

التنبؤ بأسعار الإغلاق للأسهم باستخدام الشبكات العصبية لعينة من المصارف الإسلامية العراقية

سالم صلال الحسناوي

أستاذ في كلية الإدارة والاقتصاد بجامعة القادسية - العراق

salimsalim125@yahoo.com

و

ليث حليم مالك الحجيبي

ماجستير مالية ومصرفية في كلية الإدارة والاقتصاد بجامعة القادسية - العراق

laithhaleem95@gmail.com

(سَلِّم البحث للنشر في 5 / 12 / 2021م، واعتمد للنشر في 9 / 2 / 2022م)

<https://doi.org/10.33001/M0110202218/101>



الملخص

يهدف البحث إلى بناء نماذج للتنبؤ بأسعار الإغلاق لعينة من المصارف الإسلامية المدرجة في سوق العراق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية، حيث كانت عينة البحث مؤلفة من (3) مصارف مدرجة في القطاع المصرفي لسوق العراق للأوراق المالية، فيما كانت البيانات هي المؤشرات الشهرية المعلنة بواسطة

السوق للفترة من (كانون الثاني/ 2018) إلى (كانون الأول/ 2019)، وقد تم تنفيذ الشبكات العصبية وبناء النماذج باستخدام برنامج Matlab 2014b بواقع (3) نماذج تم قياسها بواسطة مقاييس متوسطات الأخطاء ومعامل التحديد، حيث أظهر البحث دقة الشبكة العصبية (MLP) وكفاءتها في التنبؤ بأسعار الإغلاق للعينات المدروسة وبنسبة وصلت إلى 99% مما أثبت صحة فرضية البحث.

الكلمات المفتاحية: الشبكات العصبية، التنبؤ، أسعار الأسهم، أسعار الإغلاق، المصارف الإسلامية.

Forecasting the Closing Price of Shares by Deploying Neural Networks on a Sample of Iraqi Islamic Banks

Salim Salal Al-Hasnawi

Professor at College of Economics and Management, University of Al-Qadisiyah, Iraq

Laith haleem Malik

,Masters' in Finance and Banking, College of Economics and Management

University of Al-Qadisiyah, Iraq

Abstract

The Research Aims to build models to forecast closing prices to sample of Islamic banks listed on the Iraq Stock Exchange using Artificial neural network, The sample of the research is consisted of (3) banks listed in banking sector, while the dataset was the monthly indexes released by the ISX for the period from (January/2018) to (December/2019), The ANN had been executed and models building by Matlab 2014b software, The models are (3) that are measured by Means Errors Measures as well as R2, The research showed the ability and efficiency of Artificial neural network (MLP) to forecast closing prices for the research sample by 99% accuracy, thus validated the research hypothesis.

Keywords: ANN, Islamic Banks, Stocks, Closing price, Forecasting, Prediction.

المقدمة

تعتبر الصيرفة الإسلامية حديثة النشأة في العراق، حيث أنشئ أول مصرف إسلامي في أواخر عام 1992 تحت مسمى «المصرف العراقي الإسلامي للاستثمار»، ثم توالى بعد ذلك إنشاء المصارف الإسلامية لاسيما بعد العام 2003 نتيجة للتغيرات السياسية والاقتصادية، حيث يوجد اليوم (29) مصرف إسلامي في الجهاز المصرفي العراقي بضمنها (5) مصارف مدرجة في سوق العراق للأوراق المالية، وقد عزز قانون «المصارف الإسلامية» العراقي الصادر في 2015 من عمل المصارف الإسلامية من خلال منح الثقة الحكومية والضمانة القانونية.

إن الأسواق المالية اليوم تمثل العصب الذي يحرك الاقتصاد في أي بلد لما توفره من أطرٍ ووسائل تجمع عارضي القيم المنقولة بطالبيها، وتوجيه الأموال نحو الاستثمار المنتج، وقد أسهمت المصارف الإسلامية في تنشيط سوق العراق للأوراق المالية من خلال حشدها للمدخرات واستثمارها في قنوات عديدة، أهمها المشاركة في المشاريع المختلفة من خلال مجموعة من الأدوات المالية، والتي من أهمها الأسهم التي تعبر عن حقوق حاملها برأس مال المشروع أو الشركة، وتعتبر الأسهم الركيزة الأساسية في الأسواق المالية ومحور اهتمام المحللين، والباحثين، والمستثمرين، لما تتعرض له من تقلبات سريعة في أسعارها، ولذلك يهتم العديد من الأطراف المتداخلة في الأسواق المالية، ومنها المصارف الإسلامية، بأسعار الأسهم المستقبلية من أجل ترشيد القرارات الاستثمارية بشأن شراء الأسهم التي يتوقع أن يرتفع سعرها أو التخلص من الأسهم التي يتوقع أن ينخفض سعرها، لاسيما وأن المصارف الإسلامية بخلاف نظيرتها التقليدية، تعتمد بشكل كبير على الأنشطة الاستثمارية، لهذا أصبحت عمليات التنبؤ بأسعار الأسهم تلقى اهتماماً واسعاً من قبل المؤسسات المالية والمراكز البحثية، حتى ظهرت مؤخراً العديد من المؤسسات المعنية بالتنبؤ المالي وتطوير الأساليب المستخدمة في ذلك.

لقد تباينت طرق التنبؤ بأسعار الأسهم، وتراوحت بين الأساليب التقليدية التي تعتمد على التقديرات الشخصية، والأساليب المعقدة التي تعتمد على التكنولوجيا المالية والوسائل البحثية المختلفة، وبالنظر لما تشهده البيئة المالية من تغيرات زبئية وتطورات كبيرة، أضحت الأساليب التقليدية عاجزة عن رسم المسارات الدقيقة لتحركات الأسهم، مما حدى بالباحثين إلى البحث عن أساليب جديدة يمكنها التغلب على مشاكل عدم الدقة وتقنين الأخطاء الناتجة عن التنبؤ بأسعار الأسهم، ولعل أبرز هذه الأساليب ما يعرف بالشبكات العصبية، التي تعتمد أساليب الدماغ البشري في التدريب والتعلم لنمذجة البيانات التاريخية في محاولة للتنبؤ بالقيم المستقبلية.

أهمية البحث:

تعتبر عملية اتخاذ القرارات الاستثمارية من العمليات الحاسمة لما تنطوي عليها من مخاطر تتعلق بمستقبل مجهول، لذلك تكتسي عمليات التنبؤ بأسعار الإغلاق للأسهم أهمية بالغة في ترشيد القرار الاستثماري وتخفيض المخاطر المتوقعة من خلال تقدير سعر الإغلاق المستقبلي للسهم، ومن هنا يقدم البحث إطاراً نظرياً ودراسة تطبيقية لاستخدام الشبكات العصبية في مجال التنبؤ بالأسواق المالية.

مشكلة البحث:

تتمحور مشكلة البحث حول دقة الشبكات العصبية في التنبؤ بأسعار الإغلاق لعينة من المصارف الإسلامية بناءً على بعض المؤشرات الشهرية بغرض اعتمادها في ترشيد القرار الاستثماري، ويمكن تلخيص مشكلة البحث في الأسئلة التالية:

1. ما مدى دقة نموذج الشبكة العصبية متعددة الطبقات في تقدير أسعار

الإغلاق للعينة المدروسة؟

2. ما مدى دقة نموذج الشبكة متعددة الطبقات في التنبؤ بأسعار الإغلاق

للأشهر الثلاثة اللاحقة؟

3. هل يمكن الاعتماد على النتائج المتنبأ بها في اتخاذ القرارات الاستثمارية بشراء الأسهم أو بيعها؟

فرضيات البحث:

بناء على ما تم طرحه في مشكلة البحث، يفترض البحث الفرضيات التالية:

1. دقة نموذج الشبكة العصبية متعددة الطبقات في تقدير أسعار الإغلاق للأسهم عينة البحث.
2. دقة نموذج الشبكة العصبية متعددة الطبقات في التنبؤ بأسعار الإغلاق للأشهر الثلاثة اللاحقة.
3. إمكانية الاعتماد على النتائج المتنبأ بها في اتخاذ القرارات الاستثمارية بشراء الأسهم أو بيعها.

