

تحسين القدرة على التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية باستخدام أسلوب مقترح لبناء نموذج هجين بين الشبكات العصبية الاصطناعية ونماذج ARIMA -ARCH

أيهم الحميد* د. عثمان نقار ** د. أسمهان خلف ***

(الإيداع: 16 كانون الأول 2019 ، القبول: 20 شباط 2020)

الملخص:

هدفت هذه الدراسة إلى تقديم أسلوب مقترح لبناء نموذج هجين بين الشبكات العصبية الاصطناعية ونماذج ARIMA- ARCH بهدف تحسين القدرة على التنبؤ باتجاه حركة مؤشر السوق المالي وذلك بالتطبيق على مؤشر سوق دمشق للأوراق المالية، ولتحقيق هدف البحث فقد تم تطبيق مجموعة من أساليب التهجين الشائعة ومقارنتها مع الأسلوب المقترح وذلك من خلال تقسيم فترة التنبؤ إلى فترتين، من تاريخ 19/08/2019 إلى 19/09/2019 ومنها إلى تاريخ 21/10/2019 وحساب نسبة التوافق بالاتجاه ومؤشر RMSE للفترتين، وأهم النتائج التي تم التوصل إليها أن الأسلوب المقترن كان الأنسب للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية. حيث أن هذا الأسلوب لا يعتمد في حسابه لأوزان الدمج على أخطاء النماذج في مرحلة التقدير وإنما على قدرة النماذج علىمحاكاة اتجاه الحركة لسلسلة مؤشر سوق دمشق للأوراق المالية وهذا ما أعطاه قدرة أكبر في تحسين إمكانية التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية خلال فترتي التنبؤ إذا ما تمت مقارنته بأساليب التهجين الأخرى.

الكلمات المفتاحية: التنبؤ – مؤشر السوق – الشبكات العصبية الاصطناعية – نماذج ARIMA – نماذج ARCH – نماذج الهجين.

* : طالب دكتوراه في كلية الاقتصاد (تمويل ومصارف) – جامعة حماة.

** : مشرف علمي، أستاذ مساعد في قسم الاقتصاد في جامعة حماة.

*** : مشرف مشارك، أستاذ مساعد في قسم الاقتصاد في جامعة حماة.

Improving the Predictability of Damascus Securities Exchange index's Movement Using a Proposed Method to Build a Hybrid Model between Artificial Neural Networks and ARCH-ARIMA Models

Ayham AL Hameed*

Dr. Asmhan Khalaf**

Dr.Othman Naqar***

(Received: 16 December 2019, Accepted: 20 February 2020)

Abstract:

This study aimed at presenting a proposed method for constructing a hybrid model between artificial neural networks and ARIMA-ARCH models. In order to improve the ability to predict the direction of the movement of the financial market index, by applying it to DSE index, and to achieve the research goal, a set of common hybridization methods have been applied and compared with the proposed method, the forecast periods were divided into two periods, from (19/08/2019 to 19/09/2019) and (from 19/09/2019 to 21/10/2019) and calculating the trend-fit ratio and RMSE for the two periods. The most important results reached are; the proposed method was the most appropriate to predict the movement of the DSE index movement. As this method does not depend on calculating the merging weights on model errors in the estimation stage, but on the ability of the models to simulate the direction of movement of the DSE Index series, which gives a greater ability to improve the predictability of the DSE index directions' during the two forecasted periods when compared to other hybridization methods.

Key Words: Predicting – Market Index – Artificial Neural Networks – ARIMA Models – ARCH Models – Hybrid Models.

*PhD student, Department of Banking and Finance, Faculty of Economics, Hama University, Syria.

** Associate professor, Department of Economics. Faculty of Economics, Hama University, Syria.

*** Associate professor, Department of Economics. Faculty of Economics, Hama University, Syria.

1. المقدمة:

إن التباين بممؤشر 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.[16] لذا يلجأ المستثمرون إلى مناهج وأساليب مختلفة من أجل محاولة التباين بممؤشر ما سيكون عليه اتجاه السوق المالي. وفي ظل وجود دراسات سابقة استخدمت الشبكات العصبية الاصطناعية للتباين بممؤشر سوق دمشق للأوراق المالية في بدايات نشأتها وتوصلت إلى نتائج جيدة في التباين، إضافة إلى وجود دراسات أخرى استخدمت نماذج قياسية مثل الانحدار الذاتي للتباين بممؤشر سوق دمشق للأوراق المالية، فكان لابد من تقييم قدرة هذه النماذج في دراسة واحدة خلال نفس الفترة الزمنية للمقارنة بين قدرتها على التباين باتجاه حركة مؤشر سوق دمشق للأوراق المالية، وبناء عدة نماذج هجينة وتقييم قدرتها على تحسين التباين باتجاه حركة مؤشر سوق دمشق للأوراق المالية ومقارنتها مع أسلوب التهجين المقترن، وبالتالي فإنه يمكن تلخيص مشكلة البحث بالتساؤل الرئيس التالي:

هل أسلوب التهجين المقترن يساعد على تحسين القدرة على التباين باتجاه حركة مؤشر سوق دمشق للأوراق المالية إذا ما تم مقارنته مع أساليب التهجين الشائعة؟

2. أهداف البحث وأهميته:**2.1. أهداف البحث:** يمكن تلخيص أهم أهداف البحث في النقاط التالية:

- بناء نماذج هجينة بين الشبكة العصبية الاصطناعية ونماذج (ARIMA- ARCH) وفق طرق التهجين الشائعة ومقارنتها مع أسلوب التهجين المقترن.

2.2. أهمية البحث: يمكن تلخيص أهمية البحث في النقاط التالية:

- إن محاولة التباين بممؤشر سوق دمشق للأوراق المالية بأكثر من أسلوب والوصول إلى تباينات 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.
- كما تتبّع أهمية الدراسة في كونها جمعت بين الاسلوبين في دراسة واحدة وبين مجموعة من النماذج الهجينة ليتسنى القيام بالمقارنة بين قدرة هذه الأساليب مجتمعة على التباين باتجاه حركة مؤشر سوق دمشق للأوراق المالية.
- كم تتجلى الأهمية العلمية للدراسة بما ستقدمه من اقتراح أسلوب للتهجين وهذا ما يمثل إضافة علمية وعملية إذا ما تم مقارنة ذلك مع الدراسات السابقة.

3. مواد وطرائق البحث:**3.1. فرضيات البحث وحدوده ومصادر جمع البيانات:**

- 3.1.1. فرضيات البحث:** تحقيقاً لأهداف الدراسة وبناءً على التساؤلات الخاصة بالمشكلة البحثية فإنه يمكن صياغة الفرضية الرئيسية التالية: اعتماداً على مؤشر نسبة التوافق في اتجاهات الحركة فإن أسلوب التهجين المقترن لا يتفوق على أساليب التهجين الشائعة في تحسين القدرة على التباين باتجاه حركة مؤشر سوق دمشق للأوراق المالية.

3.1.2. حدود البحث ومصادر جمع البيانات: يمكن تقسيم حدود البحث إلى: الحدود المكانية والحدود الزمنية:

- الحدود المكانية: تم تطبيق الدراسة العملية في 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 21/10/2019.
- وفيما يخص مصادر جمع البيانات فإنه سيتم الحصول عليها من الموقع الرسمي لسوق دمشق للأوراق المالية.

