



مركز الاستشارات والبحوث والتطوير
بأكاديمية السادات للعلوم الإدارية

مجلة البحوث الإدارية

Journal of Management Research

علمية - متخصصة - محكمة - دورية ربع سنوية

للسنة
الثانية والأربعون

Vol. 42, No.2; Apr. 2024

عدد أبريل 2024



www.sams.edu.eg/crdc

رئيس مجلس الإدارة
أ.د. محمد حسن عبد العظيم
رئيس أكاديمية السادات للعلوم الإدارية

رئيس التحرير
أ.د. أنور محمود النقيب
مدير مركز الاستشارات والبحوث والتطوير

ISSN : 1110-225X

اختبار قدرة الشبكات العصبية الاصطناعية على التنبؤ بالسلوك السعري لمؤشرات الأسواق المالية: دراسة اختبارية باستخدام البيانات التاريخية ومؤشرات التحليل الفني

إعداد

د/ أميرة حسنين محمد علي

قسم المحاسبة - كلية الادارة
الجامعة الحديثة للتكنولوجيا والمعلومات

د/ سامح سعيد محمود محمود ضاهر

قسم التمويل والمحاسبة - شعبة ادارة الاعمال
الأكاديمية الدولية للهندسة وعلوم الاعلام

المستخلص:

هدف الدراسة: يكمن الهدف الرئيسي لهذه الدراسة في اختبار قدرة الشبكات العصبية الاصطناعية على التنبؤ بالسلوك السعري لمؤشرات الأسواق المالية باستخدام البيانات التاريخية وبيانات مؤشرات التحليل الفني بالتطبيق على المؤشر الرئيسي للبورصة المصرية EGX30، وذلك خلال الفترة ما بين عامي (2013م : 2022م). وبلغ إجمالي حجم العينة (2437) مشاهدة، وواقع (1569) مشاهدة (بنسبة 65% من إجمالي المشاهدات) تم استخدامها لغرض تدريب الشبكة العصبية، و(868) مشاهدة (بنسبة 35% من إجمالي المشاهدات) تم استخدامها لاختبار قدرة الشبكة العصبية الاصطناعية على التنبؤ لاختبار فرضي الدراسة.

منهجية الدراسة: قام الباحثان بإجراء دراسة اختبارية واستخدام الأساليب الإحصائية لاختبار فرضي الدراسة التي اعتمدت على برنامج " NeuroXL " كبرامج لتطبيق الشبكات العصبية الاصطناعية، وذلك عبر مجموعتين من البيانات، المجموعة الأولى: بيانات تاريخية تشمل كلاً من: (قيمة الفتح، أعلى قيمة لمؤشر خلال جلسة التداول، أدنى قيمة لمؤشر خلال جلسة التداول، قيمة إغلاق المؤشر في نهاية جلسة التداول، وأخيراً حجم التداول خلال تلك الجلسة)، أما المجموعة الثانية فتتضمن بيانات مؤشرات التحليل الفني التي تشمل كلاً من: (المتوسطات المتحركة لمدة (5،7،10،12،14،21،50،100 يوم)، ومؤشر التقارب، والتباعد بين المتوسطات MACD، ومؤشر الزخم Momentum، وأخيراً مؤشر المذبذبات Stochastic) .

نتائج الدراسة: خلصت الدراسة إلى قدرة الشبكات العصبية الاصطناعية على تفسير التحركات السعرية للمؤشر الرئيسي للبورصة المصرية EGX30 باستخدام البيانات التاريخية، وإيضاً باستخدام بيانات مؤشرات التحليل الفني، إلا أن هناك تبايناً في القدرة التفسيرية بين مجموعات البيانات في ضوء طبيعة مدخلات الشبكات العصبية الاصطناعية؛ حيث كان أفضل معامل تحديد طبقاً لشبكة البيانات التاريخية المعيارية (99.8%)، مقابل (65.2%) كأفضل معامل تحديد لشبكة العصبية الفنية المعدلة رقم (3)، وهو الأمر الذي يشير إلى قدرة الشبكات العصبية الاصطناعية على ترشيد قرارات المتعاملين في البورصة المصرية.

المساهمة العلمية: للدراسة الحالية مساهمتان رئيسيتان، أولاهما: تبني المدخل الكمي لاختبار تطبيق الشبكات العصبية الاصطناعية كإحدى آليات الذكاء الاصطناعي في مجالات المحاسبة والمراجعة، وثانيهما: التوصل إلى تباين قدرة الشبكات العصبية على عمليات التنبؤ في مجال أسواق المال اعتماداً على مدخلات الشبكة، ومعمارياتها، عوضاً عن فترة التدريب.

الكلمات الدالة:

الشبكات العصبية الاصطناعية، الأسهم العادية، التحليل الفني، البورصة المصرية، مؤشر EGX30، NeuroXL.

Testing the ability of artificial neural networks to predict the price behaviour of financial market indices

" An empirical study using historical data and technical analysis indicators"

Amira Hasaneen

Faculty of Management,
Modern University for Technology and
Information, MTI ,Cairo, Egypt

Sameh Daher

School of Business
International Academy for Media science
and Engineering, IAMSE, 6th of October
City, Egypt

Abstract:

Study Aims: The aim of this study is to test the ability of artificial neural networks to predict the price behaviour of financial market indices using historical data and technical analysis indicator data by applying it to the main index of the Egyptian Exchange, EGX30, during the period between the years 2013 and 2022. The total sample size was (2437) views, with (1569) views (65% of the total views) being used for the purpose of training the neural network and (868) views (35% of the total views) being used to test the ability of the artificial neural network to make predictions to test the study hypothesis.

Study methodology: The researchers conducted an empirical study and used statistical methods to test the two hypotheses of the study, which relied on the "NeurXL" programme for applying artificial neural networks, through two sets of data. The first set: historical data that includes both: (the opening price, the high price of an index per trading day, the lowest price of an index per trading day, the closing price of an index at the end of the trading day, and addition to the trading volume during trading day. The second group includes data for technical analysis indicators that include: (moving averages for (5, 7, 10, 12, 14, 21, 50, and 100 days), the MACD, the Momentum, addition to the Stochastic oscillator.

Study results: The study concluded that artificial neural networks are able to explain the price movements of the main index of the Egyptian Exchange, EGX30, using historical data, and also using data on technical analysis indicators. However, there is a discrepancy in the interpretive ability between data sets according to the nature of the artificial neural networks' inputs. The best determination coefficient according to the standard historical data network was (99.8%), compared to (65.2%) as the best determination coefficient for the modified technical neural network No. (3), which indicates the ability of artificial neural networks to rationalize the decisions of traders in the Egyptian Exchange.

Study contribution: The current study has two main contributions, the first: adopting a quantitative approach to test the application of artificial neural networks as one of the artificial intelligence mechanisms in the fields of accounting and auditing, and the second: arriving at the variation in the ability of neural networks for forecasting operations in the field of financial markets depending on the network's inputs and architecture, instead addition to the training period.

Key words:

Artificial Neural Networks, Common Stocks, Technical Analysis, Egyptian Exchange, EGX30 index, NeuroXL.

1- الإطار العام للدراسة:

1/1- مقدمة:

تُعد مهنة المحاسبة والمراجعة من المهن الحية التي تتطور وتتكيف مع متغيرات بيئة الأعمال Business Environment Variables ، وهو الأمر الذي يُمكن التذليل عليه بأكثر من صورة، كتطوير المعايير للتوائم مع تطورات بيئة الأعمال (عبدالرحمن، 2022)، وتغير طبيعة العمليات التشغيلية والاستثمارية والتمويلية لمنشآت الأعمال من جانب، واستخدام أدوات جديدة خاصة في مجال الحاسبات وتكنولوجيا المعلومات Computers and Information Technology وكذا الأعمال Business Intelligence (أحمد، 2020) من جانب آخر. وأصبح من الضروري توجه المنشآت إلى اعتماد الذكاء الاصطناعي في أنشطتها (Agustí and Orta-Pérez, 2023)، خاصة في مجالات المحاسبة والمراجعة (Solaimani et al., 2020).

ومع ذلك، يبدو أن عملية اعتماد الذكاء الاصطناعي تختلف من بلد إلى آخر، حتى بين المنشآت في نفس البلد (Gotthardt et al., 2020). وهذا ما يثير بعض الشكوك حول فائدة هذه التكنولوجيا، ويُسمح للمنشآت بأن تكون لديها مخاوف بشأن ما إذا كان اعتماد الذكاء الاصطناعي يستحق العناء أم لا (Solaimani et al., 2020). ومن ثم، يمكن القول إن وجود الذكاء الاصطناعي نفسه قد يُغير عبء العمل للمحاسبين والمراجعين، ويزيد من كفاءتهم وفعاليتهم (Wilson and Daugherty, 2018)، وهو ما أدى إلى وجود تباين بين الأكاديميين والمهنيين بشكل عام، وبين أعضاء كل فئة منهما بشكل خاص، فيما يتعلق بمدى المنافع والمخاطر والتهديدات الناتجة من استخدام تكنولوجيا الذكاء الاصطناعي Artificial Intelligence في بعض وظائف المحاسبة والمراجعة (الطنطاوي، 2023)، مثل: إعداد القوائم المالية ومراجعتها، وترشيدها قرارات منشآت الأعمال، وترشيدها قرارات المتعاملين في أسواق المال... إلخ.

والوظيفة الأخيرة هي محل اهتمام الدراسة الحالية؛ حيث جذب موضوع التنبؤ بأسعار واتجاهات الأدوات المالية انتباه العديد من الأكاديميين، وكذلك المهنيين لفترة طويلة من الوقت، لكن أسواق الأسهم تتأثر بالعديد من المتغيرات شديدة التداخل، منها: الاقتصادية، والاجتماعية، والسياسية، وحتى العوامل السيكلوجية التي تتفاعل مع بعضها البعض في شكل شديد التعقيد، ونتيجة لذلك فإنه من الصعوبة بمكان التنبؤ بالتحركات السعرية وتقلبات الأسهم في أسواق المال (Belhoula et al., 2023). لذلك، طُوِّرت عدة أساليب لتوقع أسعار الأسهم، وتهدف هذه الأساليب التنبؤية إلى اقتراح منهج لتوقع قيمة المؤشر وأسعار الأسهم (Lah et al., 2019).

وقد اجتذب التنبؤ بأسعار واتجاهات الأدوات المالية أنظار الباحثين، خاصة مع عدم وجود أسلوب أو منهج مناسب للتنبؤ السعري للسهم بدقة عالية، فالبعض يعد من أنصار التحليل الأساسي، والبعض الآخر يُعد من أنصار التحليل الفني، وثالث يُعد من أنصار التحليل السلوكي، ورابع يعد من أنصار الأساليب الإحصائية لتوقع أسعار الأسهم (Greco et al., 2023A; Wagdi et al., 2019)؛ حيث يحمل الاستثمار في سوق المال مخاطر أعلى بالمقارنة بأي مجال آخر لأدوات الاستثمار الأخرى، وذلك بسبب ما يحويه من درجة كبيرة من عدم التأكد والتذبذب والتقلبات المستمرة، جاعلاً بذلك السلوك السعري للأدوات المالية من الصعب التنبؤ به، وعلى مدى الزمن تم تطوير أساليب تقليدية للتنبؤ، ونجحت جزئياً، أو ربما قد فشلت تماماً في التعامل مع السلوك غير الخطي والمعقد لأسعار الأدوات المالية ومنها تحركات القيم السوقية للأسهم العادية (Senol and Ozturan, 2009).

وتعد التنبؤات الدقيقة بمؤشرات الأسواق المالية أمرًا مهمًا لعدة أسباب، وعلى رأس هذه الأسباب، أن المستثمرين في حاجة إلى عوائد تقابل المخاطر التي يتعرضون لها عند حيازة الأدوات المالية، وكذلك يقتضون الفرص الموجودة في السوق، والتي يستحوذ عليها المضاربون والمتحكون في السوق فقط، وذلك لحماية هؤلاء المستثمرين الصغار عن طريق المتاجرة المستندة على التنبؤ الدقيق بالمؤشرات (Lin et al., 2002). في هذا الصدد، تعد أساليب تحليل السلاسل الزمنية من أكثر الأساليب الشائعة والمستخدم للنتبؤ بأسعار الأسهم، عبر العديد من الأساليب: منها تحليل الانحدار ونماذج أريما *Auto-Regressive Integrated Moving Average (ARIMA)*، فأسلوب السلاسل الزمنية هو أسلوب رئيس يستخدم لتوقع أسعار الأسهم؛ حيث يتعامل مع سلسلة بيانات تم تجميعها خلال فترة زمنية معينة (Farahani and Hajiagha, 2021)، لذا فهو أسلوب يحاول التنبؤ بالمستقبل من خلال الاعتماد على البيانات السابقة (Shin, 2017). إلا أن هذه الأساليب قد استخدمت بكثرة في الماضي، وفشلت في أن تعطي تنبؤات دقيقة في الأوقات الحرجة بسبب هيكلها أو طريقة بنائها الخطية، وكذلك بعض العيوب والمحددات الأخرى المرتبطة بها وبطريقة استخدامها (Lin et al., 2002)، إلا أن بيانات ومتغيرات سوق رأس المال تتسم باللاخطية *Nonlinearities*، كما أن تحركات أسعار الأسهم تكتنفها علاقات معقدة وغير خطية خاصة بالعديد من المتغيرات المؤثرة في سعر الورقة (Belhoula et al., 2023).

وقد برز العديد من أدوات الذكاء الاصطناعي، حيث أصبحت تلك الأدوات خلال العقد الأخير أكثر تقدمًا، خاصة التي تستند إلى مفاهيم تعلم الآلة *Machine Learning*، ومنها: الشبكات العصبية الاصطناعية *Artificial Neural Networks* التي تعرف اختصارًا بـ *ANN* والتي تحاكي المخ البشري وعمليات التفكير (Farahani and Hajiagha, 2023 B; Wagdi et al., 2021) والتي يمكنها تحليل العلاقات غير الخطية والتي من الصعب التحكم فيها والسيطرة عليها باستخدام نماذج التنبؤ التقليدية (Al-hidi and Al-Hasan, 2002)، حيث إنه غالبًا ما تواجه الأساليب الرياضية التقليدية للنتبؤ مشاكل في صياغة نماذج البيانات التي تتسم بالتشوش (الضجيج *Noisy*) وعدم الاكتمال أو البيانات غير الكافية *Imperfections*، لذلك صممت الشبكات العصبية الاصطناعية لكي تتعامل مع هذه البيانات التي تتسم بالضجيج وعدم الاستقرار، ولكي تكون قادرة على إيجاد النماذج المعقدة في البيانات ذات الضجيج والعشوائية (Chen, 2007).

وقد اتضح من الاستخدام الشبكات العصبية الاصطناعية أنها قادرة على احتواء وتفهيم *Recognize* والتعرف على السلوكيات والمواقف المختلفة، بل وتقرح كيفية أخذ هذه المواقف والسلوكيات في الاعتبار والتعلم منها (Gallo et al., 2005)، ومع قدرتها على اكتشاف العلاقات التي تتسم بالتشوش وعدم الاستقرار *Chaotic Systems* عبر البحث، وإيجاد طبقات خفية في ظل العلاقات غير الخطية بين المتغيرات (Farahani and Hajiagha, 2021)، فإن الشبكات العصبية الاصطناعية لديها القدرة على التنبؤ باتجاه سوق رأس المال بدقة أكثر من الأساليب التقليدية (Lawrence, 1997)، وبسبب قدرتها على التعامل مع البيانات العشوائية المشوشة (*Fuzzy*) والتي تتسم بعدم التأكد؛ حيث تتعرض للتقلبات في فترات قصيرة جدًا من الزمن، فإن الشبكات العصبية الاصطناعية تصبح أداة مهمة جدًا للتنبؤ في سوق الأوراق المالية (Schoenburg, 1990)، وهو الأمر الذي جعل الشبكات العصبية الاصطناعية تصنف كأحد أساليب تعلم الآلة (Wagdi et al., 2023B). ويرى (Kurani et al., 2023) أن الشبكات العصبية الاصطناعية هي واحدة من أهم وأفضل الخوارزميات لتنبؤ الأسهم، ويمكنها التكيف بسهولة مع التغيرات في بيئة السوق.

وقد تم تطبيق الشبكات العصبية الاصطناعية في الكثير من المجالات، مثل: علوم الحاسب، الهندسة، التشخيصات الطبية، عمليات الفحص البيولوجي، وكذلك الأبحاث الاقتصادية؛ حيث يمكن استخدامها لتحليل العلاقات بين الظواهر المالية والاقتصادية التي تحدث بطريقة متكررة، مع التنبؤ بها، ومن ثم استخلاص البيانات اللازمة، كذلك يمكنها توليد أو عمل

سلاسل زمنية خاصة بهذه الظواهر، والوصول إلى الحلول والمقترحات المثلى لغرض التنبؤ (Shachmurove and Witkowska, 2000). ففي أسواق المال تعمل الشبكات العصبية الاصطناعية كنموذج للتنبؤ عبر تحليل العلاقات المخفية Hidden relationships بين المدخلات والمخرجات من خلال محاكاة سوق الأسهم عن طريق أخذ واقتباس مجموعة صغيرة Subsets من المعلومات المرتبطة لكي يدني مستويات عدم التأكد (Senol and Ozturan, 2009). فقد دفعت حالة عدم التأكد التي تتسم بها الأسواق المالية الأكاديميين والمهنيين نحو الدراسة عن وسيلة تمكنهم من تدنية هذه السمة. وكأحد مجالات الذكاء الاصطناعي فإن الشبكات العصبية الاصطناعية لكونها إحدى الطرق الشائعة التي يمكنها التمييز بين النماذج المخفية Hidden وغير المعروفة Unknown باستخدام البيانات المتعلقة بالأدوات المالية، فإن الشبكات العصبية الاصطناعية تعتبر وسيلة مناسبة للتنبؤ باتجاهات ومؤشرات أسواق المال.

2/1- مشكلة الدراسة:

تعد نماذج الشبكات العصبية الاصطناعية أسلوبًا من أساليب الذكاء الاصطناعي التي تم استخدامها لخدمة أغراض كثيرة في مجالات متعددة من أجل التنبؤ والتحليل والتصنيف واتخاذ القرارات. وقد انقسمت أغراض الدراسات السابقة ما بين التنبؤ بتحركات مؤشرات البورصات العالمية وتحديد إشارات البيع والشراء والاحتفاظ أو التنبؤ بسلوك الأسهم (جيدة أو رديئة)، وقد لوحظ أن أهم المدخلات المستخدمة في هذه الدراسات والأكثر شيوعًا هي المتغيرات الأساسية والاقتصادية (مثل: أسعار الذهب، معدلات الفائدة والتضخم والنمو الاقتصادي، أسعار الصرف)، والقليل من الدراسات استخدمت متغيرات مقتبسة من التحليل الفني (مؤشرات فنية)، ومن أهم هذه المؤشرات الفنية مؤشر القوة النسبية (RSI)، والمتوسطات المتحركة (MA, MACD, EMA)، والزمخ، بالإضافة إلى مؤشر المذبذبات (Stochastic Oscillator)، والبيانات التاريخية الخاصة بأسعار الأسهم، مثل: أسعار الإقفال والفتح وأحجام التداول وأعلى وأقل سعر خلال الفترة.

وعادةً ما يستخدم التعلم الإشرافي (Supervised Learning) لتعليم الشبكة العصبية الاصطناعية، كما تم استخدام الأساليب الإحصائية مثل: (ARIMA, GARCH, ARCH, Box and Jenkins) والانحدار الخطي (Linear Regression)، وطريقة المربعات الصغرى (Ordinary Least Squares) لأغراض المقارنة مع نماذج الشبكات العصبية الاصطناعية المستخدمة، أو لتقييم قدرة الشبكة العصبية على التنبؤ بتحريك المؤشر أو السهم خلال فترة ما، وتحديد قدرتها على تفسير تحركاتها السعرية.

وبالفعل، حققت معظم الدراسات نتائج متباينة من استخدام هذه النماذج، خاصة في عمليات التنبؤ، مما يشير إلى تباين قدرة نماذج الشبكات العصبية الاصطناعية نحو دقة عمليات التنبؤ في الأسواق المالية، ومن هنا تتبين الحاجة الملحة لتطبيق الأساليب القائمة على علم الذكاء الاصطناعي؛ نظرًا لأهميتها في المساعدة على اتخاذ القرار والتنبؤ والتحليل، وبصفة عامة لأهمية هذا العلم الحديث الذي كثر تطبيقه مؤخرًا من معظم الدول في كافة المجالات الطبية والصناعية والبيئية والاقتصادية، بذلك يظهر التساؤل البحثي التالي:

" هل توجد علاقة بين استخدام نماذج الشبكات العصبية الاصطناعية وعمليات التنبؤ بالسلوك السعري لمؤشر البورصة المصرية EGX30 باستخدام كل من البيانات التاريخية ومؤشرات التحليل الفني على حدة؟".

3/1- هدف الدراسة:

يكمن الهدف الرئيسي لهذه الدراسة في اختبار قدرة الشبكات العصبية الاصطناعية على التنبؤ بالسلوك السعري لمؤشرات الأسواق المالية بالتطبيق على المؤشر الرئيسي للبورصة المصرية EGX30 باستخدام البيانات التاريخية وبيانات مؤشرات التحليل الفني.

4/1- أهمية الدراسة:

يمكن إيجاز أهمية الدراسة على النحو التالي:

1/4/1- الأهمية العلمية :

أ تعد الدراسة الحالية من الدراسات النادرة - في حدود علم الباحثان- التي تناولت أحد أساليب وأدوات الذكاء الاصطناعي بصورة تجريبية في بيئة الأعمال المصرية، عبر اختبار قدرة الشبكات العصبية الاصطناعية في أسواق المال المصرية بصورة كمية، على عكس الجانب الأعظم من الدراسات السابقة التي تناولت استكشاف تطبيقات الاصطناعي في بيئة الأعمال المصرية اعتمادًا على قياس الآراء عبر قوائم الاستقصاء، وهو الأمر الذي يمثل المساهمة البحثية التي تقدمها الدراسة الحالية.