أهداف البحث:

يمكن تلخيص أهداف البحث في عدد من النقاط، وكما في أدناه:

1. الاستفادة من تقنيات الذكاء الاصطناعي (AI) في بناء نماذج تنبؤية فعالة.
2. التركيز على الأساليب التكنولوجية الحديثة كبديل للأساليب التقليدية في التنبؤ، والتي من شأنها تقليل الأخطاء وتوفير نتائج دقيقة.
3. المساعدة في ترشيد القرار الاستثماري من خلال تقديم نتائج يمكن الاعتماد عليها.
4. إثراء المحتوى العلمي والإسهام في تطوير الأساليب البحثية في مجال التنبؤ بالأسواق المالية.

حدود البحث:

أ. الحدود الزمانية: تمتد فترة البحث من 2018/1/1 إلى 2019/12/31 وبمعدل شهري.

ب. الحدود المكانية: تتمثل بالمصارف الإسلامية المدرجة في سوق العراق للأوراق المالية.

مجتمع وعينة البحث:

يتمثل مجتمع البحث بالقطاع المصرفي المدرج في سوق العراق للأوراق المالية أما عينة البحث فتمثل (3) مصارف إسلامية مدرجة، وهي كل من (المصرف العراقي الإسلامي، مصرف إيلاف الإسلامي، المصرف الوطني الإسلامي).

منهجية البحث:

يعتمد البحث على المنهج الوصفي التحليلي، حيث تم وصف متغيرات البحث المتمثلة بأسعار الافتاح، أعلى سعر، أدنى سعر، معدل السعر الحالي، نسبة التغير، عدد الصفقات، عدد أيام التداول كمتغيرات مستقلة للتعقب بالمتغير التابع المتمثل بسعر الاغلاق، وتم اختيار (3) مصارف الأكثر تداولاً في سوق العراق للأوراق المالية لاكتمال بياناتها وهي كل من (المصرف العراقي الإسلامي، مصرف إيلاف الإسلامي، المصرف الوطني الإسلامي)، ثم جرى تطبيق الشبكات العصبية الاصطناعية لكل مصرف على حدة، ويمكن تفصيل خطوات التحليل فيما يلي:

(1) اختيار عينة الدراسة وفقاً لمعيار توفر البيانات واكتمالها على أساس المصارف الأكثر تداولاً في مجتمع المصارف الإسلامية المدرجة في سوق العراق للأوراق المالية.

(2) تم تقسيم بيانات الدراسة على ثلاث مجموعات لأغراض بناء الشبكة العصبية هي (70% التدريب، 15% الاختبار، 15% التحقق)، حيث كانت عينة التدريب

تمتد من (2018/1/1) إلى (2019/5/24)، فيما كانت عينة الاختبار من (2019/5/25) إلى (2019/9/11)، وكانت عينة التحقق من (2019/9/12) إلى (2019/12/31)، ثم أجريت عدة محاولات لتدريب نموذج الشبكة العصبية وقياس دقته من خلال مجموعتي الاختبار والتحقق بواسطة برنامج (Matlab).

(3) تم قياس نتائج الشبكة العصبية المقدرّة بواسطة مقياس الخطأ (MAD، RMSE، MSE، MAPE) فضلاً عن مقياس التحديد (R^2) للتأكد من دقة النموذج بواسطة برنامج (Excel).

(4) أجريت عملية التنبؤ بأسعار الإغلاق للأشهر الثلاثة اللاحقة بواسطة معادلة الانحدار التي تم التوصل إليها بواسطة نموذج الشبكة العصبية.

(5) تم تقييم النتائج التنبؤية للأشهر الثلاثة اللاحقة من خلال مقارنتها بالنتائج الفعلية.

الدراسات السابقة

بحثت العديد من الدراسات السابقة في التنبؤ بمؤشرات الأسواق المالية باستخدام الأساليب الإحصائية، حيث لم يجد الباحث دراسة سابقة تطرقت للتنبؤ بأسعار الإغلاق لاسيما فيما يتعلق بالمؤسسات المالية الإسلامية العراقية، أما الدراسات التي تتعلق بموضوع التنبؤ بالأسواق المالية فهي عديدة، ومنها:

1 - دراسة منذر مرهج (2013)، الموسومة (التنبؤ بقيمة مؤشر سوق دمشق للأوراق المالية باستخدام الشبكات العصبية الاصطناعية واتجاهاتها) هدفت الدراسة إلى التنبؤ بمؤشر سوق دمشق للأوراق المالية واتجاهه لليوم التالي بواسطة نموذج الشبكات العصبية للفترة من (2010/1/4) إلى (2013/3/7)، وقد تم استخدام خوارزمية التكاثر الارتدادي في تدريب الشبكة العصبية، وعلى الرغم من أن النتائج قد أظهرت قدرة الشبكة العصبية على التنبؤ بالبيانات المدخلة وبقيمة خطأ ضئيلة، إلا أن الباحث لم يبين كيفية التنبؤ بقيمة المؤشر أو

اتجاهه لليوم التالي.

2 - دراسة مروان جمعة درويش (2018)، الموسومة ((فعالية التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الشبكات العصبية الاصطناعية: مقارنة بنموذج الانحدار الذاتي))

هدفت الدراسة إلى التنبؤ بمؤشر بورصة فلسطين باستخدام نموذج الانحدار الذاتي والشبكات العصبية الاصطناعية للفترة من (2010/3/1) إلى (2018/2/28) على أساس يومي، وقد أظهرت الدراسة أن نموذج الشبكات العصبية أكثر دقة من نموذج الانحدار الذاتي حيث أعطى معدل خطأ أقل، وبين الباحث أن الشبكات العصبية أسرع في التنبؤ وأسهل استخداماً من نموذج الانحدار الذاتي، إلا أن ما يؤخذ على الباحث عدم توضيحه لكيفية التنبؤ بمؤشر البورصة لليوم التالي حيث أكتفى بتقدير النتائج الفعلية للعينة.

3 - دراسة علي عبد الحافظ إبراهيم، سارة عبد الكريم مرهج (2019)، الموسومة ((التنبؤ بمؤشر مصرف بغداد باستخدام منهجية بوكس جينكنز))

هدفت الدراسة إلى التنبؤ بالمؤشر الشهري لمصرف بغداد باستخدام منهجية البوكس جينكنز للفترة من بداية عام 2010 إلى نهاية عام 2016، وقد كانت السلسلة غير مستقرة مما حدى بالباحث إلى أخذ الفروق واللوغاريتم للحصول على سلسلة مستقرة، وقد جرى تقييم عدة نماذج حتى تم الحصول على النموذج المناسب حيث أظهرت النتائج دقته في التنبؤ، إلا أن ما يؤخذ على الأسلوب المستخدم (منهجية بوكس جينكنز) أنها تتطلب أن تكون السلسلة مستقرة إضافة إلى تعدد الخطوات والفروض الإحصائية للحصول على النموذج المطلوب وهذا ما يجعل من الصعب استخدامها في جميع السلاسل الزمنية ولاسيما السلاسل الكبيرة.

تعد هذه الدراسة استكمالاً للجهود والدراسات السابقة في مجال التنبؤ بالأسواق المالية، وعلى الرغم من اختلاف الأهداف للدراسات السابقة أعلاه عن موضوع

البحث، إلا أنها تتشابه معها بالأسلوب، حيث يهدف البحث إلى التنبؤ بسعر الإغلاق، ويضيف البحث إمكانية التنبؤ بأسعار الإغلاق للأشهر الثلاثة اللاحقة للعيينة المدروسة.

هيكلية البحث

بناء على ما تقدم، يقدم البحث دراسة تطبيقية للتنبؤ بأسعار الإغلاق لعيينة من المصارف الإسلامية المدرجة في سوق العراق للأوراق المالية، ومن أجل تحقيق ذلك، قسم البحث إلى ثلاثة مباحث، حيث تناول المبحث الأول الجانب النظري للأسهم والصيرفة الإسلامية في العراق، فيما تناول المبحث الثاني الإطار النظري للتنبؤ والشبكات العصبية الاصطناعية، أما المبحث الثالث فتناول الدراسة التطبيقية للبحث من خلال بناء نموذج تنبؤي باستخدام الشبكات العصبية، وانتهى البحث بالخاتمة التي اشتملت على الاستنتاجات والتوصيات.

