

بررسی مقایسه‌ای کارایی روش‌هایی بر پایه تکنیک‌های هوش مصنوعی در تشخیص عیوب سیستم‌های مکانیکی

نوید مشتاقی یزدانی*

دانشجوی دکتری

دانشگاه تهران

navid.moshtaghi@ut.ac.ir

محمد محبوب جهرمی

استاد دانشکده مهندسی مکانیک

دانشگاه تهران

mmahjoob@ut.ac.ir

تاریخ دریافت: ۱۳۹۵/۰۴/۰۴

تاریخ پذیرش: ۱۳۹۶/۱۲/۰۵

چکیده

بلبرینگ‌ها یکی از پر استفاده‌ترین قطعات موتورها می‌باشند که به دلیل چرخش دائمی زودتر از بقیه قطعات دچار خرابی می‌شوند و بدین خاطر تحقیقات وسیعی بر روی پایش سلامت بلبرینگ‌های موتورهای القایی انجام شده است. عیوب بلبرینگ‌ها معمولاً از نوع محلی هستند که در حلقه داخلی، خارجی، ساچمه‌ها یا قفسه ایجاد می‌شوند. به همین علت از سیگنال ارتعاشی برای پایش سلامت بلبرینگ‌ها استفاده می‌شود. همچنین در این پژوهش عیب‌یابی ورق‌های کامپوزیت با استفاده از پردازش سیگنال ارتعاشی و روش‌های مبتنی بر هوش مصنوعی نیز صورت گرفته است. سیگنال‌های ارتعاشی از ورق‌های کامپوزیتی سالم و دارای عیب گرفته شده و با استفاده از روش‌های مختلف پردازش سیگنال حوزه زمان - فرکانس تعدادی ویژگی از این سیگنال‌ها استخراج شده است. سپس موثرترین ویژگی‌ها که حاوی اطلاعات بیشتری از ورق‌های کامپوزیتی می‌باشند به‌عنوان ورودی به سیستم‌های مختلف طبقه‌بندی داده شده است که خروجی آنها نشان‌دهنده نوع و شدت عیب می‌باشد. نتایج به‌دست آمده نشان‌دهنده برتری روش انفیس^۱ از نظر درصد دقت می‌باشد در حالی که این روش بیشترین مدت زمان اجرا را در تعداد اجراهای برابر دارد. در صورتی که روش پیشنهادی XCS بهبود یافته است، درصد دقت نسبتاً کمتری نسبت به انفیس دارد، ولی مدت زمان اجرای کمتری را (در تعداد اجرای برابر نسبت به روش فوق) به خود اختصاص می‌دهد.

واژگان کلیدی: ورق کامپوزیت، موتور القایی، پردازش سیگنال

۱. مقدمه

امروزه همگام با روند توسعه و پیشرفت تکنولوژی تقاضا برای ارائه روش‌های پایش و عیب‌یابی انواع سیستم‌های مکانیکی توسعه یافته است [۱۶-۱۷]. از طرفی امروزه پس از تحول تشخیص عیب از آن برای نگهداری بازدارنده^۲ در دهه‌های اخیر استفاده می‌شود قبل از استفاده صنایع از تشخیص عیوب شرطی که تا به امروز از آن استفاده می‌شد. تشخیص عیوب به صورت نگهداری قبل از بروز هرگونه تخریبی در سیستم تعریف می‌شد. اما عیوب ضمنی به شیوه‌ای از نگهداری اطلاق می‌شود که در آن عمل تشخیص بر اساس اطلاعاتی که از اندازه‌گیری هدف به دست آمده‌اند، اتخاذ می‌گردد. هنوز هم تعداد بسیاری از محققین به تحقیق و جستجو درباره فنون و استراتژی‌های تشخیص می‌پردازند، بعضی از آنها در مراجع [۲] و [۵] آورده شده‌اند. در یک فرایند تولید صنعتی، بروز خطای کوچک ممکن است به خرابی محصول و افزایش هزینه‌های تولید و تعطیلی خط و بروز صدمات زیست محیطی و غیره منجر گردد. پاسخ روز افزون به این نیاز منجر به شروع فعالیت‌هایی چشمگیر در زمینه پایش و نگهداری سیستم‌های صنعتی و تشخیص عیوب شده است [۱]. لذا در این مقاله به بررسی مقایسه‌ای انواع مختلفی از الگوریتم‌ها برپایه‌ی تکنیک‌های هوش مصنوعی^۳ برای تشخیص عیب در دو نمونه از سیستم‌های مکانیکی (تشخیص عیب ورق‌های کامپوزیت و تشخیص عیب بلبرینگ موتور القایی) پرداخته می‌شود. ضمن اینکه نشان می‌دهد روش پیشنهادی در این دو نمونه بسیار کارتر از روش XCS کلاسیک عمل می‌نماید. مطالعات زیادی در ارتباط با پدیده تشخیص عیب در ورق‌های کامپوزیت توسط تحلیل داده‌های تجربی صورت گرفته است. سانگ و همکارانش [۶] یک روش‌شناسی حل کامل براساس تبدیل لاپلاس را برای تحلیل ارتعاش آزاد خمشی تیر یکسر آزاد

کامپوزیت لمینت شده‌ی سگدست که ترک‌های سطحی دارد، شرح دادند. آنها به منظور توسعه‌ی تکنیک ردیابی خسارت اصل تغییر همیلتون^۴ را به همراه مدل تیر یکسر آزاد تیموشنکو^۵ به کار بردند. جاست آگوست^۶ و همکارانش [۷] متد شبکه عصبی را در ترکیب با آثار ردیابی آسیب حرارتی و ارتعاشی، برای توسعه ابزار ردیابی خسارت به کار بردند. آنها این تکنیک توسعه داده شده را روی کامپوزیت ساندویچی به منظور ردیابی ترک استفاده کردند. پرا^۷ و همکارانش [۸] الگوریتم ژنتیکی را برای حل بهینه‌سازی چند مقصوده به منظور ردیابی آسیب استفاده کردند. آنها بهینه‌سازی الگوریتم ژنتیکی^۸ را که بر اساس توابع اجتماع (مجموعه‌سازی) است، را با بهینه کردن پارتو^۹ مقایسه کردند. فریسول^{۱۰} و همکارانش [۹] الگوریتم ژنتیکی و روش حساسیت eigen را برای تعیین موقعیت آسیب در ساختارها، با هم ترکیب کردند. آنها الگوریتم ژنتیکی را به منظور بهینه کردن متغیرهای موقعیت آسیب گسسته مورد استفاده قرار دادند. فنگ^{۱۱} و همکارانش [۱۰] عملکرد تکنیک نقص آسیب ساختاری را که براساس واکنش بسامد و شبکه عصبی بود، مورد کاوش قرار دادند در این مقاله آنها در مورد یک الگوریتم تخفیف گزاف‌ترین تنظیم‌پذیر را برای بهبود سرعت همگرایی تحقیق کردند. آنها نتیجه‌گیری کردند تکنیک شبکه عصبی می‌تواند با دقت بالایی شرایط آسیب را تخمین بزند. بینا^{۱۲} و گینگلی^{۱۳} [۱۱] یک راه جدید برای ردیابی عیب در سیستم ساختار، براساس تکنیک منطق فازی پیشنهاد کردند. آنها از مکانیزم‌های پیوسته و متد اجزاء محدود برای اندازه‌گیری پارامترهای ارتعاش که به علت آسیب ساختار هستند، استفاده نمودند. تکنیک توسعه یافته حتی در حضور نویز نیز به خوبی برای آسیب ساختاری کار می‌کند آنها همچنین شبکه عصبی‌ای که بر اساس یادگیری هبیین^{۱۴} است را

