

Predicting Machine Malfunctions in Industrial Facilities Using Neural Networks (The case of the study : The General Tobacco Corporation)

Dr. Hatem Mahmoudi*

Dr. Ayman Yousef**

Turkan Hamzah***

(Received 9 / 8 / 2022. Accepted 5 / 1 / 2023)

□ ABSTRACT □

In This research the prediction of machine malfunctions in industrial facilities is studied to reduce the time period to complete the maintenance process and thus put the machines into service during the shortest possible period of time for the continuation of the production process though the use of neural network models with their computational mathematical structure that has the ability to determine the complex relationship between input and output data. Where the matlab program was relied upon to build, simulate and train neural networks due to its high efficiency in the field of prediction using a feed-forward network according to the Backpropagation algorithm by determining the amount of output for the machine number6 LOGA2-LOF in the morning, evening and night shifts as input rays, and training the neural network based on the values of weights and primary biases changing the values to reach the best values enables us to reach an actual output, and the results proved the success of neural networks in predicting machine failures at an early stage.

Keywords: Artificial Neural Network, Matlab Program, Backpropagation algorithm , feed-forward network, Artificial intelligence.

* Associate Professor–Faculty Of Mechanical & Electrical Engineering–Tishreen University–Lattakia–Syria.

** Associate Professor–Faculty Of Mechanical & Electrical Engineering–Tishreen University–Lattakia – Syria.

*** Postgraduate student (phD)- Faculty Of Mechanical & Electrical Engineering- Tishreen University – Lattakia – Syria-Tel:+963991913381- Turkan.fadi@gmail.com.

التنبؤ بأعطال الآلات في المنشآت الصناعية باستخدام الشبكات العصبونية (حالة الدراسة: المؤسسة العامة للتبغ)

* د. حاتم محمودي

** د. أيمن يوسف

*** تركان حمزه

(تاريخ الإيداع 9 / 8 / 2022. قُبل للنشر في 5 / 1 / 2023)

□ ملخص □

يتم في هذا البحث دراسة التنبؤ بأعطال الآلات في المنشآت الصناعية لتقليل الفترة الزمنية اللازمة لإنجاز عملية الصيانة وبالتالي وضع الآلات في الخدمة خلال أقل فترة زمنية ممكنة لاستمرار العملية الإنتاجية من خلال استخدام نماذج الشبكات العصبونية Neural Network مع هيكلتها الرياضية الحاسوبية التي لها القدرة على تحديد العلاقة المعقدة بين بيانات الدخل والخرج، حيث تم الاعتماد على برنامج MatLab لبناء ومحاكاة وتدريب الشبكات العصبونية نظراً لكفاءتها العالية في مجال التنبؤ باستخدام شبكة تغذية أمامية حسب خوارزمية Backpropagation من خلال تحديد كمية الإنتاج لآلة رقم 6 طراز LOGA2-LOF في الورديات (الصباحية والمسائية والليلية) كأشعة دخل وتصنيف الأعطال كأشعة خرج، وأثبتت النتائج نجاح الشبكات العصبونية في التنبؤ بأعطال الآلات في مرحلة مبكرة.

الكلمات المفتاحية: الشبكات العصبونية، برنامج MatLab، خوارزمية Backpropagation، شبكات التغذية الأمامية، الذكاء الصناعي.

* أستاذ مساعد - قسم هندسة التصميم والإنتاج - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.
** أستاذ مساعد - قسم هندسة التصميم والإنتاج - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.
*** طالبة دراسات عليا (دكتوراه) - قسم هندسة التصميم والإنتاج - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية. موبايل +963991913381 إيميل Turkan.fadi@gmail.com

مقدمة:

يعد التنبؤ بأعطال الآلات من المواضيع الهامة والأساسية في وضع الخطط التنموية لاقتصاد أي منشأة، وهي الوسيلة التي يستطيع بواسطتها المخطط رؤية الوضع المستقبلي للظاهرة المدروسة، ومحاولة كشف غموضها، حتى يتسنى له تبني اتخاذ أحسن القرارات الخاصة بعمليات الصيانة في المنشآت الصناعية، لوضع الآلات في الخدمة خلال فترة زمنية قصيرة لاستمرار العملية الإنتاجية، وخاصة في ظل التحديات القوية التي تفرضها ظروف المنافسة القوية بين مختلف المنشآت، والتي تحاول كل منها تقديم المنتجات بأفضل صورة بحيث يكون المنتج بجودة عالية ويتم إنتاجه بأقل تكلفة ممكنة وبأقل زمن ممكن ويحقق رضا المستهلك.

