استخدام الشبكات العصبية ذات الانحدار الذاتي غير الخطية NAR في التنبؤ بمعدل التضخم في الجزائر خلال الفترة 1990 إلى 2021

An Application of Non-Linear Autoregressive Neural Networks to Predict the Inflation Rate in Algeria During the Period 1990 to 2021

د. حسن قهوي *[1] أ.د. عبد القادر ساهد[2] أ.د. محمد مكيديش[3]

1- المركز الجامعي مغنية(الجزائر)، hacenkahwi@gmail.com

2- المركز الجامعي مغنية (الجزائر) ، sahed14@yahoo.fr

3- المركز الجامعي مغنية (الجزائر) ، mkidiche@yahoo.fr

تاريخ الاستلام:2022/11/23 تاريخ القبول:2023/03/20

الملخص:

يشكل التضخم إحدى المشكلات الاقتصادية الرئيسية التي تواجه معظم الاقتصادات سواء كانت دول متقدمة او دول نامية والتي تتطلب من البنوك المركزية وضع أدوات وسياسات لمنع التقلبات العالية في الأسعار وفترات التضخم الطويلة. توضح هذه الورقة التنبؤ بمعدل التضخم في الجزائر من خلال استخدام الشبكات العصبية ذات الانحدار الذاتي الغير الخطية ومقارنتها مع نماذج ARIMA. تم استخدام بيانات السلاسل الزمنية السنوية للفترة 1990 الى 2021 في التحليل، ومن اجل المقارنة بين النموذجين تم الاعتماد على معيار متوسط مربعات الأخطاء (MSE) ومعامل الارتباط R، أظهرت النتائج النهائية أن الشبكة العصبية ذات الانحدار الذاتي الغير الخطية NAR تعطي أداء أفضل ودقيق مقارنة مع نموذج ARIMA.

الكلمات المفتاحية: التضخم، التنبؤ، نماذج ARIMA، الشبكة العصبية NAR.

Abstract:

Inflation is one of the most serious economic problems facing most economies, whether developed or developing countries, which require central banks to implement policies to prevent high price fluctuations and long periods of inflation. This study uses both nonlinear

* المؤلف المرسل: د. حسن قهوي

autoregressive neural network (NARNN) and autoregressive integrated moving average (ARIMA) models to forecast Algeria's inflation rate. The empirical analysis is carried out using annual time series data from 1990 to 2021. The mean squared errors (MSE) and R squared are used to compare the outcomes of the two models. According to the results obtained the NARNN model outperformed the ARIMA model.

Keywords: Inflation, Forecasting ،ARIMA Models, Neural Network NAR.

مقدمة:

يعتبر التضخم من بين أحد اهم المشاكل الاقتصادية التي تواجه معظم الاقتصادات سواء كانت دول متقدمة او دول نامية. فيشار لها على انها ظاهرة نقدية ونعني بها زيادة مستمرة في أسعار السلع (السلع والخدمات)، مما يقلل من القوة الشرائية للعملة خلال فترة معينة. كما يمكن أيضًا التعبير عن التضخم على أنه الحالة التي يفوق فيها الطلب على السلع والخدمات المعروض منها في الاقتصاد على مدى فترة زمنية معينة، يعني الارتفاع المستمر في المستوى العام للأسعار (Abdulrahman، 2018، صفحة 17). مما يتخلف عنه رفع تكلفة المعيشة للعمال ذوي الدخل الثابت لأن التضخم يؤدي إلى تآكل القيمة الحقيقية لأرباحهم ولهدا يحظى باهتمام عالمي لأنه يؤدي إلى انخفاض المدخرات وارتفاع أسعار الفائدة، مما يؤدي إلى زيادة تكاليف الاقتراض وتباطؤ الاستثمار والنمو الاقتصادي، وعندما يكون معدل التضخم المحلي أعلى من معدل التضخم في البلدان الأخرى ، يمكن أن يضغط على عملتها (Silfiani، 2014، صفحة 1)، تشرح سيناريوهات الإشارة هذه سبب كونها قضية حاسمة تثير قلق صانعي السياسات، (Urrutia، 2021، صفحة 5297). مما يتطلب هذا الوضع التنبؤ بمعدلات التضخم المستقبلية. لذلك، فإن التنبؤ الموثوق به لمعدلات التضخم المستقبلية في بلد ما سيحدد السياسات التي

سيطبقها صناع القرار في الاقتصاد (dela Cruz، 2019، صفحة 2). ولذا كانت هناك العديد من الطرق التي استخدامها في عملية التنبؤ ، وتعد النماذج الإحصائية مثل نماذج ARIMA والمعروفة بمنهجية Box and Jenkins، من بين الأساليب الأكثر استخداما لهذا الغرض، ولكن ما يعاب على هذه النماذج انها تفترض ان السلسلة خطية وكما نعلم ان جل السلاسل الزمنية المالية في الوقت الحالي تتميز باللاخطية (Rapoo، 2017، صفحة 2504) ، ومنه تعتبر الأساليب القائمة على تقنيات الذكاء الاصطناعي مثل الشبكة العصبية الاصطناعية والتي تعتبر من بين أكثر الأساليب استخداما لتحسين أداء التنبؤ في سياق غير خطي (Dash R.، 2019، صفحة 44).وتعتبر الشبكات العصبية ذات الانحدار الذاتي الغير الخطية(NARNN) نوع من هذه الشبكات، حيث تم اختيار ها للتنبؤ بالتداخل نظرا لدقتها العالية في التنبؤ .و تتمثل إحدى الفوائد الرئيسية لشبكات NARNN في أنها تقبل المدخلات الديناميكية التي تمثلها مجموعات السلاسل الزمنية حيث تُستخدم القيم السابقة للتنبؤ بالقيم المستقبلية في مجموعة السلاسل الزمنية (Padilla، 2021، صفحة 184).حيث أظهر العديد من الباحثين انها تعطي تنبؤية جيدة باستخدم NARNN للتنبؤ بسرعة الرياح (Sarkar، 2019)،التنبؤ بتوليد الطاقة الكهربائية (KEREM، 2021).

ففي هذه الدراسة تم اقتراح التنبؤ بمعدل التضخم في الجزائر باستخدام الشبكة العصبية الاصطناعية والتي تعد من الأساليب الحديثة (أساليب الذكاء الاصطناعي) وبالتحديد الشبكة العصبية ذات الانحدار الذاتي الغير الخطي (NAR) ومقارنتها مع النماذج الكلاسيكية والمتمثلة في نماذج ARIMA.

إشكالية الدراسة:

انطلاقا مما سبق ارتأينا الى طرح الإشكالية التالية:

ما مدى فعالية الشبكات العصبية ذات الانحدار الذاتي الغير الخطيNAR في التنبؤ بمعدل التضخم في الجزائر مقارنة مع نماذج ARIMA؟

- **الفرضيات:**

وللإجابة على إشكالية الدراسة تم وضع الفرضية التالية:

الشبكات العصبية ذات الانحدار الذاتي الغير الخطي (NAR)تعطي تنبؤات أفضل مقارنة مع نماذج ARIMA للتنبؤ بمعدل التضخم في الجزائر للفترة المستقبلية.

