

التنبؤ بالمبيعات باستخدام الشبكات العصبية الاصطناعية ANN

علي قاسم شتوان
كلية الهندسة، جامعة مصراتة، ليبيا
قسم الهندسة الصناعية والتصنيع
ali.shetwan@eng.misuratau.edu.ly

فرج علي ابوليفة
كلية التقنية الصناعية-مصراتة
قسم الهندسة الصناعية
Faraj.abulifa@gmail.com

المؤسسات التي لا تستخدم طرق التنبؤ في التنبؤ بالمبيعات لا تستطيع أن تتوقع إيرادات المبيعات القابلة للتحقيق والتخطيط للنمو المستقبلي [2]. إن التطور التكنولوجي الذي شهدته المنظمات في هذا العصر، وظهور الحوسبة المعلوماتية الذكية والتي أثبتت نجاحها في ميادين تقنية مختلفة، حاول الباحثون المهندسون الاعتماد عليها في محاولة لزيادة القدرة على التنبؤ بالمستقبلي [3]. من أهم هذه التقنيات المستخدمة في مجال الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN) التي أثبتت نجاحاتها في حالات عديدة منها التنبؤ بالسلاسل الزمنية، والتي تعتبر إحدى أهم المجالات التي استخدمت فيها الشبكات العصبية الاصطناعية كأسلوب بديل أو موازي لأساليب تحليل السلاسل الزمنية، لما لها من دقة في نتائجها. فهذه الطريقة تُعد من بين أهم الطرق المستخدمة في التنبؤ بالمبيعات والتي تفيد في رصد بعض سلوك المتغيرات في الماضي، والتنبؤ بسلوكها المستقبلي [3]. الفكرة الأساسية من الخلايا العصبية هي إنشاء نموذج معلوماتي يحاكي النظام البيولوجي العصبي للإنسان، وطريقة تعلمها تتشابه مع تعلم الإنسان من خلال الأمثلة والتدريب، والتعلم في النظام البيولوجي يستخدم فيه تكييف نقاط الاشتباك العصبي بين العصبونات، وهذه هي الفكرة الجوهرية في عمل الشبكات العصبية [2].

يهدف هذا البحث لدراسة تطبيق أسلوب السلاسل الزمنية من خلال تقنية الشبكات العصبية الاصطناعية في التنبؤ بحجم مبيعات الشركة الليبية للحديد والصلب بمصراتة. سيتم تطبيق الدراسة على البيانات الشهرية لمنتجات مصنع القضبان والأسياخ خلال الفترة الزمنية من 2012م إلى 2021م للتنبؤ بحجم المبيعات الشهرية لسنة 2022م. سيتم بناء نموذج الشبكات العصبية باستخدام شبكة بيرسبترون متعدد الطبقات (MLP) Multilayers Perception، ويستخدم لتدريب هذه الشبكة خوارزمية التدريب ذات الانتشار الخلفي.

2. الدراسات السابقة

العديد من الدراسات السابقة تناولت موضوع التنبؤ بالمبيعات بأساليب ونماذج مختلفة، وصنفت طرق التنبؤ إلى طرق نوعية وأخرى كمية. طرق التنبؤ النوعية تكون مناسبة فقط في حالة عدم توفر بيانات سابقة عن السلعة، وهي طريقة تقدير تعتمد أساساً على حكم الخبراء بدلاً من التحليل العددي، ومن أهم طرق التنبؤ النوعية طريقة دلفي وأبحاث السوق. دراسة Martinovic و Janovic ذكر الباحثان أن أساليب التنبؤ النوعية تستخدم في الحالات التي لا يمكن استخدام الأساليب الكمية للتنبؤ بها، أو عندما لا تتوفر لدى الشركة البيانات الكافية، على سبيل المثال عند إطلاق خط إنتاج جديد. كذلك تستخدم هذه الأساليب عندما تكون الأسواق مضطربة بسبب الحروب أو الكوارث الطبيعية أو في حالات الركود أو التضخم، وكذلك تستخدم جنباً إلى جنب مع التقنيات الكمية، ففي دراسة استقصائية حديثة شملت 207 شركة، وجد أن 76% من الشركات تقوم بتعديل التوقعات الناتجة من الأساليب الكمية بناءً على خبرة المدير [4]. عندما تتوفر بيانات تاريخية كافية وقابلة للقياس والمعالجة، وللتنبؤ على المدى القصير أو البعيد، يتم استخدام الأساليب الكمية ومن أهمها: الانحدار

المخلص— إن عملية التنبؤ بالمبيعات تعتبر من القرارات الاستراتيجية بإدارة التخطيط في المؤسسات الصناعية، ومشكلة تحديد الطاقة الإنتاجية اللازمة لتغطية حجم الطلب على منتجاتها من أصعب المشكلات التي تواجه إدارة المؤسسة الصناعية. تكمن مشكلة الدراسة في أن الأساليب التقليدية للتنبؤ بالمبيعات والتي تستخدمها العديد من المؤسسات المحلية غير فعالة، لأنها في حالة عدم تقدير حجم المبيعات بالصورة الصحيحة، يحدث خلل في عملية التوازن بين كمية الإنتاج والمبيعات، مما يترتب على ذلك تكاليف إضافية للمؤسسة. تهدف هذه الدراسة إلى استخدام أسلوب الشبكات العصبية الاصطناعية ANN للتنبؤ بحجم المبيعات الشهرية بالشركة الليبية للحديد والصلب لمنتجات مصنع درفلة القضبان والأسياخ، باستخدام خوارزمية الانتشار الخلفي. استخدمت عدد 120 مشاهدة شهرية لسلسلة زمنية للمبيعات الشهرية بداية من 1 يناير 2012م وحتى 31 أكتوبر 2021م، وفي مرحلة التنبؤ استخدمت عدد 12 مشاهدة شهرية لسنة 2022م لاختبار النموذج. بعد ذلك تمت مقارنة القيم الفعلية بنتائج أسلوب ANN ومع أسلوب الانحدار الخطي والتمهيد الآسي، اعتماداً على المعايير الإحصائية $RMSE$ ، $MAPE$ ، $MSRE$. استخدم برنامج MATLAB لحل النماذج الرياضية لخوارزمية ANN، وبرنامج Minitab للتنبؤ بالمبيعات بأسلوب الانحدار الخطي والتمهيد الآسي. أظهرت نتائج الدراسة أن أسلوب الشبكات العصبية الاصطناعية بنموذج 12 مدخل و 3 طبقات مخفية وخرج واحد، [12-7-5-1]، حقق نتائج جيدة جداً، وتفوق على أسلوب الانحدار الخطي، والتمهيد الآسي، وكذلك على أسلوب المتوسط المتحرك المستخدم من قبل الشركة، حيث حقق أقل نسبة خطأ $MAPE=28.62\%$ ، $MSRE=17.32\%$ ، $RMSE=10532.741$ وبمعامل ارتباط موجب قوي $R=0.74703$. هذه القيم تدل على كفاءة وفعالية نموذج ANN مقارنة بقيم الأساليب الأخرى. أوصت الدراسة بضرورة إدخال الأساليب الحديثة والذكية في عملية التنبؤ بالمبيعات، كأسلوب الشبكات العصبية الاصطناعية لما له من أثر إيجابي في عملية التخطيط.

الكلمات المفتاحية— الشبكة العصبية الاصطناعية، التنبؤ، الإنتاج، المبيعات، المعايير الإحصائية.

1. المقدمة

يعتبر التنبؤ بالمبيعات من المواضيع الهامة والأساسية في وضع الخطط التنموية لاقتصاد أي مؤسسة، لكونه يقدم الأجوبة العلمية حول التساؤلات المتعلقة بمستقبل أي ظاهرة من الظواهر الاقتصادية. يُعد التنبؤ الوسيلة التي يستطيع بواسطتها المخطط رؤية الوضع المستقبلي للظاهرة المدروسة، ومحاولة كشف غموضها. عادة ما تكون مبيعات المؤسسة عرضة للزيادة أو النقصان تبعاً لعوامل وظروف مختلفة، لذلك فإن مدى قدرة إدارة المؤسسة على التنبؤ بمبيعاتها سيكون له أثر ملحوظ على مستقبلها بشكل عام، وسيمثل الأساس الذي ستبنى عليه المؤسسة خططها وبرامجها وقراراتها المستقبلية. لتلبية طلبات الزبائن ينبغي على أي مؤسسة اتباع استراتيجية دقيقة لضمان سير عملياتها بالطريقة الصحيحة، والاستغلال الأمثل لمواردها المتاحة من خلال طرق مبنية على أسس علمية تمكنها من ممارسة جميع وظائفها الاقتصادية [1].

استلمت الورقة بالكامل في 14 أكتوبر 2023 وروجعت في 22 أكتوبر 2023 وُقبلت للنشر في 25 ديسمبر 2023

ونشرت ومتاحة على الشبكة العنكبوتية في 28 ديسمبر 2023.

الشبكات العصبية الاصطناعية في التنبؤ بحجم المبيعات لمؤسسة سونلغاز بالشلف بدولة الجزائر. أجريت الدراسة على البيانات الشهرية لمبيعات الكهرباء بالكيلو وات ساعة خلال الفترة الزمنية من يناير 2006م إلى ديسمبر 2012م. تم بناء نماذج الشبكات العصبية باستخدام شبكة البيورسبترون متعددة الطبقات، والذي تكونت بنيتها المعمارية من ثلاث طبقات، كما استخدمت لتدريب هذه الشبكات خوارزمية الانتشار الخلفي. توصلت الدراسة إلى أن الشبكة الناتجة جيدة وأعطت تنبؤات دقيقة وقريبة من الواقع في الفترة من 1 يناير إلى 31 ديسمبر 2013م [1]. دراسة الظفيري تناولت استخدام الشبكات العصبية والأساليب الإحصائية التقليدية لتنبؤ بأعداد الركاب على الخطوط الجوية الكويتية، حيث قارن الباحث بين كل من تحليل الانحدار المتعدد، وتحليل السلاسل الزمنية والشبكات العصبية. توصلت الدراسة إلى أن نموذج الشبكات العصبية يُعد أفضل نموذج يلائم بيانات المسافرين بخط الكويت - القاهرة على الخطوط الجوية الكويتية، حيث بلغت مقاييس الأخطاء أقل ما يمكن في نموذج الشبكات العصبية ويمكن الاعتماد عليه بالتنبؤ بأعداد المسافرين مستقبلاً [11]. دراسة Kosanan و Kantanantha هدفت إلى التنبؤ بإنتاج تايلاند من المطاط من خلال استخدام ثلاث تقنيات مختلفة وهي المتوسطات المتحركة، والشبكات العصبية الاصطناعية، وتعليم الآلة. أظهرت نتائج الدراسة أن الشبكات العصبية الاصطناعية حققت أدنى متوسط في نسبة الخطأ 0.0037%، ومع ذلك لم يكن هناك فارق ذات صلة دلالية بين جميع الطرق المستخدمة. هذا البحث يؤكد أيضاً على أهمية الشبكات العصبية في التنبؤ وأهمية التنبؤ في خدمة مجالات كثيرة [12]. دراسة Monika هدفت إلى تقديم خوارزمية جديدة خاصة تستخدم السلاسل الزمنية بشكل غير تقليدي للتنبؤ بمؤشرات السوق والأسهم وتستند على الشبكات العصبية الاصطناعية وخوارزمية Wavelet. أثبتت نتائج الدراسة أن الخوارزمية تعطي نتائج جيدة بالتوقعات، وأفضل من الطرق التقليدية، وقد اعتمدت على العديد من السلاسل الاقتصادية. أثبتت النتائج كذلك أنه يمكن استخدام الخوارزمية في التنبؤ للمدى الطويل بنسبة خطأ صغير 0.05% تقريباً، وبالتالي يعتبر النموذج المقترح أداة فعالة لمؤشرات الأسهم في التنبؤ ولمؤشرات الاقتصاد الكلي بالرغم من صعوبة عملية التنبؤ، بسبب تقلبات سوق الأسهم والعوامل الداخلية والخارجية التي تؤثر على الأسواق. في هذا البحث تم التأكيد أيضاً على أهمية استخدام الشبكات العصبية الاصطناعية وأن نتائجها يمكن أن تكون أفضل من الطرق التقليدية، مع الإشارة إلى زيادة تعقيد العملية عندما تزداد العوامل المؤثرة [13].

