

**دراسة إحصائية مقارنة بين نماذج ARIMA و ANN : مفردة  
وهجينة  
(مع التطبيق)**

د.شادي إسماعيل التلباتي  
جامعة الأزهر-غزة- فلسطين

أ. محمد عبد الهادي صادق  
جامعة الأزهر- غزة- فلسطين

## الملخص:

تناول البحث بناء النماذج الهجينية المتولدة من دمج نموذج الانحدار الذاتي والمت渥سطات المتحركة التكاملية ARIMA مع نموذج الشبكات العصبية الاصطناعية ANNs، وذلك باستخدام بوافي كمدخلات لنموذج ANN وبالعكس، بالاعتماد على بيانات السلسلة الزمنية الشهرية لأسعار الذهب العالمية لغرض المقارنة بين النماذج الهجينية ARIMA-ANN و ANN-ARIMA مع النماذج المفردة ARIMA، ANN، وتمت المفاضلة بينهم باستخدام مقاييس دقة التنبؤ RMSE و MAE لإيجاد النموذج الأمثل للتنبؤ بالقيم المستقبلية. وقد أظهر البحث تفوق نموذج ARIMA-ANN على غيره من النماذج الأخرى لامتلاكه أقل القيم لمقاييس دقة التنبؤ.

## Abstract:

The research tackles constructing the hybrid models generated from integrated autoregressive moving average model (ARIMA) with the artificial neural networks (ANNs), This is done using ARIMA residuals as inputs for ANN model or vice versa, based on global gold price time series data to compare hybrid models of ARIMA-ANN and ANN-ARIMA with single models ARIMA and ANN, These models are compared using the RMSE and MAE prediction accuracy criteria to find the most appropriate model for predicting future values. This study reveals the superiority of ARIMA-ANN over other models by having the lowest values of the prediction criteria's.

## 1. مقدمة:

تعددت الأساليب المستخدمة في تحليل السلسلة الزمنية كأسلوب Box and Jenkins لنموذج الجزء الخطي من السلسلة وأسلوب الشبكات العصبية الإصطناعية ANN لنموذج الجزء غير الخطي وأيضاً الأسلوب الهجين الذي يجمع بين الأسلوبين السابقين. ونظراً للتقلبات التي توجد في بعض السلسلة الزمنية واحتواها على أنماط خطية وغير خطية هدف هذا البحث للجمع بين أسلوبين من حيث قوة نماذج ARIMA ومونة الشبكات العصبية ANN في قدرتها على التعامل مع أنماط مختلفة، حيث أنَّ العلاقة بينهما تكاملية وليس تنافسية، لذلك يعتبر الدمج بين نموذجي ARIMA و ANN من النماذج الهجينية التي تعطي نتائج مُرضية مما لو استخدم كل من النماذجين بصورة منفردة، حيث أنَّ أحدهما يُعوض النقص الموجود في النموذج الآخر. وتم استخدام بيانات أسعار الذهب العالمية كمثال تطبيقي وليس هدف استراتيجي للبحث.

## 2. الانحدار الذاتي والمتوسطات المتحركة التكاملية : ARIMA

ظهرت مساهمات Box and Jenkins عام 1976 الواسعة في مجال السلسلة الزمنية حيث استتباطاً سوياً أسلوباً في فهم ومعالجة عدم الاستقرارية في البيانات وتوصلا إلى المسمى بنماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية (ARIMA)  $(p,d,q)$ .

وتعتبر نماذج ARIMA متولدة من نماذج الانحدار الذاتي ونماذج المتوسطات المتحركة، بعدأخذ الفروق المناسبة لجعل السلسلة الزمنية مستقرة، ويرمز لهذه النماذج بـ ARIMA(p,d,q)، حيث أنَّ (الليلة، 2006):

$p$ : تشير إلى درجة الانحدار الذاتي. ،  $q$ : تشير إلى درجة المتوسطات المتحركة.

$d$ : تشير إلى الحد الأدنى للفروق اللاحقة لجعل السلسلة الزمنية مستقرة.

ويمكن التعبير عن هذه النماذج باستخدام عامل الإزاحة للخلف  $B$  وعامل الفرق للخلف  $\nabla$

على الصورة التالية (الطائي، 2010):

$$\phi_p(B) \nabla^d y_t = \theta_q(B) \varepsilon_t$$

$$\phi_p(B)(1-B)^d y_t = \theta_q(B) \varepsilon_t$$

### 3. منهجة Box and Jenkins

تمر منهجة Box and Jenkins بأربعة مراحل أساسية يتم من خلالها الوصول إلى النموذج الأمثل للتنبؤ بالسلسلة الزمنية محل الاهتمام، وتتلخص المراحل الأربع الأساسية في الآتي (Box and Jenkins, 1976)

- مرحلة التعرف: يتم من خلالها تحديد معالم النموذج ( $p, d, q$ )، حيث يتم تحديد عدد الفروق اللازمة لتسكين السلسلة ( $d$ ) وأن الأداتين المستخدمتين لتحديد رتبة النموذج ( $p, q$ ) هما ذاتي الارتباط الذاتي والارتباط الذاتي الجزئي ACF.

- مرحلة التقدير: وفيها يتم تقدير معلمات النموذج  $\theta$  و  $\phi$  التي تجعل مجموع مربعات الأخطاء أقل ما يمكن.

- مرحلة التشخيص: تُعد هذه المرحلة من المراحل الأساسية، حيث أنها على أساسها يتم تحديد مدى قبول النموذج الذي تم توصيفه ومعلماته المقدرة، ووفقاً لهذه المرحلة يتحدد إما الاستمرار في عملية التحليل وتحقيق ما هو مستهدف من نموذج التحليل، أو العودة إلى نقطة البداية من تحديد وتقدير ثم اختبار.

- مرحلة التنبؤ: هي المرحلة الأخيرة من مراحل التحليل الحديث للسلسلة الزمنية، وأنه لا يمكن الانتقال إلى هذه المرحلة إلا بعد الانتهاء من اجراء جميع الفحوص والاختبارات الإحصائية الضرورية لتشخيص النموذج الذي تم اختياره.

### 4. الشبكات العصبية الاصطناعية:

تُعد الشبكات العصبية الاصطناعية Artificial Neural Networks (ANNs) من أهم مجالات الذكاء الاصطناعي، الذي يعكس تطوراً هاماً في طريقة التفكير الإنساني، وهي تمثل تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، والتي تُنتج حلولاً ذات معنى، تفوق إمكانيات الحاسوبات الرقمية التقليدية، حيث أنها تقوم ب تخزين المعرفة العلمية والمعلومات التجريبية، لتجعلها متاحة للمستخدم عن طريق ضبط الأوزان.

تعرف الشبكة العصبية الاصطناعية ANN على أنها نظام حسابي مكون من عدد من وحدات (عصبونات) المعالجة Processing Elements المتراكبة مع بعضها وتصف بطبعتها الديناميكية والمتوازية في معالجة البيانات الداخلة إليه (Kumar et al., 2004). كما يُعرفها Palit and

(Popovic, 2005): على أنها مجموعة من نظم المعالجة الموزعة على التوازي، وتمثل التكنولوجيا الحاسوبية التي وجدت لتحاكي نظام معالجة المعلومات داخل العقل البشري.

## 5. طبقات الشبكة العصبية الاصطناعية

ت تكون معمارية الشبكة العصبية الاصطناعية النموذجية من ثلاثة طبقات هي (الصفاوي و زكي، 2006):

1- طبقة المدخلات: وهي الطبقة الأولى في الشبكة العصبية، تحتوي على عدد من العقد التي تمثل عدد المتغيرات المستقلة (المدخلات).

