



FAILURE PREDICTION AND DIAGNOSTIC ANALYSIS FOR LATHES USING A HYBRID APPROACH INCLUDING ARTIFICIAL NEURAL NETWORK AND DECISION MAKING BLOCK

K. Atashgar* & A. Saravany

*Karim Atashgar, Assistant professor of Industrial Engineering faculty – Malek Ashtar University of Technology
Abbas Saravany, MSc student of Industrial Engineering faculty – Malek Ashtar University of Technology*

Keywords

Artificial neural network,
Hybrid model,
Failure prediction

ABSTRACT

Failure prediction of industrial machineries plays an essential role to reduce overhead costs of production processes. Although literature addresses different models to maintain industrial machineries proposed by researchers, to the best of authors' knowledge it is the first time that a hybrid model including decision blocks and artificial neural network is proposed to predict failure and diagnosing the source responsible, at the same time before a lathe shifts to a disable condition. The proposed hybrid model designed based on the approach of monitoring digital and analog data which address the failure types of lathes. To train effectively the proposed model retrospective analysis corresponding to an industrial factory including 383 lathes in Iran has been approached by the researchers. The valuable data analyzed in this research for training has been recorded in the past thirty years. In this research it is assumed that data corresponding to the failure follows weibull distribution. The analysis of the proposed hybrid model addresses high capability of predicting, i.e. 99.95% correct prediction in term of correct classification percentage. The numerical example used to evaluate the hybrid model indicates the proposed model is capable to use by engineers for on-line condition monitoring to predict failures and to diagnose the source responsible for a lathe effectively.

© 2016 IUST Publication, IJIEPM. Vol. 27, No. 2, All Rights Reserved



پیش بینی خرابی و عیب یابی ماشین های تراش با استفاده از رویکرد ترکیبی شبکه عصبی مصنوعی و بلوک تصمیم گیری

کریم آتشگر* و عباس سراوانی

چکیده:

پیش بینی خرابی ماشین آلات، نقش مهمی را در کاهش هزینه های سربار فرآیندهای تولید دارد. در ادبیات موضوع، مدل های مختلفی برای نگهداری و تعمیرات ماشین آلات صنعتی ارائه شده است، ولی بر اساس دانش نویسندگان، این پژوهش برای اولین بار توانسته یک مدل ترکیبی از شبکه عصبی و بلوک های تصمیم گیری ارائه دهد، که با استفاده از آن، با قابلیت اطمینان بالایی، می توان خرابی و علت آن را، قبل از کارافتادگی ماشین های تراش، بطور همزمان تشخیص داد. مدل پیشنهادی در این مقاله بر اساس سیگنال های آنالوگ و دیجیتال دریافتی عمل می کند. اطلاعات مورد نیاز برای آموزش مدل پیشنهادی این مقاله از نشانه های خرابی های ثبت شده، در طی ۳۰ سال گذشته، برای دستگاه های تراش یک کارخانه صنعتی در ایران با ۳۸۳ دستگاه تراش بدست آمده است. مدل پیشنهادی این پژوهش با پیروی از توزیع وایبل^۱ آموزش داده شده است. نتایج بدست آمده نشان می دهد که مدل ترکیبی پیشنهادی می تواند با احتمال بالا و قابل توجه ۹۹/۵٪ خرابی های ماشین های تراش را قبل از وقوع، پیش بینی کرده، و علت آن را تشخیص دهد. برای ارزیابی عملکرد مدل پیشنهادی از مثال های عددی استفاده شده است. ارزیابی فوق نشان می دهد که این مدل بشکل اثربخشی می تواند برای پایش و پیش بینی وضعیت خرابی ماشین های تراش، و شناسایی علت خرابی آنها، توسط مهندسیین استفاده شود.

کلمات کلیدی

شبکه های عصبی مصنوعی،
پیش بینی خرابی،
مدل ترکیبی

۱. مقدمه

آماده بکار بودن تجهیزات خطوط تولید، همواره موضوع مورد علاقه صاحبان صنایع بوده است. اما بر اساس سیر طبیعی و ماهیت تجهیزات، همه آنها در طول چرخه حیات خود، دچار خرابی هایی می شوند. در صورت وقوع یک خرابی در هریک از تجهیزات، عوامل مسئول، تلاش خود را برای تعمیر و بازگرداندن دستگاه به شرایط کاری آغاز می کنند. آنچه در این میان مهم است سطح تخصص مورد نیاز و زمان انجام تعمیر و هزینه انجام آن برای مشتری یا صاحبان تجهیزات است.

تاریخ وصول: ۹۲/۰۸/۱۳

تاریخ تصویب: ۹۳/۰۴/۲۴

عباس سراوانی، دانشکده مهندسی صنایع، دانشگاه صنعتی مالک اشتر -

a_saravani@yahoo.com

*نویسنده مسئول مقاله: کریم آتشگر، دانشکده مهندسی صنایع، دانشگاه صنعتی

مالک اشتر، atashgar@iust.ac.ir

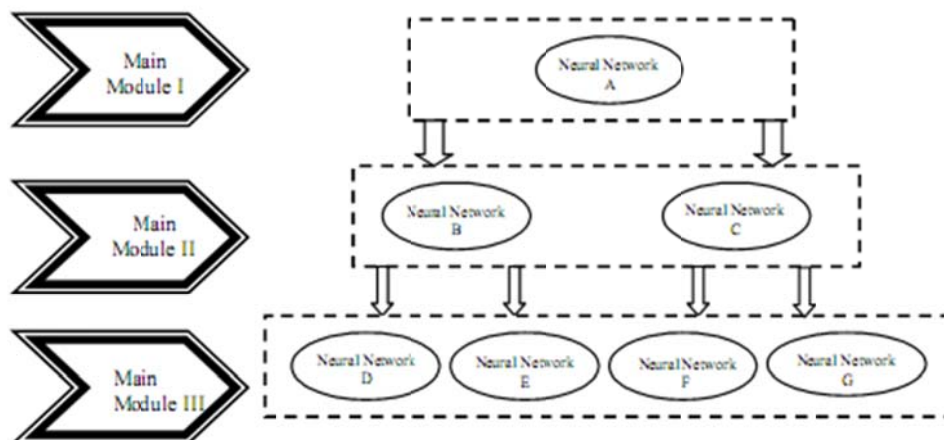
برای این منظور، دانش نت بصورت دانش تصریحی (یعنی توصیه های ثبت شده سازندگان در کاتالوگ ها) و دانش ضمنی (یعنی تجارب شخصی تعمیرکاران) در اختیار تعمیرکاران است تا در مواقع مورد نیاز بکار گرفته شوند. با این وجود، در برخی موارد پیدا کردن خرابی، روزها بلکه ماه ها بطول می انجامد و باعث توقف کوتاه مدت و یا بلند مدت خطوط تولیدی، و در نتیجه تحمیل هزینه های فراوان به مشتریان می شود.