برای توسعه سیستم ردیابی آسیب بر پایه نقشه شناختی فازی به کار بردند. کو^{۱۵} و چانگ^{۱۶} [۱۲] یک سیستم ردیابی عیب که در آن کسب داده، اقتباس ویژگی و بازشناسی الگو را برای ردیابی عیوب تیغه‌ها به کار رفته توسط سنسورهای لرزش مضاعف پیشنهاد کردند. الگوریتم اقتباس ویژگی براساس شبکه عصبی مصنوعی اشاعه به عقب گسترش داده شد. تکنیک منطقی فازی برای تسریع سرعت پرورش به کار گرفته شد. طبق نظر وی نتایج سیستم خیلی نزدیک به نتایج به دست آمده از تحلیل تجربی هستند. ونگ^{۱۷} و همکارانش [۱۳] مقایسه عملکرد دو سیستم تشخیص عیب، شبکه‌های عصبی بازگشت کننده و سیستم‌های عصبی فازی، که در آن از دو مجموعه داده محک استفاده شده را بیان کردند. همان‌طور که آنها شرح دادند معلوم شد سیستم پیش‌بینی (وابسته به آثار آتی و پیش‌بینی عیب) از سیستم تشخیص عیب شبکه عصبی برای مانیتورینگ شرایط سلامت ماشین معتبرتر می‌باشد. پوار^{۱۸} و گانگولی^{۱۹} [۱۴] یک روش‌شناسی کنترل سلامت ساختار را که سیستم فازی ژنتیکی را برای ردیابی درجای عیب به کار می‌برد، طراحی کردند. آنها تغییر مکان (جابه‌جا شدگی) و انحراف‌های اندازه‌گیری نیرو بنیان بین شرایط آسیب دیده و آسیب ندیده را برای ساخت قوانین و اتحاد داده‌ها برای سیستم ژنتیکی و فازی به کار بردند. همچنین تحقیقات وسیعی بر روی پایش سلامت بلبرینگ‌های موتور القایی در سه دهه اخیر انجام شده است [۱۸]. عیب‌های ایجاد شده در بلبرینگ‌ها معمولاً از نوع محلی هستند که در حلقه داخلی، خارجی، ساچمه‌ها یا قفسه ایجاد می‌شوند. اندازه و دوره تناوب تکرار این ضربه‌ها با توجه به سرعت چرخش، محل عیب و ابعاد مشخصه بلبرینگ تعیین می‌شود. به همین علت تامسون^{۲۰}، تاندون^{۲۱} و همکاران از سیگنال ارتعاشات برای پایش سلامت بلبرینگ‌ها استفاده نمودند [۱۹ و ۲۰]. سینگ^{۲۲} و همکارانش در مقالات مروری خود به آنچه که در کنترل و پایش سلامت در موتورهای

القایی براساس تحلیل نوسانات سیگنال‌های جریان و غیرجریان انجام شده است می‌پردازند [۲۱]. با توجه به اینکه خرابی بلبرینگ‌ها در موتور القایی بر روی سیگنال جریان استاتور موتور القایی تأثیر می‌گذارد بن‌بوزید^{۲۳} برای تحلیل سیگنال جریان از روش‌های حوزه فرکانس و زمان-فرکانس استفاده نموده است [۲۳-۲۲]. روش‌های حوزه فرکانس نیز با استفاده از آنالیز سیگنال‌های ارتعاشات و جریان به‌طور گسترده‌ای برای عیب‌یابی بلبرینگ‌ها استفاده شده‌اند. لیبولد^{۲۴} و همکارانش از روش‌های حوزه فرکانس که به‌طور معمول براساس تبدیل فوریه هستند برای تشخیص عیب استفاده نمودند [۲۴]. یازیچی^{۲۵} از روش‌های پیشرفته‌تر از تبدیل سریع فوریه^{۲۶} نظیر تبدیل فوریه زمان کوتاه برای عیب‌یابی بلبرینگ‌ها استفاده نموده است [۲۵]. لی^{۲۷} و همکارانش [۲۹] به محاسبه انرژی پخش شده در حوالی هارمونیک‌ها پرداخته و از آنها به‌عنوان ورودی برای شبکه عصبی استفاده نمودند. نیکولا^{۲۸} و همکارانش از تبدیل موجک بسته‌ای برای پایش عیب بلبرینگ‌ها استفاده نمودند [۲۶]. پریاکر^{۲۹} و همکارانش از روش تبدیل موجک برای تشخیص عیب استفاده نمودند [۲۷]. ایرن^{۳۰} و همکاران نیز با استفاده از تبدیل موجک بسته‌ای و انتخاب موجک Coiflet4 و تحلیل سیگنال جریان و انتخاب معیار مقدار مؤثر، عیب ایجاد شده بر روی حلقه خارجی و قفسه بلبرینگ را تشخیص دادند [۲۸].

۲. معرفی روش پیشنهادی

یادگیری ماشین به طیف گسترده‌ای از الگوریتم‌های یادگیری با مربی و بدون مربی اطلاق می‌شود که هدف از آنها در حوزه داده‌کاوی، پرهیز از جستجوی سراسری^{۳۱} داده‌ها و جایگزین کردن اینگونه جستجوی زمان‌بر با روش‌های هوشمندانه‌ای است که از طریق یافتن الگو(ها)ی موجود در میان داده‌ها، دسته‌بندی و یا

مدل‌سازی رفتار آنها را به سادگی امکان‌پذیر می‌سازد. در دو دهه اخیر روش‌های زیادی در حوزه داده‌کاوی ارائه شده است که در آنها از انواع الگوریتم‌های یادگیری با مربی^{۳۲}، بدون مربی^{۳۳} و یا تقویتی^{۳۴} برای اهدافی همچون تشخیص و تخصیص الگو استفاده می‌شود. از جمله موفق‌ترین این روش‌ها می‌توان به سیستم‌های طبقه‌بند^{۳۵} اشاره کرد.