ومع تطور أنشطة المنشآت وتعقدتها ظهرت تقنية حديثة للتنبؤ تمثلت في نماذج الشبكات العصبونية بأنواعها المختلفة، وهي أكثر الطرق انتشاراً واستخداماً من قبل الباحثين لما تتصف بها من مزايا عديدة تؤدي في النهاية إلى الحصول على نظام نمذجة وتنبؤ موثوق فيه، وهي نظام لمعالجة البيانات بشكل يحاكي ويشابه الطريقة التي تقوم بها الشبكات العصبونية البيولوجية.

1. الدراسة المرجعية Literature Review:

نظراً لحتمية إتباع الأساليب العلمية الحديثة في إدارة عمليات الصيانة للحفاظ على استمرارية العمل كأحد التطورات الهامة في مفاهيم الإدارة الحديثة التي تدرك تماماً أن نجاح المؤسسات الإنتاجية مرهون بتحقيق أهدافها من تطوير وتحسين الإنتاج، ونظراً للحاجة المستمرة للأساليب العلمية الحديثة أدت إلى سعي حثيث ودراسات مكثفة للعمل على اقتراح منهجيات جديدة وحلول علمية وكلفة اقتصادية مناسبة.

وفي بحث قام به الباحث Denis Borg [1] بتطوير أداة تحليل تعتمد على الشبكات العصبونية لاكتشاف مشاكل قياس المستوى مع رادارات انتشار الموجة، وتزايد اتجاه استخدام هذا النوع من الرادار بسبب سهولة تركيبه على قمة الخزانات وللحفاظ على معدل منخفض مقارنة بتقنيات الأخرى، وتم تدريب الشبكة العصبونية على البيانات الواردة من برنامج Radar Master، وبعد استخدام شبكة عصبونية واستخدام 10 و 20 و 50 عصبونات وباستخدام السعة والمسافة والوقت كمدخلات لتحسين مستوى موثوقية القياس، كان أداء الشبكة 94.4% إلى 100% في الكشف عن بعض التطبيقات الصعبة الرئيسية لاستخدام الرادار.

وفي دراسة قام بها الباحث Bin Zhao [2] ببناء نموذج لتقييم مخاطر الصيانة لوحدة المصفاة عن طريق بناء شبكة عصبونية وتدريبها ومحاكاتها من خلال تحليل بيانات الاستبيان. وتم التوصل إلى نموذج ذو دقة عالية لتقييم المخاطر، ويتم التحكم بمخاطر المصفاة بناء على DSCNN IFA و CNN-FA و DSCNN-IFA.

كما قام الباحث Yarens J.Cruz [3] بتطبيق خوارزمية تطويرية لتصنيف صور اللحام الصناعي للكشف عن عدم محاذاة الصفائح المعدنية التي سيتم ربطها من خلال عملية اللحام بالقوس المغمور من خلال إجراء عملية بحث فعالة باستخدام خمس شبكات عصبونية التفاضلية CNN للحصول على الهدف المطلوب، وأظهرت النتائج تفوق الخوارزمية المستخدمة في الأداء على سبع استراتيجيات أخرى تم أخذها بعين الاعتبار عند المقارنة مع الحفاظ على تكلفة حسابية مناسبة.

وتظهر الدراسة التي قام بها الباحث BO LI [4] بدراسة منهجية قائمة على الشبكات العصبونية لتحسين دقة تحديد مواقع الروبوتات من خلال النمذجة للتنبؤ بأخطاء الروبوت في تحديد النقاط المستهدفة في مساحة عمل الروبوت، حيث يتم استخدام الروبوتات الصناعية بشكل متزايد في صناعة السيارات والطائرات والآلات والكهرباء والالكترون

والبلاستيك والاعذية نظراً لكفاءته ومرونته العالية، وتبين النتائج التجريبية وبعد تنفيذ سلسلة من التجارب للروبوت الصناعي KUKA KR 500_3 للتحقق من صحة الطريقة المقترحة أن أخطاء تحديد الموقع انخفضت من 1.529mm إلى 0.344mm وهذا يعني زيادة دقة الروبوت للتنبؤ بالموقع بنسبة 87.6%.

