

## التنبؤ بقيم مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية واتجاهاتها

الدكتور منذر مرهج\*

(تاريخ الإبداع 29 / 4 / 2013. قُبِلَ للنشر في 2 / 9 / 2013)

### □ ملخص □

إنّ الهدف من هذا البحث هو بناء شبكة عصبية اصطناعية ذات مواصفات مناسبة اعتماداً على خبرة الباحث وقاعدة التجربة والخطأ، وذلك من أجل التنبؤ بقيم مؤشر سوق دمشق للأوراق المالية واتجاهاتها ليوم التداول التالي. لقد تمّ تدريب الشبكة العصبية وفق خوارزمية التكاثر الارتدادي على مجموعة من المتغيرات التي جرى تحديدها وحسابها في ضوء الدراسات السابقة وأساليب التحليل الفني. البيانات المستخدمة جميعها تمّ الحصول عليها من الموقع الرسمي الالكتروني لسوق دمشق للأوراق المالية خلال الفترة الواقعة بين (2010/1/4 و 2013/3/7) والتي تمت معايرتها لتسهيل عملية التدريب. وقد أظهرت النتائج بأنّ 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، وبالتالي إمكانية اتخاذ قرارات استثمارية ناجحة في السوق المدروسة اعتماداً على هذه النتائج.

**الكلمات المفتاحية:** الشبكة العصبية الاصطناعية، مؤشر السوق، سوق دمشق للأوراق المالية، اتجاه السوق، التنبؤ.

\* مدرس - قسم إدارة الأعمال - كلية الاقتصاد - جامعة تشرين - اللاذقية - سورية.

## DWX Values & Trends prediction Using Artificial Neural networks\*

Dr. Mounzer A. Mourhij\*\*

(Received 29 / 4 / 2013. Accepted 2 / 9 / 2013)

### □ ABSTRACT □

the purpose of this research is to build a suitable artificial neural network depending on the researcher's experience, and trial & error base for predicting the values and trends of Damascus Securities Exchange Weighted Index (DWX) in the next trading day.

The neural network trained by back propagation algorithm on the set of variables determined and computed according to the literature review and technical analysis techniques.

All used data was driven from the website of (DSE) Damascus Securities Exchange through the period (4/1/2010 – 7/3/2013) which is also normalized to facilitate the training process.

The results showed that the trained neural network successfully had predicted the value of (DWX) in the next trading day with high degree of accuracy and less than 1% of error, therefore it may be made successful investment decisions in the studied market due to these results.

**Keywords:** Artificial neural network, market index, Damascus Securities Exchange, DSE, market trend, predict.

---

\* DWX means Damascus Securities Exchange Weighted Index, or DSE Weighted Index.

\*\* Assistant Professor in Business Administration Department – Faculty of Economic – Tishreen University.

**مقدمة:**

تشهد أسواق المال اهتماماً كبيراً من قبل الباحثين والمحللين الذين يحاولون التنبؤ باتجاهات السوق وأسعار الأدوات المالية المتداولة فيها وذلك اعتماداً على العديد من أساليب التنبؤ وأدواته التقليدية منها والحديثة، الأمر الذي يمكن من اتخاذ القرارات الاستثمارية المناسبة في الوقت المناسب على أساس أن المؤشر العام للسوق هو المرآة التي تعكس الحالة الاقتصادية للبلد ككل، والتي قد تساعد بدورها على التنبؤ بالحالة الاقتصادية المستقبلية بوصفها مؤشرات قائدة (هندي، 1999، ص. 297) تسبق الحالة الاقتصادية المتوقعة ضمن ظروف معينة خاصة بالسوق ودرجة كفاءتها واتساعها.

يتألف الاقتصاد السوري من قطاعات عدة متنوعة، إلا أن المؤشر العام لسوق دمشق للأوراق المالية يضم حالياً 22 سهماً تتبع خمسة قطاعات (قطاع المصارف 54.5%، وقطاع التأمين 27.3%، وقطاع الخدمات 9.1%، والقطاع الصناعي 4.5% والقطاع الزراعي 4.5%) وبالتالي فإن تطور هذا المؤشر حالياً لا يعكس حقيقة تطور النشاط الاقتصادي السوري، كما أنه لا يعتبر مؤشراً قانداً للدلالة على اتجاهات الاقتصاد (الميداني، 2011).

ومع تعدد أساليب التنبؤ المستخدمة وتطورها بين كثير من الباحثين كفاءة أسلوب الشبكات العصبية في التنبؤ وخاصة في مجال الأسواق المالية وتفوقها على غيرها من أساليب التنبؤ الأخرى، وبناءً على ما تقدم تبين للباحث ضرورة وأهمية بناء واستخدام شبكة عصبية اصطناعية للتنبؤ باتجاهات سوق دمشق للأوراق المالية تتناسب وطبيعة السوق ومكوناتها الحالية وقياس مدى دقتها في عملية التنبؤ، وتوظيف ذلك للتعرف على اتجاهات السوق واتخاذ القرارات الاستثمارية المناسبة تبعاً لذلك.

كما دفع الباحث لذلك أيضاً توفر البيانات الكافية للقيام بهذا العمل من جهة وكونها التجربة الأولى التي يقوم بها أحد الباحثين للتنبؤ باتجاه سوق دمشق للأوراق المالية باستخدام أسلوب حديث ودقيق يتجاوز كثيراً من المشكلات المتعلقة بالاختبارات الإحصائية اللازمة للتأكد من صلاحية نماذج التنبؤ التقليدية وخاصة الخطية منها بسبب عدم قدرتها على اكتشاف العلاقات غير الخطية لبيانات سوق الأوراق المالية (Gunasekaran & Ramaswami, 2011, P. 968).

**مشكلة البحث:**

انطلاقاً من أهمية التنبؤ بأسعار إقبال الأوراق المالية وقيم مؤشر السوق من قبل المستثمرين والمحللين والمهتمين على مختلف الصعد، فقد قام كثير منهم باستخدام العديد من أساليب التحليل الفني والإحصائي في سبيل ذلك، إلا أن اختبارات مدى ملائمة ودقة النماذج المستخدمة ومدى قدرتها على اكتشاف العلاقات غير الخطية بين بيانات السوق قد صعبت من عمليات التنبؤ وإمكانية اعتماد نتائجها في اتخاذ قرارات استثمارية سليمة وناجحة.

اعتماداً على ما تقدم وعلى طبيعة سوق دمشق للأوراق المالية وحدثه وضيقة، فإنه يمكن التعبير عن مشكلة البحث من خلال طرح التساؤلات التالية:

- هل يمكن التنبؤ بقيم مؤشر سوق دمشق للأوراق المالية؟.
- هل يمكن التنبؤ باتجاه مؤشر سوق دمشق للأوراق المالية؟.

- هل يمكن استخدام الشبكات العصبية الاصطناعية للتنبؤ بقيم واتجاهات مؤشر سوق دمشق للأوراق المالية لفترة مستقبلية قصيرة (يوم التداول التالي)؟.

- هل يمكن اعتماد نتائج تنبؤات الشبكات العصبية الاصطناعية المستخدمة في اتخاذ قرارات استثمارية هامة؟.

### أهمية البحث وأهدافه:

رغم وجود العديد من الدراسات التي تناولت موضوع التنبؤ بقيم مؤشرات أسواق رأس المال المختلفة، تأتي أهمية البحث كونه من أوائل الأبحاث التي تدرس إمكانية استخدام أسلوب الشبكات العصبية الاصطناعية للتنبؤ بقيم مؤشر سوق دمشق للأوراق المالية واتجاهاتها بشكل تطبيقي، وما يحققه ذلك من فوائد لمتبعي أحوال السوق من محللين ومستثمرين، سواء من خلال توفير أسلوب واضح وسهل الاستخدام للتنبؤ بتغيرات مؤشر السوق أو أدواته أو من خلال دقة التنبؤ التي يحققها مقارنة بأساليب التنبؤ التقليدية الأخرى وأثر ذلك في اتخاذ القرارات الاستثمارية السليمة والناجحة المبنية على هذه التنبؤات.

