

التنبؤ بسعر الصرف الفوري للبيورو دولار في سوق (FOREX) استعمال المقارنة بين طريقة هولت والشبكات العصبية الاصطناعية

Forecasting the spot exchange rate of the Euro-dollar in the forex market using the comparison between the Holt method and artificial neural networks

<https://doi.org/10.29124/kjeas.1547.17>

مدرس/ انتصار إبراهيم الياس

قسم العلوم الإدارية / كلية الإدارة والاقتصاد/جامعة زاخو

Intisar_sulayman@yahoo.com

المستخلص:

تم في هذا البحث استعمال بيانات السلسلة الزمنية لسعر الصرف اليومي للبيورو أمام دولار لمدة من (15/12/2020 H:7 AM-10/12/2020 H:8 AM) بمجموع مشاهدات يبلغ (79) مشاهدة ، إذ تم الإبقاء على (120) مشاهدة للمقارنة مع قيم التنبؤ التي يتم الحصول عليها باستعمال الأسلوبين، لإجراء عملية المقارنة للتنبؤات المستقبلية لمدة من (15/12/2020 H:7 AM-10/12/2020 H:8 AM) بمجموع مشاهدات يبلغ (120) مشاهدة للتنبؤ بها. بين أنموذج التمهيد الأسّي المزدوج لطريقة هولت وأنموذج الشبكات العصبية الاصطناعية ذات التغذية الأمامية استعمال الخوارزميتين (خوارزمية الانتشار العكسي الزائدي، خوارزمية الانتشار السريع)، إذ تمتاز هذه الأساليب بدقة ومرنة عالية في عملية تحليل السلسلة الزمنية. وأظهرت نتائج التطبيق أنّ الأنماذج الأكفاء والأمثل لتمثيل بيانات السلسلة الزمنية هو أنموذج الشبكة العصبية الاصطناعية [1-10-2] استعمال خوارزمية الانتشار السريع لسعر الصرف اليومي للبيورو أمام دولار وفقاً لمعيار متوسط مربع الخطأ (MSE)، قد أعطت مؤشرات أقل من مؤشرات أنموذج الشبكة العصبية الاصطناعية [1-10-2] استعمال خوارزمية الانتشار العكسي التزايدية ، وأنموذج التمهيدي الأسّي المزدوج (طريقة هولت) عند استعمال ($a = 0.9$ و $b = 0.1$)، الأمر الذي يشير بوضوح بأنه الأنماذج الملائم والأكفاء لتقدير التنبؤات المستقبلية لمدة من (15/12/2020 H:7 AM-10/12/2020 H:8 AM). إذ أظهرت هذه القيم تناقضاً مع مثيلاتها في السلسلة الأصلية، وقدّمت لنا صورة مستقبلية لواقع لسعر الصرف اليومي للبيورو أمام الدولار لتلك المدة.

وقد قدّم أنموذج الشبكة العصبية الاصطناعية تنبؤات مستقبلية أفضل من تلك التي قدّمتها أنموذج التمهيد الأسّي المزدوج (طريقة هولت)، وفقاً لمعيار متوسط مربع الخطأ (MSE) ، وقد أعطى مؤشرات أقل من مؤشرات أنموذج هولت . وقد تم استعمال البرامج الإحصائية الجاهزة MinitabV18 في الجانب الإحصائي ، وبرنامج نظام الشبكات العصبية الجاهز ، والذي يُعرف Alyuda NeuroIntelligence في جانب الشبكات العصبية .

الكلمات المفتاحية: التمهيد الأسّي المزدوج (طريقة هولت)، الشبكات العصبية الاصطناعية ذات التغذية الأمامية ، سعر الصرف اليومي للبيورو أمام الدولار .

Abstract:

In this paper , the time series data of the daily exchange rate of the euro against the dollar were used for the period from (12/7/2020 H:1 AM-10/12/2020 H:7 AM) with a total of (79) Observations as (120) Observations for comparison with the forecast values obtained using the two methods, to make the comparison process for future forecasts for the period from (10/12/2020 H:8 AM- 15/12/2020 H:7 AM) with a total of (120) Observations. To predict them, between the double exponential smoothing model (Holt method) and the feed-forward artificial neural network model using the two algorithms (**Incremental Back Propagation algorithm**, **Quick Propagation algorithm**).These methods are characterized by high accuracy and flexibility of these methods in the process of analyzing the time series, the results of the application showed that the most efficient and optimal model for representing the time series data is the artificial neural network model [2-10-1] using the **Quick Propagation algorithm** for the daily exchange rate of the euro against the dollar according to the criterion The mean square error (MSE), has given lower indicators than the indicators of the artificial neural network model [2-10-1] using the **Incremental Back Propagation algorithm**, and the double exponential smoothing model (Holt method) when using ($\alpha =0.9$ and $\gamma= 0.1$), which clearly indicates that it is the appropriate and efficient model for estimating future forecasts for the period from (10/12/2020 H:8 AM- 15/12/2020 H:7 AM). Where these values showed consistency with their counterparts in the original series, and provided us with a future picture of the reality of the daily exchange rate of the euro against the dollar for that period. Therefore, the artificial neural network model provided better future predictions than those provided by the double exponential smoothing model (Holt method), according to the standard of mean square error (MSE), it gave less indicators than the indicators of the Holt model. The ready-made statistical programs MinitabV18 were used in the statistical side, and the ready-made neural network system program known as Alyuda NeuroIntelligence was used in the neural networks side.

Keywords: double exponential smoothing (Holt's method), feed-forward artificial neural networks, daily exchange rate of EUR/USD.

مقدمة Introduction

تُعد سوق (FOREX) من أضخم الأسواق العالمية سواءً أكان من ناحية قيمة التداول اليومي أم حجم المعاملات ، إذ يقدر حجم التداول اليومي في هذا السوق بنحو (5-6 تريليون دولار/يوم) ، وهذه القيمة الضخمة من التداول تهيمن عليها المضاربات في العملات المختلفة، ولاسيما العملات الأساسية، والتي تتقدمها سوق اليورو_دولار ، والتي تأخذ نصيباً واسعاً من التداول؛ نظراً لما تتمتع به هاتان العملاتان من دورٍ محوري في المدفوعات الدولية ، ويعتمد المضاربون في هذه السوق على التوقعات في تحديد خياراتهم في البيع والشراء. وهذه التوقعات على الرغم من العشوائية العالية التي تسير بها ، إلا أنها غالباً ما تكون مبنيةً على أساس علمية تعتمد على التحليلات الفنية والأساس وعلوم الإحصاء ونظرياته، ومع ذلك فإن 80-85% من المتداولين يحققون خسائر في هذه السوق والرابحون هم فقط 15%. وهذا يشير إلى حجم المخاطر العالية التي تكتفى مثل هذه السوق. والمخاطر هنا تكون حالة نسبية بين المضاربين، أي إنها تعتمد على قدرة كلّ منهم على التوقع لحركة السعر واتجاهه ، وعادةً ما تكون التوقعات أكثر دقة، كُلما كان هناك وقتٌ كافٍ لتحليل المعطيات، وعلى العكس من ذلك فإن حالات التوقع في المديات القصيرة واللحظية تكون في معظم الحالات غير دقيقة. يعتمد أغلب المضاربين أحدث ما توصلت إليه طرائق التنبؤ وتضمينها في إطار مؤشرات يمكن أن تساعد في تصويب التوقع أو تحسين دقتها، غالباً ما يعتمد نوع التنبؤ المستعمل على المدة الزمنية ونوع أزواج العملات للأزمة، للتنبؤ بها، إذ لكل زوج من العملات خصوصيته في الحركة. وعلى الرغم من حداثة سوق اليورو دولار إلا أنه أصبح اليوم المهيمن على أسواق الفوركس؛ لما تتمتع به العملاتان من دعم قوي واستقرار تفرضه السياسة النقدية للبلدان المصدرة لهاتين العملاتين. وتحتاج عمليات التنبؤ حركة سعر هذا الزوج من العمليات المعقّدة والصعبة، ولاسيما في الأجل القصير جداً. والبحث هنا يحاول إجراء دراسة مقارنة بين دقة طريقتين للتنبؤ، وهما: طريقة التمهيد الأسّي، وطريقة الشبكات العصبية، وباستعمال زوج اليورو دولار كحالة دراسية .

لذلك إن التنبؤ بحركة أسعار العملات يحتاج إلى دقة عالية قد لا تكون موجودة في الأنماذج التقليدي للتنبؤ ، والتي غالباً ما تعتمد على البيانات التاريخية وعلى الأنماذج الخطية، ويمكن هنا لأنماذج الحوسنة (الشبكات العصبية ، المنطق المضباب ، وغيرها)، والتي هي امتدادات للذكاء الصناعي، أن تكون أكثر فعالية وكفاءة في هذا المجال؛ لأنها تراعي عند التنبؤ العوامل الداخلية والخارجية مع قدرتها على التقرير اللاخطي المشتق من البيانات الأصلية.

(Kuo and Xue, 1999 : 128)

مشكلة البحث

يمكن صياغة إشكالية البحث في السؤال كالتالي:

- ما مدى قدرة أنماذج التمهيد الأسّي المزدوج (طريقة هولت) والشبكات العصبية الاصطناعية في صياغة أنماذج جيدة وملايين للتنبؤ؟

أهمية البحث

جاءت أهمية البحث بحالات عدّة نوجزها بالآتي:

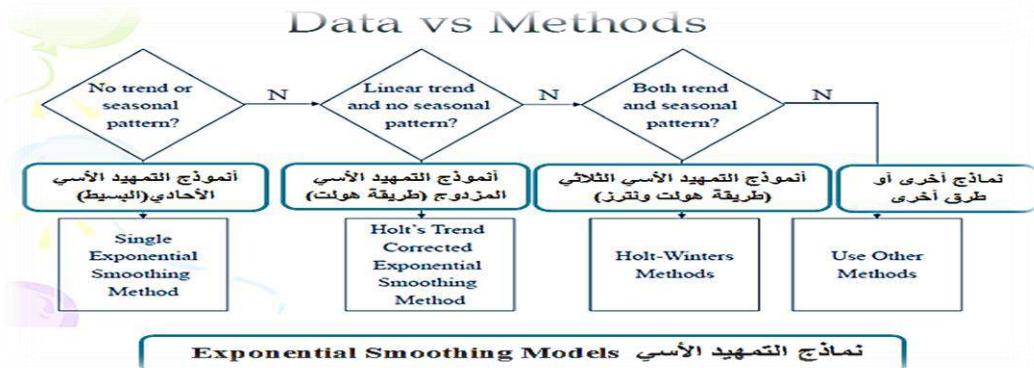
1. جاءت الأهمية في استعمال أنموذج التمهيد الأسّي المزدوج (طريقة هولت) للوقوف على الاتجاه العام للتنبؤ لمدة (5 أيام لـ (24) ساعة لشهر ديسمبر لعام 2020) من (H:8 AM-10/12/2020 H:7 AM-10/12/2020) لسعر الصرف اليومي للاليورو أمام الدولار، على بيانات السلسلة الزمنية لسعر الصرف اليومي للاليورو أمام الدولار، لمدة (4 أيام لـ (24) ساعة لشهر ديسمبر لعام 2020) من (H:7 AM-7/12/2020 H:1 AM-10/12/2020)، وكذلك في استعمال أنموذج الشبكات العصبية الاصطناعية ذات التغذية الأمامية استعمال الخوارزميتين (خوارزمية الانتشار العكسي الزائد (خوارزمية الانتشار الخلفي للخطأ Error Back-Propagation Algorithm ، أو خوارزمية الانتشار العكسي Back-Propagation Algorithm ، خوارزمية الانتشار السريع) ، من أجل الحصول على تنبؤات مستقبلية لسعر الصرف اليومي للاليورو أمام دولار لمدة من (H:8 AM-10/12/2020 H:7 AM-10/12/2020). ثمّ بعد ذلك إجراء مقارنة بينهما وفقاً لمعيار متوسّط مربع الخطأ (MSE)؛ لمعرفة القوة التنبؤية لأنموذج المستعمل؛ لأنّه المعيار الأكثر استعمالاً وشيوعاً لاختيار الأنماذج الأمثل والأكفاء الذي يعطي أقل قيمة لهذا المعيار واستعماله للتنبؤات المستقبلية.
2. وأخيراً جاءت أهمية البحث في إجراء مقارنة بين أنموذج التمهيد الأسّي وأنموذج الشبكات العصبية الاصطناعية ذات التغذية الإلأمامية (استعمال خوارزمية الانتشار السريع و خوارزمية الانتشار العكسي التزايدي)، من أجل الحصول على تنبؤات مستقبلية لسعر الصرف اليومي للاليورو أمام الدولار لمدة من (15/12/2020 H:8 AM-10/12/2020 H:7 AM). ولاختيار الأنماذج الملائم والأكفاء الذي يحقق أقل خطأ وفقاً لمعيار متوسّط مربع الخطأ (MSE)، سوف يتم الاعتماد على التنبؤات التي يقدمها هذا الأنماذج الملائم للتنبؤ بالقيم المستقبلية لسعر الصرف اليومي للاليورو أمام دولار لنتائج المدة .

هدف البحث

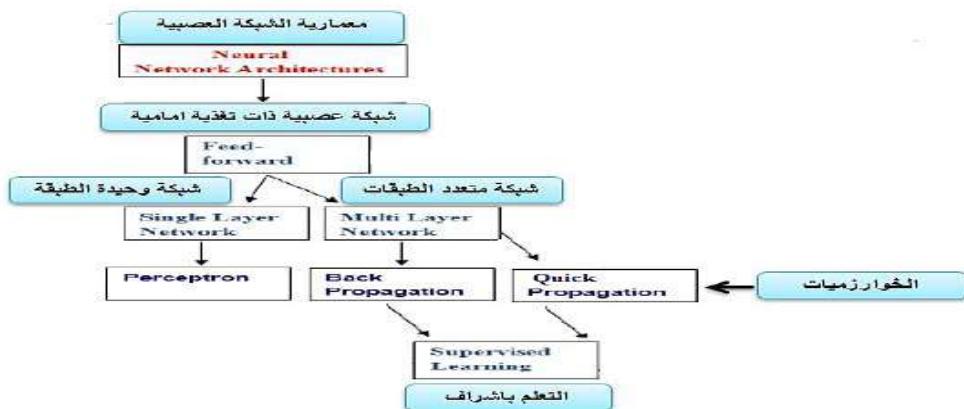
يهدف البحث إلى تحليل ومناقشة طريقي التنبؤ، ومن ثمّ الاختيار أو المفضلة بينهما، لبيان الاتجاه العام بالاعتماد على معالم التمهيد المثلّى واستعماله للتنبؤ بالقيم المستقبلية بالاعتماد على معايير الخطأ وفقاً لمعيار متوسّط مربع الخطأ (MSE). وأسلوب الشبكات العصبية الاصطناعية ذات التغذية الأمامية، واستعمال الخوارزميتين (خوارزمية الانتشار العكسي الزائد(خوارزمية الانتشار الخلفي للخطأ Error Back-Propagation Algorithm ، أو خوارزمية الانتشار العكسي Back-Propagation Algorithm ، خوارزمية الانتشار السريع) ، من أجل الحصول على تنبؤات مستقبلية لسعر الصرف اليومي للاليورو أمام دولار لمدة من (15/12/2020 H:7 AM-10/12/2020 H:8 AM)، وفقاً لمعيار متوسّط مربع الخطأ (MSE).

أنموذج البحث

تم تصميم أنموذج افتراضي للبحث كما في الشكل (1)؛ لمعرفة مدى استعمال كلّ أنموذج من نماذج التمهيد الأسّي وأنموذج الشبكات العصبية ذات التغذية الإلأمامية ، بهدف الحصول على تنبؤات مستقبلية ذات دقة عالية وفقاً لمعيار متوسّط مربع الخطأ (MSE).



الشكل (a) أنموذج البحث الافتراضي (أنموذج التمهيد الأسني)



الشكل (b) أنموذج البحث الافتراضي (عمارية الشبكة الاصطناعية)

الشكل (1): أنموذج البحث الافتراضي للمقارنة بين أنموذج التمهيد الأسني وأنموذج الشبكات العصبية ذات التعذية الأمامية

المصدر: من إعداد الباحثة.

6- فرضية البحث

ينطلق البحث من فرضيات عدّة أساس مفادها :

- ❖ تفترض النظرية الإحصائية أن أنموذج التمهيد الأسني المزدوج (طريقة هولت) تستعمل في حالة السلسلة الزمنية المحتوية على مركبة الاتجاه العام غير الموسمي (الللوسي ، الوكيل وحسين ، 2008 : 138). وتُعد هذه الطريقة من أنساب الطرائق التنبؤ استعمال السلسلة الزمنية، ولا سيما التي تتميز باتجاه عام متزايد أو متناقص (الحتو والهبيل ، 54:2017).
- ❖ يسمح أنموذج التمهيد الأسني المزدوج بتحقيق دقة التنبؤ، بالإضافة على النظرية الإحصائية المذكورة آنفا.
- ❖ يسمح أنموذج الشبكات العصبية الاصطناعية ذات التعذية الأمامية بتحقيق دقة التنبؤ، بهدف الحصول على تنبؤات مستقبلية ذات دقة عالية.
- ❖ ترتبط الأفضلية بين أنموذج التمهيد الأسني المزدوج (طريقة هولت)، وأنموذج الشبكات العصبية الاصطناعية ذات التعذية الأمامية بدقة التنبؤ.

منهجية البحث

يُعد هذا البحث مزيجاً بين المنهج الوصفي التحليلي في الجانب النظري ، ومنهج دراسة الحالة في الجانب التطبيقي . ولذلك تم تقسيم البحث على جانبين هما: الجانب النظري والذي تطرق بشكل مبسط إلى تطور سعر صرف اليورو دولار خلال المدة السابقة ، وطريقنا التنبؤ التي سوف يجري المفاضلة بينها، وهي طريقة التمهيد الأسّي المزدوج (طريقة هولت)، والشبكات العصبية الاصطناعية. مقاييس دقة التنبؤ(معايير الخطأ) ، وأسلوب الشبكات العصبية الاصطناعية ذات التغذية الأمامية استعمال الخوارزميتين (خوارزمية الانتشار العكسي الزائد) (Online) **Quick Propagation algorithm** (Incremental Back Propagation algorithm)، خوارزمية الانتشار السريع (Quick Propagation algorithm). أما الجانب التطبيقي فقد تم فيه إجراء دراسة تطبيقية (دراسة الحالة) على بيانات واقعية لسعر الصرف اليومي للاليورو أمام دولار للمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM)، للوصول إلى نموذج رياضي ملائم للتنبؤ المستقبلي للمدة من (10/12/2020 H:7 AM - 10/12/2020 H:8 AM). وقد ختم البحث ببعض الاستنتاجات والمقررات والمصادر. أما الأدوات المستعملة في الجانب التطبيقي فهي: البرامج الإحصائية SPSSV17 و MinitabV18 في الجانب الإحصائي ، وبرنامج نظام الشبكات العصبية الجاهز والذي يُعرف بالجاهزة Alyuda NeuroIntelligence في جانب الشبكات العصبية .

الجانب النظري

1: تطور سعر صرف اليورو دولار للمدة السابقة

1-1: النشأة التاريخية للدولار والاليورو:

في عام 1785 تم إعلان الدولار كعملة للولايات المتحدة الأمريكية US dolla ، ولكن سُكَّ هذه العملة تأخر حتى عام 1792 . وفي عام 1862 أصدرت وزارة الخزانة الأمريكية الدولار الورقي باللونين الأسود والأخضر من أجل تجنب التزيف، ومنذ تلك المدة ظهر الدولار في العالم، والذي تطور لما بعد الحرب العالمية الثانية ليصبح العملة القيادية الدولية الأولى ، ويدار الدولار من قبل الاحتياطي الفدرالي الأمريكي.

أما فيما يتعلق بالاليورو Euro وهو عملة الاتحاد الأوروبي والذي يضم 19 دولة ضمن منطقة العملة الأوروبية، والذي يدار من قبل البنك المركزي الأوروبي، فبدء استعمال اليورو على النطاق المتصافي منذ عام 1999 ، في حين أصبح بديلاً عن عملات الدول الداخلة في الاتحاد النقدي الأوروبي منذ عام 2002 ، ويشكّل اليورو اليوم ثاني أهمّ عملة قيادية على المستوى الدولي .

على العموم يلاحظ أنّ الدولار الأمريكي أقدم بكثير من اليورو، وهو إلى اليوم أكثر أهمية منه في التداولات والاحتياطات الدولية .

1-2: الأهمية النسبية للعملتين في النظام النقدي الدولي:

يُعدّ الدولار الأمريكي العملة الدولية الأكثر أهمية، يليه في ذلك اليورو، ثمّ الين الياباني. والشكل رقم (1) يشير إلى الأهمية النسبية لهذه العملات من خلال المؤشرات الدولية المتعلقة بـ: (الاحتياطات الأجنبية ، والديون ، والائتمان ، والدوران ، والمدفوعات)، نلاحظ من الشكل أنّه ووفقاً لإحصاءات الرابع الأخير من عام 2019 أسهم الدولار الأمريكي بنسبة تقدر بـ (60%) من الاحتياطات الدولية Foreign exchange reserves (أي أنّ 60% من احتياطات البنوك

المركزية للدول، هي بالدولار الأمريكي). في حين أسهم اليورو بنسبة (20%) منها ، أما الدين الياباني فسجل نحو (2%).

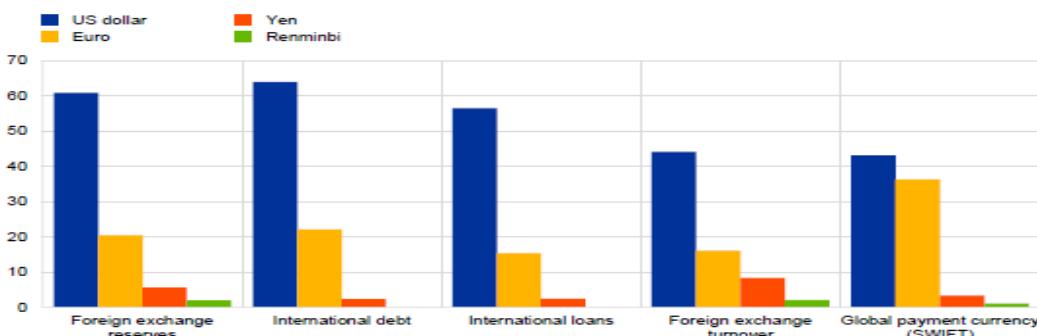
وبالانتقال للدين العالمي International debt نلاحظ أن الدولار أسهم بنسبة (64%) من الدين العالمي، في حين أسهم اليورو بنسبة (22%) منه. أما الدين الياباني فأسهم بنسبة (2%) فقط.