وتبين الدراسة التي قام بها الباحث Lemuel clark p. Velasco [5] بتحليل أداء نماذج الشبكة العصبونية للتنبؤ بالحمل الكهربائي في المستقبل، وتم إجراء هذه الدراسة من خلال إعداد البيانات التي حولت سجلات الحمل الكهربائي لمنطقة جغرافية معينة تخدمها إحدى مرافق الطاقة إلى أشكال مناسبة أدت إلى مجموعة بيانات مقسمة وممثلة وموحدة لعمليات تدريب واختبار الشبكات العصبونية، وبعد تقييم حوالي 36 نموذجاً من نماذج الشبكات العصبونية التي تحتوي على 9 عصبونات إدخال وخرج واحد من الخلايا العصبية، تم التوصل إلى أن نماذج الشبكات العصبونية أظهرت تنبؤاً جيداً من حيث نسبة الخطأ المطلق مع خوارزمية الانتشار الخلفي، وتمكنت الشبكات العصبونية من التنبؤ الدقيق للنتائج التي يمكن لشركات الطاقة استخدامها بشكل فعال للإدارة المثلى للموارد.

2. مشكلة البحث Research Question :

من خلال الزيارات المتعددة للمؤسسة العامة للتبغ، والاطلاع على كميات الإنتاج في الورديات الثلاثة (الصباحية والمسائية والليلية) والاطلاع على واقع الأعطال لآلات إنتاج السجائر القديمة تم ملاحظة حدوث توقفات نتيجة الأعطال الناجمة عن الآلات والتي تؤدي إلى ضياع في الوقت وبالتالي تخفيض كمية الإنتاج، كان لابد من تحسين عمليات الصيانة باستخدام تقنية الشبكات العصبونية للتنبؤ بالأعطال في مرحلة مبكرة للحصول على المنتج النهائي بأقل التكاليف وبأقل زمن ممكن وبجودة عالية.

أهمية البحث وأهدافه:

3. أهمية البحث:

تتجلى أهمية البحث في تناول موضوع محوري متعلق بنماذج الشبكات العصبونية والتي لها قدرة تنبؤية عالية مقارنة بالطرق الأخرى، حيث تعتبر الشبكة العصبونية نظام قابل للتكيف وتتغير بنيته اعتماداً على المعلومات التي تعبر من خلاله في ما يسمى بمرحلة التعلم. وتكمن أهميته في النقاط الآتية:

1. إبراز دور الشبكات العصبونية في زيادة الإنتاج بشكل عام سواء منشأة صناعية أو خدمية.
2. إبراز أهمية الشبكات العصبونية في عملية التنبؤ المبكر للأعطال لتقليل الفترة الزمنية لإنجاز عملية الصيانة وبالتالي وضع الآلات في الخدمة خلال أقصر فترة زمنية ممكنة لاستمرار العملية الإنتاجية.

4. هدف البحث:

هدف البحث هو تطبيق تقنية الشبكات العصبونية في المؤسسة العامة للتبغ باستخدام نماذج رياضية أو خوارزميات من خلال بناء نموذج للتنبؤ بأعطال الآلات شهرياً بشكل يومي لمدة 15 شهراً باستخدام نموذج قائم على شبكات التغذية الأمامية مع خوارزمية الانتشار العكسي.

طرائق البحث ومواده:

1. تقنية الشبكات العصبونية:

وهي خوارزميات أو نماذج رياضية لمعالجة المعلومات بالطريقة التي يؤدي فيها الدماغ البشري مهمة معينة، ويتم التدريب بواسطة خوارزميات متخصصة تدعى خوارزميات التدريب بالاعتماد على برنامج MATLAB، والتي تتولى تعديل أوزان الشبكة لتحسين أدائها ولتقليل الخطأ فيها استناداً إلى مقياس معلوم للوصول إلى تحديد قيم عددية لأوزان الشبكة والتي يمكن من خلالها تحقيق نتيجة مقارنة النتائج المطلوبة.

