

التنبؤ بسعر صرف الدينار الجزائري مقابل الدولار الأمريكي باستخدام نموذج الانحدار الذاتي و
المتوسطات المتحركة المتكاملة والشبكات العصبية الاصطناعية -دراسة مقارنة

**Forecasting the exchange rate of the Algerian dinar against the US
dollar using an Autoregressive Model, Integrated Moving Averages,
and Artificial Neural Networks – a comparative study**

عبدالقادر مراد، مخبر الطرق الكمية في العلوم الاقتصادية وعلوم إدارة الأعمال وتطبيقاتها من اجل التنمية المستدامة،

جامعة الجلفة (الجزائر)، a.merrad@univ-djelfa.dz

تاريخ النشر: 2026/03/27

تاريخ القبول: 2026/03/16

تاريخ الاستلام: 2026/01/20

ملخص:

تهدف هذه الورقة البحثية الى تقدير نموذجين للتنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الأمريكي ومقارنة ادائهما التنبؤي، نموذج الانحدار الذاتي-المتوسطات المتحركة المتكاملة ARIMA وهو أحد نماذج السلاسل الزمنية الخطية التفليدية، ونموذج الشبكات العصبية الاصطناعية NAR-ANN وهو أحد أساليب التعلم الآلي، ولتحقيق الهدف تم استخدام بيانات شهرية ممتدة من شهر جانفي 2000 الى غاية شهر ديسمبر 2025 اي 312 شهر، حيث قسمت تلك البيانات الى مجموعتين : مجموعة التدريب شملت 281 شهر الاولى لتقدير النموذجين، ومجموعة الاختبار شملت 31 شهر الاخيرة لاختبار ومقارنة النموذجين. اظهرت النتائج التطبيقية المقارنة بين الاداء التنبؤي للنموذجين باستخدام معايير دقة التنبؤ تفوق اداء نموذج الشبكات العصبية الاصطناعية NAR-ANN على اداء نموذج الانحدار الذاتي-المتوسطات المتحركة المتكاملة ARIMA في التنبؤ بسعر صرف الدينار الجزائري مقابل الدولار الأمريكي.

كلمات مفتاحية: سعر صرف، نموذج ARIMA، نموذج NAR-ANN ، دقة تنبؤ.

تصنيفات JEL : E47، F31

Abstract:

This research paper aims to evaluate and compare the predictive performance of two models for forecasting the Algerian dinar exchange rate

against the US dollar: the Autoregressive Integrated Moving Average (ARIMA) model, and the Artificial Neural Network (NAR-ANN) model, To achieve this objective, monthly data (01/2000 to 12/2025) was used. This data was divided into two sets: a training set covering the first 281 months for estimating the two models, and a test set covering the last 31 months for testing and comparing them. The applied results, comparing the predictive performance of the two models using prediction accuracy criteria, showed that the NAR-ANN model outperformed the ARIMA model in predicting the Algerian dinar exchange rate against the US dollar.

Keywords: Exchange rate; ARIMA model; NAR-ANN model; prediction accuracy;

Jel Classification Codes:F31,E47

1. مقدمة:

يُعدّ سعر الصرف أحد أهم المؤشرات الاقتصادية التي تؤثر على استقرار الاقتصاد الكلي للدول، حيث يعكس القوة الشرائية للعملة المحلية مقارنة بالعملة الأجنبية، لذلك فإن التنبؤ بأسعار الصرف يعتبر من أهم مجالات التي خصها القياس المالي. وقد بُدلت جهود كبيرة على مدى العقود العديدة الماضية لتطوير وتحسين نماذج التنبؤ بالسلاسل الزمنية بصفة عامة، ونظراً لعدم خطيتها وتقلبها العالية وحساسيتها للعديد من العوامل الاقتصادية وحتى السياسية، فإن التنبؤ بحركة أسعار الصرف وقيمتها باستعمال نماذج ARIMA التقليدية سوف لن يفضي في الغالب إلى تنبؤات دقيقة وخاصة في المدى الطويل، فعلى الرغم من أن نماذج ARIMA مرنة للغاية، إذ يمكنها تمثيل أنواع مختلفة من السلاسل الزمنية، مثل الانحدار الذاتي الصرف AR، والمتوسط المتحرك الصرف MA، ونماذج AR و MA المدججة ARMA، إلا أن عيبها الرئيسي يكمن في الشكل الخطي المفترض مسبقاً للنموذج. أي أنها تفترض وجود بنية ارتباط خطية بين قيم السلسلة الزمنية، وبالتالي، لا يمكن لهذا النوع من النماذج من التقاط الانماط غير الخطية في السلاسل الزمنية مثل سلاسل أسعار الصرف، ونتيجة لذلك اقترحت العديد من البحوث بما يسمى بنموذج الانحدار الذاتي غير الخطي للشبكات العصبية NAR-ANN التي يمكنها التقاط الانماط غير الخطية في السلاسل الزمنية كحل واعد وبديل عن نموذج ARIMA الخطي للتنبؤ بأسعار الصرف.

1.1. اشكالية البحث: انطلاقا مما سبق يمكن طرح الاشكالية التالية:

الى اي مدى يتفوق نموذج الانحدار الذاتي غير الخطي للشبكات العصبية **NAR-ANN** في تحقيق دقة تنبؤية اعلى مقارنة بنموذج **ARIMA** الخطي في التنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الأمريكي؟

2.1. فرضيات البحث:

- لا يمكن لنماذج **ARIMA** التنبؤ بالنمط غير الخطي الموجود في سلسلة سعر الصرف الدينار الجزائري مقابل الدولار الأمريكي .