المبحث الأول: الأسواق المالية والمصارف الإسلامية

أولاً: الأسهم

يعرف السهم بأنه مستند ملكية لحامله أو مالكة في شركة الأموال، مما يمنحه العديد من الحقوق مثل التصويت في الجمعية العمومية، وانتخاب مجلس الإدارة، كذلك لملك السهم الحق في الحصول على مقسومات الأرباح، وتنقسم الأسهم إلى عدة أنواع تبعاً لخصائصها وما ينص عليه عقد الاكتتاب، ومن هذه الأنواع⁽¹⁾:

1 - الأسهم العادية

وهي الأساس في تكوين الشركات والمؤسسات الخاصة ومحور اهتمام الفاعلين

(1) الحسنوي، سالم صلال، الاستثمار والتمويل في الأسواق المالية، العراق، مؤسسة دار الصادق الثقافية، 2017، ص 33.

المالين، حيث يعبر السهم العادي عن حصة مالكة في رأس مال الشركة مصدره السهم، ويتميز عن الأنواع الأخرى من الأسهم بأنه الأكثر عرضة للمخاطر، حيث أن الاكتتاب في الأسهم العادية لا يضمن استرداد الأموال للمستثمر، ولهذا السبب يحصل حامل السهم العادي على أعلى العوائد مقارنة بالأنواع الأخرى.

تحتوي الأسهم على ثلاث قيم في الواقع هي⁽²⁾:

(أ) القيمة الأسمية: وهي المدونة في قسيمة السهم، حيث تمثل قيمة الاكتتاب في السهم، وفي العادة ينص عليها في عقد التأسيس.

(ب) القيمة الدفترية: وهي قيمة محاسبية تمثل حقوق الملكية، كالاحتياجات والأرباح المحتجزة مقسومة على عدد الأسهم العادية التي تم إصدارها

(ج) القيمة السوقية: وتتمثل بقيمة السهم في السوق، أي بعبارة أخرى القيمة التي يباع ويشترى بها السهم في السوق، حيث تختلف في الغالب عن القيمة الأسمية فتكون أقل أو أكثر منها تبعاً لحركة التداول والعرض والطلب.

2 - الأسهم الممتازة:

تعتبر الأسهم الممتازة أوراقاً مالية هجينة بسبب خصائصها التي تجمع بين الأسهم العادية والسندات، وإن أهم ما يميز الأسهم الممتازة عن الأسهم العادية هي الأولوية في الحصول على مقسوم الأرباح قبل الأسهم العادية كما أن لمالك السهم الحق في الاحتفاظ بحقوقه في الحصول على الأرباح المحققة في السنوات السابقة ما لم ينص عقد الاكتتاب خلاف ذلك⁽³⁾.

ثانياً: المصارف الإسلامية

1 - الصيرفة الإسلامية في العراق

(2) هندي، منير إبراهيم، الأوراق المالية وأسواق المال، مصر، منشأة المعارف، 2006، ص 7.
(3) المرجع نفسه، ص 26-27.

تعتبر الصيرفة الإسلامية في العراق حديثة النشأة ويعود ذلك لجملة من الأسباب السياسية والأمنية التي أثرت سلباً على الواقع الاقتصادي عموماً والمصرفي خصوصاً، حيث بدأت التجربة العراقية في أواخر عام 1992 بتأسيس المصرف الإسلامي العراقي للاستثمار بموجب شهادة التأسيس الصادرة، وقد أجاز البنك المركزي العراقي التعامل بالصيرفة الإسلامية في بدايات عام 1993 سعياً منه لخلق آفاق التعاون بين المصارف المحلية⁽⁴⁾، هكذا وقد توالى بعد ذلك إنشاء المصارف الإسلامية في العراق لاسيما بعد عام 2003 حيث أسهم الانفتاح الاقتصادي في ظهور العديد من المصارف الإسلامية حتى أصبح العدد اليوم (29) مصرفاً يعمل في الجهاز المصرفي العراقي بضمنها (5) مصارف مدرجة في سوق العراق للأوراق المالية بواقع مصرف حكومي واحد و (28) مصرف إسلامي خاص⁽⁵⁾.

2 - نبذة عن المصارف عينة البحث

يتضمن سوق العراق للأوراق المالية (5) مصارف مدرجة، حيث تم اختيار (3) منها لاكتمال بياناتها وعلى أساس أكثر المصارف تداولاً، وفيما يلي نبذة عن المصارف المختارة⁽⁶⁾.

أ) المصرف العراقي الإسلامي

يُعد المصرف العراقي الإسلامي أول مصرف إسلامي عراقي حيث تم تأسيسه في تاريخ 1992/12/29 برأس مال قدره (126) مليون دينار عراقي، وقد تم ادراجه في سوق العراق للأوراق المالية عام 2004، قبل أن يتم زيادة رأس المال إلى (250) مليار دينار عام 2014، وتبلغ قيمة موجوداته (806) مليار دينار بحسب آخر تقرير صادر عن المصرف في سنة 2020، ويعمل المصرف بتقديم خدمات الصيرفة الإسلامية وتطوير المعاملات المصرفية.

(4) البيروتي، سعاد عبد الفتاح، دور المصارف الإسلامية في التنمية والاستثمار، مجلة كلية بغداد للعلوم الاقتصادية، العدد 24، 2010، ص 15.

(5) البنك المركزي العراقي، 113/page/cbi.iq

(6) هيئة الأوراق المالية، <https://www.isc.gov.iq/index.php?do=list&type=allcompany>

ب) مصرف إيلاف الإسلامي

تم تأسيس هذا المصرف باسم (مصرف البركة للاستثمار والتمويل) في تاريخ 2001/5/30 برأس مال قدره (2) مليار دينار، بعد ذلك تم تغيير اسمه في عام 2007 إلى (شركة مصرف إيلاف للمساهمة) قبل أن يتم إدراجه في سوق العراق للأوراق المالية في عام 2011، ليقوم بعد ذلك بزيادة رأسماله إلى (250) مليار دينار خلال عام 2015، فيما بلغ إجمالي موجودات المصرف أكثر من (305) مليار دينار حسب آخر تقرير صادر عن المصرف في 2020.

ج) المصرف الوطني الإسلامي

أسس المصرف الوطني الإسلامي في عام في 2005/5/5 كشركة مساهمة خاصة برأس مال قدره (25) مليار دينار، ليقوم بعد ذلك بزيادة رأسماله في 2013 إلى (251) مليار دينار، قبل أن يتم إدراجه في سوق العراق للأوراق المالية عام 2015، فيما بلغت قيمة موجوداته (491) مليار دينار عام 2020.

المبحث الثاني: التنبؤ والشبكات العصبية الاصطناعية

أولاً: التنبؤ

1 - مفهوم التنبؤ

يشير مفهوم التنبؤ بشكل عام إلى محاولة استشراف المستقبل وتوقع الأحداث في المستقبل، في محاولة للتهيؤ لتلك الأحداث أو التخطيط لها، وتتعدد مجالات التنبؤ واستخداماته، فهناك التنبؤ بالطقس، والتنبؤ بالمبيعات، والتنبؤ الاقتصادي، وقد عرفه البعض بأنه «عملية تخطيط ووضع الافتراضات حول أحداث مستقبلية باستخدام تقنيات خاصة عبر فترات زمنية مختلفة»⁽⁷⁾، وعلى هذا الأساس فإن

(7) أيوب، ناديا، نظرية القرارات الإدارية، سوريا، منشورات جامعة دمشق، 1989، ص 177.

التنبؤ بالأسواق المالية (وتحديد أسعار الأسهم موضوع البحث) لا يخرج عن هذا الإطار، فهو محاولة من قبل المتنبئين الماليين، وإدارات الشركات إلى تقدير القيم المستقبلية للأسهم وفقاً للأساليب المتبعة لاتخاذ القرار بشأنها.

2 - أساليب التنبؤ في الأسواق المالية

في الواقع هنالك العديد من الأساليب المستخدمة في التنبؤ حتى أصبح من الصعب الإحاطة بها جميعاً وتصنيفها، إلا أن الباحثين الماليين قد وضعوا خطوطاً عريضة لتصنيفها ومنها⁽⁸⁾:

أ) الأساليب النوعية

يعتمد التنبؤ في هذا الأسلوب على الموضوعية والتقدير الشخصي، والخبرة المتراكمة، أي لا تستخدم الوسائل الإحصائية أو التكنولوجية، ومن أشهر الطرق التي تندرج تحت هذا الأسلوب ما يعرف ببحوث السوق وطريقة دلفي، يعاب على هذا الأسلوب عدم دقته والتحيز من قبل المتنبئين.

