

التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية باستخدام نماذج ARIMA - ARCH والشبكات العصبية الاصطناعية (دراسة مقارنة)

* أيهم الحميد * * عثمان نقار

(الإيداع : 25 آب 2019 ، القبول : 28 تشرين الثاني 2019)

الملخص

هدفت هذه الدراسة إلى تقييم قدرة نماذج ARIMA - ARCH والشبكات العصبية الاصطناعية في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية دراسة مقارنة، وبهدف المقارنة العلمية الدقيقة بين الأسلوبين في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية فقد تم تقسيم بيانات الدراسة بشكل متكافئ، (من تاريخ 1/1/2018 إلى 18/8/2019) خصصت لبناء نماذج (ARIMA - ARCH) وكذلك لتربیت الشبکة العصبية الاصطناعية. (من تاريخ 19/08/2019 إلى 19/09/2019) خصصت للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية لكلا الأسلوبين. ومن أجل أن تكون المقارنة عادلة بين قدرة الشبکات العصبية الاصطناعية وقدرة نماذج (ARIMA - ARCH) في التنبؤ بالاتجاه فقد تم الاعتماد فقط على القيم السابقة للمتغير المدروس (سعر إغلاق المؤشر) كمدخلات للشبکة العصبية الاصطناعية للتنبؤ في اليوم التالي دون حساب أي مؤشرات فنية ودون إدخال أي متغيرات أخرى تساعد على التنبؤ بقيم المؤشر، وتم تحديد معاملات الشبکة (المدخلات - عدد العصبيون) باستخدام قاعدة التجربة والخطأ. وقد تم اقتراح شبکتين عصبيتين يمكن استخدامهما للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية. ومن أهم النتائج التي تم التوصل إليها أن النموذج الأنساب للتنبؤ بمؤشر سوق دمشق للأوراق المالية باستخدام نماذج ARCH-ARIMA هو (1.1.1) و (1) ARCH. وأنه لا يمكن الاعتماد على نماذج ARCH-ARIMA للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية بينما يمكن ذلك باستخدام الشبکات العصبية الاصطناعية بنسبة توافق قد تصل إلى 78% وفق البيانات المتباينة.

وبالتالي فإنه يمكن الاعتماد على الشبکات العصبية الاصطناعية في اتخاذ قرارات استثمارية دقيقة.

الكلمات المفتاحية: التنبؤ - الانحدار الذاتي - اتجاه السوق - مؤشر السوق - عدم تجانس التباين - جذر الوحدة -

الشبکات العصبية الاصطناعية.

Forecasting the Movement of Damascus Stock Exchange Index Using ARIMA-ARCH Models and Artificial Neural Networks (A comparative study)

*Ayham AL Hameed **Asmhan Khalaf ***Othman Naqar

(Received: 25 August 2019, Accepted: 28 November 2019)

Abstract

This study aimed to evaluate the ability of ARIMA-ARCH and Neural Networks models to forecast future movement in Damascus Securities Exchange (DSE). In order to accurately compare the two methods in predicting the direction of the DSE movement, the study data were divided equally (From 1/1/2018 to 18/8/2019) assigned to build the models and to train the neural networks. (From 19/08/2019 to 19/09/2019) assigned to forecast the movement of DSE Index for both methods. In order to achieve fair comparison between the ability of neural networks with the versions of the ARIMA-ARCH models, The previous values of the studied variable (the closing price of the index) were solely relied upon as inputs to the artificial neural network to predict the next day without calculating any technical indicators and without introducing any other variables that help predict the values. The network coefficients (inputs – number of neurons) Were set using a trial and error rule. Two neural networks have been proposed that can be used to predict the movement of the DSE index. One of the most important results is that; the most suitable model for predicting the DSE using ARCH-ARIMA models is ARIMA (1.1.1) and ARCH (1). It is not possible to rely on the models of ARCH-ARIMA to predict the direction of the movement of the DSE index, while this can be done using artificial neural networks and a compatibility proportion up to 78% according to the predicted data. Thus, it is possible to rely on artificial neural networks to make accurate investment decisions.

Key Words: Forecasting – Autoregression – Market Trend – Market Index – Heteroskedasticity – Unit Root – Artificial Neural Networks.

1. المقدمة:

إن اتخاذ أي قرار استثماري في الأسواق المالية يرتبط بشكل أساسي بدراسة وتقدير مستقبل ما سيكون عليه نتيجة هذا القرار. وعند التحدث عن التنبؤ في السوق المالي فإن التنبؤ باتجاه حركة السوق (مؤشر السوق) يكتسب أهمية خاصة، حيث يعد من المسائل العملية التي تؤثر بشكل كبير على قرار المستثمرين في شراء أو بيع الأصل المالي، إذ يمكن للتوقعات الدقيقة لاتجاهات مؤشر السوق أن تحقق للمستثمرين فرص استثمارية مربحة.

إن التنبؤ بمؤشر السوق المالي يصبح مهمة صعبة للغاية بسبب العوامل المختلفة التي تؤثر في السوق المالي وبالتالي في اتجاه حركته بشكل مستمر (العوامل الاقتصادية، السياسية، والطبيعية... الخ)، وهذا ما يضفي صبغة غير خطية على طبيعة بيانات السوق المالي [18]. حيث يتميز التنبؤ بمؤشر السوق المالي بكثافة البيانات المرتبطة بالمؤشر، والمواضيع، وعدم الاستقرارية، ودرجة عالية من عدم اليقين، والعلاقات المخفية والغامضة بين العوامل المتعددة[25]. لذا يلجأ المستثمرون إلى مناهج وأساليب مختلفة من أجل محاولة التنبؤ بمستقبل اتجاه السوق المالي.

وسitem في هذا البحث اختبار قدرة التنبؤ باتجاهات حركة مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية كدراسة مقارنة مع نماذج (ARIMA- ARCH).

2. أهداف البحث وأهميته:

يمكن تلخيص أهم أهداف البحث في النقاط التالية:

- بناء نموذج (ARIMA- ARCH) للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.
- بناء شبكة عصبية اصطناعية للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.
- المقارنة بين الشبكات العصبية الاصطناعية ونماذج (ARIMA- ARCH) من حيث القدرة على التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية لليوم التالي.

وببناء على ما سبق فإنه يمكن تلخيص أهمية البحث في نقطتين أساسيتين:

- إن محاولة التنبؤ بمؤشر سوق دمشق للأوراق المالية بأكثر من أسلوب والوصول إلى تنبؤات يمكن الاعتماد عليها في اتخاذ القرارات من شأنه أن يفيد المستثمرين في سوق دمشق للأوراق المالية في التعرف على هذه الأساليب واعطائهم صورة مسبقة عنها وبالتالي اختيار أنسابها في اتخاذ قراراتهم الاستثمارية.
- في ظل وجود دراسات سابقة استخدمت الشبكات العصبية الاصطناعية للتنبؤ بمؤشر سوق دمشق للأوراق المالية في بدايات نشأتها وتوصلت إلى نتائج جيدة في التنبؤ، إضافة إلى وجود دراسات أخرى استخدمت النماذج القياسية للتنبؤ بمؤشر سوق دمشق للأوراق المالية، فإن أهمية هذا البحث تكمن في كونها جمعت بين الأسلوبين في دراسة واحدة ليتسنى القيام بالمفاضلة بين قدرة الأسلوبين على التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.

3. مواد وطرق البحث:

3.1. فرضيات البحث وحدوده ومصادر جمع البيانات:

3.1.1. فرضيات البحث: تحقيقاً لأهداف الدراسة فإنه يمكن صياغة الفرضيات التالية:

الفرضية الأولى: اعتماداً على نسبة التوافق في اتجاه الحركة فإنه لا يمكن الاعتماد على نماذج (ARIMA- ARCH) في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية لليوم التالي.

الفرضية الثانية: اعتماداً على نسبة التوافق في اتجاه الحركة فإنه لا يمكن الاعتماد على الشبكات العصبية الاصطناعية في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية لليوم التالي.

الفرضية الثالثة: اعتماداً على مؤشر نسبة التوافق في اتجاهات الحركة فإن الشبكات العصبية الاصطناعية لا تتفوق على نماذج (ARIMA- ARCH) في تحقيق نسبة توافق أعلى مع اتجاهات حركة مؤشر سوق دمشق للأوراق المالية.

21..3 حدود البحث ومصادر جمع البيانات: يمكن تقسيم حدود البحث إلى: الحدود المكانية والحدود الزمنية:
- الحدود المكانية: تم تطبيق الدراسة العملية على سوق دمشق للأوراق المالية.

- الحدود الزمنية: تمت الدراسة بالاعتماد على البيانات التاريخية المتمثلة في سلسلة أسعار الإغلاق اليومية لمؤشر سوق دمشق للأوراق المالية وذلك للفترة الممتدة من 1/1/2018 وحتى 19/9/2019.

ويفيد مصادر جمع البيانات فإنه سيتم الحصول عليها من الموقع الرسمي لسوق دمشق للأوراق المالية.

23. الدراسات السابقة:

هناك العديد من الدراسات التي تناولت موضوع التنبؤ بمؤشر السوق المالي بأساليب ونماذج مختلفة تعددت بتنوعها، وقد تم رصد عدد من هذه الدراسات ذكر منها فيما يلي:

أولاً: بعض الدراسات التي هدفت إلى التنبؤ بمؤشر سوق دمشق للأوراق المالية:

- دراسة (مرهج، منذر 2013) بعنوان " (التنبؤ بقيم مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية واتجاهاتها)" [6]. هدفت الدراسة إلى بناء شبكة عصبية اصطناعية بهدف التنبؤ بقيم مؤشر سوق

دمشق للأوراق المالية واتجاهاتها ليوم التداول التالي. واعتمد الباحث على قاعدة التجربة والخطأ في بناء هيكل الشبكة - عدد الطبقات وعدد الخلايا (العصبونات) في كل طبقة- وذلك بالتطبيق على السلسلة الزمنية للمؤشر خلال الفترة

4/1/2010 إلى 4/1/2013. وقد تم تدريب الشبكة وفق خوارزمية التكاثر الارتدادي على مجموعة من المتغيرات

(27 متغير كمدخلات للشبكة) التي جرى تحديدها في ضوء الدراسات السابقة وأساليب التحليل الفني من مثل: (سعر الإيقاف اليومي، إبطاء السلسلة لسعر إيقاف المؤشر لفترة زمنية واحدة وفترتين، النسبة المئوية للتغير بسعر الإيقاف، حجم التداول، المتوسط المتحرك البسيط لفترة 7 و 14 و 21 و 28 يوم، إضافة إلى مؤشر القوة النسبية). وتمثلت أهم النتائج التي توصلت إليها الدراسة بأنه يمكن التنبؤ بقيمة مؤشر سوق دمشق للأوراق المالية واتجاهاته ليوم التداول التالي باستخدام أسلوب الشبكات العصبية الاصطناعية وبدرجة عالية من الدقة حيث بلغت نسبة التوافق في اتجاه الحركة 70.5%.

