

التنبؤ بأسعار الاغلاق اليومية لمصرف بغداد في سوق العراق للأوراق المالية

باستعمال الشبكات العصبية الاصطناعية

أ.م.د فراس أحمد محمد / جامعة بغداد / كلية الادارة والاقتصاد / قسم الإحصاء

الباحث / منير شهاب أحمد العكدي / كلية الادارة والاقتصاد / قسم الإحصاء

مستخلص البحث:

تعاني بعض الظواهر من وجود حالة من الفوضوية وعدم الاستقرار في بياناتها نتيجة للتطور الكبير الحاصل في تكنولوجيا المعلومات، والذي أدى بدوره إلى وجود كميات كبيرة من البيانات في قواعد البيانات، مما أدى إلى وجود أنماط عديدة كامنة في تلك البيانات، وتعتبر عملية تحديد تلك الأنماط واستخلاص المعلومات المفيدة والمعرفة الكامنة في تلك البيانات من المشاكل الرئيسية والمهمة وذلك نظراً إلى أهميتها في عملية التنبؤ.

لذا برزت الحاجة إلى معرفة وتحديد تلك الأنماط، واستعمال هذه الأنماط في عملية التنبؤ.

وعلى هذا الأساس تم اللجوء إلى استعمال بعض التقنيات الحديثة والمرنة في ذلك المجال ألا وهي الشبكات العصبية الاصطناعية، وبالتحديد شبكة الانتشار العكسي للخطأ، والتي تستعمل خوارزمية الانتشار العكسي للخطأ في تحديث (تدريب) أوزان الشبكة العصبية الاصطناعية.

ومن خلال ما افرزته النتائج في الجانب التطبيقي، وبعد أن تم بناء مجموعة من نماذج الشبكات العصبية الاصطناعية بمتغيرات بازاحات مختلفة وبعدد مختلفة في الطبقة الخفية، تم التوصل إلى أن أفضل انموذج لغرض التنبؤ هو الانموذج NN(1,2,12,13;8)، إذ امتلك ذلك الانموذج أقل القيم للمقاييس الإحصائية (AIC)، (BIC)، و(SBC)، بالإضافة إلى أن الزمن الذي استغرقه الانموذج في عملية التدريب هو أقل من باقي النماذج، إذ بلغ عدد مرات تدريب ذلك الانموذج (80) تكرار.

كما تم التوصل إلى أفضلية وأمثلية ذلك الانموذج لغرض التنبؤ بعد تقييمه بالاعتماد على بعض المقاييس الإحصائية مثل معامل التحديد (R^2)، وعدد الدورات (Epochs)، وأفضل تقييم تدريب للانموذج (Best Training Performance).

المصطلحات الرئيسية للبحث: الشبكات العصبية الاصطناعية، شبكة الانتشار العكسي للخطأ، خوارزمية الانتشار العكسي للخطأ، التنبؤ، سوق العراق للأوراق المالية، مصرف بغداد.



1. المقدمة (Introduction)

تعاني بعض الظواهر من وجود حالة من الفوضوية وعدم الاستقرار في بياناتها نتيجةً للتطور الكبير الحاصل في تكنولوجيا المعلومات، والذي أدى بدوره إلى وجود كميات كبيرة من البيانات في قواعد البيانات، مما أدى إلى وجود أنماط عديدة كامنة في تلك البيانات، وتعتبر عملية تحديد تلك الأنماط واستخلاص المعلومات المفيدة والمعرفة الكامنة في تلك البيانات من المشاكل الرئيسية والمهمة وذلك نظراً إلى أهميتها في عملية التنبؤ.

لذا برزت الحاجة إلى معرفة وتحديد تلك الأنماط، واستعمال هذه الأنماط في عملية التنبؤ. وتعتبر الشبكات العصبية الاصطناعية (Artificial Neural Networks) من التقنيات الحديثة والمهمة في ذلك المجال والتي تتميز بمرونتها العالية في التعامل مع السلاسل الزمنية، وذلك بسبب عدم حاجتها إلى التقيد بالشروط الواجب توفرها في نماذج السلاسل الزمنية التقليدية، مثل الاستقرار، واستقلالية الأخطاء، والتوزيع الطبيعي لتلك الأخطاء، كما يلاحظ ذلك في نماذج بوكس - جنكنز، وغيرها من نماذج السلاسل الزمنية التقليدية الأخرى، لكونها من النماذج اللامعلمية.

2. هدف البحث (Research Objective)

يهدف البحث إلى معرفة وتحديد الأنماط الكامنة الأكثر كفاءة من بيانات العينة قيد الدراسة واستعمال هذه الأنماط في عملية التنبؤ، ويتم ذلك من خلال استعمال الشبكات العصبية الاصطناعية (Artificial Neural Networks)، وبالتحديد شبكة الانتشار العكسي للخطأ (Error Back Propagation Neural Network)، والتي تستعمل خوارزمية الانتشار العكسي للخطأ (Error Back Propagation Algorithm) في تحديث أوزان الشبكة العصبية الاصطناعية.

3. الجانب النظري (Theoretical Side)

في هذا القسم من البحث، سيتم التعرف على مفهوم السلسلة الزمنية، كما سيتم التعرف على مفهوم الشبكات العصبية الاصطناعية وأصنافها، ومن ثم سيتم التعرف على شبكة الانتشار العكسي للخطأ والتي تستعمل خوارزمية الانتشار العكسي للخطأ في تدريب أوزان الشبكة العصبية الاصطناعية.

1-3 السلسلة الزمنية (Time Series)

هي مجموعة من المشاهدات أو القيم التي تخص ظاهرة معينة وتكون مرتبة حسب الزمن، وتكون هذه المشاهدات غير مستقلة، أي أنها تكون معتمدة على بعضها البعض، وتصنف السلاسل الزمنية حسب نوع المشاهدات إلى نوعين، السلسلة الزمنية المتقطعة وهي السلسلة الزمنية التي تكون فيها الفترة الزمنية بين مشاهدة وأخرى متساوية، ومن أمثلتها تسجيل أسعار الاغلاق اليومية في سوق الأوراق المالية، وتسجيل درجات الحرارة في ساعة معينة، والسلسلة الزمنية المستمرة وهي السلسلة الزمنية التي تتولد فيها المشاهدات عند جميع النقاط في فترة زمنية معينة، ومن أمثلتها الرصد الزلزالي [1, pp.10].

2-3 الشبكات العصبية الاصطناعية (Artificial Neural Networks)

تعتبر الشبكات العصبية الاصطناعية من أدوات التنقيب عن البيانات والتي تستعمل لأغراض التصنيف والتنبؤ، كما أنها تعتبر إحدى أهم تطبيقات الذكاء الاصطناعي (Artificial Intelligence)، ويرمز لها اختصاراً بالرمز (ANN).


سميت الشبكات العصبية الاصطناعية بذلك الاسم وذلك لأن عملها يماثل عمل الدماغ البشري المكون من حوالي ألف مليار خلية عصبية من حيث اكتساب المعرفة وتخزين تلك المعرفة [2, pp.1].



