

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

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 ساهد² أ.د. محمد ميكيدش³

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 أو 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 غير الخطية ومقارنتها مع نماذج ARIMA. تم استخدام بيانات السلاسل الزمنية السنوية للفترة 1990 إلى 2021 في التحليل، ومن أجل المقارنة بين النموذجين تم الاعتماد على معيار متوسط مربعات الأخطاء (MSE) ومعامل الارتباط R، أظهرت النتائج النهائية أن الشبكة العصبية ذات الانحدار الذاتي غير 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

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

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 أهم المشاكل الاقتصادية التي تواجه معظم الاقتصادات سواء كانت دول متقدمة أو دول نامية. فيشار لها على أنها ظاهرة نقدية ونعني بها زيادة مستمرة في أسعار السلع (السلع والخدمات)، مما يقلل من القوة الشرائية للعملة خلال فترة معينة. كما يمكن أيضاً 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 ولهذا 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

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

سيطبقها صناع القرار في الاقتصاد (del Cruz، 2019، صفحة 2). ولذا كانت
هناك العديد من الطرق التي استخدمها 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 غير الخطية (NARNN) نوع من هذه الشبكات، حيث
تم اختيارها للتنبؤ بالتداخل نظرا لدقتها العالية في التنبؤ. وتتمثل 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 تنبؤة جيدة باستخدام 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 غير 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 الخطي NAR 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 جذر متوسط مربعات الأخطاء RMSE من اجل
المفاضلة بين نتائج تطبيق كل من نماذج ARIMA ونموذج الشبكات العصبية ذات
الانحدار الذاتي الغير الخطي (NAR).

المنهجية المتبعة:

من اجل الاجابة على إشكالية الدراسة واختبار مدى صحة الفرضيات فتقوم هذه
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

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

نماذج التعلم الآلي وتم تطبيقها على بيانات معدل التضخم للفترة الزمنية الممتدة من 1990 إلى 2021 وهذا 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 هذه الدراسة سوف نتطرق إلى بعض الدراسات السابقة التي تناولت موضوع التضخم.

دراسة (ZARRA, 2009): هدفت هذه الدراسة إلى التنبؤ بمعدل التضخم في إيران باستخدام الشبكات العصبية الاصطناعية للفترة الزمنية من 1959 إلى 2007. الشبكة العصبية المطبقة عبارة عن طبقات متعددة باستخدام خوارزميات مختلفة للانتشار الخلفي. ومن أجل تقييم أداء الشبكة العصبية الاصطناعية، تم استخدام معايير خطأ التنبؤ. أظهرت النتائج أن أنسب الشبكات هي تلك القائمة على خوارزمية تدريب Levenberg- Marquard حيث 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 هذه الدراسة إلى 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

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيديش

خارج العينة، بينت النتائج ان نماذج ANN كانت في المتوسط مؤشراً أفضل للتضخم بنسبة 45٪ بينما كان أداء نموذج الانحدار الذاتي للنموذج الأول (AR1) أفضل بالنسبة لـ 23٪ من البلدان . وزيادة على ذلك تم بتطوير مجموعات حسابية للعديد من نماذج ANN ووجد أنها قد تكون أيضاً 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) قادراً 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 هذه 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 Backpropagation ونموذج الشبكة العصبية المتكررة (نموذج RNN) في ظل التنبؤات الثابتة والديناميكية على التوالي في هذه الدراسة في التنبؤ بمعدل التضخم. تتم أيضاً 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

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

البيانات التاريخية أحادية المتغير لمعدلات التضخم في البلاد من 1960-2017. أظهرت النتائج أن $ARIMA(1,0,0)$ ، هو أفضل نموذج مناسب مقارنة مع نماذج $ARIMA$ الأخرى. دراسة (Oyewale، 2019) : هدفت هذه الدراسة الى التنبؤ بمعدلات التضخم باستخدام النهج غير المعلمي (الشبكات العصبية الاصطناعية)، حيث تم استخدام ثلاث شبكات عصبية اصطناعية (Scaled ,Standard Backpropagation (SBP , 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 (de la 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 $MLPN(48,7,1)$ 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 $MLPNN$.

