International Multilingual Journal of Science and Technology (IMJST)
ISSN: 2528-9810
Vol. 5 Issue 9, September - 2020

استخدام النموذج الهجين ARIMA-ANN للتنبؤ بسعر الصرف

حسن قهوي[2]
كلية الاقتصاد
المركز الجامعي مغنية (الجزائر)
hacenkahwi@gmail.com

عبد القادر ساهد[1]
كلية الاقتصاد
المركز الجامعي مغنية (الجزائر)
sahed14@yahoo.fr

الملخص Abstract:

تهدف هذه الدراسة إلى اختبار قدرة وكفاءة نماذج التهجين ARIMA و ANNفي التنبؤ بسعر الصرف الدولار الامريكي مقابل الدينار الجزائري. تقترح هذه الدراسة ثلاث نماذج ARIMA و MLP والتهجين-ARIMA ANN، حيث تم استخدام النموذج ARIMA(1,1,1) في تقدير المركبة الخطية، وبعد ذلك تم استخلاص سلسلة البواقي عن طريق الفرق بين السلسة الاصلية والسلسلة المقدرة، ليتم بعد ذلك استخدام نموذج ANN لتقدير المركبة غير الخطية، وقد تم الجمع بين تقديرين لنحصل في الاخير على النموذج الهجين، وذلك للقيام بعملية التنبؤ.

وبعد المقارنة بين النماذج الثلاث، تم التوصل على أن النموذج الهجين ARIMA-ANN كان أفضل وأدق في التنبؤ بسعر الصرف الدولار الامريكي مقابل الدينار الجزائري من نموذج MLP ونموذج ARIMA والتي تعمل بشكل منفرد.

الكلمات المفتاحية : التنبؤ ؛ سعر الصرف ؛ التهجين ؛ ANN ؛ ARIMA.

المقدمـــــــة Introduction :

يلعب سعر الصرف دورا جوهري في الاقتصاديات كافة سواء كانت متقدمة أو نامية، بحيث يساهم سعر الصرف في توجيه سياسات البلد الاقتصادية النقدية منها والمالية وتحديد قدرة الاقتصاد التنافسية.

يعرف سعر الصرف على أنه عدد الوحدات التي تدفع من عملة بلد ما مقابل الحصول على وحدات من عملات البلدان الاخرى. وبالتالي يتضح أن سعر صرف هو محصلة تفاعل قوى العرض والطلب على العملة الاجنبية وعلى ذلك فإن تحليل مصادر الطلب والعرض للعملات الاجنبية يعتبر احد الوسائل لمعرفة تأثيرها على العملة الوطنية، ويعكس مصادر العرض والطلب على العملة الاجنبية بنود ميزان المدفوعات باعتباره ملخص جيد لمجتمع المعاملات والصفقات بين الاقتصاد الوطني والعالم الخارجي.

تعتبر الجزائر من الاقتصاديات المفتوحة الصغيرة والتي تساهم وتشارك في النشاط التجارة الدولية، فإن سعر الصرف متغير مهم ويؤثر على قرارات الافراد والمؤسسات والحكومة. زد على ذلك أن سعر الصرف يؤثر على النمو الاقتصادي والتضخم وميزان المدفوعات. وبالتالي فعلى الحكومة الجزائر إذا كانت تريد إن تبني اقتصاداً متيناً، يجب أن يكون سعر الصرف مرتفعاً هو الأفضل لان ذلك سيؤدي إلى انخفاض استيراد مستلزمات التنمية الاقتصادية اللازم توفرها لبناء اقتصاد متين. وبالمقابل إذا كانت قد بلغت تجاوز تحقيق التنمية الاقتصادية وتسعى للدخول الى الاقتصاد لعالمي فلا بد أن تسعى إلى تخفيض سعر الصرف حتى تكون أسعار منتجاته أرخص نسبياً مقارنة بالسلع الأجنبية بحكم انخفاض أسعار صرف عملته [1].

ومن جهة أخرى، فإن النظام الذي يسير عليه بنك الجزائر هو سعر الصرف المعوم اداريا منذ عام 1996، لكن هذا التعويم غير حر، أي لا يعتمد على آلية السوق في العرض والطلب على الدينار الجزائري، بل هو تعويم مسير من قبل بنك الجزائر. كما يعتمد بنك الجزائر نظام سعر صرف حقيقي فعلي، وهو يتضمن مستوى الاسعار العام في البلدان التي تتعامل مع الجزائر [2].

وبالتالي يحتاج التخطيط لوضع سياسة مالية وسياسة نقدية الى التنبؤ بسعر الصرف في وقت مبكر يمكن من تعويم سعر الصرف اداريا أو تركه حرا أو تثبيته.