ظهرت الشبكات العصبية الاصطناعية لأول مرة في أربعينيات القرن الماضي على يد العالمين (McCulloch) و (Pitts)، ثم تطورت في ثمانينيات القرن الماضي على يد العلماء (Hopfield)، (Werbose)، و (Rumelhart)، واستمرت في التطور منذ ذلك الوقت وإلى يومنا هذا على يد العديد من العلماء أبرزهم (Lippmann)، (Zupan)، (Gasteiger)، وآخرون [3, pp.199]. تتألف أي شبكة عصبية اصطناعية من العديد من الخلايا العصبية الاصطناعية التي تقوم بنقل البيانات الداخلة إليها إلى الخلايا العصبية الاصطناعية المجاورة عن طريق الأوزان والتي تمثل الارتباطات التي تربط تلك الخلايا مع بعضها البعض [4, pp.158]. يمكن تعريف الشبكة العصبية الاصطناعية على أنها نظام حسابي هائل ومعقد مكون من العديد من وحدات المعالجة البسيطة المترابطة فيما بينها والتي لها القدرة على معالجة البيانات الداخلة إليها مما يمكن ذلك النظام من اكتساب وخزن واستعمال المعرفة التجريبية [2, pp.21-22]. تعد الشبكات العصبية الاصطناعية من النماذج غير الخطية وتتميز بمرونتها العالية عند التطبيق وذلك لكونها من طرق التقدير اللامعلمي، كما تتميز بدقتها العالية من حيث التنبؤ لذلك تستعمل بشكل واسع في العديد من المجالات مثل المجال الطبي والهندسي والمالي وغيرها من المجالات الأخرى [5, pp.1-2]. تصنف الشبكات العصبية الاصطناعية من حيث عدد طبقاتها إلى نوعين رئيسيين وهي [6, pp.14-15] [15]:


1. الشبكات العصبية أحادية الطبقة (Single Layer Neural Networks)

وهي الشبكات التي لا تمتلك طبقة خفية وتتكون من طبقة واحدة من الأوزان، أي أن طبقة المدخلات ترتبط مباشرة بطبقة المخرجات عن طريق الأوزان.



2. الشبكات العصبية متعددة الطبقات (Multi Layers Neural Networks)

وهي الشبكات التي تتكون من طبقة واحدة أو أكثر من الطبقات الخفية بالإضافة إلى كل من طبقة المدخلات وطبقة المخرجات، وتمتاز هذه الشبكات بحل مشاكل أكثر تعقيداً من تلك التي تحلها الشبكات العصبية أحادية الطبقة بسبب وجود الطبقات الخفية التي تعطي مرونة أكبر في بناء الدوال الناقلة بين طبقة المدخلات وطبقة المخرجات، وقد اختلفت الآراء حول تحديد عدد الخلايا العصبية الاصطناعية في الطبقة (الطبقات) الخفية، ولكن أغلب الآراء أجمعت على أن عدد العقد العصبية الاصطناعية أو الخلايا العصبية الاصطناعية يتم تحديدها بالاعتماد على التجربة والخبرة في ذلك المجال.



إن عمل الخلية العصبية الاصطناعية أو العصبون الاصطناعي يشبه إلى حد كبير عمل الخلية العصبية البيولوجية، إذ تقوم الخلية العصبية البيولوجية بنقل الإشارات الداخلة إليها إلى الخلايا العصبية المجاورة لها، وكذلك الحال بالنسبة للخلية العصبية الاصطناعية، إذ تقوم بنقل البيانات الداخلة إليها إلى الخلايا العصبية الاصطناعية المجاورة لها [3, pp.200].

وبشكل عام تتكون أي خلية عصبية اصطناعية من أربعة أقسام رئيسية وهي [32] [4, pp.159]:

1. قنوات الإدخال (Synapse): وهي القنوات التي عن طريقها تستلم الخلية العصبية الاصطناعية الإشارات (البيانات) القادمة إليها من الخلايا العصبية الاصطناعية المرتبطة بها وتسمى تلك الإشارات بالمدخلات.

2. دالة الجمع (Summation Function): وهي الدالة التي تقوم بجمع (توحيد) الإشارات الداخلة إلى الخلية العصبية الاصطناعية في إشارة واحدة، وتأخذ الشكل التالي:

$$Net_j = \sum_{i=0}^n w_{ji} z_{ji}$$

$$= w_{j0} z_{j0} + w_{j1} z_{j1} \dots \dots \dots + w_{jn} z_{jn} \dots \dots \dots (3 - 1)$$


z_{ji} : تمثل الإشارة أو القيمة (i) التابعة للعقدة (j).
 w_{ji} : يمثل الوزن الناقل للإشارة أو القيمة (i) التابعة للعقدة (j).
 z_0 : تمثل إشارة أو قيمة ثابتة (Bias) وتكون مساوية إلى (1).

3. دالة التنشيط (Activation Function): وهي الدالة التي تقوم بمعالجة البيانات الداخلة إلى الخلية العصبية الاصطناعية، وهناك العديد من دوال التنشيط المختلفة والتي تختلف تبعاً لاختلاف نوعية المخرجات التي يتم الحصول عليها وأهداف الشبكة العصبية الاصطناعية التي تسعى إلى تحقيقها، ومن أهم هذه الدوال وأكثرها شيوعاً الدالة السينية (Sigmoid Function)، والتي تأخذ الشكل التالي:

$$Sigmoid(x) = \frac{1}{1 + exp^{-x}} \dots \dots \dots (3 - 2)$$

تعتبر الدالة السينية من الدوال غير الخطية وتأخذ قيم المدخلات المحصورة بين $(-\infty, +\infty)$ وتكون مخرجاتها محصورة بين $(0, 1)$ ، وتعد الدالة السينية من أكثر دوال التنشيط استعمالاً في الشبكات العصبية الاصطناعية وذلك لسهولة اشتقاقها بالإضافة لكونها تمتاز بسهولة الحساب والتنفيذ.

4. قناة الإخراج (Axone Paths): وهي القناة التي تقوم بإرسال إشارة الإخراج إلى الخلايا العصبية الاصطناعية الأخرى وتسمى تلك الإشارة بالمخرجات.



4-3 شبكة الانتشار العكسي للخطأ

(Error Back Propagation Neural Network)

تم اقتراح هذا النوع من الشبكات من قبل العلماء (Rumelhart)، (Hinton)، و(Williams) في عام 1986م [2, pp.25-26].

تعتبر شبكة الانتشار العكسي للخطأ من الشبكات العصبية الاصطناعية متعددة الطبقات وتتكون معمارية الشبكة من ثلاث طبقات وهي كالآتي [6, pp.17][8, pp.58][9, pp.342-343]:

1. **طبقة المدخلات (Input Layer):** إن عدد العقد العصبية الاصطناعية أو الخلايا العصبية الاصطناعية في هذه الطبقة يعتمد على عدد ونوع المتغيرات في قاعدة البيانات، وعموماً يتم تحديد عدد مدخلات الشبكة العصبية الاصطناعية في النموذج السلاسل الزمنية بالاعتماد على الصيغة الموصوفة بدلالة المتغيرات المزاحة زمنياً أي المتغيرات المتخلفة زمنياً.

2. **الطبقة الخفية (Hidden Layer):** في معظم التطبيقات الخاصة بنماذج التنبؤ باستعمال الشبكات العصبية الاصطناعية يفضل استعمال طبقة خفية واحدة، وإن كفاية استعمال الطبقة الخفية الواحدة قد تم برهانه من خلال نظرية (Kolmogorov's Superposition Theorem)، أما عدد العقد العصبية الاصطناعية في الطبقة الخفية فإنه لا يوجد عدد محدد وثابت، إذ يجب أن يتم اختيار عدد العقد العصبية الاصطناعية في تلك الطبقة بحذر وعناية شديدين، فالعدد القليل من العقد يؤدي إلى الحصول على عدد قليل من الأوزان (المعالم) وبالتالي يؤدي إلى تقدير خاطئ للنموذج مما يؤدي إلى الحصول على نتائج غير دقيقة، أما العدد الكبير من العقد فإنه يؤدي إلى الحصول على عدد كبير من الأوزان (المعالم) وبالتالي يؤدي إلى المغالاة في عملية التقدير (Overestimation)، أي الحصول على تقدير جيد ولكنه ليس الأفضل من ناحية التنبؤ، وعموماً توجد هنالك العديد من المعايير المستعملة في عملية اختيار العدد المناسب من العقد العصبية الاصطناعية في تلك الطبقة ومن أهمها:

أ. معيار (AIC)

ويسمى أيضاً معيار معلومة أكيكي (Akaike Information Criterion)، ويتم حساب هذا المعيار وفق الصيغة الرياضية التالية:

$$AIC = nk \ln(\sigma_e^2) + 2s \dots \dots \dots (3 - 3)$$

n : عدد البيانات المقدرة.

k : عدد العقد في طبقة المخرجات.

s : عدد الأوزان (المعالم) في نموذج الشبكة العصبية الاصطناعية.

