



AL-Rafidain
University College

PISSN: (1681-6870); EISSN: (2790-2293)

مجلة كلية الرافدين الجامعية للعلوم

Available online at: <https://www.jrucs.iq>

JRUCS

Journal of AL-Rafidain
University College
for Sciences

التنبؤ بمؤشر القيمة المتداولة لسوق العراق للأوراق المالية باستعمال الشبكات العصبية الاصطناعية

أ.م.د. رباب عبد الرضا صالح	نور زهير صبرى
rabab.saleh@codecuobaghdad.edu.iq	noorzuhair2020@gmail.com
كلية الإدارية و الاقتصاد، جامعة بغداد، بغداد، العراق	كلية الهندسة، جامعة بغداد، بغداد، العراق

معلومات البحث

تاریخ البحث:

تاریخ تقديم البحث: 19/2/2024

تاریخ قبول البحث: 12/4/2024

تاریخ رفع البحث على الموقع: 31/12/2024

الكلمات المفتاحية:

الشبكات العصبية، خوارزمية الانتشار العكسي، القيمة المتداولة

للمراسلة:

أ.م.د. رباب عبد الرضا صالح

rabab.saleh@codecuobaghdad.edu.iq

DOI: <https://doi.org/10.55562/jrucs.v56i1.20>

المستخلص

بعد التنبيؤ من المواضيع المهمة في العلوم الإحصائية لمساعدة القيادات في وضع الخطط المستقبلية وإتخاذ القرار المناسب لها ويتضمن هذا البحث إحدى أساليب التنبؤ الحديثة والتمثلة بنماذج الشبكات العصبية الإصطناعية (ANN) وتحديداً الشبكة المتعددة الطبقات، إذ تم إعتماد خوارزمية الإنتشار الخلفي (BP)) وتدريبها عدة مرات للحصول على أقل قيمة للخطأ. ويهدف البحث إلى التنبيؤ بمؤشر مهم من مؤشرات سوق العراق للأوراق المالية وهو مؤشر القيمة المتداولة، باستعمال أحدى الطرق العلمية وهي الشبكات العصبية الإصطناعية بتطبيق خوارزمية الإنتشار العكسي وباستعمال برنامج Matlab2018)، وتوصل الباحث إلى ان إنموذج الشبكات العصبية الإصطناعية يعطي نتائج دقيقة وذلك من خلال انتشار البيانات في خط الانحدار وبلغت قيمة معامل التحديد ($R=0.99928$) ، ومتوسط مربعات الخطأ قد بلغ (0.0000001) وهو قليل جداً وهذا يدل على دقة التنبيؤ. تم جمع بيانات يومية لمؤشر القيمة المتداولة للفترة من 1/2/2018م، ولغاية 31/10/2021م.

1. المقدمة

تعد عملية إتخاذ القرارات في أسواق المال (البورصات) من أصعب القرارات، وذلك لأنها تحمل الكثير من المخاطر وترتبط حكمة ودرایة، لذا تقوم الدول بتعظيم جهودها للتنبؤ بمؤشرات سوق الأوراق المالية، ويساعد التنبيؤ في تحقيق أكبر قدر من الارباح وتجنب الخسائر المحتملة، وقد شهد التنبيؤ بمؤشرات سوق الأوراق المالية تطوراً سريعاً وذلك بسبب الأساليب والطرق الذكية المتطرفة التي كان لها الأثر الإيجابي في تطوير القدرات التنبؤية، ورفع مستوى الأداء وخاصة مستوى تقنيات الشبكات العصبية الإصطناعية.

يؤدي استعمال الشبكات العصبية الإصطناعية (Artificial Neural Networks)، التي تستعمل نهجاً خلافاً لنهج المخرجات التقليدية، إلى موثوقية تنبؤية أفضل بكثير من الأساليب القديمة، وتعد الشبكات العصبية الإصطناعية من الطرق المناسبة لتمثيل العلاقات بشكل مختلف عن الطرق التقليدية، فهي نظام حسابي مكون من عدد من الوحدات المترابطة مع بعضها، وتصف بطبعتها الديناميكية المعالجة والمتوازنة في معالجة البيانات الداخلة إليها. وسميت الشبكات العصبية (NN) بهذا الاسم كونها شبكة من وحدات الاتصالات الداخلية، إذ أن هذه الوحدات مستوحاة من دراسة أنظمة الأعصاب

الحيوية، أن فكرة عمل الشبكات العصبية الإصطناعية هو محاكاة البيانات للوصول إلى انموذج لهذه البيانات لغرض التحليل أو التنبؤ أو أي معالجة أخرى، وقد حازت الشبكات العصبية الإصطناعية اهتمام الكثير من الباحثين والعلماء بسبب مرونتها العالمية مقارنة بالأساليب الرياضية الأخرى، إن الشبكات العصبية الإصطناعية هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة ضخمة موزعة على التوازي، ومكونة من وحدات معالجة سبطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عقد أو عصيونات (Nodes ، Neurons) والتي لها خاصية عصبية، إذ أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية لجعلها متاحة للاستعمال.

