

تحلیل خرابی‌های کوپلینگ با داده‌های پایش وضعیت با رویکرد یادگیری ماشین

رضا صادقی، کارشناسی ارشد مهندسی صنایع، گرایش کیفیت و بهره‌وری، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران، rezasdg98@gmail.com، ۰۹۱۸۲۱۹۱۲۶۰

علی حسین زاده کاشان (نویسنده مسئول)، دکتری مهندسی صنایع، دانشیار گروه سیستم‌های اقتصادی و اجتماعی، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران، a.kashan@modares.ac.ir، ۰۲۱۸۲۸۸۴۳۹۸

بختیار استادی، دکتری مهندسی صنایع، دانشیار گروه مدیریت سیستم و بهره‌وری، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران، bostadi@modares.ac.ir، ۰۲۱۸۲۸۸۴۳۸۵

چکیده: کوپلینگ‌ها در صنعت کاربرد بسیاری داشته و این تجهیزات با توجه به چرخش مداوم، همیشه در معرض نقص و خرابی هستند. تجزیه و تحلیل ارتعاش یک تکنیک مناسب برای تحلیل خرابی‌ها و تشخیص حالات خرابی تجهیزات دوار است. هدف این پژوهش تحلیل خرابی‌های رخ داده در یک کوپلینگ است که داده‌های آن در حالت عادی و سه حالت نقص با چهار سنسور متصل به کوپلینگ جمع‌آوری شده است. بدین منظور دو نوع استخراج ویژگی متفاوت استفاده شده و همچنین از هفت الگوریتم یادگیری ماشین و یک الگوریتم یادگیری عمیق برای طبقه‌بندی حالات بهره برده شده است. در این پژوهش به بررسی کارکرد هر کدام از الگوریتم‌های پیاده‌سازی شده و اهمیت ویژگی‌های استخراجی پرداخته و به بررسی نقش سنسورها و بررسی اهمیت آن‌ها برای کاهش تعداد سنسورها پرداخته شده است. از نتایج این پژوهش می‌توان به تعیین اهمیت بالای ویژگی‌های حوزه فرکانس در دقت مدل‌های اجرا شده و همچنین کارایی بالای دو عدد از سنسورها برای طبقه‌بندی اشاره نمود.

کلمات کلیدی: نگهداری و تعمیرات پیشگویانه، یادگیری ماشین، تحلیل خرابی، تجهیزات دوار

۱. مقدمه

محرك موتور در تراز درستی با بار نباشد. عدم تعادل وزنی^۲ یکی دیگر از حالات خرابی است که به دلیل نابرابری ولتاژهای فاز در یک موتور سه فاز یا به دلیل عدم یکنواختی اینرسی بار و متفاوت بودن مرکز جرم با مرکز چرخش رخ می‌دهد. لقی مکانیکی^۳ نیز یکی دیگر از حالات خرابی کوپلینگ‌ها است و زمانی رخ می‌دهد که اجزای چرخان به درستی نصب نشده باشند و یا به دلیل سایش، خوردگی یا خستگی، لقی شوند.

برای تشخیص این خرابی‌ها و حالات خرابی رخ داده می‌توان از یک سیستم تشخیص کارآمد برای تشخیص وضعیت و زمان خرابی استفاده نمود. از این رو یک سیستم نظارت بر وضعیت و تشخیص عیب موثر و کارآمد در یک صنعت بسیار مفید است. یکی از روش‌های بررسی برای تشخیص عیب در ماشین دوار استفاده از

ماشین‌آلات دوار به طور گسترده در صنایع امروزی استفاده می‌شوند. کارکرد برخی از این ماشین‌آلات بسیار حیاتی بوده و خرابی این تجهیزات ممکن است به هزینه‌های بسیار بالا و خطرات ایمنی منجر گردد. کوپلینگ‌ها با اتصال دو شفت به یکدیگر برای انتقال نیرو، نقش حیاتی در صنایع مختلف ایفا می‌کنند، در حالی که برای ناهماهنگی یا حرکت بین آن‌ها نیز جای می‌گیرند. آن‌ها اجزای ضروری در سیستم‌ها و ماشین‌آلات مکانیکی مانند پمپ‌ها، ژنراتورها، کمپرسورها و موتورها هستند. این تجهیزات دارای سه حالت خرابی مهم و عمده هستند. ناهم‌محوری^۱ یکی از این حالات خرابی است و زمانی رخ می‌دهد که خطوط مرکزی موتور و محورهای تجهیزات محرک در یک راستا با یکدیگر نباشند و محور

^۲ Looseness <https://doi.org/10.48313/jqem.2024.212638>

^۱ Misalignment

^۳ Unbalance

آنالیز ارتعاش است. حتی در بهترین شرایط عملیاتی، ماشین‌ها به دلیل نقص‌های جزئی کمی لرزش خواهند داشت و به همین دلیل هر دستگاه در حالت عادی نیز دارای سطحی از ارتعاش است. با بروز مشکلات مکانیکی در عناصر دوار، سطح و الگوی ارتعاش در این تجهیزات نسبت به حالت عادی تغییر کرده و این تغییر می‌تواند توسط حسگرهای شتاب‌سنج قابل تشخیص بوده و توسط این حسگرها ثبت گردند [۱۹،۲۰]. سیگنال‌های ارتعاشی اطلاعاتی مرتبط با حالات خرابی و نقص رخ داده هستند که این سیگنال‌ها را می‌توان در طول کارکرد تجهیزات در حالات مختلف برای بررسی سیگنال‌های مرتبط با هر نوع از نقص‌ها جمع‌آوری کرد [۸].

سیگنال‌های جمع‌آوری شده توسط حسگرها برای طبقه‌بندی خرابی‌ها مناسب نبوده و نیاز به استخراج ویژگی داده‌ها است. استخراج ویژگی به چند دلیل یکی از مراحل مهم تحلیل خرابی است؛ کاهش ابعاد محاسباتی، کاهش نویز و افزایش کارایی طبقه‌بندی از دلایل اهمیت این مرحله است. ویژگی‌های متعددی برای استخراج از داده‌های لرزش وجود دارد که ویژگی حوزه زمان و ویژگی‌های حوزه فرکانس از مهم‌ترین آن‌ها است [۲۱]. ویژگی‌های حوزه زمان در پردازش سیگنال، ویژگی‌های ضروری یک سیگنال هستند که می‌توانند مستقیماً مشاهده و اندازه‌گیری شوند زیرا سیگنال در طول زمان تغییر می‌کند. این ویژگی‌ها برای محاسبه به پیچیدگی محاسباتی بالایی نیاز ندارند، می‌توانند در برنامه‌های بلادرنگ مورد استفاده قرار گیرند و پیاده‌سازی آن‌ها آسان است و در محیط‌های کم‌نویز عملکرد خوبی دارند [۱۶،۱۱]. ویژگی‌های حوزه فرکانس ویژگی‌هایی هستند که از تجزیه و تحلیل یک سیگنال یا یک تابع با توجه به فرکانس به جای زمان به دست می‌آیند. ویژگی‌های حوزه فرکانس می‌توانند ویژگی‌های طیفی سیگنال، مانند اجزای فرکانس، طیف توان، انرژی، آنتروپی و فاز را آشکار کنند. در حوزه فرکانس، یک سیگنال با فرکانس‌های تشکیل‌دهنده آن و دامنه‌ها یا قدرت‌های مربوطه نشان داده می‌شود. این نمایش به ویژه برای سیگنال‌هایی مفید است که دارای فرکانس‌های متعددی هستند که روی یکدیگر قرار گرفته‌اند. ویژگی‌های دامنه فرکانس راهی برای درک و دست‌کاری سیگنال‌ها بر اساس محتوای فرکانس آن‌ها است که می‌تواند برای بسیاری از کاربردهای عملی حیاتی باشد [۱۷،۳].