ب. معيار (BIC)

ويسمى أيضاً معيار معلومة بيز (Bayesian Information Criterion)، ويتم حساب هذا المعيار وفق الصيغة الرياضية التالية:

$$BIC = nk \ln(\sigma_e^2) - (n - s) \ln\left(1 - \frac{s}{n}\right) + s \ln(n) + s \ln\left[\frac{\sigma_x^2}{\sigma_e^2} - 1/s\right] \dots \dots \dots (3 - 4)$$

ج. معيار (SBC)

ويتم حساب هذا المعيار وفق الصيغة الرياضية التالية:

$$SBC = nk \ln(\sigma_e^2) + s \ln(n) \dots \dots \dots (3 - 5)$$

إن انموذج الشبكة العصبية الاصطناعية بعدد عقد معين في الطبقة الخفية والذي يمتلك أقل قيمة للمعايير الثلاثة أعلاه يكون هو الأفضل ويتم اختياره واستعماله لغرض التنبؤ.

3. طبقة المخرجات (Output Layer): يختلف عدد العقد العصبية الاصطناعية أو الخلايا العصبية الاصطناعية في طبقة المخرجات باختلاف الهدف الذي تسعى الشبكة العصبية الاصطناعية إلى تحقيقه، وعموماً يكون عدد العقد في تلك الطبقة عقدة واحدة إذا كان هدف الشبكة هو التنبؤ بخطوة واحدة إلى الأمام.

3-4-1 منهجية الانتشار العكسي للخطأ

(Error Back Propagation Methodology)

تتلخص منهجية الانتشار العكسي للخطأ (EBP) بإيجاد خطأ التنبؤ (Prediction Error)، ومن ثم يتم ارجاع هذا الخطأ عكسياً من طبقة المخرجات إلى الطبقة الخفية ثم إلى طبقة المدخلات، وأثناء هذا الارتداد العكسي يتم تحديث (تعديل) الأوزان، وبعد ذلك يتم حساب مخرجات الشبكة العصبية الاصطناعية بالأوزان الجديدة، وهكذا تستمر العملية في حساب خطأ التنبؤ وتحديث الأوزان إلى أن يتم الوصول إلى الأوزان المثلى والتي باستعمالها في تقدير مخرجات الشبكة العصبية الاصطناعية نحصل على أقل خطأ ممكن [2,pp.48].

3-4-2 طريقة النزول المتدرج (Gradient – Descent Method)

تعتبر طريقة النزول المتدرج الطريقة الأساسية المعتمدة في إيجاد مجموعة من الأوزان المثلى والتي باستعمالها نحصل على أقل خطأ تدريب ممكن لانموذج الشبكة العصبية الاصطناعية، ولتوضيح ذلك نفرض أن لدينا (m) من الأوزان المستعملة في انموذج الشبكة العصبية الاصطناعية ونرغب في إيجاد القيم الخاصة بتلك الأوزان والتي باستعمالها نحصل على أقل خطأ تدريب ممكن، نستطيع استعمال طريقة النزول المتدرج لحل تلك المشكلة، إذ توفر لنا تلك الطريقة الاتجاه الذي يجب اتباعه لتعديل الأوزان بالشكل الذي يجعل من خطأ التدريب أقل ما يمكن، وذلك كما يلي [9,pp.346-347][10,pp.89-91]:

$$E(w) = \frac{1}{2} \sum_{i=1}^n (t_i - o_i)^2 \dots \dots \dots (3 - 6)$$

$E(w)$: يمثل خطأ التدريب.

t_i : القيمة المستهدفة للملاحظة (i).

o_i : القيمة التقديرية للملاحظة (i).



بأخذ المشتقة لخطأ التدريب بالنسبة لكل وزن من الأوزان المستعملة في نموذج الشبكة العصبية الاصطناعية، وذلك كما يلي:

$$\nabla E(w) = \left[\frac{\partial E}{\partial w_0}, \frac{\partial E}{\partial w_1}, \dots, \frac{\partial E}{\partial w_m} \right] \dots \dots \dots (3-7)$$

$\nabla E(w)$: يمثل متجه لمجموعة من المشتقات الجزئية الخاصة بخطأ التدريب بالنسبة لكل وزن من الأوزان المستعملة في نموذج الشبكة العصبية الاصطناعية.

$\frac{\partial E}{\partial w_0}$: تمثل المشتقة الجزئية لخطأ التدريب بالنسبة للوزن (w_0) أي إنها تمثل الميل الخاص بخطأ التدريب عند ذلك الوزن، وهكذا بالنسبة لبقية الأوزان.

إن المعادلة (3-7) أعلاه تمثل الاتجاه الذي يجعل من خطأ التدريب أكبر ما يمكن، وللحصول على الاتجاه الذي يجعل من خطأ التدريب أقل ما يمكن يتم ضرب المعادلة (3-7) بالإشارة (-).
باستعمال المعادلة (3-7) تم وضع قانون لتعديل الأوزان، وذلك كما يلي:

$$w_{new} = w_{current} + \Delta w_{current} \dots \dots \dots (3-8)$$

w_{new} : يمثل الوزن الجديد.

$w_{current}$: يمثل الوزن الحالي.

$\Delta w_{current}$: يمثل مقدار التغير في الوزن المستعمل في نموذج الشبكة العصبية الاصطناعية، أي المشتقة الجزئية لخطأ التدريب بالنسبة للوزن الحالي مضروب في الإشارة (-)، ويمكن كتابته بالشكل التالي:

$$\Delta w_{current} = - \frac{\partial E}{\partial w_{current}} \dots \dots \dots (3-9)$$

لكن إلى أي مدى يجب تعديل الوزن الحالي بالنسبة إلى الاتجاه الخاص بـ $(-\frac{\partial E}{\partial w_{current}})$ ، ولحل هذه المشكلة يتم ضرب المعادلة (3-9) بمقدار موجب صغير عادةً تتراوح قيمته بين (0,1) يسمى بمعدل التعلم (Learning Rate) ويرمز له بالرمز (η) فتكون النتيجة كما يلي:

$$\Delta w_{current} = -\eta \left(\frac{\partial E}{\partial w_{current}} \right) \dots \dots \dots (3-10)$$

بتعويض المعادلة (3-10) في المعادلة (3-8) يصبح القانون بالشكل التالي:

$$w_{new} = w_{current} + \left[-\eta \left(\frac{\partial E}{\partial w_{current}} \right) \right] \dots \dots \dots (3-11)$$

إن المعادلة (11 - 3) أعلاه هي المعادلة التي اعتمد عليها (Tom Mitchell) في اشتقاق القوانين الخاصة بتعديل الأوزان الخاصة بطبقة المخرجات والطبقة الخفية في نموذج الشبكة العصبية الاصطناعية كما سيتم التعرف على ذلك لاحقاً.