أهداف الدراسة:

الهدف الرئيسي من هذا البحث هو التنبؤ بشكل مناسب للمعدل التضخم في الجزائر من خلال استخدام نموذج ARIMA والشبكة العصبية ذات الانحدار الذاتي الغير الخطي (NAR) وتعزيزا لذلك، سيتم السعي لتحقيق الأهداف المحددة التالية:

- بناء نموذج متوسط متحرك متكامل الانحدار الذاتي (ARIMA) لمعدل لتضخم في الجزائر.

- بناء نموذج الشبكات العصبية ذات الانحدار الذاتي الغير الخطي (NAR)للتنبؤ بمعدل التضخم في الجزائر.

- استخدام معيار دقة التنبؤ جدر متوسط مربعات الأخطاء RMSEمن اجل المفاضلة بين نتائج تطبيق كل من نماذج ARIMAونموذج الشبكات العصبية ذات الانحدار الذاتي الغير الخطي (NAR).

المنهجية المتبعة:

من اجل الاجابة على إشكالية الدراسة واختبار مدى صحة الفرضيات فتقوم هده الدراسة في جزئها النظري على المنهج الوصفي والمنهج التحليلي من خلال توضيح المفاهيم الأساسية لكيفية استخدام هذه النماذج في التنبؤ، أما الجزء التطبيقي فيعتمد على منهجية يوكس جنكيز التي تعد من النماذج الاحصائية وشبكة NAR والتي تعتبر من

نماذج التعلم الالي وتم تطبيقها على بيانات معدل التضخم للفترة الزمنية الممتدة من 1990 الى 2021 وهدا بغرض إيجاد النموذج الأمثل الذي يمكن توظيفه للتنبؤ بمعدلات التضخم المستقبلية.

الدراسات السابقة:

عرف التنبؤ بالتضخم العديد من الدراسات التي تناولت منهجيات مختلفة كل من الاقتصادات المتقدمة والناشئة. فنظرا لكونه أمر مهم لكل من الوكلاء الاقتصاديين وصانعي السياسات، فإن التنبؤ بالتضخم يجذب المزيد من الاهتمام، وهناك عدد متزايد من الدراسات في الأدبيات. ومن خلال هده الدراسة سوف نتطرق الى بعض الدراسات السابقة التي تناولت موضوع التضخم.

دراسة (ZARRA، 2009) : هدفت هذه الدراسة الى التنبؤ بمعدل التضخم في ايران باستخدام الشبكات العصبية الاصطناعية للفترة الزمنية من1959 الى 2007. الشبكة العصبية المطبقة عبارة عن طبقات متعددة باستخدام خوارزميات مختلفة للانتشار الخلفي. ومن اجل تقييم أداء الشبكة العصبية الاصطناعية، تم استخدام معايير خطأ التنبؤ. أظهرت النتائج أن أنسب الشبكات هي تلك القائمة على خوارزمية تدريب Levenberg- Marquardحيث تستخدم الخلايا العصبية في الطبقات المخفية وظائف التنشيط غير الخطية، وفي طبقة الإخراج تستخدم وظائف التنشيط الخطي وعدد الخلايا العصبية في كل منها يتم اختيار الطبقة على النحو الأمثل. وفقًا لهذه الشبكة المفضلة، من المتوقع أن تكون معدلات التضخم 10.59-21.99 خلال الفترة 2008-2012.

دراسة (Choudhary، 2012) : هدفت هده الدراسة الى تقييم قوة نماذج الشبكة العصبية الاصطناعية المتنوعة (ANN) كأدوات للتنبؤ بمعدلات التضخم الشهرية لـ 28 دولة من دول منظمة التعاون الاقتصادي والتنمية .(OECD) في سياق أفق التنبؤ القصير

خارج العينة، بينت النتائج ان نماذج ANN كانت في المتوسط مؤشرًا أفضل للتضخم بنسبة 45٪ بينما كان أداء نموذج الانحدار الذاتي للنموذج الأول (AR1) أفضل بالنسبة لـ 23٪ من البلدان . وزيادة على دلك تم بتطوير مجموعات حسابية للعديد من نماذج ANNووجد أنها قد تكون أيضًا بمثابة أدوات موثوقة للتنبؤ بالتضخم.

دراسة (Uwilingiyimana، 2015) :هدفت هذه الدراسة الى التنبؤ بالتضخم ومعدلات التضخم في كينيا باستخدام نموذج ARIMA-GARCH للفترة الزمنية الممتدة من 2000 إلى 2014. حيث تم إجراء تحليل التنبؤ بالتضخم باستخدام نموذجين، كان نموذج ARIMA (1,1,12) قادرًا على إنتاج تنبؤات بناءً على اختبار الثبات وأنماط التاريخ في البيانات مقارنة بنموذج .GARCH (2,1)بينت النتائج النهائية لـ 180 سلسلة بيانات شهرية إلى أن الدمج بين نموذج ARIMA (1,1,12) بنموذج GARCH (2,1) يوفر أفضل النتائج وتحسين دقة التقدير والتنبؤ بشكل فعال مقارنة بطرق التنبؤ السابقة الأخرى.

دراسة) (Rani، 2017) : هدفت هده الدراسة الى التنبؤ بمعدل التضخم الشهري في الهند باستخدام الشبكات العصبية. البيانات المستخدمة لتقدير النماذج للفترة من 1994 إلى 2008، لغرض توضيح المنهجيتين. تم استخدام نموذجي الشبكة العصبية Backpropagationونموذج الشبكة العصبية المتكررة (نموذج (RNN في ظل التنبؤات الثابتة والديناميكية على التوالي في هذه الدراسة في التنبؤ بمعدل التضخم. تتم أيضًا مقارنة نتائج نماذج الشبكة العصبية في ظل التنبؤات الثابتة والديناميكية مع نموذج الاقتصاد القياسي الكلاسيكي. تظهر النتائج أن نموذج RNN في ظل التنبؤ الديناميكي يعمل بشكل أفضل من نموذج BPN في ظل التنبؤ الثابت والنموذج الاقتصادي القياسي الكلاسيكي في التنبؤ بمعدل التضخم.

دراسة (Delima، 2019) : هدفت هذه الدراسة الى انشاء نموذج ARIMA المناسب (p,d,q)في التنبؤ بمعدل التضخم في الفلبين للأعوام 2018 إلى 2022 باستخدام

البيانات التاريخية أحادية المتغير لمعدلات التضخم في البلاد من 1960-2017. أظهرت النتائج أن(1,0,0) ARIMA ، هو أفضل نموذج مناسب مقارنة مع نماذج ARIMA الاخرى.

دراسة (Oyewale، 2019) : هدفت هذه الدراسة الى التنبؤ بمعدلات التضخم باستخدام النهج غير المعلمي (الشبكات العصبية الاصطناعية)، حيث تم استخدام ثلاث شبكات عصبية اصطناعية Standard Backpropagation (SBP ,Scaled Conjugate Gradient (SCG), Backpropagation) للتنبؤ بمعدلات التضخم النيجيرية والأمريكية ومقارنتها مع نماذج ARIMA الكلاسيكية من اجل تقييم اداءها. بينت النتائج التي تم الحصول عليها أن جميع نماذج ANN تفوقت على نماذج ARIMA ما يترتب على ذلك هو أنه يمكن استخدام النموذج المستند إلى ANN للتنبؤ بهيكل سوق معدلات التضخم.