- 2.3. الدراسات السابقة:** هناك العديد من الدراسات التي تناولت موضوع التنبؤ بمؤشر السوق المالي بأساليب ونمذج 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)"^[4]. هدفت الدراسة إلى بناء شبكة عصبية اصطناعية للتنبؤ بقيم مؤشر سوق دمشق للأوراق المالية واتجاهاته ليوم التداول التالي. واعتمد الباحث على قاعدة التجربة والخطأ في بناء هيكل الشبكة - عدد الطبقات وعدد الخلايا (العصيبيون) في كل طبقة- وذلك بالتطبيق على السلسلة الزمنية للمؤشر خلال الفترة 4/1/2010 إلى 7/3/2013. وقد تم تدريب الشبكة وفق خوارزمية التكاثر الارتدادي على مجموعة من المتغيرات (27 متغير كمديات الشبكة) التي جرى تحديدها في ضوء الدراسات السابقة وأساليب التحليل الفني من مثل: (سعر الإغلاق اليومي، إبطاء السلسلة لسعر اغفال المؤشر لفترة زمنية واحدة وفترتين، النسبة المئوية للتغير بسعر الإغفال، 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 واتجاهه ليوم التداول التالي باستخدام أسلوب الشبكات العصبية الاصطناعية وبدرجة عالية من الدقة حيث بلغت نسبة التوافق في اتجاه الحركة 70.5%.
 - دراسة (البلخي، راتب، وقرما، 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 ونمذاج الانحدار للسلسلات الزمنية)"^[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 وحتى نهاية شهر شباط عام، 2011 ، قد تم تطبيق الأساليب الإحصائية المتعلقة بالسلسلات الزمنية، توصلت الدراسة إلى أن أفضل نموذج للتنبؤ المستقبلي بأسعار الأسهم نموذج الانحدار من الدرجة الثالثة ونموذج (2.0.1) ARIMA وذلك دون الأخذ بعين الاعتبار التغيرات الطارئة والموسمية.
 - دراسة (كوجك ورد، ونقار، عثمان، ومندو، عبد القادر 2018) بعنوان "التنبؤ بالاتجاهات المستقبلية لعوائد مؤشر سوق دمشق للأوراق المالية باستخدام نماذج ARIMA-GARCH"^[3]. 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 حتى 1/12/2016 والتنبؤ بالقيم المستقبلية للشهر الأخير، ولتحقيق هذا الهدف تم احتساب العوائد اليومية للمؤشر خلال فترة الدراسة، وبإتباع منهجية Box-Jenkins في تحليل السلسلات 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 متقطعة متطرفة من المرتبة الأولى (ARMA (2,1)، كما ويختبر تباين عوائد المؤشر لعملية (1,1) GARCH، وبالاعتماد على النموذج المقدر تم التنبؤ 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.
- ثانياً:** بعض الدراسات التي استخدمت النماذج الهجينية في التنبؤ: هناك العديد من الدراسات التي استخدمت النماذج الهجينية في السلسلات الزمنية، إلا أنه سنقتصر هنا على ذكر دراستين وذلك لضرورة اختصار العرض، بينما سيتم ذكر بعض الدراسات الأخرى التي استخدمت النماذج الهجينية عند التحدث عن أساليب التهجين الشائعة في المراجعة الأدبية:

- دراسة (الجراح، نوال، والحكاك، ندى 2013) بعنوان "استخدام الطرق الهجينية في التنبؤ لسعر الصرف الدولار الأمريكي" [2]: هدفت هذه الدراسة إلى استخدام نموذج هجين بين الشبكات العصبية الاصطناعية ونموذج التمهيد الأسني، ونموذج هجين آخر بين الشبكات العصبية الاصطناعية ونمادج ARIMA، ونموذج هجين يجمع بين التمهيد الأسني والشبكات العصبية الاصطناعية ونمادج ARIMA وذلك بهدف التنبؤ بسعر صرف الدولار الأمريكي مقابل الدينار العراقي. وقد تم بناء النماذج الهجينية (سابقة الذكر) بالاعتماد على أسلوب الانحدار المتعدد لحساب أوزان الدمج، وتمت الدراسة خلال الفترة (من كانون الأول 2011 إلى 16 نيسان لعام 2012) وأهم النتائج كانت أن أفضل نموذج هجين هو بين الشبكات العصبية ونمادج ARIMA حسب معيار MSE (متوسط مربعات الأخطاء).

- دراسة (Nashat T AL-Jallad, XU-Ning, Mergani Khairalla 2017 ، بعنوان"

(Hybrid Forecasting Scheme for Financial Time Series Data using Neural Network and Statistical Methods)"

نظام تنبؤ هجين للسلسل الزمنية المالية باستخدام الشبكات العصبية الاصطناعية والأساليب الإحصائية [20]: هدفت هذه الدراسة إلى التنبؤ بسعر صرف الجنيه السوداني مقابل اليورو ليوم التالي باستخدام نموذج هجين مكون من ثلاث نماذج هي: نموذج التمهيد الأسني، نموذج ARIMA والشبكات العصبية الاصطناعية، وقد تم الاعتماد على أسلوبين في التهجين، الأول بالاعتماد على الانحدار الخطى في حساب الوزن الترجيحي لبناء النموذج الهجين. والأسلوب الثاني هو الأسلوب التجميعي (additive) بحيث يتم التهجين باستخدام الشبكات العصبية الاصطناعية (حيث تكون مدخلات الشبكة هي مخرجات نموذج ARIMA ومخرجات نموذج التمهيد الأسني). وبناءً على مقاييس دقة التنبؤ تبين أن النموذج الهجين يعطي دقة أكبر في التنبؤ من أي نموذج يتم استخدامه على حدة، وقد أعطى التهجين بأسلوب الانحدار الخطى دقة أكبر من الأسلوب التجميعي.

بناءً على ما سبق ذكره من دراسات سابقة فإن الدراسة الحالية تختلف عن الدراسات السابقة والتي هدفت إلى التنبؤ بمؤشر سوق دمشق للأوراق المالية (على وجه الخصوص) من ناحية حداثة الفترة الزمنية للدراسة ومن ناحية الأسلوب المطبق، حيث ستقوم هذه الدراسة باستخدام النماذج الهجينية للتنبؤ بمؤشر سوق دمشق للأوراق المالية 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. كما أن هذه الدراسة ترتكز في مقارنتها بشكل أساسي على التوافق في اتجاهات الحركة كمقاييس أساسي في اختبار الدقة التنبؤية. ومن ناحية أخرى فإن هذا البحث يهدف إلى تقديم أسلوب مقترن للتهجين ومقارنته مع أساليب التهجين الشائعة، وهذه ما يمثل إضافة علمية وعملية إذا ما تم مقارنة ذلك مع الدراسات السابقة.

3.3. المراجعة الأبية:

1. منهجية بوكس جينكينز- Box-Jenkins والصياغة الرياضية لنماذج ARIMA: تم تقديم هذه منهجية من قبل كلٍ من GEORGE E.P. BOX و GWILYMM M. JENKINS في كتابهما الشهير في تحليل السلسلة الزمنية "Time Series Analysis Forecasting & control" في عام 1976 [9]، وبالرغم من مرور سنوات عديدة على تقديمها إلا أن منهجية Box-Jenkins تعد من المناهج الحديثة في تحليل السلسلة الزمنية وأكثرها شيوعاً، وقد بين Box-Jenkins في كتابهما بمختلف اصداراته مراحل تطبيق هذه منهجية بشكل مفصل حيث تمثلت بالأتي [10]: 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. ويمكن فحص استقرارية السلسلة الزمنية من خلال اختبار جذر الوحدة والذي من الممكن

الكشف عنها وفق اختبار ديكى فوللر المطور (ADF) [14] حيث يشترط لبناء نماذج الانحدار الذاتي والمتوسط المتحرك أن تكون السلسلة الزمنية مستقرة (غير عشوائية)، كما تفترض هذه المنهجية ثبات التباين. ولتحقيق مرونة أكبر في نمذجة السلسلة الزمنية، من المفيد في بعض الأحيان تضمين نموذج الانحدار الذاتي (AR) ونموذج المتوسط المتحرك (MA) في نموذج التبؤ الأساسي، وهذا يعني أن يكون النموذج الناتج هو نموذج خليط بين النموذجين ويمكن التعبير عن هذا النموذج (ARMA(p,q)) من خلال العلاقة (1) التالية [8]:

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

حيث أن: Y_t : قيمة المتغير في الفترة (t) وهي القيمة المراد التنبؤ بها (المتغير التابع). $\emptyset_1, \emptyset_2, \emptyset_p$: معاملات الانحدار. $Y_{t-1}, Y_{t-2}, Y_{t-p}$: قيم المتغير في الفترات السابقة حتى الفترة (p) وهو ما يسمى بالتأخر الزمني أو التباطؤ.). $\alpha_t, \alpha_{t-1}, \alpha_{t-q}$: الحدود العشوائية الحالية والسابقة والتي تشكل عملية ضجة البيضاء. $\theta_1, \theta_2, \theta_q$: معاملات نموذج الانحدار والتي يتم تقديرها من البيانات. ولتحديد درجة التباطؤ (p) في نموذج الانحدار الذاتي AR ودرجة التباطؤ (q) في نموذج المتوسطات المتحركة MA فقد اقترح Box & Jenkins الاعتماد على كلٍ من دالة الارتباط الذاتي (ACF) لتحديد رتبة نموذج المتوسطات المتحركة (MA(q)), ودالة الارتباط الذاتي الجزئي (PACF) لتحديد رتبة نموذج الانحدار الذاتي (AR(p)).

إن السلسلة الزمنية المالية من مثل أسعار الأسهم، أسعار الصرف، معدلات التضخم، وما إلى ذلك، غالباً ما تتصف بظاهرة التقلب في بياناتها وهذا ما يجعلها تتصرف بعدم 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 المعجم (GARCH) باعتبارهم من النماذج الأكثر استخداماً في تحليل ونمذجة السلسلة الزمنية المالية على وجه الخصوص.

2.3.3. الصياغة الرياضية لنماذج (ARCH-GARCH): إن نموذج ARCH يمكن تطبيقه على السلسلة 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 (2) التالية [15]:

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

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 عدم هي: $\{ \alpha_1 = \alpha_2 = \dots = \alpha_p = 0 \}$ فإذا تحقق ذلك فإن $var(u_t) = \alpha_0$ وبالتالي فإنه لا يوجد أثر لنموذج ARCH.