یادگیری ماشین^۴ به ابزاری محوری در تجزیه و تحلیل خرابی تجهیزات دوار با تجزیه و تحلیل سیگنال‌های ارتعاشی تبدیل شده است. کاربرد یادگیری ماشین در تجزیه و تحلیل شکست یک زمینه پویا با تحقیق و توسعه مداوم است. این نوید تبدیل استراتژی‌های تعمیر و نگهداری از واکنشی به پیش‌بینی کننده را دارد و در نتیجه در زمان و منابع صرفه‌جویی می‌کند و از خرابی‌های غیرمنتظره تجهیزات جلوگیری می‌کند. پس از آموزش مدل‌های یادگیری ماشین، این مدل‌ها می‌توانند ناهنجاری‌هایی را در داده‌های ارتعاشی جدید که ممکن است نشان‌دهنده خطا باشد را تشخیص دهند. آن‌ها همچنین می‌توانند نوع عیب را نیز طبقه‌بندی کنند. مدل‌های پیشرفته یادگیری ماشین می‌توانند به طور مداوم دانش خود را با داده‌های جدید به روز کنند. علیرغم پیشرفت، چالش‌هایی مانند داده‌های دارای خطا، هزینه‌های بالا و نیاز به مجموعه داده‌های بزرگ برای آموزش همچنان وجود دارد [۴،۱۰].

در این مقاله به تحلیل داده‌های لرزش یک کویلینگ که توسط چهار سنسور ثبت شده، پرداخته شده است. بدین منظور داده‌های لرزش برای شناسایی تأثیر تعداد داده‌ها در هر دسته، به دسته‌های مختلف تقسیم شده سپس از چهار ویژگی حوزه زمان و دو ویژگی حوزه فرکانس برای استخراج ویژگی هر دسته استفاده گردیده است سپس با استفاده از الگوریتم‌های طبقه‌بندی، به طبقه‌بندی داده‌ها پرداخته شده و در آخر محدودیت تعداد سنسورها نیز بررسی شده است. در ادامه مقاله ابتدا به بیان خلاصه‌ای از پیشینه پژوهش و روش‌شناسی پژوهش و در آخر به بررسی نتایج و بحث و نتیجه‌گیری پرداخته شده است.

۲. پیشینه پژوهش

عملیات نگهداری و تعمیرات می‌تواند از کارهای بسیار جزئی تا کارهای سیستماتیک متغیر باشد و سیاست‌های نگهداری و تعمیرات نیز به تبع آن تفاوت می‌کند. این سیاست‌ها طبق نظر کارشناسان و طبق شرکت و سازمان موردنظر، امکانات موجود، اهمیت نگهداری و تعمیرات، محدودیت‌ها و موارد دیگر تعیین می‌شود. این سیاست‌ها در تفکر سیستماتیک، نحوه اجرا و میزان اهمیت به هر یک از بخش‌های نگهداری و تعمیرات تفاوت داشته و میزان استفاده از تکنولوژی نیز در آن‌ها متفاوت است. در مقالات

و استانداردهای مختلف انواع دسته‌بندی‌ها برای انواع استراتژی‌های نگهداری و تعمیرات معرفی شده است و این دسته‌بندی می‌تواند به شکل‌های مختلفی ارائه شود. یکی از ابتدایی‌ترین روش‌ها، نگهداری و تعمیرات اصلاحی است. تعمیر و نگهداری اصلاحی یا اجرا تا شکست، یک برنامه واکنشی است که فقط تعمیرات اضطراری را انجام می‌دهد. در این رویکرد فعالیت‌ها فقط بعد از خرابی اعمال می‌گردد و هیچ مداخله‌ای تا قبل از زمان وقوع یک خرابی صورت نمی‌گیرد. نگهداری و تعمیرات پیشگیرانه یکی دیگر از سیاست‌های نگهداری و تعمیرات است. در این روش، نگهداری از تجهیزات در دوره‌های زمانی خاصی بر اساس یک برنامه زمان‌بندی منظم صورت می‌گیرد. در این سیاست سعی می‌شود تا با یک سری از بررسی‌ها و جایگزینی‌ها و بازرسی‌های مجدد برای اجزایی که نرخ خرابی بالایی دارند، تعداد خرابی‌های ناگهانی را کاهش دهند. نگهداری و تعمیرات پیشبینانه یکی از بروزترین سیاست‌های نگهداری و تعمیرات است. تعمیر و نگهداری پیشبینانه نوعی تعمیر و نگهداری است که از ابزارهای تجزیه و تحلیل داده‌ها برای پیش‌بینی احتمال وقوع خرابی استفاده می‌کند که مدرن‌ترین و محبوب‌ترین تکنیک تعمیر و نگهداری بیان شده در ادبیات این حوزه است [۱۵، ۱۲].


یکی از روش‌های نگهداری و تعمیرات پیشبینانه، نگهداری و تعمیرات مبتنی بر شرایط است. این مدل به عنوان یک برنامه تعمیر و نگهداری تعریف می‌شود که راه‌حل‌های تعمیر و نگهداری را بر اساس اطلاعات جمع‌آوری شده از پایش وضعیت توصیه می‌کند و شامل سه مرحله اصلی جمع‌آوری داده‌ها، پردازش داده‌ها و تصمیم‌گیری تعمیر و نگهداری است [۱۸]. تجزیه و تحلیل خطا مبتنی بر هوش مصنوعی جامعه مربوطه را برای توسعه مدل‌های موثر تشخیص خطا و پیش‌آگهی خرابی برای ماشین‌آلات دوار جذب می‌کند. از این رو، چالش‌های مختلفی در رابطه با ارزیابی مدل، مناسب بودن برای کاربردهای دنیای واقعی، توسعه مدل خاص خطا، وجود خطای مرکب، سازگاری دامنه، منبع داده، اکتساب داده، ترکیب داده‌ها، انتخاب الگوریتم و بهینه‌سازی مطرح می‌شود. حل این چالش‌ها برای هر یک از اجزای ماشین دوار ضروری است زیرا هر شماره از هر قطعه تأثیر منحصر به فردی بر شاخص‌های حیاتی یک ماشین دارد [۲].

یکی از روش‌های تشخیص عیب در موتورهای الکتریکی استفاده از سیگنال‌های ارتعاشی و ابزارهای یادگیری ماشین است. جونیور

و همکارانش [۵] در مقاله خود به تشخیص عیب در موتورهای الکتریکی با استفاده از شبکه‌های عصبی کانولوشنال تک بعدی با سیگنال‌های ارتعاشی چند کاناله پرداخته‌اند. هدف از این مقاله شناسایی و تشخیص شش نوع مختلف خطا در یک موتور الکتریکی با استفاده از دو شتاب‌سنج که در دو جهت مختلف اندازه‌گیری می‌کنند، بوده است. در این مقاله از روشی مبتنی بر سیگنال‌های ارتعاشی و شبکه عصبی پیچشی یک بعدی برای تشخیص عیب در موتورهای الکتریکی استفاده شده است. داده‌های این مقاله به صورت سیگنال‌های ارتعاشی موتورهای الکتریکی بوده که در دو جهت اندازه‌گیری می‌شوند و سپس به طور هم‌زمان به عنوان ورودی به شبکه عصبی برای آموزش این الگوریتم داده می‌شوند. در این مقاله محققان با تنظیم ابرپارامتر به شبکه‌ای با دقت ۹۹.۹۲ درصد دست پیدا کرده‌اند که به دلیل استفاده از شبکه‌های تک بعدی بسیار سریع است.