ب) الأساليب الكمية

على العكس مما سبق، فإن المدخل الكمي يشير إلى استخدام الوسائل الإحصائية والرياضية في تحليل المشكلة والتنبؤ بها، حيث يتم تحديد المتغيرات التي تؤثر في المشكلة ثم يصار إلى قياسها بطرق متعددة ومحاولة وضع نموذج تنبؤي يتوقع القيم المستقبلية للظاهرة أو المشكلة المدروسة.

ج) أساليب المحاكاة

ظهرت هذه الأساليب حديثاً كأحد نتائج التطورات التكنولوجية والذكاء الاصطناعي، حيث تجمع هذه الأساليب بين خصائص الأساليب النوعية

(8) سهيلة، عتروس، استخدام منهجية بوكس جنكيز والشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية بمؤسسة سونلغاز دراسة حالة ولاية بسكرة، أطروحة دكتوراه، الجزائر، جامعة محمد خيضر بسكرة، 2018، ص 97-99.

والأساليب الكمية في محاولة لمحاكاة الظاهرة المدروسة والتوقع بقيمتها المستقبلية اعتماداً على خوارزميات وأجهزة إلكترونية مخصصة لذلك، ونجد من بين هذه الأساليب الشبكات العصبية الاصطناعية⁽⁹⁾، وهي محور بحثنا الحالي.

3 - خطأ التنبؤ

مهما بلغت دقة أسلوب التنبؤ المتبع فلا يخلو من الأخطاء والانحرافات، لأنه ببساطة يتعامل مع عوامل ومتغيرات عديدة ومستقبل مجهول، وهنالك العديد من المقاييس الإحصائية المستخدمة في تقييم دقة النماذج التنبؤية، حيث تجدر الإشارة هنا، أن هذه المقاييس لا تقتصر على أسلوب معين، إنما تتعامل مع النتائج المتولدة عن النموذج المستخدم لمقارنتها بالقيم الحقيقية، ومن هذه المقاييس⁽¹⁰⁾.

(أ) متوسط مربع الأخطاء MSE

$$MSE = \frac{\sum_{i=1}^N e^2}{N}$$

(ب) جذر متوسط مربع الأخطاء RMSE

$$RMSE = \sqrt{\frac{\sum_{i=1}^N e^2}{N}}$$

(ج) المتوسط المطلق للأخطاء MAE

$$MAE = \frac{\sum_{i=1}^N |E|}{N}$$

(د) المتوسط المطلق لنسب الأخطاء MAPE

$$MAPE = \frac{\sum_{i=1}^N \left| \frac{E}{Y_i} \right|}{N}$$

(9) المرجع نفسه، ص 100.

(10) عاشور، مروان عبد الحميد، الشبكات العصبية الاصطناعية وطرائق التنبؤ بالسلاسل الزمنية، العراق، دار الذاكرة للطباعة والنشر، ط 1، 2018، ص 150.

هـ) مقياس التحديد R2

$$R^2 = \frac{\sum (y(i) - \mu(y))^2}{\sum (\bar{y}(i) - \mu(\bar{y}))^2}$$

ثانياً: الشبكات العصبية الاصطناعية

1 - مفهوم الشبكات العصبية الاصطناعية

إن الشبكات العصبية الاصطناعية هي إحدى تقنيات الذكاء الاصطناعي، وتتخلص فكرتها في محاولة لمحاكاة الخلايا البيولوجية للدماغ البشري والاستفادة من آلية عملها في مجالات واسعة، حيث تستخدم الشبكات العصبية اليوم في مجالات المعالجة والتصنيف والتحليل والتنبؤ، وإذا ما ركزنا على الأخير، نجد أن الدراسات الحديثة قد ركزت على استخدام الشبكات العصبية للتنبؤ بمختلف الأغراض، حيث استخدمت في بحوث العمليات، والطقس والاقتصاد، وفي مجال التنبؤ المالي وغيرها، إن ما يميز الشبكات العصبية في مجال التنبؤ هو مرونتها وقدرتها على معالجة البيانات اللاخطية، وهذا ما عجزت عنه الأساليب التقليدية، وميزة الشبكات العصبية هذه، متأتية من آليتها في التعلم والتدريب المستوحاة من الدماغ البشري، حيث تقوم الشبكة العصبية باستقبال المدخلات والتدرب عليها بتغيير المشابك الرابطة بين طبقاتها (synapses) لإعطاء أهمية للبيانات التي تمثل العينة بصورة صحيحة حتى الوصول إلى نموذج يقترب من القيم الحقيقية⁽¹¹⁾.

تعددت تعاريف الشبكات العصبية بالنظر لاستخداماتها الواسعة في العديد من المجالات، فقد عرفت:

بأنها «أنظمة لمعالجة المعلومات بأسلوب يحاكي الشبكات العصبية البيولوجية، حيث تربط بين المتغيرات بأسلوب يختلف عن الطرق التقليدية، فتقوم باستخدام

(11) المرجع نفسه، ص 19.

طرق التعلم وتعديل الروابط (الأوزان) لخلق التجانس الأفضل بين المدخلات والمخرجات»⁽¹²⁾، كما عرفها Nilsson بأنها «أنظمة حسابية تتكون من وحدات معالجة مترابطة فيما بينها، تتصف بالديناميكية في معالجة البيانات المدخلة إليها»، وعرفت بأنها أنظمة لمعالجة البيانات مستوحاة في الأصل من نظام التعميم العددي للإنسان، تتألف من نماذج بسيطة تشبه المعالج الموزع المتوازي⁽¹³⁾.

وبناءً على ذلك، يمكن تعريف الشبكات العصبية بأنها نظام مترابط لمعالجة البيانات، حيث تتكون من عدد من الخلايا تسمى «Neurons» ترتبط فيما بينها بواسطة روابط مشبكية تدعى الأوزان «weights»، وآلية عملها تتلخص في استقبال البيانات بواسطة طبقة المدخلات قبل ضربها بقيم الأوزان، ثم يتم تجميع الإشارات الداخلة بإشارة واحدة لتمريرها لوحدات المعالجة التي بدورها ترسلها إلى طبقة الإخراج للحصول على المخرجات.

2 - مكونات الشبكات العصبية الاصطناعية

تتكون الشبكة العصبية من أربعة أقسام رئيسة مترابطة فيما بينها، وهي كما يلي:

أ) طبقة الإدخال Input: وهي الطبقة الأولى في نظام الشبكة العصبية، وظيفتها استلام الإشارة الداخلة (البيانات)، حيث تقوم بضربها بالأوزان الرابطة، وهذه الأخيرة تكون عبارة عن أعداد كسرية تتراوح بين (0 و1)، حيث كلما ضرب المدخل بوزن قريب من 1 دل ذلك على أهميته، بعد ذلك تقوم بإرسال البيانات الداخلة إلى دالة الجمع.

ب) دالة الجمع Sum Function: وظيفتها هذه الدالة هو تجميع الإشارات الداخلة من طبقة المدخلات بإشارة واحدة لغرض إرسالها إلى دالة التنشيط.


ج) دالة التنشيط Activation Function: تختلف وظيفة دالة التنشيط من خلية

(12) بنظر: حادة مدوري، محمد مكيدش، دراسة مقارنة بين نماذج الذاكرة الطويلة ARFIMA والشبكات العصبية الاصطناعية للتنبؤ بسعر صرف الدينار الجزائري، الجزائر، مجلة الباحث، العدد 70، 2017، ص 164.

(13) Alyozbakae, araf, iraqi stock market forecasting using artificial neural network, Turkey, master thesis, the university of Turkish aeronautical association institute 2016, p 17

إلى أخرى بحسب الدالة المستخدمة، كما سيتم مناقشتها لاحقاً، لكن بشكل عام تتلخص وظيفتها في جعل القيم المدخلة في نطاق معين (0-1) لتسهيل عملية التدريب في الشبكة العصبية.