ب يعد التنبؤ بتحركات مؤشر سوق الأوراق المالية المصري من الموضوعات ذات الأهمية؛ نظرًا لتمثيله لكافة الأسهم في القطاعات المختلفة في البورصة المصرية من الأوراق المالية، ويساعد في ترشيد قرارات الاستثمار على المستوى الفردي لحماية لصغار المتعاملين من تعاملات المضاربين وكبار المستثمرين، وهذا بدوره يساعد على استقرار عمليات المتاجرة وسوق رأس المال وتخفيض حدة تقلبات الأسعار نسبيًا، وكذلك التنبؤ بأداء النمو الاقتصادي.

2/4/1- الأهمية العملية:

أ المساهمة في ترشيد عملية اتخاذ قرارات الاستثمار باستخدام الشبكات العصبية الاصطناعية من خلال التنبؤ بسوق رأس المال المصري (السلوك السعري)، وهذا مجال خصب للدراسة، وذلك لبدء انتشار مثل هذه التقنية المستحدثة في العديد من الدول الأجنبية في مجال التمويل والمحاسبة، وهو ما يدعونا لإجراء هذه الدراسة للحاق بباقي الدول في مثل هذه التقنيات.

ب تم اختبار قدرة الشبكات العصبية الاصطناعية على التنبؤ في أسواق المال عبر الاعتماد على مؤشرات الأسواق المالية، ويعد هذا التنبؤ أكثر صعوبة من التنبؤ على مستوى السهم المنفرد؛ حيث تتسم حركة مؤشرات الأسواق المالية بضجيجها غير المؤكد في ظل تعدد الأسهم المكونة للمؤشر (Gao et al., 2020).

5/1- نطاق الدراسة:

تقتصر الدراسة الحالية على تطبيق الشبكة العصبية الاصطناعية بغرض التنبؤ بالسلوك السعري للمؤشر الرئيسي للبورصة المصرية - مؤشر EGX30 - خلال الفترة من عام (2013: 2022)، باستخدام البيانات التاريخية ومؤشرات التحليل الفني.

6/1- خطة الدراسة:

في ضوء مشكلة الدراسة وأهدافها، سوف يتناول الباحثان العناصر التالية:

➤ الإطار النظري للدراسة.

- النظرية المفسرة لتحركات أسواق المال.
- التنبؤ في سوق الأوراق المالية.
- البيانات التاريخية ومؤشرات التحليل الفني.
- الشبكات العصبية الاصطناعية.

➤ الدراسات السابقة واشتقاق الفروض.

➤ منهجية وتصميم الدراسة التجريبية.

➤ نتائج اختبار فرضي الدراسة.

➤ مناقشة وتفسير النتائج.

➤ نتائج الدراسة.

➤ التوصيات ومقترحات الدراسات المستقبلية.

2- الإطار النظري للدراسة:

1/2 - النظرية المفسرة لتحركات أسواق المال:

ظهرت نظرية كفاءة الأسواق في النصف الثاني من القرن العشرين، والتي تفسر تحركات أسواق المال في ضوء نمط المعلومات المتاحة، وأثرها على قدرة المتعاملين على تحقيق عوائد غير عادية، حيث تتضمن ثلاثة فروض لكفاءة أسواق المال (The Efficient Markets Hypothesis (EMH)، ويرجع السبق للإشارة لهذا الأمر إلى الأبحاث التي قام بها Fama (Lin et al., 2002)، حيث تشير الكفاءة في مجال أسواق المال إلى ثلاثة أنواع رئيسية هي: الكفاءة المعلوماتية (Greco et al., 2019)، التخصصية، التشغيلية (Zebende et al., 2022)، إذ تفترض حالة الكفاءة أنه في أي فترة زمنية يجب أن تعكس أسعار الأوراق المالية كافة المعلومات المتاحة والمتعلقة بالورقة نفسها. أي إن السوق يعكس تمامًا كل المعلومات المتاحة والتي من السهل الحصول عليها عندئذ، كما أن الأسعار تتعدل تمامًا، وعلى الفور حالما تصل معلومات جديدة، ولو أن هذا صحيح فإنه على ذلك لن تكون هناك أي جدوى من عمليات التنبؤ في السوق، ويصبح التنبؤ بلا قيمة (Januskevicius, 2003)، ويرى (Greco et al., 2019) أن الكفاءة المعلوماتية لها تأثير كبير على أسعار الأسهم، وعادة ما تكون كفاءة سوق المال مرتبطة ببعدين أساسيين، أولهما: مدى استيعاب المتداولين في بورصات الأوراق المالية لكافة المعلومات المتاحة، ثانيهما: مدى سرعة استجابة المتداولين في بورصات الأوراق المالية ورد فعلهم

وتكفيهم مع هذه المعلومات متمثلاً في أسعار الأوراق المالية المتداولة فيه (Belhoula et al., 2023)، لذلك يعد المصطلح الشائع لفروض كفاءة أسواق المال هو "نظرية المسار العشوائي"، وتعني أن أسعار الأسهم الحالية تعكس تماماً المعلومات المتاحة عن قيمة المنشأة، ومن ثم ليس هناك وسيلة لجني أرباح إضافية باستخدام هذه المعلومات المتاحة؛ حيث تسير الأنماط السعرية في مسار عشوائي لا يمكن التنبؤ به، ففرصة أو احتمال صعود السعر المستقبلي للسهم هي نفس فرصة نزوله، وفي حالة ثبوت صحة نظرية المسار العشوائي فإن التحليل الأساسي والتحليل الفني وأساليب تعلم الآلة، مثل: الشبكات العصبية الاصطناعية، تصبح غير ذي قيمة في التنبؤ (Januskevicius, 2003).

وطبقاً لـ Fama فإنه يمكن تقسيم نظرية كفاءة الأسواق المالية إلى: فرض السوق ضعيف الكفاءة، وفرض السوق متوسط الكفاءة، وفرض السوق قوي الكفاءة:

أولاً: فرض السوق ضعيف الكفاءة Weak Form Efficient: يتبع هذا الفرض بنظرية الحركة العشوائية للأسعار؛ حيث نجد أن التغيرات السعرية المتتالية مستقلة عن بعضها، ولا يوجد بينها أي ترابط. (حنفي، 2002) ويفترض هذا الشكل من أشكال الكفاءة "أنه عند نقطة زمنية معينة فإن سعر الورقة المالية يعكس تماماً كل المعلومات السوقية الماضية الخاصة بها، مثل: الأسعار والعوائد وأحجام التداول التاريخية الخاصة بالورقة" (Januskevicius, 2003)، كما ينص هذا الفرض على أن السوق لا ذاكرة له؛ وبالتالي تأخذ التقلبات السعرية مساراً عشوائياً، ولا جدوى من تحليل الاتجاهات التاريخية لأغراض التنبؤ المستقبلي. وكذلك يتأسس على إنكار إمكانية التنبؤ بالتحركات المستقبلية للأسعار في السوق من خلال تحليل التحركات التاريخية، إنكار الوسائل المتعددة التي يلجأ إليها القائمون على التحليل.

ثانياً: فرض السوق المتوسط الكفاءة (أو شبه قوي الكفاءة) Semi-Strong Form: إن مفاد هذا الفرض هو أن أسعار الأوراق المالية تتعدل بسرعة لاستيعاب كل البيانات المنشورة المتاحة، والتي تتضمن كلاً من القوائم المحاسبية المنشورة عن المنشأة، والمعبرة عن المراكز المالية وقوائم الدخل، ومن ثم الأرباح والتوزيعات ونسب السعر إلى المكاسب ونسب التوزيعات، ونسب القيمة الدفترية إلى تلك السوقية، وما يتصل بتجزئة الأسهم أو إعادة شرائها، أو منح أسهم مجانية، وغير ذلك من بيانات المنشأة المنشورة. هذا، فضلاً عن الأنباء المنشورة عن الأنشطة الاقتصادية والسياسية والتشريعية، وأيضاً المعلومات الخاصة بالصناعة التي تنتمي إليها المنشأة. وطبقاً لهذا الفرض فإن المستثمرين الذين يبنون قراراتهم على المعلومات الجديدة بعد نشرها لن يحققوا عوائد أعلى من المتوسط على صفقاتهم (أو أرباحاً غير عادية)، وذلك بسبب بسيط؛ وهو أن أسعار الأوراق المالية تكون قد تعدلت بالفعل، لتعكس هذه المعلومات الجديدة المنشورة (سعد، 2005) وبذلك يحدث تساوي بين القيمة الحقيقية للسهم وسعره، وتحقق الأرباح فقط قبل وصول هذه المعلومات، ومن ثم تصبح التحليلات الجوهرية عديمة القيمة (حنفي، 2002).

ثالثاً: فرض السوق قوي الكفاءة Strong Form Efficient: هذا الافتراض يزيد على الفرض الخاص بالسوق المتوسط الكفاءة متطلباً جديداً، وهو أن تعكس أسعار الأوراق المالية كل المعلومات المتاحة داخلياً وخارجياً، وليس المنشور منها فقط، بل والمتوقعة أيضاً. بمعنى أن سعر السهم في السوق هو انعكاس لجميع المعلومات المتاحة للعمامة والخاصة؛ أي التي تحصل عليها فئة معينة ككبار المتعاملين في الأسهم، وهذا يعني استحالة أن يحقق أي مستثمر

أرباحًا غير عادية على حساب الآخرين، حتى ولو كان وثيق الاتصال بمصادر المعلومات داخل المنشأة صاحبة الورقة المالية. والأبحاث لا تدعم في مجملها صحة هذا الفرض (سعد، 2005؛ حنفي، 2002).

مما سبق، يتضح أنه في السوق الكفاء يعكس سعر السهم الذي تصدره منشأة ما كافة المعلومات المتاحة عنها، سواء الماضية أو المتوقعة. ومعنى هذا أنه في ظل السوق الكفاء فإن القيمة السوقية للسهم هي قيمة عادلة تعكس تمامًا قيمته الحقيقية. وتجدر الإشارة إلى أنه في تسعينيات القرن العشرين، تم الربط بين الطاقة الرقمية الهائلة للحسابات مع بعض معطيات العلم الحديث، مثل: نظرية التشوش الكامل والشبكات العصبية الاصطناعية والحسابات الجينية، في محاولة للتنبؤ بسلوك الأسعار في السوق. وقد أمكن الحصول على خرائط ذات خطوط مقاومة، أفضل مما هو متاح لدى أصحاب التحليل الفني. ولكن ما زال عليها أن تثبت إمكانية تحقيق أداء أفضل ومتميز.

ويذهب البعض إلى أن نظرية التشوش الكامل ذات المفهوم المعقد يصعب معها إيجاد تطبيقات لها في الأسواق المالية. ومن ثم، كان التوجه إلى التركيز على تقديم أساليب تكيفية، مثل: الشبكات العصبية الاصطناعية والحسابات الجينية، والتي ينعقد الأمل على استخدامها في مجال التنبؤ بالتحركات السريعة في الأجل القصير؛ حيث تحاول الشبكات العصبية الاصطناعية محاكاة عمليات المخ البشري، فتولد الأخطاء استجابة تكيفية، وتقدم طرقًا جديدة للتصرف، أما الحسابات الجينية، فتمثل خطوة إلى الأمام، فهي تعتمد على قوانين التطور. لذا فمثل هذه الأساليب التنبؤية، التي تعتمد على مداخل التكيف، ستجعل الأسواق أكثر كفاءة. وأخيرًا فأيًا كان المدخل الفني المستخدم فإن صحته لن تدوم إلا لفترة قصيرة، فطرق التعلم الآلي لا يمكن أن تعالج الهزات المستمرة في النظام (سعد، 2005). وفي حالة أن نظم التداول القائمة على الذكاء الاصطناعي استطاعت هزيمة السوق وتحقيق أرباح من وراء قدرتها على التحليل والتنبؤ في السوق فإن صحة فرضية كفاءة السوق تصبح محل جدل وتساؤل (Januskevicius, 2003).

2/2- التنبؤ في سوق الأوراق المالية:

يوصف سوق الأوراق المالية بأنه نظام ديناميكي غير خطي، ويتأثر بصفة رئيسية بالعديد من العوامل، مثل: معدلات التضخم Inflation Rates، معدلات الفائدة Interest Rates، معدلات النمو الاقتصادي Economic Growth Rates، العوامل السياسية Political، وغير ذلك (Zhang, 2005)، وكذلك يشمل التنبؤ بالأداء السعري للأسهم تداخل العديد من المتغيرات؛ مما يجعل عملية التنبؤ صعبة ومعقدة جدًا (Yoon and Swales, 1991)، حيث يعتبر سوق الأوراق المالية سلسلة زمنية يصعب التنبؤ بها، وذلك ربما بسبب تأثيره بنظرية كفاءة السوق (Kwong, 2001). ويزعم الكثير من الباحثين أن أسواق الأوراق المالية يظهر فيها حالة من التشوش أو الفوضى Chaos وعدم الاستقرار، ويعرف التشوش هذا بأنه عملية غير خطية، وتبدو عشوائية ولا يمكن التعبير عنها أو تصويرها بسهولة، وذلك بصفة قطعية، ومع قدرة الشبكات العصبية الاصطناعية على تعلم النظم اللاخطية والتشوش، فإنه يمكنها أن تفوق أساليب التحليل التقليدية الأخرى (Yu and Yan, 2020). لذلك تعتبر أسواق الأوراق المالية واحدة من أكثر السلاسل الزمنية الأكثر تعقيدًا لكي يمكن نمذجتها أو صياغتها بنظام ما، وذلك بسبب احتوائها على كمٍ ضخم من المؤثرات والعوامل التي أحيانًا يصعب تفسيرها وفهمها، مما يجعل من الصعب التنبؤ بتحركات أسواق الأوراق المالية (Weckman et al, 2008). وفي ضوء فرضية السوق شبه قوي الكفاءة Semi-Strong Form efficient، لا يمكن للمتداولين تحقيق عوائد غير عادية في ظل استخدام مدخل التحليل الأساسي.

3/2- البيانات التاريخية ومؤشرات التحليل الفني:

يعتمد التحليل الفني على البيانات التاريخية، فهو مدخل بديل عن مدخل التحليل الأساسي، حيث ينظر أنصار التحليل الفني إلى اتجاهات القيم السوقية للأسهم (وجدي، 2011)، في المقابل ينظر أنصار التحليل الأساسي إلى القيمة العادلة لهذا الأصل دون الاهتمام باتجاه القيمة السوقية له، وتعد نظرية "داو" Dow Theory النظرية الرئيسية لهذا المدخل، والتي ظهرت على يد "شارلز داو"، (الحناوي وآخرون، 2007؛ عبدالعال، 2000).

ويتم التعبير عن أداء الأدوات المالية؛ سواء كانت أسهمًا عادية أو مؤشرات أو غيرها من الأدوات، في صورة بيانية أو ما يعرف باسم "الخرائط السعرية"، وبذلك يتبين أن التحليل الفني يتميز بأدواته المتنوعة، منها: الشموع اليابانية، الأنماط السعرية، المؤشرات الفنية، موجات إليوت، خرائط النقاط والأشكال، مع انتشار استخدام التحليل الفني وأدواته المتعددة لدى العديد من المتعاملين في أسواق المال، إلا أنه لا يزال موضع شك من جانب أنصار التحليل الأساسي. وفي ضوء فرضية السوق ضعيف الكفاءة Weak Form Efficient، لا يمكن للمتداولين تحقيق عوائد غير عادية في ظل استخدام مدخل التحليل الفني.

4/2- الشبكات العصبية الاصطناعية:

شهد الربع الأخير من القرن العشرين ظهور أساليب الحوسبة الجديدة في عمليات صنع القرار في مجال الاقتصاد وأنشطة الأعمال (Doumpos et al., 2023)، وقد ساعد على ذلك انتشار عتاد الحاسب Hardware والبرامج الجاهزة المتقدمة Software. ونتيجة لذلك ظهرت على الساحة العلمية خلال العقد الماضي مجالات علمية جديدة تستخدم الحوسبة في مجالات الاقتصاد والتمويل، مثل: الاقتصاد الحسابي Computational Economics، والتمويل الحسابي Computational Finance، الإحصاء الحسابي Computational Statistics. وبالفعل جذبت هذه العلوم الحديثة الانتباه إليها، واحتلت مكانتها على الساحة العلمية. وتشير كلمة "الاصطناعي" إلى الآلة أو الحاسب، لذلك فإنه يمكن تعريف الذكاء الاصطناعي بأنه "استجابة الآلة بصورة توصف بأنها ذكية"، فهي نوع من خوارزميات التعلم الآلي مستوحاة من هيكل ووظيفة العقل البشري (Soori et al., 2023).

وقد نشأت الشبكات العصبية الاصطناعية من خلال محاولة محاكاة النظم العصبية الحيوية (البيولوجية) عن طريق تجميع العديد من العناصر الحسابية البسيطة في نظام شديد الاتصال، أملين في الحصول على نتيجة للتنظيم الذاتي أو عملية التعلم داخل هذا النظام المعقد، والتي قد تكون ظاهرة معقدة مثل عملية الذكاء البشري (Sarle, 1994). وتعتبر الشبكات العصبية الاصطناعية من أحدث أساليب التحليل والتنبؤ الحديثة؛ حيث بدأ الاهتمام بها في نهاية عام 1989 ومع بداية التسعينيات من القرن العشرين، خاصة بعد أن رصدت وزارة الدفاع الأمريكية مئات الملايين من الدولارات لتطوير هذا الأسلوب، وتعد الشبكات العصبية الاصطناعية جيدة ومعتمدة بشكل مقبول في التنبؤ بأسعار الأسهم (Idris et al., 2015).

ومع نهاية القرن الماضي، أصبحت المؤسسات التي تقدم الخدمات المالية أكثر اعتمادًا على تقنيات الحاسب المتقدمة بغرض تحقيق التنافسية في المناخ الاقتصادي العالمي. وقد ظهرت الشبكات العصبية الاصطناعية كتقنية مثيرة لاهتمام الممارسين والباحثين، وانتشرت على مدى واسع فيما يخص التطبيقات المالية امتدادًا من إجراءات تقدير مخاطر

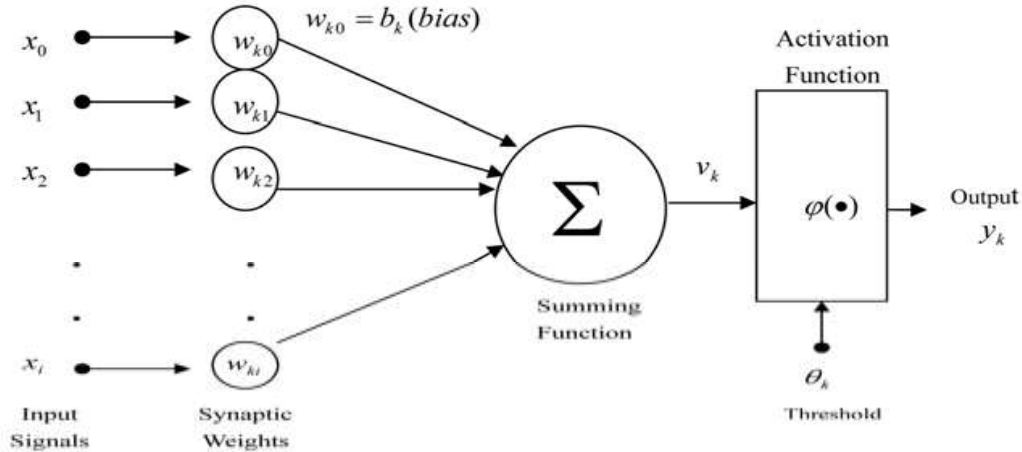
الائتمان الروتينية وحتى استراتيجيات إدارة محافظ الأوراق المالية الكبيرة، وقد أشارت مثل هذه التطبيقات السالفة إلى تحقيق مستوى ربحية بنسبة 30% فأكثر جراء الاعتماد على تقنيات الشبكات العصبية. ومن المشاكل المالية التي يمكن معالجتها أيضًا باستخدام أسلوب الشبكة العصبية: التصنيف والتقييم الائتماني، الاستثمار في الأوراق المالية، والتنبؤ المالي (Ren et al., 2024; Sariev and Germano, 2020; Zhang and Lou, 2021).

وبسبب قدرتها (الشبكات العصبية) على اكتشاف الأنماط في البيانات غير الخطية Nonlinear ، الغامضة أو غير المكتملة، المشوشة أو المبهمة noisy، وكذلك البيانات المتطايرة أو المتغيرة بسرعة volatile فإن الشبكات العصبية الاصطناعية قد أصبحت وسيلة ملائمة للتنبؤ بمتغيرات أسواق الأوراق المالية (Yu and Yan, 2020)، حيث إن هناك اتفاقًا عامًا على أن معظم المتغيرات المالية تتسم بالسمة اللاخطية Nonlinear. وقد استخدمت الشبكات العصبية الاصطناعية في الأونة الأخيرة بكثرة لحل المشاكل المتعلقة بالتنبؤ بالإفلاس، وتصنيف سندات الشركات .. إلخ. والسبب وراء انتشار هذا الأسلوب الجديد (الشبكات العصبية) هو قدرته على صياغة ونمذجة العلاقات غير الخطية بين المتغيرات المالية. (Januskevicius, 2003)، ويؤدي تطبيق تقنية الشبكات العصبية التي تتضمن متغيرات محاسبية أساسية إلى تنبؤات أكثر دقة من نماذج التنبؤ (Martins, 2022)

أما عن طبيعة عمل الشبكات العصبية الاصطناعية فإن تطوير نماذج الشبكات العصبية الاصطناعية قد نشأ من محاولة محاكاة النظم العصبية الحيوية وطريقة عمل المخ البشري (Farahani and Hajiagha, 2021) ، وذلك عن طريق تجميع العديد من عناصر الحوسبة البسيطة (العصبونات Neurons) في نظام شديد الاتصال، آمليين أن يكون الناتج من مثل هذا النظام المعقد هو الذكاء البشري كنتيجة لعملية التنظيم الذاتي والتعلم الذي يتسم به (Sarle, 1994).. ولقد تم تصميم هذا الأسلوب ليحاكي عمل الطبقات المخ، حيث تتكون الشبكة العصبية الاصطناعية من عناصر تشغيل، وهي خلايا عصبية اصطناعية تتولى عملية التشغيل، إذ تقوم كل خلية باستقبال مدخلات (بيانات)، ويجري عليها تشغيل، ثم تعطي مخرجات أو نتائج (Pang et al., 2020; Vijn et al., 2020).