2. بناء النموذج التنبؤي باستخدام الشبكات العصبونية:

تعد المؤسسة العامة للتبغ إحدى المؤسسات النموذجية الهامة، وهي مؤسسة متعددة الأنشطة تعمل كوحدة متكاملة تشرف وتنظم عمليات الزراعة وتقوم بتصنيع كافة أنواع المنتجات التبغية المطلوبة في الأسواق المحلية، حيث تقوم المؤسسة بإنتاج السجائر الطويلة القديمة بالموصفات القياسية، وتحتوي المؤسسة على 6 آلات قديمة لإنتاج السجائر القديمة، وللتنبؤ بأعطال الآلات القديمة تم اختيار آلة قديمة رقم 6 للتنبؤ بأعطالها مع إجراء احصائيات لكمية الإنتاج، وحسب البيانات المجدولة والمتوفرة للآلات في المؤسسة العامة للتبغ تم الاعتماد على تمثيل كميات الإنتاج كأشعة دخل في الورديات الثلاثة لأخذ جميع أنواع الأعطال بعين الاعتبار وتمثيل الأعطال كأشعة خرج عن طريق مصفوفات منطوية.

ولبناء النموذج التنبؤي بأعطال الآلات في المؤسسة العامة للتبغ للآلة القديمة رقم 6، تم الاعتماد على نموذج الشبكات العصبونية واجهة nntool وخوارزمية الانتشار الخلفي Backpropagation وخوارزمية Levenberg- LM (Murquardt)، حيث استخدمت بيانات 15 شهراً بشكل يومي بين عامي 2020-2021 باستثناء أيام العطل، علماً أن عدد العصبونات اللازمة لتدريب الشبكة، يعتبر الجملة الأصعب في التدريب والبناء، بسبب عدم وجود طريقة عامة لإيجادها، لذا فإن هيكليّة نماذج الشبكات العصبونية يتم استقراؤها بعد عملية التجربة، وبعد مراقبة أداء الشبكة تم اعتماد هيكليّة لشبكة عصبونية مع 3 مدخلات (كمية الإنتاج في الورديات الثلاثة) و 40 مخرجات هي نوع الأعطال الناجمة عن الآلات مع طبقة خفية واحدة فقط بين طبقتي الدخل والخرج، ومن خلال تغيير عدد العصبونات في الطبقة الخفية وتوابع التفعيل المستخدمة في تدريب الشبكة، ومن خلال مقارنة قيم متوسط مربعات الأخطاء (mse mean squared error) ومعامل الارتباط R لكل نموذج، حيث استخدمت بيانات 345 يوماً والتي تم تقسيمها في ثلاث مجموعات (241 يوماً لتدريب الشبكة و 52 يوماً للتحقق من نتائجها، و 52 يوماً لاختبارها)، فقد تم ترميز الأعطال ضمن برنامج Microsoft Excel. كما هو موضح في الجدول (1).

الجدول (1) ترميز أعطال الآلات الستة في المعمل

رقم العطل	اسم العطل	رقم العطل	اسم العطل
1	محاصرة التبغ تحت التمساح	21	معايرة طنابير الفلتر
2	عيار دخول السجارة	22	معايرة الفارزة
3	تقطيع ورق ابيض	23	محاصرة على القرنية
4	تقليش حبل السجارة	24	تبديل قشاط دوران فرشاة الفارزة
5	تبديل فحمت محرك الشفط	25	معايرة القرنية
6	تبديل قشاط بكرة جر القشاط البطيء	26	تبديل الشوكة الطويلة
7	عطل في القشاط البطيء	27	معايرة صحن الفارزة
8	تبديل فرشاة الفارزة	28	عطل في قشاطات وحدة القطع
9	تبديل قشاط الفارزة	29	فك علبه السرعة

محاصرة على القشاطر الراجع	30	عطل في الفارزة	10
تبدال محور القشاطر السريع	31	محاصرة على طنبور سكين القص الدائرية	11
تبدال قشاطر دوران السريع	32	تبدال قميص الفلتر	12
محاصرة على طنابير الفلتر	33	تبدال قشاطر فرشاة الفارزة	13
تبدال مسنن الفارزة	34	تبدال علبة سرعة محرك القشاطر الطويل	14
محاصرة على طنابير الفلتر	35	تبدال سكين قص الورق الابيض	15
محاصرة على طنبور المكواة	36	تبدال القرنية	16
تبدال جرن الغراء	37	عطل في محور التعشيقية	17
تبدال سكاكين قص الفلتر	38	تبدال محور الفارزة	18
محاصرة على القشاطر السريع	39	تبدال الفارزة	19
تهريب الفلتر	40	عطل في علبة السرعة للفارزة	20

