

استعمال الخوارزمية الجينية لتدريب الشبكة العصبية الاصطناعية لغرض التنبؤ بأسعار الأغلاق اليومية لمصرف بغداد في سوق العراق للأوراق المالية

الباحث: منير شهاب أحمد
كلية الادارة والاقتصاد
جامعة بغداد

bertraam65@gmail.com

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

drfirasmohana@gmail.com

المستخلص:

تعاني بعض الظواهر من وجود حالة من الفوضوية وعدم الاستقرارية في بياناتها نتيجةً للتطور الكبير الحاصل في تكنولوجيا المعلومات، مما أدى إلى وجود أنماط عديدة كامنة في تلك البيانات، وتعتبر عملية تحديد تلك الأنماط من المشاكل الرئيسية والمهمة وذلك نظراً لأهميتها 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، والخوارزمية الجينية، واستعمال تلك الخوارزمية 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 وبعقد مختلفة في الطبقة الخفية، تم التوصل إلى أن أفضل انموذج لغرض التنبؤ هو الانموذج (NN(1,2,12;10)، إذ امتلك ذلك الانموذج أقل القيم للمقاييس الإحصائية، معيار معلومة أكيكي (AIC)، معيار معلومة بيز (BIC)، ومعيار (SBC)، بالإضافة إلى أن الزمن الذي استغرقه الانموذج في عملية التدريب هو أقل من باقي النماذج، إذ بلغ عدد مرات تدريب ذلك الانموذج (57) تكرار.

الكلمات المفتاحية: الشبكات العصبية الاصطناعية، الخوارزمية الجينية، التنبؤ، سوق العراق للأوراق المالية، مصرف بغداد.

The Use of Genetic Algorithm to Train the Artificial Neural Network for the Purpose of Predicting Baghdad Bank Daily Closing Prices on the Iraqi Stock Exchange

Assist. Prof. Dr. Firas A. Mohammed
College of Administration and Economics
University of Baghdad

Researcher: Muneer Sh. Ahmed
College of Administration and Economics
University of Baghdad

Abstract:

Some phenomena suffer from the presence of chaos and instability in its data as a result of the great development in information technology, which led to the existence of many patterns inherent in that data, and the process of identifying those patterns is considered a major and important problem, given its 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 and the genetic algorithm, and the use of that 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;10). As that model had the lowest values for statistical measures, Akaike Information Criterion (AIC), Bayesian Information Criterion (BIC), and (SBC) Criterion. 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 (57) repetitions.

Keywords: Artificial Neural Networks, Genetic Algorithm, Prediction, Iraqi Stock Market Exchange, Baghdad Bank.

١. المقدمة (Introduction)

تعاني بعض الظواهر من وجود حالة من الفوضوية وعدم الاستقرارية 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 تميز بمرونتها العالية في التعامل مع السلسل الزمنية، وذلك بسبب عدم حاجتها إلى التقيد بالشروط الواجب توفرها في نماذج السلسل الزمنية التقليدية، مثل الاستقرارية، واستقلالية الأخطاء، والتوزيع الطبيعي لتلك الأخطاء، كما يلاحظ ذلك في نماذج بوكس-جنكزنز، وغيرها من نماذج السلسل الزمنية التقليدية الأخرى، لكونها من النماذج الالعليمية.

٢. 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)، واستعمال الخوارزمية الجينية (Genetic Algorithm) في تحديث (تدريب) أوزان الشبكة العصبية الاصطناعية.

٣. 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 الخوارزمية الجينية واستعمال تلك الخوارزمية في تدريب أوزان الشبكة العصبية الاصطناعية.

٤-٣. 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 السلسلة 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 الأغلاق 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 الرلزالي (العكدي، ٢٠١٥: ١٠).

٢-٣. **الشبكات العصبية الاصطناعية (Artificial Neural Networks)**: تعتبر الشبكات العصبية الاصطناعية من أدوات التقريب عن البيانات والتي تستعمل لأغراض التصنيف والتنبؤ، كما أنها تعتبر أحدى أهم تطبيقات الذكاء الاصطناعي (Artificial Intelligence)، ويرمز لها اختصاراً بالرمز (ANN) (عاشور، ٢٠١٨: ٢٠).

سميت الشبكات العصبية الاصطناعية بذلك الاسم وذلك لأن عملها يماثل عمل الدماغ البشري المكون من حوالي ألف مليار خلية عصبية من حيث اكتساب المعرفة وخزن تلك المعرفة (عاشور، ٢٠١٨: ٢١).