- يمكن لنموذج الشبكات العصبية الاصطناعية **NAR-ANN** تحقيق دقة عالية في التنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الأمريكي.

- يتفوق نموذج الشبكات العصبية الاصطناعية **NAR-ANN** على نموذج **ARIMA** في التنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الأمريكي.

3.1. اهداف البحث:

يسعى هذا البحث الى تحقيق الاهداف التالية:

- التعريف بمنهجية بوكس-جينكز، خطواتها وطريقة استعمالها للحصول على نموذج **ARIMA** الامثل للتنبؤ بسعر الصرف الدينار مقابل الدولار الأمريكي.

- التعريف بالشبكات العصبية الاصطناعية، مكوناتها، انواعها وطريقة استعمالها للحصول على نموذج **NAR-ANN** الامثل للتنبؤ بسعر الصرف الدينار مقابل الدولار الأمريكي.

- تقدير النموذجين السابقين ومقارنة ادائهما التنبؤي باستعمال معايير دقة التنبؤ.

4.1. منهج البحث:

تم الاعتماد على المنهج التجريبي من خلال تجريب العديد من المدخلات للحصول على نماذج **ARIMA** و **NAR-ANN** المثلى للتنبؤ بسعر الصرف، والمنهج الكمي من خلال تقدير تلك النماذج ومقارنة ادائها في التنبؤ بسعر الصرف.

5.1. الدراسات السابقة:

هناك العديد من الدراسات السابقة التي تنبأت بسعر الصرف منها من استعملت نماذج **ARIMA** ومنها من استعملت نماذج **ANN** ومنها من استعملت كلا النموذجين والمقارنة بينهما، و سيتم ذكر الدراسات المقارنة المتوفرة فقط:

A Comparative Analysis of :المعنونة (Emre Urkmez,2025) دراسة -
 Artificial Neural Networks and Time Series Models in Exchange
 Contributions to Finance and 'Rate Forecasting Accounting
 'Accounting ، هدفت هذه الدراسة الى مقارنة اداء نماذج الشبكات العصبية باداء نماذج السلاسل
 الزمنية في التنبؤ بسعر صرف الليرة التركية مقابل الدولار الامريكى خلال الفترة الممتدة من جانفي 2010
 الى غاية اكتوبر 2024. اظهرت نتائج هذه الدراسة تفوق نموذج الشبكات العصبية الاصطناعية
 ANN على نموذج ARIMA في التنبؤ بسعر صرف الليرة مقابل الدولار الامريكى.

دراسة (Md. Shahajada Mia et al,2017) المعنونة بـ
 Forecasting the BDT/USD Exchange Rate: An Accuracy Comparison of Artificial
 Neural Network Models and Different Time Series Models ، والمنشورة
 في Journal of Statistics Applications & Probability Letters ، هدفت هذه
 الدراسة الى مقارنة اداء نماذج الشبكات العصبية باداء نماذج السلاسل الزمنية في التنبؤ بسعر صرف عملة
 دولة بنغلاداش التاكا مقابل الدولار الامريكى خلال الفترة الممتدة من اوت 2004 الى غاية مارس
 2016. اظهرت نتائج هذه الدراسة تفوق نموذج الشبكات العصبية الاصطناعية ANN على نموذج
 ARIMA في التنبؤ بسعر صرف التاكا مقابل الدولار الامريكى .

دراسة (Diteboho و Mogari ,2017) المعنونة بـ :
 A Comparative Analysis of Artificial Neural Network and Autoregressive Integrated Moving
 Average Model on Modeling and Forecasting Exchange Rate
 International Journal of Economics and Management في
 والمنشورة في Engineering ، هدفت هذه الدراسة الى مقارنة اداء نماذج الشبكات العصبية واداء نماذج السلاسل
 الزمنية في التنبؤ بسعر صرف عملة دولة جنوب افريقيا مقابل الدولار الامريكى خلال الفترة الممتدة من
 جانفي 1960 الى غاية فيفري 2016. اظهرت نتائج هذه الدراسة تفوق نموذج ARIMA على
 نموذج الشبكات العصبية الاصطناعية ANN في التنبؤ بسعر صرف الراند مقابل الدولار الامريكى.

دراسة (Abou-Zaid و Stokes, 2012) المعنونة بـ
 Forecasting foreign exchange rates using artificial neural networks: a trader's approach
 ، والمنشورة في Int. J. Monetary Economics and Finance ، هدفت هذه الدراسة الى

مقارنة اداء نماذج الشبكات العصبية واداء نماذج السلاسل الزمنية في التنبؤ بسعر صرف ثلاث عملات: الاورو، الجنيه الاسترليني و الين مقابل الدولار الأمريكي خلال الفترة الممتدة من جانفي 1980 الى غاية اوت 2010. اظهرت نتائج هذه الدراسة تفوق نموذج الشبكات العصبية الاصطناعية ANN على نموذج ARIMA في التنبؤ بسعر صرف تلك العملات مقابل الدولار الأمريكي.