(د) طبقة الإخراج Output: تستلم هذه الطبقة مخرجات دالة التنشيط، حيث تقوم بإجراء بعض العمليات عليها للحصول على المخرجات المطلوبة، ومع الإشارة إلى أن مخرجات هذه الطبقة قد تكون مدخلات لشبكة أخرى وهكذا تستمر العمليات في الشبكات العصبية⁽¹⁴⁾.



الشكل (1): مقارنة بين الشبكة العصبية البيولوجية والشبكة العصبية الاصطناعية

3 - دوال التنشيط Activation Function

تعتبر دوال التنشيط من أهم الأجزاء في الشبكات العصبية لوظيفتها في معالجة البيانات الداخلة، حيث تتلخص وظيفتها في حصر قيمة المدخلات في نطاق معين وحسب الدالة المستخدمة، فمثلاً تقوم دالة (sigmoid) بحصر المدخلات ضمن نطاق (0-1)، وهذا مهم في تحسين التدريب للشبكة العصبية، كذلك فإن دالة التنشيط تضيف المعالجة اللاخطية للشبكة العصبية، حيث يتوجب في مثل هذه الحالة استخدام دوال التنشيط اللاخطية⁽¹⁵⁾.

(14) عاشور، مروان عبد الحميد، الشبكات العصبية الاصطناعية وطرائق التنبؤ بالسلاسل الزمنية، ص 29.
(15) <https://www.geeksforgeeks.org/activation-functions-neural-networks/>

هنالك العديد من دوال التنشيط المستخدمة في الشبكات العصبية، نذكر أهمها:

أ) دالة Step Function

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$$

ب) دالة Hyperbolic Tangent (Tanh)

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$$

ت) دالة Sigmoid/Logistic

$$f(x) = \frac{1}{1 + e^{-x}}$$

ث) دالة Softmax

$$f(x_i) = \frac{\exp(x_i)}{\sum \exp(x_i)}$$

4 - أساليب التعلم في الشبكات العصبية الاصطناعية

هنالك العديد من الأساليب لتعليم الشبكة العصبية وتدريبها، إلا أن الشائع منها

نوعان وهما:

أ) التعليم بإشراف Supervised Learning

وفقاً لهذا الأسلوب يتم توفير البيانات المستهدفة (Target values) للشبكة العصبية، والمطلوب من الشبكة تقليل الخطأ الناتج عن عملية التنبؤ وذلك بتكرار التدريب عدة مرات حتى الوصول إلى أقل قيمة للخطأ من خلال حساب الفروق بين القيم الفعلية والقيم الناتجة، يندرج تحت هذا الأسلوب نمطين في التعلم

الأول يتعلق بالبيانات الرقمية ويسمى Regression أي تقوم الشبكة العصبية بمعرفة الانحدار للبيانات المستهدفة ثم بناء توقعاتها على وفق ذلك، أما النوع الثاني يدعى Classification والذي يعنى بالبيانات المصنفة، حيث يعمل على توقع قيمة المدخل المستهدف⁽¹⁶⁾.

سيكون هذا النوع محور بحثنا، حيث هنالك العديد من الخوارزميات المستخدمة لتقليل الخطأ الناتج وكما ستتم مناقشتها لاحقاً.

ب) التعليم بدون إشراف Unsupervised Learning

على العكس من السابق، فلا يتم تزويد الشبكة بالبيانات وفق هذا الأسلوب، حيث تكون الشبكة العصبية قادرة على تحديد الأنماط المميزة في المدخلات ومن خلال ذلك توجد العلاقات الإحصائية مما يجعلها تتنبأ بالقيم المستقبلية⁽¹⁷⁾.

5 - أنواع الشبكات العصبية الاصطناعية

هنالك العديد من الشبكات العصبية الاصطناعية التي تختلف في معمارياتها وآلياتها والغرض منها، ويعود ذلك إلى الاستخدامات المختلفة للشبكات العصبية، إلا أننا سنركز في هذا البحث على الشبكة متعددة الطبقات MLP، وفيما يلي قائمة بأنواع الشبكات العصبية الاصطناعية:

- أ. الشبكة متعددة الطبقات Multilayer Perceptron.
- ب. الشبكة ذات الأساس الإشعاعي Radial Basis Functional Neural Network.
- ت. الشبكة العصبية التلافيفية Convolutional Neural Network.
- ث. الشبكة العصبية المتكررة Recurrent Neural Network.
- ج. شبكة الذاكرة الطويلة LSTM – Long Short-Term Memory.
- ح. شبكة النماذج المتسلسلة Sequence to Sequence Models.


(16) <https://www.ibm.com/cloud/learn/supervised-learning>

(17) <https://threatwarrior.com/unsupervised-neural-networks>

خ. الشبكة العصبية المعيارية Modular Neural Network.

6 - الشبكة العصبية متعددة الطبقات Multilayer Perceptron

تعد الشبكة متعددة الطبقات، واختصاراً (MLP)، من أشهر أنواع الشبكات العصبية وأكثرها استخداماً، حيث تعتمد على خوارزمية الانتشار الخلفي (Backpropagation) كأسلوب لتصحيح الخطأ والتعلم، تتميز معمارية الشبكة متعددة الطبقات بوجود طبقات في الوسط تدعى الطبقات المخفية (Hidden Layers)، والسبب في وجود هذه الطبقات هو للتمكن من حل المشكلات غير الخطية (Nonlinear problems) التي لا تستطيع شبكات الانتشار الأمامي حلها، يمكن أن تحتوي الشبكة متعددة الطبقات على عدد لا نهائي من الطبقات المخفية، ويكون ذلك تبعاً لمدى تعقيد المشكلة التي تحاول الشبكة معالجتها. تعتمد الشبكات متعددة الطبقات على نمط التعلم بإشراف حيث تزود الشبكة بالبيانات المستهدفة لتقوم بنمذجتها وفق أسلوب (التدريب والتعلم) ومن خلال خوارزمية الانتشار الخلفي تقوم الشبكة بتصحيح الخطأ بشكل متكرر حتى الوصول إلى أدنى نسبة خطأ ممكنة⁽¹⁸⁾.



الشكل (2): مخطط معمارية الشبكة العصبية متعددة الطبقات MLP

(18) سليمان، علي أبشر فضل، المقارنة بين التحليل التمييزي والنموذج اللوجستي الثنائي ونماذج الشبكات العصبية في تصنيف المشاهدات، السودان، أطروحة دكتوراه، جامعة السودان، 2015، ص 42.

وتعطي عملية الانتشار الأمامي للشبكة متعددة الطبقات بالصيغة التالية⁽¹⁹⁾

$$a_k^2 = f^2 \left(\sum_{j=1}^{s1} w_{jk}^2 f \left(\sum_{i=1}^R w_{ij}^1 p_i + b_j^1 \right) + b_k^2 \right), k = 1 \text{ to } s^2$$

حيث تمثل S^1 : عدد الوحدات المخفية، S^2 : عدد وحدات الاخراج R: عدد وحدات المدخلات، W_{jk} : الأوزان بين الطبقة المخفية وطبقة المخرجات، W_{ij} : الأوزان بين المدخلات والطبقة المخفية، f : تمثل دالة التنشيط، b_i : التحيز.

7 - خوارزمية الانتشار العكسي للخطأ Backpropagation Algorithm Error

سميت بالانتشار العكسي لأنها تبدأ من الطبقة النهائية (طبقة المخرجات) بعد اكتمال مرحلة الاتجاه الأمامي (Feedforawrd)، وبالاتجاه العكسي من أجل تصحيح الأخطاء الناتجة، حيث يتلخص عمل خوارزمية الانتشار العكسي بحساب الخطأ في المخرجات لتعديل الأوزان بين طبقة المخرجات والطبقة المخفية، ثم بعد ذلك تقوم بتعديل الأوزان بين الطبقة المخفية وطبقة المدخلات، ثم بعد ذلك يتم قياس المخرجات ومقارنتها بالقيم الفعلية التي تم تزويد الشبكة بها ومن ثم حساب الخطأ وتكرار العملية مرة أخرى حتى الوصول إلى أقل خطأ ممكن، حيث يطلق على هذه العملية (التدريب)، وإن الغرض من هذه العملية هو الحصول على الأوزان المثلى التي تعطي أقل قيمة خطأ للشبكة العصبية، حتى يتم بعد ذلك استخدام النموذج في التنبؤ بالبيانات الجديدة⁽²⁰⁾، أدناه صيغة تعديل الأوزان في شبكة الانتشار الخلفي:

$$W_{new} = W_{old} - \eta * \left(\frac{\theta E}{\theta W} \right)$$

حيث تمثل η : معدل التعلم، θE مشتقة الخطأ، θW مشتقة الوزن.

