



دانشگاه صنعتی امیر کبیر
(پلی تکنیک تهران)

دوره چهل و پنجم، شماره ۲، زمستان ۱۳۹۲، صفحه ۱۰۵ تا ۱۱۸
Vol. 45, No. 2, winter 2013, pp. 105-118



نشریه علمی - پژوهشی امیرکبیر (مهندسی مکانیک)
Amirkabir Journal of Science & Research (Mechanical Engineering)
(AJSR - ME)

استفاده از روش‌های هوشمند فازی - عصبی و شبکه‌های عصبی چند لایه در تشخیص عیوب اصلی ماشین‌های دوار

مجید نوری کمری^۱، غلامحسین پایگانه^{۲*}، مهرداد نوری خاجوی^۳

۱- دانشجوی کارشناسی ارشد، دانشکده مکانیک، دانشگاه تربیت دبیر شهید رجایی

۲- استادیار، دانشکده مهندسی مکانیک، دانشگاه تربیت دبیر شهید رجایی

۳- استادیار، دانشکده مهندسی مکانیک، دانشگاه تربیت دبیر شهید رجایی

(دریافت ۱۳۹۰/۶/۱۵، پذیرش ۱۳۹۲/۷/۱۶)

چکیده

امروزه عیب‌یابی ماشین‌های دوار از راه تشخیص علائم شروع و رشد عیب با استفاده از روش‌های هوشمند، شناسایی علت و قطعات آسیب دیده و پیشگویی میزان عمرکاری باقیمانده ماشین، نقش مهمی در جلوگیری از آسیب‌دیدگی شدید ماشین و هزینه‌های بالای تعمیرات بر عهده دارند. هدف این تحقیق نیز استفاده از ساختار هوشمند شبکه‌های فازی-عصبی و عصبی چند لایه در تشخیص عیوب اصلی ماشین‌های دوار از جمله نابالانسی، ناهمراستایی، خرابی بیرینگ و لقی مکانیکی است. لذا در این تحقیق علاوه بر ایجاد روشی خودکار برای تشخیص عیب، در جهت افزایش دقت و سرعت این شبکه‌ها نیز تلاش شده است. در این راستا، با استفاده از روش تحلیل اجزای اصلی ابعاد ماتریس ورودی در حد مطلوب کاهش داده شد و نیز کارایی دو شبکه هوشمند فازی-عصبی و عصبی چند لایه، در تشخیص عیوب با یکدیگر مقایسه شد. جهت دستیابی به هدف فوق، شبکه‌های گفته شده با استفاده از بردارهای ویژگی و مشخصات استخراج شده از طیف‌های فرکانسی و موج‌های زمانی، آموزش دیده شدند. نتایج نشان داد که برای ۸۴ مورد اندازه‌گیری نهایی، شبکه‌های فازی-عصبی و عصبی چند لایه به ترتیب دارای میانگین ۹۱ و ۷۸ درصد موفقیت در تشخیص درست عیوب بودند.

کلمات کلیدی

ماشین‌های دوار، طبقه‌بندی عیوب، سامانه استنتاج تطبیقی فازی-عصبی، شبکه‌های عصبی چند لایه.

* نویسنده مسئول وعهده دار مکاتبات Email: g.payganeh@srutu.edu

۱- مقدمه

نگهداری و تعمیرات به مجموعه فعالیت‌هایی گفته می‌شود که سبب افزایش عمر مفید ماشین‌ها شده و همچنین کاهش مصرف قطعات یدکی، انرژی و هزینه را نیز دنبال دارد و کارایی و راندمان عملی ماشین‌ها را افزایش می‌دهد [۱]. به طور کلی اصلی‌ترین هدف سامانه نگهداری و تعمیرات، بهینه نمودن توانایی ماشین‌آلات، به منظور رسیدن به حداکثر تولید و کاهش فرسایش و خرابی آنها است [۲].

پیشرفت سریع فناوری و همه‌گیر شدن صنعت و گسترش آن در تمامی نقاط جهان و افزایش سرمایه‌گذاری‌ها در صنایع و محدودیتی که در منابع و مواد اولیه مورد نیاز وجود دارد، مسئله کارایی و بهره‌وری را به صورت مهم‌ترین مسئله نزد صاحبان صنایع و مدیران مسئول صنعت مطرح نموده است [۳]. از طرفی امروزه از بیشتر سامانه‌های تولیدی، خدماتی و تاسیساتی انتظار می‌رود که در ساعات کار طولانی از کار افتادگی غیر منتظره نداشته باشند، این در حالی است که شکست و ایجاد عیب در زمان‌هایی از دوره عمر قطعات موجب بوجود آمدن خسارات و هزینه‌های جبران‌ناپذیر و کاهش بهره‌وری می‌شود [۴]. بنابراین برای جلوگیری از کاهش کیفیت خط تولید و هزینه‌های متعاقب ناشی از آن، نگهداری و تعمیرات به‌عنوان یکی از مهم‌ترین راه کارهای مؤثر که به صورت برنامه‌ریزی شده و هدفدار انجام می‌گیرد، مطرح است [۵].

امروزه برای تشخیص عیوب ماشین‌های دوار از روش‌های مختلفی استفاده می‌شود که از آن جمله می‌توان به روش‌های آماری [۷و۶]، تحلیل ارتعاشات [۸و۹]، تحلیل حوزه زمان [۱۰]، تحلیل المان محدود [۱۱]، شبکه‌های عصبی چند لایه^۱ (MLP) و سامانه استنتاج تطبیقی فازی - عصبی^۲ (ANFIS) [۱۲] اشاره نمود. از بین این روش‌ها، دو روش شبکه عصبی چند لایه و سامانه استنتاج تطبیقی فازی - عصبی بدلیل 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 ماشین‌های دوار در حال گسترش هستند [۱۳].

در سال ۲۰۰۹ تحقیقی توسط وینگ و همکاران [۱۴] در زمینه عیب‌یابی ماشین‌های دوار به کمک شبکه عصبی انجام شد. در این مقاله چهار عیب نابالاسی، ناهمراستایی، خرابی بیرینگ و شلاق زدن روغن را بر روی دستگاه آزمایش بطور 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 ۴ بود. عمل عیب‌یابی با سه روش ضرایب مختلف، تکرار شده و مشخص شد که روش ضرایب مختلف از دو نوع دیگر بهتر است. در سال ۲۰۰۸ تحقیقی توسط لی و همکاران [۱۵] به نام «یک شیوه جدید برای عیب‌یابی ماشین‌های دوار» انجام شده است. در این تحقیق برای عیب‌یابی بیرینگ‌های نوع شیار عمیق، بر مبنای تحلیل آماری و روش بهبود یافته با استفاده از شبکه فازی-عصبی و شبکه عصبی چند لایه انجام شده است. نتایج بدست آمده از این تحقیق نشان داد که در طبقه‌بندی عیوب، روش شبکه فازی-عصبی نسبت به روش شبکه عصبی چند لایه کارایی بیشتری دارد. در مطالعه انجام شده توسط زیو و گولا [۱۶] از روش فازی-عصبی در عیب‌یابی ماشین‌های دوار استفاده شده است. در این مطالعه هدف اصلی بالا بردن میزان درستی طبقه‌بندی بوده که نتایج نشان دادند که این روش می‌تواند در تشخیص عیب و سپس کاربرد آن به صورت پایه‌ای برای طبقه‌بندی عیوب بیرینگ‌ها و خطاهای آنها مورد استفاده قرار گیرد.