أما فيما يتعلق بالقروض الدولية فإن نسبة (58%) منها قيمة بالدولار الأمريكي ، في حين قيمة نسبة (16%) منها باليورو ، وقيمة نحو (2%) بالدين الياباني .

وبالتحول نحو مؤشر دوران الصرف الأجنبي يلاحظ أن دوران الدولار سجل نسبة (45%) من دوران الصرف الأجنبي على المستوى العالمي ، أما اليورو فسجل نسبة (17%) منه ، وسجل اليورو النسبة الأقل وهي حوالي (2%) من مؤشر الدوران .

وفيما يخص المؤشر الأخير والمتمثل بعملات الدفع العالمية أسهم الدولار بنسبة (43%) منه ، في حين أسهم اليورو بنسبة (37%) من هذا المؤشر ، أما الدين الياباني فأسهم بالنسبة الأقل، وهي (2.5%) منه .

على العموم ومن خلال المؤشرات الخمسة الآتية الذكر نلاحظ أن الدولار ما زال يهيمن على التداولات النقدية الدولية، وبنسبة عامة تصل إلى نحو 60% منها. ويأتي اليورو بالمرتبة الثانية، وبنسبة عامة تقدر بـ (18-20%) ، والجدير بالذكر هنا أن اليورو يقترب من الدولار كثيراً عندما يتعلق الأمر بأدوات الدفع الدولية، وهذا الموضوع يؤشرحقيقة تنامي دور اليورو كعملة دفع دولية ، علما أن كل المؤشرات فيما يتعلق بالدولار وأهميته قد تراجعت بشكل كبير مع ظهور اليورو في بداية الألفية الثانية.



الشكل (2): الأهمية النسبية للدولار واليورو كأدوات احتياط ودين ودفع دولية

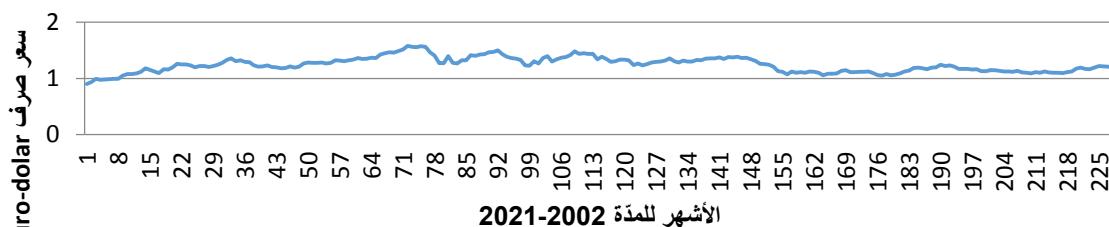
Sources: European Central Bank, 2020 , The international role of the euro, Statistical annex

3-1: تحليل اتجاه سعر صرف اليورو دولار للفترة السابقة

منذ ظهور اليورو كان منافساً قوياً للدولار الأمريكي، لذلك فالعملتان تهيمنان على نحو 80% من الأسواق المالية الدولية. ومن خلال الشكل رقم (2) نلاحظ أن أول سعر صرف لليورو أمام الدولار(سعر الافتتاح) سجل في بداية شهر أبريل عام 2002 وهو (0.8711)، وهو أدنى سعر لليورو أمام الدولار منذ بدء إصدار اليورو، إذ لم يرجع اليورو إلى هذا السعر إلى اليوم ، ومن الواضح هنا أنه ومع مرور الزمن بدأ اليورو بتحقيق المزيد من المكاسب على حساب الدولار؛ نظراً لتزايد ثقة الأفراد والمؤسسات والدول به، ولاسيما أنه كان مدعوماً بالاقتصاد الأوروبي المتقدم، وعلى هذا

الأساس استمر اليورو بالتصاعد أمام الدولار حتى وصل إلى أعلى قيمة له في شهر مارس 2008 ، إذ سجل سعر صرف (1.6036) ، وكما موضح في الشكل (2) ، ثم بدأت قيمة اليورو أمام الدولار بالتراجع بعد هذا التاريخ حتى وصلت إلى (1.0516) ، وذلك في شهر ديسمبر عام 2016 ، ومن الواضح هنا تأثير أزمة ديون اليونان والمفاوضات حول خروج بريطانيا على هذا الاتجاه التنازلي لقيمة اليورو، كذلك فإن المؤشرات الجيدة للاقتصاد الأمريكي أسهمت في هذا الاتجاه ، ثم عاود سعر صرف اليورو التحسن أمام الدولار للمرة اللاحقة، ولكن ظلّ يدور ضمن معدل (1.0560 - 1.260) ، ومنذ بداية عام 2021 وإلى النهاية شهر مارس فإن سعر اليورو دولار مستمر عند معدل يفوق (1.2) ، على العموم فإن المعدل العام لسعر صرف اليورو دولار منذ عام 2002 هو (1.2435) وهذا يعني أن قيمة اليورو بقيت محافظة على التفوق القيمي عن الدولار طوال المدة السابقة.

الشكل (3) سعر صرف اليورو دولار الشهري للمدة 2002-2021



المصدر : من إعداد الباحثة بالاعتماد على :

IMF , INTERNATIONAL FINANCIAL STATISTICS .

<https://www.imf.org/en/Home>

2:آلية التنبؤ باستعمال أنموذج التمهيد الأسّي المزدوج (طريقة هولت) والشبكات العصبية الاصطناعية

يُعد التنبؤ من الأساليب العلمية المهمة المستعملة في عمليات التخطيط للمستقبل ومجالات اتخاذ القرار. ويعرف التنبؤ بصورة عام بأنه تقدير قيم السلسلة الزمنية محل الدراسة في المستقبل . تعتمد مسألة التنبؤ بقيمة الظاهرة في المستقبل على التغيرات التي حدثت عليها في الماضي. واعتماداً على هذه التغيرات يمكن توقيع (تنبؤ) القيمة المستقبلية للظاهرة في المدة المعينة القادمة على افتراض أن التغيرات سوف تأخذ نمطاً (مساراً) معيناً في المستقبل على ضوء ما حدث في الماضي (الحتو، 19:2017) ، وسنحاول إعطاء صورة عن آلية عمل أنماذجين مهمين من النماذج التنبؤية والتي تُعد من الأنماذج المستعملة حالياً بشكل واسع ومتازت في اتجاه التطوير وهذين النماذجين ،هما كما يأتي :

1-2: أنموذج التمهيد الأسّي (ESM)

تشير المعطيات التاريخية إلى أن بداية اكتشاف أسلوب التمهيد الأسّي Exponential Smoothing كانت في عام 1958 من قبل عالم الإحصاء C.C.HOLT . وفي عام 1960 أجريت تطويرات مهمة في هذا النموذج من قبل P.R.WINTERS والذي هو تلميذ HOLT ، من خلال إدخال معامل ثالث يُمثل الموسمية (TAYLOR , 2003) . والتمهيد الأسّي هو من الأنماذج الإحصائية الاستدلالية التي تسعى لمعالجة الأخطاء العشوائية والتشویش من خلال صقل البيانات أو تتعيمها (Smoothing Data) التي تعاني من التشويش ، فضلاً عن تقليل القيم المفقودة، وهذا

الهدف مهم جدًا من أجل تحقيق الأمثلية في الإحصاء، وتقليل الأخطاء في الأنماذج (الطائي والكوراني ، 2008 : 173).

يُعدًّا أنماذج التمهيد الأسّي (Moving MA Average) أحد أشكال الطرائق المتوسطات المتحركة (MA)، ولكن الاختلاف بينهما يكمن في أنَّ المتوسطات المتحركة (MA) تعتمد على أوزان متساوية لقيم السلسلة الزمنية، في حين أنَّ أنماذج التمهيد الأسّي (ES) يعطي أوزان ترجيحية، بحيث تكون للبيانات الحديثة أوزان أكبر من البيانات الأقدم، فضلاً عن أنَّها تعتمد على الخطأ في التنبؤ في المُدد السابقة، وهذا يُعدُّ أكثر منطقية، ويتوافق مع الهدف من التنبؤ، هذه الميزة جعلت هذه الأنماذج أكثر دقة واعتمادية، وأكثر استعمالاً في الواقع العملي، وذلك بالمقارنة بأنماذج المتوسطات المتحركة (MA) (سليمان، 2010: 3).

ويتضمن أنماذج التمهيد الأسّي ثلاث طرائق رئيسة، يعتمد استعمال كلٍّ منها على طبيعة البيانات المستعملة، فعندما تكون سلسلة البيانات مستقرة يُتم اللجوء إلى طريقة التمهيد الأسّي الأحادي، والتي تميز بالاستجابة التكيفية ، أما عندما تكون البيانات ذات نمط خطّي فيتم الاعتماد على الطريقة الخطّية HOLT ، (أو ما يُسمى بطريقة التمهيد الأسّي المزدوج (طريقة هولت))، ولكن حين يظهر النمط الموسمي في البيانات تصبح الطريقة السابقة غير فعالة؛ لذلك يُتم اللجوء إلى طريقة هولت ونترز HOLT-WINTERS ، أو ما يُسمى بطريقة التمهيد الأسّي الثلاثي (Chusyairi, 2017:40). سيتناول أنماذج البحث توضيحاً لأنماذج الرياضي للطريقة الآتية:

1-1-2: أنماذج التمهيد الأسّي المزدوج (طريقة هولت)

Double Exponential Smoothing Model (Holt's Method)

وهي طريقة خاصة ومكيفة للسلسلات الزمنية المحتوية على مركبة الاتجاه العام غير الموسمي (الألوسي ، الوكيل وحسين، 2008 : 138). وتُعدُّ هذه الطريقة من أنساب طرائق التنبؤ لاستعمال السلسلات الزمنية، ولاسيما التي تتميز باتجاه عام متزايد أو متناقص. وتتصف هذه الطريقة بأنَّها تعطي أوزاناً كبيرة لقيم القريبة في السلسلة الزمنية، وأوزاناً أقل لقيم بعيدة، ويتم ترجيح المشاهدات البعيدة. وتتميز هذه الطريقة مقارنة بالتمهيد الأسّي البسيط أنَّه يمكن من خلالها التنبؤ لأكثر من قيمة واحدة. لذا تُعدُّ من أكثر الطرائق التقليدية تداولاً وشيوعاً من الناحية العملية، إذ إنَّ أغلب البرامج الجاهزة لأنماذج التمهيد الأسّي تشمل عليها دون غيرها (الحتو والهبيل ، 2017:54).

وتشمل هذه الطريقة أيضاً بطريقة HOLT ، واستعمال بشكل واسع في التنبؤات الاقتصادية ، ويمكن من خلالها توقع (التنبؤ) القيم ومراقبة الاتجاه العام ، ويتم اللجوء إليها في حال كانت السلسلة تعاني من الاتجاه العام . إنَّ التمهيد وفقاً لهذه الطريقة هو مشابهة للطريقة الأولى لكنَّه لا يستعمل معادلة التمهيد الضربي، إذ يُتم التعويض عنها من خلال الاستعمال المباشر لقيم النزعة، وهذا الأسلوب يجعل من التنبؤ أكثر مرونة، إذ يُتم تمديد النزعة من خلال معلومة أخرى غير معلومة السلسلة الرئيسية، لذلك يكون لدينا وفقاً لهذه الطريقة نموذجان: الأول: يعالج المستوى، وهو خاص بالعشوانية α (يُمثل Level) والثاني: يعمل على معالجة الاتجاه العام.

γ (يُمثل Trend) (Maia and de Carvalho , 2011 : 740-759).

هذه الطريقة تتكون من معادلتين وثابتي تمهيد (معامل التمهيد Smoothing Parameters ، أو أوزان الترجيح Weights)، ويطلق عليهما (ألفا)(α) وكاما (γ) أحدهما خاص بالعشوائية، وهي (α تُمثل Level) والأخرى بالاتجاه العام وهي (γ تُمثل Trend) (مصطفى، يوسف وتوفيق، 2022:33). وإنَّ قيمها محصورة بين [0,1]. الصفر [0] يعني أنَّ النمط بُني على قيم السلسلة جميعها بشكلٍ متساوٍ (عبارة أخرى تعني أنَّ القيم السابقة جميعاً أعطيت وزناً متساوياً في التوقع للمستقبل)، وواحد [1] يعني أنَّ النمط بُني فقط على القراءات الأخيرة في السلسلة (يعني أنَّ القيمة المتوقعة حسبت على أساس آخر قيمة في السلسلة) (أحمد، فضل وآدم، 2014:28)، (Marpaung, Salim and Kahraman and Akay, 2022:2)، (Yonar, Yonar, Tekindal and Tekindal, 2020:162)، (Kahraman and Akay, 2022:2)، (Amri, 2019:172).

هناك أنموذجان للتمهيد الأسّي المزدوج (DES)، وسنعتمد في هذا البحث على أنموذج هولت (Holt's Method). يشتق هذا الانموذج كالتالي: (برى ، الجوري ، 2002: 231)، (برى ، الجوري ، 2010: 46-47)، (محمود وإبراهيم Kahraman and Akay, 2022:2)، (Yonar, Yonar, Tekindal and Tekindal, 2020:162)، (7:2022، لمشاهدات ($x_1, x_2, \dots, x_{n-1}, x_{n-2}$) ولثابتي تمهيد $0 < \alpha < 1$ و $0 < \gamma < 1$ نجد الآتي:

$$s_t = \alpha x_t + (1 - \alpha)(s_{t-1} + b_{t-1}), \quad t = 1, 2, \dots, n \quad (1)$$

$$b_t = \gamma(s_t - s_{t-1}) + (1 - \gamma)b_{t-1}, \quad t = 1, 2, \dots, n$$

نحسب القيم المطبقة من

$$\hat{x}_t = s_t + b_t t, \quad t = 1, 2, \dots, n \quad (2)$$

والتنبؤات القيمة المستقبلية من

$$x_n(l) = s_n + b_n l, \quad l > 0 \quad (3)$$

نحسب القيم الأولية (الابتدائية) s_0 و b_0 من

$$s_0 = x_1 \quad (4)$$

$$b_0 = (x_2 - x_1) \quad or$$

$$b_0 = \frac{(x_2 - x_1) + (x_3 - x_2)}{2} = \frac{(x_3 - x_1)}{2} \quad or \quad (5)$$

$$b_0 = \frac{b_0 = (x_2 - x_1) + (x_3 - x_2) + (x_4 - x_3)}{3} = \frac{(x_4 - x_1)}{3}$$

إذ إنَّ :

x_t : تُمثل القيمة الحقيقية عند الزمن t .

a : تُمثل تمهيد المتوسط مع معامل التمهيد a .

γ : تُمثل تمهيد الاتجاه العام مع معامل التمهيد γ و $l = 1, 2, 3, \dots$ طول مسافة التنبؤات إذ أنَّ ...

1-1-2-1: مقاييس دقة التنبؤ (دقة التوفيق أو معايير الخطأ)

هناك مقاييس عدّة يمكن من خلالها المقارنة بين الأنماذج المستعمل للتنبؤ بالسلسل الزمنية، كُلّما كانت هذه المقاييس ذات قيمة قليلة، دلّ هذا على اقتراب القيم المُتنبأ بها من القيم الحقيقية، ومن أهمّ هذه المقاييس: (سليمان،2007:387)،(البيرمانى وأرشيد ،2019:85)، (محمود وإبراهيم،2022:9)، AL : (Kahraman and Akay,2022:5 (Rahamneh,2017:1545)

1. متوسط النسبة المطلقة للخطأ Mean Absolute Percentage Error (MAPE)

ويمكن إيجاده بالصيغة الآتية:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{e_t}{x_t} \right|}{n} \times 100, \quad x_t \neq 0 \text{ where } e_t = x_t - \hat{x}_t \quad (6)$$

Mean Absolute Deviation (MAD)

2- متوسط القيم المطلقة للخطأ

ويمكن إيجاده بالصيغة الآتية:

$$MAD = \frac{\sum_{t=1}^n |e_t|}{n} \quad (7)$$

3 متوسط مربعات الخطأ

Mean Square Error (MSE) or Mean Square Deviation(MSD)

ويمكن إيجاده بالصيغة الآتية:

$$MSD \text{ or } MSE = \frac{\sum_{t=1}^n (e_t)^2}{n} \quad (8)$$

إذ إنَّ:

x_t : تمثّل القيمة الحقيقية للسلسلة الزمنية عند المدة الزمنية t .

\hat{x}_t : تمثّل القيمة المُتنبأ بها للسلسلة الزمنية عند المدة الزمنية t .

e_t : تمثّل مقدار الخطأ في التنبؤ عند المدة الزمنية t .

n : تمثّل حجم العينة أو عدد المشاهدات الفعلية.

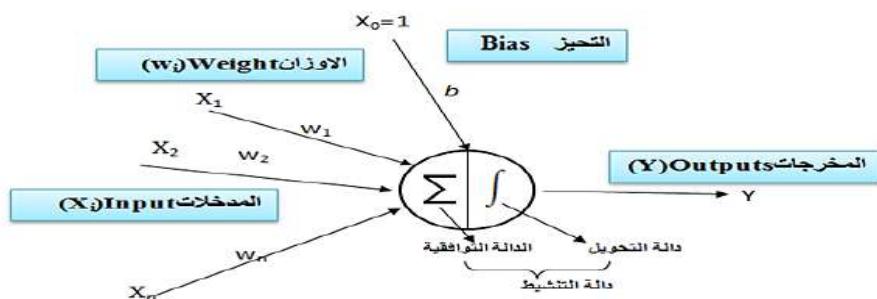
ويستعمل المقياس (3) لمعرفة القوة التنبؤية لأنماذج المستعمل؛ لأنّ المقياس الأكثر استعمالاً وشيوعاً لاختيار الأنماذج الأمثل والأكفاء الذي يعطي أقلّ قيمة لهذا المقياس واستعماله للتنبؤات المستقبلية.

2-2: الشبكات العصبية الاصطناعية Artificial Neural Networks(ANNs)

تُعدُّ الشبكات العصبية الاصطناعية (ANNs) من أهمّ الطرائق المرنة التي لديها القدرة على التعلم الذاتي السريع، وسرعة التغيير في البيئة الديناميكية. وذلك من خلال قواعدها الخاصة، ووفق منهجية محدّدة، وتعزيز هذا المنهج عبر التدريب (التعلم) بطريقة تحاكي فيها عمل الخلايا العصبية الدماغية من حيث بنيتها (هيكليتها أو معماريتها) ومعالجتها للمدخلات (السودافي والحجاج،2013:577).

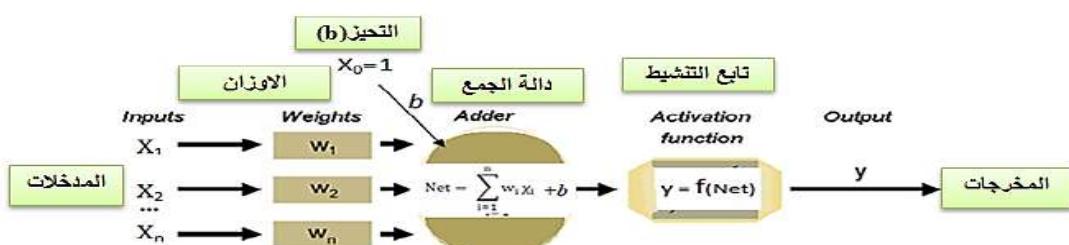
1-2-2: مفهوم الشبكات العصبية

إن أساس فكرة ANN يأتي كأسلوب محاكاة لعمل الخلايا العصبية الباريلوجية الموجودة ضمن منظومة عقل الإنسان، والتي يُتم استعمالها في ظل قواعد تدريب معينة ، لذلك ثُرِّفَ ANN بأَنَّهَا: أنظمة لمعالجة المعلومات تعتمد على أنموذج رياضي تمكّنها من تحويل المدخلات من البيانات إلى نتائج وُمُخرجات مفيدة (صليف و مطر ، 2019 : 59) ، وتوجد أنواع مختلفة من الشبكات. ولكن المكونات الأساسية جميعها هي مجموعة من العقد (العصيّونات) nodes ، والوصلات (الترابط) connections بين العقد، والعقد عبارة عن وحدات معالجة أو وحدات حسابية تتلقى المدخلات وتعالجها للحصول على المُخرجات، والمعالجة قد تكون بسيطة جداً (مثل جمع المدخلات)، أو معقدة جداً (مثل ارتباط العقد بشبكة أخرى) ، وتحدد الوصلات انتقال المعلومات والإشارات بين العقد التي قد تكون باتجاه واحد أو باتجاهين. وتستعمل ANN لنماذج مجموعة واسعة من الطواهر: الفيزيائية ، والكميائية ، والسلوكية ، والرياضية ، والاقتصادية وغيرها. على العموم هناك عملية تجريد شديدة عند بناء الشبكات العصبية الاصطناعية عمّا موجود في الشبكات الحيوية ، إذ تربط المدخلات بمشابك الوصلات (الترابطات) التي تحدّد قوّة الإشارة التي ستحفز المعالجات الرياضية في العقدة أو العصيّون ، وكما موضح في الشكل الآتي (Idown, 2012, 70):



الشكل (4): خلية (عقدة أو عصبون) الشبكة العصبية

Source :Idown, P. A., Osakwe, C., Kayode, A. A., and Adagunodo, E. R.(2012). "Prediction of Stock Market in Nigeria Using Artificial Neural Network", Published Online October 2012 in MECS (http://www.mecspress.org/) , PP.68-74.



الشكل (5): مخطط العمليات الكاملة للخلية (العقدة أو للعصيّون) العصبية الاصطناعية

المصدر: من إعداد الباحثة .

2-2: البنية الهندسية للشبكة العصبية الاصطناعية

يقصد بالبنية الهندسية (معمارية أو هيكلية) للشبكة العصبية الاصطناعية ترتيب العقد (العصيونات) في مستويات أو طبقات، ونوع الترابط ضمن الطبقات (المستويات) أو بينها. وتحدد من أهم المميزات التي توصف على أساسها الشبكة العصبية الاصطناعية (صلياوا و مطر ،2019:60).

