

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

د. مروان جمعة درويش**

ملخص:

طرق التنبؤ المستخدمة في تحليل هذه البيانات قد لا تراعي هذه الجوانب مما 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 لمحاكاة الشبكة العصبية في الكائنات الحية بقدر المعرفة المتوفرة عنها. ولها مسميات عدة كالدمغ الإلكتروني والحاسوب الذكي (العبيدي، 2000)

إن السلاسل المالية لما لها من خصوصيات خطية وغير خطية تجعل الطرق التقليدية في بعض الأحيان غير قادرة على التنبؤ الكفؤ. مما يجعل التفكير في طرق الذكاء الاصطناعي كتقنية الشبكات العصبية الاصطناعية قائماً بين المحللين. 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 لبورصة 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 الكفء. 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. وبدقة 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 لتتمحور حول الاجابة على السؤال الرئيس التالي:

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

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 كاسلوب 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:

يعد التنبؤ بأسعار مؤشرات الأسواق المالية من التقنيات المهمة في اتخاذ القرارات الاستثمارية : لأنه يوفر الأدوات اللازمة لتحقيق الربح وتعظيمه . أو لتفادي الخسارة المتوقعة. وتتأثر عملية التنبؤ في السلاسل الزمنية بشكل مباشر باختيار النموذج المناسب لبيانات السلسلة الزمنية إذ تؤثر هذه الخطوة تأثيراً مباشراً في دقة التنبؤات المتحصل عليها. وتعد بيانات السلاسل الزمنية لقطاعات مختلفة في معظمها بيانات غير خطية . وتعاني أحيانا من العشوائية والاضطرابات. إلا أن معظم

لهذه الدراسة أهمية تجعلها مدخلا للمزيد من الدراسات في هذا الاتجاه.

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 نجاعة.

الإطار النظري:

1-6 نموذج الانحدار الذاتي للسلاسل الزمنية Autoregressive Model

يتكون تحليل السلاسل 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 (AR) Autoregressive Model 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 Wiker 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 الإبطاء بحيث يكون $AR(p)$ انحدارا ذاتيا 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 بجوانب 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 يتفوق نموذج الشبكات العصبية الاصطناعية على نموذج الانحدار الذاتي في التنبؤ بمؤشر القدس لبورصة فلسطين.

أهمية الدراسة:

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

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

لذا فإن قلة البحوث والدراسات التي عالجت الموضوع في الأسواق العربية عموما وفي بورصة فلسطين خصوصا. تعطي

– طريقة تحديد الأوزان وتعديلها أو ما يسمى بخوارزمية التعليم.

– دالة التنشيط التي هي في الغالب دالة لا خطية.
2-6-1 تعليم الشبكات العصبية الاصطناعية :

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

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

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 تعليمًا بواسطة معلم على نمط تصحيح الخطأ الذي يستخدم لتعليم الشبكات الخطية ذات الطبقة الواحدة. أو تعليمًا 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 متجه 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 المتبع في أسلوب التعليم بواسطة معلم. من أمثلة التعليم بدون معلم التعليم الهيباني Hebbian. والتعليم التنافسي Competitive (Lippmann, 1987)

ت. التعليم بإعادة التدعيم:

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

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

2-6-2 الشبكات العصبية الاصطناعية:

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

وتتألف الشبكات العصبية الاصطناعية من مجموعة من الخلايا الاصطناعية أو العقد (Nodes) التي تجمع بشكل مصفوفي ضمن طبقات (Layers) متصلة مع بعضها بعضاً. وأن كل اتصال بين هذه العقد يمتلك مجموعة من القيم تسمى الأوزان (Weights) تساهم 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 نواتج الشبكة. وبين كل طبقة من هذه الطبقات هناك طبقات مخفية (Hidden Layers) تعمل على ربط 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)

وتعرف الشبكات العصبية الاصطناعية بأنها شبكات ذات ترابط (تواصل) كثيف فيما بينها. تضم عناصر بسيطة ومتوازنة. وعادة ما تكون قابلة للتكيف وذات تنظيم هرمي. حيث تتفاعل مع كائنات العالم الحقيقي بالطريقة التي يتفاعل بها النظام العصبي الطبيعي (البيولوجي) مع العالم الحقيقي. فهي تمثل نموذجاً يحاكي الشبكات العصبية الطبيعية (البيولوجية). حيث تتكون من عناصر بسيطة ومتوازنة التركيب. تسمى بالعصبونات (Neurons) أو العقد (Nodes). ولديها القدرة على محاكاة سلوك النظام العصبي الطبيعي مثل القدرة على التعلم. الاستنتاج وحل المشاكل المعقدة. وكل أنماط السلوك الذكي الذي يتميز به الإنسان عن بقية الكائنات الحية الأخرى (دريال، 2014).

وتتصف الشبكة العصبية الاصطناعية بطبيعتها الديناميكية والمتوازنة في معالجة البيانات الداخلة إليها (Kumar, 2010). وتتميز بثلاث ميزات يتم من خلالها وصف الشبكة العصبية وهي (عيسى، 2000):

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

2-2-6 خوارزميات تعليم الشبكة العصبية الاصطناعية :

يجري تعليم الشبكات العصبية بواسطة خوارزميات متخصصة تسمى خوارزميات التعلم Learning Algorithms تتولى تعديل أوزان الشبكة لتحسين أدائها وتقليل الخطأ فيها استناداً إلى مقياس معلوم للوصول إلى النتيجة المطلوبة. حيث يجري تعديل هذه الأوزان جزئياً في كل دورة. وتؤخذ إشارة الخطأ دليلاً ومؤشراً على مدى القرب أو البعد عن القيم الصحيحة (العبيدي 2000).