شکوهی و شهریاری [۱] مسئله بهینه سازی منابع برای موضوع نت را با هدف افزایش سطح دسترسی با رویکرد بهینه سازی استوار، در حالی که داده ها در شرایط عدم قطعیت تعریف شده اند، با ارائه مدل بهینه سازی منابع نگهداری و تعمیرات، مورد توجه قرار دادند. این رویکرد از آن جهت برای محققین اهمیت یافته که بتوانند، هزینه های ناشی از عدم دسترسی را بواسطه عدم پیش بینی خرابی ماشین آلات کاهش دهند. برای کاهش هزینه های ناشی از کار افتادگی، شهنقی و همکاران

کرده‌اند. مدل پیشنهادی در این مقاله از سه ماژول اصلی تشکیل شده است. مدل پیشنهادی آنها در شکل ۱ نشان داده شده است. آتشگر و نورالسا [۷] در این مدل از روش آموزش با ناظر و الگوریتم پرسپترون در طراحی ماژول‌ها استفاده کرده‌اند. زانگ و همکاران [۸] با استفاده از شبکه‌های عصبی توانستند سیستمی برای کنترل و پیش‌بینی سرعت موتورهای DC ارائه کنند. سامانه ارائه شده توسط آنها از ۲ قسمت تشکیل شده است. قسمت اول وظیفه پیش‌بینی سرعت را با استفاده از شبکه‌های عصبی بر عهده دارد. قسمت دوم یک کنترل‌کننده مبتنی بر شبکه‌های عصبی است که وظیفه تولید سیگنال کنترل را بر عهده دارد. شبکه ارائه شده توسط زانگ و همکاران [۸]، ۳ لایه، و از الگوریتم پیشخور^۳ پیروی می‌کند. در مدل پیشنهادی زانگ و همکاران [۸] در لایه‌های ورودی و پنهان از تابع سیگموئید و در لایه خروجی از تابع خطی استفاده شده است. الگوریتم آموزشی در این مدل پیشنهادی نیز پس انتشار خطا با روش لوبنرگ مارکوارت است. زانگ و همکاران [۸] با مقایسه مدل پیشنهادی خود با سیستم‌های معمولی تخمین سرعت، نتیجه گرفتند که مدل شبکه عصبی ارائه شده توسط آنها پاسخ بهتری می‌دهد. قوی پنجه [۹] در پایان نامه خود به پیش‌بینی خرابی ماشین آلات دوار با استفاده از آنالیز ارتعاشات پرداخته است. قوی پنجه [۹] در این تحقیق مدلی مبتنی بر شبکه‌های هوشمند ارائه کرده است که می‌تواند خرابی‌هایی را که روی طیف ارتعاشی دستگاه تاثیر گذار هستند، پیش‌بینی کند. قوی پنجه [۹] مدل مورد نظر خود را با ۶ نوع شبکه مورد آزمون قرار داده و نتیجه گرفته است که، مناسب‌ترین شبکه برای مدل ارائه شده، شبکه پیشخور است.

در مدل ارائه شده در این مقاله، سعی شده است تا تجربه چندین ساله تعمیرکاران و دانش تصریحی لحاظ شده در کاتالوگ دستگاه‌های تراش، به یک شبکه عصبی آموزش داده شود تا به محض گرایش دستگاه به سمت خرابی، شبکه عصبی کار تشخیص را بصورت آنلاین^۴ و با احتمال قابل قبولی در مدت چند ثانیه انجام داده و دلایل آن را نیز برای رفع خرابی احتمالی ارائه دهد. در پایش آنلاین، داده‌ها مسقیماً از دستگاه یا فرآیند، گردآوری شده و مورد پردازش قرار می‌گیرند، اما در روش آفلاین، داده‌ها توسط دستگاه‌های خاصی گردآوری شده و در زمان دیگری مورد استفاده قرار می‌گیرند. بدین ترتیب با استفاده از این مدل پیشنهادی، تعمیرکارانی که از تجربه بالایی نیز برخوردار نیستند می‌توانند با پیام‌های این سیستم، خرابی پیش‌آمده یا در حال وقوع را شناسایی و برای جلوگیری از وقوع خرابی اقدام کنند. رویکرد ترکیبی استفاده شده در مدل پیشنهادی این مقاله، توانسته است شرایط عیب‌یابی مناسبی را برای دستگاه‌های تراش ارائه دهد، و در نهایت باعث کاهش متوسط زمان تعمیر شود. عملکرد مدل ارائه شده در این مقاله با استفاده از میانگین مربعات خطا مورد ارزیابی قرار گرفته است.

[۲] بازرسی را بر مبنای ریسک برای سیاست‌های نت پیشنهاد کرده‌اند. میر محمدصادقی و همکاران [۳] نیز موضوع نگهداری و تعمیرات را برای راه آهن ایران با رویکرد اولویت بندی مورد توجه قرار دادند. رویکردی را که شهانقی و همکاران [۲] و همچنین میرمحمدصادقی و همکاران [۳] مدل خود را بر آن بنا نهاده‌اند، موضوع پیش‌بینی را قبل از وقوع مورد توجه قرار نداده است. ادبیات موضوع نشان می‌دهد که رویکرد شبکه عصبی نیز برای موضوع نگهداری و تعمیرات مورد توجه بعضی از محققین قرار گرفته است. منابع علمی منتشر شده نشان می‌دهد که عمده کارهای مرتبط با استفاده از شبکه‌های عصبی در نگهداری و تعمیرات، از الگویی مشابه پیروی می‌کنند. جدول شماره ۱ نمونه‌ایی از گزارشات منتشر شده در منابع علمی را نشان می‌دهد. بانسال و همکاران [۴] یک شبکه عصبی برای نگهداری و تعمیرات پیش‌گیرانه سیستم‌های ماشینی ارائه کردند. آنها نشان دادند که شبکه عصبی پیشنهادی آنها با درصد قابل توجهی برای این دسته از سیستم‌ها خوبی کار می‌کند. صنیعی و افتخار [۵] یک شبکه عصبی مصنوعی پیشنهاد دادند که بتواند عیب‌یابی خودرو را بطور خودکار انجام دهد. در این گزارش خرابی‌های محتمل خودرو، با استعلام از افراد خبره لیست شده و به عنوان ورودی‌های شبکه معرفی شده‌اند. صنیعی و افتخار [۵] با استفاده از ۳ نوع شبکه عصبی شامل پرسپترون چند لایه، هاپ فیلد و کوهونن مدل پیشنهادی خود را طراحی و ارزیابی کرده‌اند. آنها بر اساس نتایج حاصل از عملکرد شبکه، نتیجه گرفته‌اند که هر سه شبکه در عمل بدون خطا هستند. اما با توجه به اینکه در این گزارش، خرابی‌ها و علل قطعی آنها بطور دقیق مشخص شده است، لذا می‌توان نوعی قطعیت را استنباط نمود. در این گونه موارد نیازی به استفاده از شبکه‌های عصبی نیست و می‌توان روش‌های ساده تری مانند سیستم‌های خبره را استفاده کرد، که از یک رابطه منطقی خطی قطعی پیروی می‌کنند. در گزارش فوق از رویکرد آفلاین استفاده شده است. گاپیتاکال و همکاران [۶] برای عیب‌یابی ترانسفورماتورهای خطوط انتقال انرژی، یک شبکه عصبی پیشنهاد دادند. در این تحقیق آنها بر اساس مدار معادل یک ترانسفورماتور توزیع، خرابی‌های احتمالی موجود در آن را، که ورودی‌های شبکه عصبی را تشکیل می‌دهند، مشخص کردند. آنها در این تحقیق بر اساس خرابی‌های احتمالی و با استفاده از تبدیل موجک^۲ در مدار معادل ترانسفورماتور، پیامدهای خرابی‌ها، که همان خروجی‌های شبکه عصبی هستند را مشخص کردند. گاپیتاکال و همکاران [۶] نشان دادند که با الگوریتم ارائه شده می‌توان با دقت بالای ۹۸٪ محل خطا را پیدا کرد. مدل ارائه شده توسط گاپیتاکال و همکاران [۶] از یک لایه ورودی و ۲ لایه پنهان و یک لایه خروجی تشکیل شده است. در مدل ارائه شده توسط گاپیتاکال و همکاران [۶] تعداد خرابی‌ها یا همان ورودی، ۱۲ و برای لایه خروجی نیز ۸ نرون تعریف شده است. آتشگر و نورالسا [۷] در گزارش خود به شناسایی شرایط خارج از کنترل و تخمین نقطه تغییر که می‌تواند حاصل خرابی در تجهیزات در یک فرآیند باشد، تمرکز



شکل ۱. نمودار ماژولار (ماخذ مرجع [۷])

پنجم و ششم این مقاله نیز بترتیب به موضوع طراحی و آموزش شبکه عصبی استفاده شده در مدل پیشنهادی، و ارزیابی آن تمرکز دارد. بخش نهایی در این مقاله به نتیجه‌گیری از پژوهش انجام شده می‌پردازد.

