

دراسة إحصائية مقارنة بين نموذجي ARIMA و ANN للتنبؤ بأسعار النحاس العالمية خلال (1990-2018)

A Comparative Statistical Study of ARIMA and ANN Modelsto Forecast Global Copper Prices During (1990 -2018)

طارق الدوب¹، شادي التلبياني^{2*}، سمير أبو دحروج³

¹ أكاديمية سعد العبد الله للعلوم الأمنية / الكويت

² جامعة الأزهر غزة / فلسطين

³ جامعة الأزهر غزة / فلسطين

تاريخ الاستلام : 2019/12/13 ; تاريخ المراجعة : 2019/12/17 ; تاريخ القبول : 2020/05/20

ملخص: تناول هذا البحث استخدام نموذج الانحدار الذاتي والمتosطات المتحركة التكامالية ARIMA ونموذج الشبكات العصبية الاصطناعية ANN، بالاعتماد على بيانات السلسلة الزمنية الشهرية لأسعار النحاس العالمية للفترة الزمنية من شهر يناير 1990 حتى شهر ديسمبر 2018. ومن خلال المقارنة بين نموذج ARIMA ونموذج ANN باستخدام معايير التقييم MAE وRMSE، توصل البحث إلى أن نموذج ANN هو النموذج الأنسب للتنبؤ المستقبلي بأسعار النحاس العالمية، وذلك لامتلاكه أقل القيم لمقياس دقة التنبؤ. وبالاعتماد على هذا النموذج تم التنبؤ بأسعار النحاس العالمية حتى نهاية شهر ديسمبر 2019، وقد كانت القيم التنبؤية متناسبة مع القيم الأصلية للسلسلة مما يدل على كفاءة النموذج.

الكلمات المفتاح: انحدار ذاتي ؛ متosطات متحركة ؛ شبكات عصبية اصطناعية ؛ تنبؤ.

C53; C45; C22: JEL تصنيف

Abstract: The research talk over the use Autoregressive Integrated Moving Average (ARIMA) and the artificial neural networks (ANN).based on the data of the monthly time series for Global copper from Jan 1990 until Dec 2018. Through comparing ARIMA Model with ANN Model using evaluation criteria (RMSE, MAE),This research conducts the model ANN it is the most appropriate model to forecast the prices of Global sugar because it has the lowest value of accuracy forecasting. Based on this model, The prices of Global copper were predicted until the end of Dec 2019. As a result, the predicted values were consistent with the real values of the series showing the efficiency of the model.

Key Words: Autoregressive;Moving Average ; Artificial Neural Networks ;Forecasting.

Jel Classification Codes : C22 ; C45 ; C53

* Corresponding author, e-mail: shtelbany@gmail.com

I. مقدمة

يعتبر النحاس من أول المعادن التي استخدمها الإنسان، وثاني المعادن من حيث تعدد المنافع بعد الحديد، وقد تم اكتشافه منذ أكثر من عشرة آلاف عام قبل الميلاد، ويوجد في الطبيعة بكميات متواترة الوفرة حيث تبلغ نسبته 0.012% وزناً في القشرة الأرضية، كما أنه يوجد على هيئة خامات متحدةً مع الكبريت والحديد (واصل، 2006).

كما يستخدم في الكثير من الصناعات، وفي إنتاج الطاقة، ومن أجل الحصول على تنبؤات دقيقة فإن ذلك يتطلب دراسة تحليلية وافية للنمذاج الإحصائية، فقد جاءت نماذج الانحدار الذاتي والمتosteات المتحركة التكمالية ARIMA لنماذج الجزء الخطى من السلسلة وأسلوب الشبكات العصبية الاصطناعية ANN لنماذج الجزء غير الخطى.

II. مشكلة البحث:

تبليغ مشكلة الدراسة في تحديد النموذج المناسب للتتنبؤ بأسعار النحاس العالمية من خلال المقارنة من بين نموذجي ARIMA و ANN، فعدم وجود نموذج إحصائى مناسب للتتنبؤ الدقيق بأسعار النحاس المستقبلية يعكس بدوره على رسم السياسات المالية والاقتصادية في المستقبل، مما يكون له آثار سلبية على عملية التخطيط بشكل عام، حيث إن هناك العديد من الأساليب الإحصائية التي يمكن من خلالها بناء نماذج للتتنبؤ وبالتالي فإن مشكلة البحث تتمحور في التساؤل الرئيس التالي:

ما هو النموذج الأمثل من بين نماذج ARIMA و ANN للتتنبؤ بأسعار النحاس العالمية؟

III. أهداف البحث:

- 1- بناء نموذج ARIMA واستخدام منهجية Box and Jenkins.
- 2- بناء نموذج الشبكات العصبية ANN باستخدام شبكة MLP.
- 3- المقارنة بين النماذجين السابقين للوصول إلى النموذج الأمثل.

IV. أهمية البحث:

- 1- الوصول إلى النموذج التنبؤياً أكثر دقة عند تحليل بيانات أسعار النحاس العالمية باستخدام أسلوب ARIMA و ANN.
- 2- مساعدة الباحثين في تحسين الممارسة البحثية من خلال اختيار النموذج المناسب الذي يحقق توقعًا جيداً.

V. الدراسات السابقة:

(الشمرانى، 2018): هدفت هذه الدراسة إلى استخدام أسلوب الشبكات العصبية ونماذج أريما ARIMA للتتنبؤ بأعداد المصاين من حوادث الطرق بمدينة مكة المكرمة، بالاعتماد على بيانات سلسلة زمنية لعدد حوادث المرور وأعداد المصاين من عام (1425هـ-1435هـ) بواقع 132 مشاهدة، وتوصلت نتائج الدراسة إلى أن نموذج الشبكات الأفضل في التنبؤ عن نموذج أريما، حيث تشير جميع معايير التنبؤ RMSE, MSE, MAPE, MAE إلى أن قيم نموذج الشبكات العصبية أقل من مثيلاتها في نموذج أريما.

(الخياط و زكي، 2005): هدفت هذه الدراسة إلى استخدام أسلوب الشبكات العصبية في التنبؤ باستهلاك الطاقة الكهربائية بمدينة الموصل ومقارنته بأسلوب Box and Jenkins كطريقة للتتنبؤ، وخلصت الدراسة إلى تفوق أسلوب الشبكات العصبية في التنبؤ على أسلوب ARIMA(2,1) و المتمثل في نموذج Box and Jenkins.

(جبارة، 2012): هدفت هذه الدراسة إلى معرفة مدى كفاءة نماذج Box-Jenkins والشبكات العصبية في التنبؤ بالسلسل الرزمية لمناسيب الفيل والمفاضلة بين هذه النماذج وتم بناء نموذج (1,1,0) ARIMA وقد تم التأكد من أن هذا النموذج جيد ويعطى تنبؤات دقيقة وقريبة من الواقع كما تم بناء نماذج الشبكات العصبية والذي تكونت بيته المعمارية من ثلاث طبقات (طبقة مدخلات (2) و طبقة خفية (5) و طبقة مخرجات (1)) واتضح أن الشبكة الناتجة جيدة وأعطت تنبؤات دقيقة وقريبة من الواقع وخلصت الدراسة إلى كفاءة الأسلوبين في التعامل مع السلسل الرزمية ولكن تفضيل نماذج الشبكات على نماذج Box-Jenkins.

(Adebiyi, et al., 2014): هدفت الدراسة فارنة نماذج أريما والشبكات العصبية الاصطناعية للتتنبؤ بسعر الأسهم المنشورة التي تم الحصول عليها من بورصة نيويورك. توصلت نتائج الدراسة تفوق نموذج الشبكات العصبية على نموذج ARIMA.