وتمثل تلك الأوزان المعلومات الأولية التي تتعلم بها الشبكة لذا لا بد من تحديث الأوزان التي تستخدم في تدريب الشبكات العصبية كاملة الارتباط وذات التغذية الأمامية ومتعددة الطبقات وغير الخطية. وتعتبر هذه الخوارزمية تعميم لطريقة التدريب بنمط تصحيح الخطأ. ومن أجل هذا التحديث تستخدم خوارزميات مختلفة حسب نوع الشبكة. ومن أهم هذه الخوارزميات (Stergiou & Siganos, 1996):

خوارزمية الانتشار العكسي (الخلفي) للخطأ
Back Propagation Algorithm

تتضمن عملية تدريب الشبكة العصبية الاصطناعية باستخدام الانتشار العكسي على ثلاث مراحل هي:

(العبيدي 2000: عيسى 2000)

أ. مرحلة الانتشار الأمامي:

لا يحصل فيها أي تعديل للأوزان المشبكية وتبدأ هذه المرحلة بعرض الشكل المدخل للشبكة. حيث تخصص كل عنصر معالجة من طبقة عناصر الإدخال لأحد مكونات الشعاع الذي يمثل الدخل وتسبب قيم مكونات متجهة الدخل استثارة لوحدات طبقة الإدخال ويعقب ذلك انتشار أمامي لتلك الاستثارة عبر بقية طبقات الشبكة.

ب. مرحلة الانتشار العكسي (الخلفي):

وهي مرحلة ضبط أوزان الشبكة. حيث تعتبر خوارزمية الانتشار العكسي القياسية بمثابة خوارزمية الانحدار 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 واللاخطية. حيث يتم في أحد مراحل التعليم إعادة انتشار الإشارة من المخرج إلى المدخل بشكل عكسي. ويتم خلالها ضبط أوزان الشبكة. ويمكن تمثيل الخوارزمية لتكرار واحد كما يلي:

$$X_{k+1} = X_k - ak * gk$$

حيث:

X_k : شعاع الأوزان والإنحيازات الحالية

ak : معدل التعلم

gk : الميل الحالي

و هناك طريقتان لحساب الانحدار التدريجي: (دريال 2014)

- النظام التزايدی Incremental mode:

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

- نظام الدفعة الواحدة Batch mode :

وفق هذا النمط تزود الشبكة بكل أشعة المدخل قبل القيام بعملية تحديث الأوزان. وبالتالي يمكن أن نقول إن الأوزان والإنحيازات في هذه الطريقة تعدل بعد تزويد الشبكة بمجموعة التدريب كاملة. إذ أن الميول المحسوبة في كل مثال تدريبي تضاف لبعضها بعضاً لتحديد التغيرات في الأوزان والإنحيازات.

قاعدة دلتا المعممة (العامة) للتعليم (Generalised learning delta rule) :

وتعد 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 حسب الخطأ بين هذه المخرجات والمخرجات المعينة المطلوبة. ثم يتم العمل على تقليل قيم الخطأ من خلال نقله إلى طبقة المدخلات وتعديل الأوزان عندها. وإعادة حساب قيم المخرجات مرة أخرى. ثم إعادة حساب الخطأ بين المخرجات الجديدة والمخرجات المطلوبة. وإعادة هذه العملية مرات عدة إلى أن يتلاشى الخطأ وتصيح المخرجات المحسوبة مكافئة للمخرجات المطلوبة. وبذلك تتعلم الشبكة. حيث يعد عدد مرات التكرار مقياساً للتعلم (دريا 2014).

2-2-6 أنواع الشبكات العصبية الاصطناعية:

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

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 متجه الذي يعد إدخالاً للشبكة عند الزمن $t+1$ ، بعبارة أخرى فإن الطبقة الخفية مرتبطة ارتباطاً متكرراً متكاملًا. والمتجه يعاد خطوة واحدة خلال الشبكة. لذا فإن الإدخال للشبكة هو عبارة عن دالة لكل من المدخلات الجديدة والمتجه المخزن سابقاً والذي يمثل الإدخال في زمن معين ويعد إدخالاً للزمن السابق (Giles, 2001)

5-2-6 النموذج الرياضي لخلية عصبية :

يتكون النموذج الرياضي لخلية عصبية من: (دريال، 2014)

المدخل: (Input) نفرض أن قيم مخارج العصبونات السابقة للعصبون (الخلية العصبية) الحالية هي القيم (x_1, x_2, \dots, x_n) حيث تقوم المشابك 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:

$$Total\ input = w_1x_1 + w_2x_2 + w_3x_3 + \dots = \sum_{i=1}^n w_i x_i$$

مقارنة هذا المجموع بقيمة حدية لدالة في شكل عتبة (Step function) والمعروف بدالة (Heaviside) ، فإذا كان مجموع المدخل الموزونة أكبر من أو تساوي الدالة العتبية فإن المخرج سوف يكون مساوياً لواحد صحيح، وإذا كان المجموع أقل من قيمة الدالة العتبية فإن ناتج المخرج يصبح مساوياً لصفر.

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

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

الشبكات وحيدة الطبقة:

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

الشبكات العصبية المتعددة الطبقات : Multilayer neural networks

يتكون النموذج العام للشبكات العصبية المتعددة الطبقات من ثلاث طبقات هي: طبقة المدخل، والطبقة الخفية، وطبقة المخرج، وتم التعديل بإضافة طبقة مخفية بين طبقتي المدخل والمخرج واستخدام دالة سيغمويد (Sigmoid function) التي تحمل الخواص اللاخطية، ولذلك يلزم استحداث طريقة أخرى للتعليم تكون قادرة على التفاعل بين الطبقات الثلاث مثل: قاعدة دلتا المعممة (العامة)، أو قاعدة الانتشار الخلفي .