وقد شهد نموذج ARCH منذ اكتشافه عام 1982 تطورات عديدة، وأحد أهم هذه التطورات وأكثرها شيوعاً واستخداماً في نمذجة السلسلة الزمنية المالية هو نموذج الانحدار الذاتي المشروط بعدم تجانس التباين المعجم (Generalized ARCH) والذي قدمه Bollerslev (1986) في عام [7]، ويرمز له اختصاراً بالرمز (GARCH)، حيث يمكن صياغته بالعلاقة (3) التالية:

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 \sigma_{t-1}^2 \dots \quad (3)$$

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 (1) ARCH فحسب وإنما يعتمد أيضاً على تباين المتغير المدروس في الفترة السابقة، وبالتالي فإن إمكان أن يكون كل من مربع الخطأ والتباينات مرتبطة فيما بينها لأكثر من فترة واحدة وبالتالي فإنه يمكن تعميم هذا النموذج إلى نموذج (p,q) GARCH.

3.3.3 الشبكات العصبية الاصطناعية:

3.3.3.1. تعريف الشبكة العصبية الاصطناعية وبنيتها: الشبكة العصبية الاصطناعية (ANN) عبارة عن نظام لمعالجة المعلومات بشكل متوازي يتميز أداءه بخصائص شببه بالخلايا العصبية بالبيولوجيا الحية، وهي بمثابة تعميم للنمذاج الرياضية للإدراك البشري أو البيولوجيا العصبية.[21]، كما يمكن تعريفها أيضاً بأنها نماذج حسابية مستوحاة من النظام العصبي للكائنات الحية، لديها القدرة على اكتساب المعرفة (التعلم) من خلال مجموعة من وحدات المعالجة (processing units) والتي تشكل الخلايا العصبية الاصطناعية والمرتبطة فيما بينها لأكثر من طريق مصفوفة الأوزان والتي تمثل المشابك الاصطناعية.[25]

وتكون 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 ملتق 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 يدوره يعطي قيمة الخرج لهذه العقدة ليتم توزيعها بالتوالي إلى العصبونات الأخرى في الطبقة التالية في حال لم تكن هذه العقدة في الطبقة الأخيرة (المخرجات).[19] ولكن قبل المضي قدماً بالطرق إلى أنواع الشبكات العصبية الاصطناعية لا بد من الحديث عن أنواع توابع التنشيط Activation function والتي يتم بواسطتها المعالجة الرياضية.

تابع التنشيط Activation function [11] 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: $(-1 : x \leq -1), (+1 : x \geq 1), (x : -1 < x < +1)$; Range: $(-1, +1)$.

يمكن اختيار تابع التنشيط التي تتوافق مع توزيع القيم المستهدفة (المُتَبَّأِ 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 الأسني (Exponential) إذا كانت قيم المخرجات موجبة وغير محدودة من الأعلى (0 ، +∞) وهكذا... .

2.3.3.3 أنواع الشبكات العصبية الاصطناعية المستخدمة في التنبؤ: [22] 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)، فالشبكات ذات التغذية الأمامية تعتمد بشكل كامل على التغذية الأمامية دون أن يكون لخرج العقد أي تغذية راجعة للشبكة، أما الشبكات ذات التغذية الراجعة فإنها تتميز عن سابقتها 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.

3.3.3.3 مراحل بناء الشبكة العصبية الاصطناعية: بشكل عام فإن تصميم شبكة عصبية اصطناعية تمر بمجموعة من الخطوات الرئيسية والتي يمكن ذكرها بالآتي [24]: تحديد المشكلة >> اعداد البيانات اللازمة لتدريب الشبكة: والتي قد تشمل التحليل الاحصائي والتقدير والتطبيع...الخ. >> اختيار نموذج (نوع) الشبكة العصبية المناسبة للمشكلة >> القيام بتدريب الشبكة العصبية. >> اختبار قدرة الشبكة العصبية على التعميم (generalization) والتحقق من النتائج. حيث يتم في مرحلة إعداد البيانات تقسيم البيانات إلى ثلاث مجموعات: مجموعة التدريب، مجموعة الاختبار، مجموعة التحقق. أما فيما يخص تصميم الشبكة (هيكلها)، فيتم فيها تحديد عدد الطبقات المخفية وعدد العصبونات في كل طبقة وأنواع توابع التفعيل في كل من طبقة المدخلات والمخفية وطبقة المخرجات غالباً ما يتم ذلك عن طريق التجربة. وفيما يخص تدريب الشبكة فإنه يتم تحديد خوارزمية التدريب المناسبة للمشكلة، وتحديد عدد دورات التدريب (التجاريات)، وكذلك معدل التعلم، ومعدل الزخم [18].

4.3 مفهوم النماذج الهجين وأساليب التهجين الشائعة: من المعروف أن أي سلسلة زمنية يمكن نمذجتها والتنبؤ بها باستخدام عدة طرق، على سبيل المثال فإن السلسلة الزمنية (y_t ، $t=1,2,...$) والتي تحتوي على اتجاه عام (على سبيل المثال) يمكن التنبؤ بها من خلال كل من نموذج التمهيد الأسني (exponential smoothing) ونماذج ARIMA، في مثل هذه الحالات فإنه من غير الفعال الاعتماد فقط على تنبؤات أحد النماذج وتجاهل جميع المعلومات في النموذج الآخر، فقد اتضحت عملياً أنه يمكن الجمع بين تنبؤات النماذج للوصول إلى تنبؤات أفضل من حيث خطأ التنبؤ إذا ما تمت مقارنته بتنبؤات كل نموذج على حدة. وهنا لا بد من الإشارة إلى أن دقة التنبؤ تزداد بشكل ملحوظ كلما كانت أخطاء التنبؤات للنماذج المراد استخدامها في النموذج الهجين ترتبط ارتباطاً عكسيًا فيما بينها، ومع ذلك حتى إذا كانت الأخطاء ترتبط إيجابياً فإن التنبؤ اعتماداً على النموذج الهجين يبقى أفضل من التنبؤ اعتماداً على نموذج واحد [12].

وفي الحديث عن التنبؤ في السلاسل الزمنية فإن ما تتصف به السلاسل الزمنية من صفات خطية وغير خطية فإن نمذجتها باستخدام أسلوب واحد قد لا يعطي تنبؤات حيدة دائماً، فمثلاً نجد أن نماذج ARIMA جيدة لنمذجة السلاسل الزمنية الخطية بينما الشبكات العصبية الاصطناعية جيدة لنمذجة السلاسل الزمنية غير الخطية، وبالتالي يمكن أن تكون المنهجية الهجينية التي تتمتع بقدرات النمذجة الخطية وغير الخطية استراتيجية جيدة للاستخدام العملي من خلال الجمع بين نماذج مختلفة، ويمكن توضيح ما سبق من خلال العلاقة (4) التالية [29]:

$$y_t = L_t + N_t \dots \dots \quad (4)$$

حيث أن: L_t : تمثل الجزء الخطي من السلاسل الزمنية، N_t : تمثل الجزء غير الخطي من السلاسل الزمنية. حيث يتم تقدير الجزء الخطي والجزء غير الخطي من خلال نماذج التنبؤ المختلفة وذلك بالاعتماد على البيانات السابقة.

وهناك العديد من أساليب التهجين الشائعة، نجد مثلاً أن Zhang [30] قام أولاً بتقدير نموذج ARIMA وذلك لتقدير الجزء الخطى من السلسلة الزمنية واعتبر أن باقى نموذج ARIMA هي الجزء غير الخطى: $\hat{L}_t = y_t - e_t$, وفي الخطوة الثانية يتم محاولة نمذجة باقى نموذج ARIMA من خلال الشبكة العصبية الاصطناعية (أى يتم التنبؤ بأخطاء نموذج ARIMA باستخدام الشبكة العصبية) باعتبار أن هذه الباقي هي الجزء غير الخطى من السلسلة الزمنية وبالتالي فإن النموذج الهجين هو حاصل جمع مخرجات الشبكة في كل خطوة مراد التنبؤ بها وهذه الطريقة في التهجين الذى قدمها Zhang يطلق عليها في الأبيات additive hybrid ARIMA-ANN.

كما يمكن بناء النموذج الهجين عن طريق الشبكة العصبية الاصطناعية بحيث تكون مدخلات الشبكة العصبية الاصطناعية هي مخرجات النماذج المستخدمة (مثل ARIMA – EXP – ARIMA) وبحيث تكون مخرجات الشبكة هي القيم الأصلية، ومن خلال تدريب الشبكة يتم تقليص الخطأ بين مدخلاتها (مخرجات النماذج الأخرى) والقيم الأصلية للسلسلة الزمنية. [17]

وأخيراً فإنه يمكن بناء النموذج الهجين من خلال إعطاء وزن نسبي لكن نموذج ومن ثم فإن النموذج الهجين عبارة عن حاصل مجموع مضاريب أوزان الدمج بمخرجات النماذج المستخدمة وذلك بشرط أن يكون مجموع الأوزان يساوى (100%)، ويمكن تقدير أوزان الدمج من خلال الانحدار الخطى بين النماذج باعتبارها متغيرات مستقلة مع قيم السلسلة الأصلية باعتبارها متغيرتابع. ويمكن توضيح ما سبق من خلال العلاقة التالية: [17]

$$Y_t = W_1 F_t^{model1} + W_2 F_t^{model2} + \dots + W_n F_t^{model(n)} \dots \dots \dots \quad (5)$$

حيث أن W : الوزن الترجيحي للنموذج، F_t^{model} : خرج النموذج في الفترة t .

