



## پایش وضعیت یاتاقان‌های غلتشی به روش ارتعاشی با بهره‌گیری از مدل یادگیری ماشین

محمد رضا کاجی<sup>۱</sup>، جمشید پرویزیان<sup>\*</sup>، محمد سیلانی<sup>۱</sup>، هانس ورنر ون دِوین<sup>۲</sup>

۱- دانشکده مهندسی مکانیک، دانشگاه صنعتی اصفهان، اصفهان، ایران.

۲- پژوهشکده سیستم‌های مکترونیک، دانشگاه علمی کاربردی زوربخ، زوربخ، سوئیس.

### تاریخچه داوری:

دریافت: ۱۴۰۰/۰۲/۱۸

بازنگری: ۱۴۰۰/۰۶/۰۴

پذیرش: ۱۴۰۰/۰۶/۰۵

ارائه آنلاین: ۱۴۰۰/۰۶/۱۰

### کلمات کلیدی:

پایش وضعیت

هوش مصنوعی

یادگیری عمیق

آنالیز ارتعاشات

همزاد دیجیتال

**خلاصه:** در سال‌های اخیر با ظهور انقلاب صنعتی چهارم و توسعه فناوری‌های هوش مصنوعی، رویکردهای نوینی در زمینه نگهداری و تعمیرات افزارگان معرفی شده‌اند؛ که از آن جمله می‌توان به همزاد دیجیتال اشاره نمود. اولین گام برای ایجاد همزاد دیجیتال یک افزار، ساخت شاخص‌های کمی و کیفی است که برای توصیف لحظه‌ای افزار در طی مدت بهره‌برداری به کار می‌رود. در این پژوهش یک روش نوین برای ساخت شاخص سلامت افزارگان براساس اندازه‌گیری ارتعاشات و مدل‌های یادگیری عمیق معرفی شده است. برای این منظور داده‌های ارتعاشی خام تجهیز از استفاده از تبدیل موجک پیوسته به تصاویر دوبعدی تبدیل خواهند شد. سپس با استفاده از یک مدل یادگیری عمیق، میزان تفاوت تصاویر وضعیت سالم و معیوب افزار تشخیص داده شده و شاخص سلامت ایجاد می‌شود. مدل ارائه شده می‌تواند به صورت خودکار شاخص سلامت را ایجاد نماید و نیازمند دانش متخصص خبره برای تفسیر نتایج آنالیز ارتعاشی نیست. همچنین، آموزش مدل یادگیری عمیق به صورت بدون نظارت بوده و تنها با استفاده از داده‌های ارتعاشی وضعیت سالم تجهیز صورت می‌پذیرد و بنابراین نیازمند داده‌های خرابی پیشین نیست. عملکرد مدل پیشنهاد شده توسط داده‌های ارتعاشی یاتاقان مورد ارزیابی قرار گرفته که نشان از توانایی قابل قبول شاخص سلامت در تشخیص آغاز خرابی و چگونگی روند رشد آن دارد.

### ۱- مقدمه

اکثر افزارگان مکانیکی همچون هواپیماها، کشتی‌ها، توربین‌ها و موتورها معمولاً در شرایط محیطی سخت و به مدت طولانی مدت فعالیت می‌کنند. از این رو و اماندگی و خرابی این افزارگان اجتناب‌ناپذیر است. وجود و اماندگی برای یک افزار منجر به خاموشی، افزایش هزینه تعمیرات، تأخیر در انجام وظایف، ایجاد هزینه‌های جانی و مالی برای افزارگان و یا واحد تولیدی می‌گردد [۱]. به منظور پیش‌گیری و یا رفع خرابی یک افزار، عملیات نگهداری و تعمیر صورت می‌گیرد. عملیات نگهداری و تعمیر، به مجموعه‌ای از فعالیت‌های فنی و اقدامات اصلاحی مرتبط گفته می‌شود که به منظور نگهداری و یا بازیابی سیستم‌ها در وضعیت کاری سالم صورت می‌پذیرد [۲]. به طور کلی رویکردهای موجود برای نگهداری و تعمیر در دو دسته تعمیرات اصلاحی و تعمیرات پیشگیرانه می‌توان دسته‌بندی نمود. در رویکرد تعمیرات اصلاحی پس از آنکه شکست و خرابی افزار صورت پذیرفت، اقدامات اصلاحی انجام می‌گیرند؛ در حالی که در رویکرد پیشگیرانه به منظور جلوگیری