ومن ناحية أخرى يهدف هذا البحث للتأكد من إمكانية التنبؤ المسبق بقيم واتجاهات مؤشر سوق دمشق للأوراق المالية بدرجة عالية من الدقة، وكذلك تحديد بنية ومواصفات أفضل شبكة عصبية اصطناعية يمكن استخدامها لهذا الغرض وتدريبها على عدد كاف من أمثلة التدريب (درجات الحرية) اعتماداً على خبرة الباحث، وتعديل مواصفات الشبكة تبعاً لقاعدة التجربة والخطأ وذلك من أجل تجنب مشكلة التشبع أو التدريب المفرط over fitting المرتبطة بزيادة عدد أمثلة التدريب أو مشكلة التدريب الناقص المرتبطة بقلّة عدد المعاملات أو أمثلة التدريب وما يسببه ذلك من فشل الشبكة في التعرف على العلاقات جميعها بين المتغيرات (Kazem & Mutlag, 2005, P. 498).

### منهجية البحث:

اعتمد الباحث منهج الاستقراء العلمي لتحليل البيانات الثانوية المنشورة عن أسعار إقفال مؤشر سوق دمشق للأوراق المالية وأحجام التداول خلال فترة الدراسة المقترنة بفترة احتساب المؤشر من 2010/1/4 ولغاية 2013/3/7، حيث تمّت تهيئة البيانات المستخدمة تمهيداً لاستخدامها في عملية تدريب واختبار الشبكة العصبية وذلك من خلال استخدام دوال المعايير المناسبة للحدّ من تشتت البيانات وتتميطها ضمن مجال محدد لإنجاح عملية تدريب الشبكة وتعليمها من أجل اكتشاف العلاقات الصحيحة بين المدخلات والمخرجات.

كما تمّ تحديد وحساب قيم جميع متغيرات المدخلات والمخرجات اللازمة خلال مرحلة التدريب والاختبار وتجريب واختبار عدة بنى وأشكال للشبكات وصولاً إلى أفضل شبكة عصبية يمكن استخدامها للتنبؤ بقيم المؤشر ليوم التداول التالي، وتمّ بعد ذلك اعتماد مجموعة من المقاييس المناسبة لتقييم كفاءة الشبكة العصبية المستخدمة في عملية التنبؤ، ومدى إمكانية الاعتماد على نتائجها لاتخاذ القرارات الاستثمارية المناسبة، وبالتالي إثبات فرضية البحث.

### الدراسات السابقة:

هناك كثير من الدراسات السابقة التي تناولت موضوع التنبؤ باستخدام الشبكات العصبية الاصطناعية سواء منها المتعلقة بالأسواق المالية أم غيرها من التطبيقات المالية وغير المالية الأخرى، وقد شهدت أساليب التنبؤ هذه تطوراً كبيراً من حيث القدرات والكفاءة مما دفع الباحث للاكتفاء بعرض أهم وأحدث تلك الدراسات المتعلقة بموضوع البحث مرتبة حسب تسلسلها التاريخي، مع الإشارة إلى إمكانية الاطلاع على مزيد من الدراسات الأخرى، حيث لخص

(Zhang, G. et al., 1998, P. 53) عدداً من الدراسات (24 دراسة) التي تمت بين العام 1989 والعام 1996 وقرن نتائج أداء الشبكات العصبية المستخدمة بأداء الأساليب الإحصائية التقليدية حيث بينت نتائج غالبية تلك الدراسات تفوقاً واضحاً لأداء الشبكات العصبية على أداء الأساليب الأخرى.

في حين أجرى (Dase & Pawar, 2010) مسحاً لـ 32 دراسة أخرى أجريت خلال الفترة (1991-2010) في مجال تطبيقات الشبكات العصبية الاصطناعية للتنبؤ في أسواق الأوراق المالية، وفيما يلي عرضاً لأهم وأحدث الدراسات التي رصدها الباحث:

دراسة (Tabrizi & Panahiam, 2000) هدفت هذه الدراسة إلى التنبؤ بمؤشر سوق طهران للأوراق المالية T.S.E. بالاعتماد على الشبكات العصبية الاصطناعية، وقد تم استخدام عدة قيم إبطاء لمؤشر سوق طهران للأوراق المالية TEPIX خلال الفترة (1995-1999) إلى جانب بعض مؤشرات التحليل الفني وعناصر التحليل الأساسي، وقد بينت نتائج الدراسة قدرة الشبكة على التنبؤ والمساهمة في تحقيق عوائد سنوية أكبر مما هو مع النماذج الأخرى كالانحدار والأساليب الإحصائية التقليدية.

دراسة (Hamid & Iqbal, 2004) هدفت هذه الدراسة إلى التنبؤ بتقلبات أسعار مؤشر العقود المستقبلية S&P 500 اعتماداً على بيانات أسعار 16 عقداً مستقبلياً وثلاثة مؤشرات أسواق حاضرة DJIA, NYSE Composite S&P 500، وقد تم استخدام أسلوب الشبكات العصبية الاصطناعية إلى جانب نموذج تنبؤ آخر BAW، وقد دلت نتائج الدراسة على تفوق أسلوب الشبكات العصبية الاصطناعية في عملية التنبؤ على النموذج الآخر.

دراسة (Panda & Narasimhan, 2006) هدفت هذه الدراسة إلى استخدام أسلوب الشبكات العصبية الاصطناعية للتنبؤ بقيمة مؤشر سوق بومباي للأوراق المالية BSE وعوائد مؤشر Sensitive Index (Sensex) 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 (Sensex)، كما أظهرت إمكانية التنبؤ بعوائد سوق بومباي للأوراق المالية بسبب السلوك غير العشوائي لأسعار إقفال وعوائد مؤشراتهما، كما تبين أيضاً قدرة أسلوب الشبكات المستخدم على تمثيل العلاقات غير الخطية بين عوائد السهم.

دراسة (Thenmozhi, 2006) هدفت هذه الدراسة إلى التنبؤ بمعدلات العوائد اليومية لسوق بومباي للأسهم B. S. E.، وقد دلت النتائج على تأثر القوة التنبؤية بعوائد اليوم السابق مباشرة وبشكل أعلى من مدخلات أول ثلاثة أيام، كما بينت إمكانية استخدام الشبكات العصبية للتنبؤ بسوق بومباي.

دراسة (Senol, 2008) هدفت هذه الدراسة إلى اختبار مدى قدرة الشبكة العصبية الاصطناعية في التفوق على الأساليب الأخرى كنماذج الانحدار للتنبؤ بالتغيرات اليومية لاتجاهات أسعار الأسهم، وقد تم الاعتماد على بيانات الأسهم الخاصة وأسعار الإقفال اليومية لمؤشر سوق اسطنبول للأسهم ISE-30 خلال الفترة 1998/1/5 - 2007/8/31 والتي جرى تقسيمها إلى مجموعتين إحداهما 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.

**دراسة (Aamodt , 2010)** هدفت هذه الدراسة إلى تقصي إمكانية تطبيق أسلوب الشبكات العصبية الاصطناعية للتنبؤ بالسلاسل الزمنية المالية مثل أسعار الأسهم، وقد تمّ اختبار هذا الأسلوب 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 التدرّب والتنبؤ بتقلبات أسعار الأسهم.