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيديش

دراسة (Işığık, 2020): هدفت هذه الدراسة الى التنبؤ بمعدلات التضخم المستقبلية بواسطة طريقتين بديلتين، وهي نماذج (ARIMA) Box-Jenkins 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) جنباً إلى جنب مع الذاكرة طويلة المدى (LSTM). تشير النتائج إلى أن النموذج المقترح المستند إلى مزيج من SARIMA و LSTM يتمتع بدقة أعلى في التنبؤ بالتضخم على SARIMA و LSTM بشكل منفرد.

تتمثل 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 الآلي.

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 MA في ARIMA) (Yee, 2021، صفحة 13).

ويأخذ نموذج الانحدار الذاتي من الرتبة $AR(p)$: الصيغة التالية (Nochai,

2006، صفحة 3)

$$y_t = \phi_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيديش

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

التوال

y_t هو المتغير التابع الذي يتم توقعه في الزمن t . $\phi_0, \phi_1, \dots, \phi_p$ تمثل

المعلومات المقدرة و ε_t هو حد الخطأ في الزمن t

نموذج المتوسطات المتحركة من الرتبة $MA(q)$: وتأخذ الصيغة التالية

$$y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

حيث تشير AR نموذج الانحدار الذاتي و MA الى نموذج المتوسطات المتحركة

وأخيرا I الى الفروقات، ولذلك لديها ثلاثة معلمات نموذجية

$AR(p)$ و $I(d)$ و $MA(q)$ و لتشكل نموذج $ARIMA(p, d, q)$ ، 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

$$y_t = \phi_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

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

$$INF_t = \phi_0 + \phi_1 INF_{t-1} + \phi_2 INF_{t-2} + \dots + \phi_p INF_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

حيث تمثل INF_t معدل التضخم.

ومن اجل تطبيق منهجية Box-Jenkins 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 الإشارة إلى عدد الاختلافات المطلوب

أخذها قبل أن تصبح السلسلة ثابتة بالحرف d 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 ثبات السلسلة (Suleiman S.، 2020، صفحة 84). فبعد التأكد من استقرارية السلسلة تأتي مرحلة تحديد المعلمات (p,q) ويتم ذلك عن طريق الرسم البياني لدالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي ومن اجل المفاضلة بين النماذج المرشحة يتم استخدام معيار AIC وBIC والتي تكتب كالآتي (Suleiman، 2018، صفحة 264):

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

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 ويتم اختيار ترتيب النموذج الأمثل من خلال عدد معلمات النموذج ، والتي تقلل معيار AIC. فبعد تحديد المعلمات تأتي مرحلة التقدير للنموذج المختار وهذا بالاعتماد طريقة الامكان الأعظم. وتلها مرحلة الفحص للنموذج المختار من اجل التأكد من مدى ملائمته وصلاحيته لتمثيل النموذج من خلال اخضاعه لعدة اختبارات مثل ليونغ - بوكس (Ljung-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

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

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):

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

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 وهذا عن طريق تحسين أوزان الشبكة وتحيز الخلايا العصبية.

تتألف بنية شبكة NAR من 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 تنوع الخلايا العصبية في الطبقة المخفية من خلال إنشاء نموذج طبقة واحدة مخفية باستخدام طبقات الإدخال

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

والإخراج وهذا من أجل تقدير معلمات الأداء. ويعتبر نموذج NAR مع أقل قيمة لمعيار MSE هو النموذج الأمثل للتنبؤ. وأخيرا 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 إلى 2021 وتتكون من 32 مشاهدة، تم الحصول على البيانات من البنك الدولي.

1.3. دراسة الإحصائية الوصفية لمعدل التضخم:

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

الجدول 1: الإحصائية الوصفية لمعدل التضخم

الاحصاءات	أعلى قيمة	أدنى 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 أدناه أعلاه أن أعلى قيمة لمعدل التضخم في الجزائر بلغت 31.66966 وأصغر قيمة كانت 0.339163، والمتوسط الحسابي لمعدل التضخم بلغ 8.559418، أما الوسيط والانحراف المعياري فبلغا على التوالي 4.654329، 9.179278، كما بلغ مقياس التفرطح والالتواء: 1.506134، 3.803783 على التوالي. كما نلاحظ أن مقياس التفرطح أقل من 3 مما يدل على أن منحني البيانات مفروط.