2. مكونات الخلية العصبية الاصطناعية [1]

تتكون الخلية العصبية الاصطناعية من أربعة أقسام وكما يأتي:

- قنوات الإدخال (Synapse) : تستلم الخلية العصبية من هذه القنوات إشارات قادمة من الخلايا المرتبطة بها وتسمى هذه الإشارات الدالة بالمدخلات، ويرمز لها $n \dots , 3, 2, 1, i=1$.
- دالة الجمع (Summation Function) : تقوم هذه الدالة بجمع او توحيد الإشارات الدالة في إشارة واحدة.
- دالة التنشيط (Activation Function) : تعرف أيضاً بدالة التحويل (Transfer Function) تقوم هذه الدالة بتحويل المدخلات عبر تفاعلها مع الأوزان من صيغة رياضية الى أخرى وهي على أنواع منها الخطية وغير الخطية ومتماز بتحديد العلاقة بين قنوات الإدخال وقنوات الإخراج عند كل عقدة من عقد الشبكة.
- قناة الإخراج (Axone Path's) : مهمة هذه القناة ارسال إشارة الإخراج الى خلايا عصبية أخرى لتعد إشارة ادخال لتلك الخلايا، وتسمى إشارة الإخراج المخرجات.

3. طرائق تعلم الشبكات العصبية [8]

- **Supervised Learning**: يتطلب هذا النوع من التعلم للشبكات وجود معلم أو مشرف عند تدريب الشبكة، لأنه تحتاج إلى مخرجات مطلوبة (أي يجب تحديد المخرجات مسبقاً)، فضلاً عن مخرجات فعلية ومن خلال عملية التدريب يتم المقارنة بين المخرجات الفعلية والمخرجات المطلوبة.
- **Unsupervised Learning**: يمكن ان تحدث عملية تعلم الشبكة بلا إشراف، لأن هذا النوع من التعلم لا يحتاج إلى مخرجات مطلوبة (أي لا يتم تحديد مقدار المخرجات مسبقاً) وتستعمل في الشبكات الأحادية والمتعددة الطبقة.
- **التعلم المعزز**: إن طريقة التعلم هذه هي طريقة مشتركة تجمع بين الطريقيتين اعلاه (أي قيمة المخرجات المطلوبة) تحدد مسبقاً للشبكة، ولكن لا يوجد مشرف وإنما تستعمل دالة تقويمية لتقويم أداء الشبكة وقيمتها الخارجية، وحتى وإن كان التعلم بطبيعاً فإن الشبكة المتدربة يمكنها أن تنتج إشارة الإخراج بشكل سريع جداً، إن الشبكات العصبية متعددة الطبقات (بطبقة واحدة خفية أو أكثر) يمكن أن تتعلم أي عملية وإن وجود أكثر من طبقة أخرى.

4. خوارزميات تعليم الشبكة العصبية الاصطناعية [7]

يتم تعلم الشبكات العصبية بواسطة خوارزميات متخصصة تسمى خوارزميات التعلم (Learning Algorithms) والتي تتولى تعديل أوزان الشبكة لتحسين أدائها وتقليل الخطأ فيها استناداً إلى مقياس معلوم للوصول إلى النتيجة المطلوبة، ويتم تعديل الأوزان جزئياً في كل دورة، وتؤخذ إشارة الخطأ دليلاً ومؤشرًا على مدى القرب أو البعاد عن القيم الصحيحة وتمثل تلك الأوزان المعلومات الأولية التي تتعلم بها الشبكة ، لذا لا بد من تحديث الأوزان التي تُستعمل في تدريب الشبكات العصبية لغاية الحصول على أفضل نتيجة، وهناك أنواع مختلفة من الخوارزميات ، يتم استعمالها حسب نوع الشبكة ومن أهم هذه الخوارزميات :

- **خوارزمية الانتشار العكسي (الخلفي) للخطأ** (Back Propagation Algorithm) [3,6,9] هي أحدى الخوارزميات المستعملة في تطبيق الشبكات العصبية متعددة الطبقات وقبل البدء بذلك عملاً خوارزمية الانتشار العكسي(الخلفي) للخطأ فيه يمكن أن يكون ناجحاً في كثير من التطبيقات، ولكن استعمال طبقة خفية واحدة يعد كافياً إن الية عمل خوارزمية الانتشار العكسي (الخلفي) للخطأ تعتمد على ايجاد الخطأ بين المخرجات المطلوبة والفعلية ومن ثم تعديل الأوزان بالرجوع به من الطبقة الأخيرة إلى الطبقات الخفية ثم إلى طبقة المدخلات.
- ويتم استعمال التعليم المراقب لقليل الخطأ أقل ما يمكن ، ويفترض في التعليم المراقب وجود معلم خلال عملية التعلم، وكل انموذج يستعمل لتجريب الشبكة يتضمن : انموذج المدخلات إضافة إلى الإخراج المثالي (المرغوب به) (Target Output) يتم خلال عملية التعلم إجراء مقارنة بين الإخراج الحقيقي (Real Output) والإخراج المرغوب فيه وذلك لتعديل مقدار الخطأ، إلى أن يتم تحسين أداء الشبكة و تعطى مصفوفة الأوزان (Weights) قيمًا أولية إما صفر أو قيم حقيقة عشوائية صغيرة جداً، بعدها يدخل متوجه المدخلات (input vector) إلى الشبكة لتحديد متوجه المخرجات (output vector) والذي يتم مقارنته مع متوجه الإخراج المرغوب فيه وذلك لتحديد الخطأ خلال عملية التعلم يتم تدريب الشبكة وذلك باستعمال الدالة التفعيلية (دالة التنشيط) والتي تكون قابلة للفاصل (Differentiation)، بالإضافة إلى ذلك يجب ان لا تكون ثانية القيمة وان تكون قادرة على المنحدرة лахтия.

