



مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية

اسم المقال: فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية: مقارنة بنموذج الانحدار الذاتي

اسم الكاتب: د. مروان جمعة درويش

رابط ثابت: <https://political-encyclopedia.org/library/1718>

تاريخ الاسترداد: 2025/05/05 12:35 +03

الموسوعة السياسية هي مبادرة أكاديمية غير هادفة للربح، تساعد الباحثين والطلاب على الوصول واستخدام وبناء مجموعات أوسع من المحتوى العلمي العربي في مجال علم السياسة واستخدامها في الأرشيف الرقمي الموثوق به لإغناء المحتوى العربي على الإنترنت.

لمزيد من المعلومات حول الموسوعة السياسية – Encyclopedia Political، يرجى التواصل على info@political-encyclopedia.org

استخدامكم لأرشيف مكتبة الموسوعة السياسية – Encyclopedia Political يعني موافقتك على شروط وأحكام الاستخدام المنشورة على الموقع <https://political-encyclopedia.org/terms-of-use>

تم الحصول على هذا المقال من موقع مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية ورفده في مكتبة الموسوعة السياسية مستوفياً شروط حقوق الملكية الفكرية ومتطلبات رخصة المشاع الإبداعي التي ينضوي المقال تحتها.



فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية: مقارنة بنموذج الانحدار الذاتي*

د. مروان جمعة درويش*

DOI: <https://doi.org/10.5281/zenodo.2545384>

*تاریخ التسليم: 2018/7/11م، تاریخ القبول: 2018/8/11م.
**أستاذ مشارك/جامعة القدس المفتوحة/فلسطين.

طرق التنبؤ المستخدمة في خليل هذه البيانات قد لا تراعي هذه الجوانب ما قد ينعكس سلباً على دقة النتائج المتحصل عليها من هذه الطرق.

وهناك عدد من النماذج التي تستخدم في التنبؤ بمؤشرات أسواق المال ومستوياتها المستقبلية، من بين هذه النماذج نموذج الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN)، والتي تعد من الطرق المناسبة لتمثيل العلاقات بين المتغيرات بشكل مختلف عن الطرق التقليدية. فهي نظام حسابي مكون من عدد من الوحدات المترابطة مع بعضها. وتتصف بطبيعتها الديناميكية المعالجة والمتوازنة في معالجة البيانات الداخلة إليها. وسميت بالشبكات العصبية الاصطناعية لكونها بنيت حاكمة الشبكة العصبية في الكائنات الحية بقدر المعرفة المتوفرة عنها، ولها مسميات عده كالدماغ الالكتروني والحاஸوب الذكي (العيدي، 2000).

إن السلاسل المالية لها من خصوصيات خطية وغير خطية تجعل الطرق التقليدية في بعض الأحيان غير قادرة على التنبؤ الكافء. مما يجعل التفكير في طرق الذكاء الاصطناعي كتقنية الشبكات العصبية الاصطناعية قائماً بين المخللين. ذلك لأنها لا تتطلب فرضيات مرتبطة بالتوزيعات الاحتمالية للبيانات (العباسي، 2013).

وتقوم هذه الدراسة على المقارنة بين النماذج الحديثة والنماذج التقليدية في التنبؤ من خلال اختبار قدرة نموذج الشبكات العصبية الاصطناعية (ANN) في التنبؤ بمؤشر القدس بورصة فلسطين في مقابل نموذج الانحدار الذاتي، والمفاضلة بينهما في هذا المجال.

مشكلة الدراسة:

مع وجود طرق مختلفة للتنبؤ بمؤشرات الأسواق المالية اعتماداً على السلاسل الزمنية لتلك المؤشرات والتي تتمتع بخصوصيات خطية وغير خطية تجعل الطرق التقليدية، في بعض الأحيان، غير قادرة على التنبؤ الكافع. مما دفع عدد من الباحثين إلى التفكير في طرق حديثة أكثر تقدماً كتقنية الشبكات العصبية الاصطناعية التي أثبتت كفاءتها في مجال التنبؤ بالسلاسل الزمنية وخاصة بمؤشرات الأسواق المالية. ولا تتطلب هذه الطريقة فرضيات مرتبطة بالتوزيعات الاحتمالية للبيانات.

ولكي نحصل على نماذج تنبؤ لبيانات السلاسل الزمنية يكون لها المقدرة على تصوير الواقع. وبدقّة عالية في التنبؤات المستقبلية. يجب أن تأخذ هذه النماذج كل الاعتبارات المتعلقة بالبيانات من خطية وعدم خطية ونوعية البيانات. ومن هنا جاءت مشكلة هذه الدراسة لتمرّور حول الإجابة على السؤال الرئيس التالي:

ملخص:

هدفت هذه الدراسة إلى التنبؤ بمؤشر القدس لبورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية مقارنة بنموذج الانحدار الذاتي، وذلك بالاعتماد على قاعدة بيانات يومية للفترة 1/3/2010 إلى 28/2/2018.

وقد أظهرت النتائج أن الشبكة العصبية الاصطناعية المستخدمة قد نجحت في التنبؤ بقيمة مؤشر القدس لبورصة فلسطين بدرجة عالية من الدقة وبمعدل خطأ أقل من نموذج الانحدار الذاتي. وبالتالي فإن نموذج الشبكات العصبية الاصطناعية لديه قدرة أكبر على التنبؤ مقارنة بنموذج الانحدار الذاتي وأوصت الدراسة بالاعتماد عليه كأسلوب مناسب للتنبؤ المستقبلي بمؤشر القدس لبورصة فلسطين.

الكلمات المفتاحية: التنبؤ، نموذج الشبكات العصبية الاصطناعية، نموذج الانحدار الذاتي، مؤشر القدس، بورصة فلسطين.

The Effectiveness of Predicting the Palestine Exchange Index Using the Artificial Neural Networks Model In Comparison with Autoregressive Model

Abstract

This study aimed at predicting Al-Quds Index of Palestine Exchange (PEX) using Artificial Neural Network (ANN) in comparison with Autoregressive model (AR). To do so, daily data database is used covering the period from 3/1/2010 until 28/2/2018. The main finding of this study is that ANN model has better forecasting performance than AR model. Therefore, the study recommended using ANN to forecast Al-Quds Index of Palestine Stock Exchange.

Keywords: Forecasting, Artificial Neural Network Model, Autoregressive Model, Al-Quds Index, Palestine Exchange.

المقدمة:

بعد التنبؤ بأسعار مؤشرات الأسواق المالية من التقنيات المهمة في اتخاذ القرارات الاستثمارية : لأنّه يوفر الأدوات اللازمة لتحقيق الربح وتعظيمه . أو لتفادي الخسارة المتوقعة. وتأثير عملية التنبؤ في السلاسل الزمنية بشكل مباشر باختيار النموذج المناسب لبيانات السلسلة الزمنية إذ توفر هذه الخطوة تأثيراً مباشراً في دقة التنبؤات المتحصل عليها. وتعود بيانات السلاسل الزمنية لقطاعات مختلفة في معظمها بيانات غير خطية . وتعاني أحياناً من العشوائية والاضطرابات. إلا أنّ معظم

لهذه الدراسة أهمية جعلها مدخلاً للمزيد من الدراسات في هذا الإتجاه.

أهداف الدراسة:

- تهدف هذه الدراسة بشكل رئيس إلى دراسة فعالية التنبؤ بمؤشر القدس لبورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية بالمقارنة مع نموذج الانحدار الذاتي، وذلك من خلال الأهداف الفرعية التالية:
- دراسة سلوك مؤشر بورصة فلسطين خلال فترة الدراسة.
- صياغة الجوانب الفكرية للأساليب الحديثة والاستفادة منها في تطوير مفاهيم ومعايير التنبؤ بمؤشر بورصة فلسطين.
- التنبؤ بمؤشر القدس لبورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية ونموذج الانحدار الذاتي.
- المفاضلة بين نموذجي الشبكات العصبية الاصطناعية والانحدار الذاتي في التنبؤ بمؤشر القدس لبورصة فلسطين، وتحديد النموذج الأكثر خاعنة.

الإطار النظري:

6- نموذج الانحدار الذاتي للسلسل الزمنية Autoregressive Model

يتكون تحليل السلسلة الزمنية من مراحل تبدأ بمرحلة تشخيص النموذج، فتقدير معلماته، وفحص الملائمة للنموذج، ومن ثم استخدامه في التنبؤ، والهدف من هذا التحليل هو الوصول إلى النموذج الرياضي الذي يمثل البيانات حيث يعد نموذج الانحدار الذاتي Autoregressive Model (AR) أحد النماذج المهمة لتحقيق هذا الهدف، ومن العلماء الأوائل الذين قاموا بدراسة الانحدار الذاتي هو العالم *Yule* عام 1926، وأكمل طريقه إلى النموذج العام لنماذج الانحدار الذاتي العالم *Wieler* في عام 1931 (*Wei*, 1994).

ويستخدم نموذج الانحدار الذاتي في مختلف المجالات منها وصف ظاهرة معينة سواء تلك الظاهرة طبيعية أو اقتصادية، ويعبر عن علاقة المتغير التابع بالمتغيرات المستقلة المتمثلة في القيم الماضية لنفس المتغير التابع ولعدد محدد من فترات الإيطة بحيث يكون AR(p) انحداراً ذاتياً من الدرجة P، مع الأخذ بالاعتبار حد الخطأ العشوائي في الفترة الحالية، ويعبر عنه بالمعادلة التالية:

$$Y_t = \theta_1 Y_{(t-1)} + \theta_2 Y_{(t-2)} + \dots + \theta_p Y_{(t-p)} + u_t$$

ونلاحظ أن معادلة الانحدار الذاتي من الرتبة P هي معادلة انحدار متعدد ولكن تختلف عن معادلة الانحدار الاعتيادي في أن المتغيرات المفسرة (المستقلة) تمثل القيم

► ما مدى فعالية تطبيق نموذج الشبكات العصبية الاصطناعية للتنبؤ بمؤشر القدس لبورصة فلسطين في مقابل نموذج الانحدار الذاتي؟

ومن أجل الإحاطة بجواب هذه المشكلة تم صياغة مجموعة من الأسئلة الفرعية على النحو الآتي:

- هل يمكن الاعتماد على نموذج الشبكات العصبية الاصطناعية للتنبؤ بمؤشر القدس لبورصة فلسطين؟
- هل يتفوق نموذج الشبكات العصبية الاصطناعية على نموذج الانحدار الذاتي في التنبؤ بمؤشر القدس لبورصة فلسطين؟

فرضيات الدراسة:

للإجابة على الأسئلة الواردة في مشكلة الدراسة تم وضع الفرضيات التالية:

- الفرضية الأولى: عدم فعالية تطبيق نموذج الشبكات العصبية الاصطناعية في التنبؤ بمؤشر القدس لبورصة فلسطين .
- الفرضية الثانية: لا يتتفوق نموذج الشبكات العصبية الاصطناعية على نموذج الانحدار الذاتي في التنبؤ بمؤشر القدس لبورصة فلسطين .

أهمية الدراسة:

بعد التنبؤ بمؤشرات الأسواق المالية من التقنيات المهمة في اتخاذ القرارات الاستثمارية لأنها توفر الأدوات اللازمة لتحقيق الربح وتعظيمه أو لتفادي الخسارة المتوقعة، وقد تعددت الدراسات العملية للتنبؤ بمؤشرات الأسواق المالية المتطرفة باستخدام نموذج الشبكات العصبية الاصطناعية، بينما قلت الدراسات التي تناولت هذا الموضوع في الأسواق المالية العربية، ولذلك دعت تلك الدراسات ومنها دراسة (مرهنج، 2013) إلى تطبيق أسلوب الشبكات العصبية الاصطناعية في عملية التنبؤ في الأسواق المالية الناشئة، في حين ندرت مثل هذه الدراسات التي تناولت الموضوع في بورصة فلسطين، على حد علم الباحث.

من جهة أخرى تبع أهمية الدراسة في طريقة تناولها للموضوع من خلال المعالجات الكمية المقارنة بين أسلوبين مختلفين من أساليب التنبؤ لتحديد النموذج الأكثر دقة وفعالية، مما يوفر لتخديم القرار من المحللين والمستثمرين فرصة التعامل مع الأسلوب الأكثر كفاءة، وبالتالي اتخاذ القرار الاستثماري السليم والناجح المنفي على هذه التنبؤات.

لذا فإن قلة البحوث والدراسات التي عالجت الموضوع في الأسواق العربية عموماً وفي بورصة فلسطين خصوصاً، تعطي

- طريقة تحديد الأوزان وتعديلها أو ما يسمى بخوارزمية التعلم.

- دالة التنشيط التي هي في الغالب دالة لا خطية.

6-1 تعليم الشبكات العصبية الاصطناعية :

تتعلم الشبكة عن طريق إعطائها مجموعة من الأمثلة التي يجب أن تكون مختارة بعناية. لأن ذلك يسهم في سرعة تعلم الشبكة. ومجموعة الأمثلة هذه تسمى فئة التدريب.

Rao and (Rao, 1993) وتنقسم طرق تعليم الشبكة العصبية إلى :

أ. التعليم المراقب بواسطة معلم (Supervised learning):

تقوم كل طرق التعليم أو التدريب بواسطة معلم للشبكات العصبية الاصطناعية بفكرة عرض البيانات التدريبية أو الشبكة على هيئة زوج من الأشكال وهما شكل المدخل Input والشكل المستهدف Target. حيث أن التعليم بوجود معلم يمكن أن يتم إما بتصحيح الخطأ أو بالاعتماد على الذاكرة.

وقد يكون التعليم المراقب بواسطة معلم تعليماً بواسطة معلم على نمط تصحيح الخطأ الذي يستخدم لتعليم الشبكات الخطية ذات الطبقة الواحدة. أو تعليماً بواسطة معلم معتمد على الذاكرة والذي يتم فيه تخزين المعلومات المتوفرة عن البيئة في الشبكة العصبية (Rao and Rao, 1993).

