

استخدام الشبكات العصبية الاصطناعية في التنبؤ بمبيعات مصنع اسمنت زليتن

فاطمة علي التير^{1*}، سميرة عمر الدوفاني¹، هناء يوسف العريفي²، هناء رجب المكروود²، أسماء اشتوي العيان¹
¹قسم الإحصاء، كلية العلوم، الجامعة الاسمية الإسلامية، زليتن، ليبيا
²قسم الرياضيات، كلية التربية، جامعة الزاوية، الزاوية، ليبيا

Using Artificial Neural Networks to Predict the Sales of Zliten Cement Factory

Fatimah Ali Alteer^{1*}, Sameerah Omar Aldoufani¹, Hana Yousif Al.Arifi²,
Hana Rajab Almkroud², Asma Eshtewy Alayan¹

¹Statistics Department, Faculty of Science, Alasmarya Islamic University, Zliten, Libya

²Mathematics Department, Faculty of Education, University of Zawia, Zawia, Libya

*Corresponding author

fatmaalteer224@gmail.com

*المؤلف المراسل

تاريخ النشر: 2024-12-08

تاريخ القبول: 2024-10-27

تاريخ الاستلام: 2024-08-23

المخلص

السلاسل الزمنية ونماذجها المختلفة هي أحد الأدوات الأساسية المستخدمة للتنبؤ المستقبلي بسلوك المتغيرات وذلك من خلال النظر في سلوكها في فترات زمنية سابقة، ومن المعروف أن التنبؤ بالمبيعات المستقبلية للشركات الكبيرة يعد قضية بالغة الأهمية والحساسية لأنه مرتبط بكمية الإنتاج، ويمكن أن توفر دقة التنبؤات قدرًا كبيرًا من المال من خلال تقليل كمية الهدر بسبب الإنتاج المفرط أو العكس. ومن جهة أخرى يلعب الذكاء الاصطناعي واستخدامات شبكاته المختلفة دورًا هامًا في عمليات التنبؤ، وذلك من خلال استخدام عدة أنواع من الشبكات العصبية الاصطناعية التي أثبتت دقتها وكفاءتها في هذا المجال، عليه هدفت هذه الدراسة الى استخدام احدى أنواع الشبكات العصبية الاصطناعية والتي تدعى باسم الشبكة متعددة الطبقات ذات التغذية الأمامية (MFNN) للتنبؤ بمبيعات مصنع اسمنت زليتن، بناء على سلسلة زمنية ممتدة في الفترة (1992-2022) م. حيث أكدت نتائج هذه الورقة من خلال برنامج الماتلاب أن استخدام الشبكات العصبية للبيانات الحقيقية للإنتاج أن نموذج الشبكات العصبية الاصطناعية أعطى نتائج ذات دقة وكفاءة عالية، من خلال تحقيق نسبة خطأ صغيرة في نموذج التنبؤ المستخدم في هذه الدراسة.

الكلمات المفتاحية: السلاسل الزمنية، الشبكات العصبية الاصطناعية، الشبكة متعددة الطبقات ذات التغذية الأمامية، التنبؤ، متوسط مربع الخطأ.

Abstract

Time series and their various models are one of the basic tools used to predict the future behavior of variables by considering their behavior in previous time periods. It is known that predicting future sales of large companies is a very important and sensitive issue because it is related to the amount of production, and the accuracy of predictions can save a large amount of money by reducing the amount of waste due to excessive production or vice versa. On the other hand, artificial intelligence and the uses of its various networks play an important role in forecasting processes, through the use of several types of artificial neural networks that have proven their accuracy and efficiency in this field. This study aimed to use one of the types of artificial neural

networks, which is called the Multi-Layer Feed Forward Neural Network (MFNN) to predict the sales of the Cement Factory in Zliten, based on an extended time series in the period (1992-2022). The results of this paper through the MATLAB program confirmed that the use of neural networks of real-production data that the artificial neural network model gave results of high accuracy and efficiency, by achieving a small error rate in the prediction model used in this study.

Keywords: Time series; Artificial Neural Networks; Multi-Layer Feed Forward Neural Network; Forecasting; Mean Square Error