- دراسة (البلخي، راتب، وقزما، جان 2014) بعنوان " (الاتجاه العام لأسعار الأسهم المدرجة في سوق دمشق للأوراق المالية وبناء نموذج للتنبؤ بها- دراسة تطبيقية على أسهم بنك التجارة والتمويل الدولي باستخدام نماذج أريما ونماذج الانحدار للسلسل الرزمية)" [1]. هدف هذا البحث إلى التعرف على الاتجاه العام لأسعار الأسهم لمصرف التجارة والتمويل الدولي وذلك خلال الفترة الممتدة من بداية انطلاق سوق دمشق للأوراق المالية في آذار 2009 و حتى نهاية شهر شباط عام 2011 قد تم تطبيق الأساليب الإحصائية المتعلقة بالسلسل الرزمية، توصلت الدراسة إلى أن أفضل نموذج للتنبؤ المستقبلي بأسعار الأسهم نموذج الانحدار من الدرجة الثالثة ونموذج ARIMA(2.0.1) وذلك دون الأخذ بعين الاعتبار التغيرات الطارئة و الموسمية.

- دراسة (كوجك ورد، ونقار، عثمان، ومندور ، عبد القادر 2018) بعنوان " (التنبؤ بالاتجاهات المستقبلية لعوائد مؤشر سوق دمشق للأوراق المالية باستخدام نماذج ARIMA-GARCH)" [4]. هدف هذا البحث إلى تقييم فعالية استخدام نماذج الانحدار الذاتي المشروط بعدم تجانس التباين المعمم GARCH في دراسة تقلبات عوائد مؤشر سوق دمشق للأوراق المالية خلال الفترة الممتدة من 14/9/2015 وحتى 1/12/2016 والتنبؤ بالقيم المستقبلية للشهر الأخير، ولتحقيق هذا الهدف تم

احتساب العوائد اليومية للمؤشر خلال فترة الدراسة، وإتباع منهجية Box-Jenkins في تحليل السلسلة الزمنية تم التوصل إلى مجموعة من النتائج، أهمها عدم اتباع سلسلة عوائد المؤشر لحالة سير عشوائي خلال فترة الدراسة ، كما وأن السلسلة الزمنية لعوائد المؤشر تخضع لعملية انحدار ذاتي من المرتبة الثانية، وعملية متوازطات متحركة من المرتبة الأولى (2,1) ARMA، كما ويختبر تباين عوائد المؤشر لعملية (1,1) GARCH، وبالاعتماد على النموذج المقدر تم التبيئ بعوائد ومخاطر المؤشر للفترة الممتدة من 1/11/2016 إلى 1/12/2016 ولدى مقارنتها مع القيم الفعلية لوحظ التقارب بينهما، مما يثبت قدرة وفعالية النموذج المقترن على وصف سلوك عائد المؤشر وتقلباته خلال الفترة المدروسة.

ثانياً: بعض الدراسات العربية الأخرى:

- دراسة (كينة، صفاء 2017) بعنوان "دراسة قياسية للتبيئ بحركة أسعار المؤشرات في سوق نيويورك المالي - حالة مؤشر داو جونز الصناعي للأوراق المالية في الفترة الممتدة من 2004-2015)" [5]: هدفت الدراسة إلى بيان مدى قدرة منهجية بوكس جينكز (Box-Jenkis) في التبيئ بحركة أسعار المؤشرات في السوق المالي والمتمثل بمؤشر داو جونز الصناعي للسوق المالي في الولايات المتحدة الأمريكية، وذلك خلال الفترة 3/1/2004 إلى 5/6/2015 . وأهم النتائج التي توصلت إليها الدراسة تتمثل بأن حركة أسعار مؤشر داو جونز قابل للتبيئ على المدى القصير وأن النموذج المناسب للتبيئ بحركة مؤشر داو جونز على المدى القصير هو ARIMA (0,1,1).
 - دراسة (قاسم آغا مهدي صالح، و روهات زاده 2017) بعنوان "استخدام نماذج السلسلة الزمنية للتبيئ عن أسعار أسهم في سوق الأسهم السعودي)" [3]: هدفت الدراسة إلى إيجاد النموذج الأمثل من نماذج السلسلة الزمنية للتبيئ بسعر الأسهم في سوق الأسهم السعودي، قامت الدراسة باستكشاف وبناء نماذج بوكس-جينكز (Box-Jenkis) للسلسلة الزمنية وذلك باستخدام بيانات تاريخية يومية لسعر إغلاق سهم مصرف الراجحي للعثور على أنساب نموذج ملائمة لسوق الأسهم السعودي من بين النماذج المختلفة وتوصلت الدراسة إلى أن النموذج الأكثر ملائمة لسلسلة البيانات المحولة لوغاريتmic هو ARIMA (1.1.1)، كما بينت النتائج أن دقة التبيئ جيدة خلال المدى القصير وتنقص كلما زاد طول الفترة المتتبى بها.
 - دراسة (فاضل، عادل، وعبد مهند 2019) بعنوان "الالتبيؤ بمؤشر سوق العراق للأوراق المالية (ISX) باستعمال نموذج ARIMA(p,d,q)" [2] : هدفت هذه الدراسة إلى تطبيق منهجية Box-Jenkis للالتبيؤ بمؤشر سوق العراق للأوراق المالية للفترة من 2017/7/2 إلى 2018/1/20 وقد وجدت الدراسة أن أفضل رتبة للنموذج هو (1.1.3) للالتبيؤ بمؤشر السوق.
- ثالثاً: بعض الدراسات الأجنبية:** هناك العديد من الدراسات الأجنبية التي هدفت إلى التبيئ بمؤشر السوق المالي، إلا أنه سنقتصر على ذكر دراستين من بين ما تم الإطلاع عليه وذلك لضرورة اختصار العرض:
- دراسة (Wanle Chi 2018) بعنوان "Network Forecasting Stock Index Based On BP Neural" (Algorithm): التبيئ بمؤشر السوق اعتماداً على خوارزمية الانتشار الخلفي للشبكات العصبية الاصطناعية.
 - [12]- هدفت هذه الدراسة إلى التبيئ بمؤشر سوق شانغهاي (shanghai) باستخدام تقنية الشبكات العصبية الاصطناعية وذلك خلال الفترة الممتدة من 2017-1-28 إلى 2018-12-28 وهو ما يقارب 238 يوم تداول، وكانت مدخلات الشبكة هي أسعار الإغلاق للأيام الخمسة السابقة (أي سعر الإغلاق بتطابق زمني 5) لمؤشر السوق بينما مخرجات الشبكة هي سعر إغلاق اليوم التالي، وقد تم تتمييز البيانات باستخدام قاعدة القيمة الكبرى والصغرى وذلك لتسهيل تدريب الشبكة وقد أظهرت النتائج أن الشبكات العصبية الاصطناعية وفق خوارزمية الانتشار الخلفي كانت فعالة وممكنة في التبيئ قصير الأجل بمؤشر السوق وتعطي نتائج تبيؤ دقيقة.

- دراسة (A) [2019] -Sheikh Mohammad Idrees , M. Afshar Alam, And Parul Agarwal بعنوان "Prediction Approach for Stock Market Volatility Based on Time Series Data" تقلبات سوق المال اعتماداً على بيانات السلسلة الزمنية.[26] هدف هذا البحث إلى تحليل بيانات السلسلة الزمنية للسوق الهندي للأوراق المالية بهدف بناء نموذج إحصائي يمكنه التنبؤ بكفاءة، حيث ركزت هذه الورقة البحثية على بناء نموذج ARIMA فعال للتنبؤ بتقلب سوق الأسهم الهندية. وقد تم مقارنة السلسلة الزمنية المتوقعة مع السلسلة الزمنية الفعلية، والتي تُظهر تقريراً انحرافاً بنسبة 5% في المتوسط كنسبة خطأ لكل من أسهم Nifty و Sensex . بناءً على ما سبق ذكره من دراسات سابقة فإن الدراسة الحالية تختلف عن الدراسات السابقة والتي هدفت إلى التنبؤ بممؤشر سوق دمشق للأوراق المالية من ناحية حداثة الفترة الزمنية للدراسة ومن ناحية طريقة التحليل والهدف، حيث ستقوم هذه الدراسة على مقارنة قدرة الشبكات العصبية الاصطناعية في التنبؤ باتجاه مؤشر سوق دمشق مقارنة بالنموذج القياسي الملائم وهذا مالم تذهب إليه الدراسات السابقة التي تمت على سوق دمشق للأوراق المالية حيث اقتصرت على تطبيق أسلوب واحد وذلك في حدود ما تم الاطلاع عليه. ومن ناحية أخرى فإن هذه الدراسة تركز في مقارنتها بشكل أساسى على التوافق في اتجاهات الحركة كمقاييس أساسى في اختبار دقة التنبؤ للأسلوب المطبق.

3.3 المراجعة الأدبية:

1.3.3 تمهد: عادة ما تتضمن أي عملية تنبؤ القيام بعدة خطوات (مراحل) أساسية يمكن تلخيصها في خمس نقاط بما يلي: تعريف المشكلة >> جمع المعلومات >> القيام بعملية التحليل الاستكشافي >> تحديد النماذج المناسبة وبناءها >> استخدام نموذج التنبؤ وتقييمه.[19] وفي حديثنا عن النماذج القياسية المستخدمة للتنبؤ في السوق المالي نجد نموذج (ARIMA) من أكثر نماذج السلسلة الزمنية شيوعاً للتنبؤ في الأسواق المالية، حيث يتم تقدير نموذج (ARIMA) وفق خطوات محددة اقترحها بوكس جينكينز (Box-Jenkins). مجموعة أخرى من التقنيات المستخدمة للتنبؤ في السوق المالي تتمثل في الذكاء الصنعي، من مثل الشبكات العصبية الاصطناعية (ANN) – artificial neural networks – بما تتميز به من قدرة على محاكاة العلاقات غير الخطية المعقدة بين المدخلات الممثلة بالعامل المؤثرة والمخرجات الممثلة بالهدف. وفيما يلي سيتم بإيجاز ذكر خطوات تطبيق منهجية بوكس جينكينز Box-Jenkins والصياغة الرياضية لنماذجها وصولاً إلى التعريف بالشبكات العصبية الاصطناعية ومراحل بناءها.