هناك تصنيفات متعددة للشبكات العصبية إذ يمكن تصنيفها حسب الطبقات (Layers) أو المستويات (Levels) إلى :

1- الشبكات الوحيدة المستوى. Single Level Network

وهي نوع من الشبكات البسيطة التي تتضمن طبقتين فقط ،هما: طبقة المدخلات input ، وطبقة المخرجات output ، أي أن هذا النوع ليس فيه طبقات مخفية hidden layer ، وأقرب مثال لهذا النوع هي شبكة Hopfield، وسميت هذه الشبكات بوحيدة المستوى أو الطبقة؛ لأن حساباتها كلها يتم إجراؤها في طبقة المخرجات، وليس هناك أي دور حسابي لطبقة المدخلات .

2- الشبكات المتعددة المستويات . Multi level Network

وهذا النوع من الشبكات يمتاز باحتوائه على طبقات متعددة، أي أنه يتضمن طبقة مخفية واحدة أو أكثر يمكن أن تساعد في معالجة البيانات. وعلى الرغم من بُطء هذا النوع في عمليات المعالجة إلا أن له ميزة مهمة، وهي قدرته على تقديم الحلول المثلثة للمشكلات الأكثر تعقيداً، وأحسن مثال على هذا النوع شبكات التغذية الأمامية.

ويمكن تقسيم ANN من خلال نوعية الارتباط بين العصيونات إلى (Cortez , 2013 : 149):-

1- الشبكة العصبية ذات التغذية الأمامية . Feed Forward Neural Networks

وهي نوع من الشبكات التي لا تدخل وحداتها في ارتباطات ضمن حلقات مغلقة ، وتكون من طبقتين على أقل تقدير، وفي معظم الأحيان تتوارد فيها طبقات مخفية تكون متضمنة في طبقة المدخلات أو المخرجات، والعمليات الحسابية في مثل هذه الشبكات تنتقل باتجاه واحد نحو الأمام من الطبقات المخفية وإلى المدخلات والمخرجات .

2- الشبكات العصبية ذات التغذية العكسية . Feed back Neural Networks

هذا النوع من الشبكات له قابلية إعادة الإشارات الخارجية وتحويلها إلى إشارات داخلة ، أي أن مخرجات أي وحدة تعتمد على مدخلاتها وعلى مخرجاتها السابقة ، والمثال على هذا النوع هي شبكة Elman (Sahoo , 2015 : 211).

3- الشبكات المكررة . Recurrent networks

ضمن هذا النوع من الشبكات نتائج العصيونات الحالية تعتمد على المخرجات السابقة للعصيونات ذاتها ، وهذا النوع يطلق عليه الشبكات الديناميكية، وهي التي تكون مخرجاتها الحالية مرتبطة بالمدخلات الحالية والسابقة، والمثال عليها شبكات Hopfield and Elman and Jordan .

4- الشبكات العصبية ذات الترابط الذاتي . Auto Associative Neural Networks

وهي نوع من الشبكات يمتاز بقدرته على استقبال المدخلات وبث المخرجات في الوقت ذاته .

3-2: آلية معالجة البيانات داخل الشبكة

تتم عملية الاتصال بين العصيونات داخل الشبكة من خلال الوصلات التي تأخذ أوزانا معينة ، ومن ثم يضرب دخل العصيون مع الوزن ، وبعد ذلك تخضع نواتج الضرب لتوابع تحويل مختلف حسب نوع العصيون، علماً أن ناتج

التحويل هو الذي يمثل المخرج الذي ينتقل إلى عصبون الطبقة اللاحقة، وعليه فإنّ وحدة المعالجة في الشبكة العصبية الاصطناعية (ANN) والتي تتمثل في العصبون (العقدة أو الخلية) تتألف من العناصر الأساسية : (Zimbra , 2004 : 451)

أولاً: معاملات الأوزان Weight Coefficients

تُمثل هنا عن قوة الارتباط بين العنصر السابق واللاحق، وهي أداة انتقال المعلومات بين الطبقات، ومن خلالها يتم تعلم أو تدريب الشبكة وعادة تؤخذ الرموز الآتية بين عناصر الشبكة (W_{in} , W_{i1} , W_{i2} , W_{i3} , ...).

ثانياً: دالة الجمع Summation Function

تعد أول معالجة يقوم بها العصبون (الخلية)، والتي يتم من خلالها جمع إشارات الدخل الموزون عن طريق حساب معدّلات الأوزان لوحدات المعالجة مع ضرب قيمة كلّ مدخل مع الوزن المصاحب، وكما يأتي :

$$S_i = \sum_{i=1}^n X_i W_{ij} \quad (9)$$

إذ إنَّ

S_i : تمثل محصلة الجمع لوحدة المعالجة .

X_i : تمثل قيمة المدخل القائم من الوحدة i إلى الوحدة j .

W_{ij} : تمثل الوزن الذي يربط الوحدتين.

و عند إضافة وحدة التحيز أو الانحياز (Bias) إلى وحدات الإدخال فإن دالة الجمع تصبح كالتالي(عيسى ، 2000: 53) و (السعيد، ابتسام، فاطمة، امانيونورية، 2022: ٢٢)

$$S_i = \sum_{i=1}^n X_i W_{ij} + b \quad (10)$$

إنَّ قيمة الانحياز أو التحيز (Bias) تعد أحد مكونات الإدخال، إذ قيمة دخلها ($X_0 = 1$) ، وعملها مشابها لعمل أوزان الترابطات أو الوصلات القادمة من الوحدات التي قيم إخراجها واحد دائما (يعني يملك تنشيط ثابت مساوي إلى القيمة(1)) ، وفي العادة لا يتم إظهار هذه وحدات التحيز في مخططات الشبكة. ويتم إظهار اتجاه تدفق المعلومات خلال مدة الانتشار الأمامي لعملية التعلم، وتتم بعد ذلك عملية إرسال الإشارات خلال مدة الانتشار الخلفي بالاتجاه المعاكس لتقديم الإشارات الأولى ، كما مبين بالأشكال الآتية (4، 5):

ثالثاً: دالة التحويل (دالة التنشيط)

العملية الثانية ضمن وحدة المعالجة هي تحويل ناتج الجمع (من خلال دالة التحويل) إلى قيم مرغوبة تقع ضمن حدود معينة، وذلك من خلال المقارنة بين نتيجة الجمع والعتبة Threshold ، والتي تحدد باعتمادتابع تحويل (تنشيط) معين، والذي تعتمد عليه مخرجات الشبكة، والتي تكون محصورة بين القيم (0 ، 1) او (-1 ، 0). غالبا تقسم توابع التحويل إلى ما يأتي(فريدو العربي، 2019:74) و (السعيد، ابتسام، فاطمة، امانيونورية، 2022:32):

1. التابع الأسّي (الدالة السيمغوفيد او الدالة السينية) : Sigmoid Function

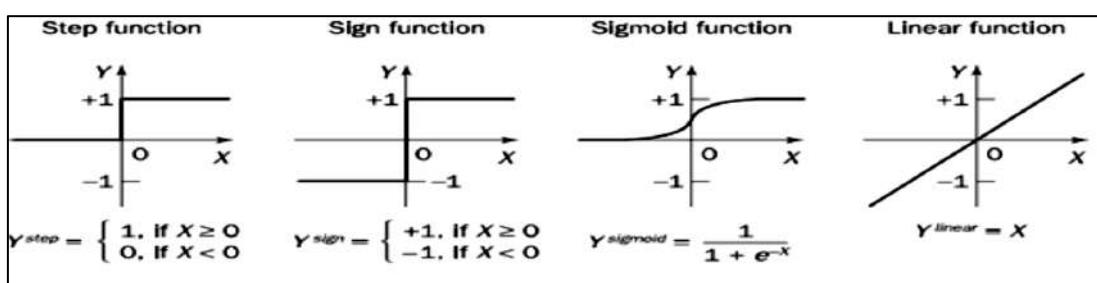
وُسمّى أيضاً بالدالة اللوجستية (Logistic Function) أو دالة الاصماد (Squashing Function) وهي دالة غير خطية ، إذ تأخذ هذه الدالة قيم المدخلات المحصورة بين (-∞ و +∞) وتجعل المخرجات محصورة بين (0 و 1) ،

وتعُد من أكثر الدوال استعمالاً في الشبكات العصبية الاصطناعية؛ وذلك لسهولة الحساب و التنفيذ، وكذلك قدرتها على توزيع القيم بين (0 و 1) بشكل انسابي، وتمثل X حاصل ضرب قيمة الإدخال مع وزنها كما موضح في الشكل (6).

2. التابع الخطّي (الدالة الخطّية) Linear Function: وهي الدالة التي تكون فيها صورة المخرجات مماثلة تماماً لصورة المدخلات، وتمنح تصنيفات متعددة وغير محدودة.

3. دالة الإشارة Sign Function: وهي الدالة التي تكون فيها صورة المخرجات بين [-1, 1] وتستعمل في مجالات الصنف والتعرّف على الأنماط.

4. التابع العتبة (دالة الخطوة) Step Function: وهي الدالة التي تكون مُخرجاتها واقعة بين [0, 1]



الشكل رقم (6) أنواع دوال التحويل المختلفة المستعملة في الشبكة العصبية الاصطناعية

Source: Kevin Gurney , 1997, An introduction to neural networks , UCL Press Limited , London EC4P 4EE .

وأخيرا وبعد الانتهاء من عملية الجمع الموزون والتحويل، تظهر لدينا المخرجات التي يمكن أن تكون متساوية مع نتائج دالة التحويل، وربما تعمد وحدة المعالجة إلى تعديل ناتج التحويل من خلال المنافسة مع وحدات التشيش المجاورة لها.

4-2-2: معالجة الأوزان في الشبكة العصبية الاصطناعية عن طريق (التعلم و التدريب)

Information Processing in ANN (Learning and Training)

إن معالجة الأوزان في الشبكات العصبية تمرّ بمرحلة أساس، وهي مرور البيانات بمرحلة التعلم أو التدريب. إن التدريب الخاضع للإشراف (المراقب) Training or Learning Step يدل على وجود معلم أو مدرب ليعلم الشبكة العصبية بالمخرجات المرغوبة فيها. أما التدريب بدون معلم أو مشرف (Unsupervised Training) تعمل على تهيئة الشبكة العصبية للاستجابة للمدخلات واختيارها للهيكلية من المدخلات فقط، لذلك سميت بطريقة التعليم الذاتي Self-Supervised Learning ، وهذا النوع من التدريب لا يستعمل معلماً أو مدرباً خارجياً (صليباً و مطر 60:2019). إن التدريب بإشراف (الخاضع للمراقب) تستعمل غالباً في الشبكات العصبية الاصطناعية ذات التخزينة الأمامية ، ومن الخوارزميات المشهورة بالتدريب بإشراف (المراقب أو الموجّه) لهذه الشبكات خوارزميات عدّة منها

-:(Alyuda , 2003:47)

1- خوارزمية الانتشار العكسي للخطأ Error Back Propagation Algorithm أو خوارزمية الانتشار العكسي الزائد (الإضافي) (Online) -Incremental Back Propagation Algorithm

2- خوارزمية الانتشار السريع Quick Propagation algorithm

3- خوارزمية الانتشار العكسي الرزم (الدفع) Batch Back Propagation Algorithm

وهذه الخوارزميات المشهورة في التعلم بإشراف اعلاه تعمل على تقليل الخطأ، وهي مربعات المتوسطات الصغرى القياسية (LMS)؛ لأنّها ببساطة عبارة عن أسلوب الإنحدار التدريجي Gradient Descent، وذلك لـ إيجاد القيمة الأدنى لمربع الخطأ الكلي لقيمة الإخراج المحسوب من قبل الشبكة. وبالمحصلة نحصل على الأوزان المثلثة التي يمكن اعتمادها في التنبؤ المستقبلي لبيانات جديدة لم تخضع للتعلم أو التدريب، وهذا هو الهدف الرئيس من تدريب الشبكات العصبية الاصطناعية (مطر والياس، 2010:11).

وللوضيح للخوارزميات المختلفة اعلاه لتدريب هذه الشبكة منها :

1- خوارزمية الانتشار الخلفي للخطأ Error Back Propagation Algorithm

تُسمى هذه الخوارزمية بخوارزمية الانتشار العكسي التزائدي (الإضافي) (Online) -Incremental Back Propagation Algorithm ، وتعُد هذه الخوارزمية من أشهر الخوارزميات استعمالاً، إذ تحدث أوزان الشبكة بعد تقديم كلّ فقرة من مجموعة التدريب بدلاً من أن يُتم تكرارها. وهذا أصلاً يجدد التغيير للانتشار العكسي للخطأ، وفي بعض الأحيان يُشار له بالانتشار العكسي القياسي Standard Back Propagation. ويفضّل استعمال هذه الخوارزمية في حالة مجموعة البيانات الكبيرة.

إن تدريب الشبكة العصبية الاصطناعية ذات التغذية الأمامية استعمال الانتشار العكسي(الخلفي) تتضمن ثلاثة مراحل وهي كالتالي (مطر والياس، 2010:13) و(صلبيوا ومطر، 2019:62):

- مرحلة الانتشار الأمامي للخطأ Error Forward propagation Step
- مرحلة الانتشار الخلفي للخطأ Error Back propagation Step
- مرحلة توليف أوزان الشبكة Network Weights Synthetic Step

2- خوارزمية الانتشار السريع Quick Propagation algorithm

إن خوارزمية الانتشار السريع هو عامل مساعد لتعديل خوارزمية الانتشار العكسي للخطأ ، قدّم من قبل Scott Fahlman ، وأن خوارزمية التدريب لهذه الطريقة تعامل الأوزان على أنها شبه مستقلة- Quasi-Independent ، وتستعمل أنموذج تربيعي بسيط لتقريب سطح الخطأ Error Surface . وأثبتت هذه الخوارزمية بأنّها أسرع من خوارزمية الانتشار العكسي للخطأ في العديد من المسائل، على الرغم من أن خوارزمية الانتشار السريع قد تكون غير مستقرّة . وتمثل معامل الانتشار السريع معلمة تدريب إضافية لهذه الخوارزمية ، وتستعمل هذه المعلمة للسيطرة على مقدار زيادة الأوزان في بعض الحالات (Alyuda ، 2003:47).

3- خوارزمية الانتشار العكسي الرزم(الدفع) Batch Back Propagation Algorithm

هي نوع متطرّر أو متقدّم للانتشار العكسي، لأنَّ الأوزان المحدثة للشبكة تقوم بمهامها حالما يُتَم التكرار. مما يُبيّن بأنَّ العملية تسجّل التدريبات كلها خلال الشبكة (Alyuda,2003:48). وتسعمل هذه الخوارزمية للبحث عن أفضل هيكلية (معمارية) للشبكة العصبية الاصطناعية وفق معايير الدقة (المطابقة) Fitness Criterion ، وبعد ذلك استعملت للتنبؤات المستقبلية وفق خوارزميات رقم (1) و(2). التنبؤية.

2-2: هيكلية الشبكات العصبية الاصطناعية في الجانب الرياضي

إنَّ بناء الشبكات العصبية الاصطناعية من الناحية الرياضية تعتمد على ثلاث حالات ، وكالآتي:

1- احتساب عدد المدخلات لمتنبئ الشبكة العصبية.

أنَّ تحليل الارتباط الذاتي Autocorrelation Analysis يستعمل لاحتساب عدد المدخلات (أنماط الإدخال) الصحيحة للتنبؤ بالسلسلة الزمنية غير الخطية من خلال الشبكات العصبية. وأنَّ أداء تنبؤ الشبكة العصبية يعتقد بتأثيرها بعدد المدخلات أو بإنماط الإدخال، فهناك مقالات قليلة توضح كيفية اختيار أو احتساب عدد المدخلات لمتنبئ الشبكة العصبية للوصول إلى أفضل تنبؤ يمكن الحصول عليه.

وللكشف عن إنماط الإدخال أو عدد المدخلات استعمال تحليل الارتباط الذاتي يتضمن بطريقتين (Kumar, et al.,2004:146;Lin, et al.,1995:247)

الطريقة الأولى : استعمال دالة الارتباط الذاتي ACF

1- يُتَم حساب معاملات الارتباط الذاتي (ACF) للسلسلة الزمنية المعطاة فإذا اكتشف هذه السلسلة على وجود اتجاه عام ، فإنَّ عملية الفروق (Differencing) يجب أن تُستعمل لإزالة الاتجاه العام. وهذه الخطوة يجب أن تتكرّر حتى يُتَم إزالة الاتجاه العام بدرجة فروق مناسبة، وهذه الخطوة مهمة يمكن استعمال معاملات الارتباطات الذاتية لتحديد التخلافات المعنوية الباقية للتنبؤ على المدى القصير (Lin, et al.,1995:247)

2- في عام 1990 ، اكتشف العالمان (موجمدار وكومار) في تحليل الارتباط الذاتي لتدفقات نهر هيمافاتي في الهند على وجود ارتباطات ذاتية معنوية قوية حتى ثلات تخلفات وارتباطات ذاتية ضعيفة من التخلف الثالث إلى الخامس. لذلك فإنَّ عدد العصبونات في طبقة المدخلات يتغيّر (من 3 إلى 5) عصبونات ، اعتماداً على عدد الارتباطات المعنوية فكانت أفضل نتائج التدريب مع (5) عصبونات لِمُثَمِّل عدد العصبونات في طبقة المدخلات (Kumar, et al.,2004:146) .

الطريقة الثانية: استعمال دالة الارتباط الذاتي الجزئي PACF

يُتَم حساب معاملات الارتباط الذاتي الجزئية (PACF) لتوضيح كيف أنَّ (X_i) ترتبط ذاتياً مع (X_{i+k})، لذا يُتَم اختيار معاملات الارتباط الذاتي الجزئية (PACF) التي تختلف معنويًا عن بقية المعاملات، وأنَّ أكبر تخلف(Lag) بين أي معاملتين يُمثّل عدد المدخلات المطلوبة لمتنبئ الشبكة العصبية (قبلأخذ الفرق) (Lin, et al.,1995:247) .

2- احتساب عدد العصبونات في الطبقة المخفية

إنَّ عدد العصبونات في الطبقة المخفية تتحسب استعمال معادلة بام هاسлер Baum-Haussler Rules للتنبؤ بالسلسلة الزمنية استعمال الشبكات العصبية (Lin, et al.,1995: 247) (ومطر والياس،2010:-)

$$N_{Hidden.} \leq \frac{N_{Train.} E_{Tolerance.}}{N_{Pts.} + N_{Output.}} \quad (11)$$

إذ أنَّ :

: N_{Hidden} تمثل عدد العقد العصبية أو عدد العصبونات المخفية ، N_{Train} : تمثل عدد أمثلة التدريب ، $E_{Tolerance}$ تمثل مقدار الخطأ المسموح ، N_{Pts} : تمثل عدد نقاط البيانات (إنماط الإدخال) لكل مثال تدريب N_{Output} : تمثل عدد العقد العصبية أو عدد عصبونات الإخراج .
 ونلاحظ كلاً من إنماط الإدخال الذي تم احتسابها في (1) وعدد العصبونات للطبقة المخفية التي تم احتسابها في (2) ، تستعمل في بناء متتبّع الشبكة العصبية .

3- عدد العصبونات في طبقة الإخراج

إن العصبونات أو العقد العصبية في طبقة الإخراج تتطلب عصبونا واحدا فقط في الشبكة العصبية للسلسلة الزمنية (Kumar , et al.,2004:146) (جمال وسهيلة،2018:173).

5-2-2: معايير الدقة (المطابقة) Fitness Criterion

بعد معرفة المدى المسموح لعدد العقد العصبية المخفية وفق معادلة بام هاسлер Baum-Haussler Rules ، نستعمل معايير المطابقة Fitness Criterion للحصول على أفضل هيكلية للشبكة العصبية الاصطناعية من بين معايير عدّة، أثناء البحث الشامل Exhaustive Search ، بالاعتماد على المعايير الآتية (Alyuda , 2003:47):

- خطأ الاختبار Test error: كلما كانت قيمة الخطأ أقل في مجموعة الاختبار، كانت الشبكة العصبية أفضل للتنبؤ بالسلسل الرزمية، ويتمثل بقيم معكوس خطأ الاختبار Inverse Test error . ويتم حساب هذا المعيار على أنها معكوس متوسط خطأ المطلقة للشبكة في مجموعة الاختبار. ومن خلال هذا المعيار أيضا يتم الحصول على قيم المطابقة Fitness بأخذ مقلوب قيم معكوس خطأ الاختبار Inverse Test error ، وسيتم في هذه الحالة اختيار أكبر قيمة من قيم المطابقة Fitness في مجموعة الاختبار للحصول على أفضل شبكة عصبية للتنبؤ.
- خطأ التدريب Train error: كلما كانت قيمة الخطأ أقل في مجموعة التدريب، كلما كانت الشبكة العصبية أفضل للتنبؤ بالسلسل الرزمية.
- معيار معلومات اكاكي (AIC): كلما كانت قيمة هذا المعيار أكبر ، كلما كانت الشبكة العصبية أفضل للتنبؤ بالسلسل الرزمية.
- معامل التحديد R-Squared: كلما كانت قيمة هذا المعيار أقرب إلى الواحد الصحيح ، كلما كانت الشبكة العصبية أفضل للتنبؤ بالسلسل الرزمية؛ لأنّ قيم معامل التحديد محصورة بين [0,1].
- معامل الارتباط Correlation: كلما كانت قيمة هذا المعيار أقرب إلى الواحد الصحيح (بمعنى أنّ هنالك ارتباط ذاتي قوي بين القيم الحقيقة وقيم مُخرجات الشبكة المتتبّعة)، كلما كانت الشبكة العصبية أفضل للتنبؤ بالسلسل الرزمية؛ لأنّ قيم معامل الارتباط محصورة بين [-1,+1].
- عدد الأوزان # of Weight: يُتم احتساب عدد الأوزان في الشبكة العصبية الاصطناعية وفق المعادلة الآتية (مطر والياس،2010:23):

$$P = (n_{Input} + 2) \cdot n_{Hidden} + 1 \quad (12)$$

إذ أنّ :

n_{Input} : تمثل عدد متغيرات الإدخال (ما دعا الحد الثابت).

n_{Hidden} : تمثل عدد العصبونات في الطبقة المخفية.