(19) Shirvany, Y., Hayati, M., & Moradian, R., Multilayer perceptron neural networks with novel unsupervised training method for numerical solution of the partial differential equations. Applied Soft Computing, 9(1), 2009, p 20-29

(20) عاشور، مروان عبد الحميد، الشبكات العصبية الاصطناعية وطرائق التنبؤ بالسلاسل الزمنية، ص 48

حيث لتعديل الخطأ يتوجب على حساب مشتقة الخطأ بالنسبة لمشتقة الوزن وكما موضح في المعادلة أعلاه، في عملية تدعى قاعدة السلسلة (Chain Rule)، وكما يلي:

إن حساب قيمة الخطأ في الشبكة متعددة الطبقات يتم وفقاً للمعادلة الآتية:

$$E = \frac{1}{2} (d_{desired} - y_{predicted})^2$$

حيث تمثل y الدالة السينية، Sigmoid Function، d القيم الفعلية Actual.

$$y = f(x) = \frac{1}{1 + e^{-s}}$$

فإذا كانت قيمة s تمثل مجموع ضرب المدخلات في الأوزان مع قيمة التحيز، وكما يلي:

$$S = \sum W_{ij} * x_i + b_i$$

فإن عملية تصحيح الأخطاء في مرحلة الانتشار الخلفي تكون وفق الصيغة التالية:

$$\frac{\theta E}{\theta W} = \frac{\theta E}{\theta y} * \frac{\theta y}{\theta s} * \frac{\theta s_i}{\theta w_i}$$

أي تعني ببساطة، حتى نحصل على مشتقة الخطأ بالنسبة للأوزان، يجب حساب مشتقة الخطأ بالنسبة لمشتقة الدالة السينية y مضروبة في مشتقة الدالة السينية y بالنسبة لمشتقة s ، بعد ذلك يتم اشتقاق كل مدخل بالنسبة للوزن المرتبط به، وهذه ما تسمى عملية Chain Rule.

المبحث الثالث: الدراسة التطبيقية

أولاً: وصف بيانات ومتغيرات البحث

تمثلت بيانات الدراسة التطبيقية بالمؤشرات الشهرية المعلنة بواسطة سوق العراق للأوراق المالية، فيما كانت المتغيرات المستقلة المستخدمة للتنبؤ بسعر الإغلاق متمثلة (بسرع الافتتاح، أعلى سعر، أدنى سعر، معدل السعر، نسبة التغير في السعر، عدد الصفقات، عدد أيام التداول خلال الشهر)، لعينة الدراسة المتمثلة بثلاث مصارف إسلامية مدرجة في السوق وهي كل من (مصرف إيلاف الإسلامي، المصرف العراقي الإسلامي، المصرف الوطني الإسلامي)، وكما يتضح في الجدول أدناه:

جدول (1): مشاهدات المصارف عينة البحث

المصرف	عدد المشاهدات	عينة التدريب %70	عينة الاختبار %15	عينة التحقق %15
المصرف العراقي الإسلامي	24	16	4	4
المصرف الوطني الإسلامي	20	14	3	3
مصرف إيلاف الإسلامي	20	14	3	3

يتضح من الجدول (1) أن عدد المشاهدات للمصرف العراقي الإسلامي كانت (24) مشاهدة، فيما كانت مشاهدات مصرف إيلاف الإسلامي والمصرف الوطني الإسلامي بواقع (20) كل منهما بسبب التوقف عن التداول، وهي تمثل البيانات الشهرية للفترة من (كانون الثاني/ 2018) إلى (كانون الأول/ 2019)، وقد جرى تقسيم البيانات إلى ثلاث عينات بواقع (70% تدريب، 15% اختبار، 15% تحقق) لتطلبات بناء الشبكة العصبية، حيث تألفت عينة التدريب للمصرف العراقي

الإسلامي من (16) مشاهدة فيما كانت عينتا الاختبار والتحقق مؤلفتين من (4) مشاهدات، وبالشكل ذاته، تألفت عينة التدريب للمصرفين الآخرين من (14) مشاهدة، فيما كانت عينتا الاختبار والتحقق للمصرفين مؤلفة من (3) مشاهدات.

ثانياً: معمارية الشبكة العصبية المستخدمة في التنبؤ


تم استخدام الشبكة العصبية متعددة الطبقات (Multilayer perceptron) مع خوارزمية الانتشار العكسي للخطأ (Backpropagation) في بناء نموذج التنبؤ بأسعار الإغلاق للمصارف عينة البحث، وجرى تنفيذ الشبكة العصبية بواسطة برنامج (Matlab 2014b)، وكما في الجدول أدناه

جدول (2): معلومات الشبكة العصبية المستخدمة في البحث

BACKPROPAGTION	خوارزمية حساب الأخطاء
(TRAINLM (Levenberg-Marquardt	خوارزمية التدريب
LOGISG	دالة التحويل
MSE	دالة تقييم الأداء
10000	الحد الأعلى للدفعات التصحيح

حيث يتضح في الجدول (2)، استخدام خوارزمية الانتشار العكسي لحساب الأخطاء الناتجة من عملية تدريب الشبكة حيث تمتاز هذه الخوارزمية بخاصية التكرار (iteration) مما يساعد على الوصول لأدنى خطأ في تدريب النموذج، فيما تم استخدام خوارزمية المربعات الصغرى (Levenberg-Marquardt) لتدريب الشبكة العصبية مع دالة التحويل السينية (Logisg) لمعالجة الأخطاء والوصول إلى الخط الانحداري الأمثل، حيث تمتاز دالة التحويل السينية (اللوجستية)

بخاصية التطبيع مما يساعد الشبكة في التدريب على اختلاف أشكال البيانات المدخلة، وكان مقياس الخطأ المستخدم في عملية التحقق هو متوسط مجموع الأخطاء (MSE).



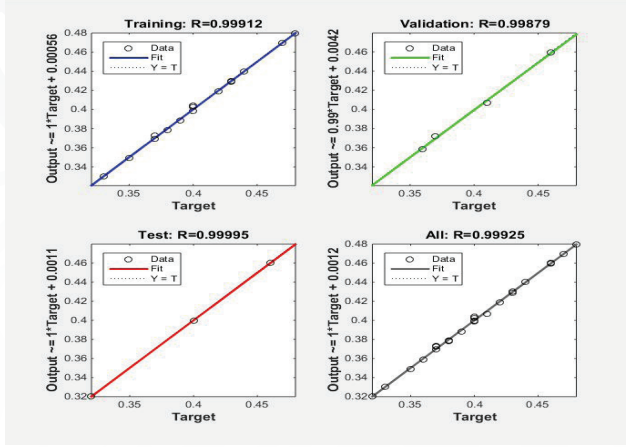
الشكل (3): معمارية الشبكة العصبية الاصطناعية MLP

الشكل (3) يوضح مخطط الشبكة العصبية المستخدمة في البحث، حيث احتوت على طبقة إدخال واحدة (Single Input) تحتوي على (7) مدخلات تمثل المتغيرات المستقلة المستخدمة لغرض التنبؤ بسعر الإغلاق، فيما احتوت الشبكة على طبقة مخفية واحدة (Single Hidden) تحتوي على (9) عقد (Neurons) حيث وجد الباحث بعد عدة تجارب أن هذا العدد من العقد في الطبقة المخفية أعطى نتيجة أفضل ونسبة خطأ أقل، أما طبقة الإخراج فتمثلت بطبقة واحدة (Single Output) تحتوي على مخرج واحد يمثل القيم المتنبأ بها، حيث يقوم البرنامج بإلغاء تطبيع البيانات وإعادةها إلى الشكل الحقيقي.