ب. التعليم غير المراقب (بدون معلم) (Unsupervised learning):

في هذه الطريقة تكون فئة التدريب عبارة عن متوجه المدخلات فقط دون عرض الهدف على الشبكة وتسمى هذه بالتعليم الذاتي. حيث تبني الشبكات العصبية الاصطناعية أساليب التعليم على أساس قدرتها على اكتشاف الصفات المميزة لها لما يعرض عليها من أشكال. وقدرتها على تطوير تمثيل داخلي لهذه الأشكال. وذلك دون معرفة مسبقة و بدون عرض أمثلة لما يجب عليها أن تنتجه. على عكس المبدأ المتبعة في أسلوب التعليم بواسطة معلم. من أمثلة التعليم بدون معلم التعليم الهيباني Hebbian، والتعليم التنافسي Competitive (Lippmann, 1987)

ت. التعليم بإعادة التدريم:

تقوم عملية التدريم على أساس الخلط بين طريقة التعليم المراقب والتعليم غير المراقب. حيث لا يفصح للشبكة العصبية الاصطناعية عن القيم الحقيقة للمخرجات كما هي الحال في التعليم غير المراقب. ولكن يشار إلى الشبكة بصحبة نتائجها أو خطئها. كما في طريقة التعليم المراقب (العباسي 2013).

السابقة للمتغير. لذا تسمى هذه الصيغة بالانحدار الذاتي إذ يصف العلاقة بين المشاهدات السابقة والخالية للمتغير (Wei, 1994).

6-2 الشبكات العصبية الاصطناعية:

تعد الشبكات العصبية الاصطناعية إحدى التقنيات التي تساعده في إيجاد الحلول البديلة المناسبة والمثالية للمسائل المعقدة. من خلال قدرتها على معالجة البيانات دون الحاجة إلى صياغة مسبقة أو هيكلية معينة. ويرجع الفضل فيدخولها إلى دائرة الأعمال العالمية على يد كل من (Mc-Culch & Pitts, 1943) (دريل, 2014).

وتتألف الشبكات العصبية الاصطناعية من مجموعة من الخلايا الاصطناعية أو العقد (Nodes) التي تجمع بشكل مصفوفي ضمن طبقات (Layers) متصلة مع بعضها البعض. وأن كل اتصال بين هذه العقد يمتلك مجموعة من القيم تسمى الأوزان (Weights) تسهم في تحديد القيم الناتجة عن كل عنصر معالجة بناء على القيم الداخلة لهذا العنصر. فوحدات الإدخال تكون طبقة تسمى طبقة المدخلات ووحدات المعالجة تكون طبقة المعالجة وهي التي تخرج نحو الشبكة. وبين كل طبقة من هذه الطبقات هناك طبقات مخفية (Hidden Layers) تعمل علىربط كل طبقة بالطبقة التي تليها. وتحتوي الشبكة على طبقة واحدة فقط من وحدات الإدخال ولكنها قد تحتوي على أكثر من طبقة من طبقات المعالجة. وتعد مخرجات كل طبقة مدخلات للطبقة التي تليها عدا الطبقة الأولى التي تتلقى البيانات كمدخلات من الوسط الخارجي. (مرهج 2013 : العباسي 2013)

وتعزف الشبكات العصبية الاصطناعية بأنها شبكات ذات ترابط (تواصيل) كثيف فيما بينها. تضم عناصر بسيطة ومتوازية . وعادة ما تكون قابلة للتكييف وذات تنظيم هرمي. حيث تتفاعل مع كائنات العالم الحقيقي بالطريقة التي يتفاعل بها النظام العصبي الطبيعي (البيولوجي) مع العالم الحقيقي. فهي مثل نموذجاً يحاكي الشبكات العصبية الطبيعية (البيولوجية). حيث تكون من عناصر بسيطة ومتوازية التركيب. تسمى بالعصبنونات (Neurons) أو العقد (Nodes). ولديها المقدرة علىمحاكاة سلوك النظام العصبي الطبيعي مثل المقدرة على التعلم. الاستنتاج وحل المشاكل المعقدة. وكل أنماط السلوك الذكي الذي يتميز به الإنسان عن بقية الكائنات الحية الأخرى (دريل, 2014).

وتتصف الشبكة العصبية الاصطناعية بطبعتها الديناميكية والمتوازية في معالجة البيانات الداخلة إليها (Kumar, 2010). وتميز بثلاث ميزات يتم من خلالها وصف الشبكة العصبية وهي (عيسي, 2000):

- طريقة التوصيل (الترابط) بين العصبونات التي تقرر هيكل الشبكة (المعمارية).

حيث:

Xk : شعاع الأوزان والإثنيات الحالية

αk : معدل التعلم

gk : الميل الحالي

و هناك طريقتان لحساب الانحدار التدريجي: (دريل، 2014)

- النظام التزايدى: Incremental mode

يتم وفق هذه الطريقة حساب الميل ومن ثم تعدل الأوزان بعد كل مدخل يعطى للشبكة.

- نظام الدفعـة الواحدـة: Batch mode

و فـقـهـذاـنـمـطـتـزـودـالـشـبـكـةـبـكـلـأـشـعـةـالـمـدـخـلـقـبـلـالـقـيـامـبـعـمـلـيـةـخـدـيـثـالـأـوزـانـ.ـوـبـالـتـالـيـيـكـنـأـنـنـقـوـلـإـنـالـأـوزـانـوـالـإـثـنـيـاتـفـيـهـذـهـطـرـيـقـةـتـعـدـلـبـعـدـتـزوـيدـالـشـبـكـةـبـجـمـوـعـةـالـتـدـرـيـبـكـامـلـةـ،ـإـذـأـنـالـمـيـوـلـالـمـسـوـبـةـفـيـكـلـمـاـلـتـدـرـيـبـيـتـضـافـبـعـضـهـاـبـعـضـاـلـتـحـدـيـدـالـتـغـيـرـاتـفـيـالـأـوزـانـوـالـإـثـنـيـاتـ.

قاعدة دلتا العممة (العامة) للتعليم Generalised (learning delta rule)

و تعد قاعدة التعليم هذه معقدة بعض الشيء إذا ما قورنت بطريقة التعليم البسيطة للشبكة، حيث تعمل على تعليم وتدريب الشبكة الاصطناعية من خلال إجراء الحسابات اللازمة في دالة المدخلات للحصول على قيم المخرجات، ثم تُحسب الخطأ بين هذه المخرجات والمخرجات المعينة المطلوبة، ثم يتم العمل على تقليل قيم الخطأ من خلال نقله إلى طبقة المدخلات وتتعديل الأوزان عندها، وإعادة حساب قيم المخرجات مرة أخرى، ثم إعادة حساب الخطأ بين المخرجات الجديدة والمخرجات المطلوبة، وإعادة هذه العملية مرات عدّة إلى أن يتلاشى الخطأ وتصبح المخرجات المسوبية مكافئة للمخرجات المطلوبة، وبذلك تتعلم الشبكة، حيث يعد عدد مرات التكرار مقياساً للتعلم (دريل، 2014).

6-3 أنواع الشبكات العصبية الاصطناعية:

من المميزات التي تملّكها منهجية الشبكات العصبية الاصطناعية، مرونة طبقة تحديد ترابط الأوزان بين طبقة المدخلات وطبقة المخرجات فقد تكون شبكات ذات طبقة واحدة (Single Multilayer Networks) أو شبكات متعددة الطبقات (MLN Networks)، وتكون هذه الشبكات من ثلاثة طبقات، طبقة الإدخال، وطبقة الإخراج، ويتوسطهما الطبقات الخفية (طبقة واحدة أو أكثر)، وقدّد عدد المدخلات وعدد الخلايا (العقد) في الطبقة الخفية بحسب درجة تعقيد المسألة وحجم الإدخال، إلى أن نصل إلى النموذج الأمثل. (Heaton, 2011)

6-2-2 خوارزميات تعليم الشبكة العصبية الاصطناعية :

يجـرـيـتـعـلـمـالـشـبـكـةـالـعـصـبـيـةـبـوـاسـطـةـخـوـارـزـمـيـاتـLearning~Algorithmsـتـتـخـصـصـتـسـمـيـخـوـارـزـمـيـاتـالـتـعـلـمـتـتـولـىـتـعـدـيلـأـوزـانـالـشـبـكـةـلـتـحـسـينـأـدائـهـاـوـتـقـلـيلـالـخـطـأـفـيـهـاـاستـنـادـاـإـلـىـمـقـيـاسـمـعـلـومـلـلـوـصـولـإـلـىـالـنـتـيـجـةـالـمـطـلـوـبـةـ.ـحـيـثـيـجـرـيـتـعـدـيلـهـذـهـالـأـوزـانـجـزـئـاـفـيـكـلـدـوـرـةـ،ـوـتـؤـخـذـإـشـارـةـالـخـطـأـدـليـلـاـوـمـؤـشـرـاـعـلـىـمـدـىـالـقـرـبـأـوـالـبـعـدـعـنـالـقـيـمـالـصـحـيـحةـ(ـالـعـبـيـديـ2000ـ).

وـتـمـثـلـتـالـأـوزـانـالـمـلـوـعـاتـالـأـوـلـيـةـالـتـيـتـتـعـلـمـبـهـاـالـشـبـكـةـلـذـاـلـابـدـمـنـخـدـيـثـالـأـوزـانـالـتـيـتـسـتـخـدـمـفـيـتـدـرـيـبـالـشـبـكـاتـالـعـصـبـيـةـكـامـلـةـالـإـرـتـيـاطـوـذـاتـالـتـغـذـيـةـالـأـمـامـيـةـوـمـتـعـدـدـالـطـبـقـاتـوـغـيـرـالـخـطـيـةـ.ـوـتـعـتـبـرـهـذـهـخـوـارـزـمـيـةـتـعـمـيمـلـطـرـيـقـةـالـتـدـرـيـبـبـنـمـطـتـصـحـيـحـالـخـطـأـ.ـوـمـنـأـجـلـهـذـهـالـتـحـدـيـتـتـسـتـخـدـمـخـوـارـزـمـيـاتـمـخـلـفـةـحـسـبـنـوـعـالـشـبـكـةـ.ـوـمـنـأـهـمـهـذـهـالـخـوـارـزـمـيـاتـ(ـSterniou~&~Siganos~1996ـ):ـ

خوارزمية الانتشار العكسي (الخلفي) Back Propagation Algorithm

تـتـضـمـنـعـلـيـةـتـدـرـيـبـالـشـبـكـةـالـعـصـبـيـةـالـاـصـطـنـاعـيـةـبـاـسـتـخـدـمـالـاـنـتـشـارـالـعـكـسـيـعـلـىـثـلـاثـمـراـحـلـهـيـ:

(العيدي، 2000؛ عيسى 2000)

أ. مرحلة الانتشار الأمامي:

لا يحصل فيها أي تتعديل للأوزان المشبكية وتبداً هذه المرحلة بعرض الشكل المدخل للشبكة، حيث تخصص كل عنصر معالجة من طبقة عناصر الإدخال لأحد مكونات الشعاع الذي يمثل الدخل وتسبب قيم مكونات متوجهة الدخل استثناء لوحدات طبقة الإدخال ويعقب ذلك انتشار أمامي لتلك الاستثناء عبر بقية طبقات الشبكة.

ب. مرحلة الانتشار العكسي (الخلفي):

وهي مرحلة ضبط أوزان الشبكة، حيث تعتبر خوارزمية الانتشار العكسي القياسي بمثابة خوارزمية الانتشار التدريجي التي تسمح لأوزان الشبكة أن تتحرك على الجانب السلبي من تابع الأداء.

ت. مرحلة توليف أوزان الشبكة:

إن دور الانتشار العكسي يعود إلى الطريقة التي يتم بها حساب الميل لطبقات الشبكة المتعددة واللخطية، حيث يتم في أحد مراحل التعليم إعادة انتشار الإشارة من المخرج إلى المدخل بشكل عكسي، ويتم خلالها ضبط أوزان الشبكة، ويمكن تمثيل الخوارزمية للتكرار واحد كما يلي:

$$Xk + 1 = Xk - \alpha k * gk$$

ت. شبكة المان Elman

تعد شبكة المان Elman من ضمن نماذج الشبكات المتكررة المستخدمة في التنبؤ، إذ إن المخرجات في الطبقة الخفية تغذي نفسها حيث أن المخرجات في الطبقة الخفية عند الزمن t تخزن في متوجه الذي يدعى إدخالاً للشبكة عند الزمن $t+1$. بعبارة أخرى فإن الطبقة الخفية مرتبطة ارتباطاً متكرراً متكاماً، والمتجه يعاد خطوة واحدة خلال الشبكة. لذا فإن الإدخال للشبكة هو عبارة عن دالة لكل من المدخلات الجديدة والمتجه للخزن سابقاً والذي يمثل الإدخال في زمن معين وبعد إدخال للزمن السابق (Giles, 2001)

6-2-5 النموذج الرياضي خلية عصبية :

يتكون النموذج الرياضي خلية عصبية من: (دریال، 2014) المدخل: (Input) نفرض أن قيم مخارج العصبونات السابقة للعصبون (الخلية العصبية) الحالية هي القيم (x_1, x_2, \dots, x_n) حيث تقوم الشابك بنقل نسبة من هذه القيم إلى الليف العصبي للمدخل من خلال فجوات بحيث تختلف هذه النسب من فجوة إلى أخرى اعتماداً على طبيعة كل فجوة، و يتمثل ذلك رياضياً بفرض أنها أوزان (Weights) التي تأخذ الشكل (w_1, \dots, w_n) وبذلك يكون الجزء المنقول إلى المدخل في كل فرع هو (WX)

جسم الخلية (عنصر المعالجة) (Processing Element) يقوم جسم الخلية بعمل الآتي:

عملية جمع المدخل الموزونة (weighted sum) لتأخذ الشكل:

$$\begin{aligned} \text{Total input} &= w_1x_1 + w_2x_2 + w_3x_3 \\ &\quad + \dots = \sum_{i=1}^n w_i x_i \end{aligned}$$

مقارنة هذا الجموع بقيمة حدبة دالة في شكل عتبة المعروفة بدالة (Step function). فإذا كان مجموع المدخل الموزونة أكبر من أو تساوي الدالة العتبية فإن المخرج سوف يكون متساوياً لواحد صحيح، وإذا كان الجموع أقل من قيمة الدالة العتبية فإن ناتج المخرج يصبح متساوياً لصفر.

المخرج (Output): يكون المخرج للنموذج الرياضي إما الواحد أو الصفر ويمكن أن يستخدم كأحد فروع الإدخال للشبكة أخرى، ويمكن كتابة قيمة المخرج (y) في الشكل الآتي:

$$y = F\left(\sum_{i=1}^n w_i x_i\right)$$

الشبكات وحيدة الطبقة:

تكون هذه الشبكات من طبقتين فقط، هما طبقة المدخلات وطبقة المخرجات، وتكون انسيابية الإشارات الداخلة من طبقة المدخلات إلى طبقة المخرجات بالجاه أمامي.

