مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية

اسم المقال: استخدام المؤشرات الفنية والشبكات العصبونية للتنبؤ بحركة أسعار الأسهم (دراسة تطبيقية على بورصة عمان)
اسم الكاتب: محمد سعد حاووط، إبراهيم عبد الواحد نائب
رابط ثابت: https://political-encyclopedia.org/library/1758
تاريخ الاسترداد: 2026/04/11 18:27 +03

الموسوعة السياسيّة هي مبادرة أكاديمية غير هادفة للربح، تساعد الباحثين والطلاب على الوصول واستخدام وبناء مجموعات أوسع من المحتوى العلمي العربي في مجال علم السياسة واستخدامها في الأرشيف الرقمي الموثوق به لإغناء المحتوى العربي على الإنترنت.
لمزيد من المعلومات حول الموسوعة السياسيّة – Encyclopedia Political، يرجى التواصل على info@political-encyclopedia.org

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

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

استخدام المؤشرات الفنية والشبكات العصبونية للتنبؤ بحركة أسعار الأسهم (دراسة تطبيقية على بورصة عمان)

Using Technical Indicators and Artificial Neural Networks (ANN) to Predict the Movement of Stock Prices «An Applied Study on the Amman Stock Exchange»

محمد سعد حاووط
طالب دكتوراه/ جامعة حلب/ سوريا

إبراهيم عبد الواحد نائب
أستاذ دكتور/ جامعة حلب/ سوريا

Mohamed Saad Hawout
PhD. student/ Aleppo University/ Syria
m.saad.haout@gmail.com

Ibrahim Abdel Wahed Nayeb
Professor/ Aleppo University/ Syria
ibrahim_nayeb@hotmail.com

تاريخ الاستلام: 5/ 1/ 2020م، **تاريخ القبول:** 10/ 5/ 2020م.
E-ISSN: 2410-3349
P-ISSN: 2313-7592

Received: 5/ 1/ 2020, **Accepted:** 10/ 5/ 2020.
DOI: 10.33977/1760-005-014-004
https: //journals.qou.edu/index.php/eqtsadia

الملخص:

برزت الحاجة لوجود مؤسسات متخصصة تسهم في تحويل الأموال من الجهات التي تتمتع بفائض منها إلى الجهات التي تعاني من عجز وتستطيع أن تقوم بتجميع هذه الفوائض وتوجيهها نحو المجالات الاستثمارية، ، حيث تنوعت الأدوات المالية المتداولة وكان أهمها الأسهم العادية كونها الأكثر انتشاراً في الأسواق المالية، حيث يعتمد نجاح القرارات الاستثمارية والمالية على توافر المعلومات اللازمة لمتخذي القرار التي تعتمد على أساليب التحليل العلمي والمنطقي، لذلك ظهرت في ميادين الذكاء الصنعي الشبكات العصبونية كإحدى تقنيات التنقيب في البيانات التي تساعد في اكتشاف أنماط غير معروفة مسبقاً من كميات كبيرة من البيانات، والوصول إلى نماذج قابلة للتفسير بهدف استخراج المعرفة ودعم عملية اتخاذ القرار.

يعتمد البحث على استخدام أداة (WEKA) ، وذلك باستخدام الشبكة العصبونية (Multi - layer perceptron) وهي شبكة متعددة الطبقات ذات الانتشار العكسي والمؤشرات الفنية الخاصة بالتنبؤ بحركة أسعار الأسهم التاريخية ليوم واحد بالاعتماد على نمذجة بعض المعاملات الفنية للوصول إلى السعر المستقبلي للسهم خلال يوم.

وتوصل البحث إلى إمكانية بناء نموذج شبكة عصبية اعتماداً على نمذجة بعض المعاملات الفنية للتنبؤ بحركة الأسعار المستقبلية للأسهم.

الكلمات المفتاحية: الشبكة العصبونية، أداة (WEKA) ، سوق الأوراق المالية، الشبكات العصبونية المتعدد الطبقات، الانتشار العكسي، التنقيب في البيانات، حركة الاسهم.

Abstract

The need for the existence of specialized institutions contributed to transferring funds from entities that enjoy a surplus from them to entities that suffer from a deficit and that can collect these surpluses and direct them towards investment areas as the traded financial instruments varied. The most important of which was the common stock being the most prevalent in the financial markets where the success of investment and financial decisions depends on the availability of the necessary information for decision makers that rely on logical scientific analysis methods. Therefore, in the fields of artificial intelligence, neuronal networks have emerged as one of the techniques of data mining that helps in discovering previously unknown patterns of large amounts of data, and accessing interpretable models in order to extract knowledge and support the decision - making process.

The research is based on the use of the WEKA tool, using the multi - layer perceptron of the neuronal network, multi - layer network with a reverse spread, and technical indicators for predicting the movement of historical stock prices for one day, based on the modeling of some technical transactions to reach the future price of the share within a day.

The research focuses on the possibility of building a neural network model based on the modeling of some technical transactions to predict the future movement of stock prices.

***Keywords**: Artificial Neural Networks (ANN) , WEKA Ada, Stock Market, Multi - Layer Neural Networks, Reverse Propagation, Data Mining, Stock Movement.*

1. الاطار العام للبحث

1. المقدمة:

تسمح الأسواق المالية بتداول الأسهم بين المستثمرين من خلال إعادة عمليات البيع والشراء فيما بينهم، ويتخذ المستثمر قراراته حول تداول الأسهم في السوق عبر عملية تحليل حركة أسعار الأسهم باستخدام الأساليب العلمية الحديثة.

سيركز البحث على دراسة مدى إمكانية تحديد المعايير التي تمكن من تحديد الأسعار المستقبلية للأسهم؛ بالاعتماد على نمذجة المعاملات الفنية كمتغيرات مستقلة، والاعتماد على سعر الأغلاق كمرحلة ثانية (متغير الهدف).

لذلك سوف نستخدم في هذا البحث تقنية الشيكات العصبونية المتمثلة بخوارزمية (Multilayer perceptron) هي شبكات متعددة الطبقات وهي أفضل من الشبكات ذات الطبقة الوحيدة؛ لأنها تحل المشكلات المعقدة) للتنبؤ بحركة أسعار الأسهم والتي تعد إحدى خوارزميات المهمة التي أثبتت الدقة العالية في حلّ مشكلات كبيرة ومعقدة في المجالات الاقتصادية، والإدارية، والطبية، والتي في نهاية الأمر تمكننا من الوصول إلى معايير محددة تساعد في اتخاذ القرار السليم في بالتنبؤ بالأسعار المستقبلية للأسهم.

2. مشكلة البحث:

زيادة الدقة في التنبؤ بحركة أسعار الأسهم في سوق الأوراق المالية هي من أهم المشكلات التي تواجه المستثمرين، لما لها من آثار كبيرة على قرار المستثمرين في الأسواق المالية، من خلال اتباع أحدث الوسائل والتقنيات حيث جاءت فكرة هذا البحث كفائدة للمستثمر من خلال دراسة واقع هذه الأسواق كنهج يمكن اتباعه في تطوير عملية التنبؤ بحركة أسعار الأسهم، وزيادة الدقة للمساعدة على اتخاذ القرار السليم للمستثمر؛ لتحقيق أرباح كبيرة بنسبة مخاطرة منخفضة وبالتالي تتلخص المشكلة البحثية بالإجابة على الأسئلة التالية:

- هل يمكن للشبكات العصبونية الصناعية والمؤشرات الفنية أن تزيد من دقة التنبؤ بالأسعار المستقبلية للأسهم.
- هل يمكن أن تعطي الشبكات العصبونية دقة تنبؤ أفضل من دقة الأساليب الإحصائية.
- ما هو مقدار تأثير المتغيرات الكمية (التحليل الفني والتحليل الأساسي) للتداول على اتخاذ القرار الاستثماري في سوق

الأوراق المالية.

3. فروض البحث:

♦ هل يمكن نمذجة البيانات التاريخية لأسعار الأسهم بشكل يجعلها قابلة للتطبيق باستخدام تقنيات التنقيب في البيانات عبر منهجية التصنيف باستخدام الشبكات العصبونية للتنبؤ بالأسعار المستقبلية للأسهم.

♦ هل يمكن استخدام النموذج المقترح للتنبؤ بشكل دقيق وعلمي بحركة تداول الاسهم، وبأداء المؤشرات الفنية في السوق المدروس باستخدام نتائج النموذج بالاعتماد على الشبكة العصبونية.