2- طبقة الإخراج: وهي الطبقة الأخيرة في الشبكة العصبية التي تمثل مخرجات الشبكة.

3- الطبقة المخفية: وهي الطبقة الوسطى التي تقع بين الطبقة الأولى (المدخلات) والطبقة الأخيرة (الإخراج)، حيث يتم فيها معالجة البيانات التي يستقبلها من طبقة الإدخال.

## 6. مراحل التنبؤ باستخدام الشبكات العصبية الاصطناعية:

يمكن تلخيص مراحل التنبؤ بالخطوات الآتية (الساعدي، 2016):

الخطوة الأولى: تحديد المتغيرات

في حالة استخدام الشبكة العصبية للتنبؤ بالقيم المستقبلية للسلسلة الزمنية يكون المتغير عند الزمن ( $t$ ) هو دالة غير خطية للمتغير ذاته عند إزاحتات مختلفة وهي  $(y_{t-p}, \dots, y_{t-1})$ .

الخطوة الثانية: جمع البيانات

يتم جمع مشاهدات متغير واحد لفترات زمنية مختلفة ومحاولة معالجة مشكلة القيم المفقودة إن وجدت في السلسلة

الخطوة الثالثة: معالجة البيانات

نادرًا ما يتم تغذية الشبكة العصبية بالمدخلات والمخرجات كما هي، لكن يتم تهيئتها عن طريق اجراء بعض التحويلات عليها وتوجد عدة طرق لتهيئة البيانات (عبد العزيز و الوكيل، 2015). ولكن سنكتفي بالصيغة الطبيعية المستخدمة في الجانب التطبيقي:

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

$$X_{new} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

**الخطوة الرابعة:** تقسيم البيانات إلى مجاميع: تقسم البيانات المتوفرة إلى المجاميع الآتية:

(1) مجموعة التدريب: هي مجموعة من بيانات السلسلة الزمنية، إذ تستعمل هذه المجموعة في تقدير 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 مجموعتين تعلم واختبار.

(3) مجموعة التقويم: وهي مجموعة تقوم بمراقبة نهاية لتقديم 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 Selection of Activation Functions

وهي المعادلات الرياضية التي تحدد الناتج لمعالجة الشبكات العصبية، وتسمى أيضاً بدوال التحويل، غالبية الشبكات العصبية الحالية تستخدم الدالة الوجستية 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: وتعُد نقطة البداية لعملية التدريب وغالباً ما يتم اختيار قيم عشوائية صغيرة للأوزان.

- عدد تكرارات التدريب : تنتهي عملية التدريب عندما لا يتجاوز قيمة خطأ التقدير نسبة الخطأ المقبولة والتي قد تُحدَّد بحسب ما يراد معالجته في الشبكة.

- معدل التعلم ( $\eta$ ) وعامل الزخم ( $\alpha$ ): يعتبر معدل التعلم من العوامل المؤثرة على سرعة تحديث الأوزان في الشبكة العصبية، كما أنَّ عامل الزخم يجعل عملية التعلم ومقدار التغيير في الوزن مستقر نسبياً

#### الخطوة الثامنة: التنفيذ

تُعدُّ من أهم الخطوات حيث تختبر الشبكة من حيث قدرة التكيف وإمكانية إعادة التدريب والوصول إلى أقل مربع خطأ عند تغير البيانات للوصول إلى حالة الاستقرار، ويتم بناء الشبكات العصبية عن طريق البرمجة و لحل مشكلة معينة يتم زيادة عدد الدورات بشكل كبير.

### 7. النموذج الهجين Hybrid Model

مع الحاجة المستمرة لتنبؤات أكثر دقة للظواهر المختلفة، فإنَّ الباحثين يحاولون إيجاد نماذج تجمع بين نموذجين بدلاً من استخدام نموذج واحد للتنبؤ، حيث أنَّ أحدهما يعوض النقص الموجود بالآخر، ويعتبر الدمج بين نموذجي ANN و ARIMA من النماذج التي تعطي نتائج أدق مما لو استخدم كل نموذج على حدة، وهي ما تعرف بالنماذج الهجينة.

#### • بناء النموذج الهجين :ARIMA-ANN

في هذا النموذج يتم استخدام الباقي المستخرجة من نموذج ARIMA لبناء الشبكة العصبية، وذلك وفقاً للخطوات التالية (Kumar and Thenmozhi, 2012; Khandelwal et al., 2015)

- 1 بناء نموذج ARIMA لسلسلة الظاهرة محل الدراسة  $y_t$  حسب منهجية Box and Jenkins من خلال اتباع مراحلها بدءاً من مرحلة التعرف وصولاً لمرحلة التنبؤ.
- 2 الحصول على القيم المتنبأ بها  $\hat{L}_t$  من نموذج ARIMA الذي تم توفيقه؛ ليمثل الجزء الخطي للسلسلة الزمنية محل الدراسة.
- 3 بناء نموذج الشبكات العصبية ANN لنمذجة الباقي، وذلك بالاعتماد على الباقي السابقة من ARIMA ثم حساب التنبؤات المستقبلية لها  $\hat{N}_t$
- 4 يتم الحصول على القيم المتنبأ بها  $\hat{y}_t$  من نموذج Zhang (ARIMA- ANN) وذلك بجمع التنبؤات من نموذج ARIMA مع التنبؤات من نموذج ANN على النحو التالي:  $\hat{y}_t = \hat{L}_t + \hat{N}_t$

• بناء النموذج الهجين : ANN-ARIMA

في هذا النموذج يتم استخدام الباقي المستخرجة من الشبكة العصبية لبناء نموذج ARIMA، وهو على النقيض من نموذج الهجين السابق، وذلك وفقاً للخطوات التالية (Babu and Reddy, 2015).

- 1- بناء نموذج الشبكات العصبية ANN لسلسلة الظاهرة محل الدراسة  $y_t$ .
- 2- الحصول على القيم المتباينا بها  $\hat{N}_t$  من نموذج الشبكات العصبية ANN الذي تم توفيره لتمثيل الجزء غير الخطى للسلسلة الزمنية محل الدراسة.
- 3- بناء نموذج ARIMA لنجدة الباقي المستخرجة من نموذج الشبكات العصبية ANN، ثم حساب التنبؤات المستقبلية لها  $\hat{L}_t$ .
- 4- يتم الحصول على القيم المتباينا بها  $\hat{y}_t$  من نموذج Zhang (ANN - ARIMA) وذلك بجمع التنبؤات من نموذج الشبكات العصبية مع التنبؤات من نموذج ARIMA حسب المعادلة:

$$\hat{L}_t + \hat{N}_t$$

8. الجانب التطبيقي:

8.1 وصف البيانات: البيانات المتوفرة لدينا هي بيانات شهرية لأسعار الذهب العالمية، المتمثلة بأوزان أونصة الذهب بالدولار الأمريكي للفترة الممتدة من يونيو 1998 حتى مايو 2017 بواقع 228 مشاهدة لبناء النماذج المفردة والهجينة، وتم التنبؤ بعشرة قيم مستقبلية لغرض مقارنة التنبؤات التي سيتم الحصول عليها من تلك النماذج المفردة ARIMA و ANN والنماذج الهجينه & ARIMA-ANN .