دراسة (Nyoni، 2019) : هدفت هذه الدراسة الى استخدام بيانات السلاسل الزمنية السنوية حول معدلات التضخم في الجزائر من 1970 إلى 2017 ، لنمذجة التضخم والتنبؤ به باستخدام نماذج ARIMA. بينت النتائج ان نموذج ARIMA(1,1,1) هو الافضل ومقبول للتنبؤ بالتضخم في الجزائر.

دراسة (dela Cruz، 2019) :هدفت هذه الدراسة لإيجاد نموذج إحصائي في التنبؤ بمعدل التضخم الشهري في الفلبين من جانفي 2015 إلى ديسمبر 2016 باستخدام نموذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة(ARIMA) والشبكة العصبية متعددة الطبقات. Perceptron(MLPNN) بينت النتائج ان نموذج ARIMA (2,1,0)(0,0,1) هو الأفضل من النماذج الأخرى وتقنيات وشبكة MLPN فتم اختيار MLP(48,7,1) هي الأفضل. ومن اجل المقارنة تم استخدام متوسط الخطأ المطلق (MAE)لاختيار الطريقة الافضل للتنبؤ بمعدل التضخم في الفلبين. وبعد المقارنة وجد أن ARIMA هي تقنية أفضل مقارنة بـ..MLPNN

دراسة(Işığıçok، 2020) : هدفت هده الدراسة الى التنبؤ بمعدلات التضخم المستقبلية بواسطة طريقتين بديلتين، وهي نماذج Box-Jenkins (ARIMA) والشبكات العصبية الاصطناعية (ANN) ، باستخدام بيانات CPI التي تتكون من 207 بيانات من يناير 2002 إلى مارس 2019. بينت النتائج التي تم الحصول عليها من كلا التقنيتين كانت قريبة من بعضها البعض.

دراسة (Peirano، 2021) : هدفت هذه الدراسة الى التنبؤ بمعدل التضخم في خمسة اقتصادات ناشئة في أمريكا اللاتينية بناءً على نموذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة الموسمية ((SARIMA جنبًا إلى جنب مع الذاكرة طويلة المدى (.(LSTMتشير النتائج إلى أن النموذج المقترح المستند إلى مزيج من SARIMA وLSTM يتمتع بدقة أعلى في التنبؤ بالتضخم على SARIMA وLSTM بشكل منفرد.

فتتمثل مساهمة الدراسة الحالية مقارنة مع الدراسات السابقة في التنبؤ بمعدل التضخم في الجزائر باستخدام نموذج الانحدار الذاتي والمتوسطات المتحركة (ARIMA) والتي تعد من الأساليب الكلاسيكية والشبكة العصبية ذات الانحدار الذاتي الغير الخطي (NAR) والتي تعد من الأساليب الحديثة المتمثلة في التعلم الالي.

1. نماذج ARIMA:

يعتبر نموذج ARIMA طريقة إحصائية مستخدمة على نطاق واسع للتنبؤ بالسلاسل الزمنية. حيث يجمع بين خاصيتين في معادلة واحدة، الخاصية الأولى تسمى عملية الانحدار الذاتي(ومن هنا ذكرت AR في ARIMA)والخاصية الثانية هي المتوسطات المتحركة(ومن هنا جاءت MAفي ARIMA) (Yee، 2021، صفحة 13).

ويأخذ نموذج الانحدار الذاتي من الرتبة$AR(p)$: الصيغة التالية (Nochai، 2006، صفحة 3)

$$y_t = \emptyset_0 + \emptyset_1 y_{t-1} + \emptyset_2 y_{t-2} + \cdots + \emptyset_p y_{t-p} + \varepsilon_t$$

حيث: $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ هي متغير الاستجابة في الزمن $\mathrm{t}-1, t-2, .., t-p$ على التوال

y_tهو المتغير التابع الذي يتم توقعه في الزمن t. $\emptyset_0$، $\emptyset_1$ ،...، $\emptyset_p$ تمثل المعلمات المقدرة .و ε_t هو حد الخطأ في الزمن t

نموذج المتوسطات المتحركة من الرتبة$(\boldsymbol{MA(q)}$: وتأخذ الصيغة التالية

$$y_t = \mu + \varepsilon_t + \theta_1\varepsilon_{t-1} + \theta_1\varepsilon_{t-2} + \cdots + \theta_q\varepsilon_{t-q}$$

حيث تشير $\boldsymbol{AR}$ نموذج الانحدار الذاتي و $\boldsymbol{MA}$ الى نموذج المتوسطات المتحركة وأخيرا $\boldsymbol{I}$ الى الفروقات، ولدلك لديها ثلاثة معلمات نموذجية $AR\ (p)$و$I(d)$و$MA(q)$ و لتشكل نموذج $\mathrm{ARIMA(p, d, q)}$ ، حيث (Guha، 2016، صفحة 118) : p هي رتبة الانحدار الذاتي و d هي رتبة الفروقات واخيرا q تشير الى رتبة المتوسطات المتحركة.

نموذج الانحدار الذاتي والمتوسطات المتحركة$ARIMA(p,q)$: وتكتب بالصيغة الرياضية التالية

$$\boldsymbol{y_t = \emptyset_0 + \emptyset_1 y_{t-1} + \emptyset_2 y_{t-2} + \cdots + \emptyset_p y_{t-p} + \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_1\varepsilon_{t-2} - \cdots - \theta_q\varepsilon_{t-q}}$$

ومنه يمكن كتابة معادلة معدل التضخم في الجزائر على النحو التالي:

$$INF_t = \emptyset_0 + \emptyset_1 INF_{t-1} + INF_2 y_{t-2} + \cdots + INF_p y_{t-p} + \varepsilon_t + \theta_1\varepsilon_{t-1} - \theta_1\varepsilon_{t-2} - \cdots - \theta_q\varepsilon_{t-q}$$

حيث تمثل INF_t معدل التضخم.

ومن اجل تطبيق منهجية Box-Jinkins يجب أن تكون السلاسل الزمنية مستقر، وفي حالة عدم ثبات السلسلة فيجب جعل سلسلة مستقرة عن طريق أخذ الاختلافات المتتالية حتى تصبح السلسلة مستقرة، ويجدر الاشارة إلى عدد الاختلافات المطلوب أخذها قبل أن تصبح السلسلة ثابتة بالحرفd ونادرا ما يكون أكثر من اثنين (2) ومن

اجل التأكد من استقرارية السلسلة فيتم الاعتماد اما عن طريقة الرسم البياني لدالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي او باستخدام اختبار ديكي فولر المطور واختيار PP والتي تعد من بين الاختبارات الأكثر استخداما لدراسة تباث السلسلة (Suleiman S.، 2020، صفحة 84). فبعد التأكد من استقرارية السلسلة تأتي مرحلة تحديد المعلمات (p,q) ويتم دلك عن طريق الرسم البياني لدالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي ومن اجل المفاضلة بين النماذج المرشحة يتم استخدام معيار AIC وBIC والتي تكتب كالاتي (Suleiman، 2018، صفحة 264):

$$AIC(p) = nln\left(\hat{\sigma}_t^2/_n\right) + 2n$$

حيث تشير n الى عدد المشاهدات الفعالة المستخدمة لملاءمة النموذج. p هو عدد المعلمات في النموذج و $\hat{\sigma}_t^2$ هو مجموع مربع البواقي للعينة و يتم اختيار ترتيب النموذج الأمثل من خلال عدد معلمات النموذج ، والتي تقلل معيار AIC. فبعد تحديد المعلمات تأتي مرحلة التقدير للنموذج المختار وهدا بالاعتماد طريقة الامكان الأعظم. وتليها مرحلة الفحص للنموذج المختار من اجل التأكد من مدى ملائمته وصلاحيته لتمثيل النموذج من خلال اخضاعه لعدة اختيارات مثل ليونغ - بوكس(Ljunge-Box) وأخيرا تأتي مرحلة التنبؤ. فبعد تقدير النموذج وفحصه والتأكد من صلاحيته يمكن استخدامه للتنبؤ (Sahed، 2020، صفحة 39).