هدف این پژوهش، تشخیص عیوب ماشین‌های دوار با رویکرد نگهداری و تعمیرات پیشگیرانه مبتنی بر شرایط دستگاه و استفاده از ساختارهای هوشمند شبکه فازی-عصبی و شبکه عصبی چند لایه و مقایسه کارایی دو روش گفته شده در تشخیص عیوب است. همچنین با استفاده از روش تحلیل اجزای اصلی در جهت افزایش دقت و سرعت این شبکه‌ها تلاش شده و با در نظر گرفتن نیازهای واقعی که در عمل پیش می‌آید، ساختار اطلاعاتی مورد نظر تهیه شده است.

۲- مواد و روش


عیوب موجود در یک ماشین دوار به دلیل انواع بسیار گوناگون ماشین‌های دوار غیر قابل شمارش و در بعضی اوقات ناشناخته می‌باشند. بنابراین در این تحقیق به بررسی برخی از عیوب اصلی که در تمام ماشین‌های دوار مشترک بوده، پرداخته می‌شود. برای انجام این کار از تجهیزات مورد نیاز، روش‌ها و مراحل زیر استفاده شده است.

۲-۱- طراحی و ساخت طرح ماشین دوار و ایجاد عیوب در آن

برای اندازه‌گیری و جمع‌آوری اطلاعات و داده‌های مورد لزوم طراحی از یک ماشین دوار طراحی و ساخته شد. طرح روتور-موتور ساخته شده در شکل (۱) نشان داده شده است.

الکتروموتور سه فاز با قدرت ۰/۲۵ کیلووات و یک دستگاه کنترل دور قبل از موتور و در مدار آن استفاده شد و قابلیت تغییر دور از ۱rpm تا ۱۵۰۰ rpm در خروجی موتور فراهم شد.

پس از ایجاد هر یک از عیوب به طور جداگانه بر روی طرح ماشین دوار ساخته شده، ویژگی‌های ارتعاشی مورد نظر توسط دستگاه تحلیل گر ADASH 4400 به دست آمد. این دستگاه دارای ۴ حسگر تک جهته و یک حسگر سه جهته پیزوالکتریک شتابسنج بوده و نیز قابلیت اندازه‌گیری هر سه عامل ارتعاشی جابجایی، سرعت و شتاب را دارد، که در این تحقیق از عامل سرعت استفاده شد.



شکل (۱): طرح ماشین دوار ساخته شده

۲-۲- انتخاب ویژگی‌های ارتعاشی مناسب برای تشخیص عیب
برای اجرای پایش وضعیت و نگهداری و تشخیص عیوب ماشین-های دوار، قبل از هر چیز انتخاب تعداد کافی از عوامل و ویژگی-های مناسب که توانایی توصیف وضعیت ارتعاشات ماشین را داشته باشند، امری ضروری است. تعداد این مشخصه‌ها در صورتی که بیش از تعداد مورد نیاز انتخاب شوند، منجر به صرف زمان و هزینه مضاعف برای تحلیل وضعیت ماشین خواهند شد. همچنین اگر تعداد مشخصه‌ها کمتر از تعداد لازم انتخاب شوند (در واقع تعدادی از مشخصه‌های کلیدی، را از دست خواهیم داد)، در این صورت اطلاعات کافی برای تشخیص درست عیب به دست نخواهد آمد.

از مشخصه‌های معروف در حوزه زمان می‌توان به ریشه میانگین مربعات، عامل کروتوسیسی و کرسرست عامل و در حوزه فرکانس، به اندازه دامنه طیف‌ها در طیف فرکانسی، انرژی فرکانس بالا و غیره اشاره نمود. در واقع انتخاب عوامل مشخصه مناسب، اصلی‌ترین مسأله در طبقه‌بندی عیوب است و انتخاب صحیح آنها موجب بالا رفتن قدرت طبقه‌بندی می‌شود. لذا در این تحقیق ابتدا با در نظر گرفتن یک وضعیت کلی، ۱۲ ویژگی ارتعاشی شامل قله، میانگین، میانگین مطلق، ریشه میانگین مربعات، نسبت پیک به میانگین، عامل کرسرست، عامل ایمپالس، عامل شکل، عامل آزاد، مقدار کروتوسیسی، انرژی و انرژی بهینه مورد استفاده قرار گرفته شد (روابط ۱ تا ۱۲). از این ۱۲ مشخصه به ترتیب ۱۰ ویژگی در حوزه زمان و ۲ ویژگی در حوزه فرکانس انتخاب شده است. در ادامه ابعاد ماتریس مشخصه‌ها توسط روش‌های مبنی بر فشرده سازی مجموعه ویژگی‌های ورودی (PCA) کاهش یافته است.

$$\Delta V = \frac{1}{2} [\max\{V[n]\} - \min\{V[n]\}] \quad (1)$$

با توجه به جداول تخمین درصد پیش آمدن انواع عیوب و طبق آمارهای موجود در جداول گفته شده، بیش از ۸۵٪ اشکالات ایجاد شده در ماشین‌های دوار مربوط به عیوب نابالانسی، ناهمراستایی، خرابی بیرینگ و لقی مکانیکی می‌باشد. بنابراین در این تحقیق عیوب فوق در طرح روتور-موتور ساخته شده ایجاد شده است.

ایجاد عیب نابالانسی با مونتاژ نمودن دو دیسک بر روی محور ماشین انجام شد. از سوی دیگر، بدلیل تحقیقاتی بودن پژوهش، شرایط و نحوه‌ی مونتاژ باید بسیار قابل قبول و آزمایشگاهی بوده و محور یا روتور در زمان آزمایش، مونتاژ و دمونتاژهای متناوب حین تحقیق از حالت بالانس خارج نشود. به همین دلیل پس از مونتاژ نمودن دیسک‌ها بر روی محور، مجموعه به طور کامل بالانس دینامیکی شد. همچنین برای ایجاد نابالانسی و قرار دادن جرم‌ها، سوراخ‌هایی بر روی دیسک به وجود آمد و از پیچ و مهره در وزن‌های مختلف ۵گرم تا ۵۰گرم استفاده شد. سپس همراستایی حالت نرمال روتور به درستی رعایت شد و سوراخ پیچ‌های یاتاقان به شیوه‌ای طراحی شد که قابلیت جابجایی در هنگام ایجاد عیب ناهمراستایی را فراهم نماید. بنابراین ناهمراستایی زاویه‌ای با جابجا شدن یاتاقان‌های دو پایه‌ی روتور ایجاد شد، همچنین با توجه به نوع یاتاقان به کار رفته در مدل ماشین دوار، دو عدد بیرینگ نوع UC204 با حلقه خارجی صدمه دیده، در زمان ایجاد خرابی بیرینگ استفاده شد. در پایان، عیب لقی محفظه بیرینگ با شل نمودن پیچ پایه‌ی یاتاقان‌ها انجام شد،

طرح ماشین دوار ساخته شده علاوه بر قابلیت‌های گفته شده باید توانایی ایجاد دوره‌های مختلف را نیز داشته باشد، زیرا اطلاعات و داده‌های ورودی شبکه‌های هوشمند فازی-عصبی و عصبی چند لایه باید در دوره‌ها و تعداد زیادی از اندازه‌گیری‌های مختلف انجام شود، بنابراین برای دستیابی به هدف فوق، از یک

سپس با استفاده از برنامه نوشته شده در نرم افزار مطلب، بردارهای ویژگی و مشخصات آنها به صورت آماری استخراج شدند. گفتنی است که، برنامه نوشته شده در نرم افزار مطلب در عین حال قادر خواهد بود که تمام مشخصه‌های تعریف شده در خود را برای تمامی ورودی‌ها یا به عبارت دیگر برای تمام اندازه-گیری‌هایی که به آن داده می‌شود، استخراج نماید.