استخراج ویژگی یکی مراحل مهم برای تشخیص خطای ماشین‌های دوار است. سانجز و همکارانش [۱۳] نیز در مقاله خود به رتبه‌بندی ویژگی‌ها برای تشخیص چند خطا در ماشین‌های دوار پرداخته‌اند. در این مقاله از دو الگوریتم جنگل تصادفی و K-نزدیکترین همسایگی استفاده شده است. هدف این مقاله ارائه یک چارچوب روش‌شناختی برای تشخیص چند خطا در ماشین‌های دوار از طریق استفاده از رتبه‌بندی بوده است. برای رتبه‌بندی ویژگی‌ها در این مقاله، از ۳۰ ویژگی حوزه زمان که دارای ۲۴ ویژگی معمولی و ۶ ویژگی غیرمعارف بوده، استفاده شده است. از نتایج این مقاله می‌توان به بهبود دقت در طبقه‌بندی با استفاده از ویژگی‌های غیرمعارف به مقدار بالا و افزایش سرعت طبقه‌بندی با استفاده از این ویژگی‌ها را بیان نمود.

در این مقاله به بررسی خرابی‌های رخ داده در یک کویلینگ پرداخته شده است. هدف این مقاله بررسی نتایج استفاده از الگوریتم‌های یادگیری ماشین و روش استخراج ویژگی مختلف برای تعیین و پیش‌بینی نوع خرابی رخ داده است. از نوآوری‌های این مقاله می‌توان به استفاده از روش طبقه‌بندی متنوع و چندین روش استخراج ویژگی و همچنین استفاده از بسته‌بندی‌های متنوع برای استخراج ویژگی داده‌ها اشاره نمود. بدین منظور برای بررسی تاثیر ویژگی‌ها از دو روش ویژگی‌های حوزه زمان و ویژگی‌های حوزه فرکانس استفاده شده است که در آخر برای بررسی بیشتر از ترکیب این ویژگی‌ها نیز برای طبقه‌بندی خرابی‌ها استفاده شده



شکل ۱. نمایی از داده‌های استفاده‌شده

۴. روش‌شناسی

در این قسمت به معرفی کوتاهی از الگوریتم‌ها و تئوری روش‌های استفاده‌شده در الگوریتم پیاده شده می‌پردازیم. در این قسمت ابتدا به روش‌های استخراج ویژگی مورد استفاده در این تحقیق پرداخته و سپس به معرفی الگوریتم کاهش ابعاد مورد استفاده می‌پردازیم و در آخر به معرفی الگوریتم‌های یادگیری ماشین مورد استفاده، روش تعیین ابرپارامترهای الگوریتم‌ها و معیارهای ارزیابی مورد استفاده در این مقاله خواهیم پرداخت.

۴-۱. استخراج ویژگی

در این پژوهش برای استخراج ویژگی داده‌های لرزش، از چهار ویژگی حوزه زمان و از دو ویژگی حوزه فرکانس بهره برده شده است. دلیل انتخاب این ویژگی‌ها، استفاده بیشتر آن‌ها در مقالات مرتبط و همچنین عدم استفاده هم‌زمان آن‌ها در ادبیات و عدم مقایسه عملکرد آن‌ها بوده است.

ویژگی‌های حوزه زمان استفاده‌شده در این پژوهش، چهار ویژگی میانگین، میانه، واریانس و ریشه میانگین مربع‌ها است. این ویژگی‌ها برای محاسبه از روابط ساده ریاضی بهره برده و به همین جهت سرعت محاسباتی بالایی دارند. خروجی آن‌ها برای هر دسته از داده خام ورودی فقط یک عدد است که حاصل رابطه ریاضی ویژگی است. جدول ۱ حاوی ویژگی‌های حوزه زمان مورد استفاده و روابط ریاضی محاسبه آن‌ها است.

است. برای بررسی نتایج طبقه‌بندی کننده‌های مختلف نیز از هشت طبقه‌بندی کننده استفاده شده است که یک مورد از آن‌ها از یادگیری عمیق برای طبقه‌بندی بهره می‌برد. برای مقایسه زمان واکنش مختلف سیستم‌ها به تغییرات رخ داده نیز از اندازه دسته‌های مختلف داده‌ها استفاده شده است. در ادبیات این موضوع نمونه‌ای برای بررسی تمامی موارد ذکر شده از جمله ترکیب چند روش استخراج ویژگی به همراه چندین طبقه‌بندی کننده متفاوت برای داده‌های ثبت‌شده کولپینگ انجام پذیرفته نشده است.

۳. داده‌های مورد استفاده

داده‌های مورد استفاده در این مقاله مربوط به یک کولپینگ است که از یک طرف به یک موتور سه فاز با دور اسمی ۱۶۵۰ دور بر دقیقه و با توان ۹۰ وات و از طرف دیگر به یک دیسک که وظیفه شبیه ساز بار را دارد، متصل است. از چهار سنسور شتاب‌سنج (لرزش‌سنج) مدل PCB 352C33 و با نرخ ثبت داده ۲۵۰۰ داده لرزش در ثانیه برای ثبت لرزش کولپینگ بهره برده شده است که دو عدد از آن‌ها در سمت عمودی و افقی کولپینگ (پولی) و دو عدد دیگر در سمت افق و عمودی روبروی کولپینگ (دیسک) نصب شده است. برای جمع‌آوری داده‌ها ابتدا کولپینگ در وضعیت عادی به مدت ۹۰۰ ثانیه شروع به کار کرده و داده‌ها با هر چهار سنسور معرفی شده جمع‌آوری گردیده شده است. سپس کولپینگ در سه حالت خرابی معرفی شده در قسمت مقدمه (ناهم‌محوری، عدم تعادل وزنی، لقی مکانیکی)، توسط تغییراتی که در قسمت بار انجام پذیرفته است، قرار گرفته و سپس مانند حالت عادی به مدت ۹۰۰ ثانیه داده‌ها جمع‌آوری گردیده‌اند. به صورت کلی هر سنسور در هر حالت ۲۲۵۰۰۰۰۰ داده خام لرزش ثبت گردیده است. در شکل ۱ نمایی از داده‌های ثبت‌شده برای ۱۰۰ داده سنسور شماره ۱ در چهار حالت کولپینگ قابل مشاهده است.

ویژگی حوزه زمان	رابطه
میانگین	$Mean(X) = \frac{1}{n} \sum_{i=1}^n x_i$
میانه	$Median(X) = \begin{cases} X \left[\frac{n+1}{2} \right] & (n \text{ فرد}) \\ \frac{X \left[\frac{n}{2} \right] + X \left[\frac{n}{2} + 1 \right]}{2} & (n \text{ زوج}) \end{cases}$
واریانس	$Var(X) = \frac{\sum (x_i - \bar{x})^2}{n-1}$
ریشه میانگین مربع‌ها ^۵	$RMS(X) = \sqrt{\frac{1}{n} \sum x_i^2}$

تبدیل کسینوس گسسته می‌تواند برای تجزیه و تحلیل طیف فرکانس یک سیگنال، فشرده‌سازی و کدگذاری داده‌ها با کاهش تعداد ضرایب مورد نیاز برای نمایش سیگنال، و استخراج ویژگی‌ها از سیگنال‌ها برای کاربردهای مختلف استفاده شود. این تبدیل شبیه تبدیل فوریه گسسته است، اما فقط از اعداد حقیقی به جای اعداد مختلط استفاده می‌کند. این تبدیل دارای خاصیت فشرده‌سازی انرژی قوی است، به این معنی که بیشتر اطلاعات یا انرژی سیگنال در چند جزء فرکانس پایین متمرکز شده است، در حالی که اجزای فرکانس بالا مقادیر کوچک یا ناچیز دارند. این ویژگی این تبدیل را برای فشرده‌سازی داده‌ها مناسب می‌کند، زیرا اجزای فرکانس بالا را می‌توان با حداقل افت کیفیت حذف کرد. در ادامه رابطه ریاضی تبدیل کسینوس گسسته بیان شده است [۷].

$$X[k] = \sum_{n=0}^{N-1} x[n] \cos \left[\frac{\pi}{N} \left(n + \frac{1}{2} \right) k \right]$$

۲-۴. کاهش ابعاد

کاهش ابعاد تکنیکی است که تعداد ویژگی‌های یک مجموعه داده را کاهش می‌دهد و در عین حال اطلاعات مهم را تا حد امکان حفظ می‌کند. در این مقاله برای کاهش ابعاد ویژگی‌ها از روش تجزیه و تحلیل مؤلفه اصلی بهره برده شده است. تجزیه و تحلیل مؤلفه اصلی^۸ (PCA) تکنیکی است که تعداد ابعاد یک مجموعه داده را با تبدیل متغیرهای اصلی به مجموعه کوچک‌تری از متغیرهای جدید به نام مؤلفه‌های اصلی کاهش می‌دهد. تجزیه و تحلیل مؤلفه اصلی یک روش آماری است که از یک تبدیل متعامد استفاده می‌کند که مجموعه‌ای از متغیرهای همبسته را به مجموعه‌ای از متغیرهای غیر همبسته تبدیل می‌کند. مؤلفه‌های اصلی ترکیب‌های خطی متغیرهای اصلی هستند که حداکثر مقدار تغییر در داده‌ها را ثبت می‌کنند [۱].

