

یک مدل هوش مصنوعی برای ساخت شاخص سلامت چرخ‌دنده‌ها

محمد رضا کاجی*	جمشید پروبزیان	محمد سیلانی	سید حسین میرلوحی
دکتری	دانشیار	دانشیار	استادیار
مهندسی مکانیک	مهندسی مکانیک	مهندسی مکانیک	مهندسی برق
دانشگاه صنعتی اصفهان	دانشگاه صنعتی اصفهان	دانشگاه صنعتی اصفهان	دانشگاه فنی و مهندسی (گروه برق)، دانشگاه آزاد اسلامی واحد مبارکه، اصفهان
mohammadreza.kaji@gmail.com	japa@iut.ac.ir	silani@cc.iut.ac.ir	mirlohi@mau.ac.ir

تاریخ دریافت: ۱۴۰۲/۰۱/۲۳

تاریخ پذیرش: ۱۴۰۲/۰۵/۰۶

چکیده

هدف از پایش وضعیت افزارگان مکانیکی، رصد لحظه‌ای افزار به منظور پایش بینی رخ داد و اماندگی است. اولین گام برای پایش وضعیت یک افزار ساخت شاخص سلامت برای آن است. برای ایجاد شاخص سلامت ابتدا بایست داده‌های عملکردی همچون داده‌های ارتعاشی از افزار در طی مدت بهره‌برداری گردآوری شوند و سپس ویژگی‌های معنی‌دار از داده استخراج شوند. در این مطالعه یک مدل هوش مصنوعی (خود رمزگذار همگشتی^۱) برای استخراج ویژگی از داده‌های ارتعاشی معرفی شده که صرفاً نیازمند داده‌های وضعیت سالم افزار برای آموزش است. در این مدل، داده‌های ارتعاشی افزار در طی مدت بهره‌برداری در وضعیت سالم افزار به صورت برخط جمع‌آوری می‌شوند تا پایگاه داده در وضعیت سالم ایجاد شود. پس از تشخیص شروع وضعیت خرابی افزار، افزودن داده به پایگاه داده وضعیت سالم متوقف شده و مدل خود رمزگذار همگشتی توسط پایگاه داده آموزش می‌بیند. در نهایت در طی مرحله رشد خرابی‌ها، شاخص سلامت توسط تفاوت داده‌های ارتعاشی افزار در وضعیت خراب با پایگاه داده در وضعیت سالم ساخته می‌شود. عملکرد مدل پیشنهادی توسط داده‌های ارتعاشی چرخ‌دنده ارزیابی شده است و نتایج نشان‌دهنده عملکرد قابل قبول این روش در ساخت شاخص سلامت برای چرخ‌دنده‌ها است.

واژگان کلیدی: پایش وضعیت، چرخ‌دنده، هوش مصنوعی، شاخص سلامت، تخمین عمر باقیمانده.

۱. مقدمه

مکانیکی در انجام وظایف محوله به آن. وجود و اماندگی برای افزارگان منجر به خاموشی افزار، افزایش هزینه تعمیر، تأخیر در انجام وظایف، ایجاد هزینه‌های جانی و مالی برای افزارگان و یا واحد تولیدی می‌گردد. به منظور پیشگیری و یا رفع خرابی یک افزار، عملیات نگهداری و تعمیر صورت می‌گیرد. عملیات

اکثر افزارگان مکانیکی همچون هواپیماها، کشتی‌ها، توربین‌ها و موتورها معمولاً در شرایط محیطی سخت و برای طولانی مدت فعالیت می‌کنند. از این رو و اماندگی این افزارگان اجتناب‌ناپذیر است. براساس استاندارد ISO 13372 و اماندگی عبارت است از ناتوانایی یک بخش (همچون یک قطعه

نگهداری و تعمیر، به مجموعه‌ای از کنش‌های فنی و کارهای اصلاحی مرتبط گفته می‌شوند، که برای نگهداری و یا بازیابی سامانه‌ها در وضعیت کاری سالم صورت می‌پذیرند [۱]. به‌طور کلی سه دسته روش کلی برای نگهداری و تعمیر افزارگان مکانیکی معرفی شده‌اند که عبارت‌اند از: نگهداری و تعمیر پس از خرابی، نگهداری و تعمیر پیشگیرانه و نگهداری و تعمیر پیشگویانه [۲]. به دلیل افزایش بازه زمانی استفاده از تجهیز، کاهش زمان‌های تعویض و کاهش رخ داده‌های واماندگی غیر منتظره، روش‌های مبتنی بر نگهداری و تعمیر پیشگویانه نسبت به دو دسته روش دیگر جامع‌تر و کارآمدترند [۳]. در رویکرد نگهداری و تعمیر پیشگویانه، وضعیت افزار رصد شده و سعی می‌شود تا با توجه به آنالیز داده‌های جمع‌آوری شده، زمان خرابی پیش‌بینی شود تا درست قبل از خرابی، افزار تعمیر و یا تعویض گردد [۴].

اولین و مهم‌ترین گام برای پیاده‌سازی روش‌های نگهداری و تعمیر پیشگویانه، ساخت شاخص‌های سلامت است که برای تشخیص وضعیت فعلی افزار و تخمین عمر مفید باقیمانده به کار گرفته می‌شوند [۵]. شاخص سلامت توصیف‌کننده فاصله بین شرایط اولیه و سالم افزار با هر لحظه از آن در طول زمان رشد خرابی است. بنابراین با گذشت زمان و رشد میزان خرابی‌ها در تجهیز، میزان این فاصله بیشتر شده و انتظار می‌رود شاخص سلامت بتواند این روند را به‌خوبی توصیف کند [۱]. به‌طور کلی ساخت شاخص سلامت شامل طی سه گام است. در گام اول باید پارامتر قابل‌سنجش و حساس نسبت به خرابی افزار انتخاب شود. این پارامتر باید در طی مدت زمان بهره‌برداری از افزار به‌صورت برخط قابل‌اندازه‌گیری باشد و رابطه مستقیم با ایجاد و رشد خرابی‌ها در افزار داشته باشد. در گام دوم پس از انتخاب پارامتر مناسب، پردازش‌های اولیه بر روی داده‌های جمع‌آوری شده صورت پذیرد. نهایتاً در گام سوم ویژگی و یا شاخص مناسب از روی داده‌های پردازش شده استخراج گردد [۱].

