

مدل سازی ترکیبی منطق فازی و شبکه عصبی مصنوعی برای پیش بینی خرابی ماشین آلات به منظور افزایش بهره‌وری

پرویز چوپان کاری

کارشناسی ارشد مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران Parviz_choopankari@yahoo.com

امیر عزیزی

(نویسنده مسئول) - استادیار، دکترای مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران azizi@srbiau.ac.ir

محمد جواد ارشادی

دانشیار پژوهشی، دکتری تخصصی مهندسی صنایع، پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک)، تهران، ایران. mjershadi@gmail.com

چکیده: در این پژوهش، یک رویکرد ترکیبی بر پایه منطق فازی و شبکه عصبی مصنوعی برای پیش بینی خرابی ماشین آلات در راستای افزایش بهره‌وری ارائه می‌شود. مورد مطالعه این پژوهش یکی از کارخانجات صنعت خودروسازی با نام دیاکو ایده آریا بوده که در حوزه تولید قطعات خودرو فعالیت می‌کند. تعمیر و نگهداری پیشگیرانه نیازمند پیش‌بینی درست خرابی‌ها و حوادث، تجهیزات و ماشین‌آلات می‌باشد تا بتوان با تعمیر و نگهداری به موقع و صحیح ماشین‌آلات و همچنین رفع نقایص و خرابی‌ها بهره‌وری را افزایش داد. برای مدل سازی شبکه فازی-عصبی پرسپترون چند لایه (MLP)، نخست تعداد ۱۰۰ خرابی و توقف در بازه زمانی ۱۵ ماه جمع‌آوری شده و سپس در نرم افزار MATLAB وارد شده است. نتایج بدست آمده نشان می‌دهد پیاده‌سازی شبکه فازی-عصبی و پیش‌بینی زمان خرابی ماشین‌آلات سبب کاهش مدت زمان و هزینه تعمیرات شده است. بنابراین مدت زمان کاری و دسترس پذیری ماشین‌آلات افزایش یافته و در نهایت سبب افزایش میزان بهره‌وری به میزان ۵۷ درصد می‌شود، همچنین، میزان دقت مدل فازی-عصبی توسعه داده شده ۹۴ درصد برآورد شده است.

کلمات کلیدی: بهره‌وری، پیش‌بینی، شبکه عصبی، منطق فازی.

۱-مقدمه

در سال‌های اخیر، منطق فازی و شبکه‌های عصبی به طور موفق در کارهای تشخیص الگو و حل مسائل تشخیص خرابی مورد استفاده قرار گرفته‌اند. شبکه عصبی چندلایه و سامانه استنتاج تطبیقی فازی-عصبی به دلیل کاهش احتمال خطای انسانی در تصمیم‌گیری‌های حساس، تخمین قدرتمند توابع غیر خطی در شرایط وجود عدم قطعیت، قابلیت یادگیری تطبیقی و نیز استفاده از دانش خبره در به دست آوردن رابطه بین ورودی و خروجی، در تشخیص عیوب ماشین‌آلات صنعتی در حال گسترش هستند. ناپ و همکاران [۱] کاربرد یک شبکه چندلایه پیشخور بر مبنای روش تشخیص وضعیت ماشین را مطالعه کرده، روابط فازی

مشخصی بین نشانه‌های شکست و دلایل آن‌ها با روابط غیر خطی زیاد بین ورودی‌ها و خروجی‌های شبکه ارائه داده‌اند. وانگ و همکاران [۲] نیز کاربرد شبکه‌ی عصبی پس انتشار خطا را در تشخیص خرابی ماشین CNC با استفاده از داده‌های نوسانی بررسی کرده‌اند. تحقیقی توسط لی و همکاران [۳] در زمینه عیب یابی ماشین‌های دوار به کمک شبکه عصبی انجام شد. در این مقاله چهار عیب نابالانسی، ناهم راستایی، خرابی بیرینگ و شلاق‌زدن زدن روغن را بر روی دستگاه آزمایش به طور جداگانه ایجاد شده است. شبکه عصبی مورد استفاده در این تحقیق از نوع سه لایه بود. تعداد نرون در لایه‌های ورودی، میانی و خروجی به ترتیب برابر با ۲۰، ۳۰ و ۴۰ بود. عمل عیب یابی با سه روش، ضرایب مختلف تکرار شده و مشخص شد که روش ضرایب مختلف

Corresponding author: azizi@srbiau.ac.ir

تاریخ دریافت: ۱۴۰۱/۰۴/۱۷ تاریخ پذیرش: ۱۴۰۱/۰۸/۱۵

دوره ۱۲/ شماره ۱

صفحات ۶۹-۸۶

جلد ۱۲- شماره ۱- بهار ۱۴۰۱

نشریه مهندسی و مدیریت کیفیت

سایش ابزار در عملیات تراشکاری برای حداکثر استفاده از ابزار برش با استفاده از شبکه عصبی-فازی تطبیقی و توسعه یک مدل برای پیش‌بینی سایش ابزار و کنترل سایش ابزار جهت استفاده حداکثری از ابزار پرداخته‌اند و رویکرد عصبی-فازی تطبیقی (ANFIS) در جهت بررسی این مورد پیاده‌سازی شده است. نتیجه‌گیری بدست آمده بر اساس نتایج تجربی مطالعه مدل سازی ANFIS تکنیکی ماهرانه برای پیش‌بینی با خطای کم و دقت بالا از به ترتیب ۶/۹۱ و ۹۴/۸ درصد سایش ابزار است. عبدالکریم و همکاران [۱۰] به تشخیص و طبقه‌بندی عیوب یاتاقان در موتورهای دنده‌ای صنعتی با استفاده از ویژگی‌های زمانی و سیستم استنتاج عصبی-فازی پرداخته‌اند. هدف تشخیص خودکار نقص بلبرینگ در موتور دنده‌ای صنعتی بر اساس آمار شاخص‌ها و سیستم استنتاج عصبی فازی (ANFIS) است. نتایج تجربی به دست آمده در حالت‌های مختلف سالم و در صورت وجود خرابی به وضوح نشان می‌دهد که رویکرد ANFIS برای شناسایی و طبقه‌بندی عملکرد در کاربردهای واقعی صنعتی قابل اعتماد است. دقت طبقه‌بندی کل روش پیشنهادی برای همه داده‌های آموزش و آزمایش ۹۷.۳۸٪ است. فوتانو و همکاران [۱۱] نوع جدیدی از روش تشخیص آسیب سریع سازه بر اساس داده‌های ارتعاش دینامیکی ساختاری ارائه کرده‌اند که می‌تواند برای ارزیابی سریع عیب ساختاری برای نظارت کوتاه مدت مورد استفاده قرار گیرد. با استفاده از استنباط عصبی-فازی سازگار می‌توان آسیب ساختاری را به سرعت پس از وقوع شناسایی کنیم. نتایج شبیه‌سازی نشان می‌دهد که اثر روش یکپارچه ANFIS و تکنیک مدل سازی فاصله در آسیب سریع تشخیص برای نظارت کوتاه‌مدت کاملاً قابل قبول است. ارشادی و همکاران [۱۲] رویکرد ترکیبی از سطح آمادگی فناوری، داده‌ها تحلیل پوششی و ANFIS را ارائه کرده‌اند. نتایج حاکی از یک تقریب مناسب برای مقادیر مشاهده شده توسط مدل ANFIS است. همچنین، نتایج نشان داد که TRL به‌عنوان یک توانمندساز مهم پروژه GLS نقش معناداری در عملکرد پروژه‌های GLS دارد. نوری کمری و همکاران [۱۳] به تشخیص عیوب ماشین‌آلات دوار با کمک ANFIS پرداخته و به این نتیجه رسیده‌اند که یکی از مهم‌ترین نکات بسیار اساسی و مهم در صنایع مختلف به خصوص صنایع سنگین را می‌توان، نیاز به داشتن یک سیستم عیب‌یاب به صورت اتوماتیک و هوشمند دانست. از آن‌جا که سیستم عصبی - فازی ارائه شده در این تحقیق نتایج قابل قبول را ارائه می‌دهد می‌تواند به‌عنوان روشی مناسب در جهت تشخیص هوشمند عیوب به کار گرفته شود. شبکه فازی-عصبی ارائه شده دارای ۹۰ درصد موفقیت در