دراسة Pirzada و Porannejad تناولت التنبؤ بحركة الأسهم واتجاهاتها (البورصة) باعتبارها واحدة من أكثر التطبيقات الصعبة للسلاسل الزمنية لتعدد المتغيرات. كان الهدف من الدراسة هو التنبؤ لخمس فترات قادمة من خلال بيانات سابقة متمثلة في سعر الذهب، والرقم القياسي لأسعار النفط، ونيويورك للأوراق المالية، وأسعار الصرف باستخدام نموذج هجين بين الشبكات العصبية متعددة الطبقات والسلاسل الزمنية. أوضحت نتائج الدراسة أن النماذج متعددة المتغيرات أو ذات المتغير الواحد وعندما لا يوجد سبيل سوى استخدام البيانات التاريخية، فالشبكات العصبونية قادرة على إنتاج نتائج ذات دقة عالية وبنسبة خطأ صغير. هنا يجب التنويه إلى أن الشبكات العصبية قد تحتاج إلى خبرة كبيرة في تحديد المتغيرات المراد إدخالها والتي لها تأثير على القيم الزمنية المدروسة والمراد التنبؤ بها، ولكن عند عدم توفر هذه المتغيرات يمكن الاكتفاء بالقيم التاريخية (السلسلة الزمنية) للمتغير الأساسي الوحيد والتنبؤ بالقيم التالية له [14]. دراسة Mutaleb تناولت واحدة من أهم المشاكل الرئيسية في إدارة الموارد وهي التنبؤ بكمية هطول الأمطار وما تشكله من تأثير على موارد الطاقة باستخدام الشبكات العصبية الاصطناعية. تم تطوير ثلاثة نماذج للتنبؤ بهطول الأمطار وتنفيذها بناءً على ملاحظات سابقة مثل نماذج السلاسل الزمنية على أساس الانحدار، والمتوسط المتحرك، والشبكات العصبية الاصطناعية. تم تطبيق التنبؤ على أساس شهري بعد التدريب على بيانات 22 عاماً من هطول الأمطار الشهرية. أظهرت نتائج الدراسة أن نموذج الشبكات العصبية الاصطناعية يمكن استخدامه كأداة للتنبؤ بهطول الأمطار ونتائج دقيقة. كذلك أوضحت الدراسة أن ربط الشبكات العصبية الاصطناعية مع السلاسل الزمنية مهم جداً في حال عدم وجود معرفة مسبقة بمتغيرات عديدة تؤثر في النظام المدروس وخاصة أن النظام غير خطي بشكل كبير ومعقد وهذه العملية غالباً ما تعطي نتائج دقيقة [15].

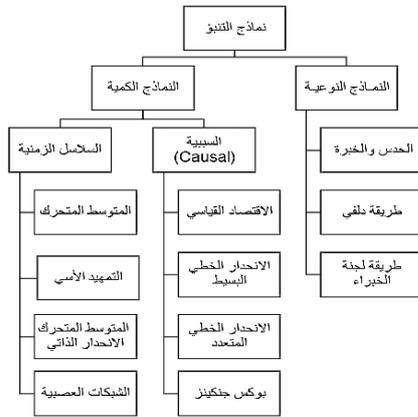
دراسة المبحوح استخدمت كل من نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية الكسرية (ARFIMA) Auto Regressive Fractionally Integrated Moving Average، وأسلوب

الخطي البسيط والانحدار الخطي المتعدد وبوكس جينكينز. تم استخدام أسلوب الانحدار الخطي البسيط في دراسة محمد المزاح، والتي هدفت إلى المقابلة بين نموذجي الانحدار الخطي البسيط والسلاسل الزمنية من حيث الكفاءة التنبؤية. تم تطبيق النموذجين على حالة دراسية بأحد مصانع المياه المعدنية ولمدة 36 شهراً خلال الفترة من 2013م-2015م بغرض الكشف عن مركبات السلسلة الزمنية. أظهرت نتائج التطبيق أن نموذج الانحدار الخطي البسيط أكثر كفاءة من التنبؤ بحجم المبيعات بواسطة السلاسل الزمنية بناءً على عدة معايير [5]. في حالات عملية عديدة يمكن أن يكون المتغير التابع معتمداً في تفسيره على أكثر من متغير مستقل. في مثل هذه الحالات يتم اللجوء إلى الانحدار الخطي المتعدد، فقد تناولت دراسة Qaradhwai تحديد عدة عوامل لها علاقة بالطلب على المبيعات بناءً على رأي خبراء في المجال واستناداً إلى دراسات سابقة. تم تحديد خمسة عوامل ذات أقوى ارتباط بالمتغير التابع، وبعد اختبار دقة النموذج بالواقع ومقارنته مع توقعات إدارة الشركة. أظهرت النتائج أن النموذج أكثر دقة بثلاث مرات من توقعات الشركة، وكانت نسبة خطأ النموذج 9.17%، بينما كان خطأ توقع الشركة 28.87% [6].

تزداد صعوبة تحليل ونمذجة السلسلة الزمنية بزيادة مستوى الكفاءة، فقد تم استخدام نموذج بوكس وجينكينز (Box-Jenkins Method) والمعروف أيضاً باسم Autoregressive Moving Average (ARMA) على نطاق واسع وحققت نجاحاً كبيراً في التنبؤ بالسلاسل الزمنية الخطية، ولكن هذه الطريقة لا تناسب السلاسل الغير خطية، ويمكن استخدامها في التنبؤات قصيرة المدى، ولكن في المدى الطويل نتائجها غير دقيقة. طريقة بوكس جينكينز تحتوي على أربعة خطوات رئيسية هي: توصيف النموذج، وتقدير معالمه، والتحقق من صلاحيته، وأخيراً مرحلة التنبؤ [7]. دراسة الغنام هدفت إلى تحليل السلاسل الزمنية لمؤشر أسعار الأسهم في المملكة العربية السعودية باستخدام منهجية بوكس وجينكينز. تم استخدام بيانات شهرية عن المؤشر في الفترة الممتدة من مارس 1985م إلى يونيو 2002م لعينة من 208 مشاهدة، وكانت السلسلة الزمنية غير مستقرة، وتم أخذ الفرق الأول للوغاريتم المؤشر. تم بناء خمسة نماذج واختير أفضل نموذجين للتنبؤ بمؤشر الأسهم السعودي وللتنبؤ ببقية المشاهدات. بينت نتائج الدراسة أن مؤشر أسعار الأسهم العام يتأثر بدرجة كبيرة بقيمة المؤشر في الفترة السابقة، كما أظهرت النتائج أيضاً أن المؤشر لا يتأثر بدرجة كبيرة بالتغيرات الموسمية [8]. دراسة Suarez وآخرون هدفت إلى بناء نموذج إحصائي لتقدير توقعات حركة المرور المستقبلية في شبكة Wi-Fi باستخدام السلاسل الزمنية. أشار الباحثون في دراستهم إلى أن أسلوب بوكس وجينكينز يعتبر من أفضل الأساليب في بناء نماذج السلاسل الزمنية. كذلك أشارت الدراسة إلى أن النموذج الذي يبنى على السلاسل الزمنية يكون له متغيرات قليلة وله القدرة على وصف خصائص النموذج بطريقة أفضل بكثير من النموذج المعقد والذي يحتوي على متغيرات كثيرة، وقد لا تصف خصائص النموذج بشكل جيد [9].

دراسة Ezennaya وآخرون درست توقعات الطلب على التيار الكهربائي في نيجيريا وما له من أهمية كبيرة خاصة مع سرعة التطور في الصناعة والزراعة، وبالتالي من المهم جداً التنبؤ بالطلب على الكهرباء في المستقبل. استخدمت في الدراسة تحليل السلاسل الزمنية لكمية الطلب في الفترات الماضية، وأشار في البحث إلى أهمية هذه الطريقة واستخداماتها المختلفة. توصلت الدراسة إلى نتائج جيدة، وتم استخدام عدة طرق للاستفادة من السلاسل الزمنية وهي Hand Free و Least Square Method والتي تعتمد على الرسم البياني وإيجاد خط مستقيم مناسب لإعطاء وصف سريع للاتجاه العام للسلاسل، بالإضافة للمتوسطات المتحركة والموزونة. يمكن القول أن السلاسل الزمنية هي طريقة تقوم بالتنبؤ بتصرفات المتغير في المستقبل بالاعتماد على سلوكه السابق، وهي تعطي نتائج جيدة ولها عدة طرق وآليات تختلف بحسب طبيعة الحالة المراد التنبؤ بها، بالإضافة لعدد البيانات والقيم ضمن السلسلة الزمنية [10].