2.3. نماذج ARIMA :

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

الشكل 1: التمثيل البياني لمعدل التضخم في الجزائر



الجدول 2: نتائج اختبار ADF

المتغير	النماذج	القيمة المحسوبة	القيمة الاحتمالية	القرار
معدل التضخم	وجود ثابت فقط	-1.6405	0.4506	السلسلة غير مستقرة
	ثابت واتجاه	-1.7794	0.6903	
	بدون ثابت واتجاه	-1.4409	0.1368	

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش
الفروق الأولى

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

المصدر: من اعداد الباحثين

الجدول 3: نتائج اختبار PP

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

الفروق الأولى

المتغير	النماذج	القيمة المحسوبة	القيمة الاحتمالية	القرار
معدل التضخم	وجود ثابت فقط	-5.5653	0.0001	السلسلة مستقرة
	ثابت واتجاه	-5.9041	0.0002	
	بدون ثابت واتجاه	-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 جذر 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 مستوى المعنوية لكلا الاختبارين. ومنه فسوف يكون لدينا النموذج على شكل $ARIMA(p,1,q)$.

فبعد ثبات السلسلة تأتي اول مرحلة من منهجية Box-Jenkins وهي مرحلة التعرف على المعلومات q و p . بالاعتماد الرسم البياني لدالة الارتباط الذاتي ودالة الارتباط الذاتي

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

الجزئي، ومن أجل المفاضلة بين النماذج التي تعد مناسبة لتمثيل معدل التضخم سيقصر 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 الذي 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 كالآتي:

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


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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

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 درين واطسون (DW) لأن قيمتها قريبة جدا من (DW=1.98) 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.

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



المصدر: من اعداد الباحثين

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

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

3.3. الشبكة العصبية ذات الانحدار الذاتي غير الخطي NAR :

من أجل التنبؤ بمعدل التضخم بالاعتماد على الشبكة العصبية ذات الانحدار الذاتي غير 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.

الجدول 5 : 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 (2,6,1) NAR 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):

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


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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

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.

الشكل 3 : معمارية الشبكة العصبية ذات الانحدار الذاتي غير 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.

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

الشكل 4: الانحدار التدريبي للنموذج NAR (2,6,1)



المصدر: من اعداد الباحثين

يمثل الشكل أعلاه مخطط الانحدار للمجموعة التدريب والتحقق واختبار البيانات وكذلك 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 $[0 - 1]$. حيث يفضل القيم التي تكون الأقرب إلى واحد.

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش


فنلاحظ من خلال هذه 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 وكذلك 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).

الشكل 5: الأداء التدريبي للنموذج NAR (2,6,1)



المصدر: من اعداد الباحثين

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيديش

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 أداء 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 $MSE = 1.3608$ في عملية لتدريب.

المقارنة بين النماذج المستخدمة:

ومن اجل اختيار النموذج الانسب لاستخدامه للتنبؤ بمعدل التضخم، قمنا بالمقارنة بين النموذج ARIMA والشبكة NAR وهذا بالاعتماد على معيار متوسط مربع الأخطاء MSE ومعامل الارتباط R، والجدول 6 يبين نتائج المقارنة:

الجدول 6 : مقارنة بين دقة التنبؤ للنماذج المستخدمة للتنبؤ بمعدل التضخم

النماذج	معامل الارتباط R	معيار MSE
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) وهذا ما تبينه قيمة معيار MSE والتي تساوي 2.4229 وهي أصغر من قيمة نموذج ARIMA والتي تساوي 15.8554، نفس الشيء لمعامل الارتباط R حيث يعطي توقع NAR تنبؤاً أفضل وهي 0.961 اكبر من نموذج ARIMA. والشكل التالي يوضح نتائج القيم المتنبئ بها باستخدام نموذج NAR(2,6,1) مع القيم الفعلية لمعدل التضخم في الجزائر

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

الشكل 6: التضخم الفعلي مقابل التضخم المتوقع



المصدر: من اعداد الباحثين

نلاحظ من خلال الشكل 6 أن قيم التضخم المتوقع 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.

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

د. قهوي حسن أ.د. عبد القادر ساهد أ.د. محمد ميكيدش

ففي هذه الدراسة تم تقديم النتائج التي تم الحصول عليها من خلال البيانات السنوية لمعدل التضخم في الجزائر للفترة الزمنية الممتدة من 1990 إلى 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) NAR يعطي تنبؤات جيدة مقارنة مع نموذج (2,1,0) ARIMA، 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 ملائمة 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 وشبكة 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. Işığçok, 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 (IJE0E)*, 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*.