www.pqprc.ir

از دو نوع دیگر بهتر است. تحقیقی توسط بکرافت و لی [۴] به نام (یک شیوه جدید برای عیب‌یابی) انجام شده است. در این تحقیق برای عیب‌یابی ماشین‌های دوار بلبرینگ های نوع شیار عمیق، بر مبنای تحلیل آماری و روش بهبود یافته با استفاده از شبکه فازی-عصبی و شبکه عصبی چندلایه انجام شده است. نتایج بدست آمده از این تحقیق نشان داد که در طبقه‌بندی عیوب، روش شبکه فازی-عصبی نسبت به روش شبکه عصبی چندلایه کارایی بیشتری دارد. در مطالعه انجام شده توسط زیو و گولا [۵] از روش فازی-عصبی در عیب یابی ماشین‌های صنعتی استفاده شده است. محی آبادی و همکاران [۶] در مطالعه‌ای تحت عنوان نگهداری و تعمیرات خودرو به کمک شبکه عصبی پرداخته و در پژوهش خود به نتیجه رسیده‌اند که استفاده از سیستمی بر پایه دانش، جهت تشخیص عیوب خودرو سبب افزایش دقت در تشخیص خرابی‌ها و در نتیجه آن کاهش زمان تعمیرات و همچنین کاهش هزینه‌های تعمیرات و نگهداری خواهد شد. کاهش زمان خرابی و کاهش هزینه‌های تعمیراتی ناشی از خطاهای انسانی می‌تواند بهره‌وری و سود بیشتری را در سیستم در برداشته باشد. محمد بحرینی و همکاران [۷] به بررسی کاربرد شبکه‌های عصبی در نگهداری و تعمیرات پیشگیرانه شبکه‌های توزیع شرکت برق استان لرستان به بررسی وضعیت خرابی و حوادث ترانسفورماتورها به‌عنوان مهم‌ترین و گران‌ترین تجهیز در سیستم‌های قدرت از تجهیزات شبکه‌های برق طی ۵ سال در شرکت توزیع برق لرستان پرداخته‌اند. به طوری که دلیل خرابی ترانسفورماتورها از کار افتاده در یک محدوده زمانی خاص را شناسایی نموده و با استفاده از این اطلاعات به‌عنوان داده‌های ورودی و خروجی، یک مدل پیش‌بینی شبکه عصبی طراحی گردیده که به وسیله آن می‌توان خرابی و حوادث ترانسفورماتورهای قدرت را پیش‌بینی نمود. پس از بررسی نتایج خروجی از شبکه عصبی مشاهده نمودند که پیش‌بینی به دست آمده با عملکرد واقعی که همان از کارافتادگی ترانسفورماتورهای توزیع می‌باشد، کاملاً مطابقت دارد و نتیجه بیان شده این است که مدل طراحی شده به وسیله شبکه عصبی می‌تواند مبنای درستی برای پیش‌بینی از کارافتادگی ترانسفورماتورها و خرابی آن‌ها و در نتیجه کل شبکه‌های توزیع برق باشد. یوسفی و عزیز [۸] استراتژی مناسب نگهداری با استفاده از شبیه‌سازی با رویکرد پویایی سیستم: گامی در جهت افزایش بهره‌وری و کاهش هزینه تعمیرات کارخانه ایمن ساخت پاسارگاد را بررسی نموده و معیارهای اصلی مورد استفاده برای اندازه‌گیری بهره‌وری و اثربخشی سیاست نگهداری مورد استفاده، هزینه چرخه عمر و خرابی‌های تجمعی می‌باشند. سرهانی [۹] به پیش‌بینی دقیق

نشریه مهندسی و مدیریت کیفیت

افزایش بهره‌وری کارخانه، وابسته به کاهش میزان خرابی‌های قابل پیش‌بینی تجهیزات است.

۳- ابزار و روش


جامعه‌ی آماری در این پژوهش شامل داده‌های خرابی و توقفات ۲۲ ماشین صنعتی در کارخانه تولید قطعات خودرو (دیاکو ایده آریا) از میان ۵۶ ماشین صنعتی با تعداد ۱۰۰ خرابی، در طول ۱۵ ماه و ۲۰ نوع محصول تولیدی می‌باشد.

شناسایی عوامل مؤثر بر خرابی ماشین‌آلات: در ابتدا به شناسایی عوامل مؤثر بر خرابی ماشین‌آلات صنعتی و بررسی عیوب ایجاد شده می‌پردازیم، که در شکل ۱ یک نمونه از ماشین صنعتی موجود در کارخانه نشان داده شده است.



شکل ۱- نمونه‌ای از ماشین‌آلات صنعتی (پرس هیدرولیک ۵ تن)

- ایجاد شکستگی در قطعات ماشین‌آلات: اعمال بار بیش از حد به قطعه‌ی مربوطه و یا استفاده از یک قطعه خاص در محل نامناسب بدون توجه به نیروهای وارده بر آن. در شکل ۲ یک نمونه خارموشکی شکسته شده نشان داده شده است.



شکل ۲- نمونه خارموشکی شکسته شده پرس ۸۰ تن

- ایجاد کندی تیغه‌ها: عدم استفاده از خنک‌کننده (مایع آب صابون) و یا استفاده بیش از عمر مفید ابزار تراشکاری. در شکل ۳ تیغه‌ی اره هیدروپنوماتیک نشان داده شده است.



شکل ۳- تیغه اره هیدروپنوماتیک

تشخیص درست عیوب مختلف می‌باشد و اگر در بخش آموزش شبکه، که مربوط به پارامترهای خطی و غیر خطی می‌باشد، از روش‌های هوشمند دیگر همچون، الگوریتم ژنتیک و PSO برای آموزش پارامترهای غیر خطی استفاده کنیم، می‌توان نتایج را متحد ممکن بهبود بخشید. مقاله حاضر در راستای این مقاله، به بررسی تأثیر پیش‌بینی خرابی ماشین‌آلات در میزان بهره‌وری پرداخته است.

امروزه استفاده از سیستم‌های پشتیبان در صنایع تولیدی از جایگاه ویژه‌ای برخوردار است. استفاده از این سیستم در تشخیص و پیش‌بینی خرابی ماشین‌آلات صنعتی می‌تواند کمک بزرگی به تولیدکنندگان، کارفرمایان، کارگران و... کند. حال با توجه به اهمیت تشخیص و پیش‌بینی خرابی ماشین‌آلات، استفاده از سیستمی که ما را در نگهداری و تعمیرات ماشین‌آلات صنعتی یاری دهد از اهمیت ویژه‌ای برخوردار است. تجزیه و تحلیل داده‌های به دست آمده از فرهای تعمیرات و شناسنامه‌های کارکردی تجهیزات و دستگاه‌ها نشان می‌دهد افزایش بهره‌وری کارخانه، وابسته به کاهش میزان خرابی‌های قابل پیش‌بینی تجهیزات است.

همانطور که از مطالعات پیشین مشاهده می‌شود از روش عصبی یا فازی- عصبی در جهت پیش‌بینی خرابی در مقالات مختلفی استفاده شده است. با توجه به بررسی‌های انجام شده مشخص گردید در هیچ یک از پژوهش‌های پیشین، به بررسی تأثیر پیش‌بینی خرابی ماشین‌آلات صنعتی بر افزایش بهره‌وری پرداخته نشده است. لذا این مقاله بر پایه روش ترکیبی شبکه عصبی و سیستم استنتاج فازی به پیش‌بینی خرابی ماشین‌آلات در جهت افزایش بهره‌وری پرداخته شده است.

قانون یادگیری اولیه شبکه فازی-عصبی تطبیقی بر اساس گرادبان نزولی و قانون زنجیره‌ای است که این روش معایبی چون کندی و تمایل به ماندن در کمینه‌های محلی را دارد. روشی که در این مقاله به کارگیری شده است یعنی شبکه ترکیبی فازی-عصبی که معایب روش تطبیقی را برطرف می‌کند.