**دراسة (Larsen, 2010)** هدفت هذه الدراسة إلى استخدام بيانات الأسعار التاريخية للأسهم من أجل التنبؤ بالأسعار المستقبلية للأسهم اعتماداً على استخدام شبكة عصبية اصطناعية مؤلفة من طبقتين، وقد بينت النتائج تفوق أداء نموذج التنبؤ المستخدم على أداء المؤشر المرجعي لسوق أوسلو للأسهم (OSEBX) بمقدار 250% خلال الفترة (كانون الثاني 2009 – أيار 2010).

**دراسة (Majumdar & Hussian, 2010)** هدفت هذه الدراسة إلى التنبؤ باتجاه حركة مؤشر سوق الأسهم الهندي S&P CNX Nifty 50 بالاعتماد على شبكة عصبية اصطناعية مؤلفة من ثلاث طبقات تمّ تدريبها على بيانات أيام التداول خلال الفترة (2009/12/31-2000/1/1) وتدقيقها على بيانات أربع سنوات، وقد تمّ اختبار دقة النتائج من خلال عدة مقاييس لتقييم الأداء، وقد بلغ متوسط دقة التنبؤ باتجاه السوق 69.72% خلال أربع سنوات.

**دراسة (Mehrra et al., 2010)** هدفت هذه الدراسة إلى التنبؤ بمؤشر سوق طهران للأوراق المالية TEPIX باستخدام نوعين من الشبكات العصبية، وقد تمّ استخدام رقم المؤشر والمعدّلات المتحركة البسيطة والمرجحة كمدخلات للشبكات المستخدمة، وقد دلت نتائج الدراسة على تفوق المعدّلات المتحركة المرجحة على المعدّلات المتحركة البسيطة، كما دلت على تفوق الشبكة العصبية المعتمدة على الخوارزمية الوراثية على الشبكة العصبية متعددة الطبقات ذات الانتشار الارتدادي في عملية التنبؤ بمؤشر سوق طهران للأوراق المالية.

**دراسة (Naeni et al., 2010)** هدفت هذه الدراسة إلى التنبؤ بتغيرات أسعار أسهم الشركات باستخدام نوعين من الشبكات العصبية الاصطناعية إلى جانب أسلوب الانحدار الخطي البسيط، وقد تمّ الحصول على البيانات الخاصة بـ 1094 شركة من الموقع الإلكتروني لسوق طهران للأسهم، وتوصلت الدراسة إلى أنّ أخطاء التنبؤ في الشبكات العصبية الاصطناعية متعددة الطبقات كانت أقلّ مما هي في الأسلوبين الآخرين.

**دراسة (Sutheebanjard & Premchaiswadi, 2010)** هدفت هذه الدراسة إلى التنبؤ بحركة مؤشر سوق تايلاندا للأوراق المالية SET وسوق الاستثمارات البديلة MAI وذلك باستخدام شبكة عصبية اصطناعية ذات انتشار ارتدادي، وقد تمّ استخدام بيانات 124 يوم تداول ممتدة من 2004/7/2 ولغاية 2004/12/30 قسّمت 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 أقلّ من 2%.

**دراسة (Desai et al., 2011)** هدفت هذه الدراسة كما في دراسة (Majumdar & Hussian, 2010) إلى التنبؤ باتجاه مؤشر سوق الأسهم الهندي S&P CNX Nifty 50 باستخدام شبكة عصبية اصطناعية وذلك من خلال التنبؤ بتغير قيمة المتوسط المتحرك البسيط لقيمة المؤشر المذكور لمدة سبعة أيام تداول، وقد تمّ تدريب الشبكة المستخدمة على بيانات أسعار إقبال مؤشر السوق لأيام التداول خلال الفترة (2009/9/1 – 2011/4/30)، ثمّ استخدمت الشبكة المدربة للتنبؤ باتجاه السوق خلال خمسة أشهر، وبالمقارنة مع إستراتيجية الشراء والاحتفاظ بيّنت الدراسة أنّ أداء الشبكة العصبية كان أفضل وأكثر دقة.

**دراسة (Gunasekaran & Ramaswami, 2011)** هدفت هذه الدراسة إلى التنبؤ باتجاه سوق بومباي للأوراق المالية باستخدام نظام اصطناعي ذي كفاءة في التدرّب والتذكر وكذلك شبكة عصبية اصطناعية، وقد تمّ تدريب الأسلوبين المستخدمين على بيانات يومية لقيم المؤشر الهندي Indian BSE SENSEX خلال الفترة (2009/1/2 – 2009/7/31) واختبارهما على بيانات يومية خلال الفترة (2009/8/3 – 2010/7/30)، وقد أظهرت نتائج الدراسة أنّ نظام التنبؤ الاصطناعي المستخدم كان أكثر كفاءة من الشبكة العصبية الاصطناعية في التنبؤ باتجاه السوق.

**دراسة (Kara et al., 2011)** هدفت هذه الدراسة إلى التنبؤ باتجاه الحركة اليومية لمؤشر سوق أسهم اسطنبول ISE National 100 باستخدام أسلوب الشبكات العصبية إلى جانب أسلوب آخر وذلك بالاعتماد على مؤشرات التحليل الفني، وقد تمّ استخدام البيانات اليومية لمؤشر السوق خلال الفترة (1997 – 2007)، وقد أكّدت نتائج الدراسة كفاءة النموذجين المستخدمين في التنبؤ باتجاه حركة أسعار الأسهم، لكنّ أسلوب الشبكات العصبية الاصطناعية كان أكثر دقة في التنبؤ بدرجة بلغت 75.74% مقارنة بـ 71.52% للأسلوب الآخر، كما أنّ استخدام متغيرات أخرى في النموذج قد يحسّن من درجة دقة التنبؤ أيضاً.

**دراسة (Desai et al., 2013)** هدفت هذه الدراسة إلى التنبؤ باتجاه حركة وقيمة إقبال مؤشر سوق الأسهم الهندي S&P CNX Nifty 50 ليوم التداول التالي، وقد اعتمدت هذه الدراسة على استخدام شبكة عصبية اصطناعية مؤلفة من ثلاث طبقات (1-5-4) جرى تدريبها واختبارها على بيانات أيام تداول السوق خلال الفترة (2010/1/1 – 2011/12/30) من خلال استخدام أربع متغيرات لطبقة المدخلات تمثل قيم إبطاء مؤشر السوق لأربع فترات، وقد أظهرت الدراسة إمكانية التنبؤ بقيمة المؤشر لليوم التالي بدرجة دقة 82%.

كما رصد الباحث دراسة عربية ترتبط بموضوع البحث بشكل مباشر، هي **دراسة (السراج والجميل، 2008)** حيث اعتمدت هذه الدراسة 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 الزمنية لتلك المؤشرات خلال الفترة الممتدة من 2004/1/1 وحتى 2004/10/16، وقد دلّت نتائج الدراسة على مدى قدرة نموذج الشبكات العصبية الاصطناعية ذات الانتشار العكسي أو الارتدادي للخطأ في التنبؤ وتفوقه على باقي النماذج الإحصائية الخطية المستخدمة الأخرى.

وبعد الدراسة والتحليل وجد الباحث أنّ الدراسة الحالية تختلف عن الدراسات السابقة التي تم استعراضها أو الإشارة إليها في مراجعها وذلك من ناحية مكان التطبيق وطبيعة وخصائص السوق المدروسة وحدثة الفترة الزمنية للدراسة وبنية الشبكة العصبية الاصطناعية المستخدمة ودرجة دقة التنبؤ المستهدفة واختلاف منهجية الدراسة وأسلوبها في اختبار كفاءة نموذج التنبؤ المستخدم.