عندما تكون السلاسل الزمنية غير خطية وغير مستقرة تصبح الطرق السابقة غير قادرة على التنبؤ بشكل كفوء، وبالتالي ظهرت في الآونة الأخيرة اهتمام العديد من الدراسات بإدخال أسلوب الشبكات العصبية Artificial Neural Networks (ANN) إلى التطبيقات الإحصائية الحديثة والتي تُعد أحد أساليب الذكاء الاصطناعي. إن استخدام أسلوب الشبكات العصبية لا يتطلب افتراضات عن طبيعة السلسلة الزمنية، كونها خطية أو طبيعية أو مستقرة، ودون الحاجة إلى تشخيص النموذج الذي تتطلبه في النماذج التقليدية السابقة. من بين هذه الدراسات دراسة بوانر وبن شهرة والتي قامت بتطبيق أسلوب السلاسل الزمنية من خلال تقنية



شكل (1) تصنيف نماذج التنبؤ [20]

د) مقاييس دقة التنبؤ

تعتمد أغلب مقاييس دقة التنبؤ على الانحرافات بين القيم الفعلية للسلسلة والقيم المقدرة، ومن أهم هذه المقاييس ما يلي [22]:
 (1) متوسط مربع الخطأ Mean Square Deviation (MSD) ويحسب هذا المقياس وفق المعادلة (1).

$$MSD = \frac{\sum_{t=1}^n e_t^2}{n} \quad (1)$$

حيث أن:

e_t : الخطأ أو انحراف القيمة المقدرة عن القيمة الحقيقية في الفترة t كما هو موضح في المعادلة (2).

$$e_t = Y_t - \hat{Y}_t \quad (2)$$

حيث أن:

Y_t : القيمة الحقيقية أو الفعلية في الفترة t .

\hat{Y}_t : القيمة المقدرة أو المتنبأ بها عند الفترة t .

n : عدد الفترات التي يتم التنبؤ لها.

لكن هذا المقياس لا يمكن الاعتماد عليه، فقد يعطي قيمة صغيرة إذا كانت الأخطاء الموجبة تساوي تقريباً الأخطاء السالبة.

(2) الجذر التربيعي لمتوسط مربع الخطأ Root Mean Squared Error (RMSE)

هذا المقياس يختلف عن المقياس السابق بأنه يأخذ الجذر التربيعي لمتوسط مربع الخطأ، ويستخدم للأخطاء الكبيرة، ويحسب هذا المقياس وفق المعادلة (3).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (3)$$

حيث أن:

n : عدد الفترات التي يتم التنبؤ لها.

Y_t : القيمة الفعلية عند الفترة t .

\hat{Y}_t : القيمة المتنبأ بها عند الفترة t .

(3) المتوسط المطلق لخطأ التنبؤ النسبي Mean Absolute Relative Prediction Error (MAPE)

يستخدم هذا المقياس عندما تكون قيم التنبؤ والفعلية كبيرة جداً، لأنه يعطي قيمة الخطأ كنسبة ويساعد على الفهم. يحسب هذا المقياس وفق المعادلة (4).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad (4)$$

حيث أن:

n : عدد الفترات التي يتم التنبؤ لها.

Y_t : القيمة الفعلية عند الفترة t .

\hat{Y}_t : القيمة المتنبأ بها عند الفترة t .

(4) متوسط مربعات خطأ التنبؤ النسبي Mean Squared Relative Prediction Error (MSRE)

يحسب هذا المقياس وفق المعادلة (5).

$$MSRE = \frac{1}{2} \sum_{t=1}^n \left(\frac{Y_t - \hat{Y}_t}{Y_t} \right)^2 \times 100 \quad (5)$$

حيث أن:

n : عدد الفترات التي يتم التنبؤ لها.

الشبكات العصبية الاصطناعية في التنبؤ بأسعار البترول الخام وذلك بالاعتماد على بيانات السلسلة الزمنية اليومية في ولاية تكساس الأمريكية لأسعار البترول الخام للفترة الزمنية من 2013/09/30 إلى 2018/03/09. من خلال المقارنة بين نتائج هذه النماذج توصل الباحث إلى أن نموذج الشبكات العصبية الاصطناعية (MLP 2-25-1) لديه قدرة أكبر في التنبؤ مقارنة مع نموذج الانحدار الذاتي ونموذج ARFIMA، لا مثلاً أقل قيم لمقاييس دقة التنبؤ (Mean Absolute Error (MAE)، Root of Mean Squared Error (RMSE)، وبذلك يكون هو النموذج الأفضل في القدرة على التنبؤ المستقبلي بأسعار البترول الخام اليومية [16]. دراسة Chi Wanle هدفت إلى التنبؤ بمؤشر سوق شنغهاي باستخدام تقنية الشبكات العصبية الاصطناعية، وذلك خلال الفترة الممتدة من 2017-1-8 إلى 2017-12-28م، وهو ما يقارب 238 يوم تداول. تمثلت مدخلات الشبكة في أسعار الغلق للأيام الخمسة السابقة، ومخرجات الشبكة هي سعر إغلاق اليوم التالي. أظهرت نتائج الدراسة أن الشبكات العصبونية الاصطناعية وفق خوارزمية الانتشار الخلفي كانت فعالة وممكنة في التنبؤ قصير الأجل بمؤشر السوق وتعطي نتائج تنبؤ دقيقة [17].

بعد استعراض الدراسات السابقة يمكن استخلاص أن معظم تلك الدراسات اتفقت على أن استخدام الشبكات العصبية الاصطناعية في التنبؤ أكثر كفاءة من الأساليب التقليدية، وذلك لأنها تعطي تنبؤات أدق من تلك الناتجة عن الأساليب التقليدية. جاءت هذه الدراسة لتساهم في بناء نماذج السلاسل الزمنية باستخدام الشبكات العصبية الاصطناعية للتنبؤ بحجم المبيعات للسنوات القادمة في الشركات الليبية بصفة عامة والشركة الليبية للحديد والصلب بصفة خاصة، بالإضافة إلى أن النتائج التي ستوصل إليها هذه الدراسة يمكنها أن تساعد المؤسسة على التنبؤ بمبيعاتها المستقبلية وكذلك في تحسين مستوى أدائها.

3. التنبؤ

إن نجاح المؤسسة مرتبط بنجاح العملية الإدارية لها، وأهم متطلباتها التنبؤ بسلوك مبيعاتها واتجاهاتها، وذلك بهدف دراستها والتحكم في مساراتها. كما يرتبط نجاح المؤسسة بنجاح وظيفة الإنتاج، لذلك يتوجب على إدارة الإنتاج معرفة حجم الإنتاج المطلوب خلال فترة إنتاجية معينة بدقة حتى لا تتحمل المؤسسة تكاليف إضافية، وتحافظ على مكانتها في السوق، ومن ثم القدرة على مواجهة المنافسة لتضمن تحقيق هدفها في النمو والاستمرار [11]. من هنا برزت أهمية التنبؤ بالنسبة للمؤسسة، وهو ما أوجب عليها ضرورة الاعتماد على طرق علمية للتنبؤ، والمفاضلة بينها من أجل اختيار التقنية التي تتناسب مع إمكانياتها من جهة، وتكون نتائجها دقيقة من جهة أخرى، مستفيدة من النتائج والمعلومات السابقة التي يتم ترتيبها في شكل سلاسل زمنية.

أ) مفهوم التنبؤ

توجد العديد من التعاريف للتنبؤ نذكر منها ما يلي:

هو علم وفن توقع الأحداث في المستقبل [18]. كذلك عرف بأنه الوظيفة التي تضبط (تدرك) المستقبل، استناداً إلى معطيات موثوق فيها حول السوق وتطوراته، والتنبؤ الأكثر دقة وثقة يعتمد على النماذج الرياضية [19]. التنبؤ هو بشكل عام عبارة عن توقع وتقدير لأحداث مستقبلية في ظل ظروف غير مؤكدة [20].

ب) أهمية التنبؤ

يعتبر التنبؤ مهم جداً لكل وظيفة في المؤسسة، ويتجلى ذلك بوضوح في العناصر الموجزة التالية [21]:

- يساعد التنبؤ في مراقبة وتسيير الجهود المبذولة من طرف الإدارة لمتابعة تطوراتها.
- تظهر أهمية التنبؤ عند التمكن من إضافة منتج، وخدمات جديدة للمؤسسة من خلال بحوث السوق لدراسة الطلب المتوقع.
- يساعد في تحديد الأرباح المتوقعة للمؤسسة في نهاية الفترة من خلال طرح التكاليف المتعلقة بالدورة.
- يساعد التنبؤ في تقدير الاحتياجات من اليد العاملة حسب التخصص والمجال الوظيفي، وكذلك تحديد نفقات الأجور المقابلة لذلك.

ج) تصنيف نماذج التنبؤ

شكل (1) يوضح أهم نماذج التنبؤ المستخدمة في الدراسات والبحوث.

4. تجمع كل عقدة في الطبقة المخفية ($Z_j ; j = 1, 2, \dots, p$) قيم وإشارات إدخالها الموزونة وفق المعادلة (6).

$$Z_in_j = V_{j0} + \sum_{i=1}^n X_i V_{ji} \quad (6)$$

5. تحسب إشارة الخرج الطبقة الخفية بتطبيق دالة التنغيع وفق المعادلة (7).

$$z_j = f(Z_in_j) = \frac{2}{1+e^{-z_y_in_j}} - 1 \quad (7)$$

وترسل قيم التنغيع إلى عقد طبقة الإخراج جميعها.

حيث أن:

X_i : وحدات الإدخال.

V_{j0} : التحيز على الطبقة الخفية ذات الدليل j .

V_{ji} : أوزان طبقة المدخلات إلى الطبقة المخفية الخفية.

Z_in_j : دخل وحدات الطبقة الخفية.

Z_j : وحدات الطبقة الخفية ذات الدليل j .

6. تجمع كل عقدة في طبقة المخرجات ($Y_k ; k = 1, 2, \dots, m$) إشارة دخلها الموزونة وفق المعادلة (8).

$$Y_in_k = W_{k0} + \sum_{j=1}^p Z_j W_{kj} \quad (8)$$

وبعد ذلك يتم تطبيق تابع التنغيع لحساب إشارة الإخراج لكل عقدة في طبقة المخرجات وفق المعادلة (9).

$$y_k = f(Y_in_k) = \frac{2}{1+e^{-y_in_k}} - 1 \quad (9)$$

حيث أن:

W_{k0} : التحيز على طبقة المخرجات ذات الدليل k .

W_{kj} : أوزان الطبقة المخفية إلى طبقة المخرجات.

Y_in_k : دخل وحدات الطبقة المخرجات.

y_k : وحدات الطبقة المخرجات ذات الدليل k .

ثانياً: مرحلة الانتشار الخلفي للخطأ

تقوم كل وحدة مخرجات بمقارنة تفعيلاتها المحسوبة مع قيمة الخرج الفعلي لتحديد قيمة الخطأ، واعتماداً على قيمة الخطأ الحاصل، يتم حساب العامل δ_k ، يستخدم هذا العامل لتوزيع الخطأ على وحدات طبقة الخرج لتتم إعادته إلى كل الوحدات في الطبقة المخفية.

7. يحسب الخطأ E_k لعقد، الإخراج عن طريق الفرق بين مخرجات العقد Y_k والقيمة الحقيقية للعقد t_k ، عن طريق المعادلة (10).

$$E_k = t_k - y_k \quad (10)$$

يتم مقارنة مخرجات الشبكة مع القيم الحقيقية لتقدير الخطأ حسب المعادلة (11).

$$\delta_k = (t_k - y_k) \cdot f'(Y_in_k) \quad (11)$$

ثم نحسب التغير في حجم الخطأ ΔW_{kj} حسب المعادلة (12).

$$\Delta W_{kj} = \alpha \cdot \delta_k \cdot Z_j \quad (12)$$

وحساب حد تصحيح انحيازها (المستخدم لتحديث الوزن W_{0k} لاحقاً) من خلال المعادلة (13).

$$\Delta W_{k0} = \alpha \cdot \delta_k \quad (13)$$

حيث أن:

δ_k : عامل تصحيح الخطأ لتحديث الوزن W_{kj} .