برای یک افزار، متناسب با شرایط کاری و ماهیت ساختاری آن، انواع داده‌های مختلفی را برای پایش وضعیت می‌توان به‌کار برد که رایج‌ترین آنها پایش دما، فشار، ذرات ساینده در روغن، نوفه و ارتعاشات است [۶]. از میان این روش‌ها، رایج‌ترین رویکرد پایش ارتعاشات افزار است که با استفاده از حسگرهای ارتعاش سنج صورت می‌پذیرد. این رویکرد برای آن دسته از اجزای موجود در یک سامانه مکانیکی که در حین کار مرتعش هستند، به‌خوبی قابل‌استفاده است. اندازه‌گیری ارتعاشات افزار، یک روش بسیار کارآمد برای پایش وضعیت دینامیکی افزار از منظرهای همچون نامیزانی، ناهم‌راستایی، شل شدن، سایش و رشد ترک است. به‌طور کلی با ایجاد و رشد خرابی‌ها در افزار، رفتار دینامیکی سامانه تغییر خواهد کرد که در نتیجه باعث بروز انحراف قابل‌توجهی در الگوی ارتعاشی افزار می‌شود [۷]. بنابراین با به‌کارگیری روش‌های مناسب پردازش داده‌ها، می‌توان تغییرات در الگوهای ارتعاشی ناشی از اجزای معیوب را تفسیر نموده و شاخص سلامت مناسب برای افزار را ایجاد نمود. با توجه به گستردگی و کارایی سیگنال‌های ارتعاشی در پایش وضعیت، در این مطالعه، سیگنال‌های ارتعاشی به‌عنوان داده‌های خام در نظر گرفته شده‌اند.

روش‌های پردازش سیگنال‌های ارتعاشی را می‌توان در سه حوزه زمان، فرکانس و زمان-فرکانس دسته‌بندی نمود. در صورت استفاده از روش‌های تحلیلی حوزه زمان، برای به‌دست آوردن پارامترهای مناسب که نشان‌دهنده ایجاد و رشد عیوب باشند، باید داده‌های ارتعاشی سری زمانی ثبت و تحلیل شوند. در این حالت، برای دستیابی به پارامترهای قابل‌اعتماد و دقیق که ایجاد و رشد عیوب را به‌خوبی توصیف نمایند، حجم زیادی از داده سری زمانی مورد نیاز است [۸]. روش‌های تحلیل حوزه فرکانس و زمان-فرکانس براساس تبدیل داده‌های سری زمانی از یک فضای حالت به فضای حالت دیگر استوارند؛ به‌نحوی که جنبه‌های دیگری از داده‌ها در فضای حالت مقصد قابل‌تحلیل هستند. روش‌های آنالیز حوزه زمان-فرکانس می‌توانند تغییرات

فرکانسی درگذر زمان را آشکار سازند، و بنابراین اطلاعات سودمندی را از هر دو حوزه زمان و فرکانس ارائه می‌کنند [۱]. به دلیل ماهیت ناپایدار سیگنال‌های ارتعاشی در هنگام ایجاد و رشد خرابی‌ها، دسته روش‌های حوزه زمان-فرکانس در تشخیص عیوب در حال رشد افزار کارآمدتر بوده و بنابراین از این روش‌ها در این مطالعه بهره برده شده است. تاکنون روش‌های حوزه زمان-فرکانس مختلفی برای تبدیل داده‌های زمانی سیگنال‌های ارتعاشی معرفی شده‌اند که از پرکاربردترین آنها می‌توان به تبدیل فوریه زمان کوتاه [۹]، تبدیل موجک^۲ [۱۰] و تبدیل هیلبرت-هانگ^۳ [۱۱] اشاره کرد. از میان این روش‌ها، تبدیل موجک پیوسته برای این مطالعه انتخاب شده است. تبدیل موجک ابزاری نسبتاً جدید و قدرتمند در زمینه پردازش علامت است، که به‌ویژه در پردازش سیگنال‌های غیرثابت و گذار استفاده می‌شود. مزیت اصلی در تبدیل موجک، امکان استفاده از پنجره با طول متغیر و در نتیجه توانایی انجام تجزیه و تحلیل موضعی سیگنال، یا بزرگنمایی هر بازه زمانی، بدون از دست دادن اطلاعات طیفی موجود در علامت است [۱۲].

پس از داده‌برداری و پردازش آنها، ویژگی‌های مناسب که معرف وضعیت افزار باشند، باید استخراج شوند؛ به نحوی که این ویژگی‌ها باید رابطه مستقیم با خرابی افزار داشته و بتوانند ایجاد و رشد خرابی‌ها را توصیف نمایند. در سال‌های اخیر با توسعه روش‌های مبتنی بر هوش مصنوعی، روش‌های مختلفی جهت استخراج ویژگی برای افزارگان مکانیکی توسط محققان توسعه داده شده است. تاکنون مدل‌های یادگیری عمیق همچون شبکه‌های عصبی همگشتی^۴ [۱۳]، شبکه عصبی بازگشتی^۵ [۱۴]، شبکه عصبی خود-رمزگذار^۶ [۱۵] و شبکه عصبی مولد تخصصی^۷ [۱۶] به‌طور موفقیت‌آمیز برای استخراج ویژگی از سیگنال‌های ارتعاشی به کار گرفته شده‌اند. مدل‌های توسعه‌یافته یادگیری عمیق، بیشتر بر مبنای یادگیری نظارت شده و برای مسائل طبقه‌بندی استفاده شده‌اند. استفاده از این

مدل‌ها نیازمند وجود داده‌های آموزشی برجسب دار است. وجود این داده‌ها مستلزم جمع‌آوری داده‌های شکست از افزار در شرایط کاری مختلف است. جمع‌آوری این داده‌ها، بزرگترین عامل محدودکننده استفاده از ابزارهای هوش مصنوعی در نگهداری و تعمیر افزارگان است، زیرا که جمع‌آوری داده‌های شکست واقعی بسیار گران و در بسیاری از مواقع غیرممکن است. برای پاسخ به محدودیت ذکر شده، توسعه مدل‌های یادگیری عمیق مبتنی بر یادگیری بی‌نظارت و یا نیمه‌نظارت که تنها از داده‌های شرایط کاری سالم برای ساخت شاخص سلامت استفاده کنند، ضروری است [۱۷]. این مدل‌ها باید توانایی داده‌برداری برخط بی‌نیاز به داده‌های تاریخی شکست را داشته باشند.

هدف از این مطالعه ارائه یک روش نوین برای ساخت شاخص سلامت برای چرخ‌دنده با استفاده از یک مدل یادگیری عمیق، بدون نیاز به داده‌های خرابی پیشین و به‌صورت برخط در طی مرحله رشد خرابی است.