هر یک از ۸۴ مورد اندازه‌گیری نهایی این تحقیق که متعلق به چهار نوع عیب اصلی نابالانسی، ناهمراستایی، خرابی بیرینگ و لقی مکانیکی هستند شامل ۱۲۸۰۰ نمونه اندازه‌گیری بوده که این تعداد نمونه را به بازه‌های ۱۰۰ تایی تقسیم نموده و برای هر بازه تعداد ۱۲ ویژگی ارتعاشی استخراج شده است. با این تفسیر ابعاد ماتریس ویژگی مربوط به هر اندازه‌گیری (۱۲۸×۱۲) بوده که با توجه به انتخاب ۲۱ نمونه اندازه‌گیری نهایی برای هر عیب ابعاد ماتریس مربوطه (۲۵۲×۱۲۸) به دست آمد. در واقع این ماتریس، ورودی شبکه فازی-عصبی و شبکه عصبی پرسپترون چند لایه است. بنابراین با توجه به در نظر گرفتن حداقل ۳ تابع عضویت برای هر ورودی در سامانه فازی، تعداد قوانین موجود برای طراحی شبکه فازی-عصبی موردنظر برابر با ۳ به توان ۲۵۲ قانون است. با این وجود برای کاهش ابعاد ماتریس ورودی و افزایش دقت و سرعت محاسبات شبکه با استفاده از روش تحلیل اجزای اصلی و نوشتن برنامه مورد نظر در نرم افزار مطلب و انتخاب مؤلفه‌های اساسی، ابعاد ماتریس موردنظر به (۴×۱۲۸) مؤلفه کاهش داده شد. برای آموزش و آزمون شبکه نیز به ترتیب از ۲/۳ و ۱/۳ کل داده‌های موجود استفاده شده است.

۲-۳- کاهش ابعاد ماتریس ویژگی با استفاده از الگوریتم تحلیل

اجزای اصلی

در این روش محورهای مختصات جدیدی برای داده‌ها تعریف شد و داده‌ها بر اساس این محورهای مختصات جدید بیان شدند. اولین محور در جهتی قرار گرفته که واریانس داده‌ها بیشینه شود (یعنی در جهتی که پراکندگی داده‌ها بیشتر است). دومین محور عمود بر محور اول به گونه‌ای قرار گرفته، که در جهت بیش‌ترین پراکندگی داده‌ها باشد.

مفاهیم ریاضی و آماری مرتبط با این روش به طور مختصر عبارتند از: انحراف از معیار استاندارد، کواریانس، بردارهای ویژه و مقادیر ویژه X رشته‌ای از داده‌ها بوده و میانگین این مقادیر از روابطه (۱۳) و (۱۴) بدست آمد:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i \quad (13)$$

$$\bar{V} = \frac{1}{N} \sum_{n=0}^{N-1} V[n] \quad (2)$$

$$DV = \frac{1}{N} \sum_{n=0}^{N-1} |V[n]| \quad (3)$$

$$RMS = \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} (V[n] - \bar{V})^2} \quad (4)$$

$$PAR = \frac{1}{|\bar{V}|} \max\{|V[n]|\} \quad (5)$$

$$Kv = \frac{\frac{1}{N} \sum_{n=0}^{N-1} (V[n] - \bar{V})^4}{RMS^4} \quad (6)$$

$$CF = \frac{\Delta V}{RMS} \quad (7)$$

$$IF = \frac{\Delta V}{|\bar{V}|} \quad (8)$$

$$SF = \frac{RMS}{|\bar{V}|} \quad (9)$$

$$CLF = \frac{\Delta V}{\frac{1}{N} \left\{ \sum_{n=0}^{N-1} \sqrt{|V[n]|} \right\}^2} \quad (10)$$

$$E = \sum_{k=0}^{K-1} |S[k]|^2 \quad (11)$$

$$E_N = \frac{1}{K} \sum_{k=0}^{K-1} |S[k]|^2 \quad (12)$$

که در معادلات فوق:

ΔV : میزان تغییرات قله بر حسب میلی متر بر ثانیه؛ $\max\{V[n]\}$ و $\min\{V[n]\}$: به ترتیب بیشترین و کمترین مقدار قله در فرکانس‌های مختلف؛ \bar{V} : میانگین مقادیر ویژه بر حسب میلی‌متر بر ثانیه؛ N : تعداد مقادیر ویژه؛ $V[n]$: مقدار ویژه در فرکانس‌های مختلف؛ DV : میانگین مطلق مقادیر ویژه بر حسب میلی‌متر بر ثانیه؛ RMS ریشه میانگین مربعات بر حسب میلی‌متر بر ثانیه؛ PAR : نسبت پیک به میانگین؛ Kv : مقدار کرتوسیس؛ CF : عامل کرتس؛ IF : عامل ایمپالس؛ SF : عامل شکل؛ CLF : عامل آزاد؛ E : انرژی بر حسب میلی‌متر بر مجذور ثانیه و E_N : انرژی بهینه بر حسب میلی‌متر بر مجذور ثانیه هستند.

به طوری که گفته شد، اندازه‌گیری‌ها با استفاده از دستگاه ADASH 4400 طی زمان‌های مشخص جمع‌آوری شد و

که در معادله فوق:

\bar{X} : میانگین داده‌ها در جهت محور X ها؛ n تعداد کل داده‌های موجود و x_i مقدار هر داده در جهت محور X ها است. واریانس داده‌ها از رابطه شماره (۱۴) محاسبه شد:

$$V(X) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (14)$$

علت اینکه در رابطه فوق از عبارت $n-1$ بجای n استفاده شده، فرض شده تمام مقادیر موجود نیستند، بلکه تعدادی از این مقادیر انتخاب شده و در X قرار گرفته‌اند یعنی مجموعه از نمونه‌ها است نه کل داده‌ها با این فرض اگر $n-1$ در رابطه فوق استفاده شود به واریانس داده‌های واقعی نسبت به وقتی که از n استفاده شود، نزدیک‌تر خواهد بود.

مشکلی که در واریانس وجود دارد این است که نمی‌توان آن را به راحتی با خود ویژگی مقایسه نمود. زیرا اگر ویژگی بر حسب متر باشد، $x_i - \bar{x}$ نیز بر حسب متر بوده در حالی که $(x_i - \bar{x})^2$ بر حسب متر مربع خواهد بود؛ بنابراین قابل مقایسه نبوده و برای رفع این مشکل از جذر مثبت واریانس، انحراف معیار یا انحراف استاندارد استفاده شد (رابطه ۱۵).

$$\sigma = \sqrt{V(X)} \quad (15)$$

معیارهایی که در بالا گفته شد فقط اطلاعات مربوط به یک بعد را ارائه می‌دهند و دانشی در مورد ارتباط بین ابعاد مختلف را نشان نمی‌دهند، بنابراین با استفاده از کواریانس ارتباط بین ابعاد مختلف داده‌ها پیدا شده است. رشته دیگری از داده‌ها را با Y نشان داده و کواریانس بین X, Y از رابطه (۱۶) بدست آمد:

$$\text{Cov}(X, Y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \quad (16)$$

که در معادله فوق:

\bar{Y} : میانگین داده‌ها در جهت محور Y ها و y_i : مقدار هر داده در جهت محور Y ها است.

اگر $\text{Cov}(X, Y) > 0$ آنگاه X, Y مشابه هم تغییر می‌نمایند.

اگر $\text{Cov}(X, Y) < 0$ آنگاه X, Y متضاد هم تغییر می‌نمایند.