وبعد أن تم تفريغ بيانات كميات الإنتاج في الورديات الصباحية والمسائية والليلية وأعطال الآلة المتوفرة لمدة 15 شهراً وتحديدهم شعاعي الدخل والخرج كالتالي:

✓ شعاع الدخل : من أجل كمية الإنتاج في الورديات الصباحية والمسائية والليلية تم إنشاء مصفوفة شعاع الدخل للآلة رقم 6 بأبعاد 3x345 ل 15 شهر لأيام العمل فقط مع أخذ العطل بعين الاعتبار.

✓ شعاع الخرج: تم إنشاء مصفوفة شعاع الخرج بأبعاد 40x345 ويعبر الرقم 1 أن العطل مفعّل والرقم 0 أن العطل غير مفعّل.

حيث يوضح الجدول (2) أشعة الدخل (لكميات الإنتاج في الورديات الثلاثة ب kg) والخرج 40 عطل ونوع كل عطل موضح في الجدول (1)، ويعبر الرقم 1 أن العطل مفعّل والرقم 0 أن العطل غير مفعّل وبقيّة الأعطال تكون مفعلة في الشهور الباقية، حيث تم توضيح شهر واحد فقط في الجدول (2) لكثرة البيانات.

الجدول (2) بيانات الشهر العاشر من عام 2021

شعاع الدخل لشهر واحد فقط أيام العمل																					
21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1	أيام العمل
135	170	125	170	125	95	155	175	140	145	130	125	135	105	125	95	0	0	0	0	0	كمية الإنتاج في الوردية الصباحية (Kg)
160	170	160	145	145	155	165	190	170	135	145	135	165	130	170	150	115	90	150	70	100	كمية الإنتاج في الوردية المسائية (kg)
85	85	0	95	95	75	95	70	115	75	100	85	100	80	35	80	0	0	0	0	0	كمية إنتاج في الوردية الليلية (kg)
شعاع الخرج																				رقم العطل	
1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2
1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	3
1	0	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	4
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	7
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9
0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	11
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	13
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	14
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	15
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	16
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	17
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	18
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	19
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	22
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	23
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	26
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	27
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	28
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	29
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	31

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	32	
0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	33
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	34
0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	35
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	36
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	37
0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	38
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	39
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	40


ويعد إجراء عدد كبير جداً من التجارب على شبكات عصبونية ذات التغذية الأمامية، ومن خلال مقارنة متوسط مربعات الأخطاء MSE، ومعامل الارتباط R لكل نموذج للألة رقم 6 ولمدة 15 شهر، تم الاعتماد على النتائج الموضحة في الجدول (3) قيم R و MSE لأنماط المدخلات لمجموعة بيانات التدريب والتحقق والاختبار. ونلاحظ من الجدول (3) أن الشبكة العصبونية التي تحتوي على عصبونات (3-9-40) هي الأفضل بالاعتماد على تابع التنشيط purelin في طبقة الخرج والتابع tansig في الطبقة الخفية وتابع التدريب Trainlm.

الجدول (3) نتائج تدريب الشبكة للألة رقم 6 ل 15 شهر

عدد العصبونات في الطبقة الخفية	Mse validiton performance	R للتدريب	R للتحقق	R للاختبار	R الكلي
2	0.012906	0.90273	0.89758	0.90134	0.90167
3	0.012421	0.90814	0.90632	0.88136	0.90379
4	0.009449	0.89843	0.92469	0.9164	0.90505
5	0.012336	0.91347	0.89981	0.84099	0.89985
6	0.011943	0.90161	0.90287	0.91883	0.90432
7	0.015322	0.91016	0.87992	0.91653	0.90645
8	0.010334	0.90508	0.91725	0.90784	0.9073
9	0.0078846	0.89743	0.93747	0.9112	0.90544
10	0.015034	0.92023	0.8808	0.87143	0.90697
11	0.012917	0.90941	0.89558	0.90677	0.90693
12	0.014595	0.90263	0.88661	0.90395	0.90025
13	0.011644	0.91031	0.91086	0.87613	0.9051
14	0.011909	0.91501	0.9033	0.87616	0.90727
15	0.010137	0.90642	0.91463	0.82983	0.89529
16	0.018526	0.9149	0.85305	0.90251	0.90361
17	0.013249	0.91047	0.89276	0.87786	0.90254
18	0.011244	0.90772	0.90939	0.89973	0.9067
19	0.016286	0.91452	0.86758	0.91937	0.90823
20	0.01447	0.90931	0.88119	0.88444	0.90133
21	0.013227	0.90925	0.89177	0.88793	0.90325
22	0.016043	0.9279	0.87086	0.87718	0.90146
23	0.014075	0.9101	0.88467	0.85524	0.89795
24	0.012045	0.90699	0.90251	0.89246	0.90402
25	0.016623	0.91143	0.86246	0.86178	0.89625