P : تمثل عدد الأوزان في الشبكة العصبية، وتساوي عدد الترابطات في أنموذج الشبكة العصبية الاصطناعية
(2) **Number**: تمثل وحدة التحيز بالنسبة لوحدات الطبقة المخفية، وكذلك لوحدة طبقة الإخراج في أنموذج الشبكة العصبية الاصطناعية.

2-2-6: التنبؤ للسلسلة الزمنية استعمال الشبكات العصبية الاصطناعية.

يعد التنبؤ المستقبلي استعمال الشبكات العصبية من الأساليب الحديثة التي لاقت اهتماماً واسعاً في مجالات مختلفة، منها: التنبؤ بأسعار العملات والموارد المالية ، أحوال الطقس ، تدفق المياه في الأنهر ، واستهلاك الطاقة الكهربائية . واستعملت هذه الشبكات العصبية في المجال الإحصائي بشكل واسع؛ كونها قادرة على التعلم (التدريب) والتكييف ذاتياً مع أي أنموذج ، ولا تحتاج إلى شروط صارمة ودقيقة لغرض التنبؤ ، ولا يتطلب افتراضات عن طبيعة السلسلة الزمنية ، كونها خطية أو غير خطية أو طبيعية أو مستقرة ، لذا يعتقد أنَّ استعمال هذا الأسلوب قد يكون مجزياً في معالجة مسألة التنبؤ. فضلاً عن أنَّ من المفيد من الناحية العلمية الاطلاع على هذا الأسلوب الحديث، ومقارنته مع الأساليب الكلاسيكية للتعرف على إمكانياته في إجراء التنبؤ (الخياط و زكي، 2005:69-63).

أن عملية التنبؤ للسلسلة الزمنية واستعمال الشبكات العصبية الاصطناعية، يمكن إيجازها بالمراحل الآتية:

(جمال وسهيلة، 2018:172) و(أحمد، محمد وحسن، 2021:29):-

المرحلة الأولى: اختيار المتغيرات Variables selection

هذه المرحلة يُثُم اختيار بيانات السلسلة الزمنية التي تمثل المشكلة المراد التنبؤ بقيمها بشكل جيد.

المرحلة الثانية: معالجة البيانات Data processing

في هذه المرحلة يتم إجراء بعض العمليات على البيانات المستعملة مثل: تقدير الاتجاه العام أو تحديده، التركيز على العلاقة بين البيانات (المشاهدات)، و إيجاد توزيع البيانات.

المرحلة الثالثة: تقسيم البيانات (المشاهدات) إلى مجاميع Divide data into sets

يتم تقسيم البيانات المتأصلة لدينا إلى المجاميع الآتية:

- مجموعة التدريب Training set: تمثل مجموعة تعلم، وتعمل على تقدير أنموذج للبيانات
- مجموعة الاختبار Testing set: ويتم عن طريقها تقدير مهارة الشبكة الافتراضية وإمكانية استعمالها بصورة عامة ، ومن خلالها يتم الحصول على القيم المتنبأ بها.
- مجموعة التحقيق(الشرعية) Validation set: تمثل مجموعة لإجراء اختبار نهائي لأداء الشبكة

المرحلة الرابعة: تحديد هيكلية الشبكة العصبية Neural network Architecture

لتحديد هيكلية الشبكة العصبية يجب اختبار الآتي:

- عدد عصوبات إنماط الإدخال ، والذي يساوي عدد المتغيرات المستقلة فضلاً عن عصبون الانحياز.
- عدد الطبقات المخفية، والذي يعتمد على قيمة الخطأ المستعمل في الشبكة.
- عدد العصبونات المخفية، والذي يحدد عن طريق التجربة، وفقاً لقاعدة بام هاسلر للمعادلة (11).

• طبقة الإخراج تتطلب عصباً واحداً فقط.

المرحلة الخامسة: تحديدتابع التنشيط (دالة التحويل) Transfer function

إنَّ تابع التنشيط يتمثل بالصيغة الرياضية التي تسمح بتحديد الإخراج، وتمكن الإخراج من الوصول إلى قيمة عالية جداً. وهناك توابع تنشيط يمكن استعمالها، والشائعة الاستعمال هو التابع الأسّي (Sigmoid Function) وُسُمِّي أيضاً بالدالة اللوجستية (Logistic Function).

المرحلة السادسة: اختيار معيار التقويم Evaluation criteria

ويسمى أيضاً بمعيار التعلم، وأن المعيار المستعمل للخوارزميات في التعلم بإشراف لشبكة العصبية الاصطناعية هو مجموع مربعات الأخطاء MSE وهو الأكثر استعمالاً.

المرحلة السابعة: تدريب الشبكة Neural network training

للحصول على مجموعة الأوزان بين العصبونات والتي تحدد أقل قيمة لمربع الخطأ ، ثم تحسينها عن طريق التدريب بهدف الوصول إلى أوزان مُثلى تعطي نتائج دقيقة، وذلك بتحقيق أقل قيمة لمربع الخطأ.

الخطوة الثامنة: التنفيذ

وتعُد من أهم الخطوات التي تختبر فيها الشبكة العصبية، وقدرتها على التكيف مع حالة التغيير في الدورة، وإمكانية إعادة التدريب بهدف الوصول إلى أقل قيمة لمربع الخطأ عند تغيير البيانات والوصول إلى حالة مستقرة.

الجانب التطبيقي

في هذا الجانب نطبق ما عرضناه سابقاً على بيانات السلسلة الزمنية لسعر الصرف اليومي للبيورو أمام الدولار للمدة من 10/12/2020 H:1 AM - 7/12/2020 H:7 AM بمجموع مشاهدات يبلغ (79) مشاهدة، (كما مبين بالجدول (2) والشكل(1))، إذ تم الإبقاء على (120) مشاهدة (كما بالملحق (1)) للمقارنة مع قيم التنبؤ التي يتم الحصول عليها واستعمال الأسلوبين ، من أجل اختيار الأنماذج الملائم لنمط هذه السلسلة للحصول على تنبؤات مستقبلية لبيانات الملحق (1) للمدة من (15/12/2020 H:7 AM-10/12/2020 H:8 AM) بمجموع مشاهدات يبلغ (120) مشاهدة للتنبؤ بها. بينَ أنموذج التمهيد الأسّي المزدوج (طريقة هولت)، وأنموذج الشبكات العصبية الاصطناعية ذات التغذية الأمامية استعمال الخوارزميتين (خوارزمية الانتشار العكسي الزائد، خوارزمية الانتشار السريع). ومن بعد ذلك إجراء مقارنة بين السلاسلتين بعد تحديد الأنماذج الملائم والكشف لتقييم التنبؤات المستقبلية للمدة من (10/12/2020 H:7 AM-H:8 AM 15/12/2020) لكل سلسلة ، وفقاً لمعيار متوسط مربع الخطأ (MSE)؛ لأنَّ المعيار الأكثر استعمالاً و شيوعاً لاختيار الأنماذج الأمثل والأكفاء الذي يعطي أقل قيمة لهذا المعيار واستعماله للتنبؤات المستقبلية. ولقد تم استعمال البرامج الإحصائية الجاهزة MinitabV18 في الجانب الإحصائي ، وبرنامج نظام الشبكات العصبية الجاهز ، والذي يُعرف Alyuda NeuroIntelligence في جانب الشبكات العصبية.

1: التنبؤ لسعر الصرف اليومي للبيورو أمام الدولار استعمال أنموذج التمهيد الأسّي المزدوج (طريقة هولت)

1-1: العرض البياني وتشخيص الأنماذج لسعر الصرف اليومي للبيورو أمام دولار في العراق.

بأخذ بيانات لسعر الصرف اليومي للبيورو أمام الدولار للمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM) ، (كما مبين في الجدول (2)) ، أنَّ الخطوة الأولى في تحليل أية سلسلة زمنية، هي توقيع السلسلة بيانياً مع الزمن وهي

خطوة أساس و مهمة في التحليل ، وهو ما يعرف (Time Series Plot) ، إذ يمكن من خلال التوقيع البياني للسلسلة الزمنية الاطلاع على طبيعة التذبذب فيها ، و ملاحظة فيما إذا كانت تتضمن اتجاهها عاماً (متزايداً أو متناقصاً) أم لا ؟
 فضلاً عن ملاحظة وجود أو عدم تغيرات موسمية .

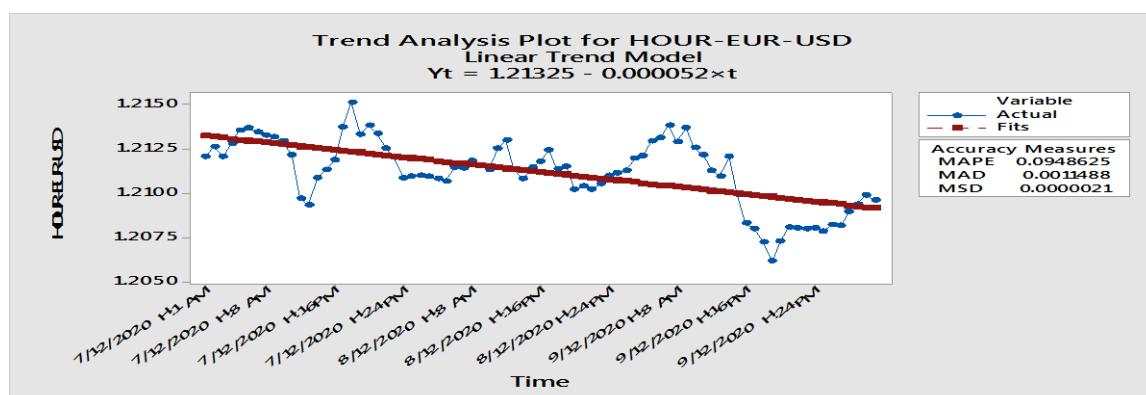


الشكل (1): الرسم الزمني لمشاهدات السلسلة الزمنية لسعر الصرف اليومي لليورو وأمام دولار للمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM)

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

الشكل (1) يُبيّن نمط السلسلة الزمنية ، إذ يلاحظ من خلاله بأنّ نمط البيانات السلسلة الزمنية لسعر الصرف اليومي لليورو أمام الدولار يعني انخفاضاً على المستوى العام للأسعار للمدة من (10/12/2020 H:1 AM - 7/12/2020 H:7 AM) ، مما يُبيّن بأنّ هناك اتجاهًا عامًا متناقصًا غير موسمي ، مما يدلّ على عدم ثبات متوسّط السلسلة الزمنية خلال المدة ، لذا نستنتج أنَّ السلسلة غير ساكنة أو مستقرة ، ولمزيد من الدقة نستعمل طريقتين :

1- ويمكن إثبات ذلك في حالة استعمال إياعز تحليل الاتجاه العام ، وهو ما يُعرف Trend Analysis لبيانات السلسلة الزمنية لسعر الصرف اليومي لليورو أمام الدولار للمدة من (10/12/2020 H:7 AM-7/12/2020 H:1 AM) ، كما مبين بالشكل الآتي:

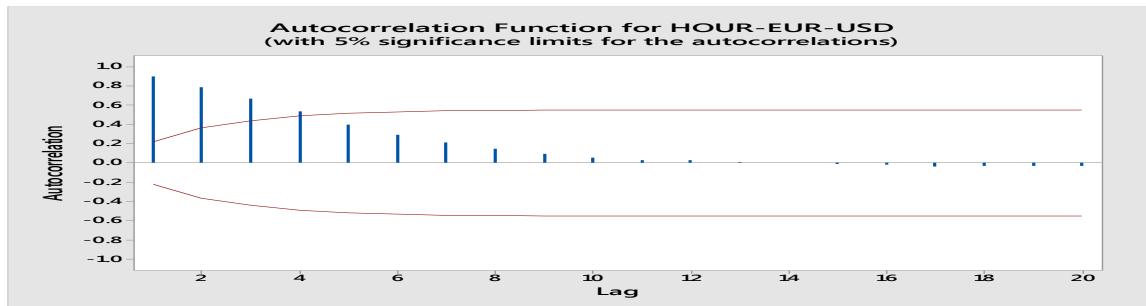


الشكل (2) : تحليل الاتجاه العام لبيانات السلسلة الزمنية لسعر الصرف اليومي لليورو وأمام الدولار للمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM)

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

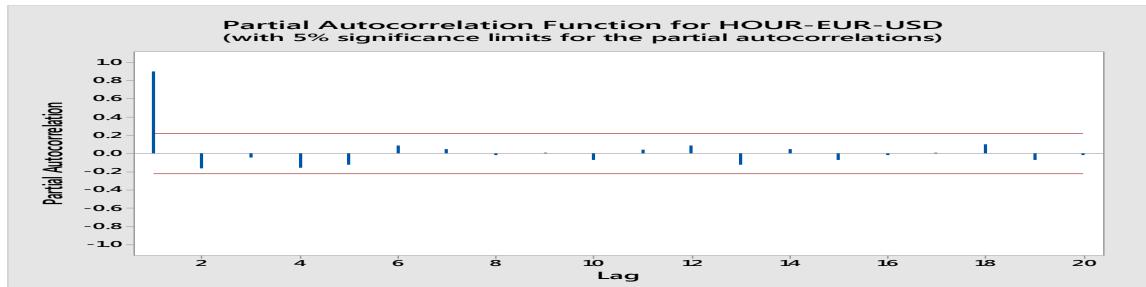
إذ نلاحظ من خلال الشكل (2) بأنَّ النمط ذو اتجاه عام متناقص غير موسمي ، مما يدلّ على عدم ثبات متوسّط السلسلة الزمنية ، لذا نستنتج أنَّ السلسلة غير ساكنة أو مستقرة في المتوسط خلال المدة .

2- في حالة رسم دالة الارتباط الذاتي ACF و دالة الارتباط الذاتي الجزئي PACF لبيانات السلسلة الزمنية لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM)، كما موضح بالشكلين الآتيين:-



الشكل (3) : دالة الارتباط الآتي ACF لبيانات السلسلة الزمنية لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM)

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .



الشكل (4) : دالة الارتباط الذاتي الجزئي PACF لبيانات السلسلة الزمنية لسعر الصرف اليومي للبيورو أمام دولار للمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM)

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

ويوضح الشكلان (3،4) أنَّ فيه عوامل ارتباط ذاتي والجزئي تتذبذب بين القيم الموجبة والقيم السالبة على امتداد السلسلة، ونلاحظ ظهور تخلفات معنوية عند التخلف ($K=1,2,3,4$) في دالة الارتباط الذاتي ACF وإيضاً وجود تخلف معنوي عند التخلف ($K=1$) في دالة الارتباط الذاتي الجزئي PACF ، وقد تعددت الحد الأعلى لحدود الثقة بدرجة ثقة 95% ، مما يدل على وجود اتجاه عام ، لذلك ينبغي معالجة مشكلة الارتباط الذاتي الموجود بالسلسلة الزمنية لإنتاج سلسلة نقية ساكنة ذات قدرة عالية على التنبؤ.

نستنتج من الأشكال (2،3،4) أنَّ النموذج الملائم لنمط هذه السلسلة هو نموذج التمهيد الأسّي المزدوج (طريقة هولت) Double Exponential Smoothing؛ لأنَّه الأنماذج الأكفاء في معالجة السلسلات الزمنية المحتوية على مركبة الاتجاه العام غير الموسمية (كما مذكور سابقاً في الجانب النظري) مما أثبتت صحة فرضية البحث.

2-1 : تقدير معالم الأنماذج لبيانات لسعر الصرف اليومي للبيورو أمام الدولار

لقد تم استعمال نموذج التمهيد الأسّي المزدوج (طريقة هولت) لبيانات السلسلة الزمنية لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM) لتقدير معالم التمهيد المُثلّى ، وفقاً لمعايير

دقة التنبؤ، ولاسيما لمعيار متوسط مربع الخطأ (MSE) ؛ من أجل الحصول على الأنماذج الملائم للتنبؤ بالقيم المستقبلية وكما يأتي :

1-2-1: تحديد أفضل ثابتين تمهيديين لـ (α و γ) وفقاً لمعيار متوسط مربع الخطأ (MSE)، بعد تجربة واختبار عدد كبير من القيم تتراوح ما بين $0.1 \leq \alpha \leq 0.9$ و $0.1 \leq \gamma \leq 0.9$ فإن القيمة المثلث لـ $\alpha=0.9$ و $\gamma=0.1$ كاماً التي تعطي القيم الأقل لهذا لمعايير كما موضح في الجدول الآتي:

الجدول(1): قيم معايير الخطأ استعمال أنماذج التمهيد الأسني المزدوج (طريقة هولت) لسعر الصرف اليومي للبيورو أمام الدولار لاختيار القيمة المثلث لـ (α ، γ)

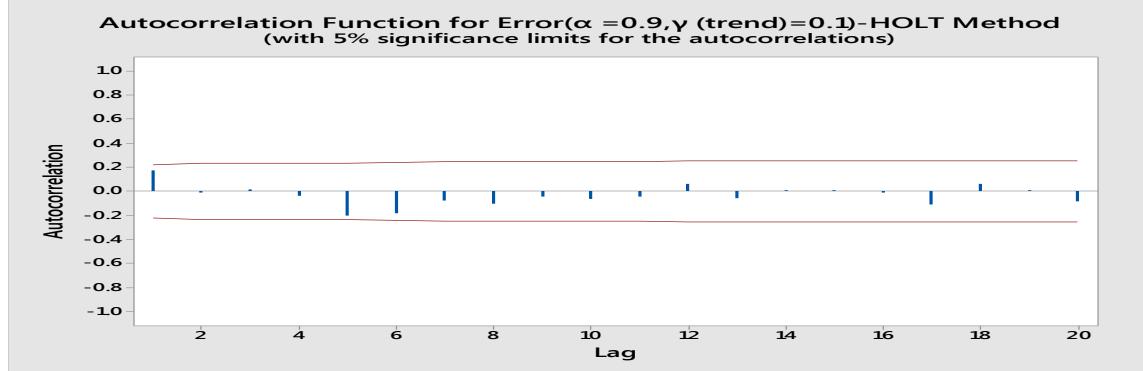
قيمة ثابت التمهيد للمستوى Alpha α (Level)	قيمة ثابت التمهيد للانحراف (الاتجاه العام) Gamma γ (Trend)	متوسط مربعات الخطأ MSD or MSE	متوسط القيم المطلقة لخطأ MAD	متوسط النسبة المطلقة لخطأ MAPE
0.1	0.1	0.0000024	0.0011466	0.0947112
0.2	0.1	0.0000020	0.0011021	0.0910209
0.3	0.1	0.0000016	0.0010075	0.0832079
0.4	0.9	0.0000013	0.0008912	0.0735760
0.5	0.9	0.0000011	0.0007824	0.0645976
0.6	0.9	0.0000010	0.0007294	0.0602259
0.7	0.8	0.0000009	0.0006980	0.0576407
0.8	0.5	0.0000008	0.0006823	0.0563304
0.9*	0.1*	0.0000007	0.0006629	0.0547275
تمثل القيمة المثلث لـ (α ، γ) التي تعطي أقل قيمة لمتوسط مربع الخطأ MSD or MSE				(*)

. المصدر: من إعداد الباحثة بالأعتماد على مخرجات البرنامج الإحصائي Minitab

2-2-1 : تقدير التنبؤات المستقبلية بعد تحديد الأنماذج الملائم وفقاً لقيمة المثلث :

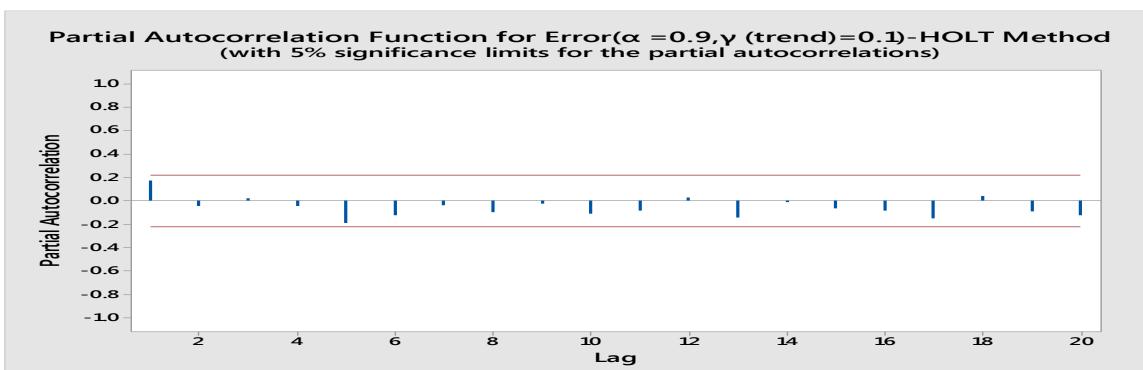
بعد تحديد قيمة التمهيد المثلث لـ (α ، γ) كما موضح بالجدول (1) وتتمثل القيمة المثلث لـ ($\alpha=0.9$ و $\gamma=0.1$) واستعمال المعادلات من (1) إلى (5) المذكورة في الجانب النظري ، لذا يُعدّ أنماذج التمهيد الأسني المزدوج (طريقة هولت) (Holt's Method) الأنماذج الملائم والأكثر لتقدير التنبؤات المستقبلية لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:8 AM - 15/12/2020 H:7 AM). وفقاً لمعامل التمهيد المثلث لـ ($\alpha=0.9$ و $\gamma=0.1$) كما موضح بالجدول (3-2) والشكلان (7-8) الآتيان لاحقاً، وبإعادة فحص

كل من دالة الارتباط الذاتي (ACF) ودالة الارتباط الذاتي الجزئي (PACF) للبواقي في السلسلة الزمنية استعمال طريقة التمهيد الأسّي المزدوج (طريقة هولت) لبيانات سعر الصرف اليومي لليورو أمام الدولار موضع الدراسة ، تبين أنّ السلسلة خالية من مشكلة الارتباط الذاتي لذا نستنتج أنّ السلسلة نقيّة ذات قدرة عالية على التنبؤ. ويتبين من الشكل البياني (5) أنّ قيم معاملات الارتباط الذاتي (ACF) ، وقيم معاملات الارتباط الذاتي الجزئي (PACF) للبواقي تقع جميعها ضمن حدود الثقة (الحد الأعلى والحد الأدنى) بدرجة ثقة 95% ، مما يعني أنّ سلسلة البواقي تمثل متغيرات عشوائية. مما يدل أنّ الانموذج المقدر جيد وكفؤ وملائم للتنبؤ ، بعبارة أخرى إنّ القيمة الممهدّة المُثلى لـ ($\alpha=0.9$ و $\gamma=0.1$) جيدة والسلسلة ذات قدرة جيدة على التنبؤ كما موضح بالجدول (2-3) والشكلين (5-6) الآتيين لاحقا .