2.الشبكات العصبية ذات الانحدار الذاتي الغير الخطي: (NAR)

الشبكة العصبية الاصطناعية هي شبكة تحاكي الجهاز العصبي للدماغ البشري وتحقق وظائف محددة، وقد تم بناء نظام الشبكة على أساس بنية الاتصال بين الخلايا العصبية في الدماغ، الكثير من الخلايا العصبية التي تحاكي الوصلات المشبكية بين الخلايا العصبية في نظام بيولوجي تمنح الشبكات العصبية الاصطناعية مزايا أكثر من

النماذج الرياضية العامة. تشارك جميع الخلايا العصبية في معالجة معلومات النظام بأكمله، ويتم الحصول على المخرجات النهائية من خلال التفاعل وردود الفعل المتبادلة بين الخلايا العصبية. هذه الخاصية تجعل نموذج الشبكة العصبية قويا. في الوقت نفسه (Wu، 2021، صفحة 2).

الشبكات العصبية ذات الانحدار الذاتي الغير الخطي (NAR) تعتبر شبكات عصبية اصطناعية تكرارية تؤدي مهام الانحدار على السلاسل، حيث يعتمد نموذج NAR أساسا على نموذج الانحدار الذاتي الخطي AR، والذي يعتبر من بين النماذج الأكثر استخداما في التنبؤ بالسلاسل الزمنية كونها تعتمد القيم المستقبلية على القيم السابقة لنفس المتغير قيد الدراسة ./*المعادلة* المحددة لشبكة NAR هي (Benmouiza، 2016، صفحة 7):

$$\hat{y}(t) = f\big(y(t-1) + y(t-2) + \cdots + y(t-d)\big) + \varepsilon_t$$

فهذه الصيغة تبين كيفية استخدام شبكة *NAR* للتنبؤ بقيمة سلسلة البيانات y في الزمن t. حيث $\hat{y}(t)$هو مخرجات النموذج الذي تعتمد القيم المستقبلية فقط على قيم d السابقة المتأخرة لإشارة الخرج،، ويهدف تدريب الشبكة العصبية إلى تقريب الدالة وهدا عن طريق تحسين أوزان الشبكة وتحيز الخلايا العصبية .

تتألف بنية شبكة NARمن ثلاث طبقات: طبقات الإدخال والمخفية والمخرجة. كم تتطلب بنيتها عددا محددا من التأخيرات لبناء الدالة الغير المعروفة f والعقد المخفية والوظائف وخوارزمية التدريب الفعالة (Amat Bernabéu، 2019، صفحة 20).

ويتم تدريب النماذج العصبية NAR بموجب قاعدة التعلم الأكثر شيوعا وهي خوارزمية Levenberg-Marquardt للانتشار الخلفي (LMBP) كونها تؤدي الى زيادة سرعة التدريب (Fraz، 2022، صفحة 166). كما يجب تنويع الخلايا العصبية في الطبقة المخفية من خلال إنشاء نموذج طبقة واحدة مخفية باستخدام طبقات الإدخال

والإخراج وهذا من اجل تقدير معلمات الأداء. ويعتبر نموذج NAR مع أقل قيمة لمعيار MSE هو النموذج الامثل للتنبؤ. واخيرا يجب توزيع نموذج NAR البيانات إلى ثلاثة أجزاء. يتم استخدام الجزء الأول من البيانات للتدريب، ويتم استخدام الأجزاء المتبقية للتحقق من بيانات السلاسل الزمنية واختبارها.

3.النتائج والمناقشة:

البيانات المستخدمة في هذه الدراسة تخص معدل التضخم في الجزائر وهي بيانات سنوية للفترة الزمنية الممتدة من سنة 1990 الى 2021 وتتكون من 32 مشاهدة، تم الحصول على البيانات من البنك الدولي.

1.3. دراسة الإحصائية الوصفية لمعدل التضخم:

الهدف من دراسة الخواص الإحصائية لهذه البيانات هو إعطاء فكرة عامة عن البيانات والجدول ادناه يبين النتائج المتحصل عليها.

الجدول 1: الإحصائية الوصفية لمعدل التضخم

الاحصاءات	اعلى قيمة	ادنى قيمة	الوسيط	المتوسط الحسابي	الانحراف المعياري	الالتواء	التفرطح
معدل التضخم	31.66966	0.339163	4.6543	8.5594	9.1792	1.5061	3.8037

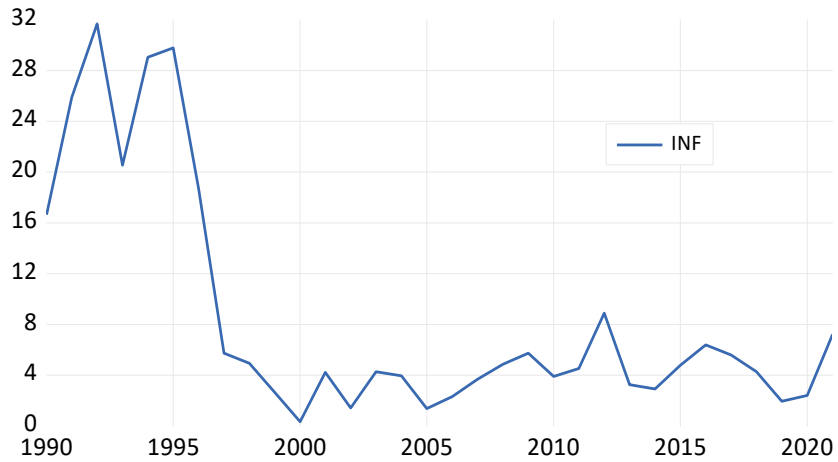
المصدر: من اعداد الباحثين

نلاحظ من خلال المعطيات الإحصائية الموضحة في الجدول ادناه أعلاه أن اعلى قيمة لمعدل التضخم في الجزائر بلغت 31.66966 وأصغر قيمة كانت0.339163، والمتوسط الحسابي لمعدل التضخم بلغ8.559418 ، أما الوسيط والانحراف المعياري فبلغا على التوالي9.179278 ، 4.654329 كما بلغ مقياس التفرطح والالتواء :1.506134 ,3.803783 على التوالي. كما نلاحظ أن مقياس التفرطح اقل من 3مما يدل على أن منحنى البيانات مفرطح.

