

# عیب‌یابی هوشمند خرابی یاتاقان غلتشی در شرایط کاری متغیر با شبکه عصبی پیچشی

## برمبنای سیگنال‌های حوزه زمان و فرکانس

علی فراهانی، علی داودآبادی، سمیه محمدی، مهدی بهزاد\*

آزمایشگاه پایش وضعیت، دانشکده مهندسی مکانیک، دانشگاه صنعتی شریف، تهران، ایران

### چکیده

تشخیص هوشمند عیوب یاتاقان غلتشی امری بسیار مهم در زمینه پایش وضعیت تجهیزات دوار است. تشخیص زودهنگام عیب‌ها جهت نگهداری و برنامه‌ریزی در واحدهای صنعتی ارزش اقتصادی بسیاری دارد. استفاده از الگوریتم‌های سنتی تشخیص هوشمند، متشکل از دو بخش استخراج ویژگی و دسته‌بندی، زمان‌بر و نیازمند تجربه کارشناسان این حوزه برای استخراج مشخصه‌های مناسب هستند. شبکه عصبی پیچشی در مقایسه با روش‌های سنتی، می‌تواند با دقت بالا، حجم وسیعی از اطلاعات را پردازش و ویژگی‌ها را به طور خودکار از سیگنال ارتعاشی استخراج کند. به همین سبب در این پژوهش سعی می‌شود با استفاده از این روش، علاوه بر تعیین سلامت یا خرابی یاتاقان غلتشی، نوع عیوب در صورت تشخیص خرابی شناسایی گردد. در این راستا از یک شبکه عصبی پیچشی ساده و کم عمق برای بررسی سه عیب متداول یاتاقان غلتشی استفاده می‌شود. به منظور یافتن بهترین دقت و کارایی شبکه از ورودی‌های مختلف از جمله سیگنال زمانی، طیف فرکانسی و انولوپ سیگنال استفاده و نتایج آنها با یکدیگر مقایسه می‌گردد. برای پیاده‌سازی و ارزیابی الگوریتم‌ها، یک ستاپ آزمایشگاهی طراحی و ساخته شده است و با ایجاد خرابی‌های مصنوعی روی یاتاقان‌ها، تست‌های آزمایشگاهی در چهار وضعیت سالم، خرابی رینگ داخلی، خرابی رینگ خارجی و خرابی ساچمه در ۳۶ شرایط کاری مختلف (۹ سرعت دورانی متفاوت و در هر سرعت با ۴ حالت بارگذاری) انجام گردیده است. نتایج حاصله نشان می‌دهد که دقت و کارایی مدل در تشخیص وجود و نوع عیب یاتاقان غلتشی در حالتی که ورودی آن طیف فرکانسی است، بیشتر از دو ورودی دیگر و برابر ۹۵ درصد می‌باشد.

### کلمات کلیدی

پایش وضعیت، عیب‌یابی هوشمند، شبکه عصبی پیچشی، یاتاقان غلتشی، شرایط کاری متغیر، آنالیز ارتعاشات.

خرابی یاتاقان‌های غلتشی یکی از مهم‌ترین دلایل خرابی ماشین‌های دوار است<sup>[۱]</sup>. از این رو توسعه یک مدل هوشمند برای تشخیص زودهنگام عیب یاتاقان‌ها می‌تواند بسیار حائز اهمیت باشد. با فراگیر شدن روزافزون روش‌های پایش وضعیت در صنعت و تلاش برای کاهش هزینه‌ها از طریق کاهش خرابی و کاهش تعداد توقفات پیش‌بینی نشده خط تولید، صاحبان صنایع و متخصصین به جمع‌آوری داده از وضعیت سلامت ماشین‌آلات، برای شناسایی و پیش‌بینی خرابی‌های احتمالی روی آورده‌اند. به همین دلیل ارائه راه‌های ساده و سریع جهت تحلیل حجم عظیمی از داده‌ها برای عیب‌یابی، بیش از پیش احساس می‌شود. تا به امروز روش‌ها و مدل‌های متعددی برای این منظور توسط محققین و پژوهشگران ابداع و معرفی شده است. یکی از این روش‌ها استفاده از الگوریتم‌های هوشمند یادگیری عمیق می‌باشد. این الگوریتم‌ها دقت و سرعت بالایی در تحلیل داده‌های حجیم دارند. در این پژوهش با استفاده از یک شبکه عصبی پیچشی<sup>۱</sup> به بررسی و مقایسه طیف‌های زمانی و فرکانسی سیگنال‌های ارتعاشی بدست آمده از یک یاتاقان غلتشی خودتنظیم به کار رفته در ستاپ آزمایشگاهی در شرایط کاری متغیر پرداخته می‌شود.

هدف این مقاله، بررسی و مقایسه عملکرد مدل شبکه عصبی پیچشی با انواع ورودی‌های مختلف شامل سیگنال‌های زمانی، طیف فرکانسی<sup>۲</sup> و انولوپ سیگنال<sup>۳</sup> جهت عیب‌یابی یاتاقان‌های غلتشی است. هدف از عیب‌یابی در اصل شناسایی الگوی خرابی برای عیوب مختلف است، که هر یک منجر به طیف ارتعاشی متفاوتی می‌شوند و در نتیجه آن، تحلیل سیگنال ارتعاشی امکان بررسی وضعیت سلامت یاتاقان و عیب‌یابی آن را فراهم می‌سازد. عیب‌یابی یاتاقان‌ها با پردازش سیگنال‌های ارتعاشی دریافت شده از سنسورها توسط شبکه‌های عصبی پیچشی، که توانایی بالایی در پردازش تصویر دارند می‌تواند مفید واقع شود. وجه تمایز این شبکه‌ها این است که می‌تواند به طور خودکار ویژگی‌ها را از سیگنال‌ها و تصاویر استخراج کند. این شبکه‌ها برای جلوگیری از بیش‌برازش به داده‌های آموزشی بیشتری نسبت به الگوریتم‌های معمولی نیاز دارند. دو ویژگی اصلی این نوع شبکه‌ها، اشتراک وزن<sup>۴</sup> و ادغام فضایی<sup>۵</sup> است که آن را برای کاربردهای بینایی ماشین، که ورودی‌های آنها معمولاً داده‌های دوبعدی هستند، بسیار مناسب می‌کند، که البته برای پردازش زبان‌های طبیعی و تشخیص گفتار که ورودی‌های آنها یک بعدی است، نیز استفاده شده است<sup>[۲ و ۳]</sup>.

به دلیل توانایی‌های بالای شبکه‌های عصبی پیچشی، بسیاری از پژوهشگران به دنبال نوآوری در این بخش و ایجاد ساختارهای جدید جهت بالا بردن دقت و سرعت هستند، برخی به دنبال استفاده از تبدیل‌های مختلف جهت اعمال روی داده‌های ورودی و نوآوری در نوع داده‌های مورد استفاده در شبکه بوده‌اند و عده‌ای نیز هر دو بخش را مورد توجه قرار داده‌اند. در پژوهشی سانگ و همکاران<sup>[۴]</sup> یک شبکه عصبی پیچشی با کرنل‌های گسترده پیشنهاد کردند که از داده‌های یک بعدی به عنوان ورودی استفاده می‌کند. مدل آنها مقاومت خوبی در برابر نویز از خود نشان داده است. چن و همکاران<sup>[۵]</sup> یک شبکه عصبی پیچشی multi-scale همراه با یک مدل LSTM<sup>۶</sup> را پیشنهاد دادند که از سیگنال ارتعاشی خام به عنوان ورودی استفاده کرده است. فنگ و همکاران<sup>[۶]</sup> یک روش تشخیص عیب را پیشنهاد کردند که از تصویر طیف تبدیل فوریه سریع<sup>۷</sup> به عنوان ورودی شبکه عصبی عمیق استفاده می‌کرد. در پژوهشی دیگر، ژو و همکاران<sup>[۷]</sup> یک روش جدید تشخیص خطای یاتاقان غلتشی مبتنی بر شبکه‌ی عصبی پیچشی و یادگیری گروهی جنگل تصادفی<sup>۸</sup> ارائه نمودند که از سیگنال‌های ارتعاشی حوزه زمان استفاده می‌کند که به تصاویر سیاه و سفید دو بعدی به عنوان ورودی تبدیل می‌شوند. پژوهش‌های دیگری نیز با رویکرد نوآوری در ساختار شبکه صورت گرفته است<sup>[۸-۱۲]</sup>. در پژوهش دیگری، ونگ و همکاران<sup>[۱۳]</sup> از شبکه عصبی پیچشی و با گرفتن تبدیل فوریه کوتاه مدت<sup>۹</sup> از سیگنال ارتعاشی به عنوان داده ورودی استفاده کرده‌اند و در کار