ظهرت الشبكات العصبية الاصطناعية لأول مرة في أربعينيات القرن الماضي على يد العالمين (Pitts) و (McCulloch)، ثم تطورت في ثمانينيات القرن الماضي على يد العلماء (Rumelhart) و (Werbose) و (Hopfield)، واستمرت في التطور منذ ذلك الوقت وإلى يومنا هذا على يد العديد من العلماء أبرزهم (Zupan)، (Lippmann)، (Gasteiger)، وآخرون (Leardi, 2003: 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 (Torgo, 2017: 158). ويمكن 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 وخذن واستعمال المعرفة التجريبية (عاشور، ٢٠١٨: ٢١-٢٢).

تعد الشبكات العصبية الاصطناعية من النماذج غير الخطية وتتميز بمردنتها العالية عند التطبيق وذلك لكونها من طرق التقدير اللامعملي، كما تتميز بدقتها العالية من حيث التنبؤ لذلك تستعمل بشكل واسع في العديد من المجالات مثل المجال الطبي والهندسي والمالي وغيرها من المجالات الأخرى (Sigo, 2018: 1-2).

تصنف الشبكات العصبية الاصطناعية من حيث عدد طبقاتها إلى نوعين رئيسيين وهي (صاحب، ٢٠١٤: ١٤-٢٠)، (علوان، ٢٠٠٢: ٢٠-١٤):

أ. **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 (صاحب، ٢٠١٤: ١٤).



الشكل (١-٣) شكل الشبكة العصبية الاصطناعية أحادية الطبقة وهو من عمل الباحثان

ب. الشبكات العصبية متعددة الطبقات (Multi Layers Neural Networks): وهي الشبكات التي تتكون من طبقة واحدة أو أكثر من الطبقات الخفية بالإضافة إلى كلٍ 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 (صاحب، ٢٠١٤: ١٥-١٤)، (علوان، ٢٠٠٢: ١٥-١٤).

وبصورة عامة تكون معمارية هكذا نوع من الشبكات من ثلاثة طبقات وهي كالتالي:

❖ **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 انموذج السلاسل الزمنية بالاعتماد على الصيغة الموصوفة بدالة المتغيرات المزاحة زمنياً أي المتغيرات المختلفة زمنياً (صاحب، ٢٠١٤: ١٧؛ Larose, 2015: 342).

❖ **طبقة 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 وثبتت، إذ يجب أن يتم اختيار عدد العقد العصبية الاصطناعية في تلك الطبقة بحذر وعناء شديدين، فالعدد القليل من العقد يؤدي إلى الحصول على عدد قليل من الأوزان (المعالم) وبالتالي يؤدي إلى تقدير خاطئ لأنموذج 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 (صاحب، ٢٠١٤: ١٧)، (فائق، ٢٠١٢: ٥٨)، (Larose, 2015: 342-343).

أ. معيار (AIC): ويسمى أيضاً معيار معلومة أكيكي (Akaike Information Criterion)، ويتم حساب هذا المعيار وفق الصيغة الرياضية التالية (صاحب، ٢٠١٤: ١٧):

$$AIC = nk \ln(\sigma^2_e) + 2s \dots \dots \dots \quad (1 - 3)$$

n : عدد البيانات المقدرة.

k : عدد العقد في طبقة المخرجات.

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

σ^2_e : تباين الخطأ.

ب. معيار (BIC): ويسمى أيضاً معيار معلومة بيز (Bayesian Information Criterion)، ويتم حساب هذا المعيار وفق الصيغة الرياضية التالية (صاحب، ٢٠١٤: ١٧):


$$BIC = nk \ln(\sigma^2_e) - (n - s) \ln\left(1 - \frac{s}{n}\right) + s \ln(n) \\ + s \ln\left[\frac{\sigma^2_x}{\sigma^2_e} - 1/s\right] \dots \dots \dots \quad (2 - 3)$$

ج. معيار (SBC): ويتم حساب هذا المعيار وفق الصيغة الرياضية التالية (صاحب، ٢٠١٤: ١٧):

$$SBC = nk \ln(\sigma^2_e) + s \ln(n) \dots \dots \dots \quad (3 - 3)$$

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.

❖ 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 عدة واحدة إذا كان هدف الشبكة هو التنبؤ بخطوة واحدة إلى الأمام (صاحب، ٢٠١٤: ٣٤٣)، (Larose, 2015: 343).



الشكل (٢-٣): شكل الشبكة العصبية الاصطناعية متعددة الطبقات (Larose, 2015: 341).

٣-٣. الخلية العصبية الاصطناعية (Artificial Neuron): 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 (Leardi, 2003: 200).

وبشكل عام تتكون أي خلية عصبية اصطناعية من أربعة أقسام رئيسة وهي:
 أ. قنوات الإدخال (Synapse): وهي القنوات التي عن طريقها تستلم الخلية العصبية الاصطناعية الإشارات (البيانات) القادمة إليها من الخلايا العصبية الاصطناعية المرتبطة بها وتشمل تلك الإشارات بالمدخلات (عاشور، ٢٠١٨: ٢٩).