4. أهمية البحث:

تكمن أهمية البحث من خلال استخدام تقنيات التصنيف (الشبكات العصبونية الاصطناعية) كإحدى تقنيات التنقيب في البيانات، في تصنيف تحركات أسعار الأسهم.

وبالتالي استخلاص قواعد وأنماط غير معروفة من كميات كبيرة من البيانات والتي لا يمكن اكتشافها بالطرائق التقليدية، بحيث تفيد في التنبؤ باتجاه تحركات الأسعار مما يحقق أرباحا رأسمالية وتجنب للمخاطر، وذلك بدعم عملية اتخاذ القرار المناسب في الوقت المناسب من خلال بناء نموذج ذي دقة عالية للتنبؤ بحركة أسعار المستقبلية للأسهم لتحقيق أرباح رأسمالية، وتجنب للمخاطر، يضاف إلى ذلك التركيز على عملية النمذجة باستخدام أهم المتغيرات التي يمكن أن تمثل المشكلة، واستخدام معايير تقييم يمكن من خلالها الحكم على النموذج بشكل يجعله يتوافق مع طبيعة قرارات تداول الأسهم في السوق.

5. أهداف البحث:

يهدف البحث إلى:

♦ إيجاد آلية ديناميكية قادرة على محاكاة واقع سوق الأوراق المالية من خلال الشبكات العصبونية الاصطناعية.

♦ بناء نموذج شبكة عصبونية قادرة على التنبؤ بالأسعار المستقبلية للأسهم لدعم قرارات المستثمرين للتداول في الأسواق المالية.

♦ الوصول إلى أنماط وقواعد مخفية في بيانات أسعار الأسهم لاكتشاف المعرفة حول سلوك هذه الأسهم في السوق، ودعم قرارات عملية التداول فيها.

6. طريقة البحث:

يعتمد البحث على المنهج التحليلي، حيث سيتم تحليل مجموعة البيانات التاريخية لسوق الأسهم في بورصة عمان عن عامي (2017 – 2018) ولمدة يوم واحد من الموقع (www.ase. com.jo/ ar) الخاص بالبنك الإسلامي الأردني في بورصة عمان للأوراق المالية (تم اختيار بورصة عمان لكثرة عدد الصفقات اليومية من عمليات بيع وشراء مما يؤدي إلى كثرة البيانات) وبالاعتماد على الأداة (WEKA) لبناء نموذج للتنبؤ بالأسعار المستقبلية للأسهم، سوف يتم تقييم نموذج التدريب عن طريق إجراء عملية اختبار ببيانات غير الموجودة في النموذج، وتقييم مدى دقة النموذج وكفاءته، والتدريب باستخدام مقاييس التقييم ومنها معامل إحصائية (Kappa) و (ROC Area) لتساعد على اتخاذ القرار الصحيح للتنبؤ بالأسعار المستقبلية للأسهم.

7. الدراسات السابقة:

دراسة (جواد عبد المجيد – 2015) : «التنبؤ بحركة الأسهم المتداولة في سوق الأوراق المالية باستخدام تقنيات الذكاء الاصطناعي» (دراسة تحليلية تطبيقية – الأسواق المالية العربية)"

هدفت الدراسة إلى استخدام عدد من النماذج الإحصائية والرياضية والتي كانت، نماذج التمهيد الأسي، نماذج (ARIMA) ، تحليل المركبات الأساسية، ومقارنتها مع تقنيات حديثة والتي كانت الشبكات العصبونية ذات الانتشار العكسي، وذلك للتنبؤ بحركة الأسهم بالتطبيق على ثلاثة أسواق مالية (الأردن، السعودية، سورية) ، وخلصت الدراسة إلى تفوق التقنيات الحديثة المتمثلة بالشبكات العصبونية ذات الانتشار العكسي على جميع النماذج التقليدية.

دراسة (زيد حياة – 2015) : «دور التحليل الفني في اتخاذ قرار الاستثمار بالأسهم دراسة تطبيقية في عينة من أسواق المال العربية (الأردن، السعودية، وفلسطين) »

هدفت الدراسة إلى معرفة دور التحليل الفني في اتخاذ قرار الاستثمار في الأسهم في مجموعة من الدول العربية (الأردن، السعودية، وفلسطين)، وقامت الدراسة بتطبيق أسلوب التحليل الفني بشكله التقليدي البياني باستخدام مؤشر القوة النسبية ومؤشر تقارب وتباعد المتوسطات المتحركة (ماكد).

خلصت الدراسة إلى أن التحليل الفني له دور فعال في دعم القرار بالتنبؤ بحركة السهم بحالات الارتفاع والانخفاض، وأكدت الدراسة على أن مؤشر القوة النسبية يعطي إشارات مبكرة بتغير الاتجاه.

دراسة (برودي نعيمة 2013) : «التحليل الفني لأوراق المالية كأداة للتنبؤ بأسعار الأوراق المالية واتجاهات الأسواق»

هدفت الدراسة إلى معرفة مدى قدرة التحليل الفني على التنبؤ بأسعار الأوراق المالية واتجاهات السوق، حيث قامت الدراسة على تطبيق أسلوب التحليل الفني بشكله التقليدي البياني على سوق الأسهم السعودي خلال الفترة من 1/ 1/ 2012 إلى 1/ 12/ 2012، وخلصت الدراسة إلى فعالية التحليل الفني في تحديد الاتجاهات والأسعار في السوق السعودي، وقد أكدت على أهمية كل من مؤشر التذبذب لقوة الدفع ومؤشر (بولنجر).

دراسة (Paliyawan P. 2015) : « Predicting the movement of stock prices using data mining by classification" («التنبؤ باتجاه حركة أسعار الأسهم باستخدام التنقيب في البيانات بالتصنيف»)

ركزت هذه الدراسة على مقارنة بين أشجار القرار وأسلوب شبكة (باين) والشبكات العصبونية والجار الأقرب من أجل التنبؤ بحركة أسعار الأسهم.

حيث تم استخدام التحليل الفني لكن بدون استخدام المؤشرات

الفنية المعروفة، بل اعتمد على استخدام الفروقات السعرية التاريخية لمدة خمسة أيام سابقة، أما متغير الهدف فقد قسم إلى ثلاثة مستويات، تداول يومي (T+1) ، وتداول على مستوى ستة أيام (T+6) ، ومستوى (21) يوما (T+21).

وخلصت الدراسة إلى أن الشبكات العصبونية بمستوى دقة (42.30%) في المرتبة الأولى في الحالة (T+1) ، وأشجار القرار في المرتبة الأخيرة بمستوى دقة (40.17%) ، أما في حالة (T+6) فكانت أشجار القرار بمستوى دقة (39.20%) في المرتبة الأولى وفي (T+21) كانت أشجار القرار الثانية بمستوى دقة (36%) ، بعد الشبكات البايزية التي بلغت دقتها (36.43%) ، حيث تم التطبيق على سوق (تايلند) وركز البحث على تقليل نسبة الخطأ عبر تغيير أسلوب نمذجة متغير الهدف.

دراسة «Predict stock market» : (Ping,H, Tang,L, - 2018) trends using improved Artificial Neural networks (ANN) using Google Trends" توقع اتجاه أسواق الأسهم باستخدام شبكات عصبية محسنة باستخدام خدمة Google Trends»)

في هذا البحث، نقدم خوارزمية جينية (ISCA) لاستخدامها في تحسين الأوزان في الشبكات العصبونية ذات الانتشار الخلفي (BPNN) حيث يتم دمج (ISCA و BPNN) لإنشاء شبكة عصبية جديدة (ISCA - BPNN) ، للتنبؤ بحركة أسعار الأسهم الافتتاحية لمؤشر (S&P 500) ومؤشر (داو جونز) الصناعي، على التوالي. يضاف إلى ذلك أخذ بيانات (Google Trends) في الاعتبار لتحسين التنبؤ بالأوراق المالية، ثم نقوم بتحليل نوعين من التنبؤ، النوع الأول: هو التنبؤ دون مؤشرات (Google) ، والنوع الثاني: هو التنبؤ مع مؤشرات (Google)، ثم يتم التحقق من إمكانية التنبؤ في تجاه سعر السهم باستخدام نموذج (ISCA – BPNN) المختلط.

وتوصلت النتائج إلى أن (ISCA - BPNN) يتفوق على (BPNN و GWO - BPNN) و (PSO - BPNN) و (WOA - BPNN) و (SCA – BPNN) من حيث التنبؤ باتجاه سعر الافتتاح حيث تصل نسبة النجاح في (ISCA - BPNN مع Google Trends) إلى (86.81%) لمؤشر (S&P 500) ، و (88.98%) لمؤشر (داو جونز) الصناعي المتوسط وهي نتائج مرتفعة، ومقبولة لكلا النموذجين للتنبؤ.