2.3. نماذج ARIMA :

قبل التطرق إلى تطبيق نماذجARIMA وكما ذكرنا سابقا المعروفة بمنهجية-Box Jinkins، يجب أولا دراسة استقرارية السلسلة الزمنية من اجل التأكد من ثباتها. حيث قمنا برسم هده البيانات في الشكل الموضح ادناه من اجل معرفة الاتجاه العام لها، فنلاحظ من خلاله ان هنالك اتجاه متناقص ويلاحظ وجود بعض التذبذبات مما يبين عدم استقراراية السلسلة ولكن الحكم بالنظر غير كافي، ومن اجل التأكد من ذلك سنقوم باستخدام كل من اختبار ADF وPP والتي تعد من بين أكثر الاختبارات استخداما لدراسة استقرارية السلسلة. والجدول 2و 3 يبين نتائج التي تم التوصل اليها.

الشكل 1: التمثيل البياني لمعدل التضخم في الجزائر



المصدر: من اعداد الباحثين

الجدول 2: نتائج اختبارADF

المتغير	النماذج	القيمة المحسوبة	القيمة الاحتمالية	القرار
معدل التضخم	بوجود ثابت فقط	-1.6405	**0.4506**	السلسلة غير
	ثابت و اتجاه	-1.7794	**0.6903**	مستقرة
	بدون ثابت و اتجاه	-1.4409	**0.1368**	

الفروق الاولى

المتغير	النماذج	القيمة المحسوبة	القيمة الاحتمالية	القرار
معدل التضخم	بوجود ثابت فقط	-5.5420	0.0001	السلسلة مستقرة
	ثابت و اتجاه	-5.5914	0.0004	
	بدون ثابت و اتجاه	-5.5493	0.0000	

المصدر: من اعداد الباحثين

الجدول 3: نتائج اختبار PP

المتغير	النماذج	القيمة المحسوبة	القيمة الاحتمالية	القرار
معدل التضخم	بوجود ثابت فقط	-1.6018	0.4697	السلسلة غير مستقرة
	ثابت و اتجاه	-1.8147	0.6732	
	بدون ثابت و اتجاه	-1.4466	0.1354	

الفروق الاولى

المتغير	النماذج	القيمة المحسوبة	القيمة الاحتمالية	القرار
معدل التضخم	بوجود ثابت فقط	-5.5653	0.0001	السلسلة مستقرة
	ثابت و اتجاه	-5.9041	0.0002	
	بدون ثابت و اتجاه	-5.5655	0.0000	

المصدر: من اعداد الباحثين

نلاحظ من خلال نتائج الجدول أعلاه ان معدل التضخم في الجزائر غير مستقر لكلا الاختبارين، ومنه فهي تحتوي على جدر وحدوي، ومن اجل جعل السلسلة مستقرة قمنا بالفروق الأولى بالاعتماد على كلا الاختبارين السابقين. والنتائج المتوصل لها مبينة في نفس الجدول 2 و3، فبعد القيام بالفروق الأولى تبين ان سلسلة معدل التضخم مستقرة عند مستوي المعنوية لكلا الاختبارين. ومنه فسوف يكون لدينا النموذج على شكل ARIMA(p,1,q).

فبعد ثبات السلسلة تأتي اول مرحلة من منهجية Box-Jinkins وهي مرحلة التعرف على المعلمات qوp. بالاعتماد الرسم البياني لدالة الارتباط الذاتي ودالة الارتباط الذاتي

الجزئي، ومن اجل المفاضلة بين النماذج التي تعد مناسبة لتمثيل معدل التضخم سيقتصر فقط على المعيار الأكثر استخدامًا والأكثر شهرة، معيار AIC من أجل اختيار أفضل النماذج.

فبعد ترشيح عدة نماذج من ARIMA وبعد التجربة تبين ان النموذج الدي يعطي اقل قيمة لمعيار AIC هو ARIMA (2,1,0) بقيمة 6.150666.

فبعد تحديد النموذج ARIMA الملائم للتنبؤ بمعدل التضخم تأتي ثاني تقدير النموذج المستخدم والجدول 4 يبين نتائج التقدير.

الجدول 4: نتائج تقدير النموذج ARIMA (2,1,0)

Dependent Variable: D(INF)				
Method: ARMA Maximum Likelihood (OPG - BHHH)				
Date: 11/01/22 Time: 06:12				
Sample: 1991 2021				
Included observations: 31				
Convergence achieved after 17 iterations				
Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.458300	0.758743	-0.604025	0.5507
AR(2)	-0.275651	0.161082	-1.711245	0.0981
SIGMASQ	22.51411	5.170004	4.354756	0.0002
R-squared	0.068580	Mean dependent var		-0.304080
Adjusted R-squared	0.002050	S.D. dependent var		4.997752
S.E. of regression	4.992628	Akaike info criterion		6.150666
Sum squared resid	697.9374	Schwarz criterion		6.289439
Log likelihood	-92.33532	Hannan-Quinn criter.		6.195903
F-statistic	1.030806	Durbin-Watson stat		1.732551
Prob(F-statistic)	0.369863			
Inverted AR Roots	-.00+.53i	-.00-.53i		

المصدر: من اعداد الباحثين

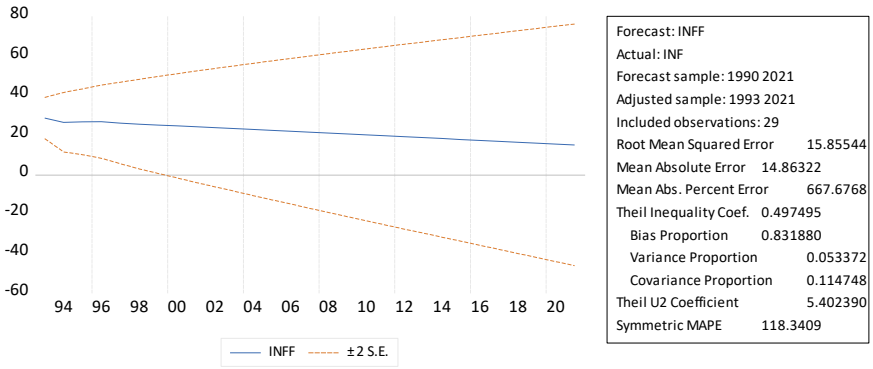
ومنه يمكن كتابة معادلة النموذج المقدر وفقا للجدول أعلاه كالاتي:

$$ARIMA(2,1,0): D(INF)_t = -0.458300 - 0.275651(INF)_{t-2}$$

كما نلاحظ من خلال هذا الجدول ان قيمة معامل التحديد R^2 في النموذج المقدر لمعدل التضخم تعادل 68.% كما لا يوجد ارتباط ذاتي بين الأخطاء وهذا ما أثبتته إحصائية دربن واطسون (DW) لأن قيمتها قريبة جدا من(DW=1.98) 2 أي تقع ضمن مجال الثقة.

فبعد تقدير النموذج ARIMA (2,1,0) وفحصه والتأكد من صلاحيته يمكن استخدامه للتنبؤ بمعدل التضخم في الجزائر، والشكل ادناه يبين القيم التنبؤية باستخدام نموذج وكذلك جودة تقييم التنبؤ باستخدام النموذج المقدر.