در حالت کلی، سیستم‌های طبقه‌بندی شامل مجموعه‌ای از قوانین با فرمت «اگر- آنگاه»^{۳۶} هستند که هر قانون راه حل بالقوه‌ای برای مسئله هدف ارائه می‌نماید. این مجموعه قوانین به تدریج با به کارگیری یک ساز و کار یادگیری تقویتی ارزیابی شده و در فواصل زمانی مشخصی به کمک یک الگوریتم ژنتیک روزآوری می‌شود. در جریان این تکامل تدریجی، سیستم رفتار محیط را می‌آموزد و سپس در فاز کاربرد، پاسخ‌های مناسبی را به پرسش‌های^{۳۷} مطرح شده از سوی کاربر ارائه می‌کند.

اولین سیستم طبقه‌بندی در سال ۱۹۷۶ توسط هالند با عنوان سیستم طبقه‌بندی یادگیری^{۳۸} پیشنهاد شد. در این سیستم، ارزش هر قانون با شاخصی به نام «قوت»^{۳۹} ارزیابی می‌شد. قوت یک قانون متناسب با میزان پاسخگویی صحیح آن به مثال‌های تربیتی در چارچوب ضوابط یادگیری تقویتی افزایش می‌یافت و در فواصل زمانی مشخصی، یک الگوریتم جستجوی تکاملی (معمولا الگوریتم ژنتیک) مسئولیت تولید قوانین جدید و حذف قوانین ناکارآمد را به‌عهده می‌گرفت. در پایان مرحله تربیت، این مجموعه قوانین توانایی نسبی آن را داشت که در مواجهه با پرسش‌های جدید، راه‌حل‌های قابل قبولی را ارائه نماید. در عین حال عملکرد موفق سیستم طبقه‌بندی یادگیری منوط به انتخاب مقادیر مناسب برای پارامترهای کنترلی سیستم بود که به‌طور معمول به تجربه طراح این سیستم وابسته بود. از زمان به وجود آمدن سیستم طبقه‌بندی یادگیری، انواع دیگری از سیستم‌های طبقه‌بندی پیشنهاد شده است که از میان آنها می‌توان به

سیستم‌های طبقه‌بندی توسعه یافته^{۴۰} اشاره کرد. تا قبل از معرفی سیستم‌های طبقه‌بندی توسعه یافته در سال ۱۹۹۵، توانایی این سیستم‌ها در به‌دست آوردن پاسخ‌های مناسب بسیار محدود بود. اما از آن زمان این سیستم‌ها به تدریج به عواملی هوشمندتر و دقیق‌تر تبدیل شدند و اکنون اعتقاد بر این است که سیستم‌های طبقه‌بندی توسعه یافته و نسخه‌های بهبود یافته آن قادرند مسائل پیچیده‌ای را بدون نیاز به تنظیم پارامترها حل کنند. با معرفی سیستم طبقه‌بندی با متغیرهای پیوسته (XCSR)، برخی ضعف‌های ذاتی سیستم‌های طبقه‌بندی دودویی^{۴۱} نظیر ناتوانی در معرفی بازه‌های مشخص مقادیر متغیرها تا حد زیادی برطرف شد و امروزه این سیستم‌ها به‌عنوان یکی از موفق‌ترین عامل‌های یادگیرنده^{۴۲} برای حل مسائل داده‌کاوی در محیط‌های نیمه مشاهده‌پذیر شناخته شده‌اند.

بر اساس رهیافت متداول برای تربیت XCSR، تنها برانزنگی قوانینی افزایش می‌یابد که به داده‌های تربیتی پاسخ صحیح بدهند. این بدان معناست که شانس هر قانون برای حذف نشدن و مشارکت در فرایند تولید قوانین جدید، بستگی مستقیم به نحوه پاسخگویی آن به داده‌های تربیتی دارد و تعیین واقع‌گرایانه این شانس نیازمند به کارگیری تعداد زیادی از داده‌های تربیتی است. از آنجا که در مسائل واقعی، تعداد داده‌های تربیتی معمولا محدود بوده و افزایش تعداد داده‌ها به سادگی میسر نیست، معمولا استفاده از XCSR در اینگونه کاربردها از نظر زمان و هزینه محاسباتی توجیه‌پذیر نمی‌باشد. در ادامه این مقاله روش جدیدی برای بهبود عملکرد و افزایش نرخ همگرایی XCSR با استفاده از داده‌های محدود تربیتی ارائه می‌گردد. در روش پیشنهادی، ابتدا مجموعه (محدود) داده‌های تربیتی به‌صورت معمول برای اصلاح مشخصه‌های قوانین (شامل «پیش‌بینی»، «خطای پیش‌بینی» و «برانزنگی») به کار گرفته می‌شود. این کار با استفاده از روابط زیر صورت می‌گیرد:

به روزآوری پیش‌بینی و خطای پیش‌بینی

(۱)

If $\exp_i < 1/\beta$ then $P_i = P_i + (R - P_i) / \exp_i$, $\varepsilon_i = \varepsilon_i + (|R - P_i| - \varepsilon_i) / \exp_i$

If $\exp_i \geq 1/\beta$ then $P_i = P_i + \beta (R - P_i)$, $\varepsilon_i = \varepsilon_i + \beta (|R - P_i| - \varepsilon_i)$

به روزآوری برازندگی

If $\varepsilon_i < \varepsilon_0$ then $k_i = 1$

If $\varepsilon_i \geq \varepsilon_0$ then $k_i = \beta (\varepsilon_i / \varepsilon_0)^{-\gamma}$ (۲)

$F_i = f_i + \beta [(k_i / \sum k_j) - f_i]$

که در این روابط، β نرخ یادگیری، γ توان دقت قانون، ε خطای پیش‌بینی، \exp تجربه قانون، P پیش‌بینی قانون، R پاداش دریافتی از محیط، k دقت قانون و f برازندگی آن است. اندیس i نیز شماره قانون را در مجموعه قوانین نشان می‌دهد. در مرحله بعد، برای گسترش تنوع در مجموعه داده‌ها، با استفاده از روش «انتخاب تصادفی با باقی‌مانده» از میان رشته‌هایی که نمایشگر بخش شرط داده‌های موجودند زوج‌های متعددی به‌عنوان والدین انتخاب شده و بخش شرط داده‌های جدید با استفاده از روش هم‌گذری میانی که بر روی این رشته‌های والدین اعمال می‌شود به‌وجود می‌آید. در این روش، مقدار هر یک از متغیرهای شرطی از رابطه زیر به‌دست می‌آید:

$$a_i = \alpha(a_i^F) + (1 - \alpha)(a_i^M) \quad (۳)$$

که در آن a_i مقدار متغیر شرطی i ام در داده جدید، a_i^F مقدار متغیر شرطی i ام در والد اول (پدر)، a_i^M مقدار متغیر شرطی i ام در والد دوم (مادر) و α ضریب مشارکت والدین است که به‌صورت تطبیقی^{۴۳} تعیین می‌گردد.