إن من خواص الابتعاث الخلفي (الارتدادي)، تقليل الخطأ والقابلية على التعامل مع البيانات المشوشه بالإضافة قدرتها على التعامل مع الدوال الخطية واللختية القابلة للاشتغال.

5. مراحل التنبؤ من خلال الشبكات العصبية الاصطناعية (Prediction of ANN)

تحتاج عملية التنبؤ بواسطة الشبكات العصبية الاصطناعية إلى اتباع الخطوات التالية :

(1) تحديد المتغيرات (Variables Selection)

لكي ننجح في تصميم الشبكة العصبية الاصطناعية يجب علينا بداية فهم المشكلة بوضوح بالإضافة إلى معرفة وتحديد متغيرات الإدخال والتي تمثل المشكلة تمثيلاً جيداً حتى تزيد قدرة الشبكات العصبية للكشف.

(2) جمع البيانات (Data Collection)

تجمع البيانات من مصادر موثوق بها بالاعتماد على المشكلة المدروسة وبما يتلائم مع متطلبات تدريب الشبكة العصبية الاصطناعية [2]

(3) تهيئة البيانات للتنبؤ (Data Preparation for prediction)

إن هذه المرحلة تمثل في إعداد البيانات لاستعمالها في التحليل والتنبؤ وتتمثل مجموعة التعلم ومجموعة الاختبار ومجموعة التقويم.

(4) تحديد معمارية الشبكة (Network Architecture Determination)

يتم اتباع الخطوات التالية لتحديد معمارية الشبكة :

1. تحديد عدد عقد الإدخال للشبكة (determination of input nodes)

يعتمد على عدد المتغيرات التوضيحية والتي يتم وصفها في مجموعة التعلم

2. اختيار عدد الطبقات المخفية (selection of number of hidden Layer)

إن وجود طبقة مخفية واحدة يعتبر كافياً للتنبؤ، علماً أنه في بعض الحالات يتم استعمال أكثر من طبقة مخفية.[1]

3. اختيار عدد العقد في الطبقة المخفية (selection of hidden neurons)

هناك بعض القواعد والصيغ التي تحدد عدد العقد في الطبقة المخفية، فمثلاً يتم تحديد عدد العقد لطبقة مخفية واحدة بما يساوي 75% من عدد خلايا متغيرات الإدخال أو من خلال التحديد ما بين (0.5) إلى (3) أضعاف لعدد خلايا متغيرات الإدخال، بالإضافة لوجود صيغ أخرى ممكن من خلالها تحديد عدد العقد في الطبقة المخفية. [4]

(5) تحديد عقد الارجاع (Determination of output nodes)

في حالة التنبؤ بخطوة واحدة في الشبكة العصبية فإن وجود عقدة واحدة يكفي، أما لو كان التنبؤ لعدة خطوات فإنه عدد العقد سيكون مناظراً وبصورة موازية لخطوات التنبؤ، علماً أنه بعض التجارب اثبتت أن إستعمال عقدة واحدة يعطي نتائج جيدة بالمقارنة مع استعمال أكثر من عقدة. [5]

(6) تحديد واختيار دوال التنشيط (Selection of Activation functions of neurons)

يوجد صيغ عديدة لدوال التنشيط يتم اختيارها حسب نوع المشكلة التي يتم بناء الإنموزج لها.[5]

(7) تدريب الشبكة العصبية (Neural Network Training)

إن عملية التدريب للشبكة العصبية تتم عن طريق تعديل أوزان الشبكة للحصول على أقل خطأ ممكن بالاعتماد على خواص ميزة الانشمار الخلفي (BP)، واهم خطوات التدريب هي :

1. تحديد قيم الأوزان الأولية (select the weight initialization)

2. معدل التعلم وعامل الزخم (Learning rate and momentum)

3. معيار التوقف (stopping criterion)

(8) التنفيذ (Implementation)

وهي آخر واهم خطوة، ويتم فيها اختبار الشبكة من حيث قدرتها على التكيف، وامكانية إعادة التدريب لغاية الوصول إلى أقل مربع خطأ، وهذا يعتمد على البرنامج المستعمل والمزود بوسائل لتدريب الشبكات العصبية.[2]

6. الجانب التطبيقي

يتضمن هذا المبحث النتائج التطبيقية من البحث، و تم استعمال انموذج الشبكات العصبية الاصطناعية للتنبؤ بممؤشر من مؤشرات سوق العراق للأوراق المالية، وهو مؤشر القيمة المتداولة، تم استعمال برنامج الماتلاب (MATLAB2018) لبناء انموذج التنبؤ، تم جمع بيانات من مؤشرات سوق العراق للأوراق المالية وذلك من خلال البيانات الموجودة في السوق بالإضافة إلى النشرات التي يعلنها السوق بصورة دورية على موقعه الإلكتروني.