الشبكات العصبية المتعددة الطبقات :

neural networks

يتكون النموذج العام للشبكات العصبية المتعددة الطبقات من ثلاثة طبقات هي: طبقة المدخل، والطبقة الخفية، وطبقة المخرج، وتم التعديل بالإضافة طبقة مخفية بين طبقتي المدخل والمخرج واستخدام دالة سigmoid (Sigmoid function) التي تحمل الخواص اللاخطية، ولذلك يلزم استخدام طريقة أخرى للتعليم تكون قادرة على التفاعل بين الطبقات الثلاث مثل: قاعدة دلتا العممة (العمامة)، أو قاعدة الانتشار الخلطي.

وتتميز هذه الشبكات بقدرتها على حل مسائل أكثر تعقيداً من المسائل التي يمكن حلها في الشبكات وحيدة الطبقة، بسبب وجود الطبقات الوسطية التي تعطي مرونة أكبر في بناء الدوال التاقلة بين المدخلات والمخرجات. (الشرقاوي، 1996)

6-2-4 نماذج الشبكات العصبية المستخدمة في التنبؤ:

هناك مجموعة من النماذج المستخدمة في الشبكات العصبية الاصطناعية منها: (دریال، 2014)

أ. شبكة دالة القاعدة الشعاعية (RBF) :

تعد من شبكات التغذية الأمامية وتحتوي على طبقة مخفية واحدة ودالة التنشيط لهذه الطبقة تدعى Basis Function. تقوم هذه الشبكة بتحويل المدخلات بطريقة غير خطية ثم بإيجاد المحنن المناسب لإعطاء النتائج الصحيحة، وتمرز هذه الشبكة نوعين من طرق تعليم الشبكات العصبية بحيث يكون التعليم بين طبقة الإدخال والطبقة الخفية تعليم بدون معلم، بينما يكون التعليم بين طبقة الخفية وطبقة المخرجات تعليماً بعلم، ويعتمد على نسبة الخطأ بالأعتماد على المخرجات (دریال، 2014).

ب. شبكة بيرسبرتون متعدد الطبقات (MLP) :

تعد من أكثر الشبكات استخداماً في التنبؤ بالسلسلة الزمنية، حيث تقوم فكرة هذه الشبكة على استخدام القيم السابقة للسلسلة الزمنية كمدخلات الشبكة، ويتم جمع الأوزان في الطبقة الخفية بالنسبة للمدخلات ويتم استخدام التحويلة غير الخطية (السيغمويد).

وفي هذا النوع تستقبل طبقة المخرجات للشبكة مخرجات الطبقة الخفية وتطبق عليها التحويلة الخطية، حيث يتم إنتاج القيم المتنبأ بها للسلسلة الزمنية (دریال، 2014).

5. وحدات المعالجة (العصبونات):

وحدات المعالجة أو العصبونات هي الوحدات التي تقوم بعملية معالجة المعلومات في الشبكة العصبية، وتتصل هذه الوحدات بطرق مختلفة بواسطة الوصلات البينية.

وتتألف وحدة المعالجة أو العصبون من المكونات الأساسية التالية: (دربال، 2014)

معاملات الأوزان:

بعد الوزن العنصر الرئيس في الشبكات العصبية الاصطناعية، فهي مثل الروابط المختلفة التي يتم عبرها نقل البيانات من طبقة إلى أخرى. ويعبر الوزن عن القوة النسبية أو الأهمية النسبية لكل مدخل إلى عنصر المعالجة وتتمثل الأوزان الوسيطة الأساسية لذاكرة الشبكة العصبية من خلال ضبط الأوزان ويرمز للوزن بين عنصري معالجة (i) و (j) بالرمز (w_{ij}) .

دالة الجمع:

إن أول معالجة تقوم بها وحدة المعالجة هي حساب مجموع المدخلات الموزونة القادمة إلى الوحدة باستخدام دالة الجمع. حيث تقوم هذه الدالة بحساب متوسط الأوزان لكل مدخلات وحدة المعالجة. ويتم ذلك بضرب كل قيمة مدخل في وزنها الصاحب. ومن ثم إيجاد الجموع لكل حواصل الضرب.

ويمكن تمثيل ذلك رياضياً كما يلي :

$$S_j = \sum_{i=1}^n x_i w_{ij}$$

S_j : ناتج عملية الجمع لكل وحدة معالجة j

x_i : القيمة المدخلة القادمة من الوحدة (i) والداخلة إلى الوحدة (j)

w_{ij} : الوزن الذي يربط وحدة المعالجة (j) بوحدة (i) الموجودة في الطبقة السابقة.

دالة التحويل:

تم هذه الخطوة باستخدام دالة التحويل حيث تقوم الدالة بتحويل ناتج عملية الجمع الموزون في الخطوة الأولى إلى قيمة محصورة بين مديين. ويتم ذلك بمقارنة نتيجة الجمع مع قيمة العتبة. ويرمز لها بالرمز (σ).

ليتحدد الناتج ويطبق على المجموع عادة المقارنة مع تابع تنشيط معين. وتتوقف مخرجات الشبكة بصورة أساسية على هذا التوزيع. وبناء على هذه التوابع أو الدوال تعطي الشبكة مخرجات محصورة ضمن المجال (0, 1) أو المجال (-1, 1) ومن أهم توابع التحويل أو توابع التنشيط:

6-2-6 معمارية (هيكلية) الشبكة العصبية الاصطناعية:

تتألف البنية العامة للشبكات العصبية الاصطناعية من المكونات الأساسية التالية أو البعض منها على الأقل حيث توجد بعض الشبكات لا تحتوي على كل هذه العناصر: (العباسي، 2013)

1. طبقة المدخلات :

الطبقة التي يتم عبرها تغذية الشبكة العصبية بالبيانات من الخارج وتستقبل البيانات بواسطة وحدات المعالجة (العصبونات). وقد تتألف هذه الشبكة من وحدة معالجة واحدة أو أكثر حسب تركيبة الشبكة.

ووحدات المعالجة في طبقة المدخلات لا يتم فيها أي معالجات حسابية. بل تقوم بنقل البيانات المدخلة من هذه الطبقة عبر الوصلات البينية (الأوزان) إلى وحدات المعالجة في الطبقة الخفية. وأي شبكة عصبية تحتوي على طبقة واحدة فقط من وحدات الإدخال (العباسي، 2013).

2. طبقة المخرجات :

تكون هذه الطبقة من وحدات المعالجة التي عبرها يتم إخراج الناتج النهائي للشبكة. وقد تحتوي هذه الطبقة على وحدة معالجة واحدة أو أكثر من وحدة وفقاً لبنيّة العمارة للشبكة. وتستقبل وحدات المعالجة في طبقة المخرجات الإشارات القادمة إليها من طبقة المدخلات مباشرةً أو من الطبقة الخفية. وبعد إجراء المعالجات اللازمة، قد ترسل إشارة بالخرجات النهائية. وقد تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة. وذلك عندما لا تتماثل المعالجة المطلوبة للبيانات. وتحتوي الشبكة عادة على طبقة مخرجات واحدة.

3. الطبقة الخفية:

قد تحتوي تراكيب بعض الشبكات على طبقة مخفية تقع بين طبقة المدخلات وطبقة المخرجات. حيث تستقبل الطبقة الخفية الإشارات القادمة إليها من طبقة المدخلات عبر الوصلات البينية فتقوم بمعالجتها ومن ثم إرسالها عبر الوصلات إلى طبقة المخرجات (العباسي، 2013).

4. الوصلات البينية (الأوزان) :

هي عبارة عن وصلات اتصال بين الطبقات المختلفة تقوم بربط الطبقات مع بعضها البعض. أو الوحدات داخل كل طبقة عبر الأوزان التي تكون مصاحبة أو مرفقة مع كل وصلة بينية. ومهماً هذه الوصلات نقل الإشارات الموزونة بين وحدات المعالجة أو الطبقات.

الخطوة الرابعة : تحديد نموذج الشبكة العصبية Neural Network Paradigms

وذلك من خلال اختيار ما يلي :

- عدد العصبونات للإدخال الذي يساوي عدد المتغيرات المستقلة.
 - عدد الطبقات الخفية الذي يعتمد على قيمة الخطأ المستخدم في الشبكة.
 - عدد العصبونات الخفية الذي يحدد عن طريق التجربة.
 - عصبون الإخراج الذي عادة يساوي الواحد.
- الخطوة الخامسة: معيار التقييم Evaluation Criteria**

إن المعيار المستخدم في الشبكة العصبية الاصطناعية لتقدير الخطأ عادة هو مجموع مربعات الأخطاء . MSE

الخطوة السادسة: تدريب الشبكة العصبية Neural Network Training

وتضم هذه الخطوة :

- تعليم الشبكة: من خلال إيجاد مجموعة الأوزان بين العصبونات والتي تحدد أقل قيمة لمربع الخطأ.
 - خوارزمية شبكة الانتشار الخلفي للخطأ: وستستخدم خوارزمية التدريب لتقليل الميل.
- الخطوة السابعة: التنفيذ Implementation**

وهي من أهم الخطوات حيث تختبر الشبكة من حيث قدرة التكيف وامكانية إعادة التدريب والوصول إلى أقل مربع خطأ عند تغيير البيانات. (أمين بك. 2005)

3- التنبؤ باستخدام نموذج الانحدار الذاتي في مقابل نموذج الشبكات العصبية الاصطناعية:

لقد أثبتت الدراسات انه بالإمكان استخدام كل من نموذج الانحدار الذاتي ونموذج الشبكات العصبية الاصطناعية للتنبؤ بأي علاقة مالية ما بين مجاميع المدخلات والخرجات وبضمنها السلسلة الزمنية للمتغيرات المالية، والتي تكون من عدد من المشاهدات Y_1, Y_2, \dots, Y_T حيث T تشير إلى الزمن. بحيث يتم عملية التنبؤ في كل النماذج باستخدام فترات التباطؤ (القيم السابقة) كمدخلات، للوصول إلى الخرجات التي تمثل القيم المستقبلية المتنبأ بها.

ويمكن تمثيل العلاقة بين المدخلات والخرجات في كل النماذج كما يلي:(الجراج. 2011)

$$Y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-m})$$

دالة الخطوة: وهي الدالة التي تقع القيمة المخرجة فيها من وحدة المعالجة من (1.0)

دالة الإشارة: وهي الدالة التي تقع القيمة المخرجة فيها من وحدة المعالجة من (-1+)

الدالة الخططية: وهي الدالة التي تكون فيها المخرجات تساوي المدخلات وتعطي تصنيفات متعددة وغير محدودة .

دالة السيغمويد Sigmoid Function: هذه الدالة تجعل المخرجات أو تحولها إلى قيمة محصورة بين (0 . 1) وتسمى في هذه الحالة بـ دالة تنشيط سigmoid. أو تحويل المخرجات إلى قيم بين (-1+ . 1) وتسمى بـ دالة تنشيط سigmoid ثانوي القطبية.

دالة المخرجات:

فقد تكون المخرجات في أغلب الأحيان متساوية لنتائج دالة التحويل. ولكن هناك بعض الشبكات تقوم بـ وحدة المعالجة فيها بتعديل نتيجة دالة التحويل ويتم ذلك خلال تنافس وحدات المعالجة المجاورة مع بعضها البعض. ويتم التنافس عادة في وحدات المعالجة التي يكون لها تنشيط أكبر. هذه المنافسة تحدد وحدة المعالجة التي ستكون نشطة أو التي ستقوم بالإخراج.

6-2-7- الشبكات العصبية الاصطناعية و التنبؤ:
يمكن تلخيص عمل الشبكة العصبية الاصطناعية في التنبؤ بالخطوات التالية : (Sinha, 2005)

• الخطوة الأولى: اختيار المتغيرات Variable Selection

يتم اختيار المشاهدات للمتغيرات التي تمثل المشكلة جيدا.

• الخطوة الثانية: معالجة البيانات Data Processing

إجراء بعض العمليات على البيانات المستخدمة مثل: تحديد الاتجاه العام، إيجاد توزيع البيانات.

• الخطوة الثالثة: تقسيم البيانات إلى مجاميع Divide Data Into Sets

تقسيم البيانات المتوفرة إلى المجاميع التالية :

- مجموعة التدريب Training Set: مجموعة تعليم وتحديد نموذج البيانات .

- مجموعة الاختبار Testing Set والتي يمكن عن طريقها تقييم مهارة الشبكة الافتراضية وامكانية استخدامها بصورة عامة.

- مجموعة الشرعية Validation Set: وهي مجموعة لإجراء اختبار نهائي لأداء الشبكة.

عينة الدراسة وتفوقه على باقي النماذج الإحصائية الخطية المستخدمة الأخرى.

وتناولت دراسة Qwaider (2012) استخدام الشبكات العصبية الاصطناعية متعددة الطبقات (بيرسبيرون) في التنبؤ بأسعار الأسهم في سوق الأوراق المالية الأردني خلال الفترة 2002/2 إلى 1/2004 حيث تم اختيار سبع شركات أردنية من قطاع الخدمات والصناعات التحويلية، وتوصلت الدراسة إلى أن نموذج الشبكات العصبية الاصطناعية يعطي أفضل نتائج تنبؤ بالمقارنة مع النماذج العلمية كنماذج الانحدار وغيرها من الأساليب التقليدية.

وهدفت دراسة مرهج (2013) إلى بناء شبكة عصبية اصطناعية ذات مواصفات مناسبة اعتماداً على قاعدة التجربة والخطأ، وذلك للتنبؤ بقيم مؤشر سوق دمشق للأوراق المالية وأجهزتها ليوم التداول التالي، باستخدام سلسلة بيانات يومية خلال الفترة الواقعة بين 1/4/2010 و 7/3/2013، وقد أظهرت النتائج بأن الشبكة العصبية المستخدمة قد نجحت في التنبؤ بقيمة مؤشر سوق دمشق للأوراق المالية ليوم التداول التالي بدرجة عالية من الدقة ودرجة خطأ أقل من واحد بالمائة.

وجاءت دراسة دريال (2014) محاولة للتنبؤ بعوائد مؤشر سوق دبي المالي بالاعتماد على نموذج الشبكات العصبية الاصطناعية بالمقارنة مع مجموعة من النماذج القياسية، باستخدام قاعدة بيانات يومية للفترة المتداة من 22/2/2006 إلى 30/1/2014، ودللت النتائج على أن نموذج الشبكات العصبية الاصطناعية أعطى أقل قيمة لمعايير قياس الخطأ، مما يترجم مدى قوته التنبؤية بعوائد مؤشر سوق دبي المالي.