-دراسة (Sarker و Kamruzzaman, 2003) المعنونة بـ Comparing ANN Based models with ARIMA for Prediction of Forex Rates ، والمنشورة في ASOR BULLETIN ، هدفت هذه الدراسة الى مقارنة اداء نماذج الشبكات العصبية واداء نماذج السلاسل الزمنية في التنبؤ بسعر صرف ستة عملات: الدولار الأمريكي، الجنيه الاسترليني، الين، الدولار السنغفوري، الدولار النيوزيلاندي و الفرنك السويسري مقابل الدولار الاسترالي خلال الفترة الممتدة من جانفي 1991 الى غاية جويلية 2002. اظهرت نتائج هذه الدراسة تفوق نموذج الشبكات العصبية الاصطناعية ANN على نموذج ARIMA في التنبؤ بسعر صرف تلك العملات مقابل الدولار الاسترالي.

2. الاطار النظري :

1.2 نماذج الانحدار الذاتي-المتوسطات المتحركة المتكاملة ARIMA:

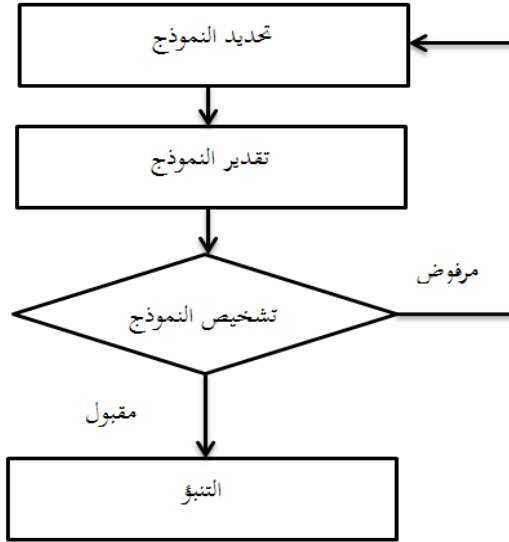
تم تقديم هذه النماذج من طرف بوكس-جينكز سنة 1970، تعد احد اكثر نماذج التنبؤ شيوعا، وهي عبارة عن نماذج خطية تستخدم القيم الماضية للتنبؤ بالقيم المستقبلية للسلسلة الزمنية (Rathod, et al., 2017). و بشكل عام فهي تتكون من دمج نماذج الانحدار الذاتي (AR) من الرتبة p ونماذج المتوسط المتحرك (MA) من الرتبة q . وتكتب الصيغة العامة لنماذج $ARIMA(p,d,q)$ على النحو التالي (Asteriou & G. Hall, 2016):

$$\Delta^d Y_t (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) = (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) u_t$$

حيث d : تمثل درجة تكامل السلسلة او عدد الفروق التي تجعل السلسلة مستقرة، p و q هي عدد الابطاءات او الرتبة في نماذج AR و MA على التوالي، و u_t هي الاخطاء او البواقي والتي تتذبذب حول الصفر بتباين ثابت.

وفي سنة 1976 قدم بوكس-جينكيز أول منهجية لإيجاد نموذج **ARIMA** الامثل، وتتكون المنهجية المقترحة من خوارزمية ثلاثية الخطوات (الشكل اسفله) تشمل تحديد النموذج، تقدير معلماته ثم تشخيصه. وأخيراً، يمكن استخدام النموذج الأمثل المتحصل عليه للتنبؤ.

الشكل 1: خطوات منهجية بوكس-جينكس



المصدر: من اعداد الباحث اعتمادا على تسلسل خطوات منهجية بوكس - جينكيز.

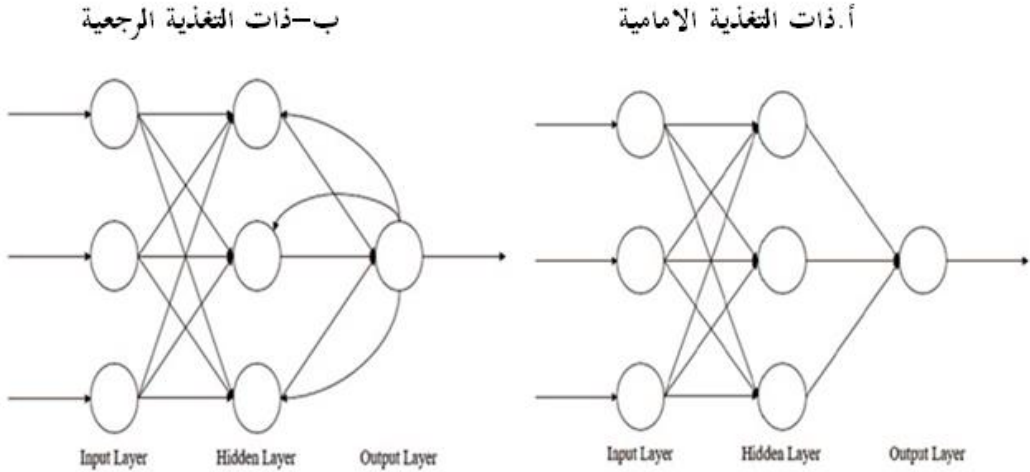
2.2 الشبكات العصبية الاصطناعية:

الشبكات العصبية الاصطناعية Artificial Neural Networks والمعروفة اختصارا بـ ANN من أكثر المناهج شيوعاً في مجال التنبؤ بأسعار الصرف، وتُعتبر القدرة على التعلم من أهم سمات هذه الشبكات، حيث يمكنها التعلم من الأمثلة، التجارب، الأنماط، وما إلى ذلك (Bal و Demir، 2017). طُوِّرت بنى الشبكات العصبية الاصطناعية انطلاقاً من نماذج معروفة للأجهزة العصبية البيولوجية والدماغ البشري نفسه. أما المكونات الحاسوبية أو وحدات المعالجة، والتي تُسمى الخلايا العصبية الاصطناعية، فهي نماذج مبسطة للخلايا العصبية البيولوجية. وقد استُلهمت هذه النماذج من تحليل كيفية توليد غشاء الخلية العصبية للنبضات الكهربائية ونقلها (BENLARIA & BOUBEKEUR, 2021).