بخش عملکرد داده‌های جدید نیز با استفاده از یک نگاشت غیرخطی از فضای متغیرهای شرطی به فضای عملکردها

که با استفاده از داده‌های موجود ایجاد شده است تولید می‌شود.


تنوع بخشی به داده‌های موجود تا آنجا ادامه می‌یابد که شرط توقف یادگیری (مثلاً رسیدن درصد پاسخ‌های صحیح سیستم به داده‌های تست به یک آستانه از پیش تعیین شده) به کمک داده‌های کامل شده ارضاء گردد.

۳. روش انجام کار (تست ورق کامپوزیت)


در این بخش جهت تشخیص عیوب و دسته‌بندی ورق‌های کامپوزیت از چهار ورق کامپوزیت سالم، عیب کم، عیب متوسط، عیب مکان جداگانه که در تصاویر زیر دیده می‌شوند استفاده شده است.




شکل ۱. ورق کامپوزیت سالم



شکل ۲. ورق کامپوزیت عیب کم



شکل ۳. ورق کامپوزیت عیب متوسط



شکل ۵. نمایی از تست ارتعاشات بر روی ورق


کامپوزیت عیب کم

در ابتدا داده‌های به‌دست آمده را پیش پردازش و آماده‌سازی نموده سپس عملیات استخراج ویژگی که شامل ویژگی‌های زمانی، فرکانسی و زمانی-فرکانسی می‌باشند را بر روی داده اجرا نموده و برای انتخاب مؤثرترین ویژگی‌های استخراج شده از روی داده‌ها از الگوریتم بین‌المللی رمزگذاری داده‌ها^{۴۴} و استفاده از آنالیز حساسیت استفاده می‌کنیم.

در ادامه به طبقه‌بندی عیوب ورق‌های کامپوزیت توسط $KNN^{۴۵}$ ، $SVM^{۴۶}$ ، $RBF^{۴۷}$ ، $MLP^{۴۸}$ ، $ANFIS^{۴۹}$ و XCS و روش پیشنهادی پرداخته و در پایان مقایسه‌ای بین نتایج به‌دست آمده از این روش‌های گوناگون طبقه‌بندی ارائه شده است.

۳-۱. تفکیک وضعیت‌های کامپوزیت

پس از به‌دست آوردن مؤثرترین ویژگی‌ها، تفکیک وضعیت‌های مختلف کامپوزیت انجام گرفته است. همان‌طور که در بخش قبل نیز مشاهده کردیم مسئله تفکیک وضعیت‌های مختلف کامپوزیت مسئله ساده‌ای نیست به‌طوری که بتوان با یک نگاه اولیه به داده‌ها آنها را از یکدیگر تفکیک کرد. برای حل این مشکل از روش‌های مختلف طبقه‌بندی موجود بهره گرفته شده است. روش‌هایی که در این مقاله استفاده شده‌اند عبارتند از: KNN ، SVM ، $ANFIS$ و شبکه‌های عصبی و



شکل ۴. ورق کامپوزیت عیب مکان جداگانه

در ورق کامپوزیت عیب کم همان‌طور که در شکل ۲ مشاهده می‌گردد یک لایه کوچک افزون بر لایه‌های کامپوزیت در قسمتی از ورق کامپوزیت که علامت‌گذاری شده است تعبیه گردیده شده همچنین در ورق کامپوزیت عیب متوسط عیبی به مانند عیب قبلی و در همان مکان اما در اندازه‌های بزرگ‌تر از حالت قبلی ایجاد شده است. در ورق کامپوزیت عیب مکان جداگانه عیبی به مانند قبل اما در قسمتی دیگر از ورق کامپوزیت تعبیه شده است.

روش انجام کار به این صورت می‌باشد که هرکدام از ورق‌های کامپوزیت را به طور جداگانه همانند شکل ۶ به کمک ریسمان ارتجاعی به یک چهار پایه نگهدارنده فلزی متصل کرده سپس برای تمامی ۴۵ نقطه مشخص بر روی تمامی ورق‌های کامپوزیت‌ها شتاب‌سنج ENDEVCO مدل ۲۲۲۲۰ را قرار داده و با چکش مخصوص به قسمتی از کامپوزیت که در شکل ۵ با دایره قرمز رنگ مشخص شده است (مکان تحریک ثابت) تحریک ضربه‌ای را وارد می‌کنیم سپس سیگنال ثبت شده را بر روی کامپیوتر مشاهده کرده این کار را برای تمامی نقاط به تعداد سه بار انجام می‌دهیم. سپس سیگنال‌های ثبت شده از هرکدام از ورق‌های کامپوزیت را در فایل‌هایی جداگانه ذخیره می‌نماییم.

سیستم طبقه‌بندی XCS و IMPROVED XCS. به‌صورتی که در جدول ۱ آورده شده است می‌باشد. در تمام قسمت‌های این بخش، بخش‌بندی گروه‌ها

جدول ۱. شماره طبقه‌بندی‌های ورق‌های کامپوزیت

گروه	سالم	عیب اندازه کم	عیب اندازه متوسط	عیب مکان جداگانه
شماره	۱	۲	۳	۴

مجموعه داده‌های تست در جدول ۲ مشاهده می‌شود. به ازای $k=23$ میانگین دقت بهتری نسبت به سایر مقادیر حاصل شده است.

۳-۱-۱. تفکیک با استفاده از روش KNN

میانگین دقت حاصل از ده بار اجرای الگوریتم KNN معرفی شده به ازای تعداد همسایه‌های مختلف روی


جدول ۲. میانگین دقت مقدار k

مقدار k	۱۵	۱۷	۱۹	۲۱	۲۳	۲۵	۲۷
میانگین دقت	۷۰/۲	۷۱/۴	۷۴/۸	۷۸/۹۵	۸۰	۷۹/۱۹	۷۸/۶۳

۳-۱-۲. تفکیک با استفاده از SVM


داده‌ها به دو قسمت آموزشی و تست تقسیم‌بندی می‌شوند. از بین ۲۴۰ داده تعداد ۲۰۰ داده به‌عنوان داده‌های آموزشی و ۴۰ داده به‌عنوان داده‌های تست در نظر گرفته شده است. پس از اجرای این روش نمودار خروجی این روش برای هر کدام از داده‌های تست رسم شده است.

پس از انتخاب $k=23$ روش KNN برای داده‌های تست اجرا گردید. در تمامی شکل‌هایی که در ادامه آمده است، نمودار افقی نشان دهنده تعداد داده‌های تست و نمودار عمودی نشان دهنده چهار عیب یاد شده در بالا می‌باشد که هر کدام در دسته‌ای از عیوب و یا سالم دسته‌بندی شده‌اند.