دراسة (Imandoust S. Bolandraftar M. 2014)

الدراسة بالمقارنة بين ثلاث تقنيات مختلفة وهي شبكة (بايز) ، والغابات العشوائية، وأشجار القرار (CART) ، واستخدمت أسلوبين من المتغيرات التنبؤية، وهي: مؤشرات التحليل الفني ومؤشرات التحليل الأساسي، حيث كانت مؤشرات التحليل الفني عبارة عن مؤشرات المتوسطات المتحركة، ومؤشرات تعتمد على الزخم ومؤشر يعتمد على حجم التداول، أما دالة الهدف فكانت التحركات اليومية لأسعار الأسهم (T+1) ، وتم التطبيق على بورصة طهران، وبعد المقارنة تبين أن أسلوب مؤشرات التحليل الفني باستخدام أشجار القرار (CART) كان الأفضل، بقدرة تنبؤية (80.08%) ، وركز البحث على نسبة السجلات الصحيحة الكلية للحكم على النموذج دون التطرق إلى قدرة النموذج على الوصول إلى كل فئة من الفئات.

رراسة (Chuang Y., Yang D., Huang C. 2008) : «Ap-plication of Wrapper Approach and Composite Classifier to The ("تطبيق أسلوب التجميع والمصنف المركب في التنبؤ باتجاه الأسهم")

قامت هذه الدراسة بالمقارنة بين أساليب التجميع، وأشجار القرار (C4.5) ، والشبكة العصبية، وآلة شعاع الدعم، والجار الأقرب، والانحدار اللوجستي، وقد اعتمدت الدراسة على البيانات التاريخية للأسعار في كل من سوق: تايوان، وسوق كوريا للأوراق المالية، للتنبؤ بالتحركات اليومية للأسعار (T+1) باستخدام المؤشرات الفنية حيث كانت مؤشرات التحليل الفني عبارة عن مؤشرات المتوسطات المتحركة، ومؤشرات تعتمد على الزخم، ومؤشر يعتمد على حجم التداول، وإضافة بيانات الأسعار الحقيقية في تداول اليوم مكونة من خمسة عناصر، هي: سعر أول صفقة، وسعر آخر صفقة، وأعلى سعر، وأدنى سعر، وحجم التداول، وقد توصل البحث إلى أن أسلوب التجميع كان الأفضل بمستوى دقة (80.28%) عند التطبيق في سوق تايوان، و (76.06%) في سوق كوريا، بينما أشجار القرار كانت في المرتبة الثانية في سوق كوريا، بمستوى دقة (71.83%) ، وفي سوق تايوان كانت مشابهة للتقنيات الأخرى بمستوى دقة (64.79%) ، وركز البحث على نسبة السجلات الصحيحة الكلية للحكم على النموذج دون التطرق إلى قدرة النموذج على الوصول إلى كل فئة من الفئات.

أهم ما يميز هذه الدراسة عن الدراسات السابقة هو أسلوب النمذجة المستخدم لبناء نموذج شجرة قرارات وفق منهجية التصنيف باستخدام خوارزميتي (CART - C4.5) والوصول إلى قواعد ديناميكية، والاعتماد على عدد كبير وأشكال عدة من المتغيرات بشكل يناسب عملية التنبؤ باتجاه حركة أسعار الأسهم وفق مستويات زمنية عدة، وإجراء عملية التدريب والاختبار بأسلوب (Cross - Validation - 10) الذي يمكن به تحقيق الاستفادة القصوى من البيانات وتطبيق أقسى أنواع الاختبار، وتقييم قدرة النموذج بشكل معمق من حيث قدرة الوصول إلى كل فئة من الفئات الهدف، وتحليل القرارات الناتجة عن كل فئة؛ لمعرفة قدرة النموذج على دعم قرارات التداول بشكل فعلي، وتفسير القواعد المخفية في البيانات من هيكلية أشجار القرار مما يمكننا من اكتشاف معرفة مفيدة في عمليات التداول في السوق، وذلك بتطبيق هذه الدراسة في سوق دمشق للأوراق المالية.

كما أنه وبحسب اطلاع الباحث على المصادر المتوفرة، تبين ندرة الدراسات العربية التي تناولت هذا الموضوع.

8.ما يميز الدراسة الحالية عن الدراسة السابقة:

أهم ما يميز هذه الدراسة عن الدراسات السابقة هو أسلوب النمذجة المستخدم لبناء نموذج وفق منهجية التصنيف باستخدام خوارزمية الشبكات العصبونية (Multi layer perceptron) ذات الانتشار العكسي والوصول إلى قواعد ديناميكية، والاعتماد على المتغيرات المؤشرات الفنية، واختلاف هذه المتغيرات عن متغيرات الأبحاث السابقة بشكل يناسب عملية التنبؤ باتجاه حركة أسعار الأسهم، وفق مستوى زمن مختلف أيضاً، وإجراء عملية التدريب والاختبار بأسلوب (Cross - Validation - 10) الذي يمكن به تحقيق الاستفادة القصوى من البيانات، وتطبيق أقسى أنواع الاختبار،

وتقييم قدرة النموذج بشكل معمق من حيث قدرة الوصول إلى كل فئة من فئات الهدف، وتحليل القرارات الناتجة عن كل فئة؛ وذلك لمعرفة قدرة النموذج على دعم قرارات التداول بشكل فعلي.

2. الإطار النظري للأسواق المالية:

1.مفهوم الأسواق المالية

(Abuzir, E. Y., & Baraka, M. A. M. (2019).,p41 - 42) :

هي آلية يتم من خلالها تداول الأصول المالية بيعاً وشراءً، وتمكن تلك الآلية من تحويل الموارد المالية بكفاءة من القطاعات الاقتصادية ذات الفوائض المالية إلى القطاعات الاقتصادية التي تعاني من العجز المالي.

إن سوق الأوراق المالية لا يختلف عن باقي الأسواق بمفهومها العام فهي تجمع كلا البائعين والمشترين حول سلعة معينة، إلا أن هذه الأسواق لها خصوصية معينة من حيث السلعة المتداولة فيها، والآلية التي تحكم هذا التداول، اما بالنسبة للأسهم المحلية والدولية فيمكن أن تتأثر أسعار أسهم السوق والشركات من عوامل عدة، مثل: الاقتصادية والسياسية والحرب والاضطرابات المدنية والكوارث الطبيعية والإرهاب الاجتماعي والنفسي (Mishkin F., Eakins, 2012 - ,p19.)

2.أنواع أسواق الأوراق المالية Securities Market Types:

تقسم أسواق الأوراق المالية من حيث الإصدار والتداول إلى (Mishkin F., Eakins, 2012 - p19.) :

1. السوق الأولية Primary Market:

وهي السوق التي يتم فيها التعامل بالأوراق المالية لأول مرة، عبر الاكتتاب العام، وذلك بإصدار هذه الأوراق عند التأسيس أو عند زيادة رأس المال، وتتولى عملية الإصدار مؤسسات خاصة بذلك. فهي السوق التي تجمع المستثمرين بالشركات.

2. السوق الثانوية Secondary Market:

وهي السوق التي يتم التداول فيها ما تم إصداره والاكتتاب عليه في السوق الأولية، والتي تجمع البائع والمشتري لتداول هذه الأوراق فيما بينهم، ويقسم هذ السوق إلى نوعين:

- السوق النظامية (البورصة) Organized Market: وهي السوق التي يتم تداول الأوراق المالية فيها من خلال قوانين وإجراءات خاصة في السوق في مكان محدد.
- السوق غير النظامية Unorganized market: وهي السوق التي يتم فيها تداول الأوراق المالية مباشرة خارج البورصة Over The Counter (OTC)، وهي لا تختلف كثيراً عن الشكل السابق إلا أنها لا تجمع المتعاملين بمكان محدد ولا تحكمها قوانين وإجراءات خاصة.