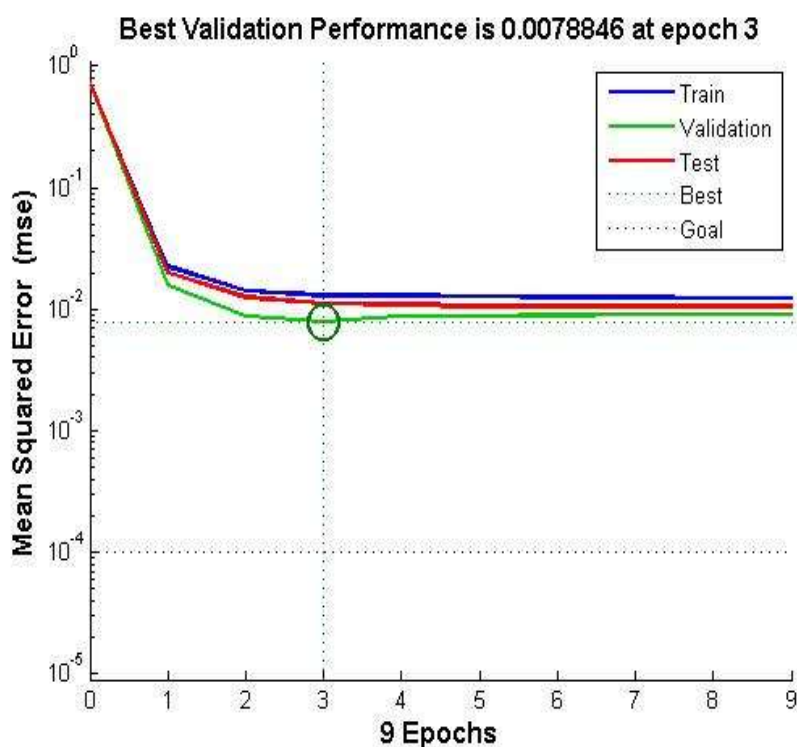
26	0.01072	0.91004	0.91516	0.86787	0.90433
27	0.091785	0.91757	0.91757	0.86835	0.90994
28	0.011336	0.90717	0.91262	0.89586	0.90605
29	0.012259	0.91337	0.90142	0.90179	0.90982
30	0.014081	0.90683	0.89278	0.70701	0.86793

ويوضح الشكل (1) هيكلية الشبكة المثالية.




الشكل(1) هيكلية الشبكة العصبية المثالية

وقيم متوسط مربعات الأخطاء mse للشبكة المثالية موضحة في الشكل(2):




الشكل(2) قيم MSE مربعات الأخطاء

ويوضح الشكل(3) قيم معامل الارتباط للتدريب والتحقق والاختبار:



الشكل (3) قيم معامل الارتباط R

ولاختبار الشبكة المختارة نقوم باستخدام simulation network لشهر واحد والذي يسمح بتطبيق أشعة الدخل على الشبكة العصبونية المثالية للحصول على شعاع الخرج المطلوب. كما هو مبين في الشكل (4):