## النتائج والمناقشة:

### فرضية البحث:

يقوم هذا البحث على فرضية رئيسية تمت صياغتها على النحو الآتي:  
**من الممكن التنبؤ وبدرجة عالية من الدقة بقيمة واتجاه مؤشر سوق دمشق للأوراق المالية ليوم التداول التالي باستخدام أسلوب الشبكات العصبية الاصطناعية.**

### الشبكات العصبية الاصطناعية

الشبكات العصبية الاصطناعية هي إحدى منتجات الذكاء الاصطناعي التي تضم مجموعات مترابطة من الخلايا العصبية الاصطناعية التي تحاكي عمل الشبكات العصبية البيولوجية للمخ البشري في التعلم والتذكر والمحاكاة المنطقية المبنية على التجارب والخبرة السابقة المكتسبة، والاستفادة من إمكانيات وسرعة الحاسبات المستخدمة لتطبيق النماذج والأساليب اللامعلمية في تحليل البيانات.

ومع التقدم الكبير في تكنولوجيا الحاسبات والفهم الواسع لآلية النظام العصبي البشري، ازداد الاهتمام بتطوير الشبكات العصبية الاصطناعية واستخدامها كبديل للأساليب التقليدية المستخدمة في العديد من المجالات المختلفة فيما يخص عمليات التنبؤ والتحكم، وذلك نظراً لما تبديه من دقة و تفوق في الأداء وتحديد العلاقات المتنوعة والمعقدة بين المتغيرات المختلفة.

تتألف الشبكة العصبية الاصطناعية من مجموعة من الخلايا العصبية الاصطناعية Neurons التي تجتمع بشكل مصفوفي ضمن طبقات Layers متصلة مع بعضها البعض، بالشكل الذي يجعل مخرجات كل طبقة هي مدخلات للطبقة التالية لها، عدا الطبقة الأولى التي تتلقى البيانات كمدخلات من الوسط الخارجي، والطبقة الأخيرة التي تعطي المخرجات المطلوبة (مرهج، 2003، ص. 61).

ومع تنوع أشكال الشبكات العصبية الاصطناعية واختلاف تراكيبها وشكل اتصال خلاياها العصبية ببعضها فإن الشبكة متعددة الطبقات Multi-Layer هي الأكثر شيوعاً واستخداماً، حيث تتألف الشبكة العصبية من ثلاث طبقات كحد أدنى:

أ- طبقة المدخلات Input Layer: التي تستقبل البيانات المدخلة من خارج الشبكة، ويتحدد عدد الخلايا العصبية فيها بعدد متغيرات المدخلات.

ب- الطبقة الخفية Hidden Layer: والتي تتصل مع الطبقات السابقة واللاحقة لها دون الاتصال مع الوسط الخارجي للشبكة بأية مدخلات أو مخرجات، وقد تضم الشبكة أكثر من طبقة خفية واحدة، وتتم في هذه الطبقة عملية تدريب وتعليم الشبكة.

ج- طبقة المخرجات Output Layer: تستقبل كل خلية فيها مدخلاتها من جميع خلايا الطبقة الخفية السابقة لها، ويتحدد عدد خلايا هذه الطبقة بعدد متغيرات المخرجات المطلوبة.

وبعد بناء الشبكة العصبية الاصطناعية وتحديد خصائصها يتم تدريبها من خلال مجموعة من البيانات المخصصة لهذه الغاية Training Set والتي تتضمن أمثلة وحالات على شكل مدخلات ومخرجات غير محددة العلاقة فيما بينها، يتم إدخالها إلى الشبكة لتحللها وتحدد علاقاتها وتتعلم منها وتخزنها في ذاكرتها كأساس معرفي تستند إليه لتحديد المخرجات الخاصة بأية مدخلات جديدة يتم إدخالها إلى الشبكة.

وأثناء عملية التدريب يتم تعديل الأوزان المعطاة لمدخلات الخلايا بمعدل تعلم وحساب العلاقات بين مدخلات ومخرجات الخلايا من جديد، وإعطاء مخرج جديد يتزايد في الاتجاه الذي يقلل من حدّ الخطأ، وتتكرر هذه العملية حتى الوصول إلى أدنى درجة مقبولة من الخطأ أو أقصى درجة مقبولة من الدقة.

وخلال هذه العملية يتم اختبار الشبكة العصبية الاصطناعية باستخدام مجموعة من البيانات المخصصة لذلك من أجل التأكد من دقة نتائج الشبكة وقدرتها في التنبؤ من خلال مقارنة مخرجاتها مع مخرجات أو نتائج معروفة مسبقاً.

ويعد الانتهاء من عملية التدريب والاختبار يتم التعامل مع الشبكة المدربة كصندوق مغلق يتضمن علاقات محسوبة ومختزنة بين متغيرات كل طبقة ومتغيرات الطبقة التالية لها.

ومع إدخال مجموعة جديدة من البيانات إلى الشبكة المدربة والمختبرة، يتم الحصول على مخرجات جديدة هي النتائج المطلوبة والمرتبطة بهذه البيانات الجديدة.

#### متغيرات المدخلات:

من خلال تحليل الدراسات والأبحاث السابقة ذات العلاقة وحصر أهم أدوات التحليل الفني المستخدمة في تحليل وتتبع تطورات أسعار مؤشرات الأسواق المالية والأدوات المتداولة فيها، قام الباحث بتحديد وحساب قيمة 27/ متغيراً اعتماداً على البيانات الثانوية الخاصة بسوق دمشق للأوراق المالية خلال الفترة الممتدة من تاريخ البدء بحساب مؤشر السوق في 2010 / 1/4 وحتى 2013/3/7 والمنشورة على الموقع الإلكتروني للسوق وذلك كما هو مبين في الجدول التالي رقم (1).

الجدول رقم (1) متغيرات مدخلات الشبكة العصبية الاصطناعية المستخدمة

تسلسل	رمز المتغير	المتغير	وصف المتغير
1	CP <sub>t</sub>	Closed Price <sub>t</sub>	سعر إقفال مؤشر سوق دمشق للأوراق المالية لليوم t وهو منشور على موقع السوق <a href="http://www.dse.sy">www.dse.sy</a> .
2	CP <sub>t-1</sub>	Closed Price <sub>t-1</sub>	إبطاء السلسلة الزمنية لسعر إقفال المؤشر لفترة زمنية واحدة، أي سعر إقفال مؤشر سوق دمشق للأوراق المالية لليوم السابق t-1.
3	CP <sub>t-2</sub>	Closed Price <sub>t-2</sub>	إبطاء السلسلة الزمنية لسعر إقفال المؤشر لفترتين زمنيتين، أي سعر إقفال مؤشر سوق دمشق للأوراق المالية لليوم ما قبل السابق t-2.
4	%C <sub>t</sub>	Percentage Change	النسبة المئوية للتغير في سعر إقفال مؤشر سوق دمشق للأوراق المالية لليوم t، أو ما يسمى أيضاً مؤشر الأداء، $C_t = \frac{CP_t - CP_{t-1}}{CCP_{t-1}}$
5	VT <sub>t</sub>	Volume Traded	حجم التداول في سوق دمشق للأوراق المالية لليوم t، وهو منشور على موقع السوق <a href="http://www.dse.sy">www.dse.sy</a> .
6	SMA7	Simple Moving Average 7 Days	المتوسط المتحرك البسيط لسعر إقفال مؤشر سوق دمشق للأوراق المالية لفترة سبعة أيام تداول تنتهي في اليوم t
7	SMA14	Simple Moving Average 14 Days	المتوسط المتحرك البسيط لسعر إقفال مؤشر سوق دمشق للأوراق المالية لفترة أربعة عشر يوم تداول تنتهي في اليوم t
8	SMA21	Simple Moving Average 21 Days	المتوسط المتحرك البسيط لسعر إقفال مؤشر سوق دمشق للأوراق المالية لفترة واحد وعشرين يوم تداول تنتهي في اليوم t
9	SMA28	Simple Moving Average 28 Days	المتوسط المتحرك البسيط لسعر إقفال مؤشر سوق دمشق للأوراق المالية لفترة ثمانية وعشرين يوم تداول تنتهي في اليوم t

