

## طبقه بندی عیوب جعبه دنده بر اساس سیگنال ارتعاشی حوزه زمان و یادگیری عمیق

آرمین فهندژ آ، عباس روحانی بسطامی<sup>ب\*</sup>، مصطفی عابدی<sup>پ</sup>

<sup>ا</sup> ایران، تهران، دانشگاه شهید بهشتی، دانشکده مهندسی مکانیک و انرژی، دانشجوی کارشناسی ارشد

<sup>ب</sup> ایران، تهران، دانشگاه شهید بهشتی، دانشکده مهندسی مکانیک و انرژی، استادیار.

<sup>پ</sup> ایران، تهران، دانشگاه شهید بهشتی، دانشکده مهندسی برق، استادیار

\*پست الکترونیکی نویسنده مسئول: [a\\_rohani@sbu.ac.ir](mailto:a_rohani@sbu.ac.ir)

### چکیده

با توجه به پیشرفت‌های اخیر تکنولوژی، رشد هوش مصنوعی و همچنین افزایش حجم داده‌ها، پایش تجهیزات دستخوش تغییرات بزرگ گشته است. کلان داده‌ها<sup>۱</sup> که حاصل حجم زیادی از اندازه‌گیری‌ها و ثبت سوابق در پایگاه‌های داده هستند، اطلاعات ارزشمندی نظیر سابقه‌ی فعالیت در اختیار ما قرار می‌دهند. تشخیص خرابی در ماشین‌های سرعت متغیر به خاطر اثر تغییر سرعت روی ارتعاشات، دشواری بیشتری از ماشین‌های سرعت ثابت وجود دارد. در این پژوهش عیب‌یابی و طبقه بندی خرابی‌های یک جعبه‌دنده توسط شبکه عصبی پیچشی<sup>۲</sup> برای طبقه‌بندی ۹ کلاس خرابی و یک کلاس نرمال (حالت سالم) انجام شده است. برای این منظور سیگنال شتاب در حوزه زمان توسط دو سنسور شتاب سنج در شرایط کاری مختلف شامل سرعت و بارهای متفاوت ذخیره شده و بعد از عبور از یک پنجره با طول مشخص به عنوان ورودی به شبکه داده شده است. در نتایج آخر نیز با توجه به نمودارها می‌توان مشاهده کرد که دقت تشخیص عیوب شبکه عصبی پیچشی به ۸۲ درصد رسیده است.