(Alhashimi, 2014): في هذه الدراسة تم مقارنة أداء ثلاثة نماذج ARIMA و ANN و MLR و تطبقها على مجموعة بيانات السلسل الزمنية الشهرية للتتنبؤ بكميات الأمطار وسرعة الرياح ومتوسط درجة الحرارة والرطوبة النسبية خلال الفترة الزمنية (1970-).

ARIMA 2008(مخطة كركوك) فبنت النتائج أن التنبؤ باستخدام نموذج ANN الشبكات العصبية الاصطناعية هي أكثر دقة من نموذجي MLR و.

VI. الجانب النظري:

VI.1 - خاتمة Box and Jenkins

تم منهجهية Box and Jenkins بأربعة مراحل أساسية يتم من خلالها الوصول إلى النموذج الأمثل للتنبؤ بالسلسلة الزمنية محل الاهتمام، وتلخص المراحل الأربع الأساسية في الآتي (عناني وآخرون، 2002):

1 - مرحلة التعرف: تتمثل أولى خطوات هذه المرحلة في التأكيد من سكون السلسلة الزمنية، ويمكننا أن نصف السلسلة بأنها ساكنة إذا توافرت بها ثلاثة شروط هي: ثبات قيمة الوسط الحسابي وعدم تغيره مع الزمن، ثبات التباين، أن يكون التباين المشترك لا يعتمد على الزمن وإنما يعتمد على الفرق (فتره الإبطاء) بين الزمنين Lag Time، فإن لم يتوافر أحد هذه الشروط أو جميعها تكون السلسلة غير ساكنة، ويتم عادة تحويل السلسلة غير الساكنة إلى سلسلة غير ساكنة عن طريقأخذ الفروق لتشييد الوسط الحسابي ومن ثم التخلص من الاتجاه العام، وكذلك تحويل البيانات بمدف تثبيت التباين وتعبر التحويلة اللوغاريتمية وتحويلة الجذر التربيعي من أكثر التحويلات استخداماً في هذا الشأن، وينعكس سكون السلسلة على سلوك دوال الارتباط الذائي لها حيث تتناقص سريعاً في اتجاه الصفر، ويكون فحص دوال الارتباط الذائي ودوال الارتباط الذائي الجزئية ذو فائدة كبيرة في هذه المرحلة للتعرف على رتبة نموذج ARIMA الذي يصف السلسلة بشكل مناسب.

2 - مرحلة التقدير: حيث يتم تقدير معلم النموذج الذي تم اختياره، وذلك باستخدام طريقة المربعات الصغرى.

3 - مرحلة التشخيص: حيث يتم اختبار البواقي من النموذج المقدر لكي تتأكد من أنه مناسب إحصائياً، ويساعد فحص النموذج في إعطاء فكرة جيدة عن كيفية إعادة صياغة النموذج غير المناسب، وإذا تبين أن النموذج المقدر غير مناسب فإنه عندئذ يجب الرجوع إلى مرحلة التعرف مرة أخرى لاختيار نموذج بديل أو أكثر.

4 - مرحلة التنبؤ: بعد أن تم تقدير وفحص نموذج ARIMA والتأكيد من أنه مناسب إحصائياً فإنه يمكن استخدامه في التنبؤ بالقيم المستقبلية للظاهرة.

VI.2 - الشبكات العصبية الاصطناعية ANN:

بعد التنبؤ باستخدام الشبكات العصبية من الأساليب الحديثة التي لاقت اهتماماً واسعاً في مجالات متعددة منها التنبؤ بأسعار العملات والموارد المالية وغيرها، واستخدمت بشكل واسع لكونها لا تحتاج إلى شروط صارمة ودقيقة لغرض التنبؤ، كما أنه يمكن تفسير سلوك البيانات غير الخطية. ويمكن تلخيص مراحل التنبؤ باستخدام الشبكات العصبية الاصطناعية بالخطوات الآتية (السعادي، 2016)، (عبد النور، 2005):

الخطوة الأولى: تحديد المتغيرات

إذا تم استخدام الشبكة العصبية كنموذج انحدار متعدد غير خططي فإن المتغير المعتمد يكون دالة غير خطية للمتغيرات المفسرة أما إذا تم استخدام الشبكة العصبية للتنبؤ بالقيم المستقبلية للسلسلة الزمنية فعندئذ يكون المتغير عند الزمن (t) هو دالة غير خطية للمتغير ذاته عند إزاحت مختلفة وهي $(y_{t-p}, \dots, y_{t-1}, y_t)$.

الخطوة الثانية: جمع البيانات

على الباحث القيام بفحص البيانات للمتغيرات المفسرة عندما يكون نموذج الشبكة العصبية انحدار غير خططي متعدد فقد يكون بعضها مفقود أو غير موجود، أما عند استخدام الشبكة للتنبؤ بقيم السلسلة الزمنية فالحالة تكون أسهل إذ يكون عليه جمع مشاهدات متغير واحد ومحاولة معالجة مشكلة القيم المفقودة إن وجدت في السلسلة الزمنية.

الخطوة الثالثة: معالجة البيانات

نادرًاً ما يتم تغذية الشبكة العصبية بالمدخلات والخرجات تحتها بشكل مواد خام أو اجراء بعض التحويلات عليها وتوجد عدة طرق لتهيئة البيانات منها (عبد العزيز و الوكيل، 2015):

1- الصيغة البسيطة Simple Formula

تعتمد هذه الصيغة على أكبر قيمة في البيانات وتأخذ العلاقة الآتية

$$X_{new} = \frac{x}{x_{max}}$$

2- الصيغة الطبيعية Normalized Formula

تستخدم هذه الصيغة عندما تكون دالة التنشيط في عقدة الإخراج هي الدالة اللوجستية وتوصف بالعلاقة الآتية:

$$X_{new} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

3- الصيغة المعيارية Standardized Formula

تستخدم هذه الصيغة عندما تكون دالة التنشيط في عقدة الإخراج هي الدالة الخطية وتوصف بالعلاقة الآتية

$$x_{new} = \frac{x - \bar{x}}{s}$$

حيث أن: \bar{x} : الوسط الحسابي ، s : الانحراف المعياري

4- الصيغة الطبيعية المعدلة Adjusted Normalized Formula

تُستخدم هذه الصيغة عندما تكون دالة التنشيط من النوع اللوجستية الثنائية القطب وتكون صيغة التعديل للبيانات كالتالي:

$$X_{new} = \frac{2(x - x_{min})}{x_{max} - x_{min}} - 1$$

الخطوة الرابعة: تقسيم البيانات إلى مجامي:

تقسم البيانات المتوفرة إلى المجامي الآتية:

1) مجموعة التدريب: هي مجموعة من بيانات السلسلة الزمنية إذ تستعمل هذه المجموعة في تدريب الأوزان وتدريب الشبكة على التنبؤ عن طريق تحديد نموذج للبيانات.

2) مجموعة الاختبار: وهي جزء من بيانات السلسلة الزمنية ولعنة لم تستعمل في التدريب، حيث تقوم باختبار قابلية الشبكة على التنبؤ بعد عملية التعليم ولا يوجد أساس علمي لتحديد تجزئة البيانات إلى مجامي تعلم واختبار.

3) مجموعة التقويم: وهي مجموعة كافية لتقويم أداء تدريب الشبكة العصبية بصورة عامة.

الخطوة الخامسة: تحديد نموذج الشبكة العصبية

عند تحديد نموذج الشبكة العصبية يجب اختيار ما يلي:

- عدد العصبونات للإدخال والذي يساوي عدد المتغيرات المستقلة.

- عدد الطبقات المخفية والذي يفضل استخدام طبقة مخفية واحدة في أغلب تطبيقات التنبؤ باستخدام الشبكات العصبية.

- عدد العصبونات المخفية والذي يحدد عن طريق التجربة.

- عصبون الإخراج والذي عادةً يساوي واحد.