مقدمة

تُعد عملية التنبؤ أداة أساسية في مجموعة متنوعة من المجالات، حيث تسهم بشكل كبير في اتخاذ القرارات الاستراتيجية وتحسين الأداء، حيث تعتمد عملية التنبؤ على تحليل البيانات التاريخية لتقدير النتائج المستقبلية، مما يجعلها ضرورية في مجالات مثل الاقتصاد والطب والهندسة والتسويق. في السنوات الأخيرة شهدت تقنيات الذكاء الاصطناعي وبالأخص الشبكات العصبية الاصطناعية تطوراً ملحوظاً، مما جعلها جزءاً لا يتجزأ من عمليات التنبؤ. إذ تمكن هذه الشبكات الباحثين من معالجة كميات ضخمة من البيانات واستخراج الأنماط المعقدة التي قد تتجاوز قدرات النماذج التقليدية. حيث تُستخدم الشبكات العصبية في تطبيقات متعددة، بدءاً من توقع أسعار الأسهم وصولاً إلى تشخيص الأمراض، كما يعكس قدرتها على التكيف مع احتياجات البيانات المتغيرة (Goodfellow et al, 2016) ونظراً للدور الذي تلعبه انتاجية العمل في زيادة الدخل القومي ورفع مستوى المعيشة بالإضافة إلى أنها من اهم المؤشرات التي تعكس فاعلية استخدام الموارد الاقتصادية المادية منها و البشرية، حيث تحتل صناعة الاسمنت موقعاً مهماً بين الصناعات القائمة في ليبيا، فقد تم اختيار سلسلة مبيعات انتاجية العمل السنوية الخاصة بمصنع اسمنت زليتن للفترة (1992-2022) كموضوع تطبيقي باستخدام الشبكات العصبية الاصطناعية للتنبؤ بمبيعات الانتاج. تعد الشبكات العصبية الاصطناعية من الأدوات الفعالة في مجال التنبؤ، حيث تجمع بين القدرة على التعلم من البيانات والتكيف مع التغيرات مع استمرار تطور التكنولوجيا، من المتوقع أن تلعب هذه الشبكات دوراً متزايد الأهمية في تحسين دقة التنبؤات عبر مختلف المجالات.

الدراسات السابقة

دراسة البياتي و المخلافي سنة (2007) تناولت الدراسة اسلوب بوكس و جينكنز للتوصل إلى أفضل نموذج للتنبؤ بإنتاجية العمل الشهرية في مصنع اسمنت عمران في اليمن للفترة (1992-1998)، و توصلت الدراسة الى ان النموذج المختلط (ARMA (1,2 هو الافضل للتنبؤ لهذه البيانات. دراسة العجال سنة (2010) هدفت الى التنبؤ بمبيعات الشركة الوطنية للصناعات الميكانيكية ولواحقها في الجزائر باستخدام الشبكات العصبية بالتطبيق على بيانات سلسلة زمنية للمبيعات مكونة من (120 مشاهدة)، واثبت نموذج الشبكات العصبية المعتمد في وصف نشاط البيع للمؤسسة وقدرته للتنبؤات بأخطاء ضئيلة.

دراسة حامد سنة (2011) تناولت استخدام نماذج بوكس وجنكنز والشبكات العصبية للتنبؤ في السلاسل الزمنية الاقتصادية بالتطبيق على بيانات الانتاج الزراعي للذرة والقمح والسمسم في السودان للفترة (1954-2005)، وتوصلت النتائج الى كفاءة الاسلوبين وان الشبكات العصبية ادق في التنبؤ للمدى الطويل.

عبد الحق وهشام سنة (2022) قدما بحث ماجستير درسا فيه دور الشبكات العصبية في التنبؤ بقيم المبيعات لمؤسسة سونلغاز - وكالة اولف بالجزائر عن طريق الاستهلاك الشهري للكهرباء، ووجدا أن التنبؤ باستخدام الشبكات العصبية الاصطناعية نتج عنه تزايد في نسبة استهلاك الكهرباء نظرا لزيادة عدد المستهلكين وضرورة الطاقة الكهربائية في الحياة اليومية، كما أكدوا على فعالية ودقة التنبؤ باستخدام الشبكات العصبية مقارنة بغيرها.

دراسة حجاج وعبدالقادر سنة (2020) هدفت الى اقتراح نموذج ملائم للتنبؤ بمعدلات المواليد في مصر من خلال المقارنة بين الانحدار اللامعلمي الحصين والشبكات العصبية معتمدا على بيانات سلسلة زمنية (1960-2019)، وتوصلت الدراسة لأفضلية الذكاء الاصطناعي المتمثل في الشبكات العصبية عن الانحدار الحصين.

دراسة ابوليفة وشتوان سنة (2023) هدفت لتطبيق اسلوب الشبكات العصبية من خلال تقنية الشبكات العصبية الاصطناعية في التنبؤ بحجم مبيعات الشركة الليبية للحديد والصلب بمصراته لسنة 2022، بالاعتماد على بيانات شهرية من 2012 الى 2021 وتمت مقارنة نتائج اسلوب الشبكات العصبية مع الانحدار الخطي والتمهيد الاسي، وظهرت النتائج ان الشبكات العصبية أكفأ من الاسلوبين الاخرين، حيث اوصت الدراسة باستخدام الاساليب الحديثة في عملية التنبؤ كأسلوب الشبكات العصبية

الشبكات العصبية الاصطناعية

تعرف الشبكات العصبية الاصطناعية بانها نماذج حسابية مستوحاة من طريقة عمل الدماغ البشري. تتكون هذه الشبكات من وحدات معالجة تعرف بالعصبونات، والتي تتصل ببعضها البعض عبر روابط تعرف بالأوزان. تستخدم هذه الشبكات في معالجة المعلومات والتعلم من البيانات، مما يجعلها مثالية للتنبؤات المعقدة (LeCun et al., 2015).