الشكل(5): رسم دالة الارتباط الذاتي للبواقي استعمال طريقة هولت (أنموذج التمهيد الأسّي المزدوج) عند استعمال $\alpha=0.9$ و $\gamma=0.1$ لسعرالصرف اليومي لليورو أمام الدولار.

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .



الشكل(6): رسم دالة الارتباط الذاتي الجزئي للبواقي استعمال طريقة هولت (أنموذج التمهيد الأسّي المزدوج) عند استعمال $\alpha=0.9$ و $\gamma=0.1$ لسعرالصرف اليومي لليورو أمام الدولار .

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

الجدول (2) : نتائج طريقة هولت (أنموذج التمهيد الأسني المزدوج) عند استعمال $\alpha=0.9$ و $\gamma=0.1$
للتنبؤات المستقبلية لسعر الصرف اليومي لليورو أمام الدولار للمدة من 10/12/2020 H:8 AM - 15/12/2020 H:7 AM

Period المدة (*)	HOUR-EUR- USD القيم الحقيقة لسعر الصرف اليومي لليورو أمام دولار(*)	Smooth قيمة التمهيد	Predict قيمة المتوقعة	Error قيم الأخطاء
7/12/2020 H:1 AM	1.21204	1.21216	1.21320	-0.0011552
7/12/2020 H:2 AM	1.21261	1.21255	1.21200	0.0006106
7/12/2020 H:3 AM	1.21204	1.21208	1.21245	-0.0004078
7/12/2020 H:4 AM	1.21280	1.21271	1.21194	0.0008570
7/12/2020 H:5 AM	1.21354	1.21345	1.21265	0.0008864
7/12/2020 H:6 AM	1.21365	1.21363	1.21347	0.0001796
7/12/2020 H:7 AM	1.21343	1.21345	1.21367	-0.0002373
7/12/2020 H:8 AM	1.21324	1.21326	1.21347	-0.0002276
7/12/2020 H:9 AM	1.21315	1.21316	1.21326	-0.0001062
7/12/2020 H:10 AM	1.21291	1.21293	1.21314	-0.0002345
7/12/2020 H:11 AM	1.21212	1.21220	1.21290	-0.0007762
7/12/2020 H:12	1.20970	1.20994	1.21209	-0.0023905

AM				
7/12/2020 H:13	1.20931	1.20934	1.20962	-0.0003068
PM				
7/12/2020 H:14	1.21084	1.21066	1.20899	0.0018492
PM				
7/12/2020 H:15	1.21130	1.21122	1.21047	0.0008284
PM				
7/12/2020 H:16	1.21187	1.21179	1.21111	0.0007617
PM				
7/12/2020 H:17	1.21373	1.21353	1.21175	0.0019765
PM				
7/12/2020 H:18	1.21512	1.21497	1.21367	0.0014501
PM				
7/12/2020 H:19	1.21329	1.21349	1.21524	-0.0019531
PM				
7/12/2020 H:20	1.21381	1.21379	1.21358	0.0002324
PM				
7/12/2020 H:21	1.21335	1.21340	1.21390	-0.0005500
PM				
7/12/2020 H:22	1.21253	1.21262	1.21347	-0.0009387
PM				
7/12/2020 H:23	1.21198	1.21204	1.21260	-0.0006231
PM				
7/12/2020 H:24	1.21086	1.21097	1.21197	-0.0011055
PM				
8/12/2020 H:1	1.21095	1.21093	1.21079	0.0001558
AM				
8/12/2020 H:2	1.21100	1.21098	1.21077	0.0002279
AM				
8/12/2020 H:3	1.21092	1.21091	1.21084	0.0000846
AM				
8/12/2020 H:4	1.21078	1.21078	1.21078	0.0000027

AM				
8/12/2020 H:5	1.21067	1.21067	1.21065	0.0000242
AM				
8/12/2020 H:6	1.21144	1.21135	1.21054	0.0009042
AM				
8/12/2020 H:7	1.21138	1.21137	1.21130	0.0000808
AM				
8/12/2020 H:8	1.21182	1.21177	1.21133	0.0004912
AM				
8/12/2020 H:9	1.21155	1.21157	1.21177	-0.0002220
AM				
8/12/2020 H:10	1.21130	1.21133	1.21155	-0.0002533
AM				
8/12/2020 H:11	1.21250	1.21238	1.21128	0.0012164
AM				
8/12/2020 H:12	1.21296	1.21291	1.21245	0.0005139
AM				
8/12/2020 H:13	1.21135	1.21152	1.21302	-0.0016726
PM				
8/12/2020	1.21078	1.21085	1.21148	-0.0007008
H:14PM				
8/12/2020 H:15	1.21144	1.21137	1.21075	0.0006895
PM				
8/12/2020 H:16	1.21179	1.21174	1.21133	0.0004565
PM				
8/12/2020 H:17	1.21242	1.21235	1.21175	0.0006721
PM				
8/12/2020	1.21135	1.21146	1.21242	-0.0010668
H:18PM				
8/12/2020 H:19	1.21149	1.21148	1.21142	0.0000653
PM				
8/12/2020 H:20	1.21021	1.21033	1.21146	-0.0012474

PM				
8/12/2020	1.21037	1.21035	1.21020	0.0001736
H:21PM				
8/12/2020	1.21021	1.21021	1.21023	-0.0000199
H:22PM				
8/12/2020 H:23	1.21051	1.21047	1.21009	0.0004225
PM				
8/12/2020	1.21097	1.21091	1.21038	0.0005887
H:24PM				
9/12/2020 H:1	1.21114	1.21111	1.21088	0.0002624
AM				
9/12/2020 H:2	1.21125	1.21124	1.21110	0.0001461
AM				
9/12/2020 H:3	1.21195	1.21188	1.21124	0.0007114
AM				
9/12/2020 H:4	1.21209	1.21208	1.21195	0.0001439
AM				
9/12/2020 H:5	1.21291	1.21283	1.21216	0.0007542
AM				
9/12/2020 H:6	1.21313	1.21312	1.21298	0.0001473
AM				
9/12/2020 H:7	1.21381	1.21376	1.21328	0.0005334
AM				
9/12/2020 H:8	1.21288	1.21299	1.21397	-0.0010860
AM				
9/12/2020 H:9	1.21365	1.21360	1.21310	0.0005498
AM				
9/12/2020 H:10	1.21255	1.21267	1.21376	-0.0012061
AM				
9/12/2020 H:11	1.21212	1.21218	1.21272	-0.0006032
AM				
9/12/2020H:12	1.21127	1.21136	1.21218	-0.0009086

AM				
9/12/2020 H:13	1.21095	1.21098	1.21128	-0.0003274
PM				
9/12/2020H:14P	1.21204	1.21192	1.21087	0.0011702
M				
9/12/2020H:15P	1.20991	1.21011	1.21192	-0.0020053
M				
9/12/2020	1.20830	1.20846	1.20992	-0.0016224
H:16PM				
9/12/2020 H:17	1.20795	1.20797	1.20813	-0.0001781
PM				
9/12/2020	1.20724	1.20728	1.20762	-0.0003776
H:18PM				
9/12/2020 H:19	1.20615	1.20622	1.20689	-0.0007436
PM				
9/12/2020 H:20	1.20726	1.20711	1.20577	0.0014867
PM				
9/12/2020 H:21	1.20805	1.20792	1.20679	0.0012560
PM				
9/12/2020 H:22	1.20803	1.20800	1.20772	0.0003098
PM				
9/12/2020	1.20795	1.20794	1.20782	0.0001273
H:23PM				
9/12/2020 H:24	1.20800	1.20798	1.20777	0.0002276
PM				
10/12/2020 H:1	1.20784	1.20784	1.20783	0.0000072
AM				
10/12/2020 H:2	1.20819	1.20814	1.20770	0.0004945
AM				
10/12/2020 H:3	1.20814	1.20813	1.20804	0.0000987
AM				
10/12/2020 H:4	1.20893	1.20884	1.20804	0.0008902

AM				
10/12/2020 H:5	1.20936	1.20931	1.20883	0.0005293
AM				
10/12/2020 H:6	1.20988	1.20983	1.20934	0.0005355
AM				
10/12/2020 H:7	1.20958	1.20961	1.20991	-0.0003320
AM				

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

المصدر(*) : البنك المركزي العراقي ، المديرية العامة للإحصاء والآبحاث ، "النشرة السنوية لسنة (2020)" ، [\(https://cbi.iq/news/view/492\)](https://cbi.iq/news/view/492)

أما مدد الثقة فتتمثل الحد الأدنى والحد الأعلى للقيم المتباينة بها بمستوى ثقة 95% ، كما موضح بالجدول (4).

الجدول (3) : نتائج القيم التنبؤية المستقبلية ومدد الثقة لطريقة هولت (أنموذج التمهيد الأسّي المزدوج) عند

استعمال ($a = 0.9$ و $\gamma = 0.1$) لسعر الصرف اليومي للينورو أمام الدولار لمدة من (10/12/2020 H:8 AM

.(15/12/2020 H:7 AM

Period	Forecas t	Lower	Upper	Period	Forecas t	Lower	Upper
10/12/2020 H:8 AM	1.20967	1.20804	1.21129	12/12/2020 H:24PM	1.21323	1.16147	1.26500
10/12/2020 H:9 AM	1.20972	1.20740	1.21205	13/12/2020 H:1 AM	1.21329	1.16073	1.26584
10/12/2020 H:10 AM	1.20978	1.20672	1.21284	13/12/2020 H:2 AM	1.21334	1.16000	1.26669
10/12/2020 H:11AM	1.20984	1.20601	1.21366	13/12/2020 H:3 AM	1.21340	1.15927	1.26753
10/12/2020 H:12 AM	1.20989	1.20530	1.21449	13/12/2020 H:4 AM	1.21346	1.15854	1.26837
10/12/2020 H:13 PM	1.20995	1.20458	1.21532	13/12/2020 H:5 AM	1.21351	1.15781	1.26922
10/12/2020 H:14PM	1.21000	1.20386	1.21615	13/12/2020 H:6 AM	1.21357	1.15707	1.27006

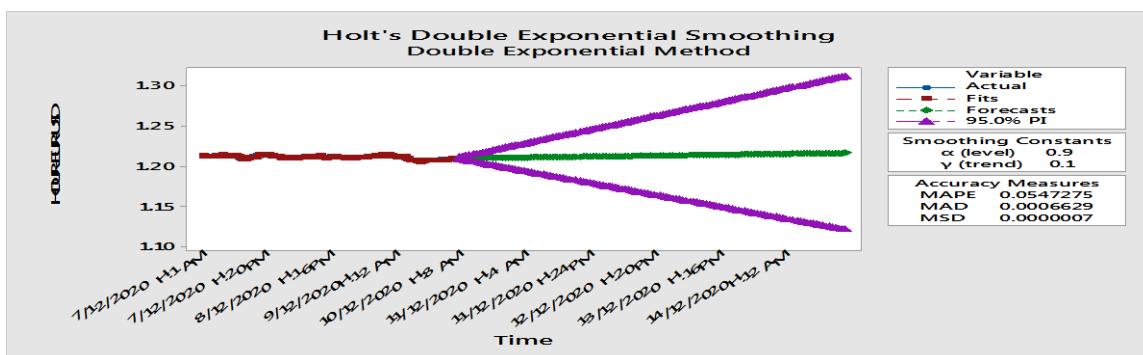
10/12/2020	1.21006	1.20313	1.21699	13/12/2020	1.21362	1.15634	1.27090
H:15PM				H:7 AM			
10/12/2020	1.21011	1.20241	1.21782	13/12/2020	1.21368	1.15561	1.27175
H:16PM				H:8 AM			
10/12/2020	1.21017	1.20168	1.21866	13/12/2020	1.21373	1.15488	1.27259
H:17PM				H:9 AM			
10/12/2020	1.21023	1.20095	1.21950	13/12/2020	1.21379	1.15415	1.27343
H:18PM				H:10 AM			
10/12/2020	1.21028	1.20022	1.22034	13/12/2020	1.21385	1.15342	1.27428
H:19PM				H:11AM			
10/12/2020	1.21034	1.19949	1.22118	13/12/2020	1.21390	1.15268	1.27512
H:20PM				H:12AM			
10/12/2020	1.21039	1.19876	1.22202	13/12/2020	1.21396	1.15195	1.27596
H:21PM				H:13 PM			
10/12/2020	1.21045	1.19803	1.22286	13/12/2020	1.21401	1.15122	1.27681
H:22PM				H:14PM			
10/12/2020	1.21050	1.19730	1.22370	13/12/2020	1.21407	1.15049	1.27765
H:23PM				H:15PM			
10/12/2020	1.21056	1.19657	1.22455	13/12/2020	1.21412	1.14976	1.27849
H:24PM				H:16PM			
11/12/2020	1.21062	1.19584	1.22539	13/12/2020	1.21418	1.14903	1.27934
H:1 AM				H:17PM			
11/12/2020	1.21067	1.19511	1.22623	13/12/2020	1.21424	1.14829	1.28018
H:2 AM				H:18PM			
11/12/2020	1.21073	1.19438	1.22707	13/12/2020	1.21429	1.14756	1.28102
H:3 AM				H:19PM			
11/12/2020	1.21078	1.19365	1.22791	13/12/2020	1.21435	1.14683	1.28187
H:4 AM				H:20PM			
11/12/2020	1.21084	1.19292	1.22876	13/12/2020	1.21440	1.14610	1.28271
H:5 AM				H:21PM			
11/12/2020	1.21089	1.19219	1.22960	13/12/2020	1.21446	1.14537	1.28355

H:6 AM				H:22PM			
11/12/2020	1.21095	1.19146	1.23044	13/12/2020	1.21451	1.14463	1.28439
H:7 AM				H:23PM			
11/12/2020	1.21101	1.19073	1.23128	13/12/2020	1.21457	1.14390	1.28524
H:8 AM				H:24PM			
11/12/2020	1.21106	1.19000	1.23213	14/12/2020	1.21463	1.14317	1.28608
H:9 AM				H:1 AM			
11/12/2020	1.21112	1.18927	1.23297	14/12/2020	1.21468	1.14244	1.28692
H:10 AM				H:2 AM			
11/12/2020	1.21117	1.18853	1.23381	14/12/2020	1.21474	1.14171	1.28777
H:11AM				H:3 AM			
11/12/2020	1.21123	1.18780	1.23465	14/12/2020	1.21479	1.14098	1.28861
H:12 AM				H:4 AM			
11/12/2020	1.21128	1.18707	1.23550	14/12/2020	1.21485	1.14024	1.28945
H:13 PM				H:5 AM			
11/12/2020	1.21134	1.18634	1.23634	14/12/2020	1.21490	1.13951	1.29030
H:14PM				H:6 AM			
11/12/2020	1.21140	1.18561	1.23718	14/12/2020	1.21496	1.13878	1.29114
H:15PM				H:7 AM			
11/12/2020	1.21145	1.18488	1.23802	14/12/2020	1.21502	1.13805	1.29198
H:16PM				H:8 AM			
11/12/2020	1.21151	1.18415	1.23887	14/12/2020	1.21507	1.13732	1.29283
H:17PM				H:9 AM			
11/12/2020	1.21156	1.18341	1.23971	12/12/2020	1.21279	1.16732	1.25826
H:18PM				H:16PM			
11/12/2020	1.21162	1.18268	1.24055	12/12/2020	1.21284	1.16659	1.25910
H:19PM				H:17PM			
11/12/2020	1.21167	1.18195	1.24140	12/12/2020	1.21290	1.16586	1.25994
H:20PM				H:18PM			
11/12/2020	1.21173	1.18122	1.24224	12/12/2020	1.21296	1.16512	1.26079
H:21PM				H:19PM			

11/12/2020 H:22PM	1.21179	1.18049	1.24308	12/12/2020 H:20PM	1.21301	1.16439	1.26163
11/12/2020 H:23PM	1.21184	1.17976	1.24392	12/12/2020 H:21PM	1.21307	1.16366	1.26247
11/12/2020 H:24PM	1.21190	1.17903	1.24477	12/12/2020 H:22PM	1.21312	1.16293	1.26332
12/12/2020 H:1 AM	1.21195	1.17829	1.24561	12/12/2020 H:23PM	1.21318	1.16220	1.26416
12/12/2020 H:2 AM	1.21201	1.17756	1.24645	14/12/2020 H:10 AM	1.21513	1.13658	1.29367
12/12/2020 H:3 AM	1.21206	1.17683	1.24730	14/12/2020 H:11AM	1.21518	1.13585	1.29451
12/12/2020 H:4 AM	1.21212	1.17610	1.24814	14/12/2020 H:12 AM	1.21524	1.13512	1.29536
12/12/2020 H:5 AM	1.21218	1.17537	1.24898	14/12/2020 H:13 PM	1.21529	1.13439	1.29620
12/12/2020 H:6 AM	1.21223	1.17464	1.24983	14/12/2020 H:14PM	1.21535	1.13366	1.29704
12/12/2020 H:7 AM	1.21229	1.17390	1.25067	14/12/2020 H:15PM	1.21541	1.13293	1.29789
12/12/2020 H:8 AM	1.21234	1.17317	1.25151	14/12/2020 H:16PM	1.21546	1.13219	1.29873
12/12/2020 H:9 AM	1.21240	1.17244	1.25235	14/12/2020 H:17PM	1.21552	1.13146	1.29957
12/12/2020 H:10 AM	1.21245	1.17171	1.25320	14/12/2020 H:18PM	1.21557	1.13073	1.30042
12/12/2020 H:11AM	1.21251	1.17098	1.25404	14/12/2020 H:19PM	1.21563	1.13000	1.30126
12/12/2020 H:12AM	1.21257	1.17025	1.25488	14/12/2020 H:20PM	1.21568	1.12927	1.30210
12/12/2020	1.21262	1.16951	1.25573	14/12/2020	1.21574	1.12853	1.30295

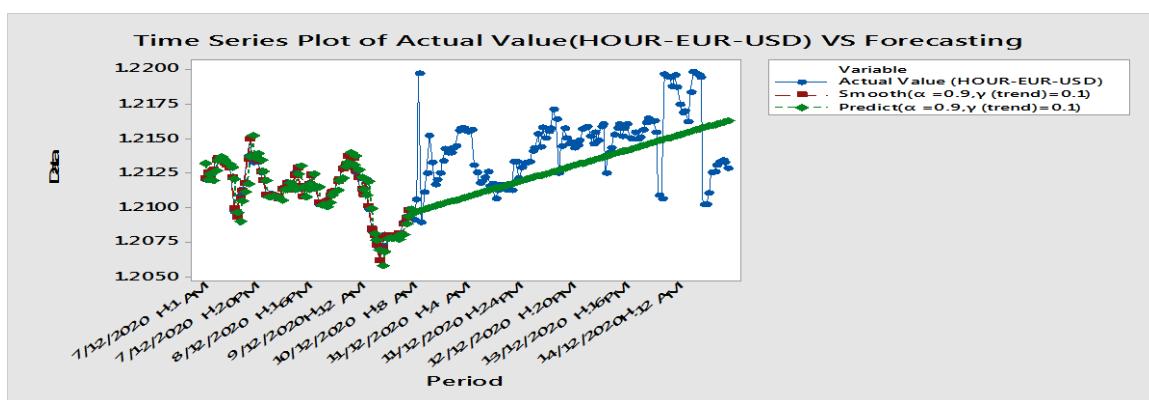
H:13 PM				H:21PM			
12/12/2020	1.21268	1.16878	1.25657	14/12/2020	1.21580	1.12780	1.30379
H:14PM				H:22PM			
12/12/2020	1.21273	1.16805	1.25741	14/12/2020	1.21585	1.12707	1.30463
H:15PM				H:23PM			
				14/12/2020	1.21591	1.12634	1.30547
				H:24PM			
				15/12/2020	1.21596	1.12561	1.30632
				H:1 AM			
				15/12/2020	1.21602	1.12488	1.30716
				H:2 AM			
				15/12/2020	1.21607	1.12414	1.30800
				H:3 AM			
				15/12/2020	1.21613	1.12341	1.30885
				H:4 AM			
				15/12/2020	1.21619	1.12268	1.30969
				H:5 AM			
				15/12/2020	1.21624	1.12195	1.31053
				H:6 AM			
				15/12/2020	1.21630	1.12122	1.31138
				H:7 AM			

. المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab



الشكل (7): يمثل: القيم الأصلية، والقيم المقدرة، والقيم المتتبّأ بها، ومدد الثقة لسلسلة بيانات لسعر الصرف اليومي للليورو أمام دولار لمدة من (15/12/2020 H:7 AM -10/12/2020 H:8 AM).

. المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .



الشكل (8) : يمثل رسم: القيم الحقيقة، والقيم التمهيدية، والقيم التنبؤية المستقبلية لسلسلة بيانات لسعر الصرف اليومي لليورو أمام الدولار لمدة من (15/12/2020 H:7 AM -10/12/2020 H:8 AM).

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

في الشكلين (7) و(8) يشير اللون الأزرق إلى قيم السلسلة الأصلية لبيانات سعر الصرف اليومي لليورو أمام الدولار، واللون الماروني يشير إلى القيم الممهدة، واللون الأخضر يشير إلى القيم المتنبأ بها، ويشير اللون البنفسجي للحد الأدنى والحد الأعلى للقيم المتنبأ بها بمستوى ثقة 95%. ونلاحظ أن البيانات لسعر الصرف اليومي لليورو أمام الدولار لمدة من (15/12/2020 H:7 AM -10/12/2020 H:8 AM)، كانت تسير نحو التزايد، وأن الفرق بين القيم المتنبأ بها وبين القيم الأصلية للسلسلة كان متقارباً مما يدل على دقة التنبؤ.