<sup>۱</sup> Convolutional Neural Network (CNN)

<sup>۲</sup> Frequency Spectrum

<sup>۳</sup> Envelope

<sup>۴</sup> Weights Sharing

<sup>۵</sup> Spatial Pooling

<sup>۶</sup> Long short-term memory

<sup>۷</sup> Fast Fourier Transform (FFT)

<sup>۸</sup> Random Forest

<sup>۹</sup> Short-Time Fourier Transform (STFT)

مشابهی فام و همکاران<sup>[۱۴]</sup> با استفاده از شبکه عصبی پیچشی و تبدیل فوریه کوتاه مدت به عیب‌یابی یاتاقان در دوره‌های متغیر شفت پرداخته‌اند. ژانگ و همکاران<sup>[۱۵]</sup> یک مدل شبکه‌ی عصبی پیچشی دو لایه برای تشخیص عیوب یاتاقان‌ها با تعداد زیادی داده آموزشی پیشنهاد کرد. به این صورت که ابتدا داده‌ها، با تبدیل فوریه سریع پردازش می‌شوند، سپس از خودرمننگار برای آموزش لایه به لایه و بدون نظارت استفاده می‌گردد و در نهایت، آموزش نظارت شده انجام می‌شود. پژوهش‌های دیگری نیز در این حوزه با رویکردهای نوآوری در مدل و داده‌های ورودی صورت گرفته است<sup>[۱۶-۱۸]</sup>. در دسته‌ی آخر پژوهش‌ها، یوان و همکاران<sup>[۱۹]</sup> از تبدیل هیلبرت-هوانگ<sup>۱</sup> روی داده‌های ورودی استفاده کردند و تصاویر زمان-فرکانس را به شبکه عصبی پیچشی دادند. ورسیتريت و همکاران<sup>[۲۰]</sup> علاوه بر تبدیل هیلبرت-هوانگ از تبدیل فوریه کوتاه مدت و تبدیل موجک<sup>۲</sup> نیز استفاده کرده‌اند. در پژوهش دیگری، پاندهاری و همکاران<sup>[۲۱]</sup> از سیگنال حوزه زمان، طیف فرکانسی و انولوپ به عنوان ورودی شبکه استفاده کرده و خرابی طبیعی یاتاقان را مورد بررسی قرار داده‌اند. پژوهش‌های دیگری نیز با این مضمون و با رویکرد نوآوری در نوع داده صورت گرفته است<sup>[۲۲-۲۶]</sup>.

در پژوهش حاضر، با ایجاد خرابی‌های مصنوعی روی یاتاقان و بررسی چهار وضعیت سالم، خرابی رینگ داخلی، خرابی رینگ خارجی و خرابی ساچمه در ۳۶ شرایط کاری مختلف (۹ سرعت دورانی متفاوت و در هر سرعت با ۴ حالت بارگذاری)، تشخیص وضعیت سالم از وضعیت غیرعادی یاتاقان مورد بررسی قرار می‌گیرد. سیگنال ارتعاشی دریافتی توسط سنسور شتاب‌سنج برای مقایسه به سه شکل، یکبار مستقیم و بدون هیچ پیش‌پردازشی به عنوان سیگنال حوزه زمان، بار دوم با گرفتن تبدیل فوریه سریع از سیگنال به صورت طیف فرکانسی و در آخر با گرفتن انولوپ به روش هیلبرت، به صورت تصاویر سیاه و سفید و به طور مجزا به سه شبکه عصبی پیچشی با ساختار مشابه داده می‌شود. این شبکه‌ها ویژگی‌های متمایز و مرتبط با عیوب مختلف یاتاقان را از سیگنال‌ها استخراج و سپس براساس این ویژگی‌ها، داده‌ها را در کلاس‌های مختلف طبقه‌بندی می‌کنند. برای آموزش و ارزیابی این مدل‌ها از داده‌های آزمایشگاهی در تمام سرعت‌ها با دو شرایط بارگذاری ۴ و ۸ کیلو نیوتن استفاده و با داده‌های جمع‌آوری شده در دو شرایط بارگذاری دیگر، ۶ و ۱۰ کیلو نیوتن تست مدل انجام می‌شود.

بخش دوم مقاله حاضر به معرفی روش شبکه عصبی پیچشی و نحوه اعمال انولوپ به سیگنال می‌پردازد. بخش سوم ستاپ آزمایشگاهی طراحی شده برای انجام آزمون‌های خرابی یاتاقان غلتشی را معرفی می‌نماید. بخش چهارم ساختار شبکه عصبی بکار گرفته شده را معرفی و نتایج آن را ارائه می‌نماید. در نهایت، جمع‌بندی و نتیجه‌گیری بیان می‌شود.

## ۲- معرفی شبکه عصبی پیچشی و انولوپ سیگنال ارتعاشی

این بخش به معرفی شبکه عصبی پیچشی و روش محاسبه انولوپ سیگنال ارتعاشات می‌پردازد.

### ۱-۲- معرفی شبکه عصبی پیچشی

شبکه‌های عصبی پیچشی با الهام گرفتن از پردازش بینایی انسانی برای کار با داده‌هایی مانند تصاویر و ایجاد ساختارهای عمیق معرفی شده‌اند. این نوع شبکه‌ها به خصوص در تشخیص تصاویر و شناسایی اشیاء عملکردهای برجسته‌ای دارند. تاریخچه این شبکه‌ها به دهه ۱۹۸۰ برمی‌گردد، اما توجه به آنها با شکل‌گیری یادگیری عمیق در اواسط دهه ۲۰۱۰ جلب شد. یکی از اساسی‌ترین پیشرفت‌ها در این زمینه به نام معماری LeNet-۵ است که توسط یان لوکان<sup>[۲۷]</sup> برای تشخیص اعداد دست‌نویس پیشنهاد شد. از آن زمان تاکنون، به طور مداوم به تغییرات و بهبودهای مختلف پرداخته شده که منجر به توسعه معماری‌های پیچیده‌تر و کارآمدتر شده است. ساختار و نحوه عملکرد این نوع شبکه‌ها متأثر از رویکرد پردازش تصویر در مغز انسان است.

شبکه‌های عصبی پیچشی از لایه‌های متعددی تشکیل شده‌اند که در سطوح مختلف، فرآیندهای استخراج ویژگی‌ها و الگوها را انجام می‌دهند. اجزای اصلی این شبکه‌ها شامل لایه‌های پیچشی<sup>۳</sup> برای استخراج ویژگی‌های مرتبط از تصویر ورودی، لایه‌های ادغام<sup>۴</sup>

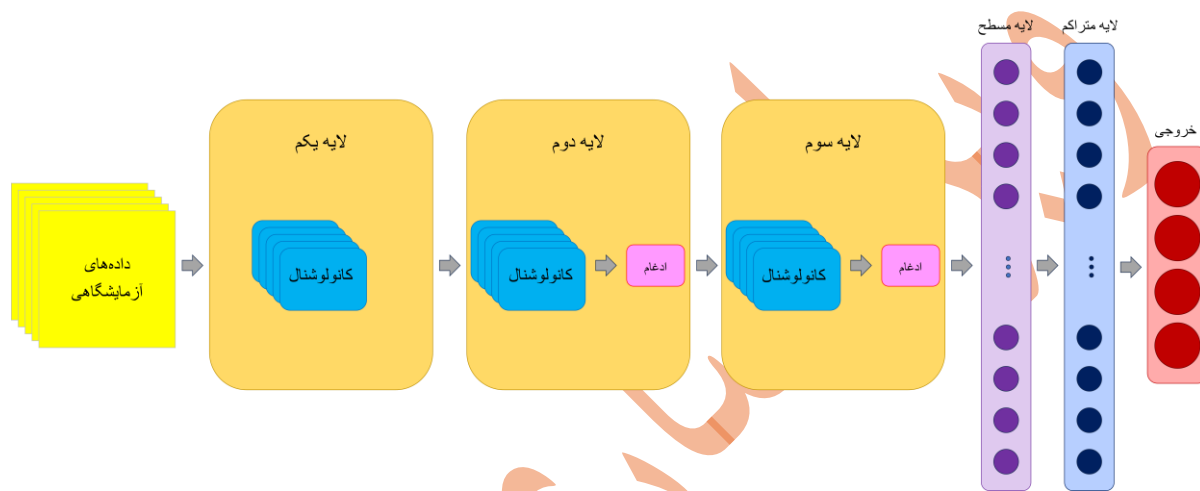
<sup>۱</sup> Hilbert-Huang Transform (HHT)