مؤشر القيمة المتداولة ويعتمد على ثلاثة متغيرات مستقلة وهي (عدد الأسهم و الصفقات والشركات المتداولة). جمع بيانات يومية لهذا المؤشر للفترة من 1/2/2018 م ولغاية 31/10/2021 م وبواقع (848) مشاهدة، من أجل تخفيض الاخطاء أثناء التنبؤ سوف نستعمل الشبكات العصبية الاصطناعية (ANN) (Artificial Neural Networks) وتم كتابة برنامج ببرمجة Matlab2018، تتمتع نماذج الشبكات العصبية الاصطناعية بانها تكتسب المزيد من ثقة المجتمع لأنها دوال غير خطية، أما الشكل العام لدالة الشبكات العصبية الاصطناعية كما في الانموذج التالي:

$$Y=F[H[suB] 1[/suB](X, H[suB]2[/suB](X, \dots, HN(X)] + U$$

و ان:

Y: يمثل المتغير التابع (Dependent Variable)

X: تمثل المتغيرات التفسيرية او المستقلة (Independent Variable)

H - F: تمثل دوال الشبكات العصبية (التفعيل- النقل)

U: حد الخطأ في الدالة (Error Term)

وفي الشبكات العصبية الاصطناعية تسمى مجموعة متغيرات (X) بالمدخلات (Input) ويسمى المتغير (Y) بالمخرجات (Output) والتي تمثل النتائج، اما (H) تسمى دالة تشتيت الطبقات الخفية (HLAF) (Hidden Layer) . (Transfer Function) وتسمى (F) مخرجات دالة التحفيز الخفية او دالة النقل (Activation Function) . خطوات الحل في البرنامج كما يلي:

نوع التعلم: التعلم المراقب

طريقة تصحيح الأخطاء: تقليل الدرجة (Gradient Descent) والتي أساسها هو تقليل دالة الخطأ

معمارية الشبكة المستخدمة: الشبكات متعددة الطبقات (Multi Layer Networks)

الدالة المستخدمة: دالة السigmoid (Sigmoid Function)

وإن أفضل طريقة تستعمل مع الشبكات متعددة الطبقات هي الانبعاث الخلفي للخطأ (Back Propagation Error) (Back Propagation) وتحت شيكة الانبعاث الخلفي (Back Propagation) واحدة من أهم وأكثر الشبكات العصبية المستعملة. وفي هذا البحث تم استعمال الطريقة بالميزات التالية:

استعملت خوارزمية الانبعاث الخلفي (Back Propagation Algorithm) ذات الخواص الآتية:

نوع ستراتيجية التعلم: ستراتيجية التعلم المراقب

نوع التعلم : تصحيح الخطأ (Error Correction)

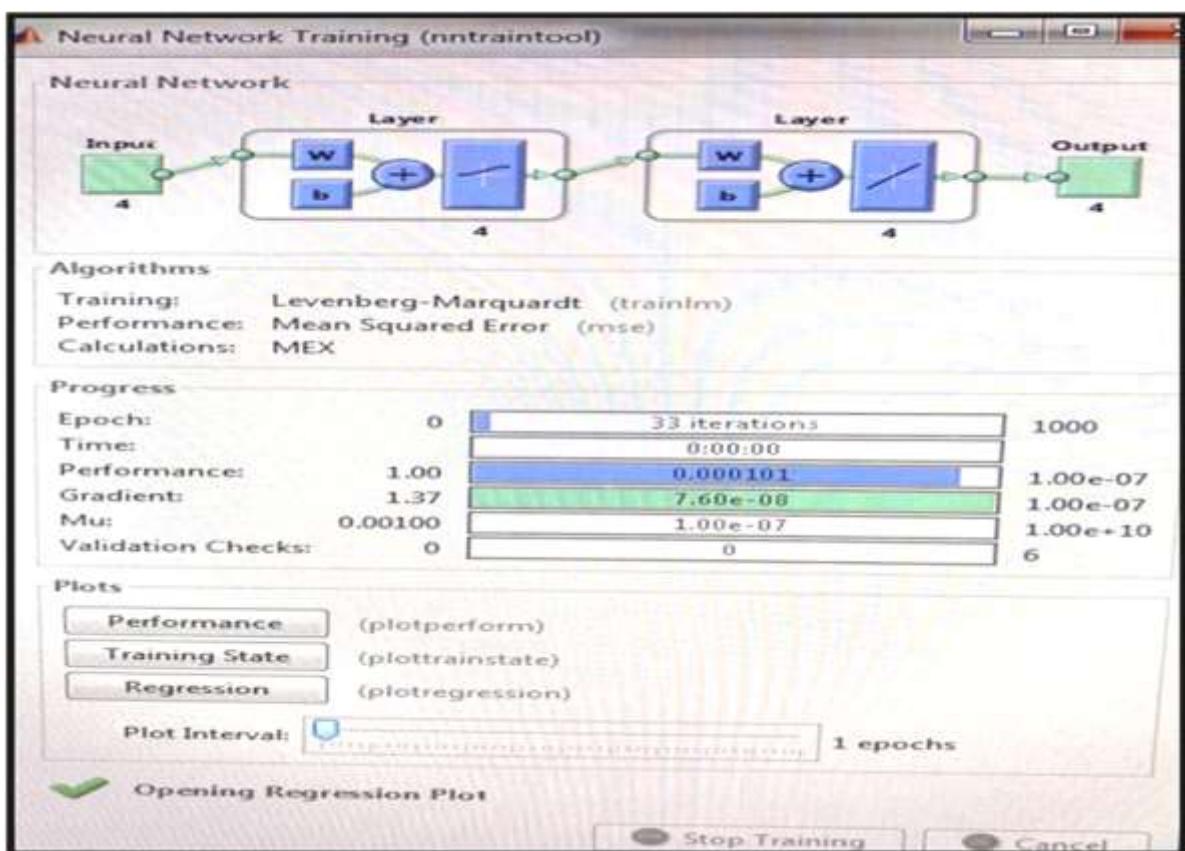
نوع المعمارياة : نوع متعدد الطبقات ذات تغذية أمامية (Multi-Layer Feed Forward Type)