ووفقاً لدراسة (Timmermann) فإن استخدام المتوسط البسيط لمخرجات النماذج تعد طريقة فعالة مثل طرق التهجين المقترنة (أى ان النموذج الهجين هو الوسط الحسابي لمخرجات النماذج الداخلة في عملية التهجين وهذا مفاده استخدام أوزان متساوية)[27] ، ولكن في كثير من الحالات لا يمكن أن تتحقق الأوزان المتساوية أفضل نتيجة للتنبؤ،

كما يمكن استخدام الخوارزميات الجينية لحساب الأوزان الترجيحية كما في دراسة (6) [6] Al-hnaity, B., & Abbod, M.) (كما يمكن تلخيص الخطوات العامة لمبدأ عمل الخوارزميات الجينية بما يلى[26] :

- تحديد دالة الصلاحية Fitness Function (هي تحويل دالة الهدف إلى دالة مناسبة للحل في الخوارزميات الجينية).
- البداية: وتتمثل في توليد مجتمع عشوائي من الكروموسومات، أو بعبارة أخرى إيجاد حلول مناسبة للمسألة.
- توليد مجتمع جديد: وتتمثل في توليد جيل جديد بتكرار الخطوات الآتية إلى أن يكتمل الجيل، ويتضمن ذلك ما يلى:
- الاختيار (Selection): يتم اختيار اثنين من الكروموسومات (والدين) Parents Chromosomes من المجتمع الابتدائي الذي تم توليده عشوائياً والتي يكون لها الاحتمال الأكبر للظهور وتعطي قيم أفضل ويتم ذلك بالاعتماد على دالة الصالحة.
- التصالب Crossover: إجراء إحدى عمليات التصالب للحصول على الذرية Offspring ويكون بين كروموسمين.
- الطفرة Mutation: يتم عمل الطفرة للسلف الجديد (الحل الجديد) بموقع معين في الكروموسوم، وتجري بين الجينات في الكروموسوم الواحد وذلك لاحتمال وجود طفرات في الأجيال.
- الاستبدال Replacement: عملية وضع السلف الجديد المتكون في الجيل الجديد للحلول محل المجتمع الابتدائي.
- الاختبار Test: عند توفر شرط التوقف، فإن الخوارزميات الجينية تتوقف وتعيد الحل الجديد من آخر جيل متكون.

- معيار التوقف: Stopping Criteria يستمر إنشاء الأجيال المتعاقبة بهدف تحسين الحل (تحسين أمثلية الحل)، وذلك حتى يتحقق شرط التوقف الذي يعتمد على مقياس توقف الخوارزميات الجينية، ويختلف هذا المقياس على حسب المسألة المراد حلها. ويتم تحديدها من قبل الباحث وذلك بتحديد عدد الأجيال الذي يتم توليدها.

5.3. الدراسة التطبيقية واختبار الفرضيات:

سيتم اختبار فرضيات الدراسة تباعاً بعد بناء كل من النموذج القياسي (ARIMA- ARCH) المناسب والشبكة العصبية الاصطناعية، والنماذج الهجينية والمقارنة بينهم.

1.5.3. تقسيم البيانات:

بهدف المقارنة العلمية الدقيقة بين قدرة النماذج القياسية ARIMA- ARCH وبين قدرة الشبكات العصبية الاصطناعية والنماذج الهجينية في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية فقد تم تقسيم بيانات الدراسة بشكل متكافئ بين الأساليب المطبقة، من تاريخ 1/1/2018 إلى 18/8/2019 خصصت لبناء نماذج (ARIMA- ARCH) وكذلك لتدريب الشبكة العصبية الاصطناعية وأيضاً لبناء النماذج الهجينية (تقدير نسب المزج). من تاريخ 19/8/2019 إلى 21/10/2019 خصصت للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية باستخدام الأساليب سابقة الذكر.

2.5.3. بناء النموذج القياسي (ARCH-ARIMA):

1.2.5.3. 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 وتبين أنها تحتوي جذر وحدة، لذا فقد تم إجراء الفروق من الدرجة الأولى لتحويلها إلى سلسلة مستقرة، وكل ذلك تم 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 (ADF) وتم تحديد عدد الفجوات المناسبة لهذا الاختبار بناءً على معيار Schwarz Information Criterion [23] وهو معيار لاختيار النموذج الأفضل من بين مجموعة من النماذج، ووفق هذا المعيار يفضل النموذج ذو القيمة الأقل من بين النماذج الأخرى مثله في ذلك مثل معيار أكايكي (AIC) [5]، 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)[28].

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

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

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

من خلال نتائج اختبار جذر الوحدة لسلسلة الفرق الأول المخصصة 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.

2.2.5.3. تحديد رتب النموذج (p): 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	1	2	0.037 -0.061	37.711	0.000
3	1	3	-0.048 -0.045	38.625	0.000
4	1	4	-0.094 -0.070	42.190	0.000
5	1	5	-0.052 -0.002	43.265	0.000
6	1	6	-0.017 -0.003	43.378	0.000
7	1	7	-0.008 -0.011	43.403	0.000

المصدر: مخرجات برنامج (EViews.9)

نلاحظ من خلال الجدول السابق (رقم2) 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 تنتهي إلى اسرة ARIMA والمفاضلة فيما بينها وفق معايير اختيار النموذج الملائم.

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 الأكثـر ملائمة من بين النماذج المقترحة هو (1,1,1)، وفيما يلي اختبار لمعنىـة معاملات النموذج (1,1,1):

الجدول رقم (4): اختبار معنىـة معاملات النموذج ARIMA (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) معنىـة، وقد تم اختبار وجود أثر (ARCH) على بوأـي نموذج (1.1.1) وفق عدة تباطـوات وتبيـن فقط أن معاملات النموذج (1) ARCH وكذلك (2) ARCH معنىـة كما هو موضـح في الجدول (5) التالـي:

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

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	0.972210	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			

المصدر: مخرجات برنامج (EViews.9)

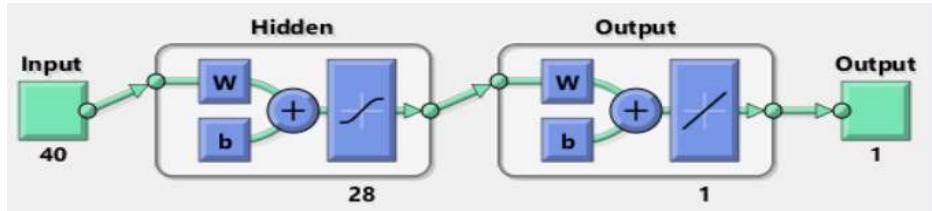
من خلال معايير المعلومات الموضحة في الجدول السابق (رقم 5) يتضح أن نموذج ARCH (1) قريب جداً من نموذج ARCH (2) في ملائمته لتمثيل البيانات وتم تجريب كل منهم واتضح أنه لا يوجد فارق لذا تم الاعتماد على نموذج ARCH للتنبؤ.

3.5.3. بناء الشبكة العصبية الاصطناعية:

1. 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 للتغير 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 لنماذج الانحدار الذاتي. وبهدف التنبؤ فقد تم استخدام الشبكة العصبية الاصطناعية من نوع التغذية الأمامية والانتشار الخلفي للخطأ. ويتم عادة بهذا النوع من الشبكات استخدامتابع $\frac{e^x - e^{-x}}{e^x + e^{-x}}$ Hyperbolic tangent: غير الخطى في الطبقة المخفية والذي يستخدم بشكل خاص لكشف العلاقات المعقدة وغير الخطية عند استخدام خوارزمية الانتشار الخلفي للخطأ، بينما يتم استخدامتابع 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. حيث تمثلت مراحل بناء الشبكة العصبية بعد تقسيم البيانات إلى بيانات خاصة بالتدريب وبيانات خاصة بالتنبؤ بالقيام بتجربة العديد من الشبكات العصبية بشكل تدريجي بناءً على التباطؤات المستخدمة كمدخلات للشبكة العصبية، حيث تم بداية اعتماد قيمة المؤشر في اليوم السابق (تباطؤ 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، 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 التجريب التدريجي لمعاملات الشبكة أمكن التوصل إلى بناء شبكة عصبية يمكن استخدامها في التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.