مكونات الشبكات العصبية الاصطناعية

تتكون الشبكات العصبية الاصطناعية من أجزاء مهمة يمكن تلخيصها كما يلي

العصبونات (Neurons)

العصبونات تُعتبر الوحدات الأساسية في الشبكات العصبية، حيث كل عصبون يتلقى معلومات من عصبونات أخرى أو من مصادر بيانات مباشرة، يقوم العصبون بوزن هذه المدخلات عبر الأوزان ثم يستخدم دالة تنشيط لتحديد ما إذا كان يجب عليه إرسال إشارة إلى العصبونات التالية. يمكن اعتبار العصبون كعنصر صغير يقوم بمعالجة المعلومات بطريقة بسيطة (عبدالله، 2018).

الطبقات (Layers)

تتكون الشبكات العصبية من عدة طبقات، وهي تشمل: طبقة المدخلات: تستقبل البيانات الأولية مثل الصور أو النصوص. الطبقات المخفية: تقوم بمعالجة المعلومات. يمكن أن تحتوي الشبكة على طبقات متعددة، مما يزيد من قدرتها على تعلم الأنماط المعقدة.

طبقة المخرجات: تقدم النتائج النهائية للنموذج، مثل تصنيفات أو توقعات للقيم (الموسوعة العربية، 2020)

الأوزان (Weights)

الأوزان هي القيم التي تحدد تأثير كل مدخل على مخرجات العصبون. يتم تعديل الأوزان خلال عملية التدريب باستخدام خوارزمية الانحدار التدرجي، حيث يهدف ذلك إلى تقليل الأخطاء في التوقعات. تلعب الأوزان دورًا حاسمًا في نجاح عملية التعلم (ادراك، 202).

دوال التنشيط (Activation Functions)

تستخدم دوال التنشيط لتحديد ما إذا كان العصبون يجب أن ينشط بناءً على المدخلات. من بين الدوال الشائعة:


- دالة Sigmoid : وهي الدالة التي تخرج قيمة بين 0 و 1، مما يجعلها مفيدة في مهام التصنيف الثنائي.
- دالة ReLU (Rectified Linear Unit) : وهي الدالة التي تُستخدم على نطاق واسع في الشبكات العميقة، حيث تعمل على تنشيط العصبونات فقط عندما تكون المدخلات موجبة.
- دالة Tanh : وهي الدالة التي تُعطي قيمًا بين -1 و 1، وتُستخدم في بعض التطبيقات التي تتطلب نتائج مركزية حول الصفر (حجاج وعبدالقادر، 2020).

عملية التدريب (Training Process)

تتضمن عملية تدريب الشبكة العصبية استخدام مجموعة بيانات لتحديث الأوزان عبر عدة تكرارات. يتم حساب الخطأ بين النتائج المتوقعة والنتائج الفعلية، ومن ثم تُستخدم خوارزمية الانحدار التدرجي لتقليل هذا الخطأ من خلال تعديل الأوزان (Huang and Hieu Le, 2021).

التخصيص (Overfitting)

التخصيص يحدث عندما يتعلم النموذج تفاصيل البيانات التدريبية بشكل مفرط، مما يؤدي إلى أداء ضعيف عند اختبار النموذج على بيانات جديدة. يمكن تقليل هذا التخصيص من خلال أساليب مثل: التوقف المبكر وذلك بإيقاف التدريب عندما يبدأ الأداء في الانخفاض، بالإضافة إلى التنظيم ويتم بإضافة قيود على الأوزان للحد من التعقيد (الدباغ، 2021).



شكل (1): نموذج مبسط للشبكة العصبية الاصطناعية.

من الشكل (1) نلاحظ أن الشبكة العصبية تتكون من ثلاثة شرائح كما يلي:

- أ- شريحة المدخلات Input Layer وتشمل قيم X .
- ب- شريحة مخفية Hidden Layer وتشمل W والعمليات الناتجة عن العمليات المخفية.
- ج- شريحة المخرجات output Layer وتشمل قيم y .

خصائص الشبكات العصبية الاصطناعية

- التكيف: يمكن للشبكات العصبية تعديل أوزانها بناءً على البيانات الجديدة، مما يجعلها قادرة على التعلم (Goodfellow et al., 2016).
- القدرة على التعامل مع البيانات غير الخطية: تستطيع الشبكات العصبية التعامل مع العلاقات المعقدة بين البيانات.
- المرونة: يمكن استخدامها في مجموعة متنوعة من التطبيقات، من التعرف على الصور إلى معالجة اللغة الطبيعية.

أنواع الشبكات العصبية الاصطناعية

الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية (MLPs)

تعد الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية نوعاً من الشبكات العصبية التقليدية. تتكون هذه الشبكات من طبقة مدخلات، وواحدة أو أكثر من الطبقات المخفية، بالإضافة إلى طبقة مخرجات. تحتوي كل طبقة على مجموعة من الخلايا العصبية (neurons) التي تتصل ببعضها البعض. تتميز MLPs بفعاليتها في حل مسائل التصنيف والتنبؤ، حيث يمكنها التعلم من الأنماط المعقدة في البيانات. ومع ذلك، يمكن أن تكون عرضة للتخصيص المفرط، خاصة عند العمل مع مجموعات بيانات صغيرة. كما أن هذه الشبكات ليست مثالية لمعالجة البيانات التسلسلية أو الزمنية (Bishop، 2006).