3.مفهوم التحليل الفني Concept of Technical Analysis (.Schannep J, 2008,p3 - 4.):

تعتمد الفكرة الأساسية من التحليل الفني على المقولة «التاريخ يعيد نفسه»، أي سلوك أسعار الأسهم في الفترات الماضية سوف تتكرر مستقبلاً، ومن خلال دراسة هذا السلوك يمكن التنبؤ بالاتجاهات المستقبلية للأسهم وهذا يعني اتخاذ القرار السليم في الوقت المناسب، وتعود أصول فلسفة التحليل الفني إلى نظرية (داو) (Dow Theory) ، حيث قام (داو جونز) (Dow Jones) بدراسة تغيرات اتجاهات حركة السهم في السوق عبر الزمن بتأثير العرض والطلب، وكان معظم ما جاء به (داوجونز) عبارة عن مجموعة من المقالات نشرت في صحيفة (وولستريت) (Wall Street Journal) ، إلا أن في عام (1966) قام (روبرت ليفي) (Levy) بتقديم ملخص عن هذه النظرية بنقاط عدة أهمها:

1. مؤشرات التحليل الفني (سرور منال، 2014 – ، ص 126)

هي عبارة عن مجموعة من المقاييس تعمل على دراسة حركة أسعار الأسهم التاريخية، بهدف التنبؤ باتجاه أسعارها مستقبلاً، وتوجد العديد من مؤشرات التحليل الفني؛ لهذا يلجأ المحللون إلى استخدام مؤشرات عدة قد تكون خمسة أو ستة كحد أقصى حيث يعتقد البعض أن استخدام كثير من المؤشرات يسبب ارتباك للمحللين، وتتكون هذه المؤشرات من صيغ رياضية تعتمد في حسابها على سعر الإغلاق في فترة زمنية معينة، وبعضها يأخذ في عمليات الحساب سعر أعلى صفقة وأدنى صفقة خلال نفس الفترة، وهذه المؤشرات المستخدمة بالبحث وهي:

- 1.1. مؤشر منحنى الإشارة (Signal) :

إذ يقوم بحساب المتوسط الأسي للمؤشر (MACD) لـ (9) فترات زمنية ويسمى بالمنحنى الإشارة ويحسب كما يلي:

Signal = EMA9 of MACD

فكلما زادت قيمة المؤشر (Signal) عن مؤشر (الماكد) تعطي إشارة بيع، والعكس بالعكس.

المتوسط المتحرك الأسي Exponential Moving Average (EMA)يعتبر المتوسط الأسي متوسط تراكمي يقوم بإعطاء وزن إضافي لأسعار الإغلاق الحديثة لتصبح أكثر استجابة لبيانات الأسعار الجديدة، ويحسب كما يلي:

$$EMAN= (CT * a) + (EMAT - 1 * (1 - a))$$

$$a = 2/ (1+N)$$

(C_T) : السعر لليوم الحالي

(N): طول السلسلة الزمنية (المدة الاساس لبناء المتوسط المتحرك الاسي)

- 2.1. مؤشر الستوكاستيك Stochastic Oscillators (OSC - %K, %D):

هي عبارة عن مؤشرات حركية تستخدم لقياس حالة التشبع في البيع والشراء، ومقارنة سعر الإغلاق مع أعلى مستويات للسعر وأدناها خلال فترة زمنية معينة، أي عندما يقترب سعر الإغلاق من أعلى سعر يكون دليلا على وجود ذروة شراء، أما في حال اقترابه من أدنى سعر فيدل على وجود ذروة بيع، حيث يتكون هذا المؤشر من خطين، خط سريع يطلق عليه (%K) وخط بطيء يطلق عليه (%D) ، إذ يعتبر الخط (%K) أكثر حساسية من الخط (%D) لقدرته

على تحديد الأماكن التي تكون فيها علاقة بين سعر الإغلاق عند فترة زمنية معينة، وأسعار الإغلاق الحديثة ضمن نطاق تداول لفترة محددة، وغالباً ما تكون هذه الفترة (14 ساعة أو يوما) ، ويحسب وفق المعادلة التالية:

$$K\% = 100 * [(C - L14) / (H14 - L14)]$$

حيث: (C) تمثل آخر سعر إغلاق، (L14) أدنى سعر سجل خلال (14) فترة زمنية، (H14) أعلى سعر سجل خلال (14) فترة زمنية.

أما الخط الثاني (D%) فيمثل متوسط ثلاث فترات من الخط (K%) ، ويسحب كما يلي:

$$\%D = SMA\ 3\ of\ \%K$$

$$\%D = SMA_{\ 3\ of\ \%K}$$

$$SMA_N = \frac{C_T + C_{T-1} + C_{T-2} \ldots C_{T-N}}{N}$$

حيث (CT) سعر الإغلاق اليوم، (1 - CT) سعر الإغلاق في اليوم السابق وهكذا، (N) طول سلسلة المتوسط وتعبر عن الأيام.

لينتج عن المعادلتين السابقتين منحنيين خطيين يتذبذبان بين (0 و 100) ، فعندما يتقاطع الخطان فوق مستوى الـ (75) تتكون حالة الإفراط في الشراء (Over Bought) ؛ ليكون القرار عندها عملية بيع، أما في حال تقاطع الخطان تحت المستوى (25) فتكون حالة الإفراط في البيع (Over Sold) ليكون القرار عندها شراء.

- 3.1. مؤشر لاري ويليامز (Larry Williams (%R:

إن آلية عمل هذا المؤشر متشابها مع آلية عمل المؤشر السريع (K%) ، إلا أن المؤشر (Larry) يقوم بإيجاد نقاط البيع أو الشراء بدون وجود مؤشر آخر معه، ويحسب من المعادلة التالية:

$$\%R = [(H14 – C) / (H14 – L14)] * -100$$

حيث تتراوح قيمة المؤشر بين (0 و100 –) ، فإذا كانت قيمة المؤشر قريبة من الحد العلوي (– 20) تكون حالة ذروة شراء، أما في حال كانت قيمة المؤشر قريبة من الحد السفلي (– 80) فتكون حالة ذروة بيع.

- 4.1. مؤشر التذبذب الذي يعكس معدل التغير Rate of Change Oscillators (ROC) :

هو مؤشر مشابه للمؤشر (MT) ، يستخدم لقياس التغير في سعر الإغلاق ولكن كنسبة مئوية، أي يقوم بقياس مقدار التسارع أو التباطؤ لحركة سعر الإغلاق أو سرعة اتجاه الأسعار كنسبة مئوية، ويحسب من العلاقة التالية:

$$ROCT = [(CT/ CT - X) - 1] * 100$$

حيث: (CT) هي سعر إغلاق السهم عند لحظة زمنية معينة (T) مثلاً يوم، (X++ - CT) سعر الإغلاق قبل (X) يوم من (T).

3 The concept of neuronal net-work (قطان عبد الباسط ـ 2017، ، ص 38)

- الشبكات العصبونية الحية Biological Neural Network

يعتبر العصبون البيولوجي عنصر الحساب الأساسي في الأنظمة البيولوجية الحية، وهو عبارة عن خلية صغيرة جداً تستقبل تنبيهاً إلكترو كيميائياً من منابع عديدة، وتستجيب بتوليد نبضات كهربائية ترسل إلى عصبونات أخرى أو خلايا مؤثرة.

هناك عدد كبير جداً من العصبونات في الجهاز العصبي لدى الانسان، يستطيع كل منها تخزين (بتات) عدو (bits) من المعلومات، حيث تستقبل العصبونات إشارات الدخل أو التنبيه من الخلايا الحسية، وترسل المخارج إلى العصبونات أخرى، أو أعضاء مؤثرة كالعضلات أو الأطراف.... الخ.

إن قرابة (10%) من العصبونات هي عصبونات دخل (مورد) وخرج (مصدر) و (90%) الباقية هي وصلات مع العصبونات الأخرى التي تخزن المعلومات أو تؤدي إلى تحويلات متنوعة على الإشارات المرسلة خلال الجملة العصبونية، ويتألف العصبون من: نواة، وجسم الخلية، وخطوط عديدة متفرقة شجرياً، وتعتبر وصلات من عصبونات لأخرى عبر الألياف ومحور يحمل كمون الخرج الفعال إلى عصبونات أخرى عبر خطوط التهابات والألياف.

- الشبكات العصبونية الاصطناعية Artificial neural networks

تعد الشبكات العصبونية الاصطناعية إحدى التقنيات التي تساعد في إيجاد الحلول البديلة للمسائل المعقدة من خلال قدرتها على معالجة البيانات دون الحاجة إلى صياغة مسبقة.