۲-۴- استفاده از شبکه‌های فازی-عصبی و عصبی چند لایه برای طبقه‌بندی عیوب

از آنجا که سامانه‌های هوشمند در شرایط وجود عدم قطعیت و نادقیقی عملکرد قابل قبولی دارند و با توجه به خاصیت‌های اصلی شبکه‌های عصبی، یعنی؛ تخمین قدرتمند توابع غیرخطی و قابلیت یادگیری تطبیقی و نیز خاصیت اصلی سامانه‌های فازی، یعنی؛ استفاده از دانش خبره در به دست آوردن رابطه بین

ورودی و خروجی، در این تحقیق از شبکه‌های هوشمند فازی-عصبی و عصبی چند لایه برای طبقه‌بندی عیوب استفاده شده است. برای این منظور با استفاده از نرم افزار مطلب شبکه‌های گفته شده به صورت زیر طراحی شدند.

۲-۴-۱- طراحی شبکه عصبی پرسپترون چند لایه

برای بهره‌گیری از شبکه عصبی چند لایه از الگوریتم زیر استفاده شده است.

- انتخاب مقادیر اولیه ضرایب وزنی و آستانه‌ها برابر با اعداد کوچک تصادفی.
- ارائه ورودی‌ها و خروجی‌های مطلوب به شبکه.
- مقادیر خروجی در هر لایه توسط رابطه (۱۷) محاسبه و به لایه بعدی انتقال یافته است:

$$y_{pj} = F \left[\sum_{i=0}^{n-1} w_{ij} x_i \right] \quad (17)$$

که در معادله فوق:

F : تابع فعال‌سازی تانژانت-سیگموئید؛ n : تعداد عناصر بردار ورودی؛ w_{ij} : ضرایب وزنی؛ x_i : عناصر بردار ورودی هستند.

تنظیم ضرایب وزنی برای لایه‌های مختلف به ترتیب از لایه خروجی شروع و به سمت لایه‌های عقب توسط رابطه (۱۸) انجام شده است.

$$w_{ij}(t+1) = w_{ij}(t) + n \delta_{pj} \cdot p_j \quad (18)$$

که در این طرح، w_{ij} ؛ نشان‌دهنده ضرایب وزنی از گره i به گره j در زمان t ، n ؛ ضریب بهره و δ_{pj} نمایانگر خطای مربوط به الگوی p در گره j است.

برای لایه‌های خروجی و پنهان از روابط (۱۹) و (۲۰) استفاده شده است.

$$\delta_{pj} = k o_{pj} (1 - o_{pj}) (t_{pj} - o_{pj}) \quad (19)$$

$$\delta_{pj} = k o_{pj} (1 - o_{pj}) \sum_k \delta_{pk} w_{jk} \quad (20)$$

که در معادلات فوق:

o_{pj} : خروجی واقعی الگوی p در گره j ؛ t_{pj} : خروجی مطلوب الگوی p در گره j و $\sum_k \delta_{pk} w_{jk}$: ورودی خالص j برای الگوی p هستند.

در این شبکه از ۵۱۲ مشخصه مربوط به عیوب مختلف به صورت؛ شماره ۱: عیب مربوط به نابالانسی، شامل ۱۲۸ مشخصه؛ شماره ۲: عیب مربوط به ناهمراستای زاویه‌ای، شامل ۱۲۸ مشخصه؛

با در نظر گرفتن خطای مورد نظر^۷ و تعداد عبور از کل داده‌ها^۸ که دو شرط برای توقف فرایند آموزش هستند، آموزش شبکه انجام شد.

۲-۴-۲- طراحی شبکه فازی - عصبی

ساختار شبکه فازی - عصبی طراحی شده از پنج لایه به شرح زیر تشکیل شد (شکل ۲) [۱۷].

• لایه اول، گره‌های ورودی: در این لایه درجه عضویت گره‌های ورودی به بازه‌های مختلف فازی با استفاده از تابع عضویت مشخص شد (روابط ۲۲ و ۲۳).

$$i=Q_i^1 = \mu_{A_i}(x) \quad ۱و۲ \quad (۲۲)$$

$$i=Q_i^1 = \mu_{A_{i-2}}(x) \quad ۳و۴ \quad (۲۳)$$

عوامل هر گره تعیین کننده شکل تابع عضویت فازی آن گره است. تابع عضویت مجموعه‌های فازی توسط رابطه (۲۴) بیان شد:

$$\mu_{A_i} = \frac{1}{1 + \left(\frac{x - c_i}{a_i}\right)^{2b_i}} \quad (۲۴)$$

که در این رابطه X مقدار ورودی به گره i بوده و مجموعه $S_1 = \{a_i, b_i, c_i\}$ عوامل تطبیقی^۹ نامیده می‌شود.

• لایه دوم، گره‌های قاعدی: در این لایه هر گره درجه فعالیت یک قانون را محاسبه می‌نماید (رابطه ۲۵).

$$Q_i^2 = W_i = \mu_{A_i}(X) \times \mu_{B_i}(y) \quad , \quad i = 1,2 \quad (۲۵)$$

که در این رابطه: μ_{A_i} : درجه عضویت X در مجموعه A_i و $\mu_{B_i}(y)$: درجه عضویت y در مجموعه B_i است.

• لایه سوم، گره‌های متوسط: در این لایه i امین گره، نسبت درجه فعالیت قانون i ام را به مجموع درجه فعالیت کلیه قوانین به صورت رابطه (۲۶) بهینه می‌شود:

$$i=O_i^3 = \bar{w}_i = \frac{w_i}{\sum_{i=1}^n w_i} \quad , \quad ۱و۲ \quad (۲۶)$$

که در این رابطه: \bar{w}_i : درجه فعالیت بهینه شده قانون i ام است.

• لایه چهارم، گره‌های نتیجه: در این لایه، خروجی هر گره به صورت رابطه (۲۷) بدست آمده است:

$$i=O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad , \quad ۱و۲ \quad (۲۷)$$

مجموعه $S_2 = \{p_i, q_i, r_i\}$ عوامل متعاقب^۹ نامیده می‌شوند.

• لایه پنجم، گره‌های خروجی: در این لایه مقدار خروجی نهایی هر گره به صورت رابطه (۲۸) محاسبه شد (تعداد گره‌ها برابر تعداد خروجی هاست):

شماره ۳: عیب مربوط به لقی، شامل ۱۲۸ مشخصه و شماره ۴: عیب مربوط به خرابی بیرینگ، شامل ۱۲۸ مشخصه استفاده شده است. از میان تمامی عیوب به صورت اتفاقی تعدادی مشخصه را به عنوان داده‌های آموزشی و مابقی برای داده‌های آزمایش در نظر گرفته شد. در مجموع داده‌ها به دو دسته آموزشی شامل ۳۴۲ داده و دسته آزمایشی شامل ۱۷۰ داده تقسیم شدند. با استفاده از روش تحلیل اجزای اصلی و کاهش ابعاد ویژگی، ورودی شبکه برای آموزش به صورت یک ماتریس (4×342) و برای آزمایش شبکه یک ماتریس (4×170) در نظر گرفته شد.

شبکه مورد استفاده شامل سه لایه، ورودی، پنهان و خروجی است. برای یافتن تعداد بهینه نرون‌ها در لایه اول و پنهان با استفاده از سعی و خطا بهترین تعداد انتخاب شد. برای کنترل سهم هر مشخصه در تعدیل وزن‌ها و آموزش شبکه، داده‌های مورد استفاده بهینه شدند تا عوامل موجود در محدوده $[-1, +1]$ به شبکه ارائه شوند.