2.3.3 منهجية بوكس جينكينز-Box-Jenkins: تم تقديم هذه منهجية من قبل كلٍ من GEORGE E.P. BOX و GWILYM M. JENKINS في كتابهما الشهير في تحليل السلسلة الزمنية "Time Series Analysis" في عام (1976). [10]، وبالرغم من مرور سنوات عديدة على تقديمها إلا أنَّ منهجية Box-Jenkins تعد من المناهج الحديثة في تحليل السلسلة الزمنية وأكثرها شيوعاً، حيث تُستخدم للتنبؤ على المدى القصير –short-term forecasting– وهي تعتمد على الارتباط الذاتي بين المشاهدات للمتغير المدروس عبر الزمن. تتضمن هذه منهجية سلسلة من الخطوات الرسمية، تشمل تحديد نموذج مبدئي وتطبيق مجموعة من الاختبارات التشخيصية لتقدير مدى ملاءمة النموذج. ولقد بين Box-Jenkins في كتابهما "Time Series Analysis" "Forecasting & control" بمختلف اصداراته مراحل تطبيق هذه منهجية بشكل مفصل حيث تمثلت بالأتي [11]: فحص استقراريه السلسلة الزمنية، وتطبيق التحويلات اللازمة لجعلها مستقرة إن لم تكن كذلك>> تحديد النموذج المناسب من نماذج (ARIMA)>> تقدير معلمات النموذج>> تشخيص النموذج (اختبار ملاءمته لبيانات السلسلة الزمنية)>> التنبؤ باستخدام النموذج المحدد. وهناك ثلات طرق تستخدم بشكل أساسى لفحص استقرارية السلسلة الزمنية: (1) التحليل البياني،

(2) دالة الارتباط الذاتي، (3) اختبار جذر الوحدة [16] والذي من الممكن الكشف عنها وفق اختبار ديكري فولر المطور

Augmented Dickey Fuller [15] (ADF)

1.23.3. نماذج الانحدار الذاتي والمتوسط المتحرك (AR-MA-ARMA): [9] لكي يتم تقدير نماذج الانحدار الذاتي والمتوسط المتحرك فإن منهجية Box-Jenkins تفترض أن تكون السلسلة الزمنية مستقرة (غير عشوائية)، كما تفترض هذه المنهجية ثبات التباين، وسيتم فيما يلي استعراض العلاقات التي توضح نموذج الانحدار الذاتي (AR) ونموذج المتوسط المتحرك (MA) ونموذج الانحدار الذاتي والمتوسط المتحرك (ARMA).

❖ **نموذج الانحدار الذاتي AR(p):** إن نموذج الانحدار الذاتي هو عملية عشوائية تستخدم للتنبؤ في القيم المستقبلية، والفكرة الأساسية في هذا النموذج هو إيجاد العلاقة التي تربط قيمة المتغير في فترة ما مع قيمة في الفترات السابقة وذلك من خلال استخدام الانحدار، أي يتم انحدار قيمة المتغير في الفترة (t) على قيمه في الفترات السابقة، ويتم التعبير عن القيمة الحالية للعملية كمجموع خطى من قيمه السابقة إضافة إلى الحد العشوائي وذلك كما يلي:

$$Y_t = \emptyset_1 Y_{t-1} + \emptyset_2 Y_{t-2} + \dots + \emptyset_p Y_{t-p} + \alpha_t \dots \quad (1)$$

حيث أن: Y_t : قيمة المتغير في الفترة (t) وهي القيمة المراد التنبؤ بها (المتغير التابع). $\emptyset_1, \emptyset_2, \emptyset_p$: معاملات الانحدار. α_t : حد الخطأ العشوائي (الضوضاء البيضاء). $Y_{t-1}, Y_{t-2}, Y_{t-p}$: قيم المتغير في الفترات السابقة حتى الفترة (p) وهو ما يسمى بالتأخر الزمني أو التباطؤ.

فعدنما يكون ($p=1$) عندها يسمى نموذج الانحدار الذاتي بنموذج انحدار ذاتي من الدرجة الأولى (1) AR أي أن قيمة المتغير في الفترة (t) تتحدر على قيمته في الفترة السابقة فقط ($t-1$).

❖ **نموذج المتوسط المتحرك MA(q):** في حين أن نموذج الانحدار الذاتي والذي تعتمد فيه قيمة المتغير المتبع به في الفترة (t) على المجموع المرجح للقيم السابقة للمتغير (Weighted sum) إضافة إلى حد الخطأ العشوائي (الضوضاء البيضاء)، فإنه في نموذج المتوسطات المتحركة تعتمد قيمة المتغير المتبع به في الفترة (t) على قيم الحد العشوائي (الضوضاء البيضاء) للمتغير في الفترات السابقة بتأخر زمني (q). ويتم التعبير عن نموذج المتوسطات المتحركة من خلال العلاقة (2) التالية:

$$Y_t = \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q} \dots \quad (2)$$

حيث أن: $\alpha_t, \alpha_{t-1}, \alpha_{t-2}, \dots, \alpha_{t-q}$: الحدود العشوائية الحالية والسابقة والتي تشكل عملية ضجة البيضاء. $\theta_1, \theta_2, \theta_q$: معاملات نموذج الانحدار والتي يتم تقديرها من البيانات.

❖ **نموذج الانحدار الذاتي والمتوسط المتحرك:** لتحقيق مرونة أكبر في نمذجة السلسلة الزمنية، من المفيد في بعض الأحيان تضمين نموذج الانحدار الذاتي (AR) ونموذج المتوسط المتحرك (MA) في نموذج التنبؤ الأساسي، وهذا يعني أن يكون النموذج الناتج هو نموذج خليط بين نماذج الانحدار الذاتي ونماذج المتوسطات المتحركة. ويمكن التعبير عن هذا النموذج من خلال العلاقة (3) التالية:

$$Y_t = \{ \emptyset_1 Y_{t-1} + \dots + \emptyset_p Y_{t-p} \} + \{ \alpha_t - \theta_1 \alpha_{t-1} - \dots - \theta_q \alpha_{t-q} \} \dots \quad (3)$$

ومن الناحية العملية، غالباً ما يمكن الحصول على تمثيل مناسب للسلسلة الزمنية المستقرة من خلال نماذج الانحدار الذاتي (AR) أو نماذج المتوسطات المتحركة (MA) أو النماذج المختلطة (ARMA)، وذلك عندما تأخذ (p) و (q) الرتبة 2 أو أقل.

2.23.3. تقيير رتب النموذج (p,q): [9] لتحديد درجة التباطؤ (p) في نموذج الانحدار الذاتي AR ودرجة التباطؤ (q) في نموذج المتوسطات المتحركة MA فقد اقترح Jenkins & Box الاعتماد على كلٍ من دالة الارتباط الذاتي (ACF) لتحديد رتبة نموذج المتوسطات المتحركة (MA(q)), دالة الارتباط الذاتي الجزئي (PACF) لتحديد رتبة نموذج الانحدار الذاتي (AR(p)). حيث تشكل عدد التباطؤات المعنوية في دالة الانحدار الذاتي الجزئي الرتبة (p) في نموذج الانحدار الذاتي AR, بينما تشكل عدد التباطؤات المعنوية في دالة الانحدار الذاتي الرتبة (q) في نموذج المتوسطات المتحركة MA. وبالتالي فإذا كانت كل من دالة الارتباط الذاتي (ACF) ودالة الارتباط الذاتي الجزئي (PACF) تنخفض تدريجياً بعد عدد من فترات الإبطاء (p,q) فإن النموذج المقترن في هذه الحالة هو نموذج خليط (ARMA) بين نموذج الانحدار الذاتي AR ونموذج المتوسط المتحرك MA.

3.2.3.3 تشخيص النموذج (اختبار ملاءمته): [14] يتم تشخيص النموذج واختبار مدى ملاءمته للبيانات من خلال دراسة الحد العشوائي الذي يولد النموذج، حيث يتشرط في النموذج الملائم أن تكون سلسلة بواقي النموذج تشكل ما يسمى بالضجة البيضاء _ أي أن متوسطها صفر وتبينها ثابت ولا يوجد ترابط متسلسل بين مشاهدات بواقي النموذج _ إضافة إلى خصوتها للتوزيع الطبيعي. وبعد التأكيد من صلاحية النموذج من حيث عدم وجود ارتباط ذاتي بين بواقي النموذج وأن متوسط بواقي الأخطاء (Homoscedasticity) صفر وتبينها ثابت _ أي تشكل ما يسمى بالضجة البيضاء _ فإنه يمكن القيام بالخطوة الأخيرة وهي التنبؤ.

إن السلسلة الزمنية المالية من مثل أسعار الأسهم، أسعار الصرف، معدلات التضخم، وما إلى ذلك، غالباً ما تتصف بظاهرة التقلب في بياناتها وهذا ما يسمى صفة عدم ثبات التباين (Heteroskedasticity)، حيث تتصرف قيم السلسلة الزمنية بتقلبات واسعة لفترات طويلة تليها فترة تكون فيها التقلبات طفيفة أو ساكنة نسبياً وقد يظهر فيها أثر ARCH. وبالتالي فإن ذلك يستدعي تقدير نموذج يطلق عليه نموذج الانحدار الذاتي المشروط بعدم تجانس التباين والذي قدمه Engle ويرمز له اختصار بـ (ARCH) [13] ، وهناك العديد من النماذج القياسية التي تنتمي إلى عائلة (ARCH) لذا سيتم التطرق إلى الصياغة الرياضية للنموذج الأساسي من نماذج (ARCH) وكذلك النموذج المعمم (GARCH) باعتبارهم من النماذج الأكثر استخداماً في تحليل ونمذجة السلسلة الزمنية المالية على وجه الخصوص.

3.3.3. الصياغة الرياضية لنماذج (ARCH-GARCH)

1.33.3. الصياغة الرياضية لنموذج ARCH: [17] إن نموذج ARCH يمكن تطبيقه على السلسل الزمنية من خلال القيام ببناء نموذج قياسي مثل نموذج انحدار متعدد أو نموذج (ARIMA) ثم القيام ببناء نموذج ARCH اعتماداً على سلسلة بواقي النموذج القياسي السابق. ويمكن اختبار وجود أثر لنموذج ARCH من خلال اختبار معنوية معاملات نموذج ARCH والممثلة في العلاقة (4) التالية:

$$var(u_t) = \sigma^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 u_{t-2}^2 + \dots + \alpha_p u_{t-p}^2 \dots \dots \dots (4)$$

إن العلاقة السابقة تمثل نموذج ARCH(p) حيث $var(u_t)$ تمثل تباين حد الخطأ (البواقي) في الفترة (t)، فإذا كان لا يوجد ارتباط ذاتي بين مربعات حدود الأخطاء (تباین الخطأ) فإن فرضية العدم هي: $\alpha_1 = \alpha_2 = \dots = \alpha_n = 0$. فلذا تتحقق ذلك لأن $\{var(u_t) = \alpha_0\}$ وبالتالي $\{var(u_t) = \alpha_0\} = \alpha_0$.