تتألف الشبكات العصبونية الاصطناعية من عقد (Neurons) أو وحدات معالجة متصلة معاً لتشكيل شبكة من العقد حيث كل اتصال بين هذه العقد يمتلك مجموعة من القيم تسمى الأوزان تسهم في تحديد القيم الناتجة عن كل عنصر معالجة بناء على القيم الداخلة لهذا العنصر فوحدات الإدخال تكون طبقة تسمى طبقة المدخلات، ووحدات المعالجة تكون طبقة المعالجة، وهي التي تخرِج نواتج الشبكة، وبين كل طبقة من هذه الطبقات هناك طبقات مخفية 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 إذن يمكن القول بأنها نموذج يحاكي الشبكات العصبونية الطبيعية البيولوجية هذه الشبكات لديها المقدرة على محاكاة سلوك النظام للعصبي الطبيعي لحل المشاكل المعقدة (Dweib, D. M., & Abuz-ir, D. Y. (2018) , Palestine.p35.).

- خوارزمية الشبكة العصبونية المتعددة الطبقات Multi - layer perceptron:

وهي شبكة تتألف من طبقات عدة مخفية، وطبقة إدخال، وطبقة إخراج حيث تترابط فيما بينها بالأوزان، وهذه الشبكات قادرة على حل مشاكل أكثر تعقيداً من الشبكات وحيدة الطبقة.

ويمكن تلخيص عمل الشبكات العصبونية في التنبؤ بالخطوات التالية (جمعة درويش. 2019، ص80) :

- 1. اختيار المتغيرات: يتم اختيار المشاهدات للمتغيرات التي تمثل المشكلة.
- 2. معالجة البيانات: هو أجراء بعض العمليات على

البيانات المستخدمة، مثل: إيجاد توزيع البيانات.

- 3. تقسيم البيانات إلى مجموعة تدريب، ومجموعة اختبار حيث تكون بيانات تدريب النسبة كبيرة من اجمالي البيانات.

والشكل التالي يبين الخطوات التي سنتبعها في استخدام الشبكات العصبونية والتي تعكس مخطط البحث:

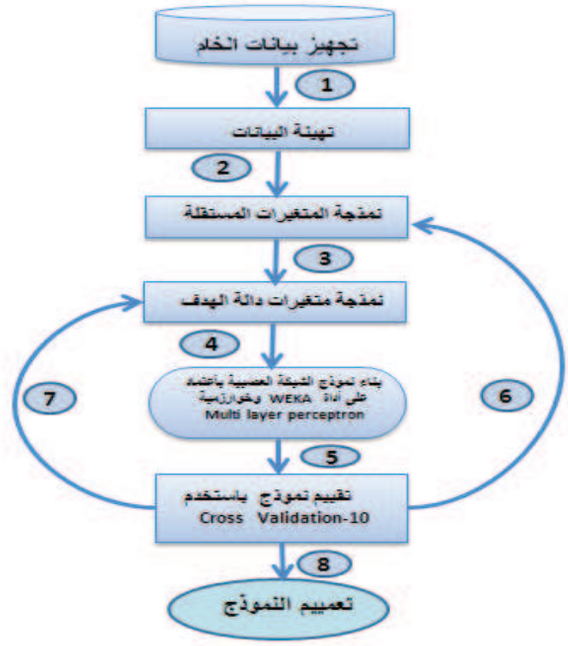

الشكل (1)

يعكس خطوات نمذجة واستخدام الشبكة العصبونية

4.الإطار النظري للتنقيب في البيانات:

- مفهوم التنقيب في البيانات **concept of data mining**:

هي عملية البحث في قواعد البيانات (مستودع البيانات) عن معرفة غير مكتشفة وهي خطوة أساسية لتطبيق أساليب ذكية تهدف إلى الكشف عن أنماط البيانات المهمة والمخبأة في مجموعات البيانات الكبيرة.

وهناك العديد من التقنيات المستخدمة في التنقيب في البيانات، حيث يرى (Dunham) بأنه يمكن تصنيف تقنيات التنقيب في البيانات بحسب الاستخدام إلى مجموعتين أساسيتين هما (Dunham, M.H., 2003, p5.)

- التنبؤ Forecasting: من تقنيات التنقيب في البيانات التي تخدم التنبؤ هي:

(التصنيف، الانحدار، تحليل السلاسل الزمنية).

- الوصف description: من تقنيات التنقيب في البيانات التي تخدم الوصف هي:

(اكتشاف التسلسل، قواعد الارتباط، العنقدة، التلخيص، المرئية).

يركز هذا البحث بشكل أساسي على اختيار الشبكة العصبونية الخاصة بتقنية التصنيف للاستفادة من قدرتها على بناء نموذج قادر على التنبؤ بحركة أسعار الأسهم.

- مصفوفة التشويش (الشك): (GUPTA L., et al., 2012, p41.)

هي مصفوفه تساعدنا على تقيم دقة النموذج حيث تبين عدد السجلات التي تم التنبؤ بها بشكل صحيح بالنسبة لكل صنف من الأصناف.

		القيم المتنبئ بها	
		a = YES	b = NO
القيم الفعلية	a = YES	True Positive (TP) الصحيحة الإيجابية	False Negative (FN) الخاطئة السلبية
	b = NO	False Positive (FP) الخاطئة الإيجابية	True Negative (TN) الصحيحة السلبية

الشكل (2)

حالات التصنيف المختلفة في مصفوفة التشويش

عند قراءة المصفوفة من الشكل رقم (2) يجب النظر إلى القطر الرئيس من أعلى اليسار إلى أسفل اليمين في المصفوفة وكل قيمه تقع خارج القطر الرئيس هي قيمة مصنفة بشكل خطأ.

أما المقاييس التي يمكن أن يتم حسابها اعتماداًعلى مصفوفة (الطويل هالة، 2009 – التنقيب عن البيانات 2009، كتاب دار شعاع للنشر والعلوم، سورية، ص 156) فهي:

- الصحيحة الإيجابية (TP) : عندما تكون قيمتها الفعلية إيجابية، وتم التنبؤ بها، أو تصنيفها على أنها إيجابية.
- الصحيحة السلبية (TN): عندما تكون قيمتها الفعلية سلبية، وتم التنبؤ بها أو تصنيفها على أنها سلبية.
- الخاطئة الإيجابية (FP) : عندما تكون قيمتها الفعلية سلبية وتم التنبؤ بها أو تصنيفها على أنها إيجابية.
- الخاطئة السلبية (FN) : عندما تكون قيمتها الفعلية إيجابية وتم التنبؤ بها أو تصنيفها على أنها سلبية.

- تقيم نموذج الشبكة العصبونية:

سوف نعتمد في هذا البحث على طريقة (10 - Cross - validation fold) باستخدام أداة (WEKA) ، في تدريب البيانات التاريخية واختبارها لأسعار الأسهم للنموذج الشبكة العصبونية حيث يقوم هذا الأسلوب على تقسيم مجموعة البيانات الكلية إلى مجموعات عدة متساوية من حيث عدد السجلات، مثلاً عشر مجموعات متساوية، ثم يقوم بعملية التدريب والاختبار بشكل تكراري عدداً من المرات مساوياً لعدد مجموعات البيانات.

بعد إجراء عملية التقييم للنموذج تكون قد حصلنا على النموذج النهائي بدرجة محددة من النجاح والفشل والسؤال هل دقة النموذج مقبولة أم لا؟ هذا ما يحدده خبراء المجال الذي يتم دراسته.

هناك العديد من مقاييس تقيم النموذج يمكن استخدامها منها:

دقة التصنيف (Precision) وإحصائية (Kappa) ونسبة التصنيف الصحيح الإيجابي و (F - measure) و (Recall و ROC Area).

- يعبر معامل إحصائية (Kappa) : عن نسبة النجاح

المثالية للتصنيف حيث تعمل على قياس التوافق بين التصنيف والقيم الفعلية بعد طرح التوافق العشوائي الناتج عن الصدفة، ويأخذ هذا المقياس قيمة بين الصفر والواحد، وكلما اقتربت نتيجة هذا المقياس إلى الواحد تعتبر دقة النموذج عالية، فإذا كانت قيمة (Kappa) ضمن المجال [0.40 – 0.59] فعندئذ درجة النجاح في التصنيف معتدلة، أما إذا كانت قيمة (Kappa) ضمن المجال [0.60 – 0.79] عندئذ درجة النجاح في التصنيف كبيرة، وأخيراً إذا كانت قيمة (Kappa) ضمن المجال [0.80 – 1.00] عندئذ درجة النجاح في التصنيف رائعة وهي جيدة (ساكت غسان، عداس ضحى، 2015، ص10)

- معامل الاستدعاء Recall: يعبّر عن النواحي التي صنفت على أنها إيجابية صحيحة وهي في الواقع إيجابية صحيحة.