چرخ‌دنده‌ها از اجزاء پرکاربرد و اصلی در انواع ماشین‌های دوار هستند که برای انتقال سرعت و گشتاور از یک منبع چرخان به دستگاه دیگر مورداستفاده قرار می‌گیرند. در توربین‌های بادی که چرخ‌دنده یکی از اجزاء اصلی آن است، کاهش هزینه‌های نگهداری و تعمیر چرخ‌دنده‌ها می‌تواند تا ۳۰٪ هزینه‌های نگهداری و تعمیر کل توربین را کاهش دهد [۱۸]. شکست‌های غیرمنتظره در چرخ‌دنده‌ها منجر به اتلاف هزینه‌های سنگین مالی و حتی جانی می‌شوند، لذا تشخیص عیب در چرخ‌دنده در مراحل اولیه از اهمیت فوق‌العاده‌ای برخوردار است. آنالیز ارتعاشات از اصلی‌ترین روش‌های موجود در پایش وضعیت چرخ‌دنده‌ها است که توانایی شناسایی انواع مختلف عیوب همچون ترک‌ها در دندانه‌ها، ناهم‌راستایی، سایش دندانه‌ها و افزایش لقی میان دندانه‌ها را دارد [۱۹]. در این پژوهش از روش آنالیز ارتعاشات به‌منظور رصد لحظه‌ای تجهیز و از مدل‌های یادگیری عمیق به‌منظور استخراج وضعیت


تجهیز از داده‌های ارتعاشی استفاده شده است. در ادامه ابتدا پایگاه داده مورد استفاده در این پژوهش بیان خواهد شد، سپس روش پیشنهادی در این پژوهش ذکر شده و نهایتاً نتایج شاخص سلامت ساخته شده برای چرخ‌دنده با استفاده از روش معرفی شده در این پژوهش ارائه شده است.

۲. معرفی پایگاه داده

برای ارزیابی عملکرد شاخص سلامت پیشنهاد شده برای چرخ‌دنده در این مطالعه، از نتایج آزمایش تجربی اجرا تا شکست^۸ ارائه شده در مرجع [۲۰] استفاده شده است. در طی این آزمایش مقادیر ارتعاشات چرخ‌دنده از لحظه اول به‌کارگیری تا زمانی که نشانه‌های خرابی ظاهر شود، جمع‌آوری شده است. برای انجام این آزمون از یک موتور الکتریکی با توان اسمی ۲/۲ کیلووات با سرعت دورانی ثابت ۲۴۰۰ دور در دقیقه استفاده شده است. توان ایجاد شده توسط موتور توسط یک جفت پولی دندانه‌ای به یک جعبه مجموعه چرخ‌دنده وارد می‌شود. مجموعه چرخ‌دنده مورد استفاده حاوی دو جفت چرخ‌دنده ساده است که دارای نسبت انتقال ۵/۱ است. خروجی شافت مجموعه چرخ‌دنده به یک ترمز مکانیکی متصل شده است، که گشتاور مخالف ۴۰ N.m را اعمال می‌کند. چیدمان افزارگان و ترتیب چرخ‌دنده‌ها در شکل ۱ نشان داده شده است، همچنین اطلاعات کامل چرخ‌دنده شامل ابعاد، جنس و فرایند ساخت در مرجع [۲۰] ذکر شده است.


برای اندازه‌گیری ارتعاشات مجموعه چرخ‌دنده دو حسگر شتاب‌سنج تک محوره در دو راستای عمود بر یکدیگر بر بدنه مجموعه چرخ‌دنده نصب شده است. نرخ داده‌برداری حسگرها ۵۱۲۰ Hz است و هر سه دقیقه به مدت ۱/۶ ثانیه داده‌برداری انجام شده است. فرایند آزمایش و داده‌برداری تا شروع نشانه‌های خرابی ادامه داشته است. پس از حدود ۳۵ ساعت از انجام آزمایش، شافت خروجی مجموعه چرخ‌دنده متوقف می‌شود. پس از توقف آزمایش و بازرسی چرخ‌دنده‌ها، مشخص

می‌شود که چرخ‌دنده شماره ۵ و ۶ به‌شدت آسیب دیده‌اند و از تماس با یکدیگر خارج شده‌اند که در شکل ۲ مشاهده می‌شود. همچنین برای هر دو چرخ‌دنده شکست دندانه‌ها صورت پذیرفته که وضعیت چرخ‌دنده ۵ وخیم‌تر بوده است [۲۰].



شکل ۱. چیدمان افزارگان مورد استفاده در آزمایش اجرا تا

شکست مجموعه چرخ‌دنده [۲۰]




شکل ۲. وضعیت چرخ‌دنده‌ها در انتهای آزمایش [۲۰]

۳. ساخت شاخص سلامت

در این پژوهش یک روش برای ساخت شاخص سلامت برای چرخ‌دنده با استفاده از یک مدل یادگیری عمیق و قابل‌پیاده‌سازی براساس فناوری‌های توسعه‌یافته در انقلاب صنعتی چهارم معرفی شده است. مدل یادگیری عمیق ارائه شده در این مطالعه صرفاً با داده‌های وضعیت سالم افزار آموزش‌دیده می‌شود و برای حالت‌های پایدار و یا گذار قابل‌استفاده است. در غیاب خرابی‌های ناگهانی و غیرمنتظره همانند شوک‌های مکانیکی و حوادث غیرمترقبه طول عمر افزارگان مکانیکی را می‌توان به دو بازه مجزا تقسیم‌بندی نمود:

بازه وضعیت سالم افزار و بازه وضعیت خرابی افزار که در آن خرابی‌ها ایجاد و رشد می‌یابند که در شکل ۳ آمده است.



شکل ۳. تقسیم‌بندی طول عمر افزار به دو بازه وضعیت سالم و وضعیت خراب

پس از بروز علائم مرحله اول، افزار دارای عدم انطباق شناخته می‌شود، ولی کماکان می‌تواند تا مدت معین در طی مرحله دوم به فعالیت خود ادامه دهد.

بنابراین، استفاده از افزار دارای عدم انطباق تا پیش از واماندگی نهایی به شرط ارضای شرایط عملکردی، به‌خصوص برای افزارگان گران‌قیمت و حساس، می‌تواند بازده عمر افزار را به‌طور چشمگیری افزایش دهد. هدف از فرایند داده‌برداری از افزار و پردازش سیگنال‌ها به‌صورت برخط، ایجاد پایگاه داده از سیگنال‌های ارتعاشی در وضعیت سالم افزار است که با بهره‌گیری از این پایگاه داده مدل یادگیری عمیق آموزش می‌بیند و سپس در طول بازه خرابی افزار، شاخص سلامت ساخته می‌شود تا عمر مفید باقیمانده افزار در دوره وضعیت خرابی تخمین زده شود.

پس از جمع‌آوری داده‌های وضعیت سالم افزار و شناسایی شروع وضعیت خرابی تجهیز با استفاده از معیار پارتو^۹ [۲۱]، مدل یادگیری عمیق توسط داده‌های وضعیت سالم آموزش داده می‌شود. پیش از آموزش مدل یادگیری عمیق، فرایند پیش‌پردازش بر روی داده‌ها بایستی صورت پذیرد. از آنجاکه سیگنال‌های ارتعاشی در زمان ایجاد و رشد خرابی‌ها ناپایدار و

گذار هستند، روش تبدیل موجک پیوسته برای این مطالعه انتخاب شده است.