كما هدفت دراسة عايد وعيسياني (2016) إلى التعرف على أسلوب الشبكات العصبية الاصطناعية ومدى قدرتها على نجد عوائد مؤشرات الأسواق المالية للتنبؤ بمستوياتها المستقبلية، حيث قاما بتدريب الشبكة العصبية الاصطناعية بالاعتماد على بيانات السلسلة اليومية لعوائد مؤشر سوق دبي المالي للفترة 12/4/2006 إلى 1/4/2015، وإجراء عملية التنبؤ للفترة 1/5/2015 إلى 2/3/2015، وجاءت نتائج التنبؤ موافقة للقيم الفعلية إلى حد كبير وهو ما يؤكد كفاءة نموذج الشبكات العصبية الاصطناعية على التنبؤ.

2- الدراسات الأجنبية:

هدفت دراسة Tabrizi & Panahiam (2000) إلى التنبؤ بمؤشر سوق طهران للأوراق المالية بالاعتماد على الشبكات العصبية الاصطناعية، وقد تم استخدام قيم إبطاء عدة لمؤشر سوق طهران للأوراق المالية TEPIX خلال الفترة (1995-1999) إلى جانب بعض مؤشرات التحليل الفني وعناصر التحليل الأساسي للأوراق المالية، وقد بينت نتائج الدراسة قدرة الشبكة العصبية الاصطناعية على التنبؤ والمساهمة في تحقيق عوائد سنوية أكبر

حيث تمثل y_t المشاهدة في الزمن t ، وتمثل m عدد المشاهدات السابقة المستخدمة للتنبؤ بالقيم المستقبلية للسلسلة الزمنية Y التي لها T من الشاهدات.

ومن هنا فان المبدأ المستخدم في نماذج الانحدار الذاتي والشبكات العصبية الاصطناعية متشابه إلى حد ما، إلا أن نموذج الشبكات العصبية الاصطناعية لا يحتاج لافتراضات متعلقة بالتوزيعات الاحتمالية والحالات الخطية للبيانات كما في نموذج الانحدار الذاتي، حيث يصلح استخدامه أيضاً في الحالات غير الخطية، من خلال إجراء تدريب للشبكة للوصول إلى القيم المتباينة بها، وإيجاد الأوزان التي تعمل على تخفيض مجموع مربعات الخطأ ما بين المخرجات المقدرة والحقيقة إلى أقل حد ممكن (الجراج، 2011).

الدراسات السابقة:

تناولت العديد من الدراسات موضوع التنبؤ باستخدام الشبكات العصبية الاصطناعية في الأسواق المالية أو في غيرها من التطبيقات المالية وغير المالية، فعلى سبيل المثال استخدم غولي والمحمداني (2010) الشبكات العصبية الاصطناعية للتنبؤ بسعر الفائدة الشهرية لسندات الغلة (CBY) للفترة من 1987/1 إلى 1993/9، واستخدمها ارسانيوس (2012) للتنبؤ بحالات الغش في التقارير المالية المنورة للشركات المساهمة المدرجة في سوق الأوراق المالية المصري، وتم استخدامها من قبل اللبناني وسالم (2013) للتنبؤ ب معدلات الجريمة في قطاع غزة خلال الفترة 2008-2012، كما أن سايد و McKidish (2014) استخدما الشبكات العصبية للتنبؤ بأسعار البترول اليومية في الجزائر خلال الفترة المتداة من 1/1/2010 إلى 31/12/2011، فيما استخدمتها أبو عايدة (2015) للتنبؤ بأسعار الذهب العالمية للفترة 1985/1 إلى 12/2014، حيث أظهرت الشبكة العصبية الاصطناعية قوتها في التنبؤ في جميع تلك الدراسات.

أما في الأسواق المالية فقد تعددت الدراسات التي استخدمت نموذج الشبكات العصبية الاصطناعية، وفيما يلي عرض لأهم وأحدث تلك الدراسات مرتبة حسب تسلسلها التاريخي.

1-7 الدراسات العربية:

اعتمدت دراسة السراج والجميل (2008) على استخدام الشبكات العصبية الاصطناعية إلى جانب بعض النماذج الإحصائية الخطية للتنبؤ بأسعار إغلاق المؤشرات الرئيسية لعينة من أسواق الأوراق المالية العربية اعتماداً على السلسلة اليومية لتلك المؤشرات للفترة ما بين 1/1/2004 ولغاية 16/10/2004، وقد دلت النتائج على مدى القدرة الكبيرة لنموذج الشبكات العصبية ذات الانتشار العكسي للخطأ في التنبؤ المستقبلي بقيم جميع المؤشرات الرئيسية لمجموعة أسواق الدول

124 يوم تداول خلال الفترة من 2004/7/2 ولغاية 2004/12/30 . قسمت إلى 53 يوماً لتدريب الشبكة و 71 يوم لاختبارها . وقد بينت نتائج الدراسة تمكّن الشبكة المستخدمة من التنبؤ باتجاه المؤشر بنجاح بلغت نسبة الخطأ فيه أقل من 2%

وهدفت دراسة Vahedi (2012) إلى التنبؤ بأسعار الأسهم ببورصة طهران عن طريق أسلوب الشبكات العصبية الاصطناعية، وذلك بالاعتماد على بيانات سنوية للفترة 2000 إلى 2008 ، بالإضافة إلى بعض التغيرات المستقلة كمدخلات، وبعد التقدير والتنبؤ تبين أن أسلوب الشبكات العصبية الاصطناعية أعطى نتائج مناسبة وتنبؤات قوية.

كما هدفت دراسة Desai & Joshi (2015) إلى التنبؤ باتجاه وقيمة إغفال مؤشر سوق الأسهم الهندي Nifty ليوم التداول التالي، وقد اعتمدت هذه الدراسة على استخدام شبكة عصبية اصطناعية جرى تدريبها واختبارها على بيانات أيام تداول السوق خلال الفترة (2013/9/11 - 2015/4/30) حيث تم مقارنة أداء الشبكة العصبية الاصطناعية مقابل عوائد المؤشر الناجحة عن إستراتيجية الشراء والبيع . وقد أظهرت الدراسة إمكانية التنبؤ بقيمة المؤشر لليوم التالي بدرجة دقة بلغت 71% للشبكة العصبية الاصطناعية، مقابل 47% لـ إستراتيجية الشراء والبيع.

واختبرت دراسة Moghaddam et. al. (2016) قابلية الشبكات العصبية الاصطناعية للتنبؤ بعوائد أسهم NASDAP اليومية، حيث تم تطبيق شبكة الانتشار العكسي باستخدام سلسلة بيانات يومية للفترة 2015/1/28 وحتى 2015/6/18 (مع الأخذ بالحسبان عطلة نهاية الأسبوع). واستخدمت مدة 23 يوماً الأخيرة لاختبار قابلية النموذج للتنبؤ، حيث أظهرت النتائج عن قابلية عالية للنموذج في التنبؤ سواء استخدمت أربعة أيام سابقة أو تسعة أيام سابقة كمدخلات للنموذج.

واستخدمت دراسة Telli & Coskun (2016) خوارزمية الانتشار العكسي للتنبؤ بمؤشر BIST 100 من خلال تطبيق طريقة التجربة والخطأ في اختيار عدد العقد والطبقات للوصول إلى هيكلية الشبكة العصبية الاصطناعية المثلث، حيث استخدم الباحثان بيانات يومية خلال الفترة 2015/7/29 إلى 2015/11/15 لمؤشر 100 BIST مع إدخال بعض الأحداث الاقتصادية ومؤشر أسعار العملات كمتغيرات، وتوصلت الدراسة إلى أن شبكة MLP ذات الهيكلية 18-20-1 هي الأفضل في التنبؤ تليها شبكة MLP ذات الهيكلية 18-16-1، وإن التنبؤ باستخدام أسعار الافتتاح أفضل من التنبؤ باستخدام أسعار إغلاق المؤشر.

وطبقت دراسة Tyagi et. al. (2016) تقنية الشبكات العصبية الاصطناعية للتنبؤ بأسعار إغلاق مؤشر Nafty 50 يومياً خلال الفترة 2006/1/1 إلى 2016/3/31، حيث أظهرت النتائج أن الشبكة العصبية الاصطناعية كانت

ما هو مع النماذج الأخرى كالانحدار والأساليب الإحصائية التقليدية.

وهدفت دراسة Panda & Narasimhan (2006) إلى استخدام أسلوب الشبكات العصبية الاصطناعية للتنبؤ بقيمة مؤشر سوق بومباي للأوراق المالية BSE وعوائد مؤشر Sensitive Index إلى جانب أسلوبين آخرين (نموذج السلوك العشوائي، نموذج الانحدار الذاتي) ومن ثم مقارنة أداء النماذج المستخدمة اعتماداً على استخدام ستة مقاييس للأداء، وقد أظهرت النتائج تفوق أداء أسلوب الشبكات العصبية الاصطناعية على الأسلوبين الآخرين للتنبؤ بعوائد مؤشر Sensitive Index.

كما هدفت دراسة Senol (2008) إلى اختبار مدى قدرة الشبكة العصبية الاصطناعية في التفوق على الأساليب الأخرى كنماذج الانحدار للتنبؤ بالتغييرات اليومية لاتجاهات أسعار الأسهم، وقد تم الاعتماد على بيانات الأسهم الخاصة وأسعار الإغفال اليومية لمؤشر سوق سلطنة بوللأسهم خلال الفترة 1998/1/5 - 2007/8/31 والتي جرى تقسيمها إلى مجموعتين : إحداهما خصصت لتدريب الشبكة العصبية المستخدمة (2005/12/29 - 1998/1/5)، والأخرى لاختبار الشبكة (2006/1/6 - 2007/8/31)، وقد أظهرت النتائج تفوق الشبكة المستخدمة على نموذج الانحدار والنماذج التقليدية الأخرى المستخدمة.

وحاول Kumar (2010) توقع العوائد المستقبلية لمؤشر Hang Seng (HIS) وStandard & poor's 500 (S & P500) باستخدام نموذج الشبكات العصبية الاصطناعية، حيث استعمل العوائد السابقة كمدخلات بالمقارنة مع نموذج ARIMA لمدة 80 و 35 سنة لكل من مؤشر (S & P500) و (HSI) على التوالي، وقد تم اختبار صحة النموذجين من خلال 36 فترة اختبار، وبعد مقارنة صحة النموذجين من خلال معاير مختلفة، خلصت الدراسة إلى أن نموذج الشبكات العصبية الاصطناعية أعطى نتائج أفضل وتنبؤات أدق بكثير من نموذج ARIMA . ما يدعم فكرة استخدام الشبكات العصبية الاصطناعية في التنبؤ بعوائد مؤشرات الأسواق المالية.

وهدفت دراسة Aamodt (2010) إلى تقصي إمكانية تطبيق أسلوب الشبكات العصبية الاصطناعية للتنبؤ بالسلسلة الزمنية لأسعار الأسهم، وذلك باستخدام بيانات عشرة أسهم مسجلة في سوق أوسلو للأسهم خلال الفترة المتداة من كانون الثاني 1999 حتى بداية العام 2009 . وتوصلت الدراسة إلى أن الشبكات المستخدمة لها قدرة كبيرة على التدريب والتنبؤ بتقلبات أسعار الأسهم.

وهدفت دراسة Sutheebanjard & Premchaiswadi (2010) إلى التنبؤ بحركة مؤشر سوق تايلاند للأوراق المالية SET . وسوق الاستثمار البديلة MAI وذلك باستخدام شبكة عصبية اصطناعية ذات انتشار ارتدادي، وقد تم استخدام بيانات

الجانب التطبيقي:

اعتمد الباحث في تغطية الجانب التطبيقي للدراسة على تقارير بورصة فلسطين المنشورة على الموقع الإلكتروني للبورصة (www.pex.ps).

وتحليل ومناقشة بيانات الدراسة تم استخدام البرنامج الإحصائي Eviews 9.5 وهو برنامج متقدم في التحليل القياسي وبناء وتقدير النماذج الاقتصادية. والبرنامج التطبيقي الذكي Alyuda NeuroIntelligence وهو من البرامج المعاصرة سريعة الذكاء وسهلة الاستعمال وله عدة اختصارات في حل العديد من المسائل المعقدة ومنها الشبكات العصبية الاصطناعية Excell و SPSS.

مجتمع الدراسة:

يتمثل مجتمع الدراسة المراد التنبؤ بهؤشره في بورصة فلسطين. وفيما يلي تقديم لحة موجزة عنها:

في مطلع عام 1995 أدرك عدد من رواد القطاع الخاص الفلسطيني أهمية إنشاء سوق حديثة متطورة ومنظمة جيداً لتسهيل التعامل بالأوراق المالية في فلسطين. وكان الهدف هو استقطاب وحشد رأس المال المحلي والأجنبي لقطاع الأعمال من خلال التمويل طويلاً الأجل للمشاريع الإنثاجية ومشاريع البنية التحتية.

ومع توقيع اتفاقية تشغيل سوق الأوراق المالية، كشركة مساهمة خاصة، مع السلطة الوطنية الفلسطينية في أواخر عام 1996، خفقت الفكرة وبدأ التداول الفعلي في السوق بتاريخ 18/2/1997 باستخدام التقنية الالكترونية والآلية للتداول بالأوراق المالية.

اعتمدت السوق في تموز 1997. رقماً لقياس مستويات أسعار الأسهم، وتحديد الإيقاع العام لها. عرف باسم (مؤشر القدس)، تم فيها اختيار عينة من عشر شركات مدرجة ونشطة موزعة على جميع القطاعات الاقتصادية المعروفة في السوق. حيث تم ترجيح المؤشر بالقيمة السوقية للشركات الداخلة في احتسابه. وتم اعتماد أسعار إغلاق جلسة تداول 1997/7/7 كنقطة أساس بحيث حدّدت قيمة الرقم الأساس 100 نقطة.

وفي مطلع شباط من العام 2010 كان التطور المهم في مسيرة السوق وتحولها إلى شركة مساهمة عامة تأوباً مع قواعد الحكومة الرشيدة والشفافية. وفي أيلول 2010 أطلقت السوق عن هويتها المؤسسية الجديدة لتصبح (بورصة فلسطين) علامتها التجارية متخذة من (فلسطين الفرص) شعاراً لها.

قادرة على التنبؤ بأسعار الإغلاق للمؤشر بدقة أكبر كلما زدنا من عدد المشاهدات المدخلة. حيث تفوقت الشبكة على النماذج التقليدية في التنبؤ.