در بخش بعدی این مقاله، پارامترهای مؤثر در عیب‌یابی ماشین‌های تراش معرفی می‌شوند. بخش سوم مقاله به بررسی نشانه‌های خرابی اختصاص دارد. در بخش چهارم، ساختار مدلی را که در این مقاله پیشنهاد شده است، معرفی می‌شود. بخش‌های

جدول ۱. کارهای انجام شده

هدف	نوع شبکه	محقق
نگهداری و تعمیرات پیش‌گیرانه	پرسپترون چند لایه	بانسال و همکاران [۴]
عیب‌یابی خودروها با استفاده از شبکه‌های عصبی	پرسپترون چند لایه - هاپفیلد - کوهونن	صنعی [۵]
استفاده از شبکه‌های عصبی برای عیب‌یابی ترانسفور ماتورها	پرسپترون چند لایه	گاپتاکال و همکاران [۶]
استفاده از تکنیک ماژولار و شبکه‌های عصبی در پیش‌بینی نقطه تغییر در فرآیندها.	پرسپترون چند لایه	آتشگر و نورالسنا [۷]
پیش‌بینی و کنترل سرعت موتور DC	پرسپترون چند لایه	زانگ و همکاران [۸]
پیش‌بینی خرابی دستگاه‌های دوار با استفاده از آنالیز ارتعاشات	پرسپترون چند لایه	قوی پنجه [۹]
شناسایی نقطه تغییر و عوامل ایجاد تغییر در بردار میانگین یک فرآیند نرمال ۲ متغیره	پرسپترون چند لایه	آتشگر [۱۰]
مشخص کردن نقطه شروع تغییرات یا زمان وقوع اغتشاش و عوامل ایجاد تغییرات در یک فرآیند دو متغیره با استفاده از شبکه‌های عصبی.	پرسپترون چند لایه	آشگرو نورالسنا [۱۱]
مقایسه عملکرد ۳ نوع شبکه عصبی پرسپترون چند لایه، شعاعی و احتمالی در پیدا کردن خرابی بلبیرینگ	پرسپترون چند لایه	سامانتا و همکاران [۱۲]
پیش‌بینی خرابی بلبیرینگ موتورهای القایی	پرسپترون چند لایه و المان	مهاماد و همکاران [۱۳]
پیدا کردن محل خرابی خطوط انتقال برق با استفاده از شبکه عصبی احتمالی	شبکه احتمالی	آلام و همکاران [۱۴]

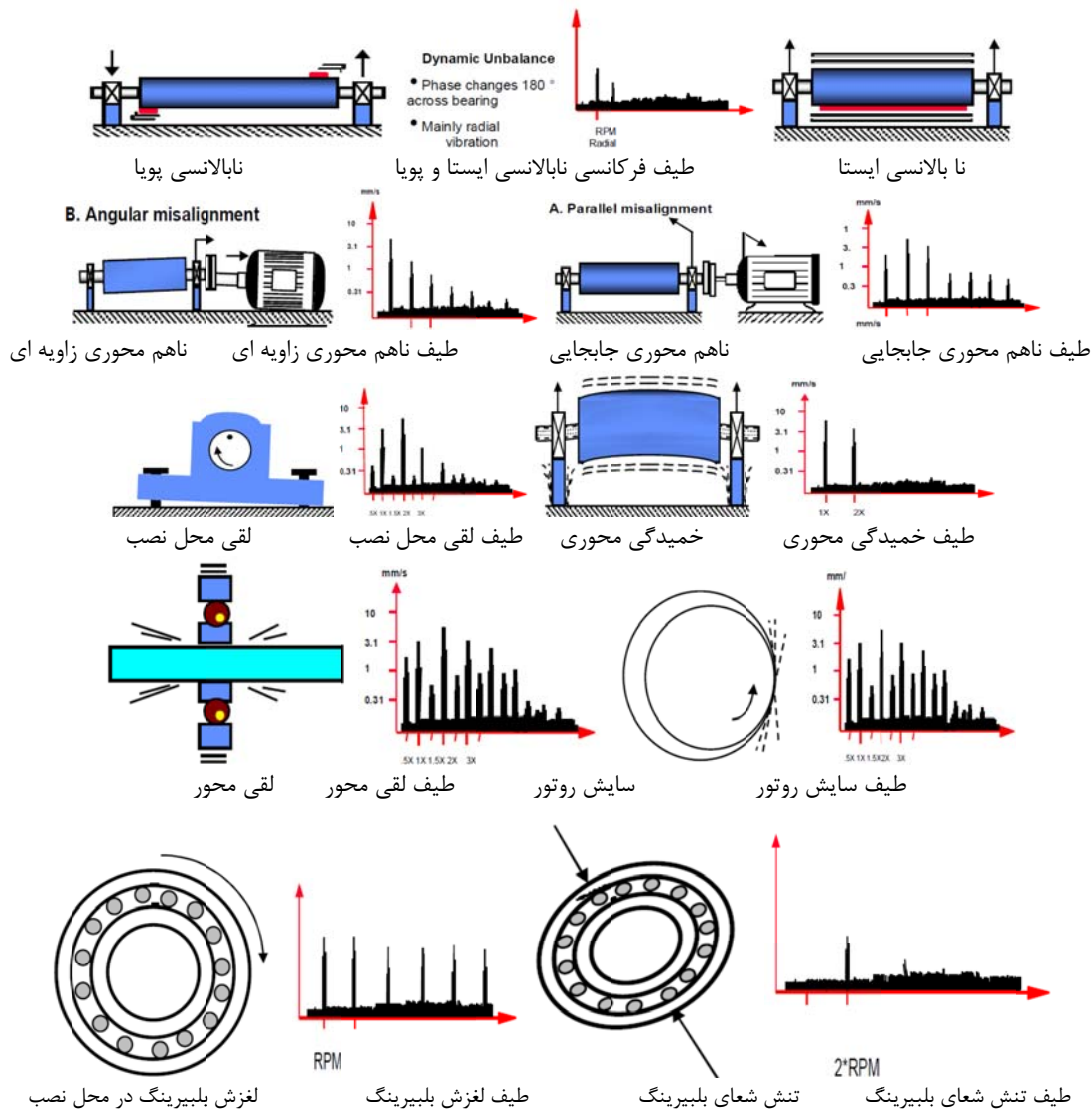
۲. آشنایی با پارامترهای مؤثر در عیب‌یابی یک ماشین تراش

بررسی فنی دستگاه‌های تراش، نیازمند ابزارهای اندازه‌گیری خاصی است. این ابزارها وظیفه اندازه‌گیری پارامترهای گوناگون

دستگاه را که نقش شناسایی علائم حیاتی آن را بازی می‌کنند، بر عهده دارند. اندازه‌گیری‌های انجام شده منجر به تحلیل شرایط دستگاه و اتخاذ تصمیمات برای نت دستگاه می‌شود. برخی از پارامترهایی که در تعیین وضعیت سلامت یک دستگاه تراش نقش

تشخیص خرابی تجهیزات الکتریکی در یک ماشین تراش است. در تجهیزات الکتریکی وقتی اتصالات، خوب سفت نشده باشند، پدیده ای بنام مقاومت اتصال بوجود می‌آید. مقاومت اتصال باعث تلف شدن توان در نقطه ای می‌شود که اتصال خوب سفت نشده است و در نتیجه، دمای آن نقطه بالا می‌رود. با حرارت سنجی نقاط اتصال الکتریکی، می‌توان شل یا سفت بودن آنها را تشخیص داد. اطلاعات موجود در کارخانه مورد مطالعه نشان می‌دهد که به دفعات مکرر ترمینال الکتروموتورها بدلیل عدم آچارکشی بموقع، سوخته و باعث توقف خط تولید شده است.