**کلمات کلیدی:** ارتعاشات؛ یادگیری عمیق؛ جعبه‌دنده؛ شبکه عصبی.

<sup>۱</sup> Big data

<sup>۲</sup> Convolutional neural network

## ۱- مقدمه

امروزه با توجه به پیشرفت تکنولوژی در صنایع مختلف، تغییرات بزرگی در زمینه پایش تجهیزات بوجود آمده است [۱]. یکی از پیشرفت‌های اخیر ایجاد کلان داده‌ها می‌باشد که در روند تغییر روش‌های عیب‌یابی بسیار اثر گذار بوده است [۲]. در همین راستا نیاز به استفاده از یک سیستم خودکار برای رصد همیشگی و الگوریتم‌هایی برای پایش بینی وضعیت تجهیز بیش از پایش احساس می‌شود، بدین علت که حجم داده‌ها و اندازه‌گیری‌های قبلی صورت گرفته بیش‌تر از توان بررسی انسان است و روند رشد اطلاعات با سرعت زیادی رو به افزایش است. در زمان قدیم عیب‌یابی ماشین‌آلات بیشتر به صورت دستی و توسط انسان انجام می‌گرفت که این باعث ایجاد فشار کاری بیشتری و همچنین دقت کمتری می‌شد. اما امروزه به دلیل پیشرفت ماشین‌آلات نیاز است که موضوعات مربوط به آن نیز پیشرفت کند. به همین دلیل صنعت به یک سیستم هوشمند و خودکار نیاز دارد تا بتواند ۱- در سریع‌ترین زمان ممکن و ۲- با دقت بالاتر وضعیت تجهیزات را بررسی نماید. این امر صنایع را به سمت الگوریتم‌های هوشمند و یادگیری ماشین سوق می‌دهد. استفاده از سیستم‌های عیب‌یابی خودکار معمولاً بر پایه‌ی الگوریتم‌های یادگیری ماشین<sup>۱</sup> می‌باشد که در میان روش‌های موجود در صنعت، بیشتر از الگوریتم‌های مربوط به بخش یادگیری ماشین و زیرمجموعه اصلی آن شبکه‌های عصبی مصنوعی استفاده می‌کند [۳،۴]. در این روش، شبکه عصبی برای پایش بینی و طبقه‌بندی وضعیت یک سیستم یا دستگاه به کار می‌رود. این روش با استفاده از داده‌های ورودی سیستم، رفتار آن را پایش بینی می‌کند و در صورت شناسایی هرگونه خطا، به کاربر اطلاع می‌دهد. در شکل ۱ می‌توان روند تکامل الگوریتم‌های هوش مصنوعی را مشاهده کرد، همانطور که مشخص است از سال ۲۰۱۹ به بعد استفاده از شبکه عصبی مصنوعی گسترش یافته و در ادامه از سال ۲۰۲۰ نیز شبکه عصبی پیچشی و به طبع نیز یادگیری عمیق در زمینه‌های تشخیص و پایش بینی عیوب توسعه داشته‌اند همچنین می‌توان با توجه به شکل ۱ میزان تکامل شبکه‌های کلاسیک را مشاهده کرد. لازم به ذکر است با کمی دقت می‌توان متوجه شد که از سال ۲۰۱۸ به بعد الگوریتم‌های بسیار متنوع و جدیدی به وجود آمده که بیشتر هم در زمینه‌های تشخیص و پایش بینی عیوب مورد بررسی قرار گرفته است، که این خود نشانه استفاده بیشتر محققین از این الگوریتم‌ها در راستای پژوهش‌های خود در سال‌های اخیر است.

جعبه‌دنده به زبان ساده یکی از ابزارهای سیستم انتقال قدرت است که میان یک تولیدکننده توان (الکتروموتور، موتور دیزل و ... ) و یک مصرف‌کننده توان (می‌تواند هر ماشینی باشد) قرار می‌گیرد. وظیفه جعبه‌دنده تغییر سرعت دوران و گشتاور ورودی متناسب با نیاز دستگاه مصرف‌کننده توان می‌باشد. جعبه‌دنده‌ها را می‌توان در دو دسته تقسیم کرد. ۱- جعبه‌دنده‌های کاهنده: این نوع جعبه‌دنده‌ها که بین موتور و متحرک قرار دارند، با کاهش دور ورودی و سرعت آن، قدرت بیشتری را در خروجی ایجاد می‌کنند. ۲- جعبه‌دنده‌های افزایشنده: این نوع جعبه‌دنده‌ها که محل قرارگیری آن‌ها با نوع کاهنده تفاوتی ندارد با افزایش دور ورودی و سرعت آن، قدرت کمتری را در خروجی ایجاد می‌کنند.


جعبه‌دنده‌ها از اجزای متفاوتی تشکیل شده‌اند که مهم‌ترین آن‌ها چرخ دنده است که می‌تواند با توجه به مدل جعبه‌دنده تغییر کند. از سایر اجزای آن می‌توان به پوسته، شافت‌ها، یاتاقان‌ها و کاسه نمد اشاره کرد. جعبه‌دنده‌ها را می‌توان در انواع مختلف در صنایع مختلف به فراوانی مشاهده کرد.