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

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

هناك مجموعة من النماذج المستخدمة في الشبكات العصبية الاصطناعية منها: (دريال، 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 إيجاد المنحنى المناسب لإعطاء النتائج الصحيحة. وتمزج هذه الشبكة نوعين من طرق تعليم الشبكات العصبية بحيث يكون التعليم بين طبقة الإدخال والطبقة الخفية هو تعليم بدون معلم، بينما يكون التعليم بين الطبقة الخفية وطبقة المخرجات تعليماً معلم، ويعتمد على نسبة الخطأ بالاعتماد على المخرجات (دريال، 2014).

ب. شبكة بيرسبترون متعدد الطبقات (MLP)

تعد من أكثر الشبكات استخداماً في التنبؤ بالسلاسل الزمنية، حيث تقوم فكرة هذه الشبكة على استخدام القيم السابقة للسلسلة الزمنية كمدخلات الشبكة، ويتم جميع 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 (دريال، 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 البيئية.

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

معاملات الأوزان:

يعد الوزن العنصر الرئيس في الشبكات العصبية الاصطناعية. فهي تمثل الروابط المختلفة التي يتم عبرها نقل البيانات من طبقة إلى أخرى. ويعبر الوزن عن القوة النسبية أو الأهمية النسبية لكل مدخل إلى عنصر المعالجة وتمثل الأوزان الوسيلة الأساسية لذاكرة الشبكة العصبية من خلال ضبط الأوزان ويرمز للوزن بين عنصري معالجة (i) و (j) بالرمز (wij) .

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 المصاحب. ومن ثم إيجاد المجموع لكل حواصل الضرب.

ويمكن تمثيل ذلك رياضياً كما يلي:

$$S_j = \sum_{i=1}^n x_{wij}$$

Sj: ناتج عملية الجمع لكل وحدة معالجة j

Xij: القيمة المدخلة القادمة من الوحدة (i) والداخلية إلى

الوحدة (j)

Wij: الوزن الذي يربط وحدة المعالجة (j) بالوحدة (i)

الموجودة في الطبقة السابقة.

دالة التحويل:

تتم 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 قبل المقارنة مع تابع تنشيط معين. وتتوقف مخرجات الشبكة بصورة أساسية على هذا التوزيع. وبناء على هذه التوابيع أو الدوال تعطي الشبكة مخرجات محصورة ضمن المجال (0, 1) أو المجال (-1, +1) ومن أهم توابيع التحويل أو توابيع 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 تركيبية الشبكة.

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

2. طبقة المخرجات:

تتكون 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 للبنية المعمارية للشبكة. وتستقبل وحدات المعالجة في طبقة المخرجات الإشارات القادمة إليها من طبقة المدخلات مباشرة أو من الطبقة الخفية. وبعد إجراء المعالجات اللازمة. قد ترسل إشارة بالمخرجات النهائية. أو قد تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة. وذلك عندما لا تماثل 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 البيئية فتقوم بمعالجتها ومن ثم إرسالها عبر الوصلات إلى طبقة المخرجات (العباسي، 2013).

4. الوصلات البيئية (الأوزان):

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

- دالة الخطوة: وهي الدالة التي تقع القيمة المخرجة فيها من وحدة المعالجة من (0 . 1)
- دالة الإثارة: وهي الدالة التي تقع القيمة المخرجة فيها من وحدة المعالجة من (1- . 1+)
- الدالة الخطية: وهي الدالة التي تكون فيها المخرجات تساوي المدخلات وتعطي تصنيفات متعددة وغير محدودة .
- دالة السيغمويد Sigmoid Function: هذه الدالة تجعل المخرجات أو تحويلها إلى قيمة محصورة بين (0 . 1) وتسمى في هذه الحالة بدالة تنشيط سيغمويد الثنائي. أو تحويل المخرجات إلى قيم بين (1- . 1+) وتسمى بدالة تنشيط سيغمويد ثنائي القطبية.
- دالة المخرجات: فقد تكون المخرجات في أغلب الأحيان مساوية لناج دالة التحويل. ولكن هناك بعض الشبكات تقوم وحدة المعالجة فيها بتعديل نتيجة دالة التحويل ويتم ذلك خلال تنافس وحدات المعالجة المتواجدة مع بعضها بعضا. ويتم التنافس عادة في وحدات المعالجة التي يكون لها تنشيط أكبر. هذه المنافسة تحدد وحدة المعالجة التي ستكون نشطة أو التي ستقوم بالإخراج.
- 7-2-6 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 تقسم البيانات المتوفرة إلى المجاميع التالية :
 - مجموعة التدريب Training Set: مجموعة تعليم وتحديد نموذج البيانات .
 - مجموعة الاختبار: Testing Set والتي يمكن عن طريقها تقرير مهارة الشبكة الافتراضية وامكانية استخدامها بصورة عامة.
 - مجموعة الشرعية Validation Set: وهي مجموعة لإجراء اختبار نهائي لأداء الشبكة.
- 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 لتقييم 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 اقل قيمة لمربع الخطأ.
 - خوارزمية شبكة الانتشار الخلفي للخطأ: وتستخدم 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 تغير البيانات. (أمين بك، 2005)
- 3-6 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 والمخرجات وبضمنها السلاسل الزمنية للمتغيرات المالية، والتي تتكون من عدد من المشاهدات Y_1, Y_2, \dots, Y_T حيث T تشير إلى الزمن. بحيث تتم عملية التنبؤ في كلا النموذجين باستخدام فترات التباطؤ (القيم السابقة) كمدخلات. للوصول إلى المخرجات التي تمثل القيم المستقبلية المتنبأ بها.
- ويمكن تمثيل العلاقة بين المدخلات والمخرجات في كلا النموذجين كما يلي:(الجراح، 2011)

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

عينة الدراسة وتفوقه على باقي النماذج الإحصائية الخطية المستخدمة الأخرى.

