واستعمال الانموذج الافضل في التنبؤ بالقيم المستقبلية لبيانات الظاهرة المدروسة .

### 1.1 الدراسات السابقة

في عام (2017) استخدم الباحثان (Hussain and Ali) في دراستهم انموذج الانحدار الذاتي والواسط المتحركة التكاملية الموسمي (SARIMA) وانموذج الشبكات العصبية الاصطناعية (ANN) لغرض التنبؤ بأسعار واردات باكستان من الشاي الاسود ، وقد اعتمد الباحثان على البيانات للفترة من شهر يناير (2004) ولغاية شهر ديسمبر من عام (2014) ، وقدم استخدم الباحثان لغرض المقارنة بين اداء الانموذجين مقاييس احصائية متمثلة بـ متوسط مربعات الخطأ (MSE) و جذر متوسط مربعات الخطأ (RMSE) و متوسط الخطأ المطلق (MAE) ، وقد اظهرت النتائج تفوق انموذج الشبكات العصبية الاصطناعية (ANN) إذ امتلك على ادنى قيمة من المعايير اعلاه [1].

وفي العام (2021) استخدم الباحث (Francesco Lomio) في اطروحته أنموذج ( Facebook Prophet) للتنبؤ بعدد الوافدين في اليوم التالي الى قسم الطوارئ في جامعة تامبيرى ، وقدم استخدم الباحث معايير احصائية متمثلة بـ متوسط الخطأ المطلق (MAE) و متوسط الخطأ النسبي (MAPE) و جذر متوسط مربعات الخطأ (RMSE) لغرض تقييم دقة الانموذج ، وقد اظهرت النتائج ان انموذج Facebook Prophet قدم قيمة تنبؤية ذات دقة عالية [2].

وفي العام (2022) قدم الباحثون (Ugoh, at al.) دراسة تهدف الى اختيار افضل انموذج تنبؤي بين كل من انموذج (ARIMA) و انموذج التمهيد الاسي الموسمي البسيط ( simple seasonal exponential smoothing) للتنبؤ بعدد المصابين بمرض السكري ، وقد اعتمد الباحثون على بيانات عدد المصابين بمرض السكري من شهر يناير لعام (2009) لغاية شهر ديسمبر من عام (2019) في مستشفى (Enugu State Teaching Hospital) في نيجيريا ، واطهر النتائج تفوق انموذج التمهيد الاسي الموسمي البسيط وفقاً لمعايير المقارنة المتمثلة بـ متوسط الخطأ المطلق النسبي (MAPE) و (Theil's U Forecast Accuracy) ، وقد تم استخدام الانموذج الافضل للتنبؤ بعدد المصابين بمرض السكري لخمس سنوات قادمة [3].

وفي العام (2023) استخدم الباحثون (Hasnain, at al.) في دراستهم انموذج Facebook Prophet لغرض التنبؤ بتركيز PM<sub>2.5</sub> المحيط في الصين ، وقد استخدم الباحثون معايير احصائية متمثلة بـ متوسط الخطأ المطلق (MAE) و جذر متوسط مربعات الخطأ (RMSE) ومعامل التحديد (R<sup>2</sup>) لغرض تقييم اداء الانموذج ، وقد اشارت النتائج بان هنالك تطابقاً بشكل كبير بين القيم الفعلية والقيم التقديرية مما يدل على كفاءة هذا الانموذج في التنبؤ [4].

### 2. الأنموذج المضاعف الموسمي SARIMA

يعتبر أنموذج (SARIMA) الذي قدمه العالمان بوكس وجينكينز (Box-Jenkins) ، احد النماذج الخطية الكلاسيكية للتنبؤ ببيانات السلاسل الزمنية الموسمية ، ويعد امتداداً لأنموذج (ARIMA) غير الموسمي ، إذ يتضمن أنموذج SARIMA المركبة الموسمية (Seasonal component) والمركبة غير الموسمية (non-seasonal component) وكما موضح في ادناه :

$$SARIMA(p, d, q) * (P, D, Q)_s$$

اذ ان : (p): عدد حدود AR غير الموسمية ، (d): عدد الفروقات غير الموسمية ، (q): عدد حدود MA غير الموسمية ، (s): طول الفترة الموسمية ، (P): عدد حدود AR الموسمية ، (D): عدد الفروقات الموسمية ، (Q): عدد حدود MA الموسمية ، وكما يلاحظ فان الرموز الكبيرة تشير للأجزاء الموسمية في الأنموذج اما الرموز الصغيرة فتشير للأجزاء غير الموسمية . [5] [3]

الصيغة العامة للأنموذج تكون وفق المعادلة التالية : [6]

$$\Phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D Y_t = \theta_q(B)\theta_q(B^s)\epsilon_t \quad \dots (1)$$

اذ ان :

$$\begin{aligned} \Phi_p(B^s) &= 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps} \\ \Phi_p(B) &= 1 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p \\ \theta_q(B^s) &= 1 - \theta_1 B^s - \theta_2 B^{2s} - \dots - \theta_q B^{qs} \quad \dots (2) \\ \theta_q(B) &= 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \end{aligned}$$