شبکه‌های عصبی یکی از محبوب‌ترین الگوریتم‌های تشخیص عیوب در زمینه هوش مصنوعی هستند. ساختمان این الگوریتم شامل سه بخش اصلی لایه ورودی، لایه‌های پنهان و لایه‌ی خروجی است. این شبکه نمونه شبیه‌سازی شده از نورون‌های مغزی انسان است و به دو دسته شبکه‌های عصبی کم‌عمق و عمیق تقسیم‌بندی می‌شوند. در شکل ۲ می‌توان تفاوت شبکه عصبی کم‌عمق و شبکه عصبی عمیق را مشاهده کرد.


یادگیری عمیق<sup>۲</sup> در واقع همان شبکه‌ی عصبی مصنوعی می‌باشد که از تعداد بیشتری لایه‌ی مخفی برای محاسبات استفاده می‌کند [۶]. در پایش وضعیت هوشمند با استفاده از شبکه عصبی عمیق، ابتدا نمونه‌هایی از داده‌های سیستم جمع‌آوری و به شبکه عصبی داده می‌شوند. سپس شبکه عصبی با استفاده از الگوریتم‌های یادگیری از داده‌های آموزشی، الگوهایی در رفتار سیستم تشخیص می‌دهد [۷]. در ادامه مروری بر تحقیقات بیان شده است.

<sup>۱</sup> Machine learning

<sup>۲</sup> Deep learning



شکل ۱- سیر تکاملی الگوریتم‌های هوش مصنوعی [۵]



شکل ۲- تفاوت شبکه عصبی عمیق و شبکه عصبی کم‌عمق

اوزان و همکاران عیب‌یابی را بر روی یک دستگاه جعبه‌دنده تک مرحله انجام دادند. سیستم آزمایشی آن‌ها از یک پینیون ۱۹ دندانه و یک چرخ‌دنده ۴۸ دندانه تشکیل شده است. داده‌برداری آن‌ها در ۴ مرحله انجام گرفته است، یک بار در حالت سالم و ۳ بار هم در حالت معیوب که البته تمامی ۳ حالت معیوب بر روی پینیون ایجاد شده است. هدف آن‌ها از انجام این پروژه بررسی پاسخ‌های به‌دست آمده با استفاده از ۳ روش سنتی یادگیری ماشین (Support Vector Classification, Random Forest Classification, Decision Tree Classification) و یک روش یادگیری عمیق است. که در نهایت نتیجه حاصل از آن‌ها با یک‌دیگر مقایسه می‌گردد. در نهایت مشخص شد که دقت روش یادگیری عمیق عملکرد بهتری دارد [۸].


در بررسی دیگر ژئی جنگ چن و همکاران عیب‌یابی ترکیبی یک جعبه‌دنده را انجام دادند. این جعبه‌دنده از ۴ چرخ‌دنده و ۶ یاتاقان تشکیل شده است. در این پژوهش ۱۲ شرایط الگویی متفاوت از خرابی لحاظ شده و در ۵ دور و ۴ بار متفاوت داده‌برداری شده است. یعنی از هر مورد از شرایط الگویی ۲۰ بار داده برداری شده است. بررسی داده‌ها با استفاده از دو روش شبکه عصبی پیچشی و ماشین بردار پشتیبان صورت گرفته است و در نتیجه آن بالاترین دقت شبکه عصبی پیچشی برابر با ۹۸٫۹ درصد و در شبکه ماشین بردار پشتیبان برابر با ۸۱٫۵ درصد بوده است. اما میانگین دقت در شبکه عصبی پیچشی در ۲۰ تکرار برابر با ۹۶٫۸ درصد و در روش دیگر برابر با ۶۷٫۸ درصد بوده است [۹].

در این پژوهش عیب‌یابی بر روی یک جعبه‌دنده انجام می‌گیرد تا بتوان خرابی‌های ایجاد شده بر روی جعبه‌دنده را از یک‌دیگر و همچنین از حالت سالم تشخیص داد. برای انجام این کار از جعبه‌دنده داده برداری انجام شده است و سپس از روش شبکه عصبی پیچشی برای تفکیک حالات مختلف خرابی استفاده شده است.