وتناولت دراسة Qwaider (2012) استخدام الشبكات العصبية الاصطناعية متعددة الطبقات (بيرسبترون) في التنبؤ بأسعار الأسهم في سوق الأوراق المالية الأردني خلال الفترة 2002/2 إلى 2004/1 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 بقيمة مؤشر سوق دمشق للأوراق المالية وإجاراتها ليوم التداول التالي. باستخدام سلسلة بيانات يومية خلال الفترة الواقعة بين 2010/1/4 و 2013/3/7. 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 دربال (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 الممتدة من 2006/2/22 إلى 2014/1/30. ودلت 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 عابد وعيساني (2016) إلى التعرف على أسلوب الشبكات العصبية الاصطناعية ومدى قدرتها على نمذجة عوائد مؤشرات الأسواق المالية للتنبؤ بمستوياتها المستقبلية. حيث قاما بتدريب الشبكة العصبية الاصطناعية بالاعتماد على بيانات السلسلة اليومية لعوائد مؤشر سوق دبي المالي للفترة 2006/12/4 إلى 2015/1/4. وإجراء عملية التنبؤ للفترة 2015/1/5 إلى 2015/2/3. وجاءت نتائج التنبؤ موافقة للقيم الفعلية إلى حد كبير. وهو ما يؤكد كفاءة نموذج الشبكات العصبية الاصطناعية على التنبؤ.

2-7 الدراسات الأجنبية:

هدفت دراسة (2000) Tabrizi & Panahiam 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 yt المشاهدة في الزمن t ، وتمثل m عدد المشاهدات السابقة والمستخدم للتنبؤ بالقيم المستقبلية للسلسلة الزمنية Y التي لها T من المشاهدات.

ومن هنا فإن 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 والحالة الخطية للبيانات كما في نموذج الانحدار الذاتي. حيث يصلح استخدامه أيضاً في الحالة غير الخطية. من خلال إجراء تدريب للشبكة للوصول إلى القيم المتنبأ بها. وإيجاد الأوزان التي تعمل على تخفيض مجموع مربعات الخطأ ما بين المخرجات المقدرة والحقيقية إلى أقل حد ممكن (الجراح، 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 والحمداني (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 المنشورة للشركات المساهمة المدرجة في سوق الأوراق المالية المصري. وتم استخدامها من قبل التلواني وسالم (2013) للتنبؤ بمعدلات الجريمة في قطاع غزة خلال الفترة 2008-2012. كما أن ساهد ومكديش (2014) استخدموا الشبكات العصبية للتنبؤ بأسعار البترول اليومية في الجزائر خلال الفترة الممتدة من 2010/1/1 وحتى 2011/12/31. فيما استخدمتها أبو عابدة (2015) للتنبؤ بأسعار الذهب العالمية للفترة 1985/1 إلى 2014/12. 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 السلاسل اليومية لتلك المؤشرات للفترة ما بين 2004/1/1 ولغاية 2004/10/16. وقد دلت النتائج على مدى القدرة الكبيرة لنموذج الشبكات العصبية ذات الانتشار العكسي للخطأ في التنبؤ المستقبلي بقيمة جميع المؤشرات الرئيسة 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 تمكن 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 المتغيرات 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 إقبال 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 (2013/9/1 - 2015/4/30) حيث تم مقارنة أداء
الشبكة العصبية الاصطناعية مقابل عوائد المؤشر الناتجة عن
إستراتيجية الشراء والبيع . وقد أظهرت الدراسة إمكانية التنبؤ
بقيمة المؤشر لليوم التالي بدرجة دقة بلغت 71% للشبكة
العصبية الاصطناعية. مقابل 47% لإستراتيجية الشراء والبيع.

واختبرت دراسة (Moghaddam et. al. (2016 قابلية
الشبكات العصبية الاصطناعية للتنبؤ بعوائد أسهم
NASDAQ 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
للمنموذج.

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 المثلى. حيث
استخدم الباحثان بيانات يومية خلال الفترة 2015/7/29 إلى
2015/11/15 لمؤشر BIST 100 مع إدخال بعض الأحداث
الاقتصادية ومؤشر أسعار العملات كمتغيرات. وتوصلت
الدراسة إلى أن شبكة MLP ذات الهيكلية 1-20-18 هي
الأفضل في التنبؤ تليها شبكة MLP ذات الهيكلية 1-16-18. وان
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 Nifty 50
باستخدام بيانات يومية خلال الفترة 2006/1/1 إلى 2016/3/31.
حيث أظهرت النتائج إ 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 بالتغيرات اليومية لآجهاات أسعار
الأسهم. وقد تم الاعتماد على بيانات الأسهم الخاصة وأسعار
الإقبال اليومية لمؤشر سوق اسطنبول للأسهم خلال الفترة
1998/1/5 - 2007/8/31 والتي جرى تقسيمها إلى مجموعتين :
إحدهما خصصت لتدريب الشبكة العصبية المستخدمة
(1998/1/5 - 2005/12/29). 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 لمؤشري
Standard & poor's 500 (S & P500) و Hang Seng (HIS)
باستخدام نموذج الشبكات العصبية الاصطناعية. حيث
استعمل العوائد السابقة كمدخلات بالمقارنة مع نموذج ARIMA
لمدة 80 و 35 سنة لكل من مؤشري (S & P500) و (HSI) على
التوالي. وقد تم اختبار صحة النموذجين من خلال فترة اختبار.
وبعد مقارنة صحة النموذجين من خلال معايير مختلفة. خلصت
الدراسة إلى أن نموذج الشبكات العصبية الاصطناعية أعطى
نتائج أفضل وتنبؤات أدق بكثير من نموذج ARIMA . مما 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
بالسلاسل الزمنية لأسعار الأسهم. وذلك باستخدام بيانات
عشرة أسهم مسجلة في سوق أوسلو للأسهم خلال الفترة
الممتدة 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 الاستثمارات 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).