وان :

$\Phi, \theta$  : معاملات الانحدار الذاتي والمتوسطات المتحركة غير الموسمية ،  $\Phi, \theta$  : معاملات الانحدار الذاتي والمتوسطات المتحركة الموسمية ،  $Y_t$  : تمثل السلسلة الزمنية ،  $\epsilon_t$  : الاخطاء العشوائية (الضوضاء البيضاء) ويفترض التوزيع الطبيعي بمتوسط (0) وتباين  $(\sigma^2)$  ،  $\epsilon_t \sim N(0, \sigma^2)$  : يمثل معامل الفروق الخلفي غير الموسمية ،  $B^s$  : يمثل معامل الفروق الخلفي الموسمي .

ان ملاءمة بيانات السلسلة الزمنية والتنبؤ بالقيم المستقبلية لها وفق أنموذج SARIMA تتم وفق منهجية بوكس وجينكينز (Box-Jenkins) ، اذ يتم بناء الأنموذج المضاعف الموسمي عن طريقها ، وتعتمد هذه المنهجية على اربع مراحل وكالتالي : [3]

1- تشخيص الأنموذج (Identification Model) .

2- تقدير معاملات الأنموذج (Model parameter estimation) .

3- اختبار ملاءمة الأنموذج (Diagnostic Checking) .

4- التنبؤ (Prediction) .

وتعتمد هذه المنهجية على نهج تكراري لتحديد أنموذج مبدئي من بين عدد من النماذج العامة المقترحة ويتم ذلك من خلال معيار اكيائي ، وخلال هذه العملية التكرارية يتم تقدير معاملات الأنموذج المختار بطريقة الامكان الاعظم Maximum Likelihood Method ، ومن ثم اختبار مدى ملاءمة لمعرفة ما إذا كان الأنموذج يصف السلسلة الزمنية بشكل جيد أم لا ، ويتم ذلك من خلال تحليل الارتباطات الذاتية للأخطاء (البواقي) ، فإذا كانت البواقي صغيرة وموزعة بشكل عشوائي أي (تتبع خصائص الضوضاء البيضاء) فيعتمد هذا الأنموذج ويتم التنبؤ من خلاله ، وإذا لم يكن كذلك فيتم تكرار عملية التحديد وتقدير المعلمات الى أن يتم الحصول على أنموذج ملائم . [6]

### 3. أنموذج Facebook Prophet

يعتبر أنموذج FB Prophet من الادوات الاحصائية الحديثة للتنبؤ بالسلاسل الزمنية ، وقد أكتشف من قبل كل من Taylor and Latham في عام 2017 ، ويعد كأنموذج مضاف معمم مختص لملاءمه بيانات السلاسل الزمنية ، ويمتاز بقدرته على التعامل مع القيم المتطرفة ، كما ويمكنه التعامل بشكل جيد مع القيم المفقودة . [7]

يستند عمل أنموذج FB Prophet على افتراض ان السلسلة الزمنية يمكن وصفها كمزيج من خصائص عديدة ، مثل الاتجاه ، الموسمية ، اضافة الى الاحداث الخاصة ( العطلات) . [8] ويتضمن أنموذج FB Prophet ثلاثة مكونات (مركبات) : الاتجاه ، الموسمية ، والمتغيرات الكامنة ، وكما في الصيغة الرياضية التالية :

$$Y(t) = g(t) + F(t) + h(t) + \epsilon_t \quad \dots (3)$$

إذ أن:  $Y(t)$  متغير الاستجابة ( السلسلة الزمنية المراد التنبؤ بها ) ،  $g(t)$  دالة تقيس طبيعة الاتجاهات ( الخطية او غير الخطية) وغير الدورية ( *Nonlinear and non-Periodic* ) في البيانات ، وتمثل دالة النمو أو الاتجاه ،  $F(t)$  دالة تقيس الاتجاهات الموسمية ( سنوية ، فصلية ، يومية ، ..... الخ) وتقيس التغيرات الدورية الموسمية ،  $h(t)$  دالة تؤثر اي تغييرات غير اعتيادية خلال الزمن ، مثل ( مواسم الأعياد ، المناسبات الوطنية ، .... الخ) ،  $\varepsilon_t$  حد الخطأ العشوائي ، يمتص أي تغييرات لم يلتقطها النموذج ويفترض أنه يتوزع توزيعاً طبيعياً  $\varepsilon_t \sim N(0, \sigma^2)$  . [7] [9]