## ۲- چیدمان آزمایشگاهی

دستگاه مورد آزمایش یک توربین شبیه‌سازی شده است که توسط یک موتور الکتریکی، پره آن به حرکت در می‌آید و انرژی تولیدی حاصل از آن تعدادی مشخص از لامپ‌ها را می‌تواند روشن نماید. داده برداری و عیب‌یابی بر روی جعبه‌دنده اصلی این مجموعه لحاظ می‌شود. این جعبه‌دنده دارای ۴ چرخ‌دنده، ۶ یاتاقان، ۳ شفت داخلی و پوسته می‌باشد. که در شکل ۳ و شکل ۴ مشخصات و شمای کلی آن آمده است.

در تصویر سمت چپ شکل ۴ محل قرارگیری یاتاقان‌ها با شماره گذاری و همچنین مسیر انتقال قدرت درون جعبه‌دنده نشان داده شده است. داده‌برداری از جعبه‌دنده توسط دو سنسور شتاب سنج که عمود بر هم و بر روی پوسته نصب شده‌اند انجام می‌شود. به صورت کلی داده برداری در شرایط، سرعت و بارهای مختلف انجام شده است تا بتوان دقت شبکه عصبی را به بالاترین حد ممکن رساند. داده برداری در ۱۰ شرایط مختلف صورت گرفته است که یک حالت آن طبیعی و سالم است و در ۹ حالت دیگر انواع خرابی به شرح زیر ایجاد شده است [۱۰].



شکل ۳- شمای کلی دستگاه [۱۷]



ب- محل قرارگیری یاتاقان‌ها

الف- شیوه قرارگیری چرخ‌دنده‌ها


شکل ۴- نمای داخلی جعبه‌دنده [۱۷]

- ۱- Normal (سالم)
- ۲- Gear ۱۸T wearing (سایش چرخ‌دنده ۱۸ دندانه)
- ۳- Gear ۱۸T wearing & Bearing ۲ (سایش چرخ‌دنده ۱۸ دندانه و بلبرینگ معیوب شماره ۲)
- ۴- Gear ۱۸T wearing & Bearing ۳ (سایش چرخ‌دنده ۱۸ دندانه و بلبرینگ معیوب شماره ۳)
- ۵- Gear ۱۸T wearing & Bearing ۴ (سایش چرخ‌دنده ۱۸ دندانه و بلبرینگ معیوب شماره ۴)
- ۶- Unbalance (نابالانسی)
- ۷- Gear ۱۸T wearing & unbalance (سایش چرخ‌دنده ۱۸ دندانه و نابالانسی)
- ۸- Gear ۹۵T Mashed (له‌شدگی چرخ‌دنده ۹۵ دندانه)
- ۹- Gear ۹۵T Chipping (لب‌پریدگی چرخ‌دنده ۹۵ دندانه)
- ۱۰- Gear ۹۵T Chipping & unbalance (لب‌پریدگی چرخ‌دنده ۹۵ دندانه و نابالانسی)

هم‌چنین ترکیب سرعت و بار مختلف هم به طور کلی در ۶ حالت زیر داده برداری شده است:

- ۱- سرعت شفت ورودی ۲۰ هرتز و بدون بار
- ۲- سرعت شفت ورودی ۳۰ هرتز و بدون بار
- ۳- سرعت شفت ورودی ۴۲,۱ هرتز و بدون بار
- ۴- سرعت شفت ورودی ۴۴,۵ هرتز و بار ۱۲۰ وات
- ۵- سرعت شفت ورودی ۴۶ هرتز و بار ۱۸۰ وات
- ۶- سرعت شفت ورودی ۴۹,۷ هرتز و بار ۳۰۰ وات