ويتكون النوع الأكثر شيوعاً من الشبكات العصبية الاصطناعية من ثلاث طبقات من الوحدات او العقد: طبقة من وحدات الإدخال متصلة بطبقة من الوحدات المخفية، والتي بدورها متصلة بطبقة من

وحدات الإخراج (Nanayakkara, Chandrasekar, & Jayasundara, 2014)، بالإضافة إلى دوال التجميع، العتبة ودوال التنشيط الموجودة على مستوى العقد. والشبكات العصبية أنواع أهمها (Chakraverty & Jeswal, 2021): الشبكة العصبية ذات التغذية الأمامية، والتي يكون تدفق المعلومات فيها أحادي الاتجاه، حيث تتدفق المعلومات من الطبقة n إلى الطبقة $(n+1)$ ، ولكن ليس العكس. والشبكة العصبية ذات التغذية الرجعية أو المتكررة، والتي تتألف من هياكل معقدة ذات طبقة مخفية واحدة أو أكثر، ويكون تدفق المعلومات فيها ممكناً في كلا الاتجاهين، حيث تنتقل المعلومات من طبقة الإدخال إلى الطبقة المخفية ومن الطبقة المخفية إلى طبقة الإخراج وترسل المعلومات بطريقة عكسية.

الشكل 2: أنواع الشبكات العصبية



المصدر: Chakraverty, S., & Jeswal, K. S., 2021, p3-4.

أما بالنسبة لخطوات استعمال الشبكات العصبية الاصطناعية في التنبؤ فيمكن تلخيصها فيما يلي (Kamouh, 2024):

- جمع البيانات: جمع البيانات المناسبة للتدريب والتي تمثل المشكلة التي يهدف النموذج إلى حلها.
- معالجة البيانات: تنظيف البيانات وتطبيعها لجعلها مناسبة للاستخدام في الشبكة العصبية.
- تقسيم البيانات: تقسيم البيانات إلى مجموعات التدريب والاختبار والتحقق.
- تصميم النموذج: اختيار بنية الشبكة المناسبة، بما في ذلك عدد الطبقات والخلايا العصبية في كل طبقة.

-تدريب النموذج: استخدم بيانات التدريب لضبط الأوزان من خلال عمليات التعلم التكرارية مثل الانتشار العكسي.

-تقييم النموذج: تقييم دقة النموذج وفعالته باستخدام بيانات الاختبار.

-تحسين النموذج: إعادة ضبط بنية النموذج أو إعدادات التدريب لتحسين الأداء.

-التنبؤ: استخدم النموذج المدرب لإجراء تنبؤات بناءً على بيانات جديدة.

3. الاطار التطبيقي:

1.3.البيانات: تم الحصول على بيانات سعر صرف الدينار الجزائري مقابل الدولار الأمريكي لنهاية الفترة من موقع investing.com. تحتوي السلسلة الزمنية على بيانات شهرية غطت الفترة 2000/01 – 2025/12، اي 312 شهر. يوضح الشكل 3 اسفله تطور سعر الصرف الدينار مقابل الدولار، و يظهر الجداول 1 ملخصًا إحصائيًا لبيانات سعر الصرف الشهري في المستوى. يُلاحظ من خلال هذا الجدول أن سعر صرف الدينار الجزائري مقابل الدولار بلغ متوسط قدره 4.521، بانحراف معياري قدره 0.263، ووصل إلى أدنى مستوى له عند 4.110 وأعلى مستوى عند 4.980. وتشير قيم الالتواء والتفرطح التي اخذت 0.398 و1.502 على التوالي إلى أن منحنى توزيع البيانات ملتو جهة اليمين، و أنه مفرطح.

وقد تم تقسيم البيانات الى ثلاث مجاميع قصد استعمالها في تقدير ومقارنة النماذج، 80% من البيانات اي 250 مشاهدة للتدريب، 10% اي 31 مشاهدة للتحقق و 10% الباقية للاختبار.

الشكل 3: التطور التاريخي لسعر صرف الدينار الجزائري



المصدر: مخرجات برنامج matlab2019b

الجدول 1: الاحصاء الوصفي لسعر صرف الدينار

المتوسط	الانحراف المعياري	ادنى قيمة	اعلى قيمة	الالتواء	التفرطح
4.521	0.263	4.110	4.980	0.398	1.502

المصدر: من اعداد الباحث اعتمادا على مخرجات برنامج matlab2019b

2.3. نموذج ARIMA الامثل للتنبؤ بسعر الصرف:

1.2.3. تحديد النموذج:

ويتم في هذه الخطوة اختبار استقرارية سلسلة سعر الصرف وتحديد درجات التأخير او الابطاء في نموذج التنبؤ. واختبار استقرارية سلسلة البطالة تم استعمال اختبار ديكي-فولر المطور (ADF(1979)، وهو احد أهم الاختبارات وأكثرها استخداما في الدراسات الحديثة والتي يمكن الاعتماد عليه في اختبار جذر الوحدة (Alhdiy, Johari, Daud, & Rahman, 2015). يتضح من خلال نتائج اختبار جذر الوحدة المطور (ADF) لسلسلة لوغاريتمات سعر الصرف المبينة في الجدول اسفله انه لا يمكن رفض فرض العدم القائل بوجود جذر الوحدة في السلسلة الاصلية، وذلك عند مستوى دلالة 1%، 5% و 10%، في حين يقبل الفرض البديل عند اخذ الفروق الأولى لهذه السلسلة، مما يعني أنها متكاملة من الدرجة الأولى I(1).