۳-۴. طبقه‌بندی داده‌ها

ویژگی‌های حوزه فرکانس مورد استفاده در این پژوهش، دو ویژگی تبدیل فوریه سریع و تبدیل کسینوس گسسته است.

تبدیل فوریه سریع^۶ (FFT) الگوریتمی است که تبدیل فوریه گسسته یک دنباله یا معکوس آن را محاسبه می‌کند. تحلیل فوریه سیگنال را از دامنه اصلی به نمایشی در حوزه فرکانس و بالعکس تبدیل می‌کند. تبدیل فوریه گسسته با تجزیه دنباله‌ای از مقادیر به اجزای فرکانس‌های مختلف به دست می‌آید. اگر داده‌های ورودی تبدیل فوریه واقعی باشد، خروجی دارای خاصیت تقارن مزدوج خواهد بود. این ویژگی می‌تواند برای کاهش محاسبه و ذخیره‌سازی به نصف، مورد استفاده قرار گیرد، زیرا فقط ضرایب فرکانس مثبت باید محاسبه و ذخیره شوند. در ادامه رابطه تبدیل فوریه سریع بیان شده است [۲۲،۶].

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-i2\pi kn/N}$$

تبدیل کسینوس گسسته^۷ (DCT) یک عملیات ریاضی است که یک توالی محدود از نقاط داده را به مجموع توابع کسینوس نوسان در فرکانس‌های مختلف تبدیل می‌کند. این تبدیل یک تکنیک تبدیل پرکاربرد در پردازش سیگنال و فشرده‌سازی داده‌ها است.

^۵ Discrete cosine transform

^۸ Principal Component Analysis

^۶ Root Mean Square

^۷ Fast Fourier transform

طبقه‌بندی داده‌ها در یادگیری ماشین فرآیندی است که در آن یک مدل آموزش می‌بیند تا برچسب‌های از پیش تعریف‌شده را به داده‌های جدید و دیده نشده اختصاص دهد. این کار با یادگیری از مجموعه داده‌ای که قبلاً برچسب‌گذاری شده است انجام می‌شود که به عنوان مجموعه آموزشی شناخته می‌شود. در این قسمت به معرفی الگوریتم‌های استفاده‌شده برای طبقه‌بندی حالات خرابی و روش تعیین ابرپارامترهای الگوریتم‌های طبقه‌بندی و در آخر به روش‌های ارزیابی و مقایسه الگوریتم‌ها خواهیم پرداخت.

۳-۴-۱. الگوریتم‌های طبقه‌بندی

در این پژوهش برای طبقه‌بندی داده‌ها از هشت الگوریتم طبقه‌بندی یادگیری ماشین استفاده گردیده است. دلیل انتخاب این الگوریتم‌ها، قدرت بالای طبقه‌بندی طبق ادبیات بررسی‌شده و مقایسه بین آن‌ها است. در ادامه به بیان خلاصه‌ای از روش طبقه‌بندی این الگوریتم‌ها خواهیم پرداخت [۱۴، ۹].

الگوریتم پرسپترون چندلایه^۹ (MLP): یک کلاس از شبکه عصبی مصنوعی پیشخور است که حداقل دارای یک لایه ورودی، یک لایه پنهان و یک لایه خروجی است. به جز گره‌های ورودی، هر گره نورونی است که از یک تابع فعال‌سازی غیرخطی استفاده می‌کند. این الگوریتم از یک تکنیک یادگیری نظارت‌شده به نام پس انتشار برای آموزش شبکه استفاده می‌کند که قادر به یادگیری مدل‌های غیرخطی نیز است.

الگوریتم K نزدیکترین همسایگی^{۱۰} (KNN): این الگوریتم فرض می‌کند که چیزهای مشابه در مجاورت نزدیک وجود دارند. در این الگوریتم هیچ مدلی به جز نگهداری کل مجموعه داده وجود ندارد بنابراین این نوع یادگیری مبتنی بر نمونه است و به کمک همسایگان داده ورودی، اقدام به طبقه‌بندی آن می‌کند.

درخت تصمیم^{۱۱} (DT): درخت تصمیم یک ابزار پشتیبانی تصمیم است که از یک مدل درخت مانند از تصمیمات و پیامدهای احتمالی آن‌ها استفاده می‌کند. درخت تصمیم یک ساختار

فلوچارت مانند است که در آن هر گره داخلی نشان‌دهنده یک آزمایش بر روی یک ویژگی، هر شاخه نشان‌دهنده نتیجه آزمایش، و هر گره برگ نشان‌دهنده یک برچسب کلاس است.

جنگل تصادفی^{۱۲} (RF): جنگل تصادفی یک روش یادگیری مجموعه‌ای برای طبقه‌بندی، رگرسیون و سایر وظایف است که با ساختن تعداد زیادی درخت تصمیم در زمان آموزش عمل می‌کند. برای کارهای طبقه‌بندی، خروجی جنگل تصادفی کلاسی است که توسط اکثر درختان انتخاب‌شده است. این موضوع سادگی درخت‌های تصمیم‌گیری را با انعطاف‌پذیری ترکیب می‌کند که منجر به بهبود گسترده در دقت می‌شود.

رگرسیون لجستیک^{۱۳} (LogReg): رگرسیون لجستیک یک روش آماری برای تجزیه و تحلیل یک مجموعه داده است که در آن یک یا چند متغیر مستقل وجود دارد که یک نتیجه را تعیین می‌کند. نتیجه با یک متغیر دوگانه که در آن فقط دو نتیجه ممکن وجود دارد، اندازه‌گیری می‌شود.

بیز ساده^{۱۴} (NB): این الگوریتم با به‌کارگیری قضیه بیز و فرض استقلال بین متغیرها، اقدام به طبقه‌بندی داده‌ها می‌کند. این الگوریتم احتمالی است که مبتنی بر قضیه بیز است، که احتمال وقوع یک رویداد را بر اساس دانش قبلی از شرایطی که ممکن است با رویداد مرتبط باشد محاسبه می‌کند.

تجزیه و تحلیل تشخیص خطی^{۱۵} (LDA): این الگوریتم یک روش آماری برای تشخیص دسته‌ها به وسیله بیشینه‌سازی نسبت پراکندگی بین گروه‌ها به درون گروه‌ها است. در این روش آماری متغیر وابسته به صورت یک ترکیب خطی از متغیرهای دیگر مدل‌سازی می‌شود.