3-4-3 عملية تدريب شبكة الانتشار العكسي للخطأ

(Error Back Propagation Network Training Process)

إن عملية تدريب أو تعلم شبكة الانتشار العكسي للخطأ تعني تغيير أوزان الاتصال بين الخلايا العصبية الاصطناعية المتصلة مع بعضها البعض، وتبدأ عملية التدريب بادخال البيانات إلى الشبكة، إذ تتعلم الشبكة على الخصائص والمزايا لهذه البيانات، ونتيجة لهذا التدريب نحصل على الأوزان المثلى والتي تعطي أفضل تقدير لمخرجات الشبكة العصبية الاصطناعية [2,pp.47].

إن الهدف من عملية التدريب هو الحصول على أقل خطأ تدريب ممكن وبالنتيجة نحصل على الأوزان المثلى والتي يتم اعتمادها في عملية التنبؤ لبيانات جديدة لم تخضع للتدريب أو التعلم سابقاً، أما بالنسبة لقيم الأوزان الابتدائية (Initial Weights) المستعملة في بداية عملية التدريب فتؤخذ كقيم عشوائية (عادة بين الصفر والواحد) [2,pp.47-48].

أما كيفية تدريب (تحديث أو تغيير) الأوزان الخاصة بنموذج الشبكة العصبية الاصطناعية فقد قام (Tom Mitchell) باشتقاق القوانين الخاصة بتعديل تلك الأوزان بالاعتماد على طريقة النزول المتدرج (Gradient - Descent Method) وباستعمال الدالة السينية (Sigmoid Function)، إذ لكل مشاهدة (d) يتم تحديث الوزن (w_{ji}) بإضافة المقدار (Δw_{ji})، وذلك كما يلي [10,pp.101-103]:

$$\Delta w_{ji} = -\eta \left(\frac{\partial E_d}{\partial w_{ji}} \right) \dots \dots \dots (3 - 12)$$

w_{ji} : يمثل الوزن الخاص بالمدخل (i) إلى العقدة (j).

E_d : يمثل خطأ التدريب الخاص بالمشاهدة (d)، ويتم حسابه كما يلي:

$$E_d(w) = \frac{1}{2} \sum_{k=1}^m (t_k - o_k)^2$$

m: يمثل عدد العقد العصبية الاصطناعية في طبقة المخرجات في نموذج الشبكة العصبية الاصطناعية.

t_k : تمثل القيمة المستهدفة التابعة للعقدة (k).

o_k : تمثل القيمة التقديرية التابعة للعقدة (k).

بما أن الوزن (w_{ji}) يؤثر على الشبكة العصبية الاصطناعية من خلال العقدة (j) لذلك نستطيع كتابة $\left(\frac{\partial E_d}{\partial w_{ji}} \right)$ بالشكل الآتي:

$$\begin{aligned}\frac{\partial E_d}{\partial w_{ji}} &= \frac{\partial E_d}{\partial net_j} \frac{\partial net_j}{\partial w_{ji}} \\ &= \frac{\partial E_d}{\partial net_j} x_{ji} \dots \dots \dots (3 - 13)\end{aligned}$$

هناك حالتان لاشتقاق $(\frac{\partial E_d}{\partial net_j})$ ، وهي كما يلي:

الحالة الأولى: وهي الحالة التي تكون فيها العقدة (j) هي عبارة عن عقدة مخرجات أي عقدة في طبقة المخرجات، وفي هذه الحالة يكون الوزن (w_{ji}) يؤثر على الشبكة العصبية الاصطناعية من خلال العقدة (j)، أما العقدة (j) فإنها تؤثر على الشبكة العصبية الاصطناعية من خلال قيمة المخرج (j) أي قيمة (o_j)، لذلك نستطيع كتابة $(\frac{\partial E_d}{\partial net_j})$ بالشكل الآتي:

$$\frac{\partial E_d}{\partial net_j} = \frac{\partial E_d}{\partial o_j} \frac{\partial o_j}{\partial net_j} \dots \dots \dots (3 - 14)$$

في البداية يتم اشتقاق الجزء الأول من المعادلة (3 - 14)، أي $(\frac{\partial E_d}{\partial o_j})$ وذلك كما يلي:

$$\frac{\partial E_d}{\partial o_j} = \frac{\partial}{\partial o_j} \frac{1}{2} \sum_{k=1}^m (t_k - o_k)^2$$

إن المقدار $[\frac{\partial}{\partial o_j} (t_k - o_k)^2]$ يكون مساوياً إلى الصفر في جميع الحالات بالنسبة للعقدة (k) ما عدا الحالة التي يكون فيها ($k = j$)، لذلك يمكن تبسيط المقدار بالشكل الآتي:

$$\begin{aligned}\frac{\partial E_d}{\partial o_j} &= \frac{\partial}{\partial o_j} \frac{1}{2} (t_j - o_j)^2 \\ &= \frac{1}{2} 2(t_j - o_j) \frac{\partial (t_j - o_j)}{\partial o_j} \\ &= -(t_j - o_j) \dots \dots \dots (3 - 15)\end{aligned}$$

أما مشتقة الجزء الثاني من المعادلة (3 - 14) فهو عبارة عن مشتقة الدالة السينية (Sigmoid Function)، ويكون كما يلي:

$$\begin{aligned}\frac{\partial o_j}{\partial net_j} &= \frac{\partial \sigma(net_j)}{\partial net_j} \\ &= o_j(1 - o_j) \dots \dots \dots (3 - 16)\end{aligned}$$



بتعويض المعادلتين (3 - 15) و (3 - 16) في المعادلة (3 - 14)، ينتج ما يلي:

$$\frac{\partial E_d}{\partial net_j} = -(t_j - o_j) o_j (1 - o_j) \dots \dots \dots (3 - 17)$$

أخيراً يتم تعويض المعادلة (3 - 17) في المعادلة (3 - 12) ثم يتم دمجها مع المعادلة (3 - 13)، فينتج ما يلي:

$$\Delta w_{ji} = \eta (t_j - o_j) o_j (1 - o_j) x_{ji} \dots \dots \dots (3 - 18)$$

الحالة الثانية: وهي الحالة التي تكون فيها العقدة (j) هي عبارة عن عقدة موجودة في الطبقة الخفية، وفي هذه الحالة يكون الوزن (w_{ji}) يؤثر على العقد العصبية الاصطناعية الموجودة في طبقة المخرجات والتي توجد أسفل الطبقة الخفية من خلال العقدة (j)، لذلك نستطيع كتابة ($\frac{\partial E_d}{\partial net_j}$) بالشكل الآتي:

$$\begin{aligned} \frac{\partial E_d}{\partial net_j} &= \sum_{k \in \text{Downstream}(j)} \frac{\partial E_d}{\partial net_k} \frac{\partial net_k}{\partial net_j} \\ &= \sum_{k \in \text{Downstream}(j)} -\delta_k \frac{\partial net_k}{\partial net_j} \\ &= \sum_{k \in \text{Downstream}(j)} -\delta_k \frac{\partial net_k}{\partial o_j} \frac{\partial o_j}{\partial net_j} \\ &= \sum_{k \in \text{Downstream}(j)} -\delta_k w_{kj} \frac{\partial o_j}{\partial net_j} \\ &= \sum_{k \in \text{Downstream}(j)} -\delta_k w_{kj} o_j (1 - o_j) \dots \dots \dots (3 - 19) \end{aligned}$$

δ_k : يمثل مقدار ما تساهمه العقدة (k) من الخطأ الخاص بطبقة المخرجات ويسمى بمسؤولية الخطأ.

بتعويض المعادلة (3 - 19) في المعادلة (3 - 12) ثم دمجها مع المعادلة (3 - 13) مع تغيير الرمز (k) إلى الرمز (j)، فينتج ما يلي:

$$\Delta w_{ji} = \eta \delta_j x_{ji} \dots \dots \dots (3 - 20)$$



إن عملية التدريب أو التعلم أعلاه تعد من أكثر طرق التدريب شيوعاً وأكثرها استعمالاً وتسمى بالتعلم المراقب أو التعلم المشرف (Supervised Learning) [2, pp.48].