ب. دالة الجمع (Summation Function): وهي الدالة التي تقوم بجمع (توحيد) الإشارات الداخلة إلى الخلية العصبية الاصطناعية في إشارة واحدة، وتأخذ الشكل التالي (عاشور، ٢٠١٨: ٢٩): (Torgo, 2017: 159)

$$Net_j = \sum_{i=0}^n w_{ji} z_{ji} \\ = w_{j0} z_{j0} + w_{j1} z_{j1} + \dots + w_{jn} z_{jn} \dots \dots \dots \quad (4 - 3)$$

z_{ji} : تمثل الاشارة أو القيمة (i) التابعة للعقدة (j).

w_{ji} : يمثل الوزن الناقل للاشارة أو القيمة (i) التابعة للعقدة (j).


Z_0 : تمثل اشارة أو قيمة ثابتة (Bias) وتكون مساوية إلى (1).

ج. 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 (عاشور، ٢٠١٨: ٣٠-٣٢)، (Torgo, 2017: 159)

$$Sigmoid(x) = \frac{1}{1 + exp^{-x}} \dots \dots \dots \quad (5 - 3)$$

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

د. قناة الإخراج (Axone Paths): وهي القناة التي تقوم بإرسال إشارة الإخراج إلى الخلايا العصبية الاصطناعية الأخرى وتشمل تلك الإشارة بالمخرجات (عاشور، ٢٠١٨: ٢٩).



الشكل (٣-٣): شكل الخلية العصبية الاصطناعية (عاشور، ٢٠١٨: ٣٠)

٣-٤. **الخوارزميات الجينية (Genetic Algorithms):** تعتبر الخوارزميات الجينية احدى خوارزميات التفقيب عن البيانات كما إنها تعتبر واحدة من أدوات الذكاء الاصطناعي والتي تستعمل في حل المشاكل الموجودة في العديد من المجالات مثل المشاكل المتعلقة بالمال والأعمال والبحوث وغيرها من المشاكل الأخرى وذلك من خلال تقديم مجموعة من الحلول المثلث لتلك المشاكل ثم تتم المقارنة بين تلك الحلول واختيار الحل الأكثر ملائمة لعلاج تلك المشاكل (Larose, 2006: 240). تم اقتراح الخوارزميات الجينية من قبل العالم الأمريكي (John Holland) في ستينيات القرن الماضي، ثم قام العالم نفسه بتطوير تلك الخوارزميات بمساعدة مجموعة من طلابه وزملاه في جامعة ميشيغان (Michigan University) في ستينيات وسبعينيات القرن الماضي (Mitchell, 1998: 3).

إن فكرة الخوارزميات الجينية مستوحاة من النظرية الجينية، إذ إن كل خلية في جسم الإنسان تحتوي على مجموعة من الكروموسومات (Chromosomes) ترتبط فيما بينها عن طريق الحمض النووي الصبغي (DNA)، وأن كل كروموسوم يتكون من مجموعة من الجينات (Genes) التي تكون مسؤولة عن صفة معينة في جسم الإنسان مثل لون العينين، أما بالنسبة للخوارزميات الجينية فإن الكروموسوم (Chromosome) يشير إلى أحد الحلول المرشحة لحل مشكلة معينة، أما الجين (Gene) فإنه يشير إلى رقم معين أو جزء معين من ذلك الحل (Larose, 2006: 240-241).

٣-٤-١. **مجالات تطبيق الخوارزميات الجينية (Genetic Algorithms Application Scopes):** هناك ثلاثة مجالات رئيسية يمكن تطبيق الخوارزميات الجينية فيها وهي (الحمامي، ٢٠٠٨: ٣٩٩):
أ. **الأمثلية (Optimization):** يتم استعمال الخوارزميات الجينية في ذلك المجال عندما توجد مشكلة في تحديد القيم المثلالية لمتغيرات معينة كما يلاحظ ذلك مثلاً عند تحديد القيم المثلالية للمتغيرات التي تستعمل في أمثلة الربح بصورة أوتوماتيكية.
ب. **التنبؤ (Prediction):** يتم استعمال الخوارزميات الجينية في ذلك المجال عندما يتم استعمالها لأمثلة خوارزميات التفقيب عن البيانات الأخرى، كما يلاحظ ذلك عند استعمالها لأمثلة الأوزان المستعملة في الشبكات العصبية الاصطناعية.


ج. **المحاكاة (Simulation):** يتم استعمال الخوارزميات الجينية في ذلك المجال عندما تكون هناك مشكلة عمل معينة غير محددة بصورة جيدة أو فيما إذا كان هناك حل أفضل من حل آخر.