شبکه عصبی کانولوشنال^{۱۶} (CNN): شبکه‌های عصبی مصنوعی سیستم‌های پردازش محاسباتی هستند که به شدت از نحوه عملکرد سیستم‌های عصبی بیولوژیکی (مانند مغز انسان) الهام گرفته شده‌اند. شبکه‌های عصبی مصنوعی عمدتاً از تعداد زیادی

^{۱۲} Logistic Regression

^{۱۴} Naive Bayes

^{۱۵} Linear Discriminant Analysis

^{۱۶} Convolutional Neural Network

^۹ Multilayer perceptron

^{۱۰} K-Nearest Neighbors

^{۱۱} Decision Tree

^{۱۲} Random Forest

گره محاسباتی به هم پیوسته تشکیل شده‌اند تا به طور جمعی از ورودی یاد بگیرند تا خروجی نهایی آن را بهینه کنند. این الگوریتم به مرحله استخراج ویژگی نیاز نداشته و با توجه با کارکرد خود به طبقه‌بندی داده‌ها می‌پردازد.

۴-۳-۲. تعیین ابرپارامترهای الگوریتم‌ها

ابروپارامترها در الگوریتم‌های طبقه‌بندی یادگیری ماشین تنظیماتی هستند که باید قبل از شروع فرآیند یادگیری تنظیم شوند. این پارامترها روند آموزش را هدایت کرده و می‌توانند به طور قابل توجهی بر عملکرد مدل تأثیر بگذارند. برای یافتن ابرپارامترها در این پژوهش از روش جستجوی شبکه‌ای استفاده شده است. جستجوی شبکه‌ای روشی برای یافتن بهترین ترکیب ابرپارامترها برای یک مدل یادگیری ماشینی است. در این روش همه ترکیبات از مقادیر ممکن برای هر ابرپارامتر انتخاب شده و مدل یادگیری و تست را انجام می‌دهد و در آخر بهترین ترکیب ممکن برای ابرپارامترها طبق عملکرد مدل، انتخاب می‌شود.

۴-۳-۳. معیارهای ارزیابی

برای مقایسه الگوریتم‌های پیاده شده نیاز به معیارهایی است که در این مقاله از معیارهای متداول مقایسه چندین الگوریتم طبقه‌بندی یادگیری ماشین بهره برده شده است. یکی از مهم‌ترین معیارهای مورد استفاده ماتریس درهم‌ریختگی الگوریتم‌ها بوده است که روشی برای خلاصه کردن عملکرد یک مدل طبقه‌بندی است. یک ماتریس درهم‌ریختگی تعداد پیش‌بینی‌های درست و نادرست انجام‌شده توسط مدل برای هر کلاس و همچنین تعداد کل نمونه‌های متعلق به هر کلاس را نشان می‌دهد. از این ماتریس می‌توان معیارهای دقت (Accuracy)، صحت (Precision)، بازیابی (Recall) و امتیاز F1 (F1-score) را محاسبه نمود. صحت نشان دهنده این است که مدل طبقه‌بندی چند درصد از داده‌ها را به‌طور کلی درست طبقه‌بندی می‌کند. دقت بر این تمرکز دارد که مدل طبقه‌بندی چند درصد در هنگام پیش‌بینی کلاس هدف درست، تشخیص صحیح می‌دهد. یادآوری (حساسیت) اندازه‌گیری می‌کند که چگونه مدل می‌تواند تمام اشیاء کلاس هدف را پیدا کند. امتیاز F1 دقت و یادآوری را متعادل کرده و یک امتیاز برای عملکرد مدل ارائه می‌دهد.

۴-۳-۴. اهمیت ویژگی‌ها

ویژگی‌های استخراجی از داده‌ها تعیین‌کننده عملکرد طبقه‌بندی کننده‌ها هستند و هر کدام از ویژگی‌های استخراجی می‌توانند نقش خاصی را در طبقه‌بندی ایفا کنند. اهمیت ویژگی‌ها در عملکرد طبقه‌بندی کننده‌ها یکسان نبوده و نسبت به یکدیگر دارای اهمیت متفاوتی هستند. در این مقاله برای تعیین اهمیت هر کدام از ویژگی‌ها از روش اهمیت جایگشت استفاده گردیده است. اهمیت جایگشت تکنیکی است برای اندازه‌گیری میزان کمک هر ویژگی به عملکرد یک مدل برازش در یک مجموعه داده معین. با به هم زدن تصادفی مقادیر یک ویژگی و مشاهده تغییر در امتیاز مدل کار می‌کند. هر چه افت امتیاز بیشتر باشد، ویژگی مهم‌تر است.

۵. روش پیاده‌سازی الگوریتم پیشنهادی


در این بخش به معرفی روش پیاده‌سازی الگوریتم پیشنهادی و مراحل آن خواهیم پرداخت. در مرحله اول، داده‌های خام برچسب‌گذاری شده و برای چهار حالت کوپلینگ برچسب‌های ۱ تا ۴ انتصاب می‌شود. سپس برای استخراج ویژگی و طبقه‌بندی داده‌ها، داده‌های خام را به ۱۸ بسته با ابعاد مختلف تقسیم می‌کنیم. هدف از تعداد متفاوت اعضای بسته‌های اعداد، تحلیل اهمیت و نتایج بسته‌های مختلف است. بدین منظور داده‌های خام در بسته‌های ۵۰۰-۱۰۰۰-۱۵۰۰-۲۰۰۰-۲۵۰۰-۳۰۰۰-۳۵۰۰-۴۰۰۰-۴۵۰۰-۵۰۰۰-۶۰۰۰-۷۰۰۰-۸۰۰۰-۹۰۰۰-۱۰۰۰۰-۱۱۰۰۰-۱۲۰۰۰-۱۲۵۰۰ عددی تقسیم‌بندی شده است. این تعداد از اعضای بسته با توجه به نرخ جمع‌آوری داده‌ها توسط سنسورها، زمان ۰.۰۲ ثانیه تا ۰.۵ ثانیه را شامل می‌شود. دلیل استفاده از این تعداد از داده‌ها برای هر بسته از داده‌ها، مفید بودن زمان تشخیص عیب است و داده‌های زیر ۵۰۰ عدد در هر بسته، به دلیل کم بودن داده‌ها برای استخراج ویژگی و همچنین شناخت ویژگی‌های داده مفید نبوده و همچنین داده‌های بالای ۱۲۵۰۰ عدد نیز به دلیل افزایش زمان تشخیص خرابی مفید نیست.

در مرحله بعد به استخراج ویژگی‌ها و کاهش ابعاد آن‌ها پرداخته شده است. بدین منظور برای فاز اول طبقه‌بندی، صرفاً از ویژگی‌های حوزه زمان استفاده گردیده و در فاز دوم از ویژگی‌های حوزه زمان و حوزه فرکانس به صورت هم‌زمان استفاده شده است. در فاز اول، چهار ویژگی حوزه زمان برای هر سنسور محاسبه گشته و در مجموع در هر بسته ۱۶ ویژگی خواهیم داشت پس از کاهش

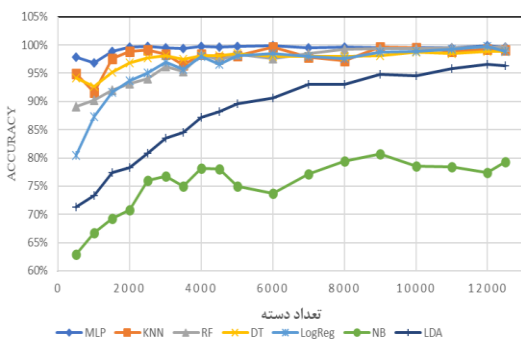
ابعاد، این تعداد ویژگی با حفظ ۹۵ درصد واریانس ویژگی‌ها به ۷ و ۸ ویژگی در بسته‌های مختلف کاهش پیدا می‌کند. در فاز دوم تعداد ویژگی‌های حوزه زمان ثابت بوده و مانند فاز قبل برای هر بسته ۱۶ ویژگی خواهیم داشت و با توجه به تغییر تعداد ویژگی تبدیل فوریه سریع و تبدیل کسینوس گسسته با توجه به ابعاد بسته‌ها و با توجه به متقارن بودن تبدیل فوریه سریع، برای هر بسته با تعداد مشخصی از داده‌ها، به تعداد نصف داده‌ها ویژگی تبدیل فوریه و به تعداد داده‌های خام هر بسته ویژگی تبدیل کسینوس گسسته خواهیم داشت. برای کاهش ابعاد از تعداد یکسان ویژگی‌ها برای همه دسته‌ها بهره برده شده و در هر بسته ۷ ویژگی حوزه زمان و ۲۰ ویژگی تبدیل فوریه و ۲۸ ویژگی تبدیل کسینوس گسسته (جمعاً ۵۵ ویژگی برای هر بسته) خواهیم داشت.