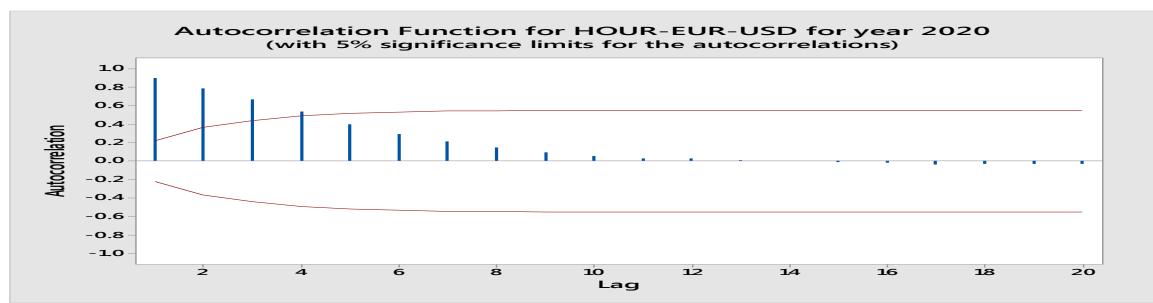
بعاره أخرى يمثل التنبؤ لخطوة واحدة للأمام ل(120) مدة زمنية مستقبلية لسعر الصرف اليومي لليورو أمام الدولار لمدة من (15/12/2020 H:7 AM -10/12/2020 H:8 AM)، ونلاحظ من خلال فحص الشكلين (7-8) بأن قيم التنبؤات تسلك سلوك السلسلة الأصلية باتجاه عام متزايد، لذا يُعدّ أنموذج التمهيد الأسّي المزدوج (طريقة هولت) أنموذجاً ملائماً لبيانات المتاحة، هذا في الجانب الإحصائي .

2: التنبؤ لسعر الصرف اليومي لليورو أمام الدولار استعمال الشبكات العصبية الاصطناعية

إن خطة التنبؤ للسلسلة الزمنية لسعر الصرف اليومي لليورو أمام الدولار هي استعمال الشبكات العصبية الاصطناعية ذات التغذية الأمامية في الجانب الرياضي ،والتي تتكون من ثلاثة مراحل هي:

1- احتساب عدد المدخلات الضرورية لمتنبئ الشبكة العصبية الاصطناعية.

للكشف عن إنماط الإدخال الصحيحة للتنبؤ بالسلسلة الزمنية غير الخطية من خلال الشبكات العصبية واستعمال تحليل الارتباط الذاتي، وستنطرق في هذا البحث إلى استعمال دالة الارتباط الذاتي ACF لتحديد عدد إنماط المدخلات. ويوضح الشكل (9) دالة الارتباط الذاتي للسلسلة الزمنية لسعر الصرف اليومي لليورو أمام الدولار لمدة من (10/12/2020 H:7 AM -7/12/2020 H:1 AM). ويتبّع من هذا الشكل وجود ارتباطات ذاتية معنوية قوية حتى التخلف الثاني وارتباطات ذاتية ضعيفة من التخلف الثالث إلى الرابع لذلك فإنّ عدد العقد العصبية في طبقة المدخلات يتغيّر (من 2 إلى 4) عصبونات ،عتماداً على عدد الارتباطات المعنوية فكانت أفضل نتائج التدريب مع (2) عصبونات، لتمثّل عدد العصبونات في طبقة المدخلات في هذا البحث، مما أثبت صحة ذلك في مرحلة إعداد البيانات Preprocessing Data . التي تمثل المرحلة الأولى في البرنامج لتحديد عدد مدخلات الشبكة العصبية، وكان عدد المدخلات أيضاً لمتنبئ الشبكة العصبية الاصطناعية تساوي (2) وسيتم ذكرها لاحقاً.



الشكل (9) : دالة الارتباط الآتي ACF لبيانات السلسلة الزمنية لسعر الصرف اليومي للاليورو أمام الدولار لمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM)

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

2- احتساب عدد العصبونات في الطبقة المخفية

استعمال المعادلة (11) الآتية والمذكورة سابقاً في الجانب النظري ،والمعروفة بقاعدة بام هاسлер Baum-Haussler Rules ، لاحتساب عدد العصبونات في الطبقة المخفية للتنبؤ بالسلسلة الزمنية استعمال الشبكات العصبية.

$$N_{\text{Hidden.}} \leq \frac{N_{\text{Train.}} E_{\text{Tolerance.}}}{N_{\text{Pts.}} + N_{\text{Output.}}} \quad (11)$$

لقد تم تثبيت مقدار الخطأ المسموح به $E_{\text{Tolerance.}}$ كي يكون 0.01 ، وعدد مرات التدريب $N_{\text{Train.}} = 10000$ ، وعدد نقاط البيانات (أنماط الإدخال) لكل مثال تدريب 2 ، وعدد عصبونات الإخراج $N_{\text{Output.}} = 1$ وبتطبيق المعادلة المذكورة آنفًا نجد أن:

$$N_{\text{Hidden.}} \leq \frac{10000 \times 0.01}{2+1} = \frac{100}{3}$$

$$N_{\text{Hidden.}} \leq 33$$

لذا فإنّ عدد العصبونات في الطبقة المخفية هي أقل أو تساوي 33، وتمثل 33 الحد الأعلى لعدد العصبونات في الطبقة المخفية.

3- عدد العصبونات في طبقة الإخراج

إنّ العصبونات في طبقة الإخراج تتطلب عصبونا واحدا فقط في الشبكة العصبية للسلسلة الزمنية ،كما ذكر سابقاً في الجانب النظري .

تم تصميم برنامج حاسوبي للحصول على قيم التنبؤ لمتسلسلة المشاهدات دون الحاجة لمعالجة الاستقرارية، باستعمال برنامج نظام الشبكات العصبية الجاهز والذي يعرف (Alyuda NeuroIntelligence) . إن البيانات المستعملة في هذه الدراسة يبلغ عددها (79) مشاهدة، إذ يتضمن البرنامج مرحلتين أساس هما:

المرحلة الأولى: تحليل البيانات Analysis Data: وقد شملت هذه المرحلة تقسيم البيانات إلى مجاميع عدّة (69.23%) (15.38%) من المشاهدات لمجموعة بيانات التدريب Training set (الشرعية Validation set) . في حين عدّة (15.38%) من المشاهدات لمجموعة بيانات الاختبار Testing set .

المرحلة الثانية: إعداد البيانات Preprocessing Data تستعمل لتحويلها إلى الصيغة القياسية (Normalize)، وتحديد مدخلات الشبكة العصبية، وبعد تهيئه البيانات لإدخالها إلى الشبكة يتم بناء هيكلية الشبكة.

المرحلة الثالثة: تحديد هيكلية الشبكة العصبية Neural network Architecture

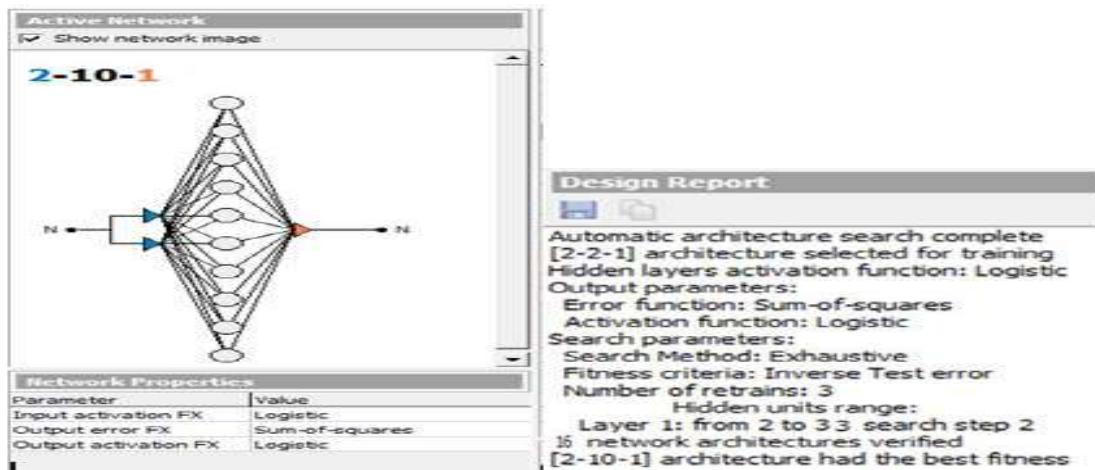
في هذه المرحلة تم استعمال دالة التنشيط Logistics في الطبقة المخفية وطبقة الارجاع . وتم تدريب الشبكات باستعمال خوارزمية الانشار العكسي الرزم (الدفع) Batch Back Propagation Algorithm ، إذ بلغ عدد التكرارات (Iterations=10000) تكرار ، وعدد مرات إعادة التدريب Number of Retrains=3 ، وعدد العصبونات في الطبقة المخفية هي أقل أو تساوي 33 وفق معادلة بام هاسلر المعروفة . واستعمال هذه العصبونات المخفية لاختيار أفضلها. وكان عددها يتراوح بين [33-2] عصبون ، للحصول على أفضل هيكلية للشبكة العصبية الاصطناعية من بين معماريات عدة. أثناء البحث الشامل Exhaustive Search ، وفقاً لمعايير المطابقة Fitness Criterion ، ولا سيما لمعيار المطابقة Fitness الذي يعطي أكبر قيمة لهذا المعيار(ويُمثل: مقلوب قيم معكوس خطأ الاختبار Inverse Test error) ، ومعيار معكوس خطأ الاختبار Inverse Test error الذي يعطي أقل قيمة لهذا المعيار؛ من أجل الحصول على الأنماذج الملائمة للتنبؤ بالقيم المستقبلية .

ومن الجدول رقم (4) ، نلاحظ أن أفضل معمارية للشبكة العصبية هي [2-10-1] من بين المعماريات الأخرى وفقاً لهذه المعاير ، كما مبين بالجدول الآتي :

الجدول (4) : النتائج الإحصائية لهيكلية شبكات عصبية عدة وفقاً لمعايير المطابقة Fitness Criterion

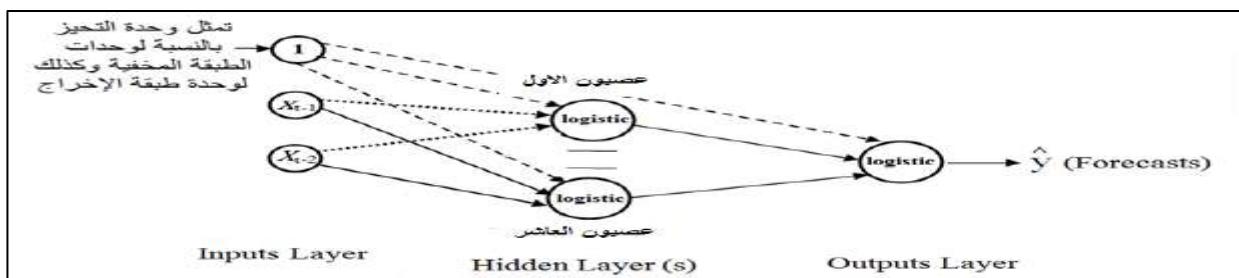
ID	Architecture	# of Weights	Fitness	Inverse Test error	Akaike's criterion	R-Squared	Correlation	Train Error
1	[2-2-1]	9	408.917045	0.002445	-0.00178	0.107275	0.827677	0.001174
2	[2-4-1]	17	1976.270591	0.000506	-0.001852	0.235805	0.769259	0.001311
3	[2-6-1]	25	2017.935198	0.000496	-0.001899	0.306693	0.774743	0.001246
4	[2-8-1]	33	2101.410321	0.000476	-0.001952	0.348114	0.782675	0.001206
5	[2-10-1]	41	2183.614109	0.000458	-0.002009	0.378486	0.789584	0.001175
6	[2-12-1]	49	1981.141496	0.000505	-0.001926	0.777422	0.887861	0.000586
7	[2-14-1]	57	2009.022935	0.000498	-0.001987	0.777721	0.888123	0.000585
8	[2-16-1]	65	2032.300883	0.000492	-0.002052	0.777796	0.888309	0.000585
9	[2-18-1]	73	2052.274384	0.000487	-0.002122	0.777822	0.888454	0.000585
10	[2-20-1]	81	2069.642234	0.000483	-0.002196	0.777816	0.888569	0.000585
11	[2-22-1]	89	2084.91521	0.00048	-0.002276	0.777789	0.888663	0.000585
12	[2-24-1]	97	2095.637108	0.000477	-0.002362	0.777689	0.888723	0.000585
13	[2-26-1]	105	2110.258174	0.000474	-0.002455	0.777692	0.888801	0.000585
14	[2-28-1]	113	2120.899729	0.000471	-0.002555	0.777633	0.888853	0.000585
15	[2-30-1]	121	2106.908917	0.000475	-0.002664	0.777295	0.888808	0.000586
16	[2-32-1]	129	427.612521	0.002339	-0.004161	-10.1325	0.819823	0.005305

المصدر: من إعداد الباحثة بالاعتماد على مخرجات برنامج نظام الشبكات العصبية Alyuda



الشكل(10): هيكلية الشبكة العصبية الأنماذجية المثلثي (مع عدم أظهار وحدة التحيز في مخطط الشبكة)

المصدر: من إعداد الباحثة بالاعتماد على مخرجات برنامج نظام الشبكات العصبية Alyuda



الشكل (11): هيكلية الشبكة العصبية الأنماذجية المثلثي [2-10-1] لمتباين السلسلة الزمنية بطبقة مخفية واحدة

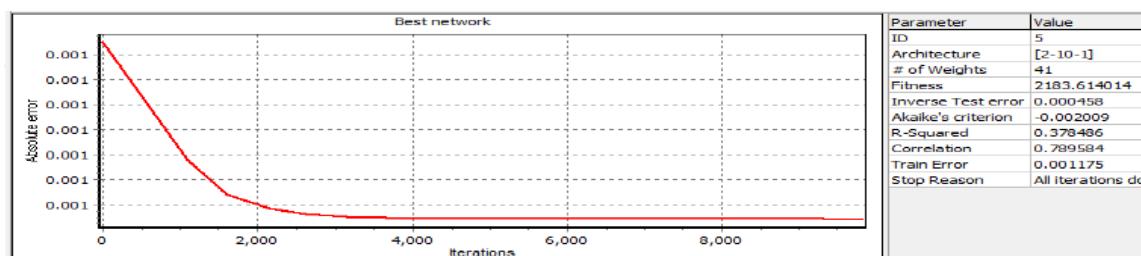
المصدر: من إعداد الباحثة

ونلاحظ أيضاً من الجدول(4) والشكل (11-10-1)، بأنّ عدد الأوزان للشبكة المثلثي [2-10-1] تساوي 41 وزن، وذلك

ينطبق مع المعادلة (12) المذكورة في الجانب النظري:

$$P = (n_{Input} + 2) \cdot n_{Hidden} + 1 \quad (12)$$

$$P = (2 + 2) \times 10 + 1 = 41 \quad \text{وزن}$$



الشكل(12): منحنى تدريب أفضل شبكة العصبية [2-10-1] استعمال خوارزمية الانتشار العكسي الدفع

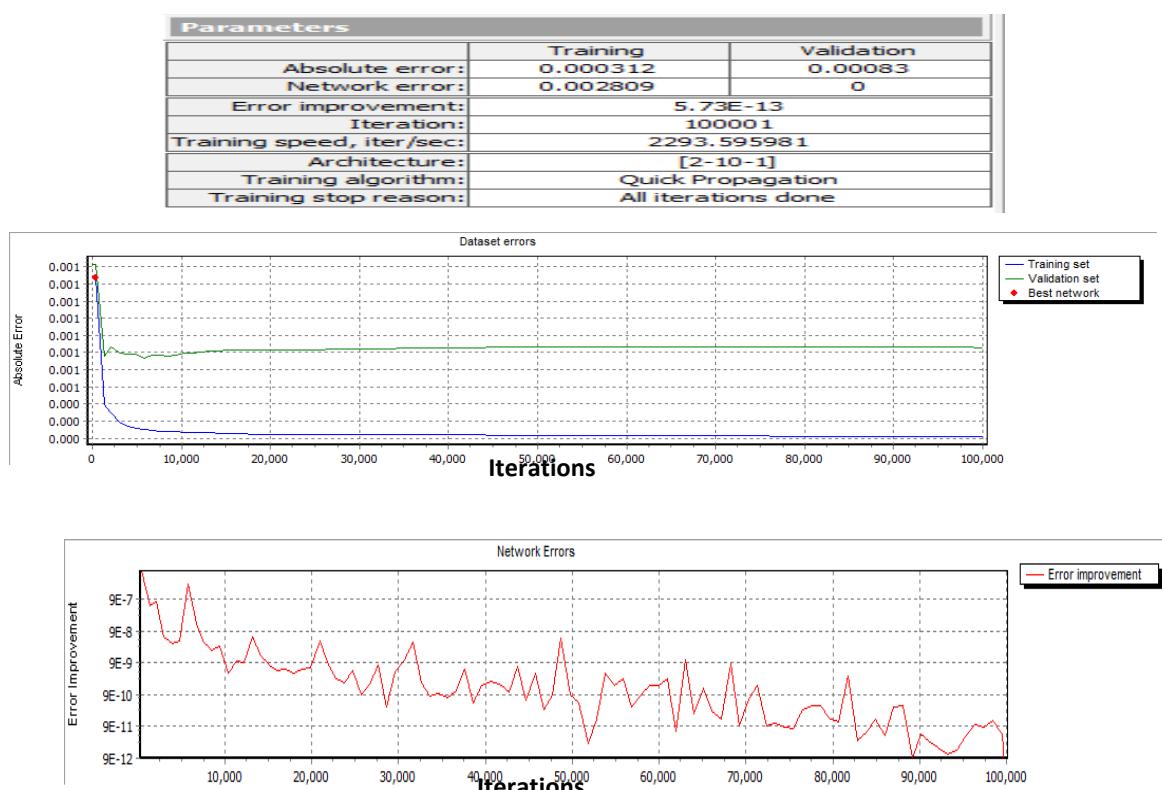
المصدر: من إعداد الباحثة بالاعتماد على مخرجات برنامج نظام الشبكات العصبية Alyuda

المرحلة الرابعة: بناء لمتنبئ الشبكة العصبية

للحصول على قيم التنبؤ للشبكة العصبية (التنبؤ لخطوة واحدة للأمام) لسعر الصرف اليومي للبيورو أمام الدولار لمدة من 15/12/2020 H:7 AM - 10/12/2020 H:8 AM ، تم تدريب واختبار الشبكة الأفضل وهي [2-10-1] التي عُدّت أفضل شبكة من بين الشبكات الأخرى باستعمال خوارزمية ، وذلك لاختيار أفضلهم وكالاتي:

A- استعمال خوارزمية الانتشار السريع Quick Propagation algorithm

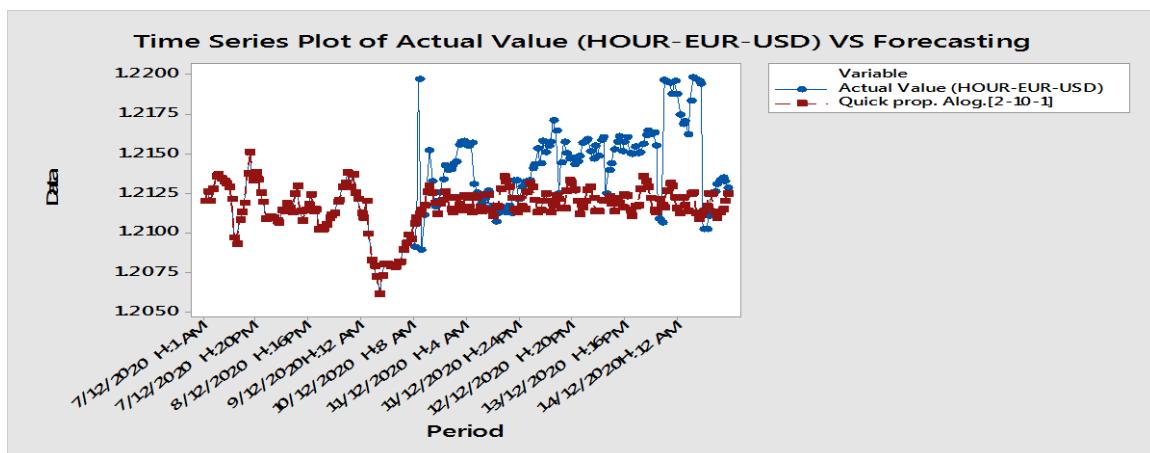
في هذه الخوارزمية تم تثبيت معامل الانتشار السريع (Quick Propagation Coefficient=1.75) ونسبة التعلم (Learrning Rate =0.9) ، وعدد التكرارات (Iterations=100000) تكرار، فضلاً عن عدد مرات إعادة التدريب(Number of Retrains=2) ، وبعد تدريب الشبكة بالاعتماد على المعلومات المذكورة آنفًا تم الحصول على النتائج الآتية :



الشكل(13): منحنيات لتدريب الشبكة [2-10-1] استعمال خوارزمية الانتشار السريع

المصدر: من إعداد الباحثة بالاعتماد على مخرجات برنامج نظام الشبكات العصبية Alyuda

يتبيّن من الشكل (13) أنّ مجموعة الشرعية (التحقيق) سلكت سلوك مجموعة التدريب نفسه ، وأنّ الخطأ المطلق(AE) لمجموعة التدريب كان الأقل . أمّا شكل منحني الخطأ المطلق للشبكة (AE) فيأخذ بالتناقص مع زيادة عدد مرات التكرار تحسين الخطأ (Error Improvement) مما يسرع ويحسن من قدرة الشبكة العصبية على التنبؤ، لذا فهو مفيد لاكتشاف الحالة عندما تكون الشبكة غير محسنة ، فضلاً عن التدريب غير المجد. ومن خلال تدريب واختبار الشبكة العصبية[2-10-1] تم التوصل إلى قيم التنبؤ المستقبلي لسعر الصرف اليومي للبيورو أمام الدولار لمدة من 15/12/2020 H:7 AM - 10/12/2020 H:8 AM) استعمال خوارزمية الانتشار السريع الذي يُمثل قيم التنبؤ لخطوة واحدة للأمام كما موضح في الملحق (1) والشكليين (14-15) الآتيين:



الشكل (15) : يُمثّل رسم القيم الحقيقية والقيم التنبؤية المستقبلية لسلسلة بيانات لسعر الصرف اليومي لليورو أمام الدولار لمدة من 15/12/2020 H:7 AM - 10/12/2020 H:8 AM (15) استعمال خوارزمية الانتشار السريع.