الشبكات العصبية التلافيفية (CNNs)

تستخدم الشبكات العصبية التلافيفية بشكل رئيسي في معالجة الصور والفيديو. تعتمد هذه الشبكات على عمليات التلافيف لاستخراج الميزات من البيانات، مما يجعلها فعالة في التعرف على الأنماط من مزاياها

أنها لا تحتاج إلى ميزات مصممة يدويًا، ولكنها تحتاج إلى كميات كبيرة من البيانات للتدريب، مما قد يجعل تصميمها أكثر تعقيدًا (LeCun et al, 1998).

الشبكات العصبية المتكررة (RNNs)

تُستخدم الشبكات العصبية المتكررة لمعالجة البيانات التسلسلية. تحتوي هذه الشبكات على حلقات تسمح بتخزين المعلومات من الخطوات السابقة لاستخدامها لاحقًا. تعتبر RNNs مناسبة لمهام مثل تحليل النصوص والتنبؤ بالسلاسل الزمنية، لكنها قد تواجه مشاكل في تلاشي التدرجات، الأمر الذي يؤثر سلبيًا على التعلم في الشبكات العميقة (Rumelhart et al, 1986).

الشبكات العصبية طويلة وقصيرة الأمد (LSTM)

تعتبر LSTM نوعًا متطورًا من RNNs، حيث تم تصميمها للتغلب على مشكلة تلاشي التدرجات. تحتوي هذه الشبكات على خلايا ذاكرة تساعد في تخزين المعلومات لفترات طويلة، وتستخدم بوابات للتحكم في تدفق المعلومات. تُعتبر LSTM فعالة في معالجة البيانات الزمنية مثل النصوص والموسيقى (Hochreiter & Schmidhuber, 1997).

الشبكات العصبية التوليدية (GANs)

تشمل هذه الشبكات نماذج مثل الشبكات التوليدية المعاكسة (GANs)، التي تستخدم لإنشاء بيانات جديدة تشبه البيانات المدربة عليها. تعتمد هذه الشبكات على نموذجين: المولد والمميز، مما يجعلها فعالة في توليد الصور والفيديو والمحتويات (Goodfellow et al, 2014).

الشبكات العصبية التلافيفية المتكررة (ConvLSTM)

تجمع ConvLSTM بين CNN و LSTM، وتُستخدم بشكل خاص في معالجة بيانات الفيديو أو أي بيانات تتطلب معالجة زمنية ومكانية. تتميز هذه الشبكات بقدرتها على التعامل مع البيانات التي تحتوي على أبعاد زمنية ومكانية، مما يجعلها فعالة في تحليل الفيديو والتنبؤ بالحركة (Shi et al, 2015).

الشبكات العصبية متعددة المدخلات والمخرجات

تُستخدم هذه الشبكات في الحالات التي يمكن أن تحتوي فيها كل عينة بيانات على أكثر من فئة واحدة. تحتوي هذه الشبكات على طبقة مخرجات متعددة، مما يوفر مرونة في التصنيف ويسمح بتصنيف العينات في أكثر من فئة. تُستخدم في تطبيقات مثل تصنيف الصور التي تحتوي على عدة عناصر (Zhang & Schneider, 2010).

الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية (MFNN)

الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية والتي استخدمت في هذه الدراسة هي نوع من الشبكات العصبية الاصطناعية التي تتكون من عدة طبقات. تتضمن هذه الشبكات طبقة مدخلات، وواحدة أو أكثر من الطبقات المخفية، وطبقة مخرجات. في هذه الشبكات تتصل كل خلية عصبية في طبقة معينة بكل الخلايا العصبية في الطبقة التالية، مما يسمح بتدفق المعلومات بشكل أحادي الاتجاه، من المدخلات إلى المخرجات.

كيفية عمل MFNN

- المدخلات: يتم إدخال البيانات إلى طبقة المدخلات.
 - الجمع الموزون: تقوم العناصر الحسابية في الطبقة المخفية بإجراء الجمع الموزون وترسل النتائج إلى طبقة المخرجات والتي تقوم هي الأخرى بعملية الجمع الموزون للشبكة كلها.
 - الخطوة الأمامية: يتم حساب مخرجات الشبكة من البيانات المدخلة ومقارنة هذه المخرجات مع المخرجات المستهدفة عن طريق حساب الخطأ.
 - الخطوة التراجعية: تقوم الشبكة فيها بتعديل الأوزان النسبية بهدف تصغير الخطأ.
 - عملية التعليم: يتم تحديث الأوزان باستخدام التعلم بالتغذية الخلفية.
- تسمى العملية التي تضم مرحلتي الخطوة الأمامية والتراجعية بالدورة (Epoch)، ويتم تكرار هذه الدورة إلى أن تصل لأصغر مجموع مربعات للخطأ (حجاج وعبدالقادر، 2020).