وأخذ فكرة عامة عن طبيعة تلك البيانات سيتم عرض بعض الاحصاءات الوصفية لها كما يوضحها الجدول التالي:-

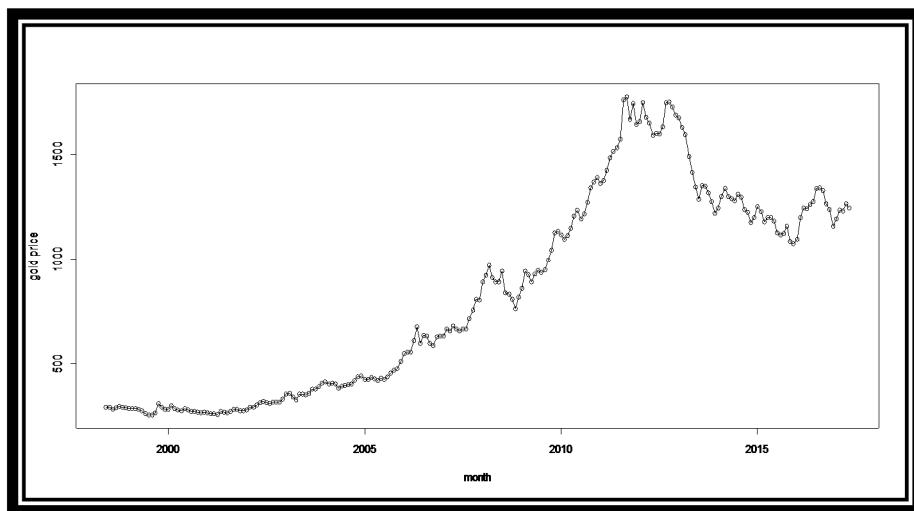
جدول(1): الاحصاءات الوصفية

الإحصاءات	N	أقل قيمة	أكبر قيمة	الوسط	الوسيط	الالتواز	التفاوت
القيمة	228	256.08	1772.14	828.23	782.03	0.298	-1.32

تبين من الجدول أعلاه أن قيمة الوسط الحسابي أكبر من قيمة الوسيط، وهذا مؤشر على أن منحنى التوزيع للبيانات ملتوٍ نحو اليمين، وهو ما يؤكد القيمة الموجبة لمعامل الالتواء، ويوضح أيضاً أن قيمة معامل التفلطح أقل من 3 مما يدل على أن منحنى التوزيع للبيانات مفلطح.

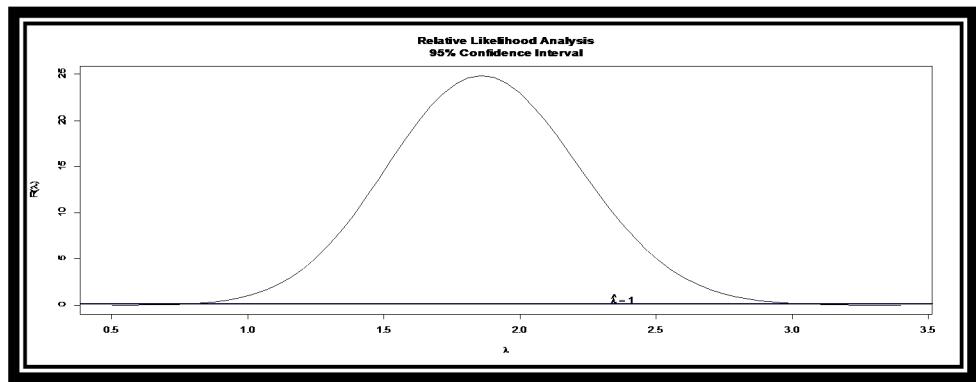
## 8.2 بناء نموذج ARIMA

أولاً: تهيئة البيانات: قبل الشروع في تطبيق منهجية Box and Jenkins، لابد من تهيئة البيانات من خلال تسكينها في الوسط والتباين، ومن خلال رسم المنحنى الزمني للسلسلة يتضح أنها غير ساكنة في الوسط والتباين مع الزمن.



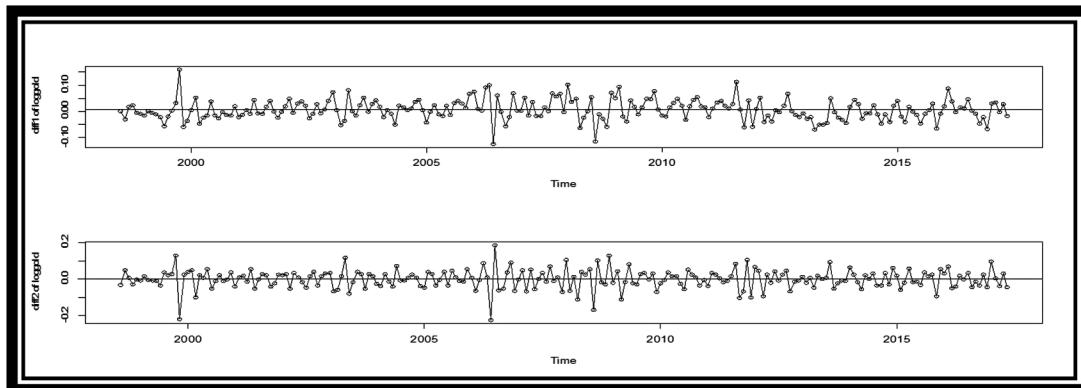
شكل (1): السلسلة الزمنية الشهرية لأسعار الذهب العالمية بالدولار الأمريكي

وللتتأكد من عدم سكونها أجرينا اختبارين من اختبارات جذر الوحدة هما اختبار KPSS وختبار ADF وكانت النتائج تؤكد على عدم سكون السلسلة في الوسط. ولتسكين السلسلة في التباين تمأخذ التحويلة اللوغاريتمية لبيانات السلسلة، وللتتأكد من اختيار التحويلة المناسبة أجرينا اختبار Box - Cox حيث كانت  $1 = \hat{\lambda}$  بدرجة ثقة 95% ما يعني أننا لسنا بحاجة لاستخدام أي تحويلة أخرى بعدأخذ التحويلة اللوغاريتمية. ويوضح ذلك من الشكل التالي:



شكل (2): اختبار Cox - Box لتحديد قيمة معلمة التحويل  $\lambda$

ولتسكين السلسلة في الوسط أخذنا الفروق الأولى ثم الثانية للوغاريتم السلسلة الأصلية، ومن ثم تم اعادة رسم المنحنى الزمني لها، كما هو موضح في الشكل:

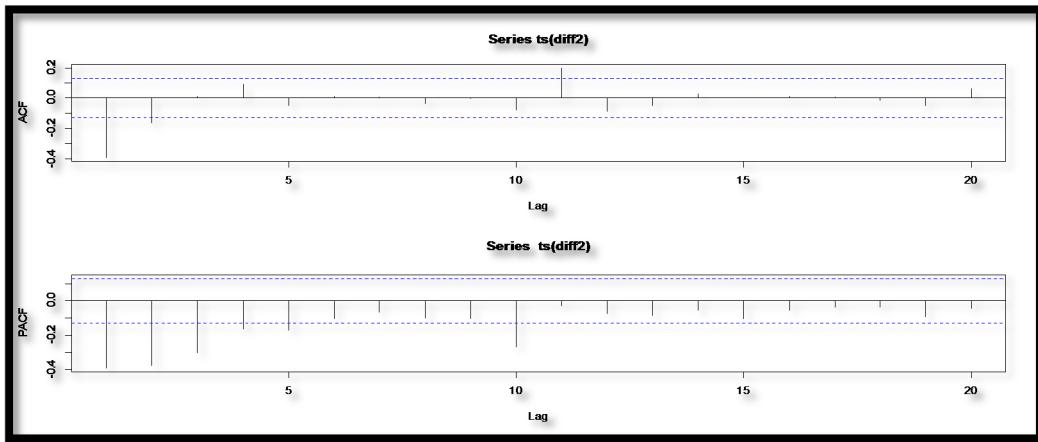


شكل(3): السلسلة الزمنية للفروق الأولى والثانية للوغاريتم السلسلة الأصلية

وبمقارنة الرسمتين في الشكل أعلاه تبين أن الفروق الثانية تبدو ساكنة أكثر من الفروق الأولى وبذلك تكون قيمة ( $d=2$ ). وللتتأكد من صحة السكون في الوسط أجرينا اختبارين من اختبارات جذر الوحدة هما اختبار ADF وختبار KPSS وكانت نتائج الاختبارين تدل على سكون السلسلة محل الدراسة.