۶-۱. دقت مدل‌های طبقه‌بندی حالت چهار سنسور

در این قسمت به بررسی دقت مدل‌های طبقه‌بندی، بدون محدودیت تعداد سنسور و با استفاده از چهار سنسور خواهیم پرداخت. شکل ۲ حاوی دقت مدل‌های مختلف در بسته‌های با تعداد داده مختلف برای فاز اول و استفاده از ویژگی‌های حوزه زمان است. شکل ۳ نیز حاوی دقت مدل‌ها در فاز دوم و استفاده از ویژگی‌های حوزه زمان-فرکانس به صورت هم‌زمان است.



شکل ۲. دقت مدل‌های طبقه‌بندی برای ویژگی‌های حوزه زمان



شکل ۳. دقت مدل‌های طبقه‌بندی برای ویژگی‌های حوزه زمان-فرکانس

در شکل ۲ مشاهده می‌کنیم دقت طبقه‌بندی الگوریتم‌های مختلف برای ویژگی‌های حوزه زمان در تمامی اندازه بسته‌ها، الگوریتم پرسپترون چندلایه (MLP) از دقت بالایی برخوردار بوده و الگوریتم‌های K-نزدیکترین همسایگی (KNN) و جنگل تصادفی (RF) و درخت تصمیم (DT) از دقت خوبی برخوردار هستند،

در مرحله بعد به طبقه‌بندی داده‌ها پرداخته‌شده و بدین منظور ابتدا با روش جستجوی شبکه‌ای به یافتن بهینه‌ترین ابرپارامترهای مدل‌های طبقه‌بندی پرداخته شده است. در مرحله بعد به تقسیم داده‌ها به داده‌های آموزش و تست به نسبت ۲ به ۱ پرداخته‌شده و در آخر با ویژگی‌های به دست آمده در مرحله قبل، برای فاز اول و فاز دوم و برای ۱۸ بسته تعیین شده، مدل‌های طبقه‌بندی مرحله یادگیری و تست را گذرانده‌اند. نتایج در قسمت بعد بیان گردیده است.

در آخر برای تعیین نقش و تاثیر تعداد سنسورهای جمع‌آوری داده و همچنین بررسی کارایی هر کدام از سنسورها، پس از حذف داده‌های سنسور، مراحل قبل به صورت کامل برای هر چهار سنسور به صورت تکی و جفت سنسور عمودی و افقی کوپلینگ سمت موتور و جفت سنسور عمودی و افقی کوپلینگ سمت بار انجام پذیرفته است.


۶. نتایج

در این قسمت به نتایج مدل پیشنهادی برای طبقه‌بندی داده‌های لرزش کوپلینگ خواهیم پرداخت.


۶-۱. دقت مدل‌های طبقه‌بندی

در این قسمت به بررسی دقت مدل‌های طبقه‌بندی مختلف در بسته‌های مختلف در دو فاز معرفی شده خواهیم پرداخت. به دلیل یکسان بودن تعداد داده‌ها برای چهار حالت موتور، شاخص‌های

کاهش تعداد نمودارها، به مقایسه میانگین تغییرات دقت الگوریتم‌های طبقه‌بندی برای هر سنسور می‌پردازیم. شکل ۵ نشان‌دهنده میانگین تغییرات دقت هفت مدل‌های طبقه‌بندی (به جز شبکه عصبی کانولوشنال) برای حالت استفاده از ویژگی‌های حوزه زمان به ازای هر سنسور است. شکل ۶ نیز نشان‌دهنده همین تغییرات برای حالت استفاده از ویژگی‌های حوزه زمان-فرکانس است.



شکل ۵. تغییرات میانگین دقت الگوریتم‌ها با استفاده از ویژگی‌های حوزه زمان




شکل ۶. تغییرات میانگین دقت الگوریتم‌ها با استفاده از ویژگی‌های حوزه زمان-فرکانس

شکل ۷ نشان‌دهنده تغییرات دقت الگوریتم شبکه عصبی کانولوشنال به ازای هر سنسور در حالت محدودیت سنسور است.

سایر الگوریتم‌ها از دقت مناسبی برخوردار نیستند. همچنین مشاهده می‌شود با افزایش تعداد اندازه اعضای بسته‌ها دقت الگوریتم‌ها به صورت صعودی است. در شکل ۳ نیز مشاهده می‌کنیم دقت طبقه‌بندی الگوریتم‌ها با استفاده از ویژگی‌های حوزه زمان-فرکانس به صورت هم‌زمان نسبت به استفاده از ویژگی‌های حوزه زمان بسیار بهبود یافته است. در این قسمت نیز الگوریتم پرسپترون چندلایه (MLP) برای طبقه‌بندی حالات در همه بسته‌ها عملکرد بهتری ارائه داده و پس از آن مثل حالت قبل الگوریتم‌های K-نزدیکترین همسایگی (KNN) و درخت تصمیم (DT) و جنگل تصادفی (RF) هستند. همچنین دقت طبقه‌بندی‌ها برای اندازه دسته ۴۰۰۰ به بالا برای چهار الگوریتم برتر تقریباً یکسان بوده و تغییر زیادی ندارد.

حال به بررسی دقت مدل‌ها در حالت استفاده از مدل طبقه‌بندی شبکه عصبی کانولوشنال می‌پردازیم. این الگوریتم بدون نیاز به مرحله استخراج ویژگی و صرفاً با داده‌های خام اولیه، اقدام به طبقه‌بندی حالات خرابی می‌پردازد. شکل ۴ نشان‌دهنده دقت این مدل در دسته‌های مختلف است.

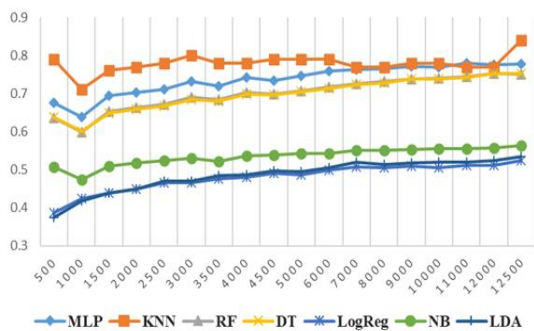


شکل ۴. دقت طبقه‌بندی الگوریتم شبکه عصبی کانولوشنال


با توجه به شکل ۴ دقت طبقه‌بندی الگوریتم شبکه عصبی کانولوشنال بسیار برای اندازه دسته‌های مختلف متفاوت بوده و برای بسته‌های با اندازه داده پایین عملکرد مناسبی داشته است و تعداد اعضای داخل بسته از اهمیت کمتری نسبت به تعداد خود بسته‌ها برای آموزش مدل دارا بوده است.