شهدت في الآونة الاخيرة اهتمام كبير من قبل مجموعة من الباحثين بتقنيات جديدة في التقدير والتنبؤ، حيث تكمن مشكلة الدراسة في غياب الاساليب الدقيقة المستخدمة للتنبؤ بالسير العشوائي الخطي وغير الخطي لسعر الصرف. لذلك تم تطبيق نماذج السلاسل الزمنية على نطاق واسع في حل مشكلة دقة التنبؤ. إذ أن هناك العديد من نماذج التنبؤ التي اقترحها الباحثون لحل المشاكل في مجالات مختلفة، منها مشاكل التنبؤ بسعر الصرف، حيث تم تطبيق نماذج ARIMA في التنبؤ بسعر الصرف، كما تم تطبيق نماذج الشبكات العصبية بنجاح للتنبؤ بسعر الصرف، إلا أن تطبيق هذه النماذج لم تكن الادق، حيث قام الباحثون آخرون بتحسين العديد من الطرق لزيادة الدقة التنبؤ، وهذا باستخدام نموذج هجين بين السير العشوائي الخطي والسير العشوائي غير خطي، على رأسهم الباحث Zhang الذي قام بتطبيق نماذج هجينة من خلال الجمع بين نماذج ARIMA والشبكات العصبية ANN والتي أظهرت نتائج أدقة أفضل. في هذه الدراسة، نقترح نموذج مختلط يجمع نموذج ARIMA ونموذج الشبكات العصبية للتنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الامريكي.

الدراسات السابقة :

دارسة Babu AS, Reddy SK (2015) والموسومة بـ Exchange Rate Forecasting using ARIMA Neural Network and Fuzzy Neuron تتناول هذه دارسة سلوك أسعار الصرف اليومية للروبية الهندية (INR) مقابل الدولار الأمريكي (USD) والجنيه الإسترليني (GBP) واليورو (EUR) والين الياباني (JPY) ، وتحاول هذه الورقة دراسة أداء ARIMA والشبكة العصبية والنماذج العصبية الضبابية في التنبؤ بالعملات المتداولة في أسواق الصرف الأجنبي الهندية. واستخدمت أسعار الصرف اليومية في الفترة من يناير 2010 إلى أبريل 2015 ، حيث توصلت نتيجة البحث أن نماذج الشبكات العصبية الضبابية كانت هي الافضل في التنبؤ بسعر الصرف [3] .

دراسة Tran Mong Uyen Ngan (2016) والموسومة بـ Forecasting Foreign Exchange Rate by using ARIMA Model: A Case of VND/USD Exchange Rate، حيث تم استخدام البيانات الشهرية المتعلقة بسعر الصرف الحقيقي من عام 2013 إلى عام 2015 ، وتقدم هذه الدراسة نموذج أريما في أربع خطوات للتنبؤ بسعر الصرف VND مقابل USD للأشهر الاثني عشر المقبلة من عام 2016، وبمقارنة النتائج المتحصل عليها ببيانات سعر الصرف الحقيقي، تبين أن نموذج ARIMA مناسب لتقدير سعر الصرف في فيتنام على مدى فترة قصيرة [4].

دارسة Asma' Mustafa, Maizah Hura Ahmad and Norazlina Ismail (2017) والموسومة بـ Modeling and Forecasting US Dollar/ Malaysian Ringgit Exchange Rate، حيث تم استخدم نماذج السلاسل الزمنية من بينها نماذج الهجينة ARIMA-GARCH و ARIMA-EGARCH للتنبؤ بالبيانات اليومية عن سعر صرف الدولار الأمريكي مقابل الرينجيت الماليزي (USD/MYR). ولمقارنة أداء التنبؤ لهذه النماذج تم استخدام معيار معلومات akaike (AIC) ومتوسط الخطأ التربيعي (RMSE). وقد اسفرت النتائج على أفضل نماذج ARIMA-EGARCH في دقة التنبؤ بسعر الصرف والذي يمكن أن تساعد في تقييم التدفقات النقدية المقومة بالعملات الأجنبية التي تنطوي عليها المعاملات الدولية [5].

دارسة Santosh Kumar Nanda, Rahul Vyas, H K Vamshidhar والموسومة بـ Forecasting Foreign Exchange Rate Using Robust Laguerre Neural Network، حيث تم استخدام شبكة عصبية الحصينة للتنبؤ بسعر الصرف. وقد بينت دراسات عديدة أن سلسلة أسعار الصرف تتقلب دائما وفقا للنمو الاقتصادي وأسعار الفائدة، وبالتالي من الصعب جدا على الباحثين التنبؤ بأسعار الصرف. حيث تم المقارنة بين نوعين من النماذج، ARIMA و FLAMA في التنبؤ بسعر الصرف، وقد أسفرت النتائج على دقة وجودة

نماذج FLAMA في التنبؤ بسعر الصرف وهذا بالاعتماد على معيار متوسط الخطأ التربيعي [6].