از شکست، اقدامات اصلاحی به صورت پیش‌دستانه صورت می‌پذیرند [۳]. براساس دور رویکرد معرفی شده، سه دسته روش اصلی نگهداری و تعمیر پس از خرابی، نگهداری و تعمیر پیشگیرانه و نگهداری و تعمیر پیش‌گويانه را می‌توان تعیین نمود [۴]. در این میان روش‌های مبتنی بر نگهداری و تعمیر پیش‌گويانه، بخصوص برای افزارگان سنگین، نسبت به دودسته روش دیگر جامع‌تر و کارآمدتر است [۵]. در روش‌های نگهداری و تعمیر پیش‌گويانه، وضعیت هر لحظه افزار با توجه به آنالیز داده‌های جمع‌آوری شده رصد می‌شود؛ تا بتوان زمان خرابی افزار را پیش‌بینی نمود [۶]. اولین و مهم‌ترین گام برای پیاده‌سازی این روش‌ها، ساخت شاخص‌های سلامت است. 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 به خوبی توصیف کند [۲]. به طور کلی ساخت شاخص سلامت دربرگیرنده سه مرحله است که عبارت‌اند از: (۱) جمع‌آوری سیگنال مناسب، (۲) پردازش سیگنال و (۳) استخراج ویژگی‌های معنی‌دار از سیگنال به عنوان شاخص سلامت [۷].

\* نویسنده عهده‌دار مکاتبات: japa@iut.ac.ir

فرکانسی درگذر زمان را آشکار سازند، و بنابراین اطلاعات سودمندی را از هر دو حوزه زمان و فرکانس ارائه می‌کنند. از میان روش‌های آنالیز حوزه زمان-فرکانس، روش تبدیل موجک پیوسته<sup>۱</sup> برای این مطالعه انتخاب گردیده شده است. تبدیل موجک روشی جدید و نیرومند برای تحلیل سیگنال‌ها است که می‌تواند تغییرات محلی جزئی در سیگنال را به‌خوبی آشکار سازند [۱۱]. پس از داده‌برداری و پردازش آن‌ها، ویژگی‌های مناسب که معرف وضعیت افزار باشند، باید استخراج شوند. این ویژگی‌ها باید رابطه مستقیم با خرابی افزار داشته و بتوانند ایجاد و رشد خرابی‌ها را توصیف نمایند. روش‌های موجود در ساخت شاخص سلامت از نگاه شیوه استخراج ویژگی از داده‌ها را می‌توان در دو دسته رویکرد مبتنی بر تحلیلی فیزیکی و داده محور طبقه‌بندی نمود [۱۲]. در سال‌های اخیر، رویکردهای داده محور به‌طور گسترده و موفقیت‌آمیز در زمینه‌های پایش وضعیت و مدیریت پیش‌گویی و صحت استفاده‌شده‌اند [۱۳ و ۱۴]. در این روش‌ها، تلاش می‌شود تا با استفاده از حجم زیادی از داده‌های عملکردی روند و ویژگی معنادار به‌صورت خودکار از داده‌های پردازش‌شده، استخراج شوند.