α : معدل التعلم (Learning Rate)، وهو يستخدم للتحكم في تحديث الأوزان خلال كل خطوة في مرحلة التدريب، وقيمة معدل التعلم بين [0, 1].

تجمع كل عقدة في الطبقة المخفية إشارات المدخلات الموزونة من خلال المعادلة (14).

$$\delta_in_j = \sum_{k=1}^m \delta_k W_{kj} \quad (14)$$

تضرب هذه القيمة بمشتقة تابع تفعيلها لحساب عامل تصحيح الخطأ لتحديث الوزن V_{ji} من خلال المعادلة (15).

$$\delta_j = \delta_in_j \cdot f'(Z - in_j) \quad (15)$$

ثم نحسب التغير في حجم الخطأ ΔV_{ji} من المعادلة (16).

$$\Delta V_{ji} = \alpha \delta_j X_i \quad (16)$$

بعدها يحسب حد تصحيح تحيزها (المستخدم لتحديث الوزن V_{j0}) من خلال المعادلة (17).

$$\Delta V_{j0} = \alpha \delta_j \quad (17)$$

ثالثاً: مرحلة تحديث الأوزان والتحيزات

يتم تعديل الأوزان وفقاً لطريقة الانتشار الخلفي كما يلي:

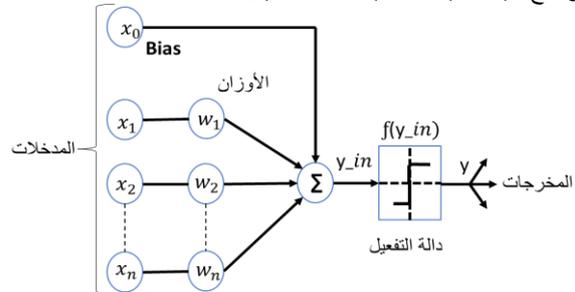
8. يتم تحديث الأوزان والتحيزات ($j = 0, \dots, p$) لكل عقدة في طبقة المخرجات ($Y_k ; k = 1, 2, \dots, m$) وفق المعادلتين (18)، (19).

Y_t : القيمة الفعلية عند الفترة t .

\hat{Y}_t : القيمة المتنبأ بها عند الفترة t .

4. الشبكات العصبية الاصطناعية

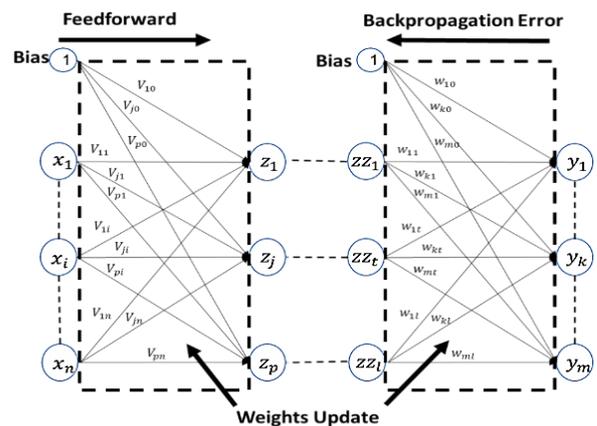
يمكن تعريف الشبكات العصبية الاصطناعية بأنها: عبارة عن نظام لمعالجة المعلومات بشكل متوازي يتميز بأدائه بخصائص شبيهة بالخلايا العصبية البيولوجية (الحيية)، وهي بمثابة تعميم للنماذج الرياضية للإدراك البشري أو البيولوجيا العصبية [23]. كذلك يمكن أن تعرف بأنها: نماذج حسابية مستوحاة من النظام العصبي للكائنات الحية، لديها القدرة على اكتساب المعرفة (التعلم) من خلال مجموعة من وحدات المعالجة والتي تشكل الخلايا العصبية الاصطناعية والمرتبطة مع بعضها البعض عن طريق مصفوفة الأوزان والتي تمثل المشابك الاصطناعية [24]. شكل (2) يوضح بنية الخلية العصبية الاصطناعية.



شكل (2) الخلية العصبية الاصطناعية [23]

4.1 خوارزمية الانتشار الخلفي Back propagation algorithm

هي إحدى الطرق التعليم المراقب وتعد من أكثر الخوارزميات استعمالاً، فهي تسعى إلى تقليل مربع الخطأ الكلي عند التدريب، وبالتالي الحصول على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة عندما تخضع للتدريب أو التعلم، وهذا هو الهدف من تدريب الشبكات العصبية. تدريب الشبكة العصبية الاصطناعية باستخدام الانتشار الخلفي يتضمن ثلاث مراحل كما هو موضح بالشكل (3) [25].



شكل (3) خوارزمية الانتشار الخلفي

- مرحلة الانتشار الأمامي لدفعات التدريب.

- مرحلة الانتشار الخلفي للخطأ.

- مرحلة تحديث الأوزان للشبكة.

ويمكن أن نلخصها في الخطوات التالية:

أولاً: مرحلة الانتشار الأمامي (التغذية بالاتجاه الأمامي بافتراض طبقة مخفية واحدة)

تستقبل كل وحدة دخل X_i إشارة تنقل إلى الطبقة الخفية Z_j ، يتم حساب قيمة التنشيط لهذه الإشارة بإحدى دوال التنغيع وترسل إشارتها إلى وحدات المخرجات Y_k ، ويتم حساب تنشيطها، وتتم وفق الخطوات الآتية [24]:

1. تهيئة قيم أولية للأوزان، بقيم عشوائية صغيرة.

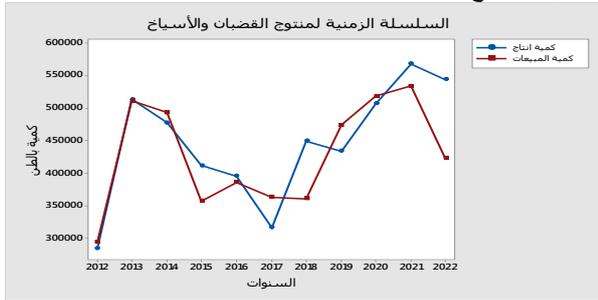
2. اختيار زوج التدريب من مجموعة التدريب

3. تستقبل كل عقدة في طبقة المدخلات إشارة دخلها، إذ أن ($X_i ; i = 1, 2, \dots, n$)، ثم ترسلها إلى جميع عقد الطبقة المخفية.

وقد صمم المصنع لدرفلة منتجات تلبى من حيث الجودة أقصى متطلبات الشروط الصارمة للمعايير الصناعية الألمانية (DIN) Deutsches Institut für Normung [26].

أ) السلسلة الزمنية لكمية الإنتاج والمبيعات بالمصنع

من أهم مزايا التنبؤ حدوث توازن بين الإنتاج والمبيعات، والشكل (5) يوضح السلسلة الزمنية بالسنوات لكمية الإنتاج والمبيعات بالطن لمنتج القضبان والأسياخ.



شكل (5) مقارنة بين كمية الإنتاج وكمية المبيعات لمنتج القضبان والأسياخ

يلاحظ من شكل (5) التذبذب في السلسلة لكل سنة، إما بزيادة كمية الإنتاج على كمية المبيعات أو بالعكس، ويلاحظ أيضاً في حالة كمية المبيعات أكثر، يكون في السنة التي قبلها الإنتاج أكثر ويتم تعويض الفارق من المخزون، وهذا يدل على عدم التوازن بين كمية الإنتاج وكمية المبيعات، مما يترتب على ذلك تكاليف إضافية على المنتج، ومما يدل على أن الأسلوب المستخدم للتنبؤ بالمبيعات غير دقيق.

ب) بيانات الدراسة

تمثلت بيانات الدراسة في سلسلة زمنية للمبيعات الشهرية لمصنع درفلة القضبان والأسياخ للفترة الممتدة من 2012\1\1 إلى غاية 2022\12\30 والمحددة بعدد 132 مشاهدة، واستخدمت بقية المشاهدات 12 الأخيرة أي سنة 2022م لغرض المقارنة مع نتائج نماذج التنبؤ، وقد تم الحصول على البيانات من إدارة المبيعات للشركة كما هو موضح في الجدول (1).

جدول (1) المبيعات الشهرية من مصنع درفلة القضبان والأسياخ (بالطن) []

الشهر/السنة	2021	2020	2019	2018	2017	2016	2015	2014	2013	2012	المجموع
1	47969.1	42649.2	40073.7	33989.6	16595.6	29732.7	29030.3	43892.2	37475.5	13448.6	
2	44868.6	36281.8	30095.5	33005.3	28457.8	34922	41628.1	39971.1	35883.6	11258.1	
3	56192.4	53159.6	53037.8	28345.3	43106.4	45321.7	55725.8	52284	46431.7	11101.5	
4	46164.3	26064.3	41816	19481.3	48560.1	30391	14073.8	42787.5	48028.8	15688.6	
5	45100.7	22569.3	24303.9	23612.3	38905	31747.8	24032	41368.2	46033.5	33984.1	
6	60345.9	40620.7	29211.4	23653.1	21167.6	16246.3	36877.7	56354.5	44346.6	32480.7	
7	32.053	41943.8	44930.4	39592.3	16905.2	34906	19514.3	10688.8	22821.2	21315.5	
8	2	33280.3	33194.4	31758.7	19532.9	45778.4	35860	0	29153.7	18475.7	
9	29231.1	40533.9	44606.3	39369.2	32562.1	29141.3	33093.8	25413.3	44982.7	43360.2	
10	62199	43816.4	46339.9	26956.5	36357.6	32941.5	26221	58045.2	41437.4	23247.8	
11	74772.5	48703.9	44968.8	27233.3	23313.7	17507.2	28770.9	69928.9	53454	31941.3	
12	66866.7	88674.5	41137	33818.6	37706.7	37407.4	31459.9	62605.8	61154.2	37518	
المجموع	533744	518298	473715	360815	363171	386043	376288	503340	511203	293820	

من أولى خطوات وصف وتحليل السلسلة الزمنية هو تمثيلها بيانياً بما يعرف بالرسم الزمني لمعرفة الاتجاه العام للسلسلة ومدى استقرارها، كما هو مبين في الشكل (6). يلاحظ من شكل (6) وجود تذبذب في السلسلة الزمنية ناتجة عن اختلاف الكميات المباعة من فترة إلى أخرى، وهذا يدل على وجود عدم استقرار في نشاط البيع، والذي يزيد من حاجة المؤسسة إلى التنبؤ بمبيعاتها.