۲- اهداف

در این پژوهش، علاوه بر پیش‌بینی خرابی ماشین‌آلات صنعتی به تأثیر آن بر افزایش بهره‌وری نیز پرداخته شده است. تجزیه و تحلیل داده‌های به دست آمده از فرهای تعمیرات و شناسنامه‌های کارکردی تجهیزات و دستگاه‌ها نشان می‌دهد

نشریه مهندسی و مدیریت کیفیت

جلد ۱۲- شماره ۱- بهار ۱۴۰۱

شکل (۷): شیربرقی پنوماتیک پرس ۷۰ تن بهره‌وری: با توجه به این که یکی از عوامل مؤثر بر میزان تولید، هزینه تولید است. یکی از راه‌های افزایش میزان تولید، کاهش هزینه‌های تولید است. در واقع هدف این است که بیشترین میزان تولید را نسبت به هزینه صرف شده، داشته باشیم. میزان خروجی و سود سازمان نسبت به هزینه‌ها بهره‌وری می‌باشد. یعنی اگر سازمانی بتواند با ثابت نگه داشتن کیفیت، از میزان هزینه‌های سازمانی خود کم کند، می‌تواند بگوید بهره‌وری ایجاد کرده است. نحوه‌ی محاسبه میزان بهره‌وری هر ماه: سود خالص ماهانه / هزینه تعمیرات ماهانه نحوه‌ی محاسبه میزان رشد بهره‌وری: بهره‌وری ماه دوم - بهره‌وری ماه اول / بهره‌وری ماه اول در جدول ۱ میزان بهره‌وری و رشد بهره‌وری در بازه زمانی ۱۵ ماه محاسبه و نشان داده شده است.

جدول ۱- محاسبه میزان بهره‌وری و رشد بهره‌وری

ردیف	بازه زمانی (ماه)	بهره‌وری	رشد بهره‌وری
۱	ماه اول	۱۹.۰۶۳۳	۵۹٪
۲	ماه دوم	۴۷.۶۲۳۳	۱۳٪
۳	ماه سوم	۵۴.۷۱۴۲	-۱۰٪
۴	ماه چهارم	۴۹.۳۸۳۰	۶۴٪
۵	ماه پنجم	۱۴۰.۰۷۳۱	-۲۰٪
۶	ماه ششم	۱۱۶.۵۹۷۳	-۶٪
۷	ماه هفتم	۱۰۹.۲۰۷۵	۶۸٪
۸	ماه هشتم	۳۴۶.۴۴۱۸	-۲۶٪
۹	ماه نهم	۱۲.۵۵۲۹	۸۷٪
۱۰	ماه دهم	۱۰۳.۸۵۵۵	-۱۶٪
۱۱	ماه یازدهم	۸۹.۲۲۲۱	-۴۰٪
۱۲	ماه دوازدهم	۶۳.۵۲۹۴	۱۸٪
۱۳	ماه سیزدهم	۷۸.۰۰۸۹	-۶٪
۱۴	ماه چهاردهم	۱۰.۹۸۹۲	۹۸٪
۱۵	ماه پانزدهم	۷۱۶.۸۳۳۳	۹۹٪

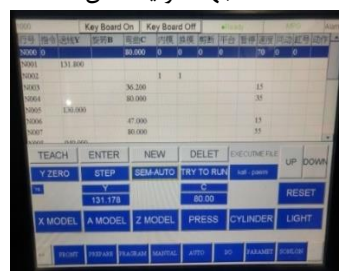
شبکه فازی-عصبی: نوعی شبکه عصبی مصنوعی است که براساس سیستم فازی تاکاگی-سوگنو می‌باشد. از آن جایی که سیستم‌های هوشمند در شرایط وجود عدم قطعیت و نادقیقی عملکرد قابل قبولی دارند و با توجه به خاصی‌های اصلی شبکه‌های عصبی، یعنی؛ تخمین قدرتمند توابع غیر خطی و قابلیت یادگیری تطبیقی و نیز خاصیت اصلی سیستم‌های فازی، یعنی؛ استفاده از دانش خیره در به دست آوردن رابطه بین ورودی و خروجی در این تحقیق از شبکه‌های هوشمند ANFIS جهت طبقه‌بندی عیوب استفاده شده است. ANFIS یک مدل ترکیبی است که شامل ترکیبی از دو روش عصبی و فازی است. ANFIS نیز یک روش داده محور است که می‌تواند برای به دست آوردن راه حل

-ایجاد خرابی در بلبرینگ: عدم روانکاری مناسب، استفاده از بلبرینگ در جای نامناسب بدون توجه به ویژگی و کارایی آن. در شکل ۴ بلبرینگ NSK 53048-2RS دستگاه CNC نشان داده شده است.



شکل ۴- بلبرینگ NSK 53048-2RS دستگاه CNC

-خارج شدن برنامه از تنظیمات دستگاه: عدم استفاده از مواد اولیه مناسب دستگاه، سختی بیش از حد مواد اولیه. در شکل ۵ برنامه تنظیم شده دستگاه CNC جهت تولید نشان داده شده است.



شکل ۵- برنامه تنظیم شده دستگاه CNC جهت تولید

-ایجاد پارگی زنجیر دستگاه NC: اعمال فشار بیش از حد به زنجیر، عدم روانکاری مناسب. در شکل ۶ زنجیر دستگاه NC نشان داده شده است.



شکل ۶: زنجیر دستگاه NC

-ایجاد خرابی قطعات یدکی: عدم انجام سرویس‌های دوره‌ای، اعمال بیش از حد بار، استفاده از قطعات غیر استاندارد، تعویض و یا تغییر توسط افراد غیر متخصص. در شکل ۷ شیر برقی پنوماتیک پرس ۷۰ تن نشان داده شده است.



$$A^{(i)} = \{A^{(1)}, A^{(2)}, \dots, A^{(3)}\} \quad (5)$$

این مجموعه‌های فازی به صورت توابع عضویت مثلثی و تابع چند جمله‌ای نامتقارن باز از سمت چپ و راست در بازه $[-\alpha_i, +\beta_i]$ ($i = 1, 2, \dots, n$) در نظر گرفته می‌شود. در این حالت دامنه‌ها طوری تعیین می‌گردند که به ازای هر $A^{(i)}, x_i \in [-\alpha_i, +\beta_i]$ وجود داشته باشد که درجه تابع عضویت غیر صفر داشته باشد.

مدل‌سازی شبکه فازی -عصبی: در مرحله اول داده‌ها و اطلاعات که داده‌های ورودی شامل عمر مفید ماشین‌آلات بر حسب سال، مدت زمان تعمیر بر حسب دقیقه، مدت زمان کاری ماشین‌آلات بر حسب دقیقه، میزان در دسترس بودن ماشین‌آلات بر حسب دقیقه و داده‌ی خروجی مدت زمان خرابی ماشین‌آلات بر حسب دقیقه محاسبه و جمع‌آوری می‌شود. در مرحله بعدی بعد از مدل‌سازی شبکه فازی-عصبی، ورودی‌ها مشخص شده و عملیات آموزش و سپس تست با دو الگوریتم Grid Partition و Subtractive Clustering صورت می‌پذیرد. همچنین در این مطالعه سیستم فازی سوگنو و شبکه عصبی پرسپترون چند لایه مورد استفاده قرار گرفته است.

پرسپترون چند لایه (MLP) یک شبکه عصبی مصنوعی عمیق است. که از بیش از یک پرسپترون تشکیل شده است. آن‌ها از یک لایه ورودی برای دریافت سیگنال تشکیل شده‌اند، یک لایه خروجی که در مورد ورودی تصمیم می‌گیرد یا پیش‌بینی می‌کند، و در بین این دو، تعدادی دلخواه از لایه‌های پنهان که موتور محاسباتی واقعی MLP هستند قرار دارد MLPها با یک لایه مخفی قادر به تقریب هر عملکرد پیوسته‌ای هستند. شبکه عصبی پرسپترون چند لایه اغلب برای مشکلات یادگیری تحت نظارت به کار گرفته می‌شوند. آن‌ها بر روی مجموعه‌ای از جفت‌های ورودی-خروجی آموزش می‌بینند و یاد می‌گیرند که همبستگی (یا وابستگیها) بین ورودی‌ها و خروجی‌ها را مدل کنند. از جمله مزایای این روش میتوان به موارد زیر اشاره کرد :

۱- قابلیت یادگیری مدل‌های غیر خطی

۲- قابلیت یادگیری مدل‌ها در زمان واقعی

در شکل ۸ فلوجارت شبکه عصبی پرسپترون چند لایه ارائه شده است که شامل ورودی‌ها، وزن‌ها و خروجی‌ها می‌باشد.