### 1.3 دالة النمو Growth Function

إن دالة النمو  $g(t)$  تحسب وفق طبيعة الاتجاه ( خطي أو غير خطي ) ، وكالتالي: [10][11]  
**1- دالة النمو غير الخطية Nonlinear Growth Function** : وتستعمل عندما يكون هناك حد أعلى للسلسلة الزمنية لا يمكن تجاوزه ، ويطلق عليها دالة النمو اللوجستي ( The logistic Growth function ) ، وتصاغ وفقاً للمعادلة التالية:

$$g(t) = \frac{c}{1 + e^{-k(t-m)}} \quad \dots (4)$$

إذ ان :  $c$  الطاقة الاستيعابية ( *Carrying Capacity* ) وتمثل أعلى حد للسلسلة الزمنية ،  $k$  : معدل النمو الأساس ( اللوجستي ) وتمثل عدد النقاط حتى الوصول إلى نقطة المنتصف ،  $t$  : متغير مستمر ، ويمثل هنا الزمن ( سنوات ، أيام ، .... الخ ) ،  $m$  نقطة زمنية تمثل وصول النمو إلى نقطة المنتصف *midpoint* والتي يبدأ عندها النمو بالتباطؤ ، ( معلمة الإزاحة ) ، ويتم تقدير هذه المعلمات باستخدام خوارزمية L-BFGS .

**2- دالة النمو الخطية Linear Growth Function** : وهو يمثل معدل النمو البسيط على مستوى البيانات ، ويستخدم عندما لا يكون هنالك حد أعلى للسلسلة الزمنية ، أي لا يظهر حد معين لسلسلة الزمنية كما في النمو غير الخطي ، ويحسب وفق المعادلة التالية :

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T \gamma) \quad \dots (5)$$

### 2.3 الدالة الموسمية Seasonality Function

يستند حساب الدالة الموسمية  $F(t)$  في معادلة [3] إلى متسلسلة فورييه ( Fourier ) ، والتي تمتلك مرونة لقياس التأثيرات الموسمية في حالة الزيادة أو الانخفاض ، ولقياس  $F(t)$  يتم الاعتماد على الصيغة التالية:

$$F(t) = \sum_{n=1}^N \left[ \alpha_n \cos\left(\frac{2\pi n t}{s}\right) + b_n \sin\left(\frac{2\pi n t}{s}\right) \right] \quad \dots (6)$$

إذ ان :  $s$  تمثل الفترة الموسمية المتوقعة للبيانات ،  $N$  عدد الحدود في متسلسلة Fourier ،  $t$  الفترة الزمنية ، إذ أن  $(t = 1, 2, \dots, T)$  ،  $\alpha_n$  ،  $b_n$  وتمثل معلمات التعلم ( Learning Parameters ) ، ويتم تقدير هذه المعلمات باستخدام خوارزمية L-BFGS [2]. [11]

### 3.3 دالة الاحداث غير المنتظمة Irregular Events Function

يقصد بالأحداث غير المنتظمة هي العطلات (Holidays) ، والتي تؤثر بشكل واضح على السلسلة الزمنية ، فعلى سبيل المثال يمكن لعطلات الأعياد أن تزيد بشكل واضح من استهلاك الطاقة الكهربائية ، أو الحضور في المتاجر ومراكز التسوق ، ويمكن حساب دالة الاحداث وفق الصيغة الرياضية التالية :

$$h(t) = Z(t) K \quad \dots (7)$$

إذ ان  $K_i$  معلمة لكل عطلة ،  $Z(t)$  مؤشر يدل على إذا ما كان الوقت ( $t$ ) يقع في فترة الحدث (العطلة) ويحسب وفق الاتي : [11] [2]

$$Z(t) = [1 (t \in Day_1), \dots, 1 (t \in Day_i)] \quad \dots (8)$$

### 4. معايير المقارنة The Criteria For Comparison [12]

يتم تقييم أداء النماذج لغرض معرفة أي منها تمتلك أفضل قيم تنبؤية في كميات استهلاك الطاقة الكهربائية في محافظة بغداد ، إذ يتم التقييم بالاعتماد على مقاييس الخطأ ، وأن الأنموذج الأفضل هو الذي يمتلك أقل قيمة من هذه المقاييس ، والتي منها :

1- متوسط الخطأ المطلق (MAE) Mean Absolute Error : ويحسب وفق الصيغة التالية :

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad \dots (9)$$

2- متوسط الخطأ المطلق النسبي (MAPE) Mean Absolute Percentage Error : ويحسب وفق الصيغة التالية :

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad \dots (10)$$

3- جذر متوسط مربعات الاخطاء (RMSE) Root Mean Squared Error : ويمكن حسابه وفق الصيغة الرياضية التالية :

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad \dots (11)$$

إذ أن  $n$  : حجم العينة ،  $e_t$  الأخطاء العشوائية ،  $|e_t|$  القيمة المطلقة للأخطاء ،  $y_t$  القيمة الحقيقية ،  $\hat{y}_t$  القيمة المتنبأ بها .