شکل ۷. تفکیک داده‌های تست با پارامترهای IDE به کمک روش SVM

همان‌طور که از شکل ۷ پیداست استفاده از SVM نتایج بهتری نسبت به روش KNN را داشته است. از بین ۴۰ داده تست ۳۳ داده به‌طور صحیح و ۷ داده به‌طور اشتباه تشخیص داده شده‌اند.



شکل ۶. تفکیک داده‌های تست با پارامترهای IDE به کمک روش KNN

همان‌طور که از شکل ۶ مشخص است روش KNN نتوانست همه داده‌های تست را به‌طور صحیح تفکیک کند و از بین ۴۰ داده تست به ۳۲ داده جواب صحیح داده و ۸ داده را اشتباه طبقه‌بندی کرده است.


۳-۱-۳. تفکیک با استفاده از شبکه‌های عصبی

پس از انجام سعی و خطا بهترین شبکه عصبی MLP با مشخصات جدول ۳ به دست آمد:

جدول ۳. مشخصات بهترین شبکه عصبی

تعداد لایه‌های مخفی	تعداد نرون لایه مخفی اول	تعداد نرون لایه مخفی دوم	تعداد نرون لایه مخفی سوم	تعداد نرون لایه مخفی چهارم	روش پیشگیری	تابع تبدیل نرون
۴	۸	۷	۱۰	۷	پس انتشار خطا	تانژانت هیپربولیک


شده است. همان‌طور که در دو شکل ۸ و ۹ مشخص می‌باشد، خطای شبکه عصبی RBF از خروجی خواسته شده نسبت به شبکه عصبی MLP بیشتر است؛ لذا شبکه عصبی MLP عملکرد بهتری نسبت به شبکه عصبی RBF داشته است.



شکل ۸. تفکیک داده‌های تست با پارامترهای IDE به کمک روش MLP

۳-۱-۴. تفکیک با استفاده از شبکه عصبی نروفازی

قبل از آموزش سیستم ابتدا خوشه‌بندی داده‌ها را با استفاده از روش خوشه‌بندی کاهشی^{۵۰} انجام می‌دهیم که برای هر کدام از ورودی‌ها ۶ تابع گوسی در نظر می‌گیرد سپس سیستم با استفاده از روش ترکیبی تربیت می‌شود.




شکل ۱۰. تفکیک داده‌های تست با پارامترهای IDE به کمک روش شبکه نروفازی

جدول ۴. مقادیر وزن ورودی‌های شبکه انفیس

شماره ورودی	۱	۲	۳	۴
مقدار وزن	۰/۸۹۳	۱	۰/۷۱۶	۰/۶۳۸

پس از وزن‌دار کردن ورودی‌های شبکه باردیگر تفکیک و طبقه‌بندی داده‌ها برای شبکه انفیس جدید انجام گرفت که


همان‌طور که در شکل ۸ مشخص می‌باشد شبکه عصبی MLP با توجه به این که از بین ۴۰ داده تست ۳۳ داده را به طور صحیح و ۷ داده به طور اشتباه تشخیص داده اما برای دو طبقه از داده‌های طبقه‌بندی دچار اشتباه شده است و از این نظر دارای ضعف بزرگی می‌باشد. برای تفکیک در شبکه عصبی RBF بایستی مقدار پراکندگی توابع شعاع محوری مشخص باشد که این امر پس از چندین عمل سعی و خطا مقدار ۰/۴ به دست می‌آید.



شکل ۹. تفکیک داده‌های تست با پارامترهای IDE به کمک روش RBF

در شکل ۹ مشخص است که شبکه عصبی RBF برای هر چهار طبقه از داده‌ها (داده‌های ۱۰ تا ۴۰) طبقه‌بندی را به اشتباه انجام داده است و ۷ داده به اشتباه تشخیص داده

شکل ۱۱ خروجی این سیستم جدید را برای داده‌های تست نشان می‌دهد.




شکل ۱۱. تفکیک داده‌های تست با پارامترهای IDE به کمک روش شبکه نروفازی وزندهی شده

همان‌طور که در شکل ۱۱ مشخص است شبکه عصبی نروفازی جدید توانست از بین ۴۰ داده تست تمامی داده‌ها به درستی تشخیص دهد.

۳-۱-۵. تفکیک با استفاده از سیستم طبقه‌بندی XCS

تعداد ۵۰۰ مجموعه قوانین ایجاد شده سیستم طبقه‌بندی XCS که برای تشخیص ویژگی‌های استخراج شده از الگوریتم IDE به صورت کاملا تصادفی ایجاد می‌شوند که شامل ۵ قسمت شرط و یک قسمت نتیجه شرط می‌باشند از بین ۲۴۰ داده موجود تعداد ۲۰۰ داده به‌عنوان داده‌های آموزشی و ۴۰ داده به‌عنوان داده‌های تست در نظر گرفته شده است پس از اجرای این روش نمودار خروجی این روش برای هر کدام از داده‌های تست رسم شده است.




شکل ۱۲. تفکیک داده‌های تست با پارامترهای IDE به کمک روش XCS کلاسیک

همان‌طور که از شکل ۱۲ مشخص است روش XCS کلاسیک نتوانست همه داده‌های تست را به‌طور صحیح

تفکیک کند و از بین ۴۰ داده تست به ۳۶ داده جواب صحیح داده و ۴ داده را اشتباه طبقه‌بندی کرده است.

۳-۱-۶. تفکیک با استفاده از روش پیشنهادی

تعداد ۶۰۰ مجموعه قوانین ایجاد شده سیستم طبقه‌بندی XCS که برای تشخیص ویژگی‌های مستخرج از الگوریتم بین‌المللی رمزگذاری داده‌ها به‌صورت کاملا تصادفی ایجاد می‌شوند که هر کدام از این قوانین شامل ۵ قسمت شرط و یک قسمت نتیجه شرط می‌باشند. از بین ۲۴۰ داده تعداد موجود به مانند همیشه ۲۰۰ داده به‌عنوان داده‌های آموزشی و ۴۰ داده به‌عنوان داده‌های تست در نظر گرفته شده است پس از اجرای این روش نمودار خروجی این روش برای هر کدام از داده‌های تست رسم شده است.



شکل ۱۳. تفکیک داده‌های تست با پارامترهای IDE به کمک روش XCS پیشنهادی

همان‌طور که از شکل ۱۳ مشخص است روش XCS پیشنهادی توانست بیشتر داده‌های تست را به‌طور صحیح تفکیک کند و از بین ۴۰ داده تست به ۳۹ داده جواب صحیح داد و تنها ۱ داده را به اشتباه طبقه‌بندی کرده است و در مقابله با XCS کلاسیک و شبکه عصبی نروفازی مدت زمان اجرای کمتری برای آموزش و تست نیاز دارد.