برای محاسبه تبدیل موجک یک علامت ارتعاشی پیوسته، در ابتدا باید این علامت را به قسمت‌های مساوی تقسیم نمود و برای هر قسمت تبدیل موجک به‌کار گرفته شود. برای این کار، حداقل تعداد نقطه داده که شامل اطلاعات یک سیکل کاری افزار است، برای طول هر قسمت انتخاب می‌شود. تعداد این نقطه داده تابعی از فرکانس داده‌برداری و سرعت دورانی افزار است. در آنالیز تبدیل موجک با مقایسه تابع موجک مادر با علامت تکه شده، مقادیر جابه‌جایی و اتساع تابع موجک مادر به‌دست می‌آید. از آنجاکه انتخاب تابع موجک مادر وابسته به شکل علامت پایه است، انتخاب مناسب آن تأثیر به‌سزایی در دقت نتایج دارد. به‌طور کلی هر میزان شکل تابع موجک مادر به علامت پایه شبیه‌تر باشد، نتایج دقیق‌تری را به همراه خواهد داشت.

نتیجه آنالیز تبدیل موجک، تابع مختلط $W_n(s)$ خواهد بود. این تبدیل را می‌توان به قسمت حقیقی $\Re\{W_n(s)\}$ و قسمت موهومی $\Im\{W_n(s)\}$ تقسیم نمود. در نهایت طیف توانی تبدیل موجک برابر با $|W_n(s)|^2$ خواهد بود [۱۲].

هدف از استفاده ابزار تبدیل موجک در این مطالعه، ایجاد تصاویر متمایز متناسب با میزان رشد خرابی است؛ به‌نحوی که تصاویر ایجاد شده در طول عمر افزار بتوانند مراحل ایجاد و رشد خرابی‌ها را به‌خوبی نشان دهند. پس از ایجاد این تصاویر توسط تبدیل موجک، وظیفه مدل یادگیری عمیق آن است که بتواند میزان تفاوت تصاویر را به‌صورت خودکار تعیین نماید. برای نشان دادن مزایای استفاده از تبدیل موجک، نمایش علامت در حوزه زمان و طیف توانی تبدیل موجک متناظر با آن برای دو حالت علامت ارتعاشی در وضعیت سالم و وضعیت خراب برای نمونه در شکل ۴ نشان داده شده است. درحالی‌که برای علامت در وضعیت سالم نوسانات دوره‌ای و با دامنه کم


قابل مشاهده است، برای علامت در وضعیت خرابی نوسانات شدیدتر و با دامنه بزرگتر قابل مشاهده است.

برای علامت در وضعیت سالم بیشتر انرژی در طیف توانی در فرکانس‌های بالا تمرکز داشته، درحالی که برای علامت در وضعیت خرابی انفجار انرژی در بازه فرکانسی وسیع‌تر رخ می‌دهد.


همان‌گونه که قابل مشاهده است تبدیل موجک می‌تواند به خوبی میان علامت سالم و خراب تمایز قائل کند و تصاویر متفاوت ایجاد نماید. پس از جمع‌آوری سیگنال‌های ارتعاشی در وضعیت سالم افزار و پیش‌پردازش این سیگنال‌ها به وسیله

تبدیل موجک پیوسته، پایگاه داده برای آموزش مدل یادگیری عمیق ایجاد گشته و مدل یادگیری عمیق توسط این پایگاه داده آموزش می‌بیند.


مدل یادگیری عمیق توسعه یافته در این پروژه، یک مدل‌های خود-رمزگذار است که از دسته مدل‌های نیمه نظارت است و برای استخراج ویژگی‌ها، کاهش ابعاد و حذف نوفه‌ها استفاده می‌شود. مهم‌ترین مشخصه این شبکه‌ها، داشتن تعداد یکسان از نورون در لایه ورودی و لایه خروجی شبکه است؛ به نحوی که شبکه آموزش می‌بیند تا مقادیر ورودی را عیناً در لایه خروجی پیش‌بینی کند.




(ب)



(الف)



(د)

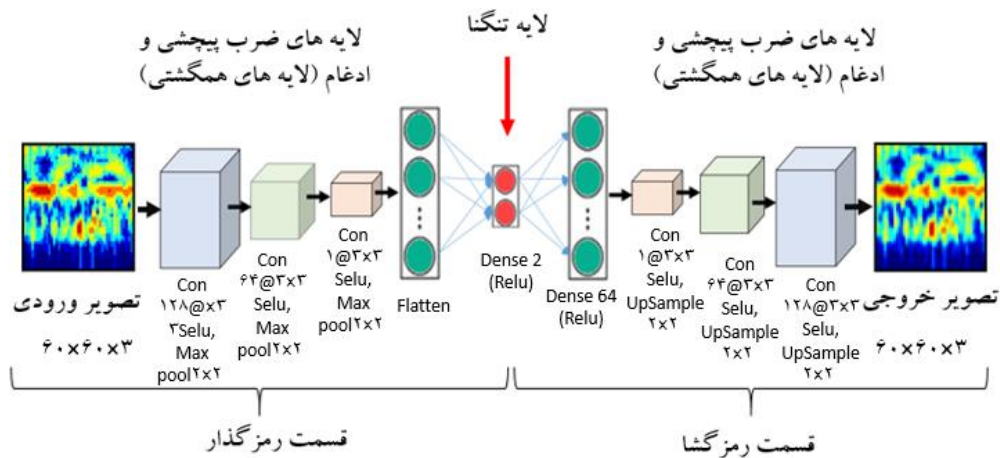


(ج)

شکل ۴. مقایسه تصاویر علامت در حوزه زمان با تصاویر طیف توانی تبدیل موجک برای افزار سالم و معیوب (الف) علامت خام سالم در حوزه زمان، (ب) تصویر طیف توانی تبدیل موجک برای وضعیت سالم، (ج) علامت خام برای وضعیت معیوب در حوزه زمان و (د) تصویر طیف توانی تبدیل موجک برای وضعیت معیوب.

یک شبکه خود-رمزگذار ساده حداقل از سه لایه تشکیل شده که عبارت‌اند از: لایه ورودی، لایه تنگنا (میانی) و لایه خروجی. از منظر تعداد نورون در هر لایه، لایه ورودی و لایه خروجی همانند یکدیگر بوده و لایه تنگنا از دو لایه دیگر تعداد نورون کمتری دارد. یک مدل خود-رمزگذار را می‌توان به‌عنوان ابزاری برای فشرده‌سازی و استخراج ویژگی‌های اصلی تصاویر به‌کار برد؛ به‌نحوی که این ویژگی‌ها به‌خوبی نماینده کل تصویر خواهند بود. به‌این‌ترتیب، اعداد در نورون‌های لایه تنگنا فشرده‌ترین و درعین‌حال کامل‌ترین اعداد معرف هر تصویر هستند. ورودی مدل خود-رمزگذار در مرحله آموزش، تصاویر تبدیل‌موجک برای هر پنجره ارزیابی در وضعیت سالم افزار است. در طی فرایند آموزش، مدل خود-رمزگذار آموزش می‌بیند که بتواند مشخصه‌های اصلی تصاویر تبدیل‌موجک در وضعیت سالم را به‌طور خودکار استخراج کند و تصاویر را با حداقل تعداد نورون در لایه تنگنا فشرده‌سازی کند. در مدل خود-رمزگذار پیشنهادی برای بهبود توانایی مدل در استخراج ویژگی‌های اصلی و کاهش حجم داده‌های پردازش، پیش از لایه‌های خود-رمزگذار کاملاً متصل، لایه‌های ضرب پیچشی^{۱۰} و ادغام^{۱۱} اضافه می‌شوند. استفاده از این لایه‌ها قبل از لایه‌های خود-رمزگذار، علاوه‌بر بهبود فرایند استخراج ویژگی، اندازه داده‌های ورودی به