ثالثاً: مناقشة النتائج


1 - المصرف العراقي الإسلامي

تم تزويد نموذج الشبكة العصبية ببيانات التدريب البالغة (16) مشاهدة وجرى تدريب النموذج بعدة محاولات للوصول إلى أفضل نتيجة، ثم تم اختبار النموذج بواسطة بيانات الاختبار البالغة (4) مشاهدات، ثم بيانات التحقق البالغة (4) مشاهدات، وكما يلي:



الشكل (4) المعادلة الانحدارية لنموذج المصرف العراقي الإسلامي

يتضح من الشكل (4) أن معامل الارتباط لعينة التدريب والاختبار والتحقق بالإضافة إلى العينة الكلية كان (0.99) مما يدل على قوة ارتباط القيم المتنبأ بها بالقيم الفعلية، حيث كانت معادلة الانحدار المستخدمة في التنبؤ للنموذج هي $(Y = 0.99 * X + 0.0012)$.




الشكل (5): ارتباط القيم المتنبأ بها بالقيم الفعلية لنموذج المصرف العراقي الإسلامي

الشكل (5) يبين مدى ترابط القيم المتنبأ بها بالقيم الفعلية، وهذا يؤكد على مدى كفاءة النموذج في التنبؤ بأسعار الإغلاق للمصرف العراقي الإسلامي.


2 - المصرف الوطني الإسلامي

تم تزويد نموذج الشبكة العصبية ببيانات التدريب البالغة (14) مشاهدة وجرى تدريب النموذج بعدة محاولات للوصول إلى أفضل نتيجة، ثم تم اختبار النموذج بواسطة بيانات الاختبار البالغة (3) مشاهدات، ثم بيانات التحقق البالغة (3) مشاهدات، وكما يلي:



الشكل (6) المعادلة الانحدارية لنموذج المصرف الوطني الإسلامي

يتضح من الشكل (6) أن معامل الارتباط لعينة التدريب والتحقق كان (0.99) فيما كان لعينة الاختبار (1) والعينة الكلية (0.99) مما يدل على قوة ارتباط القيم المتنبأ بها بالقيم الفعلية، حيث كانت معادلة الانحدار المستخدمة في التنبؤ للنموذج هي $(Y = 0.99 * X + 0.00031)$.

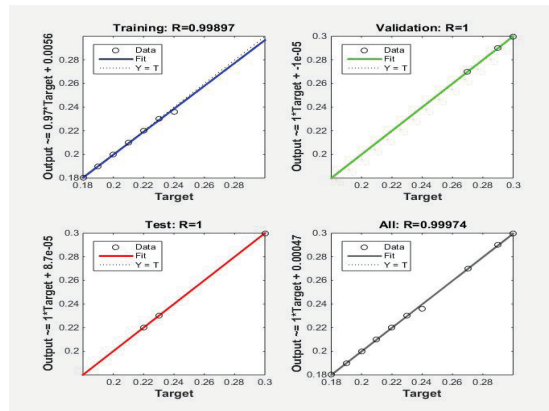


الشكل (7): ارتباط القيم المتنبأ بها بالقيم الفعلية لنموذج المصرف الوطني الإسلامي

الشكل (7) يبين مدى ترابط القيم المتنبأ بها بالقيم الفعلية، وهذا يؤكد على مدى كفاءة النموذج في التنبؤ بأسعار الإغلاق للمصرف الوطني الإسلامي.


2 - مصرف إيلاف الإسلامي

تم تزويد نموذج الشبكة العصبية ببيانات التدريب البالغة (14) مشاهدة وجرى تدريب النموذج بعدة محاولات للوصول إلى أفضل نتيجة، ثم تم اختبار النموذج بواسطة بيانات الاختبار البالغة (3) مشاهدات، ثم بيانات التحقق البالغة (3) مشاهدات، وكما يلي:



الشكل (8) المعادلة الانحدارية لنموذج مصرف إيلاف الإسلامي

يتضح من الشكل (8) أن معامل الارتباط لعينة الاختبار والتحقق كان (1) فيما كان لعينة التدريب والعينة الكلية (0.99) مما يدل على قوة ارتباط القيم المتنبأ بها بالقيم الفعلية، حيث كانت معادلة الانحدار المستخدمة في التنبؤ للنموذج هي $(Y = 0.99 * X 0.00047)$.



الشكل (9): ارتباط القيم المتنبأ بها بالقيم الفعلية لنموذج مصرف إيلاف الإسلامي

الشكل (9) يبين مدى ترابط القيم المتنبأ بها بالقيم الفعلية، وهذا يؤكد على مدى كفاءة النموذج في التنبؤ بأسعار الإغلاق لمصرف إيلاف الإسلامي.

جدول (3): مقياس الأخطاء للنماذج التنبؤية

MAPE	RMSE	MSE	MAD	R ²	المصرف
0.0024	0.0013	0.000002	0.0009	0.99	المصرف العراقي الإسلامي
0.001	0.002	0.000006	0.0016	0.99	المصرف الوطني الإسلامي
0.001	0.0009	0.0000008	0.0002	0.99	مصرف إيلاف الإسلامي

تم قياس النماذج التنبؤية للمصارف عينة البحث وفقاً لنتائج التنبؤ بمقاييس الأخطاء (MAPE، RMSE، MSE، MAD) فضلاً عن مقياس التحديد (R²)، حيث يوضح الجدول (3) أن جميع النماذج كانت فعالة وبنسب خطأ ضئيلة جداً، حيث كان نموذج مصرف إيلاف الإسلامي الأفضل في العينة بمعامل تحديد (0.99) ومتوسط خطأ بنسبة (8e-7) وجذر متوسط خطأ بنسبة (9e-4).

جدول (4): النتائج المقدرة والفعلية لنموذج الشبكة العصبية

المصرف الإسلامي		المصرف الوطني الإسلامي		المصرف العراقي الإسلامي		التاريخ
الفعلية	التنبؤية	الفعلية	التنبؤية	الفعلية	التنبؤية	
0.300	0.300	1.200	1.199	0.480	0.4799	01/01/2018
0.300	0.300	1.200	1.200	0.470	0.4698	02/01/2018
0.290	0.290	1.160	1.163	0.460	0.4596	03/01/2018
0.270	0.270	1.150	1.152	0.460	0.4603	04/01/2018
0.230	0.230	1.200	1.206	0.430	0.4301	05/01/2018
0.230	0.230	1.200	1.198	0.430	0.4291	06/01/2018
0.210	0.210	1.200	1.200	0.440	0.4401	07/01/2018
0.220	0.220	1.210	1.204	0.400	0.3996	08/01/2018
0.220	0.220	-	-	0.350	0.3492	09/01/2018
0.240	0.236	-	-	0.320	0.3206	10/01/2018
0.200	0.200	1.060	1.060	0.330	0.3301	11/01/2018
0.220	0.220	0.900	0.901	0.400	0.3994	12/01/2018
0.180	0.180	0.940	0.939	0.370	0.3693	01/01/2019
0.200	0.200	0.830	0.834	0.360	0.3587	02/01/2019
0.180	0.180	0.650	0.647	0.370	0.3731	03/01/2019
0.180	0.180	0.630	0.630	0.370	0.3725	04/01/2019
0.190	0.190	0.630	0.630	0.380	0.3788	05/01/2019
-	-	0.630	0.630	0.420	0.4190	06/01/2019
-	-	0.630	0.630	0.400	0.3986	07/01/2019
-	-	0.640	0.640	0.410	0.4070	08/01/2019
0.180	0.180	-	-	0.380	0.3783	09/01/2019
0.180	0.180	-	-	0.390	0.3885	10/01/2019
0.180	0.180	0.900	0.904	0.400	0.4026	11/01/2019
-	-	1.000	1.000	0.400	0.4040	12/01/2019

يوضح الجدول (4) النتائج المقدرة لأسعار الإغلاق الشهرية للعينات المدروسة، حيث يتضح مدى تقارب النتائج المقدرة مع النتائج الفعلية مما يؤكد على دقة النموذج المستخدم، ويتضح من خلال الجدول وجود بعض البيانات المفقودة بسبب التوقف عن التداول للمصرف الوطني الإسلامي ومصرف إيلاف الإسلامي، حيث يمكن للشبكة العصبية نمذجة البيانات بغض النظر عن اختلاف السلاسل الزمنية وهذا ما يميز الشبكات العصبية عن الأساليب الإحصائية التقليدية.