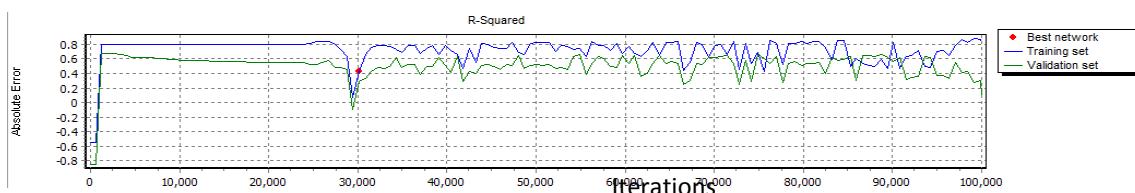
المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

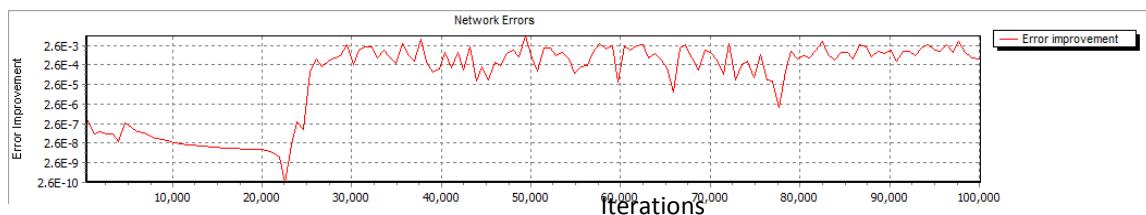
في الشكل (15) يشير اللون الأزرق قيم السلسلة الأصلية لبيانات سعر الصرف اليومي لليورو أمام الدولار، واللون الماروني يشير لقيم المُتنبأ بها. ونلاحظ أن بيانات لسعر الصرف اليومي لليورو أمام دولار لمدة من 10/12/2020 H:7 AM - H:8 AM (15/12/2020 H:7 AM - 15/12/2020 H:8 AM)، يُمثّل التنبؤ خطوة واحدة للأمام لـ (120) مدة زمنية مستقبلية ، ونلاحظ من خلال فحص الشكل (15) أنَّ قيم التنبؤات المستقبلية تسلك سلوك السلسلة الأصلية على الرغم من أنَّ قيم التنبؤات الشبكة الاصطناعية المذكورة تقارب قيم السلسلة الأصلية، لذا تُعدُّ أنموذجاً ملائماً للبيانات المتاحة.

ب- استعمال خوارزمية الانتشار العكسي التزادي (الإضافي) (Online) Incremental Back Propagation algorithm

في هذه الخوارزمية تم تثبيت معلمات التدريب والتي تمثل نسبة التعلم (Learning Rate=0.9)، وثابت الزخم (Momentum Constant =0.9) ، عدد التكرارات Iterations =100000 ، Training speed, iter/sec: 1858.75006 ، Training algorithm: Online Back Propagation ، Training stop reason: All iterations done ، وبعد تدريب الشبكة بالاعتماد على المعلمات تم الحصول على النتائج الآتية:

Parameters		
	Training	Validation
Absolute error:	0.000503	0.001061
Network error:	0.00593	0
Error improvement:	0.000593	
Iteration:	100001	
Training speed, iter/sec:	1858.75006	
Architecture:	[2-10-1]	
Training algorithm:	Online Back Propagation	
Training stop reason:	All iterations done	

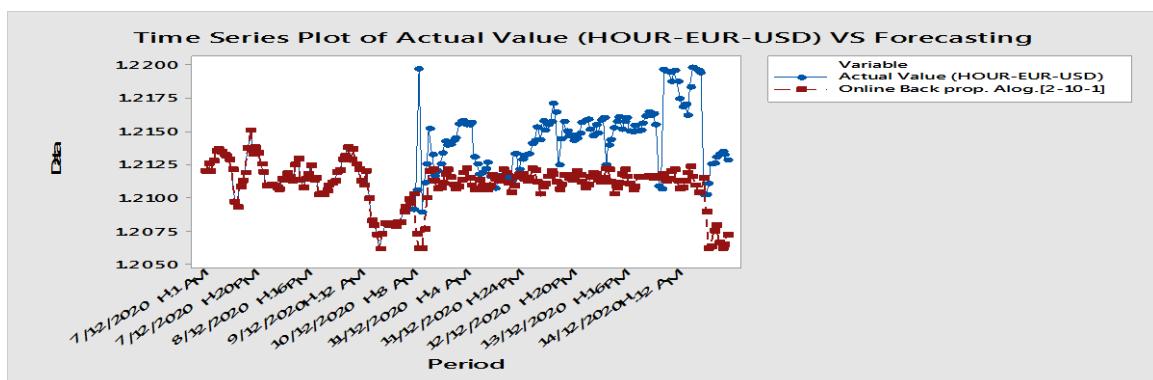




الشكل(16): منحنيات لتدريب الشبكة [10-2] استعمال خوارزمية الانتشار العكسي التزايدى

المصدر: من إعداد الباحثة بالاعتماد على مخرجات برنامج نظام الشبكات العصبية Alyuda

يتبيّن من الشكل (16) أنَّ مجموعة الشرعية (التحقّق) سلكت سلوك مجموعة التدريب نفسه، وأنَّ الخطأ المطلق (AE) لمجموعة التدريب كان الأقل. أمّا شكل منحنى الخطأ المطلق للشبكة (AE) فيأخذ بالتلاقص والتزايد بشكل متذبذب مع زيادة عدد مرات التكرار تحسين الخطأ (Error Improvement)، مما يُسرّع ويعزّز من قدرة الشبكة العصبية على التنبؤ، لذا فهو مفيد لاكتشاف الحالة عندما تكون الشبكة غير محسنة، وفضلاً عن التدريب غير المجدى. ومن خلال تدريب واختبار الشبكة العصبية [10-1] ثمَّ التوصل إلى قيم التنبؤ المستقبلى لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:7 AM - 15/12/2020 H:8 AM) باستعمال خوارزمية الانتشار العكسي التزايدى الذي يمثّل قيم التنبؤ لخطوة واحدة للأمام كما موضح الملحق (1) والشكل(17-18) الآتى:

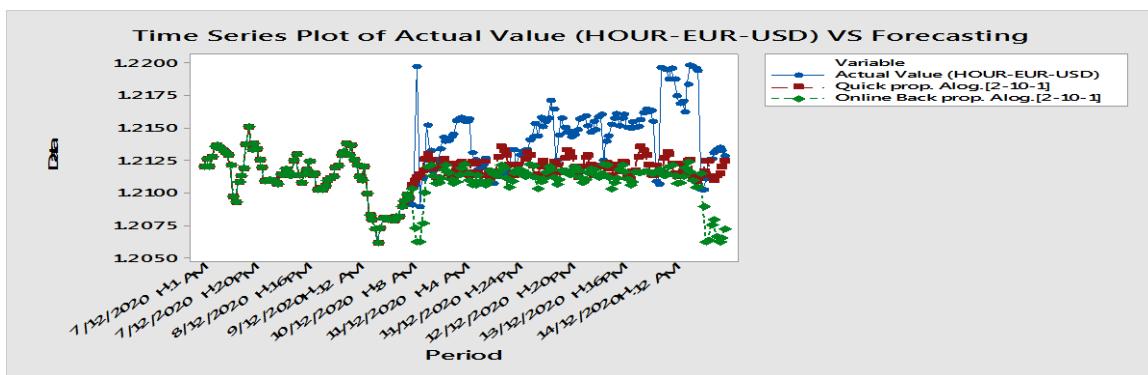


الشكل (18) : يُمثل رسم القيم الحقيقية والقيم التنبؤية المستقبلية لسلسلة بيانات سعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:7 AM - 15/12/2020 H:8 AM) استعمال خوارزمية الانتشار العكسي التزايدى

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

يشير اللون الأزرق في الشكل (18) إلى قيم السلسلة الأصلية لبيانات سعر الصرف اليومي للبيورو أمام الدولار، واللون الماروني يشير لقيم المُتنبأ بها. إذ نلاحظ أنَّ بيانات لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:7 AM - 15/12/2020 H:8 AM)، يمثّل التنبؤ لخطوة واحدة للأمام – (120) مدة زمنية مستقبلية. ونلاحظ من خلال فحص الشكل (18) بأنَّ قيم التنبؤات المستقبلية تسلّك سلوك السلسلة الأصلية، على الرغم من أنَّ قيم التنبؤات الشبكة الاصطناعية المذكورة لاقرابة قيم السلسلة الأصلية على عكس خوارزمية الانتشار السريع .

الملحق (1) والشكل (19) يبيّنان قيم التنبؤات المستقبلية للشبكة العصبية الاصطناعية [10-2] لبيانات السلسلة الزمنية لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:7 AM - 15/12/2020 H:8 AM) باستعمال الخوارزميات السابقة مقارنة مع القيم الحقيقة.



الشكل (19) : يوضح مقارنة بين القيم الحقيقة والقيم التنبؤية المستقبلية للشبكة العصبية الاصطناعية [2-10-1] (استعمال خوارزمية الانتشار العكسي التزايدى وخوارزمية الانتشار السريع) لسلسلة بيانات لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (15/12/2020 H:7 AM - 10/12/2020 H:8 AM)

المصدر: من إعداد الباحثة بالاعتماد على مُخرجات البرنامج الإحصائي Minitab .

نلاحظ من الملحق (1) والرسم (19) بأنَّ قيم التنبؤات المستقبلية للشبكة العصبية الاصطناعية [2-10-1] (سواء كانت باستعمال خوارزمية الانتشار السريع أو خوارزمية الانتشار العكسي التزايدى) لبيانات سعر الصرف اليومي للبيورو أمام الدولار لمدة من (15/12/2020 H:7 AM-10/12/2020 H:8 AM)، بأنَّ قيم التنبؤات المستقبلية تسلك إلى حدٍ كبير سلوك قيم السلسلة الأصلية، ولاسيما نتائج خوارزمية الانتشار السريع Quick Propagation algorithm ، على الرغم من أنَّ قيم لتنبؤات الشبكة الاصطناعية المذكورة تقارب قيم السلسلة الأصلية.

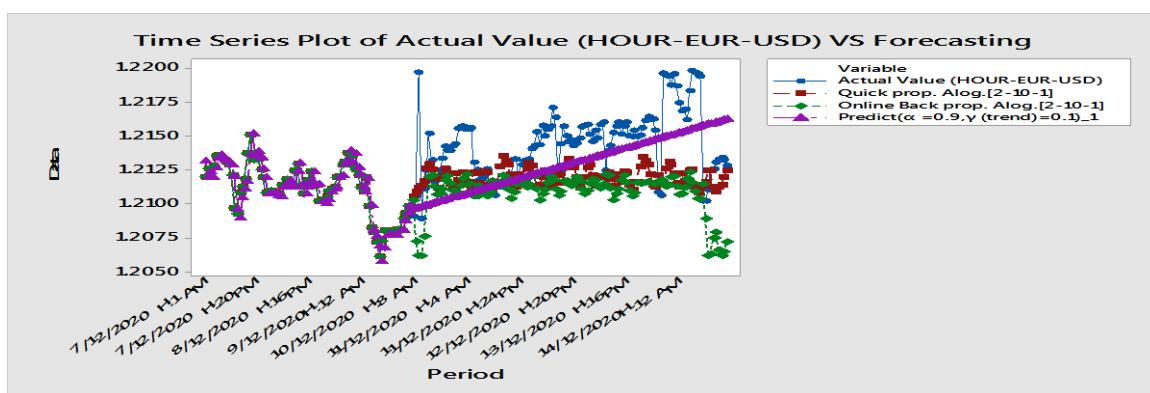
3: دراسة المقارنة بين نتائج الطريقة الإحصائية وطريقة الشبكات العصبية الاصطناعية

سيتم إجراء المقارنة بين أنموذج التمهيد الأسّي المزدوج (طريقة هولت) و أنموذج الشبكة العصبية الاصطناعية [2-10-1] (سواء أكانت استعمال خوارزمية الانتشار السريع أم خوارزمية الانتشار الخلفي التزايدى) من أجل الحصول على تنبؤات مستقبلية لسعر الصرف اليومي للبيورو أمام الدولار لمدة من (10/12/2020 H:8 AM - 15/12/2020 H:7 AM)، وفقاً لمعيار متوسط مربع الخطأ (MSE)، لمعرفة مدى القوة التنبؤية للأنموذج المستعمل؛ لأنَّ المعيار الأكثر استعمالاً و شيوعاً لاختيار الأنماذج الأكفاء والأمثل الذي يعطي أقل قيمة لهذا المعيار واستعماله للتنبؤات المستقبلية كما موضح في الجدول (5). والشكل (20) الآتيان:

الجدول(5): مقارنة بين أنموذج التمهيد الأسّي المزدوج (طريقة هولت) عند استعمال ($\alpha = 0.9, \gamma = 0.1$) مع أنموذج الشبكة العصبية الاصطناعية [2-10-2] استعمال الخوارزميتين وفقاً لمقاييس دقة التنبؤ

مقاييس دقة التنبؤ	أنموذج التمهيد الأسّي المزدوج (طريقة هولت) عند استخدام ($\alpha = 0.9, \gamma = 0.1$)	أنموذج الشبكة العصبية الاصطناعية [2-10-1]	
		Online Back Propagation Alog	Quick Propagation Alog.
MSE or MSD	0.0000007	0.0000003	0.0000002*
تمثل القيمة المثلثى التي تعطى أقل قيمة لمتوسط مربع الخطأ MSE or MSD			(*)

المصدر: من إعداد الباحثة بالاعتماد على مُخرجات البرنامج الإحصائي Minitab .



الشكل (20): يوضح مقارنة بين القيم الحقيقة والقيم التنبؤية المستقبلية للشبكة العصبية الاصطناعية [2-10-1] (استعمال خوارزمية الانتشار العكسي التزايدية وخوارزمية الانتشار السريع) مع طريقة هولت لسلسلة بيانات لسعر الصرف اليومي لليورو أمام الدولار لمدة من (15/12/2020 H:7 AM -10/12/2020 H:8 AM)

المصدر: من إعداد الباحثة بالاعتماد على مخرجات البرنامج الإحصائي Minitab .

وفي ضوء المعايير الموضحة ولاسيما معيار متوسط مربع الخطأ ($MSE=0.0000002$ *) في الجدول (5)، نرى أنَّ أنموذج الشبكة العصبية الاصطناعية [2-10-1] باستعمال خوارزمية الانتشار السريع لسعر الصرف اليومي لليورو أمام الدولار وفقاً لمعيار متوسط مربع الخطأ (MSE)، قد أعطت مؤشرات أقل من مؤشرات أنموذج الشبكة العصبية الاصطناعية [2-10-1] باستعمال خوارزمية الانتشار العكسي التزايدية ، وأنموذج التمهيدي الأسي المزدوج (طريقة هولت) ، الأمر الذي يشير بوضوح بأنه الأنماذج الملائم والأكفاء تقدير التنبؤات المستقبلية لمدة من (15/12/2020 H:7 AM-10/12/2020 H:8 AM) . إذ أظهرت هذه القيم تتناسبًا مع مثيلاتها في السلسلة الأصلية، وقدّمت لنا صورة مستقبلية لواقع لسعر الصرف اليومي لليورو أمام الدولار لذاك المدة. كما موضح بالملحق (1) والجدول (6) والأشكال (15،19،20)، مما ثبت صحة فرضية البحث.

الاستنتاجات : توصل البحث إلى مجموعة من الاستنتاجات نوجزها بالآتي :

- إنَّ زوج العملات اليورو دولار تُعد من أكثر الأزواج تداولًا في سوق الفوركس، إذ إنَّ معظم سيولة هذا السوق العالمي تأتي من هاتين العملاتين، وشهدت العلاقة بينهما تطويراً كبيراً منذ إطلاق اليورو . وتشير هذه العلاقة إجمالاً إلى التراجع في قيمة اليورو أمام الدولار عبر السنوات؛ لأنَّ الدولار من العملات القيادية الدولية التي تهيمن على نسب تقدُّر بنحو 60% من الاحتياطيات المالية الدولية ، أما اليورو يتصرَّ المرکز الثاني في الاحتياطيات لدى البنوك المركزية في العالم.
- إنَّ التقلبات اليومية أو على مستوى الساعات بين العملات تُتيح مجالاً واسعاً لـكلِّ المتعاملين في سوق الفوركس، ولاسيما التجار والمضاربين في الحصول على الأرباح أو تكبُّ الخسائر؛ لأنَّ هذه التقلبات كبيرة في الحجم، وسريعة في الانتقال، وتُخضع لأحداث كثيرة تساعد في هذا التقلب بين العملاتين.
- من خلال التوفيق البياني للسلسلة الزمنية لسعر الصرف اليومي لليورو أمام الدولار لمدة من 7/12/2020 H:1 AM - 10/12/2020 H:7 AM) بأنَّ هناك اتجاه متناقض غير موسمي للسلسلة، لذلك فإنَّ الأنماذج الملائم والأكفاء لنمط هذه السلسلة هو أنموذج التمهيد الأسي المزدوج (طريقة هولت)؛ وذلك لقدرتها على معالجة السلسلة الزمنية المحتوية على مركبة الاتجاه العام غير الموسمي.

4. أفضل ثابتين تمهيدين ل(α و γ) لأنموذج التمهيدي الأسّي المزدوج (طريقة هولت) لسعر الصرف اليومي للبيورو أمام الدولار للمدة من (10/12/2020 H:7 AM - 7/12/2020 H:1 AM) وفقاً لمعيار متوسط مربع الخطأ (MSE) لمعرفة القوة التنبؤية لأنموذج المستعمل، لأنّ المعيار الأكثر استعمالاً و شيوعاً لاختبار الأنماذج الأمثل والأكفاء، الذي يعطي أقلّ قيمة لهذا المعيار واستعماله للتنبؤات المستقبلية. بعد تجربة عدد كبير من القيم تتراوح ما بين $\gamma \leq 0.1$ و $0.9 \leq \alpha \leq 0.1$ فإنّ القيمة المثلثى ل($\alpha = 0.9$ و $\gamma = 0.1$) التي تعطي القيم الأقلّ لهذا لمعيار.
5. تُعدّ أنموذج التمهيدي الأسّي المزدوج (طريقة هولت) وفقاً لمعيار متوسط مربع الخطأ بعد تحديد معلم التمهيد المثلثى من أجل الحصول على تنبؤات مستقبلية لسعر الصرف اليومي للبيورو أمام الدولار للمدة من (10/12/2020 H:8 AM - 15/12/2020 H:7 AM)، بأنّ قيم التنبؤات المستقبلية تسلك سلوك السلسلة الأصلية باتجاه عام متزايد.
6. إنّ عدد العقد العصبية في طبقة الإدخال في هذه الدراسة تساوي 2 ، وذلك بالاعتماد على تحليل الارتباط الذاتي للكشف عن أنماط الإدخال.
7. إنّ عدد العقد العصبية في الطبقة المخفية تتراوح بين [2-33]، وذلك بالاعتماد على قاعدة بام هاسلر المعروفة، وكانت أفضليها عند ($N_{\text{Hidden}} = 10$).
8. إنّ العصبونات في طبقة الإخراج تتطلب عصبوناً واحداً فقط في الشبكة العصبية للسلسلة الزمنية.
9. أفضل هيكلية للشبكة العصبية هي [2-10-1] من بين المعماريات الأخرى، وذلك حسب معايير الدقة (المطابقة) يتمثل بـ (المطابقة Fitness ، معكوس خطأ الاختبار Inverse Test error ، خطأ التدريب Train error ، معيار معلومات Akaike AIC) ، ومعامل الارتباط Correlation ، معامل التحديد R-Squared ولاسيما معيار المطابقة Fitness ومعيار معكوس خطأ الاختبار Inverse Test error الذي يحدد أفضل هكلية لتلك الشبكة.
10. تُعدّ أنموذج الشبكة العصبية الاصطناعية [1-2-10] (سواء أكانت استعمال خوارزمية الانتشار السريع أم خوارزمية الانتشار الخلفي التزايدية) من أجل الحصول على تنبؤات مستقبلية لسعر الصرف اليومي للبيورو أمام الدولار للمدة من (15/12/2020 H:7 AM- 10/12/2020 H:8 AM) ، بأنّ قيم التنبؤات المستقبلية تسلك إلى حدّ كبير سلوك قيم السلسلة الأصلية، ولاسيما نتائج خوارزمية الانتشار السريع Quick Propagation algorithm ، وفقاً لمعيار متوسط مربع الخطأ (MSE).
11. بعد إجراء المقارنة تبيّن أنّ أنموذج الشبكة العصبية الاصطناعية [1-2-10] استعمال خوارزمية الانتشار السريع لسعر الصرف اليومي للبيورو أمام الدولار وفقاً لمعيار متوسط مربع الخطأ (MSE) ، قد أعطت مؤشرات أقلّ من مؤشرات أنموذجي الشبكة العصبية الاصطناعية [1-2-10] باستعمال خوارزمية الانتشار العكسي التزايدية ، وأنموذج التمهيدي الأسّي المزدوج (طريقة هولت) ، الأمر الذي يشير بوضوح أنه الأنماذج الملائم، والأكفاء لتقدير التنبؤات المستقبلية للمدة من (15/12/2020 H:7 AM- 10/12/2020 H:8 AM). إذ أظهرت هذه القيم تناسقاً مع مثيلاتها في السلسلة الأصلية، وقدّمت لنا صورة مستقبلية لواقع لسعر الصرف اليومي للبيورو أمام الدولار لتلك المدة.