٣-٤-٢. **المراحل الأساسية للخوارزمية الجينية (Genetic Algorithm Basic Stages):** هناك أربعة مراحل للخوارزمية الجينية يمكن توضيحها كما يأتي (Larose, 2006: 241-242):
أ. **توليد المجتمع الأولي (Initial Population Generating):** وفي هذه المرحلة يتم توليد مجتمع أولي يتكون من (N) من الكروموسومات وكل كروموسوم يكون بطول (L).
ب. **الانتقاء (Selection):** وفي هذه المرحلة يتم انتقاء أو اختيار مجموعة من الكروموسومات التي ستسعمل لإنشاء الجيل الجديد (جيل البناء)، إذ يتم حساب دالة الملائمة (Fitness Function) لكل كروموسوم، ثم يتم انتقاء مجموعة من الكروموسومات التي تعطي أعلى قيمة لهذه الدالة، وبعد أن يتم انتقاء الكروموسومات الملائمة يتم اختيار كل زوج من الكروموسومات (والاين) لإنشاء اثنين من الكروموسومات الجديدة (البناء)، مع الأخذ بنظر الاعتبار امكانية اختيار الكروموسوم الواحد مع أكثر من كروموسوم آخر لإنشاء اثنين من الكروموسومات الجديدة.

ج. التهجين (Crossover): وفي هذه المرحلة يتم انشاء اثنين من الكروموسومات الجديدة (الابناء) وذلك عن طريق اختيار الموقع في الكروموسومات القديمة (والاين) والذي على أساسه تتم عملية التهجين، وتم عملية اختيار ذلك الموقع بصورة عشوائية، وبعد عملية اختيار الموقع يتم ابدال الجزء الذي يبدأ من ذلك الموقع لكل كروموسوم مع الجزء المقابل له في الكروموسوم الآخر، فعلى سبيل المثال لو كان لدينا اثنين من الكروموسومات التالية (00000000) و (11111111) فإنه يمكن اجراء عملية التهجين باختيار الموقع الخامس في كل كروموسوم وابدال الجزء الذي يبدأ من ذلك الموقع في كل كروموسوم مع الجزء المقابل في الكروموسوم الآخر لإنشاء اثنين من الكروموسومات الجديدة التالية (11110000) و (00001111).

د. الطفرة (Mutation): وفي هذه المرحلة يتم انشاء طفرة في مجموعة صغيرة من الكروموسومات الجديدة وذلك عن طريق تغيير أحد اجزاء الكروموسوم (الجين) بصورة عشوائية، فعلى سبيل المثال للكروموسومات الجديدة التي تم انشاؤها في مرحلة التهجين يمكن عمل طفرة لهما في الموقع الثالث ليصبحا بالشكل التالي (00101111) و (11010000).

ثم يتم حساب دالة الملائمة لكل كروموسوم في الجيل الجديد (جيل الابناء)، فإذا كان مجموع دالة الملائمة للجيل الجديد أكبر من مجموع دالة الملائمة للجيل القديم (جيل الآباء) يحل الجيل الجديد محل الجيل القديم، أما إذا كان مجموع دالة الملائمة للجيل الجديد أقل من مجموع دالة الملائمة للجيل القديم يتم الرجوع إلى المرحلة الثانية (مرحلة الانتقاء) لتبدأ عملية انتقاء جديدة، وهكذا (Larose, 2006: 242).



الشكل (٤-٣) المراحل الأساسية للخوارزمية الجينية وهو من عمل الباحثان

٣-٤. الخوارزمية الجينية المستعملة لتدريب الشبكة العصبية:

(Genetic Algorithm Used To Train A Neural Network)

وهي الخوارزمية المستعملة لتدريب 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 المستعملة في انموذج الشبكة العصبية الاصطناعية، ويتكون من صيغة (Normalized Formula) والتي يمكن حسابها كالتالي (Larose, 2015: 339-340):

$$x_{new} = \frac{x - \min(x)}{\max(x) - \min(x)} \dots \dots \dots \dots \dots \quad (6-3)$$

بعد تعديل البيانات يتم تدريب الشبكة العصبية الاصطناعية باستعمال الخوارزمية الجينية والتي يمكن ايجاز خطواتها كالتالي (عشور، ٢٠١٨: ٤٩-٥١)، (Larose, 2006: 242-254):