وهدفت دراسة Al Shajee (2017) إلى التنبؤ بأسعار الإغلاق المستقبلية لمؤشر داو جونز باستخدام نموذج مركب من الشبكة العصبية الاصطناعية ذات الانحدار الذاتي غير الخطية مع نموذج انحدار متغير خارجي exogenous. حيث تم اختبار النموذج المركب باستخدام سلسلة بيانات يومية خلال الفترة 2010/1/9 إلى 2016/9/16 مشاهدة، وقد كانت فوائد هذا النموذج بأنه سريع التدرب والقابلية للتعلم وبدرجة عالية في دقة التنبؤ. وبينت النتائج أن نموذج الشبكة العصبية المركب أعطى نتائج تنبؤ ذات أداء جيد.

ما يميز هذه الدراسة:

وتعد هذه الدراسة استكمالاً للجهود السابقة المبذولة في مجال استخدام الشبكات العصبية الاصطناعية في التنبؤ بمؤشرات الأسواق المالية المختلفة. حيث تقوم باختبار نموذج الشبكات العصبية الاصطناعية مقارنة بنموذج الانحدار الذاتي في سوق مالي ناشيء له ظروفه وخصائصه الخاصة. كما أنها الدراسة الأولى التي تطبق في بورصة فلسطين على حد علم الباحث.

منهج الدراسة:

لتحقيق أهداف الدراسة استخدم المنهج الوصفي التحليلي الذي يمثل أسلوباً من أساليب التحليل المركز على معلومات كافية ودقيقة عن ظاهرة أو موضوع محدد. ومن خلال فترة أو فترات زمنية معلومة. وذلك من أجل الحصول على نتائج عملية تم تفسيرها بموضوعية وبما ينسجم مع المعطيات الفعلية للظاهرة. بهدف دراسة المتغيرات التي تسهم في التنبؤ بهؤشر السوق المالي وذلك بالاعتماد على المنهج التحليلي في التطبيق العملي وإجراء الاختبارات اللازمة.

مصادر جمع البيانات:

الجانب النظري:

اعتمد على الكتب والمراجع العلمية، ورسائل الماجستير والدكتوراه التي تناولت موضوع الدراسة، والأبحاث الحكومية في الدوريات المتخصصة والمجلات العلمية. لتغطية الجانب النظري للدراسة.

الحسابي للسلسلة الزمنية 501.98 وبانحراف معياري يساوي 34.41، ويتبين أيضاً أن قيمة معامل الالتواء (skewness) 0.494 وهذا دليل على أن توزيع الأخطاء ملتوٍ بجهة اليمين (التواه موجب). كذلك يختلف معامل التفلفط (kurtosis) بقليل عن قيمة (3) المميزة للتوزيع الطبيعي، حيث بلغ في هذه العينة 3.187 مما يدل على أن البوافي تتسم بالتفلفط وبالتالي يختلف توزيع البيانات عن التوزيع الطبيعي. وهذا ما تؤكد إحصائية (Jarque-Bera) التي تشير إلى أن هذه البوافي لا تتبع التوزيع الطبيعي عند مستوى معنوية (%) 5، وهذه ميزة عامة للسلسلة الزمنية المالية.

حدود الدراسة:

اقتصرت الدراسة على بورصة فلسطين نظراً لتوفر سلسلة زمنية مناسبة لإجراء التحليل القياسي. أما حدود الدراسة الزمنية فتمثل في الفترة المتداولة بين 2010/1/3 إلى 2018/2/28. وتعد هذه الفترة كافية لدراسة نماذج تأثير المتغيرات المستقلة على المتغير التابع.

محددات الدراسة:

من بين أهم الصعوبات التي اعترضت الباحث في إنجاز هذه الدراسة هي نقص الدراسات القياسية المرتبطة بموضوع الدراسة في المكتبة الفلسطينية.

الجانب التطبيقي:

14- تطبيق نموذج الانحدار الذاتي:

بيّنت النتائج أن النموذج المفضل لسلسلة مؤشر القدس لبورصة فلسطين هو نموذج الانحدار الذاتي من الرتبة الثانية (AR2) حيث تم اختيار هذا النموذج حاسوبياً بناءً على قيم المتغيرات المعنوية وقيمة معيار أكايكي AIC. وقد تم الحصول على قيم معلمات النموذج باستخدام برنامج Eviews 9.5 كما يلي:

جدول (2):
نتائج الانحدار الذاتي

$Y_t = 1.108931 * Y_{(t-1)} - 0.108876 * Y_{(t-2)}$	
t=49.668	t=-4.876
(0.000)	(0.000)
F = 96752.21 (0.000)	R ² =0.9942
D.W=2.0098	LM = 10.1714 (0.008)

المصدر: من إعداد الباحث بناءً على مخرجات البرنامج الإحصائي Eviews 9.5

وتبيّن النتائج أن قيم معلمات النموذج θ_1 و θ_2 في النموذج المقدر كانت ذات دلالة إحصائية. حيث كانت القيم الاحتمالية لاختبار F أقل من 5%، وتبيّن قيم اختبار F أن النموذج

تعمل البورصة تحت إشراف هيئة سوق رأس المال الفلسطينية. طبقاً لقانون الأوراق المالية رقم (12) لسنة 2004. وتسعى البورصة إلى تنظيم التداول في الأوراق المالية من خلال رزمة من القوانين والأنظمة الحديثة التي توفر أساس الحماية والتداول الآمن.

وقد بلغ عدد الشركات المدرجة بالبورصة 48 شركة كما هي بتاريخ 2018/4/30 بقيمة سوقية تجاوزت 3,731 مليون دولار موزعة على خمسة قطاعات هي: البنوك والخدمات المالية والتأمين، والاستثمار، والصناعة، والخدمات. في حين وصل عدد شركات الأوراق المالية الأعضاء بالبورصة إلى 8 شركات.

تمثل القيم والمبادئ الأساسية للبورصة في الحكومة الرشيدة، وتحقيق العدالة، والشفافية، والكافأة، وتوفير الفرص المتساوية لكافة المستثمرين. (المعلومات أكثر يمكن الرجوع للموقع الإلكتروني لبورصة فلسطين www.pex.ps)

عينة الدراسة:

تم الاعتماد على قاعدة بيانات أسعار الإغلاق اليومية المؤشر القدس لبورصة فلسطين (باستثناء أيام العطل) خلال الفترة 2010/1/3 و حتى 2018/1/31 أي باستخدام 1986 مشاهدة والتي تمثل أيام تداول فعليه. حيث تم الحصول عليها من الموقع الإلكتروني للبورصة، وتم تدقيقها للتحقق من أنها غطت أيام العمل جميعاً بعد استعراض أيام العطل الرسمية خلال فترة الدراسة.

ويشير الجدول رقم (1) إلى الإحصاء الوصفي لسلسلة أسعار الإغلاق اليومية المؤشر القدس لبورصة فلسطين وكذلك الاختبارات الأساسية لبيانات الدراسة.

جدول (1):
الإحصاء الوصفي والاختبارات الأساسية لبيانات الدراسة

البيان	القيمة
القيمة الصغرى	416.26
القيمة العظمى	603.03
الوسط الحسابي	501.98
الانحراف المعياري	34.41
معامل الالتواء skewness	0.494
معامل التفلفط kurtosis	3.187
جاركوب-بيرا Jarque-Bera	83.65
الاحتمالية sig.	0.0000

المصدر: من إعداد الباحث بناءً على مخرجات البرنامج الإحصائي Eviews 9.5

ومن الجدول المذكور يتبيّن أن أصغر قيمة في السلسلة الزمنية كانت 416.26 وأكبر قيمة كانت 603.03، والمتوسط

بـ. مرحلة التحليل : Analysis

بعد القيام بعملية خليل الشبكة بينت النتائج ما يلي :

جدول (3):
نتائج عملية التحليل

النسبة	العدد	المجموعات
%68.08	1352	مجموعه التدريب
%15.96	317	مجموعه تأكيد
%15.96	317	مجموعه الاختبار
%100	1986	مجموع المشاهدات

المصدر من إعداد الباحث بناء على مخرجات البرنامج التطبيقي Alyuda NeuroIntelligence

وفي هذه مرحلة تم جمع البيانات محل الدراسة وعددها Alyuda (1986) مشاهدة، ثم قرئتها بالاعتماد على برنامج NeuroIntelligence بشكل عشوائي. حيث خصص (1352) مشاهدة وبنسبة (68.08 %) كمجموعه تدريب Training Set. بينما خصص (317) مشاهدة وبنسبة (15.96 %) كمجموعه تأكيد Validation Set. بينما خصص (317) مشاهدة وبنسبة (15.96 %) كمجموعه اختبار . Test Set

تـ. مرحلة المعالجة : Processing

تمثيل البيانات في الشبكة يتم إما بالشكل الثنائي (0 . 1) أو بالتمثيل ثنائي القطبية (-1+ . 1-) وبالاعتماد على برنامج Alyuda NeuroleIntelligence تم تمثيل البيانات محل الدراسة كما يلي :

جدول (4):
تمثيل البيانات

البيانات	التمثيل
المدخلات	(-1+ . 1-)
الخرجات	(1 . 0)

المصدر من إعداد الباحث بناء على البرنامج التطبيقي Alyuda NeuroIntelligence

ثـ. مرحلة التصميم : Design

في هذه المرحلة تم الاعتماد على الدالة اللوجستية logistic كدالة خفيف في الطبقة الخفيفية وطبقة المخرجات. وبالاعتماد على برنامج Alyuda NeuroIntelligence تم ترشيح مجموعة من التصميم للتنبؤ بهمؤشر بورصة فلسطين. حيث يوضح الشكل (1) نتائج مرحلة التصميم كما يلي:

مناسب لتمثيل العلاقة الخطية بين المتغير التابع والمتغيرين المفسرين. حيث كانت القيمة عالية والقيمة الاحتمالية للاختبار أقل من 5%.

كما تشير النتائج إلى القيم السابقة لمؤشر القدس لبورصة فلسطين تفسر ما نسبته 99.42 % من القيمة الحالية للمؤشر، وأن النسبة المتبقية 0.58 % تعود إلى الأخطاء العشوائية. وبالتالي تمثل هذه النماذج توفيقاً جيداً للعلاقة بين المتغير التابع والمتغيرات المستقلة.

أما قيمة اختبار ديرين واتسون W.D لارتباط الذاتي في بوافي النموذج. فتشير إلى عدم وجود ارتباط ذاتي في البوافي حيث كانت قيمتها قريبة من 2. وللتتأكد من دقة هذه النتيجة، كون المتغيرات التفسيرية هي متغيرات متطابقة للمتغير التابع. Lagrange Multiplier (LM) ثم احتساب قيمة مضاعف لجراخ (LM) وتبين النتائج في جدول (2) أن القيمة الاحتمالية لاختبار LM كانت أقل من 5% وهذه النتيجة تؤكد عدم وجود ارتباط ذاتي في البوافي. وبالتالي صلاحية نموذج الانحدار لتمثيل العلاقة الخطية بين المتغير التابع والمتغيرات المستقلة.

اختبار الفرضية الأولى:

تنص الفرضية الأولى على (عدم فعالية تطبيق نموذج الشبكات العصبية الاصطناعية للتنبؤ بهمؤشر القدس لبورصة فلسطين).

و濂اخبار هذه الفرضية تم تطبيق نموذج الشبكات العصبية الاصطناعية للتنبؤ بهمؤشر القدس لبورصة فلسطين وذلك وفق الخطوات التالية:

• اختبار نوع الشبكة المستخدمة:

تم الاعتماد على شبكة بيرسيبترتون متعددة الطبقات (MLP) وهذا لزيادتها التفضيلية في التنبؤ بأسعار مؤشرات الأسواق المالية بالإضافة إلى اعتمادها من طرف جل الباحثين في المجال.(مهرج. 2013)

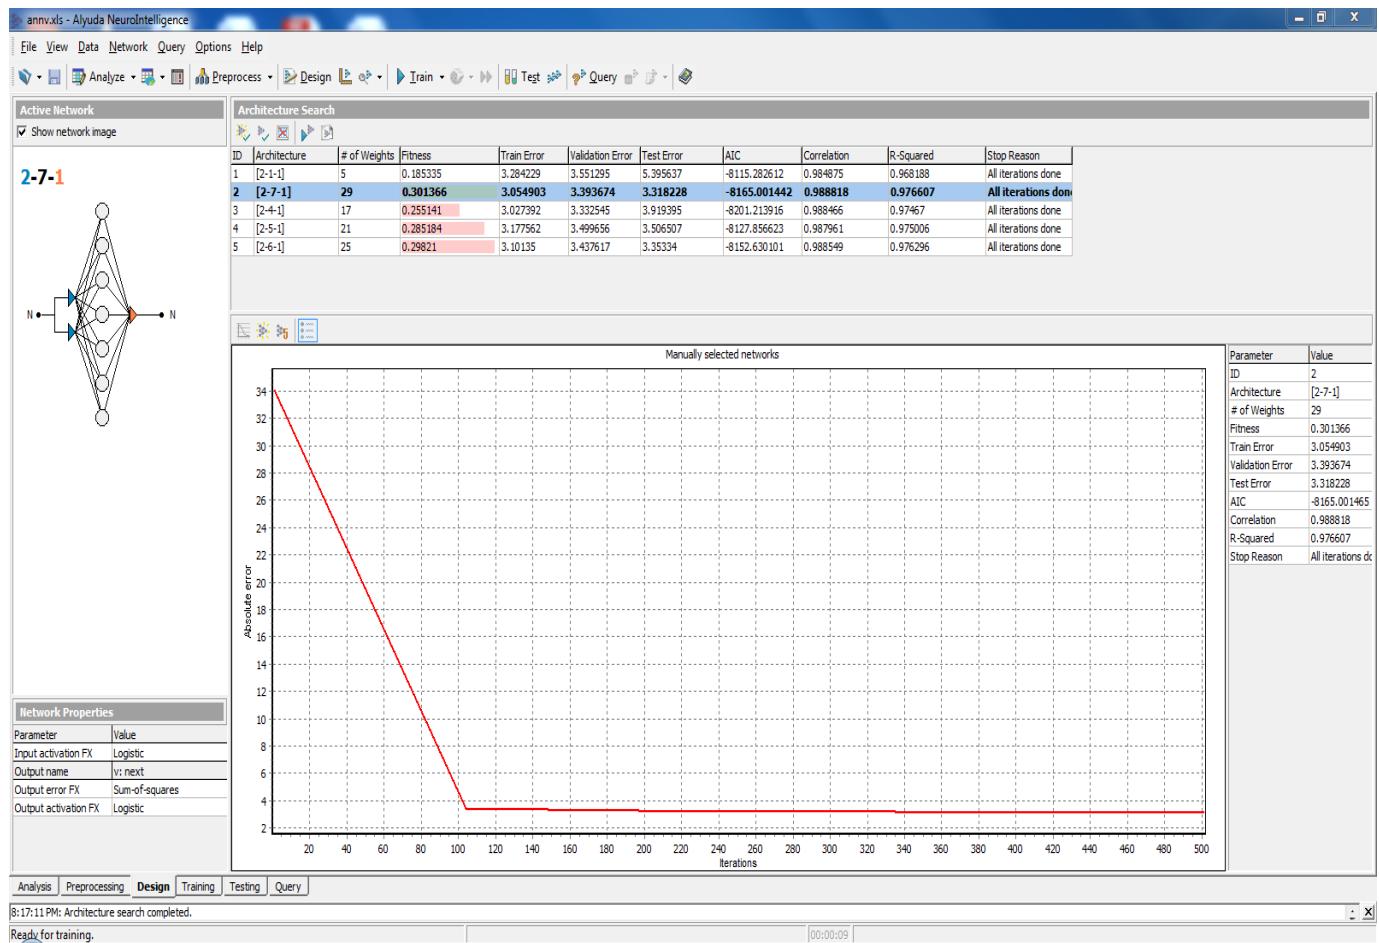
• بناء الشبكة :