4-4-3 خوارزمية الانتشار العكسي للخطأ

(Error Back Propagation Algorithm)

وهي الخوارزمية المستعملة في تدريب الشبكة العصبية الاصطناعية، ولكن قبل تدريب الشبكة العصبية الاصطناعية باستعمال تلك الخوارزمية يجب تعديل وتهيئة البيانات، إذ يتم تعديل البيانات لكي تكون ضمن نطاق عمل الدالة السينية (Sigmoid Function) وهي دالة التنشيط المستعملة في انموذج الشبكة العصبية الاصطناعية، ويتم تعديل البيانات وفق الصيغة الطبيعية (Normalized Formula) والتي يمكن حسابها كالآتي [9, pp.339-340]:

$$x_{new} = \frac{x - \min(x)}{\max(x) - \min(x)} \dots \dots \dots (3 - 21)$$

بعد تعديل البيانات يتم تدريب الشبكة العصبية الاصطناعية باستعمال خوارزمية الانتشار العكسي للخطأ والتي يمكن ايجاز خطواتها كالآتي [2, pp.49-51] [9, pp.342-349]:

- توليد قيم أولية عشوائية للأوزان (عادة ما تكون بين 0،1).
- تستقبل كل عقدة في طبقة المدخلات الإشارات أو القيم الداخلة إليها من قاعدة البيانات ثم يتم إرسالها إلى جميع عقد الطبقة الخفية.
- تجمع كل عقدة في الطبقة الخفية الإشارات أو القيم الموزونة الداخلة إليها من طبقة المدخلات باستعمال دالة الجمع (Summation Function).
- يتم إرسال ناتج دالة الجمع لكل عقدة في الطبقة الخفية إلى دالة التنشيط (Activation Function) وذلك لتقدير مخرجات الطبقة الخفية.
- يتم إرسال ناتج دالة التنشيط لكل عقدة من عقد الطبقة الخفية والتي تمثل مخرجات الطبقة الخفية إلى جميع عقد طبقة المخرجات.
- تجمع كل عقدة في طبقة المخرجات الإشارات أو القيم الموزونة الداخلة إليها من الطبقة الخفية باستعمال دالة الجمع.
- يتم إرسال ناتج دالة الجمع لكل عقدة من عقد طبقة المخرجات إلى دالة التنشيط وذلك لتقدير مخرجات طبقة المخرجات.
- يتم حساب خطأ التدريب لكل عقدة في طبقة المخرجات.
- تحديث الأوزان لكل عقدة في طبقة المخرجات ولكل عقدة في الطبقة الخفية بموجب المعادلة (8 - 3).
- تستمر عملية التدريب أو التعلم (تحديث الأوزان) إلى (n) من المرات عادة ما تكون بالآلاف المرات.
- يتم اختيار أفضل توفيق للنموذج بعد انتهاء عملية التدريب أي الشبكة العصبية الاصطناعية التي تعطي أقل قيمة لخطأ التدريب.



5-4-3 معيار التوقف (Stopping Criterion)

هو المعيار المستعمل في إيقاف خوارزمية الانتشار العكسي للخطأ، وهناك العديد من المعايير المستعملة لهذا الغرض، ويعتبر معيار (Epochs) من أكثر هذه المعايير شيوعاً واستعمالاً، إذ يمثل عدد مرات التكرار (Iterations) اللازم للوصول إلى الخطأ المطلوب (أقل خطأ يتم الحصول عليه أثناء عملية التدريب، أو الخطأ المراد الوصول إليه) [2, pp.162][11, pp.9].

6-4-3 تعديل خوارزمية الانتشار العكسي للخطأ

(Error Back Propagation Algorithm Modification)

تتميز خوارزمية الانتشار العكسي للخطأ بكونها بطيئة أثناء التطبيق خصوصاً عندما تمتلك نماذج الشبكات العصبية الاصطناعية عدد كبير من الأوزان المراد تعديلها، لذلك تم وضع العديد من الطرق لتعديل تلك الخوارزمية من أجل الوصول إلى انموذج الشبكة العصبية الاصطناعية الملائم بأقل مدة زمنية، ومن أهم هذه الطرق [8, pp.53][9, pp.351-353]:

• أسلوب معامل الزخم (Momentum Term Procedure)

يمكن تلخيص ذلك الأسلوب بإضافة مقدار صغير تتراوح قيمته بين (0,1) يسمى بمعامل الزخم (Momentum Rate) ويرمز له بالرمز (Mu)، وذلك كالآتي:

$$\Delta w_{current} = -\eta \left(\frac{\partial E}{\partial w_{current}} \right) + \alpha \Delta w_{previous} \dots \dots \dots (3 - 22)$$

$\Delta w_{current}$: يمثل مقدار التغير في الوزن الحالي المستعمل في انموذج الشبكة العصبية الاصطناعية.

$\Delta w_{previous}$: يمثل مقدار التغير في الوزن السابق المستعمل في انموذج الشبكة العصبية الاصطناعية.

α : يمثل معامل الزخم.

يعتبر معامل الزخم كمنقح للأوزان مما يجعل من عملية التدريب ومقدار التغير في الوزن مستقر نسبياً وهذا بدوره يؤدي إلى تقليص مقدار التذبذب في الشبكات العصبية الاصطناعية، فهو يحدد مدى تأثير التغير في الوزن السابق على التغير في الوزن الحالي ويحافظ على البحث عن أقل القيم ضمن مساره وينفس الاتجاه وهذا بدوره يقلل من عدد التكرارات للوصول إلى انموذج الشبكة العصبية الملائم.

5-3 تقييم الانموذج (Model Evaluation)

في هذه المرحلة يتم تقييم الانموذج المختار لغرض التنبؤ ويتم ذلك من خلال تقييم أداء الشبكة العصبية الاصطناعية وحالة التدريب باستعمال بعض المؤشرات الخاصة، وهي كالآتي:

1. معامل التحديد (R^2)

هو مقياس يستعمل لقياس دقة التنبؤ وتنحصر قيمته بين (0,1)، فإذا كانت قيمته تساوي (1) فهذا يعني أن جميع القيم التقديرية (o_i) تقع على خط الانحدار أي أن جميع القيم التقديرية تكون مطابقة للقيم المستهدفة (t_i) مما يدل على أن مهارة طريقة التنبؤ تكون تامة، أما إذا كانت قيمته تساوي (0) فهذا يعني أن جميع القيم التقديرية (o_i) لا تقع على خط الانحدار أي أن جميع القيم التقديرية لا تكون مطابقة للقيم المستهدفة (t_i) مما



يدل على أن مهارة طريقة التنبؤ تكون غير جيدة أي غير كفوءة، ويتم حساب معامل التحديد كالاتي [2,pp.151]:

$$R^2 = \frac{\sum_{i=1}^n (o_i - \frac{t_i}{n})^2}{\sum_{i=1}^n (t_i - \frac{t_i}{n})^2} \dots \dots \dots (3 - 23)$$

2. قيمة (Epochs)

وهي تمثل عدد مرات تكرار (تدريب) الشبكة العصبية الاصطناعية اللازم للوصول إلى الخطأ المطلوب، فكلما قل عدد التكرارات دل ذلك على قلة الوقت المستغرق في عملية تدريب الشبكة العصبية الاصطناعية [11,pp.95].

3. أفضل تقييم تدريب (Best Training Performance)

يتم اختيار أفضل تقييم تدريب للشبكة العصبية الاصطناعية وذلك من خلال اختيار أقل قيمة لخطأ التدريب عند تكرار معين [11,pp.95].