ولتحليل ومناقشة بيانات الدراسة تم استخدام البرنامج الإحصائي Eviews 9.5 وهو برنامج متقدم في التحليل القياسي وبناء وتقدير النماذج الاقتصادية. والبرنامج التطبيقي Alyuda NeuroIntelligence وهو من البرامج الجاهزة سريعة الذكاء وسهلة الاستعمال وله عدة اختصاصات في حل العديد من المسائل المعقدة ومنها الشبكات العصبية الاصطناعية. بالإضافة إلى استخدام البرامج الإحصائية التقليدية Excell و SPSS.

مجتمع الدراسة:

يتمثل مجتمع الدراسة المراد التنبؤ بمؤشره في بورصة فلسطين. وفيما يلي تقديم لمحة موجزة عنها:

في مطلع عام 1995 أدرك عدد من رؤاد 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 طويل الأجل للمشاريع الإنتاجية ومشاريع البنية التحتية.

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

اعتمدت السوق في تموز 1997. رقما لقياس مستويات أسعار الأسهم. وتحديد الاتجاه العام لها. عرف باسم (مؤشر القدس). تم فيها اختبار 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 تجاوباً مع قواعد الحوكمة الرشيدة والشفافية. وفي أيلول 2010 أطلقت السوق عن هويتها المؤسسية الجديدة لتصبح (بورصة فلسطين) علامتها التجارية متخذة من (فلسطين الفرص) شعاراً لها.

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

وهدف دراسة (2017) Al Shajee إلى التنبؤ بأسعار الإغلاق المستقبلية لمؤشر داو جونز باستخدام نموذج مركب من الشبكة العصبية الاصطناعية ذات الانحدار الذاتي غير الخطية مع نموذج انحدار بمتغير خارجي exogenous. بالمقارنة مع خوارزميات مختلفة. حيث تم اختبار النموذج المركب باستخدام سلسلة بيانات يومية خلال الفترة 2010/1 إلى 2016/9 (1679 مشاهدة). وقد كانت فوائد هذا النموذج بأنه سريع التدريب 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 الاسواق 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 المرتكز 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 بمؤشر 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 المحكمة في الدوريات المتخصصة والمجلات العلمية. لتغطية الجانب النظري للدراسة.

الحسابي للسلسلة الزمنية 501.98 وانبساط معياري يساوي 34.41. ويتبين أيضا أن قيمة معامل الالتواء (skewness) 0.494. وهذا دليل على أن توزيع الأخطاء ملتو لجهة اليمين (التواء موجب). كذلك يختلف معامل التفلطح (kurtosis) بقليل عن قيمة (3) المميزة للتوزيع الطبيعي. حيث بلغ في هذه العينة 3.187 مما يدل على أن البواقي تتسم بالتفلطح. وبالتالي يختلف توزيع البيانات عن التوزيع الطبيعي. وهذا ما تؤكدته إحصائية (Jarque-Bera)، التي تشير إلى أن هذه البواقي لا تتبع التوزيع الطبيعي عند مستوى معنوية (5%). وهذه ميزة عامة للسلاسل الزمنية المالية.

حدود الدراسة:

اقتصرت الدراسة على بورصة فلسطين نظرا لتوفر سلسلة زمنية مناسبة لإجراء التحليل القياسي. أما حدود الدراسة الزمنية فتتمثل في الفترة الممتدة 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:

1-14 تطبيق نموذج الانحدار الذاتي:

بينت النتائج أن النموذج المفضل لسلسلة مؤشر القدس لبورصة فلسطين هو نموذج الانحدار الذاتي من الرتبة الثانية (AR2) حيث تم اختيار هذا النموذج حاسوبيا بناء على قيم المتغيرات المعنوية وقيمة معيار اكايكي AIC. وقد تم الحصول على قيم معاملات 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 بناء على مخرجات البرنامج الإحصائي Eviews 9.5

وتبين النتائج ان قيم معاملات النموذج θ_1 و θ_2 في النموذج المقدر كانت ذات دلالة إحصائية. حيث كانت القيم الاحتمالية لاختبار t اقل من 5%. وتبين 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 أسس 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.

تتمثل القيم والمبادئ الأساسية للبورصة في الحوكمة الرشيدة، وتحقيق العدالة، والشفافية، والكفاءة، وتوفير الفرص المتساوية لكافة المستثمرين. (معلومات أكثر يمكن الرجوع للموقع الإلكتروني لبورصة فلسطين www.pex.ps)

عينة الدراسة:

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

ويشير الجدول رقم (1) إلى الإحصاء الوصفي لسلسلة أسعار الإغلاق اليومية لمؤشر 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 التفلطح kurtosis | 3.187 |
| جاركو- بيرا Jarque-Bera | 83.65 |
| الاحتمالية sig. | 0.0000 |

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

ومن الجدول المذكور يتبين أن أصغر قيمة في السلسلة الزمنية كانت 416.26 و أكبر قيمة كانت 603.03 والمتوسط

ب. مرحلة التحليل : Analysis

بعد القيام بعملية تحليل الشبكة بينت النتائج ما يلي :

جدول (3):
نتائج عملية التحليل

| المجموعات | العدد | النسبة |
|-----------------|-------|--------|
| مجموعة التدريب | 1352 | 68.08% |
| مجموعة التأكيد | 317 | 15.96% |
| مجموعة الاختبار | 317 | 15.96% |
| مجموع المشاهدات | 1986 | 100% |