الشكل (4) واجهة اختبار الشبكة simulate

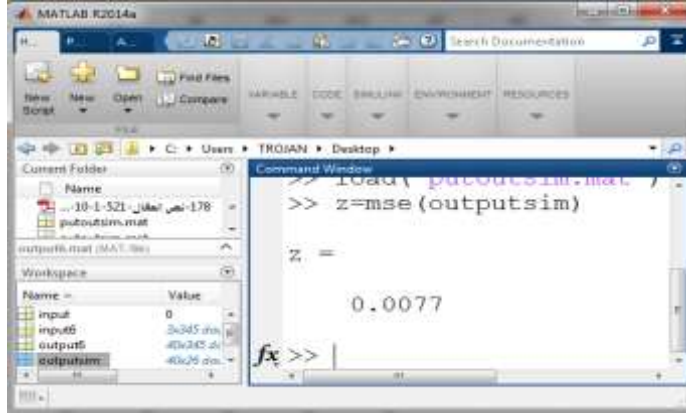
ويمكن اختبار مدى ملائمة الشبكة العصبونية المقترحة من خلال حساب عدة أنواع من الأخطاء لتساعد في عملية اختيار الشبكة المقترحة منها:

1. mse (Mean Of squared Error) وهو متوسط مربعات الأخطاء وتحسب من العلاقة:

$$mse = \frac{\sum_{i=1}^n \sum_{j=1}^m (Q_{ij} - T_{ij})^2}{N}$$

n: عدد عينات التدريب، m= عدد مركبات شعاع الخرج.

Qiz: هو الخرج الناتج عن الشبكة للعصبون، $T_{ij} =$ هو الخرج الحقيقي للعصبون. حيث تم حسابه في MATLAB بعد إيجاد الفرق بين الخرج الفعلي والخرج الناتج عن الشبكة، كما في الشكل (5):

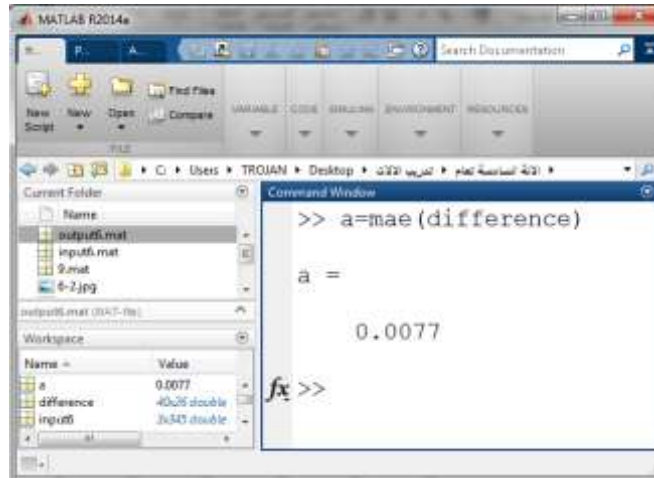


الشكل (5) قيمة MSE بعد حساب الفرق بين القيم الحقيقية والقيم التي تم التنبؤ بها

2. MAE (Mean Absolute Error) وهو الخطأ المتوسط المطلق ويحسب من العلاقة:

$$MAE = \frac{\sum_{i=1}^n \sum_{j=1}^m |Q_{ij} - T_{ij}|}{N}$$

تم حسابه في MATLAB كما في الشكل (6):



الشكل (6) قيمة MAE

3. RMSE (Root Mean squared Error) وهي جذر متوسط مربعات الأخطاء وتحسب:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n \sum_{j=1}^m (Q_{ij} - T_{ij})^2}{N}} = \sqrt{0.0077} = 0.0877$$

النتائج والمناقشة:

نلاحظ من الجدول (3) مايلي:

1. إن الشبكة العصبونية التي تحتوي على عصبونات (3-9-40) هي الأفضل.

2. قيم مربعات الأخطاء MSE تساوي **0.0078846**، وهي قيمة قريبة جداً من الصفر، وقد أعطت الشبكة العصبونية المختارة قيمة عالية لمعامل الارتباط بين القيم الحقيقية والقيم الناتجة عن الشبكة حيث كانت مراحل التدريب والتحقق والاختبار على الترتيب هي (**0.89743** ، **0.93747** ، **0.9112**) وقد بلغت القيمة الكلية خلال المراحل الثلاث **0.90544** وهي قيمة قريبة من الواحد وبالتالي الشبكة المصممة مثالية وتحقق الاستجابة للتنبؤ بالأعطال الناتجة عن العمل في الورديات الثلاثة.
3. إن قيمة MSE لشهر الاختبار هي 0.0077 كما هي موضحة في الشكل (5) وهي قريبة جداً من الصفر، وبالتالي الشبكة العصبونية المختارة مثالية.