الخطوة السادسة: اختيار دوال التنشيط

وهي المعادلات الرياضية التي تحدد الناتج لمعالجة الشبكات العصبية وتسمى أيضاً بـ دوال التحويل وغالباً الشبكات العصبية الحالية تستخدم الدالة اللوجستية في الطبقة المخفية، والدالة الخطية عند طبقة المخرجات عندما يكون أكثر من عقدة للناتج.

الخطوة السابعة: تدريب الشبكة

إن عملية تدريب الشبكة على التنبؤ تضم الخطوات التالية:

- تحديد قيم الأوزان الأولية: وتعد نقطة البداية لعملية التدريب غالباً ما يتم اختيار قيم عشوائية صغيرة للأوزان تقع ما بين (-1, 1).
- عدد تكرارات التدريب: تنتهي عملية التدريب عندما يتجاوز قيمة خطأ التقدير نسبة الخطأ المقبولة والتي قد تحدد بحسب ما يراد معالجته في الشبكة.
- معدل التعلم α وعامل الزخم: يعتبر معدل التعلم من العوامل المؤثرة على سرعة تحديث الأوزان في الشبكة العصبية كما أن عامل الزخم يجعل عملية التعلم ومقدار التغير في الوزن مستقر نسبياً.

الخطوة الثامنة: التفريز

تُعد من أهم الخطوات حيث تختبر الشبكة من حيث قدرة التكيف وإمكانية إعادة التدريب والوصول إلى أقل مربع خطأ عند تغيير البيانات للوصول إلى حالة الاستقرار، ويتم بناء الشبكات العصبية عن طريق البرمجة ويتكون من عدد كبير من الدورات التي يزيد استعمالها حل مشكلة معينة.

VII. الجانب التطبيقي:

السلسلة المتاحة لدينا تمثل أسعار النحاس العالمية للفترة الزمنية الممتدة من يناير 1990 ولغاية أكتوبر 2019 بواقع 358 مشاهدة، وتم تناول أول 348 مشاهدة في التحليل من الفترة يناير 1990 ولغاية ديسمبر 2018 وأبقيت المشاهدات العشر الأخيرة من الفترة يناير 2019 ولغاية ديسمبر 2019 لأغراض التنبؤ والمقارنة بين النماذج. وذلك بالاعتماد على برمجية R لتحليل بيانات الظاهرة. ولأخذ فكرة عامة عن البيانات سيتم عرض بعض المؤشرات الإحصائية البسيطة التي تدلنا على طبيعة البيانات. من الجدول رقم (1) يمكننا أخذ فكرة سريعة وأولية عن السلسلة الزمنية موضع البحث، حيث نلاحظ أن سلسلة أسعار النحاس تتكون من 228 مشاهدة، مستوى متوسط 4244.505، وقيمة صغرى سُجلت في بداية الفترة 1377.37، وقيمة كبرى سُجلت في نهاية الفترة 9880.938، وتعكس لنا هاتين القيمتين على الترتيب أكبر نسبياً نمو وانخفاض عرقتها أسعار النحاس خلال فترة البحث، بينما يُنصف هذه السلسلة مستوى وسيطي 3006.333، وتشتت قيم السلسلة عن متوسطها بانحراف معياري قدره 2471.353، وهو ما يعطينا فكرة حول درجة عدم تجانس مستويات السلسلة نتيجة التقليبات الحادة لأسعار النحاس كونها تتأثر بعدة عوامل.

VII.1 – تطبيق منهجية Box & Jenkins للتنبؤ بأسعار النحاس :

سنطبق منهجية Box & Jenkins للتنبؤ بأسعار النحاس الشهرية لمعرفة سلوكها في المستقبل.

أولاً: وصف السلسلة من حيث الاستقرار

وتتمثل أولى خطوات تلك المرحلة في فحص استقرار السلسلة الزمنية، وتطبيق التحويلات الازمة لجعلها مستقرة إن لم تكن كذلك، ولمعرفة ذلك يتم فحص التوقع البياني لسلسلة أسعار النحاس وفق منظمة الأوبك العالمية من حيث ثبات التباين والوسط والحساسي.

وذلك من خلال رسم المحنن التاريخي للظاهرة للتعرف على الخصائص المميزة للسلسلة الزمنية من حيث وجود اتجاه عام من عدمه، أو عدم ثبات التباين، أو وجود قيم متطرفة أو قيم شاذة ضمن السلسلة أو غير ذلك من المشاكل العلمية. نلاحظ من الشكل (1) وجود اتساع في التذبذب مع مرور الزمن في بعض قيم السلسلة وهذا يعني أنها غير مستقرة في التباين، ونلاحظ أيضاً وجود اتجاه عام متزايد وتارة أخرى متناقض مع الزمن مما يدل على عدم استقرارية بيانات السلسلة في المتوسط.

ولتسكين السلسلة في التباين تم أخذ التحويلة اللوغاريتمية لبيانات السلسلة، ومن ثم إعادة رسم السلسلة فيصبح الشكل البياني للسلسلة بعد أخذ التحويلة اللوغاريتمية للسلسلة كما يظهر في الشكل (2). ونلاحظ أن التحويل أعطى تحسناً ملحوظاً لهذه السلسلة، مما يدل على أن هذه

السلسلة مستقرة في التباين، وفيما يتعلق بالاستقرارية في المتوسط يبدو من خلال الشكل (2) إلى وجود اتجاه عام مما يؤكّد أن السلسلة غير مستقرة في المتوسط، ولتسكين السلسلة في الوسط، تمّأخذ الفروق الأولى للوغاريتيم السلسلة الأصلية، ومن ثمّ تمّ إعادة رسم المنحنى الزمني لهذه السلسلة، كما هو موضح في الشكل(3).

حيث تبيّن من الشّكل (3) أنّ رسم المنحنى الزمني للسلسلة بعد إجراء الفروق الأولى للوغاريتيم السلسلة الأصلية تبدو ساكنة، وبذلك تكون أصغر رتبة للفروق الضرورية لتسكين السلسلة هي ($d=1$) . وللتّأكّد من صحة السكون من الناحية البيانية قمنا بإجراء اختبار ADF واختبار PP لفحص استقرار السلسلة الزمنية حيث الفرضية العدمية لوجود جذور الوحيدة مقابل الفرضية البديلة عدم وجود جذور الوحيدة، نلاحظ النتائج من خلال جدول (2) لاختبار ADF, PP لمؤشر السلسلة الزمنية أظهرت عدم وجود جذور الوحيدة مما يدل على استقرار السلسلة.

ثانياً: مرحلة التعرّف والتقدّير Identification and Estimation

تهدف هذه المرحلة إلى التعرّف على نموذج ARIMA المناسب لتمثيل البيانات، وذلك من خلال تحديد رتبة الحرج الخاص بالانحدار الذاتي AR المعروفة بالرمز (p)، ورتبة الجزء الخاص بالمتطلبات المتحركة MA المعروفة بالرمز (q)، وتعتمد هاتين الرتبتين في التقدّير على أداتين أساسيتين هما دالّي الارتباط الذاتي والارتباط الذاتي الجزئي المقدّرتين، ويوضّح الشّكل (4) دالّي الارتباط الذاتي والارتباط الذاتي الجزئي المقدّرتين للسلسلة بعدأخذ الفروق الثانية للسلسلة الأصلية.

وبعد الفحص الأولى لدالة الارتباط الذاتي ACF ودالة الارتباط الذاتي الجزئي PACF نلاحظ أن دالة الارتباط الذات ينقطع بعد الفحص الزمنية الأولى مما يوجه الانتباه إلى وجود معلمة متطلبات متحركة، بينما دالة الارتباط الذاتي الجزئي تنقطع بعد الفحص الزمنية الأولى مما يوجه الانتباه إلى وجود معلمة الانحدار ذاتي وبالتالي يمكن ترشيح النموذج المبدئي $ARIMA(1,1,1)$ ، وهذا النموذج المرشح يؤخذ كنموذج أولي قابل للتعديل لاحقاً.