مؤشر القوة النسبية لـ 7 أيام، يقاس بحساب القوة النسبية RS من خلال تقسيم متوسط التغيرات الموجبة في قيم المؤشر خلال 7 أيام على متوسط التغيرات السالبة في قيم المؤشر خلال 7 أيام، ومن ثم: $RSI7=100-1/(1+RS7)$	Relative Strength Index 7 Days	RSI 7	10
مؤشر القوة النسبية لـ 14 يوماً، يحسب بنفس طريقة حساب RSI7 ولكن خلال فترة 14 يوم.	Relative Strength Index 14 Days	RSI 14	11
مؤشر القوة النسبية لـ 21 يوم، يحسب بنفس طريقة حساب RSI14 ولكن خلال 21 فترة يوم.	Relative Strength Index 21 Days	RSI 21	12
مؤشر القوة النسبية لـ 28 يوم، يحسب بنفس طريقة حساب RSI21 ولكن خلال فترة 28 يوم.	Relative Strength Index 28 Days	RSI 28	13
مؤشر التقلب العشوائي لـ 7 أيام	Stochastic Indicator 7 Days	%K7	14
المتوسط المتحرك البسيط لقيم %K7 لثلاث فترات تنتهي في اليوم t	3 Days Simple Moving Average of %K7	7%D3	15
المتوسط المتحرك البسيط لقيم %K7 لسبع فترات تنتهي في اليوم t	7 Days Simple Moving Average of %K7	7%D7	16
مؤشر التقلب العشوائي لـ 14 يوم	Stochastic Indicator 14 Days	%K14	17
المتوسط المتحرك البسيط لقيم %K14 لثلاث فترات تنتهي في اليوم t	3 Days Simple Moving Average of %K14	14%D3	18
المتوسط المتحرك البسيط لقيم %K14 لسبع فترات تنتهي في اليوم t	7 Days Simple Moving Average of %K14	14%D7	19
مؤشر التقلب العشوائي لـ 21 يوم	Stochastic Indicator 21 Days	%K21	20
المتوسط المتحرك البسيط لقيم %K21 لثلاث فترات تنتهي في اليوم t	3 Days Simple Moving Average of %K21	21%D3	21
المتوسط المتحرك البسيط لقيم %K21 لسبع فترات تنتهي في اليوم t	7 Days Simple Moving Average of %K21	21%D7	22
مؤشر التقلب العشوائي لـ 28 يوم	Stochastic Indicator 28 Days	%K28	23
المتوسط المتحرك البسيط لقيم %K28 لثلاث فترات تنتهي في اليوم t	3 Days Simple Moving Average of %K28	28%D3	24
المتوسط المتحرك البسيط لقيم %K28 لسبع فترات تنتهي في اليوم t	7 Days Simple Moving Average of %K28	28%D7	25
مؤشر حجم التداول الإيجابي، ويحسب من خلال العلاقة: $PVI_t = PVI_{t-1} + [(CPI_t - CPI_{t-1}) / CPI_{t-1}] * PVI_{t-1}$	Positive Volume Index	PVI	26
مؤشر حجم التداول السلبي، ويحسب من خلال العلاقة: $NVI_t = NVI_{t-1} + [(CPI_t - CPI_{t-1}) / CPI_{t-1}] * NVI_{t-1}$	Negative Volume Index	NVI	27

وفيما يخص عدد الخلايا العصبية في كل طبقة، فقد تم تخصيص خلية عصبية اصطناعية واحدة لكل متغير من متغيرات المدخلات بالنسبة لطبقة المدخلات، أما طبقة المخرجات فتم تخصيص خلية واحدة للمخرج المطلوب (سعر إقبال المؤشر ليوم التداول التالي)، أما الطبقة الخفية حيث لا توجد قاعدة محددة لعدد خلاياها، فرغم أن البعض يوصي بتحديد عددها بمتوسط عدد خلايا المدخلات والمخرجات، إلا أن عدد الخلايا الخفية نفسها قد يختلف من طبقة خفية لأخرى ضمن الشبكة نفسها، وبالتالي يتم تحديدها بشكل تقديري، ومن ثم تعديل عددها تبعاً للنتائج التي تحققها الشبكة ومعدل خطأ التنبؤ فيها.

### تدريب الشبكة العصبية الاصطناعية:

قام الباحث بجمع البيانات الثانوية الخاصة بأسعار إقبال مؤشر سوق دمشق للأوراق المالية DWX منذ بداية احتسابه في جلسة تداول 2010/1/4 حتى 2013/3/7 بالإضافة إلى رقم حجم التداول اليومي خلال الفترة المذكورة، وبعد ترتيب البيانات ضمن صفحة Excell وحساب قيم مختلف متغيرات المدخلات البالغة 27 متغيراً تم اعتماد القسم المتجانس من البيانات الكاملة حيث إن القيمة الأولى لبعض المتغيرات ظهرت بعد 28 يوماً تداول (SMA28)، (K28,RSI28%)، وبذلك تم الحصول على بيانات 500 يوم تداول خلال الفترة الزمنية المدروسة، ومن أجل تسهيل عملية التدريب وتسريعها فقد تمت تهيئة تلك البيانات ومعايرتها وتنميطها ضمن نطاق محدد كونها بيانات مشتقة من أسعار إقبال الأسهم التي تنسم بالتقلب ضمن مجال واسع عبر فترة زمنية طويلة نسبياً، وقد اعتمد بهذا الخصوص على استخدام دالة التتميط الأكثر استخداماً:

$$\text{القيمة المعدلة} = \frac{2 \times \text{القيمة الحقيقية} - (\text{أكبر قيمة خلال الفترة} + \text{أصغر قيمة خلال الفترة})}{(\text{أكبر قيمة خلال الفترة} - \text{أصغر قيمة خلال الفترة})}$$

وبعد ذلك جرى تقسيم هذه البيانات إلى ثلاث مجموعات رئيسية:

1- المجموعة الأولى (مجموعة بيانات التدريب Training Data Set) وتمثل 50% من البيانات حيث تضم 250 مثالاً موزعة عبر الفترة الزمنية للدراسة كما هو مبين في الجدول رقم (2) وهي على شكل مدخلات ومخرجات، تتدرب الشبكة عليها لتتعلم نمط العلاقة السائدة فيما بينها وذلك من خلال حساب الفرق بين المخرجات الفعلية والمخرجات التي تنتبأ بها الشبكة في كل دورة من دورات التدريب لتحديد مستوى الخطأ ومقارنته بالمستوى المستهدف، ومن ثم تعديل قيم قوة الاتصال بين خلايا مختلف الطبقات المتجاورة لتقليل الخطأ عملاً بأسلوب التكاثر الارتدادي للخطأ، وتكرار هذه العملية حتى الوصول إلى المستوى المستهدف من الخطأ، ومن ناحية أخرى تعدّ أوزان الاتصال بين خلايا الطبقات المتجاورة بمثابة ذاكرة الشبكة Network Memory المختزنة للمعلومات والتي تعتمد عليها الشبكة العصبية في تحديد قيم المخرجات، وهي تقابل قيم معاملات المتغيرات المستقلة عند استخدام دوال الانحدار.