دراسة Abraham Deka, Nil Gunsel Resatoglu (2019) والموسومة بـ Forecasting Foreign Exchange Rate and Consumer Price Index with Arima، حيث تناولت هذه الدراسة استخدام نماذج (ARIMA) في التنبؤ بسعر الصرف والتضخم في تركيا، وقد خلصت هذه الدراسة إلى أن ARIMA (3,1.3) هو أفضل نموذج للتنبؤ بسعر الصرف في تركيا وأن نموذج ARIMA (1.1.4) هو أفضل في التنبؤ بالتضخم في تركيا. وهذا بالاعتماد على مقاييس اداء التنبؤ مثل MAE، MAPE، نسبة التحيز، RMSE وTheil في عملية اختيار أفضل نموذج [7].

دراسة Markova, M. (2019) والموسومة بـ Foreign Exchange Rate Forecasting by Artificial Neural Networks، تناولت هذه الورقة القدرة على التنبؤ بسعر الصرف لليورو مقابل الدولار الأمريكي وهذا باستخدام الانحدار الذاتي غير الخطي مع الشبكات العصبية للمدخلات الخارجية. وبعد تدريب الشبكات وإجراء التنبؤات خارج العينة ، تُظهر الشبكات ANN أنها طريقة فعالة في التنبؤ بأسعار الصرف. وقد تم اقتراح في هذه الورقة نموذجين، حيث يتم إنشاء شبكات NARX متعددة وبنى مختلفة وتقييمها للعثور على أفضل هيكل للشبكة. وقد وجدت الشبكة التي تحتوي على 4 عصبونات إدخال و15 عصبون من طبقة مخفية وخلية عصبية ناتجة وتأخر زمني 3، ومستخدمين خوارزمية Levenberg-Marquardt على أنها أفضل أداء للتنبؤ ببيانات أسعار الصرف والذي يقدر بـ 1.9771E-5 وقيمة R للانحدار هي 0.99617 لجميع البيانات مما يعني وجود علاقة وثيقة بين المخرجات والأهداف [8].

دراسة Kaushik, M., & Giri, A. K. (2020) والموسومة بـ Forecasting Foreign Exchange Rate: A Multivariate Comparative Analysis between Traditional Econometric, Contemporary Machine Learning & Deep Learning Techniques، تحاول هذه الورقة التوصل إلى تطبيق نهج سلسلة زمنية متعددة المتغيرات للتنبؤ بسعر الصرف (USD / INR) وهذا من خلال المقانة بين أداء ثلاث تقنيات لنمذجة التنبؤ متعدد المتغيرات: شعاع الانحدار الذاتي (تقنية الاقتصاد القياسي التقليدية) ، آلة ناقلات الدعم (تقنية التعلم الآلي المعاصر) والشبكات العصبية المتكررة (تقنية التعلم العميق المعاصر). لقد تم استخدم البيانات التاريخية الشهرية للعديد من متغيرات الاقتصاد الكلي من أبريل 1994 إلى ديسمبر 2018 للولايات المتحدة الأمريكية والهند، من أجل التنبؤ بسعر صرف العملات الأجنبية للدولار الأمريكي مقابل الروبية الهندية. تشير النتائج بوضوح إلى أن التقنيات المعاصرة لـ SVM و RNN (الذاكرة الطويلة وقصيرة المدى) تفوقت على الأداء الطريقة شعاع الانحدار الذاتي. وتوفر نموذج RNN مع LSTM أقصى دقة (97.83٪) يليه نموذج SVM (97.17%) ونموذج VAR (96.31%) [9].

الطرق والأدوات :

1- نموذج ARIMA :

تم نشر هذا النموذج لأول مرة من طرف Box and Jenkins في عام 1970، ويمكن تعريف نماذج ARIMA على أنها مزيج من جزء من نماذج الانحدار الذاتي الذي ترتبط فيه قيم بيانات السلاسل الزمنية الماضية بالقيم المستقبلية، وجزء يسمى بالفروق ويشير إلى تحول غير مستقر لسلسلة البيانات زمنية إلى سلسلة مستقرة، وجزء يعبر عن المتوسط المتحرك والذي ترتبط أخطاء قيمة البيانات السابقة بأخطاء قيمة البيانات المستقبلية [10]. يعطى نموذج ARIMA بالمعادلة (1):

$$y_t = c + \sum_{i=1}^{p} \varphi_t y_{t-i} - \sum_{i=1}^{q} \theta_i \varepsilon_{t-i} + \varepsilon_t \qquad (1)$$