نوع التطبيق : تمييز النماذج (Pattern Recognition)

وقد تم استعمال (1000) تكرار اثناء تدريب الشبكة اما عدد الطبقات المخفية فتم استعمالها بعدد المتغيرات الداخلة، وللحصول على دقة اكثراً اقترح الباحث بان يكون هناك تكرار للتجربة اضافة الى التكرار خلال عملية التدريب والبالغ (1000 تكرار).

7. استعمال أسلوب الشبكات العصبية الإصطناعية

فيما يلي وصف لمتغيرات مؤشر القيمة المتداولة



شكل (1): معمارية الشبكة العصبية لمؤشر القيمة المتداولة

جدول (1): وصف لمتغيرات المؤشر الاول مؤشر القيمة المتداولة

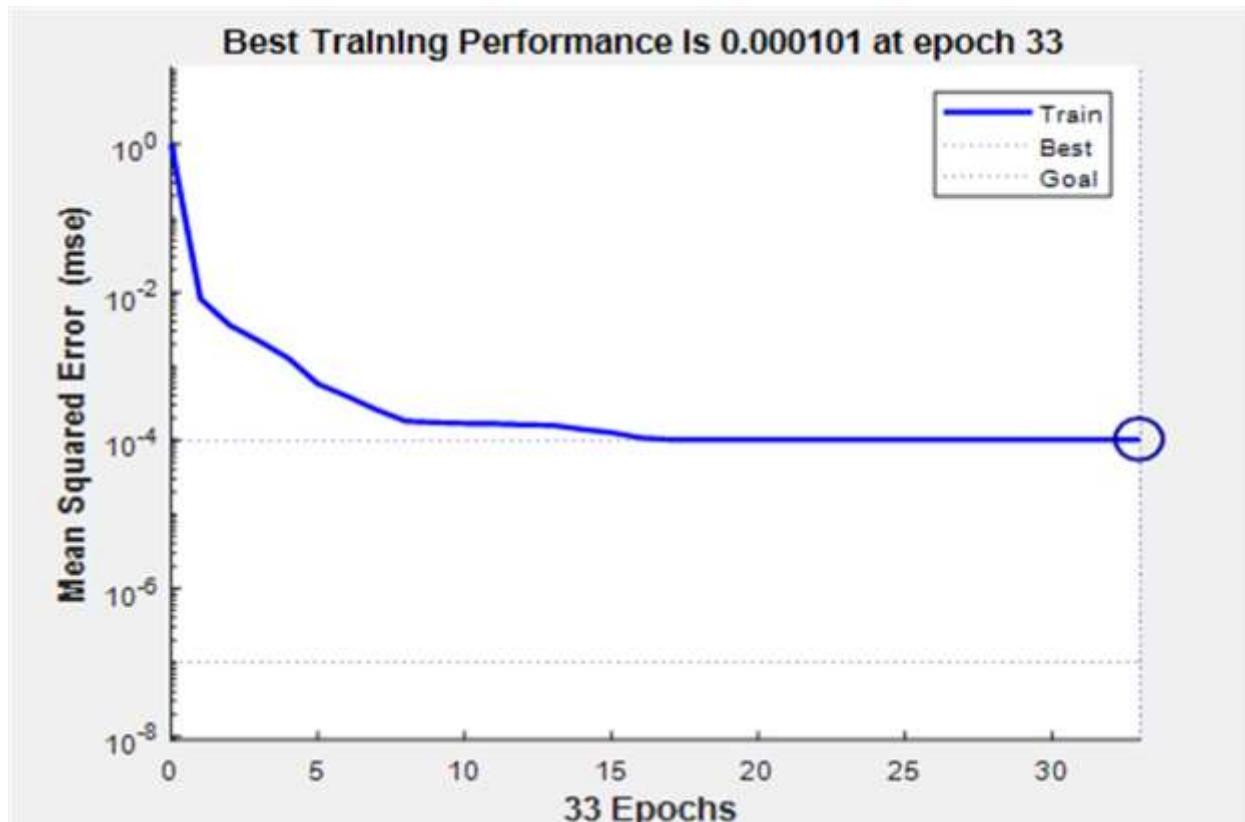
الاتحراف المعياري	الوسط الحسابي	نوع المتغير	المتغيرات
4893605792.32	2111343563.76	متغير معتمد	القيمة المتداولة
7215980308.15	2985467759.23	متغير توضيحي	عدد الاسهم
156.17	395.40	متغير توضيحي	الصفقات
4.97	29.02	متغير توضيحي	الشركات المتداولة