- دقة التصنيف Precisio: يسمى بمعامل التحقيق، ويحدد هذا المقياس نسبة السجلات التي يتبين أنها إيجابية والتي صرح المصنف بأنها إيجابية.

- التصنيف الصحيح الإيجابي.

- نسبة التصنيف الصحيح الإيجابي Measure (F-) : يلخص هذا المقياس كلاً من معامل الاستدعاء Recall والتحقيق Precision، ويمثل متوسطاً توافقياً بينهما.

- ROC Area – : يُعبّر مقياس التقييم (Area ROC) عن قدرة النموذج على تصنيف بيانات الاختبار بشكل صحيح، وهو يعتبر من أهم المقاييس، وأقل قيمة يأخذها (صفر) ، وأكبر قيمة (واحد) ، ويكون التصنيف أفضل كلما اقتربت قيمته من (الواحد) وعندما يأخذ هذا المقياس قيمة (0.5) يكون النموذج في حالة عدم التمييز.

- الحالة التطبيقية العملية:

إن البيانات التي سوف نستخدمها في هذا البحث هي بيانات الأسهم التاريخية من الموقع الرسمي لبورصة عمّان على شبكة (www.ase.com.jo/ ar) حيث تضمنت (343) سجلا يخص الأسعار اليومية التاريخية للأسهم بين عامي (2017 – 2018) ، وتم اختيار العامين (2017 – 2018) دون غيرهما من الأعوام بناءً على البيانات المتاحة على الموقع من حيث حجم التداول وإمكانية الوصول والخلو من الأخطاء قدر الإمكان وهي بيانات التي تخدم البحث.

سوف نعتمد طريقة الاختبار Cross - validatio 10 - حيث سيتم في هذه الطريقة اخذ نسبة (90%) من البيانات من اجل التدريب و (10%) من أجل الاختبار ويتم إجراء الاختبار ثم سنقوم بعكس العملية لتصبح جزءا من بيانات لتدريب الاختبار وبيانات الاختبار تصبح تدريب ويتم الحصول على الخطأ الكلي بجمع أخطاء المرحلتين.

سنقوم بتهيئة بيانات التدريب لكي تتناسب مع خوارزمية الشبكة العصبونية المستخدمة وهي (Multilayer perceptron) ذات الانتشار العكسي الخاصة بالتصنيف وبناء نموذج الشبكة العصبونية باستخدام برنامج (weka 3.6.11) ، ثم نقوم بحفظ النموذج واختبارها بالاعتماد على بيانات الاختبار لمعرفة كفاءة نموذج التدريب ومدى قدرته على التنبؤ بالقيم الجديدة. الشكل (3) يوضح جزءا من البيانات بعد تهيئتاها قبل إجراء عملية التدريب لخوارزمية (ANN).

```
١  @relation 111111
٢  @attribute k numeric
٣  @attribute D numeric
٤  @attribute signal numeric
٥  @attribute R numeric
٦  @attribute ROC numeric
٧  @attribute G {up,down,hold}
٨
٩  @data
١٠ up،١,٨٨٦٧٩٢-،١٠٠-،٠،٠،١,١٩٠٤٧٦
١١ up،٢,٤٠٦٤١٧-،٩٢,٨٥٧١٤٣-،٧,١٤٢٨٥٧،٢,٣٨٠٩٥٢،٠,٥٩٥٢٣٨
١٢ down،٢,١٢٧٦٦-،٧١,٤٢٨٥٧١-،١٤,٢٨٥٧١٤،٧,١٤٢٨٥٧،٢,٣٨٠٩٥٢
١٣ down،٧,٤-،٨٥,٧١٤٢٨٦-،٠،٧,١٤٢٨٥٧،٦,٥٤٧٦١٩
١٤ down،٣٣,٣٣٣٣٣٤-،٣٣,٣٣٣٣٣٤،١٧,١٤٢٨٥٧،٨,٥٤١٦٦٧
١٥ down،٠,٢٧٣٢٢٤-،٤٤,٤٤٤٤٤٤-،٠،٢٠،١١,٧٥٥٩٥٢
١٦ down،٠,٨٢٤١٧٦-،٨٠-،٠،١٠,٧١٤٢٨٦،١٣,٨٣٩٢٨٦
١٧ down،١,٣٧٣٦٢٦-،٦٢,٥-،٠،٠،٢,٦٧٨٥٧١
١٨ up،٣,٨٢٥١٣٧-،١٠٠-،٠،٠،٠
١٩ up،١١,١١١١١١،١,١٤٣٨٣٦-،٨٥,١٨٥١٨٥،٣٧,٨٧٨٧٨٨،١٣,٠٠٩٨٥٤
٢٠ down،٦,٨٩٦٥٥٢،٤,١٧٨٢٧٣-،٨٩,١٥٥١٧٢،٩٠,٨٠٤٥٩٨،٨٤,٨٥٥٦٨٨
٢١ down،٣,١٢٥،٧,٣٨٦٣٦٤-،٨٧,٥،٩٠,١٠٩٨٩،٩٠,٣٦٩٦٨٨
٢٢ down،٦,٢٥،٦,٤٩٧١٧٥-،٩٠,٦٢٥،٩٠,٤٢٥٥٣٢،٩٠,٢٧٤٩٢١
٢٣ down،٩,٣٧٥،٦,٢١٤٦٨٩-،٨٧,٥،٨٨,٥٤١٦٦٧،٨٩,٩٩٦٥٤٥
٢٤ up،١٥,٦٢٥،٥,٣٥٢١١٣-،٨٤,٣٧٥،٨٧,٥،٨٩,١٤٤٢٧٧
```

الشكل (3)

شكل البيانات بعد التهيئة لتدريب خوارزمية ANN

تتكون قاعدة بيانات الحالة التطبيقية العملية من (4) متغيرات مستقلة، وهي مجموعة من المؤشرات الفنية الموجودة المستخدمة في تحليل الأسهم في الأسواق المالية (مؤشر منحنى الإشارة (Signa) مؤشر (الستوكاستيك) Stochastic Oscillators (OSC - %K, %D)، مؤشر لاري (ويليامز %R) Larry Williams، ومؤشر التذبذب الذي يعكس معدل التغيير Rate of Change Oscilla-tors ROC) ومتغير تابع (متغير الهدف رمزه G) الذي يعكس سعر الأغلاق اليومي للأسهم. والشكل (4) يوضح شكل جزء من البيانات وبالمتغيرات المستقلة ومتغير الهدف كما هي في أداة (WEKA).

No.	k Numeric	signal Numeric	R Numeric	ROC Numeric	G Nominal
1	0.0	1.190...	-100.0	-1.886...	up
2	7.142...	0.595...	-92.85...	-2.406...	up
3	14.28...	2.380...	-71.42...	-2.12766	down
4	0.0	6.547...	-85.71...	-2.4	down
5	33.33...	8.541...	-33.33...	0.0	down
6	0.0	11.75...	-44.44...	-0.273...	down
7	0.0	13.83...	-80.0	-0.824...	down
8	0.0	2.678...	-62.5	-1.373...	down
9	0.0	0.0	-100.0	-3.825...	up
10	85.18...	13.00...	-11.11...	1.643...	up
11	89.65...	84.85...	-6.896...	4.178...	down
12	87.5	90.36...	-3.125	7.386...	down
13	90.625	90.27...	-6.25	6.497...	down

Undo OK Cancel

الشكل (4)

جزء من البيانات والمتغيرات المستقلة ومتغير الهدف في أداة (WEKA)

بناء نموذج الشبكة العصبونية ومعرفة مدى دقتها:

من خلال برنامج الـ (WEKA) سنقوم بتحضير البيانات المراد العمل عليها واختيار نوع التصنيف على أنه شبكة عصبية واختيار خوارزمية الشبكة العصبونية من نوع Multilayer perceptron.

سوف تركز الدراسة العملية على مرحلتين هما مرحلة التدريب ومرحلة الاختبار مع التقييم الدقيق في كل مرحلة باستخدام

الاختبار (Cross validation fold10) والجدول التالي يبين بنية الشبكة العصبونية الناتجة عن عملية التدريب والاختبار، والجدول رقم (1) يوضح بنية الشبكة العصبونية الناتجة عن عملية التدريب والاختبار.