### 5. الجانب التطبيقي

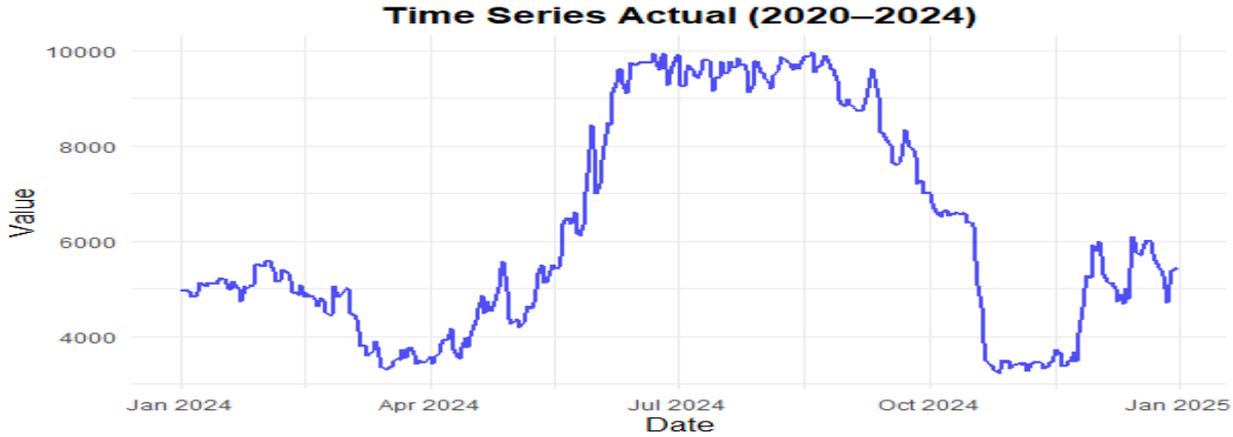
سيتم استخراج النتائج وتحليلها باستخدام برنامج (R-Programming) ، والذي يعد من أكثر البرمجيات شيوعاً في نمذجة البيانات الاحصائية وتحليلها .

### 1.5 وصف بيانات الدراسة Description of Study Data

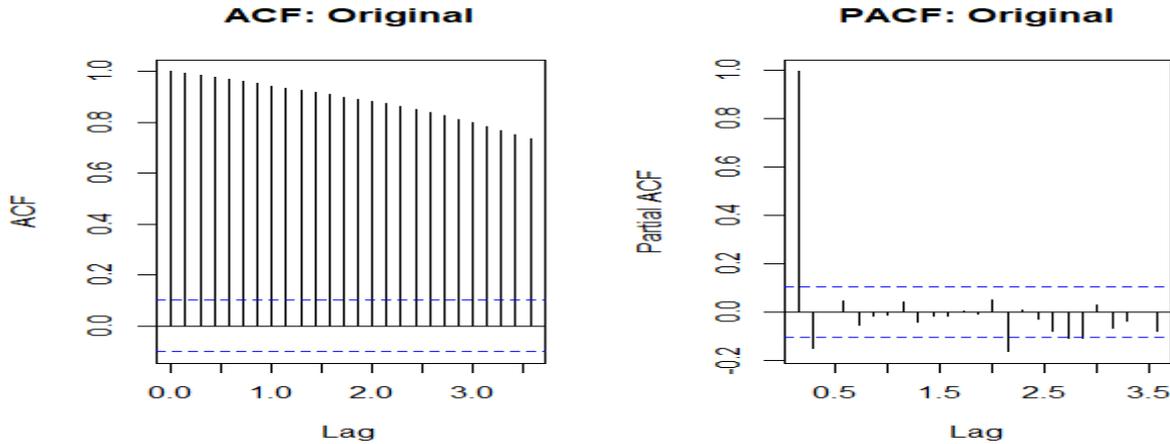
بيانات الدراسة تتمثل بالكميات المستهلكة من الطاقة الكهربائية في محافظة بغداد مقاسة بالكيلو واط / ساعة (Kw/h) اخذت على اساس يومي وللفترة الزمنية من 2024/1/1 الى 2024/12/31 ، وقد تم الحصول على هذه البيانات من وزارة الكهرباء / دائرة التشغيل والتحكم .

## 2.5 بناء أنموذج SARIMA

الخطوة الاولى من تحليل السلسلة الزمنية هي رسمها والتعرف على بعض مكوناتها كالاتجاه والتغيرات الموسمية والعرضية ، والتعرف على استقراريتها من حيث التباين والوسط الحسابي ، ورسم كل من دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) وسيتم ذلك من خلال الشكلين التاليين:



الشكل (1) يمثل رسم السلسلة الزمنية



الشكل (2) يمثل دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF)