الشكل2 : القيم التنبؤية باستخدام النموذج ARIMA (2,1,0) وكذلك جودة تقييم التنبؤ باستخدام النموذج المقدر



المصدر: من اعداد الباحثين

نلاحظ من خلال الشكل2 ان النموذج المقدر محصور بين حدي الثقة بانحراف معياري ± 2 ومنه نستنتج أن النموذج معنوي على طول السلسلة . كما ان الفجوة بين المعدل الفعلي والمعدل المتنبأ بها والتي يمثلها جذر متوسط مربع الأخطاء صغيرةجدا (15.85544) ومنه فان القدرة التنبؤية لنموذج دقيقة.

3.3. الشبكة العصبية ذات الانحدار الذاتي الغير الخطي NAR :

من اجل التنبؤ بمعدل التضخم بالاعتماد على الشبكة العصبية ذات الانحدار الذاتي الغير الخطي NAR يجب اتباع الخطوات التالية:

1.3.3.تقسيم البيانات :

ففي هذه الخطوة نقوم بتقسيم السلسلة محل الدراسة الى ثلاثة مجموعات وهي مجموعة التدريب والتحقق والاختبار عشوائيا والجدول ادناه يبين نتائج التقسيم.

الجدول5 : تقسيم البيانات

المجموعات	نسبة المشاهدات
مجموعة التدريب	70%
مجموعة التحقق	15%
مجموعة الاختبار	15%

المصدر: من اعداد الباحثين

فمن خلال الجدول أعلاه فقد تم تقسيم البيانات على النحو التالي:

- تم استخدام 70% لعملية التدريب.
- تم استخدام 15% للتحقق.
- والباقي والمتمثل في 15% لعملية الاختبار.

2.3.3.تحديد معمارية الشبكة :

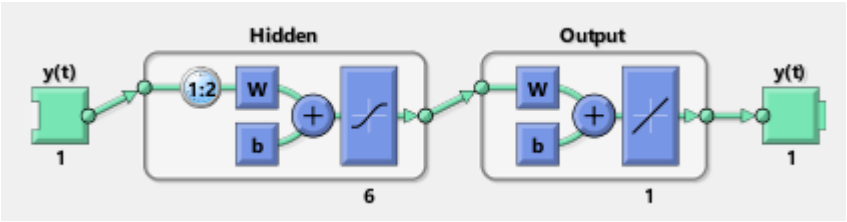
نلاحظ من خلال الشكل 03 ان أفضل معمارية التي تم الحصول عليها بعد عدة تجارب هي NAR (2,6,1)بناء على متوسط مربع الأخطاء MSE والذي يستخدم لقياس الأداء في عملية التدريب وكذلك لمقارنة الأداء المتوقع بين طرق التنبؤ ويكتب على النحو التالي (Hoong، 2012، صفحة 150):

$$MSE = \frac{1}{N}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$$

أي تحتوي على ثلاثة طبقات وهي طبقة المدخلات وتحتوي على عنصر معالجة واحد وطبقة مخفية بستة عناصر معالجة وطبقة مخرجات بعنصر معالجة واحدة بالإضافة الى التأخير والذي حدد بعدد 2.

ومن اجل تدريب الشبكة تم استخدام خوارزمية Marquardt-Levenberg الشهيرة وتم استخدام دالة التنشيط Hyperbolic Tangent في الطبقة المخفية ودالة التنشيط الخطية في طبقة الإخراج.

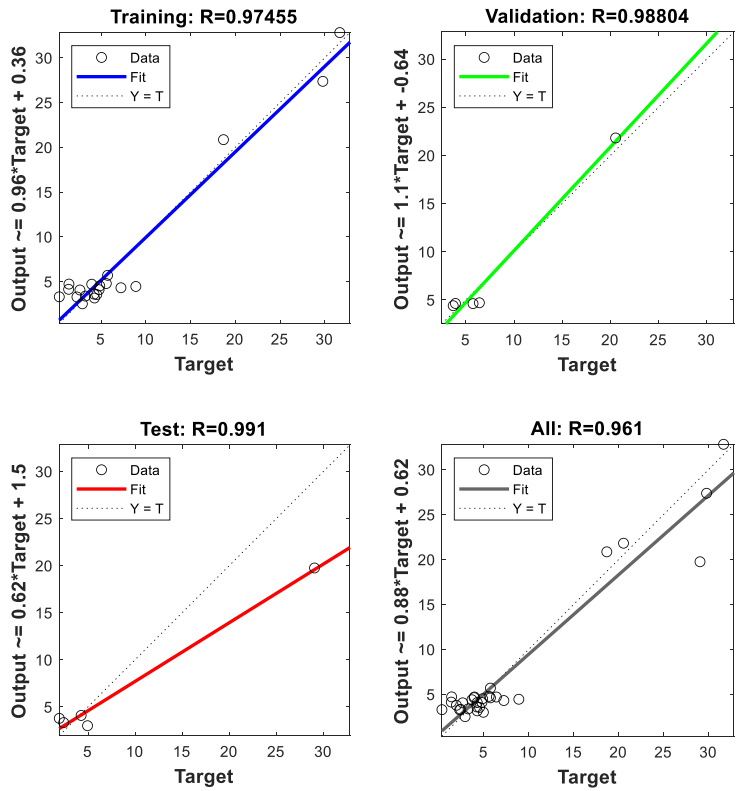
الشكل3 : معمارية الشبكة العصبية ذات الانحدار الذاتي الغير الخطية لمعدل التضخم



المصدر: من اعداد الباحثين بالاعتماد على برنامج MATLAB

وبناء على الخيارات التي تم تحديدها في عملية التدريب توصلنا الى النتائج النهائية لعملية التدريب والتحقق والاختبار لمعدل التضخم المبينة في الشكل ادناه.

الشكل4 : الانحدار التدريبي للنموذج NAR (2,6,1)



المصدر: من اعداد الباحثين

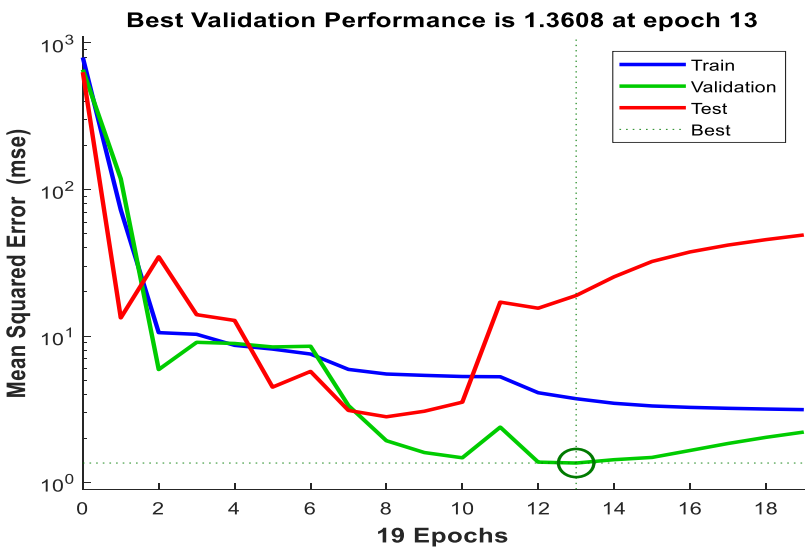
يمثل الشكل أعلاه مخطط الانحدار للمجموعة التدريب والتحقق واختبار البيانات وكدلك يتضمن المجموعات الثلاثة في مخطط واحد. حيث تمثل الخطوط المتقطعة في كل من الأرباع النتائج المثلى (الإخراج يقترب من الأهداف). كما يمثل الخط الناصح في الاشكال الأربعة أفضل خط خطي ملائم بين الناتج والهدف. اما (R) وهو معامل الارتباط فيقيس مدى العلاقة بين الناتج والهدف مع مجال القيم من $[1 - 0]$. حيث يفضل القيم التي تكون الأقرب إلى واحد.