وتقوم نماذج ARIMA على ثلاث مراحل: التعرف والتقدير والفحص التشخيصي، ففي مرحلة التعريف يجب التأكد من أن البيانات مستقرة (لا توجد جذور الوحدة)، وهذا بالاعتماد على دالة الارتباط الذاتي واختبار ديكي فولار الموسع واختبار kpss، إذ تؤدي البيانات غير مستقرة إلى الزيادة في خطأ التنبؤ [11]. وبعد ذلك يتم تحديد معلمات ARIMA (p,d,q) باستخدام الرسم البياني لدالة معامل الارتباط الذاتي (ACF) والرسم البياني لدالة معامل الارتباط الذاتي الجزئي (PACF) ، وهذا يعني أن من خلال الرسم البياني لـ ACF وPACF تحدد قيمة q و p على التوالي [12]، ولتقدير معالم النموذج p و q نتبع إما طريق المربعات الصغرى أو طريقة الامكان الاكبر ومن أجل المفاضلة بين النماذج المقدرة، نعتمد على تذنية معيار Akaike Info Criterion (AIC) ومعيار Schwarz (SCH). ومن أجل التحقق من جودة نموذج ARIMA ، يجب أن تتبع سلسلة البواقي توزيعًا طبيعا، بمتوسط يساوي الصفر وتباين ثابت، أي أنها تشويش أبيض ، وبالتالي نتأكد من أن مركبات السلاسل الزمنية قد تم نمذجتها. ليتم بعد ذلك عملة التنبؤ بالقيم المستقبلية للظاهرة المدروسة [13].

2- طريقة الشبكات العصبية:

يعود استخدام الشبكات العصبية إلى كل من McCulloch and Pitts سنة 1943، حيث تشبه بنية الشبكات العصبية البنية البيولوجية للجهاز العصبي، ويقوم نموذج ANN على نمذجة المركبات غير الخطية. وأن عمل الشبكات العصبية هو نفس مبدأ الدماغ البشري، حيث تجرى العمليات حسابية على مستوى وحدات معالجة بسيطة نسبيًا تسمى الخلايا العصبية، ويتم الاتصال بين الطبقات الشبكة عن طريق ما يسمى بالأوزان لنقل المعلومات، وهناك ثلاثة أنواع مختلفة من الطبقات: طبقة الإدخال، التي توفر رابطًا لمعلومات الإدخال ، وطبقة المخرجات التي تولد المخرجات النهائية، والطبقة المخفية والتي تعمل كطبقة وسيطة بين المدخلات والمخرجات. في نفس السياق، يتم ضرب قيم المدخلات في أوزان مبدئية، حيث يتم دمج النتيجة مع معلمة تسمى التحيز، والتي تعتبر مدخلات لعقد الطبقة المخفية والتي يتم معالجتها عن طريق دالة التنشيط غير الخطي (sigmoid unit) وتتم معالجة الإشارات الناتج في طبقة المخرجات والتي بدورها تقوم بتوليد مخرجات الشبكة . ويعطى نموذج ANN بالمعادلة (2)

$$y_t = w_o + \sum_{j=1}^{H} w_{oj} f\left(w_{oj} + \sum_{i=1}^{N} w_{ij} y_{t-i}\right) + \varepsilon_t \qquad (2)$$

حيث:

W0: مصفوفة الاوزان

H: عدد العقد في طبقة الخفية

N: عدد العقد في طبقة المدخلات

3- النموذج الهجين ARIMA-ANN :

في الواقع، إن المشكلة التي تواجهنا في تحليل السلاسل الزمنية هي أنها تحتوي على نمط خطي ونمط غير خطي، لذا فإن الاعتماد على نماذج ARIMA التي تقوم بمذجة النمط الخطي لا تعطينا نتائج جيدة، لأنها لا تأخذ بعين الاعتبار المركبات غير الخطية في السلسلة الزمنية، وأن الاعتماد على نماذج ANN التي تقوم بمذجة النمط غير الخطي لا تكون نتائجها دقيقة لأننا أهملنا المركبات الخطية في السلسلة الزمنية، وأن الاعتماد على الجديد النهج والمسمى بالتهجين (Hybrid) والذي يجمع بين خصائص نموذج ARIMA الخطي والنموذج غير الخطي ANN وبهذا تكون نمذجة السلاسل الزمنية أقرب إلى الواقع [14].

وقد تم اقتراح النموذج الهجين الذي يجمع بين نماذج الانحدار الذاتي والمتوسطات المتحركة ARIMA ونماذج الشبكة العصبية ANN، من طرق الباحث Zhang سنة (2003) من خلال نشره لمقال بعنوان Time series forecasting using a hybrid ARIMA and neural network model في مجلة Neurocomputing [15].