دارند عبارتند از، (۱) صوت، (۲) آنالیز روغن، (۳) ارتعاش، (۴) دما، و (۵) فشار سیال (به مرجع [۹] مراجعه شود). تجارب کسب شده در رابطه با دستگاه‌های تراش مورد مطالعه، نشان می‌دهد که آنالیز صوت برای این نوع دستگاه کاربرد ندارد. آنالیز روغن نیز فقط در آزمایشگاه قابل انجام است. بنا براین برای طراحی سیستم پیشنهادی در این مقاله، ۳ پارامتر فشار سیال^۵، دما و ارتعاش انتخاب شده است. در ماشین‌های تراش، با اندازه‌گیری فشار سیال، برخی خرابی‌های دستگاه، مانند خرابی اورینگ، پکینگ و خراش داخل سیلندر، قابل تشخیص است. حرارت سنجی (اندازه‌گیری دما)، یکی از مهمترین ابزارهای پایش وضعیت، بخصوص در



شکل ۲. برخی خرابی‌های قابل تشخیص با آنالیز ارتعاشات (ماخذ مرجع [۹])

طیف ارتعاشی ماشین و یافتن هارمونیک‌های اصلی و فرعی آن مقدمه مناسبی برای عیب‌یابی ماشین‌های تراش خواهد بود. اندازه‌گیری ارتعاشات در دو راستای امتداد محور ماشین (راستای

در ماشین‌های تراش هر یک از خرابی‌ها معمولاً اثری در دامنه فرکانس از خود بجا می‌گذارند که روی مولفه اصلی دور نامی ماشین یا هارمونیک‌های آن قابل مشاهده است. بنابراین استخراج

۳. بررسی نشانه‌های خرابی و جمع‌آوری داده‌ها

در این تحقیق، کارخانه ایی با ۳۸۲ دستگاه ماشین تراش مورد بررسی قرار گرفت. ابتدا با استفاده از کاتالوگ دستگاه‌ها، تجربیات ثبت شده واحد نت کارخانه فوق، و همچنین مصاحبه با کاربران مجرب دستگاه‌ها، کلیه خرابی‌های پیش آمده منطبق بر سوابق و خرابی‌های محتمل برای ماشین‌های تراش گردآوری شد. سپس با استفاده از همان مراجع، دلایل احتمالی و در برخی موارد، دلایل قطعی خرابی‌ها، مشخص شدند. بررسی فوق نشان داد که نشانه‌های خرابی در ماشین‌های تراش را می‌توان به دو گروه آنالوگ و دیجیتال دسته بندی کرد. از این رو تصمیم گرفته شد که در مدل پیشنهادی این تحقیق، نشانه‌های دیجیتال توسط بلوک‌های تصمیم‌گیری، و نشانه‌های آنالوگ توسط شبکه‌های عصبی پردازش شوند. نشانه‌های خرابی‌های پیش آمده در طی ۳۰ سال گذشته برای دستگاه‌های تراش مطالعه شده، در جدول ۲ نشان داده شده است. علل همه خرابی‌های پیش آمده نیز در جدول ۳ آورده شده است.

محوری) و راستای عمود بر آن (راستای شعاعی) انجام می‌شود. ارتعاشات مختلف در یک ماشین تراش، توسط سنسورهای شتاب سنج^۷ قابل اندازه‌گیری است. همانگونه که در شکل ۲ مشاهده می‌شود، خرابی‌ها از روی شکل طیف ارتعاشی، قابل تشخیص هستند. اما این اطلاعات برای تشخیص بعضی از خرابی‌ها که آثار نزدیک به یکدیگر دارند، کافی نیست. به همین دلیل، از اطلاعات مربوط به اختلاف فاز و در مواردی از اطلاعات حوزه زمان نیز جهت رده بندی بهتر استفاده می‌گردد. لازم بذکر است که در عرصه واقعی فعالیت‌ها، و در محیط‌های صنعتی، به ندرت حالتی پیش می‌آید که فقط یکی از خرابی‌های فوق در ماشین تراش اتفاق افتد، بلکه معمولاً بروز چند عیب بطور هم زمان و با درجات اهمیت مختلف در دستگاه مشاهده می‌شود. به همین دلیل است که امروزه در کار عیب‌یابی ماشین‌های صنعتی در صنایع سنگین، نیاز به استفاده از روش‌های هوشمند مانند شبکه‌های عصبی مطرح می‌باشد.

جدول ۲. نشانه‌های خرابی دستگاه تراش

ردیف	شرح خرابی	ردیف	شرح خرابی
۱	ارتعاش زیاد موتور اصلی	۹	اختلال در عملکرد رنده رو
۲	افزایش دمای موتور اصلی	۱۰	اختلال در عملکرد رنده زیر
۳	افت فشار هوای فشرده	۱۱	خاموش شدن دستگاه حین کار
۴	افزایش جریان موتور میز	۱۲	کار نکردن ترمز موتور اصلی
۵	افزایش جریان موتور اصلی	۱۳	کار نکردن واحد روغن کاری
۶	ولتاژ خط ورودی	۱۴	حرکت نکردن میز
۷	سه نظام باز و بسته نمی‌شود	۱۵	کار کرد پله ای رنده
۸	دستگاه روشن نمی‌شود		

جدول ۳. علل خرابی دستگاه تراش

ردیف	علت خرابی	نشانه خرابی	ردیف	علت خرابی	نشانه
۱	خرابی شیر پنوماتیک رنده رو	۹	۲۴	خرابی بازوی کپی	۱۰ و ۹
۲	خرابی پدال	۷	۲۵	رله کنترل حرارت موتور اصلی	۱۱ و ۵ و ۲
۳	خرابی پرشر سوئیچ هوای فشرده	۷ و ۹ و ۱۰ و ۱۱	۲۶	گیر کردن میز	۱۴ و ۱۱ و ۴
۴	خرابی تایمر	۷	۲۷	خرابی کلید اصلی	۸
۵	پاره شدن شیلنگ	۳	۲۸	خرابی شیر پنوماتیک ۳	۳
۶	استپ اضطراری فعال است	۸	۲۹	خرابی میکروسوئیچ رنده رو	۹
۷	خرابی سیستم روغن کاری	۱۰ و ۹	۳۰	خرابی جک رنده رو	۹ و ۳
۸	خرابی شیر کنترل فشار رنده رو	۹	۳۱	خرابی غلتک اهرمی رنده رو	۹
۹	خرابی شیر پنوماتیک رنده زیر	۱۰ و ۳	۳۲	خرابی میکروسوئیچ رنده زیر	۱۰

۱۰	خرابی میکروسوئیچ ترمز	۱۲	۳۳	خرابی چک رنده زیر	۱۰ و ۳
۱۱	خرابی شیر کنترل فشار رنده زیر	۱۰	۳۴	خرابی گلنتک اهرمی رنده زیر	۱۰
۱۲	کمبود روغن هیدرولیک	۸ و ۹ و ۱۰	۳۵	خرابی رله پالسر روغن	۱۱
۱۳	بی‌متال موتور اصلی	۲ و ۵ و ۶ و ۱۱	۳۶	رله کنترل جریان موتور میز	۱۴ و ۴
۱۴	خرابی جعبه مقاومت	۱۱	۳۷	هماهنگ نبودن سه نظام و میز	۱۱
۱۵	سوختن فیوز اصلی	۱۱ و ۸ و ۱۱	۳۸	خرابی کنتاکتور ترمز	۱۲
۱۶	تنظیم نبودن کنترل کننده دور	۱۲	۳۹	قطع بودن کابل کنترل	۱۲
۱۷	خرابی میکروسوئیچ ۱	۹	۴۰	خرابی کوپلینگ	۱
۱۸	خرابی بلبیرینگ	۱	۴۱	لق شدن پایه‌های موتور	۱
۱۹	گیربکس روغن کاری نمی‌شود	۱	۴۲	سوختن فیوز روغن کاری	۱۳
۲۰	خرابی اویل پمپ	۱۳	۴۳	کمبود روغن	۱۳
۲۱	خرابی شیر هیدرولیک رنده	۱۵	۴۴	رله حرارت موتور میز	۱۴ و ۴
۲۲	سوختن فیوز موتور میز	۱۴	۴۵	خرابی کلید فرمان	۱۴
۲۳	اعمال بار اضافه به دستگاه	۲ و ۱	۴۶	تنظیم نبودن ولتاژ خط	۱ و ۲ و ۳ و ۴ و ۵ و ۶