الجدول 2: نتائج اختبار الاستقرارية

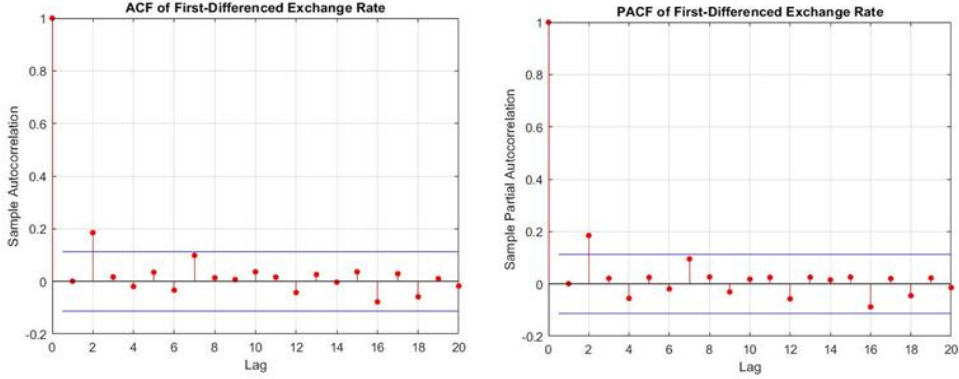
القرار	القيم الحرجة	P-Value	T-stat
I (1)	-1.942	0.995	2.342
	-1.942	0.001	-16.485

المصدر: من اعداد الباحث اعتمادا على مخرجات برنامج matlab2019b

بعد ان تم ايجاد درجة تكامل سلسلة سعر الصرف ناتي الان الى تحديد نموذج ARIMA الامثل للتنبؤ بسعر الصرف، ولتحديد ذلك النموذج تم الاستعانة بدالتي الارتباط الذاتي ACF و الارتباط الذاتي الجزئي PACF الموضحة في الشكل اسفله ومعايير AIC و BIC، وحسب هذا الشكل تم ترجيح 3 نماذج وهي ARIMA(0,1,2)، ARIMA(2,1,0)، و ARIMA(2,1,2)، وبالاعتماد

على المعايير AIC و BIC المبينة في الجدول اسفله تم اختيار النموذج ذو اقل قيمة لتلك المعايير وهو النموذج $ARIMA(0,1,2)$ للتنبؤ بسعر الصرف.

الشكل 4 : دالتي الارتباط الذاتي والارتباط الذاتي الجزئي



المصدر: مخرجات برنامج matlab2019b

الجدول 3: نتائج معايير AIC و BIC

	AIC	BIC
ARIMA(2,1,2)	-1486.1	-1471.6
ARIMA(2,1,0)	-1487.7	-1476.8
ARIMA(0,1,2)	-1488.1	-1477.2

المصدر: من اعداد الباحث اعتمادا على مخرجات برنامج matlab2019b

2.2.3. تقدير نموذج $ARIMA(0,1,2)$

يتضمن الجدول 4 اسفله نتائج تقدير النموذج $ARIMA(0,1,2)$ باستخدام طريقة المعقولة العظمى. من خلال هذه النتائج يتبين ان قيمة t ستودنت المحسوبة للمعلمة المتوسطة المتحركة المقدرة جاءت اكبر من القيمة الجدولية (1.96) ، مما يعني رفض فرض العدم القائل بعدم اختلاف تلك المعلمة عن الصفر.

الجدول 4: نتائج اختبار معلمات النموذج


	المعلمة	الخطا المعياري	قيمة t	الاحتمالية
C	0.0023	0.0012	1.8965	0.0579
MA(2)	0.1948	0.0576	3.3799	0.0000
AIC=-1488.1 BIC=-1477.2				

المصدر: من اعداد الباحث اعتمادا على مخرجات برنامج matlab2019b

3.2.3. تشخيص النموذج:

يضم اختبار صلاحية النموذج مجموعة من الفحوص والإختبارات التشخيصية أهمها رسم البواقي وفحص دالة الارتباط الذاتي واختبار بوكس وييرس المعدل . يعرض الشكل 5 اسفله رسم البواقي والذي يقدم مؤشر اولي على خالوها من جميع الأنماط والتحركات المنتظمة، فالبيانات تتذبذب بشكل عشوائي حول الصفر. ويؤكد رسم دالة الارتباط الذاتي للبواقي والمعروض في الشكل نفسه هذه المعلومة إلى حد كبير، حيث تقع جميع معاملات الارتباط الذاتي للبواقي داخل مجال الثقة ، أي أن شكل دالة الارتباط الذاتي للبواقي خالية من التواءات وهذا مؤشر جيد آخر على أن الأخطاء عبارة عن تشويش ابيض.