المصدر: من إعداد الباحث بناء على مخرجات البرنامج التطبيقي Alyuda NeuroIntelligence

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

ت. مرحلة المعالجة : Processing

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

جدول (4):
تمثيل البيانات

| البيانات | التمثيل |
|----------|-----------|
| المدخلات | (-1 ، +1) |
| المخرجات | (0 ، 1) |

المصدر: من إعداد الباحث بناء على البرنامج التطبيقي Alyuda NeuroIntelligence

ث. مرحلة التصميم : Design

في هذه المرحلة تم الاعتماد على الدالة اللوجستية logistic كدالة تحفيز في الطبقة الخفية وطبقة المخرجات، وبالاعتماد على برنامج Alyuda NeuroIntelligence تم ترشيح مجموعة من التصاميم للتنبؤ بمؤشر 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 D.W للارتباط الذاتي في بواقى النموذج، فتشير إلى عدم وجود ارتباط ذاتي في البواقى حيث كانت قيمتها قريبة من 2، وللتأكد من دقة هذه النتيجة، كون المتغيرات التفسيرية هي متغيرات متباطئة للمتغير التابع، تم احتساب قيمة مضاعف لاجرانج (LM) Lagrange Multiplier، وتبين النتائج في جدول (2) أن القيمة الاحتمالية لاختبار LM كانت أقل من 5% وهذه النتيجة تؤكد عدم وجود ارتباط ذاتي في البواقى، 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 بمؤشر القدس لبورصة فلسطين).

ولاختبار هذه الفرضية تم تطبيق نموذج الشبكات العصبية الاصطناعية للتنبؤ بمؤشر القدس لبورصة فلسطين وذلك وفق الخطوات التالية:

• اختيار نوع الشبكة المستخدمة:

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


• بناء الشبكة :

تمر 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، وهذا ما يتلاءم والمعالجات المقارنة مع النماذج السابقة (Lin et. al, 1995)

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)

$$P = (ai + 2)au + 1$$

حيث ان:

ai : تمثل عدد متغيرات الإدخال .

au : 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 التزايدي. حيث تم أليا من خلال برنامج Alyuda NeuroIntelligence تثبيت نسبة التعلم عند Learning Rate =

كما هو موضح في الشكل (1) فقد تم ترشيح خمس شبكات بمعماريات مختلفة للتنبؤ بمؤشر بورصة فلسطين. حيث تم اختيار المعمارية [2-7-1] من قبل برنامج Alyuda NeuroIntelligence اعتمادا على معيار اكايكي AIC، ومعيار درجة الملائمة (Fitness). حيث تشير النتائج في الشكل (1) إلى أن هذه المعمارية قد حصلت على اقل قيمة لمعيار اكايكي (الأعلى سلبية) وبلغت -8165. في حين كانت قيمة درجة الملائمة الأعلى بين القيم، حيث بلغت 0.301. إضافة إلى حصولها على معامل تحديد الذي بلغ 0.977 .

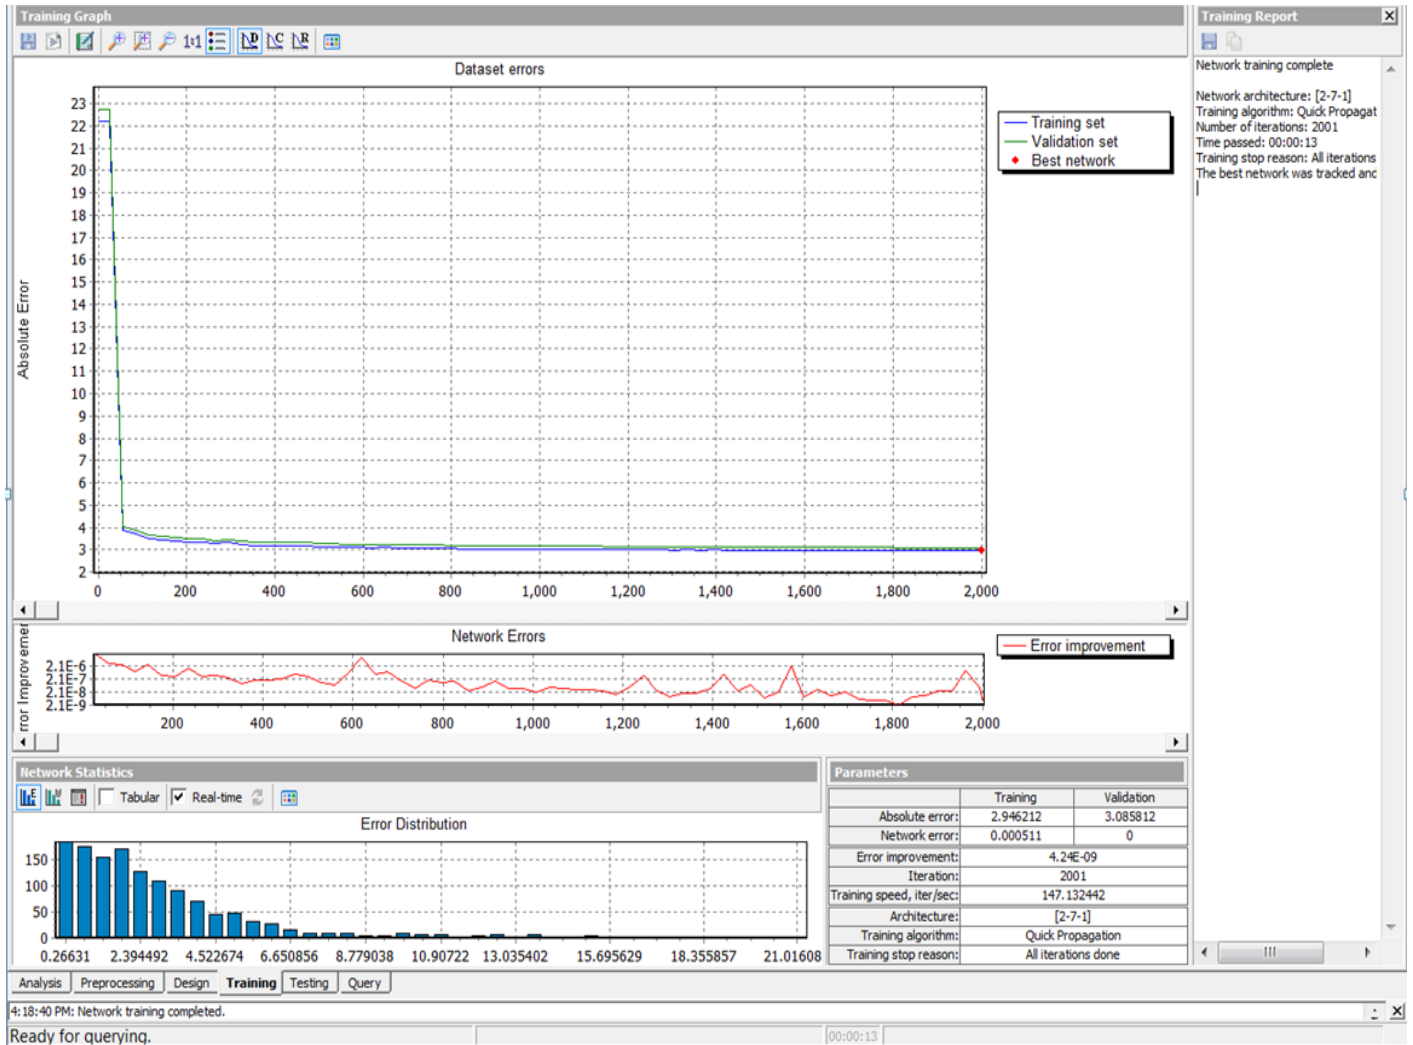
وعليه فان أفضل معمارية تتكون من ثلاث طبقات هي:

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

Learning Rate = تثبيت نسبة التعلم عند 0.1 و ثابت الزخم عند Momentum Constant = 0.1 و تم اعتماد عدد التكرارات = 2000. وقد كانت نتائج عملية التدريب كما يلي:

و ثابت الزخم عند 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 الخلفي التزايدى. حيث تم أليا من خلال برنامج Alyuda

الشكل (2):
نتائج عملية التدريب



المصدر : مخرجات البرنامج التطبيقي Alyuda NeuroIntelligence

التكرارات إلى أن تثبت بعد عدد التكرارات يساوي 1800. وهذا دليل أن الشبكة تدرت بشكل جيد ووصلت إلى مستوى مقبول إحصائيا.


ح. 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 سلكت مجموعة الشرعية سلوك مجموعة التدريب نفسها، وأن الخطأ المطلق لمجموعة التدريب كان أقل. أما منحنى الخطأ المطلق للشبكة فإنه يأخذ بالتناقص مع زيادة عدد مرات التكرار. كما يتبين من النتائج الواردة في الشكل السابق أن أفضل شبكة قد حددت عند عدد التكرارات يساوي 2000 . وأن أخطاء الشبكة وتوزيعها يتناقص مع زيادة عدد

الشكل (3): نتائج عملية الاختبار



المصدر: مخرجات البرنامج التطبيقي 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 أي 2018/2/4. وهكذا حتى نهاية الشهر مع الأخذ بالاعتبار عطله نهاية الأسبوع.

تبين من الشكل (3) أعلاه أن القيم التنبؤية (المخرجات) تحاكي القيم الأصلية بنسبة تزيد عن 95% خلال فترة الدراسة. إذ إن تطابق المنحنيين في معظم فترات الدراسة خير دليل على ذلك. ومنه يمكن اعتماد الشبكة الناجمة للتنبؤ بمؤشر 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 التطبيقي 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 الى 2018/2/28

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

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

الجذر التربيعي لمتوسط مربعات الأخطاء Root Mean Squared Error (RMSE)

متوسط القيم المطلقة للنسب المئوية للأخطاء Mean Absolute Percentage Error (MAPE)

أظهرت دراسة (Muttar, 2008) أنه من غير السليم الاعتماد على أحد المعايير السابقة وحده لتقييم دقة النموذج في التنبؤ. واقترحت استخدام متوسط مرجح (Weighted Average) للمعايير الثلاثة وفق ثلاث طرق. فقد تم استخدام المتوسطات المرجحة للمعايير الثلاث 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)
المفاضلة بين نموذجي ANN و AR

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

المصدر: من إعداد الباحث بناء على البرنامج الإحصائي Exell

ويتبين من الجدول رقم (6) أن هناك انخفاضاً ملحوظاً في قيم المعايير الثلاثة المحسوبة لكلا النموذجين وبالتالي قربها من القيم الفعلية. حيث تظهر قيمة MAPE أن القيم الفعلية بالمتوسط 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. ما يشير إلى أفضلية الشبكة العصبية الاصطناعية في التنبؤ.