۴. ساختار مدل پیشنهادی

ساختار کلی مدل پیشنهادی در شکل ۳ نمایش داده شده است. مدل پیشنهادی در این مقاله، از رویکرد ماژولاریتی^۸ پیروی می‌کند در رویکرد ماژولاریتی، ورودیها و خروجیها را بهتر می‌توان مدیریت نمود و نتایج حاصل از عملکرد هر ماژول قابل ردیابی است [۱۰]. این رویکرد، خود را هم در ماژول دیجیتال و آنالوگ، و هم در شبکه عصبی، نشان می‌دهد. همانگونه که در شکل ۳ مشاهده می‌شود، مدل پیشنهادی در این مقاله، از ۲ بخش آنالوگ و دیجیتال تشکیل شده است. در بخش سیگنال‌های آنالوگ، ورودی‌های ۱ تا ۳ که شامل ارتعاش موتور اصلی و دمای موتور اصلی و فشار هوای فشرده هستند، دائماً از طریق نمونه برداری نظارت می‌شوند. نمونه‌ها در فواصل زمانی قابل تنظیم، برداشته شده و به شبکه‌های عصبی اعمال می‌شوند. برای ورود اطلاعات به شبکه از پنجره متحرک استفاده شده است که اندازه آن ۳۰ تایی در نظر گرفته شده است. عدد ۳۰، عددی تجربی است که با سعی و خطا به دست می‌آید [۱۰].

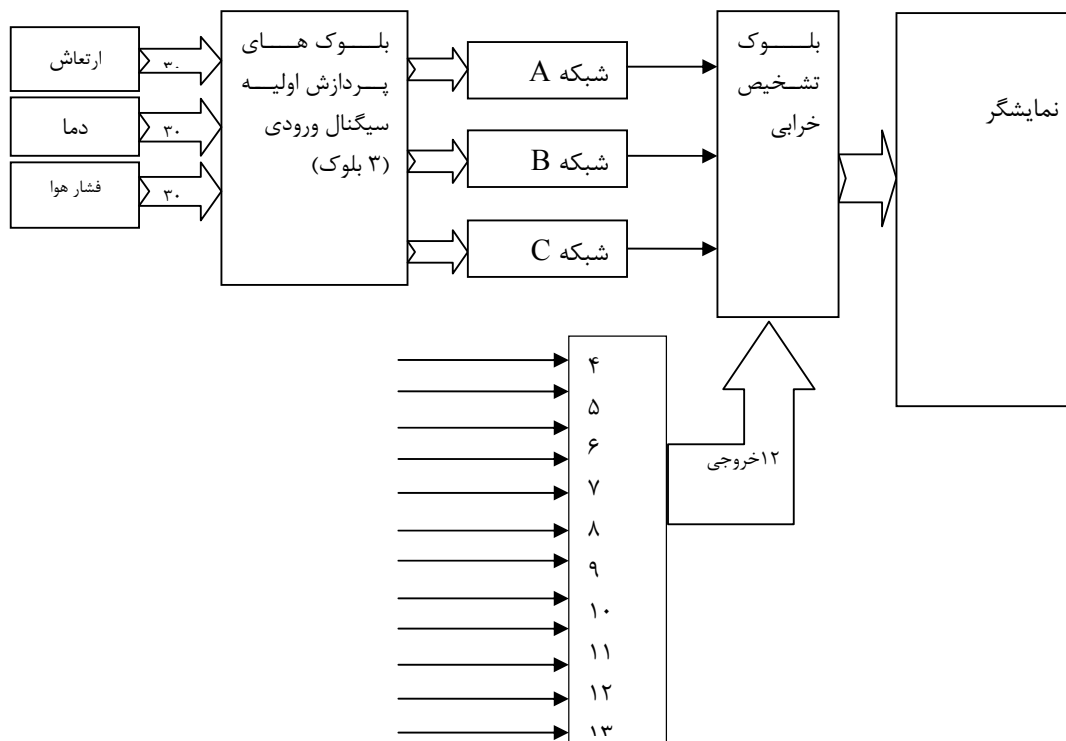
در ماژول آنالوگ، یکی از نکات مهم، وجود سیگنال‌های ضعیف حاصل از نشانه‌های خرابی در ماشین‌های تراش است. بعبارت دیگر، سیگنال خروجی سنسورها در شناسایی نشانه‌های خرابی دامنه ضعیفی دارند. این نوع سیگنال‌ها معمولاً دارای مقداری نویز هستند، که استفاده از آنها را دچار مشکل می‌کند. برای غلبه بر این مشکل یعنی کاهش اثر نویز، همانطور که در شکل ۴ نشان داده شده است، در مدل پیشنهادی، بلافاصله بعد از سنسور از پیش تقویت کننده استفاده می‌شود تا دامنه سیگنال نسبت به دامنه نویز بزرگتر شود. در مدل پیشنهادی، سیگنال خروجی سنسور پس از تقویت اولیه دامنه، از یک فیلتر عبور داده می‌شود. فیلتر فوق

طوری انتخاب می‌شود که فقط فرکانس‌های خاصی را عبور دهد، و بدین ترتیب عمده سیگنال‌های نویز در این مرحله حذف می‌شوند. پس از این مرحله است که اطلاعات مورد نظر، توسط آشکار ساز از سیگنال استخراج می‌شود. در مراحل بعد می‌توان از تقویت کننده نهایی و مبدل آنالوگ به دیجیتال برای پردازش سیگنال و سرانجام نمایش مقدار کمیت اندازه گیری شده استفاده کرد. در سیستم‌های پردازش سیگنال دیجیتال، میزان دقت و صحت مراحل اندازه گیری و پیش پردازش، مستقیماً در نتیجه پردازش هوشمند تاثیر می‌گذارد.


سیگنال خروجی بلوک‌های پردازش اولیه پس از طی مرحله ایی که در بالا توضیح داده شد، به شبکه‌های عصبی وارد می‌شود. شبکه‌های A، B و C در شکل شماره ۳، بترتیب مربوط به تجزیه و تحلیل پارامترهای ارتعاش، دما و فشار هوای فشرده می‌باشند. این شبکه‌ها، وظیفه نظارت و پردازش نهایی داده‌ها و تشخیص خرابی ماشین تراش را بر عهده دارند. خروجی سه شبکه عصبی فوق به بلوک تشخیص خرابی یا بلوک تصمیم‌گیری، ارسال می‌شود. از طرف دیگر در بخش سیگنال‌های دیجیتال، بافری^۹ برای سیگنال‌های ورودی قرار داده شده است که فقط سیگنال‌ها را به طبقه تشخیص خرابی ارسال می‌کند. در این بخش، ورودی‌های ۴، ۵ و ۶ توسط قطعات کنترلی دستگاه، و ورودی‌های ۷ تا ۱۲ توسط اپراتور اعلام می‌شود. خروجی طبقه بافر سیگنال‌های دیجیتال نیز، به طبقه تشخیص خرابی ارسال می‌شود. در طبقه تشخیص خرابی با توجه به منطق تعریف شده برای خرابی یا سلامت دستگاه، تصمیم‌گیری و پیام مناسبی بر اساس تشخیص بلوک‌های تصمیم‌گیری به طبقه نمایشگر ارسال می‌شود. در این تحقیق وضعیت خرابی با "۰" منطقی مشخص می‌شود. بدیهی است در صورتی که

را تشخیص دهند. این شبکه‌ها در خروجی خود یک بیت تولید می‌کنند که مبین خرابی یا سلامت ماشین است.

خروجی شبکه‌های عصبی یا بلوک بافر "۱" باشد خرابی در دستگاه وجود ندارد. شبکه‌های عصبی استفاده شده در این مقاله، با توجه به آموزشی که دیده اند می‌توانند گرایش دستگاه به سمت خرابی



بلوک بافر سیگنال های دیجیتال ورودی
شکل ۳. بلوک دیاگرام سیستم پیش بینی خطا



شکل ۴. زنجیره مراحل اندازه گیری کمیت‌ها

تعداد، مساوی اندازه پنجره متحرک شبکه است. اگر چه ادبیات موضوع نشان می‌دهد که تعداد بهینه نرون‌های لایه پنهان را می‌توان با سعی و خطا پیدا کرد [۱۰]، اما با استفاده از فرمول شماره ۳ و ۲ نیز می‌توان بترتیب تعداد اولیه و نهایی نرون‌ها را برای لایه پنهان حساب کرد [۶].

$$Z = 2 * (r + q) / 3 \quad (2)$$

بطوری که r تعداد نرون لایه ورودی، و q تعداد لایه خروجی است.