الشكل 5: البواقي ودالة الارتباط الذاتي لها



المصدر: مخرجات برنامج matlab2019b

الجدول اسفله يوضح نتائج اختبار $ljung-Box$ واختبار $ARCH-LM$ لاختبار معنوية معاملات الارتباط الذاتي لسلسلة البواقي. من خلال هذه النتائج يتضح انه لا يمكن رفض فرض العدم القائل بعدم معنوية معاملات الارتباط الذاتي للبواقي ، ذلك ان قيمة الاحتماليه المرافقة لاحصائية $ljung-Box$ لمعاملات الارتباط للبواقي اخذت القيمة 0.9922 وهي اكبر من 0.05. وعليه يمكن القول ان البواقي عبارة عن تشويش ابيض.

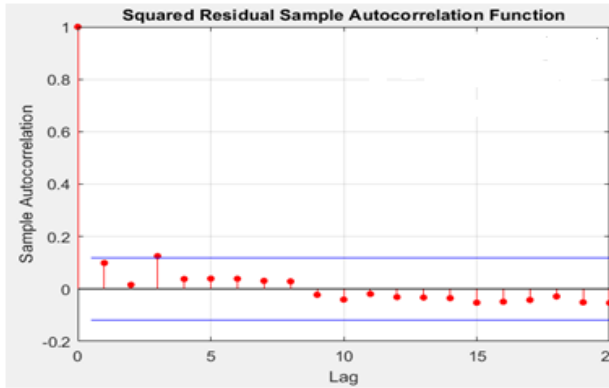
الجدول 5: نتائج اختبار $ARCH-LM$ و $ljung-Box$ لسلسلة بواقي النموذج

الاختبار	قيمة الاحصائية	الاحتمال المرافق
$ljung-Box$ للبواقي	7.8467	0.9928
$ARCH-LM$	2.7077	0.0999

المصدر: من اعداد الباحث اعتمادا على مخرجات برنامج matlab2019b

ويتضح ايضا من خلال النتائج المبينة في الجدول اعلاه ان قيمة مضاعف لاغرنج (2.7077) جاءت اقل من قيمة كاي-مربع عند درجة حرية 1 ومستوى معنوية 0.05(3.8415) ، وعليه يتم قبول فرض العدم القائل بغياب اثر ARCH في سلسلة البواقي. ويؤكد الشكل 6:اسفله لدالة الارتباط الذاتي لمربعات البواقي تقدير النموذج تلك النتيجة حيث تقع جميع معاملات الارتباط الذاتي لمربعات البواقي داخل مجال الثقة.

الشكل 6:دالة الارتباط الذاتي لمربعات البواقي



المصدر: مخرجات برنامج matlab2019b

3.3. نموذج NAR-ANN الامثل للتنبؤ بسعر الصرف:

1.3.3. تحديد بنية النموذج:

استخدمت هذه الدراسة نموذج الانحدار الذاتي غير الخطي للشبكات العصبية NAR-ANN وهو النموذج الأبسط والأكثر استخدامًا في التنبؤ بالسلاسل الزمنية، حيث يتيح هذا النموذج التنبؤ بالقيم المستقبلية لسلسلة زمنية انطلاقًا من ماضيها، عن طريق آلية إعادة التغذية. وعلى الرغم من وجود العديد من الطرق المختلفة لإيجاد البنية المثلى للشبكات العصبية الاصطناعية، إلا أن هذه الطرق عادةً ما تكون معقدة للغاية ويصعب تطبيقها (Zhang, Patuwo, & Hu, 1998). إضافة إلى ذلك، فإن أي من تلك الطرق لا تضمن الحل الأمثل لجميع مسائل التنبؤ. ويبقى الإجراء المعتاد هو اختبار شبكات متعددة بأعداد متفاوتة من وحدات الإدخال والوحدات المخفية، وتقدير الاداء لكل منها ومقارنتها، ومن ثم اختيار الشبكة ذات الاداء الجيد (Hosseini, Luo, & Reynolds, 2006).

و بناءا على ماسبق وبعد تجريب العديد من الشبكات ومقارنة ادائها، استقر اختيار بنية الشبكة على ثلاث طبقات (الشكل 7 أسفله): طبقة الإدخال مكونة من ثلاثة وحدات او عقد ، طبقة الإخراج مكونة من وحدة او عقدة واحدة وطبقة وسيطة (مخفية) مكونة من 12 عقدة. تعطى صيغة النموذج المستعمل في دراستنا على النحو التالي:


$$lmer_t = w_0 + \sum_{j=1}^q w_j f \left(w_{0j} + \sum_{i=1}^p w_{ij} lmer_{t-i} \right) + \varepsilon_t$$

حيث:

W تمثل بمرتمرات النموذج وتسمى بأوزان الوصلات،

p : عدد عقد الادخال، q : عدد العقد المخفية، f : دالة التفعيل، $lmer_{t-i}$: التضخم مبطأ.

الشكل 7: بنية الشبكة المختارة




المصدر: مخرجات برنامج matlab2019b

2.3.3. اختبار اداء وصلاحية النموذج:

من اجل اختبار اداء وصلاحية نموذج الشبكة (NAR-ANN(3,12,1) المختار سابقا تم تدريبه باستخدام خوارزمية Levenberg-Marquardt ، كما وتم استخدام دالتي التنشيط ظل التمام الزائدي tanh في الطبقة المخفية ودالة التنشيط الخطية Lf في طبقة الإخراج ، و متوسط مربع الخطأ كدالة تكلفة للشبكة. الشكل رقم 8 أسفله يُوضِّح أداء الشبكة العصبية، من خلال هذا الشكل يلاحظ أن أفضل أداء يسجل عند التكرار 20 ويساوي 0.00016.