2.33.3. الصياغة الرياضية لنموذج GARCH: شهد نموذج ARCH منذ اكتشافه عام 1982 تطورات عديدة، وأحد أهم هذه التطورات وأكثرها شيوعاً واستخداماً في نمذجة السلسل الزمنية المالية هو نموذج الانحدار الذاتي المشروط بعدم تجانس التباين المعتم (Generalized ARCH) والذي قدمه (Bollerslev) في عام (1986) [8]، ويرمز له اختصاراً بالرمز (GARCH)، حيث يمكن صياغته بالعلاقة (5) التالية:

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 \sigma_{t-1}^2 \dots \dots \dots \quad (5)$$

من خلال الصياغة الرياضية لهذا النموذج نجد أن تباين (قلب) المتغير المدروس لا يعتمد فقط على مربع الأخطاء للفترة السابقة (الفروق) كما هو الحال في نموذج ARCH(1) فحسب وإنما يعتمد أيضاً على تباين المتغير المدروس في الفترة السابقة، وبالتالي فإن كل من الممكن أن يكون كل من مربع الخطأ والتباينات مرتبطة فيما بينها لأكثر من فترة واحدة وبالتالي فإنه يمكن تعليم هذا النموذج إلى نموذج GARCH(p,q).

4.3.3 الشبكات العصبية الاصطناعية:

1. تعريف الشبكة العصبية الاصطناعية: الشبكة العصبية الاصطناعية (ANN) عبارة عن نظام لمعالجة المعلومات بشكل متوازي يتميز أداءه بخصائص شبيهة بالخلايا العصبية البيولوجية (الحياة)، وهي بمثابة تعليم للنماذج الرياضية للإدراك البشري أو البيولوجيا العصبية [23]. كما يمكن تعريفها أيضاً بأنها نماذج حسابية مستوحة من النظام العصبي للكائنات الحية، لديها القدرة على اكتساب المعرفة (التعلم) من خلال مجموعة من وحدات المعالجة العصبي (processing units) والتي تشكل الخلايا العصبية الاصطناعية والمترتبة مع بعضها البعض عن طريق مصفوفة الأوزان والتي تمثل المشابك الاصطناعية.[29]

2. بنية الشبكة العصبية الاصطناعية: تتكون الشبكات العصبية الاصطناعية من عدة طبقات بحيث يوجد في كل طبقة مجموعة من العقد (node) أو كما تسمى أيضاً الوحدات (unit) وتستقبل كل عقدة مدخلاتها الموزونة _ إما من العصبونات الأخرى في الطبقة السابقة لها أو من خلال ملقن خارجي للبيانات (المدخلات) إذا كانت هذه العقد في طبقة المدخلات (الأولى) ليتم جمعها عن طريق ما يسمى بالجامع (Summer) ومن ثم معالجتها رياضياً عن طريق تابع التنشيط (التفعيل) Activation function والذي بدوره يعطي قيمة الخرج لهذه العقدة ليتم توزيعها بالتوازي إلى العصبونات الأخرى في الطبقة التالية في حال لم تكن هذه العقدة في الطبقة الأخيرة (المخرجات).[21] ولكن قبل المضي قدماً بالنظر إلى أنواع الشبكات العصبية الاصطناعية لا بد من الحديث عن أنواع توابع التنشيط Activation function والتي يتم بواسطتها المعالجة الرياضية لكل وحدة (عقدة) معالجة.

تابع التنشيط Activation function: إن العقد (node) العصبية في الطبقات الخفية للشبكات متعددة الطبقات لا تتمتع بقدرة أعلى في المعالجة من العقد العصبية للشبكات العادي ذات الطبقة الواحدة في حال وجود مشاكل خطية، لذا فإنه غالباً ما يتم استخدام توابع تنشيط غير خطية للعقد العصبية مما يؤثر على زيادة قدرة الشبكات العصبية متعددة الطبقات في معالجة البيانات، وبالتالي فإن تابع تنشيط الخلايا العصبية في الطبقة الخفية له دور كبير في توفير التعلم للشبكة العصبية الاصطناعية. ويوجد العديد من توابع التنشيط وكل منها مجال تعريف حسب دالة التابع، وفيما يلي أكثر توابع التنشيط شيوعاً من الناحية التطبيقية:

- Function: **Linear** ; Definition: x ; Range: $(-\infty, +\infty)$.
- Function: **Logistic sigmoid** ; Definition: $\frac{1}{1+e^{-x}}$; Range: $(0, +1)$.
- Function: **Hyperbolic tangent** ; Definition: $\frac{e^x - e^{-x}}{e^x + e^{-x}}$; Range: $(-1, +1)$.
- Function: **Exponential** ; Definition: e^{-x} ; Range: $(0, +\infty)$.
- Function: **Sine** ; Definition: $\sin(x)$; Range: $(0, +1)$.
- Function: **Step** ; Definition: $(0 : x < 0), (1 : x \geq 0)$; Range: $(0, +1)$.
- Function: **Ramp** ; Definition: $(-1 : x \leq -1), (+1 : x \geq 1), (0 : -1 < x < +1)$; Range: $(-1, +1)$.

يمكن اختيار توابع التنشيط التي تتوافق مع توزيع القيم المستهدفة (المتنبأ بها) في طبقة المخرجات، فمثلاً نجد أن تابع التنشيط اللوجستي (Logistic sigmoid) مفيد بشكل خاص عندما تكون القيم المستهدفة محدودة ($+1, 0$)، فإذا كانت القيم المستهدفة غير محدودة عندها يُستخدم تابع تنشيط غير محدود، وكذلك فإنه من الأفضل استخدام تابع التنشيط الأسوي (Exponential) إذا كانت قيم المخرجات موجبة وغير محدودة من الأعلى ($+∞, 0$) وهذا... .

3.4.3.3 أنواع الشبكات العصبية الاصطناعية المستخدمة في التنبؤ: [24]

يوجد بشكل عام نوعان أساسيان للشبكات العصبية الاصطناعية يمكن استخدامهما في التنبؤ وهما: الشبكات العصبية ذات التغذية الأمامية، والشبكات العصبية ذات التغذية الراجعة (الخلفية) feedback أو كما تسمى أيضاً الشبكات العصبية ذات التغذية الخلفية أو المتكررة، ولا بد من الإشارة إلى أنه يوجد أنواع أخرى من الشبكات العصبية الاصطناعية إضافة إلى النوعين السابقين، وسيتم الاقتصر على ذكر وتوضيح النوعين السابقين باعتبار أن موضوع الدراسة الحالية سيعتمد على الشبكات العصبية الاصطناعية التي تستخدم في التنبؤ ويتم ذلك غالباً بالاعتماد على هذين النوعين من الشبكات (الشبكات ذات التغذية الأمامية والشبكات ذات التغذية الراجعة). وفيما يلي توضيح مختصر لكل نوع من هذه الأنواع:

الشبكات ذات التغذية الأمامية: يعتمد هذا النوع من الشبكات بشكل كامل على التغذية الأمامية دون أن يكون لخرج العقد (الوحدات) أي تغذية راجعة للشبكة، إن كل وحدة من وحدات المعالجة متصلة بجميع الوحدات في الطبقة التالية لها باتجاه واحد إلى الأمام.

الشبكات ذات التغذية الراجعة: تتميز الشبكات العصبية ذات التغذية الراجعة RNN (المرتدة) عن الشبكات العصبية ذات التغذية الأمامية FNN بأن هذا النوع من الشبكات تحتوي على حلقة تغذية راجعة واحدة على الأقل، حيث يعتقد أن وجود حلقات تغذية راجعة له تأثير عميق في قدرة الشبكة العصبية على التدريب والتعلم، إن هذا النوع من الشبكات مفيد في حال كان النظام الذي تتربّع عليه الشبكة هو نظاماً ديناميكياً غير خطياً، وهذا النوع من الشبكات قد يكون مفضل على الشبكات ذات التغذية الأمامية في الحالات غير الخطية والمعقدة وغير الواضحة (غير معروفة).

4.4.3.3 مراحل بناء الشبكة العصبية الاصطناعية:

شكل عام فإن تصميم شبكة عصبية اصطناعية تمر بمجموعة من الخطوات الرئيسية والتي يمكن ذكرها بالأتي [28]: تحديد المشكلة >> اعداد البيانات اللازمة لتدريب الشبكة: والتي قد تشمل التحليل الاحصائي والتقدير والتقطيع...الخ. >> اختيار نموذج (نوع) الشبكة العصبية المناسبة للمشكلة. >> القيام بتدريب الشبكة العصبية. >> اختبار قدرة الشبكة العصبية على التعميم (generalization) والتحقق من النتائج. وفيما يلي توضيح لأهم هذه الخطوات [20]: فيما يخص اعداد البيانات اللازمة لتدريب الشبكة: يتم جمع البيانات الخاصة بمدخلات الشبكة ومخرجاتها _ والتي تمثل المتغيرات المستقلة والتابعة، ومن ثم تقسيم البيانات إلى ثلاثة مجموعات: مجموعة التدريب، مجموعة الاختبار، مجموعة التحقق

فيما يخص تصميم الشبكة(Hيكلها): يتم فيها تحديد عدد الطبقات المخفية وعدد العصبونات في كل طبقة وأنواع توابع التقليل في كل من طبقة المدخلات والمخفية وطبقة المخرجات وغالباً ما يتم ذلك عن طريق التجريب.
فيما يخص تدريب الشبكة: يتم تحديد خوارزمية التدريب المناسبة للمشكلة، وتحديد عدد دورات التدريب (التكرارات)، وكذلك معدل التعلم، ومعدل الزخم.

4.3. الدراسة التطبيقية واختبار الفرضيات: سيتم اختبار فرضيات الدراسة تباعاً بعد بناء كل من النموذج القياسي (ARIMA- ARCH) المناسب والشبكة العصبية الاصطناعية والمقارنة بينهما.

1.4.3. تقسيم البيانات: بهدف المقارنة العلمية الدقيقة بين قدرة النماذج القياسية ARIMA- ARCH وبين قدرة الشبكات العصبية الاصطناعية في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية فقد تم تقسيم بيانات الدراسة بشكل متكافئ بين الأسلوبين كما يلي:

- من تاريخ 18/8/2019 إلى 1/1/2018 خصصت لبناء نماذج (ARIMA- ARCH) وكذلك لتدريب الشبكة العصبية الاصطناعية.