تاکنون مدل‌های یادگیری عمیق همچون شبکه‌های عصبی همگشتی<sup>۲</sup> [۱۵]، شبکه عصبی بازگشتی<sup>۳</sup> [۱۶]، شبکه عصبی خود-رمزگذار<sup>۴</sup> [۱۷] و شبکه عصبی مولد تخصصی<sup>۵</sup> [۱۸] به‌طور موفقیت‌آمیز برای استخراج ویژگی از سیگنال‌های ارتعاشی بکار گرفته‌شده‌اند. مدل‌های توسعه‌یافته یادگیری عمیق، بیشتر بر مبنای یادگیری نظارت‌شده و برای مسائل طبقه‌بندی استفاده‌شده‌اند. برای این‌گونه مسائل، به دست آوردن داده‌های عملکردی برای مراحل مختلف خرابی افزار ضروری است تا با استفاده از آن‌ها بتوان پایگاه‌های داده سالم و ناسالم برچسب‌دار برای حالت مختلف عملکردی را ایجاد نمود [۱۹]. این پایگاه‌های داده برچسب‌دار برای آموزش مدل‌های یادگیری عمیق بکار گرفته می‌شوند و چنانچه متنوع‌تر و گسترده‌تر باشند، نتایج دقیق‌تری را به همراه خواهند داشت. ایجاد این پایگاه‌های داده نیازمند تعداد زیادی از نمونه‌های شکست و خرابی است که برای بسیاری از افزارگان، بخصوص افزارگان با قابلیت اطمینان بالا و یا حساس، هزینه‌بر و یا غیرممکن است. بنابراین محدودیت اصلی برای ساخت شاخص سلامت در اکثر مطالعات، عدم دسترسی بودن داده‌های خرابی گسترده برای آموزش مدل‌های یادگیری عمیق است [۲۰].

برای قطعات مکانیکی انواع مختلف داده‌ها قابل جمع‌آوری است که از آن جمله می‌توان به داده‌های ارتعاشی، صوتی، ترموگرافی و آنالیز روغن و ذرات سایشی اشاره نمود. برای بیشتر قطعات مکانیکی، بخصوص قطعات دوار، سیگنال‌های ارتعاشی حاوی اطلاعات بسیار مفیدی برای پایش وضعیت می‌باشند. این سیگنال‌ها می‌توانند به‌خوبی عیوب دینامیکی تجهیز مانند نابالانسی، غیر هم‌راستایی، شل شدن و لقی مکانیکی، سایش، آسیب و خمیدگی شفت را نشان دهند. برای قطعات دوار توسعه هر نوع عیب خاص منجر به تغییر رفتار دینامیکی سیستم می‌شود، که در الگوی ارتعاشی تجهیز اثرگذار خواهد بود [۱]. 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 در سه حوزه زمان، فرکانس و زمان-فرکانس دسته‌بندی می‌شوند [۸]. استفاده از روش‌های استخراج ویژگی در حوزه زمان نیازمند ثبت داده‌های ارتعاشی در طول مدت‌زمان طولانی به‌منظور استنباط الگوهای ایجاد و رشد خرابی است. برای بسیاری از قطعات و خرابی‌های پیچیده، به دلیل حجم بالای داده موردنیاز و یا در دسترس نبودن داده‌ها، استفاده از این نوع آنالیز غیرممکن است [۹]. آنالیزهای سیگنال در حوزه فرکانس به‌طور گسترده توسط محققان برای استخراج ویژگی و ساخت شاخص سلامت مورد استفاده قرار گرفته است [۸]. از منظر آنالیز ارتعاشات، عیوب قطعات مکانیکی را می‌توان به دودسته کلی طبقه‌بندی نمود: عیوب دوره‌ای و عیوب گذرا. سیگنال‌های ارتعاشی برای عیوب دوره‌ای ماهیت سینوسی داشته و دارای الگو تکرار شونده یکسان در طول زمان هستند. برای این سیگنال‌ها استفاده از روش‌های آنالیز در حوزه فرکانس همچون تبدیل فوریه را می‌توان به‌خوبی استفاده نمود، زیرا که در تبدیل فوریه از تابع تحلیل سینوسی به‌عنوان تابع پایه استفاده می‌شود [۱۰]. برخلاف عیوب دوره‌ای، از روش‌های آنالیز حوزه فرکانس برای تحلیل سیگنال‌های عیوب گذرا نمی‌توان استفاده کرد. برای عیوب گذرا، سیگنال‌های ارتعاشی در طی زمان تغییر کرده و ماهیت تکرار شونده ندارند. علی‌رغم این، این سیگنال‌ها معمولاً حاوی اطلاعاتی ارزشمند از چگونگی ایجاد و رشد خرابی‌ها می‌باشند که با استفاده از آنالیزهای حوزه زمان و یا فرکانس نمی‌توان به آن دست یافت [۹].