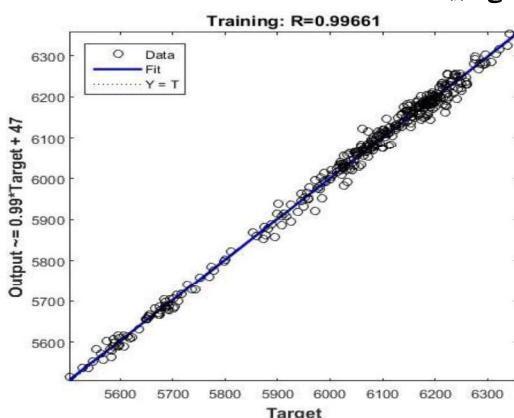
2.3.5.3 هيكـل الشـبـكـة العـصـبـونـيـة الـاصـطـنـاعـيـة المقـتـرـحة وـنـتـائـج تـدـريـبـها: تـبـين من خـلـال التـجـربـة أـن زـيـادـة التـبـاطـؤـات تعـطـي نـتـائـج أـفـضـل لـلتـبـؤـ بالـاتـجـاه بـالـرـغـم مـن زـيـادـة الخـطـأ (الـفـرق بـيـن الـقـيم الـفـعـلـيـة وـمـخـرـجـات الشـبـكـة) ، لـذـكـ بـعـد التـجـربـة التـدـريـجيـة اـقـرـاحـ شـبـكـة العـصـبـونـيـة تـكـوـن مـن ثـلـاث طـبـقـات: طـبـقـة الـمـدـخـلـات: تـكـوـن مـن 40 مـدـخـل (قـيم أـسـعـار إـغـلـاقـ السـابـقـة لـمـؤـشـرـ السـوق خـلـال 40 يـوـم سـابـقـ). طـبـقـة الـمـخـفـيـة: تـكـوـن مـن (28 عـصـبـون) خـفـيـ. طـبـقـة الـمـخـرـجـات: تـمـثـلـ بـسـعـرـ إـغـلـاقـ الـمـؤـشـرـ لـلـيـومـ التـالـيـ (الـمـرـادـ التـبـؤـ بـه y_{t+1}) وـبـالـتـالـيـ فـيـ تـحـويـ عـصـبـونـ وـاـحـدـ.

وـقـدـ تـجـهـيزـ الـبـيـانـاتـ باـسـتـخدـامـ بـرـنـامـجـ Microsoft Excelـ قـبـلـ إـدـخـالـهـ إـلـىـ بـرـنـامـجـ Matlabـ، بـحـيثـ يـكـونـ سـعـرـ إـغـلـاقـ فـيـ الـيـوـمـ التـالـيـ هوـ خـرـجـ الشـبـكـةـ العـصـبـونـيـةـ، بـيـنـماـ أـسـعـارـ إـغـلـاقـ السـابـقـةـ (40 يـوـمـ سـابـقـ) هوـ دـخـلـ الشـبـكـةـ وـذـكـ لـكـ يـوـمـ تـادـولـ خـلـالـ الـفـرـقـةـ الـمـدـرـوـسـةـ، حـيـثـ بـلـغـتـ عـدـدـ أـيـامـ التـدـريـبـ (348) يـوـمـ مـنـ تـارـيـخـ 1/1/2018 إـلـىـ 18/8/2019 (وـهـيـ الـفـرـقـةـ الـمـخـصـصـةـ لـتـدـريـبـ الشـبـكـةـ). وـالـشـكـلـ (1) يـوـضـعـ بـنـيـةـ الشـبـكـةـ العـصـبـونـيـةـ (net) (lag40)ـ:



الشكل رقم (1): بنية الشبكة العصبونية (net) (lag40) المصدر: مخرجات برنامج Matlab 2017

يـوـضـعـ الشـكـلـ السـابـقـ بـنـيـةـ الشـبـكـةـ العـصـبـونـيـةـ مـنـ حـيـثـ أـشـكـالـ تـوـابـعـ التـفـعـيلـ فـيـ كـلـ طـبـقـةـ وـعـدـدـ الـمـدـخـلـاتـ وـعـدـدـ الـعـصـبـونـاتـ فـيـ طـبـقـةـ الـمـخـفـيـةـ وـكـذـلـكـ عـدـدـ الـعـصـبـونـاتـ فـيـ طـبـقـةـ الـخـرـجـ. وـالـشـكـلـ (2) التـالـيـ يـوـضـعـ نـتـائـجـ تـدـريـبـ الشـبـكـةـ العـصـبـونـيـةـ وـالـذـيـ يـظـهـرـ أـنـ الشـبـكـةـ تـدـريـبـ بـشـكـلـ جـيـدـ عـلـىـ الـبـيـانـاتـ:



الشكل رقم (2): نـتـائـجـ تـدـريـبـ الشـبـكـةـ العـصـبـونـيـةـ (net) (lag40) المصدر: مخرجات برنامج Matlab 2017

يـظـهـرـ الشـكـلـ السـابـقـ عـلـاقـةـ الـانـهـارـ بـيـنـ الـخـرـجـ الـفـعـلـيـ (Target) وـخـرـجـ الشـبـكـةـ (Output) أـنـتـهـاـ التـدـريـبـ، حـيـثـ بـلـغـ مـعـاـمـلـ الـإـرـتـاطـ 0.99661ـ وـهـيـ عـلـاقـةـ اـرـتـباطـ قـوـيـةـ مـاـ يـشـيرـ إـلـىـ أـنـ الشـبـكـةـ تـدـريـبـ بـشـكـلـ جـيـدـ، حـيـثـ تـمـ تـقـيـيـمـ الشـبـكـةـ اـعـتمـادـاـ عـلـىـ نـتـائـجـ التـدـريـبـ فـيـ كـلـ مـرـةـ يـتـمـ فـيـهـ تـعـدـيلـ عـدـدـ الـعـصـبـونـاتـ أوـ الـتـبـاطـؤـاتـ حـتـىـ تـمـ التـوـصـلـ إـلـىـ هـذـهـ النـتـائـجـ. وـلـاـ بدـ مـنـ إـلـاـسـارـ إـلـىـ أـنـ نـسـبـةـ التـوـافـقـ فـيـ اـتـجـاهـ الـحـرـكـةـ لـلـشـبـكـةـ العـصـبـونـيـةـ لـلـعـيـنـاتـ الـتـيـ تـدـريـبـ عـلـيـهـاـ كـانـتـ (72.62%)ـ بـيـنـماـ فـيـ نـمـوذـجـ ARIMA-ARCHـ (63.96%)ـ، وـأـنـ الجـذـرـ التـرـيـعـيـ لـمـتـوـسـطـ مـرـبـعـاتـ الـأـخـطـاءـ (RMSE)ـ (16.7)ـ لـلـشـبـكـةـ بـيـنـماـ فـيـ نـمـوذـجـ ARIMA-ARCHـ (31.81)ـ وـبـهـذاـ فـإـنـ الشـبـكـةـ العـصـبـونـيـةـ تـفـوقـتـ عـلـىـ نـمـاذـجـ ARIMA-ARCHـ فـيـ قـدرـتـهـاـ عـلـىـ تـمـثـيلـ الـبـيـانـاتـ الـتـيـ بـنـيـتـ عـلـيـهـاـ سـوـاءـ مـنـ نـاحـيـةـ التـبـؤـ بـاـتـجـاهـ الـحـرـكـةـ أـمـ مـنـ نـاحـيـةـ خـطـأـ التـبـؤـ.

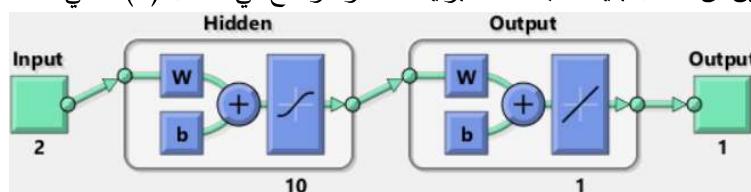
4.5.3 بناء النماذج الهجينة وأسلوب التهجين المقترن: تم بناء النماذج الهجينة خلال الفترة التي تم على أساسها تدريب نموذج ARIMA-ARCH وتدريب الشبكة العصبية (1/1/2018 إلى 18/8/2019). حيث تمثل بما يلي:
أولاً: الانحدار المتعدد بين مخرجات النماذج والقيم الفعلية: تم بناء نموذج الانحدار المتعدد بين مخرجات نموذج ARIMA ومخارات الشبكة العصبية الاصطناعية كمتغيرات مستقلة وبين القيم الفعلية لمؤشر سوق دمشق للأوراق المالية كمتغير تابع،

والجدول رقم (6) التالي يبين نتائج هذا الاختبار:

Significance F	F	MS	SS	df	ANOVA
0.000000	22895470	6351592868	12703185737	2	Regression
		277	95986	346	Residual
			12703281723	348	Total
P-value	t Stat	Standard Error	Coefficients		
1.075E-99	30.38938293	0.035255935	1.071406122		الشبكة العصبية
0.04346612	-2.026637122	0.035260646	-0.071460535		نموذج ARIMA-ARCH