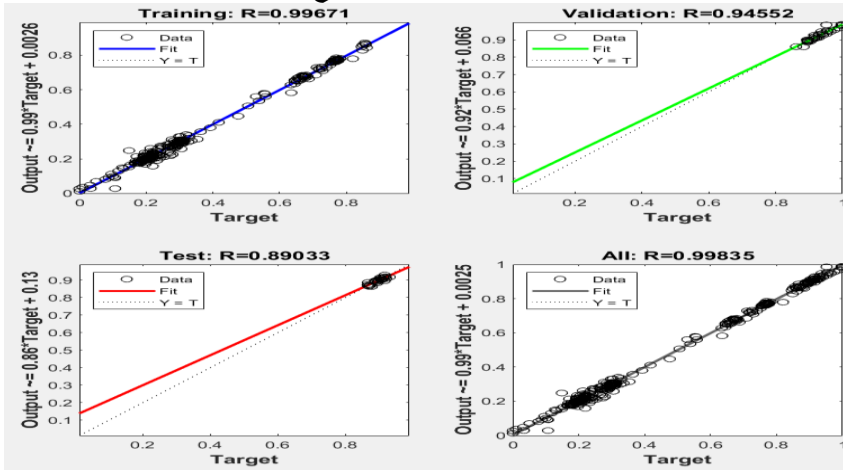
الشكل 8: دالة اداء الشبكة



المصدر: مخرجات برنامج matlab2019b


وللتحقق من دقة الشبكة المستعملة وصلاحيتها، تم الحصول على معاملات الارتباط لعينات التدريب وعينات الاختبار والبيانات ككل، بالإضافة إلى دالة الارتباط الذاتي للخطأ كما هو موضح في الشكلين 9 و 10 أسفله. من خلال النتائج المبينة في الشكل 9 فان معاملات الارتباط r بلغت 0.9967، 0.8903، 0.9983 لعينات التدريب، الاختبار والبيانات ككل على التوالي، وكلما اقترب هذه المعاملات من 1 كانت الملائمة أفضل. ومن خلال شكل دالة الارتباط الذاتي لبواقي النموذج المبينة في الشكل 10 يتضح أنه على الرغم من تذبذب معاملات الارتباط الذاتي لأخطاء النموذج، إلا أنها بقيت ضمن نطاق الثقة، وهاتين النتيجةين تعتبر مؤشر كافي على أن النموذج المقترح مناسب للتنبؤ بالسلسلة الزمنية لسعر الصرف.

الشكل 9: معاملات الارتباط لمجاميع الشبكة



المصدر: مخرجات برنامج matlab2019b

الشكل 10: دالة الارتباط الذاتي للبواقي



المصدر: مخرجات برنامج matlab2019b

4.3. مقارنة اداء النموذجين:

لغرض مقارنة الاداء التنبؤي للنماذج المقدره سابقا تم استعمال ثلاث معايير من معايير دقة التنبؤ وهي: جذر متوسط مربعات الأخطاء (RMSE)، متوسط الخطأ المطلق (MAE) و متوسط النسبة المئوية للخطأ المطلق (MAPE)، والتي تحسب قيمها من العلاقات التالية:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100$$

حيث: y_i : القيم الفعلية، \hat{y}_i : القيم المقدره و N : حجم عينة الخطأ.

و بناءً على قيم معايير دقة التنبؤ السابقة الذكر لمجموعة الاختبار الموضحة في الجدول 6 اسفله يتضح تفوق الاداء التنبؤي لنموذج الشبكة العصبية الاصطناعية (NAR-ANN(3,12,1) مقارنة بالاداء التنبؤي لنموذج (ARIMA(0,1,2)، حيث سجل نموذج (NAR-ANN(3,12,1) اقل قيم لتلك المعايير مقارنة بنموذج (ARIMA(0,1,2)، لمعيار RMSE، 0.0064، لمعيار MAE و 0.72% لمعيار MAPE. كما ويؤكد رسم القيم الفعلية والقيم المتنبأ بها الموضحة في الشكل اسفله تلك النتائج، حيث يظهر نموذج (ARIMA(0,1,2) نمط خطي للقيم المتنبأ بها، في حين تتوافق القيم المتنبأ بها لنموذج (NAR-ANN(3,12,1) بشكل ممتاز مع اتجاه السلسلة الزمنية، وقد يعود ذلك الى عملية التدريب والتعلم التي مكنت النموذج من فهم خصائص سلسلة سعر الصرف بشكل أفضل. وعليه يمكن القول ان نموذج (NAR-ANN(3,12,1) سيكون النموذج الافضل مقارنة بنموذج (ARIMA(0,1,2) للتنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الأمريكي.