- من تاريخ 19/9/2019 إلى 8/8/2019 خصصت للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية لكل من نماذج (ARIMA- ARCH) وكذلك الشبكات العصبية الاصطناعية.

2.4.3. بناء النموذج القياسي (ARCH-ARIMA)

1.2.4.3. دراسة استقرارية السلسلة الزمنية: تم دراسة استقرارية سلسلة مؤشر سوق دمشق للأوراق المالية من خلال الكشف عن وجود جذر الوحدة من عدمه في السلسلة الزمنية، حيث تم التطبيق بداية على السلسلة الأصلية دون إجراء أي فروق وتبيّن أنها تحوي جذر وحدة، لذا فقد تم إجراء الفروق من الدرجة الأولى لتحويلها إلى سلسلة مستقرة، وكل ذلك تمّ عن طريق تقدير ثلاثة نماذج (مع ثابت واتجاه عام - مع ثابت فقط - بدون ثابت وبدون اتجاه عام) وذلك بالاعتماد على اختبار (Augmented Dickey-Fuller Test) وتم تحديد عدد الفجوات المناسبة لهذا الاختبار بناءً على معيار (SIC) [27] Schwarz Information Criterion ل المعلومات وهو معيار لاختيار النموذج الأفضل من بين مجموعة من النماذج، ووفق هذا المعيار يُفضّل النموذج ذو القيمة الأقل من بين النماذج الأخرى مثله في ذلك مثل معيار أكايكي (AIC) [1]، وتم الاعتماد على معيار (SIC) على اعتبار أن هذا المعيار متشدد أكثر من معيار (AIC) حيث وضع قيود على عدد البارامترات أكثر من معيار (AIC)[30]. والجدول (1) التالي يلخص نتائج اختبارات جذر الوحدة قبل وبعد إجراء الفروق عليها:

الجدول رقم (1) : نتائج اختبار جذر الوحدة (unit root test)

نتائج اختبار جذر الوحدة (ADF): Augmented Dickey-Fuller Test على السلسلة									
أولاً: دون إجراء أي فروق على السلسلة					ثانياً: بعدأخذ الفرق الأول				
non	مع ثابت	بدون ثابت	مع ثابت	بدون ثابت	مع ثابت	بدون ثابت	مع ثابت	بدون ثابت	مع ثابت
	C	TREND	C	non	C	TREND	C	Prob (Coefficient)	
	0.919	0.73	0.726		0.013	0.67	0.012		Prob (ADF)
0.000	0.000	0.000	0.689		0.123	0.33			

المصدر: من اعداد الباحث بالاعتماد على مخرجات برنامج (EViews.9)

من خلال نتائج اختبار جذر الوحدة لسلسلة الفرق الأول الملخصة في الجدول السابق(رقم 1) نلاحظ أن معاملات النموذج (مع ثابت واتجاه) غير معنوية وكذلك معامل النموذج (مع ثابت فقط) غير معنوي وبالتالي فإن السلسلة مستقرة عند الفرق الأول بدون ثابت ولا اتجاه عام، ومن ثم فإنه سيتم بناء نموذج ARIMA بالاعتماد على سلسلة الفرق الأول.

2.4.3. تحديد رتب النموذج (p,q): تم تحديد رتب النموذج بناءً على اختبار الارتباط الذاتي والارتباط الذاتي الجزئي:

الجدول رقم(2): نتائج اختبار الارتباط الذاتي والذاتي الجزئي لسلسلة الفرق الأول

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	1	1	0.305	0.305	37.158 0.000
2	2	2	0.037 -0.061	37.711 0.000	
3	3	3	-0.048 -0.045	38.625 0.000	
4	4	4	-0.094 -0.070	42.190 0.000	
5	5	5	-0.052 -0.002	43.265 0.000	
6	6	6	-0.017 -0.003	43.378 0.000	
7	7	7	-0.008 -0.011	43.403 0.000	

المصدر: مخرجات برنامج (EViews.9)

نلاحظ من خلال الجدول السابق (رقم 2) اقتراب معاملات الارتباط الذاتي والارتباط الذاتي الجزئي من الصفر، ومن خلال الجدول السابق تم اقتراح نموذج (1.1,1) لتمثيل سلسلة مؤشر سوق دمشق للأوراق المالية. ويمكن اقتراح أيضاً مجموعة من النماذج الأخرى والتي تنتمي إلى اسرة ARIMA والمفاضلة فيما بينها وفق معايير اختيار النموذج الملائم. كما هو موضح في الجدول (3) التالي:

الجدول رقم (3): معايير المعلومات لنماذج ARIMA المقترحة

Model	Log Likelihood	AIC	BIC
ARIMA(1,1,0)	-1975.520	9.94231	9.97235
ARIMA(0,1,1)	-2420.193	12.17685	12.2069
ARIMA(1,1,1)	-1955.034	9.84439	9.88445

المصدر: من اعداد الباحث بالاعتماد على مخرجات برنامج (EViews.9)

من خلال الجدول (رقم 3) السابق نلاحظ أن النموذج الأكثر ملائمة من بين النماذج المقترحة هو (1,1,1)، وفيما يلي اختبار لمعنى معاملات النموذج (1,1,1):

الجدول رقم(4): اختبار معنوية معاملات النموذج (1,1,1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6020.171	101.2904	59.43475	0.0000
AR(1)	0.973631	0.011044	88.15859	0.0000
MA(1)	0.316771	0.040456	7.830082	0.0000
SIGMASQ	1072.099	59.17675	18.11689	0.0000
R-squared	0.972124	Mean dependent var	6027.970	
Adjusted R-squared	0.971912	S.D. dependent var	196.3596	
S.E. of regression	32.90871	Akaike info criterion	9.844394	
Sum squared resid	426695.3	Schwarz criterion	9.884459	
Log likelihood	-1955.034	Hannan-Quinn criter.	9.860263	
F-statistic	4580.088	Durbin-Watson stat	1.952501	
Prob(F-statistic)	0.000000			

المصدر: من اعداد الباحث بالاعتماد على مخرجات برنامج (EViews.9)

نلاحظ من خلال الجدول السابق (رقم 4) أن جميع معاملات النموذج (1,1,1) ARIMA معنوية، وقد تم اختبار وجود أثر (ARCH) على بواعي نموذج (1.1.1) ARIMA وفق عدة تباطؤات وتبيين فقط أن معاملات النموذج (1) ARCH وكذلك (2) ARCH معنوية كما هو موضح في الجدول (5) التالي:

الجدول رقم(5) : نتائج اختبار أثر ARCH (1) - ARCH (2)

Variable	Coefficient	Std. Error	z-Statistic	Prob.	Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	5972.851	135.9378	43.93813	0.0000	C	5933.399	181.6219	32.66897	0.0000
AR(1)	0.983127	0.009804	100.2822	0.0000	AR(1)	0.986568	0.009223	106.9697	0.0000
MA(1)	0.337717	0.055904	6.040962	0.0000	MA(1)	0.303520	0.052485	5.782955	0.0000
Variance Equation									
C	823.1381	57.06725	14.42400	0.0000	C	767.0739	52.69919	14.55571	0.0000
RESID(-1)^2	0.272188	0.085231	3.193545	0.0014	RESID(-1)^2	0.219986	0.081627	2.695012	0.0070
RESID(-2)^2					RESID(-2)^2	0.089185	0.036490	2.444070	0.0145
R-squared	0.972353	Mean dependent var	6028.538		R-squared	0.972313	Mean dependent var	6028.538	
Adjusted R-squared	0.972110	S.D. dependent var	198.8098		Adjusted R-squared	0.972169	S.D. dependent var	198.8098	
S.E. of regression	33.14233	Akaike info criterion	9.803296		S.E. of regression	33.16641	Akaike info criterion	9.794368	
Sum squared resid	422889.5	Schwarz criterion	9.854340		Sum squared resid	423504.2	Schwarz criterion	9.855621	
Log likelihood	-1896.839	Hannan-Quinn criter.	9.823534		Log likelihood	-1894.107	Hannan-Quinn criter.	9.818654	
Durbin-Watson stat	2.009916				Durbin-Watson stat	1.940828			

(EViews.9) مخرجات برنامج

من خلال معايير المعلومات الموضحة في الجدول السابق (رقم 5) يتضح أن نموذج (1) ARCH أكثر ملائمة لتمثيل البيانات من نموذج (2) ARCH، وبالتالي فإنه تم الاعتماد على نموذج (1) ARCH في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية خلال الفترة المخصصة للتنبؤ (من 19/8/2019 إلى 19/9/2019).

3.4.3. بناء الشبكة العصبية الاصطناعية:

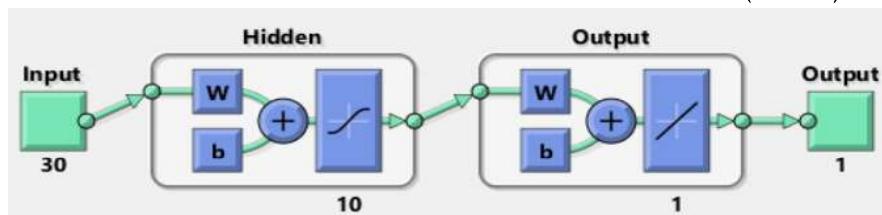
1.3.4.3 الآلية المتبعة في بناء الشبكة العصبية الاصطناعية: من أجل أن تكون المقارنة عادلة بين قدرة الشبكات العصبية الاصطناعية وقدرة نماذج (ARIMA- ARCH) في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية، فقد تم الاعتماد فقط على القيم السابقة للمتغير المدروس (سعر إغلاق المؤشر) كمدخلات للشبكة العصبية الاصطناعية للتنبؤ في اليوم التالي دون حساب أي مؤشرات فنية ودون إدخال أي متغيرات أخرى تساعد على التنبؤ بقيمة المؤشر، أي تم تحديد مدخلات الشبكة العصبية بشكل موافق للفكرة الأساسية لنموذج الانحدار الذاتي. وبهدف التنبؤ فقد تم استخدام الشبكة العصبية الاصطناعية من نوع التغذية الأمامية والانتشار الخلفي للخطأ والتي تستخدم بهدف التنبؤ. ويمكن بهذا النوع من الشبكات استخدامتابع التفعيل Hyperbolic tangent ; Definition: $\frac{e^x - e^{-x}}{e^x + e^{-x}}$ غير الخطى في الطبقة المخفية والذي يستخدم بشكل خاص لكشف العلاقات المعقدة وغير الخطية عند استخدام خوارزمية الانتشار الخلفي للخطأ، بينما يتم استخدام تابع التفعيل الخطى Linear في طبقة المخرجات وذلك بهدف السعي إلى مطابقة الخرج الفعلى مع خرج الشبكة. كما تم الاعتماد على برنامج Matlab في بناء الشبكة العصبية الاصطناعية وتدريبها والتنبؤ بها أيضاً.