ولتوسيق أفضل نموذج للسلسلة تم العمل على تحديد الملايين ورتبته من خلال قيم المعايير الإحصائية BIC,AIC,AICc، حيث تم ملائمة مجموعة من نماذج ARIMA(p,d,q) لاختيار النموذج الأفضل والذي يعطي أقل قيمة للمعايير كما هو مبين في الجدول (3). ونلاحظ أن النموذج الأفضل هو نموذج $ARIMA(1,1,0)$ ، وذلك لامتلاكه أقل قيمة للمعايير الإحصائية BIC,AIC,AICc على النقيض من النموذج المرشح $ARIMA(1,1,1)$ ، وبذلك فإن النموذج النهائي الذي يمكن استخدامه في التنبؤ هو النموذج $ARIMA(1,1,0)$ الذي سيكون بالصيغة الآتية:

$$\begin{aligned}\phi_p(B)(1-B)^d y_t &= \theta_q(B)\varepsilon_t \\ (1-\phi_1 B)(1-B)^d \ln y_t &= \varepsilon_t \\ (1-0.3844B)(1-B) \ln y_t &= \varepsilon_t\end{aligned}$$

ومن تقدّيرات معلمات النموذج في الجدول (4) يتضح أن القيمة المطلقة لتقدير المعلمة ϕ أكبر من ضعف الخطأ المعياري وهذا دليل على معنوية معلمة النموذج المقترن.

ثالثاً: مرحلة التشخيص Diagnostic Checking

تُعد هذه المرحلة من أهم مراحل التحليل حيث يتم فيها ملائمة النموذج، وذلك من أجل تحسين النموذج وتطويره أو الابقاء عليه كما هو، حيث يتم في هذه المرحلة إخضاع النموذج محل البحث لعدد من الاختبارات لتقويم النموذج، فإذا اجتاز هذا النموذج الاختبارات فإنه يكون صالح للاستخدام، وهذه الاختبارات تكون في عملية تحليل الاستقرار والباقي التالية:-

- تحليل السكون والإنبعاس Stationarity Analysis and Invertibility

يُعد تحقق شرط الاستقرار والإنبعاس في مقدرات النموذج دليلاً على كفاية النموذج للبيانات، حيث أن جميع الانحدار الذاتي منعكسة دائماً بدون وضع أي قيود أو شروط على المعلمة ϕ ، وللحصول على السكون نلاحظ من الجدول (4) أن معلم النموذج المقترن تتحقق شرط السكون حيث أن :

$$|\phi_1| = |0.3844| = 0.3844 \leftarrow 1$$

- تحليل الباقي Residuals Analysis

يعتبر تحليل الباقي جزء أساسي ومرحلة مهمة لمعرفة مدى صلاحية النموذج ARIMA(1,1,0) المستخدم للتبيؤ. حيث أن شكل (5) لداليا الارتباط الذاتي دالة الارتباط الذاتي الجزئي المقدرتين للفرق الأولى للباقي، تؤكد أن النموذج الملائم لسلسلة الفرق الأولى هو بالفعل نموذج ARIMA(1,1,0)، حيث تبدو دالة الارتباط الذاتي وكأنها تقطع فجأة بعد الفجوة الزمنية الأولى، بينما تتلاشى دالة الارتباط الذاتي الجزئي تدريجياً إلى الصفر. يتضح من الشكل (6) أن الرسم البياني لسلسلة الباقي تتأرجح نوعاً ما حول الصفر. وللحائق من عشوائية الباقي تتأمل دالة الارتباط الذاتي ACF الجزء الثاني من الشكل نفسه حيث يبين أن جميع معاملات الارتباط الذاتي للباقي عند كل فجوة زمنية تقع داخل حدٍ فترة الثقة، مما يشير إلى أن الباقي لهذا النموذج غير مترابطة مع بعضها البعض وهذا يعني أن الأخطاء الناجمة عشوائية.

وللتتأكد أيضاً من عشوائية الباقي نجري اختبار Ljung-Box كما في الجزء الأخير من شكل (6)، حيث وجدنا أن قيم p-value أكبر من 0.05 وهذا يشير إلى أن الباقي مستقلة، أي أن الأخطاء عشوائية.

يعتبر المنحنى التكراري للباقي Q-Q plotNormal الذي يمثل المنحنى التكراري للباقي تمثيل للحكم على مدى طبيعية التوزيع للباقي، حيث يتضح من الشكل (7) الذي يمثل المنحنى التكراري للباقي أن الباقي تمثل للطبيعية ولكن ليس بصورة كاملة، ويوضح أيضاً من الشكل نفسه الذي يمثل Q-Q plotNormal بأن الباقي تبعد عن الخط المستقيم، وهذا دليل على عدم طبيعية التوزيع للباقي وهذا ربما دليل على عدم طبيعية التوزيع للباقي.

وللتتأكد قمنا بفحص طبيعية التوزيع للباقي من خلال اختبار Jarque-Bera وكانت النتائج لهذا الاختبار كما في الجدول (5). حيث يتضح أن قيمة p-value أقل من 0.05، وهذا يعني عدم قبول الفرضية العدمية (H_0 : الباقي طبيعية التوزيع)، وهذا يؤكّد بالطبع وجود نمط غير خططي في الباقي مما يستدعي استخدام نماذج غير خططية، وعلى الرغم من نتيجة الاختبار فهذا لا يعني أهمية نموذج ARIMA الذي تم اختياره.

رابعا: التبيؤ باستخدام نموذج ARIMA(1,1,0)

وعلى الرغم من أن نموذج ARIMA(1,1,0) لا يمثل السلسلة على النحو الكافي إلا أنها نستطيع استخدامه للتبيؤ والجدول (6) يعطي تنبؤات نموذج ARIMA(1,1,0) بعشرة قيم مستقبلية من نوفمبر 2019 حتى أغسطس 2020.

VII.2 - بناء نموذج الشبكات العصبية الاصطناعية (ANN) :

تعتبر شبكة MLP من أكثر الشبكات العصبية استخداماً في مجال التبيؤ بالسلسلات الزمنية وت تكون هذه الشبكة من ثلاث طبقات: طبقة المدخلات والطبقة المخفية وطبقة المخرجات وتقوم فكرة هذه الشبكة على استخدام القيم السابقة للسلسلة الزمنية كمدخلات للشبكة ويتم تجميع الأوزان في الطبقة المخفية بالنسبة للمدخلات وقد تم استخدام دالة التنشيط FunctionSigmoid في كل من الطبقة المخفية وطبقة المخرجات.

لبناء نموذج الشبكة العصبية الاصطناعية متعددة الطبقات ذات التغذية الأمامية (MLP) للتبيؤ Multi-layer Perceptron(MLP) بالسلسلة الزمنية محل البحث نتبع الخطوات الآتية:

1 - معالجة البيانات

قبل ادخال البيانات إلى الشبكة تم معالجتها وذلك باستخدام معادلة Min Max Method Normalization

$$\zeta_i = \frac{x_i - \min(x)}{\max(x) - \min(x)}$$

والتي تحول البيانات تتبع للفترة المغلقة [0,1] وذلك لتتوافق دالة التنشيط المستخدمة في الطبقة المخفية

2 - تقسيم البيانات

تم الاعتماد على القيم السابقة لسلسلة البيانات الشهرية لأسعار النحاس العالمية من يناير 1990 حتى ديسمبر 2018 كمدخلات للشبكة بواقع 348 مشاهدة وهو نفس العدد المستخدم لبناء نموذج ARIMA، حيث بلغ إجمالي عدد المشاهدات 358 مشاهدة، أي أن 97% (348 مشاهدة) من السلسلة تعتبر مجموعة تدريب، و3% (10 مشاهدات) لاختبار المقارنة بين النماذج من خلال التنبؤات.