لایه‌های خود-رمزگذار را نیز کاهش می‌دهد. در نتیجه به‌دلیل کاهش اندازه ورودی، تعداد نورون‌ها در لایه‌های خود-رمزگذار کاهش یافته و تعداد پارامترهای آموزش کمتر می‌گردد، که این کار خود می‌تواند در همگرایی و سرعت حل تأثیرگذار باشد. برای آموزش مدل خود-رمزگذار همگشتی به‌صورت نیمه‌نظارت شده، لازم است تا لایه‌های ضرب پیچشی و ادغام، قبل و پس از مدل خود-رمزگذار عمیق به‌طور قرینه به‌کار گرفته شوند. در ساختار شماتیک مدل ارائه شده است. پس از آموزش مدل خود-رمزگذار همگشتی با داده‌های وضعیت سالم، نوبت به ساخت شاخص سلامت در طی دوره وضعیت خرابی افزار است. برای ساخت شاخص سلامت، میزان فاصله دوری مقادیر نورون‌های لایه تنگنا برای هر بازه ارزیابی در وضعیت خرابی با میانگین مقادیر نورون‌های لایه تنگنا در وضعیت سالم محاسبه می‌شود. همان‌گونه که در شکل ۵ نشان داده شده است، با رشد خرابی‌ها فاصله مقادیر نورون‌ها نسبت به وضعیت سالم افزایش می‌یابد. برای اندازه‌گیری این فاصله از رابطه ماهلانویز^{۱۲} استفاده شده است. رابطه ماهلانویز یک معیار فاصله چند متغیره مؤثر است که می‌تواند فاصله بین یک بردار با توزیع برداری را اندازه‌گیری کند. این رابطه در تشخیص ناهنجاری‌های چند متغیره بسیار کارآمد است [۲۲].



شکل ۵. مدل خود رمزگذار همگشتی ارائه شده در این پروژه

اعضای آن همبستگی میان پارامترهای مختلف مجموعه را نشان می‌دهند. در نهایت فاصله ماهالانویز در طی هر بازه ارزیابی برای X^{n} each interval بر اساس رابطه ۱ محاسبه می‌شود:

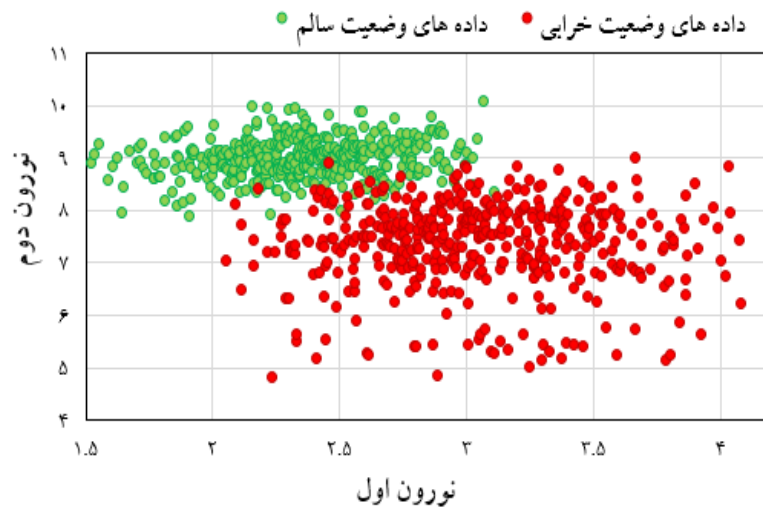
$$(MD)^2 = (X - \mu)^T C^{-1} (X - \mu) \quad (1)$$

که در رابطه فوق C^{-1} معکوس ماتریس کوواریانس و μ بردار میانگین برای مجموعه داده وضعیت سالم بوده و X بردار مقادیر لایه تنگنا برای بازه ارزیابی مورد نظر است.

برای محاسبه رابطه ماهالانویز، در ابتدا از داده‌های وضعیت سالم افزار مجموعه برداری $X^h = \{x_1^h, x_2^h, \dots, x_m^h\}$ از مقادیر برداری نورون‌های لایه تنگنا انتخاب می‌شود به نحوی که

$$x_i^h = \{v_1, v_2\} | v \text{ bottleneck nodes values}$$

و سپس برای مجموعه انتخابی X^h بردار میانگین (v_1^m, v_2^m) محاسبه می‌گردد. همچنین برای مجموعه برداری X^h ماتریس کوواریانس 13×13 نیز محاسبه می‌شود. ماتریس کوواریانس، ماتریسی مربعی دو-در-دو و متقارن خواهد بود که




شکل ۶. مقایسه مقادیر نورون اول و دوم برای تصاویر در وضعیت سالم و معیوب

نمی‌کند، ولی ارتعاشات در جهت عمود دارای روند خرابی است، بنابراین در ادامه تنها از داده‌های ارتعاشات عمودی استفاده خواهد شد. برای ایجاد ساخت شاخص سلامت باید تعداد نقاط داده در هر پنجره ارزیابی معین شوند. از آنجاکه در این آزمایش نرخ داده برداری 5120 Hz بوده و سرعت دورانی 2400 دور بر دقیقه است، بنابراین تعداد نقطه داده در هر پنجره ارزیابی برابر با 128 خواهد بود.

۴. نتایج تجربی

به منظور ارزیابی عملکرد روش پیشنهادی برای ساخت شاخص سلامت در این مطالعه، از داده‌های اجرا تا شکست مرجع [۲۰] استفاده شده است. مقدار دامنه ارتعاشات ثبت شده در جهت افقی و عمودی برای کل مدت زمان داده برداری در شکل ۷ نشان داده شده است. همان گونه که مشاهده می‌شود، ارتعاشات اندازه گیری شده در جهت افق هیچگونه روند خرابی را آشکار




شکل ۷. نمودار داده‌های ارتعاشی مجموعه چرخ‌دنده (الف) در جهت افقی و (ب) در جهت عمودی. داده‌های خام از مرجع [۲۰]

شد. نمونه‌ای از تصاویر در وضعیت سالم و حالت‌های مختلف خرابی به همراه تصاویر بازسازی شده آنها توسط مدل آموزش‌دیده، در شکل ۸ نشان داده شده است. همان‌گونه که مشاهده می‌شود مدل توانسته است به‌خوبی تصاویر را بازسازی نماید. همچنین علی‌رغم آنکه مدل صرفاً توسط داده‌های سالم آموزش‌دیده است، لیکن توانایی بازسازی تصاویر در وضعیت خراب را نیز به‌خوبی دارد که نشان از توانایی مدل در استخراج ویژگی‌های مناسب از تصاویر است.