المصدر : مخرجات برنامج EXCEL اعتماداً على أداة Data Analysis

ثانياً: محاولة التنبؤ في بواقي نموذج ARIMA باستخدام الشبكة العصبية **hybrid ARIMA-ANN:** تم الاعتماد على قاعدة التجربة التدريجي في تحديد عدد التباطؤات (بواقي نموذج ARIMA في الفترات السابقة) كمدخلات للشبكة وذلك وفق دراسة G [29]، غالباً فإن أخطاء النموذج لا ترتبط مع بعضها لفترات طويلة سابقة، وفقاً لذلك وبعد التجربة تبين أن أفضل بنية للشبكة العصبية كما هو موضح في الشكل (2) التالي:



الشكل رقم (2) بنية الشبكة العصبية (net error- lag2) المصدر : مخرجات برنامج Matlab 2017

يظهر الشكل السابق بنية الشبكة العصبية التي تم استخدامها للتنبؤ ببواقي نموذج ARIMA (1.1.1)، حيث تتكون من مدخلين (تباطؤين للبواقي) وعدد العصبونات في الطبقة الخفية (10) وخرج واحد (عصبون واحد في طبقة الخروج) وهو يمثل قيمة الخطأ (بواقي) المتتبلي به. كما يظهر الشكل السابق أنواع توابع التفعيل في الطبقة الخفية وطبقة المخرجات، حيث تم استخدام تابع التفعيل Hyperbolic tangent: $\frac{e^x - e^{-x}}{e^x + e^{-x}}$ غير الخططي في الطبقة المخفية غير الخطية باعتبار أن البواقي المراد النبو بها تتشكل الجزء غير الخططي في السلسلة.

ثالثاً: التهجين عن طريق التوزيع المتساوي لنسب المجز: وفق هذه الطريقة فإنه يتم إعطاء أوزان متساوية في بناء النموذج الـ ARIMA، فيما أنه يوجد نماذجين يتم استخدامهما في هذا البحث (الأول: نموذج ARIMA-ARCH والثاني: الشبكات العصبية الاصطناعية) فإنه وفقاً لهذه الطريقة فإن النموذج الـ ARIMA هو:

$$Y_{\text{Hybrid}} = (50\%) * Y_{\text{net}} + (50\%) * Y_{\text{ARCH}} \dots \dots \dots \quad (4)$$

رابعاً: حساب أوزان الدمج باستخدام الخوارزميات الجينية: تم تحديد تابع دالة الصلاحية Fitness Function (دالة الهدف) اعتماداً على مؤشر RMSE: الجذر التربيعي لمتوسط مربعات أخطاء التنبؤ للنموذج الـ ARIMA- ARCH والشبكة العصبية، بحيث يكون الحل الأمثل بناءً على تحديد أوزان الدمج والذي يعطي أقل قيمة لخطأ RMSE: تابع الصلاحية المحدد)، ولضمان تحديد الأوزان بأفضل نسب فقد تم تحديد معيار التوقف Stopping

Creteria _ عدد الأجيال الذي يتم توليدها لأمثلة الحل_ بـ— (1000) جيل. وتم استخدام الحزمة البرمجية (GA Optimization for EXCEL) بهدف تطبيق الخوارزميات الجينية، وتم التوصل إلى أوزان الدمج التالية:

$$Y_{\text{Hybrid}} = (106.993\%)*Y_{\text{net}} + (-6.997\%)*Y_{\text{ARCH}} \dots\dots (5)$$

نلاحظ أن استخدام الخوارزميات الجينية في حساب أوزان التهجين قد أعطت أوزان قريبة جداً للأوزان التي تم الحصول عليها باستخدام الانحدار المتعدد، وذلك بسبب العلاقة الخطية بين القيم المتبعة بها من خلال نموذج ARIMA-ARCH والشبكة العصبية الاصطناعية وبين القيمة الفعلية (مؤشر السوق المالي).

خامساً: أسلوب التهجين المقترن: بما أن التبؤ باتجاه الحركة في السوق المالي يحظى على اهتمام كبير فإن النموذج الذي لديه قدرة أكبر على تحقيق نسبة توافق في اتجاه الحركة من المنطق أن يكون وزنه الترجيحي أكبر وذلك بهدف زيادة قدرة النموذج الهجين على التبؤ باتجاه الحركة، وكما هو معروف فإن خطأ النموذج الهجين (مثلاً معيار RMSE) لا يمكن أن يكون قيمته أكبر من قيمة النموذج ذو الخطأ الأكبر من بين النماذج المراد تهجينها، لذا وبعيداً عن التعقيد فإن هذا الأسلوب يعتمد في حساب أوزان التهجين بناءً على قدرة النماذج في التبؤ باتجاه الحركة (أي بغض النظر عن قيمة الباقي /الأخطاء /لكل نموذج) فمن الممكن أن يكون للنموذج قدرة على التبؤ باتجاه الحركة ولكن الفرق بين القيمة الفعلية وخرج النموذج كبير مقارنة بنموذج آخر يكون الفارق بين القيمة الفعلية وخرجه أقل ولكن نسبة التوافق في اتجاه الحركة أقل من النموذج الأول (كما سيتضح ذلك لاحقاً عند مقارنة النماذج في فترة التبؤ) لذا فإن الأسلوب المقترن يعتمد في حسابه لأوزان النماذج على نسب التوافق في اتجاه الحركة للنماذج الداخلة في النموذج الهجين، وبعبارة أخرى فإنه يعتمد في حساب أوزان النماذج على قدرة النماذج على محاكاة اتجاه الحركة لسلسلة مؤشر السوق المالي. ويمكن حساب نسبة التهجين لأي نموذج من خلال العلاقة التالية:

$$w_i = \frac{Cr_i}{\sum_{i=1}^n Cr_i} \dots\dots (6)$$

حيث أن w_i : الوزن الترجيحي للنموذج i ، n : عدد النماذج الداخلة في بناء النموذج الهجين، Cr_i : نسبة التوافق (Compatibility ratio) في اتجاه الحركة للنموذج i .

أي أن الوزن الترجيحي لكل نموذج يتم حسابه بقسمة نسبة توافق هذا النموذج إلى مجموع نسب التوافق لجميع النماذج الداخلة في التهجين. وبناءً على ما سبق فإنه تم حساب نسب التهجين لكل من الشبكات العصبية الاصطناعية ونموذج ARCH، حيث كانت قيمتها كما هو موضح في العلاقة التالية:

$$Y_{\text{Hybrid}} = (53.277\%)*Y_{\text{net}} + (46.723\%)*Y_{\text{ARCH}} \dots\dots (5)$$

والجدول رقم (7) التالي يوضح نتائج النماذج الهجينة خلال الفترة نفسها التي تم على أساسها تقدير النماذج الهجينة وبناء جميع النماذج السابقة (مرحلة ما قبل التبؤ من 1/1/2018 إلى 18/8/2019):

الفترة		
نسبة التوافق باتجاه الحركة	RMSE	النماذج المؤشرات
72.62%	16.71	ANN
63.69%	31.82	ARCH
62.50%	32.01	additive hybrid
		ARIMA-ANN
72.33%	16.61	regression
66.57%	22.03	(ANN,ARCH)
72.33%	16.61	التوزيع المتساوي
		GA(ARCH;ANN)
66.28%	21.49	الأسلوب المقترن

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

من خلال الجدول السابق نلاحظ أن النموذجين regression(ANN-ARCH) – GA(ANN-ARCH) كان لهما نفس الأداء بسبب التقارب الكبير في أوزان الدمج فيما بينهما، كما أن مؤشر RMSE لهما كان الأفضل مقارنة بباقي النماذج، حيث استطاعا تخفيض خطأ الشبكة ممثلاً بعيار RMSE من 16.71 إلى 16.61 من خلال دمجها مع نموذج ARCH، بينما الأسلوب المقترن كان حل وسطي بين النماذج الأخرى سواء من حيث نسبة التوافق أو من حيث مؤشر RMSE، ولكن هل الاعتماد على أحدهم (باتجاه الحركة) سوء من حيث التباين المترافق؟ في التنبؤ سيكون الأفضل في مرحلة التنبؤ؟ وهل يمكن القدرة في تحسين التنبؤ باتجاه الحركة أو تقليل خطأ التنبؤ مقارنة بباقي النماذج الأخرى؟ هذا ما سيتم مناقشته في الفقرة التالية.