5: المقترنات : من خلال النتائج التي تم التوصل إليها نقترح ما يأتي:

1. يفضل في المستقبل استعمال طريقة هولت وتنرز للتنبؤ بالقيم المستقبلة ومقارنتها مع أنموذج الشبكات العصبية التكرارية (RNN).
2. يفضل في المستقبل استعمال أنموذج الشبكات العصبية مثل الشبكات العصبية التكرارية (RNN) والشبكات العصبية ذات التغذية الإمامية (ANN)، ومقارنتها مع بعضها لتحديد الطريقة المثلثة لتلك الأنماذج من أجل الحصول على تنبؤات مستقبلية.
3. يفضل في المستقبل استعمال أنموذج الشبكات العصبية مثل الشبكات العصبية التكرارية (RNN) والشبكات العصبية ذات التغذية الإمامية (ANN) ومقارنتها مع أنموذج بوكس جنكنز (ARIMA) ، لتحديد الطريقة المثلثة لتلك الأنماذج من أجل الحصول على تنبؤات مستقبلية.
4. يفضل استعمال معايير الدقة التنبؤية ولاسيما لمعيار متوازن مربع الخطأ(MSE)؛ لأنَّ المعيار الأكثر استعمالاً وشيوعاً لاختيار الأنماذج الملائمة والأمثل، الذي يعطي أقل قيمة لهذا المعيار واستعماله للتنبؤات المستقبلية، ولاسيما أثناء إجراء المقارنة بين نماذج مختلفة عدَّة.

6: المصادر العربية

1. ابتسام، باسي ،فاطمة،خبار، أمانى،بلعيد، نورية،بن حدة ، والسعيد ، غندير: " دراسة تطبيقات التعليم العميق في مجال الذكاء الاصطناعي إنجاز جهاز للكشف عن القناع الواقي " ، رسالة ماجستير كلية التكنولوجيا ، جامعة الشهيد حمد لخضير بالوادي ،الجزائر ، (2022).
2. الألوسي، سلمى ثابت ذاكر ،الوكيل ، وحسين ، خولة : " التنبؤاتالمستقبلية لعدد المصابين بمرض اللوكيميا لعموم القطر مع اشارة ولاسيما لمدينة بغداد " ، مجلة الإدارة والاقتصاد ، العدد الثاني والسبعين ، المستنصرية، (2008).
3. أحمد، عبد الرحمن أحمد عثمان، فضل، عصام عمر وآدم، أمين إبراهيم : " استعمال أنموذج استعمال أنموذج الشبكات العصبية الاصطناعية في التحليل التميزي بالتطبيق على عينة من المصابين وغير المصابين بمرض البروستات " ، مجلة العلوم الإنسانية والطبيعية ،المجلد 2، العدد 7-2014 ISSN(E)2709-0833
4. أحمد، إبراهيم محمد إبراهيم سيد، محمد، أشرف إدريس سعيد وحسن، محمد أحمد محمد : " استعمال أنموذج السلسل الزمنية ونموذج التمهيد الأسّي للتنبؤ بعائدات الصادرات الشهرية لمحصول السمسم (2008م-2013م)" ، رسالة ماجستير العلوم في الإحصاء ،قسم الإحصاء، كلية العلوم الرياضية والحاسب، جامعة الجزيرة، (2021).
5. الحتو، طه سعيد موسى والهبيل ، عبد الله محمد: " دراسة مقارنة بين نموذج ARIMA وطريقة التمهيد الأسّي في التنبؤ بالسلسل الزمنية " ، رسالة ماجستير في الإحصاء ،كلية الاقتصاد والعلوم الإدارية ، جامعة الأزهر، غزّة، (2017).
6. البيرماني ،فاطمة عبد الحميد جواد وأرشيد، أحمد جودة : " استعمال السلسل الزمنية للتنبؤ بالأرقام القياسية لإيجارات الدور السكنية في العراق للسنوات 2018-2021 " ، مجلة كلية الرافدين الجامعة للعلوم ،العدد 45، (2019).
7. البنك المركزي العراقي ، المديرية العامة للإحصاء والابحاث ،"النشرة السنوية لسنة (2020)" ،
[\(https://cbi.iq/news/view/492\)](https://cbi.iq/news/view/492)

8. الجبوري ، عبير حسن علي : " التنبؤ بأسعار النفط العراقي للعام 2010 استعمال السلسلة الزمنية " ، مجلة جامعة بابل ، كلية العلوم الإنسانية، المجلد 18، العدد 1، (2010).
9. الخياط ، باسل يونس وركي ، عزة حازم " استعمال الشبكات العصبية في التكهن بالسلسلة الزمنية لاستهلاك الطاقة الكهربائية في مدينة الموصل " ، المجلة العراقية للعلوم الإحصائية ، كلية علوم الحاسوب والرياضيات ، المجلد 5، العدد 8 ، جامعة الموصل، العراق، (2005).
10. بري، عدنان ماجد عبد الرحمن : " طرق التنبؤ الإحصائي " ، جامعة الملك سعود ، (<http://www.abarry.ws/books/statisticalForecast.pdf>)
11. سليمان، أسامة ربيع أمين . (2007) : " التحليل الإحصائي للبيانات استعمال برنامج Minitab " ، كلية التجارة (بالسداد)، جامعة المنوفية ، مصر ، (2002).
12. سليمان، أسامة ربيع أمين : " التنبؤ بمعدل الاحتفاظ بالأقساط في سوق التأمين المصري استعمال السلسلة الزمنية " ، مجلة الباحثة، المجلد 2010، كلية العلوم الاقتصادية والتجارية وعلوم التسيير، العدد 8، جامعة قاصدي مرباح ورقلة، الجزائر، (2010). (<http://search.emarefa.net/detail/BIM-280257>)
13. سهيلة ، عتروس وجمال ، خنشور: " استعمال منهجية بوكس جنكنز الشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية بمؤسسة سونلغاز دراسة حالة: ولاية بسكرة "، رسالة دكتوراه في علوم التسيير، كلية العلوم الاقتصادية والتجارية وعلوم التسيير، قسم علوم التسيير، جامعة محمد خضير بسكرة ،الجزائر، (2018).
14. صليوا، ورهاد عماد و مطر ، ظافر رمضان" مقارنة أداء التنبؤ بين بعض الشبكات العصبية الاصطناعية ومنهجية بوكس- جنكنز مع التطبيق" ، المجلة العراقية لعلوم الإحصاء، العدد 28، (2019).
15. محمود، رانيا فكري و إبراهيم ، سحر عبد السلام: " استعمال أنموذج التمهيد الأسّي في التنبؤ بإنتاج محصولي القمح والفول " ، المجلة العربية للعلوم الزراعية ، المؤسسة العربية للتربية والعلوم والإادب ، المجلد 5، العدد 13 ، (2022).
16. مصطفى ، طويطي، يوسف ، بازين وتوفيق ، طباخ: " المقارنة بين أنموذج التمهيد الأسّي ومنهجية بوكس وجينكينز في التنبؤ بالمبيعات- دراسة تطبيقية لشركة NAFTAL غردية " ، رسالة ماجستير في العلوم الاقتصادية والتسيير والعلوم التجارية ، جامعة غردية ، الجزائر ، (2022).
17. مطر ، ظافر رمضان و الياس، انتصار ابراهيم : " تحليل ونمذجة السلسلة الزمنية لتدفق المياه الداخلة إلى مدينة الموصل دراسة مقارنة " ، المجلة العراقية لعلوم الإحصاء ، العدد 18، (2010).
18. فريد، بن نور والعربي ، نايت مرزوق محمد: " استعمال أنموذج الذكاء الاصطناعي للتنبؤ باحتياطيات الصرف الأجنبي في الجزائر -نموذج الشبكات العصبية الإصطناعية- ANN " ، مجلة اقتصاديات شمال اقتصاديات شمال إفريقيا، المجلد 15، العدد 2020، ISSN112-6132، (2019).

19. عيسى، علام زكي: "الشبكات العصبية، البنية الهندسية-الخوارزميات – التطبيقات"، الطبقة الاولى، شعاع للنشر والعلوم ، حلب، سوريا، (2000).

8: المصادر الأجنبية

1- AL Rahamneh, Adeeb Ahmed Ali:" Using Single and Double Exponential Smoothing for Estimating The Number of Injuries and Fatalities Resulted From Traffic Accidents in Jordan (1981-2016)", Middle-East Journal of Scientific Research 25 (7): DOI: 10.5829/idosi.mejsr .2017.1544.1552,ISSN 1990-9233,(2017).

2- Kahraman, Esma and Akay, Ozlem:" Comparison of exponential smoothing methods in forecasting global prices of main metals",Mineral Economics.

[\(2022\)](https://doi.org/10.1007/s13563-022-00354-y)

3-Marpaung, Noveri Lysbetti, Salim, Kelvin Rainey and Amri, Rahyul:"Application of Single Exponential Smoothing in Forecasting Number of New Students Acceptance", International Journal of Technology and Engineering Studies, volume 5 issue 6, (2019). doi: <https://dx.doi.org/10.20469/ijtes.5.10001-6>.

4-Yonar, Harun, Yonar, Aynur, Tekindal, Mustafa Agah and Tekindal, Melike " Modeling and Forecasting for the number of cases of the COVID-19 pandemic with the Curve Estimation Models, the Box-Jenkins and Exponential Smoothing Methods", EJMO ,4(2). DOI: 10.14744/ejmo.2020.28273.

5-European Central Bank:"The international role of the euro", Statistical annex, (2020).

6-IMF:"INTERNATIONAL FINANCIAL STATISTICS".<https://www.imf.org/en/Home>

7- Kuo, R. J., Xue K. C. :"Fuzzy Neural Networks with Application to Sales Forecasting", Fuzzy Sets and Systems 108(2), (1999).

8-Taylor,J. W.:"Exponential smoothing with a damped multiplicative trend", Forecasting 19 (4), (2003).

9-Ahmad Chusyairi , Pelsri Ramadar N.S. , Bagio , 2017 , The Use of Exponential Smoothing Method to Predict Missing Service E-Report , 2nd International Conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE).

- 10-** Maia, A. L. S., de Carvalho, F. D. a. T.: " Holt's exponential smoothing and neural network models for forecasting interval-valued time series", International Journal of Forecasting , 27 (3) , (2011).
- 11-**Idown, P. A., Osakwe, C., Kayode, A. A., and Adagunodo, E. R:"Prediction of Stock Market in Nigeria Using Artificial Neural Network", Published Online October 2012 in MECS (<http://www.mecspress.org/>) , (2012).
- 12-**Sahoo. P. K and Satpathy: "Elman Neural Network Backpropagation Based Evaluation of Critical Busbars in Power Systems with Renewable Sources" , International Journal of Renewable Energy Research Satpathy et al,Vol.5 , No.2, (2015).
- 13-**Cortez, P., Rio, M., Rocha, M., & Sousa, P. (2012), Multi-Scale Internet Traffic Forecasting Using Neural Networks And Time Series Methods, Expert Systems, 29(2).
- 14 -**Zimbra D.K., Saidane H.,Ghiassi M.: A Dynamic Artifical Neural Network. Model For Forecasting Time Series Events, International Journal of Forecasting, Vol.21,Iss.2, (2004).
<http://www.sciencedirect.com>
- 15-**Kevin Gurney :" An introduction to neural networks ", UCL Press Limited , London EC4P 4EE. , (1997).
- 16-**Alyude,NouroIntelligence:"Neural NetworkSoftware", (2003).Web:www.alyuda.com
- 17-**Kumar, D.Negesh , Raju, K. Srinivasa and Sathish , T. :"River Flow Forecasting using Recurrent neural Networks",Water Resources Management18:1431-161,(2004).
- 18-**Lin , Feng , Gregor , Shirley ,Irons,Richard and Yu ,Xing Huo:"Time Series Forecasting with Neural Network", Complexity International (1995)2. <http://Journol - Ci. Csse. Monash. Edu./ci/> Vol02/ cmxhk /Cmxhk.html , (1995).

الملحق(1): يمثل القيم الحقيقة والقيم التنبؤية المستقبلية للشبكة العصبية الاصطناعية [1-10-2] (استعمال خوارزمية الانشار العكسي التزايدى وخوارزمية الانتشار السريع) مع طريقة هولت لبيانات السلسلة الزمنية لسعر الصرف اليومى لليورو أمام دولار لمدة من (15/12/2020 H:7 AM -10/12/2020 H:8 AM)

Period	Actual Value	Predict	Predict	Predict
(*)	(HOUR-EUR-USD)	Quick prop.	Online Back prop.	($\alpha = 0.9, \gamma$) ($trend = 0.1$)
(*)		Alog.[2-10-1]	Alog.[2-10-1]	Holt's method

10/12/2020 H:8	1.20909	1.21058	1.21029	1.20967
AM				
10/12/2020 H:9	1.21061	1.21092	1.20728	1.20972
AM				
10/12/2020 H:10	1.21972	1.21119	1.20623	1.20978
AM				
10/12/2020	1.20895	1.21140	1.20620	1.20984
H:11AM				
10/12/2020 H:12	1.21111	1.21173	1.20761	1.20989
AM				
10/12/2020 H:13	1.21252	1.21262	1.20998	1.20995
PM				
10/12/2020	1.21522	1.21299	1.21201	1.21000
H:14PM				
10/12/2020	1.21328	1.21254	1.21213	1.21006
H:15PM				
10/12/2020	1.21167	1.21191	1.21130	1.21011
H:16PM				
10/12/2020	1.212	1.21120	1.21072	1.21017
H:17PM				
10/12/2020	1.21252	1.21185	1.21076	1.21023
H:18PM				
10/12/2020	1.21337	1.21206	1.21111	1.21028
H:19PM				
10/12/2020	1.21428	1.21260	1.21180	1.21034
H:20PM				
10/12/2020	1.21398	1.21223	1.21210	1.21039
H:21PM				
10/12/2020	1.214	1.21150	1.21153	1.21045
H:22PM				
10/12/2020	1.21433	1.21130	1.21103	1.21050
H:23PM				

10/12/2020	1.21448	1.21226	1.21068	1.21056
H:24PM				
11/12/2020 H:1	1.21556	1.21178	1.21083	1.21062
AM				
11/12/2020 H:2	1.21573	1.21140	1.21134	1.21067
AM				
11/12/2020 H:3	1.21578	1.21239	1.21187	1.21073
AM				
11/12/2020 H:4	1.21553	1.21225	1.21220	1.21078
AM				
11/12/2020 H:5	1.21553	1.21158	1.21149	1.21084
AM				
11/12/2020 H:6	1.21566	1.21131	1.21096	1.21089
AM				
11/12/2020 H:7	1.21308	1.21239	1.21060	1.21095
AM				
11/12/2020 H:8	1.21256	1.21223	1.21059	1.21101
AM				
11/12/2020 H:9	1.21176	1.21157	1.21137	1.21106
AM				
11/12/2020 H:10	1.21192	1.21134	1.21090	1.21112
AM				
11/12/2020 H:11AM	1.21219	1.21243	1.21073	1.21117
AM				
11/12/2020 H:12	1.21264	1.21240	1.21060	1.21123
AM				
11/12/2020 H:13	1.21157	1.21141	1.21092	1.21128
PM				
11/12/2020 H:14PM	1.21171	1.21104	1.21174	1.21134
11/12/2020 H:15PM	1.21068	1.21160	1.21144	1.21140
11/12/2020	1.21124	1.21166	1.21129	1.21145

H:16PM				
11/12/2020	1.21166	1.21276	1.21159	1.21151
H:17PM				
11/12/2020	1.21162	1.21354	1.21212	1.21156
H:18PM				
11/12/2020	1.21132	1.21324	1.21189	1.21162
H:19PM				
11/12/2020	1.21172	1.21291	1.21112	1.21167
H:20PM				
11/12/2020	1.21125	1.21221	1.21043	1.21173
H:21PM				
11/12/2020	1.21331	1.21146	1.21092	1.21179
H:22PM				
11/12/2020	1.21331	1.21130	1.21151	1.21184
H:23PM				
11/12/2020	1.21211	1.21218	1.21176	1.21190
H:24PM				
12/12/2020 H:1	1.2129	1.21168	1.21178	1.21195
AM				
12/12/2020 H:2 AM	1.21319	1.21151	1.21141	1.21201
12/12/2020 H:3 AM	1.21326	1.21261	1.21122	1.21206
12/12/2020 H:4	1.2133	1.21312	1.21150	1.21212
AM				
12/12/2020 H:5 AM	1.21407	1.21288	1.21216	1.21218
12/12/2020 H:6 AM	1.21435	1.21210	1.21210	1.21223
12/12/2020 H:7 AM	1.21534	1.21130	1.21115	1.21229
12/12/2020 H:8 AM	1.21438	1.21142	1.21032	1.21234
12/12/2020 H:9 AM	1.21579	1.21200	1.21080	1.21240
12/12/2020 H:10	1.21507	1.21250	1.21108	1.21245
AM				
12/12/2020	1.21552	1.21199	1.21161	1.21251
H:11AM				

12/12/2020 H:12AM	1.21576	1.21129	1.21202	1.21257
12/12/2020 H:13 PM	1.21713	1.21172	1.21178	1.21262
12/12/2020 H:14PM	1.21643	1.21235	1.21116	1.21268
12/12/2020 H:15PM	1.21249	1.21212	1.21067	1.21273
12/12/2020 H:16PM	1.21444	1.21156	1.21098	1.21279
12/12/2020 H:17PM	1.21575	1.21157	1.21170	1.21284
12/12/2020 H:18PM	1.21504	1.21268	1.21169	1.21290
12/12/2020 H:19PM	1.21466	1.21333	1.21146	1.21296
12/12/2020 H:20PM	1.21474	1.21314	1.21136	1.21301
12/12/2020 H:21PM	1.21432	1.21275	1.21163	1.21307
12/12/2020 H:22PM	1.2145	1.21200	1.21200	1.21312
12/12/2020 H:23PM	1.21486	1.21121	1.21173	1.21318
12/12/2020 H:24PM	1.21571	1.21160	1.21116	1.21323
13/12/2020 H:1 AM	1.21579	1.21202	1.21075	1.21329
13/12/2020 H:2 AM	1.2159	1.21273	1.21100	1.21334
13/12/2020 H:3 AM	1.21518	1.21290	1.21154	1.21340
13/12/2020 H:4 AM	1.21465	1.21216	1.21181	1.21346
13/12/2020 H:5	1.21548	1.21138	1.21177	1.21351

AM				
13/12/2020 H:6	1.21484	1.21134	1.21135	1.21357
AM				
13/12/2020 H:7	1.21585	1.21208	1.21116	1.21362
AM				
13/12/2020 H:8	1.21603	1.21199	1.21148	1.21368
AM				
13/12/2020 H:9	1.21251	1.21203	1.21218	1.21373
AM				
13/12/2020 H:10	1.21396	1.21232	1.21216	1.21379
AM				
13/12/2020 H:11AM	1.21436	1.21186	1.21117	1.21385
13/12/2020 H:12AM	1.21529	1.21136	1.21031	1.21390
13/12/2020 H:13	1.21577	1.21218	1.21077	1.21396
PM				
13/12/2020 H:14PM	1.21608	1.21184	1.21111	1.21401
13/12/2020 H:15PM	1.21514	1.21162	1.21177	1.21407
13/12/2020 H:16PM	1.21573	1.21244	1.21212	1.21412
13/12/2020 H:17PM	1.21607	1.21239	1.21158	1.21418
13/12/2020 H:18PM	1.21505	1.21142	1.21104	1.21424
13/12/2020 H:19PM	1.215	1.21105	1.21061	1.21429
13/12/2020 H:20PM	1.21544	1.21165	1.21085	1.21435
13/12/2020 H:21PM	1.21501	1.21169	1.21160	1.21440

13/12/2020	1.21511	1.21277	1.21156	1.21446
H:22PM				
13/12/2020	1.21563	1.21353	1.21154	1.21451
H:23PM				
13/12/2020	1.21615	1.21323	1.21158	1.21457
H:24PM				
14/12/2020 H:1 AM	1.21647	1.21290	1.21165	1.21463
AM				
14/12/2020 H:2 AM	1.21622	1.21220	1.21161	1.21468
14/12/2020 H:3 AM	1.21631	1.21144	1.21149	1.21474
14/12/2020 H:4 AM	1.21548	1.21131	1.21149	1.21479
AM				
14/12/2020 H:5 AM	1.21089	1.21215	1.21168	1.21485
14/12/2020 H:6 AM	1.21063	1.21173	1.21178	1.21490
14/12/2020 H:7 AM	1.21968	1.21161	1.21152	1.21496
14/12/2020 H:8 AM	1.21952	1.21264	1.21129	1.21502
14/12/2020 H:9 AM	1.21945	1.21316	1.21144	1.21507
14/12/2020 H:10 AM	1.21878	1.21294	1.21202	1.21513
AM				
14/12/2020 H:11AM	1.21959	1.21225	1.21210	1.21518
AM				
14/12/2020 H:12 PM	1.21875	1.21151	1.21128	1.21524
AM				
14/12/2020 H:13 PM	1.21748	1.21127	1.21070	1.21529
PM				
14/12/2020 H:14PM	1.21689	1.21225	1.21079	1.21535
14/12/2020 H:15PM	1.21702	1.21171	1.21124	1.21541
14/12/2020 H:16PM	1.21622	1.21138	1.21192	1.21546
14/12/2020 H:17PM	1.21836	1.21247	1.21236	1.21552
14/12/2020	1.21984	1.21257	1.21158	1.21557

H:18PM				
14/12/2020	1.21973	1.21124	1.21092	1.21563
H:19PM				
14/12/2020	1.21961	1.21086	1.21042	1.21568
H:20PM				
14/12/2020	1.21943	1.21115	1.21043	1.21574
H:21PM				
14/12/2020	1.21023	1.21136	1.21150	1.21580
H:22PM				
14/12/2020	1.21021	1.21165	1.20891	1.21585
H:23PM				
14/12/2020	1.21107	1.21247	1.20619	1.21591
H:24PM				
15/12/2020 H:1 AM	1.21253	1.21247	1.20633	1.21596
AM				
15/12/2020 H:2 AM	1.2126	1.21130	1.20750	1.21602
15/12/2020 H:3 AM	1.21308	1.21094	1.20795	1.21607
15/12/2020 H:4 AM	1.21332	1.21129	1.20661	1.21613
15/12/2020 H:5 AM	1.21347	1.21145	1.20619	1.21619
15/12/2020 H:6 AM	1.21327	1.21202	1.20652	1.21624
15/12/2020 H:7 AM	1.21283	1.21251	1.20722	1.21630

المصدر (*): البنك المركزي العراقي ، المديرية العامة للإحصاء والابحاث ، "النشرة السنوية لسنة (2020)" ، [\(https://cbi.iq/news/view/492\)](https://cbi.iq/news/view/492)

المصدر: القيم التنبؤية المستقبلية Predict من إعداد الباحثة بالاعتماد على مخرجات البرامج الإحصائية Minitab و نظام الشبكات العصبية Alyuda .