با توجه به شرایط و حالات مختلف مجموعاً ۶۰ فایل داده برداری ایجاد شد که در هر کدام از این حالت‌ها، داده برداری به صورت حدودی در بازه زمانی ۵ دقیقه با فرکانس نمونه برداری ۱۰ کیلوهرتز برداشت شده است. یعنی به ازاء هر ۰,۱ میلی ثانیه یک داده ثبت شده است. اما چون داده در هنگام روشن و خاموش شدن دستگاه هم ذخیره شده پس برای انجام بهتر پروژه از داده‌های ۴ دقیقه میانی استفاده شده است زیرا در هنگام خاموش و روشن کردن دستگاه سرعت کم و زیاد شده و از فرکانس‌های طبیعی نیز عبور می‌کند که این خود خطایی در فرایند ایجاد می‌کند. یک نمونه از سیگنال حوزه زمان شتاب در شکل ۵ قابل مشاهده است.



شکل ۵- نمونه‌ای از سیگنال شتاب در حوزه زمان

### ۳- عیب‌یابی با یادگیری عمیق

همان‌طور که گفته شد یادگیری عمیق به دلیل توانایی شناسایی الگوهای پیچیده و ارتباطات نهفته، از آنجایی که می‌تواند اطلاعاتی را که ابتدا به نظر پیچیده و درهم‌تنیده می‌آیند را به صورت ساده و قابل فهم برای سیستم‌های کامپیوتری تبدیل کند، در بسیاری از حوزه‌ها مورد استفاده قرار می‌گیرد [۱۱، ۱۲]. گرچه این روش در عیب‌یابی سیستم‌های دوار دارای چالش‌هایی است (طول شبکه، دقت و زمان و ...) که باید بررسی شود [۱۳] اما در این پروژه از شبکه پیچشی برای طبقه‌بندی و پیش‌بینی خرابی‌ها استفاده شده است.

در این روش از شبکه عصبی پیچشی استفاده شده است که شبکه قابلیت تشخیص الگو از روی داده‌های در حوزه زمان را دارد [۱۴، ۱۵]. روش کار بدین صورت است که در هر حالت ۴ دقیقه‌ای داده برداری شده، پنجره‌ای به طول ۱۰۰۰ نقطه ایجاد کرده و بر روی سیگنال شتاب حرکت داده می‌شود و داده‌های موجود در پنجره را در هر بار درون ماتریسی به ابعاد (۱۰۰، ۲۸۸۰۰، ۱۰۰۰) ذخیره می‌شود. سپس این ماتریس کلی برچسب<sup>۱</sup> گذاری شده و به دو بخش ۸۰ درصد آموزش و ۲۰ درصد آزمون<sup>۲</sup> تقسیم می‌شود و در نهایت به شبکه وارد می‌شود [۱۶]. در جدول ۳ ساختار لایه شبکه عصبی پیچشی آمده است و لازم به ذکر است که تعداد لایه‌ها از روش آزمون و خطا بدست آمده است و تعداد نقطه لایه آخر به دلیل اینکه ۱۰ کلاس طبقه‌بندی داریم برابر با ۱۰ در نظر گرفته شده است.

#### ۳-۱ اثر طول پنجره بر دقت شبکه

یکی از پارامترهای تاثیرگذار بر دقت شبکه در این روش طول پنجره ای می‌باشد که با استفاده از آن یک سیگنال را به بخش‌های کوچک‌تر تقسیم کرده تا بتوان آن را به عنوان داده ورودی به شبکه داد. لازم به ذکر است که به طور کلی هر چه طول پنجره کمتر باشد تعداد داده‌های ورودی به شبکه بیشتر می‌شود که برای آموزش شبکه بسیار موثر است و این موضوع در شبکه عصبی پیچشی هم صدق می‌کند. ولی نکته قابل توجه اینجاست که با کاهش طول پنجره تعداد داده بیشتر شده و مدت زمان بیشتری برای محاسبه نیاز دارد پس باید مقدار بهینه برای طول پنجره پیدا شود. برای این کار ابتدا طول پنجره ۵۰۰۰ نقطه در نظر گرفته شد که در این حالت دقت شبکه به ۷۱ درصد رسید، در ادامه طول پنجره تا ۵۰۰ نقطه در طی چند مرحله کاهش داده شد که میزان افزایش دقت در جدول ۲ آمده است. لازم به توضیح است که پس از بررسی طول‌های مختلف، عدد انتخاب شده برابر با ۱۰۰۰ نقطه شد.