پس از مشخص شدن اندازه پنجره ارزیابی، معیار پارتو به کار گرفته می‌شود تا زمان آغاز خرابی معین شود و وضعیت سیگنال‌های سالم از سیگنال‌های معیوب مشخص شود. برای هر پنجره ارزیابی تبدیل موجک انجام شده تا تصاویر در وضعیت سالم و وضعیت خرابی به دست آیند. برای سیگنال‌های ارتعاشی مورد نظر، تعداد تصاویر در وضعیت سالم برابر با ۲۳۴۰۵ و تعداد تصاویر در وضعیت خرابی برابر با ۱۰۵۶۵ خواهد بود. پایگاه داده ایجاد شده از تصاویر در وضعیت سالم، برای آموزش مدل خود-رمزگذار همگشتی به کار گرفته

درصد رشد خرابی



شکل ۸. مقایسه تصاویر ورودی با تصاویر خروجی شبکه خود-رمزگذار همگشتی در وضعیت سالم و خرابی‌های مختلف در

مجموعه چرخ‌دنده

۴-۱. نمودار شاخص سلامت

پس از آموزش مدل خود-رمزگذار همگشتی با پایگاه داده وضعیت سالم، نمودار اولیه شاخص سلامت در طول مدت زمان مرحله خرابی ایجاد شده است. به منظور حذف نوسانات محلی از این نمودار، از تابع هموارساز معرفی شده در رابطه ۲ استفاده می‌شود:

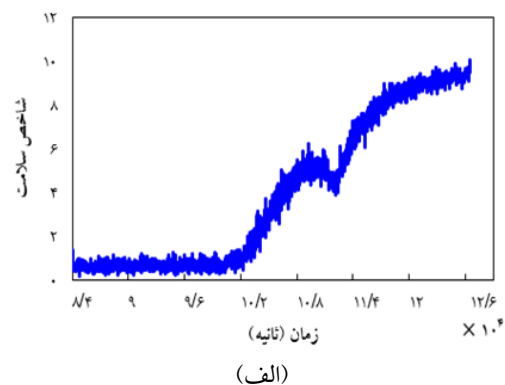

$$MHI_i = \exp(\sum_{j=1}^i HI_j / i) \quad 1 \leq i \leq N \quad (2)$$

که در رابطه فوق MHI_i بیانگر مقدار شاخص سلامت هموار شده در بازه ارزیابی i ام است، HI_j مقدار شاخص سلامت محاسبه شده از لحظه اول تا لحظه i ام است و N تعداد پنجره ارزیابی تا پیش از لحظه i ام است.

در معادله هموارسازی نمودار شاخص سلامت برای محاسبه MHI_i ، از مقادیر میانگین اندازه‌گیری شده از لحظه اول تا لحظه i ام استفاده شده است، که در نتیجه در صورتی که نمودار

اولیه شاخص سلامت دارای نوسانات شدید باشد، حذف و یا تقلیل خواهند یافت. علاوه بر این، تابع‌نمایی به‌طور ذاتی یک تابع افزایشی یکنواخت است که در نتیجه می‌تواند روند افزایشی در منحنی شاخص سلامت را بهبود سازد.

نمودار شاخص سلامت اولیه به همراه نمودار شاخص هموار شده آن در شکل ۹ نشان داده شده است. مشاهده می‌شود که نمودار شاخص سلامت دارای یک روند افزایشی و نسبتاً یکنواخت بوده و توانسته میزان پیشرفت خرابی در مجموعه چرخ‌دنده را به‌خوبی نشان دهد. همچنین با مقایسه این نمودار با نمودار مقادیر ارتعاشات اندازه‌گیری شده در طول مرحله خرابی چرخ‌دنده‌ها، به‌خوبی مشخص می‌شود که روش پیشنهادی توانایی تشخیص مراحل اولیه شروع عیب در چرخ‌دنده‌ها را دارد و می‌تواند روند رو به افزایش خرابی‌ها را به‌خوبی توصیف نماید و در نتیجه امکان استفاده از آن در تخمین عمر مفید باقیمانده وجود دارد.



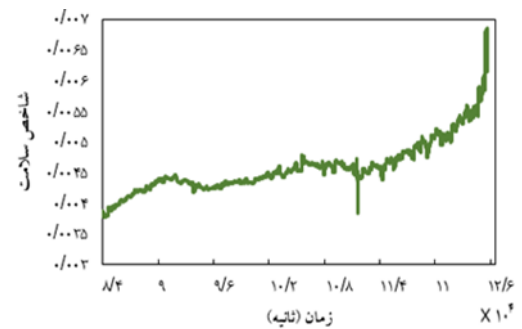
شکل ۹. نمودار شاخص سلامت با استفاده از روش پیشنهادی در این پروژه برای مجموعه چرخ‌دنده

(الف) نمودار شاخص سلامت اولیه و (ب) نمودار شاخص سلامت هموار شده با استفاده از تابع هموارساز نمایی

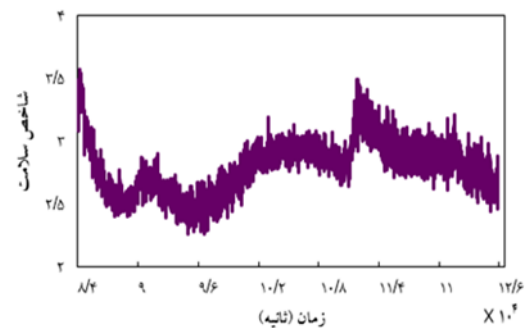
شاخص سلامت برای چرخ‌دنده‌ها در صنایع هستند. نمودار شاخص سلامت با استفاده از این روش‌ها برای داده‌های ارتعاشی مجموعه چرخ‌دنده در شکل ۱۰ نشان داده شده‌اند. نمودار شاخص سلامت با استفاده از جذر میانگین مربعات در شکل ۱۰-الف نشان داده شده است. همان‌گونه که مشاهده می‌شود، پارامتر جذر میانگین مربعات می‌تواند نشانه‌های اولیه

نمودارهای شاخص سلامت ساخته شده برای مجموعه چرخ‌دنده با استفاده از مدل پیشنهادی در این پروژه با دو روش مرسوم در ساخت شاخص سلامت چرخ‌دنده‌ها مقایسه شده است. برای این کار دو روش ساخت شاخص سلامت با استفاده از پارامترهای آماری جذر میانگین مربعات^{۱۴} و کشیدگی^{۱۵} انتخاب شده‌اند. این روش‌ها از پرکاربردترین روش‌های ساخت

بروز عیوب را به خوبی شناسایی کند. علی‌رغم آن، مشاهده می‌شود که این نمودار همگام با رشد عیوب و خرابی‌ها رشد نکرده و نمی‌تواند گسترش خرابی‌ها را به خوبی توصیف نماید که این کار برای مرحله میانی نمودار به وضوح قابل مشاهده است. شاخص سلامت ساخته شده با استفاده از پارامتر کشیدگی در شکل ۱۰-ب نشان داده شده است. مشاهده می‌شود که این نمودار دارای نوسانات شدید بوده و هیچ روند رو به افزایش و یا کاهش را دنبال نمی‌کند، زیرا که اساساً پارامتر کشیدگی در تشخیص عیوب ناشی از سایش دندانها موفق عمل می‌کند و نه شکست دندانها [۲۳].