- ❖ توليد قيم أولية عشوائية لأوزان الشبكة العصبية الاصطناعية (عادةً ما تكون بين ١٠٠).
- ❖ تستقبل كل عقدة في طبقة المدخلات الإشارات أو القيم الداخلة إليها من قاعدة البيانات ثم يتم ارسالها 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 ارسال ناتج دالة الجمع لكل عقدة في الطبقة الخفية إلى دالة التنشيط (Activation Function) وذلك لتقدير مخرجات الطبقة الخفية.
- ❖ يتم ارسال 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 قيم الإشارات أو القيم الموزونة الداخلة إليها من الطبقة الخفية باستعمال دالة الجمع.
- ❖ يتم ارسال ناتج دالة الجمع لكل عقدة من عقد طبقة المخرجات إلى دالة التنشيط وذلك لتقدير مخرجات طبقة المخرجات.
- ❖ يتم حساب خطأ التدريب لأنموذج الشبكة العصبية الاصطناعية.
- ❖ يتم تكرار الخطوات من (١-٨) إلى (n) من المرات وذلك لتوليد (n) من نماذج الشبكات العصبية الاصطناعية.
- ❖ يتم حساب دالة الملائمة (Fitness Function) لكل انموذج من نماذج الشبكات العصبية الاصطناعية التي تم توليدها وذلك كالتالي:

$$f_{(xi)} = 1/Training\ Error \dots \dots \dots \dots \dots \quad (7-3)$$

- ❖ يتم حساب احتمالية اختيار أي انموذج من نماذج الشبكات العصبية وذلك كما يلي:

$$Probability\ of\ Selection = \frac{f_{(xi)}}{\sum_{i=1}^n f_{(xi)}} \dots \dots \dots \dots \dots \quad (8-3)$$

$f_{(xi)}$: تمثل دالة الملائمة لأنموذج (i).

n : تمثل عدد الشبكات العصبية الاصطناعية التي تم توليدها.

- ❖ يتم اختيار كل أنموذجين معاً وذلك لتعديل الأوزان الخاصة بهما (إنشاء أوزان جديدة) بالاعتماد على احتمالية الاختيار (Probability of Selection)، فالأنموذجين اللذين يعطيان أعلى قيمة

الاحتمالية الاختيار يتم اختيارهما أولاً لتعديل الأوزان الخاصة بهما، إذ تمثل الأوزان الخاصة بكل نموذج من نماذج الشبكة العصبية الاصطناعية كروموسوم (Chromosome) ويمثل الوزن الواحد أحد جينات ذلك الكروموسوم.

- ❖ يتم تمثيل الكروموسوم الواحد (أوزان الشبكة العصبية الاصطناعية) على شكل صف ثم يتم اختيار نقطة التهجين (Crossover Point) بشكل عشوائي، إذ يتم استبدال الجزء الذي يبدأ من نقطة التهجين (الجينات) الخاص بأحد الأنماذج مع الجزء الذي يقابلها في الأنماذج الآخر وبذلك تكون أوزان جديدة (الجيل الجديد).
 - ❖ يتم اختيار (n) من العقد العصبية الاصطناعية (عدا العقد العصبية الاصطناعية الخاصة بطبقية المدخلات) لمجموعة صغيرة من الكروموسومات الجديدة ثم يتم عمل طفرة (Mutation) للأوزان الداخلة إلى تلك العقد وذلك بإضافة رقم عشوائي تتراوح قيمته بين (0,1) على لا تتجاوز قيمة كل وزن من الأوزان بعد الإضافة (١).
 - ❖ يحل الجيل الجديد من الكروموسومات (الأوزان الجديدة) محل الجيل القديم من الكروموسومات (الأوزان القديمة) وباستعمال الأوزان الجديدة يتم توليد (n) من النماذج الجديدة.
 - ❖ يتم حساب خطأ التدريب لكل نموذج من نماذج الشبكات العصبية الاصطناعية الجديدة.
 - ❖ يتم حساب دالة الملائمة (Fitness Function) لكل نموذج من النماذج الجديدة.
 - ❖ يتم ايجاد مجموع دالة الملائمة والخاصة بكل نموذج من النماذج الجديدة $\sum_{i=1}^n f_{(xi)}$ ، فإذا كان مجموع دالة الملائمة للنماذج الجديدة أكبر من مجموع دالة الملائمة للنماذج القديمة يتم ايقاف الخوارزمية ويتم اختيار الانماذج الذي يعطي أعلى قيمة لدالة الملائمة (أقل قيمة للخطأ) ويتم استعماله لغرض التتبؤ، أما إذا كان مجموع دالة الملائمة للنماذج الجديدة أقل من مجموع دالة الملائمة للنماذج القديمة يتم الذهاب إلى الخطوة (١٢).

٤-٣. التنبؤ المستقبلي (Forecasting): بعد اختيار الانموذج الملائم لغرض التنبؤ تتم عملية التنبؤ المستقبلي لخطوات لاحقة ومتعددة باستعمال ذلك الانموذج، 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 انموذج يتكون من عقدتين في الطبقة الخفية وعقدة واحدة في طبقة المخرجات تتم عملية التنبؤ المستقبلي، لخطوة واحدة إلى الإمام وذلك كالتالي (صاحب، ٢٠١٤، ٢٤):

R: يمثل عدد متغيرات طبقة المدخلات.