والشبكة ذاتها تتكون من مجموعة خلايا عصبية مجمعة في طبقات، حيث توجد ثلاث طبقات على الأقل: هي طبقة المدخلات Input Layer؛ الطبقة الوسيطة أو الخفية Hidden Layer؛ طبقة المخرجات Output Layer. فطبقة المدخلات تستقبل المعلومات والبيانات وتقوم بتوزيعها، وتقوم الطبقة الخفية بعملية اكتشاف الخصائص وتصنيف المدخلات، بينما تقوم طبقة المخرجات بإرسال ناتج التحليل. ويتم التحليل بإعطاء أوزان معينة لكل مدخل من المدخلات، ثم تستخدم دالة تحويلية لتعديل هذه الأوزان باستمرار طوال عملية التدريب والتعلم، حيث يتم ذلك على خطوات أو مراحل، وفي كل مرة تعدل الأوزان حتى تتم عملية التعلم بالكامل، ويتكون لدى الشبكة العصبية الخبرة الكافية للحكم وإعطاء نتائج دقيقة، ثم تأتي مرحلة الاختبار؛ حيث تستخدم قاعدة البيانات التي تم تكوينها واستيعابها في التأكد من قدرة الشبكة العصبية على الأداء؛ ثم تقوم عناصر التشغيل من خلال دالة الجمع بحساب الوزن المتوسط المرجح Weighted Sum لكل أوزان المدخلات إلى عناصر التشغيل بالشبكة، وذلك من خلال ضرب نتيجة كل مدخل في وزنه فيتم إيجاد دالة الجمع، ثم يتم تحويله من خلال دالة غير خطية يطلق عليها دالة التحويل، وهي عبارة عن معادلة رياضية تحدد نوعية المخرجات الخاصة بعناصر التشغيل، مع الأخذ في الاعتبار نوعية المدخلات وأوزانها الترجيحية أو النسبية، وذلك للحصول على المخرجات من عناصر التشغيل بالشبكة، كما تقوم دالة الجمع بحساب مستوى الاستثارة والذي على أساسه يتم تحديد ما إذا كان كل

مدخل من المدخلات إلى منطقة التشغيل نشطاً Excitatory أو غير نشط Inhibitory من مدخلات الشبكة العصبية (Wang and Lee, 2023; Vijn et al., 2020) ويمكن استعراض التمثيل الرياضي للشبكة العصبية من خلال الشكل رقم (1).



شكل رقم (1) نموذج التمثيل الرياضي للشبكة العصبية (Bakar and Tahir, 2009)

أما معمارية الشبكات العصبية الاصطناعية Neural Network Architecture فهي طريقة ارتباط العصبونات مع بعضها البعض لتكوين الشبكة، وتصنف الشبكات العصبية الاصطناعية حسب عدد طبقاتها إلى شبكات وحيدة الطبقة (بدون طبقة خفية) أو شبكات متعددة الطبقات (طبقة خفية أو أكثر)، ويتم حساب عدد طبقات الشبكة بدون عدد طبقة الدخل؛ لأنها لا تنفذ أي حساب، وتتعدد معماريات الشبكة العصبية، وأبسط تركيب ممكن لشبكة عصبية هو التركيب الذي يتكون من طبقة واحدة من العناصر تربط ربطاً مباشراً مدخلات الشبكة ومخرجاتها. وهناك الشبكات العصبية الاصطناعية متعددة الطبقات Multilayer Network؛ حيث تتكون من طبقة مدخلات وطبقة مخرجات وطبقة خفية أو أكثر، وقد تكون هناك شبكة عصبية من طبقتين من عناصر المعالجة، وهما: طبقة المدخلات وطبقة المخرجات فقط (Dhillon and Verma, 2020).

3- الدراسات السابقة واشتقاق الفروض:

تعد تطبيقات تكنولوجيا الذكاء الاصطناعي إحدى الأدوات الداعمة لعمليات الاستدلال المحاسبي (Hasan, 2021)، حيث دعت دراسة (والي ونصير، 2022) إلى استحداث أدوات محاسبية جديدة تعتمد على تكنولوجيا الذكاء الاصطناعي كالأنظمة الخبيرة والشبكات العصبية الاصطناعية والأنظمة الضبابية وغيرها من التطبيقات الحديثة. حيث اجتذبت الشبكات العصبية الاصطناعية (ANNs) مؤخرًا اهتمامًا كبيرًا في المجالات المختلفة ومنها مجال المحاسبة؛ بسبب قدرتها الكبيرة على التعلم الذاتي ودقتها الجيدة في رسم خرائط العلاقات غير الخطية المعقدة (Rafiuddin et al., 2023; et al., Wagdi et al., 2023B; Xu 2021)، وتحسين جودة التقارير المالية (سيد، وآخرون، 2021)، ودقة التنبؤ بالتدفقات النقدية من الأنشطة التشغيلية بالاعتماد على نموذج هجين من الشبكات العصبية الاصطناعية والمنطق الضبابي (محمد، وآخرون، 2023)، والتنبؤ بأسعار السهم (المر، 2024؛ Senol and Ozturan, 2024; Shamsaliniya et al., 2024).

(2009) والمخاطر والتنبؤ بالسيولة (Tavana et al., 2018 ; Farahabadi et al., Kumar and Walia, 2006) وتحسين استراتيجيات المتاجرة الموجودة في سوق رأس المال (Vanstone and Finnie, 2007; Lin and Yu, 2009)، وتقييم مخاطر الائتمان (Mhlanga, 2021)، والتنبؤ بالتعثر المالي (Ansari et al., 2020; Tang et al., 2019; Zhou et al., 2019) والدراسات السابقة إلى مجموعتين؛ تناولت المجموعة الأولى: قدرة الشبكات العصبية الاصطناعية على التنبؤ مقابل الأساليب الإحصائية التقليدية، بينما تناولت المجموعة الثانية: الشبكات العصبية الاصطناعية والتنبؤ بعوائد وأسعار الأسهم والتنبؤ بكفاءة سوق الأوراق المالية.

المجموعة الأولى: قدرة الشبكات العصبية الاصطناعية على التنبؤ مقابل الأساليب الإحصائية التقليدية:

تناولت دراسة (Kumar and Walia, 2006) نموذجين من الشبكات العصبية الاصطناعية للتنبؤ بالسيولة أو النقدية لأحد فروع البنوك بالهند، النموذج الأول: نموذج يومي يأخذ البيانات اليومية كمدخلات للنموذج للتنبؤ بمتطلبات تحقيق السيولة لليوم التالي، أما الآخر فنموذج أسبوعي يأخذ بيانات المسحوبات من النقدية والتي تؤثر على نماذج المدخلات للأسبوع للتنبؤ بالسيولة للأسبوع التالي، وتوصلت الدراسة إلى أن هذين النموذجين يؤديان أفضل من النظم الأخرى للتنبؤ بالنقدية، ويمكن استخدامه للتنبؤ بأداء كل الفروع للبنك، وذلك عن طريق تجميع البيانات التاريخية لهذه الفروع. بينما قامت دراسة (Matoussi and Abdelmoula, 2009) بتقييم مخاطر الائتمان المصرفي باستخدام نموذج الشبكات العصبية الاصطناعية متعددة الطبقات للتنبؤ بتصنيف العميل من حيث قدرته على الوفاء أو تعثره، وخلصت الدراسة إلى تفوق نموذج الشبكات العصبية الاصطناعية على غيره من النماذج والأساليب الإحصائية في قدرته التنبؤية لتقييم مخاطر الائتمان. وهذا ما أكدت وتوصلت إليه دراستي (Huang et al., 2018; Bao and Li, 2016) بشأن دقة وسرعة الشبكات العصبية الاصطناعية في تقييم والتنبؤ بمخاطر الائتمان للشركات. وعلى جانب آخر ركزت دراسة (Ansari et al., 2020) ودراسة (Zhou et al., 2019) ودراسة (Tang et al., 2019) على قدرة الشبكات العصبية الاصطناعية على التنبؤ بالتعثر المالي في ظل عدم توازن البيانات Balance Data وتداخلها وتعقده، حيث استنتجت زيادة دقة الشبكات العصبية الاصطناعية على دقة التنبؤ عند إضافة البيانات غير المالية إلى البيانات المالية في التنبؤ بالتعثر المالي. وتوصلت أيضًا دراسة (الشوادفي، وآخرين، 2019) إلى تفوق الشبكات العصبية الاصطناعية المتعددة الطبقات للتنبؤ بالتعثر المالي للشركات المصرية المساهمة الصغيرة والمتوسطة على نماذج الانحدار اللوجستي LR ونموذج التمان 2016 المعدل. وأكدت دراسة (سيوني، 2008) على تفوق الشبكات العصبية الاصطناعية عن نموذج انحدار كوكس ونموذج الانحدار اللوجستي في تحديد العوامل المؤثرة في زمن البقاء والتصنيف والتنبؤ. وتوصلت دراسة (Pradhan and ESQ, 2008) إلى أن الشبكات العصبية الاصطناعية تعطي نسبة خطأ أقل في عملية التنبؤ بالمقارنة بالانحدار الخطي. وأثبتت دراسة (Desai and Bharati, 1998) تفوق الشبكات العصبية الاصطناعية على أسلوب الانحدار الخطي أو نماذج جارش (GARCH) حالة استخدام مقاييس الأداء المالي كمتغيرات للتنبؤ، وأن نماذج جارش ذات كفاءة شرطية بالمقارنة مع الشبكات العصبية الاصطناعية، بسبب العلاقة غير الخطية بين هذه المتغيرات (المالية والاقتصادية) والأسهم والسندات الخاصة بالمنشآت الكبيرة. وأكدت دراسة (المر، 2024) تفوق تقنيات تعلم الآلة، والتي تتمثل في: شجرة القرارات والشبكات العصبية، وآلية نقل الدم، والشبكة البايزية على الأساليب التقليدية للتنبؤ بعوائد الأسهم.

وقارنت دراسة (Al-Shayea et al., 2010) بين نموذجين من الشبكات العصبية الاصطناعية، الأول: نموذج الشبكات للانتشار الخلفي، والثاني: الشبكات العصبية الاصطناعية ذات الخرائط (التمثيل) ذاتية التنظيم، للتنبؤ بتعثر البنك

قبل إفلاسه باستخدام الشبكات العصبية الاصطناعية، لكي يتمكن جميع الأطراف من القيام بإجراءات علاجية، وخلصت الدراسة إلى أن الشبكات العصبية الاصطناعية تنتج إشارات تحذيرية واضحة، وتراقب القدرة على الوفاء، بالإضافة إلى أنه من الواضح أن الشبكات ذاتية التعليم تعطي نتائج أفضل من شبكات الانتشار الخلفي. واعتمدت دراسة Tavana et al., (2022) and Farahabadi et al., 2018 على أسلوب دراسة الحالة لاختبار أسلوب الشبكات العصبية الاصطناعية للتنبؤ بمخاطر السيولة.

وقد اجتذبت الشبكات العصبية الاصطناعية مؤخرًا اهتمامًا كبيرًا في المجالات البيئية بسبب قدرتها الكبيرة على التعلم الذاتي ودقتها الجيدة في رسم خرائط العلاقات غير الخطية المعقدة (Xu et al., 2021)، وتمويل الشركات متوسطة وصغيرة الحجم، حيث تناولت دراسة (Sang, 2021) تمويل سلسلة التوريد على توليد تدفق الأموال والسلع عند تقديم خدمات التمويل للمؤسسات الصغيرة والمتوسطة الحجم، وتبادل المعلومات من جانب تقييم مخاطر الائتمان. وقامت دراسة (عثمان وإسماعيل، 2022) بإجراء دراسة تحليلية لنماذج التنبؤ بالمخاطر المالية، وتوصلت إلى أن استخدام الشبكات العصبية الاصطناعية في التنبؤ سيعمل على زيادة القدرة التنبؤية بالمخاطر المالية لما تتمتع به تلك النماذج من دقة تنبؤية مرتفعة مقارنة بالنماذج الإحصائية. وأكدت دراسة (Sun and Lei, 2021) أن نموذج الإنذار المالي المبكر للشبكة العصبية BP يتمتع بدقة تنبؤ عالية يمكن استخدامها بشكل جيد في ممارسة الإنذار المالي المبكر لشركات التعدين المدرجة في الصين من فئة A في عام 2018 لتحسين الأداء المالي للمؤسسات. كما أظهرت دراسة (Shachmurove and Witkowska, 2000) أن نماذج الشبكات العصبية متعددة الطبقات تتفوق على النماذج التقليدية للتنبؤ في توقعات عوائد الأسهم اليومية بالتطبيق على سوق الأسهم في كندا وفرنسا وألمانيا واليابان والمملكة المتحدة والولايات المتحدة. علاوة على ذلك، أظهرت الشبكات العصبية متعددة الطبقات التي تضم خمس وحدات في الطبقة الخفية تنبؤات أكثر دقة لعوائد مؤشرات الأسهم مقارنة بشبكة عصبية تحتوي على وحدتين فقط في الطبقة الخفية.

المجموعة الثانية: الشبكات العصبية الاصطناعية والتنبؤ بعوائد وأسعار الأسهم والتنبؤ بكفاءة سوق الأوراق المالية:

تتميز سوق الأوراق المالية وأسعار الأسهم بتقلبات شديدة نظرًا لطبيعتها غير الخطية، ويرى (Kurani et al., 2023) أن الشبكات العصبية الاصطناعية هي واحدة من أهم وأفضل الخوارزميات للتنبؤ بالأسهم، لقدرتها على التكيف بسهولة مع التغيرات في بيئة السوق. فقد اختبرت دراسة (Desai and Bharati, 1998) فعالية الشبكات العصبية الاصطناعية في التنبؤ بعوائد مؤشرات الأسهم والسندات بالاعتماد على المتغيرات المالية والاقتصادية. وعلى نفس السياق استخدمت دراسة (Nygren, 2004) البيانات الفنية والمالية كمدخلات للشبكة للتنبؤ بأسعار الأسهم وبعوائد الاستثمار في مؤشر البورصة السويدي، وأيضًا هدفت دراسة (Senol and Ozturan, 2009) إلى استخدام الشبكات العصبية الاصطناعية في التنبؤ بأسعار الأسهم في بورصة إسطنبول (تركيا).

وتوصلت دراسة (Shamsaliniya et al., 2024) إلى أن الشبكات العصبية الاصطناعية من أهم التقنيات الأكثر دقة للتنبؤ بأسعار الأسهم. في حين استخدمت دراسة (Nygren, 2004) شبكتين منفصلتين لهما هياكل معمارية (بنائية) مختلفة. وقد تم استخدام الشبكات العصبية الاصطناعية النمطية المصححة للأخطاء Error Correction Neural Network من أجل التنبؤات اليومية (على أساس يومي)، بينما تم استخدام الشبكات العصبية الاصطناعية الممتدة Extension من أجل التنبؤات الأسبوعية. وقد أثبتت الدراسة نجاح التنبؤ بسلوك المؤشر السويدي، وذلك من خلال إجراء المقارنات المرجعية، بينما كانت نتائج الدراسة أقل إقناعًا بالنسبة للتنبؤات الخاصة بالأسهم، ومع ذلك فإن الشبكات العصبية

الاصطناعية تؤدي أفضل من الاستراتيجية التقديرية. وحاولت دراسة (Senol and Ozturan, 2009) تخفيض تأثير عدم التأكد والتطير الخاصة بأسعار الأسهم والناجحة من التقلبات الاقتصادية والمواقف المختلفة التي يتعرض لها سوق الأوراق المالية التركي، وذلك بنمذجة هذا التغير أو التطير من خلال النظرية والخطوات التي تتضمنها الشبكات العصبية الاصطناعية عند تطبيقها في الأسواق المالية، وذلك بتطوير برنامج يستخدم في التنبؤ بالسلوك السعري الاتجائي للأسهم على أساس يومي. واعتمدت دراسة (Khan et al., 2011) على البيانات التاريخية كمدخلات للشبكات العصبية الاصطناعية لزيادة قدرتها على التنبؤ بأسعار الأسهم. واعتمدت دراسة (Chhajer et al., 2022) أيضًا على تحليل توقعات أسعار الأسهم باستخدام الشبكات العصبية الاصطناعية وآلات الدعم.

وناقشت دراسة (Senol and Ozturan, 2009) مدى تفوق الشبكات العصبية الاصطناعية على المناهج التقليدية الأخرى المستخدمة في المتاجرة في سوق الأوراق المالية التركي، واستخدمت أسلوب دراسة الحالة، وأوضحت الدراسة أن مخرجات النموذج لم تختلف كثيرًا عن الواقع، مما يثبت صلاحية النموذج المقترح، كما تمت مقارنة مخرجات نماذج الانحدار مع مخرجات نماذج الشبكات العصبية الاصطناعية، وقد تم إثبات تفوق الثانية عن الأولى، وأثبتت الدراسة كذلك مدى تفوق الشبكات العصبية الاصطناعية على الأساليب التقليدية الأخرى، وأخيرًا توصلت إلى أن السوق ليس ضعيف الكفاءة.

على الجانب الآخر، هدفت دراسة (Kara et al., 2011) إلى تحديد قدرة الشبكات العصبية، وآلات ناقلات الدعم (SVM) على خدمة المستثمرين بأسواق المال، حيث قامت الدراسة حول هذين النموذجين في مجال القدرة على التنبؤ باتجاه الحركة اليومية في بورصة إسطنبول للأوراق المالية (ISE) اعتمادًا على مؤشر (ISE100)، وقد استخدمت الدراسة المؤشرات الفنية كمدخلات لهذه النماذج المقترحة، وأظهرت تفوق أداء الشبكات العصبية الاصطناعية (ANN) على آلات ناقلات الدعم (SVM) عند التنبؤ باتجاه الحركة اليومية لمؤشر بورصة إسطنبول للأوراق المالية (ISE100). وعلى نفس السياق هدفت دراسة (Vanstone and Finnie, 2007) إلى تحسين استراتيجيات المتاجرة الموجودة في سوق رأس المال عن طريق استخدام الشبكات العصبية الاصطناعية، وكانت مشكلة الدراسة تكمن في: هل يمكن للشبكات العصبية الاصطناعية أن تُستخدم في تطوير نظم متاجرة مالية صالحة للتطبيق في أسواق رأس المال. وقد قامت الدراسة بعمل منهجية تطبيقية أظهرت الخطوات المطلوبة لعمل شبكات عصبية اصطناعية تساعدهم في الإجابة عن هذا السؤال؛ حيث قامت الدراسة بمراجعة وفحص نظم المتاجرة القائمة وخاصة طويلة ومتوسطة الأجل، واستخدموا نموذج الشبكات العصبية الاصطناعية لتحسين هذه النظم القائمة، وتم استخدام البيانات المتعلقة بسوق رأس المال الأسترالي ASX200، وكانت البيانات داخل العينة تغطي الفترة من (1994-2003)، أما البيانات خارج العينة فتغطي الفترة من (2004-2006) اعتمادًا على بيانات متعلقة بـ (362) ورقة مالية. وقد توصلت إلى أن الشبكات العصبية الاصطناعية تساعد المنفذ أو السمسار في اتخاذ القرار والتعرف على إشارات البيع والشراء، حيث أظهرت الدراسة أن نتائج الشبكات العصبية الاصطناعية التي استخدمت بيانات داخل العينة مقارنة مع نتائج الشبكات العصبية الاصطناعية التي استخدمت بيانات خارج العينة، وأن الشبكات العصبية الاصطناعية تعطي نتائج وتحسينات ذات أهمية للمتاجرة القائمة على Guppy Multiple Moving Average (GMMA) المتوسط المتحرك المتعدد. بينما ركزت دراسة (Lin and Yu, 2009) على التنبؤات المشتقة من الشبكات العصبية الاصطناعية كاستراتيجية بسيطة لعمليات المتاجرة، وتمت مقارنة ربحية استخدام الشبكات العصبية الاصطناعية مع استراتيجية الشراء - الاحتفاظ. وقد استخدم الباحثون الشبكات العصبية الاصطناعية في هذه الدراسة

بالتطبيق على المؤشر التايواني المرجح ومؤشر ستاندارد آند بورز (S&P500)، وتوصلت إلى أنه يمكن تحقيق عوائد باستخدام قاعدة المتاجرة التي تستند أو تقوم على الشبكات العصبية الاصطناعية أفضل من استراتيجية الشراء والاحتفاظ .