جلد ۱۲- شماره ۱- بهار ۱۴۰۱

برای مشکل تابع تقریب استفاده شود. در این پژوهش ابتدا سیستم استنتاج فازی که شامل مدل فازی اولیه است شکل می‌گیرد که بر پایه قواعد استخراج شده از داده‌های ورودی و خروجی است. در مرحله بعد شبکه‌های عصبی برای بهتر کردن قوانین فازی اولیه به کار گرفته می‌شود و با استفاده از متدولوژی ANFIS شبکه آموزش داده می‌شود.

مدل‌سازی توابع تعلق فازی:

برای یک ساختار فازی جهت مدل‌سازی می‌توان از نگاشت داده‌های ورودی-خروجی استفاده کرد. تعریف معمولی از یک مسئله شناسایی تعیین یک تابع \hat{f} است بطوریکه تقریباً بتوان به جای تابع اصلی f مورد استفاده قرار گیرد. در نتیجه پیش‌بینی خروجی \hat{Y} به ازای ورودی $X = (X_1, X_2, X_3, \dots, X_n)$ باید تا حد امکان به مقدار خروجی حقیقی Y نزدیک باشد. حال یک مجموعه m تایی از داده‌های چند ورودی و یک خروجی بصورت رابطه زیر در نظر گرفته می‌شود:

$$y_i = f(x_{i1}, x_{i2}, \dots, x_{in}) \quad (i = 1, 2, \dots, m) \quad (1)$$

حال می‌توان از روی این داده‌ها یک جدول برای آموزش سیستم فازی جهت تخمین مقادیر خروجی \hat{Y}_1 به ازای بردارهای ورودی $X = (X_{i1}, X_{i2}, \dots, X_{in})$ که:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, \dots, x_{in}) \quad (i = 1, 2, \dots, m) \quad (2)$$

تشکیل داد. حال مسئله تعیین یک ساختار فازی جهت مینیمم کردن تفاوت بین مقادیر خروجی و مقادیر پیش‌بینی شده می‌باشد و یا به عبارت دیگر:

$$\sum_{i=1}^m [\hat{f}(x_{i1}, x_{i2}, \dots, x_{in}) - y_i]^2 \rightarrow \min \quad (3)$$

در این روش جهت تقریب تابع f با \hat{f} با استفاده از m بردار شامل n ورودی و تک خروجی $(X_i, Y_i), (i = 1, 2, \dots, m)$ طراحی می‌گردد. قواعد فازی تشکیل شده در مدل را می‌توان به راحتی به صورت زیر بیان نمود:

$$\text{Rule}_1 = \text{IF } x_1 \text{ is } A_1^{(j1)} \text{ AND } x_2 \text{ is } A_1^{(j2)} \text{ AND } \dots \text{ AND } x_n \text{ is } A_1^{(jn)}, \quad (4)$$

$$\text{THEN } y = \sum_{i=1}^n w_i^1 x_i + w_0^1$$

که در آن


$$j_i \in \{1, 2, \dots, r\}$$

$$w^1 = \{w_1^1, w_2^1, \dots, w_n^1, w_0^1\}$$

مجموعه پارامترهای بخش تالی هر قاعده می‌باشد. تمامی مجموعه‌های فازی در فضای X_i بصورت زیر می‌باشد:

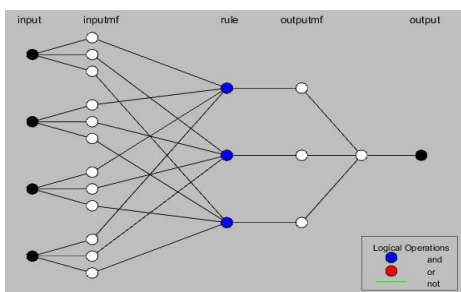
نشریه مهندسی و مدیریت کیفیت

پارامترهای ثابت Toolbox شروع به تنظیم ساختار فازی نمودیم. سپس با انتخاب روش Hybrid و انتخاب ۱۰ تکرار شروع به آموزش می‌کنیم و در نهایت در دهمین تکرار به Error 0.060433 می‌رسیم که در شکل ۱۱ قابل مشاهده است (شکل‌های ۹ و ۱۰).



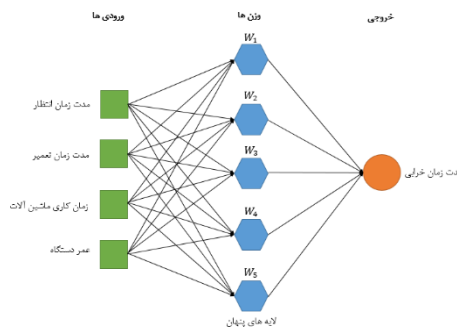
شکل ۱۱- Error Training

با انتخاب الگوریتم Subtractive Clustering ساختار اطلاعات Anfis با ۴ ورودی و ۱ خروجی و ۳ Rule ساختاری را تشکیل می‌دهند که در شکل ۱۲ نشان داده شده است.




شکل ۱۲- ساختار ANFIS

در بعضی از شرایط، انتخاب نوع توابع عضویت در سیستم‌های فازی بسیار مشکل است، از طرفی شکل توابع عضویت به پارامترهایی وابسته است و با تغییر این پارامترها شکل توابع عضویت تغییر خواهد کرد که استفاده از تکنیک‌های عصبی فازی می‌تواند در انتخاب توابع عضویت بهینه بسیار مفید باشد. این روش یادگیری بسیار شبیه شبکه‌های عصبی است و با عبور داده‌های آموزشی از سیستم بهینه توابع عضویت برای جور شدن با شکل داده‌ها و مدل کردن رفتار داده‌ها بدست می‌آید. بعد از تشکیل قوانین توابع عضویت و قوانین اگر آنگاه فرضی مربوط به سیستم، شبکه آموزش داده می‌شود آموزش شبکه تا وقتی ادامه می‌یابد که خطای حاصل مقدار کمی گردد و سیستم به فرم مناسبی بهینه شود. معمولاً هرچه تعداد تکرارها بیشتر باشد، خطای حاصل شده کمتر است. در این مقاله با ۱۰ بار تکرار، کاهش زیادی در میزان خطای سیستم مشاهده می‌شود. ساختار توابع عضویت برای شرایط این مقاله در اشکال زیر توسط نرم‌افزار متلب




شکل ۸- فلوچارت شبکه عصبی پرسپترون چند لایه

در ابتدا با استفاده از نرم افزارهای تعیین تصادفی اعداد تعداد ۱۰۰ داده خرابی را با نرم افزار Excel به دو بخش ۳۰ داده Checking و ۷۰ داده Training انتخاب نموده (بر اساس نظریه McLachlan et al ۲۰۰۴، ۱. ده نوع مجموع داده، برای در نظر گرفتن Training مناسب و معتبر است. ۲. مجموعه داده‌ها باید به صورت تصادفی ایجاد شوند.) و با دستور Anfis Edit در Toolbox فازی-عصبی در قسمت Load Data داده‌های Train و Check را Load کرده و نتایج در شکل‌های ۹ و ۱۰ ارائه شده است.




شکل ۹- داده‌های آموزش پس از انتخاب تصادفی



شکل ۱۰- داده‌های آزمایش پس از انتخاب تصادفی

نتایج نشان می‌دهد که در قسمت Generate FIS که دارای دو الگوریتم Grid Partition و Subtractive Clustering می‌باشد در ابتدا با انتخاب الگوریتم Grid Partition و با کم و زیاد کردن تعداد توابع عضویت فازی و تغییر نوع تابع عضویت فازی از مثلی به دوزنقه‌ای و زنگوله‌ای و نرمال و نوع خروجی فازی به صورت خطی که آموزش دادیم نتایج مطلوبی بدست نیامد و بعد از دهمین تکرار با Error 7.67814 مواجه شدیم و در نتیجه با انتخاب الگوریتم Subtractive Clustering با استفاده از



شکل ۱۶- توابع تعلق ورودی چهارم سیستم فازی

با توجه به توابع عضویت رسم شده می توان گفت که هرچه تفکیک توابع در نمودارهای ورودی به سیستم بیشتر باشد، عیوب مربوط به پارامترهای توابع عضویت، مستقل تر و برای فرایند تصمیم گیری مناسب و مؤثرتر هستند.