3 - تحديد عدد العقد في طبقة المدخلات والطبقة المخفية

إن عدد الفجوات غير الموسمية وعدد العقد في الطبقة المخفية يتم تحديدها عن طريق التجربة والخطأ لأنها تحتاج إلى خبرة أكثر من احتياجها إلى تقنية رياضية، وذلك لأنه عندما يكون عدد الوحدات في الطبقة المخفية صغيراً جداً، لا تتم دراسة العلاقة بين المخرجات والمدخلات بشكل صحيح وفي هذه الحالة ترداد الأخطاء، كذلك عندما يكون عدد وحدات الطبقة المخفية كبيراً بشكل غير عادي، ستكون هناك اضطرابات في العلاقة بين المدخلات والمخرجات مما يؤدي إلى زيادة الخطأ.

توجد العديد من الطرق لتحديد عدد وحدات الطبقة المخفية، ولكن لا يوجد حل مثالي لهذه المشكلة (Kermanshahi and Iwamiya, 2002)، لذلك في هذا البحث يبدأ الباحث بخمس وحدات معالجة في الطبقة المخفية ويزيد تدريجياً 5 وحدات في كل مرة حتى يصل إلى 50 وحدة، أما بالنسبة لعدد العقد في طبقة المدخلات فيبدأ بواحدة ويستمر بزيادة عقدة في كل مرة حتى يصل إلى 15 عقدة.

4 - تقدير النموذج

سيتم تقدير عدد من النماذج التي سيتم دراستها للوصول إلى أفضل نموذج لتمثيل البيانات وقد تم استخدام دالة nnetar في برنامج R لتقدير تلك النماذج، حيث أن النموذج المولد من هذه الدالة يُسمى (NNAR).

سيتم الحصول على النتائج من خلال تطبيق خوارزمية الانتشار العكسي أمامية التغذية، وقد تم اعتماد معيار RMSE للحصول على أفضل نموذج ويوضح ذلك في جدول (7)، وذلك وفق الخطوات التالية:

- أ - يتم البحث عن أفضل عدد لوحدات المعالجة في الطبقة المخفية في الصنف الواحد وذلك من خلال البحث عن أقل قيمة للمعيار الاحصائي RMSE المقابل لكل وحدة معالجة بحيث تتوقف عن البحث عندما لا يتجاوز الفرق المطلق للجذر التربيعي لمتوسط مربع الأخطاء للنموذجين المراد المفضلة بينهما عن 0.0001

$$|RMSE_i - RMSE_{i+1}| < 0.0001$$

- ب - يتم البحث عن أفضل فجوة زمنية وذلك من خلال البحث عن أقل قيمة للمعيار الإحصائي RMSE المقابل لوحدات المعالجة التي تم اختيارها في الخطوة الأولى بحيث تتوقف عن البحث عندما لا يتجاوز الفرق المطلق للجذر التربيعي لمتوسط مربع الأخطاء للنموذجين المراد المفضلة بينهما عن 0.0001

ت - يتم الحصول على أفضل نموذج للشبكات العصبية وهو NNAR(14,50).

5 - مرحلة التنبؤ

تم استخدام نموذج (NNAR(14,50)) للتتبؤ بعشرة قيم مستقبلية من نوفمبر 2019 حتى أغسطس 2020 ويوضح ذلك من خلال الجدول (8).

VIII. المقارنة بين نموذجي ARIMA و ANN في دقة التنبؤ

للمقارنة بين نموذجي ARIMA و ANN في التنبؤ بسلسلة أسعار النحاس العالمية تم الاعتماد على مقاييس دقة التنبؤ MAE، RMSE وكانت النتائج كما هي موضحة في الجدول (9). ويوضح من نتائج الجدول أن نموذج (NNAR(14,50)) كان له الأفضلية بصورة واضحة.

IX. النتائج والتوصيات

هدف هذا البحث إلى بناء أفضل نموذج للتنبؤ بأسعار النحاس العالمية للفترة الزمنية الممتدة من شهر يناير 1990 حتى شهر أكتوبر 2019، لغرض المقارنة بين نموذجي ARIMA و ANN وذلك بالاعتماد على مقاييس دقة التنبؤ للوصول إلى النموذج الأمثل، حيث توصل البحث إلى جملة من الاستنتاجات والتوصيات التي ستكون بمثابة الأسس الأولية للباحثين الذين سيلجمون غمار هذا الموضوع.

Conclusions - النتائج

- 1- توصل البحث إلى أن الظاهرة قيد الدراسة تمثل سلسلة زمنية غير مستقرة بالنسبة للبيانات الأصلية المتاحة، وعليه تم تطبيق الفروق الأولى لأنماها الأنسب من غيرهما في جعل السلسلة الزمنية مستقرة.
- 2- تم تطبيق منهجية Box and Jenkins على سلسلة أسعار النحاس العالمية لبناء نموذج ARIMA وتبين أن نموذج ARIMA(1,1,0) هو الأفضل من بين نماذج ARIMA المقترحة، وذلك لامتلاكه أقل قيم لمعايير التقييم AIC, AIC_c, BIC واستخدامه للتنبؤ بد 12 قيم مستقبلية.
- 3- تم بناء نموذج الشبكات العصبية الاصطناعية ANN باستخدام شبكة البيرسيترون متعدد الطبقات (MLP) وتبين أن نموذج NNAR(14,50) هو الأنسب من بين نماذج NNAR المقترحة، وذلك لامتلاكه أقل قيمة للمعيار الاحصائي (RMSE) وتم استخدامه للتنبؤ بد 12 قيم مستقبلية.
- 4- تفوق نموذج NNAR(14,50) على نموذج ARIMA(1,1,0) مما يعطي مؤشر على احتواء السلسلة الزمنية محل الدراسة على أنماط غير خطية بصورة كبيرة.

Recommendations - التوصيات

- 1- نوصي باستخدام أسلوب المحاكاة بأحجام وعينات مختلفة في توليد بيانات لدراسة النماذج الإحصائية لمعرفة خصائصها ودقتها في التنبؤ.
- 2- نوصي باستبدال نموذج الشبكة العصبية المتعددة الطبقات بنموذج الشبكات العصبية الشعاعية (RBF).
- 3- نوصي باستبدال نوع الشبكة من الشبكة العصبية الأمامية (FNN) إلى الشبكة العصبية الاسترجاعية كشبكة Elman أو شبكة Jordan في دراسات أخرى بغية زيادة دقة التنبؤات.
- 4- استخدام أساليب إحصائية هجينة مثل ARIMA-GARCH, ARIMA-ANN وذلك لأنها تعالج المشاكل الخطية واللانخطية الموجودة بالسلسلة الزمنية.

الملاحق:

جدول (1): المقاييس الاحصائية لأسعار النحاس العالمية

الإحصاءات	حجم العينة	أقل قيمة	أكبر قيمة	الوسط الحسابي	الوسيط	الخraf معياري	الانتواء	التفرطح
القيمة	348	1377.37	9880.938	4244.505	3006.333	2471.353	0.4741	-1.2977

المصدر: نتائج التحليل الاحصائي باستخدام برنامج R .

جدول رقم (2): نتائج اختبار PP, ADF لسلسة البيانات بعدأخذ الفروق الأولى

الحالات	المعنوية	القيمة	الاختبار
مستقرة	0.01	-7.4152	ADF اختبار ديكى - فولار (ADF)
مستقرة	0.01	-207.25	PP اختبار فيليب - بيرون (PP)

المصدر: نتائج التحليل الاحصائي باستخدام برنامج R.