من جهة أخرى، اختبرت دراسة (Januskevicius, 2003) كفاءة سوق الأوراق المالية في ليتوانيا باستخدام الشبكات العصبية الاصطناعية لاختبار مدى الكفاءة، إذ إن الشبكات العصبية الاصطناعية لديها القدرة على تعلم الآليات الرئيسية للعمليات المعقدة المستخدمة في سوق رأس المال، وقد عرضت الدراسة لفروض الكفاءة والانتقادات الموجهة لأصحاب مدخل كفاءة الأسواق المالية، وتم عمل محاكاة لعملية المتاجرة على أساس القيم المتوقعة لمؤشرين وهما: LITIN and LITIN-G خلال الفترة من (يناير 1999 إلى أكتوبر 2002) حاصلين بذلك على 15180 قيمة متوقعة ككل، وتوصلت إلى أن سوق رأس المال الليتواني سوق غير كفاء، وأنه في أغلب الأحوال فإن الشبكات العصبية الاصطناعية قادرة على جني عوائد إضافية متفوقة بذلك على استراتيجية الشراء والاحتفاظ التي تمت مقارنتها مع نموذج الشبكات العصبية الاصطناعية خلال الدراسة.

هذا، وقد قدمت دراسة (Pan et al., 2005) مدخلا (منهجا) رياضيا للتنبؤ بمؤشر سوق رأس المال الأسترالي AORD باستخدام الشبكات العصبية الاصطناعية ذات التغذية الأمامية والمتعددة الطبقات استنادا إلى بيانات السلسلة الزمنية لمؤشر AORD، وكذلك البيانات التي تتعلق بالأسواق المترابطة (المتداخلة) المتنوعة. وذلك بهدف اكتشاف شبكة عصبية فعالة أو مجموعة من الشبكات العصبية الاصطناعية المتكيفة لغرض التنبؤ بالمؤشر، والذي يمكن أن يستغل أو يصوغ نماذج ديناميكية متنوعة، ويستغل تأثيرات السوق اليومية الداخلية والمقتبسة من التحليل الفني والتحليل الكمي، وقد تم استخدام ثلاثة أوجه لتحقيق كفاءة اختيار بيانات المدخلات، وهي: بيانات من السوق المستهدف نفسه، وبيانات من هذه الأسواق المتداخلة والمترابطة، كذلك فإنه تم أخذ بُعدين تقليديين لمعمارية الشبكات العصبية الاصطناعية في الاعتبار وهما: العدد الأمثل من الطبقات المخفية، وكذلك العدد الأمثل للنيورونات المخفية لكل طبقة خفية، وتوصلت الدراسة لاكتشاف دورة الستة أيام 6 day cycle في سوق رأس المال الأسترالي خلال فترة الدراسة، والتوقع الزمني المستخدم في الدراسة كمدخلات إضافية وفرت معلومات مفيدة، وأخيرا فإن الشبكة العصبية الأساسية التي تستخدم عوائد يومية لستة أيام من مؤشر AORD وعائد يومي واحد من مؤشر S&P500 بالإضافة إلى يوم من الأسبوع كمدخلات تعطي صحة تنبؤ اتجاهي بنسبة مئوية أعلى من 80% .

ومن ناحية أخرى، دعمت دراسة (Prasad, 2008) قدرة الشبكات العصبية الاصطناعية على التنبؤ بمؤشرات الأسواق المالية وسوق النفط، وذلك بإدخال مجموعة من المتغيرات والثوابت في نظام الشبكة، وقد تم تنفيذ الدراسة بالتطبيق على ثلاث آليات في السوق وهي: معدلات أسعار الصرف، وأسعار الأسهم، وأسعار البترول، وتوصلت الدراسة إلى تحقيق تنبؤات دقيقة بالنسبة لمعدلات سعر الصرف وأسعار الأسهم عن طريق المدخلات والمحددات التي تم اختيارها من أجل الدراسة، حيث أعطت تنبؤات دقيقة لتحركات الأسعار المستقبلية استنادا إلى التحركات السابقة للأسعار. وتعد هذه التنبؤات باستخدام الشبكات العصبية الاصطناعية أفضل من التنبؤات التي تم الحصول عليها من طريقة التنبؤ التقليدية المربعات الصغرى، كذلك فإن استراتيجية المتاجرة التي تم تطويرها على أساس تنبؤات الشبكة العصبية قد أعطت فرصا كبيرة لجني الأرباح، ولم يتم التوصل لنتائج ذات أهمية بالنسبة للتنبؤ بأسعار النفط في هذه الدراسة على أساس القيم المشاهدة.

وقامت دراسة (Chopra et al., 2019) باختبار قدرة الشبكات العصبية الاصطناعية (ANN) على توقع أسعار سوق الأسهم قبل وبعد فترة التحويل النقدي في الهند، وبلغ حجم العينة (9) أسهم ومؤشر CNX NIFTY50 لتوقع القيمة المستقبلية للسهم خلال فترة (8) سنوات، وتم تدريب الشبكات العصبية الاصطناعية متعددة الطبقات، وإنشاء عدة شبكات بتغيير عدد الخلايا العصبية لتحقيق أدنى معدل مربعات الانحدار، وقيم انحدارية تم العثور عليها أثناء التدريب تشير إلى كفاءة عالية للشبكة العصبية المصممة، وتم التحقق من القيم المتوقعة من قبل الشبكات المصممة مع القيم الفعلية قبل وبعد فترة التحويل النقدي في الهند. وتوصلت الدراسة إلى أن جميع الشبكات (سواء كانت كبيرة الرأسالية، أو متوسطة الرأسالية، أو صغيرة الرأسالية) المبنية فعالة جدًا في التنبؤ بأسعار سوق الأسهم الهندي بشكل فعال، سواء قبل أو بعد التحويل النقدي. وبلغت قيم الانحدار المحصل عليها هي 0.999، مما يدل على زيادة كفاءة الشبكة المقترحة لجميع أنواع الأسهم ومؤشر NIFTY50. وتوقعت دراسة (Shamsaliniya et al., 2024) مرونة أسعار الأسهم في بورصة طهران باستخدام نموذج متعدد الطبقات من الشبكات العصبية الاصطناعية خلال الفترة من 2009 إلى 2019، وقارنت الدراسة نماذج مشتقة في الشبكات NARX و NAR و ARMAX و AR على التوالي والأساليب الإحصائية من الشبكات العصبية الاصطناعية لتوقع متوسط مرونة أسعار الأسهم للسنة التالية. وتوصلت الدراسة إلى أن جميع نماذج الشبكات العصبية الاصطناعية تتمتع بدقة أعلى بكثير في توقع مرونة أسعار الأسهم مقارنة بالأساليب الإحصائية. وأيضًا هدفت دراسة (Teixeira Zavadzki de Pauli et al., 2020) إلى دراسة العلاقة بين الشبكات العصبية الاصطناعية وتوقع أسعار الأسهم في الفترة من مارس 2019 إلى إبريل 2020 بالتطبيق على ستة من أكثر الأسهم تداولًا على بورصة البرازيل الرسمية، وتوصلت إلى أن الشبكات العصبية الاصطناعية قادرة على التنبؤ بأسعار الأسهم حتى في ظل جائحة "كورونا".

وعلى الجانب الآخر، قامت دراسة (Das et al., 2017) بتطبيق التنقيب عن البيانات Data Mining والشبكة العصبية المحسنة Optimized Neural Network Techniques البيانات الكبيرة Big Data في توقع الأسهم بقطاع تكنولوجيا المعلومات في بورصة دكا، حيث يسمح التنقيب عن البيانات باستخراج معلومات مفيدة من مجموعة البيانات الضخمة Big Data، في حين أن الشبكة العصبية قادرة على التنبؤ بالاتجاهات المستقبلية.

وهدف الدراسة (Zhang and Lou, 2021) إلى تصنيف أنماط أسعار الأسهم والتنبؤ بها باستخدام الشبكة العصبية وخوارزمية تعلم الآلة، فتمثل الطريقة في استخدام الشبكة العصبية لخوارزمية وتعلم الآلة لبيانات المعاملات لمدة (5) أيام متتالية كعينات إدخال، بحيث يكون هناك (20) عقدة لطبقة الإدخال. يتم استخدام القيمة النهائية لليوم التالي كعينة إخراج، وعدد العقد في طبقة الإخراج. وأظهرت النتائج أن دقة التنبؤ لسعر السهم تبلغ (62,12%) تحت تنبؤ خوارزمية التعلم و(73,29%) تحت تنبؤ الشبكة العصبية لخوارزمية BP. ومن خلال تحليل التنبؤ بعدد الطبقات المخفية لسعر السهم والنطاقات المختلفة، يمكن أن نستنتج أن التنبؤ بنموذج التنبؤ باتجاه سعر السهم للشبكة العصبية لخوارزمية BP أفضل من نموذج التنبؤ بخوارزمية التعلم العميق الغامض؛ حيث توفر هذه الخوارزمية للمستثمرين قيمة معينة للتنبؤ بالأسهم.

وتوصلت دراسة (Kurani et al., 2023) إلى أنه يمكن تعزيز دقة الشبكات العصبية الاصطناعية في التنبؤ بأسعار الأسهم والتنبؤ بسوق الأوراق المالية من خلال تقديم نموذج هجين مثل ANN-MLP و GARCH-MLP، وهو مزيج من خوارزمية Backpropagation وشبكة التغذية الأمامية متعددة الطبقات، والعمل على دمج الشبكات العصبية الاصطناعية مع نماذج وأساليب أخرى، مثل: أجهزة نقل الدعم (SVM)، والتنقيب عن البيانات Data Mining من أجل التنبؤ وتوقعات أشكال التنبؤات المختلفة للأسهم، وتوصلت الدراسة إلى أن تطبيق أجهزة نقل الدعم (SVM) يتم بنجاح في التنبؤ بالمخزون، مما أعطى دقة تبلغ حوالي 60%-70% باستخدام الانحدار البسيط. وبشكل قاطع لعبت SVM

و ANN أدوارًا بارزة في معالجة مشكلة ضيق الوقت ومحدودية البيانات ومشكلات البداية الباردة، وتوصلت الدراسة إلى أن الشبكات العصبية الاصطناعية هي واحدة من أهم وأفضل الخوارزميات لتنبؤ الأسهم، ويمكن تعزيزها بشكل أكبر من خلال تكاملها مع تقنيات جديدة أخرى، وقامت دراسة (Chhajer et al., 2022) بتحليل توقعات أسعار الأسهم باستخدام الشبكات العصبية الاصطناعية وآلات الدعم النوعية.

مما سبق - وفي حدود علم الباحثين- يتبين تنوع مجالات تطبيق الذكاء الاصطناعي بصورة عامة والشبكات العصبية الاصطناعية بصورة خاصة في مجالات المحاسبية والمراجعة، ويتبين مما سبق تفوق قدرة الشبكات العصبية الاصطناعية على الأساليب الإحصائية المختلفة في دقة التنبؤ.

ونجد أن هناك فجوة معرفية حول مدى تطبيق تلك الشبكات بالأسواق الناشئة، حيث إن الجانب الأعظم من الدراسات السابقة تناولته في الدول المتقدمة، وأن الدراسات السابقة التي أجريت في البيئة المصرية في جانبها الأعظم اعتمدت على أسلوب الاستقصاء عند تجميع البيانات، إلا أن الدراسة الحالية تعتمد على التحليل الكمي، وفي ضوء ما سبق يمكن اشتقاق فرضي الدراسة، على النحو التالي:

الفرض الأول:

" لا توجد علاقة ذات دلالة إحصائية بين البيانات التاريخية كمدخلات للشبكة العصبية الاصطناعية، وبين عملية التنبؤ بالسلوك السعري لمؤشر البورصة المصرية EGX30 كمخرجات الشبكة العصبية الاصطناعية".

الفرض الثاني:

" لا توجد علاقة ذات دلالة إحصائية بين مؤشرات التحليل الفني كمدخلات للشبكة العصبية الاصطناعية، وبين عملية التنبؤ بالسلوك السعري لمؤشر البورصة المصرية EGX30 كمخرجات الشبكة العصبية الاصطناعية".

4- منهجية وتصميم الدراسة التجريبية:

تتناول منهجية الدراسة التجريبية: عرضًا لأهداف الدراسة التجريبية، ومجتمع الدراسة وعينتها، وأساليب جمع البيانات، والأساليب الإحصائية المستخدمة لتحليل البيانات، وتعريف ووصف متغيرات الدراسة، ونتائج اختبار فرضي الدراسة.

1/4 - أهداف الدراسة التجريبية:

يكمّن الهدف الرئيسي للدراسة في اختبار قدرة الشبكات العصبية الاصطناعية في التنبؤ بتحركات مؤشرات الأسواق المالية باستخدام البيانات التاريخية ومؤشرات التحليل الفني؛ حيث قام الباحثان بإجراء مقابلة مع بعض الممارسين من المحللين الفنيين، وخاصة في جمعية المحللين الفنيين المصرية، وكذلك بعض السماسرة وال Traders العاملين بالبورصة المصرية، وذلك للتعرف على أساليب التحليل والتنبؤ التي يتم استخدامها من قبل المتعاملين في البورصة المصرية، ومدى العلم (المعرفة) أو الخلفية عن نماذج الشبكات العصبية الاصطناعية كنموذج حديث للتنبؤ والتصنيف والتحليل، ومدى تطبيق نماذج الشبكات العصبية الاصطناعية في المؤسسات المالية، والتي تبين عدم ممارسة الكثير من المحللين لهذه النماذج، وإن كانت هناك فئة قليلة تعلم بهذه النماذج، ولكن لم تستطع الدراسة الحصول على ممارسين تستخدم هذه النماذج لقياس أدائها حتى وقتنا هذا، فكان هذا حافزًا ودافعًا من أهم الدوافع الأساسية لإجراء هذه الدراسة.

2/4 - مجتمع وعينة الدراسة:

يتمثل مجتمع وعينة الدراسة في المؤشر الرئيسي للبورصة المصرية EGX 30، خلال الفترة الزمنية من عام (2013م) إلى عام (2022م)، وفي ضوء ذلك بلغ حجم العينة (2437) مشاهدة منها (1569) مشاهدة تم استخدامها لغرض تدريب الشبكة العصبية الاصطناعية، و(868) مشاهدة تم استخدامها لاختبار قدرة الشبكة العصبية الاصطناعية على التنبؤ لاختبار فرضي الدراسة.

3/4 - أساليب جمع البيانات:

اعتمدت الدراسة على المسح المستندي للبيانات والمعلومات المرتبطة بمشكلة الدراسة للتحقق من صحة فرضي الدراسة لتحديد مدى قبول أي من صيغة فرض عدم أو صيغة الفرض البديل لكليهما.

1/3/4 - البيانات الأولية: تم الحصول على البيانات التاريخية لمؤشر EGX30، وهو المؤشر الرئيسي للبورصة المصرية من خلال البيانات التي تصدرها شركة مصر للنشر المعلومات .

2/3/4 - البيانات الثانوية: قامت الدراسة بعمل مسح مستندي للبيانات المتعلقة بموضوع الدراسة، وتضمنت تلك المجموعة بيانات المؤشرات الفنية بناء على حزمة برامج التحليل الفني Meta Stock Professional الإصدار الحادي عشر .

4/4 - الأساليب الإحصائية المستخدمة لتحليل البيانات:

اعتمدت الدراسة على تطبيق الاختبارات الإحصائية لتحليل البيانات المتصلة بمشكلة الدراسة، وذلك من خلال كل من؛ الأساليب الإحصائية الاعتمادية، والأساليب الإحصائية الوصفية، والأساليب الإحصائية الاستدلالية.

1/4/4 - الأساليب الإحصائية الاعتمادية: وهي تلك الأساليب التي تُعنى بإعطاء نتائج مدى الاعتمادية على سلاسل الزمنية، وذلك لبحث مدى الاعتماد على نتائج التحليل الإحصائي في تعميم النتائج من عدمها.

2/4/4 - الأساليب الإحصائية الوصفية: وهي تلك الأساليب التي تُعنى بإعطاء معلومات عن خصائص البيانات الداخلة إلى التحليل، ومن أمثلة تلك الأساليب كل من: الوسط الحسابي، الانحراف المعياري.

3/4/4 - الأساليب الإحصائية الاستدلالية: وهي تلك الأساليب التي تُعنى بإعطاء نتائج عن مدى قبول أو رفض فروض الدراسة، إضافة إلى تحديد كل من مستويات الثقة والمعنوية لنتائج الاختبار، وسوف يتم الاعتماد على كل من أساليب الاختبار المعملية Parametric وغير المعملية Non-Parametric، وذلك في ضوء مجتمع وعينة الدراسة.

5/4 - تعريف ووصف متغيرات الدراسة:

1/5/4 - المتغيرات المستقلة:

تنقسم المتغيرات المستقلة التي تشملها الدراسة الحالية إلى مجموعتين من البيانات، المجموعة الأولى: تغطي مدخلات الشبكة التاريخية، أما المجموعة الثانية فتُعنى بمدخلات الشبكة الفنية؛ حيث شملت البيانات التاريخية لمؤشر البورصة المصرية EGX30 كمدخلات للشبكة العصبية كلاً من: قيمة الفتح في بداية كل جلسة، وأعلى قيمة لمؤشر خلال جلسة التداول، وأدنى قيمة لمؤشر خلال جلسة التداول، وأخيراً حجم التداول خلال تلك الجلسة، أما بيانات مؤشرات التحليل الفني كمدخلات للشبكة العصبية الفنية فشملت كلاً من: (المتوسطات المتحركة لمدة (5-7-10-12-14-21-50-100 يوم)، ومؤشر التقارب والتباعد بين المتوسطات MACD، ومؤشر الزخم Momentum، وأخيراً مؤشر المذبذبات (Stochastic Oscillator)، حيث يتم تقدير مؤشرات التحليل الفني على النحو التالي:

1/1/5/4 - مؤشر المتوسط المتحرك Moving Average:

يمكن تقدير ذلك المؤشر من خلال المعادلة رقم (1):

$$SMA_k = \frac{p_{n-k+1} + p_{n-k+2} + \dots + p_n}{k}$$

$$= \frac{1}{k} \sum_{i=n-k+1}^n p_i$$

حيث إن:

- SMA_k قيمة مؤشر المتوسط المتحرك البسيط لعدد (k) من جلسات التداول.
- $P_{n,k}$ القيمة السعرية للمؤشر خلال جلسة التداول بمعلومية (k)، (n).
- K رتبة المتوسط المتحرك البسيط.
- N عدد المشاهدات الممكنة خلال السلسلة الزمنية.

2/1/5/4 - مؤشر التقارب والتباعد بين المتوسطات Moving Average Convergence/Divergence (MACD):

يمكن تقدير ذلك المؤشر من خلال المعادلة رقم (2):

$$MACD = 12\text{-Period EMA} - 26\text{-Period EMA}$$

حيث إن:

- MACD مؤشر التقارب والتباعد بين المتوسطات.
- 12-Period EMA المتوسط المتحرك الأسي لآخر 12 جلسة تداول.
- 26-Period EMA المتوسط المتحرك الأسي لآخر 26 جلسة تداول.

3/1/5/4 - مؤشر الزخم Momentum:

يمكن تقدير ذلك المؤشر من خلال المعادلة رقم (3):

$$\text{Momentum} = (SMA_{\text{today}} - SMA_{\text{today}-k}) (k-1)$$

حيث إن:

- Momentum قيمة مؤشر الزخم.
- k رتبة (فترة) مؤشر الزخم.
- SMA_{today} المتوسط الحسابي البسيط لليوم.
- $SMA_{\text{today}-k}$ المتوسط الحسابي البسيط لفترة إبطاء قدرها رتبة الزخم (k).

4/1/5/4 - مؤشر المذبذبات Stochastic Oscillator:

يمكن تقدير ذلك المؤشر من خلال المعادلة رقم (4):

$$\%K = (P_0 - PL_K) - (PH_K - PL_K)$$

حيث إن:

- %K قيمة مؤشر المذبذبات.
- K رتبة (فترة) مؤشر المذبذبات.
- P_0 القيمة السعرية للمؤشر خلال آخر جلسة تداول.
- PL_K أقل قيمة سعرية للمؤشر خلال آخر (K) من جلسات التداول.
- PH_K أكبر قيمة سعرية للمؤشر خلال آخر (K) من جلسات التداول.

2/5/4 - المتغير التابع:

تُعد القيم المقدرة من عملية التنبؤ السعري لمؤشر البورصة المصرية EGX30، هي المتغير التابع، الذي يتم تقديره من خلال الشبكة العصبية الاصطناعية والناتج من عملية تدريب الشبكة.

6/4 - الدوال الرياضية للشبكات العصبية الاصطناعية:

يمكن التعبير رياضياً عن نموذجي الشبكة العصبية الاصطناعية على النحو التالي:

1/6/4 - دالة الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية:

يمكن التعبير الرياضي عن تلك الشبكة على النحو التالي:

$$P(EGX30_t) = f(OP_T, HP_T, LP_T, V_T)$$

حيث إن:

- EGX30_t القيمة المتنبأ بها لمؤشر EGX30 خلال جلسة التداول (t).
- OP_T قيمة الفتح الخاصة بمؤشر EGX30 خلال جلسة التداول (t).
- HP_T أعلى قيمة لمؤشر EGX30 خلال جلسة التداول (t).
- LP_T أدنى قيمة لمؤشر EGX30 خلال جلسة التداول (t).
- V_T قيمة اغلاق المؤشر EGX30 في نهاية جلسة التداول (t).