از آنجاکه سیگنال‌های ارتعاشی در هنگام ایجاد و رشد خرابی‌ها ناپایدار و گذرا هستند، از روش‌های آنالیز حوزه زمان-فرکانس در این مطالعه بهره برده شده است. تکنیک‌های آنالیز حوزه زمان-فرکانس می‌توانند تغییرات

- 1 Continuous wavelet transform
- 2 Convolutional neural networks
- 3 Recurrent neural networks
- 4 Autoencoder neural networks
- 5 Generative adversarial networks

ابری داده ارتعاشی در وضعیت سالم افزار در یک پایگاه داده جمع‌آوری و پردازش شده و سپس مدل یادگیری عمیق توسط این پایگاه آموزش داده می‌شود. نهایتاً در طول مرحله ایجاد و رشد خرابی‌ها در یاتاقان، شاخص سلامت با استفاده از مدل آموزش‌دیده و داده‌های ارتعاشی بر خط، محاسبه می‌شود.

## ۲- داده‌های تجربی

برای ارزیابی عملکرد شاخص سلامت پیشنهادشده در این مطالعه، از نتایج آزمون‌های تجربی ارائه‌شده در مرجع [۲۵] استفاده شده است. افزارگان آزمون مورد استفاده توسط این پایگاه داده در شکل ۱ نشان داده شده است. افزارگان آزمون شامل یک موتور جریان متناوب است که توسط یک تسمه به شفت متصل شده است. شفت مذکور توسط چهار یاتاقان شیار عمیق دو ردیف مهارشده است و هر یاتاقان بار شعاعی ۶۰۰۰ پوندی را تحمل می‌کند. سرعت دورانی شفت ثابت و برابر با ۲۰۰۰ دور بر دقیقه انتخاب شده است. بر روی پایه هر یاتاقان یک سنسور شتاب سنج با نرخ داده‌برداری kHz ۲۰ نصب شده و هر ده دقیقه یک‌بار به مدت یک دقیقه ارتعاشات یاتاقان‌ها اندازه‌گیری شده است. تعداد نقطه داده در طی هر بار اندازه‌گیری برابر با ۲۰۴۸۰ است. فرآیند اجرای آزمون و داده‌برداری تا ظهور نشانه‌های خرابی در ساچمه‌ها و یا کُس‌های یاتاقان‌ها ادامه داشته است، که نتیجه آن به دست آوردن توأمان داده‌های ارتعاشی در وضعیت سالم و معیوب در طی طول عمر یاتاقان‌ها است [۲۵].



## ۳- روش پیشنهادی برای ساخت شاخص سلامت

برای ساخت خودکار شاخص سلامت در این مطالعه، از مدل‌های یادگیری عمیق استفاده شده است. به‌طور کلی فرآیند ساخت شاخص سلامت در روش پیشنهادی دارای سه‌گام اصلی است. در گام اول داده‌های ارتعاشی افزار در طی مدت‌زمان عملکرد آن به‌صورت برخط جمع‌آوری و پردازش می‌شوند. برای این امر، داده‌های جمع‌آوری‌شده در طی پنجره‌های زمانی ثابت در طی طول مدت عمر تجهیز به‌طور خودکار جمع‌آوری می‌شود. داده‌های ارتعاشی افزار به دودسته داده‌های وضعیت سالم افزار و داده‌های وضعیت خرابی افزار دسته‌بندی می‌شوند و برای هر دو دسته داده ارتعاشی، تبدیل موجک پیوسته محاسبه‌شده و سیگنال‌های ارتعاشی یک‌بعدی به تصاویر دوبعدی تبدیل خواهد شد.