<sup>۲</sup> Wavelet Transform (WT)

<sup>۳</sup> Convolutional Layers

<sup>۴</sup> Pooling Layers

برای نمونه برداری از نقشه‌های ویژگی جهت کاهش پیچیدگی محاسباتی و همچنین لایه‌های کاملاً متصل<sup>۱</sup> است، که ویژگی‌ها را ترکیب می‌کنند و در نهایت پیش‌بینی‌های نهایی را انجام می‌دهند. این شبکه‌ها در استخراج و تشخیص ویژگی‌ها و الگوهای سلسله‌مراتبی دارای عملکرد بسیار خوبی هستند. در لایه‌های پیشی، از فیلترها برای تشخیص جزئیات مختلف مانند لبه‌ها یا بافت‌ها استفاده می‌شود. این ویژگی‌ها در لایه‌های عمیق‌تر ترکیب می‌گردند تا الگوهای پیچیده‌تری مانند اشیاء یا مناظر تشخیص داده شوند. پارامترهای این شبکه‌ها از طریق روش‌های پس انتشار<sup>۲</sup> و بهینه‌سازی آموزش داده می‌شوند. در شکل ۱ شماتیک ساختار شبکه عصبی پیشی پیشنهادی نشان داده شده است. از مزایای مهم این شبکه‌ها، استخراج خودکار ویژگی‌ها و مقاومت در برابر نویز و تغییرات است. با این حال، برای آموزش صحیح به حجم قابل توجهی از داده و منابع محاسباتی نیاز دارند. در صورت مدیریت نادرست، مشکل بیش‌برازش نیز ممکن است پیش‌آید.



شکل ۱: ساختار شبکه عصبی پیشی پیشنهادی

## ۲-۲- معرفی روش تعیین انولوپ سیگنال ارتعاشی

اگر در یک یاتاقان غلتشی عیبی در یکی از اجزای آن (رینگ داخلی، رینگ خارجی یا ساچمه) وجود داشته باشد، هنگامی که اجزای دیگر با عیب برخورد می‌کنند، پالس‌های کوتاه مدت متناوب با فرکانس مشخص مربوط به محل وقوع عیب تولید می‌شود. در نتیجه، ارتعاشات ناشی از رزونانس با فرکانس مشخصه عیب مدوله می‌شود. مک‌فادن و اسمیت<sup>[۲۸]</sup> مروری بر مطالعات انجام شده در مورد تشخیص عیب یاتاقان غلتشی با آنالیز انولوپ ارائه نمودند. فرآیند عیب‌یابی پیشنهاد شده توسط این گروه در نمودار شکل ۲ نشان داده شده است. در این روش پس از اندازه‌گیری ارتعاشات یاتاقان معیوب، ابتدا فیلتر میان‌گذر به سیگنال مربوطه اعمال می‌شود. سپس عملیات یکسوسازی روی سیگنال‌ها انجام و منحنی انولوپ استخراج می‌شود. در نهایت، با اعمال تبدیل فوری سریع منحنی فرکانسی موج انولوپ بدست می‌آید (شکل ۲). آنالیز انولوپ روشی کارآمد جهت تشخیص خرابی در یاتاقان‌های غلتشی است.



شکل ۲: نمودار جریان فرآیند عیب‌یابی

<sup>۱</sup> Fully Connected Layer

<sup>۲</sup> Backpropagation


در این پژوهش ابتدا با اعمال فیلتر بر روی ناحیه‌ی تشدید، از داده‌ها انولوپ گرفته شد و سپس به عنوان ورودی در شبکه عصبی استفاده شدند. برای تعیین ناحیه‌ی تشدید تعدادی داده از هر چهار وضعیت به صورت تصادفی انتخاب شد و با آزمون و خطا محل و ابعاد فیلتر برای هر وضعیت تخمین زده شد و بر روی تمام داده‌ها اعمال گردید.

### ۳- معرفی تست آزمایشگاهی


بخش حاضر به معرفی ستاپ، سناریو تست و داده‌های آزمایشگاهی می‌پردازد.

#### ۳-۱- معرفی ستاپ، یاتاقان تست، آنالایزر و سنسور

به منظور ارزیابی مدل، نیاز به یک ستاپ تست یاتاقان غلتشی بود که در این راستا یک ستاپ با قابلیت تغییر بار و سرعت در طی فرآیند تنزل یاتاقان غلتشی در آزمایشگاه پایش وضعیت دانشگاه صنعتی شریف توسعه داده شد. شماتیک ستاپ در شکل ۳ نشان داده شده است. به منظور کنترل بار در مواقع اضطرار، از سیستم کنترل بار توسط پاورپک هیدرولیک استفاده شده است، که بار آن از طریق کامپیوتر کنترل می‌شود. در این طراحی، یاتاقان غلتشی هدف بین دو یاتاقان که نقش تکیه‌گاهی را دارند قرار داده شده است. از دیگر ویژگی‌های این ستاپ قابلیت کنترل پذیر بودن سرعت دورانی از طریق درایو موتور آن می‌باشد. مقدار سرعت و ارتعاشات عمودی و افقی بار وارد شده به یاتاقان غلتشی به صورت لحظه‌ای توسط این ستاپ قابل اندازه‌گیری است. در این پژوهش از داده‌های سنسور شتاب‌سنج افقی که در راستای اعمال بار قرار داشته، استفاده شده است. در شکل ۴ ستاپ تجربی ساخته شده قابل مشاهده است.



شکل ۳: ستاپ طراحی شده برای تست یاتاقان غلتشی از نمای روبه‌رو



شکل ۴: پلتفرم تجربی جهت انجام آزمایش‌های عیب‌یابی

در این پژوهش از یاتاقان خود تنظیم دو ردیفه استفاده شده است. در شکل ۵ خرابی‌های مصنوعی ایجاد شده روی یاتاقان‌ها قابل مشاهده است.



شکل ۵: نمایش خرابی‌های ایجاد شده در یاتاقان غلتشی

در جدول ۱ ابعاد یاتاقان و فرکانس‌های مشخصه مربوط به عیوب رینگ داخلی، رینگ خارجی، ساچمه و مشخصات دینامیکی یاتاقان تست ذکر شده است.



جدول ۱: مشخصات یاتاقان ETN<sup>۹</sup> ۱۲۱۰ ۱۲۹۱

مقدار	نماد	پارامتر	
۹۰	D	قطر خارجی	مشخصات ابعادی بیرینگ (میلی متر)
۵۰	d	قطر داخلی	
۲۰	B	عرض	
۳۴	N	تعداد ساچمه	
۷/۲۶	BPFO	فرکانس خرابی رینگ خارجی	مشخصات فرکانسی بیرینگ (مضرب دور روتور)
۹/۷۸	BPFI	فرکانس خرابی رینگ داخلی	
۶/۵۴	BSF	فرکانس خرابی المان غلتشی	
۰/۴۲	FTF	فرکانس خرابی قفسه	
۹/۱۵	C.	ظرفیت بار استاتیکی	مشخصات دینامیکی بیرینگ (کیلو نیوتن)
۲۶/۵	C	ظرفیت بار دینامیکی	

ارتعاشات به کمک دستگاه داده برداری SDT Vigilant<sup>[۳۰]</sup> اندازه گیری شده است. در شکل ۶ نمایی از دستگاه و محیط کاربری آن نشان داده شده است. برای اندازه گیری سیگنال ارتعاشات شتاب نیز از سنسور HS۱۰۰۱۰۰۵۰۰۸ استفاده شده است. بازه فرکانسی سیگنال های اندازه گیری شده بین ۱ تا ۲۵۶۰۰ هرتز می باشد.