۶-۱-۲. دقت مدل‌های طبقه‌بندی حالت محدودیت سنسور

حال در این قسمت به بررسی نتایج دقت مدل‌های طبقه‌بندی با توجه به محدودیت سنسور خواهیم پرداخت. بدین منظور برای



شکل ۸. میانگین دقت طبقه‌بندی الگوریتم‌ها برای حالت محدودیت سنسور با ویژگی‌های حوزه زمان

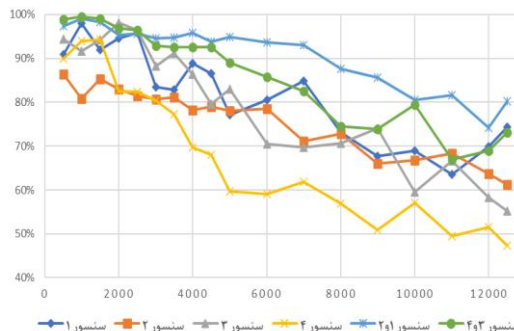


شکل ۹. میانگین دقت طبقه‌بندی الگوریتم‌ها برای حالت محدودیت سنسور با ویژگی‌های حوزه زمان-فرکانس

طبق شکل ۸ مشاهده می‌کنیم که میانگین دقت طبقه‌بندی الگوریتم ک-نزدیکترین همسایه (KNN) و پرسپترون چندلایه (MLP) از دقت بالایی برخوردار بوده و الگوریتم‌های و جنگل تصادفی (RF) و درخت تصمیم (DT) نیز از دقت مشابه و پایین‌ترین برخوردار هستند و شکل ۹ نیز نشان‌دهنده همین نتایج با تفاوت اندکی است و الگوریتم ک-نزدیکترین همسایه (KNN) از عملکرد ضعیف‌ترین نسبت به حالت قبل داراست. این نتایج نشان می‌دهد که الگوریتم پرسپترون چندلایه در حالت محدودیت سنسور نیز از دقت مناسبی برخوردار بوده و افت کمتری را در دقت دارد.

۴-۲. اهمیت ویژگی‌ها

در این قسمت به بررسی اهمیت ویژگی‌های استخراج‌شده در طبقه‌بندی حالات خرابی با الگوریتم‌های یادگیری ماشین خواهیم پرداخت. بدین منظور همان‌طور که در قسمت‌های قبل بیان گردید از روش اهمیت جایگشت استفاده شده است. برای این کار ابتدا



شکل ۷. تغییرات دقت الگوریتم شبکه عصبی کانولوشنال در حالت محدودیت تعداد سنسور

شکل ۵ نشان‌دهنده افت شدید دقت میانگین الگوریتم‌ها در حالت استفاده از استفاده از سنسور ۱ و ۳ به صورت تکی در حالتی که فقط از ویژگی‌های حوزه زمان استفاده می‌کنیم، است. در بقیه حالات محدودیت تعداد سنسور شاهد تغییرات زیادی نبوده و حتی در حالات استفاده از دسته‌های دارای ۵۰۰۰ داده به بالا شاهد افزایش میانگین دقت الگوریتم‌ها نیز هستیم. شکل ۶ نیز نشان‌دهنده این است که در حالت استفاده از ویژگی‌های حوزه زمان-فرکانس در همه حالات محدودیت سنسور میانگین دقت مدل‌ها کاهش می‌یابد ولی استفاده از سنسور ۳ و ۴ در حالت جفت سنسور و استفاده از سنسور ۴ در حالت تک سنسور گزینه‌های بهتری هستند. طبق شکل ۷ نیز مشاهده می‌کنیم که بهترین حالت استفاده از سنسورها طبق الگوریتم شبکه عصبی کانولوشنال، استفاده از سنسور ۱ یا ۲ بوده و بدترین عملکرد مختص سنسور ۴ است که متفاوت با قسمت‌های قبل است. در استفاده از جفت سنسورها نیز، استفاده از سنسورهای ۱ و ۲ دقت بهتری را دارا است که باز هم خلاف قسمت‌های قبل و استفاده از الگوریتم‌های کلاسیک است.


شکل ۸ نشان‌دهنده میانگین دقت طبقه‌بندی الگوریتم‌های طبقه‌بندی در همه حالات محدودیت سنسور با استفاده از ویژگی‌های حوزه زمان است که جهت مقایسه عملکرد الگوریتم‌های طبقه‌بندی برای حالات محدودیت سنسور است. شکل ۹ نشان‌دهنده همین نمودار و با استفاده از ویژگی‌های حوزه زمان-فرکانس است.

استخراجی از تبدیل فوریه اهمیت بسیار بالاتری را از ویژگی‌های استخراجی حوزه زمان و تبدیل کسینوس گسسته دارد.

۷. نتیجه‌گیری و پیشنهادات

نگهداری و تعمیرات یکی از ارکان اصلی صنعت و تولید است که در اغلب موارد هزینه‌های بالایی را به صنعت تحمیل می‌کند. همین امر باعث تصمیم به بهبود روش‌های نگهداری و تعمیرات در صنعت از دیرباز تا به الان شده است. یکی از مهم‌ترین تجهیزات در صنایع، تجهیزات دوار هستند که به دلیل کار کردن با ساعات بالای این قطعات و اصطکاک و دیگر عوامل محیطی، دچار خرابی و نقص‌های زیادی می‌شوند. با پیشرفت هوش مصنوعی و سنسورهای پایش وضعیت و ارزان‌تر شدن و در دسترس‌تر شدن این عوامل، باعث افزایش استفاده روش‌های داده‌محور برای پایش وضعیت دائمی قطعات شده است. در این پژوهش اقدام به پیاده‌سازی مدلی برای طبقه‌بندی داده‌های یک کپلینگ با چندین ویژگی پرداخته که هدف از آن بررسی کارایی الگوریتم‌های طبقه‌بندی یادگیری ماشین و همین‌طور اهمیت ویژگی‌های موردبررسی در طبقه‌بندی و نتایج محدودیت سنسور است. بدین منظور داده‌های کپلینگ در چهار سنسور و چهار حالت کارکرد با استفاده از ویژگی‌های حوزه زمان و زمان-فرکانس موردبررسی قرار گرفت. طبق نتایج بیان‌شده مشاهده می‌کنیم الگوریتم‌های پرسپترون چندلایه (MLP) و ک-نزدیکترین همسایه (KNN) و جنگل تصادفی (RF) در اغلب موارد دارای عملکرد مناسب و قابل اتکایی بوده و حتی با کاهش تعداد سنسورها نیز دقت و عملکرد مناسبی را ارائه می‌دهند. بالاترین دقت الگوریتم‌های طبقه‌بندی در حالت استفاده از ویژگی‌های حوزه زمان مربوط به پرسپترون چندلایه با دقت طبقه‌بندی ۹۴.۴٪ بوده و با استفاده از ویژگی‌های حوزه زمان-فرکانس نیز به الگوریتم پرسپترون چندلایه با دقت ۹۹.۹۱٪ تعلق دارد. بالاترین دقت الگوریتم شبکه عصبی کانولوشنال که بدون نیاز به استخراج ویژگی اقدام به طبقه‌بندی داده‌ها می‌کند نیز به ۹۹.۷۴٪ می‌رسد. همچنین در حوزه محدودیت سنسورها نیز مشاهده می‌کنیم که استفاده از جفت سنسور افقی و عمودی قسمت بار (دیسک) و در صورت استفاده از تک سنسور، سنسور افقی قسمت بار (دیسک) برای کاهش تعداد سنسورها بسیار مناسب بوده و در اغلب موارد با استفاده از بهترین الگوریتم طبقه‌بندی بیان‌شده، تفاوت آن با حالت استفاده از چهار سنسور کمتر از ۲۰ درصد است. این بدان معنی است که در صورت


اهمیت ویژگی‌ها در همه الگوریتم‌ها محاسبه‌شده و برای کاهش حجم شکل‌ها، شکل ۱۰ که نشان‌دهنده مجموع اهمیت ویژگی‌های همه الگوریتم‌ها است برای هر ویژگی به‌دست‌آمده است. عدد مقابل ویژگی‌های چهارگانه حوزه زمان، نشانگر شماره سنسور لرزش سنج است که به ترتیب سنسورهای عمودی و افقی سمت موتور و سنسورهای عمودی و افقی سمت بار است.