۳-۲. تست بلبرینگ‌ها در موتور القایی

در این آزمایش‌ها از یک موتور القایی ۳ فاز با مشخصات نامی چهار قطب ۱۴۰۰ rpm، ۵۰ Hz، ۲۸۰ V، ۲/۱ kW استفاده شده است. هر دو بلبرینگ انتهایی شفت و انتهایی فن ۲Z-۶۲۰۵ می‌باشند. همان‌طور که در کاتالوگ بلبرینگ ۲Z-۶۲۰۵ نوشته شده است. این بلبرینگ دارای ۹ ساچمه

است که قطر هر کدام ۷/۹۳۸ میلی‌متر و قطر داخلی آن ۲۵ میلی‌متر و قطر خارجی آن ۵۲ میلی‌متر و قطر گام بلبرینگ ۳۸/۵ میلی‌متر می‌باشد. ابتدا، آزمایش را بر روی موتور با بلبرینگ‌های سالم انجام داده‌ایم برای آزمایش دوم که شبیه‌سازی عیب رینگ داخلی می‌باشد بر روی رینگ داخلی بلبرینگ انتهایی شفت سوراخی به قطر ۲ میلی‌متر ایجاد می‌کنیم و در آزمایش سوم که برای شبیه‌سازی عیب رینگ خارجی است بر روی رینگ خارجی بلبرینگ انتهایی شفت سوراخی به قطر ۲ میلی‌متر ایجاد می‌کنیم.



شکل ۱۴. نمونه‌ای از بلبرینگ مورد آزمایش

برای اینکه تعداد داده‌های لازم برای آموزش روش‌های طبقه‌بندی تولید شوند، گرفتن میانگین را بر روی هر ۳ سیکل انجام می‌دهیم. پس از اعمال این روش تعداد ۴۸ سیکل داده برای هر کدام از عیوب مختلف به دست می‌آید که در مجموع تعداد ۱۴۴ داده برای عیوب متفاوت ایجاد شده در موتور القایی ایجاد می‌شوند. پس از به دست آوردن مؤثرترین ویژگی‌ها، تفکیک عیوب مختلف موتور القایی انجام گرفته است. همان‌طور که می‌دانیم مسأله تفکیک وضعیت‌های مختلف موتور القایی، مسأله ساده‌ای نیست. به طوری که بتوان با نگاه اول به داده‌ها آنها را از یکدیگر تفکیک کرد. برای حل این مشکل از روش‌های مختلف طبقه‌بندی موجود بهره گرفته شده است. برای اینکه بتوان سیستم‌های طبقه‌بندی را در شرایط یکسان مقایسه نمود، از ۱۴۴ داده موجود تعداد ۱۰۰ عدد برای آموزش شبکه و ۴۴ عدد برای تست در نظر گرفته می‌شوند. از مجموع ۴۴ داده تست ۱۵ عدد مربوط به عیب رینگ خارجی و ۱۵ عدد مربوط به رینگ داخلی، ۱۴ عدد نیز مربوط به حالت سالم می‌باشند. در تمام قسمت‌های این بخش؛ بخش‌بندی گروه‌ها در جدول ۵ آورده شده است.

جدول ۵. بخش‌بندی گروه‌ها

گروه	سالم	عیب رینگ خارجی	عیب رینگ داخلی
شماره عیب	۱	۲	۳


۳-۲-۱. تفکیک با استفاده از روش KNN

به ازای تعداد همسایه‌های مختلف روی مجموعه داده‌های تست در جدول ۶ مشاهده می‌شود. به ازای $k=11$ میانگین دقت بهتری نسبت به سایر مقادیر حاصل شده است.

جدول ۶. میانگین دقت مقدار k

مقدار k	۵	۷	۹	۱۱	۱۳	۱۵
میانگین دقت	۷۶/۵	۷۸/۲	۷۹/۱	۷۹/۵	۷۸/۸۳	۷۷/۵

پس از اجرای این روش نمودار خروجی آن برای هر کدام از داده‌های تست رسم شده است.



شکل ۱۶. تفکیک داده‌های تست با پارامترهای IDE به کمک

روش SVM

همان‌طور که از شکل ۱۶ مشخص است، استفاده از SVM نتایج بهتری نسبت به روش KNN داشته است. از بین ۴۴ داده تست ۳۹ داده به‌طور صحیح و ۵ داده به‌طور اشتباه تشخیص داده شده‌اند. این نتیجه نشان‌دهنده قدرت بیشتر SVM در طبقه‌بندی‌های پیچیده است.

۳-۲-۳. تفکیک با استفاده از شبکه‌های عصبی

پس از انجام سعی و خطا بهترین شبکه عصبی MLP با مشخصات جدول ۷ به‌دست آمد.

جدول ۷. مشخصات بهترین شبکه عصبی


تعداد لایه‌های مخفی	تعداد نرون لایه مخفی اول	تعداد نرون لایه مخفی دوم	روش پیشگیری	تابع تبدیل نرون
۲	۹	۷	پس انتشار خطا	تانژانت هیپربولیک

۳-۲-۴. تفکیک با استفاده از سیستم طبقه‌بندی

XCS

تعداد ۳۰۰ مجموعه قوانین ایجاد شده سیستم طبقه‌بندی XCS که برای تشخیص ویژگی‌های مستخرج از الگوریتم IDE به‌صورت کاملاً تصادفی ایجاد می‌شوند، شامل ۵ قسمت شرط و یک قسمت نتیجه شرط می‌باشند. از بین ۱۴۴ داده موجود تعداد ۱۰۴ داده به‌عنوان داده‌های آموزشی و ۴۰ داده به‌عنوان داده‌های تست در نظر گرفته

پس از انتخاب $k=11$ روش KNN برای داده‌های تست اجرا گردید.



شکل ۱۵. تفکیک داده‌های تست با پارامترهای IDE تفکیک به


کمک روش KNN

همان‌طور که از شکل ۱۵ مشخص است روش KNN نتوانست همه داده‌های تست را به‌طور صحیح تفکیک کند و از بین ۴۴ داده تست به ۳۴ داده جواب صحیح داده و ۱۰ داده را اشتباه طبقه‌بندی کرده است.

۳-۲-۳. تفکیک با استفاده از روش SVM

از بین ۱۴۴ داده تعداد ۱۰۰ داده به‌عنوان داده‌های آموزشی و ۴۴ داده به‌عنوان داده‌های تست در نظر گرفته شده است.


همان‌طور که در شکل ۱۷ مشخص می‌باشد شبکه عصبی MLP با توجه به این که از بین ۴۴ داده تست ۳۷ داده را به‌طور صحیح و ۷ داده به‌طور اشتباه تشخیص داده است.



شکل ۱۷. تفکیک داده‌های تست با پارامترهای IDE به کمک


روش MLP

شده است. پس از اجرای این روش نمودار خروجی این روش برای هر کدام از داده‌های تست رسم شده است.



شکل ۱۸. تفکیک داده‌های تست با پارامترهای IDE به کمک روش XCS کلاسیک

از آن و با توجه به یادگیری سیستم طبقه‌بندی پس از آن برای مثال‌های دیگر و متنوع‌تر نیازی به آموزش و یادگیری سیستم طبقه‌بندی نیست.