مدل ریاضی توابع تعلق:

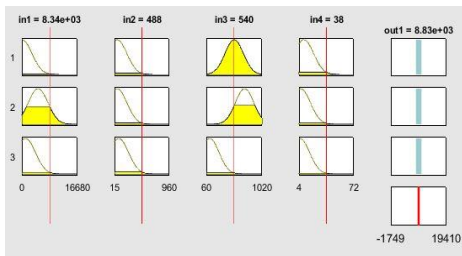
$$\mu(x) = \exp\left[-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2\right]$$

تابع در Matlab : Gaussmf(x,[sig,mu])

سیستم فازی استفاده شده :

سیستم استنتاج تاکاگی سوگنو، توسط تاکاگی و میشیو سوگنو در سال ۱۹۸۵ به منظور توسعه یک رویکرد سیستماتیک برای تولید قوانین فازی ارائه شد، این سیستم استنتاج بیشتر در سیستم های کنترلی و در زمینه هایی که نیاز به محاسبات ریاضی باشد مورد استفاده قرار می گیرد.

در مرحله آخر بعد از طراحی سیستم و آموزش آن نتایج هر سطح محاسبه شد و خروجی که همان تخمین مدت زمان خرابی ماشین آلات کارخانه دیاکو ایده آریا می باشد بدست آمد که در شکل ۱۷ نشان داده شده است.




شکل ۱۷- Rule های کل ورودی و خروجی

نمودارهای رسم شده در شکل های ۱۹ و ۱۸ رفتار ورودی های مختلف را بر اساس خروجی های مختلف را نشان می دهند.


رسم شده است. تعداد ورودی های سیستم تصمیم گیر، با توجه به تعداد ویژگی های استخراج شده از سیگنال ها و تعداد خروجی های تعیین شده برای سیستم، مشخص می شوند.

با توجه به ورودی های پژوهش، این تعداد به ۴ مورد ورودی می رسد. تعداد توابع عضویت نیز با توجه به پارامترها تغییرات اعمال شده تعیین می گردد.


شکل ۱۳ تابع عضویت استفاده شده برای ورودی های سیستم (مدت زمان انتظار تعمیر) و شکل ۱۴ تابع عضویت استفاده شده برای ورودی های سیستم (مدت زمان تعمیر) و شکل ۱۵ تابع عضویت استفاده شده برای ورودی های سیستم (زمان کاری ماشین آلات) و شکل ۱۶ تابع عضویت استفاده شده برای ورودی های سیستم (عمر دستگاه) در فرآیند مدل سازی، عیب مدار را نشان می دهد.



شکل ۱۳- توابع تعلق ورودی اول سیستم فازی



شکل ۱۴- توابع تعلق ورودی دوم سیستم فازی




شکل ۱۵- توابع تعلق ورودی سوم سیستم فازی

جدول ۲- نتایج مدل پیش‌بینی برای ارزیابی موفقیت


ردیف	کارایی واقعی	مقدار برآورد شده
۱	۱۲۰	۱۱۹.۹۹۹۱
۲	۲۴۰	۲۳۹.۹۹۶۱
۳	۹۶۰	۹۵۹.۹۹۵۴
۴	۱۲۰	۱۱۹.۹۹۸۴
۵	۵۴۰	۵۳۹.۹۹۴۳
۶	۳۱۸۰	۳۱۷۹.۹۹۹۶
۷	۱۶۵	۱۶۴.۹۹۹۲
۸	۱۲۰	۱۱۹.۹۹۸۳
۹	۶۰۰	۵۹۹.۹۹۷۴
۱۰	۱۵۶۰	۱۵۵۹.۹۹۹۷
۱۱	۱۴۴	۱۴۳.۹۹۹۷
۱۲	۱۰۲۰	۱۰۱۹.۹۹۹۹
۱۳	۱۸۰	۱۷۹.۹۹۹۲
۱۴	۶۰	۵۹.۹۹۹۴
۱۵	۱۳۲۰	۱۳۱۹.۹۹۹۳
۱۶	۹۶۰	۹۵۹.۹۹۸۲
۱۷	۲۱۰	۲۰۹.۹۹۹۹
۱۸	۵۲۸۰	۵۲۷۹.۹۹۹۷
۱۹	۶۴۰	۶۳۹.۹۹۸۳
۲۰	۱۱۴۰	۱۱۳۹.۹۹۸۵
۲۱	۱۸۰۰	۱۷۹۹.۹۹۹۱
۲۲	۱۴۷۰	۱۴۶۹.۹۹۹۹
۲۳	۱۳۵	۱۳۴.۹۹۹۸
۲۴	۱۰۲۰	۱۰۱۹.۹۹۹۹

همانطور که در جدول ۲ و شکل ۲۰ مشخص شده است، نتایج برآورد مدل طراحی شده نسبت به کارایی واقعی محاسبه شده بسیار نزدیک می‌باشد و برای ۴ مورد تقریباً نزدیک به ۱۰۰ درصد بوده است. برای سایر موارد نیز، تقریب مدل کمتر ۰.۹۸ نبوده است.


در انتها با Run کردن مدل، داده‌های train شده و داده‌های واقعی در مدل نشان داده شده است. اگر داده‌های train شده با داده‌های نتایج واقعی نزدیک به هم باشند یعنی مدل قابلیت استنتاج خوبی دارد. در شکل‌های ۲۱ و ۲۲ نتایج این آزمون ارائه شده است.




شکل ۲۱: تست داده‌های آموزش



شکل ۱۸: گراف ورودی‌های ۱ و ۳ سیستم فازی عصبی



شکل ۱۹: گراف ورودی‌های ۲ و ۴ سیستم فازی عصبی



شکل ۲۰- نتایج برآورد مدل Anfis

شکل ۱۸ در حالت سه بعدی رفتار دو ورودی ۱ و ۳ را نشان می‌دهد. بر اساس ادبیات تحقیق و محاسبات انجام گرفته هر گاه معیارهای مدت زمان انتظار کاهش و زمان کاری ماشین‌آلات افزایش یابد و به حد مناسب برسد، دقت پیش‌بینی خرابی ماشین‌آلات در کارخانه افزایش داشته و به حالت مطلوب نزدیک می‌شود. در شکل ۱۹، دیده می‌شود که بر اساس قوانین تدوین شده، با کاهش مدت زمان تعمیر و افزایش عمر دستگاه مدت زمان کاری دستگاه‌های کارخانه افزایش می‌یابد که این مطابق انتظارات ما می‌باشد.

بر اساس نتایج بدست آمده در جدول زیر، میزان انطباق‌پذیری برآورد صورت گرفته با نتایج واقعی و قابلیت پیش‌بینی‌کنندگی و صحت برآورد نتایج در شکل ۲۰ و جدول ۲ ارائه شده است:

برای ارزیابی عملکرد مدل پارامترهای ریشه میانگین مجذور خطا (RMSE)، میانگین خطای مطلق (MAE)، درصد خطای نسبی (ϵ) و ضریب تبیین (R^2) استفاده شده است.

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - Y_{1i})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$$

از معیارهای آماری برای ارزیابی عملکرد مدل پیش‌بینی RMSE و MAE هستند. این دو شاخص میانگین خطاها را در هر متغیر خروجی نشان می‌دهند که در معادلات زیر نشان داده شده است:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - Y_{2i})^2}{n}}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - Y_{2i}|$$

$$\epsilon = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{Y_i - Y_{2i}}{Y_i} \right|$$


در روابط فوق Y_i نشان‌دهنده پیش‌بینی مدل، Y_{1i} پیش‌بینی خط رگرسیون و \bar{Y} میانگین مقادیر رگرسیون را نشان می‌دهد. \hat{y} ، y و n به ترتیب مقدار هدف (مشاهده واقعی)، خروجی مدل و تعداد مشاهدات می‌باشد.