### ثانياً: مرحلتي التعرف والتقدير:

بعد أن تم تسكين السلسلة في الوسط والتبالغ تأتي مرحلة التعرف على النموذج المبدئي من خلال رسم دالة الارتباط الذاتي والذاتي الجزئي، حيث تنتقطع دالة الارتباط الذاتي (ACF) بعد الفجوة الزمنية الثانية مما يدل على أن  $p=0$ , بينما تتلاشى دالة الارتباط الذاتي الجزئي تدريجياً مما يدل على أن  $q=2$ ، وبالتالي يمكن ترشيح النموذج المبدئي (ARIMA(0,2,2)، وهذا النموذج قابل للتعديل لاحقاً.



شكل (4): دالة الارتباط الذاتي والذاتي الجزئي للفروق الثانية للوغاريتم السلسلة الأصلية

وللتتأكد تم الاستعانة بدالة الارتباط الذاتي الموسعة EACF للمساعدة في تحديد معلم نموذج ARIMA.

جدول (2): دالة الارتباط الذاتي الموسعة EACF للفروق الثانية للوغاريتم السلسلة

ARMA	0	1	2	3	4	5	6	7	8	9	10	11	12	13
0	X	X	0	0	0	0	0	0	0	0	X	0	0	0
1	X	X	0	0	0	0	0	0	0	0	X	0	0	0
2	X	X	X	0	0	0	0	0	0	0	X	0	0	0
3	X	X	0	X	0	0	0	0	0	0	X	0	0	0
4	X	X	X	0	X	0	0	0	0	0	X	0	0	0
5	X	0	X	0	0	0	0	0	0	0	X	0	0	0
6	X	0	X	0	0	0	0	0	0	0	X	0	0	0
7	X	X	0	0	0	0	X	0	0	0	X	0	0	0

حيث نلاحظ من الجدول أعلاه أن الدالة ترشح لنا النماذجين ARIMA(0,2,2) & ARIMA(1,2,2) وبالتالي يُؤخذان كنماذج أولية قابلة للتعديل.

ولتوفيق أفضل نموذج للسلسلة سنقوم بترشيح نماذج أخرى ARIMA(p,d,q)، ومن خلال المفاضلة بين هذه النماذج وجدنا أن النموذج الأمثل هو ARIMA(0,2,2) وذلك لامتلاكه أقل القيم لمعايير التقييم المذكورة.

جدول (3): النماذج المرشحة والمعايير الإحصائية المقابلة لكل نموذج

MODEL	AIC	AICC	BIC
ARIMA(1,2,2)	-816.56	-816.38	-802.88
ARIMA(0,2,2)	-817.43	-817.32	-807.17
ARIMA(0,2,1)	-817.23	-817.28	-801.49
ARIMA(1,2,1)	-816.93	-816.82	-806.67
ARIMA(1,2,0)	-727.25	-727.2	-720.41
ARIMA(2,2,0)	-759.7	-759.59	-749.44
ARIMA(2,2,2)	-816.26	-815.99	-799.16

ولتتحقق من معنوية معالم النموذج المقترن يتضح من الجدول أدناه أن القيمة المطلقة لتقدير المعلمة  $\theta_2$  أكبر من ضعف الخطأ المعياري لكل منها مما يؤكد معنوية معالمه.

جدول (4): تقديرات معالم النموذج ARIMA(0,2,2) المقترن

المعلمة المقدرة	التقدير	الخطأ المعياري	قيمة T
$\theta_1$	-0.8604	0.074	11.627
$\theta_2$	-0.1095	0.027	4.055

وعليه فإن النموذج سيكون بالصيغة الآتية:

$$(1 - B)^2 \ln y_t = (1 + 0.8604B + 0.1095B^2) \varepsilon_t$$

ثالثاً: مرحلة التشخيص : وفيها يتم اختصار النموذج المرشح لعدد من الاختبارات هي:

### 1. تحليل السكون والانعكاس

نعلم أن نموذج المتوسطات المتحركة ساكن دائماً ولتحقيق شرط الانعكاس نجد أن:

$$\theta_1 + \theta_2 = -0.8604 + (-0.1095) = -0.9699 < 1$$

$$\theta_2 - \theta_1 = -0.1095 - (-0.8604) = 0.7509 < 1$$

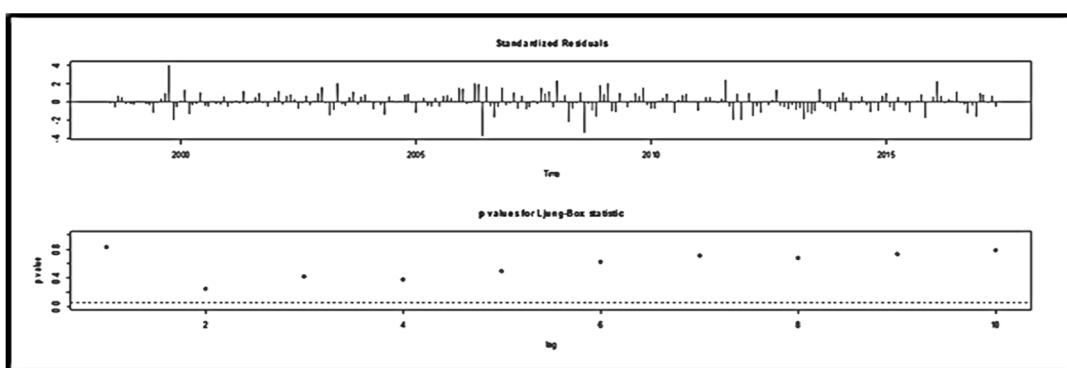
$$|\theta_2| = |-0.1095| = 0.1095 < 1$$

وبالتالي فإن معالم النموذج تحقق شرطى السكون والانعكاس.

2. تحليل البوافي : ويتم ذلك من خلال فحص:

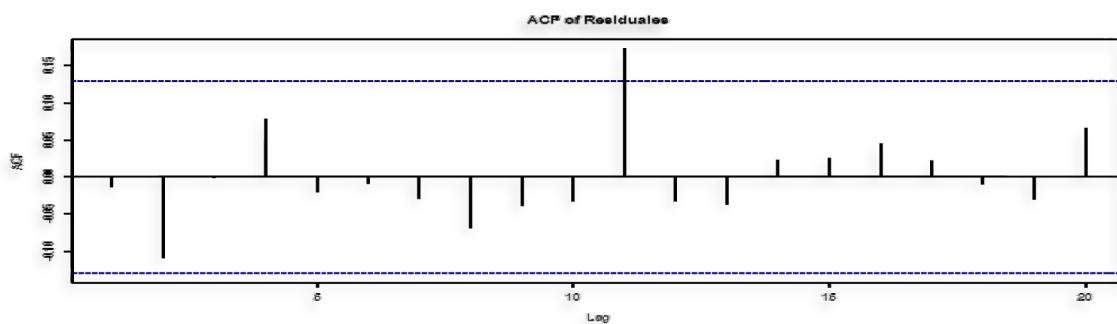
□ تجسس تباين البوافي حول الصفر وعشوانية البوافي:

يتضح من الرسم البياني التالي للبوافي أنها تتارجح بصورة ثابتة نوعاً ما حول الصفر، ويتبين من الجزء الأخير من الشكل الذي يتعلق باختبار Ljung-Box أن قيم P-Value لجميع الفجوات الزمنية أكبر من 0.05.