شکل ۱۹. تفکیک داده‌های تست با پارامترهای IDE به کمک روش XCS پیشنهادی

همان‌طور که از شکل ۱۸ مشخص است روش XCS کلاسیک نتوانست همه داده‌های تست را به‌طور صحیح تفکیک کند و از بین ۴۰ داده تست به ۳۶ داده جواب صحیح داده و ۴ داده را اشتباه طبقه‌بندی کرده است.

۳-۲-۵. تفکیک با استفاده از روش پیشنهادی

تعداد ۳۰۰ مجموعه قوانین ایجاد شده سیستم طبقه‌بندی XCS که برای تشخیص ویژگی‌های مستخرج از الگوریتم IDE به‌صورت کاملاً تصادفی ایجاد می‌شوند که هر کدام از این قوانین شامل ۵ قسمت شرط و یک قسمت نتیجه شرط می‌باشند. از بین ۱۴۴ داده تعداد موجود به مانند همیشه ۱۰۰ داده به‌عنوان داده‌های آموزشی و ۴۴ داده به‌عنوان داده‌های تست در نظر گرفته شده است پس از اجرای این روش نمودار خروجی این روش برای هر کدام از داده‌های تست رسم شده است.

در این روش تنها مدت زمان آموزش سیستم طبقه‌بندی که به‌صورت آفلاین می‌باشد مدت قابل توجهی است، اما پس

همان‌طور که از شکل ۱۹ مشخص است روش XCS پیشنهادی توانست بیشتر داده‌های تست را به‌طور صحیح تفکیک کند و از بین ۴۴ داده تست به ۴۰ داده جواب صحیح داده و تنها ۴ داده را به اشتباه طبقه‌بندی کرده است و در مقایسه با انواع سیستم‌های طبقه‌بندی مدت زمان اجرای کمتری برای آموزش و تست نیاز دارد.

۴. مقایسه نتایج سیستم‌های تشخیص عیب

در این بخش مقایسه‌ای بین نتایج روش‌های مختلف طبقه‌بندی و تفکیک عیوب در دو بخش هزینه محاسباتی و درصد پاسخ صحیح به داده‌های تست برای هر دو مجموعه انتخاب ویژگی‌ها انجام شده است. برای این منظور، لازم است، نتایج آزمایشات در زمان اجرای محاسبات در شرایط یکسانی قرار گیرد. در تمامی تست‌ها از لپ‌تاپی با مشخصات CPU= ۲/۴ و چهار گیگ رم استفاده شد.

جدول ۸. مقایسه نتایج سیستم‌های طبقه‌بندی جهت تشخیص عیوب ورق‌های کامپوزیت

روش انجام کار	هزینه محاسباتی انتخاب IDE بر حسب دقیقه	درصد پاسخ‌گویی صحیح انتخاب IDE
SVM	۵	٪۸۲/۵
ANFIS	۱۰	٪۱۰۰
MLP	۴	٪۸۲/۵
RBF	۵	٪۸۲/۵
KNN	۲	٪۸۰
XCS	۶	٪۹۰
IMPROVED XCS	۶	٪۹۷/۵

جدول ۹. مقایسه نتایج سیستم‌های طبقه‌بندی جهت تشخیص عیوب بلرینگ موتور القایی

روش انجام کار	هزینه محاسباتی انتخاب IDE بر حسب دقیقه	درصد پاسخ‌گویی صحیح انتخاب IDE
SVM	۵	٪۸۸/۶
MLP	۴	٪۸۴
KNN	۲/۵	٪۷۹/۵
CLASSIC XCS	۴/۵	٪۸۷
IMPROVED XCS	۵	٪۹۰/۹

۵. نتیجه‌گیری

در این مقاله عیب‌یابی ورق‌های کامپوزیت با استفاده از پردازش سیگنال ارتعاشی و روش‌های مبتنی بر هوش مصنوعی انجام شد. سیگنال‌های تست ارتعاشی تعدادی ورق کامپوزیتی سالم و دارای عیب ثبت گردید و به کمک روش‌های مختلف پردازش سیگنال حوزه زمان-فرکانس تعدادی ویژگی از این سیگنال‌ها استخراج شد. سپس مؤثرترین ویژگی‌ها که حاوی اطلاعات بیشتری هستند به‌عنوان ورودی به سیستم‌های مختلف طبقه‌بندی داده شد. سیستم‌های طبقه‌بندی را ماشین بردار پشتیبان، سیستم استنتاج فازی عصبی تطبیقی، KNN، شبکه‌های عصبی مصنوعی، الگوریتم XCS و الگوریتم پیشنهادی XCS بهبود یافته تشکیل می‌دادند.

نتایج به‌دست آمده نشان‌دهنده برتری روش ANFIS از نظر درصد دقت می‌باشد. درحالی‌که این روش بیشترین

مدت زمان اجرا را در تعداد اجراهای برابر دارد. در مقابل، روش پیشنهادی XCS بهبود یافته درصد دقت نسبتاً کمتری نسبت به ANFIS داشت. اما از نظر زمان اجرا مدت کمتری را به خود اختصاص داده است. همچنین مقایسه‌ای بین نتایج روش‌های مختلف طبقه‌بندی و تفکیک عیوب در دو بخش هزینه محاسباتی و درصد پاسخ صحیح به داده‌های تست انجام گردید. برای اینکه نتایج آزمایشات در زمان اجرای محاسبات در شرایط یکسانی قرار بگیرند در تمامی تست‌ها از رایانه‌ای با مشخصات ۲/۴ CPU= و چهار گیگ رم استفاده شد.

مجموعه داده‌های مربوط به حالت سالم، عیب رینگ بیرونی و عیب رینگ درونی مورد تست و ارزیابی قرار گرفته، نشان داد که روش پیشنهادی هم از زمان هزینه محاسباتی و هم درصد پاسخ‌گویی صحیح نسبت به روش‌های دیگر، عملکرد بهتری دارد.