(الف)



(ب)

شکل ۱۰. نمودارهای شاخص سلامت با استفاده از روش‌های رایج مبتنی بر پردازش علامت برای مجموعه چرخ‌دنده. (الف) جذر میانگین مربعات، (ب) کشیدگی

برای کمی‌سازی ویژگی‌های شاخص سلامت، سه معیار اندازه‌گیری یکنواختی (Mon)، استحکام (Rob) و همبستگی (Corr) معرفی شده‌اند [۵]. در معیار یکنواختی، اختلاف بین

مقادیر دو نقطه مجاور منحنی اندازه‌گیری می‌شود. آنگاه، برای منحنی‌ای که دارای روند یکنواخت افزایشی (و یا کاهش) باشد، تعداد کل مقادیر با تفاضل مثبت بیش از تعداد کل مقادیر با تفاضل منفی است و معیار یکنواختی نزدیک به یک خواهد بود. از طرف دیگر، برای یک منحنی آشفته بدون روند افزایشی (و یا کاهش)، تعداد کل مقادیر با تفاضل مثبت به تعداد کل مقادیر با تفاضل منفی نزدیک خواهد بود، که در نتیجه معیار یکنواختی نزدیک به صفر است. معیار یکنواختی براساس رابطه ۳ محاسبه می‌شود [۵]:

$$\text{Mon} = \left| \frac{\text{No. of } df > 0}{N - 1} - \frac{\text{No. of } df < 0}{N - 1} \right| df \quad (3)$$

$$= \frac{HI_{i+1} - HI_i}{i}$$

$$1 \leq i \leq N$$

که در رابطه فوق، df تفاضل هر دو نقطه مجاور در نمودار شاخص سلامت است و N تعداد کل نقاط در نمودار شاخص سلامت (HI) است.

معیار استحکام، توانایی مقاومت شاخص سلامت در برابر نوسانات تصادفی را منعکس می‌کند، که می‌تواند ناشی از نوفه‌های محیط، حسگر معیوب، تغییرات جزئی در شرایط کاری و یا هرگونه حوادث غیرمنتظره باشد. معیار استحکام براساس رابطه ۴ تعریف می‌گردد [۵]:

$$\text{Rob} = \frac{1}{N} \sum_{i=1}^N \exp\left(-\left|\frac{HI_i - \overline{HI}}{HI_i}\right|\right) \quad (4)$$

$$1 \leq i \leq N$$

که در رابطه فوق N تعداد کل نقاط در نمودار شاخص سلامت و \overline{HI} مقدار میانگین کلیه مقادیر شاخص سلامت و HI_i شاخص سلامت نام در نمودار شاخص سلامت است. معیار همبستگی، میزان همبستگی بین شاخص سلامت و زمان را اندازه‌گیری می‌کند.

انتظار می‌رود که یک شاخص سلامت مناسب، به تدریج با گذشت زمان روند افزایشی (و یا کاهش) داشته باشد. در یک

۵. جمع بندی

در این مقاله یک روش مبتنی بر هوش مصنوعی برای پایش وضعیت چرخ‌دنده‌ها معرفی شده است. برای این منظور یک مدل خود رمزگذار همگشتی ایجاد شده است که برای آموزش تنها از داده‌های وضعیت سالم افزار بهره می‌برد. روش معرفی شده محدودیت اکثر روش‌های پایش وضعیت مبتنی بر هوش مصنوعی را ندارد؛ زیرا نیازمند داده‌های شکست تاریخی از افزار نیست. پیاده‌سازی روش معرفی شده شامل سه گام است. در گام اول داده‌های ارتعاشی افزار در طی مرحله کارکرد سالم افزار پیش‌از آن که خرابی‌ها ایجاد شوند به صورت برخط جمع‌آوری شده و با استفاده از تبدیل موجک پیوسته به تصاویر دو بعدی تبدیل می‌گردند. در گام دوم، با استفاده از تصاویر تبدیل موجک در وضعیت سالم، مدل خود رمزگذار همگشتی آموزش می‌بیند. مدل مذکور باید توانایی استخراج ویژگی‌های اصلی تصاویر تبدیل موجک را داشته باشد. نهایتاً در گام سوم پس از ایجاد و رشد خرابی‌های افزار، داده‌های ارتعاشی برخط توسط تبدیل موجک به تصاویر دو بعدی تبدیل شده و مدل خود رمزگذار همگشتی تفاوت تصاویر تبدیل موجک در وضعیت سالم و خراب تجهیز را ارزیابی می‌نماید. صحت عملکرد مدل پیشنهاد شده توسط داده‌های اجرا تا خرابی چرخ‌دنده در این پژوهش ارزیابی شده و نتایج ارائه شده مؤید عملکرد مناسب این روش برای ساخت شاخص سلامت چرخ‌دنده است.

همبستگی مثبت قوی، مقدار معیار همبستگی نزدیک به یک خواهد بود. معیار همبستگی براساس رابطه ۵ تعریف می‌گردد [۲۴]:

$$\text{Corr} = \frac{\left| \sum_{i=1}^N (HI_i - \bar{HI}) \left(i - \left(\frac{\sum_{i=1}^N i}{N} \right) \right) \right|}{\sqrt{\sum_{i=1}^N (HI_i - \bar{HI})^2 \sum_{i=1}^N \left(i - \left(\frac{\sum_{i=1}^N i}{N} \right) \right)^2}} \quad (5)$$

$$1 \leq i \leq N$$

که در رابطه فوق نیز N تعداد کل نقاط در نمودار شاخص سلامت، \bar{HI} مقدار میانگین کلیه مقادیر شاخص سلامت و HI_i شاخص سلامت i ام در نمودار شاخص سلامت است. مقادیر سه معیار یکنواختی، استحکام و همبستگی برای سه روش جذر میانگین مربعات، کشیدگی و روش پیشنهادی برای چرخ‌دنده مورد مطالعه در این مقاله در جدول ۱ ارائه شده است. مشاهده می‌شود که براساس معیارهای یکنواختی، استحکام و همبستگی نیز، روش پیشنهادی کارایی بهتری دارد و در نتیجه برای ساخت شاخص سلامت و پیش‌بینی عمر مفید باقیمانده یک مجموعه چرخ‌دنده مناسب است.