شكل(5): رسم البوافي واختبار Ljung-Box لنموذج ARIMA(0,2,2)

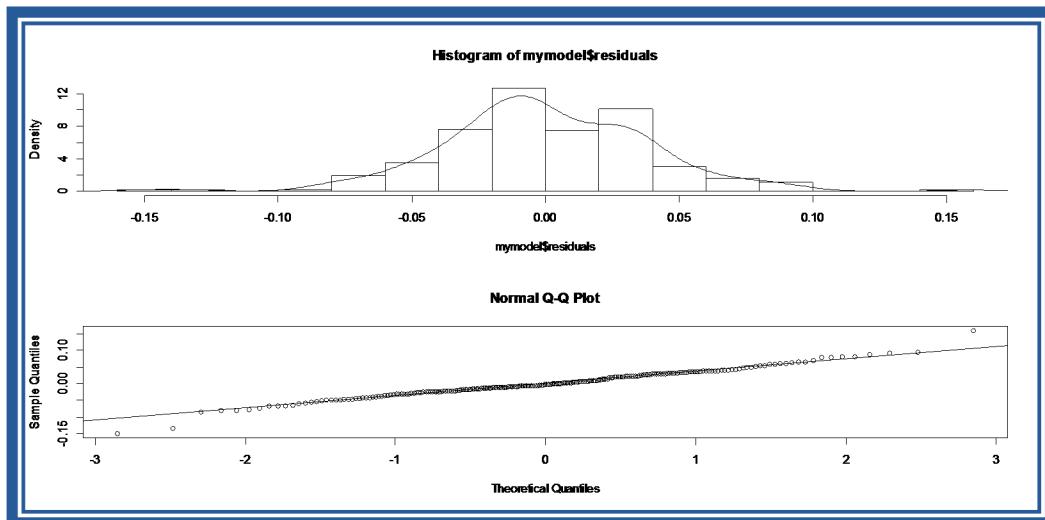
ولكن عند رسم دالة الارتباط الذاتي للبوافي كما في الشكل التالي وجد أن جميع معاملاتها تقع داخل حدود فترة الثقة عدا عند الفجوة 11 حيث نلاحظ وجود نتوء خارج حدود فترة الثقة وهذا يدعونا للقول بأن البوافي ليست عشوائية بصورة كاملة.



شكل(6): دالة الارتباط الذاتي للبوافي لنموذج ARIMA(0,2,2)

## □ طبيعية التوزيع للبواقي

يتضح في الجزء الأول من الشكل التالي أن البواقي تميل للطبيعة ولكن ليس بصورة كاملة، كما يظهر في الجزء الأخير من الشكل وجود قيم عند الأطراف تبعد عن الخط المائل، وهذا ربما دليل على عدم طبيعية التوزيع للبواقي.



شكل (7): المنحني التكراري و Q-Q plotNormal للبواقي

وللتتأكد من طبيعية التوزيع للبواقي أجرينا اختبار Jarque – Bera حيث تبين أن قيمة p-value أقل من 0.05، وبالتالي فإن البواقي غير طبيعية التوزيع.

جدول (5): نتائج اختبار Jarque-Bera لفحص طبيعية التوزيع للبواقي

$\chi^2$	DF	P-VALUE
30.27	2	2.673e-07

وهذا يؤكد بالطبع وجود نمط غير خطى في البواقي مما يستدعي استخدام نماذج غير خطية وأخرى هجينية. وعلى الرغم من نتيجة الاختبار فهذا لا ينفي أهمية نموذج ARIMA الذي تم اختياره.

### رابعاً: مرحلة التنبؤ

تم استخدام نموذج ARIMA(0,2,2) للتنبؤ بعشرة قيم مستقبلية وكان مقدار الخطأ في التنبؤ بين القيم الحقيقة والمتنبأ بها باستخدام المقاييس RMSE ، MAE على النحو التالي:

جدول (6): مقاييس دقة التنبؤ لنموذج ARIMA(0,2,2)

النموذج	MAE	RMSE
ARIMA(0,2,2)	35.02671	36.387462

### 8.3 بناء نموذج الشبكات العصبية الاصطناعية ANN باستخدام شبكة MLP

لبناء هذا النموذج نتبع المراحل الآتية

- معالجة البيانات: قبل ادخال البيانات إلى الشبكة تم معالجتها باستخدام المعادلة التالية:

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

والتي تجعل البيانات تنتمي للفترة المغلقة [0,1] وذلك لتناسب دالة التنشيط Sigmoid Function المستخدمة في الطبقة المخفية.

- تقسيم البيانات : تم تقسيم البيانات إلى مجموعتين مجموعة تدريب بواقع 216 مشاهدة (95%) ومجموعة اختبار بواقع 12 مشاهدة (5%)
- تحديد عدد العقد في طبقة المدخلات والطبقة المخفية

تم تحديدها باستخدام طريقة المحاولة والخطأ حيث بدأ الباحث بخمس وحدات معالجة في الطبقة المخفية واستمر بزيادة 5 وحدات في كل محاولة حتى وصل إلى 50 وحدة، أما بالنسبة لعدد العقد في طبقة المدخلات فبدأ بواحدة واستمر بزيادة عقدة في كل محاولة حتى وصل إلى 15 عقدة.

- تقيير النموذج
- في هذه المرحلة تم تقيير مائة وخمسين نموذجاً باستخدام دالة nnetar في برنامج R، ومن خلال تدريب الشبكة وتطبيق خوارزمية الانتشار العكسي حصلنا على نتائج RMSE للنماذج المذكورة كما هو موضح في الجدول أدناه، وللمفاضلة بين هذه النماذج والحصول على النموذج الأمثل تم البحث عن أقل قيمة لفرق المطلق للمعيار الاحصائي RMSE بحيث تتوقف عن البحث عندما لا يتجاوز هذا الفرق للمونجين المراد المفاضلة بينهما عن 0.0001 وبالتالي حصلنا على النموذج الأمثل وهو NNAR(10,45).

جدول (7): نتائج RMSE لنموذج ANN

lags	Number of nodes in hidden layer									
	5	10	15	20	25	30	35	40	45	50
1	0.02350117	<b>0.0233673</b>	0.0234077	0.023451	0.023446	0.0233853	0.02334775	0.0233821	0.02335939	0.02339366
2	0.02211789	<b>0.0217409</b>	0.021676	0.021496	0.021207	0.0214558	0.0213572	0.0213895	0.02137644	0.02135562
3	<b>0.0215306</b>	0.02146213	0.0211784	0.021017	0.021256	0.0212425	0.02114356	0.0210928	0.02093204	0.02118291
4	0.02084615	0.0205063	<b>0.0202816</b>	0.020189	0.020042	0.020169	0.02015746	0.019985	0.02001574	0.01999783
5	0.02022869	0.01927127	0.0191174	0.018777	0.019292	<b>0.0189386</b>	0.01890521	0.0192763	0.01888113	0.01832829
6	0.01977003	0.01821551	0.0179223	0.018399	0.017926	0.01809	0.01782543	0.0172705	<b>0.01791679</b>	0.01791513
7	0.01951578	<b>0.0174358</b>	0.0174175	0.01748	0.017492	0.0173858	0.0172387	0.0174822	0.01701962	0.0172353
8	0.01833028	0.01682285	0.0169908	0.016527	<b>0.016756</b>	0.0168197	0.0164743	0.0165244	0.01565051	0.01575131
9	0.01789944	<b>0.0155453</b>	0.0155731	0.015811	0.016064	0.0157067	0.01532319	0.0150631	0.01479117	0.01429763
10	0.01694795	0.01534849	0.0150209	0.014798	0.014089	0.0142111	0.01445498	0.0136903	<b>0.01350396</b>	0.01416823
11	0.01662745	0.01352536	0.0132067	0.013402	0.013665	<b>0.0134248</b>	0.01336534	0.0133758	0.01276144	0.01300053
12	0.01598559	0.01277357	0.0121302	0.012009	0.012796	0.0120195	0.01173284	<b>0.0111832</b>	0.01118732	0.0111372
13	0.01567881	0.01235537	0.0119169	0.011411	0.011917	<b>0.0111952</b>	0.01109911	0.011115	0.01064503	0.01017484
14	0.01446642	0.01171262	0.0110411	0.010884	<b>0.010553</b>	0.0105289	0.01069132	0.0108409	0.009963416	0.01016971
15	0.01443481	0.0111375	0.0104461	0.010302	0.010431	0.0114409	0.01035425	0.0098676	0.009724972	<b>0.0090217</b>