جدول (1)

بنية الشبكة العصبونية الناتجة عن عملية التدريب والاختبار

معدل التعليم Learning Rate	وسيط عزم التحريك Momentum	عدد الطبقات المخفية Hidden Layers	عدد مرات التدريب Eqoch
.1 .2		3	3000

نلاحظ من الجدول السابق اعتماد البحث على عدد دورات التدريب الشبكة العصبونية بلغت (3000) حتى الوصول دالة الخطأ لأقل نسبة ممكنة، ووسيط العزم التحريك حيث تم إدخال قيمة (0.2) لا يجعل معدل الخطأ في كل دورة أقل ما يمكن وهي مناسبة للنموذج المدروس كان معدل تعليم (0.1) ؛ لتكون التغيرات في شعاع الأوزان صغير لتصنيف احتمالية وجود اختلافات في الأوزان، وكانت عدد الطبقات المخفية (3) طبقات للوصول إلى الهدف المطلوب. الجدول (2) يوضح تقييم عملية التدريب والاختبار للنموذج الشبكة العصبونية.

جدول (2)

ملخص عملية التقييم لمجموعة بيانات في مرحلة التدريب والاختبار

	عدد السجلات	القيمة
نسبة السجلات المصنفة بشكل صحيح	268	78.1341%
نسبة السجلات المصنفة بشكل خاطئ	75	21.8659%
العدد الكلي للسجلات	343	
معامل Kappa		.6146

الجدول (2) يبين لنا عدد حالات التصنيف الصحيح (268) في مجموعة التدريب والاختبار ونسبتها المئوية (78.1341%) ، بينما عدد حالات التصنيف الخطأ (75) ونسبتها المئوية (21.8659%). والمجموع الكلي لسجلات البيانات (343)، وقيمة إحصائية (Kappa) تساوي (0.6146)، وتعبر عن نسبة نجاح النموذج، فهي تقيس التوافق بين القيم المتوقعة والقيم الفعلية، ويأخذ هذا المعامل قيمه بين (1–، 1+) وكلما زادت قيمة هذا المقياس زادت دقة نموذج التصنيف وكفاءته، ونقصت قيمته يصبح التنبؤ عشوائي (1 –). يوضح الجدول رقم (3) البيانات التفصيلية المعبرة عن دقة التصنيف.

جدول (3)

تفاصيل دقة التصنيف لمجموعة التدريب

	TPRate	FP Rate	Precision	Recall	F - Measure	ROC Area	Class
	.869	.158	.816	.869	.842	.901	up
	.886	.206	.767	.886	.822	.92	down
	.073	.017	.375	.073	.122	.633	hold
Weighted Avg.	.781	.162	.742	.781	.747	.877	

حيث العمود TP Rate: يعبر عن نسبة التصنيف الصحيح الإيجابي لكلٍ من حالات (up ، down , hold) وبلغ (0.781%) تدل على كفاءة النموذج؛ لأنها قريبه من الواحد الصحيح.

العمود (FP Rate) : يعبر عن نسبة التصنيف الخطأ الإيجابي لكلٍ من حالات اختيار التخصصات، وهذه النسبة كلما انخفضت تدل على كفاءة النموذج.

العمود Precision: يعبر عن نسبة دقة التصنيف لكلٍ من حالات، وهي مرتفعة وتدل على قدرة النموذج على التنبؤ.

الأعمدة Recall، F - Measure، ROC area: عبارة عن مقاييس مختلفة لتقييم النواحي الإيجابية الخطأ مقابل السلبية الخطأ.

والجدول التالي يوضح مصفوفة التشويش الناتجة عن عملية الاختبار التدريب:

جدول (4)

مصفوفة التشويش الخاصة بعملية الاختبار

A	B	c	Classified as	
133	18	2	a	Up
14	132	3	b	down
16	22	3	C	Hold

نلاحظ من الجدول (4) لمصفوفة التشويش انه كلما كانت القيم أعلى أو أسفل القطر الرئيس أقل كان النموذج أفضل (التشويش أقل) وهذه الارقام الموجودة في مصفوفة التشويش جدول رقم (5) تعبر عن البيانات المستخدم في الدراسة فالنسبة للفئة (up) فإن مجموع بياناتها يساوي (153) منها (133) مصنفة بشكل صحيح، والباقي مصنف بشكل خطأ، وهكذا بالنسبة لباقي الفئات أي من خلال قراءة مصفوفة التشويش يمكن معرفة أي من الفئات التي تضعف التنبؤ.

النموذج المقترح للتنبؤ بالقرارات الخاصة بحركة وتداول الاسهم في سوق عمان

بعد ان تم استعراض أهم النتائج التي تم التوصل إليها بتطبيق تقنيات الذكاء الصنعي المتمثلة بالشبكات العصبونية Multi layer perceptron ذات الانتشار العكسي لبناء نموذج قادر على التنبؤ بحركة أسعار الأسهم حيث تم الاعتماد على أداة (weka 3.6.11) لبناء النموذج التنبؤي وطريقة الاختبار (10 - Cross - valida-tio)حيث سيتم في هذه الطريقة اخذ نسبة (90%) من البيانات من أجل التدريب و (10%) فإن الباحث سيقدم في هذه الفقرة مكونات النظام المقترح من حيث المدخلات والمخرجات والعمليات التي يقوم بها بالإضافة لتوصيف آلية عمله، وهي وفق المراحل التالية:

- 1.5 المدخلات:

وتتضمن المدخلات التالية: هي عبارة عن أربعة متغيرات مستقلة المتمثلة بمؤشرات التحليل الفني التي تؤثر على قرار التداول الخاصة بحركة أسعار الأسهم، وهذه المؤشرات هي (مؤشر ننحنى الإشارة Signal، مؤشر الستوكاستيك Stochastic Oscilla-tors (OSC - %K, %D، مؤشر لاري ويليامز %R) Larry Williams، ووشر التذبذب الذي يعكس معدل التغير Rate of Change Oscilla-tors ROC) ومتغير تابع (متغير الهدف) الذي يعكس سعر الإغلاق اليومي للأسهم.

- 2.5 المخرجات:

- هي عبارة عن تقارير للتنبؤ بالأسهم الرابحة أي المرتفعة
- تقارير عن الأسهم ذات الأسعار الهابطة.
- تقارير للتنبؤ بالإجراء عملية التداول في الوقت المناسب.

- 3.5 العمليات:

يقوم النموذج بالعمليات التالية:

- التنبؤ بحالات ربحية مناسبة للأسهم.
- حساب مؤشرات التحليل الفني.
- التنبؤ بقرارات التداول سواء بيع أو شراء.
- تقسيم البيانات إلى بيانات تدريب وبيانات اختبار حسب نسبة التقسيم.

والشكل التالي يبين بنية النموذج المقترح للتنبؤ بحركة أسعار الأسهم بالاعتماد على المؤشرات الفنية:

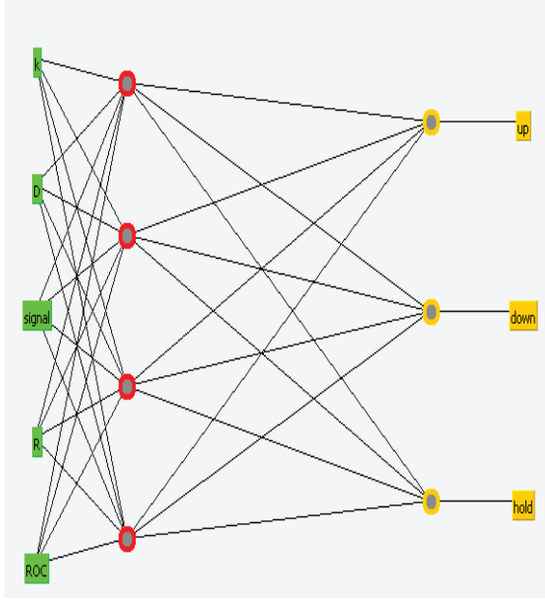

شكل (4)

يوضح بنية النموذج المقترح للتنبؤ بأسعار الاسهم

6. النتائج:

- قدرة وكفاءة خوارزمية الشبكة العصبونية (Multilayer perceptron) على بناء نموذج قادر على دعم القرارات الخاصة بالتداول في سوق الأوراق المالية لمدة يوم.
- إضافة طريقة جديدة تعتمد على الذكاء الصنعي (نماذج الشبكات العصبونية) بعيداً عن الأساليب التقليدية للتنبؤ بحركة أسعار المستقبلية للأسهم.
- أظهرت نتائج التدريب والاختبار (343) سجلا باستخدام خوارزمية Multilayer perceptron أن (268) سجلا صنف بشكل صحيح أي بنسبة (78.1341%و75) سجلا صنفوا خطأ بنسبة (21.8659%) وهذا يدل على كفاءة النموذج كما أكد على نجاح نموذج التدريب معامل (Kappa) الذي يساوي (0.6146) وهي نتيجة جيدة جداً لقربها من الواحد الصحيح.
- أظهرت النتائج أن الحالات خارج القطر الرئيس للمصفوفة التشويش عددها (75) حالة، وهي تدل على الحالات المصنفة بشكل خطأ من أصل (343) حالة بالنسبة لمرحلة الاختبار والتدريب وهي نتيجة جيدة.