جدول (3): مقارنة بين نماذج ARIMA(p,d,q) المرشحة

Models	AIC	AICc	BIC
ARIMA (1,1,0)	-999.41	-999.38	-991.72
ARIMA (0,1,1)	-994.36	-994.32	-986.66
ARIMA (0,1,2)	-988.64	-998.57	-987.09
ARIMA (1,1,1)	-997.83	-997.76	-986.28
ARIMA (1,1,2)	-996.64	-996.53	-981.25
ARIMA (2,1,0)	-997.92	-997.85	-986.37
ARIMA (2,1,1)	-996.11	-995.99	-980.71
ARIMA (2,1,2)	-994.88	-994.7	-975.63

المصدر: نتائج التحليل الاحصائي باستخدام برنامج R.

جدول (4): تقديرات معلمات النموذج ARIMA(1,1,0)

النماذج	المعلمة	قيمة المعلمة	الخطأ المعياري	ضعف الخطأ المعياري
AR(1)	ϕ_1	0.3844	0.0494	0.0988

المصدر: نتائج التحليل الاحصائي باستخدام برنامج R.

جدول (5): اختبار Jarque–Bera لطبيعة التوزيع للمواقي

Jarque–Bera Test	χ^2	DF	P-value
	255.07	2	e-162.2

المصدر: نتائج التحليل الاحصائي باستخدام برنامج R.

جدول (6): قيم التنبؤات لنموذج ARIMA(1,1,0)

Jun/2019	May/2019	Apr/2019	Mar/2019	Feb/2019	Jan/2019	السنة
5882.2250	6017.9047	6438.3625	6439.4642	6300.4875	5939.1022	القيم الفعلية
6087.1787	6071.4212	6056.4191	6043.3151	6035.0293	6039.1225	التبؤات
Dec/2019	Nov/2019	Oct/2019	Sep/2019	Aug/2019	Jul/2019	السنة
-	-	5757.2978	5759.2500	5709.4404	5941.1956	القيم الفعلية
6185.1096	6168.6297	6152.1998	6135.8199	6119.5020	6103.2640	التبؤات

المصدر: نتائج التحليل الاحصائي باستخدام برنامج R .

جدول(7): نتائج RMSE لنموذج ANN لبيانات السلسلة الزمنية لأسعار النحاس العالمية .

Lags p	Numbers of nodes in hidden layer										
	5	10	15	20	25	30	35	40	45	50	55
1	0.03687415	0.0368668	0.03688855	0.03688959	0.03688015	0.03688694	0.0368982	0.03690351	0.03686829	0.03690655	0.03690359
2	0.03313973	0.03299128	0.03283959	0.03273034	0.03281101	0.03256469	0.03275502	0.03269014	0.03279815	0.03271324	0.0327285
3	0.03202294	0.03124196	0.03144978	0.03118854	0.03123046	0.03103617	0.0310324	0.03086259	0.03083972	0.03091918	0.03100855
4	0.03080301	0.0291215	0.02944618	0.029338	0.02933462	0.029124	0.02902227	0.0285597	0.02874948	0.02889709	0.02887477
5	0.02918248	0.0265905	0.02680993	0.02644618	0.02621324	0.0259126	0.02597398	0.02597829	0.02583915	0.02577063	0.02552481
6	0.02797359	0.02520232	0.02500764	0.02494689	0.02436534	0.02420602	0.02460879	0.02413746	0.0241898	0.02419935	0.02403775
7	0.02815351	0.02415452	0.02450072	0.0234942	0.02340942	0.02316037	0.02320173	0.02275214	0.0229926	0.02285328	0.02271222
8	0.02694124	0.02316165	0.02213552	0.02177223	0.02197594	0.02075681	0.02076829	0.02072291	0.0209197	0.02054394	0.02067563
9	0.02572237	0.02113854	0.02000411	0.01943038	0.0187415	0.01851561	0.01843826	0.01846099	0.01814292	1.82E-02	1.85E-02
10	0.02417605	0.01874553	0.0170483	0.01706127	0.01667488	0.01595396	1.62E-02	1.59E-02	1.58E-02	1.60E-02	1.60E-02
11	0.02328829	0.01694262	0.01635209	0.01489159	0.01481836	1.47E-02	1.44E-02	1.45E-02	1.48E-02	1.41E-02	1.40E-02
12	0.02184508	0.01657577	0.01531762	0.01473277	0.01411469	1.37E-02	1.42E-02	1.36E-02	1.37E-02	1.38E-02	1.39E-02
13	0.02089699	0.01539097	0.01398894	0.01389107	1.34E-02	1.31E-02	1.30E-02	1.29E-02	1.30E-02	1.31E-02	1.29E-02
14	0.02098292	0.01536916	0.01385387	0.01318078	1.29E-02	1.27E-02	1.26E-02	1.26E-02	1.27E-02	1.26E-02	1.25E-02
15	0.0204604	0.01366186	0.01307977	1.28E-02	1.24E-02	1.24E-02	1.21E-02	1.22E-02	1.21E-02	1.21E-02	1.20E-02

المصدر: نتائج التحليل الاحصائي باستخدام برنامج R .

جدول(8): قيم التبؤات لنموذج NNAR(14,50)

Jun/2019	May/2019	Apr/2019	Mar/2019	Feb/2019	Jan/2019	السنة
5882.2250	6017.9047	6438.3625	6439.4642	6300.4875	5939.1022	القيم الفعلية
5996.56	6022.14	6047.00	6053.08	6068.63	6094.62	التبؤات
Dec/2019	Nov/2019	Oct/2019	Sep/2019	Aug/2019	Jul/2019	السنة
-	-	5757.2978	5759.2500	5709.4404	5941.1956	القيم الفعلية
5989.63	5994.46	6000.93	5997.28	5985.82	5981.91	التبؤات

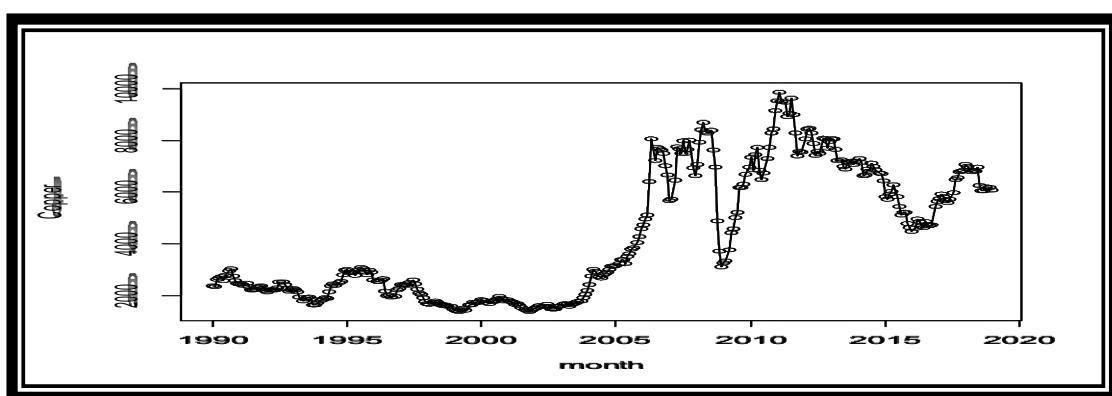
المصدر: نتائج التحليل الاحصائي باستخدام برنامج R .