- التنبؤ: تم استخدام نموذج الشبكات (NNAR(10,45) للتنبؤ بعشرة قيم مستقبلية ، ولتحديد مقدار الخطأ في التنبؤ بين القيم الفعلية و المتنبأ بها تم استخدام مقاييس دقة التنبؤ: MAE, RMSE وكانت النتائج كما في الجدول التالي:

جدول (8): مقاييس دقة التنبؤ لنموذج NNAR(10,45)

النموذج	MAE	RMSE
NNAR (10,45)	14.27578	15.65312

### 8.3 بناء نموذج ARIMA-ANN الهجين:

يمكن تلخيص خطوات التنبؤ باستخدام نموذج ARIMA-ANN الهجين من خلال بناء نموذج الشبكات العصبية NNAR لنموذج بوافي (0,2,2) كال التالي:

- معالجة البيانات

تمَ معالجة بوافي نموذج ARIMA(0,2,2) باستخدام المعادلة السابقة :

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

- تقسيم البيانات

تمَ تقسيم بوافي نموذج ARIMA(0,2,2) إلى 95% (216 مشاهدة) لتدريب الشبكة و 5% (12 مشاهدة) لاختبار والمقارنة بين النماذج.

- تحديد عدد العقد في طبقة المدخلات والطبقة المخفية

تمَ تحديدها باستخدام طريقة المحاولة والخطأ التي ذكرناها سابقاً في بناء نموذج الشبكات العصبية.

- تقيير النموذج

في هذه المرحلة تمَ تقيير مائةٍ وخمسةٍ وثلاثين نموذجاً باستخدام دالة `nnetar` في برنامج R، وللمفاضلة بين تلك النماذج والحصول على النموذج الأمثل تمَ البحث عن أقل قيمة للمعيار الاحصائي RMSE بحيث يتوقف عن البحث عندما لا يتجاوز الفرق المطلق لهذا المعيار للنموذجين المراد المفاضلة بينهما عن 0.001 وبالتالي حصلنا على النموذج الأمثل وهو (6,35) NNAR. ويتبين ذلك من الجدول التالي:

جدول (9): نتائج RMSE لبوافي نموذج ARIMA(0,2,2) باستخدام ANN .

lags	Number of nodes in hidden layer								
	5	10	15	20	25	30	35	40	45
1	0.111637	0.109051	<b>0.107554</b>	0.10705	0.1047283	0.1077159	0.1079122	0.107618	0.1066417
2	0.105117	0.100136	0.094905	<b>0.09291</b>	0.0920341	0.08976854	0.09036451	0.089423	0.0886966
3	0.097468	0.079574	0.068145	0.062148	0.0574729	0.05278871	0.05112373	<b>0.048448</b>	0.0491184
4	0.090315	0.066467	0.052543	0.042341	0.0341212	0.02785678	0.02576863	0.023766	<b>0.022418</b>
5	0.082102	0.054863	0.037103	0.029224	0.0214736	0.01791365	0.01673066	<b>0.015636</b>	0.0165805
6	0.078016	0.047628	0.029269	0.02098	0.0153783	0.01403515	<b>0.0124059</b>	0.013053	0.012741
7	0.070062	0.040285	0.024023	0.01706	0.0146416	<b>0.0123087</b>	0.01142215	0.011694	0.0114489
8	0.063818	0.035469	0.019545	0.014883	0.0119628	<b>0.010499</b>	0.01030032	0.009566	0.0093944
9	0.064744	0.029592	0.016809	0.013163	0.0103485	<b>0.0089042</b>	0.0091092	0.008974	0.0086467
10	0.056671	0.026444	0.015817	0.011728	0.0086418	<b>0.0074668</b>	0.00711348	0.006672	0.0067711
11	0.056579	0.022184	0.01273	0.009185	0.0073741	<b>0.005877</b>	0.00576569	0.005385	0.0051723
12	0.051075	0.020029	0.011773	0.007669	0.0059575	<b>0.0047718</b>	0.00424361	0.004448	0.0044559
13	0.047811	0.017492	0.009466	0.005694	0.0049365	<b>0.0038049</b>	0.00301914	0.002777	0.0028365
14	0.044934	0.016478	0.008885	0.005154	0.0032667	<b>0.0021868</b>	0.00222143	0.002511	0.0024992
15	0.04739	0.014565	0.006709	0.003859	<b>0.002411</b>	0.00249774	0.00226636	0.002226	0.0023687

- التنبؤ:

تم جمع تنبؤات نموذج ARIMA(0,2,2) مع تنبؤات بوافيه باستخدام نموذج NNAR(6,35) على النحو التالي:

$\hat{y}_t = \hat{L}_t + \hat{N}_t$  ولتحديد مقدار الخطأ في التنبؤ بين القيم الفعلية والمتباينة بها تم استخدام مقاييس دقة التنبؤ RMSE, MAE كما في الجدول التالي:

جدول(10): القيم المتباينها لنموذج ARIMA-ANN (الهجين)

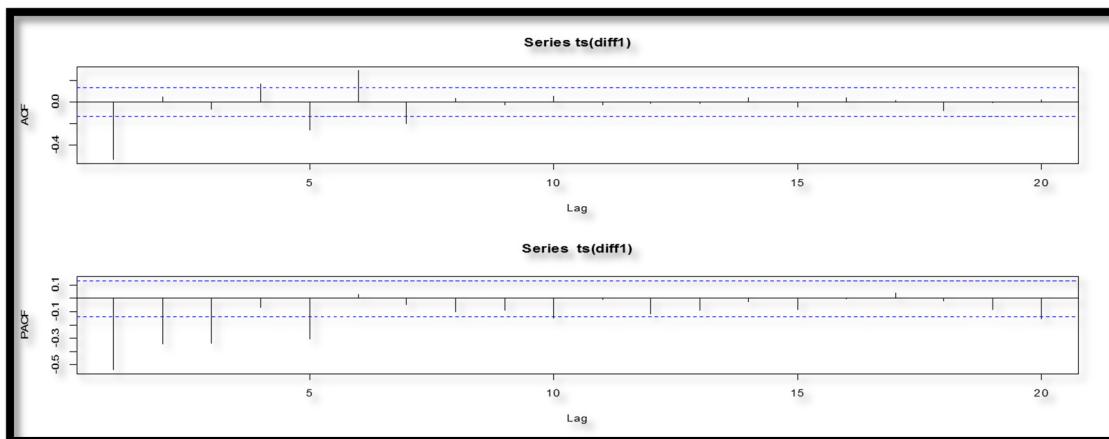
النموذج الهجين	MAE	RMSE
ARIMA- ANN	6.880542	11.5201