5.5.3. التنبؤ والمقارنة واختبار الفرضيات: من أجل بيان دور الأسلوب المقترن لبناء النموذج الهجين في تحسين القدرة على التنبؤ فإنه تم تقسيم فترة التنبؤ إلى فترتين، من تاريخ 19/08/2019 إلى 19/09/2019 ومنها إلى تاريخ 21/10/2019 وحساب نسبة التوافق بالاتجاه ومؤشر RMSE (مؤشر الجذر التربيعي لمتوسط مربعات الأخطاء) للفترتين. كما هو موضح في الجدول رقم (8) التالي وذلك وفق النماذج والأساليب التي تم بناءها (الهجينة وغير الهجينة) ووفق الأسلوب المقترن:

الجدول رقم (8): مؤشرات قياس دقة التنبؤ خلال الفترة 19/8/2019 إلى 21/10/2019

الفترة				
نسبة التوافق باتجاه الحركة	RMSE	نسبة التوافق باتجاه الحركة	RMSE	النماذج المؤشرات
66.67%	63.46	78.26%	99.64	ANN
76.19%	27.92	47.83%	22.99	ARCH
68.18%	25.82	52.17%	24.75	additive hybrid
66.67%	67.25	78.26%	106.12	ARIMA-ANN
76.19%	39.40	60.87%	55.69	regression
66.67%	67.14	78.26%	105.93	(ANN,ARCH)
76.19%	40.78	65.22%	58.47	التوزيع المتساوي
				GA(ARCH;ANN)
				الأسلوب المقترن

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

من خلال الجدول (8) السابق نلاحظ ما يلي:

- من خلال فترة التنبؤ الأولى نلاحظ أنه بالرغم من قدرة نموذج ARIMA-ARCH في تقليل خطأ التنبؤ بالقيم كما هو موضح من خلال مؤشر (RMSE) مقارنة بالشبكة العصبية الاصطناعية (ANN) إلا أنها لم تستطع التنبؤ باتجاه حركة مؤشر سوق دمشق كما هو عليه في الشبكة العصبية الاصطناعية، حيث بلغت نسبة التوافق باتجاه الحركة لهذه الفترة من التنبؤ 47.83% وهي نسبة أقل من احتمال 50% وبالتالي فإنه حسب معطيات التنبؤ لهذه الفترة يتضح أنه لا يمكن الاعتماد على نموذج ARCH بهدف التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية. وبالمقابل نجد أن مؤشر نسبة التوافق باتجاه الحركة للشبكة العصبية الاصطناعية وصلت إلى 78.26% وهي نسبة يمكن اعتبارها عالية إذا ما تمت مقارنتها بنماذج ARIMA-ARCH ولكن هذه النسبة المرتفعة كانت على حساب ارتفاع مؤشر RMSE مقارنة بنموذج ARIMA-ARCH رغم قدرتها على توقع اتجاه الحركة. وبالتالي فإنه حسب معطيات التنبؤ لهذه الفترة يتضح أنه يمكن الاعتماد على الشبكة العصبية الاصطناعية بهدف التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.

- من خلال فترة التنبؤ الثانية نلاحظ أن نموذج ARIMA-ARCH تفوق على الشبكة العصبية الاصطناعية في تحقيق نسبة أعلى للتوافق باتجاه الحركة وبمقدار أقل من مؤشر RMSE حيث وصلت نسبة التوافق باتجاه الحركة إلى 76.19% مقابل 66.67% للشبكة العصبية الاصطناعية، وبالتالي فإنه حسب معطيات التنبؤ لهذه الفترة يتضح أنه يمكن الاعتماد على نموذج ARIMA-ARCH بهدف التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية وذلك على خلاف ما هو عليه في الفترة الأولى من التنبؤ.

ويمكن تفسير ما سبق بأن سلسلة أسعار الإغلاق لمؤشر سوق دمشق للأوراق المالية خلال فترة التنبؤ الأولى اتصف بأنها غير خطية وكما نعلم أن الشبكة العصبية لديها قدرة أكبر في التعامل مع البيانات غير الخطية وخاصة أنه تم استخدامتابع التعديل $\frac{e^x - e^{-x}}{e^x + e^{-x}}$ Hyperbolic tangent غير الخطى في الطبقة المخفية للشبكة العصبية والذي يستخدم بشكل خاص لكشف العلاقات المعقدة وغير الخطية لذا فإنها أعطت نتائج أفضل للتنبؤ باتجاه الحركة مقارنة بنموذج ARIMA-ARCH، أما في فترة التنبؤ الثانية فإن السلسلة الزمنية كانت أقرب إلى الخطية لذا فإن نماذج ARIMA-ARCH تفوقت على الشبكة العصبية في تحقيق نسبة توافق أعلى باتجاه الحركة. ويمكن ملاحظة ذلك من خلال عرض القيم الفعلية لسلسلة أسعار إغلاق مؤشر سوق دمشق للأوراق المالية خلال فترتي التنبؤ كما هو موضح في الشكل (3) التالي:



الشكل رقم (3) القيم الفعلية لسلسلة أسعار إغلاق مؤشر سوق دمشق للأوراق المالية خلال فترتي التنبؤ

- بالنسبة للنماذج الهجينية نلاحظ أن الشبكة العصبية الاصطناعية كانت أفضل من النماذجين الهجينين لأنها حققت نفس قيمة مؤشر نسبة التوافق باتجاه الحركة وبمقدار GA (ARCH;ANN), regression(ANN,ARCH)

أقل من مؤشر RMSE وذلك سواء بفترة التنبؤ الأولى أو الثانية وبالتالي فإن هذان النموذجان لم يحققان أي إضافة على صعيد تحسين القدرة التنبؤية خلال الفترتين، إلا أن النموذج الهجين ذو التوزيع المتساوي كان كحل وسطي بين الشبكة العصبية ونمادج ARIMA-ARCH في كلا الفترتين. وبالنسبة لنموذج ARIMA-ANN فإنه additive hybrid ARIMA-ANN حسّن قليلاً من أداء نموذج ARIMA-ARCH من ناحية زيادة القدرة على التوافق باتجاه الحركة في الفترة الأولى من التنبؤ ولكنه سلك سلوكاً معاكساً خلال الفترة الثانية من التنبؤ حيث أضعف من قدرته على التنبؤ باتجاه الحركة من 76.19% إلى 68.18% ولكن بقي أفضل من أداء الشبكة العصبية الاصطناعية وأفضل من النموذجين الهجينين regression(ANN,ARCH) GA (ARCH;ANN).

- وإذا ما تمت مقارنة الاستقراءات السابقة بأسلوب التهجين المقترن أنه في فترة التنبؤ الأولى حقق نسبة توافق 65.22% وهي نسبة توافق أعلى من النموذج الهجين ذو التوزيع المتساوي حيث حقق هذا الأخير نسبة توافق 60.87% وإذا ما تمت مقارنته بأساليب التهجين الأخرى نلاحظ أن هذه الأساليب لم تتحقق أي تحسن إذا ما تمت مقارنتها بالشبكة العصبية كما ذكرنا سابقاً أي أن الأسلوب المقترن خفض من خطأ الشبكة العصبية من 99.64 إلى 58.47 تبعاً لمؤشر RMSE خلال فترة التنبؤ الأولى، وبالطبع فإن نسبة توافقه أقل من الشبكة العصبية خلال هذه الفترة ولكنه كحل وسطي بين النماذج المستخدمة مع ميل نحو النموذج الذي يحقق نفس نسبة توافق أعلى.

أما خلال فترة التنبؤ الثانية فإن الأسلوب المقترن حقق نفس نسبة التوافق الذي حققه نموذج ARIMA-ARCH 76.19% وهي أعلى نسبة توافق باتجاه بالنسبة لجميع النماذج. أما باقي نماذج التهجين فإنها حققت نفس أداء الشبكة العصبية تقريباً وهي نسبة توافق أقل وبخطأ أكبر.

- بما أنه لا يمكن معرفة طبيعة السلوك الذي ستتبّعه سلسلة الأسعار في السوق المالي في كل فترة يتم بها التنبؤ (هل ستكون خطية أم غير خطية) فإن الاعتماد على أحد النماذج (الشبكات العصبية أو ARIMA-ARCH) من شأنه أن يحقق في فترات معينة دقة جيدة وفي فترات أخرى دقة أقل في التنبؤ باتجاه الحركة لذا فإنه من الضروري الاعتماد على نموذج هجين يأخذ الصفات الخطية وغير الخطية معاً مع ميل نحو النموذج الذي لديه قدرة أكبر في تحقيق نسبة توافق أعلى. وهذا ما اتضح من خلال ما سبق، فلو تم الاعتماد على الأسلوب المقترن في التنبؤ في الفترة الأولى لكان أفضل من الاعتماد على نموذج ARIMA-ARCH للتنبؤ باتجاه الحركة وأفضل من التوزيع المتساوي أيضاً، وخلال الفترة الثانية فإنه لو تم الاعتماد على الأسلوب المقترن لكان أفضل من الاعتماد على الشبكة العصبية الاصطناعية، كما أن الاعتماد على نماذج التهجين الأخرى (الانحدار المتعدد، التهجين بالخوارزميات الجينية) لم يعطي أي ميزة مقارنة بالشبكة العصبية الاصطناعية لأن أوزان التهجين التي أعطتها هذه الأساليب اعتمدت على أخطاء النموذجين في مرحلة التقدير (البناء) وكان خطأ الشبكة قليلاً في هذه المرحلة مقارنة بنمذاج ARIMA-ARCH لذا فإن أوزان التهجين كانت بحدود 107% للشبكة و 7% لنموذج ARIMA-ARCH. لذا سلكت سلوك قريب لسلوك الشبكة العصبية الاصطناعية. وإذا ما سلمنا بأن أسلوب التهجين ذو التوزيع المتساوي أفضل من أساليب التهجين الشائعة الأخرى باعتباره حل وسطي فإن الأسلوب المقترن يتقدّم على النموذج الهجين ذو التوزيع المتساوي في الفترات التي تتصف بها طبيعة تحركات الأسعار بأنها غير خطية لأن نماذج ARIMA-ARCH في الفترات غير الخطية (الفترة الأولى) حققت نسبة توافق (47.83%) وهي أقل كفاءة بفارق ملحوظ عن الشبكة العصبية الاصطناعية في الفترات الخطية (الفترة الثانية) حيث حققت الشبكة (66.67%)، أي أن الشبكة العصبية الاصطناعية كانت أفضل خلال الفترة الكلية لذا فإن الأسلوب المقترن هو الأنسب للتنبؤ باتجاه الحركة وأفضل من التوزيع المتساوي لأنه أعطى النموذج الأفضل تقدّم أكبر في التهجين