$$W_{k0}(new) = W_{k0}(old) + \Delta W_{k0} \quad (18)$$

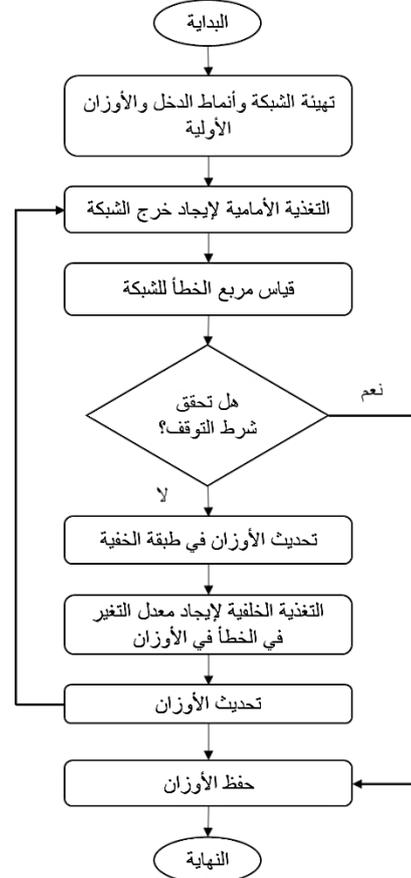
$$W_{kj}(new) = W_{kj}(old) + \Delta W_{kj} \quad (19)$$

كذلك تحديث الأوزان والتحييزات ($i = 0, \dots, n$) لكل عقدة في الطبقة المخفية ($Z_j ; j = 1, 2, \dots, p$) وفق المعادلتين (20)، (21).

$$V_{j0}(new) = V_{j0}(old) + \Delta V_{j0} \quad (20)$$

$$V_{ji}(new) = V_{ji}(old) + \Delta V_{ji} \quad (21)$$

9. تستمر الشبكة في تحديث الأوزان لغاية الحصول على الأوزان المثلى، ثم الحصول على المخرجات المرغوب فيها، أي التوصل إلى أفضل توفيق للنموذج قيد البحث (بمعنى اختبار شروط التوقف)، والشكل (4) يوضح المخطط الانسيابي لخوارزمية الانتشار الخلفي.



شكل (4) المخطط الانسيابي لخوارزمية الانتشار الخلفي

5. الحالة الدراسية

تعتبر بالشركة الليبية للحديد والصلب من أكبر الشركات الصناعية بليبيا، وتقع على مساحة قدرها 1,200 هكتار بالقرب من مدينة مصراتة، على بعد 210 كيلو مترا إلى الشرق من مدينة طرابلس. تبلغ الطاقة التصميمية للشركة 1,324,000 طن من الصلب السائل سنوياً بطريقة الاختزال المباشر لمكورات الحديد باستخدام الغاز الطبيعي المحلي. وضع حجر الأساس للشركة في 1979م، ايداناً بإرساء قاعدة التصنيع الثقيل بليبيا، وبتاريخ 1989م تم افتتاح الوحدات الإنتاجية وبذلك دخلت الشركة مرحلة الإنتاج.

يحتوي مصنع درفلة القضبان والأسياخ على خطين متماثلين تبلغ الطاقة التصميمية لكل منهما 200,000 طن سنوياً، أي ما مجموعه 400,000 طن سنوياً من القضبان والأسياخ وبعض من القطاعات الصغيرة. صُمم المصنع لإنتاج ما مجموعه 250,000 طن سنوياً من القضبان الدائرية الملساء والمحرزة من قطر 12 ملم إلى 40 ملم. وبالنسبة للأسياخ صُمم المصنع لإنتاج ما مجموعه 100,000 طن سنوياً من الأسياخ الملساء والمحرزة من قطر 5.5 ملم إلى أقل من 12 ملم. يوجد بالمصنع وحدات لتقويم وقص الأسياخ، ويعمل المصنع على أساس نظام 3 ورديات، 8 ساعات يومياً، 300 يوم في السنة، كما أن المصنع مصمم لدرفلة الصلب منخفض، ومتوسط، وعالي الكربون من درجة C1010 إلى C1074 وأعلى حسب (American Iron and Steel (AISI) Institute وللمصنع القدرة على درفلة بعض سبائك الصلب المنخفضة.

تم تحديد المخرج بكمية المبيعات خلال الفترة t أي مخرج واحد، وعقدة إخراج واحدة تكفي لعملية التنبؤ.

(2) مرحلة التحليل

تتم في مرحلة التحليل في خطوتين هما كالآتي:

- تقسيم بيانات الدراسة

يتم تقسيم البيانات إلى مجموعتين وذلك من أجل تدريب الشبكة العصبية، وتمثل المجموعتين في مجموعة تدريب، ومجموعة اختبار، ويتم الاستغناء عن التحقق بسبب قلة عدد المشاهدات (البيانات) أما عملية توزيع البيانات تتم بشكل عشوائي، والجدول (3) يبين نسبة المشاهدات كل مجموعة وعددتها.

جدول (3) توزيع المجموعات المستخدمة في الشبكة العصبية للمبيعات

مجموعة	نسبة المشاهدات	عدد المشاهدات
التدريب	90%	108
الاختبار	10%	12
مجموع البيانات	100%	120

والجدير بالذكر أن هذا النوع من التوزيع 90%، 10% هو أكثر التوزيعات استخداماً في الشبكات العصبية [25].

- معالجة البيانات

هي عملية تحويل البيانات التي يتم تدريب الشبكة العصبية عليها إلى الصيغة القياسية، وتمثل البيانات بالصور الثنائية [1,0] هو الاختيار الأفضل لمعظم الشبكات، وعملية تحويل البيانات تتم وفق المعادلة (22).

$$N(E) = \frac{E - \min}{\max - \min} \quad (22)$$

حيث أن:

$N(E)$: القيمة النظامية المُقيسة.

E : القيمة الحقيقية.

\min : القيمة الدنيا للمبيعات المسجلة.

\max : القيمة العظمى للمبيعات.

(3) مرحلة التصميم

هذه المرحلة تتم وفق الآتي:

- تحديد عدد الطبقات المخفية

تم استخدام طبقة، وطبقتان، وثلاث طبقات والمقارنة بينهم كما هو موضح في الجدول (4)، لكن أغلب تطبيقات التنبؤ بالسلاسل الزمنية يفضل استخدام طبقتان مخفية أو أكثر في حالة التنبؤ طويل المدى، أما في حالة التنبؤ قصير المدى حتى طبقة واحدة تكفي.

- تحديد عدد العقد في الطبقات المخفية

تم الاعتماد على طريقة المحاولة والخطأ في تحديد عدد العقد بالطبقات المخفية من خلال تجربة عدد مختلف من القيم واختبار الأداء الأفضل. إن عدد العقد في الطبقة المخفية يعتمد على عدد عقد الإدخال، وبهذا فإن نموذج الخلية العصبية يكون حسب عدد عقد الإدخال وبقاعدة Baum-Haussler للتقريب في تحديد عدد عقد في الطبقة المخفية وفق المعادلة (23).

$$N_{1Hidden} \leq \frac{N_{Train} E_{Tolerance}}{N_{pts} + N_{Output}} \quad (23)$$

تم تثبيت مقدار الخطأ المسموح به $E_{Tolerance} = 0.05$ وعدد مرات التدريب $N_{Train} = 10,000$ ، وعدد عقد البيانات الداخلة للشبكة لكل مرة تدريب $N_{pts} = 12$ ، وعدد عصبونات الإخراج $N_{Output} = 1$ وبتطبيق في المعادلة السابقة:

$$N_{1Hidden} \leq \frac{10000 \times 0.05}{12 + 1}$$

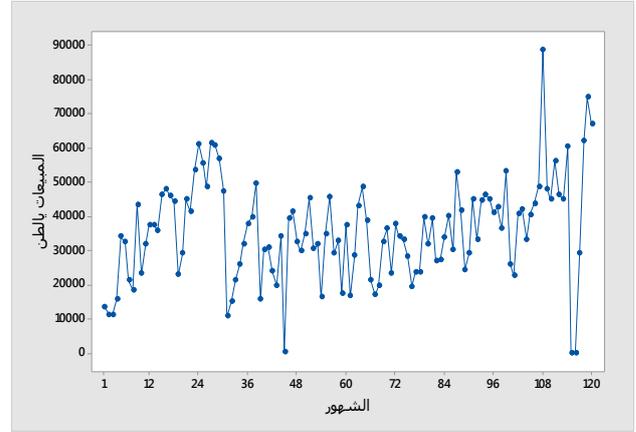
$$N_{1Hidden} \leq 38$$

لتحديد عدد العقد في الطبقة المخفية الثانية يتم ذلك بنفس المعادلة السابقة مع زيادة عدد العقد المخفية للطبقة الأولى مع عدد المدخلات مع المخرجات كالتالي:

$$N_{2Hidden} \leq \frac{10000 \times 0.05}{12 + 38 + 1}$$

$$N_{2Hidden} \leq 10$$

لتحديد عدد العقد في الطبقة المخفية الثالثة يتم بنفس المعادلة السابقة مع زيادة عدد العقد المخفية للطبقة الأولى مع الطبقة الثانية مع عدد المدخلات مع المخرجات كالتالي:



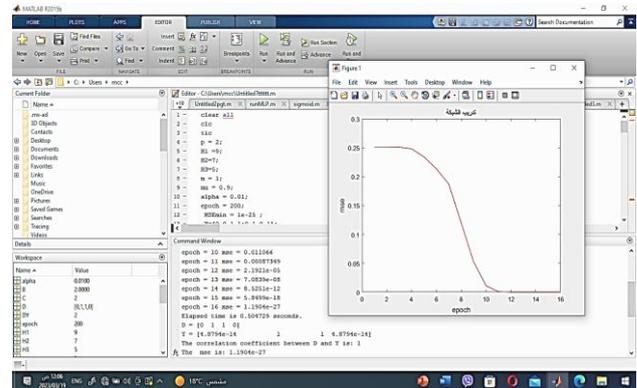
شكل (6) السلسلة الزمنية للمبيعات الشهرية من الضبان والأسياخ

(ج) معايرة الخوارزمية المستخدمة في الدراسة

قبل الشروع في تطبيق الخوارزمية المستخدمة على الحالة الدراسية، يجب القيام بمعايرتها للتأكد من مدى دقة وصحة النتائج التي ستحصل عليها من الخوارزمية. تمت معايرة خوارزمية الدراسة عن طريق تطبيق نموذج:

Perceptron Application-logic functions OR (Binary input, Binary targets).

والنتائج المتحصل عليها من هذا التطبيق موضحة في الشكل (7).