با توجه به وجود چهار طبقه مختلف برای عیوب و در نظر گرفتن چهار خروجی مطلوب، لایه خروجی شبکه دارای چهار نرون خواهد بود. برای بهینه نمودن روند آموزش و حضور تمامی پرسپترون‌ها در روند آموزش (در اصطلاح جلوگیری از مرگ پرسپترون) خروجی مطلوب بصورت ماتریسی حاوی مقادیر غیر صحیح بصورت زیر به شبکه ارائه شد.

$$۱ = [0, 9, 0, 1, 0, 1, 0, 1]$$

$$۲ = [0, 1, 0, 9, 0, 1, 0, 1]$$

$$۳ = [0, 1, 0, 1, 0, 9, 0, 1]$$

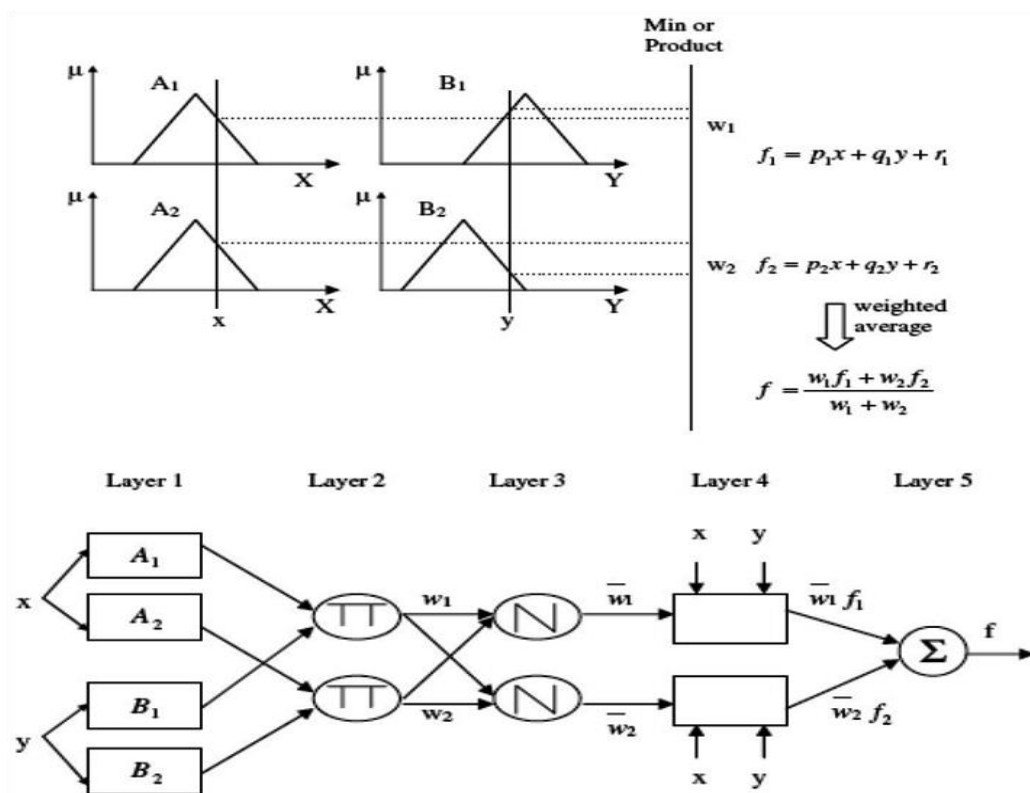
$$۴ = [0, 1, 0, 1, 0, 1, 0, 9]$$

در نتیجه خروجی شبکه نیز در حالت آموزش به صورت یک ماتریس 4×342 و در حالت آزمایش به صورت یک ماتریس 4×170 به دست آمد. برای آموزش این نوع شبکه از الگوریتم پیش فرض لونیبرگ مارکوارت (LM) استفاده شده است. هم-چنین در شبکه فوق از تابع فعال‌سازی تانژانت-سیگموئید^{۱۰} برای هر پرسپترون استفاده شد. برای تابع کارایی معمول مورد استفاده در شبکه‌های پیش‌خور از مجموع مربعات خطاها استفاده شده است (رابطه ۲۱).

$$f = mse = \frac{1}{n} \sum_{i=1}^n (e_i^2) = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (۲۱)$$

که در این مدل: e_i : خطای شبکه؛ t_i : خروجی مطلوب و a_i : خروجی واقعی است.

$$O_i^5 = \sum_{i=1}^n \bar{w}_i f_i \quad (28)$$



شکل (۲): یک سامانه فازی سوگنو با تابع عضویت مثلثی و سامانه هوشمند فازی-عصبی معادل با آن [۱۷]

در این شبکه نیز مانند شبکه عصبی چند لایه از ۵۱۲ مشخصه مربوط به عیوب مختلف به شرح زیر استفاده شده است:

- ✓ عیب شماره ۱: مربوط به نابالانسی، شامل ۱۲۸ مشخصه.
- ✓ عیب شماره ۲: مربوط به ناهمراستایی زاویه‌ای، شامل ۱۲۸ مشخصه.
- ✓ عیب شماره ۳: مربوط به لقی، شامل ۱۲۸ مشخصه.
- ✓ عیب شماره ۴: مربوط به خرابی بیرینگ، شامل ۱۲۸ مشخصه.

$$1 = \text{rand}(1,128) \text{ عیب شماره ۱}$$

$$2 = \text{rand}(1,128)+3 \text{ عیب شماره ۲}$$

$$3 = \text{rand}(1,128)+6 \text{ عیب شماره ۳}$$

$$4 = \text{rand}(1,128)+9 \text{ عیب شماره ۴}$$

در نتیجه خروجی شبکه نیز در حالت آموزش به صورت یک ماتریس 5×342 و در حالت آزمایش به صورت یک ماتریس 5×170 استفاده شده است.

در طراحی شبکه فازی-عصبی از شبکه عصبی چند لایه پیش-خور با الگوریتم یادگیری پس انتشار خطا و سامانه استنتاج فازی سوگنو با توابع عضویت اولیه تفاوت سه تابع سیگموئید استفاده شده است.

۳- نتایج:

نتایج مربوط به استفاده از شبکه عصبی چند لایه برای طبقه‌بندی و تشخیص عیوب موردنظر در جدول (۱) و شکل‌های (۳) تا (۵) نشان داده شده است.

نتایج مقایسه خروجی‌های مطلوب و خروجی‌های واقعی شبکه نشان می‌دهد که از ۱۲۸ مورد اندازه‌گیری مربوط به کل داده‌های هر عیب، شبکه عصبی چند لایه موردنظر تعداد ۱۰۵ مورد نابالانسی، ۹۲ مورد ناهمراستایی، ۱۰۲ مورد لقی مکانیکی و ۹۹ مورد خرابی بال بیرینگ را به صورت صحیح و در سایر موارد، عیوب را اشتباه تشخیص داده است (جدول شماره ۱).

قبل از پردازش، برای بهتر شدن فرایند آموزش و بالا بردن توان پیش‌بینی، داده‌ها بوسیله شبکه فازی-عصبی نرمال‌سازی شدند. بنابراین تبدیلی بر روی داده‌های ورودی به شبکه انجام شد تا اینکه داده‌ها در فاصله $[\alpha, \beta]$ قرار گیرند. این کار با استفاده از روابط (۲۹) تا (۳۱) انجام می‌شود:

$$X_{\text{scaled}} = mX_i + b \quad (29)$$

$$m = \frac{\beta - \alpha}{X_{\text{max}} - X_{\text{min}}} \quad (30)$$

$$b = \frac{X_{\text{max}} \cdot \alpha - X_{\text{min}} \cdot \beta}{X_{\text{max}} - X_{\text{min}}} \quad (31)$$

که در این روابطه α و β حد بالا و پایین فاصله نرمال‌سازی هستند. X_{max} و X_{min} نیز به ترتیب مقادیر کمینه و بیشینه X_i ها هستند. در این صورت رابطه گفته شده به شکل رابطه ساده شده (۳۲) مورد استفاده قرار گرفته است:

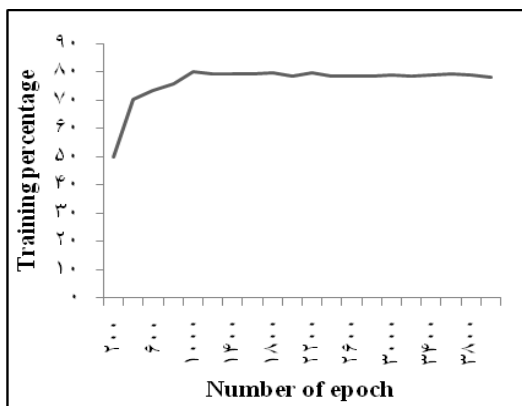
$$X_n = \frac{2(X - X_{\text{min}})}{X_{\text{max}} - X_{\text{min}}} - 1 \quad (32)$$

انتخاب فاصله $[\alpha, \beta]$ بسته به نوع مسئله موردنظر و تابع تبدیل انتخاب شده متفاوت است. فاصله‌هایی که بیشتر از بقیه مورد استفاده قرار می‌گیرند شامل $[0, 1]$ و $[-1, 1]$ هستند. در این تحقیق داده‌ها در فاصله $[-1, 1]$ بهینه شدند. در بین تمام عیوب به صورت اتفاقی تعدادی مشخصه را به عنوان داده‌های آموزشی و مابقی برای داده‌های آزمایش در نظر گرفته و در مجموع داده‌ها به دو دسته آموزشی شامل ۳۴۲ داده و دسته آزمایشی شامل

جدول (۱): نتایج حاصل از داده‌های آموزش و آزمایش شبکه

درستی کل	درستی آموزش و آزمایش	تعداد داده	نتایج آموزش و آزمایش				نوع عیب
			نابالانسی	ناهمراستایی	لقی	خرابی بیرینگ	
٪۷۸	٪۸۲	۱۲۸	۱۰۵	۱۳	۵	۵	نابالانسی
	٪۷۲	۱۲۸	۱۹	۹۲	۹	۸	ناهمراستایی
	٪۸۰	۱۲۸	۱۱	۷	۱۰۲	۸	لقی
	٪۷۸	۱۲۸	۸	۱۱	۱۰	۹۹	خرابی بیرینگ

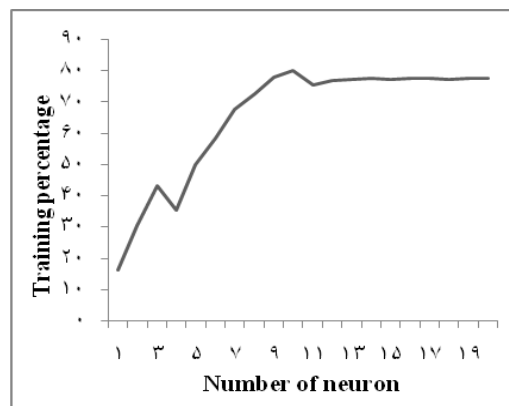
بررسی رابطه میان درصد آموزش شبکه و تعداد عبور داده‌ها نشان می‌دهد که با افزایش تعداد عبور داده‌ها، درصد آموزش شبکه نیز بهبود می‌یابد به طوری که با رسیدن تعداد عبور داده‌ها به ۱۰۰۰ تکرار، شبکه عصبی چند لایه بالاترین کارایی را به دست آورده است در حالیکه با افزایش تعداد عبور داده‌ها (بیشتر از ۱۰۰۰ تکرار) درصد آموزش شبکه تغییر محسوسی نداشته است (شکل ۴).



شکل (۴): منحنی درصد آموزش شبکه با توجه به تعداد تکرار عبور داده‌ها


کاهش یافته و در حد قابل قبولی از خطا همگرا شده است. در پایان، مقایسه همگرایی شبکه در بخش آموزش و آزمایش نشان-دهنده همگرایی بهتر و خطای کمتر در بخش آموزش است.

شکل شماره (۳) نشان می‌دهد که با افزایش تعداد نرون در لایه میانی، درصد آموزش شبکه بهبود یافته به طوری که با افزایش تعداد نرون‌ها به ۱۰ عدد در لایه میانی، شبکه بهترین عملکرد را از خود نشان داده است. البته همیشه میان افزایش تعداد نرون‌ها در لایه میانی و بهبود آموزش شبکه رابطه مستقیمی برقرار نیست چنانکه در این مطالعه، با افزایش تعداد نرون‌ها (بیشتر از ۱۰ نرون) درصد آموزش شبکه نه تنها افزایش نمی‌یابد بلکه در برخی موارد ثابت و یا با روند نزولی همراه است.



شکل (۳): منحنی درصد آموزش شبکه با تغییر تعداد نرون لایه میانی

با توجه به اینکه خطای موردنظر و تعداد عبور داده‌ها دو شرط اصلی برای توقف فرآیند آموزش هستند، شکل (۵) نشان می‌دهد که با افزایش تعداد عبور داده‌ها، خطای ایجاد شده که همان اختلاف بین خروجی واقعی شبکه و خروجی مطلوب است، دائماً



شکل (۵): مقایسه همگرایی خطا در آموزش و آزمایش شبکه

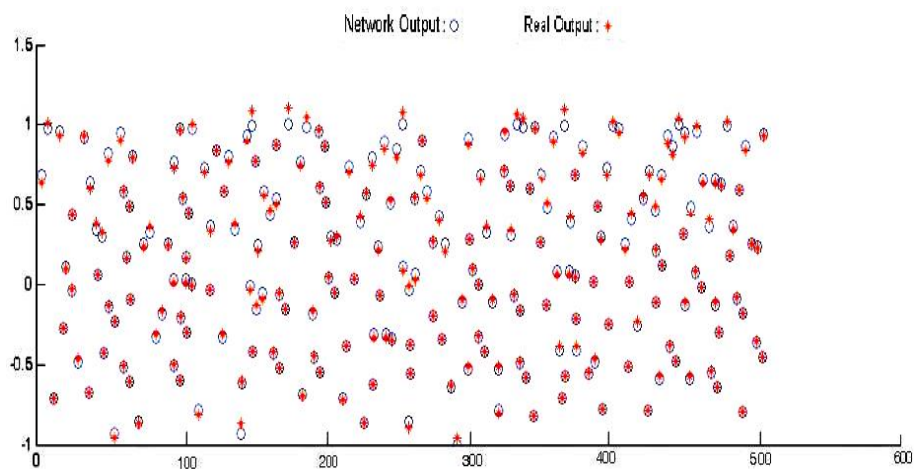
نتایج مربوط به شبکه فازی-عصبی برای طبقه‌بندی و تشخیص شده است
عیوب موردنظر در جدول (۲) و شکل‌های (۶) تا (۹) نشان داده

جدول (۲): نتایج حاصل از خروجی شبکه با استفاده از داده‌های آموزشی و آزمایشی

درستی کل	درستی آموزش و آزمایش	تعداد داده	نتایج آموزش و آزمایش				نوع عیب
			ناپالانسی	ناهمراستایی	لقی	خرابی بیرینگ	
%۹۱	%۹۷	۱۲۸	۱۲۵	۳	-	-	ناپالانسی
	%۸۲	۱۲۸	۱۱	۱۰۹	۶	۲	ناهمراستایی
	%۹۰/۵	۱۲۸	۳	۶	۱۱۸	۱	لقی
	%۹۲/۵	۱۲۸	۲	۴	۱	۱۲۱	خرابی بیرینگ

با توجه به ۵۱۲ مورد اندازه‌گیری نهایی مربوط به عیوب مختلف و بهینه‌سازی تمام داده‌ها، مقایسه خروجی واقعی و خروجی شبکه در شکل (۷) نشان می‌دهد که شبکه فازی-عصبی دارای تقریب قابل قبولی از خروجی واقعی نسبت به خروجی شبکه در مورد تشخیص عیوب است.