وتمثلت مراحل بناء الشبكة العصبية بعد تقسيم البيانات إلى بيانات خاصة بالتدريب وبيانات خاصة بالتنبؤ بالقيام بتجرب العديد من الشبكات العصبية بشكل تدريجي بناءً على التباطؤات المستخدمة كمدخلات للشبكة العصبية، حيث تم بداية اعتماد قيمة المؤشر في اليوم السابق (تباين 1) وتدريب الشبكة على سعر الإغلاق لليوم التالي لكل يوم من أيام التداول خلال فترة التدريب، وتم تحديد عدد دورات التدريب الأعظمي بـ (Epoch 1000) وحفظ النتائج ليعاد التدريب بتعديل عدد العصبونات في الطبقة المخفية بشكل تدريجي أيضاً من (1 إلى 50) عصبون، وب مجرد إعطاء الشبكة نتائج غير جيدة أثناء زيادة عدد العصبونات أو عدم تحسن أدائها فإنه يتم تعديل المدخلات بزيادة التباطؤات وإعادة التدريب، ومن خلال التجربة التدريجي لمعلمات الشبكة أمكن التوصل إلى بناء شبكتين عصبونيتين يمكن استخدامهما للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.

3.4.3. هيكل الشبكات العصبية الاصطناعية المقترحة ونتائج تدربها: بعد التجربة التدريجية أمكن التوصل إلى الشبكتين التاليتين:

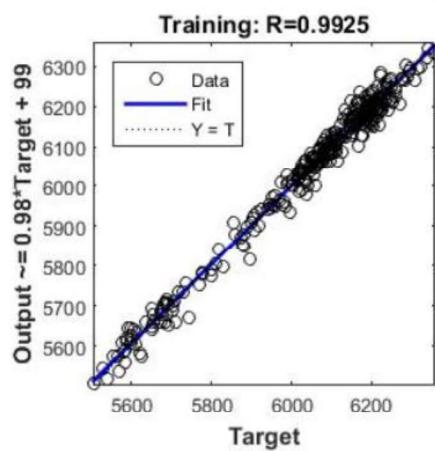
1. الشبكة العصبية الأولى: تتكون من ثلاثة طبقات:

طبقة المدخلات: تتكون من 30 مدخل (قيم أسعار الإغلاق السابقة لمؤشر السوق خلال 30 يوم سابق)، الطبقة المخفية: تكون من (10 عصبونات) خفية، طبقة المخرجات: تمثل بسعر إغلاق المؤشر ليوم التالي (المراد التنبؤ به y_{t+1}) وبالتالي فهي تحوي عصبون واحد. وقد تم تجهيز البيانات باستخدام برنامج Microsoft Excel قبل إدخالها إلى برنامج Matlab، بحيث يكون سعر الإغلاق في اليوم التالي هو خرج الشبكة العصبية، بينما أسعار الإغلاق السابقة (30 يوم سابق) هو دخل الشبكة وذلك لكل يوم تداول خلال الفترة المدروسة، حيث بلغت عدد أيام التدريب (357) يوم من تاريخ 2018/01/01 إلى 2019/08/18 (وهي الفترة المخصصة لتدريب الشبكة) وهي بمثابة عينات التدريب. أي أن الشبكة تدربت على التنبؤ باليوم التالي لـ 357 يوم بحيث يتم اعطاءها في كل يوم من هذه الأيام قيم أسعار الإغلاق السابقة (30 يوم سابق) كدخل للشبكة العصبية بهدف تعليم الشبكة العصبية على كشف العلاقة غير الخطية بين تحركات أسعار إغلاق المؤشر في الأيام السابقة وبين حركته في اليوم التالي وذلك عن طريق إعادة ضبط أوزانها في كل مرة تعيد بها التدريب للوصول إلى تطابق أفضل بين خرج الشبكة والقيم الفعلية. والشكل (1) يوضح بنية الشبكة العصبية الأولى net lag 30 (المقترحة):



الشكل (1) بنية الشبكة العصبية net lag 30 المصدر: مخرجات برنامج Matlab 2017. يوضح الشكل السابق بنية الشبكة العصبية من حيث أشكال توابع التفعيل في كل طبقة وعدد المدخلات وعدد العصبونات في الطبقة المخفية وكذلك عدد العصبونات في طبقة الخرج.

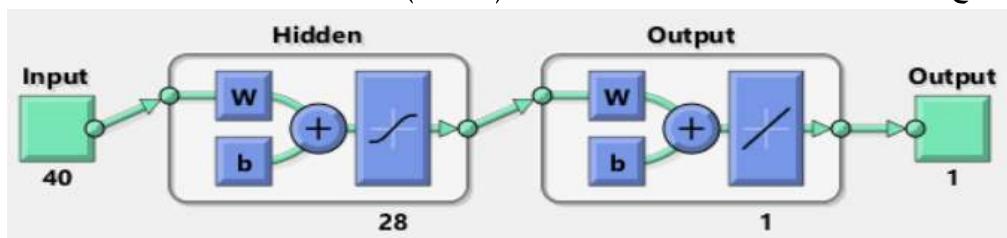
والشكل (2) التالي يوضح نتائج تدريب الشبكة العصبية والذي يظهر أن الشبكة تدربت بشكل جيد على البيانات:



الشكل (2) نتائج تدريب الشبكة العصبية net lag 30 المصدر: مخرجات برنامج Matlab 2017.

يظهر الشكل السابق علاقة الانحدار بين الخرج الفعلي (Output) وخرج الشبكة (Target) أثناء التدريب، حيث بلغ معامل الارتباط بينهما 0.9925 وهي علاقة ارتباط قوية مما يشير إلى أن الشبكة تدربت بشكل جيد، حيث تم تقييم الشبكة اعتماداً على نتائج التدريب في كل مرة يتم فيها تعديل عدد العصبونات والتباينات حتى تم التوصل إلى هذه النتيجة.

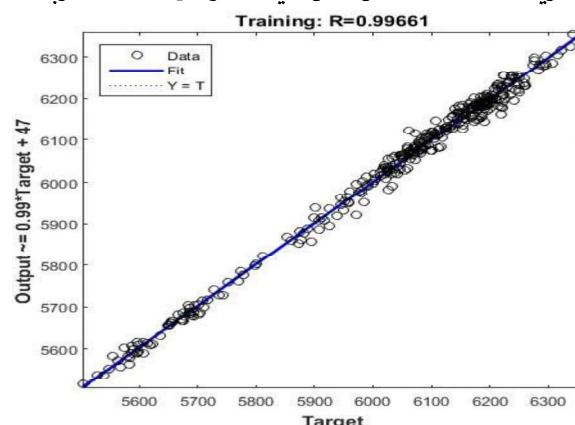
2. الشبكة العصبية الثانية: تتكون أيضاً من ثلاث طبقات، وتحتاج إلى تغيير عدد العصبونات في كل طبقة المدخلات (وهي عدد العصبونات في الطبقة الخفية)، حيث تم زيادة عدد المدخلات بشكل تدريجي لتصبح (40 مدخل) وبالتالي فقد بلغت عدد أيام التدريب (348) يوم من تاريخ 1/1/2018 إلى 18/8/2019 (وهي الفترة المخصصة لتدريب الشبكة). بينما تم تحديد عدد عصبونات الطبقة الخفية بعد التجربة التدريجية بـ (28) عصبون. والشكل (3) التالي يوضح بنية الشبكة العصبية الثانية net lag 40 (المقترحه):



الشكل (3) بنية الشبكة العصبية net lag 40 المصدر: مخرجات برنامج Matlab 2017.

يوضح الشكل السابق بنية الشبكة العصبية من حيث أشكال توابع التفعيل في كل طبقة وعدد المدخلات وعدد العصبونات في الطبقة الخفية وكذلك عدد العصبونات في طبقة الخرج.

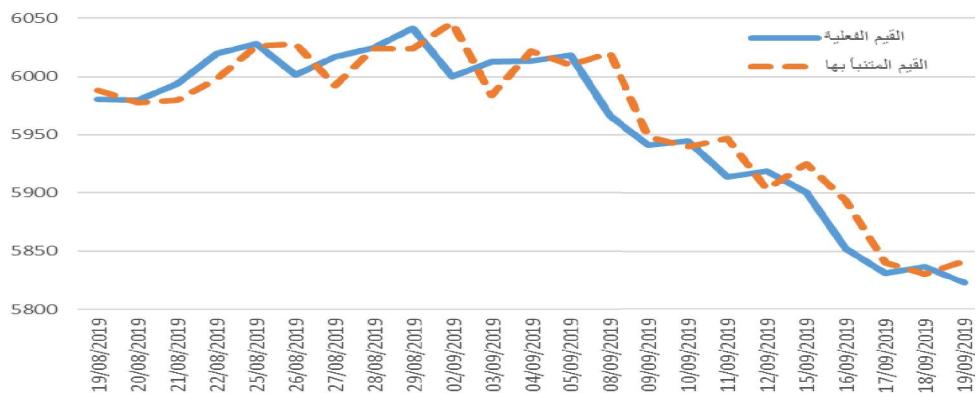
والشكل (4) التالي يوضح نتائج تدريب الشبكة العصبية والذي يظهر أن الشبكة تدربت بشكل جيد على البيانات:



الشكل (4) نتائج تدريب الشبكة العصبية net lag 30 المصدر: مخرجات برنامج Matlab 2017.

يظهر الشكل السابق علاقة الانحدار بين الخرج الفعلي (Output) وخرج الشبكة (Target) أثناء التدريب (Training)، حيث بلغ معامل الارتباط بينهما 0.996 وهي علاقة ارتباط قوية، مما يشير إلى أن الشبكة تدربت بشكل جيد.