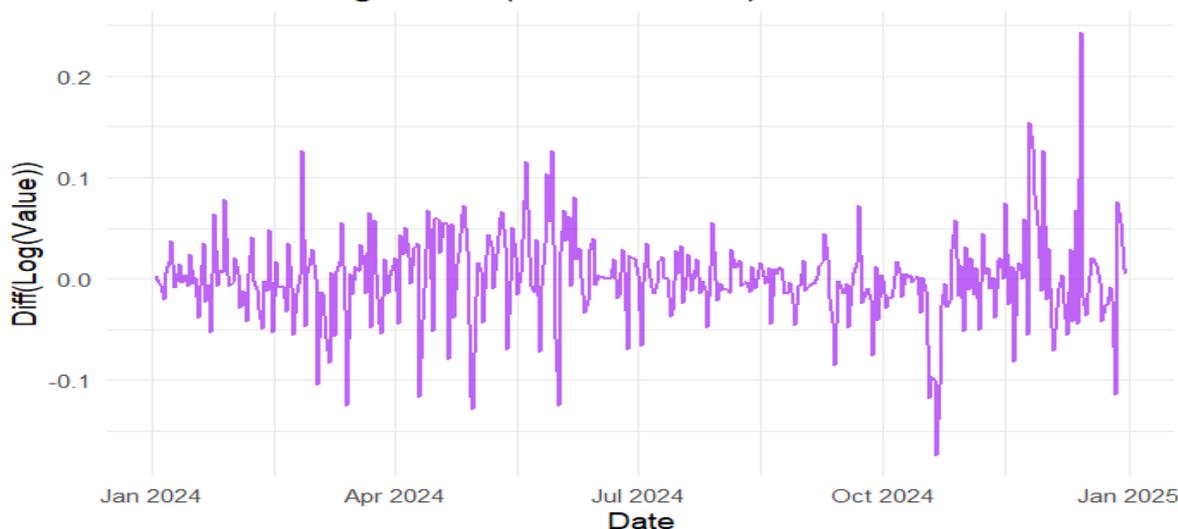
من خلال الشكل (1) نلاحظ ان البيانات لا تتذبذب حول متوسط ثابت ، من ذلك نستدل على ان السلسلة الزمنية غير مستقرة ، وهذا ما يؤكد الشكل (2) إذ ان معاملات دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) تقع خارج حدود الثقة ، وتم اجراء اختبار ديكي فولر الموسع للتأكد اكثر من عدم الاستقرارية والجدول التالي يبين نتائج الاختبار :

جدول (1) يبين نتائج اختبار ديكي فولر الموسع Augmented Dickey fuller

Dickey fuller	-1.0821
Lag order	7
p-value	0.9246

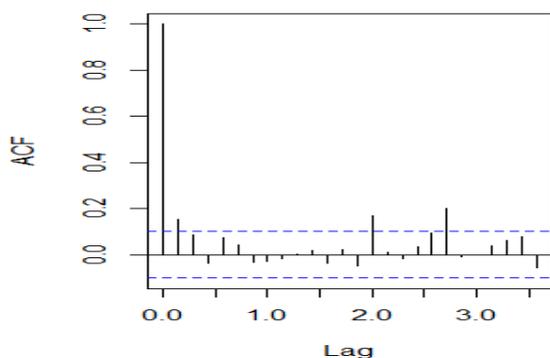
جدول (1) يبين بأن إحصاءة اختبار ديكي فولر معنوية وهذا يدعوننا الى قبول الفرضية القائلة بأن السلسلة الزمنية غير مستقرة ، وقمنا بمعالجتها وتحويلها الى سلسلة مستقرة من خلال التحويل اللوغاريتمي للبيانات واخذ الفرق الزمني الاول لها ، والشكلين (3) و (4) يبينان ذلك ، ومن ثم قمنا باختبارها من خلال اختبار ديكي فولر جدول (2) وظهرت احصاءة الاختبار غير معنوية ، وهذا ما يؤكد استقرار السلسلة الزمنية.

Differenced Log Series (1st Difference)

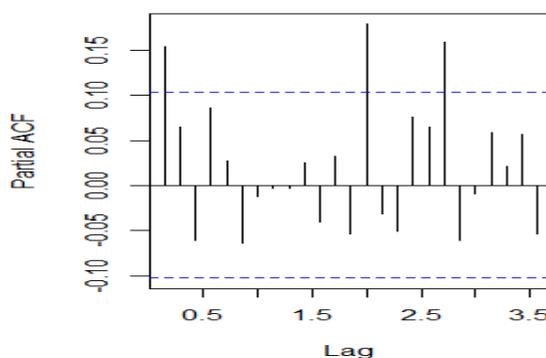


الشكل (3) يمثل السلسلة الزمنية بعد اخذ الوغاريتم والفرق الموسمي الاول لها.

ACF: Diff(Log)



PACF: Diff(Log)



الشكل (4) يمثل دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) بعد اخذ الفرق الموسمي الاول للبيانات التي تم اجراء التحويل اللوغاريتمي عليها

جدول (2) يبين نتائج اختبار ديكي فولر الموسع Augmented Dickey fuller بعد التحويلات التي تم إجراؤها على البيانات

Dickey fuller	-6.4579
Lag order	7
p-value	0.01

بعد التأكد من استقرار السلسلة الزمنية نقوم الآن بتحديد نموذج SARIMA المناسب ، وتمثل هذه المرحلة بتحديد ومعرفة الرتب المناسبة لأنموذج SARIMA (p, d, q, P, D, Q, S) ، ويُحدد تلك الرتب من خلال دراسة دالة الارتباط الذاتي (ACF) ، ودالة الارتباط الذاتي الجزئي (PACF) للسلسلة الزمنية ، إذ تُفحص الأنماط الظاهرة في رسم كل من الدالتين لتقديم اقتراحات حول القيم المناسبة ، وفي بعض الأحيان قد تعطينا دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي شكلاً يصعب تفسيره وكما هو الحال في الشكل (7) ، ، لذا فسنقوم بتحديد الرتب المناسبة من خلال معيار معلومات اكايكي (AIC) (Akaike Information) ، والجدول التالي يبين بعض من نماذج SARIMA المقترحة لتحديد واختيار أفضلها :