برای پاسخ به محدودیت ذکرشده، توسعه مدل‌های یادگیری عمیق مبتنی بر یادگیری بی نظارت که تنها از داده‌های شرایط کاری سالم برای ساخت شاخص سلامت استفاده کنند، ضروری است [۲۱]. هدف از این مطالعه ارائه یک روش نوین برای ساخت شاخص سلامت برای یاتاقان‌های غلتشی با استفاده از مدل‌های یادگیری عمیق است. از یاتاقان‌های غلتشی برای تحمل بارهای شعاعی و محوری و کاهش اصطکاک در بسیاری از افزارگان دورانی استفاده می‌شوند. واماندگی در یاتاقان‌ها عامل بیش ۵۰٪ از خرابی‌ها در افزارگان دوار است و بنابراین توسعه روش‌های پایش وضعیت برای آن‌ها همواره مورد توجه محققان بوده است [۲۲]. واماندگی در یاتاقان‌ها در ابتدا با افزایش سطح ارتعاشات، سروصدا و کاهش راندمان افزار همراه است و نهایتاً می‌تواند منجر به شکست ناگهانی و یا خرابی‌های فاجعه‌بار شود. مدهای غالب در واماندگی یاتاقان‌ها عبارت‌اند از: خستگی، سایش، خوردگی و تغییر شکل‌های پلاستیک؛ که ناشی از عواملی همچون انتخاب نامناسب یاتاقان، محیط کاری نامناسب، ناهمراستایی، مونتاژ اشتباه، روانکاری ضعیف، اعمال بار اضافه، و خطاهای ساخت است. بنابراین می‌توان نتیجه گرفت که در اکثر مواقع رشد و توسعه خرابی‌ها در یاتاقان‌ها به‌صورت تدریجی و قابل پیش‌بینی صورت می‌پذیرند [۲۳].

به‌طور سنتی روش‌های نگه‌داری و تعمیر یاتاقان‌ها بخصوص در افزارگان حساس مانند توربین‌ها، بر اساس رویکرد نگه‌داری و تعمیر پیشگیرانه است؛ که به دلیل عدم استفاده از ظرفیت کامل افزار، منجر به اتلاف هزینه‌های گسترده می‌شود. برای کاهش این هزینه‌ها، روش‌های پایش وضعیت متنوعی بر اساس اندازه‌گیری صدا، پایش جریان مصرفی، سنجش مقدار ذرات ساینده در روانکار، آنالیز ارتعاشات و ترموگرافی برای یاتاقان‌ها توسعه داده شده است [۲۳]. از آن‌جا که تغییر در سطح ارتعاشی یاتاقان از اولین نشانه‌های ایجاد و رشد خرابی است، روش آنالیز ارتعاشات به‌طور گسترده برای یاتاقان‌ها در صنایع استفاده می‌شود [۲۳]. صرف‌نظر از نوع عیب موجود در یاتاقان، سیگنال‌های ارتعاشی خرابی از اثر متقابل میان سطح آسیب و سطوح متحرک ایجاد خواهند شد و در نتیجه آنالیز ارتعاشات قادر به شناسایی عیوب خواهد بود [۲۴].

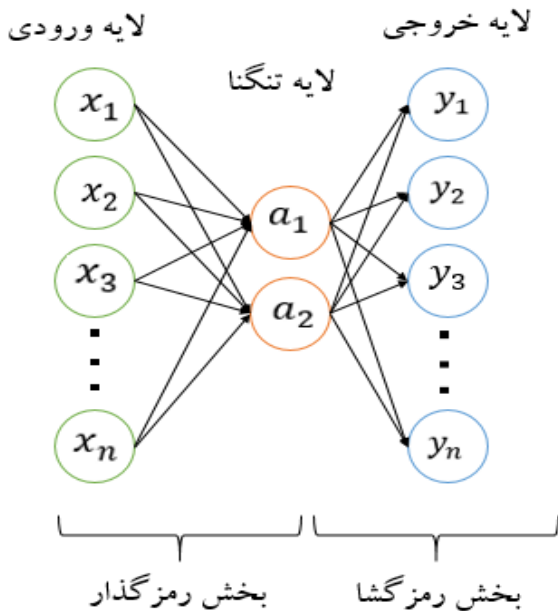
مدل یادگیری عمیق پیشنهادی در این پروژه صرفاً با داده‌ها در وضعیت سالم افزار آموزش‌دیده می‌شود و برای حالت‌های پایدار و گذرا قابل استفاده است. برای استفاده از این مدل، سیگنال‌های ارتعاشی یاتاقان به‌صورت بر خط در طول عمر افزار با استفاده از فناوری‌های اینترنت اشیا به سرور ابری انتقال یافته و پردازش می‌شوند. در سرور



شکل ۱. ابزارگان مورد استفاده در طی آزمایش‌های پایگاه داده مرجع [۲۵].