جدول(9): معايير دقة التبؤ للمقارنة بين النماذجين

النماذج	RMSE	MAE
ARIMA(1,1,0)	303.3688	274.5643
NNAR(14,50)	242.3948	208.2451

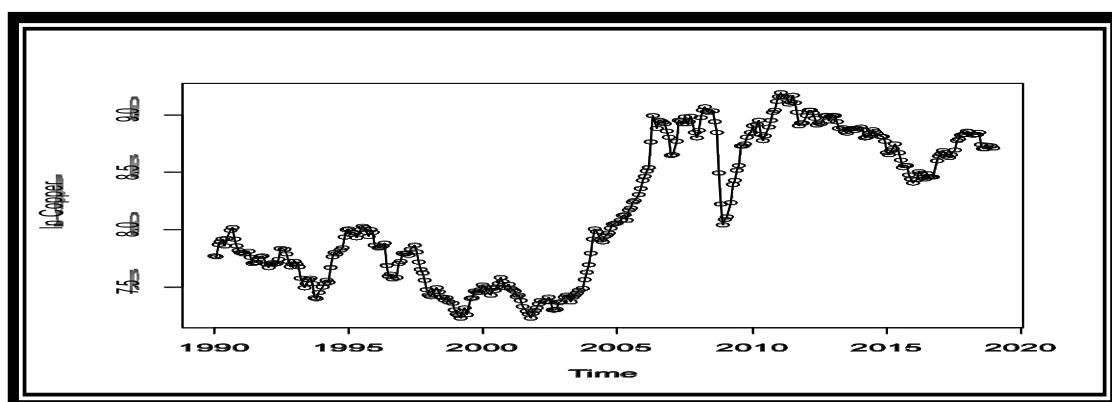
المصدر: نتائج التحليل الاحصائي باستخدام برنامج R .

شكل (1) السلسلة الزمنية لأسعار النحاس العالمية



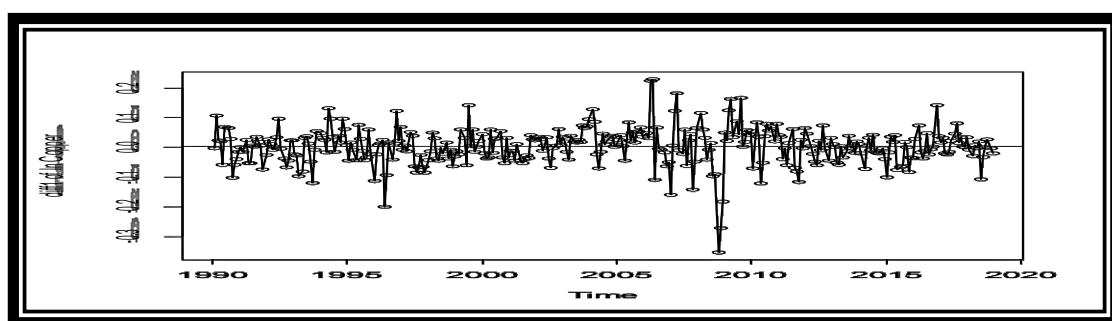
المصدر:

نتائج
التحليل



الإحصائي باستخدام برنامج R .

شكل(2): السلسلة الزمنية بعدأخذ التحويلة اللوغاريتمية للدالة الأصلية

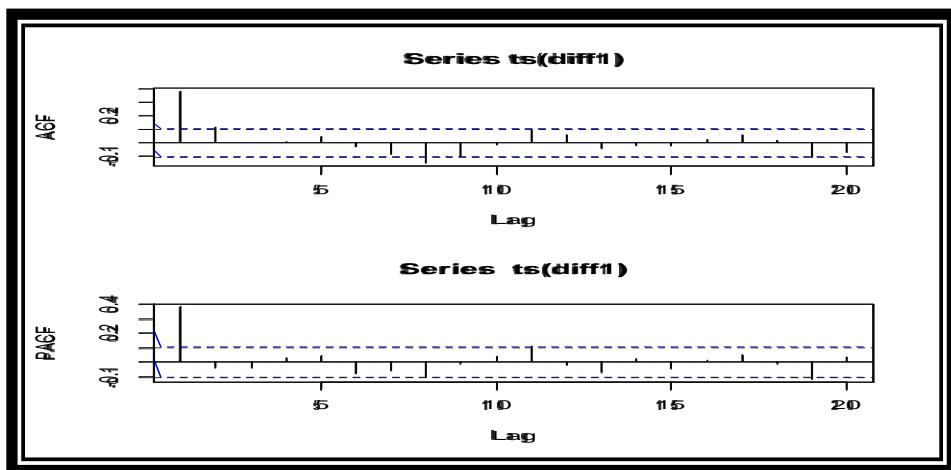


المصدر: نتائج التحليل الإحصائي باستخدام برنامج R

شكل(3): السلسلة الزمنية للفروق الأولى للوغاريتم السلسلة الأصلية

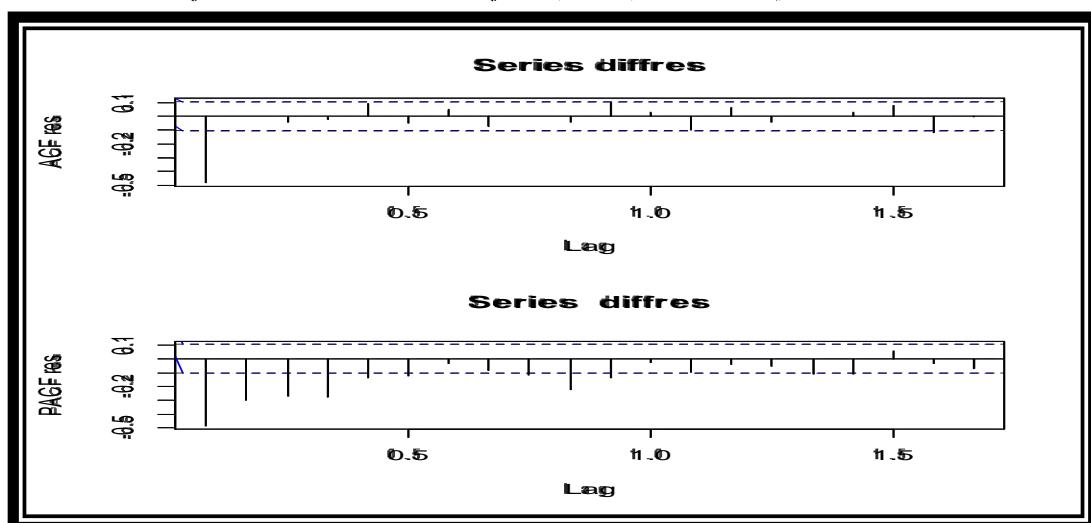
المصدر: نتائج التحليل الاحصائي باستخدام برنامج R.

شكل (4) دالتي الارتباط الذائي والذائي الجزئي للفروق الأولى للوغاريتم السلسلة الأصلية



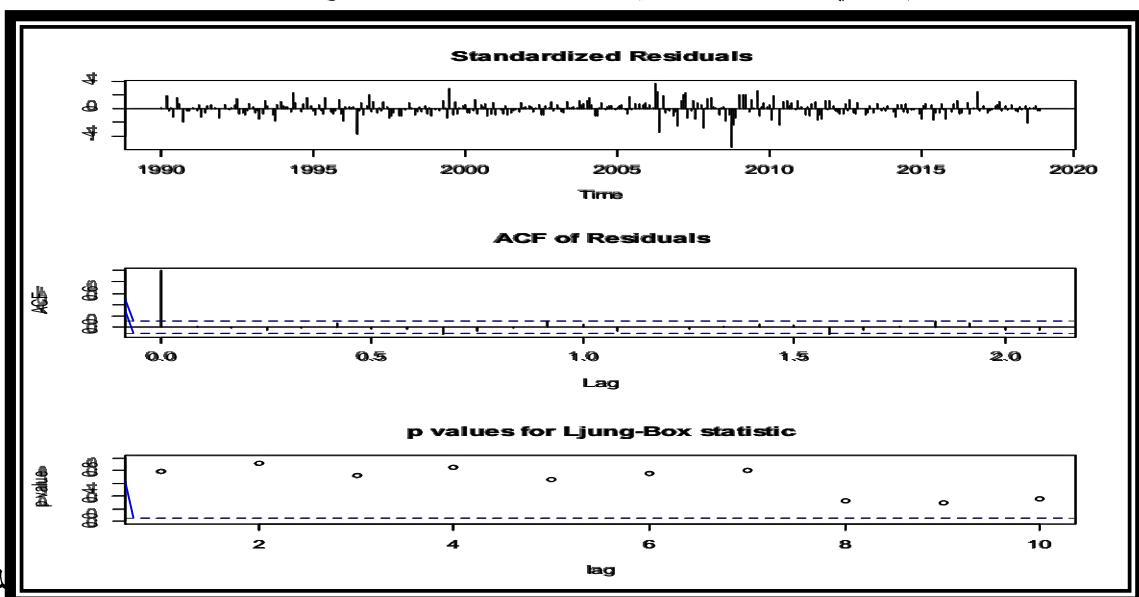
المصدر: نتائج التحليل الاحصائي باستخدام برنامج R.