شکل ۱۰. اهمیت ویژگی‌های حوزه زمان برای همه طبقه‌بندی‌ها

طبق نتایج شکل ۱۰ به صورت کلی ویژگی‌های سنسور ۲ و ۴ دارای اهمیت بالاتری برای طبقه‌بندی حالات خرابی بوده و در طبقه‌بندی نقش پررنگ‌تری را ایفا می‌کنند. همچنین مشاهده می‌کنیم در ویژگی‌های حوزه زمان به صورت کلی، اهمیت ویژگی‌های میانگین و واریانس در همه سنسورها بالاتر است.

حال به بررسی اهمیت ویژگی‌های حوزه فرکانس و مقایسه آن با اهمیت ویژگی‌های حوزه زمان خواهیم پرداخت. شکل ۱۱ نشان‌دهنده اهمیت ویژگی‌های حوزه زمان (جمع همه ویژگی‌های حوزه زمان) و دو ویژگی حوزه فرکانس است.



شکل ۱۱. اهمیت ویژگی‌های حوزه زمان و فرکانس

در شکل ۱۱ نیز مشاهده می‌کنیم که با استفاده از ویژگی‌های حوزه زمان-فرکانس برای طبقه‌بندی حالات خرابی، ویژگی‌های حوزه فرکانس از اهمیت بالاتری برای طبقه‌بندی حالات برخوردار هستند. همچنین در این شکل مشاهده می‌کنیم که ویژگی‌های

4. Jablon, L. S., Avila, S. L., Borba, B., Mourão, G. L., Freitas, F. L., & Penz, C. A. (2021). Diagnosis of rotating machine unbalance using machine learning algorithms on vibration orbital features. *Journal of Vibration and Control*, 27(3-4), 468-476.
5. Junior, R. F. R., dos Santos Areias, I. A., Campos, M. M., Teixeira, C. E., da Silva, L. E. B., & Gomes, G. F. (2022). Fault detection and diagnosis in electric motors using 1d convolutional neural networks with multi-channel vibration signals. *Measurement*, 190, 110759.
6. Kanwal, N., Girdhar, A., Kaur, L., & Bhullar, J. S. (2019, April). Detection of digital image forgery using fast fourier transform and local features. In *2019 international conference on automation, computational and technology management (ICACTM)* (pp. 262-267). IEEE.
7. Karhan, Z., & Ergen, B. (2013, April). Classification of face images using discrete cosine transform. In *2013 21st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
8. Kırıl, Z., & Karagülle, H. (2006). Vibration analysis of rolling element bearings with various defects under the action of an unbalanced force. *Mechanical systems and signal processing*, 20(8), 1967-1991.
9. Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. (2006). Machine learning: a review of classification and combining techniques. *Artificial Intelligence Review*, 26, 159-190.
10. Manikandan, S., & Duraiavelu, K. (2021). Fault diagnosis of various rotating equipment using machine learning approaches—A review. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, 235(2), 629-642.
11. Nayana, B. R., & Geethanjali, P. (2017). Analysis of statistical time-domain features effectiveness in identification of bearing faults from vibration signal. *IEEE Sensors Journal*, 17(17), 5618-5625.
12. Pintelon, L., Pinjala, S. K., & Vereecke, A. (2006). Evaluating the effectiveness of maintenance strategies. *Journal of quality in maintenance engineering*, 12(1), 7-20.

نیاز به کاهش هزینه‌های سنسورها و جمع‌آوری داده‌ها و تحلیل آن‌ها می‌توان از سنسور سمت افقی روبروی کوپلینگ (دیسک) و یا از جفت سنسور سمت عمودی و افقی روبروی کوپلینگ (دیسک) استفاده نمود. یکی دیگر از نتایج بررسی ویژگی‌های بیان‌شده، تعیین تغییرات دقت الگوریتم‌های طبقه‌بندی در صورت استفاده از ویژگی‌های حوزه زمان و حوزه زمان-فرکانس است. تغییرات دقت الگوریتم‌های با دقت بالا در حالت استفاده از ویژگی‌های حوزه زمان در حالت استفاده از ویژگی‌های حوزه زمان-فرکانس، کمتر از ۲۵ درصد بوده است. برای تحقیقات آینده استفاده از حالات مختلف بیشتر برای نقص و ثبت داده در این حالات بسیار در امر طبقه‌بندی مفید بوده و می‌تواند قابل نتایج قابل‌تأملی باشد. استفاده از زیر حالت‌های خرابی، مانند ارائه چندین زیر حالت خرابی برای حالت خرابی ناهم‌محوری می‌تواند برای بررسی عمیق‌تر مناسب بوده و نتایج جالبی را دارا باشد. در استفاده از الگوریتم‌های یادگیری ماشین، استفاده از الگوریتم‌های سفارشی‌شده و استفاده از آموزش گروهی جهت بهبود دقت طبقه‌بندی می‌تواند مفید باشد و همین‌طور استفاده از ویژگی‌های حوزه زمان و فرکانس بیشتر جهت بررسی عمیق‌تر نیز، می‌تواند از موضوعات قابل‌بررسی باشد.

مراجع

1. Abdi, H., & Williams, L. J. (2010). Principal component analysis. *Wiley interdisciplinary reviews: computational statistics*, 2(4), 433-459.
2. Akmal, M. (2023). Enhancing Rotary Machine Reliability Through Condition-Based Maintenance Optimization. *Pakistan Journal of Scientific Research*, 3(1), 7-13.
3. Dargie, W. (2009, August). Analysis of time and frequency domain features of accelerometer measurements. In *2009 Proceedings of 18th International Conference on Computer Communications and Networks* (pp. 1-6). IEEE.

transform for facial expression recognition. In *Transactions on Engineering Technologies: International MultiConference of Engineers and Computer Scientists 2014* (pp. 413-424). Springer Netherlands.

13. Sanchez, R. V., Lucero, P., Vasquez, R. E., Cerrada, M., Macancela, J. C., & Cabrera, D. (2018). Feature ranking for multi-fault diagnosis of rotating machinery by using random forest and KNN. *Journal of Intelligent & Fuzzy Systems*, 34(6), 3463-3473.
14. Sen, P.C., Hajra, M. and Ghosh, M., 2020. Supervised classification algorithms in machine learning: A survey and review. In *Emerging Technology in Modelling and Graphics: Proceedings of IEM Graph 2018* (pp. 99-111). Springer Singapore.
15. Shafiee, M. (2015). Maintenance strategy selection problem: an MCDM overview. *Journal of Quality in Maintenance Engineering*, 21(4), 378-402.
16. Sreejith, B., Verma, A. K., & Srividya, A. (2008, December). Fault diagnosis of rolling element bearing using time-domain features and neural networks. In *2008 IEEE region 10 and the third international conference on industrial and information systems* (pp. 1-6). IEEE.
17. Srinivasan, V., Eswaran, C., & Sriraam, A. N. (2005). Artificial neural network based epileptic detection using time-domain and frequency-domain features. *Journal of Medical Systems*, 29, 647-660.
18. Telford, S., Mazhar, M. I., & Howard, I. (2011, January). Condition based maintenance (CBM) in the oil and gas industry: An overview of methods and techniques. In *Proceedings of the 2011 international conference on industrial engineering and operations management, Kuala Lumpur, Malaysia* (pp. 22-24).
19. Umbrajkaar, A. M., Krishnamoorthy, A., & Dhumale, R. B. (2020). Vibration analysis of shaft misalignment using machine learning approach under variable load conditions. *Shock and Vibration*, 2020, 1-12.
20. Vishwakarma, M., Purohit, R., Harshlata, V., & Rajput, P. R. A. M. O. D. (2017). Vibration analysis & condition monitoring for rotating machines: a review. *Materials Today: Proceedings*, 4(2), 2659-2664.
21. Yang, H., Mathew, J., & Ma, L. (2003). Vibration feature extraction techniques for fault diagnosis of rotating machinery: a literature survey. In *Asia-pacific vibration conference* (No. 42460, pp. 801-807).
22. Zhang, D., Ding, D., Li, J., & Liu, Q. (2015). Pca based extracting feature using fast fourier