2- المجموعة الثانية (مجموعة بيانات تدقيق واختبار الشبكة Validating Data Set) وتمثل 20% من البيانات حيث تضم 100 مثال موزعة عبر الفترة الزمنية للدراسة كما هو مبين في الجدول رقم (2) يتم خلالها اختبار مستوى أداء الشبكة وقدرتها على التنبؤ أثناء عملية التدريب نفسها.

3- المجموعة الثالثة (مجموعة بيانات السؤال والتنبؤ Querying Data Set) وتمثل 30% من البيانات حيث تضم 150 مثال موزعة عبر الفترة الزمنية للدراسة كما هو مبين في الجدول رقم (2) وهي على شكل قيم جديدة لمتغيرات المدخلات بنفس عددها وترتيبها المستخدم في تدريب واختبار الشبكة يطلب من الشبكة إعطاء قيم المخرجات المقابلة لها بناءً على ما تعلمته واختزنته من معرفة أثناء عمليتي التدريب والاختبار.

ومع زيادة عدد الأمثلة (حجم البيانات) تزداد كفاءة التدريب وتكون أفضل رغم الإبطاء في عملية التدريب واستغراقها وقتاً أطول، وعموماً فإنّ العدد المناسب للأمثلة للتدريب يعادل عدد متغيرات المدخلات ÷ 10% أي 25 ÷ 10% = 250 مثال، أي إنّ عدد المدخلات المناسب يعادل 10% من عدد أمثلة التدريب (Hamid & Iqbal, 2004, P. 1122).

كما تمّ حساب قيم متغير مخرج الشبكة العصبية المستخدمة والذي يمثل سعر إقبال مؤشر سوق دمشق للأوراق المالية لليوم التالي  $DWX_{t+1}$  المقابلة لجميع بيانات التدريب والاختبار، في حين أعطي هذا المتغير رمز إشارة الاستفهام "؟" مقابل جميع بيانات مجموعة التنبؤ Querying. وبعد ترتيب المتغيرات وتهيئتها وتحويلها إلى الشكل النصّي المناسب لاستيرادها من خلال برنامج الشبكات العصبية المستخدم EasyNN-Plus وتسميتها وتعريفها وتصنيفها ضمن الشبكة المستخدمة، تمّ تحديد المواصفات الأولية للشبكة (عدد الطبقات وعدد الخلايا العصبية في كل طبقة منها) ومن ثمّ تغذيتها بقيم متغيرات معدّل التعلم Learning Rate الذي تستخدمه الشبكة في تعديل أوزان المدخلات أثناء عملية التدريب، ومعدّل الزخم (الدفع) Momentum Rate الذي يستخدم لتحسين سرعة وكفاءة عملية التدريب من خلال التعديل المستمر في تأثير معدّل التعلم، وحدّ الخطأ المستهدف Target Error Rate وغير ذلك من القيم والإجراءات اللازمة للتأكد من سلامة البيانات ومناسبتها، أعطيت الشبكة أمر البدء بعملية التدريب.

ومع تتبع مراحل تطور عملية التدريب واتجاه الخط البياني لمعدلات الخطأ (الأدنى والأعلى والمتوسط) تمّ تعديل مواصفات الشبكة من خلال زيادة أو تخفيض عدد الطبقات الخفية وعدد خلايا كل منها، وقد تبيّن للباحث أنّ الشبكة المؤلفة من ثلاث طبقات (1-13-27) والتي جرى تعديل معدلات التعلم والزخم (الدفع) وعدد خلايا طبقتها الخفية بشكل تدريجي وصولاً إلى شبكة من ثلاث طبقات (1-4-27) رغم تدريبها لأكثر من 335000 دورة غير قادرة على بلوغ الحدّ المستهدف من معدّل الخطأ البالغ 1%، لذلك قام الباحث باختبار درجة حساسية قيمة متغير المخرج إلى قيم متغيرات المدخلات ومن ثمّ استبعاد المتغيرين ( $C_t$ ،  $K_{14}$ %) نظراً لقلّة أهميتهما النسبية.

ومع إعادة تدريب الشبكة بمواصفاتها ومتغيراتها الجديدة المعدّلة انخفضت جميع مؤشرات خطأ التنبؤ إلى ما دون حدّ الخطأ المستهدف وذلك بعد 128528 دورة Epochs من دورات التدريب، حيث تمّ بعدها سؤال الشبكة عن قيم متغير المخرج المقابلة لمجموعة بيانات التنبؤ للحصول على قيم أسعار إقبال مؤشر سوق دمشق للأوراق المالية المتنبأ بها لليوم التالي لكل يوم تداول ضمن هذه المجموعة.

وبذلك أمكن تحديد المواصفات النهائية للشبكة المستخدمة بأنها شبكة مؤلفة من أربع طبقات:

(I=25 , H<sub>1</sub>=10 , H<sub>2</sub> = 7 , O =1) طبقة المدخلات بخمس وعشرين خلية عصبية (25 متغير)، الطبقة الخفية الأولى بعشر خلايا عصبية، الطبقة الخفية الثانية بسبع خلايا عصبية، وطبقة المخرجات ذات خلية عصبية واحدة (متغير واحد)، وحدّد معدل التعلّم بـ 0.5652 ومعدّل الدفع بـ 0.7536 ومعدّل الخطأ المستهدف بـ 1% .

ومن أجل الموضوعية في عملية التقدير فقد جرى توزيع واستخدام البيانات المتاحة في عمليات التدريب والاختبار والتنبؤ عبر الفترة الزمنية المدروسة وفقاً لما هو مبين في الجدول التالي رقم (2):

الجدول رقم (2) توزيع البيانات ( قيم المتغيرات) المستخدمة في عمليات التدريب والاختبار والتنبؤ


البيانات الفترة الزمنية	مخصصة للتدريب (يوم تداول)	مخصصة للاختبار (يوم تداول)	مخصصة للتنبؤ (يوم تداول)
11/03/2010-05/07/2010	50	-	-
07/07/2010-18/08/2010	-	25	-
19/08/2010-24/11/2010	50	-	-
25/11/2010-12/01/2011	-	25	-
13/01/2011 - 03/04/2011	-	-	50
04/04/2011 -15/06/2011	50	-	-
16/06/2011 -20/07/2011	-	25	-
21/07/2011 02/11/2011	-	-	50
14/11/2011 -14/05/2012	75	-	-
15/05/2012-12/09/2012	-	-	50
17/09/2012 -13/11/2012	25	-	-
14/11/2012-15/01/2013	-	25	-
المجموع ( يوم تداول)	250	100	150

## اختبار فرضية البحث:

تم اختبار فرضية البحث بناءً على نتائج التنبؤات بقيم واتجاهات مؤشر سوق دمشق للأوراق المالية باستخدام الشبكة العصبية الاصطناعية التي تم تصميمها وتدريبها لهذه الغاية، وكذلك تقييم درجة دقة تلك التنبؤات، وقد تم ذلك على النحو الآتي:

بعد الانتهاء من تدريب واختبار الشبكة العصبية المستخدمة تم الحصول على تقديرات أسعار إقفال مؤشر سوق دمشق للأوراق المالية خلال الفترات المبينة في الجدول رقم (2) وبالبالغة 150 يوم تداول، والشكل البياني التالي رقم (1) يبين شكل القيم الفعلية والقيم المتنبأ بها باستخدام أسلوب الشبكات العصبية الاصطناعية خلال الفترة المذكورة.

الشكل رقم (1) القيم الفعلية والقيم المتنبأ بها لمؤشر سوق دمشق للأوراق المالية خلال فترة التنبؤ



المصدر: الشكل من إعداد الباحث بناءً على القيم الفعلية لمؤشر السوق ومخرجات الشبكة العصبية المستخدمة خلال فترة التنبؤ.