<sup>۱</sup> label

<sup>۲</sup> Train and Test

جدول ۱- ساختار شبکه عصبی پیچشی استفاده شده در این تحقیق

Model: "sequential"

Layer (type)	Output Shape	Params #
conv\1d (Conv\1D)	(None, ۹۹۹, ۳۲)	۹۶
conv\1d_1 (Conv\1D)	(None, ۹۹۸, ۶۴)	۴۱۶۰
conv\1d_2 (Conv\1D)	(None, ۹۹۷, ۱۲۸)	۱۶۵۱۲
conv\1d_3 (Conv\1D)	(None, ۹۹۶, ۲۵۶)	۶۵۷۹۲
conv\1d_4 (Conv\1D)	(None, ۹۹۵, ۵۱۲)	۲۶۲۶۵۶
conv\1d_5 (Conv\1D)	(None, ۹۹۴, ۲۵۶)	۲۶۲۴۰۰
conv\1d_6 (Conv\1D)	(None, ۹۹۳, ۱۲۸)	۶۵۶۶۴
flatten (Flatten)	(None, ۱۲۷۱۰۴)	۰
dense (Dense)	(None, ۱۲۸)	۱۶۲۶۹۴۴۰
dense_1 (Dense)	(None, ۱۰)	۱۴۱۹

Total params: ۱۶,۹۴۸,۱۳۹

Trainable params: ۱۶,۹۴۸,۱۳۹

Non-trainable params: ۰

جدول ۲- نسبت طول پنجره و دقت شبکه


دقت شبکه	طول پنجره
۸۰	۵۰۰
۸۲	۱۰۰۰
۷۹	۲۰۰۰
۷۶	۳۰۰۰
۷۴	۴۰۰۰
۷۱	۵۰۰۰

#### ۴- نتایج

در این روش که از شبکه عصبی پیچشی استفاده شده است دقت متوسط آن برابر با ۸۲ درصد می‌باشد که در نمودار ماتریسی شکل ۶ به خوبی توانایی تفکیک کلاس‌ها توسط شبکه نشان داده شده است. این نتایج نشان می‌دهد که می‌توان از این سیستم برای تشخیص و عیب‌یابی استفاده کرد. همچنین از میزان دقت و خطای شبکه که در شکل ۷ نشان داده شده است می‌توان متوجه شد که

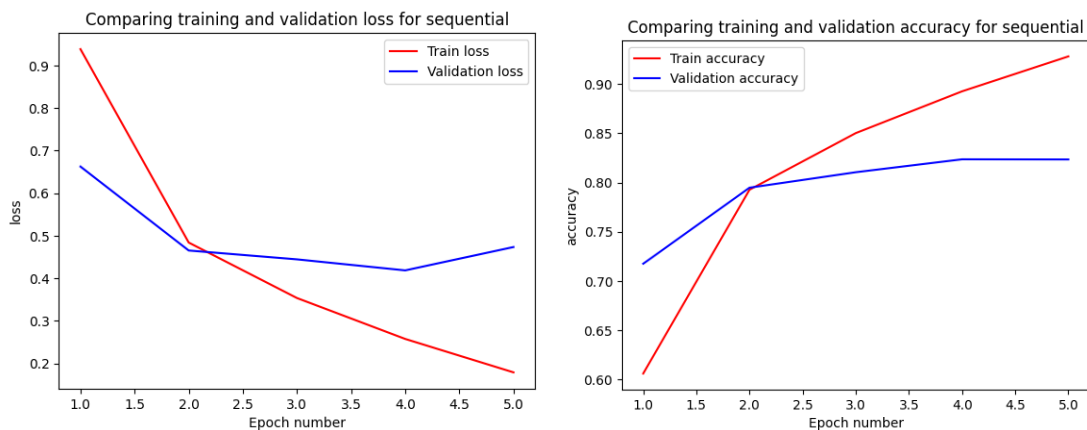


با گذر زمان دقت بالا رفته و میزان خطا کاهش یافته است و همچنین میزان رفت و برگشت<sup>۱</sup> شبکه برابر با ۵ بوده است که خود حاکی از توانایی تفکیک این شبکه می‌باشد.