Fig. 1. Test bench used in the reference experiment data of this research [25].

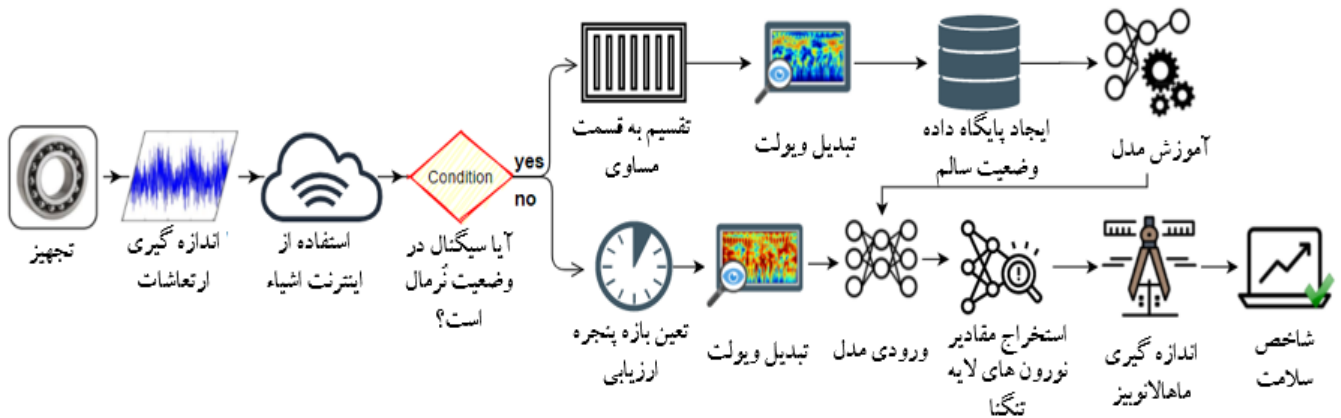
برای هر پنجره ارزیابی در وضعیت سالم افزار است. در طی فرآیند آموزش، مدل خود-رمزگذار آموزش می‌بیند که بتواند مشخصه‌های اصلی تصاویر تبدیل موجک در وضعیت سالم را به‌طور خودکار استخراج کند و تصاویر را با حداقل تعداد نورون در لایه تنگنا فشرده‌سازی کند [۲۱].



شکل ۲. ساختار یک مدل خود-رمزگذار ساده.

Fig. 2. Architecture model of a simple autoencoder.

در گام دوم، مدل یادگیری عمیق صرفاً با استفاده از تصاویر تبدیل موجک داده‌های ارتعاشی در وضعیت سالم افزار آموزش داده می‌شود. مدل یادگیری عمیق توسعه یافته در این پروژه از انواع دسته مدل‌های خود-رمزگذار است. شبکه‌های عصبی خود-رمزگذار دسته‌ای از مدل‌ها بدون نظارت می‌باشند که برای استخراج ویژگی‌ها، کاهش ابعاد و حذف نویزها استفاده می‌شوند [۲۶]. مهم‌ترین مشخصه این شبکه‌ها، داشتن تعداد یکسان از نورون‌ها در لایه ورودی و لایه خروجی شبکه است، به نحوی که شبکه آموزش می‌بیند تا مقادیر لایه ورودی را عیناً در لایه خروجی پیش‌بینی کند. همان‌گونه که در شکل ۲ نشان داده شده است، یک شبکه خود-رمزگذار ساده حداقل از سه لایه ورودی، میانی و خروجی تشکیل شده است. از منظر تعداد نورون در هر لایه، لایه ورودی و لایه خروجی همانند یکدیگر بوده و لایه میانی از دو لایه دیگر تعداد نورون کمتری دارد. در یک مدل خود-رمزگذار لایه میانی با کمترین تعداد نورون را لایه تنگنا می‌نامند. از آنجاکه تعداد نورون‌ها در لایه تنگنا کمتر از دو لایه دیگر است، شبکه خود-رمزگذار آموزش می‌بیند تا مقادیر ورودی را در لایه تنگنا فشرده‌سازی نماید و بر اساس همین مقادیر لایه تنگنا، مقادیر ورودی را در خروجی بازسازی نماید [۲۷]. بنابراین یک شبکه خود-رمزگذار از دو قسمت اصلی تشکیل شده است: قسمت رمزگذار که وظیفه نگاشت مقادیر ورودی به کدهای فشرده شده در لایه تنگنا را دارد و قسمت رمزگشا که وظیفه بازسازی مقادیر کدهای فشرده شده در خروجی را دارد. ورودی مدل خود-رمزگذار در مرحله آموزش، تصاویر تبدیل موجک



شکل ۳. روش پیشنهادی برای ساخت شاخص سلامت.