### 8.3 بناء نموذج ARIMA ANN الهجين:

يمكن تلخيص خطوات التنبؤ باستخدام نموذج ARIMA ANN الهجين من خلال بناء نموذج ARIMA لنموذج بوافي نموذج الشبكات NNAR(10,45) كالتالي:

- مرحلتي التعرف والتقدير

بعد التتحقق من سكون السلسلة عند  $d=1$ , تأتي مرحلة التعرف على النموذج المبدئي عن طريق رسم دالتي الارتباط الذاتي والذاتي الجزئي، وبالتالي يمكن ترشيح النموذج ARIMA(0,1,1) كما يتضح من الشكل التالي:



شكل(8): دالتي الارتباط الذاتي والذاتي الجزئي لسلسلة البوافي لنموذج NNAR(10,45)

ولتتحقق تم الاستعانة بدالة الارتباط الذاتي الموسعة EACF للمساعدة في تحديد معالم نموذج ARIMA، حيث أن دالة الارتباط الذاتي الموسعة EACF رشحت لنا النموذج ARIMA(1,1,2). ولتوفيق أفضل نموذج للسلسلة، سنقوم بترشيح نماذج أخرى ARIMA(p,d,q)، ثم يتم المفاضلة بين هذه النماذج للحصول على النموذج الأفضل وهو ARIMA(1,1,2)، وذلك لامتلاكه أقل القيم للمعايير أدناه.

جدول (11): النماذج المرشحة ومعايير التقييم المقابلة لكل نموذج مرشح

MODEL	AIC	AICC	BIC
ARIMA(1,1,1)	1627.79	1627.9	1637.86
ARIMA(0,1,2)	1627.82	1627.94	1637.89
ARIMA(1,1,2)	1625.73	1625.92	1629.15
ARIMA(2,1,2)	1627.61	1627.9	1644.39
ARIMA(0,1,1)	1626.58	1626.63	1633.29
ARIMA(2,1,1)	1629.7	1629.89	1643.13
ARIMA(1,1,0)	1708.69	1708.75	1715.4
ARIMA(2,1,0)	1685	1685.12	1695.07

وأن تقديرات معالم هذا النموذج مبينة في الجدول الآتي:

جدول (12): تقديرات معالم النموذج ARIMA(1,1,2) المقترن

المعلمـة المقدرة	التقـدير	الخطـأ المعيـاري	قيـمة T
$\phi_1$	-0.9192	0.0712	12.91
$\theta_1$	-0.1405	0.0602	2.33
$\theta_2$	-0.8595	0.0899	9.56

حيث يتضح من الجدول أعلاه معنوية معالم النموذج المقترن  $\theta_1, \theta_2, \phi_1 \neq 0$  وذلك لأن القيمة المطلقة لتقدير تلك المعالم أكبر من ضعف الخطأ المعياري لكل منهم.

#### • مرحلة التشخيص

وفيها يتم اختصار النموذج المرشح لعدد من الاختبارات هي:

## 1. تحليل السكون والانعكاس

إن معالم النموذج تحقق شرطي السكون والانعكاس حيث نجد أن

$$|\phi_1| = |-0.9192| = 0.9192 < 1$$

$$\theta_1 + \theta_2 = -0.1405 + (-0.8595) = -1 < 1$$

$$\theta_2 - \theta_1 = -0.8595 - (-0.1405) = -0.719 < 1$$

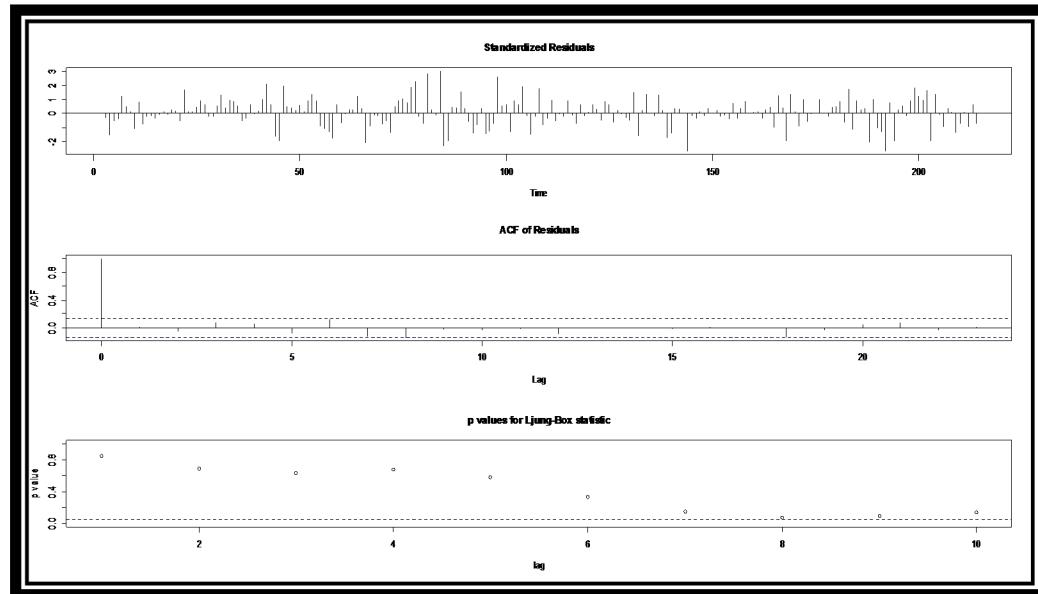
$$|\theta_2| = |-0.8595| = 0.8595 < 1$$

2. تحليل البوافي : ويتم ذلك من خلال فحص كل من:

- تجانس تباين البوافي حول الصفر وعشوانية البوافي

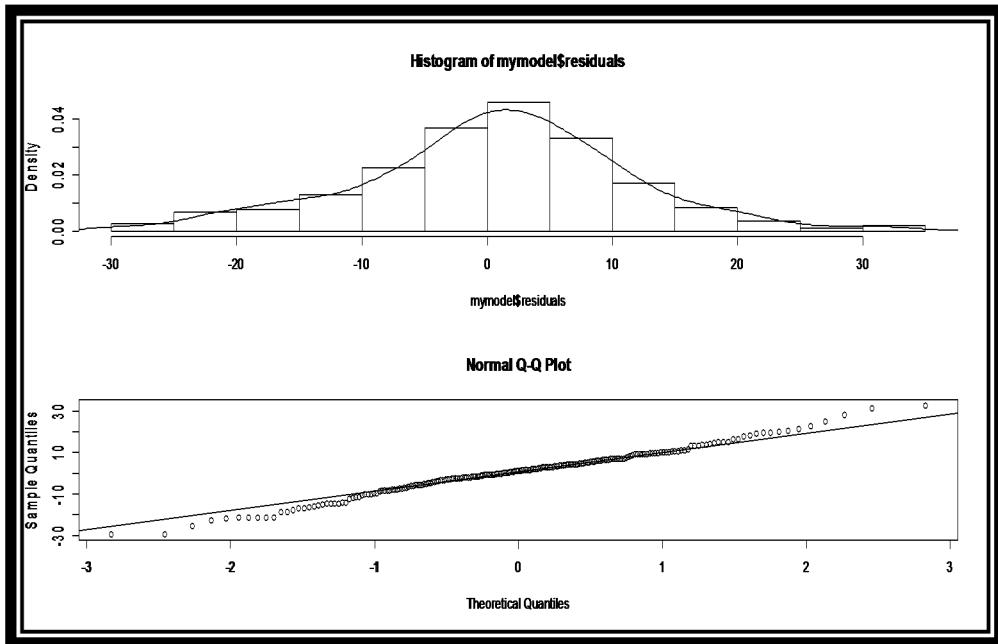
يتضح من الرسم البياني التالي للبوافي أنها تتراوح بصورة ثابتة حول الصفر، كما يتضح من دالة الارتباط الذاتي للبوافي أن جميع معاملاتها تقع داخل حدود فترة الثقة وهذا يعني أن البوافي تمثل متغيرات عشوائية بحثة، كما يؤكد ذلك اختبار Ljung-Box حيث أن قيم p-value عند جميع الفجوات