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

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

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

ويوضح من النتائج في الجدول (5) أن قيم مؤشر القدس لبورصة فلسطين المقدرة أعطت مستويات ايجابية إذ يأخذ السوق الاتجاه الصاعد. وهذا الاتجاه للقيم المقدرة يتوافق 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. ما 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. وقبل 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 تمت في الأسواق الناشئة كدراسات (Aamodt 2010) و Tyagi et. al. و Sutheebanjard & Premchaiswadi (2010) وغيرها من الدراسات التي تمت في الأسواق الناشئة والمتقدمة 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 المفاضلة بين نموذج الانحدار الذاتي AR ونموذج الشبكة العصبية الاصطناعية ANN بالاعتماد على عدة معايير وهي: (مرهج. 2013)

متوسط القيمة المطلقة للأخطاء Mean Absolute 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 و MAPE وكذلك متوسطاتها المرجحة. ما 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 الناتجة ونموذج الانحدار الذاتي بالاستعانة بمعايير MAE و RMSE و MAPE وكذلك متوسطاتها 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 المتنبأ بها لمؤشر القدس لبورصة فلسطين خلال الفترة 2018/2/1 إلى 2018/2/28 كانت موجبة. ما 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 والمحللين 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 المركزي الفلسطيني للإحصاء في الدراسات التنبؤية التي يقوم بها.

قيام الباحثين بدراسة أنماط 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 الجدولية. 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 مربعات الفروق | درجات الحرية | متوسط المربعات | قيمة F | الاحتمال Sig. |
|----------------|---------------------|--------------|----------------|--------|---------------|
| بين المجموعات | 66.315 | 1 | 66.315 | | |
| خلال المجموعات | 213.028 | 38 | 5.606 | 11.829 | 0.001 |
| 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 Panda&Narasimhan (2006) و Kumar (2010) و Desai & Joshi (2015) التي تمت في الأسواق الناشئة. ويؤكد نتائجها في بورصة فلسطين.

خاتمة الدراسة:

يعد التنبؤ أحد أهم الموضوعات التي تناولتها الإدارة المالية وبالتحديد صناعة القرار الاستثماري في أسواق المال. وفي هذا الاتجاه 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 متعددة الطبقات تكونت من ثلاث طبقات (طبقة المدخلات (2)، طبقة خفية (7)، طبقة المخرجات (1)). وبعد تدريبها 2000 مرة

المراجع:

أولا: المراجع العربية

1. ابو عايدة. الفت فتحي. استخدام الطرق الاحصائية في التنبؤ بأسعار الذهب العالمية. رسالة ماجستير غير منشورة. جامعة الأزهر. 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 للسلاسل الزمنية بتطبيق على استهلاك الطاقة الكهربائية في مدينة الموصل. رسالة ماجستير غير منشورة. كلية العلوم. جامعة الموصل. العراق. (2005)
 4. التلواني. 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 والاقتصاد. السنة (34). العدد (89). (2011). ص ص 174-194
 6. دريال. أمينة. محاولة التنبؤ بمؤشرات الاسواق المالية العربية باستعمال النماذج القياسية: دراسة حالة مؤشر سوق دبي المالي. اطروحة دكتوراه غير منشورة. جامعة ابي بكر بلقايد. تلمسان. الجزائر. (2014).
 7. ساهد. عبد القادر. و مكيديش محمد . دراسة مقارنة بين الانحدار المبهم باستخدام البرمجة بالاهداف والشبكات العصبية الاصطناعية للتنبؤ بأسعار البترول. مجلة الباحث. عدد (14). (2014). ص ص 109-122.
 8. السراج. عمر والجميل سرمد. تقدير نماذج التنبؤ بأسعار الاسهم في اسواق رأس المال العربية. جامعة الموصل. مجلة تنمية الرافدين. المجلد (30). الاصدار(91). (2008). ص ص 9-47.
 9. الشرقاوي. محمد علي. الذكاء الاصطناعي والشبكات العصبية. مطابع المكتب المصري الحديث. القاهرة. (1996).
 10. عايد. احمد زقاي وعيساني عبد القادر. نمذجة 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. العباسي. عبد الحميد محمد. مقدمة في الشبكات العصبية الاصطناعية وتطبيقاتها في العلوم الاجتماعية باستخدام
- 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-الخوارزميات-التطبيقات. شعاع للنشر والعلوم. حلب. سورية. ط(1) . (2000)
 14. غولي. احمد سلطان والحمداني اسراء. استخدام نماذج الشبكات العصبية اصطناعية للتنبؤ بسعر الفائدة. مجلة ديالا للعلوم المصرفية. المجلد (6). العدد (2). (2010). ص ص 50-58.
 15. مرهج. منذر. التنبؤ بقيم مؤشر سوق دمشق للاوراق المالية باستخدام الشبكات العصبية الاصطناعية وإجهااتها. مجلة جامعة تشرين للبحوث والدراسات العلمية. سلسلة العلوم الاقتصادية والقانونية. المجلد (35). العدد (5). (2013). ص ص 243-260

ثانيا: المراجع الاجنبية

1. Aamodt, R., *Using Artificial Neural Networks to Forcast Financial Time Series, Master Thesis, Norwegian University of Science and Technology, Department of Computer and Information Science, (2010)*
2. Al Shaya, 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 Network: 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*

- International Review of Economics and Management*, Vol. (4), No. (3), (2016), p.p.26-46.
21. Tyagi, C., Singh H., Bhardnaji, V., Nagpal, K., *Application of Artificial Neural Network in Forecasting of Stock Market Index*, *International Journal of Recent Research in Mathematics Computer Science and Information Technology*, 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 Research*, 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)
 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, Assp 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 Proposed Technique for the Problem of Selecting the Best Forecasting 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, Inc*, 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/vol4/cs11/report.html
 18. Suthabanjard, P., Premchaiswadi, W., *Stock Exchange of Thailand Index Prediction Using Back Propagation 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*,

ثالثاً: المواقع الإلكترونية

1. موقع بورصة فلسطين www.pex.ps