2/6/4 - دالة الشبكة العصبية الاصطناعية طبقاً للبيانات الفنية:

يمكن التعبير الرياضي عن تلك الشبكة على النحو التالي:

$$P(EGX30_t) = f(SMA5_t, SMA7_t, SMA10_t, SMA12_t, SMA14_t, SMA21_t, SMA50_t, SMA100_t, MACD_t, MOM_t, STO_t).$$

حيث إن:

- EGX30_t القيمة المتنبأ بها لمؤشر EGX30 خلال جلسة التداول (t).
- SMA5_t قيمة المتوسط المتحرك البسيط لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (5) جلسات.
- SMA7_t قيمة المتوسط المتحرك البسيط لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (7) جلسات.
- SMA10_t قيمة المتوسط المتحرك البسيط لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (10) جلسات.
- SMA12_t قيمة المتوسط المتحرك البسيط لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (12) جلسة.
- SMA14_t قيمة المتوسط المتحرك البسيط لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (14) جلسة.
- SMA21_t قيمة المتوسط المتحرك البسيط لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (21) جلسة.
- SMA50_t قيمة المتوسط المتحرك البسيط لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (50) جلسة.
- SMA100_t قيمة المتوسط المتحرك البسيط لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (100) جلسة.
- MACD_t قيمة مؤشر التقارب والتباعد بين المتوسطات لمؤشر EGX30 خلال جلسة التداول (t) بين المتوسط الحسابي الأثني لفترة (12) جلسة من جانب والمتوسط الحسابي الأثني لفترة (26) جلسة.
- MOM_t قيمة مؤشر الزخم Momentum لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (14) جلسة.
- STO_t قيمة مؤشر المذبذبات Stochastic Oscillator لمؤشر EGX30 خلال جلسة التداول (t) عن فترة (14) جلسة.

7/4 - الأساليب الإحصائية المستخدمة:

لقد رغب الباحثان في البداية قبل تناول الأساليب الإحصائية المستخدمة ونتائج اختبار فرضي الدراسة في إظهار طريقة بناء نموذج الشبكات العصبية الاصطناعية، باستخدام برامج (NeuroXL) لبناء الشبكة العصبية، الإصدار (3.1.2).

1/7/4 - طريقة بناء نموذج الشبكة العصبية الاصطناعية:

أ. إدخال البيانات: تم إدخال البيانات (المدخلات) مع ضرورة مراعاة الاتساق في هذه البيانات حتى يمكن تسهيل عمل الشبكة العصبية. بصفة عامة كلما زاد حجم البيانات المجمعة والداخلة للشبكة كان ذلك أفضل، وإلا فإنه لا يمكن ضمان جودة النتائج لو حدث العكس. على أنه يجب ملاحظة أن مجموعات البيانات الكبيرة تزيد من فترات التشغيل خلال عملية التدريب، ولكن هذا يزيد من دقة عملية التدريب، ويؤدي إلى الوصول للأوزان المثلى بسرعة. (Weckman et al, 2008).

ب. تحديد وحجز المساحة التي تعمل عليها الشبكة العصبية: من الضروري جداً تحديد المساحة التي تعمل عليها الشبكة العصبية وتعريف الشبكة بمكان جميع العناصر في التحليل ويتم ذلك كما يلي: (عبيد، 1994)

1. تحديد عدد سطور (مفردات) المدخلات.
2. تحديد الأعمدة التي توجد فيها المدخلات.
3. تحديد العمود أو الأعمدة التي توجد فيها النتائج المستهدفة.
4. تحديد الجزء من البيانات الذي يجري عليه التعلم والجزء الذي يُجرى عليه الاختبار.
5. تحديد العمود أو الأعمدة التي يتم فيها إعطاء المخرجات أو النتائج.

ج. تحديد حجم الشبكة العصبية: وهذه الخطوة تعتبر أصعب الخطوات؛ حيث تلعب خبرة الباحثين دوراً هاماً، فالمطلوب هنا تحديد عدد الطبقات الملائمة للبيانات، وزيادة كفاءة الشبكة في عملية التعلم، فيلعب عدد الطبقات في الشبكات دوراً أساسياً في عملية التنبؤات (Farahani and Hajiagha, 2021)، فالشبكة العصبية غالباً ما تحتاج إلى ثلاث طبقات، ولكن المشكلة في تحديد عدد الخلايا الوسيطة أو الخفية التي تقوم بالتشعب، وعملية التكاثر الارتدادي Back Propagation، وتقدير الأوزان المختلفة. وتؤدي الشبكات العصبية الاصطناعية ذات الوحدات المخفية القليلة أفضل من الشبكات العصبية الاصطناعية ذات الوحدات المخفية الكثيرة، وتستطيع الشبكة متعددة الطبقات حل العديد من المشاكل المعقدة مقارنة مع الشبكة وحيدة الطبقة، لكن تدريب الشبكات متعددة الطبقات يستغرق وقتاً أطول (بسيوني، 2008). وقد أشار Nelson and Illingworth إلى أنه يمكن تحسين أداء الشبكة عن طريق تخفيض حجم الطبقة المخفية، وفي الوقت نفسه سوف يؤدي ذلك إلى تخفيض وقت المحاكاة الخاص بالشبكة (Lin et al., 2002)، حيث إن طبقة مخفية واحدة أو اثنتين كافية، وإن زيادة عدد الطبقات المخفية يزيد من خطورة Over Fitting وكذلك طول فترة الحوسبة (Coupelon, 2007).

د. تحديد معاملات الشبكة العصبية: يتضمن ذلك تحديد معدل التعلم، والقدرة على التعلم، ومعدل الاختبار، وعدد الخطوات أو مراحل التعلم، والزمن المسموح به في عملية التعلم، ونسبة الخطأ المسموح بها، وهكذا، وتحديد هذه المعاملات يخضع بدرجة كبيرة لمدى خبرة الباحث (Aris and Mohamad, 2008).

هـ. **مرحلة التعلم أو التدريب Training and Learning:** هناك العديد من طرق تدريب الشبكات العصبية الاصطناعية؛ وذلك بسبب تعامله مع العلاقات الخطية وغير الخطية (Farahani and Hajiagha, 2021)، حيث يعرف التدريب بأنه: العملية التي بواسطتها يتم الحصول على القيم المثلى لمحددات أو معلمات الشبكة، والهدف من عملية التدريب هو إيجاد مجموعة الأوزان التي تؤدي إلى تخفيض مجموع الأخطاء التربيعية squared errors بين المخرجات التقديرية أو التي تم التنبؤ بها والمخرجات الفعلية (Al-hidi and Al-Hasan, 2002)، وتتكون مرحلة التدريب من عرض أو تقديم مجموعة بيانات التدريب إلى الشبكة، وبذلك فإنه يتم تعديل الأوزان لإنتاج المخرجات المرغوبة بالنسبة لكل مجموعة مدخلات؛ لذلك فإنه يتم تكرار هذه العملية (التدريب) حتى يتم الوصول إلى أوزان متسقة أو مثلى تُخرج الناتج المرغوب.

و. **مرحلة الاختبار وإعطاء النتائج النهائية (Testing (Validation):** بعد إتمام عملية التعلم يتم توجيه الشبكة العصبية لمرحلة الاختبار التي عادةً لا تستغرق وقتاً طويلاً؛ ومن ثم تظهر نتائج التقدير أو التحليل المطلوب، ونسبة الخطأ، وعدد المفردات الصحيحة. إذا أسفرت مرحلة الاختبار عن انحرافات كبيرة فإنه يجب إعادة فحص عملية التدريب وربما إعادة عملية التدريب، وفي هذه المرحلة يتم اختبار مدى صلاحية الشبكة العصبية الاصطناعية، وذلك من خلال إدخال مجموعة من بيانات الاختبار، وهي البيانات الجديدة المطلوبة إلى الشبكة التي سبق تجربتها واختبارها، وبعد وقت قصير تظهر النتائج المطلوبة ونسبة الأخطاء (Trippi and Turban, 1992).

يُذكر أن مطوري برامج الشبكات العصبية الاصطناعية التي تستخدم للأغراض التجارية يعتبرون أن ما يقومون به لتطوير مثل هذه البرامج معلومات خاصة بهم، وتُعامل كحق ملكية فكرية لهم، ويحتفظون بسرية ذلك لأنفسهم؛ حيث يرفضون إفشاء المعلومات وذكر التفاصيل الخاصة بعملية بناء الشبكات الخاصة بهم .

2/7/4- أسلوب تحليل علاقة الارتباط: حيث يتم استخدام مُعامل ارتباط بيرسون واختبار Kendall للتأكد، والذي يُعنى باختبار علاقة الارتباط بين مدخلات ومخرجات الشبكة العصبية، إضافة إلى تحديد معنوية مُعامل الارتباط متغيرات كل شبكة على حدة مع قيم المؤشر.

3/7/4- أسلوب تحليل الانحدار: لتحديد القدرة التفسيرية؛ حيث يتم استخدام مُعامل التحديد (R^2) لقياس القدرة التفسيرية لكل شبكة عصبية في تفسير النقلب الحادث في قيم المؤشر.

8/4- اختبارات تحليل البيانات، ونتائج اختبار فرضي الدراسة:

تتناول الدراسة في هذا القسم اختبار استقرار السلاسل الزمنية، والإحصاء الوصفي للمتغيرات البحثية، وبالإضافة إلى تناول نتائج الاختبارات الإحصائية التي قامت بها الدراسة؛ لتحديد مدى صحة أو عدم صحة فرضي الدراسة محل الاختبار.

1/8/4- اختبار استقرار السلاسل الزمنية وإزالة القيم المتطرفة:

قامت الدراسة بمعالجة القيم المتطرفة عند معدل تطرف قدره (5%) (Maydeu-Olivares et al., 2017) من سلسلة البيانات الداخلة إلى الشبكة العصبية الاصطناعية عن الفترة من عام 2013 إلى عام 2022، وهي القيم الناتجة عن الأزمات غير العادية التي مرت بها جمهورية مصر العربية، سواء في جانب المخاطر السياسية أو جانب صدمات تحرير أسعار الصرف، بالإضافة إلى ما سبق تم اختبار ثبات السلسلة الزمنية التي جاءت مستقرة عند مستوى (5%).

2/8/4- الإحصاء الوصفي للمتغيرات البحثية:

1/2/8/4- الإحصاء الوصفي لأداء المؤشر الرئيسي للبورصة المصرية EGX30:

يعد مؤشر EGX 30 (المعروف بمؤشر CASE 30 سابقاً) هو المؤشر الرئيسي للبورصة المصرية، تم حساب مؤشر EGX 30 وفقاً للعملة المحلية ابتداء من 4 يناير 1998 بقيمة أساس تبلغ 1000 نقطة، ويضم مؤشر EGX 30 أعلى 30 شركة مقيدة في البورصة المصرية من حيث السيولة والنشاط والتداول على أسهمها العادية المُصدرة، ويتم ترجيح مؤشر EGX 30 بالأسهم الحرة إلى إجمالي الأسهم المتضمنة فيه طبقاً لسعر إقفال تلك الأسهم بالجنيه المصري. ويشترط لدخول شركة ما ذلك المؤشر ألا تقل نسبة التداول الحر للشركة عن 15% كحد أدنى، ويمكن للقارئ الرجوع إلى موقع البورصة المصرية للتعرف على منهجية حساب هذا المؤشر. ويمكن استعراض تطور المؤشر الرئيسي للبورصة المصرية EGX30 خلال فترة التحليل عبر الشكل رقم (2)، واستعراض البيانات التاريخية للمؤشر من خلال الشكل رقم (3)، واستعراض المؤشرات الفنية للمؤشر من خلال الشكل رقم (4)، وذلك على النحو التالي:

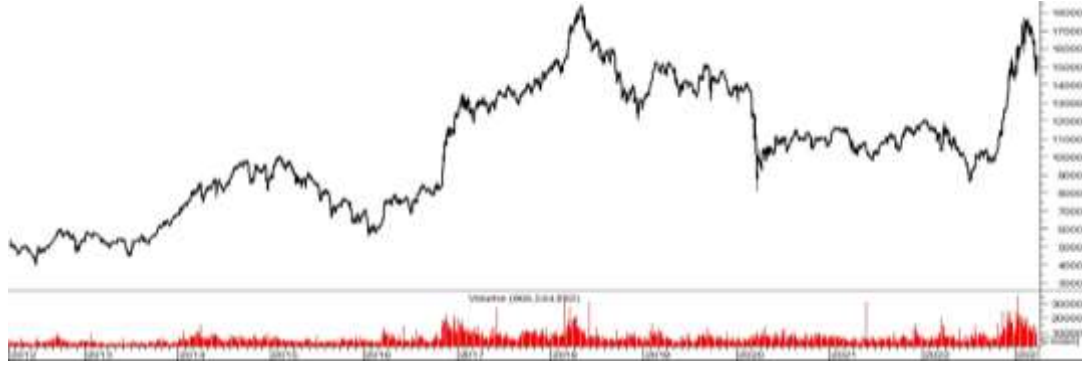
أ- استعراض تطور المؤشر الرئيسي للبورصة المصرية EGX30 خلال فترة التحليل عبر الشكل رقم (2)



شكل رقم (2): أداء المؤشر الرئيسي للبورصة المصرية EGX30 ما بين عامي (2013: 2022)

لقد تباين أداء المؤشر خلال فترة 2013: 2022، حيث سجل المؤشر EGX30 أعلى قيمة خلال تلك الفترة بمقدار (18354,02) نقطة والمسجلة في 30 إبريل 2018. أما أقل قيمة للمؤشر خلال ذات الفترة فهي 4519,11 والمسجلة خلال جلسة التداول 25 يونيو 2013، وقد بلغ إجمالي المشاهدات (2437)، منها (1569) مشاهدة تم استخدامها لغرض تدريب الشبكة العصبية مقابل (868) مشاهدة تم استخدامها لاختبار قدرة الشبكة على التنبؤ لاختبار فروض الدراسة.

ب- استعراض البيانات التاريخية للمؤشر من خلال الشكل رقم (3):



شكل رقم (3): الخريطة السعرية للبيانات التاريخية للمؤشر الرئيسي للبورصة المصرية EGX30 في الفترة من (2013: 2022)

يتضح من استعراض الشكل رقم (3) الخريطة السعرية للبيانات التاريخية للمؤشر الرئيسي للبورصة المصرية EGX30 في الفترة من (2013: 2022)، بأنه سجّل أدنى قيمة (21838272) سهمًا في يوم 2013/3/31، وأعلى قيمة (8853716992) سهمًا في يوم 2017/7/5.

ج- استعراض المؤشرات الفنية للمؤشر من خلال الشكل رقم (4):



شكل رقم (4): الخريطة السعرية لبيانات المؤشرات الفنية للمؤشر الرئيسي للبورصة المصرية EGX30 في الفترة (2013: 2022)

يتضح من استعراض الشكل رقم (4) تناغم حركة المؤشر مع المتوسطات المتحركة بأنواعها المختلفة، أما على مستوى تقارب وتباعد المتوسطات المتحركة (المجد) فقد استطاع الوصول إلى قيم تعلو مستوى (500+) مرتين خلال فترة الدراسة مقابل الوصول لمستوى دوني (-1000) مرة واحدة، وذلك خلال يوم 2020/3/23، وهو ذات اليوم الذي حقق أدنى قيمة لمؤشر الزخم (Momentum)، أما مؤشر المذبذبات فقد حقق أدنى قيمة في ذات التاريخ أيضًا.

2/2/8/4 - معالم الإحصاء الوصفي لمتغيرات الدراسة:

يمكن استعراض معالم الإحصاء الوصفي للمتغيرات الداخلة إلى الشبكات العصبية الاصطناعية، وهما: المتوسط الحسابي والانحراف المعياري، كما يُظهر الجدول التالي رقم (1):

جدول رقم (1): معالم الإحصاء الوصفي للمتغيرات الداخلة إلى الشبكات العصبية الاصطناعية

الانحراف المعياري	المتوسط الحسابي	البيان
3120,763459	10647,54165	قيمة الفتح لمؤشر EGX30
3134,694473	10720,02803	أعلى قيمة لمؤشر EGX30
3109,934696	10587,35098	أقل قيمة لمؤشر EGX30
3120,018572	10651,37721	قيمة الإغلاق لمؤشر EGX30
345104367,5	562324165,7	حجم قيمة التداول
3114,409699	10652,22838	المتوسط المتحرك البسيط لمؤشر EGX30 عن فترة (5) جلسات
3111,617676	10652,65147	المتوسط المتحرك البسيط لمؤشر EGX30 عن فترة (7) جلسات
2797,886569	9587,772545	المتوسط المتحرك البسيط لمؤشر EGX30 عن فترة (10) جلسات
3104,273476	10654,91626	المتوسط المتحرك البسيط لمؤشر EGX30 عن فترة (12) جلسة
3102,758429	10653,83882	المتوسط المتحرك البسيط لمؤشر EGX30 عن فترة (14) جلسة
3089,932093	10655,2329	المتوسط المتحرك البسيط لمؤشر EGX30 عن فترة (21) جلسة
3048,964319	10670,21386	المتوسط المتحرك البسيط لمؤشر EGX30 عن فترة (50) جلسة
2987,358835	10722,58706	المتوسط المتحرك البسيط لمؤشر EGX30 عن فترة (100) جلسة
236,1467276	20,3413-	مؤشر التقارب والتباعد بين المتوسطات لمؤشر EGX30
25,32878074	98,30986581	مؤشر الزخم Momentum لمؤشر EGX30
23,45691196	50,0165	مؤشر المذبذبات Stochastic Oscillator لمؤشر EGX30

3/2/8/4 - توصيف الشبكات العصبية الاصطناعية:

قامت الدراسة ببناء تسع عشرة شبكة عصبية اصطناعية منها عشر شبكات عصبية اصطناعية طبقاً للبيانات التاريخية، مقابل سبع شبكات عصبية اصطناعية طبقاً لبيانات المؤشرات الفنية. ويمكن استعراض معالم الشبكات العصبية الاصطناعية طبقاً للبيانات التاريخية من خلال الجدول رقم (2)، بينما يستعرض الجدول رقم (3) معالم الشبكات العصبية الاصطناعية طبقاً لبيانات مؤشرات التحليل الفني.

جدول رقم (2): معالم الشبكات العصبية الاصطناعية طبقاً للبيانات التاريخية

الزخم	معدل التعلم	الوزن المبدئي	حد التجربة (الحد الأقصى لمرات التجربة)	الحد الأدنى للانحراف (خطأ التقدير)	الشبكية
0.6	0.3	0.9	1000	0.001	معالم معمارية الشبكة المعيارية
0.6	0.3	0.9	5000	0.0001	معالم معمارية الشبكة المعدلة رقم 1
0.6	0.3	0.9	10000	0.0001	معالم معمارية الشبكة المعدلة رقم 2
0.9	0.9	0.9	10000	0.000001	معالم معمارية الشبكة المعدلة رقم 3
0.9	0.9	0.6	10000	0.000001	معالم معمارية الشبكة المعدلة رقم 4
0.9	0.9	0.6	10000	0.000001	معالم معمارية الشبكة المعدلة رقم 5
0.9	0.9	0.6	200000	0.000001	معالم معمارية الشبكة المعدلة رقم 6
0.9	0.9	0.3	200000	0.000001	معالم معمارية الشبكة المعدلة رقم 7
0.9	0.9	0.3	300000	0.000001	معالم معمارية الشبكة المعدلة رقم 8
0.9	0.9	0.3	400000	0.000001	معالم معمارية الشبكة المعدلة رقم 9
0.9	0.9	0.1	500000	0.000001	معالم معمارية الشبكة المعدلة رقم 10

يتضح من الجدول رقم (2) خصائص الشبكات العصبية الاصطناعية التي قامت بمعالجة البيانات التاريخية؛ حيث كان الحد الأدنى للانحراف (خطأ التقدير) يتراوح ما بين (0.000001): (0.001)، أما حد التجربة فيتراوح ما بين (1000): (500000)، بينما الوزن المبدئي للمتغيرات الداخلة للشبكة فيتراوح ما بين (0.1): (0.9)، أما معدل تعلم الشبكة العصبية فقد تراوح ما بين (0.3): (0.9)، وأخيراً الزخم فقد تراوح ما بين (0.6): (0.9).

جدول رقم (3): معالم الشبكات العصبية الاصطناعية طبقاً لبيانات مؤشرات التحليل الفني

الزخم	معدل التعلم	الوزن المبدئي	حد التجربة (الحد الأقصى لمرات التجربة)	الحد الأدنى للانحراف (خطأ التقدير)	الشبكية
0.9	0.9	0.9	10000	0.0001	معالم معمارية الشبكة المعيارية
0.9	0.9	0.6	10000	0.00001	معالم معمارية الشبكة المعدلة رقم 1
0.9	0.9	0.6	10000	0.000001	معالم معمارية الشبكة المعدلة رقم 2
0.9	0.9	0.6	200000	0.000001	معالم معمارية الشبكة المعدلة رقم 3
0.9	0.9	0.3	200000	0.000001	معالم معمارية الشبكة المعدلة رقم 4
0.9	0.9	0.3	300000	0.000001	معالم معمارية الشبكة المعدلة رقم 5
0.9	0.9	0.3	400000	0.000001	معالم معمارية الشبكة المعدلة رقم 6
0.9	0.9	0.1	500000	0.000001	معالم معمارية الشبكة المعدلة رقم 7

يتضح من الجدول رقم (3) خصائص الشبكات العصبية الاصطناعية التي قامت بمعالجة البيانات للمؤشرات الفنية؛ حيث كان الحد الأدنى للانحراف (خطأ التقدير) يتراوح ما بين (0.000001): (0.0001)، أما حد التجربة فيتراوح ما بين (10000): (500000)، بينما الوزن المبدئي للمتغيرات الداخلة للشبكة فيتراوح ما بين (0.1): (0.9)، أما معدل تعلم الشبكة العصبية فقد كان (0.9)، وأخيراً كان معدل الزخم (0.9) لكافة الشبكات العصبية الاصطناعية التي قامت بمعالجة بيانات المؤشرات الفنية.