أكبر من 0.05



شكل(9): رسم البوافي ودالة الارتباط الذاتي لبوافي النموذج المقترن واختبار Ljung-Box

- طبيعية التوزيع للبواقي: يوضح الجزء الأول من الشكل طبيعة التوزيع للبواقي، ويؤكد ذلك الجزء الأخير من الشكل، والذي يبين أن البواقي تجتمع بشكل كبير حول الخط المائل الذي يمثل منحنى التوزيع الطبيعي.



شكل(10): المنحنى التكراري و Normal Q-Q plot للبواقي

- مرحلة التنبؤ :

تم جمع تنبؤات نموذج NNAR(10,45) مع تنبؤات بواقيه باستخدام نموذج ARIMA(1,1,2) ولتحديد مقدار الخطأ في التنبؤ بين القيم الفعلية والمتنبأ بها، تم استخدام مقاييس دقة التنبؤ ، RMSE ، MAE كما في الجدول:

جدول (13): مقاييس دقة التنبؤ لنموذج (ANN-ARIMA) الهجين

النموذج الهجين	MAE	RMSE
(ANN-ARIMA)	13.42512	15.30648

9. المقارنة بين النماذج المفردة والهجينة:

جدول (14): مقاييس دقة التنبؤ للمقارنة بين النماذج المفردة والهجينة

النموذج	MAE	RMSE
ARIMA(0,2,2)	35.02671	36.87492
NNAR(10,45)	14.27578	15.65312
Hybrid (ARIMA-ANN)	6.880542	11.5201
Hybrid(ANN-ARIMA)	13.42512	15.30648

يتضح من الجدول أعلاه أن النموذج الهجين ARIMA-ANN أكفاءً نموذج مقارنة بالنماذج الأخرى، يليه النموذج الهجين ANN-ARIMA ثم النموذج ANN وأخيراً نموذج ARIMA. وللوضيح ما تم التوصل إليه من نتائج سنستخدم مبدأ الكفاءة النسبية (White and Safi, 2016)

$$\rho = \frac{RMSE_p \text{ لطريقة التنبؤ المقترحة}}{RMSE_b \text{ بها القياس المراد التنبؤ لطريقة}}$$

إذا كانت  $\rho < 1$  فهذا يعني أن طريقة التنبؤ المقترحة أكثر كفاءة من الطريقة المراد القياس بها، أمّا إذا كانت  $\rho$  قريبة جداً من 1 فهذا يعني أن كفاءة الطريقة المقترحة قريبة جداً من كفاءة الطريقة المراد القياس بها، وغير ذلك فإنَّ أداء الطريقة المقترحة سيئة. ويتبين ما سبق في الجدول التالي:

جدول (15): الكفاءة النسبية للنماذج

طريقة التنبؤ المراد القياس بها	طريقة التنبؤ المقترحة			
	ARIMA(0,2,2)	NNAR(10,45)	ARIMA- ANN	ANN- ARIMA
ARIMA(0,2,2)	-	0.4244	0.3124	0.415
NNAR(10,45)	-	-	0.736	0.97785

أي أن:-

- نموذج NNAR(10,45) أكثر دقةً وكفاءةً في التنبؤ بـ 2.36 مرة على نموذج ARIMA(0,2,2).
- النموذج الهجين ARIMA-ANN أكثر دقةً وكفاءةً في التنبؤ بـ 3.2 مرة على نموذج ARIMA(0,2,2)، وأكثر دقةً وكفاءةً في التنبؤ بـ 1.36 مرة على نموذج NNAR(10,45).
- النموذج الهجين ANN-ARIMA أكثر دقةً وكفاءةً في التنبؤ بـ 2.41 مرة على نموذج ARIMA(0,2,2).
- النموذج الهجين ANN-ARIMA مساوياً تقريباً في الدقة والكفاءة لنموذج NNAR(10,45).

## 10. الخلاصة:

مما سبق نستطيع القول بأنَّ نموذج ARIMA-ANN الهجين أكفاءً نموذج مقارنة بالنماذج الأخرى، يليه النموذج ANN-ARIMA الهجين ثم النموذج ANN وأخيراً نموذج ARIMA. ونوصي الباحثين باستخدام أسلوب المحاكاة بهدف تعميم النتيجة التي توصل إليها هذا البحث.

## المراجع:

### أولاً: المراجع العربية

1. الساعدي، علي (2016). "استخدام نماذج السلسل الزمنية الهجينه وغير الهجينه للتنبؤ بأعداد المسافرين لمطار بغداد الدولي" رسالة ماجستير، الجامعة المستنصرية، بغداد، العراق.
2. الصفاوي، صفاء و زكي، عزة (2006). "مقارنة بين طرائق التنبؤ المكيفه والشبكات العصبية مع التطبيق"، المجلة العراقيه للعلوم الاحصائيه، المجلد (6)، العدد (9)، ص:49-66، العراق.
3. الطائي ، فاضل (2010). " التنبؤ والتمهيد للسلسل الزمنية باستخدام التحويلات مع التطبيق" ، المجلة العراقيه للعلوم الاحصائيه، العدد (17)، ص:293-308، العراق.
4. عبد العزيز، بشينة 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:62-92، العراق.
5. الليلة ، ظافر (2006). " التكهنه بالسلسل الزمنية المتعددة باستخدام المكونات الرئيسية" ، رسالة ماجستير غير منشورة، جامعة الموصل، العراق.

### ثانياً: المراجع الأجنبية

6. Babu, C.N. and Reddy, B.E., (2015). "Performance Comparison of Four New ARIMA-ANN Prediction Models on Internet Traffic", Department of Computer Science and Engineering, JNT University College of Engineering, Anantapuramu, India.
7. Box, G.E.P. and Jenkins, G.M., (1976). "Time Series Analysis; Forecasting and Control", 2nd ed., Holden-Day: San Francisco.
8. Khandelwal, I. Adhikari, R. and Verma, G. (2015). "Time Series Forecasting Using Hybrid ARIMA and ANN Models Based on DWT Decomposition", International Conference on Intelligent Computing, Communication and Convergence 48, pp: 173 – 179, Jaipur, India.

- 9. Kumar, D. Raju. K. and Sathish , T. (2004). "River Flow Forecasting Using Recurrent Neural Networks", WaterResources Management Vol.18,pp.1431-161.**
- 10.Kumar, M. and Thenmozhi, M.,(2012). "Stock Index Return Forecasting and Trading Strategy Using Hybrid ARIMA-Neural Network Model", International Journal of Financial Management, Vol. 1, No. 1, Chennai, India.**
- 11.Palit, A. K. and Popovic, P., (2005). "Computational Intelligence in Time Series Forecasting", Springer, London.**
- 12.White, A. K. and Safi, S. K. (2016). The Efficiency of Artificial Neural Networks for Forecasting in the Presence of Auto correlated Disturbances. International Journal of Statistics and Probability, 5 (2) :51**