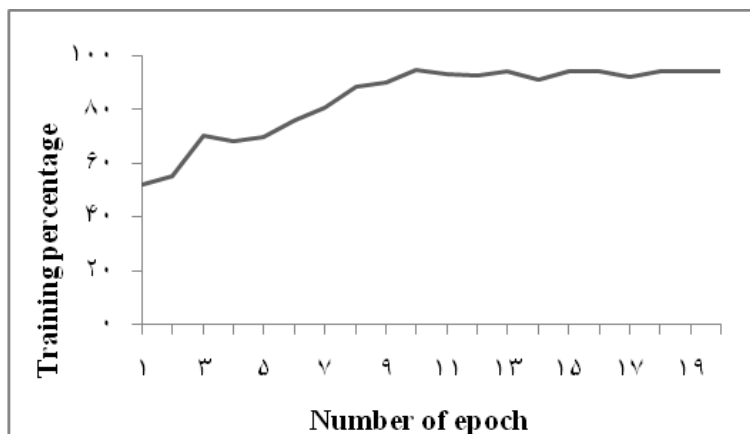
نتایج مقایسه خروجی‌های مطلوب و خروجی‌های واقعی شبکه در جدول شماره (۲) نشان می‌دهد که از ۱۲۸ مورد اندازه‌گیری مربوط به کل داده‌های هر عیب، شبکه فازی-عصبی موردنظر تعداد ۱۲۵ مورد ناپالانسی، ۱۰۹ مورد ناهمراستایی، ۱۱۸ مورد لقی مکانیکی و ۱۲۱ مورد خرابی بالیرینگ را به صورت صحیح و در سایر موارد، عیوب را اشتباه تشخیص داده است.



شکل (۷): مقایسه خروجی واقعی و خروجی شبکه در بخش آموزش و آزمایش

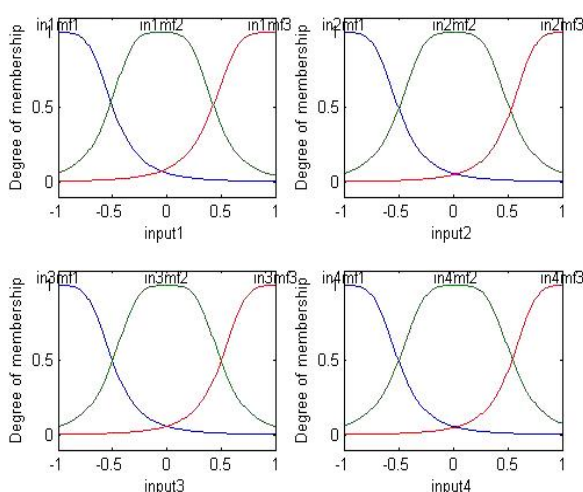
آموزش شبکه، همواره با افزایش تعداد عبور داده‌ها دارای روند افزایشی نیست و در برخی از موارد ثابت و یا با روند نزولی نیز همراه است

شکل (۶) نشان می‌دهد که با افزایش تعداد عبور داده‌ها، درصد آموزش شبکه فازی-عصبی نیز بهبود می‌یابد چنانکه با افزایش تعداد عبور داده‌ها به ۱۰ تکرار، بیشترین میزان کارایی شبکه به دست آمده است. نتایج همچنین نشان می‌دهند که درصد




شکل (۶): منحنی درصد آموزش شبکه بر اساس تعداد عبور داده‌ها

نتایج این مطالعه نشان می‌دهد که تغییرات موجود در توابع عضویت، قبل و بعد از آموزش شبکه فازی-عصبی بسیار کم است (شکل‌های ۸ و ۹).



شکل (۹): توابع عضویت بعد از آموزش شبکه



شکل (۸): توابع عضویت قبل از آموزش شبکه

۴- بحث و نتیجه‌گیری:

از نوآوری‌های این پژوهش، استفاده از اعداد تصادفی برای طبقه‌بندی و شناسایی عیوب توسط شبکه‌های فازی عصبی و نیز استفاده از اعداد اعشاری برای طبقه‌بندی عیوب در شبکه‌های عصبی چند لایه است. چنانچه نتایج مربوط به شبکه عصبی و شبکه فازی عصبی نشان داد که استفاده از این اعداد موجب بهینه نمودن نتایج و حضور تمامی پرسپترون‌ها در روند آموزش (به اصطلاح جلوگیری از مرگ پرسپترون) می‌شود. نتایج بررسی موج‌های زمانی و طیف‌های فرکانسی، دیدن مشخصه‌های ارتعاشی استخراج شده و استفاده از شبکه نشان داد که از میان ۱۲ ویژگی ارتعاشی مورد استفاده، بیش‌ترین اثر مربوط به عوامل

انرژی، انرژی بهینه و ریشه میانگین مربعات بود. هم‌چنین ویژگی‌های قله، میانگین، میانگین مطلق و نسبت قله به میانگین اهمیت و اثر کمتری نسبت به سایر ویژگی‌ها داشتند. علاوه بر این استفاده از روش تحلیل اجزای اصلی برای کاهش ابعاد ماتریس ورودی شبکه، منجر به تولید وزن‌ها و عوامل قابل تنظیم کمتری شد که نتیجه آن کاهش حجم محاسبات برای آموزش شبکه و افزایش سرعت و دقت در مرحله دسته بندی بود.

۴-۱- تحلیل نتایج شبکه عصبی پرسپترون چند لایه

نتایج مربوط به استفاده از شبکه عصبی چند لایه برای طبقه‌بندی و تشخیص عیوب موردنظر نشان داد که با افزایش تعداد

مقایسه با شبکه عصبی چند لایه دارای تقریب دقیق‌تری از مقادیر خروجی شبکه نسبت به مقادیر خروجی واقعی در نظر گرفته شده است و می‌توان دید که خطای ایجاد شده در شبکه فازی عصبی در بیشتر موارد بسیار کم بوده و به سادگی می‌توان عیب مربوطه را تشخیص داد. همچنین می‌توان دریافت که شبکه فازی عصبی با تعداد تکرار بسیار کمتر از شبکه عصبی چند لایه دارای محاسبات کمتر، سرعت و دقت بالاتر و میانگین ۹۱ درصد در تشخیص درست عیوب است. این نتایج چندان دور از انتظار نبود به طوری که مرجع [۱۶]، [۱۵] و [۱۸] نیز نتایج مشابهی در برتری شبکه‌های فازی عصبی در تشخیص عیوب مختلف در ماشین‌های دوار به‌دست آورده‌اند.

۵- نتیجه‌گیری

مطالعه انجام شده نشان داد، برای موفقیت در عیب‌یابی علاوه بر داشتن شناخت کامل نسبت به اجزای مختلف ماشین و فرکانس-های مربوط به هر یک، استفاده از روش‌های هوشمند جهت تعیین درصد هر عیب، امری ضروری است. از این رو، یکی از نکات بسیار مهم و اساسی در صنایع مختلف به خصوص صنایع سنگین را می‌توان نیاز به داشتن یک سامانه عیب‌یاب به صورت خودکار و هوشمند دانست و از آنجا که نتایج این مطالعه کارآیی بالاتر شبکه فازی عصبی را در مقایسه با شبکه عصبی چند لایه نشان می‌دهد، می‌تواند به عنوان روشی مناسب‌تر در جهت تشخیص هوشمند عیوب به کار برده شود.