Fig. 3. Proposed methodology for the construction of the health indicator.

مدل با محدودیت روبرو خواهد شد؛ زیرا که اساس استفاده از مدل پیشنهادی مقایسه وضعیت سالم تجهیز و وضعیت معیوب تجهیز است که در این صورت شرایط بهره‌برداری بایستی یکسان باشد.

### ۳-۱- پردازش سیگنال‌های اولیه

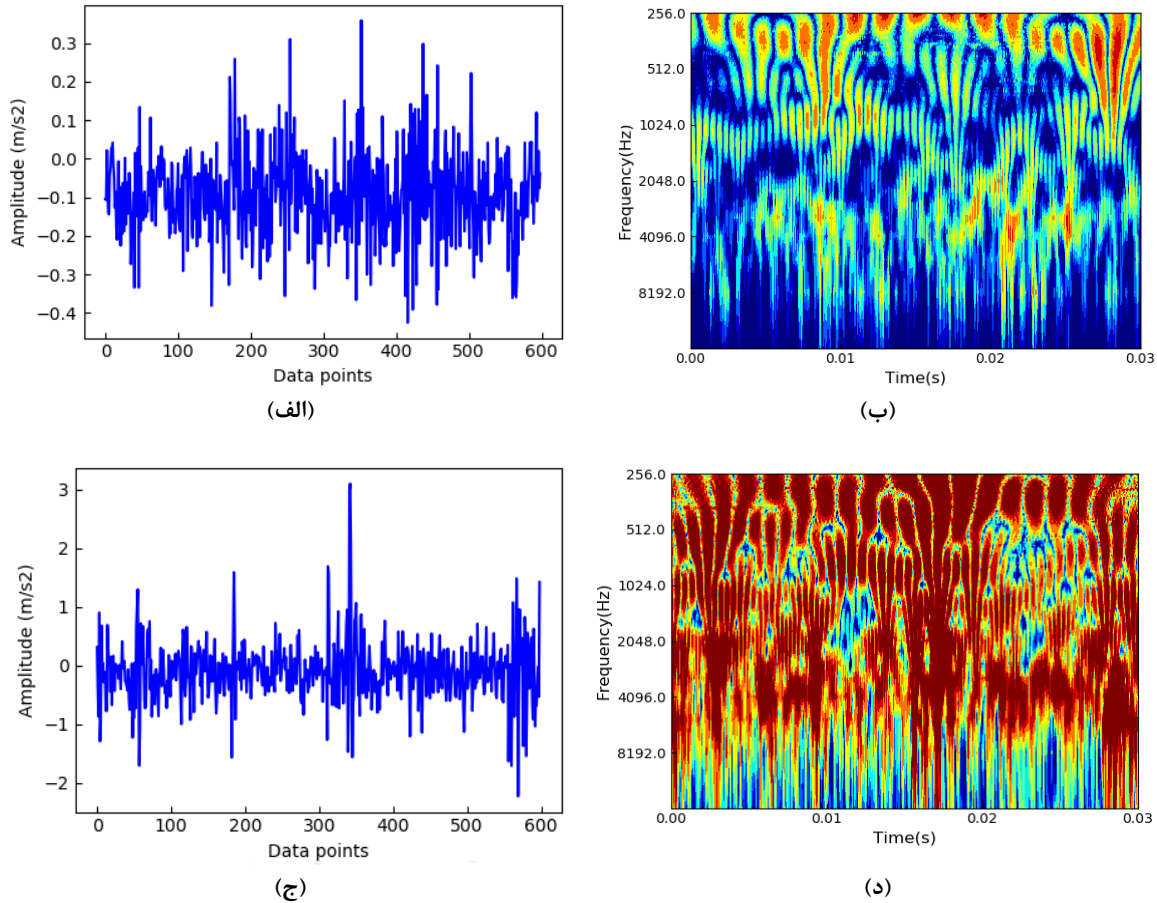
هدف از استفاده ابزار تبدیل موجک پیوسته در این پروژه، ایجاد تصاویر متمایز متناسب با میزان رشد خرابی است؛ به نحوی که تصاویر ایجاد شده در طول عمر افزار بتواند مراحل ایجاد و رشد خرابی‌ها را به خوبی نشان دهند. پس از ایجاد این تصاویر توسط تبدیل موجک پیوسته، وظیفه مدل یادگیری عمیق آن است که بتواند میزان تفاوت تصاویر را به صورت خودکار تعیین نماید. تبدیل موجک پیوسته ابزاری نسبتاً جدید و قدرتمند در زمینه پردازش سیگنال است، که به‌ویژه در پردازش سیگنال‌های غیر ثابت و گذرا استفاده می‌شود. با استفاده از تبدیل موجک پیوسته می‌توان تغییرات حوزه فرکانس یک سیگنال را در طی یک بازه زمان نشان داد. در تبدیل موجک پیوسته، همانند تبدیل فوریه از ضرب داخلی یک تابع تحلیلی در سیگنال هدف برای اندازه‌گیری میزان شباهت موجود میان سیگنال و تابع تحلیلی استفاده می‌شود. تابع تحلیل مورد استفاده در تبدیل فوریه، تابع مختلط نمایی  $(e^{i\omega t})$  است، در حالی که تابع تحلیلی در تبدیل موجک پیوسته، متناسب با وضعیت سیگنال هدف انتخاب شده و به‌عنوان تابع موجک مادر  $(\psi(t))$  شناخته می‌شود [۲۸].