وتم بناء من خلال نسب التوافق وليس بالاعتماد على الأخطاء كما هو الحال في التموذجين الهجينين .GA (ARCH;ANN), regression(ANN,ARCH)

بناء على ما سبق يمكن رفض الفرضية الرئيسية في هذا البحث وقبول الفرضية البديلة، وبالتالي فإن أسلوب التهجين المقترن يتفوق على أساليب التهجين الشائعة في تحسين القدرة على التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.

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

- إن الاعتماد على نموذج ARIMA-ARCH كنموذج خطى أو على الشبكة العصبية الاصطناعية كنموذج غير خطى من شأنه أن يحقق في فترات معينة دقة جيدة وفي فترات أخرى دقة أقل في التنبؤ باتجاه الحركة إذا فإنه من الضروري الاعتماد على نموذج هجين يأخذ الصفات الخطية وغير الخطية معاً.
- عند بناء نموذج هجين باستخدام الانحدار المتعدد أو باستخدام الخوارزميات الجينية لحساب أوزان الدمج فإنه في بعض الحالات لا تعطي هذه الأساليب أي تحسين في القدرة التنبؤية وذلك في حال كانت أخطاء أحد النماذج المراد تضمينها في التموذج الهجين قليلة مقارنة بالنماذج الأخرى، وبالتالي فإنه سيتم اعطاءها الوزن الأكبر كما هو عليه الحال في الشبكة العصبية الاصطناعية - وخاصة أن أوزان التهجين التي أعطتها هذه الأساليب تعتمد على أخطاء النماذج في مرحلة التقدير وتعمد في تحديدها لهذه الأوزان إلى تخفيض الخطأ إلى أقل قدر ممكن - حيث تم إعطاء الشبكة العصبية وزن ترجيحي 107% مقابل 7% لنماذج ARIMA-ARCH وبالتالي فإن التموذج الهجين سلك نفس سلوك الشبكة العصبية الاصطناعية تقريباً.
- إن الأسلوب المقترن والذي تم بناءه اعتماداً على نسب التوافق باتجاه الحركة كان الأنسب للتنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية. حيث أن هذا الأسلوب لا يعتمد في حسابه لأوزان الدمج على أخطاء النماذج في مرحلة التقدير وإنما على قدرة النماذج على محاكاة اتجاه الحركة لسلسلة مؤشر سوق دمشق للأوراق المالية وهذا ما أعطاه قدرة أكبر في تحسين إمكانية التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية.

6 . التوصيات:

- إعطاء أهمية للنماذج الهجينية عند القيام بعملية التنبؤ في السوق المالي لاتخاذ قرارات استثمارية رشيدة.
- تطبيق أساليب التهجين الشائعة في أسواق أخرى ومقارنتها مع الأسلوب المقترن، وهذا من شأنه أن يؤدي إلى تعميم أسلوب التهجين الأفضل عند المقارنة.
- ضرورة قيام الباحثين والمستثمرين والمهتمين بتجربة عدة أشكال وبين هيكليات أخرى للشبكات العصبية الاصطناعية.

7 . المراجع

أولاً: المراجع العربية:

1. البلخي، راتب، وقرما، 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 للسلسلة الزمنية"، مجلة جامعة تشرين للبحوث والدراسات العلمية، سلسلة العلوم الاقتصادية والقانونية، المجلد (36) العدد (5).
2. الجراح، نوال، والحكاك، ندى، (2013)، "استخدام الطرق الهجينية في التنبؤ لسعر الصرف للدولار الأمريكي"، مجلة كلية بغداد للعلوم الاقتصادية الجامعية، العدد (34)، ص ص: 380-359.
3. كوجك ورد، ونقار، عثمان، ومندو، عبد القادر، (2018) "التنبؤ بالاتجاهات المستقبلية لعوائد مؤشر سوق دمشق للأوراق المالية باستخدام نماذج ARIMA-GARCH" ARIMA-GARCH، مجلة جامعة حماة، المجلد الأول.

4. 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:

5. Akaike, H. (1974), "A new look at the statistical model identification", *IEEE Transactions on Automatic Control*, 19 (6): 716–723.
6. Al-hnatiy, B., & Abbod, M. (2016). "Predicting financial time series data using hybrid model". *In Intelligent Systems and Applications*, Springer International Publishing Switzerland, pp. 19–41.
7. Bollerslev. T. (1986) "Generalized Autoregressive Conditional Heteroskedasticity", *Journal of Econometrica*, Volume 31, pp. 307–326.
8. 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.
9. Box, G. E. P. & Jenkins, G. M. (1976), **Time Series Analysis Forecasting and Control**", Revised Edition., Holden-Day, California
10. Box, G. E. P. & Jenkins, G. M.& Reinsel, G.C. (1994), **Time Series Analysis Forecasting and Control**", Third Edition., Prentice-Hall, Inc., New jersey.
11. Cain. G., (2017)., “ **Artificial neural networks : new research**”, Nova Science Publishers, New York, USA, p.6.
12. DOUGLAS ,C., CHERYL,L., MURAT,.K, (2015), “**INTRODUCTION TO TIME SERIES ANALYSIS AND FORECASTING**”, Second Edition, Published by John Wiley & Sons, Inc., Hoboken, New Jersey, p:518.
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. Gujarati, D., (2004), “**Basic Econometrics**”, Fourth Edition, The McGraw-Hill, p.817.
15. Gujarati, D., Porter, D., (2009), "BASIC ECONOMETRICS" 5th Ed, McGraw-Hill/Irwin, New York, and PP: 791–796.
16. 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.
17. Hyndman R., Athanasopoulos G., (2018), " Forecasting: Principles and Practice ", textbook, two ND Edition, Published by AMAZON, p: 15.

18. Khairalla, X. N. M., & AL-Jallad, N. T. (2017). Hybrid Forecasting Scheme for Financial Time-Series Data using Neural Network and Statistical Methods. *(IJACSA) International Journal of Advanced Computer Science and Applications*, 8.
19. 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.
20. 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.
21. Nashat T AL-Jallad, XU-Ning, Mergani Khairalla, (2017), "Hybrid Forecasting Scheme for Financial Time Series Data using Neural Network and Statistical Methods", *International Journal of Advanced Computer Science and Applications*, Vol. 8, No. 9, pp:319–327.
22. Neha, Y., Anupam, Y., Manoj, K., (2015), "**An Introduction to Neural Network Methods for Differential Equations**", Springer Dordrecht Heidelberg New York, p: 18–19.
23. Ng, G., (2003)," **Intelligent Systems –Fusion, Tracking and Control**", Research Studies Press LTD, Baldock, Hertfordshire, England, and pp: 41–42.
24. Schwarz, Gideon E. (1978), "Estimating the dimension of a model", *Annals of Statistics*, 6 (2): 461–464.
25. Shanmuganathan, S., Samarasinghe, S., (2016), "**Artificial Neural Network Modelling**", Springer International Publishing, Switzerland, P: 8.
26. Silva, I., Liboni, L., Spatti, N., Alves, S., Flauzino, R., (2017), "**Artificial Neural Networks A Practical Course** ", Springer International Publishing Switzerland, p: 5.
27. Slimane Sefiane, Mohamed Benbouziane; "Portfolio Selection Using Genetic Algorithm", *Journal of Applied Finance & Banking*, vol.2, no.4, 2012.
28. Timmermann, A. (2006). "Forecast combinations". Handbook of economic forecasting, 1, 135–196.
29. 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.
30. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
31. www.dse.sy

ثالثاً: المواقع الإلكترونية
سوق دمشق للأوراق المالية: •