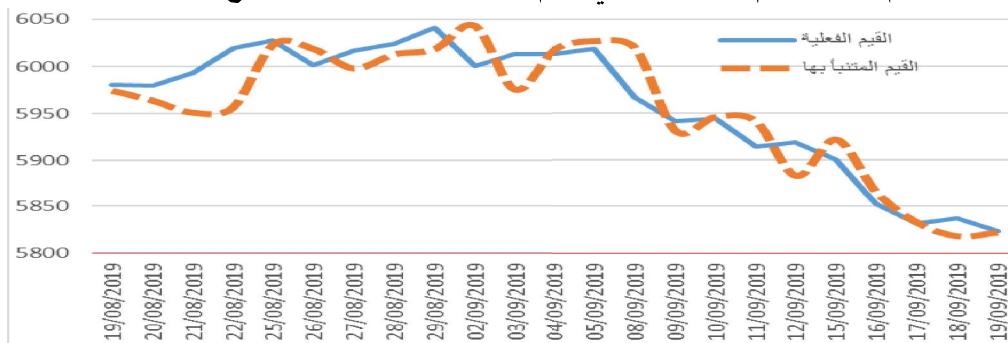
4.4.3. التنبؤ: تم التنبؤ بممؤشر سوق دمشق للأوراق المالية خلال الفترة من 19/08/2019 إلى 19/09/2019 وذلك باستخدام نموذج (1) ARIMA والذي تم بناءه اعتماداً على بوافي نموذج (1.1.1) ARIMA (كما هو موضح سابقاً، وكذلك التنبؤ باستخدام الشبكتين العصبيتين المقترحتين، وفيما يلي تلخيص لهذه النتائج:



الشكل (5) القيمة الفعلية والقيمة المتوقعة بها باستخدام نموذج (1) ARCH خلال فترة التنبؤ

المصدر: من إعداد الباحث اعتماداً على برنامج Eviews ومخرجات برنامج Excel

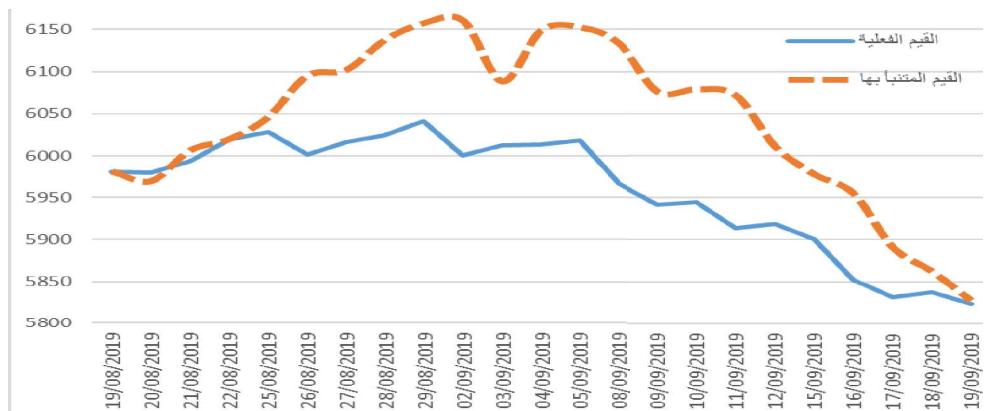
نلاحظ من خلال الشكل السابق التقارب بين القيمة الفعلية والقيمة المتوقعة بها باستخدام نموذج (1) ARCH ولكن هل يمكن الاعتماد على نموذج (1) ARCH للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية؟، ولهذا الغرض فقد تم حساب نسبة التوافق بين القيمة الفعلية والقيمة المتوقعة بها والتي سيتم عرضها عند إجراء المقارنة مع الشبكات العصبية.



الشكل (6) القيمة الفعلية والقيمة المتوقعة بها باستخدام الشبكة العصبية الاصطناعية Net Lag 30 خلال فترة التنبؤ

المصدر: من إعداد الباحث اعتماداً على برنامج Matlab ومخرجات برنامج Excel

نلاحظ من خلال الشكل السابق قدرة الشبكة العصبية (Net Lag 30) على التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.



الشكل (7) القيمة الفعلية والقيمة المتوقعة بها باستخدام الشبكة العصبية الاصطناعية Net Lag 40 خلال فترة التنبؤ

المصدر: من إعداد الباحث اعتماداً على برنامج Matlab ومخرجات برنامج Excel

من خلال الشكل السابق نلاحظ أن الشبكة (Net Lag 40) استطاعت التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية حيث يوجد تطابق ملحوظ باتجاهات الحركة بين المنحنيين.

5.4.3 المقارنة واختبار الفرضيات:

قبل القيام بعرض أهم مؤشرات قياس الدقة التنبؤية لا بد من إعطاء وصف لاتجاهات حركة مؤشر سوق دمشق للأوراق المالية لبيان كيف أن حركة مؤشر سوق دمشق تتحرك صعوداً وهبوطاً بحسب تحويت حول 50% مما يزيد من صعوبة التنبؤ باتجاه حركته وخصوصاً خلال الفترة المتباينة بها، والجدول التالي يظهر النسبة المئوية لاتجاه حركة مؤشر سوق دمشق للأوراق المالية صعوداً وهبوطاً خلال فترة تقيير النماذج وتدريب الشبكة العصبية وخلال فترة التنبؤ أيضاً

الجدول رقم (6)

وصف لاتجاه تحركات مؤشر سوق دمشق للأوراق المالية			
خلال فترة التنبؤ		خلال فترة بناء النماذج	
52%	هبوط	43%	هبوط
48%	ارتفاع	57%	ارتفاع

المصدر: من إعداد الباحث اعتماداً على برنامج Excel

وفيمما يلي تلخيص لأهم مؤشرات قياس دقة التنبؤ للأساليب السابقة:

الجدول رقم (7) مؤشرات قياس دقة التنبؤ

المؤشر / النموذج	AR(1)	Net Lag 30	Net Lag 40
نسبة التوافق باتجاه الحركة	43.48%	65.22%	78%
RMSE	23.284	26.957	99.64
MAPE	0.003	0.003	0.01
MAE	5.664	4.324	82.06

المصدر: من إعداد الباحث اعتماداً على برنامج Eviews ومحررات برنامجي Matlab و Excel

حيث أن: RMSE: الجذر التربيعي لمتوسط مربعات أخطاء التنبؤ، MAPE: متوسط القيم المطلقة للنسب المئوية لأخطاء التنبؤ، MAE: متوسط القيم المطلقة لأخطاء التنبؤ. [22]

من خلال الجدول (7) السابق نلاحظ ما يلي:

- بالرغم من قدرة نماذج ARCH على تقليل خطأ التنبؤ بالقيم كما هو موضح من خلال مؤشرات (MAE) إلا أنها لم تستطع التنبؤ باتجاه الحركة بنسبة مقبولة، حيث بلغت نسبة التوافق باتجاه الحركة 43.5% تقريباً، وهي نسبة أقل من احتمال 50% وبالتالي فإنه لا يمكن الاعتماد على نموذج ARCH بهدف التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية، وعليه يتم قبول الفرضية الأولى أي أنه لا يمكن الاعتماد على نماذج (ARIMA-ARCH) في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية لليوم التالي.

- من خلال مقارنة مؤشرات قياس الدقة التنبؤية بين الشبكة العصبية (Net Lag 30) ونموذج (AR(1)) نلاحظ التقارب الكبير بينهما فيما يخص مؤشرات (RMSE - MAPE - MAE) وقدرتها علىمحاكاة القيم الفعلية لمؤشر سوق دمشق للأوراق المالية، إلا أن الشبكة العصبية استطاعت تحقيق نسبة توافق في اتجاه الحركة أكبر من نموذج ARCH حيث بلغت نسبة التوافق باتجاه الحركة 65.22% وهي تعتبر نسبة جيدة تبعاً لأدبيات التنبؤ، وبملاحظة مؤشرات الشبكة العصبية Net Lag 40 نجد أنها استطاعت تحقيق نسبة توافق بالاتجاه ووصلت إلى 78% وهي نسبة يمكن اعتبارها عالية إذا ما تمت مقارنتها بنماذج ARIMA-ARCH ولكن هذه النسبة المرتفعة كانت على حساب ارتفاع القيم المتباينة عنها عن القيم الفعلية إذا ما تمت مقارنتها بنموذج ARCH والشبكة العصبية الأولى Net Lag 30 رغم قدرتها على توقع اتجاه الحركة، وعليه يتم رفض الفرضية الثانية أي أنه يمكن الاعتماد على

الشبكات العصبية الاصطناعية في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية لليوم التالي بنسبة تفوق (50%).

- من خلال الدراسة العملية السابقة ومن خلال مؤشرات نسبة التوافق في اتجاه الحركة نرفض الفرضية الثالثة أي أن الشبكات العصبية الاصطناعية تتفوق على نماذج (ARIMA-ARCH) في تحقيق نسبة توافق أعلى مع اتجاهات حركة مؤشر سوق دمشق للأوراق المالية.

4. النتائج: توصلت الدراسة إلى مجموعة من النتائج يمكن تلخيص أهمها فيما يلي:

- إن حركة مؤشر سوق دمشق للأوراق المالية تتحرك صعوداً وهبوطاً بنسب تمحورت حول 50% مما يزيد من صعوبة التنبؤ باتجاه حركته.

- إن النموذج الأنسب للتتبؤ بمؤشر سوق دمشق للأوراق المالية باستخدام نماذج ARCH-ARIMA هو ARCH(1) و ARIMA(1.1.1).

- لا يمكن الاعتماد على نماذج ARIMA - ARCH للتتبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.

- يمكن التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية وبنسبة توافق قد تصل إلى 78%. وبالتالي فإنه يمكن الاعتماد على نتائج التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية في اتخاذ قرارات استثمارية دقيقة.

- من الممكن التوصل إلى بناء شبكة عصبية أخرى للتتبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية لديها قدرة أكبر من الشبكتين اللتين تم التوصل إليهما في هذه الدراسة وذلك بتغيير بنية الشبكة من حيث عدد الطبقات المخفية أو عدد العصبونات في كل طبقة أو نوع توابع التعديل وتجريب تباطؤات أخرى...الخ.

5. المناقشة: يمكن تفسير وتحليل النتائج ومقارنتها مع الدراسات السابقة فيما يلي:

إن تفوق الشبكة العصبية الاصطناعية على نماذج ARIMA-ARCH في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية يمكن تفسيره بأن الشبكة العصبية عندما تقوم بضبط الأوزان في طبقة المدخلات تحديداً (والتي تحوي القيم السابقة لأسعار إغلاق المؤشر) في كل مرة تعيد فيها التدريب فإن لتذبذب قيم المدخلات فيما بينها أهمية في ربط التذبذبات السابقة مع حركة المؤشر في اليوم التالي (خرج الشبكة) وخاصة أن الشبكة تقارن بين خرجها والقيمة الفعلية في كل مرة تقوم بها في التدريب لتعديل ضبط أوزانها بناء على الخطأ، وبالتالي فإن تحركات أسعار المؤشر السابقة (التباطؤات: مدخلات الشبكة) لها تأثير في نمذجة تحركات مؤشر السوق إضافة إلى ما تتميز به الشبكة العصبية من وجود توابع التعديل غير الخطية وغيرها من المميزات. وبالتالي فإن مدخلات الشبكات (30 - 40 يوم سابق) أتاحت للشبكة قدرة أكبر على كشف طبيعة العلاقة بين هذه التحركات. بينما نماذج ARCH-ARIMA تتطلب شروط يجب تحقيقها ليتم نمذجة التقلب في اتجاه الحركة واختيار التباطؤات، وبفرض أن الشروط جميعها تتحقق فلا يمكن تشكيل نموذج يعتمد على تباطؤ يصل إلى 30 يوم سابق ولا إلى 10 أيام سابقة لما في ذلك من صعوبة في تطبيق النموذج في كل مرة يلزم بها التنبؤ لليوم التالي حيث ستصبح معادلة التنبؤ معقدة جداً وغير عملية.