وأشار Zhang في البداية إلى حقيقة مهمة، وهي أن السلاسل الزمنية في أغلب الاحيان تكون عبارة عن خليط يجمع المركبات الخطية والتي يمكن أن تنمذج باستخدام نماذج ARMA ومركبات غير خطية والتي يمكن أن يتم نمذجتها باستعمال نماذج ANN، ومن خلال المعادلة (3) نبين ذلك.

$$y_t = L_t + N_t \qquad (3)$$

وتتلخص هذه الطريق في الخطوات التالية: أولاً ، يتم عن طريق نموذج ARIMA نمذجة المركبات الخطية والحصول على القيم المتوقعة $\hat{\mathbf{L}}_t$. ولذلك فإن قيم البواقي بعد استخلاص القيم المتوقعة، تعطى بالشكل التالي:

$$e_t = y_t - \hat{L}_t \qquad (4)$$

ثانيا، قد تحتوي البواقي المستخرجة من نموذج ARIMA على مركبات غير خطية، والتي نقوم بنمذجتها باستخدام نموذج ANN ، حيث يحتوي هذا الاخير على p من المدخلات. والتي تأخذ المعادلة التالية:

$$e_t = f(e_{t-1}, e_{t-2}, e_{t-3}, e_{t-4}, \ldots\ldots, e_{t-p}, \varepsilon_t) \qquad (5)$$

حيث :

$\boldsymbol{\varepsilon_t}$: تمثل تشويش أبيض

ثالثا، في الاخير، فإن التنبؤات الهجينة النهائية في اللحظة t، تكون مبينة في المعادلة رقم (6):

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \qquad (6)$$

$\hat{\mathbf{y}}_\mathbf{t}$: التنبؤات النهائية

$\hat{\mathbf{L}}_\mathbf{t}$: تنبؤات ARIMA للمركبة الخطية

$\hat{\mathbf{N}}_\mathbf{t}$: تنبؤات ANN للمركبة غير الخطية

4- معايير التقييم :

من أجل تشخيص أداء وفعالية الطريقة المقترحة (التهجين)، يجب مقارنتها مع طرق التنبؤ الاخرى، مثل منهجية بوكس جينكز وطرق الشبكات العصبية. حيث يوجد العديد من مقاييس الخطأ التي تُستخدم غالبًا لقياس أداء التنبؤ، من أهمها متوسط مربع الاخطاء (MSE) وجذر متوسط مربع الخطأ (RMSE)، والتي تعرف على النحو التالي :

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(X_t - \hat{X}_t)^2 \qquad (7)$$

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(X_t - \hat{X}_t)^2} \qquad (8)$$

حيث، N تمثل حجم العينة، $\hat{\mathbf{X}}_\mathbf{t}$ تمثل القيم المتنبأ بها، و $\mathbf{X}_\mathbf{t}$ تمثل القيم الفعلية، فكلما كانت الاخطاء أقل كان النموذج أفضل وأدق في عملية التنبؤ.

النتائج والمناقشة:

لقد تم الحصول على بيانات الشهرية لسعر الصرف الدينار الجزائري مقابل الدولار الامريكي من موقع البنك العالمي، من الفترة الممتدة من جانفي 2000 إلى ديسمبر 2019، حيث تم تقسيم البيانات إلى قسمين، القسم الاول 70% من البيانات لغرض التدريب و30% لغرض الاختبار.

الشكل (1) يبين تطور سعر الصرف من جانفي 2000 إلى ديسمبر 2019، حيث يتضح من خلال هذا الشكل أن سعر الصرف كان مستقر في حدود 60 من سنة 2000 إلى سنة 2008، تم عاد بعد ذلك في حركة تصاعدية مستمر إلى يومنا هذا، مما يدل على أن سلسلة سعر الصرف للدينار مقال الدولار تحتوى على اتجاه عام، وبالتالي فهي غير مستقرة.

الشكل (1) : تطور سعر الصرف خلال فترة الدراسة

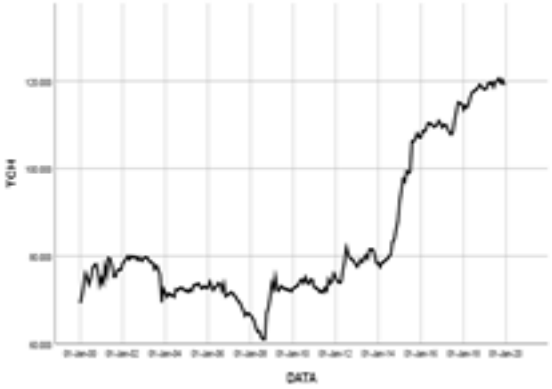

المصدر : من إعداد الباحثين

ولتأكد من عدم استقرارية السلسلة الزمنية، تم رسم دالة الارتباط الذاتي البسيطة لسلسلة سعر الصرف، حيث يبين ذلك الشكل (2)، إذ نلاحظ وجود ارتباط ذاتي في سلسلة سعر الصرف مما يدل على عدم استقرارية السلسلة. ولإرجاع سلسلة سعر الصرف مستقرة، فهذا يعنى التخلص من الاتجاه العام، فقد تم استخدام طريقة الفروق، بعد ذلك تم رسم دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئية لسلسلة سعر الصرف أنظر الشكل (3)، والذي يبين لنا أن السلسلة مستقرة وهي من النوع ARIMA(1,1,1)، حيث تم اختيار هذا النموذج بعد المقارنة بين عدة نماذج على أساس معيار أكايك ومعيار شوارز لتدنية كمية المعلومات.