يبين الشكل البياني مدى التقارب بين القيم المتنبأ بها والقيم الفعلية باستثناء فترة قصيرة من الفترة الزمنية المدروسة (2011/3/2 - 2011/3/23) وربما يعود ذلك للتقلب الحادّ والمفاجئ في أسعار الأسهم وإعادة التصحيح بسرعة تحت تأثير ظروف من خارج السوق.

كما قام الباحث بتقييم درجة دقة تنبؤ الشبكة العصبية المستخدمة من خلال مجموعة المعايير التالية الأكثر شهرة واستخداماً<sup>\*</sup> (Zhang, G. et al., 1998, P. 43):

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

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - P_t)^2}$$

2- متوسط القيم المطلقة للأخطاء (MAE) Mean Absolute Error

$$MAE = \frac{1}{n} \sum_{t=1}^n [A_t - P_t]$$

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

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left[ \frac{A_t - P_t}{A_t} \right]$$

4- متوسط مربعات الأخطاء المعيارية (NMSE) Normalized Mean Squared Error

$$NMSE = \frac{\sum_{t=1}^n (A_t - P_t)^2}{\sum_{t=1}^n (A_t - \bar{P}_t)^2}$$

حيث تعبر  $A_t$  عن القيمة الفعلية ليوم التداول  $t$ ، وتعبر  $P_t$  عن القيمة المتنبأ بها ليوم التداول  $t$ ، بينما تعبر  $\bar{P}_t$  عن متوسط القيم المتنبأ بها خلال الفترة.

وفيما يلي يلخص الجدول رقم (3) القيم المحسوبة لهذه المعايير ضمن كل فترة من فترات التنبؤ المشار إليها في الجدول رقم (2) وعلى مستوى الفترة الكلية للتنبؤ.

الجدول رقم (3) القيم المحسوبة لمعايير تقييم دقة تنبؤ الشبكة العصبية المستخدمة

حدود الفترة الزمنية	عدد أيام التداول	RMSE	MAE	MAPE	NMSE
13/01/2011 - 03/04/2011	50 يوم	65.89	44.58	0.02	0.02
21/07/2011 - 02/11/2011	50 يوم	40.78	36.26	0.04	0.04
15/05/2012 - 12/09/2012	50 يوم	7.19	5.09	0	0
13/01/2011 - 12/09/2012	150 يوم	44.93	28.64	0.02	0.02

المصدر: الجدول من إعداد الباحث بناءً على الحسابات المباشرة للمعاملات باستخدام حزمة جداول الـ Excel.

\* لخصت هذه الدراسة أبرز خصائص لـ 21 دراسة تمت بين العام 1991 والعام 1996 واعتمدت على التنبؤ باستخدام الشبكات العصبية الاصطناعية وذلك من حيث بنية الشبكة وحجم البيانات وأنواع الدوال ومعايير تقييم الأداء المستخدمة.

يبين الجدول السابق انخفاضاً ملحوظاً في قيم المعايير المحسوبة خلال الفترة المدروسة، حيث تدلّ قيم MAPE المنخفضة خلال الفترات الفرعية والفترة الكلية على القوة التنبؤية العالية للشبكة العصبية الاصطناعية المستخدمة، فقد بلغت قيمة MAPE بعد التقريب 0.02 مما يدلّ على أنّ القيم الفعلية لمؤشر السوق بالمتوسط أعلى من القيم المتنبأ بها بـ 2% خلال كامل فترة التنبؤ، وقد بيّنت بعض الدراسات أنّ قيمة MAPE حتى 10% تدلّ على قوة تنبؤية مرتفعة.

كما تؤكد أيضاً قيم NMSE المنخفضة جداً على القوة التنبؤية العالية للشبكة العصبية الاصطناعية المستخدمة.

ومن ناحية أخرى أظهرت إحدى الدراسات (Muttar, 2008, P. 10) أنّه من غير السليم الاعتماد على أحد المعايير السابقة لوحده لتقييم دقة النموذج في التنبؤ، واقترحت استخدام معيار المتوسط المرجح (WM) Weighted Mean الذي يتم حسابه من خلال ترجيح المعايير السابقة وفق ثلاث طرق كما يلي:

$$WM1 = (RMSE + 4MAPE + MAE) / 6$$

$$WM2 = (4RMSE + MAPE + MAE) / 6$$

$$WM3 = (RMSE + MAPE + 4MAE) / 6$$

وبحساب قيمة المتوسط المرجح خلال فترة التنبؤ الكلية وفق الطرق المذكورة، تبين أنّ  $WM1 = 34.73$ ،  $WM2 = 12.27$ ،  $WM3 = 26.59$  مما يدلّ على قوة النموذج المستخدم (الشبكات العصبية الاصطناعية) في عملية التنبؤ بـ قيم مؤشر السوق المدروسة.

وباستبعاد الفترة (2011/3/23 - 2011/3/2) بسبب التقلب الحادّ و المفاجيء في أسعار الأسهم خلالها - كما أشير سابقاً- من الفترة الزمنية المتنبأ بها، انخفضت قيم مختلف المعايير المحسوبة بشكل ملحوظ حيث بلغت:  $RMSE = 29.57$ ,  $MAE = 19.45$ ,  $MAPE = 0.015$ ,  $NMSE = 0$ ,  $WM1 = 22.96$ ,  $WM2 = 8.18$ ,  $WM3 = 17.9$

مما يؤكد من جديد قوة ودقة أسلوب الشبكات العصبية الاصطناعية المستخدم في التنبؤ بـ قيم مؤشر سوق دمشق للأوراق المالية ليوم التداول التالي، وهذا ما يثبت صحّة فرضية البحث أيضاً.

ولتقييم قدرة الشبكة العصبية الاصطناعية المستخدمة على التنبؤ باتجاهات مؤشر السوق المدروسة فقد قام الباحث بحساب معدل الملائمة أو التطابق Hit Rate بين القيم الفعلية والقيم المتنبأ بها حيث يقيس هذا المؤشر مدى ميل القيم المتنبأ بها  $Y_i$  لأن يكون لها نفس إشارة القيم الفعلية  $X_i$ ، وعليه تكون قيمة  $Hit(X_i, Y_i) = 1$  إذا كانت القيمتان من نفس الإشارة، في حين تكون قيمة  $Hit(X_i, Y_i) = 0$  إذا كانت القيمتان من إشارتين مختلفتين، وبناءً على القيم المحسوبة يأخذ المعدل المذكور قيمته كمتوسط حسابي لتلك القيم المحسوبة:

$$Hit Rate = \frac{1}{n} \sum_{i=1}^n Hit(X_i, Y_i)$$

وقد بلغت نسبة التطابق Hit Rate المحسوبة 70.5% وهي نسبة عالية تدلّ على قوة تنبؤ عالية جداً لأسلوب الشبكات العصبية المستخدم، إذ تشير الدراسات إلى أنّ ارتفاع قيمة هذه النسبة عن 50% يدلّ على قوة تنبؤية عالية للنموذج المستخدم (Aamodt, 2010, P. 70).

كما قام الباحث أيضاً بحساب قيمة معامل ارتباط بيرسون Person Correlation Coefficient بين سلسلة البيانات الفعلية وسلسلة البيانات المنتبأ بها باستخدام حزمة البرامج الإحصائية SPSS التي أظهرت أن قيمة معامل الارتباط المذكور هي 99.4% مما يدل على وجود علاقة ايجابية قوية جداً بين السلسلتين وأن كل منهما يتحرك بنفس الاتجاه والمعدّل تقريباً (Aamodt,2010, P.70)، مما يؤكد أيضاً دقة الأسلوب المستخدم للتنبؤ بقيمة واتجاه مؤشر السوق المدروسة.