الاستنتاجات والتوصيات:

الاستنتاجات:

1. استخدام الشبكات العصبونية في عملية التنبؤ بالأعطال في الورديات، يمكن أن يخفف من فترة صيانة الآلات وبالتالي إعادة الخدمة للآلات بأقل فترة زمنية ممكنة.
2. أثبتت الشبكة العصبونية ذات الهيكلية (3-9-40) وذات معامل الارتباط الكلي 0.90544 وبمتوسط مربعات الأخطاء 0.0078 لمجموعة البيانات الكلية، قدرتها على التنبؤ بأعطال الآلات في المؤسسة العامة للتبغ.

التوصيات:

1. التأكيد على استخدام نماذج الشبكات العصبونية ذات التغذية الأمامية في المنشآت الصناعية، وتطبيقها على الآلات بإدخال بيانات مستقبلية جديدة لكميات الإنتاج، مع إدخال عدد أكبر من السنوات لزيادة الدقة في التنبؤ بالأعطال لتقليل الفترة الزمنية اللازمة لإجراء عمليات الصيانة.
2. التأكيد على تطبيق نماذج الشبكات العصبونية الأخرى، مع الأخذ بعين الاعتبار بيانات جديدة مثل بيانات صناعة الورق الأبيض للسجائر وكيفية تخزين التبغ وبيانات صناعة الفلتر وبيانات أخرى تساعد في الحصول على نتائج أدق.
3. اعتماد الشبكات العصبونية بديلاً للطرائق التقليدية في عملية التنبؤ، لأن كفاءتها تكون بشكل أكبر خصوصاً في نماذج غير الخطية، خاصة أن الشبكات العصبونية لا تحتاج إلى عملية نمذجة أو فرضيات معينة، وذلك لامتلاك تلك الشبكات خاصية التعلم والتدريب والتكيف ذاتياً مع أي نموذج.

References:

1. BORG, D; PINTO, F; SUETAKE, M. *Neutral networks as a diagnosing tool for industrial level measurement through non-contacting radar type and support to the decision for its better application*. Brazil, 49-30, 2016, 349-354.
2. ZHAO, B; CHEN, H; XU, L. *Risk assessment of unit maintenance based on fuzzy second generation curvelet neutral network*. 59, 2020, 1823-1831.
3. CRUZ, Y; RIVAS, M; QUIZ, R. *Ensemble of convolution neural networks based on an evolutionary algorithm applied to an industrial welding process*. Spain, Universidad de Matanzas, 133, 2021, 1-9.
4. LI, B; TIAN, W; ZHANG, C; HUA, F. *Positioning error compensation of an industrial robot using neural networks and experimental study*. China, Nanjing University, 35(2), 2022, 346-360.
5. VELASCO, L; ARNEJO, K; MACARAT, J. *Performance analysis of artificial neural network models for hour-ahead electric load forecasting*. 197, 2022, 16-24.

6. NGUYEN, N; ZHOU, J; KANG, J. *A calibration method for enhancing robot accuracy through integration of an extended kalman filter algorithm and an artificial neural network*. *Neur-computingm*, 151, 2015, 996-1005.
7. BARYRO, E; LECHUGA, L. *Geometric techniques for robotics and HMI: interpolation and haptics in conformal gecometrics algebra and control using quarter-nion spike neural networks*. 104, 2018, 72-84.
8. BIAGETTI, L; KOCHAR, A; CRISTALLI, C. *Cognitive grasping system: A grasping solution for industrial robotics manipulation using convolutional neural network*. Italy, 51, 2020, 32-37.
9. ALBLAWI, A. *Fault diagnosis of an industrial gas turbine based on the thermodynamic model coupled with a multi feedforwarded artificial neural networks*. Saudi arabia, 6, 2020, 1083-1096.
10. OKOJI, A; ANOZIE, A. OMOLEYE, J; *Evaluating the thermodynamic efficiency of the cement grate clinker cooler process using artificial neural networks and ANFIS*. Nigeria, 13, 2022, 1-10.
11. OKOLO, B; OBIEOGU, K. *Modeling of methyl ester yield from terminalia catappa L. kernel oil by artificial neural network and response surface methodology for possible industrial application*. Nigeria, 6, 2022, 1-16.