الشكل (2) : رسم دالة الارتباط الذاتي للسلسلة الاصلية

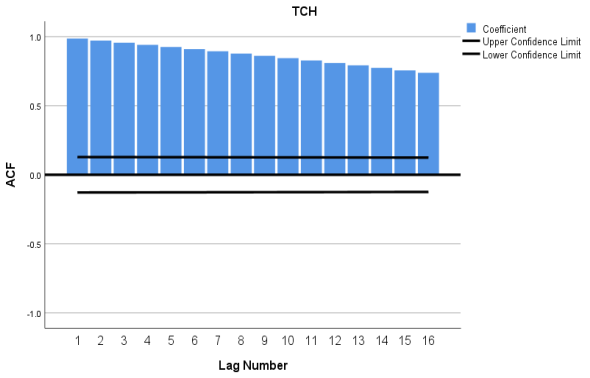

المصدر : من إعداد الباحثين

الشكل (3) : رسم دالة الارتباط الذاتي والجزئي للسلسلة الفروق

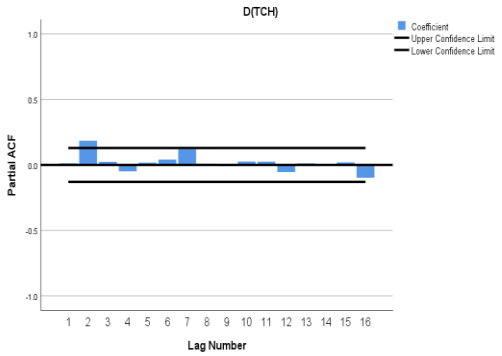

المصدر : من إعداد الباحثين

ولتقدير نموذج ARIMA(1,1,1) فقد تم استخدام طريقة الامكان الاكبر، ويتضح من الجدول (1) ان معلمات النموذج تختلف جوهرا عن

الصفر، حيث أن احتمال معلمات AR و MA أصغر من 5%، وبالتالي فنموذج المقدر يبدو جيد.

الجدول (1) : تقدير النموذج ARIMA(1,1,1)

	تقدير	SE	t	Sig
AR(1)	0.860	0.164	5.257	0.000
MA(1)	0.797	0.195	4.096	0.000

المصدر : من إعداد الباحثين

وبعدما تم تقدير النموذج، يجب اختبار جودة هذه النموذج، وهذا من خلال رسم دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي للبواقي، والشكل (4) يبين أن البواقي تقع ضمن الحدود المسموحة بها. وبالتالي فإن النموذج جيد للتنبؤ.

الشكل (4) : رسم دالة الارتباط الذاتي والجزئي للسلسلة البواقي

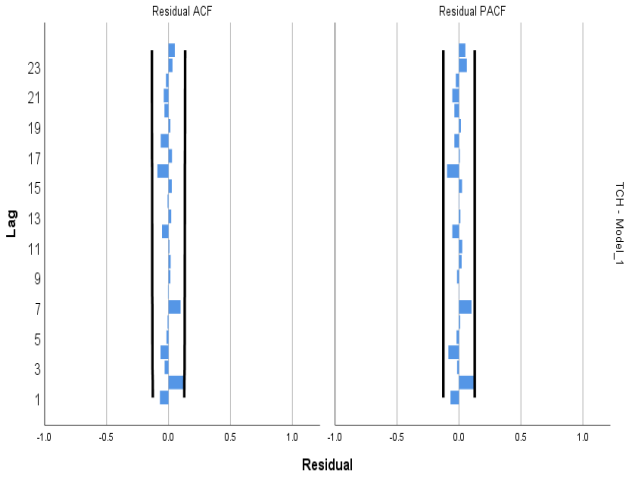

المصدر : من إعداد الباحثين

ومن جهة أخرى، فإن التنبؤ باستخدام طريقة الشبكات العصبية ومن النوع MLP، يجب أولا تحديد عدد العقد في طبقة المدخلات، وتحدد عدد العقد في الطبقة الخفية، ومن خلال التجربة تبين أن النموذج الدقة هو MLP(3,1,1) وممثل في الشكل (5). وبصفة عامة يمكن تلخص هذا النموذج من حيث دالة التنشيط المثلى وهي من النوع Hyperbolic tangent وأن مجموع مربعات الاخطاء في مرحلة التدريب هي 37.277 وفي مرحلة الاختبار هي 11.533.