در پایان برای دستیابی به نتایج بهتر برای تشخیص عیوب در ماشین‌های دوار می‌توان راه‌کارهایی را به صورت زیر پیشنهاد داد:

- اگر در بخش آموزش شبکه فازی عصبی که مربوط به عوامل خطی و غیر خطی است، از روش هوشمندی مانند الگوریتم ژنتیک برای آموزش پارامترهای غیر خطی استفاده شود، می‌توان نتایج بالا را تا حد ممکن بهبود بخشید.
- انتخاب ویژگی‌های برتر یکی از مراحل پایه و اصلی در بحث تشخیص عیوب ماشین آلات دوار است. بنابراین استفاده از روش‌های مناسب‌تر همچون فرایند تحلیل سلسله مراتبی مبنی بر انتخاب ویژگی‌های برتر می‌تواند مؤثر باشد.

عبور از کل داده‌ها، خطای ایجاد شده که همان اختلاف بین خروجی واقعی شبکه و خروجی مطلوب است، دائماً کاهش یافته تا به یک مقدار همگرا شد. همچنین نتایج مقایسه همگرایی شبکه در بخش آموزش و آزمایش نشان‌دهنده همگرایی بهتر و خطای کمتر در بخش آموزش شبکه است. نتایج مربوط به تغییر تعداد نرون لایه میانی نشان داد که شبکه گفته شده با داشتن ۱۰ نرون در لایه میانی بیشترین کارایی را از خود نشان می‌دهد. در حالیکه با افزایش تعداد نرون لایه میانی نه تنها فرآیند آموزش بهتر صورت نمی‌گیرد بلکه با افزایش محاسبات شبکه در پاره‌ای از موارد کاهش این مقدار را نیز شاهد خواهیم بود (شکل ۳). ارتباط بین آموزش شبکه و تعداد عبور داده‌ها از شبکه مشخص می‌نماید که با رسیدن به تعداد ۱۰۰۰ تکرار شبکه مذکور بالاترین کارایی را به‌دست می‌آورد (شکل ۴). در پایان نتایج نشان داد که شبکه عصبی پرسپترون چند لایه MLP با داشتن ۴ نرون در لایه ورودی و ۱۰ نرون در لایه میانی، دارای میانگین ۷۸ درصد در تشخیص درست عیوب است.

۴-۲- تحلیل نتایج شبکه فازی عصبی

نتایج مربوط به شبکه فازی عصبی برای طبقه‌بندی و تشخیص عیوب مورد نظر نشان داد که خطای ایجاد شده در بیشتر موارد بسیار کم بوده و به سادگی می‌توان عیب مربوطه را تشخیص داد. در این شبکه نیز مانند شبکه عصبی چند لایه برای بخش آموزش از ۲/۳ داده‌های موجود و برای آزمایش شبکه از ۱/۳ داده‌ها استفاده شده است. نتایج نشان داد که برای تعیین عامل تعداد عبور کل داده‌ها، شبکه با داشتن ۱۰ بار تکرار داده‌ها می‌تواند نتایج خوبی را کسب نماید. مقایسه توابع عضویت مربوط به قبل و بعد از آموزش نشان‌دهنده تغییر بسیار کم در این توابع و دقت بالای شبکه در بخش آموزش است. همچنین مقایسه خروجی واقعی و خروجی شبکه نیز گویای این حقیقت است که شبکه فازی عصبی دقت بسیار زیادی در تقریب خروجی واقعی دارد. در نهایت نتایج حاصل از خروجی شبکه با استفاده از داده‌های آموزشی و مقایسه خروجی واقعی و خروجی شبکه می‌دهد که شبکه فازی عصبی با داشتن ۱۹۳ گره و ۸۱ قانون دارای میانگین ۹۱ درصد در تشخیص درست عیوب است.

۴-۳- مقایسه نتایج شبکه فازی عصبی و شبکه عصبی چند

لایه

از مقایسه نتایج مربوط به شبکه‌های فازی عصبی و عصبی چند لایه این نکته را می‌توان دریافت که شبکه فازی عصبی در

۶- مراجع

- [۱۱] Chow, M.Y. and S. O., Yee ,“An adaptive back-propagation through time training algorithm for a neural controller”, Proc IEEE Int Symp Intell Control, 170-5, 1991.
- [۱۲] Chow M. Y. and Y. S., Lee ,“Motor Incipient Fault Detection using Artificial Neural Network and Fuzzy Logic Technologies, Computer Aided Maintenance, Methodology and Practices”, London, UK: Chapman & Hall, 1996.
- [۱۳] Chow, Li. B., Tipsuwan, M. Y. and Hung, J. C., “Neural-network-based motor rolling bearing fault diagnosis”, IEEE Trans Ind Electr, Vol.47, No.5, 1-2, 2000.
- [۱۴] Wang, C. C., Y., Kang, Shen, P. C., Chang, Y. P. And Chung, Y. ,“Applications of fault diagnosis in rotating machinery by using time series analysis with neural network”, Expert Systems with Applications, VVol. 37, No. 2, 1696-1702, 2010.
- [۱۵] Lei Y., Z. He. And Y. Zi ,“A new approach to intelligent fault diagnosis of rotating machinery”, Expert Systems with Applications, Vol. 35, No. 4, 1593-1600, 2008.
- [۱۶] Zio, E. And G., Gola ,“A neuro-fuzzy technique for fault diagnosis and its application to rotating machinery”, Reliability Engineering and System Safety, Vol. 94, 78-88, 2009.
- [۱۷] Hunt, K. J., R., Haas and S., Murray, “Extending the function equivalent of radial basis function networks and fuzzy inference systems”, IEEE Transaction on neural networks , Vol. 7, No. 3, 134-145, 1996.
- [۱۸] Lou, X. and K. L., Loparo ,“Bearing fault diagnosis based wavelet transform and fuzzy inference”, Mechanical Systems and Signal Processing, Vol. 18, 1077-1095, 2004.
- [۱] M. Alexandru, “Analysis of induction Motor fault diagnosis With fuzzy neural network”, applied artificial intelligence, No. 17, 105-133, 2003.
- [۲] Buragohain, M. And Mahanta C., “A novel approach for ANFIS modeling based on full factorial design”, Applied Soft Computing, No. 8, 609-625, 2008.
- [۳] Keith, M. R. An introduction to predictive maintenance, 2nd Edition, Elsevier Science, 2002.
- [۴] Emmanouilidis, C., Macintyre, J. And Cox, “CNeuro-fuzzy computing aided machine fault diagnosis”, information sciences conference, jcis'98, 1998.
- [۵] Chow, M., and R. N., Sharpe, And J., Hung, “The application and design of artificial neural network for motor fault detection”, IEEE Transactions on Industrial Electronics, No. 40, Vol. 2, 189-196, 1993.
- [۶] Ragulskis, K., and A., Yurkauskas ,“Vibration of bearings”, PA: Hemisphere, 1989.
- [۷] Lipovszky, G. K. and G., Solyomvari Varga, “Vibration testing of machines and their maintenance”, Elsevier, 1990.
- [۸] House, J. M. and D. R., Lee., “ShinClassification techniques for fault detection and diagnosis of an air-handling unit”, ASHRAE Trans, No. 105, Vol 1, 1987-97, 1999.
- [۹] Robinson, J. C., R. G., Canada and K. R., Piety, “Peak Value analysis—new methodology for bearing fault detection”, Sound Vib, No. 30, Vol. 11, 22-5. 1996.
- [۱۰] Donley M., W., Stokes, G. S., Jeong, K. K., Suh and S. G., Jung, “Validation of finite element for noise/vibration/harshness models simulation”, Sound Vib, No. 30, Vol.8, 18-23, 1996.

۷- زیر نویس ها

-
- ^۱ Multi-Layer Perceptron (MLP)
 - ^۲ Adaptive Neural - Fuzzy Inference Systems (ANFIS)
 - ^۳ Absolute average
 - ^۴ Shape factor
 - ^۵ Free factor
 - ^۶ Tan-sigmoid
 - ^۷ Goal
 - ^۸ Epochs
 - ^۹ Premise Parameters