7. التوصيات:

1. نوصي باستخدام تقنية الشبكة العصبونية (Multilayer perceptron) لما له من دقة عالية في تصنيف البيانات التاريخية لأسعار اليومية للأسهم.

2. نوصي باستخدام تقنيات أخرى لبناء نماذج تدعم قرارات التداول في سوق الأوراق المالية.

3. وجود الخبرة في مجال التطبيق للحكم الفعلي على النماذج وتحليل مصفوفة التشويش بشكل معمق عند كل فئة بشكل يتناسب مع طبيعة القرارات المتخذة عبر قياس منفعة، وتكلفة القرار عند كل فئة، وذلك للنماذج التي تتمثل بعدة فئات ولكل فئة

أهمية نسبية مختلفة.

4. استخدام مؤشرات التحليل الفني لتحديد سلوكيات الأسهم على المستويات الزمنية الأطول نسبياً، وذلك اعتماداً على مؤشرات فنية عدة.

5. تطبيق خوارزميات ذكاء الاصطناعي أخرى من أجل مسألة التنبؤ باتجاه تحركات أسعار الأسهم، وفق أسلوبي النمذجة، والتقييم المقترح من الباحث.

6. استخدام أداة التنقيب في البيانات WEKA والتي تعد أداة مجانية Open Source والتي توفر تكلفة تصميم البرنامج، وتكلفة صيانته وتكاليف أخرى.

8. الخلاصة

من خلال الدراسة العلمية والتطبيقية على سوق عمان للأوراق المالية تم بناء نموذج قادر على دعم القرارات الخاصة بالتداول في سوق الأوراق المالية لمدة يوم باستخدام تقنيات التصنيف (الشبكات العصبونية الاصطناعية) كإحدى تقنيات التنقيب في البيانات، لتصنيف تحركات أسعار الأسهم حيث أظهرت نتائج التدريب والاختبار الخاصة بالنموذج (343) سجلا (العدد الكلي للسجلات) باستخدام خوارزمية Multilayer perceptron منها (268) سجلا صنف بشكل صحيح أي بنسبة (78.1341%) و (75) سجلا صنفوا خطأ بنسبة (21.8659%) ، وهذا يدل على كفاءة النموذج كما أكد على نجاح نموذج التدريب معامل (Kappa) الذي يساوي (0.6146) وهي نتيجة جيده جداً لقربها من الواحد الصحيح.

إضافة إلى ذلك تم اقتراح طريقة جديدة تعتمد على الذكاء الصنعي (نماذج الشبكات العصبونية) بعيداً عن الأساليب التقليدية للتنبؤ بحركة أسعار المستقبلية للأسهم.

المصادر والمراجع العربية:

- برودي، نعيمة – 2013، إستراتيجيات المضاربة في سوق الأوراق المالية باستعمال المؤشرات الفنية، المجلة الاقتصادية جامعة محمد بوقرة ، الجزائر.
- جمعة درويش. (2019) فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية: مقارنة بنموذج الانحدار الذاتي، مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية، فلسطين
- جواد، عبد المجيد – (2015) ، التنبؤ بحركة الأسهم المتداولة في سوق الأوراق المالية باستخدام تقنيات الذكاء الاصطناعي، أطروحة دكتوراه قسم الإحصاء ونظم المعلومات، جامعة حلب، حلب، سورية.
- حسين عصام، (2008) – أسواق الأوراق المالية (البورصة) ، دار أسامة للنشر والتوزيع الكتب الوطنية العدد (1) ، عمّان، الأردن.
- زيد حياة (2015) ، دور التحليل الفني في اتخاذ قرار الاستثمار بالأسهم دراسة تطبيقية في عينة من أسواق المال العربية الأردن، السعودية، وفلسطين، رسالة ماجستير في العلوم الاقتصادية جامعة محمد خيضر، الجزائر.
- ساكت غسان، عداس ضحى، (2015) استخدام شجرة القرار لدعم قرارات منح القروض، مجلة البحوث جامعة حلب، قسم الإحصاء ونظم المعلومات، كلية الاقتصاد، جامعة حلب، حلب، سورية.
- سرور منال، (2014) العوامل المؤثرة في سوق العملات الأجنبية – دراسة تطبيقية على مؤشر الدولار الأمريكي، رسالة ماجستير جامعة دمشق، سورية.
- قطان عبد الباسط (2017) ، التنبؤ بفقدان الزبائن لمخطوط المسبقة الدفع باستخدام الشبكات العصبونية، رسالة ماجستير جامعة حلب، حلب، سورية.
- الطويل هالة، 2009 – التنقيب عن البيانات 2009، كتاب دار شعاع للنشر والعلوم، سورية.

المصادر والمراجع العربية مترجمة:

- *Prodi, Naima , 2013. Speculation strategies in the stock market using technical indicators. , Economic Journal, University of Mohamed Boukara, Algeria.*
- *Jawad Abdel- Majid,2015. Predicting the Movement of Shares Traded in the Stock Market Using Artificial Intelligence Techniques, PhD thesis, Department of Statistics and Information Systems, University of Aleppo, Aleppo, Syria.*
- *Friday Darwish. (2019) - Effectiveness of predicting the Palestine Stock Exchange index using the artificial neural networks model: a comparison of the self- regression model, Al- Quds Open University Journal for Administrative and Economic Research, Palestine*
- *Hussein Issam, 2008. Stock Markets (Stock Exchange) , Osama House for Publishing and Distribution National Books No. (1) , Amman, Jordan.*
- *Zaid Hayat- 2015, the role of technical analysis in making a stock investment decision. An applied*
- *Saket Ghassan, Adas Duha, 2015. Using the decision tree to support loan granting decisions, Research Journal, Aleppo University, Department of Statistics and Information Systems, Faculty of Economics, University of Aleppo, Aleppo, Syria.*
- *Srour Manal, 2014. Factors Affecting the Foreign Currency Market- An Applied Study on the US Dollar Index, MA Thesis, University of Damascus, Syria.*
- *Qattan Abdel- Basit , 2017. Predicting Customers' Loss of Prepaid Lines Using Neural Networks, Master Thesis, University of Aleppo, Aleppo, Syria.*
- *Al- Tawilha, Hala, 2009. Data Mining 2009, Dar Shua` Book for Publishing and Science, Syria*

المصادر والمراجع الأجنبية:

- *Abuzir, E. Y., & Baraka, M. A. M. (2019). Financial Stock Market Forecast Using Data Mining in Palestine. Palestinian Journal of Technology and Applied Sciences (PJTAS) , (2). Palestine.*
- *Dunham, M.H., 2003, data mining introduction and advanced topics, prentice hall.*
- *GUPTA L., et al., 2012, Performance Analysis of Classification Tree Learning Algorithms, Volume 55– No.6, International Journal of Computer Applications, India.*
- *Huang, C. J., Yang, D. X., & Chuang, Y. T.- 2008. Application of wrapper approach and composite classifier to the stock trend prediction. Expert Systems with Applications.*
- *Imandoust, S. B., & Bolandraftar, M. (2014). Forecasting the direction of stock market index movement using three data mining techniques: the case of Tehran Stock Exchange. International Journal of Engineering Research and Applications.*
- *Mishkin F., Eakins, 2012- Financil Markets and*

Institutions,7thED, Pearson, Graduate School of Business, Columbia University, USA

- *Paliyawan P.2015- "Stock Market Direction Prediction Using Data Mining Classification, ARPN Journal of Engineering and Applied Sciences, Thailand.*
- *Ping, H, Tang, L,- 2018, Predict stock market trends using improved Artificial Neural networks (ANN) using Google Trends, Faculty of Science, University of Northern China, China.*
- *Schannep J, 2008 – Dow theory for the 21 st Century, Wiley, New Jersey, Published by John Wiley & Sons, Inc., Hoboken, New Jersey, Canada*
- *Witten I., et al., 2011, Data Mining Practical Machine Learning Tools and Techniques, book, 3rd ed, Morgan Kaufmann, London.*