شکل ۶: آنالایزر Vigilant

### ۳-۲- معرفی شرایط کاری و داده های آزمایشگاهی

در راستای اهداف پژوهش حاضر، با ایجاد خرابی های مصنوعی روی یاتاقان ها، در چهار وضعیت سالم، خرابی رینگ داخلی، خرابی رینگ خارجی و خرابی ساچمه در ۳۶ شرایط کاری مختلف تست های آزمایشگاهی انجام گردید. دلیل استفاده از شرایط کاری متغیر این است که مدل توسعه یافته به کمک این داده ها بتواند در حالت های مختلف به عیب یابی هوشمند یاتاقان غلتشی بپردازد و مستقل از شرایط کاری باشد. در این آزمایش ها به طور همزمان اندازه گیری توسط سه سنسور ارتعاشات در سه جهت عمودی، افقی و محوری روی یاتاقان انجام شده است و داده های آن در همه شرایط کاری ثبت گردیده است. تعداد مجموعه داده های ثبت شده برای هر چهار وضعیت تحت هر بارگذاری و در هر سرعت برابر با ۴۷۴۱ می باشد، که در شکل ۷ نشان داده شده است. شایان ذکر است که هر یک از

داده‌های زمانی در بازه زمانی ۱۶۰ میلی‌ثانیه و با ۴۰۹۶ نقطه ثبت شده است. داده‌های فرکانسی و آنولوپ به دلیل اعمال تبدیل فوریه سریع دارای سیگنال قرینه می‌باشند که به منظور رفع آن نیمی از سیگنال حذف گردید و به همین سبب این داده‌ها دارای ۲۰۴۸ نقطه می‌باشند. در این آزمایش تلاش شد تا از هر شرایط کاری ۳۰ داده ثبت شود و تنها در بارگذاری ۱۲ کیلو نیوتنی به دلیل بالا رفتن دمای بیرینگ و فشار زیاد روی شفت و موتور الکتریکی، برای جلوگیری از خرابی ستاپ زمان داده‌برداری کاهش پیدا کرد و تعداد داده کمتری ثبت شد.




شکل ۷: تعداد داده‌های ثبت شده در چهار وضعیت، ۹ سرعت و ۵ بارگذاری مختلف

برای نشان دادن نتایج داده‌ها از دو مشخصه پرکاربرد صنعتی در حوزه عیب‌یابی استفاده می‌شود. نخستین مشخصه، جذر میانگین مربعات<sup>۱</sup> ارتعاشات است که برای تمامی شرایط کاری و برای چهار وضعیت سالم، خرابی رینگ داخلی، خرابی رینگ خارجی و خرابی ساچمه محاسبه و در شکل‌های ۸-۱۱ نشان داده شده است. همچنین دومین خصیصه پیک<sup>۲</sup> است که برای تمامی شرایط کاری و هر چهار وضعیت محاسبه و در شکل‌های ۱۲-۱۵ نشان داده شده است. همان‌طور که در این نمودارها قابل مشاهده است، دامنه ارتعاشات در حالت خرابی رینگ خارجی بیشترین مقدار را نسبت به دو عیب دیگر دارد. دامنه ارتعاشات در حالت خرابی رینگ داخلی و خرابی ساچمه به ترتیب بیشترین مقدار را بعد از خرابی رینگ خارجی دارند.

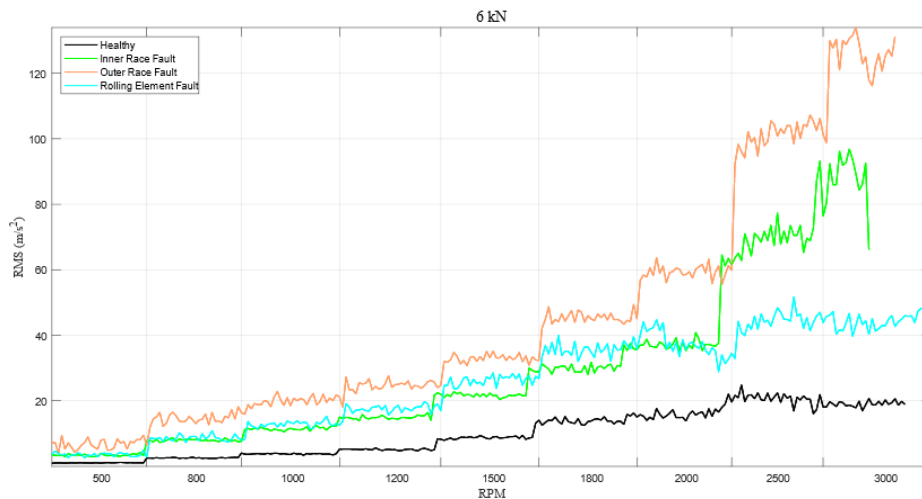
<sup>۱</sup> Root Mean Squared (RMS)

<sup>۲</sup> Peak







شکل ۸: نمودار جذر میانگین مربعات ارتعاشی برای چهار وضعیت یاتاقان و تمامی سرعتها در بار ۴ kN




شکل ۹: نمودار جذر میانگین مربعات ارتعاشی برای چهار وضعیت یاتاقان و تمامی سرعتها در بار ۶ kN




شکل ۱۰: نمودار جذر میانگین مربعات ارتعاشی برای چهار وضعیت یاتاقان و تمامی سرعتها در بار ۸ kN




شکل ۱۱: نمودار جذر میانگین مربعات شتاب ارتعاشی برای چهار وضعیت یاتاقان و تمامی سرعتها در بار ۱۰ kN




شکل ۱۲: نمودار پیک ارتعاشات برای چهار وضعیت یاتاقان و تمامی سرعتها در بار ۴ kN



شکل ۱۳: نمودار پیک شتاب ارتعاشی برای چهار وضعیت یاتاقان و تمامی سرعتها در بار ۶ kN



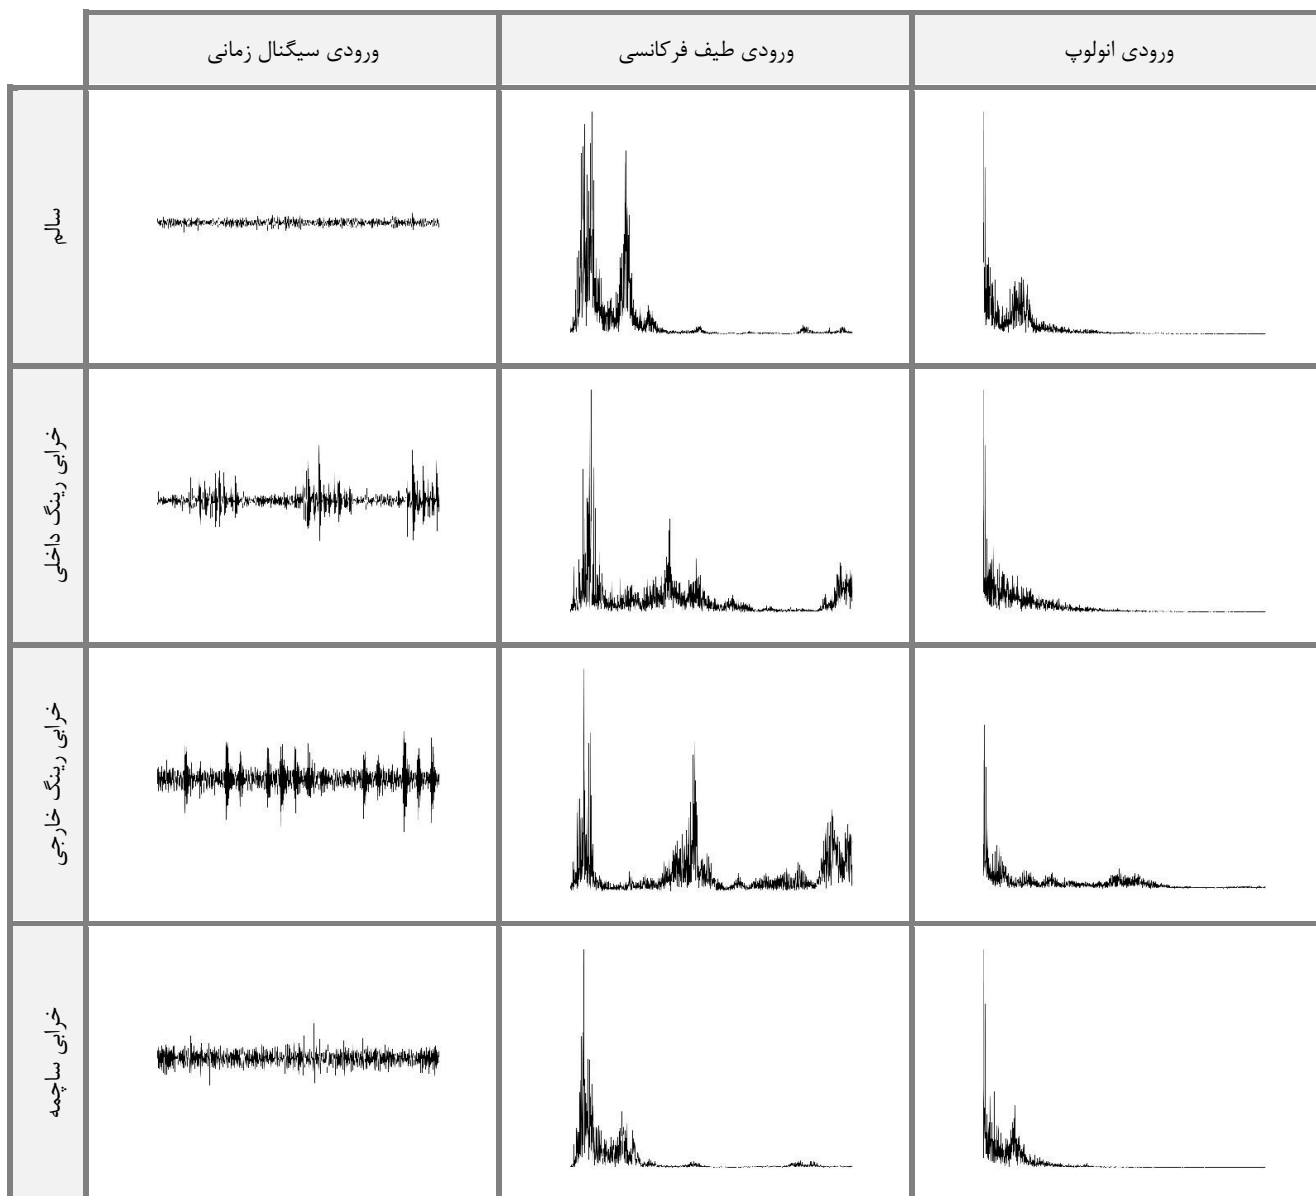
شکل ۱۴: نمودار پیک شتاب ارتعاشی برای چهار وضعیت یاتاقان و تمامی سرعت‌ها در بار ۸ kN