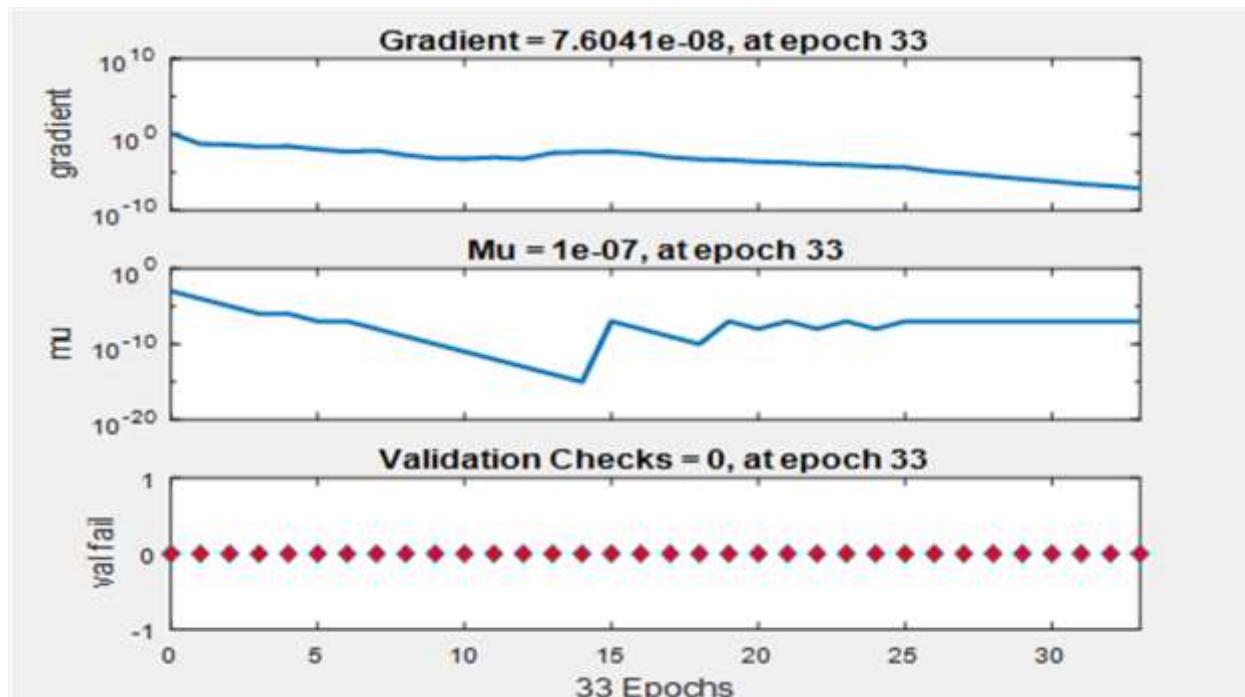
حيث كانت مدخلات الشبكة اربعة (متغير معتمد وثلاث متغيرات توضيحية) وهي القيمة المتداولة، عدد الاسهم، الصفقات، الشركات المتداولة وتضمنت البيانات لجميع الجلسات اليومية من بداية عام 2018 م ولغاية شهر العاشر 2021 م وقد تم تحديد العقد المخفية (4) وتم الحصول على النتائج التالية:

جدول (2): نتائج تطبيق (ANN) لمؤشر القيمة المتداولة

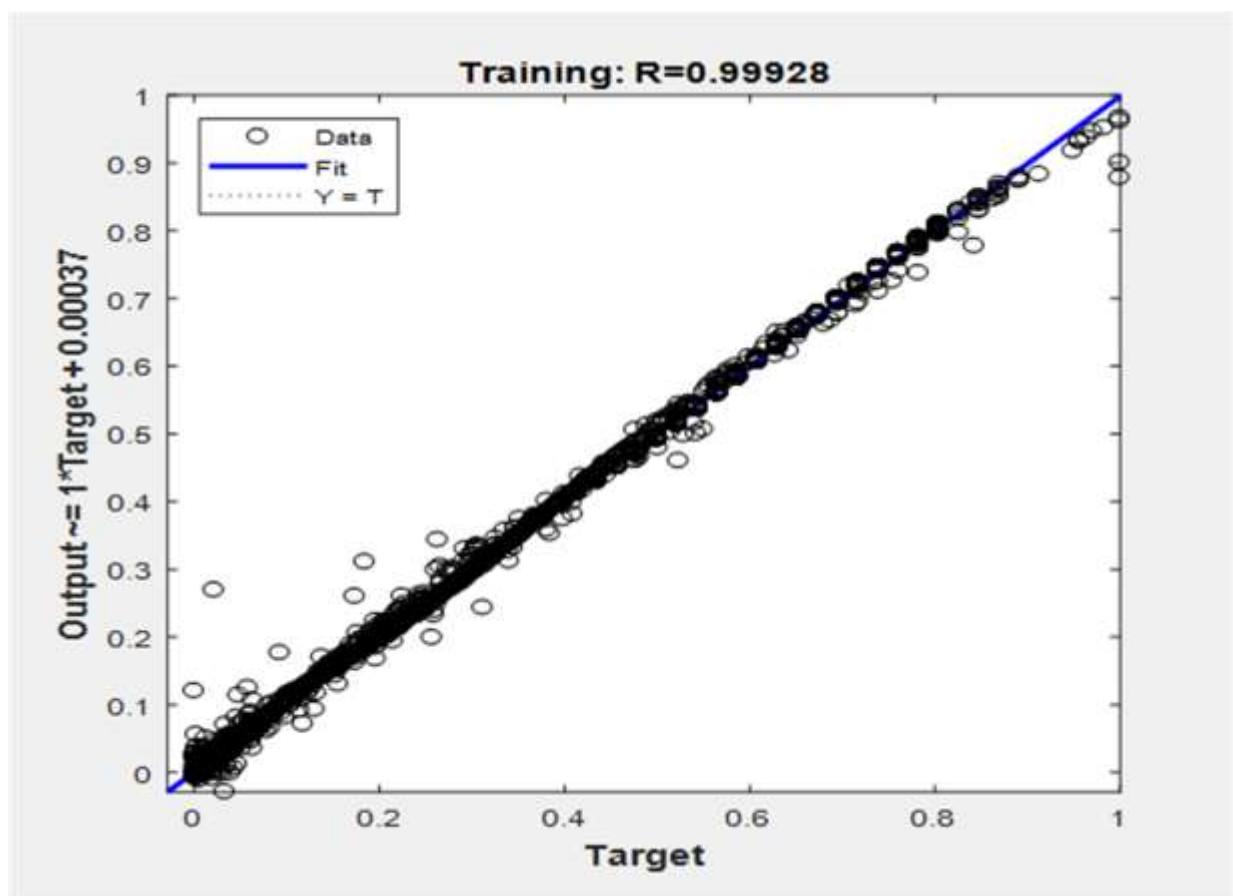
المتوسط العام للأخطاء	الشركات المتداولة	الصفقات	عدد الاسهم	القيمة المتداولة	
0.0856	0.0970	0.0524	0.1011	0.0921	متوسط الاخطاء
	3	1	4	2	الرتبة

من خلال الجدول (2) وبالمقارنة مع المتوسط العام للأخطاء تبين وجود اخطاء طفيفة جداً عند التنبؤ بمؤشرات سوق العراق للأوراق المالية من خلال مؤشرات القيمة المتداولة وكان أعلى خطأ في عدد الاسهم ويليه الشركات المتداولة ويليه القيمة المتداولة ويليه الصفقات، والشكل (1) يبين معمارية الشبكة العصبية ونلاحظ أعلى تكرار في ترتيب الشبكة كان (33).

**شكل (2): رسم بياني يوضح قيمة (Best Training Performance) لمؤشر القيمة المتداولة**



شكل (3): يوضح قيم درجة الميل (Gradient) و افضل متوسط (Mu) و فحص درجة التحقق



شكل (4) رسم بياني يوضح قيمة معامل التحديد (R) لممؤشر القيمة المتداولة

ومن خلال الاشكال (2)، (3)، (4) نلاحظ انتشار البيانات في خط الانحدار وبلغت قيمة معامل التحديد ($R=0.99928$) اي نسبة المساهمة للمتغيرات المستقلة في المتغير التابع وهذا يعني بان المتغيرات غير المسيطر عليها بلغت (0.00072) وهي نسبة قليلة جداً، اما متوسط مربعات الخطأ فقد بلغ (0.0000001) وهو قليل جداً وهذا يدل على دقة التنبؤ.

8. الاستنتاجات

من الاستنتاجات التي تم التوصل إليها من خلال نتائج هذا البحث :

1. ان أسلوب الشبكات العصبية ذو كفاءة ودقة عالية في التنبؤ بمؤشرات سوق العراق للأوراق المالية حيث ان قيمة متوسط مربعات الخطأ لمؤشر القيمة المتداولة باستعمال الشبكات العصبية الاصطناعية قليل جداً وهذا دليل على جودة ودقة اسلوب الشبكات العصبية الاصطناعية .
2. ان تحليل البيانات باستعمال الشبكات العصبية الاصطناعية يحتاج إلى وقت وجهد أقل مما تحتاجه طرق التنبؤ الكلاسيكية كالموزج الانحدار الخطي المتعدد حيث يحتاج الى عدة إفتراضات خاصة بتقدير معالم الانموذج باستعمال المربيات الصغرى الاعتيادية والى اختبارات مهمة كي تستطيع تقدير المعالم، منها اختبار مشكلة التعدد الخطي واختبار وجود مشكلة الارتباط الذاتي واختبار تجانس الاخطاء، بينما اسلوب الشبكات العصبية لا يحتاج الى تلك الافتراضات .
3. للحصول على نتائج أكثر دقة باستعمال الشبكات العصبية الاصطناعية يجب الإهتمام باختيار معمارية مناسبة للشبكة تتمثل بعد متغيرات الإدخال وعقد الطبقية المخفية ودوال التنشيط المستعملة لمعالجة البيانات في هذه العقد وتحديد التدريب الذي يعطي أقل قيمة للخطأ .
4. قررة الشبكة العصبية الاصطناعية على التعامل مع أعداد كبيرة من المشاهدات بعدد وحجم مختلف من متغيرات الإدخال فضلاً عن تعاملها مع العلاقات الخطية وغير الخطية في عملية التدريب ولعدة مرات.