جدول ۱. مقایسه سه پارامتر یکنواختی، استحکام و همبستگی برای روش پیشنهادی، کشیدگی و جذر میانگین مربعات

معیار	روش پیشنهادی	جذر میانگین مربعات	کشیدگی
یکنواختی	۰/۵۹۹۳۹	۰/۰۲۲۶۲	۰/۰۰۱۲۳
استحکام	۰/۹۳۸۸۴	۰/۹۳۸۷۸	۰/۹۳۶۸۸
همبستگی	۰/۹۱۷۴۰	۰/۸۰۹۹۲	۰/۴۱۹۹۵

۶. مآخذ

- [1] Wang, Dong, Kwok-Leung Tsui, and Qiang Miao, "Prognostics and health management: A review of vibration-based bearing and gear health indicators", *Ieee Access*, 2017, Vol.6, pp.665-676.
- [2] Mobley, R. Keith, "An introduction to predictive maintenance", Elsevier, 2002.
- [3] Gandhare, Balasaheb S., and Milind Akarte, "Maintenance strategy selection", In *Ninth AIMS International Conference on Management*, Maharashtra, India: AIMS International, 2012, pp. 1330-1336.

- [4] B. A. Gandhare, Milind, "Maintenance Strategy Selection," in *The 9th AIMS International Conference on Management*, 2012.
- [5] Duong, Bach Phi, Sheraz Ali Khan, Dongkoo Shon, Kichang Im, Jeongho Park, Dong-Sun Lim, Byungtae Jang, and Jong-Myon Kim, "A reliable health indicator for fault prognosis of bearings", *Sensors*, 2018, Vol.18, no.11, p.3740.
- [6] Liu, Zepeng, and Long Zhang, "A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings", *Measurement*, 2020, Vol.149, p.107002.
- [7] Lee, Won Gi, Jin Woo Lee, Min Sung Hong, Sung-Ho Nam, YongHo Jeon, and Moon G. Lee, "Failure diagnosis system for a ball-screw by using vibration signals", *Shock and Vibration*, 2015.
- [8] Yen, Gary G., and K-C. Lin, "Wavelet packet feature extraction for vibration monitoring", *IEEE transactions on industrial electronics*, 2000, Vol.47, no.3, pp.650-667.
- [9] Kar, Chinmaya, and A. R. Mohanty, "Vibration and current transient monitoring for gearbox fault detection using multiresolution Fourier transform", *Journal of Sound and Vibration*, 2008, Vol.311, no.1-2, pp.109-132.
- [10] Al-Badour, Fadi, Mehmet Sunar, and Lahouari Cheded, "Vibration analysis of rotating machinery using time–frequency analysis and wavelet techniques", *Mechanical Systems and Signal Processing*, 2011, Vol.25, no.6, pp.2083-2101.
- [11] Elbouchikhi, Elhoussin, Vincent Choqueuse, Yassine Amirat, Mohamed El Hachemi Benbouzid, and Sylvie Turri, "An efficient Hilbert–Huang transform-based bearing faults detection in induction machines", *IEEE Transactions on Energy Conversion*, 2017, Vol.32, no.2, pp.401-413.
- [12] Torrence, Christopher, and Gilbert P. Compo, "A practical guide to wavelet analysis", *Bulletin of the American Meteorological society*, 1998, Vol.79, no.1, pp.61-78.
- [13] Yoo, Youngji, and Jun-Geol Baek, "A novel image feature for the remaining useful lifetime prediction of bearings based on continuous wavelet transform and convolutional neural network", *Applied Sciences*, 2018, Vol.8, no.7, p.1102.
- [14] Abed, Wathiq, Sanjay Sharma, Robert Sutton, and Amit Motwani, "A robust bearing fault detection and diagnosis technique for brushless DC motors under non-stationary operating conditions", *Journal of Control, Automation and Electrical Systems*, 2015, Vol.26, pp.241-254.
- [15] He, Jun, Ming Ouyang, Chen Yong, Danfeng Chen, Jing Guo, and Yan Zhou, "A novel intelligent fault diagnosis method for rolling bearing based on integrated weight strategy features learning", *Sensors*, 2020, Vol.20, no.6, p.1774.
- [16] Yin, Hang, Zhongzhi Li, Jiankai Zuo, Hedan Liu, Kang Yang, and Fei Li, "Wasserstein generative adversarial network and convolutional neural network (WG-CNN) for bearing fault diagnosis", *Mathematical Problems in Engineering*, 2020, pp.1-16.
- [17] Booyse, Wihan, Daniel N. Wilke, and Stephan Heyns, "Deep digital twins for detection, diagnostics and prognostics", *Mechanical Systems and Signal Processing*, 2020, Vo.140, p.106612.

- [18] Carroll, James, Sofia Koukoura, Alasdair McDonald, Anastasis Charalambous, Stephan Weiss, and Stephen McArthur, "Wind turbine gearbox failure and remaining useful life prediction using machine learning techniques", *Wind Energy*, 2019, Vol.22, no.3, pp.360-375.
- [19] Fan, Xianfeng, and Ming J. Zuo, "Gearbox fault detection using Hilbert and wavelet packet transform", *Mechanical systems and Signal processing*, 2006, Vol.20, no.4, pp.966-982.
- [20] Fan, X. F., H. Lin, and M. J. Zuo, "Gearbox Lifetime Assessment Experiment: Part I, Experiment Design & Operation Guide", Technical Report. Department of Mechanical Engineering, University of Alberta, Edmonton, Alberta, 2004.
- [21] Hua, Cheng, Qing Zhang, Guanghua Xu, Yizhuo Zhang, and Tao Xu, "Performance reliability estimation method based on adaptive failure threshold", *Mechanical Systems and Signal Processing*, 2013, Vol.36, no.2, pp.505-519.
- [22] Ahn, Jeongyoun, Myung Hee Lee, and Jung Ae Lee, "Distance-based outlier detection for high dimension, low sample size data", *Journal of Applied Statistics*, 2019, Vol.46, no.1. pp.13-29.
- [23] Sait, Abdulrahman S., and Yahya I. Sharaf-Eldeen, "A review of gearbox condition monitoring based on vibration analysis techniques diagnostics and prognostics", In *Rotating Machinery, Structural Health Monitoring, Shock and Vibration, Volume 5: Proceedings of the 29th IMAC, A Conference on Structural Dynamics, 2011*, Springer New York, 2011, pp. 307-324.
- [24] Xu, Fan, Zhelin Huang, Fangfang Yang, Dong Wang, and Kwok Leung Tsui, "Constructing a health indicator for roller bearings by using a stacked auto-encoder with an exponential function to eliminate concussion", *Applied Soft Computing*, 2020, Vol.89 pp.106119.

پی نوشت:

1. Convolutional Autoencoder
2. Wavelet Transform
3. Hilbert Huang Transform
4. Convolutional Neural Networks
5. Recurrent Neural Networks
6. Autoencoder Neural Networks
7. Generative Adversarial Networks
8. Run to Failure
9. Pareto Law
10. Convolutional Layer
11. Pooling Layer
12. Mahalanobis Distance
13. Covariance Matrix
14. Root Square Mean
15. Kurtosis