- [1] Sohn, M.S, Hu .X.Z, Kim J. K and Walker.L, "Impact damage characterization of carbon fiber /epoxy composites with mlti-layer reinforcement", *Composites:Part B*, vol.31, 2000, pp.681-69.
- [2] Chen C. and C. Mo: "A method for intelligent fault diagnosis of rotating machinery", *Digital Signal Processing*, vol.14, 2004, pp.203–217.
- [3] Rafiee, J., M.A. Rafiee, and P.W. Tse: "Application of mother wavelet functions for automatic gear and bearing fault diagnosis", *Expert Systems with Applications*, vol.37, 2010, pp.4568–4579.
- [4] Goddu, G., B. Li, M.Y. Chow, and J.C. Hung: "Motor Bearing Fault Diagnosis by a Fundamental Frequency Amplitude Based Fuzzy Decision System," *IEEE Industrial Electronics Society Conference*, vol.4, 1998, pp.1961-1965.
- [5] Zio, E. and G. Gola: "A Neuro-Fuzzy technique for fault diagnosis and its application to rotating machinery", *Reliability Engineering & System Safety*, vol.94, no.1, 2009, pp.78–88.
- [6] Song, O., T. W. Ha, and L. Librescu, "Dynamics of anisotropic composite cantilevers weakened by multiple transverse open cracks," *Engineering Fracture Mechanics*, vol.70, no.1, 2003, pp.105–123.
- [7] Just-Agosto, F., D. Serrano, B. Shafiq, and A. Cecchini, "Neural network based nondestructive evaluation of sandwich composites," *Composites B*, vol.39, no.1, 2008, pp.217–225.
- [8] Perera, R., A. Ruiz, and C.Manzano, "Performance assessment of multicriteria damage identification genetic algorithms", *Computers and Structures*, vol.87, no.12, 2009, pp.120–127.
- [9] Friswell, M. I., J. E. T. Penny, and S. D. Garvey, "A combined genetic and eigensensitivity algorithmfor the location of damage in structures," *Computers and Structures*, vol.69, no5, 1998, pp.547-556.
- [10] Fang, X., H. Luo, and J. Tang, "Structural damage detection using neural network with learning rate improvement," *Computers and Structures*, vol.83, no.25-26, 2005, pp.2150–2161.
- [11] Beena, P. and R. Ganguli, "Structural damage detection usin fuzzy cognitive maps and hebbian learning", *Applied Soft Computing Journal*, vol.11, no.1, 2011, pp.1014–1020.
- [12] Kuo, H. C. andH. K. Chang, "A new symbiotic evolution-based fuzzy-neural approach to fault diagnosis of marine propulsion systems," *Engineering Applications of Artificial Intelligence*, vol.17, no.8, 2004, pp. 919–930.
- [13] Wang, W. Q., M. F. Golnaraghi, and F. Ismail, "Prognosis of machine health condition using neuro-fuzzy systems", *Mechanical Systems and Signal Processing*, vol.18, no.4, 2004, pp.813–831.
- [14] Pawar, P. M. and R. Ganguli, "Genetic fuzzy system for online structural health monitoring of composite helicopter rotor blades," *Mechanical Systems and Signal Processing*, vol.21, no.5, 2007, pp.2212–2236.
- [15] ShariatPanahi, M., N.MoshtaghiYazdani, "An Improved XCSR classifier system for data mining with limited training samples", *Global Journal of Science, Engineering and Technology*, Issue.2, 2012, pp.52-57.
- [16] Thomson, W. T., "A review of on-line condition monitoringtechniques for three-phase squirrel cage induction motors Past present and future," *IEEE SDEMPED'99, Spain*, 1999, pp.3–18.
- [17] Nandi, S., H. A. Toliat, X. Li, "Condition monitoring and fault diagnosis of electrical motors-A Review," *IEEE Transactions on Energy Conversion*, vol.20, no.4, 2005, pp.719-29.

- [18] Farrar, C. R., S. Doebling and C. R. Prime, "A summary review of vibration-based damage identification methods" *The Shock and Vibration Digest*, vol.30, no.2, 1998, pp.91-105.
- [19] Thomson, W. T., "A review of on-line condition monitoring techniques for three-phase squirrel cage induction motors— Past present and future," *IEEE SDEMPED '99, Spain*, 1999, pp.3–18.
- [20] Tandon, N. and A. Choudhury, "A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings," *Journal of Tribology International*, vol.32, no.8, 1999, pp.469-480.
- [21] Singh, G.K., Sa'ad Ahmed Saleh Al Kazzaz, "Induction machine drive condition monitoring and diagnostic researcha survey," *Journal of electric power research*, vol.64, 2003, pp.145-158.
- [22] Benbouzid, M. E. H., "A review of induction motors signature analysis as a medium for faults detection," *IEEE Trans. Industrial Electronics*, vol.47, no.5, 2000, pp.984-993.
- [23] Benbouzid, M. E. H., "What stator current processingbased technique to use for induction motor rotor faults diagnosis?" *IEEE Trans. Energy Conversion*, vol.18, no.2, 2003, pp.238-244.
- [24] Lebold, M.; McClintic, K.; Campbell, R.; Byington, C.; Maynard, K. "Review of Vibration Analysis Methods for Gearbox Diagnostics and Prognostics", *Proceedings of the 54th Meeting of the Society for Machinery Failure Prevention Technology, Virginia Beach, VA, May 1-4, 2000*, p. 623-634.
- [25] Yazici, B., G. B. Kliman, "An adaptive statistical timefrequency method for detection of broken bars and bearing faults in motors," *IEEE Trans. On Industry App.*, vol.35, no.2, 1999, pp.442-52.
- [26] Nikolaou, N.G., I.A. Antoniadis, "Rolling element bearing fault diagnosis using wavelet packets," *Journal of NDT & E*, vol.35, Issue.3, 2002, pp.197-205.
- [27] Prabhakar, S., A. R. Mohanty, A. S Sekhar, "Application of discrete wavelet transform for detection of ball bearing race faults," *Journal of Tribology International*, vol.35, no.12, 2002, pp.793-800.
- [28] Eren, L., J. Devaney, "Bearing Damage Detection via Wavelet Packet Decomposition of the Stator Current," *IEEE Trans. On Instrumentation and Measurement*, vol.53, no.2, 2004, pp.431-6.
- [29] Polikar, R, "Ensemble based systems in decision making", *IEEE circuits & systems magazine*, vol.6 no.3, 2006, pp.21-45.

1. ANFIS
2. Preventive Maintenance
3. Artificial Intelligence
4. Hamilton
5. Timoshenko
6. Just-Agosto
7. Perera
8. Genetic Algorithm (GA)
9. Pareto
10. Friswell
11. Fang
12. Bina
13. Gnguli
14. Hebbain learning
15. Kuo
16. Chang
17. Wang
18. Pawar
19. Ganguli
20. Thomson

-
21. Tandon
 22. Singh
 23. Benbouzid
 24. Lebold
 25. Yazici
 26. Fast Fourier transform (FFT)
 27. Li
 28. Nikolaou
 29. Prabhakar
 30. Eren
 31. Exhaustive Search
 32. Supervised
 33. Unsupervised
 34. Reinforcement
 35. Classifier Systems
 36. If-then
 37. Queries
 38. Learning Classifier System (LCS)
 39. Strength
 40. Extended Classifier System (XCS)
 41. Binary
 42. Learning Agents
 43. Adaptive
 44. International Data Encryption Algorithm (IDEA)
 45. K Nearest Neighbor
 46. Support Vector Machine
 47. Radial Basis Function
 48. Multi-Layer Perceptron
 49. Adaptive Neuro-Fuzzy Inference System
 50. Subtractive