تم مرحلة بناء الشبكة العصبية الاصطناعية بالمراحل التالية :

أ. مرحلة تحديد المدخلات :

إن أول خطوة في بناء شبكة عصبية اصطناعية لغرض التنبؤ هو تحديد عدد المدخلات. حيث تم الحصول على طبقة المدخلات وبها اثنان من عناصر المعالجة بناء على النتائج المتحصل عليها من البرنامج التطبيقي Alyuda NeuroIntelligence (Lin et. al. 1995) ما يتلاءم والمعالجات المقارنة مع النماذج السابقة)

الشكل (1):
نتائج مرحلة التصميم



المصدر: مخرجات البرنامج التطبيقي Alyuda NeuroIntelligence

كما نلاحظ من الشكل السابق أن عدد أوزان الشبكة المفضلة [2-7-1] يساوي 29 وهذا ما يتطابق مع معادلة (Faraway and Chatfield, 1998)

$$P = (\alpha i + 2)\alpha u + 1$$

حيث ان:

αi : تمثل عدد متغيرات الإدخال.

αu : تمثل عدد العصبونات أو عدد الوحدات في الطبقة الخفية.

P : تمثل عدد الأوزان في الشبكة العصبية.

ج. مرحلة التدريب : Training

لإجراء عملية التدريب تم الاعتماد على خوارزمية الانتشار الخلفي التزايدى. حيث تم آلياً من خلال برنامج Alyuda Learning Rate ثبيت نسبة التعلم عند

كما هو موضح في الشكل (1) فقد تم ترشيح خمس شبكات بعمارات مختلفة للتنبؤ بمؤشر بورصة فلسطين. حيث تم اختبار العمارة [2-7-1] من قبل برنامج Alyuda NeuroIntelligence اعتماداً على معيار أكايكي AIC. ومعيار درجة الملائمة (Fitness). حيث تشير النتائج في الشكل (1) إلى أن هذه العمارة قد حصلت على أقل قيمة لمعيار أكايكي (الأعلى سلبية) وبلغت -8165.001465. في حين كانت قيمة درجة الملائمة الأعلى بين القيم، حيث بلغت 0.301366. إضافة إلى حصولها على أعمالي تحديد الذي بلغ 0.977.

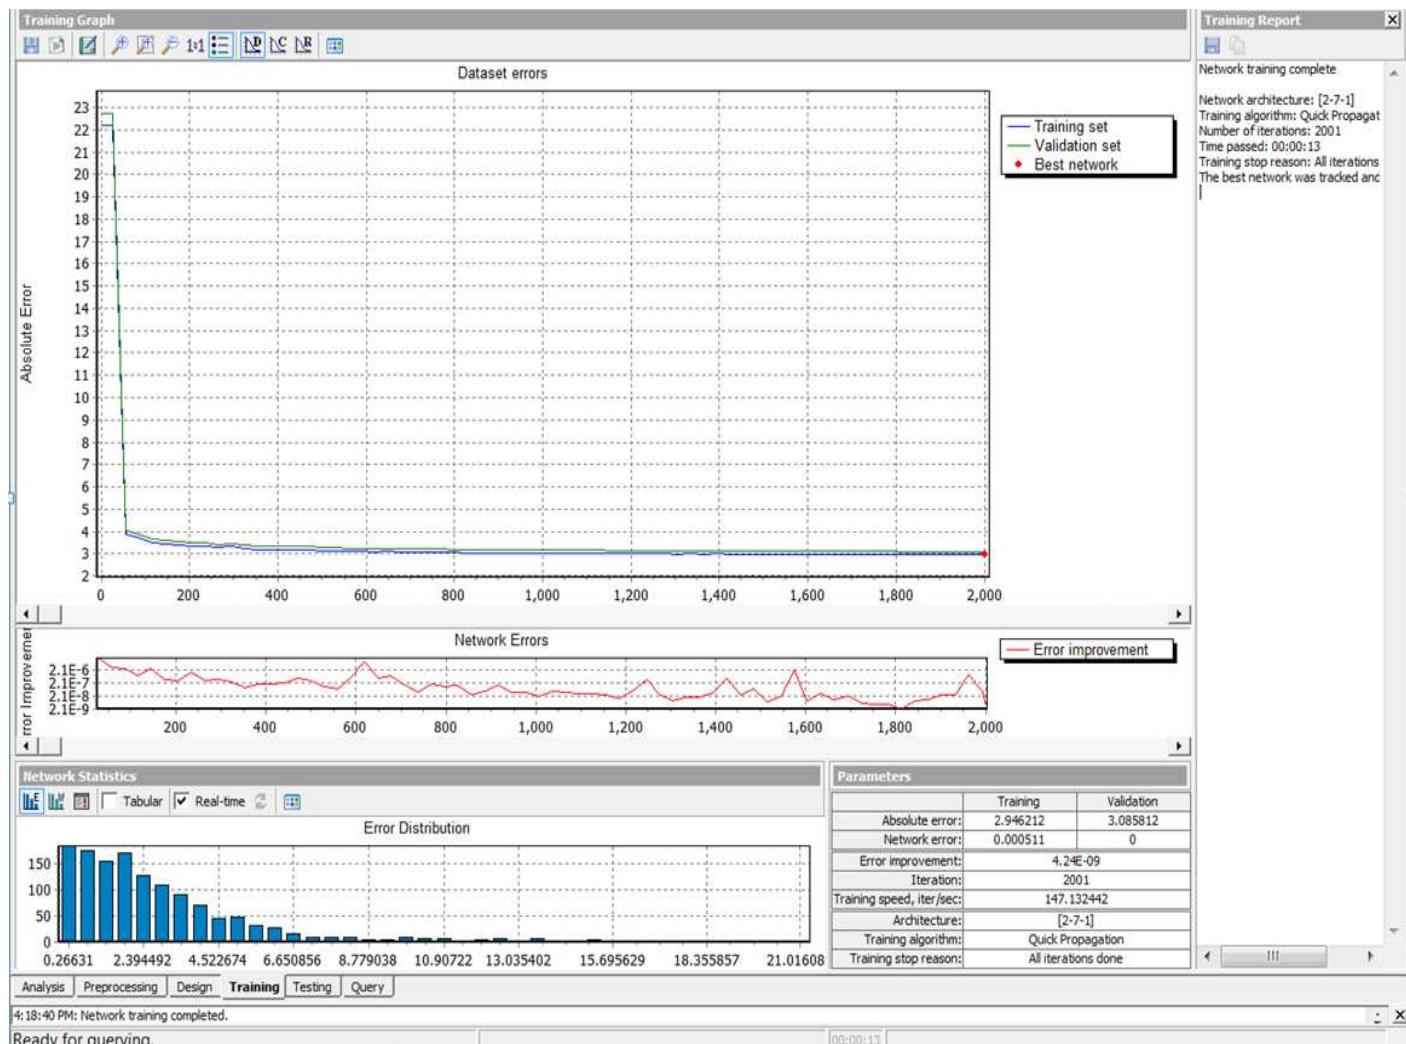
وعليه فإن أفضل عمارة تكون من ثلاث طبقات هي:

- طبقة المدخلات وبها اثنان من عناصر المعالجة.
- الطبقة الخفية وبها سبعة عناصر معالجة.
- طبقة المخرجات وبها عنصر معالجة واحد.

Learning Rate ثبيت نسبة التعلم عند NeuroIntelligence 0.1 وثابت الزخم عند $\text{Momentum Constant} = 0.1$. وتم اعتماد عدد التكرارات = 2000. وقد كانت نتائج عملية التدريب كما يلي: عدد التكرارات = 2000. وقد كانت نتائج عملية التدريب كما يلي:

0.1 وثابت الزخم عند $\text{Momentum Constant} = 0.1$. و تم اعتماد عدد التكرارات = 2000. وقد كانت نتائج عملية التدريب كما يلي: لإجراء عملية التدريب تم الاعتماد على خوارزمية الانتشار المخلفي التزايدى. حيث تم آليا من خلال برنامج Alyuda

الشكل (2):
نتائج عملية التدريب



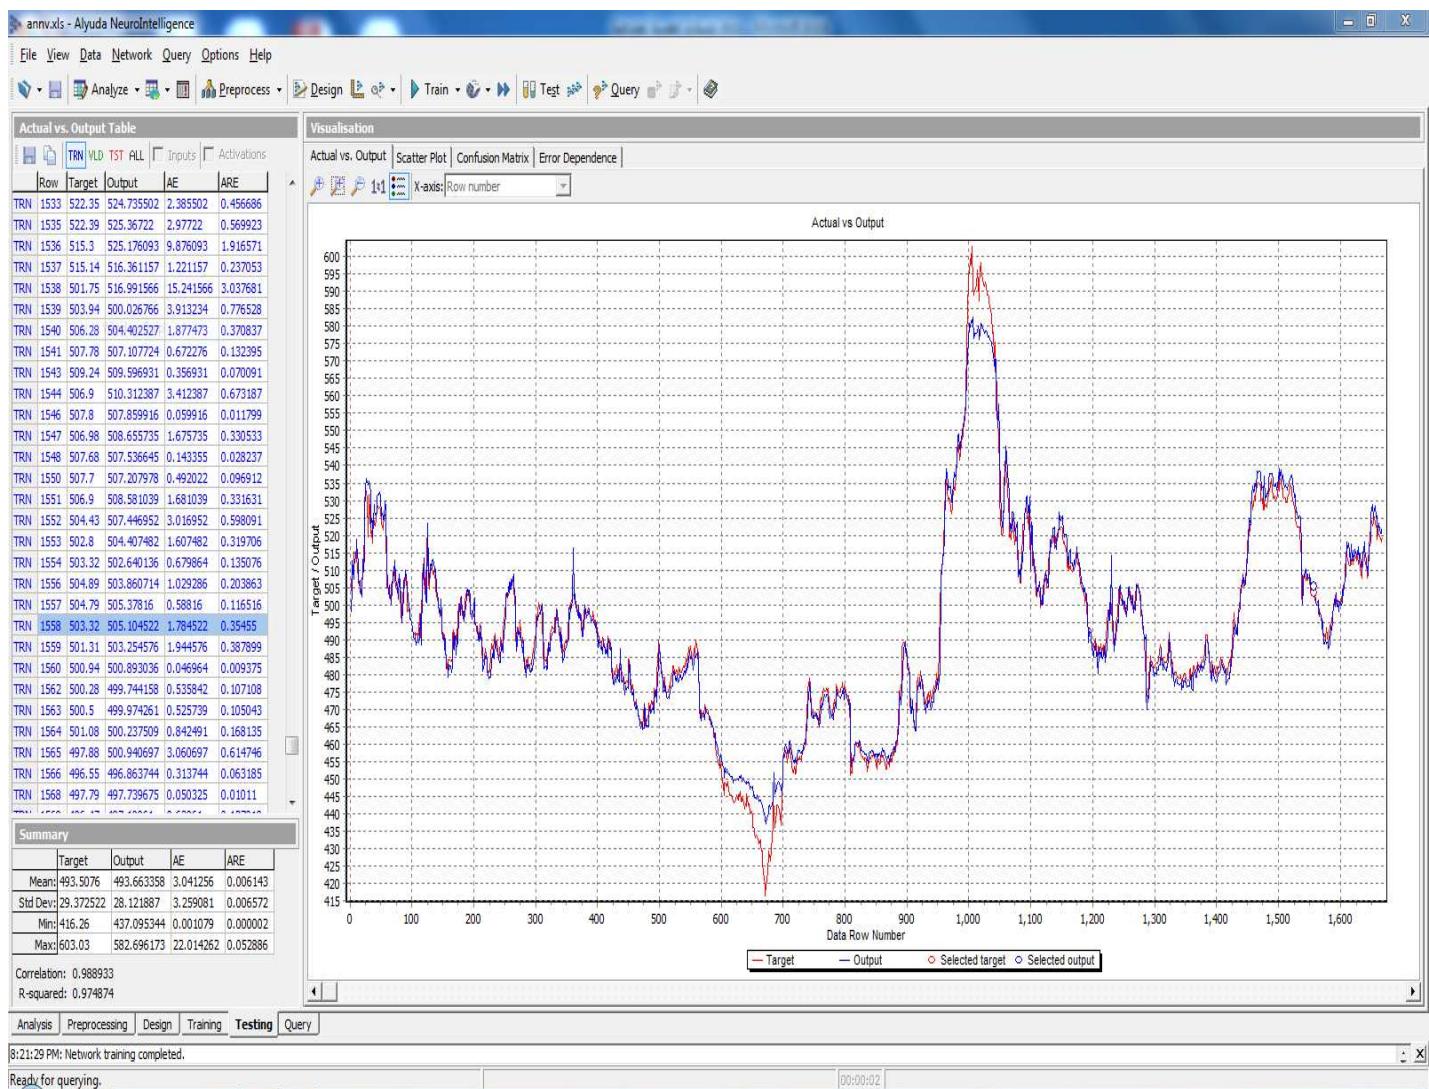
المصدر : مخرجات البرنامج التطبيقى Alyuda NeuroIntelligence

التكرارات إلى أن ثبت بعد عدد التكرارات يساوى 1800. وهذا دليل أن الشبكة تدرست بشكل جيد ووصلت إلى مستوى مقبول إحصائيا.