شكل (7) نتائج خوارزمية الدراسة

يلاحظ من خلال شكل (7) أن عملية التدريب تمت في 16 دفعة، وفي زمن 0.5 ثانية، ومتوسط مربع الخطأ $MSE = 1.1904e-27$ ، وأن معامل الارتباط يساوي 1، وهناك تطابق كبير بين مخرجات الشبكة والمخرجات الفعلية، وهذا يدل على أن الشبكة قد تدربت بشكل جيد وبسرعة عالية، والجدول (2) يوضح نتائج الشبكة.

جدول (2) مقارنة نتائج الخوارزمية المقترحة مع النتائج الفعلية

Target (t)	0	1	1	0
Output (y)	4.8794e-14	1	1	4.8794e-14
MSE	1.1904e-27			
R	1			

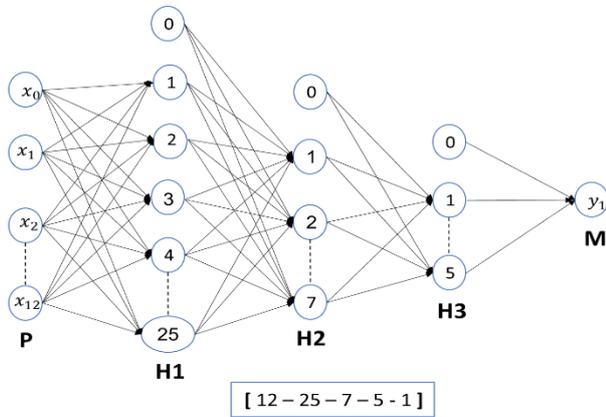
(د) تطبيق الخوارزمية على التنبؤ بالمبيعات

قُسمت السلسلة الزمنية إلى سلسلتين كخطوة أولى لتطبيق النموذج الأولى ليتم من خلالها تقدير معالم النموذج، والتي تسمى قاعدة الاختبار من الفترة 2012/1/1م إلى غاية 2021/12/30م. أما السلسلة الثانية من الفترة 2022/1/1م إلى 2022/12/30م، فهي وسيلة لتثبيت النتائج بالمقارنة مع النتائج المتحصل عليها في الاختبار الأول. تمر مرحلة بناء الشبكة العصبية الاصطناعية بمراحل محددة وهي كما يلي:

(1) تحديد المدخلات والمخرجات

مدخلات الشبكة فهي عبارة عن الكميات المباعة من الفترة t، وتم تحديدها بعدد 12 فترة لأنه تم الاعتماد على طريقة تجميع بيانات شهرية.

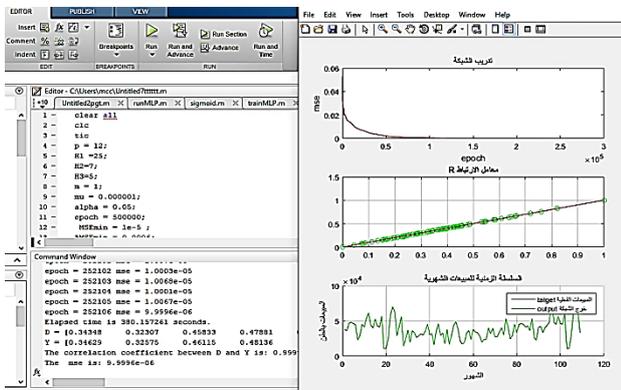
$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-12})$$



شكل (8) معمارية الشبكة العصبية النموذجية للتنبؤ بالسلسلة الزمنية للمبيعات

4) مرحلة التدريب

بعد ما تم تحديد معمارية الشبكة [1-5-7-25-12] النموذجية للتنبؤ، تم عملية التدريب ويتم في هذه المرحلة تحديد خيارات عملية التدريب وتحديد لو غاريمت التعلم، وتنتهي باستخراج النتائج النهائية للشبكة ومستوى دقة تنبؤاتها. حيث يتم تدريب الشبكة عدد من المرات حتى يتم الحصول على أقل خطأ ممكن. تم الاعتماد على الدالة اللوجستية Binary sigmoid كدالة تفعيل في الطبقة المخفية، وكذلك في طبقة الإخراج، باستخدام التدريب الإشرافي، ثبت معدل التعلم $\alpha=0.05$ ، ومعدل العزم $\mu=0.00001$ ، كما تم تثبيت عدد تكرار التدريب عند 500,000 دفعة، وأقل متوسط خطأ $MSE = 1e^{-5}$ ، وتدريب الشبكة باستخدام خوارزمية الانتشار العكسي، وكانت نتائج عملية التدريب موضحة بالشكل (9).



شكل (9) نتائج عملية التدريب

جدول (5) يلخص نتائج عملية التدريب، وأهم مؤشرات عملية تطابق البيانات الناتجة أثناء عملية التدريب مع البيانات الفعلية.

جدول (5) نتائج عملية التدريب

ملخص النتائج				
متوسط الخطأ النسبي	الخطأ المطلق	القيم المقدرة (طن)	القيم المستهدفة (طن)	
0.6	233.52	37771.5	37537.98	المتوسط
0.01	1.6	14102.18	14100.56	الانحراف المعياري
0.22	24.172	10713	10688.828	القيمة الدنيا
0.12	106.534	88568	88674.534	القيمة العليا
			0.9998	معامل الارتباط
			9.9996e-06	MSE
			252,106	عدد الدفعات
			6 دقائق	الزمن

يلاحظ من شكل (9) تطابق مجموعة التدريب مع المجموعة الأصلية، والنتائج تبين أن أخطاء الشبكة تتناقص، وهذا يدل على أن الشبكة قد تدربت بشكل جيد، ووصلت إلى مستوى مقبول من أجل التنبؤ. لتقييم كفاءة

$$N_{3Hidden} \leq \frac{10000 \times 0.05}{12 + 38 + 10 + 1}$$

$$N_{3Hidden} \leq 8$$

لذا فإن عدد العقد في الطبقة المخفية الأولى هي أقل أو تساوي 38 عقدة وأقل من أو تساوي 10 عقد في الطبقة الثانية، وأيضاً أقل من 8 عقد في الطبقة الثالثة، إذ يمثل الحد الأعلى لعدد العقد في الطبقات المخفية. لتحديد عدد العقد تم الاعتماد على طريقة التجربة والخطأ في تحديد عدد العقد للطبقات المخفية بتجربة عدد مختلف من القيم (العقد) في النطاق المحسوب من قاعدة Baum-Haussler واختبار الأداء الناتج، والبحث عن أفضل عدد يحقق أداء مرضياً.

تم تدريب الشبكة العصبية باستخدام خوارزمية الانتشار الخلفي لتحديد عدد العقد المخفية، وباستخدام أكثر المقاييس شيوعاً تم استخدام متوسط مربع الخطأ MSE، ومعامل الارتباط R للاختيار بين جودة النماذج، وتم تثبيت عدد التكرارات 10,000 بهدف الحصول على أفضل معمارية للشبكة العصبية والنتائج موضحة في الجدول (4).

جدول (4) نتائج تحديد معمارية الشبكة

R	MSE	عدد الأوزان	معمارية الشبكة
0	0.098365	99	1-7-12
6.4e-08	0.093021	281	1-20-12
9.8e-04	0.090443	421	1-30-12
10.5	0.032152	561	1-40-12
0.57	0.025082	280	1-5-15-12
0.58	0.023826	365	1-10-15-12
0.31	0.085108	450	1-15-15-12
0.58	0.023902	370	1-5-20-12
0.61	0.021518	481	1-10-20-12
0.42	0.063976	591	1-15-20-12
0.52	0.026594	460	1-5-25-12
0.67	0.020545	515	1-7-25-12
0.55	0.028086	596	1-10-25-12
0	0.14344	730	1-15-25-12
0.60	0.021623	551	1-5-30-12
0.49	0.040393	711	1-10-30-12
0.47	0.039247	871	1-15-30-12
0.40	0.071114	1360	1-20-40-12
0.71	0.017739	555	1-7-10-20-12
0.79	0.014152	670	1-7-10-25-12
0.78	0.014076	785	1-7-10-30-12
0.77	0.015524	571	1-7-7-25-12
0.77	0.015372	671	1-7-7-30-12
0.72	0.017818	505	1-7-5-25-12
0.60	0.024812	595	1-7-5-30-12
0.80	0.012047	553	1-5-7-25-12
0.72	0.016683	653	1-5-7-30-12
0.74	0.014994	534	1-3-7-25-12
0.66	0.018312	635	1-3-7-30-12
0.61	0.028285	1341	1-15-20-30-12
0.5968	0.021397	290	1-2-5-15-12

يلاحظ من جدول (4) أن أفضل معمارية للشبكة العصبية هي [1-7-25-12] من بين المعماريات الأخرى، وذلك حسب المعيار المستخدم وهو متوسط مربع الخطأ MSE ومعامل الارتباط R، وأن التحيز Bias جزء من مجموعة الأوزان (معلمات النموذج) ويدخل في عملية التدريب كما هو مبين في الشكل (8).

القيم الفعلية للمبيعات، وهذا ما يؤكد الدقة والجودة العالية لنموذج الشبكات العصبية في التنبؤ بالمبيعات.

وهي التنبؤ باستخدام طريقة الانحدار الخطي

تم استخدام طريقة الانحدار الخطي للتنبؤ بنفس السلسلة الزمنية التي استخدمت في الشبكة العصبية والمتمثلة في مبيعات سنة 2022م، حيث بعد فحص السلسلة الزمنية وإيجاد معلمات الانحدار الخطي باستخدام برنامج Minitab تم الحصول على النتائج كما هي موضحة في الجدول (6)، ونموذج الانحدار الخطي ممثل في المعادلة (24).

$$y_t = 30630 + 75.5 \times t \quad (24)$$

جدول (6) كمية المبيعات الشهرية المتنبأ بها لسنة 2022م بطريقة الانحدار الخطي

الشهر	القيم الفعلية (بالطن)	قيم التنبؤ لعام 2022م	الفترة (t)	الخطأ المطلق
1	33030.27	39012.1	111	5981.8
2	45628.12	39087.6	112	6540.5
3	59725.81	39163.1	113	20562.7
4	18073.82	39238.6	114	21164.78
5	28031.97	39314.2	115	11282.23
6	40877.72	39389.7	116	1488.02
7	22514.35	39465.2	117	16950.85
8	39860.03	39540.7	118	319.33
9	37093.84	39616.2	119	2522.36
10	30221.02	39691.8	120	9470.78
11	32770.9	39767.3	121	6996.4
12	35459.9	39842.2	122	4382.3
المجموع	423287.7	473128.7		49841

يلاحظ من جدول (6) أن مؤشر قيم التنبؤ من النموذج الانحدار الخطي في تصاعد، وأن هناك تفاوت كبير في قيمة الخطأ المطلق بين القيم التنبؤ والقيم الفعلية لجميع الأشهر.