فنلاحظ من خلال هده النتائج أن أخطاء الشبكة تناقصت مع زيادة تدريبها وهي متناظرة

بالنسبة للمحور الصفري مما يدل على كفاءة التدريب. كما نلاحظ ان معامل الارتباط اعلى في مجموعة التدريب والتحقق واختبار وكدلك يساوي R= 0.961 في المخطط المتضمن المجموعات الثلاثة وهي قيمة قريبة من الواحد ما يبين قوة العلاقة بين الأهداف والمخرجات.

ومن اجل معرفة الأداء التدريبي للنموذج الشبكة العصبية المقترحة، الذي تم إنشاؤه أثناء التدريب. ا فالشكل 5 يوضح تقييم الأداء أو القدرة التنبؤية باستخدام متوسط مربع الخطأ (MSE) .

الشكل5 : الأداء التدريبي للنموذج NAR (2,6,1)



المصدر: من اعداد الباحثين

نلاحظ من الشكل 05 ان توقف التدريب بعد 19 تكرارا (Epochs)وهذا بسبب زيادة خطأ في مرحلة التحقق. حيث تعتبر كأداة تشخيصية مفيدة لرسم التدريب والتحقق واختبار الأخطاء للتحقق من تقدم التدريب.

فتظهر النتيجة أن اداء الشبكة كان جيدا لأن خطأ مجموعة الاختبار وخطأ مجموعة التحقق لهما خصائص متشابهة، فبعد التدريب الأولي لنموذج الشبكة العصبية، يتم إعادة تدريبه لمدة 19 تكرار ويتم الحصول على أداء MSE= 1.3608في عملية لتدريب.

المقارنة بين النماذج المستخدمة:

ومن اجل اختيار النموذج الانسب لاستخدامه للتنبؤ بمعدل التضخم، قمنا بالمقارنة بين النموذج ARIMA والشبكة NAR وهدا بالاعتماد على معيار متوسط مربع الأخطاء MSE ومعامل الارتباط R، والجدول 66يبين نتائج المقارنة:

الجدول6 : مقارنة بين دقة التنبؤ للنماذج المستخدمة للتنبؤ بمعدل التضخم

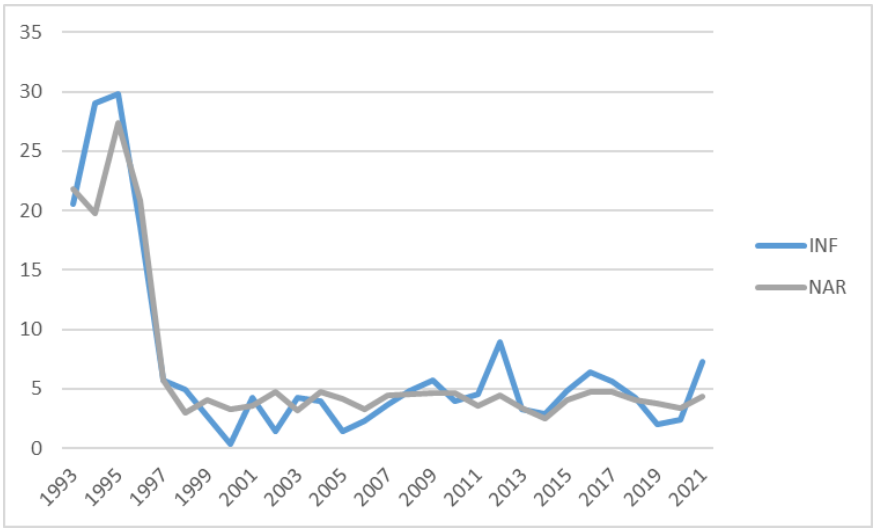
النماذج	معامل الارتباط R	معيارMSE
ARIMA(2,1,0)	0.498	15.8554
NAR(2,6,1)	0.961	2.4229

المصدر: من اعداد الباحثين

نلاحظ من خلال نتائج الجدول أعلاه ان نموذج NAR (2,6,1) يعطي أداء أفضل مقارنة مع نموذج ARIMA (2,1,0) وهدا ما تبينه قيمة معيار MSE والتي تساوي 2.4229 وهي أصغر من قيمة نموذج ARIMA والتي تساوي 15.8554، نفس الشيء لمعامل الارتباطR حيث يعطي توقع NAR تنبؤًا أفضل وهي 0.961 اكبر من نموذجARIMA.

والشكل التالي يوضح نتائج القيم المتنبئ بها باستخدام نموذج NAR(2,6,1) مع القيم الفعلية لمعدل التضخم في الجزائر

الشكل6 : التضخم الفعلي مقابل التضخم المتنبؤ به



المصدر: من اعداد الباحثين

نلاحظ من خلال الشكل6 أن قيم التضخم االمتنبؤ بها والتي تأخذ اللون الرمادي أقرب بكثير إلى القيم الفعلية ذات اللون الأزرق.

الخاتمة:

يعتبر التضخم أحد متغيرات الاقتصاد الكلي التي تنطوي على مشاكل والتي تحتل مكانة مركزية في إدارة معظم الاقتصادات. هذا لأنه يتم استخدامه في الغالب كأحد مؤشرات لقياس الأداء الاقتصادي لأي بلد ما. فغالبًا ما جعلت التناقضات السياسية من الصعب على بعض صانعي السياسات تحقيق معدلات التضخم المستهدفة في بلدانهم، مما سمح بمستويات المعيشة في نزوات التضخم المدمرة. لذلك، فإن التنبؤ الموثوق به لمعدلات التضخم المستقبلية في بلد ما سيحدد السياسات التي سيطبقها صناع القرار في الاقتصاد.

ففي هذه الدراسة تم تقديم النتائج التي تم الحصول عليها من خلال البيانات السنوية لمعدل التضخم في الجزائر للفترة الزمنية الممتدة من1990 الى 2021 وتتكون من 32 مشاهدة حول أداء نموذج ARIMA ونموذج الشبكة العصبية ذات الانحدار الذاتي الغير الخطي NAR لتنبؤ بمعدل التضخم. تمت مقارنة أداء نموذج NAR مع نموذج Box-Jenkins ARIMA الكلاسيكي، والذي تم استخدامه على نطاق واسع للتنبؤ بالسلاسل الزمنية بالاعتماد على معيار دقة التنبؤ MSE ومعامل الارتباط R. كشفت النتائج التي تم التوصل إليها أن نموذج(2,6,1) NARيعطي تنبؤات جيدة مقارنة مع نموذج ARIMA(2,1,0)، وبالتالي يمكن الاستفادة من الشبكة العصبية NAR بشكل فعال من التنبؤ بمعدل التضخم المستقبلي.

التوصيات والاعمال المستقبلية:

فيما يلي التوصيات الناتجة عن نتائج الدراسة.