W₁²: يمثل الوزن الخاص بالعقدة الأولى في الطبقة الخفية.

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

a^o : 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 تدريبيها 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 الصيغة الرياضية التالية (Larose, 2015: 342):

$$\text{Prediction Value} = \text{output Value(Data Range)} + \text{Minimum Value} \dots \dots \dots \quad (10 - 3)$$


output Value : تمثل القيمة المتنبأ بها باستعمال انموذج الشبكة العصبية الاصطناعية.

Data Range : يمثل مدى البيانات الحقيقة (الأصلية).

Minimum Value : تمثل أصغر قيمة في البيانات الحقيقة (الأصلية).


٤. **الجانب التطبيقي (Practical Side):** يتضمن هذا القسم من البحث بناء عدة نماذج من الشبكات العصبية الاصطناعية لأسعار الإغلاق اليومية الخاصة بمصرف بغداد والتي تم الحصول عليها من سوق العراق للأوراق المالية باستعمال الخوارزمية الجينية، ثم يتم المقارنة بين النماذج وفق بعض المقاييس الاحصائية لاختيار أفضل انموذج ملائم لغرض التنبؤ.

٤. جمع البيانات: تم جمع البيانات من سوق العراق للأوراق المالية، والتي هي عبارة عن سلسلة زمنية يومية مكونة من (2609) مشاهدة تمثل أسعار الإغلاق 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 الإغلاق اليومية الخاصة بمصرف بغداد للفترة المذكورة:



الشكل (١-٤): الرسم البياني لأسعار الإغلاق اليومية الخاصة بمصرف بغداد للفترة ٢٠١٩-٢٠٠٩

٤-٢. **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 (٢-٤): الرسم البياني لأسعار الاغلاق اليومية الخاصة بمصرف بغداد للفترة ٢٠١٩-٢٠٠٩ بعد تحويلها إلى الصيغة الطبيعية (Normalized Formula)

٤-٣. **تحديد معمارية الشبكة العصبية الاصطناعية:** قبل القيام بعملية تدريب الشبكة العصبية الاصطناعية للتنبؤ بأسعار الاغلاق اليومية الخاصة بمصرف بغداد يجب تحديد متغيرات الإدخال (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-13}) إلى (Z_t) والمتغيرات المتداخلة بينها ولمجموعة من العقد في الطبقة الخفية ولعقدة واحدة في طبقة المخرجات والتي تمثل القيمة التنبؤية (\hat{Z}_t).

٤-٤. **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 لتركيبة خطية ومن ثم يؤخذ ناتج هذه التركيبة الخطية إلى دالة التنشيط في عقد الطبقة الخفية وبنفس الأسلوب يتم تطبيق العلاقة الخطية التي تجمع بين الطبقة الخفية وطبقة المخرجات، ولكن عدد الأوزان في نماذج الشبكات العصبية الاصطناعية يكون كبيراً جداً وبسبب هذا العدد الكبير من الأوزان فإن عملية التدريب قد تؤدي إلى الوقوع في حالة من المعالاة 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 وبعده 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:

الجدول (٤): نماذج الشبكات العصبية الاصطناعية لأسعار الاغلاق اليومية الخاصة بمصرف بغداد للفترة من (٩-٢٠١٩) والمدربة باستعمال الخوارزمية الجينية

الانموذج المقترن	عدد العقد في الطبقة الخفية	Epochs	AIC	BIC	SBC
NN(1,12)	2	112	-38252	-23370	-32385
	4	104	-38264	-23378	-32398
	6	102	-38259	-23374	-32393
	8	108	-38437	-23484	-32571
	10	82	-38276	-23385	-32409
NN(1,2,12)	2	606	-19177	-15259	-13310
	4	103	-76434	-61543	-70567
	6	92	-76396	-61513	-70529
	8	58	-76729	-61782	-70862
	10	57	-77073	-62060	-71206
NN(1,2,12,13)	2	580	-24355	-20841	-18488
	4	124	-11340	-9851	-10753
	6	117	-11397	-9901	-10810
	8	57	-11345	-9855	-10758
	10	14	-11483	-9975	-10896
NN(1-13)	2	313	-15292	-12309	-9425
	4	1000	-17558	-14358	-11692
	6	759	-20386	-16914	-14519
	8	1000	-24020	-20201	-18153
	10	1000	-29474	-25132	-23608

يلاحظ من خلال الجدول (٤-٤) أعلاه أن الانموذج $NN(1,12)$ بالمتغيرات (Z_{t-1}, Z_{t-12}) يبيّن 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 للأنموذج $NN(1,2,12)$ بالمتغيرات $(Z_{t-1}, Z_{t-2}, Z_{t-12})$ زيادة كفاءة الانموذج بزيادة عدد العقد العصبية 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 (10) عقد عصبية في الطبقة الخفية لامتلاك المقاييس أقل القيم بالنسبة لذلك الانموذج ويمكن كتابته بالشكل $NN(1,2,12; 10)$.