9. التوصيات

1. وضع استراتيجيات طويلة وقصيرة الامد للشركات المساهمة في سوق العراق للأوراق المالية من أجل التغلب على النبذيات الحادة في مؤشرات السوق.
2. توظيف الطرائق الذكية كالشبكات العصبية الاصطناعية في التنبؤ للحصول على نتائج تنبؤية أكثر دقة وسرعة عالية.
3. استعمال أسلوب السلسل الزمنية مع الشبكات العصبية الاصطناعية للتنبؤ والمقارنة، خاصة لمؤشرات السوق التي يصعب الحصول على قيم (بيانات) لمتغيراتها.

المصادر

- [1] Saleh. R & Salman .M ,(2022),”Comparison of some artificial neural networks for graduate students” Periodicals of Engineering and Natural Sciences Original Research Vol. 10, No. 3, June 2022, pp.187-196
- [2] Al Shaye, Qeethara K., (2017),” Neural Networks to Predict Stock Market Price”, Proceedings of the World Congress on Engineering and Computer Science, Vol. (I), San Francisco, USA.
- [3] HAMID, S. A. & IQBAL, Z.,(2004),” Using Neural Networks for Forecasting Volatility of S&P500 Index Futures Prices” , Journal of Business Research 57, 2004, 1116 – 1125.
- [4] Kaastra3, lebeling & Boyd, Milton,(1996), " Designing a neural network for forecasting financial and economic time series "
- [5] Panda, C.&Narasimhan, V.,(2006),” Predicting Stock Return: An Experiment of the Artificial Neural Network in Indian Stock Market”, South Asia Economic Journal, Vol. (7), No. (2), p.p. 205-218.
- [6] Qwaider, Walid, (2012),” Finance Stock Price Prediction by Artificial Neural Networks; A Study of Jordanian's Stock Prices (J.S.P)” ,International Conferences on Business Intelligence and Knowledge Economy, Al Zaytoonah University of Jordan, Amman, Jordan.
- [7] Rameshkumar G.P. &Samundeswari S.,(2014),” Neural Network, Artificial Neural Network (ANN) and Biological Neural Network (BNN) in Soft Computing” , International Journal of Engineering Sciences & Research Technology, March, 2014.
- [8] Sutheebanjard, P. &Premchaiswadi, W.,(2010),” Stock Exchange of Thailand Index Prediction Using Back Propagation Neural Networks”, Second International Conference on Computer and Network Technology, p.p 377-380.
- [9] Vahedi, A., (2012),” The Predicting Stock Price Using Artificial Neural Network”, Journal of Basic and Applied Scientific Resarch, Vol. (2), No. (3), p.p. 2325-2328.

AL- Rafidain
University College

PISSN: (1681-6870); EISSN: (2790-2293)

**Journal of AL-Rafidain
University College for Sciences**Available online at: <https://www.jrucs.iq>**JRUCS**Journal of AL-Rafidain
University College
for Sciences**Predicting the Traded Value Index for the Iraqi Stock Market Using
Artificial Neural Networks****Noor Z. Sabri**noorzuhair2020@gmail.comCollege of Engineering, University of Baghdad,
Baghdad, Iraq**Rabab A. Saleh**rabab.saleh@codecuobaghdad.edu.iqCollege of Administration and Economics,
University of Baghdad, Baghdad, Iraq**Article Information****Article History:**

Received: February, 19, 2024

Accepted: April, 12, 2024

Available Online: December, 31,
2024**Keywords:**Neural networks, back propagation
algorithm, rolling value**Abstract**

Prediction is one of the important topics in statistical sciences to help leaders develop future plans and make appropriate decisions for them. This research includes one of the modern prediction methods represented by artificial neural network (ANN) models, specifically the multi-layer network, as the back propagation (BP) algorithm was adopted and trained several times to get the lowest error value.

The research aims to predict an important indicator of the Iraqi Stock Exchange, which is the traded value index, using one of the scientific methods, which is artificial neural networks, applying the back propagation algorithm and using the (Matlab 2018) program. The researcher concluded that the artificial neural network model gives accurate results by spreading the data in the regression line, and the value of the coefficient of determination reached ($R = 0.99928$), and the mean square error reached (0.0000001), which is very small, and this indicates the accuracy of the prediction. Daily data was collected for the traded value index for the period from January 2, 2018, until October 31, 2021.

Correspondence:**Rabab A. Saleh**rabab.saleh@codecuobaghdad.edu.iqDOI: <https://doi.org/10.55562/jrucs.v56i1.20>