جدول ۴ ارزیابی عملکرد محاسبه شده شاخص‌هایی مانند R^2 ، RMSE، MAE و NSE را نشان می‌دهد.

جدول ۴- ارزیابی عملکرد Anfis

Stage	R^2	RMSE	MAE	ϵ (%)
Training	۱.۰۰	۰.۰۲	۰.۰۳	۰.۴۳
Testing	۰.۸۰	۱.۰۲	۱.۵۴	۰.۱۵۳

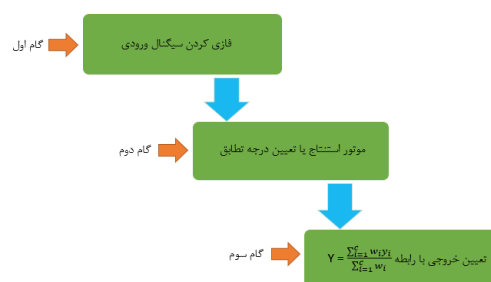
مقادیر به دست‌آمده برای این معیارها نشان‌دهنده خوبی مدل شبیه‌سازی هستند. همان‌طور که در جدول ۴ نشان داده شده است، این مقادیر محاسبه شده ثابت می‌کند که ANFIS اعمال شده دارای قابلیت مناسب برای پیش‌بینی خرابی‌ها است. از این رو، نتایج جدول ۴ از طریق این دو شاخص صحت مدل برای پیش‌بینی را تأیید می‌کند.



شکل ۲۲: تست داده‌های آزمایش

الگوریتم منتج به سیستم استنتاج فازی سوگنو:

در شکل ۲۳ الگوریتم منتج به سیستم استنتاج فازی سوگنو قابل مشاهده است.



شکل ۲۳: الگوریتم منتج به سیستم استنتاج فازی سوگنو

۴- نتایج

در این بخش ورودی‌های شبکه فازی-عصبی مشخص شده و عملیات آموزش و سپس تست صورت می‌پذیرد. داده‌های ورودی شامل عمر مفید ماشین‌آلات بر حسب سال، مدت زمان تعمیر بر حسب دقیقه، مدت زمان کاری ماشین‌آلات، زمان انتظار بر حسب دقیقه و داده‌ی خروجی مدت زمان خرابی ماشین‌آلات بر حسب دقیقه محاسبه می‌شود. در جدول ۳ تعدادی از نتایج مطلوب بدست آمده از شبکه فازی-عصبی نشان داده شده است. با توجه به نتایج بدست آمده میزان دقت شبکه فازی-عصبی مدل‌سازی شده ۹۴ درصد و میزان خطای آن ۶ درصد می‌باشد که نشان‌دهنده بالا بودن میزان دقت شبکه فازی-عصبی و کم بودن خطای این شبکه‌ی ترکیبی در پیش‌بینی خرابی ماشین‌آلات صنعتی است.

معیارهای ارزیابی عملکرد Anfis :

معیارهای مختلفی برای ارزیابی مدل‌های پی‌بینی وجود دارد، که به طور عمده بر اساس اختلاف بین خروجی‌های پیش‌بینی شده و خروجی‌های مطلوب و واقعی استوارند.

نشریه مهندسی و مدیریت کیفیت

جدول ۳- نتایج Anfis نرم افزار MATLAB

ورودی				خروجی	نتایج Anfis	
مدت زمان انتظار (دقیقه)	مدت زمان تعمیر (دقیقه)	زمان کاری ماشین‌آلات (دقیقه)	عمر دستگاه (سال)	مدت زمان خرابی (دقیقه)	برآورد مدل Anfis	مقایسه (اختلاف) زمان خرابی واقعی و خروجی)
۳۰	۹۰	۵۴۰	۶	۱۲۰	۱۱۹.۹۹۹۱	۰.۰۰۰۸
۱۲۰	۱۲۰	۴۲۰	۲۵	۲۴۰	۲۳۹.۹۹۶۱	۰.۰۰۳۸
۷۸۰	۱۸۰	۳۶۰	۶	۹۶۰	۹۵۹.۹۹۵۴	۰.۰۰۴۵
۱۰	۱۱۰	۵۴۰	۵	۱۲۰	۱۱۹.۹۹۸۴	۰.۰۰۱۵
۴۲۰	۱۲۰	۷۸۰	۵	۵۴۰	۵۳۹.۹۹۴۳	۰.۰۰۵۶
۳۰۰۰	۱۸۰	۷۸۰	۵	۳۱۸۰	۳۱۷۹.۹۹۹۶	۰.۰۰۰۳
۴۵	۱۲۰	۴۹۵	۶	۱۶۵	۱۶۴.۹۹۹۲	۰.۰۰۰۷
۰	۱۲۰	۵۴۰	۵	۱۲۰	۱۱۹.۹۹۸۳	۰.۰۰۱۶
۴۲۰	۱۸۰	۷۲۰	۵	۶۰۰	۵۹۹.۹۹۷۴	۰.۰۰۲۵
۱۵۰۰	۶۰	۴۲۰	۱۱	۱۵۶۰	۱۵۵۹.۹۹۹۷	۰.۰۰۰۲
۸۴	۶۰	۵۱۶	۲۰	۱۴۴	۱۴۳.۹۹۹۷	۰.۰۰۰۲
۹۶۰	۶۰	۳۰۰	۷	۱۰۲۰	۱۰۱۹.۹۹۹۹	۸.۹۶۲۵
۶۰	۱۲۰	۴۸۰	۵	۱۸۰	۱۷۹.۹۹۹۲	۰.۰۰۰۷
۳۰	۳۰	۶۰۰	۴	۶۰	۵۹.۹۹۹۴	۰.۰۰۰۵
۱۲۰۰	۱۲۰	۶۶۰	۶	۱۳۲۰	۱۳۱۹.۹۹۹۳	۰.۰۰۰۶
۹۰۰	۶۰	۱۰۲۰	۵	۹۶۰	۹۵۹.۹۹۸۲	۰.۰۰۱۷
۶۰	۱۵۰	۴۵۰	۱۰	۲۱۰	۲۰۹.۹۹۹۹	۸.۲۱۰۸
۴۹۲۰	۳۶۰	۶۶۰	۱۰	۵۲۸۰	۵۲۷۹.۹۹۹۷	۰.۰۰۰۲
۵۲۰	۱۲۰	۶۸۰	۷	۶۴۰	۶۳۹.۹۹۸۳	۰.۰۰۱۶
۱۰۸۰	۶۰	۸۴۰	۵	۱۱۴۰	۱۱۳۹.۹۹۸۵	۰.۰۰۱۴
۱۶۸۰	۱۲۰	۱۸۰	۵	۱۸۰۰	۱۷۹۹.۹۹۹۱	۰.۰۰۰۸
۱۲۹۰	۱۸۰	۵۱۰	۳۰	۱۴۷۰	۱۴۶۹.۹۹۹۹	۸.۲۸۱۶
۷۵	۶۰	۵۲۵	۲۰	۱۳۵	۱۳۴.۹۹۹۸	۰.۰۰۰۱
۹۶۰	۶۰	۳۰۰	۴	۱۰۲۰	۱۰۱۹.۹۹۹۹	۷.۱۰۴۶

۵- بحث

شبکه فازی- عصبی همان‌طور که انتظار می‌رفت شاهد پیش‌بینی مدت زمان خرابی ماشین‌آلات صنعتی بودیم که نتایج در جدول نتایج خروجی مدل‌سازی در جدول ۳ ارائه شده است. با توجه به نتایج بدست آمده میزان دقت شبکه فازی- عصبی مدل‌سازی شده ۹۴ درصد و میزان خطای آن ۶ درصد می‌باشد که نشان‌دهنده بالا بودن میزان دقت شبکه فازی-عصبی و کم بودن خطای این شبکه‌ی ترکیبی در پیش‌بینی خرابی ماشین‌آلات صنعتی نیز می‌باشد.