وبالنسبة للأنموذج (13) $NN(1,2,12,13)$ بالمتغيرات ($Z_{t-1}, Z_{t-2}, Z_{t-12}, Z_{t-13}$) فلاحظ انخفاض كفاءة الانموذج بزيادة عدد العقد العصبية في الطبقة الخفية ثم تزداد 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 عقدتين عصبيتين في الطبقة الخفية ويمكن كتابته بالشكل (13;2).

أما بالنسبة للأنموذج (13) $NN(1-13)$ بالمتغيرات ($Z_{t-1}-Z_{t-13}$) فلاحظ 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 (13;10)، والجدول التالي يبين أفضل نماذج الشبكات العصبية الاصطناعية لأسعار الاغلاق الخاصة بمصرف بغداد والمدربة باستعمال الخوارزمية الجينية من حيث عدد العقد العصبية في الطبقة الخفية:

الجدول (٤-٢): أفضل نماذج الشبكات العصبية الاصطناعية لأسعار الاغلاق اليومية الخاصة بمصرف بغداد والمدربة باستعمال الخوارزمية الجينية من حيث عدد العقد العصبية في الطبقة الخفية

الأنموذج المقترن	عدد العقد في الطبقة الخفية	Epochs	AIC	BIC	SBC
NN(1,12)	8	108	-38437	-23484	-32571
NN(1,2,12)	10	57	-77073	-62060	-71206
NN(1,2,12,13)	٢	580	-24355	-20841	-18488
NN(1-13)	10	1000	-29474	-25132	-23608

يلاحظ من الجدول (٤-٢) أعلاه بأن أفضل انموذج من حيث عدد العقد العصبية في الطبقة الخفية هو الانموذج (10;12,2,1) $NN(1,2,12;10)$ 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 (57) تكرار.

٤-٥. التنبؤ المستقبلي: بعد عملية اختيار الانموذج الملائم 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 للأنموذج (10;12,2,1) $NN(1,2,12;10)$:

الجدول (٤-٣): القيم التنبؤية باستعمال الانموذج (NN(1,2,12;10) لأسعار الاغلاق اليومية
الخاصة بمصرف بغداد (Normalized Data)

الأيام	القيم التنبؤية
1	0.00500004798840971
2	0.00707680101168487
3	0.10072983769513600
4	0.09655329596599950
5	0.09655329596599950
6	0.09050574344849900
7	0.08757813488478970

يبين الجدول (٤-٣) أعلاه القيم بالصيغة الطبيعية والتي تم التنبؤ المستقبلي بها باستعمال الانموذج (NN(1,2,12;10) وهي عبارة عن سبعة أيام قادمة لأسعار الاغلاق اليومية الخاصة بمصرف بغداد.

الجدول (٤-٤): القيم التنبؤية باستعمال الانموذج (NN(1,2,12;10) لأسعار الاغلاق اليومية
الخاصة بمصرف بغداد (Un-Normalized Data)

الأيام	القيم التنبؤية
1	0.249000182
2	0.256891844
3	0.612773383
4	0.596902525
5	0.596902525
6	0.573921825
7	0.562796913

يبين الجدول (٤-٤) أعلاه القيم الحقيقية والتي تم التنبؤ المستقبلي بها باستعمال الانموذج (NN(1,2,12;10)، وهي عبارة عن سبعة أيام قادمة لأسعار الاغلاق اليومية الخاصة بمصرف بغداد.

٥. الاستنتاجات والتوصيات (Conclusions and Recommendations)

- ١-٥. الاستنتاجات (Conclusions): بعد الحصول على النتائج في الجانب التطبيقي من البحث، ندرج في أدناه أهم الاستنتاجات التي تم التوصل إليها والتي يمكن إجمالها بما يلي:
 - أ. قدرة الخوارزمية الجينية (Genetic Algorithm) على التعامل مع الشبكات العصبية الاصطناعية (Artificial Neural Networks) من خلال قدرتها على تدريب الشبكات العصبية الاصطناعية بعد مختلف من متغيرات الإدخال ولعدة مرات.
 - ب. عند تدريب الشبكة العصبية الاصطناعية باستعمال الخوارزمية الجينية (Genetic Algorithm) وبعد أن تم بناء مجموعة من النماذج بمتغيرات بإزاحات مختلفة وبعد مختلفة في الطبقة الخفية، تم التوصل إلى أن أفضل النماذج من حيث عدد العقد العصبية في الطبقة الخفية هي النماذج

ج. عند المقارنة بين النماذج الأربع أعلاه، تم التوصل إلى أن أفضل انموذج لعرض التنبؤ هو الانموذج (NN(1,2,12;10)، إذ امتلك ذلك الانموذج أقل القيم بدلالة مقاييس (AIC)، (BIC)، و(SBC)، بالإضافة إلى أن الزمن الذي استغرقه الانموذج في عملية التدريب هو أقل من باقي النماذج، إذ بلغ عدد مرات تدريب الانموذج (57) تكرار.