۵. طراحی و آموزش شبکه

اگر چه انواع مختلفی از شبکه‌های عصبی و توابع آنها وجود دارند، اما ادبیات موضوع، به‌مراه آزمایش‌های انجام شده، بخش شبکه عصبی این تحقیق را به سمت شبکه‌های پرسپترون چند لایه (MLP) سوق داد. شکل شماره ۵ بخش شبکه عصبی مدل پیشنهادی این مقاله را بصورت شماتیک نشان می‌دهد. جدول ۴ نیز مشخصات شبکه‌های عصبی طراحی شده در مدل ترکیبی پیشنهادی در این مقاله را نشان می‌دهد. همانطور که در جدول ۴ مشاهده می‌شود، تعداد نرون لایه ورودی ۳۰ می‌باشد که این

در این مقاله برای بدست آوردن تعداد نرون لایه پنهان از فرمول‌های فوق استفاده شده است. محاسبات زیر تعداد نرون بدست آمده برای لایه پنهان در مدل این مقاله را نشان می‌دهد.

$$Z = 2 * (r + q) / 3 = 2 * (30 + 1) / 3 \approx 21$$

$$Z_l = 2 \Rightarrow Z_{st} = 21 + 2 = 23 \quad (4)$$


$$Z_l = \begin{cases} 5 & \text{if } 2 \leq Z \leq 6 \\ 4 & \text{if } 7 \leq Z \leq 10 \\ 3 & \text{if } 11 \leq Z \leq 13 \\ 2 & \text{if } 14 \leq Z \end{cases}$$

مقدار ثابت (۳)

$$Z_{st} = Z + Z_l$$

جدول ۴. مشخصات شبکه‌ها

نام شبکه	تعداد نرون لایه ورودی	تعداد لایه پنهان	تعداد نرون لایه خروجی	تابع انتقال لایه پنهان	تابع انتقال لایه خروجی	الگوریتم آموزشی	روش تعمیم
شبکه A	۳۰	۱	۲۳	Tan-sig	purelin	لونیبرگ - مارکوارت	توقف سریع
شبکه B	۳۰	۱	۲۳	Tan-sig	purelin	لونیبرگ - مارکوارت	توقف سریع
شبکه C	۳۰	۱	۲۳	Tan-sig	purelin	لونیبرگ - مارکوارت	توقف سریع




شکل ۵. ساختار شبکه‌های A, B, C

تابع میزان لقی بیرینگ بکار رفته در آن است. همانطور که در شکل ۶ نشان داده شده است، این دامنه، بین ۰ تا ۶۳ میکرومتر است. شکل ۶ محدوده مجاز ارتعاشات را در بلبرینگ یک الکتروموتور نشان می‌دهد.

$$D = D_m * \sin(2\pi f t) \quad (5)$$

در فرمول ۴، D دامنه ارتعاشات، Dm حداکثر دامنه ارتعاشات، و f فرکانس برق شهر است.

در این مدل پیشنهادی، شبکه A وظیفه نظارت بر ارتعاشات بیرینگ‌ها را بر عهده دارد. از این رو لازم است که برای آموزش شبکه، شکل داده‌های فوق بخوبی شناخته شود. تنها منبع ارتعاشات برای تشخیص خرابی در دستگاه‌های تراش مطالعه شده، برای شبکه عصبی مورد نظر، الکتروموتورها هستند. ارتعاشات در الکتروموتورها تابع جریان الکتریکی اعمال شده به آنهاست. جریان الکتریکی اعمالی، دارای تابع سینوسی با فرکانس ۵۰ هرتز است. بنابراین ارتعاشات ناشی از آن نیز دارای شکل سینوسی و فرکانس ۵۰ هرتز است. بر اساس فرمول ۵ دامنه ارتعاشات در الکتروموتورها



شکل ۶. نمودار رابطه سرعت و لقی [۱۵]

الکتریکی است. وقتی دمای یک الکتروموتور از حد مجازی که سازنده برای آن تعریف کرده است، فراتر رود، می‌تواند مبین وقوع

در این مدل، شبکه B کار نظارت بر مقدار دمای الکتروموتور اصلی را بر عهده دارد. دما یکی از پارامترهای بسیار مهم در موتورهای

جدول ۵. محدوده‌ی داده‌ها بر اساس کاتالوگ سازندگان

شبکه	وظیفه	محدوده‌ی داده‌های سالم
A	سنجش ارتعاشات موتور اصلی	$m \mu [0,63]$
B	سنجش دما موتور اصلی	$[5,50] ^\circ c$
C	سنجش فشار هوا فشرده	$[4.5,8.5] \text{ bar}$

جدول ۶. محدوده سالم پارامترهای شبکه‌ها

شبکه	مقیاس	پارامتر	شکل
A (ارتعاش)	$1 < a \leq 32$		$b \geq 4$
B (دما)	$1 < a \leq 30$		$b \geq 4$
C (فشار)	$1 < a \leq 6/5$		$b \geq 15$

جدول ۷. نتایج آستانه شبکه‌ها

شبکه	حد آستانه	متوسط طول دنباله
A	۰/۳۷۵۳	۲۰۱
B	۰/۵۲۷۷	۲۰۰
C	۰/۶۹۵۱	۲۰۰

۶. ارزیابی مدل پیشنهادی

برای ارزیابی شبکه‌های عصبی، از داده‌های شبیه‌سازی شده استفاده شده است. در ضمن از رویکرد پنجره متحرک که اندازه آن مساوی اندازه پنجره ورودی است (به مرجع شماره [۱۰] مراجعه شود) استفاده شده است. برای اطمینان از نتایج حاصل از عملکرد شبکه‌های طراحی شده، هر یک از تغییرات با استفاده از داده‌های شبیه‌سازی شده ۱۰۰۰۰ بار تکرار شده است. مقدار MSE شبکه‌ها که معیار ارزیابی آنها می‌باشد، برای هر یک از آنها محاسبه و در جدول ۸ آمده است.

جدول ۸. نتایج ارزیابی شبکه‌ها

شبکه	MSE متوسط
A	۰/۰۴۱۷
B	۰/۰۱۵۴
C	۰/۰۰۲۱

برای ارزیابی شبکه عصبی مدل پیشنهادی تغییرات به سه شکل به شبکه اعمال گردید، (۱) تغییر در پارامتر مقیاس، (۲) تغییر در پارامتر شکل، و (۳) تغییر هم‌زمان در هر دو پارامتر مقیاس و شکل. نتایج ارزیابی عملکرد شبکه‌ها در جدول ۹ نشان داده شده است. همانطور که در جدول ۹ مشاهده می‌شود، شبکه پیشنهادی

خرابی در الکتروموتور باشد. حداکثر دمای مجاز الکتروموتور ۵۰ درجه سانتیگراد است. در گستره دمایی الکتروموتورها، افزایش یا کاهش ناگهانی دما وجود ندارد و دما با آهنگ خاصی کاهش یا افزایش می‌یابد.

شبکه C وظیفه نظارت بر فشار هوای فشرده را بر عهده دارد. برخی سیستم‌های موجود در دستگاه‌های تراش مثل سه نظام از هوای فشرده استفاده می‌کنند. کاهش یا افزایش بیش از حد فشار هوا باعث بروز مشکلاتی در عملکرد دستگاه می‌شود. تجربیات ثبت شده در کارخانه مورد مطالعه نشان داده است که افزایش فشار در سیستم پنوماتیک دستگاه به ندرت اتفاق می‌افتد، اما کاهش فشار مشکلی است که به دلایل مختلف مثل پارگی شیلنگ و خرابی شیرهای پنوماتیکی رخ می‌دهد. بنابراین با پایش مقدار فشار هوای فشرده می‌توان وقوع خرابی در سیستم پنوماتیک دستگاه‌ها را رصد کرد.