شکل ۶- ماتریس سردرگمی شبکه عصبی پیچشی

با توجه به شکل ۶ که ماتریس سردرگمی<sup>۲</sup> می‌باشد. قطر فرعی نشان از درست بودن تشخیص شبکه از کلاس‌ها می‌باشد. یعنی هرچه اعداد روی قطر اصلی بیشتر باشد قدرت تشخیص بالاتر است. البته می‌توان متوجه شد که در بعضی از ردیف‌ها تشخیص اشتباه نیز وجود دارد که با توجه به رنگ‌ها کمیت آن مشخص شده است.



شکل ۷- نمودار دقت و خطای شبکه عصبی پیچشی در ۵ تکرار

در شکل ۷ مشخص است که دقت شبکه با گذر زمان بیشتر و خطا کمتر می‌شود. تعداد رفت و برگشت این روش (۵ تکرار) است و علت آن جلوگیری از یادگیری بیش از حد شبکه می‌باشد. دقت شبکه بعد از ۵ بار تکرار به ۸۲ درصد رسیده است.

## ۵- جمع بندی

با توجه به پژوهشی که انجام شد می‌توان گفت که یادگیری عمیق به دلیل قابلیت تشخیص الگوهای پیچیده و استخراج ویژگی‌های عمیق از داده‌ها، در پایش وضعیت هوشمند دارای قابلیت بالایی می‌باشد. با استفاده از شبکه عصبی پیچشی و سیگنال حوزه زمان می‌توان با دقت و سرعت قابل قبولی به عبیبابی سیستم‌های مکانیکی پرداخت. به عنوان پیشنهاد برای ادامه کار می‌توان

<sup>۱</sup> Epoch

<sup>۲</sup> Confusion matrix



طبقه بندی سایر عیوب متداول در ماشین های دوار را با شبکه عصبی پیچشی انجام داد. این روش می تواند در نرم افزارهای هوشمند عیب یابی مورد استفاده قرار گیرد. همچنین استفاده از ویژگی های حوزه فرکانس می تواند در افزایش دقت طبقه بندی موثر باشد.