جدول (3) يبين بعض من نماذج SARIMA المقترحة لتحديد واختيار أفضلها

MODEL	AIC
ARIMA(1,1,2)(2,0,0)[7]	-1257.617
ARIMA(0,1,2)(2,0,0)[7]	-1257.763
ARIMA(0,1,3)(2,0,0)[7]	-1257.145
ARIMA(1,1,0)(2,0,0)[7]	-1257.335

يتضح لنا من خلال الجدول (3) ان افضل نموذج هو ARIMA(0,1,2)(0,0,2)[7] ، إذ امتلك اقل قيمة وفقاً لمعيار اكايكي .

أما تقدير معاملات الانموذج المناسب فكانت بتطبيق طريقة الامكان الاعظم Maximum Likelihood Method ودرجت النتائج وفق الجدول التالي :

جدول (4) يبين نتائج تقدير معاملات الانموذج

Parameter	Coefficient	std. error
MA (1)	0.1716	0.0536
MA (2)	0.1002	0.0502
SAR (1)	-0.0205	0.0519
SAR (2)	0.1870	0.0518
$\sigma^2$	0.001815	

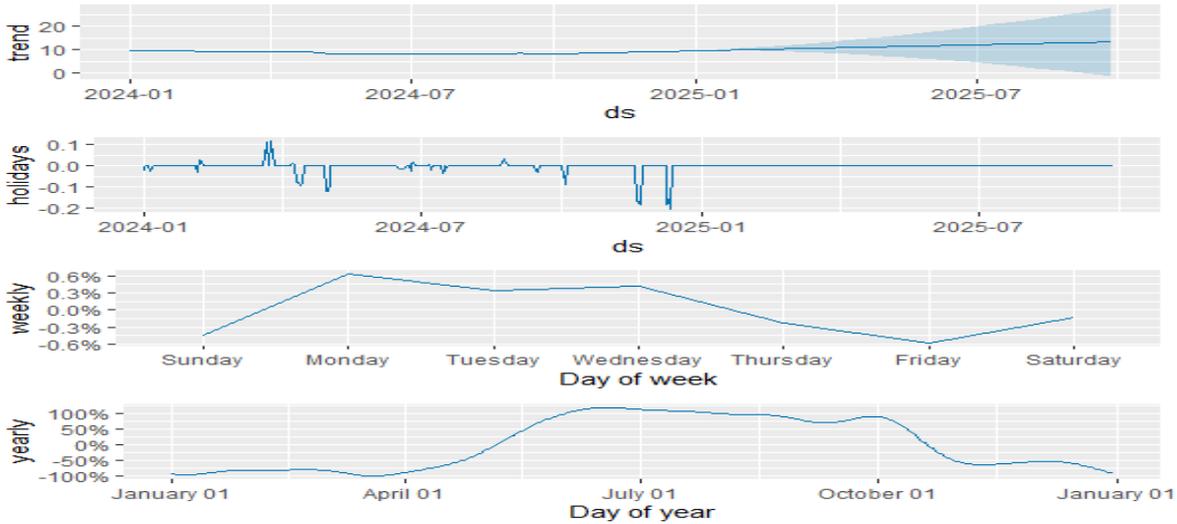
ولمعرفة مدى ملاءمة الأنموذج المناسب لبيانات الظاهرة المدروسة ، تم تطبيق اختبار ليونغ بوكس Ljung – Box Test لتحقيق هذا الغرض وكانت قيمة الاختبار غير معنوية مما يدل على عدم وجود ارتباط ذاتي بين الأخطاء ، والجدول التالي يبين نتائج هذا الاختبار:

جدول (5) يبين نتائج اختبار ليونغ بوكس Ljung – Box Test

Q (L-B)	6.1537
p-value	0.8022
Df	10

### 3.5 بناء أنموذج FB Prophet

الخطوة الاولى من بناء الأنموذج هو رسم مكونات السلسلة الزمنية للتعرف على الاتجاه العام والموسمية والاحداث الخاصة ، ويكون ذلك من خلال الشكل التالي :