جدول (5): نتائج التنبؤ خارج العينة لنماذج الشبكات العصبية المستخدمة

مصرف إيلاف الإسلامي		المصرف الوطني الإسلامي		المصرف العراقي الإسلامي		التاريخ
الفعلية	التنبؤية	الفعلية	التنبؤية	الفعلية	التنبؤية	
0.180	0.180	1.000	1.000	0.430	0.431	01/01/2020
0.180	0.180	0.650	0.650	0.410	0.411	02/01/2020
-	-	0.650	0.650	0.400	0.401	03/01/2020

تم استخدام نماذج الشبكة العصبية للتنبؤ بأسعار الإغلاق للمصارف عينة البحث خارج فترة العينة، حيث تم التنبؤ بأسعار الإغلاق للأشهر (كانون الثاني، شباط، آذار) من عام (2020) وكما يتضح من الجدول (5) أن النماذج المستخدمة استطاعت التنبؤ بأسعار الإغلاق للبيانات خارج العينة وبنسبة خطأ ضئيلة وهذا يؤكد دقة نماذج الشبكات العصبية في التنبؤ.

الخاتمة النتائج:

في ضوء ما جاء في الدراسة التطبيقية وبناءً على ما تم التوصل إليه من نتائج، وضعت الاستنتاجات التالية:

1. فاعلية الشبكة متعددة الطبقات (MLP) في محاكاة بيانات العينة وتقدير أسعار الإغلاق بنسبة وصلت إلى 99 %، ودقتها في التنبؤ بأسعار الإغلاق المستقبلية (خارج العينة).
2. يختصر أسلوب الشبكات العصبية الاصطناعية الوقت والجهد في التنبؤ، كذلك قدرة الشبكات العصبية على التعامل مع جميع أنواع البيانات دون اشتراط تحقيق الفروض الإحصائية الأولية مقارنة بالناذج التقليدية.
3. زيادة عدد مرات التدريب للشبكة العصبية الاصطناعية يزيد من دقة النموذج في التنبؤ.
4. إمكانية الاعتماد على الشبكات العصبية في اتخاذ القرارات الاستثمارية إلى جانب الأساليب الأخرى مما يعطي ثقة ودقة أفضل.

التوصيات:

1. نوصي باستخدام الشبكات العصبية في سوق العراق للأوراق المالية، بالنظر لدقة النتائج التي توصلنا إليها، وكذلك لأنه أسلوب يختصر الجهد والوقت ولا يشترط نمطاً معيناً للبيانات المدروسة.
2. نوصي بالاعتماد على نماذج الشبكات العصبية الاصطناعية في اتخاذ القرارات الاستثمارية إلى جانب الأساليب الأخرى.
3. الاهتمام بتقنية الشبكات العصبية الاصطناعية كأسلوب فعال للتنبؤ يحاكي

التغيرات المفاجئة في البيئة المالية لاسيما في المصارف الإسلامية كونها تعتمد وبشكل كبير على النشاط الاستثمائي.

4. توسيع الدراسات والأبحاث في مجال الشبكات العصبية الاصطناعية لتشمل متغيرات أكثر وبيانات أكبر مما يعطي صورة أوضح لها.

المراجع العربية:

- أيوب، ناديا، نظرية القرارات الإدارية، سوريا، منشورات جامعة دمشق، 1989.
- البيروتي، سعاد عبد الفتاح، دور المصارف الإسلامية في التنمية والاستثمار، مجلة كلية بغداد للعلوم الاقتصادية، العدد 24، 2010.
- حادة مدوري، محمد مكيدش، دراسة مقارنة بين نماذج الذاكرة الطويلة ARFIMA والشبكات العصبية الاصطناعية للتنبؤ بسعر صرف الدينار الجزائري، الجزائر، مجلة الباحث، العدد 70، 2017.
- الحسناوي، سالم صلال، الاستثمار والتمويل في الأسواق المالية، العراق، مؤسسة دار الصادق الثقافية، 2017.
- سليمان، علي أبشر فضل، المقارنة بين التحليل التمييزي والنموذج اللوجستي الثنائي ونماذج الشبكات العصبية في تصنيف المشاهدات، السودان، أطروحة دكتوراه، جامعة السودان، 2015.
- سهيلة، عتروس، استخدام منهجية بوكس جنكنز والشبكات العصبية الاصطناعية للتنبؤ باستهلاك الطاقة الكهربائية بمؤسسة سونلغاز دراسة حالة ولاية بسكرة، أطروحة دكتوراه، الجزائر، جامعة محمد خيضر بسكرة، 2018.
- عاشور، مروان عبد الحميد، الشبكات العصبية الاصطناعية وطرائق التنبؤ بالسلاسل الزمنية، العراق، دار الذاكرة للطباعة والنشر، ط 1، 2018.
- هندي، منير ابراهيم، الأوراق المالية وأسواق المال، مصر، منشأة المعارف، 2006.

المراجع الإنجليزية:

- Alyozbakee, araf, iraqi stock market forecasting using artificial neural network ,Turkey ,master thesis, the university of turkish aeronautical association institute 2016.
- Shirvany, Y., Hayati, M., & Moradian, R., Multilayer perceptron neural networks with novel unsupervised training method for numerical solution of the partial differential equations. Applied Soft Computing, 9(1), 2009.

المراجع الإلكترونية:

- <https://www.cbi.iq/page/113>
- <https://www.geeksforgeeks.org/activation-functions-neural-networks/>
- <https://www.ibm.com/cloud/learn/supervised-learning>
- <https://www.threatwarrior.com/unsupervised-neural-networks>
- <https://www.isc.gov.iq/index.php?do=list&type=allcompany>

Transliteration of Arabic References

- Ayyūb, Nādiyā, Naẓarīyat al-qarārāt al-Idārīyah, Sūriyā, Manshūrāt Jāmi‘at Dimashq, 1989.
- al-Bayrūtī, Su‘ād ‘Abd al-Fattāh, Dawr al-maṣārif al-Islāmīyah fī al-tanmiyah wa-al-Istithmār, Majallat Kullīyat Baghdād lil-‘Ulūm al-iqtisādīyah, al-‘adad 24, 2010.
- Ḥāddah Maddūrī, Muḥammad mkydysh, dirāsah muqāranah bayna namādhij al-dhākīrah al-Ṭawīlah ARFIMA wa-al-shabakāt al-‘aṣabīyah alāṣṭnā‘yh lltbn’ bs’r ṣarf al-dīnār al-Jazā’irī, al-Jazā’ir, Majallat al-bāhith, al-‘adad 70, 2017.
- al-Ḥasnāwī, Sālim Ṣallāl, al-istithmār wa-al-tamwīl fī al-aswāq al-mālīyah, al-‘Irāq, Mu’assasat Dār al-Ṣādiq al-Thaqāfīyah, 2017.
- 5-Sulaymān, ‘Alī Abshar Faḍl, al-muqāranah bayna al-Taḥlīl altmyyzy wa-

- al-namūdhaj allwjsty al-thunā'ī wa-namādhij al-Shabakāt al-‘aşabīyah fī taşnīf almshāhdāt, al-Sūdān, uṭrūḥat duktūrāh, Jāmi‘at al-Sūdān, 2015.
- Suhaylah, ‘Atrūs, istikhdām manhajīyah Būks jnknz wa-al-shabakāt al-‘aşabīyah alāştnā‘yh lltnb’ bāsthāk al-ṭāqah al-kahrabā’īyah bi-Mu’assasat swnlghāz dirāsah ḥālat Wilāyat Baskarah, uṭrūḥat duktūrāh, al-Jazā’ir, Jāmi‘at Muḥammad Khayḍar Baskarah, 2018.
 - ‘Āshūr, Marwān ‘Abd al-Ḥamīd, al-Shabakāt al-‘aşabīyah alāştnā‘yh wa-ṭarā’iq al-tanabbu’ bāslāsl al-zamanīyah, al-‘Irāq, Dār al-dhākīrah lil-Ṭībā‘ah wa-al-Nashr, Ṭ 1, 2018.
 - Hindī, Munīr Ibrāhīm, al-awraq al-mālīyah wa-aswāq al-māl, Mişr, Munsha‘at al-Ma‘ārif, 2006.