وبناءً على ما تقدم كلاً يمكن القول: إنّه من الممكن التنبؤ وبدرجة عالية من الدقة بقيمة واتجاه مؤشر سوق دمشق للأوراق المالية ليوم التداول التالي باستخدام أسلوب الشبكات العصبية الاصطناعية، وهذا ما نصّت عليه فرضية البحث.

### الاستنتاجات والتوصيات:

استناداً إلى ما تمّ استعراضه وتحليله خلال هذا البحث، توصلّ الباحث إلى الاستنتاجات التالية:

- 1- يمكن التنبؤ بقيمة مؤشر سوق دمشق للأوراق المالية واتجاهه ليوم التداول التالي باستخدام أسلوب الشبكات العصبية الاصطناعية وبدرجة عالية من الدقة.
- 2- يعتبر أسلوب الشبكات العصبية الاصطناعية من الأساليب الهامة والمناسبة للتنبؤ بالبيانات المالية بعيداً عن الاختبارات والتعقيدات الإحصائية اللازمة عند استخدام أساليب التنبؤ التقليدية.
- 3- ترتبط دقة التنبؤ بقيمة مؤشر سوق دمشق للأوراق المالية واتجاهه بطول الفترة الزمنية المستقبلية المنتبأ بها وكذلك بمواصفات الشبكة العصبية المستخدمة وآلية تدريبها.
- 4- يمكن الاعتماد على نتائج التنبؤ بقيمة مؤشر سوق دمشق للأوراق المالية واتجاهه ليوم التداول التالي في اتخاذ قرارات استثمارية هامة وتحقيق عوائد غير عادية بدرجة ثقة عالية.

### كما أوصى الباحث بما يلي:

- 1- استخدام أسلوب الشبكات العصبية الاصطناعية في التنبؤ كبديل جيد لأساليب التنبؤ التقليدية، وقيام الباحثين والمستثمرين والمهتمين بتجريب عدة أشكال وبنى هيكلية أخرى للشبكات المستخدمة.
- 2- قيام الباحثين بإجراء أبحاث مشابهة للتنبؤ بقيمة مؤشر سوق دمشق للأوراق المالية واتجاهه لفترة زمنية أطول، وتقييم دقة التنبؤ في هذه الحالة.
- 3- قيام الباحثين باستخدام متغيرات أخرى وبدرجات إبطاء متعددة لتدريب الشبكة واختبارها الأمر الذي قد يحسّن من درجة دقة التنبؤ.
- 4- قيام الباحثين وإدارة سوق دمشق للأوراق المالية بالربط بين القيم المنتبأ بها وبعض الظواهر الاقتصادية العامة لاختبار إمكانية اعتماد مؤشر سوق دمشق للأوراق المالية كمتغير قائد يسبق تغييره الحالة الاقتصادية العامة في سوريا.
- 5- تطبيق منهجية وأسلوب هذا البحث للتنبؤ بقيم واتجاهات مؤشرات أسواق ناشئة مشابهة للتأكد من إمكانيات الشبكات العصبية الاصطناعية ودقتها في عملية التنبؤ في الأسواق المالية.

## المراجع

- 1- DASE, R. K. ; PAWAR, D. D. *Application of Artificial Neural Network for Stock Market Prediction: A Review of Literature*, International journal of Machine Intelligence, Vol. 2, Issue 2, 2010, 14-17.
- 2- DESAI, J. et al. *Forecasting of Indian Stock Market Index S&P CNX Nifty 50 Using Artificial Intelligence*, Behavioral & Experimental Finance E-journal, Vol. 3, No. 79, 2011.
- 3- GUNASEKARAN, M. ; RAMASWAMI, K. S. *Evaluation of Artificial Immune System with Artificial Neural Network for Predicting Bombay Stock Exchange Trends*, journal of Computer Science, Volume 7, Issue 7, 2011, 967-972.
- 4- HAMID, S. A. ; IQBAL, Z. *Using Neural Networks for Forecasting Volatility of S&P500 Index Futures Prices*, Journal of Business Research 57, 2004, 1116 – 1125.
- 5- KARA, Y. et al. *Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange*, Expert Systems with Applications 38, 2011, 5311–5319.
- 6- KAZEM, B. I. ; MUTLAG A. K. *Optimal Brain Surgeon Pruning of Neural Network Models of Manufacturing Processes*, Journal of Engineering, N. 3, Vol. 11, 2005, 495-508.
- 7- MEHRARA, M. et al. *Using Technical Analysis with Neural Network for Forecasting Stock Price Index in Tehran Stock Exchange*, Middle Eastern Finance and Economics, Volume 6, Issue 6, 2010, 50-61.
- 8- MUTTAR, T. R. *A Proposed Technique for the Problem of Selecting the best Forecasting Model in Time Series: A Case Study*, Iraqi Journal of Statistical Science 14, 2008, 1-20.
- 9- NAEINI, M. P. et al. *Stock Market Value Prediction Using Neural Networks*, International Conference on Computer Information Systems and Industrial Management Applications (CISIM), 2010, 132-136.
- 10- 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, 205-218.
- 11- SUTHEEBANJARD, P. ; PREMCHAIWADI, W. *Stock Exchange of Thailand Index Prediction Using Back Probagation Neural Networks*, Second International Conference on Computer and Network Technology, 2010, 377-380.
- 12- THENMOZHI, M. *Forecasting Stock Index Returns Using Neural Networks*, Delhi Business Review, Vol. 7, No. 2, 2006, 59-69.
- 13- ZHANG, G. et al. *Forecasting with artificial neural networks: The state of the art*, International Journal of Forecasting 14, 1998, 35–62.
- 14- 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, 95 Pages.
- 15- LARSEN, J. I. *Predicting Stock Prices Using Technical Analysis and Machine Learning*, Master thesis, Norwegian University of Science and Technology, Department of Computer and Information Science, 2010.
- 16- SENOL, D. *Prediction of Stock Price Direction by Artificial Neural Network Approach*, Master thesis, Bogazici University, Institute for Graduate Studies in Social Sciences, 2008.

- 17- DESAI, J. et al. *Forecasting of Stock Market Indices Using Artificial Neural Networks*. Working Paper No. CPI/MBA/2013/0003, Shri Chimanbhai Patel Institutes, Ahmadabad, 2013.
- 18- MAJUMDER, M. ; HUSSIAN, M. A. *Forecasting of Indian Stock Market Index Using Artificial Neural Network*, Working Paper, 2010.
- 19- TABRIZI, H. A. ; PANAHIAN, H. *Stock Price Prediction by Artificial Neural Networks: A Study of Tehran's Stock Exchange (T. S. E.)*, Working Paper, 2000.
- 20- هندي، منير إبراهيم. *الأوراق المالية وأسواق رأس المال*، منشأة المعارف، الإسكندرية، 1999.
- 21- السراج، عمر محمد فهمي. ؛ الجميل، سرمد كوكب. *تقدير نماذج التنبؤ بأسعار الأسهم في أسواق رأس المال العربية*، جامعة الموصل، مجلة تنمية الرافدين، المجلد 30، الإصدار 91، 2008، 9-47.
- 22- مرهج، منذر عبد الكريم. *أثر استراتيجية توقيت السوق على أداء الاستثمار في البورصة المصرية*، رسالة دكتوراه غير منشورة، جمهورية مصر العربية: جامعة قناة السويس، كلية التجارة بالإسماعيلية، 2003.
- 23- الميداني، محمد أيمن عزت. *تطور أسعار الأسهم في سوق دمشق للأوراق المالية*، محاضرة في جمعية العلوم الاقتصادية السورية بتاريخ 2011/3/22.