#### شكل (5) يبين الاتجاه العام والموسمية والاحداث الخاصة لبيانات السلسلة الزمنية

نلاحظ من خلال الرسم الاول من الشكل (5) بان الاتجاه العام للسلسلة الزمنية يظهر تغير القيم عبر الزمن ، إذ نلاحظ ان الاتجاه في بداية السلسلة كان مستقراً ثم بدأ بالارتفاع التدريجي شيئاً فشيئاً ، أما الرسم الثاني فيوضح تأثير العطلات ، إذ تظهر قمم وانخفاضات حادة في فترات معينة مما نستنتج بأن هنالك تأثيراً للعطل على بيانات السلسلة الزمنية ، أما الرسم الثالث فيبين الموسمية الاسبوعية ، إذ يظهر هنالك نمط واضح يتغير بتغير ايام الاسبوع ، كما يبين ان فترة الذروة كانت يوم الاثنين ، اما الانخفاض الابرز فكان في يوم الجمعة ، اما الرسم الرابع فيمثل تكرار النمط خلال السنة الواحدة (تكرار النمط خلال اشهر السنة) ، ويشير الشكل الى ان السلسلة الزمنية تبلغ ذروتها في منتصف السنة ( اي في فصل الصيف ) وتنخفض في بداية ونهاية السنة ( اي في فصل الشتاء) .  
أما تقدير معالم الانموذج فكانت بتطبيق خوارزمية عددية وهي خوارزمية L-BFGS ، وكانت وفق الجدول التالي :

جدول (6) يبين نتائج تقدير معاملات الانموذج

Parameter	Coefficient
$k$ معدل النمو	0.2411
$m$ معلمة الازاحة	1.0271
$\delta$ يمثل مقدار الزيادة أو النقصان في معدل النمو	[1,1:30] -8.001 , 0.6781 , -0.2427 , ...
$\beta$ يمثل متجه معاملات سلسلة فورييه	[1,1:74] -0.5451 , -0.1083 , 0.0047 , ...

4.5 المقارنة بين النماذج

يتم تقييم أداء النماذج لغرض معرفة أي منها تمتلك أفضل قيم تنبؤية في كميات استهلاك الطاقة الكهربائية في محافظة بغداد ، وتم حساب معايير المقارنة للأنموذجين SARIMA و FB Prophet وكما في الجدول التالي :

جدول (7) يبين نتيجة المقارنة بين الانموذجين

critierion	SARIMA	FB Prophet	best model
MAE	0.030	0.034	SARIMA
MAPE	0.347	0.393	SARIMA
RMSE	0.042	0.051	SARIMA

من خلال جدول (7) نلاحظ تفوق أنموذج SARIMA ، إذ حصل على أقل قيمة من المعايير الثلاثة المستخدمة في هذا البحث ، وبالتالي سيتم التنبؤ باستهلاك الطاقة الكهربائية في محافظة بغداد وفق الأنموذج الافضل SARIMA ، والجدول التالي يبين القيم التي تم التنبؤ بها :

جدول (8) يبين القيم التنبؤية لبيانات استهلاك الطاقة الكهربائية في محافظة بغداد

Forecast	Lower_95	Upper_95	Forecast	Lower_95	Upper_95
5477.36	5038.55	5954.38	5428.32	3494.35	8432.65
5500.26	4836.40	6255.24	5424.37	3432.42	8572.32
5526.53	4676.98	6530.41	5414.00	3369.68	8698.58
5513.71	4523.64	6720.47	5408.59	3312.96	8829.84
5463.86	4364.32	6840.41	5403.49	3259.01	8959.07
5435.91	4239.43	6970.06	5401.65	3209.85	9090.10
5409.15	4127.59	7088.62	5397.45	3161.42	9214.98
5399.79	4040.68	7216.04	5375.62	3104.77	9307.39
5377.84	3951.63	7318.80	5390.12	3070.85	9461.04
5263.34	3801.78	7286.79	5400.92	3036.18	9607.45
5339.30	3794.37	7513.26	5403.06	2998.00	9737.53
5395.63	3775.29	7711.42	5404.19	2960.58	9864.72
5406.49	3726.98	7842.85	5405.06	2922.52	9996.41
5411.96	3677.72	7963.99	5406.02	2885.49	10128.29
5416.42	3614.50	8116.62	5407.81	2849.94	10261.42
5421.10	3552.56	8272.43			

### 6. الاستنتاجات

اهم ما توصل اليه البحث من استنتاجات هي :

1- من خلال دراسة السلسلة الزمنية تبين ان السلسلة غير مستقرة، وقد احتوت على المركبة الموسمية  
2- أنموذج SARIMA حقق ادنى قيم لمعايير الاداء مما يدل على كفاءته في نمذجة بيانات استهلاك الطاقة الكهربائية .

3- بالرغم من حصول أنموذج FB Prophet على قيم لمعايير الاداء اعلى من أنموذج SARIMA الا انها كانت تنافسية ، مما يشير الى انه انموذج كفوء .

### 7. التوصيات

اهم التوصيات التي من شأنها تعزيز من المنهجية البحثية للباحثين في المستقبل:

1- يوصى بتوظيف تقنيات التعلم الآلي في بحوث لاحقة ومقارنتها مع أحد الأنموذجين المستخدمين في هذا البحث لزيادة القدرة التنبؤية.

2- على الجهات المختصة الاستفادة من مخرجات هذا البحث لتطوير سياسات إدارة الطاقة الكهربائية وضمان استمرارية تزويد الطاقة بشكل أكثر فاعلية.

### 8. المصادر

[1]M. N. Hussain and A. Ali, "Forecasting of Pakistan's Import Prices of Black Tea Using ANN and SARIMA Model," vol. 6, 2017.