در این مقاله به پیش‌بینی خرابی ماشین‌آلات صنعتی با استفاده از شبکه فازی-عصبی در راستای افزایش بهره‌وری پرداختیم. ابتدا شناخت کاملی نسبت به تمام قطعات مختلف ماشین‌آلات صنعتی و کارکرد مربوط به هر یک از آن‌ها پیدا کردیم و بعد از جمع‌آوری داده‌های مربوطه، میزان بهره‌وری را محاسبه کرده که نتایج در جدول ۱ قابل مشاهده می‌باشد. در آخر برای بررسی مسئله در نرم‌افزار Matlab به مدل‌سازی شبکه فازی-عصبی برای پیش‌بینی خرابی ماشین‌آلات پرداختیم. پس از مدل‌سازی

۶- نتیجه گیری

همان طور که پیش تر ذکر شد جنبه دیگر در نظر گرفته شده در این مطالعه افزایش میزان بهره‌وری می‌باشد که پس از انجام مدل‌سازی نتیجه بر آن شده که کاهش مدت زمان خرابی و تعمیرات و کاهش هزینه‌های نت سبب افزایش مدت زمان کاری و دسترس پذیری ماشین‌آلات شده و در نهایت میزان بهره‌وری افزایش می‌یابد.

از آن جا که می‌توان یکی از مهم‌ترین و اساسی‌ترین نکات در صنایع مختلف را نیاز به داشتن یک سیستم پیش‌بینی خرابی به صورت اتوماتیک و هوشمند دانست و همان طور که پیش تر ذکر شد سیستم ارائه شده در این تحقیق نتایج و خوب و قابل قبولی با قابلیت اطمینان و دقت بالا و خطای کم را ارائه می‌دهد. پیشنهاد می‌شود به‌عنوان روشی مناسب در جهت تشخیص هوشمند خرابی‌ها در صنایع به‌کار برده شود.

۷- مراجع

- [7] Bahraini, M., Bakhtiyari, H., Baharvandi, B. (2014). Application of neural networks in preventive maintenance and repairs of distribution networks of Lorestan province electricity company. International Science and Technology Research Conference. [In Persian]
- [8] Yousefi, Sh. and Azizi, A. (2017). Providing an appropriate maintenance strategy using simulation with a system dynamics approach: a step towards increasing productivity and reducing the cost of repairs at the Pasargad safe manufacturing plant". JR_MIEJ-4-16_001 [In persian]
- [9] Sarhan, A. A. (2015). Adaptive neuro-fuzzy approach to predict tool wear accurately in turning operations for maximum cutting tool utilization. IFAC-PapersOnLine, 48(1), 93-98.
- [10] Abdelkrim, C., Meridjet, M. S., Boutasseta, N., & Boulanouar, L. (2019). Detection and classification of bearing faults in industrial geared motors using temporal features and adaptive neuro-fuzzy inference system. Heliyon, 5(8), e02046.
- [11] Zhu, F., & Wu, Y. (2014). A rapid structural damage detection method using integrated ANFIS and interval modeling technique. Applied Soft Computing, 25, 473-484.
- [12] Ershadi, M. J., Qhanadi Taghizadeh, O., & Hadji Molana, S. M. (2021). Selection and performance estimation of Green Lean Six Sigma Projects: a hybrid approach of technology readiness level, data envelopment analysis, and ANFIS. Environmental Science and Pollution Research, 28(23), 29394-29411.
- [13] Venturini, F. (2015). The modern drivers of productivity. Research Policy, 44(2), 357-369.
- [14] Nouri Kameri, M., Paiganeh, G., & Nouri Khajovi, M. (2012). Using intelligent fuzzy-neural methods and multi-layer neural networks in detecting the main defects of rotating machines. Amirkabir Mechanical Engineering Journal, 45(2), 105-118.[In persian]
- [1] Lei, Y., He, Z., & Zi, Y. (2008). A new approach to intelligent fault diagnosis of rotating machinery. Expert Systems with applications, 35(4), 1593-1600.
- [2] Knapp, G. M. & Wang, H. P. (1992). Machine fault classification: a neural network approach. International Journal of Production Research, 30(4), 811-823.
- [3] Wang, C. C., Kang, Y., Shen, P. C., Chang, Y. P., & Chung, Y. L. (2010). Applications of fault diagnosis in rotating machinery by using time series analysis with neural network. Expert Systems with Applications, 37(2). 1696-1702.
- [4] Zamani Mohiabadi, M. (2013). Car maintenance and repairs with the help of neural network. Mechanical Engineering, 23(2), 71-81. [In Persian].
- [5] Becraft, W. R., & Lee, P. L. (1993). An integrated neural network/expert system approach for fault diagnosis. Computers & chemical engineering, 17(10), 1001-1014.
- [6] Zio, E., & Gola, G. (2009). A neuro-fuzzy technique for fault diagnosis and its application to rotating machinery. Reliability Engineering & System Safety, 94(1), 78-88.

Combined Modeling of Fuzzy Logic and Artificial Neural Network to Predict Machine Breakdowns in Order to Increase Productivity

Parviz Chopankari

Master's Degree in Industrial Engineering, Science and Research Unit, Islamic Azad University, Tehran, Iran
Parviz_choopankari@yahoo.com

Amir Azizi

(Responsible author). Assistant professor and faculty member of Islamic Azad University, Faculty of Industrial Engineering, Islamic Azad University, Science and Research Unit, Tehran, Iran. azizi@srbiau.ac.ir

Mohammad Javad Ershadi

Ph.D. in Industrial Engineering, Research Assistant Professor, Iran Science and Information Technology Research Institute (IRANDAC), Tehran, Iran. mjershadi@gmail.com

Abstract: In this research, a hybrid approach based on fuzzy logic and artificial neural network is presented to predict the failure of machines in order to increase productivity. The subject of this research is one of the factories of the automobile industry named Diaco Ide Aria, which operates in the field of automobile parts production. Preventive maintenance requires correct prediction of breakdowns and accidents, equipment and machines so that productivity can be increased by timely and correct maintenance of machines as well as fixing defects and breakdowns. To model the multi-layer perceptron fuzzy-neural network (MLP), first, 100 failures and stops were collected in a period of 15 months and then entered into MATLAB software. The obtained results show that the implementation of fuzzy-neural network and the prediction of machine failure time has reduced the duration and cost of repairs. Therefore, the working time and accessibility of the machines increased and ultimately increased the productivity by 57%, also, the accuracy of the developed neural-fuzzy model was estimated at 94%.

Keywords: productivity, prediction, neural network, fuzzy logic.

1. Introduction

In recent years, fuzzy logic and neural networks have been successfully used in pattern recognition and fault diagnosis problems. Multi-layer neural network and fuzzy-neural adaptive inference system due to reducing the probability of human error in sensitive decisions, powerful estimation of non-linear functions in the presence of uncertainty, the ability to learn adaptively and also the use of expert knowledge in obtaining the relationship between input and output, in diagnosing the defects of industrial machines are expanding.

Nap et al.[1] studied the application of a multi-layer feed forward network based on the machine condition detection method, and presented certain fuzzy relationships between failure signs and their reasons with many nonlinear relationships between the inputs and outputs of the network. Lee et al [2] have also investigated the application of fault back propagation neural network in the diagnosis of CNC machine failure using oscillatory data. A research was done by Wing et al.[3] in the field of fault finding of rotating machines with the help of neural network. In this article, four defects of imbalance, misalignment, bearing damage and oil whipping have been created separately on the testing machine. The neural network used in this research was a three-layer type. The number of neurons in input, middle and output layers was equal to 20, 30 and 40

respectively. The fault finding process was repeated with three methods, different coefficients, and it was found that the method of different coefficients is better than the other two types. In the study conducted by Ziv and Gola [4], the fuzzy-neural method was used in fault finding of industrial machines.

Today, the use of backup systems in manufacturing industries has a special place. The use of this system in diagnosing and predicting the failure of industrial machines can be of great help to manufacturers, employers, workers, etc.

As can be seen from previous studies, neural or fuzzy-neural method has been used to predict failure in various articles. According to the investigations, it was found that in none of the previous researches, the effect of predicting the failure of industrial machines on increasing productivity has not been investigated. Therefore, this article is based on the combined method of neural network and fuzzy inference system to predict the failure of machines in order to increase productivity.