6-3 التنبؤ المستقبلي (Forecasting)

بعد عملية تقييم النموذج المختار لغرض التنبؤ تتم عملية التنبؤ المستقبلي لخطوات لاحقة ومتعددة باستعمال ذلك النموذج، ويتم ذلك من خلال استعمال التغذية الأمامية (Feed Forward) والتي فيها يتم تدريب الشبكة العصبية الاصطناعية ومعالجة البيانات من طبقة المدخلات وصولاً إلى طبقة المخرجات، إذ يعد التنبؤ لخطوة واحدة كمتغير للمدخلات مع إعادة تطبيق نفس معمارية الشبكة العصبية الاصطناعية للتنبؤ بخطوة أخرى وهكذا، وعلى فرض أن لدينا نموذج يتكون من عقدتين في الطبقة الخفية وعقدة واحدة في طبقة المخرجات تتم عملية التنبؤ المستقبلي لخطوة واحدة إلى الإمام وذلك كالاتي [6,pp.24]:

$$\hat{z}_t = b^2 + w_1^2 \left\{ \left(1 + \exp(-b_1^1 - \sum_{j=1}^R w_{1j}^1 \cdot a_j^0) \right)^{-1} \right\} + w_2^2 \left\{ \left(1 + \exp(-b_2^1 - \sum_{j=1}^R w_{2j}^1 \cdot a_j^0) \right)^{-1} \right\} \dots \dots \dots (3 - 24)$$

R : يمثل عدد متغيرات طبقة المدخلات.

w_1^2 : يمثل الوزن الخاص بالعقدة الأولى في الطبقة الخفية.

w_2^2 : يمثل الوزن الخاص بالعقدة الثانية في الطبقة الخفية.

a_j^0 : تمثل مخرجات الطبقة الخفية.

b_1^1 : يمثل مدخلات الحد الثابت (Bias) إلى العقدة الأولى في الطبقة الخفية.

b_2^1 : يمثل مدخلات الحد الثابت (Bias) إلى العقدة الثانية في الطبقة الخفية.

b^2 : يمثل مخرجات الحد الثابت (Bias) للطبقة الخفية.

إن مخرجات الشبكة العصبية الاصطناعية التي يتم الحصول عليها تكون محصورة بين (0,1)، إذ من المعلوم بأنه تم تعديل البيانات قبل تدريبها باستعمال الشبكة العصبية الاصطناعية لكي تكون ضمن نطاق عمل الدالة السينية (Sigmoid Function) وهي دالة التنشيط المستعملة في انموذج الشبكة العصبية الاصطناعية وهي لا تمثل القيم الحقيقية لبيانات الظاهرة قيد الدراسة وللحصول على القيم الحقيقية يتم ذلك باستعمال الدالة التالية [9,pp.342]:

$$\text{Prediction Value} = \text{output Value(Data Range)} + \text{Minimum Value} \dots \dots \dots (3 - 25)$$


output Value: تمثل القيمة المتنبأ بها باستعمال انموذج الشبكة العصبية الاصطناعية.
Data Range: يمثل مدى البيانات الحقيقية (الأصلية).
Minimum Value: تمثل أصغر قيمة في البيانات الحقيقية (الأصلية).

4. الجانب التطبيقي (Practical Side)

يتضمن هذا القسم من البحث بناء عدة نماذج من الشبكات العصبية الاصطناعية لأسعار الاغلاق اليومية الخاصة بمصرف بغداد والتي تم الحصول عليها من سوق العراق للأوراق المالية باستعمال خوارزمية الانتشار العكسي للخطأ، ثم يتم المقارنة بين النماذج وفق بعض المقاييس الاحصائية لاختيار افضل انموذج ملائم لغرض التنبؤ.

1-4 جمع البيانات


تم جمع البيانات من سوق العراق للأوراق المالية، والتي هي عبارة عن سلسلة زمنية يومية مكونة من (2609) مشاهدة تمثل أسعار الاغلاق الخاصة بمصرف بغداد والمقدرة بالدينار العراقي للفترة من شهر آب (2009) ولغاية شهر آب (2019)، بقيمة عليا مقدارها (4.03) دينار، وقيمة دنيا مقدارها (0.23) دينار، ومتوسط مقداره (1.52) دينار، وانحراف معياري مقداره (0.89) دينار، والشكل التالي يبين الرسم البياني لأسعار الاغلاق اليومية الخاصة بمصرف بغداد للفترة المذكورة:



الشكل (1-4) يبين الرسم البياني لأسعار الاغلاق اليومية الخاصة بمصرف بغداد للفترة من (2019-2009)

2-4 تعديل البيانات

قبل تدريب البيانات باستعمال الشبكات العصبية الاصطناعية للتنبؤ بأسعار الاغلاق الخاصة بمصرف بغداد تم تعديل البيانات وذلك بتحويلها إلى الصيغة الطبيعية (Normalized Formula) من أجل أن تكون هذه البيانات ضمن نطاق عمل دالة التنشيط (Activation Function) لكون هذه البيانات تحتوي على قيم أكبر من الواحد الصحيح، والشكل التالي يبين الرسم البياني للبيانات بعد تحويلها إلى الصيغة الطبيعية (Normalized Formula):



الشكل (2-4) يبين الرسم البياني لأسعار الاغلاق اليومية الخاصة بمصرف بغداد للفترة من (2009-2019) بعد تحويلها إلى الصيغة الطبيعية (Normalized Formula)

3-4 تحديد معمارية الشبكة العصبية الاصطناعية

قبل القيام بعملية تدريب الشبكة العصبية الاصطناعية للتنبؤ بأسعار الاغلاق اليومية الخاصة بمصرف بغداد يجب تحديد متغيرات الادخال (العقد العصبية في طبقة المدخلات) وعدد العقد في الطبقة الخفية وكذلك عدد العقد في طبقة المخرجات، وللقيام بذلك تم اختيار متغيرات الادخال لبيانات السلسلة الزمنية من (Z_{t-1}) إلى (Z_t) و (13) والمتغيرات المتداخلة بينها ولمجموعة من العقد في الطبقة الخفية ولعقدة واحدة في طبقة المخرجات والتي تمثل القيمة التنبؤية $(\hat{Z}_t)$.

4-4 تدريب الشبكة العصبية الاصطناعية

بعد تحديد معمارية الشبكة العصبية الاصطناعية وللقيام بعملية التدريب تم تحديد الحد الأعلى للتكرار، إذ تم اختيار (5000) تكرار كحد أعلى لتدريب الشبكة العصبية الاصطناعية وبقيم أولية عشوائية للأوزان، إذ يُعد مجموع هذه الأوزان المضروبة مع قيم متغيرات الادخال كمدخلات لتركيبية خطية ومن ثم يؤخذ ناتج هذه التركيبية الخطية إلى دالة التنشيط في عقد الطبقة الخفية وبفلس الأسلوب يتم تطبيق العلاقة الخطية التي تجمع بين الطبقة الخفية وطبقة المخرجات، ولكون عدد الأوزان في نماذج الشبكات العصبية الاصطناعية يكون كبيراً جداً ويسبب هذا العدد الكبير من الأوزان فإن عملية التدريب قد تؤدي إلى الوقوع في حالة من المغالاة في عملية التقدير (Overestimation)، أي الحصول على تقدير جيد ولكنه ليس الأفضل من ناحية التنبؤ، لذلك فقد تم بناء مجموعة من نماذج الشبكات العصبية الاصطناعية بمتغيرات إدخال مزاحة مع الزمن وبعقد مختلفة في الطبقة الخفية حيث تبدأ برقم صغير ثم يزداد بالتدريج لحين الحصول على العدد الملائم من العقد، ومن ثم تم استعمال بعض المعايير لاختيار النموذج الأفضل بعد المقارنة بين هذه المعايير، والجدول الآتي يبين هذه النماذج:

جدول (1-4) يبين نماذج الشبكات العصبية الاصطناعية
لأسعار الاغلاق اليومية الخاصة بمصرف بغداد للفترة من (2009-2019)

الانموذج المقترح	عدد العقد في الطبقة الخفية	Epochs	AIC	BIC	SBC
NN(1,12)	2	196	-38258	-23597	-32392
	4	110	-38286	-23614	-32419
	6	83	-38297	-23621	-32431
	8	183	-38386	-23675	-32519
	10	77	-38270	-23604	-32403
NN(1,2,12)	2	1000	-46943	-37928	-41076
	4	158	-76378	-61722	-70511
	6	140	-77139	-62337	-71272
	8	128	-76709	-61990	-70843
	10	114	-76545	-61857	-70678
NN(1,2,12,13)	2	1000	-65971	-57363	-60104
	4	365	-113540	-98860	-107680
	6	115	-113340	-98680	-10747
	8	80	-114130	-99370	-108260
	10	47	-113810	-99090	-107940
NN(1-13)	2	1000	-63036	-55701	-57169
	4	1000	-72780	-64512	-66914
	6	1000	-79338	-70441	-73472
	8	1000	-84902	-75472	-79035
	10	1000	-91234	-81197	-85367

نلاحظ من الجدول الخاص بنماذج الشبكات العصبية الاصطناعية لأسعار الاغلاق اليومية الخاصة بمصرف بغداد أن انموذج NN(1,12) بالمتغيرات (z_{t-1}, z_{t-12}) يبين زيادة كفاءة الانموذج بزيادة عدد العقد العصبية في الطبقة الخفية ثم تنخفض كفاءة الانموذج عندما يتم استعمال (10) عقد عصبية في الطبقة الخفية وذلك بدلالة مقاييس (AIC)، (BIC)، و(SBC)، وإن الانموذج الأفضل لأسعار الاغلاق اليومية الخاصة بمصرف بغداد



هو $NN(1,12)$ باستعمال (8) عقد عصبية في الطبقة الخفية لامتلاك المقاييس أقل القيم بالنسبة لذلك الانموذج ويمكن كتابته بالشكل $NN(1,12;8)$.

وكذلك نلاحظ بالنسبة للانموذج $NN(1,2,12)$ بالمتغيرات $(Z_{t-1}, Z_{t-2}, Z_{t-12})$ زيادة كفاءة الانموذج بزيادة عدد العقد العصبية في الطبقة الخفية ثم تنخفض كفاءة الانموذج عندما يتم استعمال (8) عقد عصبية في الطبقة الخفية وذلك بدلالة مقاييس (AIC)، (BIC)، و (SBC)، وإن الانموذج الأفضل لأسعار الاغلاق اليومية الخاصة بمصرف بغداد هو $NN(1,2,12)$ باستعمال (6) عقد عصبية في الطبقة الخفية لامتلاك المقاييس أقل القيم بالنسبة لذلك الانموذج ويمكن كتابته بالشكل $NN(1,2,12;6)$.

وبالنسبة للانموذج $NN(1,2,12,13)$ بالمتغيرات $(Z_{t-1}, Z_{t-2}, Z_{t-12}, Z_{t-13})$ فنلاحظ أيضاً زيادة كفاءة الانموذج بزيادة عدد العقد العصبية في الطبقة الخفية ثم تنخفض كفاءة الانموذج عندما يتم استعمال (10) عقد عصبية في الطبقة الخفية، وإن الانموذج الأفضل لأسعار الاغلاق اليومية الخاصة بمصرف بغداد هو $NN(1,2,12,13)$ باستعمال (8) عقد عصبية في الطبقة الخفية ويمكن كتابته بالشكل $NN(1,2,12,13;8)$.

أما بالنسبة للانموذج $NN(1-13)$ بالمتغيرات $(Z_{t-1}-Z_{t-13})$ فنلاحظ زيادة كفاءة الانموذج بزيادة عدد العقد العصبية في الطبقة الخفية، وإن الانموذج الأفضل لأسعار الاغلاق اليومية الخاصة بمصرف بغداد هو $NN(1-13)$ باستعمال (10) عقد عصبية في الطبقة الخفية ويمكن كتابته بالشكل $NN(1-13;10)$ ، والجدول التالي يبين أفضل نماذج الشبكات العصبية الاصطناعية لأسعار الاغلاق الخاصة بمصرف بغداد من حيث عدد العقد العصبية في الطبقة الخفية:

جدول (2-4) يبين أفضل نماذج الشبكات العصبية الاصطناعية
لأسعار الاغلاق اليومية الخاصة بمصرف بغداد من حيث عدد العقد العصبية في الطبقة الخفية

الانموذج المقترح	عدد العقد في الطبقة الخفية	Epochs	AIC	BIC	SBC
NN(1,12)	8	183	-38386	-23675	-32519
NN(1,2,12)	6	140	-77139	-62337	-71272
NN(1,2,12,13)	8	80	-114130	-99370	-108260
NN(1-13)	10	1000	-91234	-81197	-85367

يلاحظ من الجدول (2-4) أعلاه بأن أفضل انموذج من حيث عدد العقد العصبية في الطبقة الخفية هو الانموذج $NN(1,2,12,13;8)$ وذلك بدلالة مقاييس (AIC)، (BIC)، و (SBC)، كما يلاحظ أيضاً إلى أن الزمن الذي استغرقه الانموذج في عملية التدريب هو أقل من باقي النماذج، إذ بلغ عدد مرات تدريب الانموذج (80) تكرار، لذلك يتم اختيار ذلك الانموذج لغرض التنبؤ.


5-4 تقييم الانموذج


بعد اختيار الانموذج الملائم لغرض التنبؤ تتم عملية تقييم الانموذج وذلك من خلال تقييم أداء الشبكة العصبية الاصطناعية وحالة التدريب وتتم عملية التقييم باستعمال بعض المعايير، والجدول التالي يبين أهم المعايير المستعملة في تقييم الانموذج:

جدول (3-4) يبين المعايير المستعملة في عملية تقييم الانموذج

الانموذج	Epochs	R^2	Best Training Performance
NN(1,2,12,13;8)	80	1	9.0028e-08

يتبين من النتائج في الجدول (3-4) أعلاه بأن قيمة معامل التحديد (R^2) قد بلغت (1)، وعدد الدورات (Epochs) قد بلغ (80) دورة، أما أفضل تقييم تدريب للانموذج (Best Training Performance) أي أفضل قيمة لمعيار (MSE) للانموذج فقد بلغ (9.0028e-08) في التكرار (80)، مما يدل على أفضلية وأمثلية الانموذج المستعمل لغرض التنبؤ.