[2]A.-J. Mäkipää, "Forecasting Emergency Department Arrivals with Facebook Prophet library," *Electr. Eng.*, 2021.

[3]"Application of SARIMA Model and Simple Seasonal Exponential Smoothing on Diabetes Mellitus: A Case of Enugu State Teaching Hospital, Nigeria," *Eur. J. Stat. Probab.*, vol. 10, no. 1, pp. 21–32, Mar. 2022, doi: 10.37745/ejsp.2013/vol10no1pp.21-32.

[4]A. Hasnain, M. Z. Hashmi, B. Nadeem, M. M. Nizamani, and S. U. Bazai, "Ambient PM2.5 Prediction Based on Prophet Forecasting Model in Anhui Province, China," in *Proceedings of International Conference on Information Technology and Applications*, vol. 614, S. Anwar, A. Ullah, Á. Rocha, and M. J. Sousa, Eds., in *Lecture Notes in Networks and Systems*, vol. 614. , Singapore: Springer Nature Singapore, 2023, pp. 27–34. doi: 10.1007/978-981-19-9331-2\_3.

[5]C. Jeong and M. S. Kim, "Comparison Studies of Hybrid and Non-hybrid Forecasting Models for Seasonal and Trend Time Series Data," *J. Intell. Inf. Syst.*, vol. 19, no. 1, pp. 1–17, Mar. 2013, doi: 10.13088/jiis.2013.19.1.001.

[6]"clark-hu-ph-d-dissertation."

[7]Z. Luo *et al.*, "A Combined Model of SARIMA and Prophet Models in Forecasting AIDS Incidence in Henan Province, China," *Int. J. Environ. Res. Public. Health*, vol. 19, no. 10, p. 5910, May 2022, doi: 10.3390/ijerph19105910.

[8]S. F. Stefenon, L. O. Seman, V. C. Mariani, and L. D. S. Coelho, "Aggregating Prophet and Seasonal Trend Decomposition for Time Series

Forecasting of Italian Electricity Spot Prices,” *Energies*, vol. 16, no. 3, p. 1371, Jan. 2023, doi: 10.3390/en16031371.

[9]E. F. Agyemang, J. A. Mensah, E. Ocran, E. Opoku, and E. N. N. Nortey, “Time series based road traffic accidents forecasting via SARIMA and Facebook Prophet model with potential changepoints,” *Heliyon*, vol. 9, no. 12, p. e22544, Dec. 2023, doi: 10.1016/j.heliyon.2023.e22544.

[10]P. Ma *et al.*, “Multiscale Superpixelwise Prophet Model for Noise-Robust Feature Extraction in Hyperspectral Images,” *IEEE Trans. Geosci. Remote Sens.*, vol. 61, pp. 1–12, 2023, doi: 10.1109/TGRS.2023.3260634.

[11]S. J. Taylor and B. Letham, “Forecasting at scale,” Sep. 27, 2017, *PeerJ Preprints*. doi: 10.7287/peerj.preprints.3190v2.

[12]Y. Wang *et al.*, “An Advanced Data-Driven Hybrid Model of SARIMA-NNNAR for Tuberculosis Incidence Time Series Forecasting in Qinghai Province, China,” *Infect. Drug Resist.*, vol. Volume 13, pp. 867–880, Mar. 2020, doi: 10.2147/IDR.S232854.

## Predicting Electricity Consumption in Baghdad Governorate Using SARIMA and FB Prophet Models: A Comparative Study

**Mohammed Abdel Hamid Musa**<sup>(1)</sup>

(Department of Statistics, College of Administration and Economics, Al-Mustansiriyyah University)

[mohamad.abdalhamid@uomustansiriya.edu.iq](mailto:mohamad.abdalhamid@uomustansiriya.edu.iq)

**Suhad Ali Shaheed**<sup>(2)</sup>

(Department of Statistics, College of Administration and Economics, Al-Mustansiriyyah University)

[dr.suhadali@uomustansiriya.edu.iq](mailto:dr.suhadali@uomustansiriya.edu.iq)

### Abstract:

Electricity represents the important and vital nerve of both economic and social activities, as its consumption is one of the essential matters that has gained great importance, and it is also an important indicator of the level of development in modern societies. Through this, this research aimed to build highly accurate predictive models to analyze the electricity consumption data in Baghdad Governorate. This study relied on consumption data on a daily basis for the period from 1/1/2024 to 12/31/2024, which was obtained from the Operations and Control Department of the Ministry of Electricity. Two predictive models were used to achieve the research goal, including: the SARIMA model and the Facebook Prophet (FB Prophet) model. To compare the performance of each of the two models, the following comparison criteria were used: the Mean Absolute Error (MAE), the Mean Absolute Percentage Error (MAPE), and the Root Mean Square Error (RMSE). The results showed the superiority of the SARIMA model, as it obtained the lowest values of the above comparison criteria. Accordingly, the future values of the electricity consumption data in Baghdad Governorate were predicted by the model SARIMA.

**Keyword:** Sarima model, FB Prophet model, forecasting, electrical energy consumption.