شکل ۱۵: نمودار پیک شتاب ارتعاشی برای چهار وضعیت یاتاقان و تمامی سرعت‌ها در بار ۱۰ kN

#### ۴- توسعه الگوریتم شبکه‌ی عصبی پیچشی و پیاده‌سازی آن روی داده‌های آزمایشگاهی

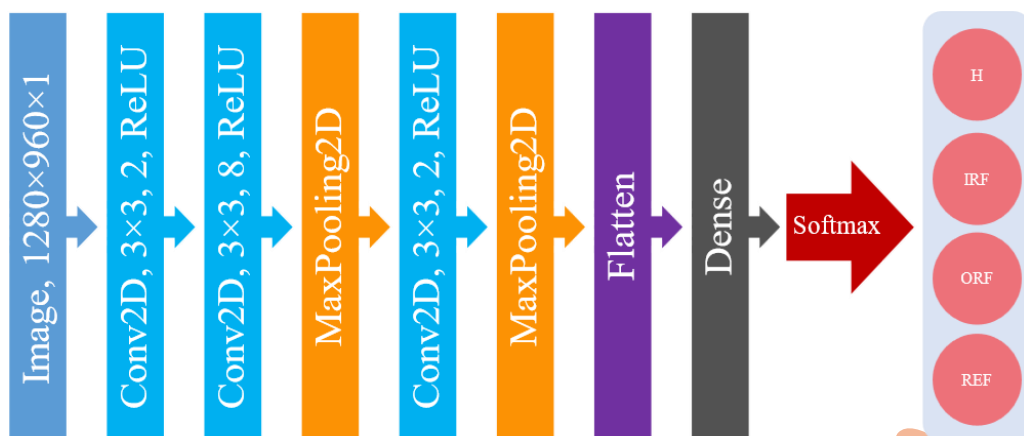
همان‌طور که در قسمت‌های قبلی بیان گردید شبکه‌ی عصبی پیچشی، ویژگی‌های متمایز و مرتبط با عیوب مختلف یاتاقان را از سیگنال‌ها استخراج و سپس براساس این ویژگی‌ها، داده‌ها را در کلاس‌های مختلف طبقه‌بندی می‌کند. به منظور یافتن بهترین دقت و کارایی شبکه از ورودی‌های مختلف از جمله سیگنال زمانی، طیف فرکانسی و انولوپ استفاده می‌شود. در این راستا برای همه شرایط کاری در چهار وضعیت مختلف یاتاقان تصاویر سیگنال زمانی، طیف فرکانسی و انولوپ استخراج گردید. این سیگنال‌ها به منظور عیب‌یابی مدل در شرایط کاری مختلف و تشخیص عیوب فارغ از شرایط کاری نرمالیز نشده و دامنه سیگنال ارتعاشی وابسته به سرعت و بارگذاری‌های مختلف، متفاوت است. نمونه‌ای از این ورودی‌ها برای چهار وضعیت مختلف یاتاقان در شکل ۱۶ نشان داده شده است.



شکل ۱۶: تصاویر سیگنال زمانی، طیف فرکانسی و انولوپ استخراج شده برای چهار وضعیت یاتاقان

ساختار شبکه عصبی پیچشی توسعه یافته برای این پژوهش به صورت آزمون و خطا بدست آمده که شماتیک مدل در شکل ۱۷ و مشخصات آن در جدول ۲ گزارش شده است. این فرآیند در بستر پایتون و با استفاده از کتابخانه TensorFlow ایجاد گردید. در این شبکه از تصاویر سیاه و سفید با ابعاد  $1280 \times 960$  پیکسل به عنوان ورودی و از سه لایه پیچشی، دو لایه ادغام، یک لایه مسطح و تابع فعال ساز سافت مکس<sup>۱</sup> استفاده شده که این مقادیر با استفاده از آزمون و خطا بدست آمده است. سیگنال ارتعاشی دریافتی توسط سنسور شتابسنج، برای مقایسه به سه شکل مختلف، یکبار مستقیم و بدون هیچ پیش پردازشی به عنوان سیگنال حوزه زمان، بار دوم با گرفتن تبدیل فوری به سه مدل شبکه عصبی پیچشی توسعه یافته با ساختار مشابه داده می شود. شبکه ها ویژگی های متمایز و مرتبط با عیوب مختلف یاتاقان را از سیگنال ها استخراج و براساس این ویژگی ها، داده ها را در کلاس های مختلف طبقه بندی می کنند.

<sup>۱</sup> Softmax Activation Function




شکل ۱۷: مدل شبکه عصبی پیچشی مورد استفاده

جدول ۲: پیکربندی مدل پیشنهادی


شماره لایه	نوع لایه	فیلتر	هسته	تابع	ابعاد داده
۱	Conv <sup>۲</sup> D	۲	۳*۳	ReLU	(۱۲۷۸, ۹۵۸, ۲)
۲	BatchNormalization	-	-	-	-
۳	Conv <sup>۲</sup> D	۸	۳*۳	ReLU	(۱۲۷۶, ۹۵۶, ۸)
۴	BatchNormalization	-	-	-	-
۵	MaxPooling <sup>۲</sup> D	-	۲*۲	-	(۶۳۸, ۴۷۸, ۸)
۶	Conv <sup>۲</sup> D	۲	۳*۳	ReLU	(۶۳۶, ۴۷۶, ۲)
۷	BatchNormalization	-	-	-	-
۸	MaxPooling <sup>۲</sup> D	-	۲*۲	-	(۳۱۸, ۲۳۸, ۲)
۹	Flatten	-	-	-	۱۵۱۳۶۸
۱۰	Dropout	۰,۶	-	-	۱۵۱۳۶۸
۱۱	Dense	۴	-	Softmax	-
۱۲	Loss Function	-	-	Categorical Crossentropy	-
۱۳	Optimizer	-	-	Adam	-
۱۴	Total Params	-	-	۶۰۵۷۹۴	-

برای هر سه داده زمانی، فرکانسی و انولوپ همان‌طور که در شکل ۱۸ قابل مشاهده است تقریباً ۵۰ درصد داده‌های آزمایشگاهی در هر چهار وضعیت یاتاقان برای فرآیند آموزش و ارزیابی شبکه و از ۵۰ درصد دیگر برای تست شبکه استفاده می‌شود.