أهمية الشبكات العصبية في التنبؤ

التنبؤ هو العملية التي يتم من خلالها استخدام البيانات والنماذج الرياضية لتقدير النتائج المستقبلية. يستخدم التنبؤ في مجالات متعددة مثل الاقتصاد والطب والهندسة والتسويق (Hyndman & Koehler, 2002). تكمن أهمية التنبؤ في عدة جوانب:

- تحسين اتخاذ القرار: يوفر التنبؤ معلومات دقيقة تدعم اتخاذ قرارات مستنيرة
- توفير الوقت والموارد: من خلال التنبؤ الدقيق، يمكن تقليل الهدر في الموارد.
- زيادة الكفاءة: يمكن أن يؤدي التنبؤ الجيد إلى تحسين العمليات وزيادة الإنتاجية.

يعتبر التنبؤ بأنه الوظيفة التي تضبط المستقبل استناداً إلى معلومات موثوق بها حول موضوع معين وتطوراته، وبالتالي يكون الهدف الوصول الى التنبؤ الأكثر دقة وكفاءة من خلال إيجاد نموذج رياضي يعطينا توقع أقرب إلى الواقع. والجدير بالذكر هنا أن الشبكات العصبية الاصطناعية أداة قوية في مجال التنبؤ، حيث توفر دقة عالية بفضل قدرتها على التعلم من البيانات الكبيرة والمعقدة (Haykin, 1999). يلعب التنبؤ دوراً هاماً في كل المجالات وأغلب وظائف المؤسسات ولاسيما في المؤسسات الإنتاجية والمالية وبحوث السوق وغيرها (Fawaz et al, 2019). حيث يساعد التنبؤ في مراقبة وتسيير الجهود المبذولة من طرف الإدارة لمتابعة تطورها، كما تبرز أهمية التنبؤ في بحوث السوق التي تدرس الطلب المتوقع على منتج معين أو خدمة معينة، كذلك تحديد الأرباح المتوقعة للمؤسسة خلال فترة زمنية معينة (Tsay, 2005)، بالإضافة إلى أن التنبؤ يساعد في تقدير الاحتياجات من اليد العاملة حسب التخصص والمجال الوظيف وتحديد نفقات الأجور المناظرة لذلك. كما أن التنبؤ يعمل تحسين استراتيجيات التسويق من خلال تحليل سلوك المستهلكين، وكذلك التنبؤ في المجال الطبي من خلال تحليل الصور الطبية لتشخيص الأمراض (Litjens et al, 2017).

تعد الشبكات العصبية الاصطناعية من الأدوات الفعالة في مجال التنبؤ، حيث تجمع بين القدرة على التعلم من البيانات والتكيف مع التغيرات. مع استمرار تطور التكنولوجيا، من المتوقع أن تلعب هذه الشبكات دوراً متزايد الأهمية في تحسين دقة التنبؤات عبر مختلف المجالات (Goodfellow et al, 2016).

قياس دقة التنبؤ

لقياس دقة التنبؤ يتم الاعتماد في ذلك على قياس الانحرافات بين القيم الفعلية للسلسلة الزمنية والقيم المقدره لنفس السلسلة ومن أهم هذه المقاييس والذي تم استخدامه في هذه الدراسة هو متوسط مربع الخطأ Mean Squared Error (MSE). يحسب هذا المقياس وفق المعادلة التالية (Ali Shetwan, 2023):

$$MSE = \frac{\sum_t^n (y_t - \hat{y}_t)^2}{n}$$

y_t : هي القيم الفعلية أو القيم الحقيقية في الفترة t .

\hat{y}_t : هي القيم المقدره أو القيم التنبؤية عند الفترة t .

n : عدد الفترات التي يتم التنبؤ لها.


الجانب التطبيقي للدراسة:

تناول الجزء التطبيقي والعملي لهذه الدراسة كيفية إيجاد القيم التنبؤية لمبيعات مصنع اسمنت زليتن من خلال البيانات المعطاة في الفترة الزمنية من 1992 إلى 2022 (13 سنة) حيث تم الاستعراض المبدئي للبيانات من خلال شكل الانتشار وبعض الاختبارات الأولية الهامة.

الشكل الانتشاري للبيانات:

من أولى خطوات وصف وتحليل السلسلة الزمنية هو تمثيلها بيانياً بما يعرف بالشكل الانتشاري للبيانات لغرض معرفة الاتجاه العام للسلسلة ومدى استقرارها، كما هو مبين في الشكل (2):

cement production



شكل (2): الشكل البياني للسلسلة الزمنية لمبيعات إنتاج الاسمنت.

واضح من خلال الشكل (2) أن هناك تذبذب في قيم مبيعات إنتاج الاسمنت، حيث كان هناك تزايد في قيمة المبيعات باستثناء سنة 2011، لتعود لترتفع قيمة المبيعات من جديد حتى انخفضت سنة 2017 لتعود إلى الارتفاع مجددا في نهاية الفترة.

اختبار طبيعية البيانات

للقيام باختبار طبيعية البيانات تم استخدام اختبار كولمجروف وشابيرو بالاعتماد على برمجية SPSS وكانت النتائج موضحة بالجدول (1).

