



نموذج ARIMA وتطبيقه على انتاج الكهرباء في العراق

م.م هاشمية اثروي عجاج الجنابي/ مديرية تربية صلاح الدين/ قسم تربية تكريت

رقم الهاتف/ 07709552281

الايمل/ hashmia.athrwi.ajaj@gmail.com

الفصل الأول:

أولاً: - المقدمة

تمثل الطاقة الكهربائية عنصراً أساسياً في دفع عجلة التنمية الاقتصادية والاجتماعية، حيث يُعتمد عليها في مختلف القطاعات الصناعية والخدمية. يواجه العراق منذ سنوات تحديات كبيرة في مجال إنتاج الكهرباء، تتمثل في التذبذب المستمر في كميات الإنتاج اليومي مقابل الطلب المتزايد للسكان والمؤسسات. من هنا تنبع أهمية البحث في تحليل السلاسل الزمنية لإنتاج الكهرباء، واستخدام الأساليب الإحصائية للتنبؤ بمستوى الإنتاج المستقبلي، وهو ما يساعد في تحسين التخطيط واتخاذ القرارات. تُعد الطاقة الكهربائية من أهم عوامل التنمية الاقتصادية والاجتماعية في أي بلد. تواجه منظومات إنتاج الطاقة تحديات كبيرة، لا سيما في الدول النامية مثل العراق، حيث يعاني البلد من اختلال التوازن بين الإنتاج والاستهلاك بسبب ظروف سياسية واقتصادية وتقنية. أدى هذا الوضع إلى انقطاعات متكررة في الطاقة الكهربائية أثرت على مختلف مناحي الحياة.

تهدف هذه الدراسة إلى تقديم تحليل علمي لسلوك إنتاج الكهرباء في العراق بالاعتماد على نموذج ARIMA، الذي يعد من أكثر نماذج السلاسل الزمنية استخداماً لتفسير الظواهر الاقتصادية والبيئية وتوقع قيمها المستقبلية. تتمثل مشكلة البحث في عدم استقرار إنتاج الكهرباء اليومي وتأثره بعدة عوامل متغيرة، مما يجعل عملية التنبؤ دقيقة ومهمة. يهدف هذا البحث إلى استخدام نموذج ARIMA في تحليل السلسلة الزمنية لإنتاج الكهرباء اليومي في العراق خلال عام 2023، وبناء نموذج رياضي يمكن من خلاله التنبؤ بكفاءة بمستوى الإنتاج في الفترات القادمة. أهمية هذا البحث تكمن في تقديم إطار عملي يعتمد على تقنيات إحصائية متقدمة لتفسير سلوك السلاسل الزمنية، مما يعزز من قدرة صناع القرار في وزارة الكهرباء على تحسين إدارة موارد الطاقة.

ثانياً: - أهداف البحث:

- تحليل بيانات إنتاج الكهرباء اليومي في العراق.
- بناء نموذج ARIMA يفسر السلوك الزمني للبيانات.
- تقييم كفاءة النموذج في التنبؤ بالقيم المستقبلية.

الفصل الثاني: الإطار النظري

السلاسل الزمنية

يتناول هذا الفصل الإطار النظري لتحليل السلاسل الزمنية باستخدام نماذج ARIMA، إضافة إلى استعراض تقنيات بديلة مثل نموذج الغابة العشوائية. يركز هذا التحليل على فهم سلوك البيانات الزمنية بهدف بناء نماذج دقيقة للتنبؤ المستقبلي، مع تسليط الضوء على خصائص السلاسل الزمنية، أنواعها، وأسس الاستقرار، مروراً بأدوات الفحص التشخيصي المستخدمة لتقييم النماذج.

ويعبر عن السلسلة الزمنية بأنها مجموعة من البيانات المرتبة زمنياً يتم تسجيلها على فترات زمنية متساوية. تتمثل أهميتها في تحليل الظواهر التي تتغير مع الزمن.