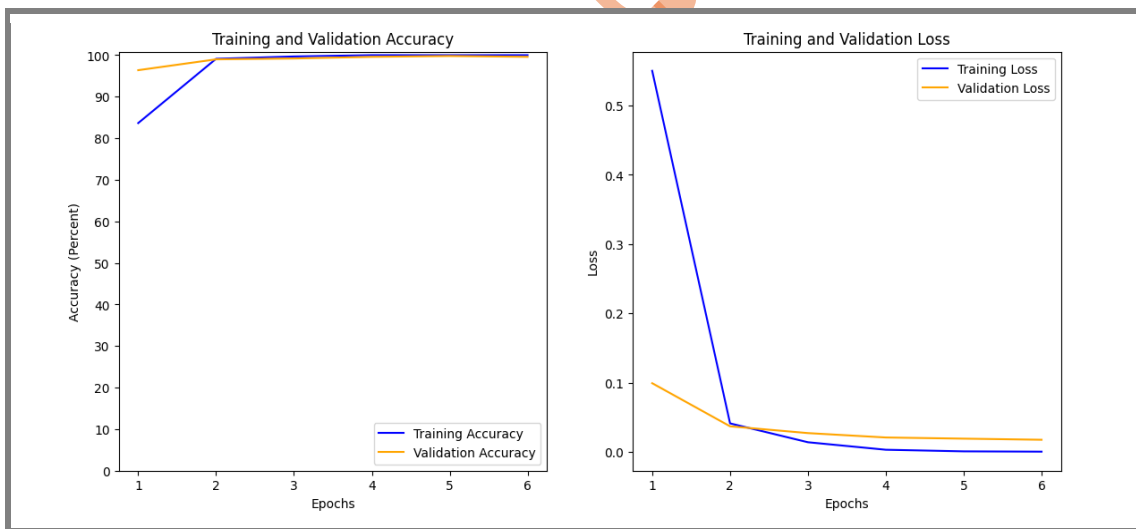


شکل ۱۸: تعداد داده‌های استفاده شده در فرآیند آموزش، ارزیابی و تست

تعداد گام‌های آموزشی<sup>۱</sup> و دقت آموزش مدل روی داده‌های آزمایشگاهی، برای سه ورودی مختلف با تصاویر سیگنال زمانی، طیف فرکانسی و انولوپ به ترتیب در شکل‌های ۱۹ تا ۲۱ نمایش داده شده است. همانطور که از این شکل پیداست مدل با ورودی طیف فرکانسی در تعداد گام کمی به دقت ۱۰۰ درصد رسیده و نتیجه‌ی بهتری نسبت به دو مدل دیگر از خود نشان داده است.




شکل ۱۹: دقت آموزش مدل روی داده‌های آزمایشگاهی برای ورودی سیگنال زمانی



شکل ۲۰: دقت آموزش مدل روی داده‌های آزمایشگاهی برای ورودی سیگنال طیف فرکانسی

<sup>۱</sup> Epochs





شکل ۲۱: دقت آموزش مدل روی داده‌های آزمایشگاهی برای ورودی سیگنال انولوپ

برای تست این مدل‌ها از داده‌های آزمایشگاهی با بار ۶ kN و ۱۰ kN در همه سرعت‌ها استفاده می‌شود. ماتریس درهم‌ریختگی برای داده‌های تست برای مدل با ورودی سیگنال زمانی (رنگ بنفش)، مدل با ورودی طیف فرکانسی (رنگ آبی) و مدل با ورودی انولوپ (رنگ قرمز) در شکل ۲۲ نمایش داده شده است. در این شکل حروف اختصار H ، IRF ، ORF و REF به ترتیب بیانگر وضعیت سالم، خرابی رینگ داخلی، خرابی رینگ خارجی و خرابی ساچمه یاتاقان است. محور عمودی ماتریس‌ها بیانگر حالت واقعی و محور افقی بیانگر حالت پیش‌بینی شده است. همانطور که ملاحظه می‌شود مدل با ورودی سیگنال زمانی دقت خوبی از خود نشان نداده است. در مقابل مدل با ورودی انولوپ در تشخیص بسیار عالی عمل کرده و تنها ضعف آن در تشخیص داده‌های سالم است. با این حال مدل با ورودی طیف فرکانسی در تمام وضعیت‌های خرابی و سالم عملکرد خوب و قابل قبولی از خود نشان داده است.

	سیگنال زمانی				اسپکتروم				انولوپ			
H	0.385	0.225	0.000	0.390	0.955	0.032	0.000	0.013	0.702	0.094	0.000	0.204
IRF	0.202	0.442	0.116	0.240	0.028	0.942	0.030	0.000	0.014	0.960	0.000	0.026
ORF	0.010	0.325	0.665	0.000	0.000	0.006	0.994	0.000	0.000	0.000	1.000	0.000
REF	0.185	0.004	0.000	0.811	0.000	0.075	0.000	0.925	0.062	0.000	0.000	0.938
	H	IRF	ORF	REF	H	IRF	ORF	REF	H	IRF	ORF	REF

شکل ۲۲: ماتریس درهم‌ریختگی برای داده‌های تست

به طور خلاصه در جدول ۳ دقت شبکه برای ورودی‌های مختلف ارائه شده است. همان‌طور که مشاهده می‌شود مدلی که ورودی تصویر طیف فرکانسی دریافت کرده از بالاترین دقت (۹۵٪) برخوردار است. با توجه به اینکه روش انولوپ در عیب‌یابی بسیار رایج و پرکاربرد است انتظار می‌رفت که از دقت بیشتری برخوردار باشد و این به دلیل ویژگی‌های شبکه‌های عصبی پیچشی است به این صورت که در استفاده از انولوپ، بازه فرکانسی فیلتر میان‌گذر تاثیر زیادی در شناسایی صحیح عیوب دارد. در این تحقیق، به دلیل بالا

بودن تعداد داده‌ها، برای هر نوع عیب یک بازه فیلتر منحصر بفرد در نظر گرفته شده است. برای وضعیت سالم فیلتر در بازه ۶۲۰ تا ۳۲۸۰ هرتز، برای وضعیت خرابی رینگ داخلی در بازه ۳۱۰۵ تا ۷۷۳۰ هرتز، برای وضعیت خرابی رینگ خارجی در بازه ۷۵۹۰ تا ۱۱۸۷۵ هرتز و برای وضعیت خرابی ساچمه در بازه ۶۰۵ تا ۳۰۶۵ هرتز اعمال گردید. این فرآیند روی داده‌های آزمایشگاهی پیش از استفاده در مدل در مرحله پیش‌پردازش اعمال می‌گردد. طبیعی است ناحیه تشدید برخی از داده‌ها به طور کامل در این بازه قرار نگیرد و دقت مناسبی حاصل نشود. همچنین سائز فیلتر عاملی بسیار مهم است. هرچه فیلتر بزرگتر باشد طیف وسیعی از فرکانس‌ها را شامل می‌شود و به طبع آن، تصویر سیگنال جزئیات بیشتری را در بر می‌گیرد و بالعکس. از این حیث سائز فیلتر متغیر می‌تواند مدل CNN را به اشتباه بیان‌دازد. همین طور محل فیلتر زدن بسیار مهم است به سادگی این امر قابل مشاهده است که با جابجا کردن ناحیه‌ی فیلتر حتی در حد چند فرکانس شکل انولوپ تغییر می‌کند و این تغییر نیز مدل را به اشتباه می‌اندازد. در مقابل طیف فرکانسی هیچ یک از این مشکلات را ندارد، چون از تمام سیگنال تبدیل فوریه گرفته می‌شود و این اطمینان وجود دارد که هم ناحیه تشدید در سیگنال طیف فرکانسی موجود است و هم تمام بازه فرکانسی سیگنال را شامل می‌شود. همچنین شکل سیگنال در هر چهار حالت مورد بررسی تغییر نمی‌کند. سیگنال طیف فرکانسی در هر یک از چهار حالت مورد بررسی از الگوی خاصی پیروی می‌کند، به طوری که در شکل ۱۶ این موضوع کاملاً مشهود است. بنابراین در راستای ارتقای عملکرد مدل با ورودی انولوپ لازم است ابعاد بازه فیلتر و محل اعمال آن توسط یک الگوریتم، با میانگین‌گیری از ناحیه تشدید سیگنال‌های هر وضعیت طبق الگوریتم نوشته شده صورت پذیرد.