5- اختبار فرضي الدراسة:

1/5- اختبار الفرض الأول:

ينص الفرض الأول على:

أنه لا توجد علاقة ذات دلالة إحصائية بين البيانات التاريخية كمداخلات للشبكة العصبية الاصطناعية، وبين عملية التنبؤ بالسلوك السعري لمؤشر البورصة المصرية EGX30 كمخرجات الشبكة العصبية الاصطناعية".

1/5-1 اختبار علاقات الارتباط بين متغيرات الدراسة:

تناولت الدراسة أسلوب تحليل الارتباط؛ حيث تم استخدام مُعامل ارتباط بيرسون، ويمكن إجراء اختبار تأكدي من خلال اختبار Kendall على ذات البيانات، والذي يقوم بالأساس باختبار علاقة الارتباط بين القيم الحقيقية "لمدخلات الشبكة التاريخية" والقيم المتوقعة للتنبؤ "بالسلوك السعري للمؤشر" الناتج من الشبكة العصبية الاصطناعية، إضافة إلى تحديد معنوية مُعامل الارتباط لمتغيرات كل شبكة على حدة مع قيم المؤشر .

أ- نتائج اختبار بيرسون لمعامل الارتباط بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من الشبكة العصبية الاصطناعية:

قام الباحثان باختبار مخرجات الشبكة العصبية التي تم بناؤها على أساس البيانات التاريخية باستخدام حزمة البرامج الإحصائية للعلوم الاجتماعية SPSS، ويوضح الجدول رقم (4) نتيجة هذا الاختبار:

جدول رقم (4): نتائج اختبار بيرسون لمعامل الارتباط بين القيم الحقيقية والمتوقعة للشبكات العصبية الاصطناعية للبيانات التاريخية

Correlations												
	NN_E1	NN_E10	NN_E2	NN_E3	NN_E4	NN_E5	NN_E6	NN_E7	NN_E8	NN_E9	NN_S	RV
Pearson Correlation	NN_E1	1.000	.997**	1.000**	.999**	.997**	.996**	.997**	.996**	.997**	.998**	.999**
	NN_E10	.997**	1.000	.997**	.994**	.996**	1.000**	1.000**	1.000**	1.000**	1.000**	.998**
	NN_E2	1.000**	.997**	1.000	.999**	1.000**	.997**	.996**	.997**	.998**	.997**	.998**
	NN_E3	.999**	.994**	.999**	1.000	1.000**	.994**	.995**	.994**	.994**	.995**	.995**
	NN_E4	1.000**	.996**	1.000**	1.000**	1.000	.996**	.995**	.996**	.995**	.996**	.997**
	NN_E5	.997**	1.000**	.997**	.994**	.996**	1.000	1.000**	1.000**	1.000**	1.000**	.998**
	NN_E6	.996**	1.000**	.996**	.994**	.995**	1.000**	1.000	1.000**	1.000**	1.000**	.997**
	NN_E7	.997**	1.000**	.997**	.995**	.996**	1.000**	1.000	1.000**	1.000**	1.000**	.999**
	NN_E8	.996**	1.000**	.996**	.994**	.995**	1.000**	1.000**	1.000**	1.000	1.000**	.998**
	NN_E9	.997**	1.000**	.997**	.994**	.996**	1.000**	1.000**	1.000**	1.000	1.000**	.998**
	NN_S	.998**	1.000**	.998**	.995**	.997**	1.000**	.999**	1.000**	1.000**	1.000	.999**
	RV	.999**	.998**	.998**	.996**	.998**	.997**	.999**	.998**	.998**	.999**	1.000
Sig. (2-tailed)	NN_E1	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E10	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E2	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E3	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E4	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E5	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E6	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E7	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E8	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_E9	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	NN_S	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	RV	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
N	NN_E1	868	868	868	868	868	868	868	868	868	868	868
	NN_E10	868	868	868	868	868	868	868	868	868	868	868
	NN_E2	868	868	868	868	868	868	868	868	868	868	868
	NN_E3	868	868	868	868	868	868	868	868	868	868	868
	NN_E4	868	868	868	868	868	868	868	868	868	868	868
	NN_E5	868	868	868	868	868	868	868	868	868	868	868
	NN_E6	868	868	868	868	868	868	868	868	868	868	868
	NN_E7	868	868	868	868	868	868	868	868	868	868	868
	NN_E8	868	868	868	868	868	868	868	868	868	868	868
	NN_E9	868	868	868	868	868	868	868	868	868	868	868
	NN_S	868	868	868	868	868	868	868	868	868	868	868
	RV	868	868	868	868	868	868	868	868	868	868	868

** . Correlation is significant at the 0.01 level (2-tailed).

يتضح من الجدول رقم (4) أنه توجد علاقة ارتباط موجبة بين القيم الحقيقية لمؤشر EGX30 والقيم المتوقعة التي تم التنبؤ بها من خلال الشبكة العصبية للبيانات التاريخية، وأن علاقة الارتباط بين المتغيرات كانت تتراوح بين (أدنى قيمة ارتباط) للشبكة رقم (3) تبلغ (99.6%)، وجاءت الشبكة المعيارية، والشبكة رقم (1) ورقم (7) أعلى درجة ارتباط بمعدل (99.9%)، ونجد معنوية الارتباط لجميع الشبكات عند مستوى معنوية (1%).

ب- نتائج اختبار Kendall لمعامل الارتباط بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من الشبكة العصبية الاصطناعية:

جدول رقم (5): نتائج اختبار Kendall لمعامل الارتباط بين القيم الحقيقية والمتوقعة للشبكات العصبية الاصطناعية للبيانات التاريخية

Correlations															
		NN_E1	NN_E10	NN_E2	NN_E3	NN_E4	NN_E5	NN_E6	NN_E7	NN_E8	NN_E9	NN_S	RV		
Kendall's tau_b	Correlation	NN_E1	1.000	.923**	.998**	.960**	.980**	.922**	.915**	.928**	.917**	.923**	.933**	.948**	
	Coefficient	NN_E10	.923**	1.000	.922**	.901**	.914**	.991**	.985**	.988**	.980**	.980**	.980**	.980**	.944**
		NN_E2	.998**	.922**	1.000	.961**	.980**	.921**	.914**	.927**	.916**	.922**	.932**	.946**	.917**
		NN_E3	.960**	.901**	.961**	1.000	.979**	.901**	.897**	.905**	.898**	.902**	.907**	.917**	.917**
		NN_E4	.980**	.914**	.980**	.979**	1.000	.914**	.908**	.918**	.909**	.914**	.922**	.933**	.933**
		NN_E5	.922**	.991**	.921**	.901**	.914**	1.000	.989**	.985**	.989**	.986**	.974**	.941**	.941**
		NN_E6	.915**	.985**	.914**	.897**	.908**	.989**	1.000	.977**	.990**	.987**	.966**	.933**	.933**
		NN_E7	.928**	.988**	.927**	.905**	.918**	.985**	.977**	1.000	.978**	.984**	.984**	.984**	.951**
		NN_E8	.917**	.986**	.916**	.898**	.909**	.989**	.990**	.978**	1.000	.987**	.969**	.935**	.935**
		NN_E9	.923**	.990**	.922**	.902**	.914**	.996**	.987**	.984**	.987**	1.000	.974**	.942**	.942**
		NN_S	.933**	.980**	.932**	.907**	.922**	.974**	.966**	.984**	.969**	.974**	1.000	.959**	.959**
RV	.948**	.944**	.946**	.917**	.933**	.941**	.933**	.951**	.935**	.942**	.959**	1.000	1.000		
Sig. (2-tailed)	NN_E1	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E10	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E2	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E3	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E4	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E5	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E6	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E7	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E8	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_E9	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
	NN_S	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	
RV	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000		
N	NN_E1	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E10	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E2	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E3	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E4	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E5	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E6	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E7	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E8	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_E9	868	868	868	868	868	868	868	868	868	868	868	868	868	
	NN_S	868	868	868	868	868	868	868	868	868	868	868	868	868	
RV	868	868	868	868	868	868	868	868	868	868	868	868	868		

** Correlation is significant at the .01 level (2-tailed).

يتضح من الجدول رقم (5) وجود علاقة ارتباط موجبة بين القيم الحقيقية لمؤشر EGX30 والقيم التي تم التنبؤ بها من خلال الشبكة العصبية للبيانات التاريخية، وأن علاقة الارتباط بين المتغيرات كانت تتراوح بين (أدنى قيمة ارتباط) للشبكة رقم (3) تبلغ (91.7%)، وجاءت الشبكة المعيارية أعلى درجة ارتباط بمعدل (95.1%)، ونجد معنوية الارتباط لجميع الشبكات عند مستوى معنوية (1%).

2/1/5- أسلوب تحليل الانحدار:

تم تقدير معدل تفسير تحركات المؤشر الرئيسي للبورصة المصرية عبر مخرجات الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية عبر استعراض نتائج تحليل الانحدار لإحدى عشرة شبكة عصبية اصطناعية تم تجربتها مسبقاً، حيث توضح الجداول التالية من رقم (6) إلى رقم (16) نتيجة هذا الاختبار.

1- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية للشبكة المعيارية، يوضح الجدول رقم (6) نتيجة هذا الاختبار:

جدول رقم (6): تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعيارية

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.999 ^a	.998	.998	89.6506

a. Predictors: (Constant), NN_S

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	474176.0	.000 ^a
	Residual	6960235	866	8037.223		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_S

b. Dependent Variable: RV

يتضح من الجدول رقم (6) وجود علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعيارية التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,8%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

3- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية (الشبكة المعدلة رقم 1)، ويوضح الجدول رقم (7) نتيجة هذا الاختبار:

جدول رقم (7): تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (1)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.999 ^a	.997	.997	112.8302

a. Predictors: (Constant), NN_E1

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	299041.7	.000 ^a
	Residual	1.1E+07	866	12730.648		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E1

b. Dependent Variable: RV

يتضح من الجدول رقم (7) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (1) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,7%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

4- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية (الشبكة المعدلة رقم (2)، يوضح الجدول رقم (8) نتيجة هذا الاختبار:

جدول رقم (8): تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (2)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.998 ^a	.997	.997	116.5433

a. Predictors: (Constant), NN_E2

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	280235.6	.000 ^a
	Residual	1.2E+07	866	13582.345		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E2

b. Dependent Variable: RV

يتضح من الجدول رقم (8) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (2) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,7%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

5- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية (الشبكة المعدلة رقم (3)، يوضح الجدول رقم (9) نتيجة هذا الاختبار:

جدول رقم (9): تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (3)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.996 ^a	.992	.992	187.2914

a. Predictors: (Constant), NN_E3

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	107977.4	.000 ^a
	Residual	3.0E+07	866	35078.083		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E3

b. Dependent Variable: RV

يتضح من الجدول رقم (9) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (3) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,2%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

6- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية (الشبكة المعدلة رقم (4)، يوضح الجدول رقم (10) نتيجة هذا الاختبار:

جدول رقم (10): تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (4)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.998 ^a	.995	.995	148.2697

a. Predictors: (Constant), NN_E4

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	172807.5	.000 ^a
	Residual	1.9E+07	866	21983.890		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E4

b. Dependent Variable: RV

يتضح من الجدول رقم (10) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (4) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,5%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

7- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية (الشبكة المعدلة رقم (5)، يوضح الجدول رقم (11) نتيجة هذا الاختبار:

جدول رقم (11): تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (5)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.998 ^a	.996	.996	133.4316

a. Predictors: (Constant), NN_E5

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	213581.3	.000 ^a
	Residual	1.5E+07	866	17803.992		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E5

b. Dependent Variable: RV

يتضح من الجدول رقم (11) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (5) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,6%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

8- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية (الشبكة المعدلة رقم 6)، يوضح الجدول رقم (12) نتيجة هذا الاختبار:

جدول رقم (12): تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (6)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.997 ^a	.995	.995	153.9668

a. Predictors: (Constant), NN_E6

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	160192.5	.000 ^a
	Residual	2.1E+07	866	23705.789		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E6

b. Dependent Variable: RV

يتضح من الجدول رقم (12) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (6) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,5%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

9- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ بالسلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً للبيانات التاريخية (الشبكة المعدلة رقم 7)، يوضح الجدول رقم (13) نتيجة هذا الاختبار:

جدول رقم (13): تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (7)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.999 ^a	.997	.997	110.3061

a. Predictors: (Constant), NN_E7

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	312924.0	.000 ^a
	Residual	1.1E+07	866	12167.432		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E7

b. Dependent Variable: RV

يتضح من الجدول رقم (13) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (7) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,7%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

10- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ، السلوك السعري للمؤشر الناتج من معالم معمارية، الشبكة العصبية الاصطناعية؛ طبقاً للبيانات التاريخية (الشبكة المعدلة رقم 8)، يوضح الجدول رقم (14) نتيجة هذا الاختبار.

جدول رقم (14) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (8)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.998 ^a	.995	.995	147.6201

a. Predictors: (Constant), NN_E8

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	174339.3	.000 ^a
	Residual	1.9E+07	866	21791.685		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E8

b. Dependent Variable: RV

يتضح من الجدول رقم (14): أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (8) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,5%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

11- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ، السلوك السعري للمؤشر الناتج من معالم معمارية، الشبكة العصبية الاصطناعية؛ طبقاً للبيانات التاريخية (الشبكة المعدلة رقم 9)، يوضح الجدول رقم (15) نتيجة هذا الاختبار.

جدول رقم (15) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (9)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.998 ^a	.996	.996	131.1670

a. Predictors: (Constant), NN_E9

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	221050.1	.000 ^a
	Residual	1.5E+07	866	17204.787		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E9

b. Dependent Variable: RV

يتضح من الجدول رقم (15): أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (9) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,6%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

12- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة التاريخية والقيم المتوقعة للتنبؤ، السلوك السعري للمؤشر الناتج من معالم معمارية، الشبكة العصبية الاصطناعية؛ طبقاً للبيانات التاريخية (الشبكة المعدلة رقم 10)، يوضح الجدول رقم (16) نتيجة هذا الاختبار.

جدول رقم (16) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية التاريخية المعدلة رقم (10)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.998 ^a	.996	.996	127.4399

a. Predictors: (Constant), NN_E10

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.8E+09	1	3.8E+09	234220.2	.000 ^a
	Residual	1.4E+07	866	16240.929		
	Total	3.8E+09	867			

a. Predictors: (Constant), NN_E10

b. Dependent Variable: RV

يتضح من الجدول رقم (16) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (10) التي تم بناؤها في ضوء البيانات التاريخية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (99,6%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

نتيجة الاختبار الفرض الأول:

تأسيساً على نتيجة التحليلات السابقة (اختبار علاقات الارتباط بين متغيرات الدراسة، وأسلوب تحليل الانحدار)، يمكن للباحثين من رفض فرض عدم وقبول الفرض البديل الذي ينص على:

"توجد علاقة ذات دلالة إحصائية بين البيانات التاريخية كمدخلات للشبكة العصبية الاصطناعية، وبين عملية التنبؤ بالسلوك السعري لمؤشر البورصة المصرية EGX30 كمخرجات الشبكة العصبية الاصطناعية".

2/5- اختبار الفرض الثاني:

ينص الفرض الثاني للدراسة على:

"لا توجد علاقة ذات دلالة إحصائية بين المؤشرات الفنية كمدخلات للشبكة العصبية الاصطناعية وبين عملية التنبؤ بالسلوك السعري لمؤشر البورصة المصرية EGX30 كمخرجات الشبكة العصبية الاصطناعية".

1/2/5- اختبار علاقات الارتباط بين متغيرات الدراسة:

تناولت الدراسة أسلوب تحليل الارتباط؛ حيث تم استخدام معامل ارتباط بيرسون، ويمكن إجراء اختبار تأكدي من خلال اختبار Kendall على ذات البيانات، والذي يقوم بالأساس باختبار علاقة الارتباط بين القيم الحقيقية «مدخلات الشبكة الفنية» والقيم المتوقعة للتنبؤ «السلوك السعري للمؤشر» الناتج من الشبكة العصبية الاصطناعية، إضافة إلى تحديد معنوية معامل الارتباط متغيرات كل شبكة على حده مع قيم المؤشر.

أ- نتائج اختبار بيرسون لمعامل الارتباط بين القيم الحقيقية مدخلات الشبكة الفنية والقيم المتوقعة للتنبؤ السلوك السعري للمؤشر الناتج من الشبكة العصبية الاصطناعية.

جدول رقم (17) نتائج اختبار بيرسون لمعامل الارتباط بين القيم الحقيقية والمتوقعة للشبكات العصبية الاصطناعية للبيانات الفنية.

.EGX30

Correlations

		EGX30	NN_TE1	NN_TE2	NN_TE3	NN_TE4	NN_TE5	NN_TE6	NN_TE7	NN_TS
Pearson Correlation	EGX30	1.000	.323**	.051	.808**	.432**	.417**	.523**	.388**	.615**
	NN_TE1		1.000	-.259**	.604**	.810**	.819**	.769**	.839**	.433**
	NN_TE2			1.000	.102**	-.186**	-.164**	-.142**	-.257**	.404**
	NN_TE3				1.000	.778**	.773**	.847**	.725**	.854**
	NN_TE4					1.000	.996**	.988**	.988**	.656**
	NN_TE5						1.000	.984**	.990**	.657**
	NN_TE6							1.000	.968**	.714**
	NN_TE7								1.000	.560**
	NN_TS									1.000
Sig. (2-tailed)	EGX30		.000	.190	.000	.000	.000	.000	.000	.000
	NN_TE1			.000	.000	.000	.000	.000	.000	.000
	NN_TE2				.009	.000	.000	.000	.000	.000
	NN_TE3					.000	.000	.000	.000	.000
	NN_TE4						.000	.000	.000	.000
	NN_TE5							.000	.000	.000
	NN_TE6								.000	.000
	NN_TE7									.000
	NN_TS									.000
N	EGX30	668	668	668	668	668	668	668	668	668
	NN_TE1		668	668	668	668	668	668	668	668
	NN_TE2			668	668	668	668	668	668	668
	NN_TE3				668	668	668	668	668	668
	NN_TE4					668	668	668	668	668
	NN_TE5						668	668	668	668
	NN_TE6							668	668	668
	NN_TE7								668	668
	NN_TS									668

** . Correlation is significant at the 0.01 level (2-tailed).

يتضح من الجدول رقم (17): توجد علاقة ارتباط موجبة بين القيم الحقيقية لمؤشر EGX30، والقيم التي تم التنبؤ بها من خلال الشبكة العصبية للبيانات الفنية، وإن علاقة الارتباط بين المتغيرات كانت تتراوح بين (أدنى قيمة ارتباط للشبكة رقم (2) تبلغ (1,5%)، وجاءت الشبكة رقم (3) أعلى درجة ارتباط بمعدل (80.8%)، نجد معنوية الارتباط لجميع الشبكات عند مستوى معنوية (1%)، عدا الشبكة العصبية المعدلة رقم (2).

ب - نتائج اختبار Kendall لمعامل الارتباط بين القيم الحقيقية والمتوقعة للشبكات العصبية الاصطناعية للبيانات الفنية.

جدول رقم (18) نتائج اختبار Kendall لمعامل الارتباط بين القيم الحقيقية والمتوقعة للشبكات العصبية الاصطناعية للبيانات الفنية.

		Correlations									
		EGX30	NN_TE1	NN_TE2	NN_TE3	NN_TE4	NN_TE5	NN_TE6	NN_TE7	NN_TS	
Kendall's tau_b	Correlation	EGX30	1.000	.259**	.139**	.762**	.485**	.466**	.572**	.562**	.445**
	Coefficient	NN_TE1	.259**	1.000	.273**	.303**	.226**	.218**	.191**	.210**	.311**
		NN_TE2	.139**	.273**	1.000	.323**	.400**	.435**	.357**	.358**	.514**
		NN_TE3	.762**	.303**	.323**	1.000	.645**	.642**	.722**	.700**	.664**
		NN_TE4	.485**	.226**	.400**	.645**	1.000	.933**	.869**	.894**	.764**
		NN_TE5	.466**	.218**	.435**	.642**	.933**	1.000	.873**	.882**	.785**
		NN_TE6	.572**	.191**	.357**	.722**	.869**	.873**	1.000	.950**	.722**
		NN_TE7	.562**	.210**	.358**	.700**	.894**	.882**	.950**	1.000	.722**
		NN_TS	.445**	.311**	.514**	.664**	.764**	.785**	.722**	.722**	1.000
		Sig. (2-tailed)	EGX30	.000	.000	.000	.000	.000	.000	.000	.000
		NN_TE1	.000	.000	.000	.000	.000	.000	.000	.000	.000
		NN_TE2	.000	.000	.000	.000	.000	.000	.000	.000	.000
		NN_TE3	.000	.000	.000	.000	.000	.000	.000	.000	.000
		NN_TE4	.000	.000	.000	.000	.000	.000	.000	.000	.000
		NN_TE5	.000	.000	.000	.000	.000	.000	.000	.000	.000
		NN_TE6	.000	.000	.000	.000	.000	.000	.000	.000	.000
		NN_TE7	.000	.000	.000	.000	.000	.000	.000	.000	.000
		NN_TS	.000	.000	.000	.000	.000	.000	.000	.000	.000
	N	EGX30	668	668	668	668	668	668	668	668	668
		NN_TE1	668	668	668	668	668	668	668	668	668
		NN_TE2	668	668	668	668	668	668	668	668	668
		NN_TE3	668	668	668	668	668	668	668	668	668
		NN_TE4	668	668	668	668	668	668	668	668	668
		NN_TE5	668	668	668	668	668	668	668	668	668
		NN_TE6	668	668	668	668	668	668	668	668	668
		NN_TE7	668	668	668	668	668	668	668	668	668
		NN_TS	668	668	668	668	668	668	668	668	668

** Correlation is significant at the .01 level (2-tailed).

يتضح من الجدول رقم (18): توجد علاقة ارتباط موجبة بين القيم الحقيقية لمؤشر EGX30، والقيم التي تم التنبؤ بها من خلال الشبكة العصبية للبيانات الفنية، وإن علاقة الارتباط بين المتغيرات كانت تتراوح بين (أدنى قيمة ارتباط للشبكة رقم (2) تبلغ (13.9%)، وجاءت الشبكة رقم (3) اعلي درجة ارتباط بمعدل (76.2%)) نجد معنوية الارتباط لجميع الشبكات عند مستوى معنوية (1%).