(و) التنبؤ باستخدام طريقة التمهيد الأسّي

هذا النموذج يعطي أوزان نسبية لقيم الظاهرة القديمة وتتناقص بمعدل متوالية هندسية، بمعنى إنها تعطي أوزان أكبر للبيانات الحديثة من أوزان البيانات القديمة، تم استخدام طريقة التمهيد الأسّي للتنبؤ بنفس بيانات السلسلة الزمنية التي استخدمت في الشبكة العصبية والمتمثلة في مبيعات سنة 2022م، تم حساب القيم التنبؤية باستخدام برنامج Minitab، كما هو موضحة في جدول (7)، ونموذج التمهيد الأسّي ممثل في المعادلة (25).

$$y_t = 25888.1 \times (1.00335^t) \quad (25)$$

جدول (7) كمية المبيعات الشهرية المتنبأ بها لسنة 2022م بطريقة التمهيد الأسّي

الشهر	القيم الفعلية (بالطن)	قيم التنبؤ لعام 2022م	الفترة (t)	الخطأ المطلق
1	33030.27	37520.9	111	4490.63
2	45628.12	37646.5	112	-7981.62
3	59725.81	37772.6	113	-21953.2
4	18073.82	37899.1	114	19825.28
5	28031.97	38026.0	115	9994.03
6	40877.72	38153.4	116	-2724.32
7	22514.35	38281.2	117	15766.85
8	39860.03	38409.4	118	-1450.63
9	37093.84	38538.0	119	1444.16
10	30221.02	38667.1	120	8446.08
11	32770.9	38796.6	121	6025.7
12	35459.9	38926.5	122	3466.6
المجموع	423287.7	458637.3		35349.6

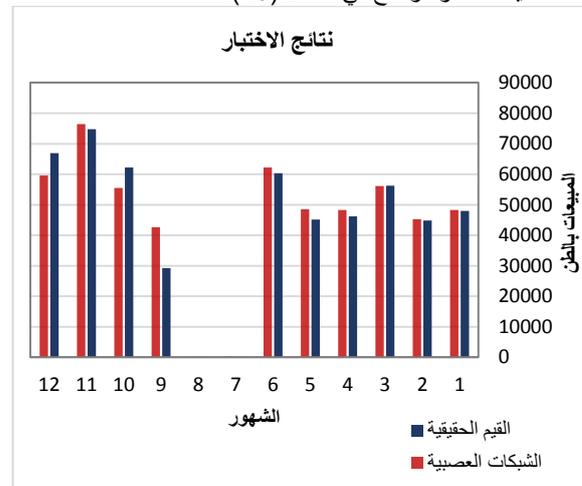
يلاحظ من الجدول (7) أن مؤشر قيم التنبؤ لنموذج التمهيد الأسّي في تصاعد، وأن هناك تفاوت كبير في قيمة الخطأ المطلق بين القيم التنبؤ والقيم الفعلية لجميع الأشهر.

(ر) المقارنة بين نتائج نماذج التنبؤ للتنبؤ بمبيعات سنة 2022م

التدريب وتحديد أفضلية الشبكة تم اعتماد معيار الانحدار R، حيث يظهر شكل (9) علاقة الانحدار بين الخرج الفعلي (Target) وخرج الشبكة أثناء التدريب، حيث بلغ معامل الارتباط بينهما 99.98%، وهي علاقة ارتباط قوية جداً، مما يشير إلى أن الشبكة قد درست بشكل جيد، ويدل على جودة وكفاءة النموذج، وأنه قادر على محاكاة بيانات مبيعات الشركة الليبية للحديد والصلب لمنتج مصنع القضبان والأسياخ.

(5) مرحلة الاختبار

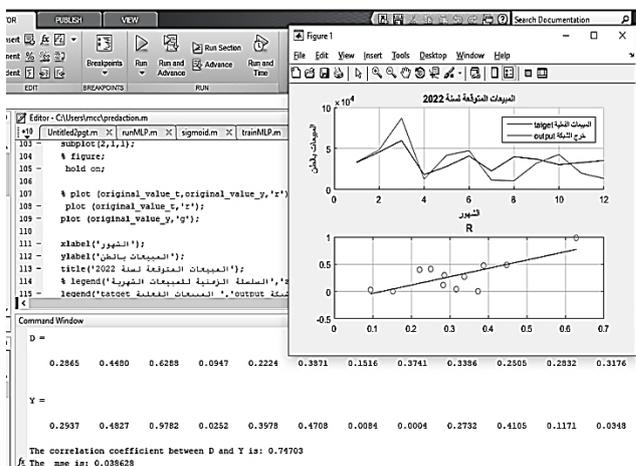
بعد الانتهاء من عملية التدريب تبدأ عملية الاختبار، حيث تم اختيار بيانات سنة 2021م، وذلك بإدخال بيانات الاختبار (المبيعات الشهرية لسنة 2020م) على الأوزان المثالية المخزنة في الشبكة ومعالجتها، وعمل اختبار لكفاءة الشبكة العصبية المدربة وقدرتها على اعطاء قيم تقديرية مقبولة. تم الحصول على المخرجات المطلوبة من الشبكة العصبية الاصطناعية كما هو موضحة في الشكل (10).



شكل (10) نتائج عملية الاختبار

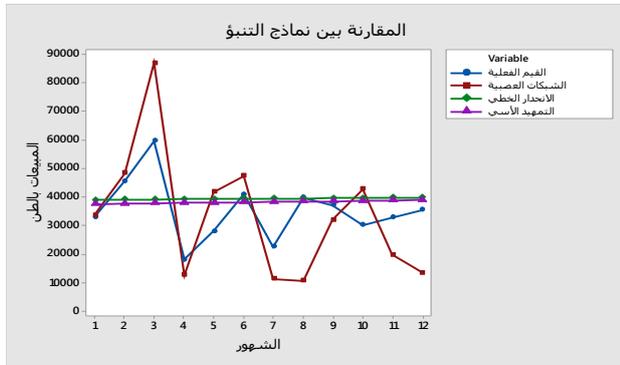
يلاحظ من شكل (10) أن القيم المتنبأ بها بواسطة الشبكة العصبية قريبة جداً من القيم الفعلية للمبيعات، ومنها نجد أن الشبكة العصبية التي تم بنائها يمكن الاعتماد عليها في عملية التنبؤ. يلاحظ أيضاً من نتائج التنبؤ للشبكة العصبية أن شهر 7 وشهر 8 كانت قريبة من الصفر في ذروة الصيف، هذا بسبب أن الشركة الليبية للحديد والصلب كانت قد توقفت عن العمل في هذه الفترة بسبب مشكلة الكهرباء التي مرت بها البلاد.

(6) التنبؤ بالمبيعات الشهرية لسنة 2022م باستخدام الشبكة العصبية وهي المرحلة الأخيرة ويتم فيها استخدام الشبكة للغرض الذي أنشئت من أجله وهو التنبؤ بالمبيعات الشهرية من القضبان والأسياخ، والنتائج موضحة في الشكل (11).



شكل (11) نتائج عملية التنبؤ لسنة 2022م

يلاحظ من خلال شكل (11) أن نتائج عملية التنبؤ جيدة جداً، حيث أن متوسط مربع الخطأ صغير ويساوي 0.0386، وقيمة معامل الارتباط تساوي 0.74 ويعتبر ارتباط قوي. وبالتالي فإن نتائج التنبؤ، قريبة جداً من



شكل (12) مقارنة بين القيم الفعلية وقيم التنبؤ الشهرية لأسلوب الشبكات العصبية وأساليب الانحدار الخطي والتمهيد الأسي لمبيعات عام 2022م

6. مناقشة النتائج

إن التوقعات الدقيقة للمبيعات في المستقبل هي أساس نجاح السياسات الاقتصادية للشركة، ومن هنا تأتي أهمية اختيار الطرق المناسبة للتنبؤ. تم بناء نموذج للتنبؤ بالمبيعات لمصنع درفلة القضبان والأسياخ بالشركة الليبية للحديد والصلب باستخدام الشبكات العصبية. النموذج تكون من عدد 12 مدخلا، و3 طبقات مخفية، وخرج واحد، بحيث أصبحت معمارية الشبكة كالتالي: 1-5-7-25-12. تم مقارنة نتائج النموذج مع أسلوب الانحدار الخطي والتمهيد الأسي اعتمادا على المعايير الإحصائية RMSE، MAPE، RMSE، كما هو موضح بالجدول (8). لاختبار النموذج الأفضل تم استخدام عدد 120 مشاهدة شهرية في شكل سلسلة زمنية بداية من 1 يناير 2012م وحتى 31 أكتوبر 2022م، وفي مرحلة التنبؤ استخدمت عدد 12 مشاهدة شهرية لسنة 2022م. من خلال نتائج الدراسة نجد أن نتائج التنبؤ لقيم المبيعات الشهرية لسنة 2022م من منتجات القضبان والأسياخ بالاعتماد على السلسلة الزمنية لمبيعات الفترات السابقة وجود توافق خطي بين القيم الفعلية، ومخرجات الشبكة المتنبأ بها بمعامل ارتباط مقداره 0.74، وهذا يدل على وجود علاقة طردية قوية. في المقابل نجد أن معامل الارتباط لنموذج الانحدار الخطي، والتمهيد الأسي 0.21 لكل منهما. وهذا يدل على وجود ارتباط ضعيف. بالنظر إلى المعايير الموضحة في جدول (8) ومنحنيات النماذج في شكل (12) يتبين أن أسلوب الشبكات العصبية الاصطناعية قد تفوق تفوقا ملحوظا على أسلوب الانحدار الخطي والتمهيد الأسي، حيث أن بمقارنة المؤشرات الإحصائية للنماذج الثلاثة: MAPE، RMSE، MSRE نجد أن أداء نموذج الشبكة العصبية أفضل بكثير من النموذجين الآخرين. كذلك عند مقارنة نموذج التنبؤ المستخدم في الشركة وهو المتوسط المتحرك (متوسط ثلاث سنوات سابقة) مع نموذج الشبكات العصبية للتنبؤ بإجمالي سنة 2022م فكانت النتائج كما هي موضحة في جدول (9).

جدول (9) مقارنة ANN مع نموذج الشركة

ANN(طن)	المتوسط المتحرك للشركة (طن)	المبيعات الفعلية (طن)
400660	508585.8	423287.7

من خلال المقارنة نجد أن التنبؤ الناتج من نموذج الشبكات العصبية أقرب إلى القيمة الفعلية، إذ تفوق نموذج الشبكة العصبية على النموذج المستخدم من قبل الشركة. كذلك يلاحظ من شكل (12) اقتراب القيم الفعلية والقيم المتنبأ بها من الشبكات العصبية وخاصة في سبعة الأشهر الأولى، أما التنبؤات في الشهرين الأخيرين 11، 12 ليست جيدة، وذلك لطول مدى فترة التنبؤ. نموذج الشبكة العصبية الذي تم تطويره، يمكن للشركة الليبية للحديد والصلب استخدامه للتنبؤ بمبيعات الفترات المستقبلية سواء في مصنع درفلة القضبان والأسياخ أو مبيعات الشركة بصفة عامة. هذا النموذج سيساعد الشركة في تقدير حجم المبيعات، والتي كانت تحدث خلل في عملية التوازن بين حجم المبيعات وحجم الإنتاج، وما يترتب على ذلك من تكاليف إضافية، ويؤثر في سمعة الشركة وموقعها التنافسي. هذا النموذج سيساهم بدرجة كبيرة في تحديد حجم المبيعات للفترات المستقبلية، وبواسطته يمكن المحافظة على التوازن بين الطلب على المنتج، وكمية الإنتاج.