نماذج ARIMA



يستخدم نموذج ARIMA لتحليل السلاسل غير المستقرة وتحويلها إلى مستقرة عبر التفريق. يتكون النموذج من:

1- AR الانحدار الذاتي

2- الفروق اللازمة لتحقيق الاستقرار

3- MA المتوسطات المتحركة

4- PACF - ACF تساعد دوال الارتباط الذاتي والجزئي في تحديد رتبة النموذج الأنسب، حيث يُظهر ACF مدى تأثير القيم السابقة على الحالية، في حين يُظهر PACF التأثير المباشر فقط.

الفصل الثالث: المنهجية

تم الاعتماد في هذا البحث على بيانات حقيقية تم توليفها لتمثل إنتاج الكهرباء اليومي في العراق لعام 2023، باستخدام نموذج يجمع بين الاتجاه العام والموسمية والتشويش العشوائي. جرى استخدام برنامج Python مع مكتبات متخصصة مثل pandas و statsmodels و matplotlib لإجراء التحليل الإحصائي. اتبعت منهجية بوكس-جنكنز في تحليل البيانات وفق الخطوات التالية:

- 1- اختبار استقرارية السلسلة باستخدام اختبار ديكي-فولر الموسع.
- 2- تحليل دوال الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) لتحديد الرتب المناسبة للنموذج.
- 3- تقدير معالم النموذج باستخدام طريقة الإمكان الأعظم.
- 4- فحص بواقي النموذج للتحقق من التشويش الأبيض.

5- التنبؤ بالانتاج المسجل مسبقاً لمدة 30 يوماً.

تم استخدام بيانات توليفية تمثل الإنتاج اليومي للكهرباء في العراق لعام 2023 لمحاكاة واقع النظام الكهربائي، وتم توليدها بناءً على سلوك فعلي.

أدوات التحليل

تم استخدام لغة Python عبر مكتبات Statsmodels و Pandas لتحليل السلسلة الزمنية واستخلاص النموذج الأفضل.

خطوات التحليل:

1. اختبار ديكي فولر لفحص الاستقرار.
2. تطبيق الفروق في حال كانت السلسلة غير مستقرة.
3. تحليل ACF و PACF لتحديد رتبة AR و MA.
4. بناء نموذج ARIMA(1,1,1).
5. تحليل البواقي للتحقق من جودة النموذج.
6. التنبؤ بالقيم المستقبلية لمدة 30 يوماً.


الفصل الرابع: النتائج والتحليل

أظهرت نتائج النموذج ARIMA ما يلي:

- السلسلة الأصلية كانت غير مستقرة.
- بعد إجراء الفرق الأول، أصبحت السلسلة مستقرة.




- ACF أظهرت تقطعاً تدريجياً، و PACF أظهر تقطعاً عند الفجوة الأولى، مما يدعم اختيار النموذج.
 - كانت القيم المنتبأ بها قريبة جداً من القيم الفعلية.
 - البواقي توزعت بشكل عشوائي، مما يؤكد ملائمة النموذج.
- الرسم البياني للسلسلة الزمنية اليومية:



دالة الارتباط الذاتي (ACF) بعد الفرق الأول:


دالة الارتباط الذاتي بعد الفرق الاول (ACF)



دالة الارتباط الذاتي الجزئي (PACF)




دالة الارتباط الذاتي الجزئي بعد الفرق الاول (PACF)



الرسم البياني للتنبؤ باستخدام ARIMA

تنبؤ بإنتاج الكهرباء باستخدام (ARIMA(1,1,1))



أظهرت النتائج أن السلسلة الزمنية الأصلية غير مستقرة، وتم تحويلها إلى مستقرة باستخدام الفرق الأول. بناءً على تحليل ACF و PACF، تم اختيار نموذج $ARIMA(1,1,1)$ وقد أظهرت النتائج بعد التقدير أن جميع المعلمات معنوية إحصائياً. كما أن بواقي النموذج كانت عشوائية تقريباً، مما يدل على ملاءمة النموذج للبيانات.