٥-٢. التوصيات (Recommendations): على ضوء ما تم التوصل إليه من استنتاجات، يمكن ادراج التوصيات والدراسات المستقبلية، وكما في أدناه:

أ. تطبيق الخوارزمية الجينية (Genetic Algorithm) في الدراسات الاحصائية التطبيقية المختلفة لما تتميز به من الدقة والمرونة أثناء التطبيق.

ب. استعمال الخوارزمية الجينية (Genetic Algorithm) لاختيار العدد الأمثل من العقد العصبية الاصطناعية في الطبقة الخفية، ومقارنة النتائج مع تلك التي يتم الحصول عليها عندما يتم استعمال معايير (AIC)، (BIC)، و(SBC) لاختيار العدد الأمثل من العقد العصبية الاصطناعية في الطبقة الخفية.

ج. توسيع نماذج الدراسة بحيث تتضمن المقارنة مع نماذج الشبكات العصبية الاصطناعية الأخرى، مثل نماذج الشبكات العصبية التكرارية (RNN)، ونماذج الشبكات العصبية للانحدار العام (GRNN).

د. بحث امكانية استعمال بعض الخوارزميات الأخرى، مثل خوارزمية سرب الطيور، وخوارزمية النمل، وخوارزمية الذئاب الرمادية، في تحديث أوزان الشبكة العصبية الاصطناعية ومقارنة النتائج مع تلك التي تم التوصل إليها باستعمال الخوارزمية الجينية (Genetic Algorithm).

المصادر

أولاً. المصادر العربية:

١. الحمامي، علاء حسين، (٢٠٠٨)، *تنقيب البيانات*، الطبعة الأولى، دار اثراء للنشر والتوزيع، عمان، الأردن.
٢. صاحب، دعاء عبد الكريم، والشاروط، محمد حبيب، (٢٠١٤)، *التنبؤ باستهلاك الطاقة الكهربائية في محافظة القادسية باستخدام نماذج السلسل الزمنية ونماذج الشبكات العصبية الاصطناعية*، مجلة القadesia لعلوم الحاسوب والرياضيات، المجلد السادس، العدد الأول.
٣. عاشور، مروان عبد الحميد، (٢٠١٨)، *الشبكات العصبية الاصطناعية وطرائق تنبؤ السلسل الزمنية*، الطبعة الأولى، الذاكرة للنشر والتوزيع، بغداد، العراق.
٤. العكيدية، منير شهاب أحمد، (٢٠١٥)، *التنبؤ بالتلوك البيئي باستعمال نماذج بوكس-جنكز لمحطة الوزيرية*، بحث دبلوم عالي في الاحصاء التطبيقي، كلية الادارة والاقتصاد، جامعة بغداد.
٥. علوان، عبير سالم، (٢٠٠٢)، *استخدام الشبكة العصبية الخلفية للتنبؤ في مبيعات الشركة العامة لتوزيع كهرباء بغداد*، رسالة ماجستير في بحوث العمليات، كلية الادارة والاقتصاد، جامعة بغداد.
٦. فائق، رؤى خلون، (٢٠١٢)، *دراسة مقارنة لأسلوب الشبكات العصبية مع طرائق أخرى للتنبؤ بتصاريف المياه لبعض السدود في العراق*، رسالة ماجستير في علوم الاحصاء، كلية الادارة والاقتصاد، الجامعة المستنصرية.

ثانياً. المصادر الأجنبية:

1. Larose, D. T. (2006). Data mining methods and models (Vol. 2): (Wiley Online Library).
2. Larose, D. T., & Larose, C. D. (2015). Data Mining and Predictive Analytics (John Wiley & Sons).
3. Leardi, R. (2003). Nature-inspired methods in chemometrics: genetic algorithms and artificial neural networks (Vol. 23): Elsevier.
4. Mitchell, M. (1998). An introduction to genetic algorithms: MIT press.
5. Sigo, M. O., Selvam, M., Maniam, B., Kannaiah, D., Kathiravan, C., & Vadivel, T. (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. Torgo, L. (2017) Data mining with R: learning with case studies (Taylor & Francis Group, LLC/CRC).