جدول ۳: دقت مدل‌های سیگنال زمانی، طیف فرکانسی و انولوپ

ورودی	دقت آموزش (درصد)	دقت ارزیابی (درصد)	دقت تست (درصد)	سالم کاذب (تست)
سیگنال زمانی	۷۴/۰	۶۳/۹	۵۸/۸	۱۳/۳
طیف فرکانسی	۱۰۰	۹۹/۶	۹۵/۵	۰/۹
انولوپ	۸۲/۳	۹۲/۶	۹۰/۵	۲/۶

در توضیح جدول ۳ روی دادگان تست برای ورودی انولوپ که دادگان بالاتری در مقایسه با دادگان آموزش این ورودی دارد، لازم به توضیح است دادگان تست در مقایسه با آموزش و ارزیابی تحت بارگذاری بیشتری هستند. انتظار می‌رود با افزایش بار، شدت خرابی در سیگنال بیشتر نمایان گردد. بنابراین مدلی که تشخیص عیب در شرایط بارگذاری کم را فراگرفته است، در شناسایی خرابی در بارگذاری بالاتر بعید نیست عملکرد بضعاً بهتری داشته باشد. در ورودی انولوپ، نظر به اعمال بازه فیلتر، خرابی در لود بالا بهتر از ورودی‌های دیگر نمایان شده است و همین مسئله موجب گشته است دقت مدل روی دادگان تست بالاتر از دادگان آموزش و البته کمی کمتر از دادگان ارزیابی باشد.

نتیجه دیگری که از تست‌ها بدست می‌آید میزان دقت شبکه برای داده‌های خرابی است که به اشتباه سالم تشخیص داده می‌شوند. این موضوع در صنعت بسیار مهم و قابل توجه است زیرا عدم تشخیص خرابی منجر به حوادث با خسارات جانی و مالی بسیار زیاد می‌شود. نتایج بدست آمده از داده‌های آزمایشگاهی در ستون آخر جدول ۲ نشان از برتری مدل طیف فرکانسی با خطای زیر یک درصد است. باید توجه داشت مدل مورد استفاده در این پژوهش تنها توانایی شناسایی یک عیب را دارا می‌باشد و در صورت وقوع خرابی در دو المان یاتاقان که می‌تواند در نتیجه گسترش خرابی و انتقال عیب از یک المان به المان دیگر باشد، عملکرد مدل مورد ابهام است اما گمان می‌رود مدل عیبی که شدت خرابی بیشتری دارد را شناسایی کند. در شرایطی که ابتدا یک عیب پدیدار شده، مدل قادر به شناسایی المان خراب خواهد بود، اما با گسترش آن به المان دیگر، عملکرد مدل نیازمند بررسی خواهد بود که موضوع پژوهشی بعدی می‌باشد.

یاتاقان‌های غلتشی بیشترین سهم را در خرابی ماشین‌های دوار دارند. از این‌رو تشخیص زود هنگام و هوشمند عیوب یاتاقان غلتشی امری بسیار مهم در واحدهای صنعتی است. در این پژوهش به سبب توانایی‌های شبکه‌های عصبی پیچشی در پردازش تصاویر، کلاس‌بندی، سرعت و دقت بالا از یک مدل ساده و کم عمق شبکه‌ی عصبی پیچشی برای تشخیص خرابی یاتاقان و نوع عیب آن استفاده شد. بدین منظور یک ستاپ تست با توانایی کار در شرایط متغیر به منظور ثبت سیگنال‌های ارتعاشی توسعه یافت. برای تست از چهار یاتاقان غلتشی خودتنظیم به منظور بررسی وضعیت سالم، خرابی رینگ داخلی، خرابی رینگ خارجی و خرابی ساچمه استفاده شد. خرابی‌ها به صورت مصنوعی روی یاتاقان‌ها ایجاد شدند و در ۳۶ شرایط کاری سرعت و بار متنوع داده‌برداری انجام شد. برای یافتن بهترین نوع سیگنال ورودی به جهت عیب‌یابی، داده‌های ارتعاشی ثبت شده به سه شکل سیگنال زمانی، طیف فرکانسی و انولوپ به عنوان ورودی به شبکه عصبی پیچشی داده شد. پس از آموزش مدل، ارزیابی و تست مدل، نتایج حاکی از برتری ورودی طیف فرکانسی در مقایسه با سیگنال زمانی و انولوپ بود. با بررسی‌های انجام شده مشخص شد اگرچه انولوپ اطلاعات بسیار مفیدی از طیف فرکانسی سیگنال به ما می‌دهد، اما دلایلی مانند متغیر بودن ابعاد فیلتر و محل فیلتر موجب بروز خطا در شبکه عصبی پیچشی شود. به همین دلیل طیف فرکانسی با ارائه الگوی رفتاری ثابت برای هریک از انواع عیوب، بهترین گزینه برای عیب‌یابی در شبکه‌های عصبی پیچشی محسوب می‌شود. نتایج این پژوهش می‌تواند با انجام تبدیل‌های متنوع دیگر روی داده‌ها و بررسی عملکرد آنها بهبود یابد. همچنین مدل توسعه یافته در این مرحله شایسته تست روی دادگان صنعتی برای تشخیص عیوب یاتاقان‌های غلتشی می‌باشد.

## مراجع

- [۱] Wen, L., Gao, L. and Li, X., ۲۰۱۷. A new deep transfer learning based on sparse auto-encoder for fault diagnosis. *IEEE Transactions on systems, man, and cybernetics: systems*, ۴۹(۱), pp. ۱۳۶-۱۴۴.  
<https://doi.org/10.1109/TSMC.2017.2754287>
- [۲] Abdel-Hamid, O., Mohamed, A.R., Jiang, H. and Penn, G., ۲۰۱۲, March. Applying convolutional neural networks concepts to hybrid NN-HMM model for speech recognition. In ۲۰۱۲ IEEE international conference on Acoustics, speech and signal processing (ICASSP) (pp. ۴۲۷۷-۴۲۸۰). IEEE.  
<https://doi.org/10.1109/ICASSP.2012.6288864>
- [۳] Zhang, Y. and Wallace, B., ۲۰۱۵. A sensitivity analysis of (and practitioners' guide to) convolutional neural networks for sentence classification. *arXiv preprint arXiv:1510.03820*.  
<https://doi.org/10.48550/arXiv.1510.03820>
- [۴] Song, X., Cong, Y., Song, Y., Chen, Y. and Liang, P., ۲۰۲۲. A bearing fault diagnosis model based on CNN with wide convolution kernels. *Journal of Ambient Intelligence and Humanized Computing*, ۱۳(۸), pp. ۴۰۴۱-۴۰۵۶.  
<https://doi.org/10.1177/1077546314524260>
- [۵] Chen, X., Zhang, B. and Gao, D., ۲۰۲۱. Bearing fault diagnosis base on multi-scale CNN and LSTM model. *Journal of Intelligent Manufacturing*, ۳۲(۴), pp. ۹۷۱-۹۸۷.  
<https://doi.org/10.1007/s10845-020-01600-2>
- [۶] Jia, F., Lei, Y., Lin, J., Zhou, X. and Lu, N., ۲۰۱۶. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical systems and signal processing*, ۷۲, pp. ۳۰۳-۳۱۵.  
<https://doi.org/10.1016/j.ymssp.2015.10.025>
- [۷] Xu, G., Liu, M., Jiang, Z., Söfker, D. and Shen, W., ۲۰۱۹. Bearing fault diagnosis method based on deep convolutional neural network and random forest ensemble learning. *Sensors*, ۱۹(۵), p. ۱۰۸۸.  
<https://doi.org/10.3390/s19051088>
- [۸] Eren, L., ۲۰۱۷. Bearing fault detection by one-dimensional convolutional neural networks. *Mathematical Problems in Engineering*, ۲۰۱۷, pp. ۱-۹.  
<https://doi.org/10.1155/2017/8617315>
- [۹] Chen, J., Jiang, J., Guo, X. and Tan, L., ۲۰۲۱. An Efficient CNN with Tunable Input-Size for Bearing Fault Diagnosis. *Int. J. Comput. Intell. Syst.*, ۱۴(۱), pp. ۶۲۵-۶۳۴.  
<https://doi.org/10.2991/ijcis.d.210113.001>