لازم به ذکر است که از آنجاییکه تابع نمایی دارای خاصیت بی‌حافظگی است، لذا وقوع خرابی در دستگاه‌ها بطور معمول از تابع توزیع وایبل پیروی می‌کند. این تابع دارای ۲ پارامتر مقیاس و شکل است. تغییرات یک یا هر دو پارامتر در توزیع آن می‌تواند بیانگر شروع یک خرابی باشد [۱۶].

$$f(t) = \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1} e^{-\left(\frac{t}{\eta}\right)^\beta} \quad (۶)$$

که در آن η پارامتر مقیاس و β پارامتر شکل است. هرچه β بزرگتر باشد نرخ خرابی درآینده بیشتر می‌شود.

در این مدل برای آموزش شبکه‌های عصبی از رویکرد با ناظر استفاده شده است. محدوده داده‌های آموزشی براساس مرجع شماره [۱۷]، مطابق جدول ۵ می‌باشد. با توجه به محدوده مشخص شده برای پارامترهای کنترلی ماشین‌های تراش طبق مرجع شماره [۱۷]، محدوده پارامترهای توزیع وایبل طبق جدول شماره ۶ برای هر یک از شبکه‌ها، به منظور تولید داده‌های آموزشی آن شبکه تعیین شدند

فرآیند آموزش نشان داد که شبکه فوق بخوبی در مقابل تغییرات پارامترهای مقیاس و شکل توزیع وایبل حساس می‌باشد. حد آستانه بدست آمده برای شبکه‌های A، B و C در جدول ۷ نشان داده شده است. برای آشنایی با چگونگی بدست آوردن حدآستانه می‌توانید به مرجع آتشگر و نورالسنا [۱۰] مراجعه نمایید. لازم بذکر است برای بدست آوردن حد آستانه، میزان خطا برابر ۰/۰۰۵ ($\alpha = 0.005$) در نظر گرفته شده است جدول شماره ۷ مقدار متوسط طول دنباله را نیز برای هر یک از شبکه‌ها نشان می‌دهد.

مقیاس در بازه [۵.۱/۵] تغییر داده شد. در جدول ۹ پاسخ شبکه‌ها به تغییرات مجزا و توأم پارامترهای توزیع آمده است.

عملکرد مناسبی را ارائه کرده است. در جدول ۹، سطر Both برای زمانی است که هر دو پارامتر تغییر کرده اند. بعنوان مثال، در این ارزیابی برای شبکه A، پارامتر شکل در بازه [۳۰،۳۹] و پارامتر

جدول ۹. پاسخ شبکه‌ها به تغییرات پارامترهای توزیع خرابی

شبکه C			شبکه B			شبکه A			
پارامترهای توزیع وایبل			پارامترهای توزیع وایبل			پارامترهای توزیع وایبل			
شکل	مقیاس	خروجی شبکه	شکل	مقیاس	خروجی شبکه	شکل	مقیاس	خروجی شبکه	
۱۵	۵.۸	0	۴	۳۲	۱	۴	۳۵	۱	پارامتر شکل ثابت
۱۵	۵.۹	0	۴	۳۳	۱	۴	۳۶	۱	فرض شده است
۱۵	6	0	۴	۳۵	۰	۴	۳۷	۰	
۱۵	۶.۱	1	۴	۳۵	۰	۴	۳۸	۰	
۱۵	۶.۲	1	۴	۳۶	۰	۴	۳۹	۰	
۴/۴ e-۱۴			۰/۰۱۸۴			۰/۰۲۳۳			mse scale
۱۳	۶.۵	0	۳.۷	۲۵	۰	۳.۷	۳۰	۰	پارامتر مقیاس ثابت
۱۴	۶.۵	0	۳.۸	۲۵	۰	۳.۸	۳۰	۰	فرض شده است
۱۵	۶.۵	0	۳.۹	۲۵	۱	۳.۹	۳۰	۰	
۱۶	۶.۵	1	۴	۲۵	۱	۴	۳۰	۱	
۱7	6.5	1	۴.۱	۲۵	۱	۴.۱	۳۰	۱	
۷/۷ e-۱۱			۰/۰۶۶۴			۰/۰۳۴۹			mse shape
۴/۴ e-۱۲			۰/۰۱۷۱			۰/۰۱۹۰			Both

نشان می‌دهد که به ازای $(a,b) = (۳۴,۱)$ مقدار خطای شبکه برابر با $۰/۰۰۴۶۴۷$ است. با توجه به نتایج موجود در جدول شماره ۱۰ متوسط نرخ خطای شبکه A برابر $۰/۰۰۵۳۳۹$ بدست می‌آید. لازم بذکر است که متوسط نرخ خطا برای شبکه‌های B و C بترتیب برابر $۰/۰۰۵۳$ و $۰/۰۰۱۰۲۳۴$ می‌باشد.

گزارش مفصل تر تغییرات تشریح شده برای جدول شماره ۹، در جداول شماره ۱۰ تا ۱۲ نشان داده شده است. بعنوان نمونه، جدول شماره ۱۰ نرخ خطای شبکه A، FR (Failour Rate) را نسبت به تغییرات پارامترهای شکل b و مقیاس a در توزیع وایبل آزمایشی با ۳۰۰۰۰ داده و با تکرار ۱۰۰۰۰ بار نشان می‌دهد. این جدول مثلاً

جدول ۱۰. نرخ خطای شبکه A به ازای تغییر پارامترهای توزیع (ماتریس FR)

b/a	۳۰	۳۱	۳۲	۳۳	۳۴	۳۵	۳۶	۳۷	۳۸	۳۹
۱	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷	۰/۰۰۴۶۱۷
۱/۵	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱
۲	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱	۰/۰۰۴۶۹۱
۲/۵	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶	۰/۰۰۵۱۳۶
۳	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹	۰/۰۰۵۴۱۹
۳/۵	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷	۰/۰۰۵۵۳۷
۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴	۰/۰۰۵۵۹۴
۴/۵	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱	۰/۰۰۵۷۰۱
۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵	۰/۰۰۵۹۲۵
۵/۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵	۰/۰۰۵۹۷۵

جدول ۱۱. نرخ خطای شبکه B به ازای تغییر پارامترهای توزیع (ماتریس FR)

b/a	۳	۳/۵	۴	۴/۵	۵	۵/۵	۶	۶/۵	۷	۷/۵
۲۵	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸	۰/۰۱۲۷۴۸
۲۶	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰	۰/۰۰۶۰۲۰
۲۷	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸	۰/۰۰۸۱۰۸
۲۸	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹	۰/۰۰۵۵۵۹
۲۹	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸	۰/۰۰۵۰۴۸
۳۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰	۰/۰۰۲۹۰۰
۳۱	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰	۰/۰۰۲۸۲۰
۳۲	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵	۰/۰۰۴۲۱۵
۳۳	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲	۰/۰۰۲۸۳۲
۳۴	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹	۰/۰۰۲۷۴۹

جدول ۱۲. نرخ خطای شبکه C به ازای تغییر پارامترهای توزیع (ماتریس FR)

b/a	۱۳	۱۳/۵	۱۴	۱۴/۵	۱۵	۱۵/۵	۱۶	۱۶/۵	۱۷
۴
۴/۵
۵
۵/۵
۶	۰/۰۰۱	.	۰/۰۰۳	۰/۰۰۲	۰/۰۰۲	۰/۰۰۲	۰/۰۰۳	۰/۰۰۲	۰/۰۰۴
۶/۵	۰/۰۰۸	۰/۰۰۵	۰/۰۰۶	۰/۰۰۵	۰/۰۰۴	۰/۰۰۲	۰/۰۰۳	۰/۰۰۳	۰/۰۰۵
۷	۰/۰۰۲	۰/۰۰۲	۰/۰۰۱	۰/۰۰۳	۰/۰۰۱	.	۰/۰۰۲	.	۰/۰۰۲
۷/۵	.	.	۰/۰۰۳	۰/۰۰۱	.	.	.	۰/۰۰۱	.
۸	.	۰/۰۰۱	.	۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	.	.	.