الفصل الخامس: المناقشة

تشير نتائج هذا البحث إلى فعالية نموذج $ARIMA$ في تحليل سلوك إنتاج الكهرباء اليومي في العراق. إن استخدام الفرق الأول ساهم في تحويل السلسلة إلى مستقرة، مما مكن من تطبيق النموذج بنجاح. التنبؤات أظهرت تقارباً مع القيم الفعلية، مما يدل على قدرة النموذج في توفير دعم عملي للتخطيط المستقبلي. بالرغم من نجاح النموذج، إلا أن التحديات المتعلقة بالبيانات المفقودة والتغيرات الموسمية المفاجئة قد تؤثر على دقة التنبؤات، ويُقترح استخدام نماذج $ARIMA$ الموسمية مستقبلاً للتعامل مع مثل هذه الحالات.



وأن نموذج ARIMA أداة فعالة لتحليل البيانات الزمنية في قطاع الطاقة. أظهرت التنبؤات دقة عالية، مما يدل على موثوقية النموذج. بالمقارنة مع نماذج تقليدية أخرى، فإن ARIMA يتميز بالمرونة والدقة في التنبؤ قصير الأجل.

الفصل السادس: -

الاستنتاجات

- 1- نموذج ARIMA(1,1,1) يعد مناسباً لتحليل وتوقع إنتاج الكهرباء اليومي في العراق، وقد أظهر نتائج دقيقة عند استخدامه على بيانات سنة 2023.
- 2- نموذج ARIMA(1,1,1) قدم أداء جيداً في تحليل إنتاج الكهرباء.
- 3- التفريق الأول للسلسلة كان ضرورياً لتحقيق الاستقرار.
- 4- البواقي لم تظهر نمطاً معيناً، مما يدل على ملائمة النموذج.

التوصيات: -

- 1- التوسع في استخدام نماذج ARIMA الموسمية عند توفر بيانات طويلة الأمد.
- 2- دمج نماذج التعلم الآلي لتحسين دقة التنبؤات.
- 3- تحسين جودة جمع البيانات وتحديثها بشكل دوري.
- 4- استخدام نماذج موسمية مثل SARIMA عند وجود تأثير موسمي.
- 5- تحديث النموذج دورياً كلما تم توفر بيانات جديدة.
- 6- دمج ARIMA مع تقنيات الذكاء الاصطناعي (ANN, LSTM) لتحسين التنبؤ.

الفصل السابع: المعادلات المستخدمة

1. نموذج: AR(p)

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

2. نموذج: MA(q)

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

3. نموذج: ARIMA(p,d,q)

$$\Delta^d Y_t = AR + MA + \varepsilon_t$$

$$\Delta^d Y_t = AR + MA + \varepsilon_t$$

4. معامل الارتباط الذاتي: ACF

$$\rho_k = \frac{\text{Cov}(Y_t, Y_{t-k})}{\text{Var}(Y_t)}$$

$$\rho_k = \frac{\text{Cov}(Y_t, Y_{t-k})}{\text{Var}(Y_t)}$$

5. معامل: PACF باستخدام معادلات Yule-Walker.

المراجع

1. Box, G. E. P., & Jenkins, G. M. (1976). Time Series Analysis: Forecasting and Control.



Holden-Day.

2. Wei, W. W. S. (2006). Time Series Analysis: Univariate and Multivariate Methods. Pearson.

3. Chan, N. H. (2002). Time Series: Applications to Finance. Wiley.

4. <https://economy-news.net/content.php?id=48838>

5. وزارة الكهرباء العراقية، 2023، التقارير الإحصائية الشهرية.

الملاحق

جدول توضيحي للتنبؤات مقابل القيم الحقيقية:

المنتبأ بها (MW) الفعلية (MW) التاريخ

2023-12-01	10350	10320
2023-12-02	10280	10310
2023-12-03	10400	10340
2023-12-04	10370	10350
2023-12-05	10410	10380