الشكل (5) : بينة الشبكات العصبية لسلسلة سعر الصرف

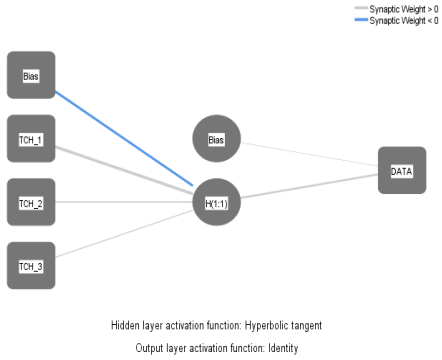

المصدر : من إعداد الباحثين

أما فيما يخص نموذج التهجين، فقد تم نموذج البواقي المستخلصة من نموذج ARIMA(1,1,1) المقدر في المرحلة الاولى، لنقوم بعد ذلك بنمذجة هذه البواقي عن طريق نموذج الشبكات العصبية من النوع MLP والذي يعتمد على ثلاث تباطأت لسلسلة البواقي والموضح في الشكل (6)، أما فيما يخص تقدير معلمات الاوزان لهذا النموذج فهي موضحة في الجدول (2). وبعدما تم تقدير المركبات غير الخطية الموجودة في سلسلة البواقي، تأتي بعدها عملة الجمع بين النمذجة الخطية وغير الخطية للوصول الي التنبؤ النهائي.

الشكل (6) : بينة الشبكات العصبية لسلسلة البواقي

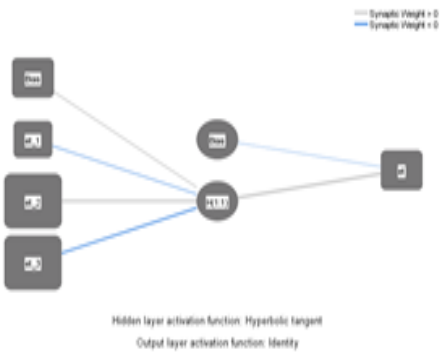

المصدر : من إعداد الباحثين

الجدول (2) : تقدر النموذج MLP

Predictor		Predicted: Hidden Layer 1 H(1:1)	Predicted: Output Layer et
Input Layer	(Bias)	.218	
	et_1	-.208	
	et_2	.526	
	et_3	-.524	
Hidden Layer 1	(Bias)		-.124
	H(1:1)		.904

المصدر : من إعداد الباحثين

ومن جل المقارنة بين نماذج الثلاث فقد تم حساب كل من متوسط مربعات الاخطاء (MSE) وجذر متوسط مربعات الاخطاء (RMSE) لتنبؤات لـ 12 شهرا من سنة 2019، ومن خلال الجدول (3) يتبين لنا جليا أن نموذج التهجين ARIMA-MLP أفضل وأدق من النماذج الأخرى. ولتوضيح أكثر قما برسم تنبؤات النماذج الثلاث ومقارنها مع القيم الفعلية في منحى واحد والمبينة في الشكل (7)، حيث يتضح أن التنبؤات باستخدام النموذج الهجين في الاقرب في محاكاة القيم الفعلية لسعر الصرف الدولار الامريكي مقابل الدينار الجزائري.

الشكل (7) : المقارنة بين تنبؤات النماذج الثلاث

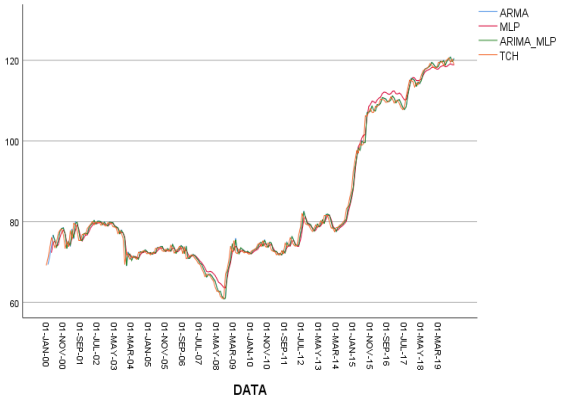

المصدر : من إعداد الباحثين

الجدول (3) : نتائج مقارنة بين النموذج الهجين ARIMA و MLP

TAME	TCH	ARIMA	MLP	ARIMA-MLP
1-Jan-19	118.084	118.461	118.033	118.378
1-Feb-19	118.364	118.265	117.821	118.228
1-Mar-19	119.53	118.556	117.874	118.538
1-Apr-19	119.368	119.787	118.357	119.748
1-May-19	119.775	119.592	118.594	119.609
1-Jun-19	118.653	120.009	118.697	119.893
1-Jul-19	119.736	118.798	118.412	118.824
1-Aug-19	120.121	119.95	118.508	119.806
1-Sep-19	120.615	120.346	118.901	120.42
1-Oct-19	119.545	120.856	119.162	120.771
1-Nov-19	120.255	119.699	118.926	119.699
1-Dec-19	119.082	120.452	118.907	120.316
MSE		**0.66955**	**1.224558**	**0.591876167**
RMSE		**0.81826**	**1.106598**	**0.769334886**

المصدر : من إعداد الباحثين

الخلاصة:

تم اختبار في هذه الورقة البحثية قدرة وكفاءة نماذج التهجين ARIMA و ANNفي التنبؤ بسعر الصرف الدولار الامريكي مقابل الدينار الجزائري.