گزارش نشان می‌دهد که بلوک تشخیص خرابی به درستی توانسته است خرابی را تشخیص داده و پیام‌هایی مرتبط با آن، برای اپراتور چاپ کند.

لازم به توضیح است که برای انجام این تحقیق، در کلیه مراحل برنامه نویسی و شبیه‌سازی از نرم‌افزار متلب استفاده شده است.

برای آزمایش کلی سیستم ترکیبی پیشنهاد شده در این مقاله، حالات ممکن خرابی، تولید و به بلوک تشخیص خرابی اعمال شدند. یک نمونه از گزارشات بدست آمده در شکل ۷ نشان داده شده است. در گزارش شکل شماره ۷، مؤلفه‌های بردار موجود در ستون‌های شماره ۱۴ و ۱۵، صفر و بقیه مؤلفه‌ها یک هستند. این

```

Variables - p
p <1x15 double>
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20
1 1 1 1 1 1 1 1 1 1 1 1 1 1 0 0
2

Command Window
New to MATLAB? Watch this video, see Examples, or read Getting Started.
>> detection1
Every thing is ok
>> detection1
Carriage dose not work
check :,Thermal relay ,Fuse ,Displacement switch,Carriage jam
>> detection1
Carriage dose not work
check :,Thermal relay ,Fuse ,Displacement switch,Carriage jam
Blade malfunction
check :Blade Hyd. valve
fx >>

```

شکل ۷. نمونه گزارش سیستم ترکیبی

[4] Bansal D, Evans DJ, Jones B. A real-time predictive maintenance system for machine system, *International Journal of Machine Tools & Manufacture*, 2004, Vol. 44, pp. 759-766.

[۵] صنیعی منفرد، محمدعلی؛ افتخار اردبیلی، زهرا. اتوماسیون سیستم‌های نگهداری و تعمیرات خودرو به کمک شبکه‌های عصبی، دومین کنفرانس ملی برنامه‌ریزی نگهداری و تعمیرات، ایران، تهران، ۱۳۸۳.

[6] Ngaopitakkul A, et al. Internal fault classification in transformer windings combination of discrete transforms and back-propagation neural networks, *International Journal of Control, Automation, and Systems*, 2006, No. 3, Vol. 4, pp. 365-371.

[7] Atashgar K, Noorossana R. A comprehensive scheme to monitor simulataneously all required knowledge for an effective root cause analysis, 2nd International Conference on Industrial Engineering and Operations Management (IEOM), Kuala Lumpur, Malaysia, Jan 22-24, 2011, pp. 911-918.

[8] Dzung PQ, Phoung LM. ANN-Control System DC Motor, Faculty of Electrical & Electronic Engineering, HCMC University of Technology, Ho Chi Minh City, Vietnam, 2005.

[۹] قوی پنجه، محمد. پیش‌بینی خرابی ماشین آلات دوار با استفاده از سیستم‌های هوشمند، پایان نامه کارشناسی ارشد، دانشگاه تربیت مدرس، ۱۳۸۳.

[۱۰] آتشگر، کریم؛ نورالسنا، رسول. شناسایی نقطه تغییر در بردار میانگین فرآیند نرمال دو متغیره با تغییرات مونوتونیک، نشریه بین‌المللی مهندسی صنایع و مدیریت تولید، بهار ۱۳۸۹، شماره ۱، جلد ۲۹، صص. ۱-۱۳.

[11] Atashgar K, Noorossana R. An integration approach to root cause analysis of a bivariat mean vector with a linear trend disturbance, *International Journal of Advanced Manufacturing Technology*, 2011, Vol. 52, pp. 407-420.

[12] Al-Araimi SA, Al-Balushi KR, Samanta B. Bearing fault detection using artificial neural networks and genetic algorithm, *Eurasip Journal on Applied Signal Processing*, 2004, Vol. 3, pp. 366-377.

[13] Mahamad AK, Saon S, Abd Vahab MH, Yaha MN, Ghazali MI. Using artificial neural network to monitor and predict induction motor bearing (IMB) failure", *International Journal of*

۷. نتیجه‌گیری

از قابلیت شبکه‌های عصبی مصنوعی می‌توان برای تشخیص و پیش‌بینی خرابی‌های دستگاه‌ها و ماشین‌آلات صنعتی بشکل موثر و کارآ استفاده کرد. در این مقاله، یک مدل ترکیبی ارائه گردید که از دو بخش دیجیتال و آنالوگ تشکیل شده است. مدل ترکیبی پیشنهادی فوق که در هسته خود یک شبکه عصبی مصنوعی را شامل می‌شود، توانست با قابلیت بالایی خرابی‌های محتمل در ماشین‌های تراش را پیش‌بینی و عامل خرابی احتمالی را تشخیص دهد. هرچند این مدل که برای یک کارخانه بزرگ که دارای بیش از ۳۸۰ ماشین تراش است، طراحی و با رویکرد با ناظر آموزش داده شده است، ولی بدلیل متابعت ماشین‌های تراش از قوانین مشابه در خرابی و عیب‌یابی، مدل پیشنهادی این مقاله می‌تواند در تمامی کارگاه‌ها و کارخانجاتی که از ماشین‌های تراش استفاده می‌کنند، برای پیش‌بینی خرابی و تشخیص عامل خرابی بصورت اثربخشی بکارگرفته شود. گزارش عملکرد و ارزیابی مدل پیشنهادی ثابت کرد که مدل ترکیبی معرفی شده از کفایت لازم برای عیب‌یابی برخوردار است.

پی‌نوشت

1. Weibull
2. Wavelet
3. Feed forward
4. Online
5. Fluid pressur
6. Contact Resistance
7. Accelerometer
8. Modularity
9. Buffer

مراجع

- [۱] شکوهی، امیرحسین؛ شهریار، حمید. رویکرد بهینه‌سازی استوار در تخصیص منابع در سیستم نگهداری و تعمیرات، نشریه بین‌المللی مهندسی صنایع و مدیریت تولید، بهار ۱۳۸۹، شماره ۱، جلد ۲۱، صص. ۲۵-۳۳.
- [۲] شهنقی، کامران؛ آریانزاد، میربهادرقلی؛ برزگر، علی. کاربرد رویکرد بازرسی بر مبنای ریسک در انتخاب سیاست‌های نگهداری و تعمیرات (نت)، نشریه بین‌المللی مهندسی صنایع و مدیریت تولید، تابستان ۱۳۹۰، شماره ۲، جلد ۲۲، صص. ۲۰۴-۱۹۴.
- [۳] میرمحمد صادقی، سیدجواد؛ عاشوری، حجتف؛ امیری دلویی، الهه. توسعه الگوریتم الویت‌بندی و برنامه ریزی برای نگهداری و تعمیرات خطوط راه آهن ایران، نشریه بین‌المللی مهندسی صنایع و مدیریت تولید، آذر ۱۳۹۱، شماره ۳، جلد ۲۳، صص. ۳۷۶-۳۸۸.

- Limited, London and Bury St Edmunds, UK, 2002.
- [۱۶] موننگومری، داگلاس سی؛ رانگر، جرج. مترجم: آتشگر، کریم. آمار و احتمال کاربردی مهندسی، جلد اول، ۱۳۹۱.
- [17]Bohringer AG. Catalogue, User Manuall for VDF 250, 1991, pp. 1-3.
- Engineering Convention, Jaddeh, Saudi Arabia, 2007, pp. 35-41.
- [14]Allam DF, Alsayed MH, Gilany M, Elnagar A. A new Succesive ANN for fault classification and estimation of combined fault resistance and loading conditions, IEEE, Power Tech, July 2007, p. 663.
- [15]Mathews C. Engineer's Guid to Rotating Equipments, Professional Engineering Publishing