ولا بد من الإشارة إلى أن الدراسة الحالية تتميز عن دراسة (مرهج، منذر 2013: التنبؤ بقيم مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية واتجاهاتها) بما يلي:

- إن الشبكات العصبية التي تم بناءها في هذه الدراسة حققت نسبة توافق في الاتجاه لا تقل عن نسبة التوافق التي تم تحقيقها في الدراسة السابقة حيث بلغت 78% مقابل 70.5%， ويمكن أن يكون لاختلاف الفترة المدروسة أثر في ذلك

بالرغم من أن فترة التنبؤ في الدراسة الحالية (19/08/2019 إلى 19/09/2019) شهدت تقلبات ملحوظة، وهذه النسبة من الممكن أن تتغير بتغير فترة التنبؤ في كلا الدراستين.

- إن الشبكات العصبية الاصطناعية المقترحة في الدراسة الحالية لا تحتاج مدخلاتها إلى إجراء أي حسابات كما هو الحال في الدراسة السابقة حيث أن الدراسة السابقة تستلزم حساب 27 مؤشر في كل يوم يلزم فيه القيام بالتنبؤ ليوم التالي، أما الدراسة الحالية تحتاج فقط إلى إدخال الأسعار السابقة لمؤشر السوق (مدخلات الشبكة) ليتم التنبؤ ليوم التالي. وبما أن جميع المؤشرات المحسوبة في الدراسة السابقة (27 متغير) تعتمد في حسابها على القيم السابقة لمؤشر السوق فإنه في هذه الدراسة تم إعطاء الشبكة القيم السابقة للمؤشر وعلى الشبكة العصبية أثناء التدريب اكتشاف ما توفره هذه المؤشرات بنفسها دون الحاجة إلى تجيزها كما هو الحال في الدراسة السابقة.

6. التوصيات: إعطاء أهمية للشبكات العصبية الاصطناعية عند القيام بعملية التنبؤ لاتخاذ القرارات الاستثمارية كرديف أساسي مقارنة بالنماذج القياسية ARIMA – ARCH، وضرورة قيام الباحثين والمستثمرين والمهتمين بتجربة عدة أشكال وبنى هيكلية أخرى للشبكات العصبية الاصطناعية المستخدمة، وتوظيف الخوارزميات الجينية في تحديد معاملات الشبكة العصبية الاصطناعية ومقارنة ذلك مع الأسلوب التجريبي.

7. المراجع

أولاً: المراجع العربية:

- البلخي، راتب، وقزما، جان، (2014)، "الاتجاه العام لأسعار الأسهم المدرجة في سوق دمشق للأوراق المالية وبناء نموذج للتنبؤ بها- دراسة تطبيقية على أسهم بنك التجارة والتمويل الدولي باستخدام نماذج أريما ونماذج الانحدار للسلسل الزمنية"، مجلة جامعة تشرين للبحوث والدراسات العلمية، سلسلة العلوم الاقتصادية والقانونية، المجلد (36) العدد (5).
- فاضل، عادل، وعبيد مهند، (2019)، "التنبؤ بمؤشر سوق العراق للأوراق المالية (ISX) باستعمال نموذج ARIMA (p,d,q)"، مجلة الدنایر، الجامعة العراقية، كلية الإدارة والاقتصاد ، العدد (15).
- قاسم آغا مهدي صالح، وروهات زاده، (2017)، "استخدام نماذج السلسلة الزمنية للتنبؤ عن أسعار أسهم في سوق الأسهم السعودي"، مجلة قهـلـاـيـ زـانـسـتـ العـلـمـيـ، مجلـةـ عـلـمـيـ دـوـرـيـةـ مـحـكـمـةـ تـصـدـرـ عـنـ الجـامـعـةـ الـلـبـانـيـةـ الفـرـنـسـيـةـ، أربيل، كوردستان، العراق، المجلد (٤) العدد (٢)، رقم التصنيف الدولي : ISSN 2518-6558.
- كوجك ورد، ونقار، عثمان، ومندو، عبد القادر، (2018) "التنبؤ بالاتجاهات المستقبلية لعوائد مؤشر سوق دمشق للأوراق المالية باستخدام نماذج ARIMA-GARCH" ، مجلة جامعة حماة، المجلد الأول.
- كينة، صفاء، (2017)، "دراسة قياسية للتنبؤ بحركة أسعار المؤشرات في سوق نيويورك المالي- حالة مؤشر داو جونز الصناعي للأوراق المالية في الفترة الممتدة من 2004-2015" ، رسالة ماجستير، جامعة قاصدي مرياح، ورقـةـ، كلـةـ العـلـمـ الـاـقـتـصـادـيـ وـالـعـلـمـ الـتـجـارـيـ وـعـلـمـ التـسـيـرـ، الجزائـرـ .
- مرهج، منذر، (2013)، " التنبؤ بقيم مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية واتجاهاتها" ، مجلة جامعة تشرين للبحوث والدراسات العلمية، سلسلة العلوم الاقتصادية والقانونية، المجلد (35) العدد (5).
- ثانياً: المراجع باللغة الأجنبية:
- Akaike, H. (1974), "A new look at the statistical model identification", IEEE Transactions on Automatic Control, 19 (6): 716–723.

8. Bollerslev. T. (1986) "Generalized Autoregressive Conditional Heteroskedasticity", *Journal of Econometrica*, Volume 31, pp. 307–326.
9. Box, G. E. P. & Jenkins, G. M. & Reinsel, G.C. & Ljung, G.M. (2016), "**Time Series Analysis Forecasting and Control**", Fifth Edition, John Wiley & Sons, Inc., Hoboken, New Jersey. pp:52–53.
10. Box, G. E. P. & Jenkins, G. M. (1976), "**Time Series Analysis Forecasting and Control**", Revised Edition., Holden-Day, California.
11. Box, G. E. P. & Jenkins, G. M. & Reinsel, G.C. (1994), "**Time Series Analysis Forecasting and Control**", Third Edition., Prentice-Hall, Inc., New jersey.
12. Chi, W. (2018). "Forecasting Stock Index Based On BP Neural Network Algorithm". *2nd International Conference on Mechanical, Electronic, Control and Automation Engineering (MECAE 2018). Advances in Engineering Research*, volume 149 Atlantis Press. This is an open access article under the CC BY-NC license (<http://creativecommons.org/licenses/by-nc/4.0/>).
13. Engle, R., (1982), "Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation", *Econometrica*, vol. 50. no. 1, pp. 987–1007.
14. Goodwin, Paul., (2018), "Profit from Your Forecasting Software- A Best Practice Guide for Sales Forecasters", John Wiley & Sons, Inc., United States of America, Hoboken, New Jersey, pp:92–94.
15. Gujarati, D., (2004), "**Basic Econometrics**", Fourth Edition, The McGraw-Hill, p.817.
16. Gujarati, D., (2011), "**Econometrics by Example**", Palgrave Macmillan, Palgrave® and Macmillan® are registered trademarks in the United States, the United Kingdom, Europe and other countries, pp:206–217.
17. Gujarati, D., Porter, D., (2009), " BASIC ECONOMETRICS " 5th ed, McGraw-Hill/Irwin, New York, PP:791–796.
18. Guresen E, Kayakutlu G, Daim TU. (2011). "Using artificial neural network models in stock market index prediction". *Expert Syst Appl. Contents lists available at Science Direct*, 38(8). pp:10389–10397.
19. Hyndman R., Athanasopoulos G., (2018), "**Forecasting: Principles and Practice**", textbook, 2 ND Edition, Published by AMAZON, p:15.
20. MACIE, L., BALLINI, R., (2010), "NEURAL NETWORKS APPLIED TO STOCK MARKET FORECASTING: AN EMPIRICAL ANALYSIS", Learning and Nonlinear Models (L&NLM) – Journal of the Brazilian Neural Network Society, Vol. 8, Iss. 1, pp. 3–22.

21. Manoonpong. P., (2007), "Neural Preprocessing and Control of Reactive Walking Machines—Towards Versatile Artificial Perception–Action Systems", Springer–Verlag Berlin Heidelberg, New York, p. 35.
22. Montgomery D., Jennings C., Kulahci M.,(2015), " **INTRODUCTION TO TIME SERIES ANALYSIS AND FORECASTING**", Second Edition, Printed in the United States of America, John Wiley & Sons, Inc., Hoboken, New Jersey, pp: 65–69.
23. Neha, Y.,Anupam, Y., Manoj, K.,(2015),"**An Introduction to Neural Network Methods for Differential Equations**",Springer Dordrecht Heidelberg New York,p:18–19.
24. Ng, G., (2003)," Intelligent Systems –Fusion, Tracking and Control", Research Studies Press LTD, Baldock, Hertfordshire, England, pp: 41–42.
25. Qiu, M., & Song, Y. (2016). Predicting the direction of stock market index movement using an optimized artificial neural network model. *PloS one*, 11(5), e0155133.
26. S. M. Idrees , M. A. Alam, P. Agarwal.(2019), "A Prediction Approach for Stock Market Volatility Based on Time Series Data ", *IEEE, VOLUME 7*, pp: (17287–17298).
27. Schwarz, Gideon E. (1978), "Estimating the dimension of a model", *Annals of Statistics*, 6 (2): 461–464.
28. Shanmuganathan, S., Samarasinghe, S., (2016), "Artificial Neural Network Modelling", Springer International Publishing, Switzerland, P:8.
29. Silva, I., Liboni, L., Spatti, N., Alves, S., Flauzino, R., (2017), "**Artificial Neural Networks A Practical Course** ", Springer International Publishing Switzerland, p:5.
30. Wit, Ernst; Edwin van den Heuvel; Jan-Willem Romeyn (2012)."All models are wrong...':an introduction to model uncertainty". *Statistica Neerlandica*. 66 (3): 217–236.
31. www.dse.sy
32. موقع سوق دمشق للأوراق المالية)

ثالثاً: الموقع الإلكتروني