الجدول 6: نتائج معايير دقة التنبؤ

	RMSE	MAE	MAPE
ARIMA(0,1,2)	0.0672	0.0574	1.16%
NAR-ANN(3,12,1)	0.0084	0.0064	0.72%

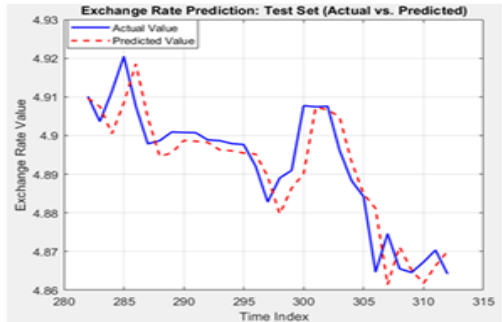
المصدر: من اعداد الباحث اعتمادا على مخرجات برنامج matlab2019b

الشكل 11: القيم الفعلية والمتنبأ بها لمجموعة الاختبار

ARIMA(0,1,2)



NAR-ANN(3,12,1)



المصدر: مخرجات برنامج matlab2019b

4. خاتمة:

تم في هذه الورقة البحثية تقديم مفاهيم نظرية حول منهجية بوكس-جينكز و الشبكات العصبية الاصطناعية، بالإضافة الى تقدير نموذج الانحدار الذاتي و المتوسطات المتحركة المتكاملة ARIMA ونموذج الانحدار الذاتي غير الخطي لنماذج الشبكات العصبية NAR-ANN، ومقارنة ادائهما في التنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الامريكي، و توصل البحث الى جملة من النتائج :
 - باستخدام منهجية بوكس-جينكز تم الحصول على نموذج الانحدار الذاتي و المتوسطات المتحركة المتكاملة الامثل ARIMA(0,1,2) للتنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الامريكي.
 - بعد تجريب العديد من نماذج الانحدار الذاتي غير الخطي لنماذج الشبكات العصبية NAR-ANN ومقارنة ادائها تم الحصول على نموذج الانحدار الذاتي غير الخطي لنماذج الشبكات العصبية الامثل NAR-ANN(3,12,1) للتنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الامريكي.
 - ابرزت مقاييس دقة التنبؤ تفوق نموذج NAR-ANN(3,12,1)، الذي سجل مستويات خطأ أقل من نموذج ARIMA(0,1,2)، وهذه النتيجة تتوافق تماما مع نتائج الدراسات السابقة المذكورة

سابقاً، كما و تعزز بدورها صحة الفرضيات البحثية بشأن دقة التنبؤ الأعلى لنموذج الانحدار الذاتي غير الخطي للشبكات العصبية NAR-ANN وتفوقه على نموذج ARIMA الخطي في التنبؤ بسعر الصرف الدينار الجزائري. ومع ذلك، لا ينبغي اعتبار تفوق نموذج NAR-ANN قاعدة عامة؛ بل هو مرتبط ارتباطاً وثيقاً بالخصائص الهيكلية لبيانات السلسلة الزمنية قيد الدراسة.

وبناء على ماسبق نقدم بعض المقترحات والتي لها صلة بموضوع البحث:

- ان يطبق نموذج الشبكات العصبية الاصطناعية المذكور أعلاه من قبل صناع القرار في البنك المركزي الجزائري على البيانات الجديدة لسعر الصرف الدينار فور توفرها، بهدف التنبؤ بقيمها مستقبلاً.

- أن تشمل الأبحاث المستقبلية مقارنة أداء نماذج الشبكات العصبية الاصطناعية بالنماذج الخطية التقليدية مثل نموذج التمهيد الاسي في التنبؤ بسعر الصرف الدينار الجزائري.

- ان تعدل المتغيرات التنبؤية في الدراسات المستقبلية المقارنة، فعوضاً عن استعمال فترات التأخير لسعر الصرف كمتغيرات تنبؤية تستعمل متغيرات النموذج النقدي كالعرض النقدي، سعر الفائدة والدخل الحقيقي.

-ان تستعمل النماذج التنبؤية الهجينة مثل ARIMA-ANN، ARIMA-LSTM، في الدراسات المستقبلية المقارنة.

5. قائمة المراجع:

- Kamouh, M. M. (2024). Forecasting Exchange Rates Using Artificial Neural Networks: An Applied Study on the Arab Republic of Egypt. Arab Journal of Administration, Vol. 46, No. 6, PP 12-13.
- Alhdiy, F. M., Johari, F., Daud, S. N., & Rahman, A. A. (2015). Short and Long Term Relationship between Economic Growth and Unemployment in Egypt: An Empirical Analysis. Mediterranean Journal of Social Sciences, Vol. 6, No. 4, P457.
- Asteriou, D., & G. Hall, S. (2016). Applied Econometrics. London: saffron house.
- BENLARIA, A., & BOUBEKEUR, L. (2021). Forecasting Exchange Rates Using Artificial Neural Networks. Al Bashaer Economic Journal, Vol. 2, No. 02, P807.

- Cagatay Bal و ،Serdar Demir .(2017) .Forecasting TRY/USD Exchange Rate with Various Artificial Neural Network Models .TEM Journal, Vol. 6, No. 01,PP11-12.
- Chakraverty, S., & Jeswal, K. S. (2021). Applied Artificial Neural Network Methods for Engineers and Scientists. India: World Scientific.
- Hosseini, H. G., Luo, D., & Reynolds, K. J. (2006). The comparison of different feed forward neural network architectures for ECG signal diagnosis. Medical Engineering & Physics, Vol. 28, No. 4, P373.
- Nanayakkara, K., Chandrasekar, N., & Jayasundara, D. (2014). Forecasting Exchange Rates using Time Series and Neural Network Approaches. European International Journal of Science and Technology, Vol. 3, No. 02, P68.
- Rathod, S., Singh, K., Arya , P., Ray, M., Mukherjee, A., Sinha, K., et al. (2017). Forecasting maize yield using ARIMA-Genetic Algorithm approach. Outlook on Agriculture , Vol. 46, No. 4, P266.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting, Vol. 14, No. 1, P42.