ج. مرحلة الاختبار : Testing نتائج عملية اختبار صلاحية الشبكة موضحة في الشكل (3) كما يلي :

ومن الشكل (2) يتضح تطابق مجموعة التدريب مع مجموعة الشرعية. حيث ساکت مجموعة الشرعية سلوك مجموعة التدريب نفسها. وأن الخطأ المطلق لمجموعة التدريب كان أقل. أما منحنى الخطأ المطلق للشبكة فإنه يأخذ بالتنافص مع زيادة عدد مرات التكرار، كما يتبيّن من النتائج الواردة في الشكل السابق أن أفضل شبكة قد تحدّدت عند عدد التكرارات يساوى 2000 . وأن أخطاء الشبكة وتوزيعها يتنافص مع زيادة عدد

الشكل (3):
نتائج عملية الاختبار



المصدر: مخرجات البرنامج التطبيقى Alyuda NeuroIntelligence

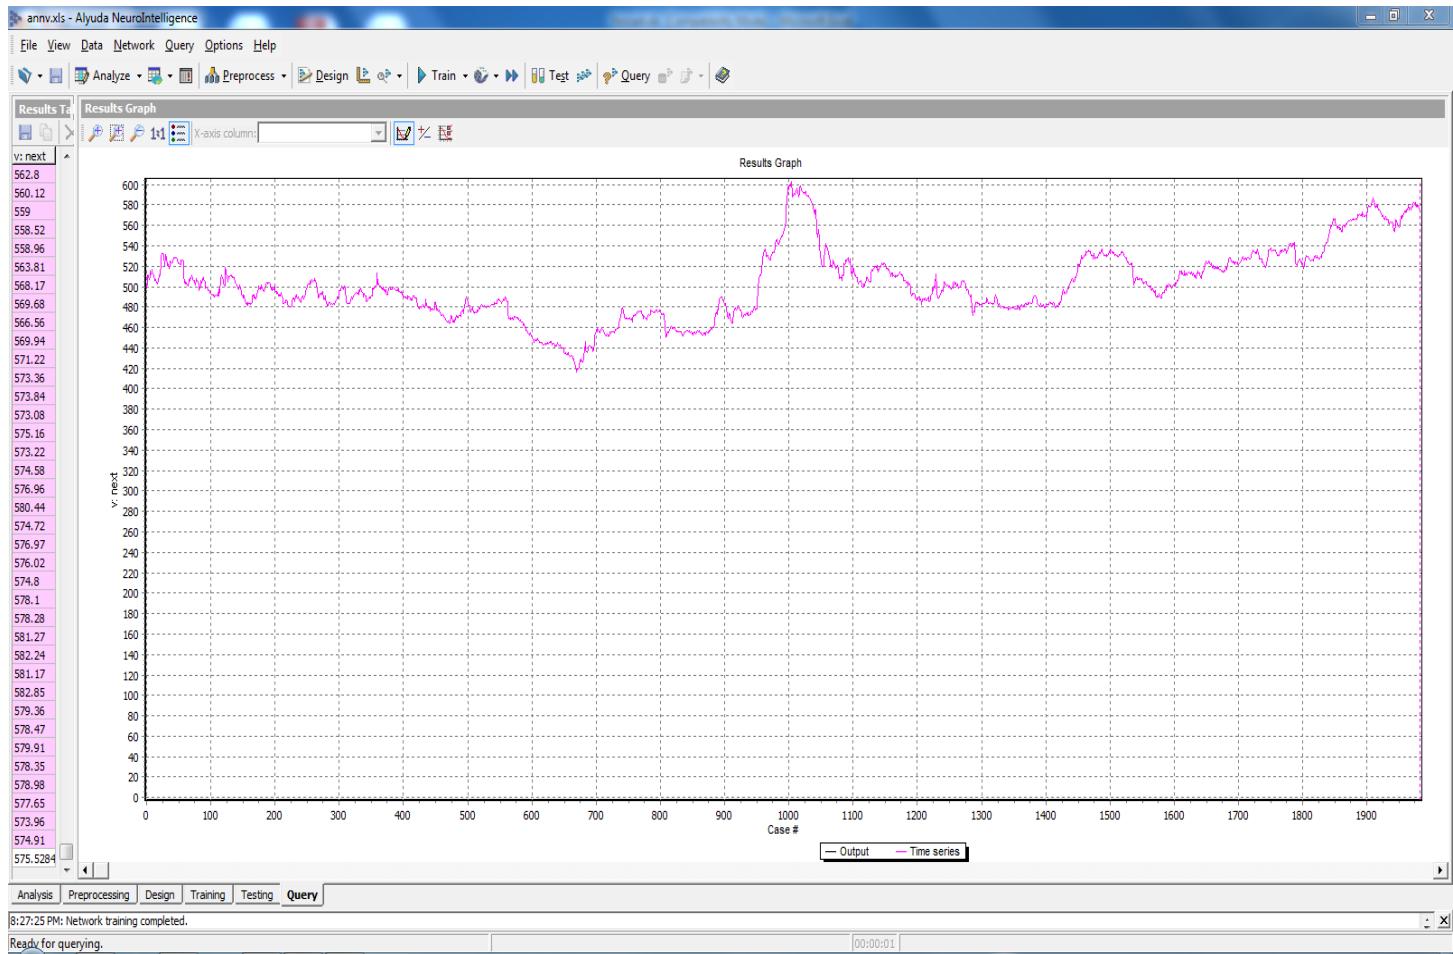
استخدم النموذج الناتج في عملية التنبؤ للفترة من 2018/2/1 إلى 2018/2/28

أما الشبكة العصبية الاصطناعية فاستخدمت في عملية التنبؤ لليوم التالي كما يوضحها الشكل رقم (4). وتبين النتائج الواردة في الشكل (4) إلى أن القيمة المقدرة لمؤشر القدس لبورصة فلسطين ليوم 2018/2/1 هي 575.5284، حيث استخدمت هذه القيمة في التنبؤ لليوم الذي يليه اي 2018/2/4، وهذا حتى نهاية الشهر، مع الأخذ بالاعتبار عطلة نهاية الأسبوع.

تبين من الشكل (3) أعلى أن القيم التنبؤية (الخروجات) تفوق القيم الأصلية بنسبة تزيد عن 95% خلال فترة الدراسة، إذ إن تطابق المنحنيين في معظم فترات الدراسة غير دليل على ذلك، ومنه يمكن اعتماد الشبكة الناتجة للتنبؤ بهؤشر القدس لبورصة فلسطين.

خ. مرحلة التنبؤ : Forecasting
اعتماداً على عينة الدراسة خلال الفترة 2010/1/3 إلى 2018/1/31 تم تحليل السلسلة الزمنية للمؤشر واستخراج نموذج الانحدار الذاتي المناسب (كما ورد في جدول رقم (2)). حيث

الشكل(4):
القيم التنبؤية لسلسلة مؤشر القدس لبورصة فلسطين



المصدر: مخرجات البرنامج التطبيقى Alyuda NeuroIntelligence

ويوضح الجدول رقم (5) نتيجة المقارنة بين القيم الفعلية والقيم المقدرة (المتنبأ بها) باستخدام نموذج الانحدار الذاتي ونموذج الشبكة العصبية الاصطناعية كما يلي:

جدول(5)

القيم المقدرة لمؤشر القدس لبورصة فلسطين خلال الفترة 2018/2/1 إلى 2018/2/28

القيمة المقدرة حسب نموذج الشبكة العصبية الاصطناعية	القيمة المقدرة حسب نموذج الانحدار الذاتي	القيمة الفعالية	التاريخ
574.18	575.2347	575.59	8/2/2018
575.94	575.2702	580.9	11/2/2018
577.2	575.3057	582.07	12/2/2018
579.87	575.3412	586.56	13/2/2018
580.11	575.3767	589.06	14/2/2018
580.76	575.4122	590.1	15/2/2018
586.74	575.4477	588.21	18/2/2018
576.97	575.4833	585.83	19/2/2018
582.65	575.5188	588.76	20/2/2018
578.99	575.5543	588.54	21/2/2018
581.86	575.5898	587.94	22/2/2018

القيمة المقدرة حسب نموذج الشبكة العصبية الاصطناعية	القيمة المقدرة حسب نموذج الانحدار الذاتي	القيمة الفعالية	التاريخ
575.53	575.0451	576.93	1/2/2018
575.81	575.0914	576.39	4/2/2018
576.33	575.1281	577.03	5/2/2018
574.05	575.1637	577.37	6/2/2018
572.66	575.1992	576.58	7/2/2018

Root Mean Squared Error (RMSE)

متوسط القيم المطلقة للنسبة المئوية للأخطاء Absolute Percentage Error (MAPE)

أظهرت دراسة (Muttar, 2008) أنه من غير السليم الاعتماد على أحد المعايير السابقة وحده لتقدير دقة النموذج في التنبؤ، واقتصرت استخدام متوسط مرجح (Weighted Average) للمعايير الثلاثة وفق ثلاثة طرق. فقد تم استخدام المتوسطات المرجحة للمعايير الثلاثة وعلى النحو الآتي:

$$WA_1 = (MAE + RMSE + 4MAPE)/6$$

$$WA_2 = (MAE + 4RMSE + MAPE)/6$$

$$WA_3 = (4MAE + RMSE + MAPE)/6$$

ويعرض الجدول التالي نتائج المعايير الثلاثة لقياس الخطأ ومتوسطاتها المرجحة:

جدول (6)
المفضلة بين نموذجي ANN و AR

الشبكة العصبية الاصطناعية	الانحدار الذاتي	المعيار
5.632	8.2143	MAE
1.9935	2.1588	RMSE
0.1827	0.1848	MAPE
1.3928	1.8521	WA ₁
2.2981	2.8390	WA ₂
24.7043	35.2007	WA ₃

المصدر: من إعداد الباحث بناء على البرنامج الإحصائي Exell

ويتبين من الجدول رقم (6) أن هناك انخفاضاً ملحوظاً في قيم المعايير الثلاثة المحسوبة لكلا النماذجين وبالتالي قربها من القيمة الفعلية، حيث تظهر قيمة MAPE أن القيم الفعلية بالتوسط أعلى من القيم المقدرة بنسبة 0.18%. ما يشير إلى دقة النماذج المستخدمة في التقدير.

كما يظهر من النتائج أن قيم المعايير الثلاثة للشبكة العصبية الاصطناعية كانت أقل من قيمها لنموذج الانحدار الذاتي، مما يشير إلى أفضلية الشبكة العصبية الاصطناعية في التنبؤ.

كما تبين النتائج في الجدول رقم (6) انخفاضاً ملحوظاً في المتوسطات المرجحة خاصة WA₁ و WA₂ مما يؤكد دقة التقدير وخاصة لنموذج الشبكة العصبية الاصطناعية حيث كان المتوسط المرجح للمعايير الثلاثة أقل منها لنموذج الانحدار الذاتي.

القيمة المقدرة	القيمة الفعلية	التاريخ
حسب نموذج الشبكة العصبية الاصطناعية	حسب نموذج الانحدار الذاتي	
578.83	575.6254	587.44 25/2/2018
577.33	575.6609	586.58 26/2/2018
577.18	575.6964	585.53 27/2/2018
576.39	575.7319	584.61 28/2/2018
577.969	575.3867	583.601 المتوسط الحسابي
0.7980	0.7541	معامل الارتباط

المصدر: من إعداد الباحث بناء على البرنامجين التطبيقين Alyuda Eviews و NeuroIntelligen

ويتبين من النتائج في الجدول (5) أن قيم مؤشر القدس لبورصة فلسطين المقدرة أعطت مستويات ايجابية إذ يأخذ السوق الاتجاه الصاعد. وهذا الاتجاه للقيم المقدرة يتواافق مع اتجاه القيم الفعلية للمؤشر خلال الفترة، حيث بلغ معامل الارتباط بين سلسلة البيانات الفعلية وسلسلة البيانات المقدرة باستخدام نموذج الانحدار الذاتي 0.7541. ومعامل الارتباط بين سلسلة البيانات الفعلية وسلسلة البيانات المقدرة باستخدام الشبكة العصبية الاصطناعية 0.7980، مما يدل على وجود علاقة ايجابية قوية بين سلسلة البيانات الفعلية وسلسلة البيانات المقدرة، والذي يؤكد على حركتهما بالاتجاه نفسه.

والنتائج السابقة تقودنا لرفض الفرضية الصفرية التي تفيد بعدم فعالية تطبيق نموذج الشبكات العصبية الاصطناعية للتنبؤ بمؤشر القدس لبورصة فلسطين. وقبول الفرضية البديلة بفعالية هذا النموذج في التنبؤ. وهذه النتيجة تتوافق مع دراسة السراج والجميل (2008) التي تمت في بعض الأسواق العربية، ودراسة مرهج (2013) في سوق دمشق للأوراق المالية. وكذلك دراستي دريال (2014) و عايد وعيساني (2016) في سوق دبي المالي، وكذلك تتوافق هذه النتيجة مع نتائج دراسات مت في الأسواق الناشئة كدراسات Aamodt (2010) و Tyagi et. al. Sutheebanjard & Premchaiswadi (2010) . وغيرها من الدراسات التي تمت في الأسواق الناشئة والمقدمة على حد سواء.

3-14 اختبار الفرضية الثانية:

تنص الفرضية الثانية على انه (لا يتفوق نموذج الشبكات العصبية الاصطناعية على نموذج الانحدار الذاتي للتنبؤ بمؤشر القدس لبورصة فلسطين)

ولاختبار هذه الفرضية تمت المفضلة بين نموذج الانحدار الذاتي AR ونموذج الشبكة العصبية الاصطناعية ANN بالاعتماد على عدة معايير وهي: (مرهج، 2013)

متوسط القيمة المطلقة للأخطاء
Error (MAE)

باستخدام خوارزمية الانتشار العكسي أعطت نتائج دقيقة ومتقاربة مع القيم الفعلية. كما أنها أعطت أقل قيم لمعايير قياس الخطأ المتمثلة في معايير MAE و RMSE وكذلك متواسطاتها المرجحة. مما يعكس مدى قوة النموذج التنبؤية بمؤشر القدس لبورصة فلسطين. وهو ما يتفق مع نتائج معظم الدراسات التي تمت حول الموضوع في الأسواق المالية العربية والأجنبية على حد سواء.