شكل (5): دالتي الارتباط الذائي والذائي الجزئي المقدرتين للفروق الأولى للبوافي



المصدر: نتائج التحليل الاحصائي باستخدام برنامج R.

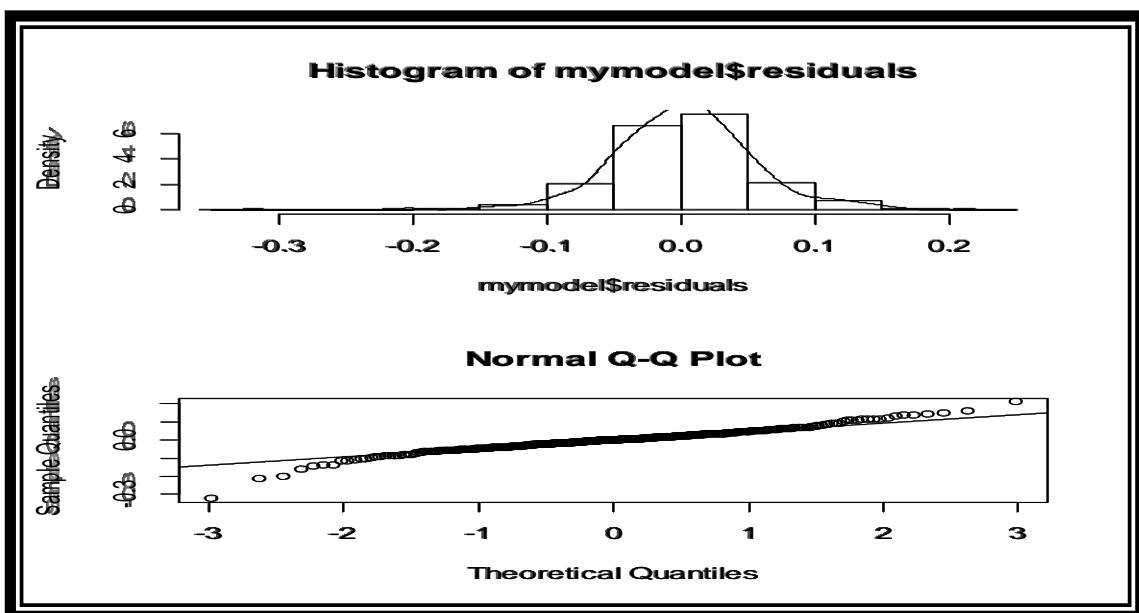
شكل (6): رسم الباقي و دالة الارتباط الذاتي و اختبار Ljung-Box لنموذج ARIMA (1,1,0)



المصدر:

نتائج التحليل الاحصائي باستخدام برنامج R.

شكل (7): المنحنى التكراري و Q-Q plotNormal للباقي



المصدر: نتائج التحليل الاحصائي باستخدام برنامج R.

X. الإحالات والمراجع ::

1. جباره، جلال (2012). "التنبؤ بالسلسل الزمنية لتسوب النيل الأزرق في محطة ودمدني باستخدام نماذج بوكس - جينيكتر ونماذج الشبكات العصبية الاصطناعية"، رسالة ماجستير غير منشورة، جامعة السودان للعلوم والتكنولوجيا، السودان.
2. الخياط، باسل و زكي ، عزة (2005). "استخدام الشبكات العصبية في التكهن بالسلسلة الزمنية لاستهلاك الطاقة الكهربائية في مدينة الموصل"، المجلة العراقية للعلوم الاحصائية، المجلد (5)، العدد(8)، جامعة الموصل، العراق، ص 79-63.
3. الساعدي، علي (2016). "استخدام نماذج السلسل الزمنية المجننة وغير المجننة للتنبؤ بأعداد المسافرين لمطار بغداد الدولي"، رسالة ماجستير، الجامعة المستنصرية، بغداد، العراق.
4. الشمراني، محمد (2018). دراسة بين استخدام الشبكات العصبية ونماذج أريما (ARIMA) للتنبؤ بأعداد المصاين من حوادث الطرق. مدينة مكة المكرمة، مجلة الشمال للعلوم الأساسية والتطبيقية، المجلد (3)، العدد (1)، ص 1-20.
5. عبد العزيز، بشيحة و الوكيل، خولة (2015). "التنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى والصغرى في مدينة بغداد باستخدام الشبكة العصبية المتعددة الطبقات"، مجلة كلية الرافدين الجامعية للعلوم، العدد(36)، ص: 92-62، كلية الرافدين الجامعية، العراق.
6. عبد النور، عادل (2005). "أساسيات الذكاء الاصطناعي" ، ط 1، دار الفيصل الثقافية، الرياض.
7. عتاني ، محمد و عبد العاطي ، فاطمة و مبارك ، امال (2002) . "أسلوب الجمع بين تحليل الانحدار وتحليل السلسل الزمنية ، دراسة تطبيقية" ، مجلة البحوث التجارية ، جامعة الرقازيق ، مصر.
8. واصل ، محمد (2006). "أساسيات كيمياء العناصر" ، دار طيبة للنشر والتوزيع.
- Adebisi, A. Adewumi, A. and Ayo, C. (2014). " Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction ", Journal of Applied Mathematics, Vol.1, P: 1-7.
- Alhashimi, S., (2014). "Prediction Of Monthly Rainfall In Kirkuk Using Artificial Neural Network And Time Series Models", Journal of Engineering and Sustainable Development, Vol.18, P: 129-143.
- "Up to year 2020 load forecasting using neural nets", Kermanshahi, B. and Iwamiya, H. (2002), International Journal Electrical Powerand Energy System24(9), pp:789-79

كيفية الاستشهاد بهذا المقال حسب أسلوب APA:

طارق الدواب ، شادي التلبياني ، سمير أبو دحروج (2020)، دراسة إحصائية مقارنة بين نموذجي ARIMA و ANN للتنبؤ بأسعار النحاس العالمية خلال (1990-2018) ، المجلة الجزائرية للتنمية الاقتصادية، الجلد 7 (العدد 1)، الجزائر: جامعة قاصدي مرداج ورقلة، ص. ص 17-32.



يتم الاحتفاظ بحقوق التأليف والنشر لجميع الأوراق المنشورة في هذه المجلة من قبل المؤلفين المعنين وفقاً لـ [رخصة المشاع الإبداعي تُسَبِّبُ المصنَفَ - غير تجاري - منع الاشتراق 4.0 دولي \(CC BY-NC 4.0\)](#).

المجلة الجزائرية للتنمية الاقتصادية مرخصة بموجب [رخصة المشاع الإبداعي تُسَبِّبُ المصنَفَ - غير تجاري - منع الاشتراك 4.0 دولي \(CC BY-NC 4.0\)](#).



The copyrights of all papers published in this journal are retained by the respective authors as per the [Creative Commons Attribution License](#).

Algerian Review of Economic Development is licensed under a [Creative Commons Attribution-Non Commercial license \(CC BY-NC 4.0\)](#).