- الاعتماد على الشبكات العصبية الاصطناعية من اجل التنبؤ بمعدل التضخم في الجزائر.

- ينبغي النظر إلى التنبؤ بالتضخم على أنه عنصر مصيري من عملية تطوير تدابير سياسة مجدية للتخفيف من معدلات التضخم.

- يجب إيلاء المزيد من الاهتمام لمدى ملاءمة النماذج للبيانات الأخرى غير العشوائية.

وكعمل مستقبلي، سنحاول التنبؤ بمعدل التضخم باستخدام شبكة NARX كما سنقوم بإجراء المزيد من الدراسات حول خوارزميات التعلم الآلي الأخرى مثل شبكة GMDH وشيكة LSTM.

المراجع والمصادر:

1. Abdulrahman, B. M. A., Ahmed, A. Y. A., & Abdellah, A. E. Y. (2018). Forecasting of Sudan Inflation Rates using ARIMA Model. International Journal of Economics and Financial Issues, 8(3), 17.
2. Silfiani, M. (2014). Forecasting Inflation in Indonesia Using Hybrid ARIMA and Artificial Neural Networks Ensemble (Doctoral dissertation, Asian Institute of Technology).
3. Urrutia, J. D. (2021). An Analysis on Forecasting Inflation Rate in the Philippines: A Recurrent Neural Network Method Approach. Turkish Journal of Computer and Mathematics Education (TURCOMAT), 12(3), 5297-5310.
4. dela Cruz, V. P. J., Pamaylaon, G. A., & Largo, F. F. (2019). FORECASTING THE PHILIPPINE INFLATION RATE USING BOX-JENKINS AUTOREGRESSIVE INTEGRATED MOVING AVERAGE AND MULTI-LAYER PERCEPTRON NEURAL NETWORK TECHNIQUES.
5. Padilla, C., Hashemi, R., Mahmood, N. H., & Latva-Aho, M. (2021, October). A Nonlinear Autoregressive Neural Network for Interference Prediction and Resource Allocation in URLLC Scenarios. In 2021 International Conference on Information and Communication
6. Sarkar, R., Julai, S., Hossain, S., Chong, W. T., & Rahman, M. (2019). A comparative study of activation functions of NAR and NARX neural network for long-term wind speed forecasting in Malaysia. Mathematical Problems in Engineering, 2019.
7. KEREM, A., & KIRBAŞ, İ. (2021). Multi-step forward forecasting of electrical power generation in lignite-fired thermal power plant. Mühendislik Bilimleri ve Tasarım Dergisi, 9(1), 1-13.
8. Rapoo, M. I., & Xaba, D. (2017). 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 Engineering, 11(11), 2669-
9. Dash, R., McMurtrey, M., Rebman, C., & Kar, U. K. (2019). Application of artificial intelligence in automation of supply chain management. Journal of Strategic Innovation and Sustainability, 14(3), 43-53.
10. ZARRA, N. M., & HAMID, S. (2009). Prediction of Inflation Rates in Iran Using Dynamic Artificial Neural Network (Time Series Approach).
11. Choudhary, M. A., & Haider, A. (2012). Neural network models for inflation forecasting: an appraisal. Applied Economics, 44(20), 2631-2635.

12. Uwilingiyimana, C., Munga'tu, J., & Harerimana, J. D. D. (2015). Forecasting Inflation in Kenya Using Arima-Garch Models. *International Journal of Management and Commerce Innovations*, *3*(2), 15-27.
13. Rani, S. J., Haragopal, V. V., & Reddy, M. K. (2017). Forecasting inflation rate of India using neural networks. International Journal of Computer Applications, 158(5), 45-48.
14. Delima, A. J. P., & Lumintac, M. T. Q. (2019). Application of time series analysis for philippines' inflation prediction. Int. J. Recent Technol. Eng, 8(1), 1761-1765.
15. Oyewale, A. M., Kasali, A. O., Phazamile, K., Abiodun, M. V., & Adeyinka, A. I. (2019). Forecasting Inflation Rates Using Artificial Neural Networks. *International Journal of Statistics and Applications*, *9*(6), 201-207.
16. Nyoni, T. (2019). Can Algeria be the first African country to outsmart the Malthusian population trap? Insights from the ARIMA approach.
17. dela Cruz, V. P. J., Pamaylaon, G. A., & Largo, F. F. (2019). FORECASTING THE PHILIPPINE INFLATION RATE USING BOX-JENKINS AUTOREGRESSIVE INTEGRATED MOVING AVERAGE AND MULTI-LAYER PERCEPTRON NEURAL NETWORK TECHNIQUES.
18. Işığıçok, E., Öz, R., & Tarkun, S. (2020). Forecasting and technical comparison of inflation in Turkey with box-jenkins (ARIMA) models and the artificial neural network. International Journal of Energy Optimization and Engineering (IJEOE), 9(4), 84-103.
19. Peirano, R., Kristjanpoller, W., & Minutolo, M. C. (2021). Forecasting inflation in Latin American countries using a SARIMA–LSTM combination. Soft Computing, 25(16), 10851-10862.
20. Yee, K. W., & Samsudin, H. B. (2021). Comparison between artificial neural network and arima model in forecasting palm oil price in Malaysia. International Journal of Scientific Engineering and Science, 5(11), 12-15.
21. Nochai, R., & Nochai, T. (2006, June). ARIMA model for forecasting oil palm price. In Proceedings of the 2nd IMT-GT Regional Conference on Mathematics, Statistics and applications (pp. 13-15).
22. Guha, B., & Bandyopadhyay, G. (2016). Gold price forecasting using ARIMA model. Journal of Advanced Management Science, 4(2).
23. Guha, B., & Bandyopadhyay, G. (2016). Gold price forecasting using ARIMA model. Journal of Advanced Management Science, 4(2).

24. Suleiman, S., & Sani, M. (2020). Application of ARIMA and Artificial Neural Networks Models for Daily Cumulative Confirmed Covid-19 Prediction in Nigeria. Equity Journal of Science and Technology, 7(2), 83-9.
25. Suleiman, S., Burodo, M. S., & Yusuf, G. Comparative studies of ARIMA and Artificial Neural Network in forecasting Naira/Dollars exchange rate.
26. Sahed, A., Mekidiche, M., & Kahoui, H. (2020). Forecasting natural gas prices using nonlinear autoregressive neural network. IJ Mathematical Sciences and Computing, 5, 37-46.
27. Wu, P., & Chen, Y. (2021). Product Demand Forecasting in Ecommerce Based on Nonlinear Autoregressive Neural Network.
28. Benmouiza, K., & Cheknane, A. (2016). Small-scale solar radiation forecasting using ARMA and nonlinear autoregressive neural network models. Theoretical and Applied Climatology, 124(3), 945-958.
29. Amat Bernabéu, A. (2019). ARIMA and Artificial Neural Networks to forecast the CO2 emissions allowances price: application to the design of petrochemical supply chain under uncertainty.
30. Fraz, T. R., Fatima, S., & Uddin, M. Comparing the forecast performance of nonlinear models and machine learning process. An empirical evaluation of GARCH family and NAR models in the light of CPEC.
31. Hoong, P. K., Tan, I. K., & Keong, C. Y. (2012). Bittorrent network traffic forecasting with ARMA. *arXiv preprint arXiv:1208.1896*.