وفيما يلي أهم نتائج الدراسة وتوصياتها:

- بعد المفاضلة بين نموذج الشبكة العصبية الاصطناعية الناجحة ونموذج الانحدار الذاتي بالاستعانة بمعايير MAE و RMSE وكذلك متواسطاتها المرجحة، والاختبارات الإحصائية F و LSD، اتضح أن نموذج الشبكة العصبية الاصطناعية تفوق على نموذج الانحدار الذاتي، وبالتالي يمكن الاعتماد عليه كأسلوب مناسب للتنبؤ المستقبلي بمؤشر القدس لبورصة فلسطين.
- الأسعار المتباينة لها لمؤشر القدس لبورصة فلسطين خلال الفترة 2018/2/1 إلى 2018/2/28 كانت موجبة، مما يعني ارتفاع مؤشر القدس لبورصة فلسطين. وهذا يشجع على زيادة جذب المستثمرين وانتعاش السوق في الفترات اللاحقة.
- هناك دقة في النتائج المرتبطة بتطبيق نموذج الشبكات العصبية الاصطناعية وسرعة في تطبيقه وبساطة في استعماله. وهذا قد يشجع القائمين على بورصة فلسطين الاعتماد عليه في التنبؤ باتجاه السوق.

التوصيات:

بناء على ما تم التوصل إليه من نتائج يوصي الباحث بما يلي:

اعتماد القائمين على بورصة فلسطين والخليلين والمستثمرين فيها على الطرق الكمية في التنبؤ بمؤشر البورصة وبخاصة نموذج الشبكات العصبية الاصطناعية نظراً لدقته في التنبؤ وسرعة تطبيقه.

استخدام نموذج الشبكات العصبية الاصطناعية من قبل الجهاز الرئيسي الفلسطيني للإحصاء في الدراسات التنبؤية التي يقوم بها.

قيام الباحثين بدراسة أ направيات أخرى يمكن الاعتماد عليها في إجراء التنبؤ المستقبلي بمؤشر بورصة فلسطين وذلك لتحديد النموذج الملائم الذي يعطي أكبر دقة ممكنة، ولذلك يقترح الباحث تطبيق نموذج هجين بين نموذج الانحدار الذاتي ونموذج الشبكات العصبية الاصطناعية.

ولتأكيد تفوق الشبكة العصبية على الانحدار الذاتي تم إجراء اختبار الفروق بين النموذجين، حيث تشير النتائج في جدول رقم (7) إلى وجود فروق ذات دلالة إحصائية عند مستوى 1% بين القيم المقدرة بأسلوب الشبكة العصبية الاصطناعية والقيم المقدرة بنموذج الانحدار الذاتي. فقد بلغت قيمة F المحسوبة 11.823 وهي أعلى من القيمة المجدولة. وبلغ مستوى الدلالة المحسوب 0.001 وهو أقل من 5%. وبإجراء اختبار أقل مربع فروق (LSD) تبين أن الفروق كانت لصالح القيم المقدرة باستخدام نموذج الشبكة العصبية الاصطناعية. وهذا يؤكد تفوق هذا النموذج على نموذج الانحدار الذاتي.

جدول(7)

تحليل التباين بين نموذجي ANN و AR

مصدر الفروق	مجموع الفروق	درجات الحرارة	متوسط المربعات	الاحتمالي Sig.	قيمة F
بين المجموعات	66.315	1	66.315		
داخل المجموعات	213.028	38	5.606	0.001	11.829
المجموع	279.343	39			

المصدر: من إعداد الباحث بناء على البرنامج الإحصائي SPSS

وبناء على النتائج السابقة نرفض الفرضية الصفرية التي تفيد بعدم تفوق نموذج الشبكات العصبية الاصطناعية على نموذج الانحدار الذاتي للتنبؤ بمؤشر القدس لبورصة فلسطين. وقبول الفرضية البديلة بتفوق نموذج الشبكات العصبية الاصطناعية. وهو ما يتوافق مع نتائج الدراسات السابقة التي فاضلت بين الأساليب التقليدية ونموذج الشبكات العصبية الاصطناعية كدراسة Qwaider (2012) التي تمت في السوق الأردني ودراسات Kumar و Panda&Narasimhan (2006) و Desai & Joshi (2015) التي تمت في الأسواق الناشئة، وبؤكد نتائجها في بورصة فلسطين.

خاتمة الدراسة:

بعد التنبؤ أحد أهم الموضوعات التي تناولتها الإدارة المالية وبالتحديد صناعة القرار الاستثماري في أسواق المال. وفي هذا الإتجاه جاءت هذه الدراسة كمحاولة للتنبؤ بمؤشر القدس لبورصة فلسطين خلال الفترة 2010/1/3 إلى 2018/2/28 بالاعتماد على نموذجي الانحدار الذاتي والشبكات العصبية الاصطناعية والمفاضلة بينهما. وعلى الرغم من أن نموذج الانحدار الذاتي أعطى نتائج مرضية وبالتالي يمكن الاعتماد عليه للتنبؤ بالمؤشر، إلا أن هذا النوع من النماذج لا يأخذ بالاعتبار الصفة غير الخطية والصفة العشوائية التي تمتاز بها السلاسل المالية عموماً. ولذلك قام الباحث بالاعتماد على نموذج الشبكات العصبية الاصطناعية بحيث تم بناء شبكة عصبية اصطناعية متعدد الطبقات تكونت من ثلاثة طبقات (طبقة المدخلات (2)، طبقة خفية (7)، طبقة الخرجات (1)). وبعد تدريبها 2000 مرة

المراجع:

اولاً: المراجع العربية

- SPSS. معهد الدراسات والبحوث الاحصائية. قسم الاحصاء الحيوي والسكاني. جامعة القاهرة. (2013).
12. العبيدي، محمود خليل. الشبكات العصبية الاصطناعية، مجلة ابحاث الحاسوب، الجامعة التكنولوجية، بغداد، المجلد (4)، العدد (1)، (2000). ص ص 74-89
13. عيسى، علام زكي. الشبكات العصبية-البنية الهندسية-المخوارزميات-التطبيقات، شعاع للنشر والعلوم، حلب، سوريا، ط(1) (2000).
14. غولي، احمد سلطان والحمداني اسراء. استخدام نماذج الشبكات العصبية اصطناعية للتنبؤ بسعر الفائدة، مجلة ديارا للعلوم المصرفية، المجلد (6)، العدد (2)، (2010). ص ص 50-58.
15. مرهج، منذر. التنبؤ بقيم مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية وآلياتها، مجلة جامعة تشرين للبحوث والدراسات العلمية، سلسلة العلوم الاقتصادية والقانونية، المجلد (35)، العدد (5)، (2013). ص ص 243-260

ثانياً: المراجع الاجنبية

1. Aamodt, R., Using Artificial Neural Networks to Forecast Financial Time Series, Master Thesis, Norwegian University of Science and Technology, Department of Computer and Information Science, (2010)
2. Al Shayea, Q. K., Neural Networks to Predict Stock Market Price, Proceedings of the World Congress on Engineering and Computer Science 2017, Vol. (I), San Francisco, USA, (2017)
3. Chatfield, C., Faraway, J., Time Series Forecasting with Neural Networks: A Comparative Study Using the Airline Data, Applied Statistics, Vol. (47), Part (2), (1998), p.p. 231-250
4. Desai, J., Forecasting of Indian Stock Market Index S&P CNX Nifty 50 Using Artificial Intelligence, International Journal of Science and Research (IJSR), Vol. (4), Issue (11), (2015), p. p. 2544-2550
5. Giles, C., Steve, L., Chung, T. AH, Noisy Time Series Prediction Using Recurrent Neural Networks and Grammatical Inference, Kluwer Academic Publishers. Manufactured in the Netherlands, (2001)
6. Heaton J., Programming Neural Networks With Encog 3 in Java, Heaton Research, Inc., St. Louis, MO, USA, (2011), Retrieved January 2018 <https://s3.amazonaws.com/heatonresearch-books/free/Encog3Java-User.pdf>
7. Kumar, J., Artificial Neural Networks – An Application To Stock Market Volatility, International Journal of Engineering Science and Technology, Vol. (2), No.(5), (2010), p.p. 1451-1460
1. ابو عايدة، الفت فتحي. استخدام الطرق الاحصائية في التنبؤ باسعار الذهب العالمية، رسالة ماجستير غير منشورة، جامعة الازهر، غزة، (2015).
2. ارسانيوس، بدرنيه. دراسة اختبارية لاستخدام الشبكات العصبية لتطوير دور مراقب الحسابات في التقرير عن القوائم المالية المضللة، المؤتمر العلمي السنوي الحادي عشر، جامعة الزيتونة الاردنية، عمان - الاردن، (2012).
3. أمين بك، استخدام الشبكات العصبية الاصطناعية في التنبؤ للسلالس الزمنية بتطبيق على استهلاك الطاقة الكهربائية في مدينة موصل، رسالة ماجستير غير منشورة، كلية العلوم، جامعة الموصل، العراق، (2005).
4. التلبياني، شادي: سالم، فادي. استخدام الشبكات العصبية الاصطناعية في التنبؤ بمعدلات الجريمة في قطاع غزة، مؤسسة كنوز الحكمة للنشر والتوزيع، مجلة الحكمة للدراسات الاقتصادية، عدد (2)، (2013). ص ص 298-323
5. الجراح، نوال علاء الدين. كفاءة طريقتي الشبكات العصبية وطريقة بوكس جنكز في التنبؤ مع حالات تطبيقية في العراق، مجلة الادارة وللاقتصاد، السنة (34)، العدد (89)، (2011). ص ص 174-194
6. دريال، أمينة، محاولة التنبؤ بمؤشرات الاسواق المالية العربية باستعمال النماذج القياسيّة: دراسة حالة مؤشر سوق دبي المالي، اطروحة دكتوراه غير منشورة، جامعة ابي بكر بلقايد، تلمسان، الجزائر، (2014).
7. ساهد، عبد القادر، وكيديش محمد، دراسة مقارنة بين الانحدار البهم باستخدام البرمجة بالاهداف والشبكات العصبية الاصطناعية للتنبؤ باسعار البترول، مجلة الباحث، عدد (14)، (2014). ص ص 109-122
8. السراج، عمر والجميل سرمد، تقدير نماذج التنبؤ باسعار الاسهم في اسواق رأس المال العربية، جامعة الموصل، مجلة تنمية الرافدين، المجلد (30)، الاصدار (91)، (2008). ص ص 47-9
9. الشرقاوي، محمد علي، الذكاء الاصطناعي والشبكات العصبية، مطبع المكتب المصري الحديث، القاهرة، (1996).
10. عايد، احمد زقاي وعيسانى عبد القادر، نبذة عوائد الاسواق المالية والتنبؤ بمستوياتها المستقبلية باستخدام نموذج الشبكات العصبية الاصطناعية: دراسة حالة سوق دبي المالي من الفترة 2006/12/4 الى 2015/2/3، رسالة ماجستير غير منشورة، جامعة د. الطاهر مولاي سعيدة، الجزائر، (2016).
11. العباسى، عبد الحميد محمد، مقدمة في الشبكات العصبية الاصطناعية وتطبيقاتها في العلوم الاجتماعية باستخدام

- International Review of Economics and Management*, Vol. (4), No. (3), (2016), p.p.26-46.
21. Tyagi, C., Singh H., Bhardnaj, V., Nagpal, K., Application of Artificial Neural Network in Forcasting of Stock Market Index, *International Journal of Recent Research in Mathematics Computer Science and Information Technolgy*, Vol. (3), Issue (1), (2016), P.P. 28-38.
22. Vahedi, A., The Predicting Stock Price Using Artificial Neural Network, *Journal of Basic and Applied Scientific Researsh*, Vol. (2), No. (3), (2012), p.p. 2325-2328.
23. Wei, William,W.S., *Time Series Analysis: Univariate and Multivariate Methods*, Addison-Wesley Publishing Company Inc. , (1994)

ثالثاً: الموقع الالكتروني

موقع بورصة فلسطين .1 www.pex.ps

8. Lin, F., Gregor, S., Irons, R., Yu, X. H., *Time Series Forecasting With Neural Network*, *Complexity International*, Vol. (2), (1995), p.p. 1320-1338
9. Lippmann, R. P., *Introduction to Computing With Neural Nets*", IEEE, *Aspp Magazine*, Vol. (4), No. (2), (1987), p.p. 4-22.
10. Moghaddam, A.H., Moghaddam, M.H., Eslandyari M., Stock Market Prediction Using Artificial Neural Network, *Journal of Economics, Finance, and Administrative Sciences*,Vol. (21), issue (41), (2016) , pp.89-93.
11. Muttar, T., A Prrposed Technique for the Proplem of Selecting the Best Forcasting Model in Time Series: A Case Study, *Iraqi Journal of Statistical Science*, Vol. (14), (2008), p.p. 1-20
12. Panda, C., Narasimhan, V., *Predicting Stock Return: An Experiment of the Artificial Neural Network in Indian Stock Market*, *South Asia Economic Journal*, Vol. (7), No. (2), (2006), p.p. 205-218
13. Qwaider, Walid, *Finance Stock Price Prediction by Artificial Neural Networks; A Study of Jordanian's Stock Prices (J.S.P)*, *International Conferences on Business Intelligence and Knowledge Economy*, Al Zaytoonah University of Jordan, Amman, Jordan, (2012)
www.cmvm.pt/CMVM/Publicacoes/cadernos/.../c19c_urto_reis_esperanca.pdf
14. Rao, V.B., Rao, H.V., "C++ Neural Networks and Fuzzy Logic", Henry Holt and Company, Ins, New York, (1994)
15. Senol, D., *Prediction of Stock Direction by Artificial Neural Network Approach*, Master Thesis, Bogazici University, Institute for Graduate Studies in Social Sciences, (2008)
16. Sinha, H., *Designing a Neural Network for Forecasting Financial and Economic Time Series*", June 4th, INDE, (2005), p. 593.
17. Stergiou, C., Siganos, D., *Neural Networks*, (1996), Retrieved January 2018
https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol14/cs11/report.html
18. Sutheebanjard, P., Premchaiswadi, W., *Stock Exchange of Thailand Index Prediction Using Back Probagation Neural Networks*, Second International Conference on Computer and Network Technology, (2010), p.p 377-380
19. Tabrizi, H., Panahian, H., *Stock Price Prediction by Artificial Neural Networks: A Study of Tehrans Stock Exchange*, Working Paper, (2000).
20. Telli S., and Coskun M., *Forecasting the BIST 100 Index Using Artificial Neural Networks with Consideration of the Economic Calendar*,