جدول (1): اختبار الاعتدالية.

| Tests of Normality | | | | | | |
|--------------------|--------------------|----|------|--------------|----|------|
| | Kolmogorov-Smirnov | | | Shapiro-Wilk | | |
| | Statistic | Df | Sig. | Statistic | Df | Sig. |
| إنتاج الاسمنت | .147 | 31 | .085 | .857 | 31 | .001 |

واضح من خلال الجدول (1) أن البيانات حسب اختبار شابيرو حيث أن العينة أصغر من 50 لا تتوزع وفق التوزيع الطبيعي.

اختبار استقرار السلسلة الزمنية

من الخطوات المهمة كذلك في تحليل السلاسل الزمنية هو اختبار استقرار السلسلة لتكون مناسبة للعديد من النماذج التي نحتاجها للتنبؤ بالقيم المستقبلية عليه فقد اخترنا في هذه الدراسة أحدها وأشهرها وهو اختبار ديكي فولر المعدل Augmented Dickey Fuller test وكانت نتائج الاختبار كما في الجدول (2).

جدول (2): اختبار ديكي فولر المعدل Augmented Dickey Fuller test

| Prob.* | t-Statistic | Augmented Dickey-Fuller test statistic | |
|--------|-------------|----------------------------------------|-----------------------|
| 0.9794 | 0.412637 | 1% level | Test critical values: |
| | -3.724070 | 5% level | |
| | -2.986225 | 10% level | |
| | -2.632604 | | |

يتضح من خلال الجدول (2) أن السلسلة الزمنية غير مستقرة في المستوى وذلك من خلال قيمة p -value حيث كانت (0.9794) ولذلك فقد تم معالجة هذه المشكلة من خلال أخذ اللوغاريتم لقيم السلسلة.

تطبيق طريقة الشبكات العصبية الاصطناعية

لقد اعتمدنا في هذه الدراسة على أسلوب الشبكة متعددة الطبقات ذات التغذية الأمامية (Multi-(MFNN) Layer Feed Forward Neural Network، حيث يستطيع هذا النوع من الشبكات حل الكثير من المشاكل التي قد تتعرض لها والتي لا تستطيع الشبكات ذات الطبقة الواحدة إيجاد حلول لها. بالإضافة إلى أن هيكل هذا النوع من الشبكات يعتبر الأكثر استخداماً من بين العديد من هياكل الشبكات العصبية. كما أننا استخدمنا برنامج الماتلاب لتحليل هذا النوع من الشبكات.

توصيف النموذج بطريقة الشبكات العصبية

تم توصيف النموذج بطريقة الشبكات العصبية من خلال مجموعة من الخطوات وهي كما يلي :

1- دراسة بيانات المدخلات والمخرجات

إن تهيئة وتجهيز البيانات هي الخطوة الأولى والأساسية لتحليل البيانات، وذلك لتصبح صالحة لإجراء العمليات الحسابية عليها ولكي نحصل منها على نتائج وتنبؤات دقيقة. وتتم هذه التهيئة على مرحلتين هما مرحلة الفصل ومرحلة التحويل.

• مرحلة الفصل

وهي المرحلة التي يتم فيها تكوين مجموعة البيانات الخاصة بمرحلة التدريب ومرحلة الاختبار، وهي مرحلة وخطوة مهمة لتحديد مدى فعالية النماذج الإحصائية ونماذج الشبكات العصبية الاصطناعية، وذلك من خلال تزويد كلا النموذجين ببيانات مدخلة، ومن ثم مراقبة ما إذا كانت مخرجات كل نموذج تعطي النتائج المتوقعة، وفي سبيل تحقق ذلك يتم تقسيم البيانات المتاحة إلى مجموعتين:

- أ- مجموعة التدريب: وهذه المجموعة تحتوي على $n-3$ مشاهدة وتستخدم للحصول على النموذج المناسب.
- ب- مجموعة الاختبار: وهذه المجموعة تحتوي على الثلاثة مشاهدات الأخيرة. ويجب ملاحظة أن المجموعة التي تستخدم في التدريب لا تستخدم في الاختبار.

• مرحلة التحويل

غالبية نماذج الشبكات العصبية تستخدم دوال رياضية لتحويل البيانات المخرجة من هذه الشبكات، حيث تنحصر هذه القيم بين $[0,1]$. وذلك بغرض استخدام بعض الدوال المنطقية عليها كدوال تفعيلية.

2- هيكل بناء الشبكة:

بفرض أن الشبكات العصبية الاصطناعية كنموذج انحدار غير خطي كما يلي:

$$Y = v(X) + \varepsilon$$

حيث يفترض أن $E(\varepsilon/X) = 0$ ، وكذلك الدالة $v(X) = E(Y/X)$ غالباً ما تكون غير معلومة ويتم تقريبها بواسطة الدالة $g(X, W)$ وعلى ذلك فإن نموذج الشبكة العصبية المقرب من الممكن أن يكون على الصيغة التالية:

$$Y_{t+1} = g(X, W) + \varepsilon_{t+1}$$

وبالتالي كما أشرنا سابقاً أن الهيكل البنائي للشبكة المعتمد في هذه الدراسة هو الشبكة متعددة الطبقات ذات التغذية الأمامية لتميزها لتحليل بيانات هذا النوع من الدراسات والتطبيقات.