لتحديد أفضل نموذج للتنبؤ بحجم مبيعات منتجات مصنع الدرفلة القضبان والأسياخ بالشركة، تمت المقارنة بين النموذج المستخدم من قبل الشركة وهو نموذج المتوسط المتحرك ومع نتائج نموذج الشبكات العصبية، ونموذج الانحدار الخطي، ونموذج التمهيد الأسي. فكانت نتائج التنبؤ لنموذج المتوسط المتحرك المتبع في الشركة لمبيعات سنة 2022م لمتوسط آخر ثلاث سنوات 2019، 2020، 2021، كالتالي:

$$\text{Moving Average (MA)} = \frac{473715.194 + 518297.698 + 533744.471}{3} = 508585.8 \text{ طن}$$

تم استخدام المعايير الإحصائية للمقارنة بين كفاءة النماذج المستخدمة وهي:

معيار الجذر التربيعي لمتوسط مربعات خطأ التنبؤ RMSE، المتوسط المطلق لخطأ التنبؤ النسبي MAPE، متوسط مربعات الخطأ التنبؤ النسبي MSRE، ويبين جدول (8) نتائج معايير المقارنة بين النماذج.

جدول (8) مقارنة بين نتائج نماذج التنبؤ الثلاثة لمبيعات سنة 2022م (بالطن)

الشهر	القيم الفعلية	قيم التنبؤ بالانحدار الخطي	قيم التنبؤ بالتمهيد الأسي	ANN
1	33030.27	39012.1	37520.9	33593
2	45628.12	39087.6	37646.5	48334
3	59725.81	39163.1	37772.6	86973
4	18073.82	39238.6	37899.1	12656
5	28031.97	39314.2	38026.0	41712
6	40877.72	39389.7	38153.4	47408
7	22514.35	39465.2	38281.2	11340
8	39860.03	39540.7	38409.4	10723
9	37093.84	39616.2	38538.0	31995
10	30221.02	39691.8	38667.1	42704
11	32770.9	39767.3	38796.6	19822
12	35459.9	39842.2	38926.5	13400
المجموع	423287.7	473128.7	458637.3	400660
	R	0.2118	0.2109	0.74703
	MAPE	31.31	29.46	28.62
	MSRE	20.30	18.78	17.32
	RMSE	11293.3682	10949.1470	10532.7418

من خلال النتائج الموضحة في جدول (8) يتبين أن أسلوب الشبكات العصبية الاصطناعية قد تفوق تفوقا ملحوظا على جميع أساليب التنبؤ المستخدمة وفقا للمعايير التي استخدمت في المقارنة، ويوضح شكل (12) منحنيات نتائج نماذج التنبؤ للتنبؤ بالمبيعات لسنة 2022م. يلاحظ من خلال شكل (12) اقتراب القيم الفعلية والقيم المتنبأ بها في الشبكة العصبية، الأمر الذي يشير وبوضوح أن الشبكات العصبية الاصطناعية أفضل وأدق من طرق الأخرى في التنبؤ بالمبيعات للشركة الليبية للحديد والصلب.

Engineers and Computer Scientists (Vol. 2, pp. 979-984).

- [13] Hadaś-Dyduch, M. (2014). Non-classical algorithm for time series prediction of the range of economic phenomena with regard to the interaction of financial market indicators. *Chinese Business Review*, 13(4), 221-231.
- [14] Pirzad, D., & Porannejad, M. (2014). Stock Exchange Index Prediction Using Hybrid Models [J]. *Indian J. Sci. Res*, 7(1), 186-193.
- [15] Muttaleb Alhashimi, S. A. (2014). Prediction of monthly rainfall in Kirkuk using artificial neural network and time series models. *Journal of engineering and development*, 18(1), 129-143.
- [16] مهدي ناهض شعبان المبحوح، (2018). "في التنبؤ بأسعار البترول الخام ANN و ARFIMA دراسة مقارنة بين نموذجي"، رسالة ماجستير، جامعة الأزهر غزة.
- [17] Chi, W. (2018). Forecasting stock index based on BP neural network algorithm. In *Proceedings of the 2018 International Conference on Mechanical, Electronic, Control and Automation Engineering (MECAE 2018)*, Qingdao, China (pp. 30-31).
- [18] عبد الكريم محسن، صباح مجيد النجار. 2006. إدارة الإنتاج والعمليات، طبعة ثانية (الأردن). دار وائل للنشر.
- [19] أيهم الحميد، أسهمان خلف، عثمان نقار. (2019). التنبؤ باتجاه حركة مؤشر سوق دمشق للأوراق المالية باستخدام نماذج ARCH-ARIMA والشبكات العصبونية الاصطناعية (دراسة مقارنة). مجلة جامعة حما 2..11
- [20] عبدالرحمن الأحمد العبيد. 2004. مبادئ التنبؤ الإداري. جامعة الملك سعود، المملكة العربية السعودية.
- [21] Hanke, J. Wichern, D. (2014), "Business Forecasting", Ninth Edition, Pearson Education Limited, United Kingdom, London.
- [22] محمد عبيدات وآخرون، 2008. إدارة المبيعات والبيع الشخصي، دار وائل للنشر والتوزيع، عمان.
- [23] Neha, Y., Anupam, Y., Manoj, K., (2015), "An Introduction to Neural Network Methods for Differential Equations", Springer Dordrecht Heidelberg New York.
- [24] . Silva, I., Liboni, L., Spatti, N., Alves, S., Flauzino, R., (2017), "Artificial Neural Networks A Practical Course ", Springer International Publishing Switzerland, p:5
- [25] Shankar. N .(2008). "Neural Networks" UNIVERSITY SCIENCE PRESS.
- [26] <http://libyansteel.com/ar/> تاريخ الدخول 2023/09/30م.

7. الخلاصة

هدفت الدراسة إلى استخدام أسلوب الشبكات العصبية الاصطناعية للتنبؤ بحجم المبيعات الشهرية بالشركة الليبية للحديد والصلب لمنتجات مصنع درفلة القضبان والأسياخ باستخدام خوارزمية الانتشار الخلفي. اعتمدت الدراسة على سلسلة زمنية للمبيعات الشهرية لعشر سنوات (2012م - 2021م) لبناء وتدريب نموذج التنبؤ. أما في مرحلة التنبؤ استخدمت البيانات الشهرية لسنة 2022م لاختبار النموذج. للتأكد من دقة النموذج تمت مقارنة القيم الفعلية بنتائج أسلوب ANN، وكذلك مقارنته مع أسلوب الانحدار الخطي والتمهيد الأسّي، اعتماداً على المعايير الإحصائية. أظهرت نتائج الدراسة أن أسلوب الشبكات العصبية الاصطناعية [12-25-7-5-1]، حقق نتائج جيدة جداً، وتفوق على أسلوب الانحدار الخطي، والتمهيد الأسّي، وكذلك على أسلوب المتوسط المتحرك المستخدم من قبل الشركة، حيث حقق أقل نسبة خطأ $MAPE=28.62\%$ ، $RMSE=10532.741$ ، $MSRE=17.32\%$ وبمعامل ارتباط موجب قوي $R=0.74703$. هذه القيم تدل على كفاءة وفاعلية نموذج ANN. من خلال النتائج نوصي بضرورة إدخال الأساليب الذكية في عملية التنبؤ بالمبيعات، كأسلوب الشبكات العصبية الاصطناعية لقدرته وكفاءته في عملية التنبؤ.

8. المراجع

- [1] بوادر فاطيمة ومداني بن شهرة. (2015). "استخدام أسلوب الشبكات العصبية الاصطناعية في التنبؤ بحجم المبيعات في المؤسسة الجزائرية - دراسة تطبيقية" جامعة ابن خلدون، 63-89.
- [2] Cantón Croda, R. M., Gibaja Romero, D. E., & Caballero Morales, S. O. (2019). Sales Prediction through Neural Networks for a Small Dataset. *International Journal of Interactive Multimedia & Artificial Intelligence*, 5(4).
- [3] بوغوروي فاطمة، وبودرامة مصطفى. (2018). دور الشبكات العصبونية الاصطناعية في التنبؤ بالمبيعات لدعم صنع القرارات الإدارية بالمؤسسات: دراسة حالة مؤسسة الإسمنت بعين الكبيرة. مجلة الإبداع، مج. 8، ع. 1، ص ص. 215-229.
- [4] Martinovic, J., & Damn Janovic, V. (2006). The sales forecasting techniques. *Materials of International scientific days "Competitiveness in the EU—challenge for the v4 countries"*, 526-531
- [5] محمد محمد أحمد المزاح. 2017. مقارنة الكفاءة التنبؤية لنموذجي الانحدار والسلاسل الزمنية لحجم المبيعات، رسالة ماجستير، جامعة الملك خالد.
- [6] Farizal, Qaradhawi, Y., Cornelis, C. I., & Dachyar, M. (2020, May) Fast moving product demand forecasting model with multi linear regression. In *AIP Conference Proceedings*. Publishing LLC.
- [7] Box, G.P. and Jenkins, G.M. (1976). "Time Series Analysis Forecasting and Control", Revised Edition Holden-Day Inc. San Francisco
- [8] الغنام، حمد بن عبد الله بن ناصر. 2003. تحليل السلسلة الزمنية لمؤشر أسعار الأسهم في المملكة العربية السعودية باستخدام منهجية بوكس جينكينز. مجلة جامعة الملك عبد العزيز: الاقتصاد والإدارة، مج. 17، ع. 2، ص ص. 3-26.
- [9] Hernández Suarez, C. A., Salcedo Parra, O. J., & Escobar Díaz, A. (2009). An ARIMA model for forecasting Wi-Fi data network traffic values. *Ingeniería E Investigación*, 29(2), 65-69.
- [10] Ezennaya, O. S., Isaac, O. E., Okolie, U. O., & Ezeanyim, O. I. C. (2014). Analysis of Nigeria's national electricity demand forecast (2013–2030). *International Journal of Science and Technology Research*, 3(3), 333-340.
- [11] الظفيري، (2004) "استخدام الشبكات العصبية والأساليب الإحصائية التقليدية لتنبؤ بأعداد الركاب على الخطوط الجوية الكويتية"، رسالة ماجستير، جامعة قناة السويس .
- [12] Kosanan, O., & Kantanantha, N. (2014). Thailand's Para Rubber Production Forecasting Comparison. In *Proceedings of the International MultiConference of*