تقترح هذه الورقة ثلاث نماذج ARIMA و ANN والتهجين ARIMA-ANN، حيث تم استخدام النموذج ARIMA(1,1,1) في تقدير المركبة الخطية، وبعد ذلك تم استخلاص سلسلة البواقي عن طريق الفرق بين السلسة الاصلية والسلسلة المقدرة، ليتم بعد ذلك استخدام نموذج ANN لتقدير المركبة غير الخطية، وقد تم الجمع بين تقديرين لنحصل في الاخير على النموذج الهجين، وهذا من أجل القيام بالتنبؤ النهائي.

وبعد المقارنة بين النماذج الثلاث، تم التوصل على أن النموذج الهجين ARIMA-ANN كان أفضل وأدق في التنبؤ بسعر الصرف الدينار الجزائري مقابل الدولار الامريكي من نموذج ANN ونموذج ARIMA التي تعمل بشكل منفرد.

References المراجع

1- حميد ,ع .ا (2016)، اقتصاديات سعر الصرف وتخفيض وتعويم العملة وحرب العملات، الدار الجامعية-الاسكندرية

2- الموسوي, ضياء مجيد (2016)، تقلبات أسعار الصرف. ضياء مجيد الموسوي، ديوان المطبوعات الجامعية، ص. 113.

3- Babu AS, Reddy SK (2015), Exchange Rate Forecasting using ARIMA, Neural Network and Fuzzy Neuron, J Stock Forex Trad, PP 1-5

4- Tran Mong Uyen Ngan (2016). Forecasting Foreign Exchange Rate by using ARIMA Model: A Case of VND/USD Exchange Rate. Research Journal of Finance and Accounting, 7(12), PP 38-44

5- Asma Mustafa, Maizah Hura Ahmad, Norazlina Ismail (2017). Modeling and Forecasting US Dollar/ Malaysian Ringgit Exchange Rate. Reports on Economics and Finance, 3(1), PP.1 – 13

6- Nanda, S. K., Vyas, R., & Vamshidhar, H. K. (2018, November). Forecasting Foreign Exchange Rate Using Robust Laguerre Neural Network. In 2018 3rd International Conference and Workshops on Recent Advances and Innovations in Engineering (ICRAIE) (pp. 1-5). IEEE.

7- Deka, A., & Resatoglu, N.G. (2019). Forecasting Foreign Exchange Rate And Consumer Price Index With Arima Model: The Case Of Turkey. International Journal of Scientific Research and Management, 7(08)

8- Markova, M. (2019). Foreign exchange rate forecasting by artificial neural networks. In AIP Conference Proceedings (2164, No. 1, p. 060010). AIP Publishing LLC

9- Kaushik, M., & Giri, A. K. (2020). Forecasting Foreign Exchange Rate: A Multivariate Comparative Analysis between Traditional Econometric, Contemporary Machine Learning & Deep Learning Techniques. arXiv preprint arXiv:2002.10247.

10- Din, M.A. (2016). ARIMA by Box Jenkins Methodology for Estimation and Forecasting Models in Higher Education, Athens: ATINER'S Conference Paper Series, No: EMS2015-1846.

11- Bahareh Fanoodi, Behnam Malmir, Farzad Firouzi Jahantigh. (2019) . Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models. Computers in Biology and Medicine. PP 1-10.

12- Qiang Wang, Shuyu Li, Rongrong Li, Minglu Ma. Forecasting U.S. Shale Gas Monthly Production Using a Hybrid ARIMA and Metabolic Nonlinear Grey Model, Energy.energy. 07(047), PP 01-38

13- Mengjiao Qin, Zhihang Li, Zhenhong Du. (2017). Red tide time series forecasting by combining ARIMA and deep belief network. Knowledge-Based Systems.03(027), PP 01-23.

14- Novri Suhermia , Suhartonoa, Dedy Dwi Prastyoa , Baharuddin Alib. (2018). Roll motion prediction using a hybrid deep learning and ARIMA model. Procedia Computer Science Volume 144, PP. 251-258

15- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. Neurocomputing, 50, PP. 159-175.