تقدير معالم النموذج

يقصد بتقدير معالم النموذج هنا هو تقدير أوزان الشبكة باستخدام أسلوب الشبكات العصبية الاصطناعية، وللوصول إلى ذلك يجب جعل متوسط مربعات الخطأ MSE أقل ما يمكن. ومن الممكن تحقيق ذلك بواسطة تدريب الشبكة من خلال مجموعة بيانات التدريب، حيث تمثل هذه الأوزان المعلومات الأولية التي سنتعلم بها الشبكة. لذا لا بد من تحديث الأوزان خلال مرحلة التدريب، ومن أجل هذا التحديث تستخدم عدة خوارزميات مختلفة (داخل حزم الماتلاب) حسب نوع الشبكة، ومن أهم هذه الخوارزميات خوارزمية الانتشار العكسي التي تستخدم في تدريب الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية وغير الخطية، وتتم عملية تدريب الشبكة داخل برنامج MATLAB باتباع الخطوات التالية:

أ- إنشاء الشبكة وهي الخطوة الأولى في تدريب الشبكة، حيث نقوم بإنشاء شبكة تغذية أمامية عكسية للخطأ من خلال تنفيذ الأمر التالي

$$net = fitnet(2, trainlm)$$

ب- التدريب خلال عملية التدريب تتغير أوزان الشبكة والانحياز بشكل دوري حتى الوصول إلى القيمة الصغرى لتابع الكلفة أو ما يسمى تابع الأداء، إن تابع الأداء الافتراضي لشبكات التغذية الأمامية يعبر عنه بمتوسط مربع الخطأ (MSE). والشكل (3) يوضح ذلك.




شكل (3): نتائج مخرجات الاختبار والتدريب والخطأ للشبكة.

ان الهدف الأساسي من استخدام أسلوب التغذية الخلفية في التدريب هو حساب الخطأ بين المخرجات المستهدفة والمخرجات الفعلية في طبقة المخرجات ثم إعادته مرة أخرى لكل طبقة خفية من أجل تعديل أوزان الاتصال حتى يتم الوصول إلى طبقة المدخلات، ويتم هذا التعديل في الأوزان إلى أن تحقق الشبكة أقل مجموع مربع أخطاء عند التدريب.

التحقق من صلاحية النموذج

تعتبر هذه الخطوة من أهم خطوات تحليل الشبكات العصبية الاصطناعية، حيث تتم على أساسها مدى قبول النموذج الذي تم توصيفه وتقديره، وبناء على هذه المرحلة يحدد إذا ما سوف يتم الاستمرار في التحليل وتحقيق ما هو متوقع من نموذج التحليل أو العودة إلى نقطة البداية من تحديد ثم تقدير وأخيراً اختبار، وسيتم اختيار النموذج الذي سيحقق أقل متوسط مربعات خطأ MSE والذي تم حسابه باستخدام برنامج MATLAB. بالإضافة إلى معايير أخرى والتي تتمثل في عدد مرات إجراء تعديل الأوزان (معالم النموذج) وتسمى Epoch والتي يمكن التحكم بها في النموذج كما في الشكل (4) حيث تم إجراء Epoch 10 للوصول إلى أفضل أداء للشبكة لتحقيق أقل أخطاء ممكنة والذي تحقق عند 4 Epoch.



شكل (4): متوسط مربعات الخطأ (MSE).

استخدام النموذج في التنبؤ:

تأتي مرحلة التنبؤ بالمشاهدات المجهولة للظاهرة والتي تمثل في دراستنا مبيعات انتاج الاسمنت بمصنع اسمنت زليتن بعد التأكد من صلاحية النموذج، ولقد تم قياس كفاءة نموذج الظاهرة المدروسة بمدى قدرتها على تمثيل الواقع والتوقع للقيم المجهولة من خلال قياس مقدار الخطأ للنموذج. ولقد تم استخدام برنامج **MATLAB** الذي من خلال أكواد مناسبة لاستخدام الشبكات العصبية الاصطناعية للوصول الى النموذج الأمثل المستخدم للتنبؤ، حيث تم ذلك من خلال الدالة التالية

$$Y = sim(net, X)$$


حيث

Y : تمثل القيم التنبؤية للثلاثة قيم المجهولة باستخدام أسلوب الشبكات العصبية الاصطناعية.

net : تمثل الشبكة المدربة.

X : تمثل البيانات التي تم استخدامها لتدريب الشبكة والتي حجمها $n-3$

ولحساب دقة القيم التنبؤية تم استخدام مقياس احصائي يعتمد على حساب الفرق بين القيم التنبؤية والقيم الفعلية وهو ما يسمى بالباقي **MSE** والذي كانت قيمته 2.02997 والشكل (5) يوضح كلا من القيم الفعلية والتنبؤية للدراسة.



شكل (5): القيم الفعلية والتنبؤية لمبيعات الاسمنت.