## مراجع

- ۱- Goyal, Deepam, B. S. Pabla, and S. S. Dhami. "Condition monitoring parameters for fault diagnosis of fixed axis gearbox: a review." *Archives of Computational Methods in Engineering* ۲۴ (۲۰۱۷): ۵۴۳-۵۵۶.
- ۲- Yin, Shen, Xianwei Li, Huijun Gao, and Okyay Kaynak. "Data-based techniques focused on modern industry: An overview." *IEEE Transactions on Industrial Electronics* ۶۲, no. ۱ (۲۰۱۴): ۶۵۷-۶۶۷.
- ۳- Duan, Lixiang, Mengyun Xie, Jinjiang Wang, and Tangbo Bai. "Deep learning enabled intelligent fault diagnosis: Overview and applications." *Journal of Intelligent & Fuzzy Systems* ۳۵, no. ۵ (۲۰۱۸): ۵۷۷۱-۵۷۸۴.
- ۴- Liu, Ruonan, Boyuan Yang, Enrico Zio, and Xuefeng Chen. "Artificial intelligence for fault diagnosis of rotating machinery: A review." *Mechanical Systems and Signal Processing* ۱۰۸ (۲۰۱۸): ۳۳-۴۷.
- ۵- van Dreven, Jonne, Veselka Boeva, Shahrooz Abghari, Håkan Grahn, Jad Al Koussa, and Emilia Motoasca. ۲۰۲۳. "Intelligent Approaches to Fault Detection and Diagnosis in District Heating: Current Trends, Challenges, and Opportunities" *Electronics* ۱۲, no. ۶: ۱۴۴۸. <https://doi.org/10.3390/electronics12061448>
- ۶- LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. "Deep learning." *nature* ۵۲۱, no. ۷۵۵۲ (۲۰۱۵): ۴۳۶-۴۴۴.
- ۷- Lei, Yaguo, Feng Jia, Jing Lin, Saibo Xing, and Steven X. Ding. "An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data." *IEEE Transactions on Industrial Electronics* ۶۳, no. ۵ (۲۰۱۶): ۳۱۳۷-۳۱۴۷.
- ۸- Gecgel, Ozhan, Stephen Ekworo-Osire, João Paulo Dias, Abdul Serwadda, Fisseha M. Alemayehu, and Abraham Nispel. "Gearbox fault diagnostics using deep learning with simulated data." In ۲۰۱۹ IEEE International Conference on Prognostics and Health Management (ICPHM), pp. ۱-۸. IEEE, ۲۰۱۹.
- ۹- Chen, ZhiQiang, Chuan Li, and René-Vinicio Sanchez. "Gearbox fault identification and classification with convolutional neural networks." *Shock and Vibration* ۲۰۱۵ (۲۰۱۵).
- ۱۰- Liang, Xihui, Ming J. Zuo, and Zhipeng Feng. "Dynamic modeling of gearbox faults: A review." *Mechanical Systems and Signal Processing* ۹۸ (۲۰۱۸): ۸۵۲-۸۷۶.
- ۱۱- Zhao, Rui, Ruqiang Yan, Zhenghua Chen, Kezhi Mao, Peng Wang, and Robert X. Gao. "Deep learning and its applications to machine health monitoring." *Mechanical Systems and Signal Processing* ۱۱۵ (۲۰۱۹): ۲۱۳-۲۳۷.
- ۱۲- Duan, Lixiang, Mengyun Xie, Jinjiang Wang, and Tangbo Bai. "Deep learning enabled intelligent fault diagnosis: Overview and applications." *Journal of Intelligent & Fuzzy Systems* ۳۵, no. ۵ (۲۰۱۸): ۵۷۷۱-۵۷۸۴.
- ۱۳- Saufi, Syahril Ramadhan, Zair Asrar Bin Ahmad, Mohd Salman Leong, and Meng Hee Lim. "Challenges and opportunities of deep learning models for machinery fault detection and diagnosis: A review." *Ieee Access* ۷ (۲۰۱۹): ۱۲۲۶۴۴-۱۲۲۶۶۲.
- ۱۴- Zhao, Xiaoli, and Minping Jia. "A new local-global deep neural network and its application in rotating machinery fault diagnosis." *Neurocomputing* ۳۶۶ (۲۰۱۹): ۲۱۵-۲۳۳.
- ۱۵- Liu, Haiying, Ruizhe Ma, Daiyi Li, Li Yan, and Zongmin Ma. "Machinery fault diagnosis based on deep learning for time series analysis and knowledge graphs." *Journal of Signal*

Processing Systems ۹۳ (۲۰۲۱): ۱۴۳۳-۱۴۵۵.

۱۶-Jiang, Wanlu, Chenyang Wang, Jiayun Zou, and Shuqing Zhang. "Application of deep learning in fault diagnosis of rotating machinery." Processes ۹, no. ۶ (۲۰۲۱): ۹۱۹.

۱۷-جواد حسن‌پور سنگلجی، پایان‌نامه کارشناسی ارشد، "طراحی الگوریتم آشکارسازی عیب جعبه‌دنده توربین بادی با استفاده از شبکه‌های عصبی عمیق"، دانشگاه شهید بهشتی، ۱۴۰۱