- [10] Peng, D., Wang, H., Liu, Z., Zhang, W., Zuo, M.J. and Chen, J., 2020. Multibranch and multiscale CNN for fault diagnosis of wheelset bearings under strong noise and variable load condition. *IEEE Transactions on Industrial Informatics*, 16(7), pp.4949-4960.  
<https://doi.org/10.1109/TII.2020.2967557>
- [11] Zhu, X., Luo, X., Zhao, J., Hou, D., Han, Z. and Wang, Y., 2020. Research on deep feature learning and condition recognition method for bearing vibration. *Applied Acoustics*, 168, p.107435.  
<https://doi.org/10.1016/j.apacoust.2020.107435>
- [12] Peng, D., Wang, H., Desmet, W. and Gryllias, K., 2023. RMA-CNN: A residual mixed-domain attention CNN for bearings fault diagnosis and its time-frequency domain interpretability. *Journal of Dynamics, Monitoring and Diagnostics*.  
<https://doi.org/10.37965/jdmd.2023.156>
- [13] Wang, B., Feng, G., Huo, D. and Kang, Y., 2022. A bearing fault diagnosis method based on spectrum map information fusion and convolutional neural network. *Processes*, 10(7), p.1427.  
<https://doi.org/10.3390/pr10071427>
- [14] Pham, M.T., Kim, J.M. and Kim, C.H., 2020. Accurate bearing fault diagnosis under variable shaft speed using convolutional neural networks and vibration spectrogram. *Applied Sciences*, 10(18), p.6385.  
<https://doi.org/10.3390/app10186385>
- [15] Zhang, W., Peng, G. and Li, C., 2017. Rolling element bearings fault intelligent diagnosis based on convolutional neural networks using raw sensing signal. In *Advances in Intelligent Information Hiding and Multimedia Signal Processing: Proceeding of the Twelfth International Conference on Intelligent Information Hiding and Multimedia Signal Processing, Nov., 21-23, 2016, Kaohsiung, Taiwan, Volume 2* (pp. 77-84). Springer International Publishing.  
[https://doi.org/10.1007/978-3-319-50212-0\\_10](https://doi.org/10.1007/978-3-319-50212-0_10)
- [16] Hasan, M.J., Islam, M.M. and Kim, J.M., 2021. Bearing fault diagnosis using multidomain fusion-based vibration imaging and multitask learning. *Sensors*, 22(1), p.56.  
<https://doi.org/10.3390/s22010056>
- [17] Qin, Y. and Shi, X., 2022. Fault diagnosis method for rolling bearings based on two-channel CNN under unbalanced datasets. *Applied Sciences*, 12(17), p.8474.  
<https://doi.org/10.3390/app12178474>
- [18] Xin, Y., Li, S., Wang, J., An, Z. and Zhang, W., 2020. Intelligent fault diagnosis method for rotating machinery based on vibration signal analysis and hybrid multi-object deep CNN. *IET Science, Measurement & Technology*, 14(4), pp.407-415.  
<https://doi.org/10.1049/iet-smt.2018.5672>
- [19] Yuan, Z., Zhang, L., Duan, L. and Li, T., 2018, October. Intelligent fault diagnosis of rolling element bearings based on HHT and CNN. In *2018 Prognostics and System Health Management Conference (PHM-Chongqing)* (pp. 292-296). IEEE.  
<https://doi.org/10.1109/PHM-Chongqing.2018.00056>
- [20] Verstraete, D., Ferrada, A., Droguett, E.L., Meruane, V. and Modarres, M., 2017. Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings. *Shock and Vibration*, 2017.  
<https://doi.org/10.1155/2017/567651>
- [21] Pandhare, V., Singh, J. and Lee, J., 2019, May. Convolutional neural network based rolling-element bearing fault diagnosis for naturally occurring and progressing defects using time-frequency domain features. In *2019 Prognostics and System Health Management Conference (PHM-Paris)* (pp. 32-36). IEEE.  
<https://doi.org/10.1109/PHM-Paris.2019.00061>
- [22] Bai, R., Meng, Z., Xu, Q. and Fan, F., 2023. Fractional Fourier and time domain recurrence plot fusion combining convolutional neural network for bearing fault diagnosis under variable working conditions. *Reliability Engineering & System Safety*, 232, p.109076.  
<https://doi.org/10.1016/j.res.2022.109076>
- [23] Zhang, X., Chen, G., Hao, T. and He, Z., 2020. Rolling bearing fault convolutional neural network diagnosis method based on casing signal. *Journal of Mechanical Science and Technology*, 34, pp.2307-2316.  
<https://doi.org/10.1007/s12206-020-0506-8>

- [۲۴] Youcef Khodja, A., Guersi, N., Saadi, M.N. and Boutasseta, N., ۲۰۲۰. Rolling element bearing fault diagnosis for rotating machinery using vibration spectrum imaging and convolutional neural networks. The International Journal of Advanced Manufacturing Technology, ۱۰۶, pp.۱۷۳۷-۱۷۵۱.  
<https://doi.org/10.1007/s00170-019-04726-7>
- [۲۵] Zhu, X., Zhao, J., Hou, D. and Han, Z., ۲۰۱۹. An SDP characteristic information fusion-based CNN vibration fault diagnosis method. Shock and Vibration, ۲۰۱۹.  
<https://doi.org/10.1155/2019/3926963>
- [۲۶] Kumar, A., Vashishtha, G., Gandhi, C.P., Tang, H. and Xiang, J., ۲۰۲۱. Tacho-less sparse CNN to detect defects in rotor-bearing systems at varying speed. Engineering applications of artificial intelligence, ۱۰۴, p.۱۰۴۴۰۱.  
<https://doi.org/10.1016/j.engappai.2021.104401>
- [۲۷] LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., ۱۹۹۸. Gradient-based learning applied to document recognition. Proceedings of the IEEE, ۸۶(۱۱), pp.۲۲۷۸-۲۳۲۴.  
<https://doi.org/10.1109/5.726791>
- [۲۸] McFadden, P.D. and Smith, J.D., ۱۹۸۴. Vibration monitoring of rolling element bearings by the high-frequency resonance technique—a review. Tribology international, ۱۷(۱), pp.۳-۱۰.  
[https://doi.org/10.1016/0301-679X\(84\)90076-8](https://doi.org/10.1016/0301-679X(84)90076-8)
- [۲۹] SKF Bearing Select, in, pp. <https://skfbearingselect.com/#/size-lubrication/single-bearing>.
- [۳۰] SDT, Vigilant, in, pp. <https://sdtultrasound.com/products/permanent-monitoring/vigilant/>.

# Intelligent Fault Detection of Rolling Element Bearing under Variable Operating Conditions by Convolutional Neural Network using Time and Frequency Domain Signals

Ali Farahani, Ali Davoodabadi, Somaye Mohammadi, Mehdi Behzad<sup>1</sup>\*

Condition Monitoring Lab, Department of Mechanical Engineering, Sharif University of Technology, Tehran, Iran

## ABSTRACT

Intelligent detection of rolling element bearing faults is a critical aspect of rotating equipment condition monitoring. Early detection of faults holds significant economic value for industrial units in terms of maintenance and planning. Traditional intelligent fault detection algorithms, which rely on a combination of feature extraction and signal classification, are time-consuming and require a high level of expertise. In comparison to traditional methods, Convolutional Neural Networks (CNNs) can process a large volume of data with high accuracy and automatically extract features from vibration signals. Therefore, in this research, an attempt has been made to use a simple and shallow CNN to not only determine the health state of rolling element bearings but also identify the defective element. For this purpose, a CNN model has been employed to investigate three common faults in rolling element bearings. In order to achieve the best performance, various inputs, including time waveforms, spectra, and envelopes, have been utilized. To implement and validate the algorithms, a laboratory setup was designed and constructed. After creating artificial faults on the bearings, experiments were conducted under 36 different operating conditions, comprising 6 different speeds, each at 6 different loads, encompassing four healthy states, including healthy, inner race fault, outer race fault, and rolling element fault. The obtained results have illustrated that the fault detector model with the frequency spectrum input is more accurate with an accuracy of 95% than the models receiving the other two inputs.

## KEYWORDS

Condition Monitoring, Intelligent Fault Diagnosis, Convolutional Neural Network, Rolling Element Bearing, Variable Operating Conditions, Vibration Analysis.

---

<sup>1</sup> Corresponding Author: Email: m\_behzad@sharif.edu