In this research, in addition to predicting the failure of industrial machines, its effect on increasing productivity has also been discussed. Analyzing the data obtained from the repair forms and the functional certificates of the equipment and devices shows that the increase in the productivity of the factory is dependent on the decrease in the amount of predictable breakdowns of the equipment.

2. Research method

The statistical population in this research includes the breakdown and stoppage data of 22 industrial machines in the auto parts factory (Diac Idea Aria) out of 56 industrial machines with 100 breakdowns during 15 months and 20 types of manufactured products.

Productivity: due to the fact that one of the factors influencing the amount of production is the cost of production. One of the ways to increase production is to reduce production costs. In fact, the goal is to have the highest amount of production compared to the cost spent. The amount of output and profit of the organization compared to costs is productivity. That is, if an organization can reduce its organizational costs by keeping the quality constant, it can say that it has created productivity. In Table 1, the productivity rate and productivity growth in a period of 3 months are calculated and shown as examples.

Table 1: Calculation of productivity and productivity growth

growth productivity	productivity	of time period (months)	row
59%	19.0633	First month	1
13%	47.6233	second month	2
-10%	54.7142	The third month	3

Fuzzy-neural network: It is a kind of artificial neural network based on the Takagi-Sugno fuzzy system. Since intelligent systems have an acceptable performance in the presence of uncertainty and inaccuracy, and considering the main properties of neural networks, that is; Powerful estimation of non-linear functions and adaptive learning capability as well as the main property of fuzzy systems, that is; Using expert knowledge to obtain the relationship between input and output. In this research, ANFIS smart networks have been used to classify defects.

Fuzzy-neural network modeling: at first, by using random number determination software, 100 failure data were selected with Excel software into two parts: 30 checking data and 70 training data (based on the theory of McLachlan et al, 2004 1. ten The type of data set is suitable and valid for considering Training. 2. The data sets must be created randomly.) and with the Anfis Edit command in the Fuzzy-Neural Toolbox in the Load Data section, load the Check and Train data and the results It is presented in Figures 1 and 2.




Figure 1: Training data after random selection




Figure 2: Test data after random selection

The results show that in the Generate FIS section, which has two algorithms, Grid Partition and Subtractive Clustering, first by choosing the Grid Partition algorithm, by increasing and decreasing the number of fuzzy membership functions, and changing the type of fuzzy membership function from triangular to trapezoidal and bell-shaped and The normal and linear type of fuzzy output that we taught did not get the desired results and after the tenth repetition we encountered Error 7.67814 and as a result we started to adjust the fuzzy structure by selecting the Subtractive Clustering algorithm using the fixed parameters of the Toolbox. Then we start training by choosing the Hybrid method and selecting 10 iterations, and finally, in the tenth iteration, we reach Error 0.060433, which can be seen in Figure 3.




Figure 3: Error Training

By choosing the Subtractive Clustering algorithm, Anfis information structure with 4 inputs and 1 output and 3 rules form the structure shown in Figure 4.




Figure 4: ANFIS structure

According to the inputs of the research, this number reaches 4 inputs. The number of membership functions is also determined according to the applied parameters. Figure 5 membership function used for system inputs (repair waiting time) and Figure 6 membership function used for system inputs (repair time) and Figure 7 membership function used for system inputs (machine working time) and Figure 8 shows the membership function used for

system inputs (device life) in the modeling process of the circuit fault.




Figure 5: Membership functions of the first input of the fuzzy system




Figure 6: The membership functions of the second input of the fuzzy system




Figure 7: Membership functions of the third input of the fuzzy system




Figure 8: Membership functions of the fourth input of the fuzzy system

According to the drawn membership functions, it can be said that the more the separation of functions in the input diagrams to the system is, the more independent the defects related to the parameters of the membership functions are, and more suitable and effective for the decision-making process.

Based on the results obtained in the table below, the degree of compatibility of the estimation with the actual results and the predictive ability and accuracy of the estimation of the results are presented in Table 2:

Table 2: Prediction model results for success evaluation

Estimated value	Real performance	Row
119.9991	120	1
239.9961	240	2
959.9954	960	3
119.9984	120	4

As shown in Table 2, the estimation results of the designed model are very close to the actual calculated efficiency and for 4 cases it was almost 100%. For other cases, the approximation of the model was not less than 0.98.

Finally, by running the model, the trained data and real data are shown in the model. If the trained data are close to the real results data, it means that the model has a good inference capability. Figures 10 and 11 show the results of this test.




Figure 10: Training data test




Figure 11: Testing the test data

3-Results

In this section, the inputs of the fuzzy-neural network are specified and the training and then testing operations are performed. The input data includes useful life of machines in years, repair time in minutes, working time of machines, waiting time in minutes, and output data of machine breakdown time in minutes. Table 3 shows some of the desired results obtained from the fuzzy-neural network.

According to the obtained results, the accuracy rate of the modeled fuzzy-neural network is 94% and its error rate is 6%, which indicates the high accuracy rate of the fuzzy-neural network and the low error of this combined network in predicting machine failures. It is industrial.

An example of the results obtained from Matlab software is shown in Table 3.

4-Discussion and conclusion:

In this article, we predicted the failure of industrial machines using fuzzy-neural network in order to increase productivity. First, we got a complete understanding of all the different parts of industrial machines and the functions related to each of them, and after collecting the relevant data, we calculated the productivity, the results of which can be seen in Table 1. Finally, for Examining the problem in Matlab software, we modeled the fuzzy-neural network to predict machine failure. After modeling the fuzzy-neural network, as expected, we saw the prediction of the duration of the failure of industrial machines, and the results are in the results table. The modeling output is presented in Table 3.

Table 3- Anfis results of MATLAB software

Waiting time (minutes)	Repair time (minutes)	Machine working time (minutes)	Device life (years)	Downtime (minutes)	Estimation of Anfis model	Comparison (difference between real and output downtime)
30	90	540	6	120	119.9991	0.0008
120	120	420	25	240	239.9961	0.0038
780	180	360	6	960	959.9954	0.0045
10	110	540	5	120	119.9984	0.0015
420	120	780	5	540	539.9943	0.0056

According to the obtained results, the accuracy rate of the modeled fuzzy-neural network is 94% and its error rate is 6%, which indicates the high accuracy rate of the fuzzy-neural network and the low error rate of this artificial network in predicting the failure of industrial machines.

As mentioned earlier, the other aspect considered in this study is the increase in productivity, which after doing the modeling, it was concluded that the reduction in the duration of breakdowns and repairs and the reduction in network costs lead to an increase in the working time and The availability of machines is increased and finally the productivity increases.

Reference

- [1] Knapp, G. M., & Wang, H. P. (1992). Machine fault classification: a neural network approach. *International Journal of Production Research*, 30(4), 811-823.
- [2] Lei, Y., He, Z., & Zi, Y. (2008). A new approach to intelligent fault diagnosis of rotating machinery. *Expert Systems with applications*, 35(4), 1593-1600.
- [3] Wang, C. C., Kang, Y., Shen, P. C., Chang, Y. P., & Chung, Y. L. (2010). Applications of fault diagnosis in rotating machinery by using time series analysis with neural network. *Expert Systems with Applications*, 37(2), 1696-1702.
- [4] Zio, E., & Gola, G. (2009). A neuro-fuzzy technique for fault diagnosis and its application to rotating machinery. *Reliability Engineering & System Safety*, 94(1), 78-88.
- [5] Zhu, F., & Wu, Y. (2014). A rapid structural damage detection method using integrated ANFIS and interval modeling technique. *Applied Soft Computing*, 25, 473-484.
- [6] Ershadi, M. J., Qhanadi Taghizadeh, O., & Hadji Molana, S. M. (2021). Selection and performance estimation of Green Lean Six Sigma Projects: a hybrid approach of technology readiness level, data envelopment analysis, and ANFIS. *Environmental Science and Pollution Research*, 28(23), 29394-29411.
- [7] Venturini, F. (2015). The modern drivers of productivity. *Research Policy*, 44(2), 357-369.