الشكل (4-4) يبين الرسم البياني لقيمة (Best Training Performance) لأسعار الاغلاق اليومية الخاصة بمصرف بغداد للفترة من (2019-2009)

6-4 التنبؤ المستقبلي

بعد عملية تقييم النموذج المختار لغرض التنبؤ تتم عملية التنبؤ المستقبلي لخطوات لاحقة ومتعددة لأسعار الاغلاق اليومية الخاصة بمصرف بغداد ويتم ذلك من خلال استعمال التغذية الأمامية (Feed Forward)، إذ يعد التنبؤ لخطوة واحدة كمتغير للمدخلات مع إعادة تطبيق نفس معمارية الشبكة العصبية الاصطناعية للتنبؤ بخطوة أخرى وهكذا، والجدول التالي يبين القيم التنبؤية لأسعار الاغلاق اليومية الخاصة بمصرف بغداد والتي تم الحصول عليها باستعمال التغذية الأمامية للنموذج NN(1,2,12,13;8):

جدول (4-4) يبين القيم التنبؤية باستعمال النموذج NN(1,2,12,13;8)

لأسعار الاغلاق اليومية الخاصة بمصرف بغداد (Normalized Data)

الأيام	القيم التنبؤية
1	0.00500007362997641
2	0.03690158326917970
3	0.06819345427315890
4	0.06992449684760010
5	0.07152368808916930

6	0.07421143694472870
7	0.07810432308604960

جدول (4-5) يبين القيم التنبؤية باستعمال النموذج NN(1,2,12,13;8)
لأسعار الاغلاق اليومية الخاصة بمصرف بغداد (Un-Normalized Data)

الأيام	القيم التنبؤية
1	0.249000280
2	0.370226016
3	0.489135126
4	0.495713088
5	0.501790015
6	0.512003460
7	0.526796428

5. الاستنتاجات والتوصيات (Conclusions and Recommendations)

1-5 الاستنتاجات (Conclusions)

بعد الحصول على النتائج في الجانب التطبيقي من البحث، ندرج في أدناه أهم الاستنتاجات التي تم التوصل إليها والتي يمكن اجمالها بما يلي:

1. قدرة الشبكة العصبية الاصطناعية (Artificial Neural Networks) على التعامل مع أعداد كبيرة من الأوزان بعدد مختلف من متغيرات الإدخال فضلاً عن قدرتها على التعامل مع العلاقات الخطية وغير الخطية في عملية التدريب ولعدة مرات.

2. عند تدريب الشبكة العصبية الاصطناعية باستعمال خوارزمية الانتشار العكسي للخطأ (Error Back Propagation Algorithm) وبعد أن تم بناء مجموعة من النماذج بمتغيرات بازاحات مختلفة وبعقد مختلفة في الطبقة الخفية، تم التوصل إلى أن أفضل النماذج من حيث عدد العقد العصبية في الطبقة الخفية هي النماذج NN(1,2,12;6)، NN(1,2,12,13;8)، NN(1,2,12,13;10)، NN(1-13;10) وذلك بدلالة مقاييس (AIC)، (BIC)، و(SBC).

3. عند المقارنة بين النماذج الأربعة أعلاه، تم التوصل إلى أن أفضل نموذج لغرض التنبؤ هو النموذج NN(1,2,12,13;8)، إذ امتلك ذلك النموذج أقل القيم بدلالة مقاييس (AIC)، (BIC)، و(SBC)، بالإضافة إلى أن الزمن الذي استغرقه النموذج في عملية التدريب هو أقل من باقي النماذج، إذ بلغ عدد مرات تدريب النموذج (80) تكرار.

4. عند تقييم النموذج NN(1,2,12,13;8)، تم التوصل إلى أفضلية وأمثلية النموذج المستعمل لغرض التنبؤ بالاعتماد على مقاييس كل من معامل التحديد (R^2)، وعدد الدورات (Epochs)، وأفضل تقييم تدريب للنموذج (Best Training Performance).

2-5 التوصيات (Recommendations)

- على ضوء ما تم التوصل إليه من استنتاجات، يمكن ادراج التوصيات والدراسات المستقبلية، وكما في أدناه:
1. تطبيق الشبكات العصبية الاصطناعية (Artificial Neural Networks) في الدراسات الاحصائية التطبيقية المختلفة لما تميزت به من الدقة والمرونة أثناء التطبيق.
 2. استعمال دوال تنشيط أخرى غير الدالة السينية (Sigmoid Function) في معالجة البيانات الداخلة إلى الخلية العصبية الاصطناعية، والمقارنة بين النتائج.
 3. توسيع نماذج الدراسة بحيث تتضمن المقارنة مع نماذج الشبكات العصبية الاصطناعية الأخرى، مثل نماذج الشبكات العصبية التكرارية (RNN)، ونماذج الشبكات العصبية للانحدار العام (GRNN).

المصادر (References)

1. العكيدي، منير شهاب أحمد، (2015)م، التنبؤ بالتلوث البيئي باستعمال نماذج بوكس – جنكنز لمحطة الوزيرية، بحث دبلوم عالي في الاحصاء التطبيقي، كلية الادارة والاقتصاد، جامعة بغداد.
2. عاشور، مروان عبد الحميد، (2018)م، الشبكات العصبية الاصطناعية وطرائق تنبؤ السلاسل الزمنية، الطبعة الأولى، الذاكرة للنشر والتوزيع، بغداد، العراق.
3. Leardi, Riccardo (2003), '*Nature-inspired methods in chemometrics: genetic algorithms and artificial neural networks*', (23: Elsevier).
4. Torgo, Luis (2017), '*Data mining with R: learning with case studies*', (Taylor & Francis Group, LLC/CRC).
5. Sigo, Marxia Oli, et al. (2018), '*Big data analytics-application of artificial neural network in forecasting stock price trends in india*', Academy of Accounting and Financial Studies Journal, 22 (3), 1-13.
6. صاحب، دعاء عبد الكريم، والشاروط، محمد حبيب، (2014)م، التنبؤ باستهلاك الطاقة الكهربائية في محافظة القادسية باستخدام نماذج السلاسل الزمنية ونماذج الشبكات العصبية الاصطناعية، مجلة القادسية لعلوم الحاسوب والرياضيات، المجلد السادس، العدد الأول.
7. علوان، عيبر سالم، (2002)م، استخدام الشبكة العصبية الخلفية للتنبؤ في مبيعات الشركة العامة لتوزيع كهرباء بغداد، رسالة ماجستير في بحوث العمليات، كلية الإدارة والاقتصاد، جامعة بغداد.
8. فائق، رؤى خلدون، (2012)م، دراسة مقارنة لأسلوب الشبكات العصبية مع طرائق أخرى للتنبؤ بتصاريق المياه لبعض السدود في العراق، رسالة ماجستير في علوم الاحصاء، كلية الإدارة والاقتصاد، الجامعة المستنصرية.
9. Larose, Daniel T and Larose, Chantal D (2015), '*Data Mining and Predictive Analytics*', (John Wiley & Sons).
10. Mitchell, Tom M (1997), '*Machine learning*', (McGraw hill), New York, USA.
11. Rajihy, Yasen, et al. (2017), '*Back-propagation artificial neural networks in stock market forecasting. An application to the Warsaw stock exchange WIG20*', Aestimatio: The IEB International Journal of Finance, (15), 88-99.

**Abstract:**

Some phenomena suffer from the presence of chaos and instability in their data as a result of the great development in information technology, which in turn led to the presence of large amounts of data in the databases; As a result, there are many patterns inherent in that data, and the process of identifying these patterns and extracting useful information and the knowledge inherent in these data are considered major and important problems, given their importance in the prediction process.

So the need arose to know and identify those patterns, and to use these patterns in the prediction process.

On this basis, recourse was made to the use of some modern and flexible technologies in that field, namely The Artificial Neural Networks, specifically The Error Back Propagation Neural Network, which uses The Error Back Propagation Algorithm to update (train) the weights of The Artificial Neural Network.

Through the results produced by the applied side, and after a set of models of Artificial Neural Networks were built with different displacements in variables and different nodes in The Hidden Layer, it was concluded that the best model for the purpose of prediction is the model NN(1,2,12,13;8), as that model had the lowest values for statistical measures (AIC), (BIC), and (SBC), in addition, the time taken by that model in the training process is less than the rest of the models, as it reached the number of times that model was trained is (80) repetitions. also, the preference and optimization of this model were reached for the purpose of prediction after its evaluation based on some statistical measures such as Coefficient of Determination (R^2), Epochs, and Best Training Performance.

Keywords: Artificial Neural Networks, Error Back Propagation Neural Network, Error Back Propagation Algorithm, Prediction, Iraqi Stock Market Exchange, Baghdad Bank.