شكل (4) يوضح تقارب بشكل كبير بين القيم التنبؤية والقيم الفعلية وما يؤكد ذلك قيمة MSE والتي تساوي 2.02997 مما يؤكد جودة النموذج الناتج من الشبكات العصبية الاصطناعية وكفاءته للتنبؤ بالقيم المجهولة والمستقبلية لمبيعات الاسمنت بمصنع زليتن.

الخاتمة

من خلال هذه الدراسة تبين أن استخدام أسلوب الشبكات العصبية الاصطناعية وبالتحديد أسلوب الشبكة متعددة الطبقات ذات التغذية الأمامية (MFNN) على بيانات مبيعات مصنع الاسمنت بزليتن خلال الفترة الزمنية (1992-2022) بهدف التنبؤ بالمبيعات في المستقبل من خلال بناء وتدريب نموذج لذلك، أظهرت نتائج الدراسة أن أسلوب الشبكات العصبية حقق نتائج ذات كفاءة ودقة عالية وذلك من خلال تحقيقه نسبة خطأ صغيرة بلغت 2.02997. من خلال النتائج نوصي بضرورة ادخال الأساليب الذكية في عملية التنبؤ بالمبيعات، كأسلوب الشبكات العصبية الاصطناعية لمدى كفاءته ودقته في عملية التنبؤ.

المراجع

- 1- ابوليفة، فرج؛ شتوان، قاسم (2023). التنبؤ بالمبيعات باستخدام الشبكات العصبية الاصطناعية، المجلة الدولية للعلوم الهندسية وتقنية المعلومات، المجلد 11، العدد 1، ص 27-36.
 - 2- البياتي، عصام؛ المخلافي، فؤاد (2007). استخدام اسلوب بوكس جينكنز – للتنبؤ بإنتاجية العمل في مصنع اسمنت عمران في القطاع الصناعي اليمني، مجلة الادارة والاقتصاد، العدد 63 ص 25-48.
 - 3- حامد، عماد (2011). استخدام نماذج بوكس جنكنز ونماذج الشبكات العصبية الاصطناعية للتنبؤ في السلاسل الزمنية للقطاع الزراعي السوداني، المؤتمر الدولي الثالث للإحصائيين العرب، عمان، الأردن، ص 511-541.
 - 4- حجاج، عبد الوهاب؛ عبد القادر، محمد (2020). استخدام الذكاء الاصطناعي والانحدار الحصين للتنبؤ بمعدلات المواليد في مصر، المجلة العلمية لقطاع كلية التجارة جامعة الازهر، العدد 24 ص 600-637.
 - 5- الدباغ، سامي. (2021). مقدمة في تعلم الآلة والشبكات العصبية. دمشق: دار الكتب العلمية.
 - 6- عبد الله، عادل. (2018). الشبكات العصبية الاصطناعية. القاهرة: دار المعرفة.
 - 7- عبدالحق، سمادي؛ هشام، توفيق (2022). التنبؤ بالمبيعات باستخدام الشبكات العصبية الاصطناعية - دراسة حالة سونلغاز وكالة اولف، أطروحة ماجستير، جامعة أحمد دراية، الجزائر.
 - 8- العجال، عدالة (2010). نمذجة التنبؤ بالمبيعات باستخدام الشبكات العصبية دراسة حالة الشركة الوطنية للصناعات الميكانيكية ولواحقها، مجلة العلوم الاجتماعية والإنسانية، العدد 22، ص 176-202.
 - 9- الموسوعة العربية. (2020). الشبكات العصبية. تم الاسترجاع من [الموسوعة العربية].
<https://www.encyclopedia.com/philosophy-and-religion/bible/biblical-proper-names/arab> 25.11.2024
 - 10- إدراك. (2021). دورة تعليمية في الشبكات العصبية. تم الاسترجاع من [منصة إدراك].
<https://www.edraak.org/course/course-v1:edraak+neural-networks+2021/about> 25.11.2024
1. Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
 2. Chen, Y., & Zhou, H. (2019). Applications of neural networks in business forecasting. Journal of Business Research, 102, 102-109.
 3. Fawaz, I. H., et al. (2019). Deep learning for time series classification: A review. Data Mining and Knowledge Discovery, 33(4), 917-963.
 4. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

5. Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice Hall.
6. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
7. Huang, S.C. & Hieu Le, T. (2021). *Principles and Labs for Deep Learning*, Academic Press, Pages 27-55.
8. Hyndman, R. J., & Koehler, A. B. (2002). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688.
9. LeCun, Y., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
10. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
11. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. J., & Ghafoorian, M. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
12. Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
13. Shi, H., Gao, J., & Wang, Y. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Proceedings of the IEEE International Conference on Computer Vision*, 802-810.
14. Siegel, S., & Castellan, N. J. (1988). *Nonparametric Statistics for the Behavioral Sciences*. McGraw-Hill.
15. Tsay, R. S. (2005). *Analysis of Financial Statements*. Wiley
16. Zhang, M., & Schneider, J. (2010). Multi-Label Learning with Multi-Label Neural Networks. *Journal of Machine Learning Research*, 11, 2671-2699.
17. Zhang, Y., Wang, S., & Lu, J. (2018). A survey on multi-label learning. *Artificial Intelligence Review*, 50(1), 1-26.