2/2/5- أسلوب تحليل الانحدار:

يمكن تقدير معدل تفسير تحركات المؤشر الرئيس للبورصة المصرية عبر مخرجات الشبكة العصبية الاصطناعية طبقاً للمؤشرات الفنية عبر استعراض نتائج تحليل الانحدار لقيم ثمانية شبكة عصبية اصطناعية تم تدريبها مسبقاً، حيث يوضح الجدول التالية من رقم (19) إلى رقم (26) نتيجة هذا الاختبار.

1- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة الفنية والقيم المتوقعة للتنبؤ، السلوك السعري للمؤشر الناتج من معالم معمارية، الشبكة العصبية الاصطناعية؛ طبقاً لمؤشرات التحليل الفني الشبكة المعيارية، يوضح الجدول رقم (19) نتيجة هذا الاختبار.

جدول رقم (19) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية الفنية المعيارية

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.615 ^a	.378	.377	843.1339

a. Predictors: (Constant), NN_TS

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2.9E+08	1	2.9E+08	405.324	.000 ^a
	Residual	4.7E+08	666	710874.7		
	Total	7.6E+08	667			

a. Predictors: (Constant), NN_TS

b. Dependent Variable: EGX30

يتضح من الجدول رقم (19) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعيارية التي تم بناؤها في ضوء المؤشرات الفنية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (37,8%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

2- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمداخل الشبكة الفنية والقيم المتوقعة للتنبؤ السلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً لمؤشرات التحليل الفني (الشبكة المعدلة رقم 1)، يوضح الجدول رقم (20) نتيجة هذا الاختبار.

جدول رقم (20) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية الفنية المعدلة رقم (1)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.323 ^a	.104	.103	1012.0506

a. Predictors: (Constant), NN_TE1

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	7.9E+07	1	7.9E+07	77.549	.000 ^a
	Residual	6.8E+08	666	1024246		
	Total	7.6E+08	667			

a. Predictors: (Constant), NN_TE1

b. Dependent Variable: EGX30

يتضح من الجدول رقم (20) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (1) التي تم بناؤها في ضوء المؤشرات الفنية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (10,4%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

3- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة الفنية والقيم المتوقعة للتنبؤ السلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً لمؤشرات التحليل الفني (الشبكة المعدلة رقم 2)، يوضح الجدول رقم (21) نتيجة هذا الاختبار.

جدول رقم (21) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية الفنية المعدلة رقم (2)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.051 ^a	.003	.001	1067.9722

a. Predictors: (Constant), NN_TE2

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	1961305	1	1961305	1.720	.190 ^a
	Residual	7.6E+08	666	1140565		
	Total	7.6E+08	667			

a. Predictors: (Constant), NN_TE2

b. Dependent Variable: EGX30

يتضح من الجدول رقم (21) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (2) التي تم بناؤها في ضوء المؤشرات الفنية لبيانات غير معنوية عند مستوى (1% أو 5%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (3%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

4- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة الفنية والقيم المتوقعة للتنبؤ السلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً لمؤشرات التحليل الفني (الشبكة المعدلة رقم 3)، يوضح الجدول رقم (22) نتيجة هذا الاختبار.

جدول رقم (22) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية الفنية المعدلة رقم (3)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.808 ^a	.652	.652	630.7335

a. Predictors: (Constant), NN_TE3

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	5.0E+08	1	5.0E+08	1248.354	.000 ^a
	Residual	2.6E+08	666	397824.7		
	Total	7.6E+08	667			

a. Predictors: (Constant), NN_TE3

b. Dependent Variable: EGX30

يتضح من الجدول رقم (22): أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (3) التي تم بناؤها في ضوء المؤشرات الفنية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (65,2%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

5- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة الفنية والقيم المتوقعة للتنبؤ السلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً لمؤشرات التحليل الفني (الشبكة المعدلة رقم 4)، يوضح الجدول رقم (23) نتيجة هذا الاختبار.

جدول رقم (23) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية الفنية المعدلة رقم (4)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.432 ^a	.187	.186	964.2145

a. Predictors: (Constant), NN_TE4

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	1.4E+08	1	1.4E+08	153.156	.000 ^a
	Residual	6.2E+08	666	929709.5		
	Total	7.6E+08	667			

a. Predictors: (Constant), NN_TE4

b. Dependent Variable: EGX30

يتضح من الجدول رقم (23) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (4) التي تم بناؤها في ضوء المؤشرات الفنية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (18,7%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

6- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة الفنية والقيم المتوقعة للتنبؤ السلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً لمؤشرات التحليل الفني (الشبكة المعدلة رقم 5)، يوضح الجدول رقم (24) نتيجة هذا الاختبار.

جدول رقم (24) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية الفنية المعدلة رقم (5)

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.417 ^a	.174	.172	972.1173

a. Predictors: (Constant), NN_TE5

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	1.3E+08	1	1.3E+08	139.892	.000 ^a
	Residual	6.3E+08	666	945012.1		
	Total	7.6E+08	667			

a. Predictors: (Constant), NN_TE5

b. Dependent Variable: EGX30

يتضح من الجدول رقم (24) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (5) التي تم بناؤها في ضوء المؤشرات الفنية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (17,4%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

7- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة الفنية والقيم المتوقعة للتنبؤ السلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً لمؤشرات التحليل الفني (الشبكة المعدلة رقم 6)، يوضح الجدول رقم (25) نتيجة هذا الاختبار.

جدول رقم (25) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية الفنية المعدلة رقم (6)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.523 ^a	.273	.272	911.6280

a. Predictors: (Constant), NN_TE6

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2.1E+08	1	2.1E+08	250.387	.000 ^a
	Residual	5.5E+08	666	831065.6		
	Total	7.6E+08	667			

a. Predictors: (Constant), NN_TE6

b. Dependent Variable: EGX30

يتضح من الجدول رقم (25) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (6) التي تم بناؤها في ضوء المؤشرات الفنية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (27,3%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

8- أسلوب تحليل الانحدار لاختبار العلاقة بين القيم الحقيقية لمدخلات الشبكة الفنية والقيم المتوقعة للتنبؤ السلوك السعري للمؤشر الناتج من معالم معمارية الشبكة العصبية الاصطناعية طبقاً لمؤشرات التحليل الفني (الشبكة المعدلة رقم 7)، يوضح الجدول رقم (26) نتيجة هذا الاختبار.

جدول رقم (26) تحليل الانحدار بين القيم الحقيقية والمتوقعة للشبكات العصبية الفنية المعدلة رقم (7)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.388 ^a	.151	.150	985.3907

a. Predictors: (Constant), NN_TE7

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	1.1E+08	1	1.1E+08	118.327	.000 ^a
	Residual	6.5E+08	666	970994.9		
	Total	7.6E+08	667			

a. Predictors: (Constant), NN_TE7

b. Dependent Variable: EGX30

يتضح من الجدول رقم (26) أنه توجد علاقة انحدار معنوية بين القيمة الحقيقية لإغلاق مؤشر EGX30 مع القيمة التي تم التنبؤ بها من خلال الشبكة العصبية المعدلة رقم (7) التي تم بناؤها في ضوء المؤشرات الفنية لبيانات تداول المؤشر عند مستوى معنوية (1%)، وأن القدرة التفسيرية لهذه الشبكة طبقاً لمعامل التحديد هي (15,1%) من القيمة الحقيقية لإغلاق مؤشر EGX30.

نتيجة الاختبار الفرض الثاني:

تأسيسًا على نتيجة التحليلات السابقة (اختبار علاقات الارتباط بين متغيرات الدراسة، وأسلوب تحليل الانحدار) يمكن للباحثين من رفض فرض العدم وقبول الفرض البديل الذي ينص على:

" توجد علاقة ذات دلالة إحصائية بين المؤشرات الفنية كمدخلات للشبكة العصبية الاصطناعية وبين عملية التنبؤ بالسلوك السعري لمؤشر البورصة المصرية EGX30 كمخرجات الشبكة العصبية الاصطناعية".

6- مناقشة وتفسير النتائج:

يمكن أن يساعد التنبؤ الدقيق باستخدام الشبكات العصبية الاصطناعية على ترشيد القرارات لتكون أكثر حكمة، مما يقلل من حالة عدم اليقين، لذلك كان هناك اتجاه في السنوات الأخيرة نحو استخدام الشبكات العصبية الاصطناعية علي نطاق واسع وبشكل أكثر دقة عبر السلاسل الزمنية لاستخدامها لأغراض التنبؤ. وهو الأمر الذي تضمن توقعات أسعار الأسهم ومؤشراتها، وقد تم إرجاع ذلك إلى قدرتها القوية على الربط بين المتغيرات ذات العلاقات الخطية وغير الخطية، وعلى الرغم من تفوق الشبكات العصبية الاصطناعية على بعض المشاكل الخاصة بالسلاسل الزمنية، إلا أنه توجه بعض التحديات؛ مثل التوقيت الزمني الطويل، وانقطاع المفاجئة للبيانات، حيث إن عملية تدريب الشبكات العصبية تتطلب في بعض الأحيان توافر حاسبات آلية متقدمة، وأحيانًا قد تنخفض دقة التنبؤ (Li and Shi, 2024) وقد تم تقليل أخطاء التنبؤ الناتجة من معالجة البيانات عبر تصنيف وتطوير الخوارزميات (Quilty and Adamowski, 2018; Mi et al., 2019) وهو الأمر الذي انعكس على مدى الاعتمادية على نتائج التنبؤ بأسعار الاسهم وتحليل الأسواق المالية، حيث يساعد دقة التنبؤ في دعم موثوق لاتخاذ وصناع القرارات الاستثمارية (Li and Shi, 2024).

هذا وقد توصلت الدراسة إلى قدرة الشبكات العصبية الاصطناعية على التنبؤ وتفسير تحركات المؤشر الرئيسي للبورصة المصرية EGX30 اعتمادًا على البيانات التاريخية لعمليات التداول إلى جانب البيانات مؤشرات التحليل الفني. وهو الأمر الذي يتوافق مع نتائج بعض من الدراسات السابقة، ومنها (Senol and Ozturan, 2009) حيث أشارت تلك الدراسة إلى تفوق نماذج الشبكات العصبية الاصطناعية بالمقارنة مع الأساليب الأخرى، حيث أثبتت تلك الدراسة مدى تفوق الشبكات العصبية الاصطناعية على الأساليب التقليدية الأخرى ببورصة إسطنبول (تركيا).

إلى جانب التوافق مع نتائج دراسة (Farahani and Hajjagha, 2021) والتي خلصت إلى قدرة الشبكات العصبية الاصطناعية على تفسير التحركات السعري لمؤشرات الاسواق الدولية، والتي تتضمن أربع مؤشرات أمريكية (S&P500, DAX, Nasdaq and DJI بجانب مؤشر FTSE100 البريطاني. وأيضًا مع دراسة (Wagdi et al., 2023A) والتي خلصت إلى قدرة الشبكات العصبية الاصطناعية على التنبؤ بأسعار عملات الاقتصاديات الناشئة اعتمادًا على بيانات المؤشرات الفنية.

كما خلصت الدراسة أيضًا إلى أن قدرة الشبكات العصبية الاصطناعية تتباين من شبكة إلى أخرى، وهو الأمر الذي يتوافق مع نتائج دراسة (Pang et al., 2020) والتي أشارت إلى تباين قدرة الشبكات العصبية الاصطناعية في التنبؤ بتحركات سوق الأوراق المالية، ما بين الشبكات العصبية الاصطناعية ذات الذاكرة طويلة الأجل مقابل الشبكات العصبية الاصطناعية ذات الذاكرة قصيرة الأجل. وعلى مستوى الدراسة الحالية يمكن للباحثين تفسير هذا التباين في ضوء

مجموعتين من الأسباب، الأولى تتعلق بمدخلات الشبكة العصبية الاصطناعية، أي: طبيعة البيانات الداخلة إلى التحليل تؤثر على نتائجها وقدرتها على التنبؤ. بالإضافة إلى المجموعة الثانية والتي تتعلق بطبيعة الشبكة العصبية الاصطناعية ذاتها، حيث تؤثر كلٌّ من معمارية بناء الشبكة ومعالمها على نتائجها وقدرتها على التنبؤ.

7- نتائج الدراسة:

يمكن للباحثين استعراض نتائج الدراسة فيما يلي:

1/7- نتائج الدراسة النظرية:

أ. تعد مهنة المحاسبة والمراجعة من المهن الحية، التي تتطور وتتكيف مع متغيرات بيئة الأعمال، وهو ما جعل من ظهور الذكاء الاصطناعي نافذة جديدة لمهنية المحاسبة والمراجعة، حيث يحمل الذكاء الاصطناعي العديد من مكامن النفع للمهنة، مقابل نطاق من التهديدات والتحديات. لذا على المهنيين والأكاديميين أن يكونوا ذا يقظة نحو أثر تطورات الذكاء الاصطناعي على المهنة.

ب. في ظل ما تتميز به أسواق المال سمة عدم التأكد، كان هناك حاجة لتدنية هذه السمة، لكن هذا الأمر يتوقف على مستوى كفاءة السوق؛ حيث مستوى كفاءة السوق هو العنصر الحاكم لطبيعة البيانات التي يمكن استخدامها لتحقيق عوائد غير عادية؛ حيث في ظل الأسواق دون مستوى الكفاءة يمكن تحقيق عوائد غير عادية عبر مدخل التحليل الفني، أما في ظل الأسواق ضعيفة الكفاءة فيمكن تحقيق عوائد غير عادية من خلال مدخل التحليل الأساسي.

ج. تتعدد أدوات وأساليب الذكاء الاصطناعي، وتعد الشبكات العصبية الاصطناعية أن تلك الأساليب، حيث يعد أحد أنماط تعلم الآلة، وقد اكتسب هذا الأسلوب اهتمام كثير من الدول في المجالات العسكرية، بالإضافة إلى الأغراض المدنية من مجالات الطب والهندسة بالإضافة إلى العديد من تطبيقات الأعمال.

2/7- نتائج الدراسة التجريبية:

أ. هناك علاقة ذات دلالة إحصائية بين البيانات التاريخية للأسهم؛ كمدخلات للشبكة العصبية الاصطناعية وعملية التنبؤ بالتحركات السعريّة لمؤشر EGX30 كمرجات الشبكة العصبية؛ حيث تفسر الشبكة العصبية المعيارية التي تم بناؤها في ضوء بيانات التداول التاريخية على الأساس اليومي [قيمة الفتح في بداية جلسة التداول - أعلى قيمة للمؤشر خلال جلسة التداول - أدنى قيمة للمؤشر خلال جلسة التداول - قيمة إغلاق المؤشر في نهاية جلسة التداول - قيمة التداول خلال جلسة التداول] ما نسبته (99,8%) من الحركة السعريّة لمؤشر (EGX30).

ب. هناك علاقة ذات دلالة إحصائية بين المؤشرات الفنية للأسهم كمدخلات للشبكة العصبية الاصطناعية وعملية التنبؤ بالتحركات السعريّة لمؤشر EGX30 كمرجات الشبكة العصبية؛ حيث تفسر الشبكة العصبية المعدلة رقم (3) التي تم بناؤها في ضوء مؤشرات التحليل الفني على الأساس اليومي [المتوسط المتحرك لمدة 5 أيام، المتوسط المتحرك لمدة 7 أيام، المتوسط المتحرك لمدة 10 أيام، المتوسط المتحرك لمدة 12 يوم، المتوسط المتحرك لمدة 14 يوم، المتوسط المتحرك لمدة 21 يوم، المتوسط المتحرك لمدة 50 يوم، المتوسط

المتحرك لمدة 100 يوم، التقارب والتباعد بين المتوسطات MACD، الزخم Momentum، المذبذبات Stochastic] ما نسبته (2,65%) من الحركة السعرية لمؤشر (EGX30) .

ج. تباين قدرة الشبكات العصبية الاصطناعية في تفسير السلوك السعري للمؤشرات السوقية في ضوء تباين طبيعة البيانات الداخلة إلى الشبكة العصبية الاصطناعية، إلى جانب تباين معمارية الشبكة، الحد الأدنى للانحراف، حدد التجربة، الوزن المبدئي، معدل التعلم، وأخيرًا الزخم.

8- التوصيات ومقترحات الدراسات المستقبلية:

1/8- التوصيات:

في ضوء ما توصل إليه الباحثان من نتائج، يقدمان التوصيات التالية والإجراءات التنفيذية المقترحة لتطبيق توصيات الدراسة، كما يوضح الجدول رقم (27) .

جدول رقم (27) الإجراءات التنفيذية المقترحة لتطبيق توصيات الدراسة

الإطار الزمني	الموارد المطلوبة	مسئولية التنفيذ	التوصيات
من شهر إلى سنة	- موارد مالية - موارد بشرية - موارد تكنولوجية	المستثمرون والمحللون الماليون، ومديرو المحافظ المالية وصناديق الاستثمار	زيادة استخدام تطبيقات الشبكات العصبية الاصطناعية في مجال الاستثمار المالي، حيث يمكن الاستفادة من هذه التطبيقات لزيادة كفاءة وفعالية قرارات المتداولين في أسواق الأوراق المالية.
من شهر إلى سنة	- موارد بشرية - موارد مادية - موارد تكنولوجية	المستثمرون والمحللون الماليون، ومديرو المحافظ المالية وصناديق الاستثمار	تنوع مدخلات الشبكات العصبية الاصطناعية ليشتمل بجانب بيانات السلوك السعري والتي تشمل البيانات التاريخية ومؤشرات التحليل الفني كل من مؤشرات الأداء المالي للشركة المصدرة للأسهم العادية.
من شهر إلى سنة	- موارد بشرية - موارد مادية - موارد تكنولوجية	الجمعيات المهنية مثل: (الجمعية المصرية للأوراق المالية / الجمعية المصرية للمحللين الفنيين / الجمعية العربية للمحللين الفنيين / الجمعية المصرية للتمويل والاستثمار).	زيادة الوعي الاستثماري للمتداولين بالبورصة المصرية بنماذج الشبكات العصبية الاصطناعية كأحد مداخل إدارة الاستثمار المالي.
من شهر إلى سنة	- موارد بشرية - موارد مادية - موارد تكنولوجية	الجمعيات المهنية مثل: (الجمعية المصرية للأوراق المالية / الجمعية المصرية للمحللين الفنيين / الجمعية العربية للمحللين الفنيين / الجمعية المصرية للتمويل والاستثمار).	العمل على توفير البيانات التي يتم استخدامها كمدخلات للشبكات العصبية للمتداولين والمحللين بصورة فورية ومجانبة مما يعد تشجيعاً من قبل تلك الجمعيات على استخدام نماذج الشبكات العصبية.

2/8- مقترحات الدراسات المستقبلية:

- أ. تحديد مدى تماثل أو تباين القدرة التفسيرية للشبكات العصبية في تفسير السلوك السعري للمؤشرات السوقية في ضوء الفاصل الزمني للبيانات الداخلة إلى الشبكة العصبية (يومية / أسبوعية / شهرية / ربع سنوية/ سنوية).
- ب. تقييم كفاءة وفعالية استخدام الشبكات العصبية الاصطناعية في إدارة محافظ الأوراق المالية وصناديق الاستثمار.
- ج. تقييم كفاءة وفعالية استخدام الشبكات العصبية الاصطناعية للتنبؤ بالأداء المالي للشركات المصدرة للأصول المالية، بحيث تستخدم النسب المالية للشركات كمدخلات للنظام.
- د. دمج واستخدام البيانات الوصفية (مثل الأحداث السياسية، القرارات الاقتصادية المرتبطة ... إلخ)، والبيانات الكمية معاً كمدخلات للشبكة المستخدمة.
- هـ. اختبار قدرة الشبكات العصبية الاصطناعية في مجال مراجعة القوائم المالية.
- و. دمج مؤشرات التحليل المالي والتحليل الفني معاً؛ كمدخلات للشبكة في محاولة لتحسين النتائج النهائية.

قائمة المراجع

أولاً: مراجع باللغة العربية :

- أحمد، جيهان وحيد (2020)، دور تقنيات ذكاء الأعمال في تطوير العمليات المحاسبية وعلاقتها بالبيانات الضخمة، *المجلة العلمية للبحوث والدراسات التجارية*، م 34، ع 1، <https://doi.org/10.21608/sjrbs.2020.96526>
- الحناوي، محمد صالح؛ مصطفى، نهال فريد؛ العبد، جلال إبراهيم (2007)، "تقييم الأسهم والسندات: مدخل الهندسة المالية"، المكتب الجامعي الحديث.
- الشوادفي، محمد غمري؛ شهوان، تامر محمد حسن؛ فاضل، ميسرة أحمد (2019)، استخدام الشبكات العصبية الاصطناعية للتنبؤ بالتعثر المالي للشركات المصرية المساهمة الصغيرة والمتوسطة: دراسة تطبيقية، *مجلة الدراسات والبحوث التجارية*، س39، ع4، 357 - 379.
- الطنطاوي، هبة السيد إبراهيم (2023)، أثر تكنولوجيا الذكاء الاصطناعي في تحسين فعالية دور أساليب المحاسبة القضائية في مكافحة الفساد: دراسة ميدانية، *مجلة التجارة والتمويل*، ع2، 117 - 189.
- المر، نزمين علي محمد (2024)، استخدام تقنيات تعلم الآلة للتنبؤ بعوائد الأسهم وأثر ذلك علي الإفصاح عن المعلومات المستقبلية. *المجلة العلمية للدراسات والبحوث المالية والتجارية*، كلية التجارة، جامعة دمياط، 3 (2) ج 2، DOI: [10.21608/CFDJ.2024.324711](https://doi.org/10.21608/CFDJ.2024.324711). 1125 - 1177
- بسيوني، عبد الحميد (2008)، "تكنولوجيا الشبكات العصبية الاصطناعية والجيل السادس للحوسبة"، دار الكتب العلمية للنشر والتوزيع.
- حنفي، عبد الغفار (2002)، "بورصة الأوراق المالية"، دار الجامعة الجديدة للنشر.
- سعد، بهاء الدين (2005)، "دراسات في الأسواق المالية"، القاهرة: غير مبين الناشر.
- سيد، أحمد سيد طه؛ الهريطى، يحيى السيد محمد؛ منصور، أشرف محمد إبراهيم (2021)، دور الشبكات العصبية الاصطناعية في تحسين جودة التقارير المالية: دراسة تطبيقية على الشركات المقيدة في سوق الأوراق المالية المصرية، *مجلة الدراسات والبحوث التجارية*، س41، ع4، 609 - 630.
- عبد الرحمن، أحمد عبد الله خليل عبده (2022)، المحاسبة عن الأصول الرقمية كأحد المفاهيم الحديثة للتحويل الرقمي دليل تطبيقي وميداني من بيئة الأعمال المعاصرة، *المجلة العلمية للدراسات والبحوث المالية والتجارية*، م 3، ع 2، ج2، [10.21608/CFDJ.2022.229926](https://doi.org/10.21608/CFDJ.2022.229926). 447-510
- عبدالعال، طارق (2000)، "التحليل الأساسي والفني للأوراق المالية"، الدار الجامعية للنشر.
- عبيد، سعيد توفيق (1994)، نموذج مقترح لتقدير كفاءة الاستثمار الفردي واستخدام أسلوب الشبكة العصبية لتصنيف الشركات مع دراسة تطبيقية على الأسهم بالبورصة المصرية، *المجلة العلمية للاقتصاد والتجارة*، كلية التجارة، جامعة عين شمس، ملحق العدد 2.
- عثمان، حسام محمد؛ إسماعيل، طارق محمد حسنين (2022)، استخدام الشبكات العصبية متعددة الطبقات في التنبؤ بمخاطر الائتمان لمنشآت الأعمال: دراسة تطبيقية، *مجلة الدراسات المالية والتجارية*، ع1، 169 - 219. <https://doi.org/10.21608/mosj.2022.230551>

محمد، أحمد صلاح سيد؛ جادو، سماسم كامل موسى إبراهيم؛ الجوهري، رشا مصطفى عبد الحميد (2023)، أثر تطبيق نموذج الشبكات العصبية الضبابية كأحد نماذج الذكاء الاصطناعي على تحسين دقة التنبؤ بالتدفقات النقدية من الأنشطة التشغيلية: دراسة تطبيقية، *الفكر المحاسبي*، مج27، ع1، 121 - 148.

والي، محمد زيدان إبراهيم؛ نصير، مبروك محمد السيد (2022)، أثر فاعلية تكنولوجيا الذكاء الاصطناعي على الاستدلال المحاسبي بالتقارير المالية للشركات: دراسة تطبيقية، *الفكر المحاسبي*، مج26، ع1، 115 - <https://doi.org/10.21608/atasu.2022.244716>

وجدي، أسامة (2011)، دراسة تحليلية مقارنة للشموع اليابانية الانعكاسية بين السوق المصري EGX والسوق السعودي للأوراق المالية Tadawul، *المجلة العلمية للبحوث والدراسات التجارية*، ع1، 255 - 300.

ثانيًا: مراجع باللغة الأجنبية:

- Agustí, M. A., & Orta-Pérez, M. (2023). Big data and artificial intelligence in the fields of accounting and auditing: a bibliometric analysis. *Spanish Journal of Finance and Accounting/Revista Española de Financiación y Contabilidad*, 52(3), 412-438. <https://doi.org/10.1080/02102412.2022.2099675>
- Al-hidi, H., & Al-Hasan, Z. (2002). A Neural Network Approach to Forecasting Stock Prices of Saudi Companies. *The UNiv. of King saud*, 65-81.
- Al-Shayea, Q. K., El-Refae, G. A., & El-Itter, S. F. (2010). Neural networks in bank insolvency prediction. *International Journal of Computer Science and Network Security*, 10(5), 240-245.
- Ansari, A., Ahmad, I. S., Bakar, A. A., & Yaakub, M. R. (2020). A hybrid metaheuristic method in training artificial neural network for bankruptcy prediction. *IEEE access*, 8, 176640-176650. <https://doi.org/10.1109/ACCESS.2020.3026529>
- Aris, Z., & Mohamad, D. (2008). Application of artificial neural networks using Hijri Lunar transaction as extracted variables to predict stock trend direction. *Labuan e-Journal of Muamalat and Society (LJMS)*, 2, 9-16. <https://doi.org/10.51200/ljms.vi.2971>
- Bakar, N. M. A., & Tahir, I. M. (2009). Applying multiple linear regression and neural network to predict bank performance. *International Business Research*, 2(4), 176-183.
- Bao, L., & Li, S. (2016). P2P Personal Credit Risk Simulation Model Based on BP Neural Network. *Advances in Applied Mathematics*, 5(2), 192-207.
- Belhoula, M. M., Mensi, W., & Naoui, K. (2023). Impacts of investor's sentiment, uncertainty indexes, and macroeconomic factors on the dynamic efficiency of G7 stock markets. *Quality & Quantity*, 1-32. <https://doi.org/10.1007/s11135-023-01780-y>
- Chen, J. (2007). *Advanced Applications of Neural Networks Computer Systems Lab* 2006-2007.
- Chhajer, P., Shah, M., & Kshirsagar, A. (2022). The applications of artificial neural networks, support vector machines, and long-short term memory for stock market prediction. *Decision Analytics Journal*, 2, 100015. <https://doi.org/10.1016/j.dajour.2021.100015>
- Chopra, S., Yadav, D., & Chopra, A. N. (2019). Artificial neural networks based indian stock market price prediction: before and after demonetization. *J Swarm Intel Evol Comput*, 8(174), 2.

- Coupelon, O. (2007). Neural network modeling for stock movement prediction A state of the art. *Network*, (2007), 1-5.
- Das, D., Sadiq, A. S., Ahmad, N. B., & Lloret, J. (2017). Stock Market Prediction with Big Data Through Hybridization of Data Mining and Optimized Neural Network Techniques. *Journal of Multiple-Valued Logic & Soft Computing*, 29.
- Desai, V. S., & Bharati, R. (1998). The efficacy of neural networks in predicting returns on stock and bond indices. *Decision Sciences*, 29(2), 405-423. <https://doi.org/10.1111/j.1540-5915.1998.tb01582.x>
- Dhillon, A., & Verma, G. K. (2020). Convolutional neural network: a review of models, methodologies and applications to object detection. *Progress in Artificial Intelligence*, 9(2), 85-112. <https://doi.org/10.1007/s13748-019-00203-0>
- Doumpos, M., Zopounidis, C., Gounopoulos, D., Platanakis, E., and Zhang, W., (2023), Operational research and artificial intelligence methods in banking, *European Journal of Operational Research*, 306(1), 1–16. <https://doi.org/10.1016/j.ejor.2022.04.027>.
- Farahabadi, M., Eivazlou, R., & Safari, H. (2022). An Artificial Neural Network and Bayesian Network model for liquidity risk assessment in banking. *Journal of Securities Exchange*, 15(59), 121-156. <https://dx.doi.org/10.22034/jse.2021.11606.1715>
- Farahani, M., and Hajiagha, S., (2021), Forecasting stock price using integrated artificial neural network and metaheuristic algorithms compared to time series models, *Soft Computing*, 25:8483–8513 <https://doi.org/10.1007/s00500-021-05775-5>.
- Gallo, C., Letizia, C., & Stasio, G. (2005, May). *Artificial neural networks in financial modelling*. In XXXVI EWGFM International Meeting “European Working Group on Financial Mathematics”, Brescia (pp. 5-7).
- Gao, P., Zhang, R., & Yang, X. (2020). The application of stock index price prediction with neural network. *Mathematical and Computational Applications*, 25(3), 53. <https://doi.org/10.3390/mca25030053>
- Gotthardt, M., Koivulaakso, D., Paksoy, O., Saramo, C., Martikainen, M., & Lehner, O. (2020). Current state and challenges in the implementation of smart robotic process automation in accounting and auditing. *ACRN Journal of Finance and Risk Perspectives*.
- Greco, S., Ishizaka, A., Tasiou, M., and Torrisi, G., (2019), On the Methodological Framework of Composite Indices: A Review of the Issues of Weighting, Aggregation, and Robustness. *Soc Indic Res*, 141(1), 61–94. <https://doi.org/10.1007/s11205-017-1832-9>
- Hasan, A. R. (2021). Artificial Intelligence (AI) in accounting & auditing: A Literature review. *Open Journal of Business and Management*, 10(1), 440-465. <https://doi.org/10.4236/ojbm.2022.101026>
- Huang, X., Liu, X., & Ren, Y. (2018). Enterprise credit risk evaluation based on neural network algorithm. *Cognitive Systems Research*, 52, 317-324. <https://doi.org/10.1016/j.cogsys.2018.07.023>
- Idris, M. A., Saiang, D., & Nordlund, E. (2015). Stochastic assessment of pillar stability at Laisvall mine using artificial neural network. *Tunnelling and Underground Space Technology*, 49, 307-319. <https://doi.org/10.1016/j.tust.2015.05.003>.
- Januskevicius, M. (2003). Testing stock market efficiency using neural networks: case of Lithuania. *Rigas Ekonomikas augstskola*.
- Kara, Y., Boyacioglu, M. A., & Baykan, Ö. K. (2011). 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(5), 5311-5319. <https://doi.org/10.1016/j.eswa.2010.10.027>
- Khan, Z. H., Alin, T. S., & Hussain, M. A. (2011). Price prediction of share market using artificial neural network (ANN). *International Journal of Computer Applications*, 22(2), 42-47.
- Kumar, P., & Walia, E. (2006). Cash Forecasting: An Application of Artificial Neural Networks in Finance. *Int. J. Comput. Sci. Appl.*, 3(1), 61-77.
- Kurani, A., Doshi, P., Vakharia, A., & Shah, M. (2023). A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting. *Annals of Data Science*, 10(1), 183-208. <https://doi.org/10.1007/s40745-021-00344-x>
- Kwong, K. (2001). Financial forecasting using neural network or machine learning techniques. *University of Queensland*, 13, 221-228.
- Lah, M. S. C., Arbaiy, N., & Efendi, R. (2019). *Stock market forecasting model based on AR (1) with adjusted triangular fuzzy number using standard deviation approach for ASEAN countries*. In Intelligent and Interactive Computing: Proceedings of IIC 2018 (pp. 103-114). https://doi.org/10.1007/978-981-13-6031-2_22.
- Lawrence, R. (1997). Using neural networks to forecast stock market prices. *University of Manitoba*, 333(2006), 2013.
- Li, Jianlei. and Shi. (2024). wei-kang, Stock Price Prediction Based on Hybrid Preprocessing Neural Network Models. Available at SSRN: <https://ssrn.com/abstract=4711039> or <http://dx.doi.org/10.2139/ssrn.4711039>
- Lin, C. S., Khan, H. A., & Huang, C. C. (2002). Can the neuro fuzzy model predict stock indexes better than its rivals. *Discussion Papers of University of Tokyo CIRJE-F-165*.
- Lin, T. W., & Yu, C. C. (2009). Forecasting stock market with neural networks. Available at SSRN 1327544. <https://dx.doi.org/10.2139/ssrn.1327544>
- Martins, A. I. (2022). *Earnings prediction using machine learning methods and analyst comparison* (Doctoral dissertation). https://scholar.google.com/scholar?hl=ar&as_sdt=0%2C5&q=Earnings+prediction+using+machine+learning+methods+and+analyst+comparison&btnG=
- Matoussi, H., & Abdelmoula, A. (2009). Using a neural network-based methodology for credit-risk evaluation of a Tunisian bank. *Middle Eastern Finance and Economics*, 4, 117-140.
- Maydeu-Olivares, A., Fairchild, A. J., & Hall, A. G. (2017). Goodness of fit in item factor analysis: Effect of the number of response alternatives. *Structural Equation Modeling: A Multidisciplinary Journal*, 24(4), 495-505. <https://doi.org/10.1080/10705511.2017.1289816>
- Mhlanga, D. (2021). Financial inclusion in emerging economies: The application of machine learning and artificial intelligence in credit risk assessment. *International journal of financial studies*, 9(3), 39. <https://doi.org/10.3390/ijfs9030039>
- Mi, X., Liu, H., & Li, Y. (2019). Wind speed prediction model using singular spectrum analysis, empirical mode decomposition and convolutional support vector machine. *Energy conversion and management*, 180, 196-205. <https://doi.org/10.1016/j.enconman.2018.11.006>
- Nygren, K. (2004). Stock prediction—a neural network approach. *Royal Institute of Technology*, 1-34.

- Pan, H., Tilakaratne, C., & Yearwood, J. (2005). Predicting Australian stock market index using neural networks exploiting dynamical swings and intermarket influences. *Journal of research and practice in information technology*, 37(1), 43-55. <https://search.informit.org/doi/10.3316/informit.015290427438445>
- Pang, X., Zhou, Y., Wang, P., Lin, W., & Chang, V. (2020). An innovative neural network approach for stock market prediction. *The Journal of Supercomputing*, 76, 2098-2118. <https://doi.org/10.1007/s11227-017-2228-y>
- Pradhan, R. P. ESQ, A. K. (2008). Forecasting economic growth using an artificial neural network model. *Journal of Financial Management & Analysis*, 21(1), 24.
- Prasad, J. G. (2008). Financial forecasting using artificial neural networks, *work paper, UNSW Sydney*. <https://doi.org/10.26190/unsworks/18071>
- Quilty, J., & Adamowski, J. (2018). Addressing the incorrect usage of wavelet-based hydrological and water resources forecasting models for real-world applications with best practices and a new forecasting framework. *Journal of hydrology*, 563, 336-353. <https://doi.org/10.1016/j.jhydrol.2018.05.003>
- Rafiuddin, A., Gaytan, J. C. T., Ahmed, G., & Alshurideh, M. (2023). Machine Learning Techniques for Stock Market Predictions: A Case of Mexican Stocks. *In The Effect of Information Technology on Business and Marketing Intelligence Systems* (pp. 1833-1843). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-031-12382-5_100
- Ren, T., and Jiang, J., and qian, sh., and Xu, (2024), Research on Early Warning of Stock Market Crash Risk Based on the Fractal-Neural Network Model. *Available at SSRN: https://ssrn.com/abstract=4711376* or <http://dx.doi.org/10.2139/ssrn.4711376>
- Sang, B. (2021). Application of genetic algorithm and BP neural network in supply chain finance under information sharing. *Journal of Computational and Applied Mathematics*, 384, 113170. <https://doi.org/10.1016/j.cam.2020.113170>
- Sariev, E., & Germano, G. (2020). Bayesian regularized artificial neural networks for the estimation of the probability of default. *Quantitative Finance*, 20(2), 311-328. <https://doi.org/10.1080/14697688.2019.1633014>
- Sarle, W. S. (1994). Neural networks and statistical models. In Proceedings of the 19th annual SAS users group international conference (Vol. 13).
- Schoenburg, E. (1990). Stock price prediction using neural networks: A project report. *Neurocomputing*, 2(1), 17-27. [https://doi.org/10.1016/0925-2312\(90\)90013-H](https://doi.org/10.1016/0925-2312(90)90013-H)
- Senol, D., & Ozturan, M. (2009). Stock price direction prediction using artificial neural network approach: The case of Turkey. *Journal of Artificial Intelligence*. 1 (2), 70-77.
- Shachmurove, Y., & Witkowska, D. (2000). *Utilizing artificial neural network model to predict stock markets*. University of Pennsylvania, Center for Analytic Research in Economics and the Social Sciences.
- Shamsaliniya, S., Safa, M., Chavoshi, S. K., & Jahangirnia, H. (2024). Prediction of Stock Price Resilience, using Artificial Neural Networks (MLP) in companies listed on the Stock Exchange. *International Journal of Finance & Managerial Accounting*, 9(34), 95-117. <https://doi.org/10.30495/ijfma.2022.67454.1852>
- Shin, Y., (2017), *Time series analysis in the social sciences: the fundamentals*. Univ of California Press.
- Solaimani, R., Mohammed, S., Rashed, F., & Elkelish, W. (2020). The impact of artificial intelligence on corporate control. *Corporate Ownership & Control*, 17(3), 171-178. <http://doi.org/10.22495/cocv17i3art13>

- Soori, M., Arezoo, B., & Dastres, R. (2023). Artificial neural networks in supply chain management, a review. *Journal of Economy and Technology*, 1, 179-196. <https://doi.org/10.1016/j.ject.2023.11.002>.
- Sun, X., & Lei, Y. (2021). Research on financial early warning of mining listed companies based on BP neural network model. *Resources Policy*, 73, 102223. <https://doi.org/10.1016/j.resourpol.2021.102223>
- Tang, Y., Ji, J., Zhu, Y., Gao, S., Tang, Z., & Todo, Y. (2019). A differential evolution-oriented pruning neural network model for bankruptcy prediction. *Complexity*. <https://doi.org/10.1155/2019/8682124>.
- Tavana, M., Abtahi, A. R., Di Caprio, D., & Poortarigh, M. (2018). An Artificial Neural Network and Bayesian Network model for liquidity risk assessment in banking. *Neurocomputing*, 275, 2525-2554. <https://doi.org/10.1016/j.neucom.2017.11.034>
- Teixeira Zavadzki de Pauli, S., Kleina, M., & Bonat, W. H. (2020). Comparing artificial neural network architectures for Brazilian stock market prediction. *Annals of Data Science*, 7, 613-628. <https://doi.org/10.1007/s40745-020-00305-w>.
- Trippi, R. R., & Turban, E. (Eds.). (1992). *Neural networks in finance and investing: Using artificial intelligence to improve real world performance*. McGraw-Hill, Inc..
- Vanstone, B., & Finnie, G. (2007, November). Enhancing existing stock market trading strategies using artificial neural networks: A case study. *In International Conference on Neural Information Processing* (pp. 478-487). Berlin, Heidelberg: Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-69162-4_50
- Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock closing price prediction using machine learning techniques. *Procedia computer science*, 167, 599-606. <https://doi.org/10.1016/j.procs.2020.03.326>
- Wagdi, O., Kinawy, R. N., & Nabil, G. (2023B). Machine Learning for Predicting Deposits Bank Market Shares in Emerging Markets: Evidence from Egypt. *Journal of Management & Technology*, 23(4), 473-492. <https://doi.org/10.20397/2177-6652/2023.v23i4.2729>
- Wagdi, O., Salman, E., & Albanna, H. (2023 A). Integration between technical indicators and artificial neural networks for the prediction of the exchange rate: Evidence from emerging economies. *Cogent Economics & Finance*, 11(2), 2255049. <https://doi.org/10.1080/23322039.2023.2255049>
- Wang, L., & Lee, R. S. (2023). Stock Index Return Volatility Forecast via Excitatory and Inhibitory Neuronal Synapse Unit with Modified MF-ADCCA. *Fractal and Fractional*, 7(4), 292. <https://doi.org/10.3390/fractalfract7040292>
- Weckman, G. R., Lakshminarayanan, S., Marvel, J. H., & Snow, A. (2008). An integrated stock market forecasting model using neural networks. *International Journal of Business Forecasting and Marketing Intelligence*, 1(1), 30-49. <https://doi.org/10.1504/IJBFMI.2008.020813>
- Wilson, H. J., & Daugherty, P. R. (2018). Collaborative intelligence: Humans and AI are joining forces. *Harvard Business Review*, 96(4), 114-123.
- Xu, A., Chang, H., Xu, Y., Li, R., Li, X., & Zhao, Y. (2021). Applying artificial neural networks (ANNs) to solve solid waste-related issues: A critical review. *Waste Management*, 124, 385-402. <https://doi.org/10.1016/j.wasman.2021.02.029>.
- Yoon, Y., & Swales, G. (1991, January). Predicting stock price performance: A neural network approach. *In Proceedings of the twenty-fourth annual Hawaii international conference on system sciences* (Vol. 4, pp. 156-162). IEEE. <https://doi.org/10.1109/HICSS.1991.184055>

- Yu, P., & Yan, X. (2020). Stock price prediction based on deep neural networks. *Neural Computing and Applications*, 32, 1609-1628. <https://doi.org/10.1007/s00521-019-04212-x>
- Zebende, G. F., Dias, R. S., & de Aguiar, L. C. (2022). Stock market efficiency: An intraday case of study about the G-20 group. *Heliyon*, 8(1). <https://doi.org/10.1016/j.heliyon.2022.e08808>
- Zhang, D. (2005). Application of neural networks in financial data mining. *Int. J. Computational Intelligence*, 1(2), 106-109.
- Zhang, D., & Lou, S. (2021). The application research of neural network and BP algorithm in stock price pattern classification and prediction. *Future Generation Computer Systems*, 115, 872-879. <https://doi.org/10.1016/j.future.2020.10.009>
- Zhou, H., Sun, G., Fu, S., Liu, J., Zhou, X., & Zhou, J. (2019). A big data mining approach of PSO-based BP neural network for financial risk management with IoT. *IEEE Access*, 7, 154035-154043. <https://doi.org/10.1109/ACCESS.2019.2948949>