در گام سوم، پس از آموزش مدل و در مرحله اجرا، تصاویر تبدیل موجک پیوسته برای هر بازه ارزیابی در وضعیت خراب افزار به ورودی مدل داده می‌شود و اعداد نورون‌ها در لایه تنگنا متناسب با نوع تصویر، تغییر خواهند کرد. به این ترتیب که اعداد در نورون‌های لایه تنگنا برای تصاویر مشابه، به‌طور تقریبی یکسان خواهد بود و هر میزان تفاوت تصاویر بیشتر باشد، میزان اعداد در نورون‌های لایه تنگنا متفاوت‌تر خواهند بود. با ایجاد و رشد خرابی‌ها در افزار، تصاویر تبدیل موجک متفاوت‌تری ایجاد خواهند شد و در نتیجه مدل خود-رمزگذار می‌تواند میزان تفاوت تصاویر را به‌طور خودکار به دست آورد. از آن‌جاکه لایه تنگنا شامل فشرده‌ترین و کامل‌ترین ویژگی‌های استخراجی است، می‌تواند برای مقایسه تصاویر به کار رود. بنابراین، مقدار بردار لایه تنگنا برای هر لحظه از وضعیت خرابی افزار با بردار لایه تنگنا در وضعیت سالم توسط رابطه ماهالانوبیز<sup>۱</sup> مقایسه شده و شاخص سلامت ایجاد خواهد شد (شکل ۳).

در آموزش مدل پیشنهاد شده در این پروژه، برای ساخت شاخص سلامت یک تجهیز صرفاً از داده‌های همان تجهیز در طی وضعیت سالم استفاده می‌شود. بنابراین مدل آموزش دیده مختص به همان تجهیز است و شرایط محیطی و کلی تجهیز در استفاده از مدل بی‌اثر بوده و مدل از دقت بالاتری برخوردار خواهد بود. با این حال باید توجه داشت که چنانچه شرایط بهره‌برداری از تجهیز در حین زمان تغییر کند، مانند تغییر سرعت، استفاده از

1 Mahalanobis





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

**Fig. 4.** Comparison of time-domain vibration signals and power spectrum images for healthy and damaged signals, (a) raw signal in healthy stage (b) wavelet power spectrum of normal stage (c) raw signal in failure stage (d) wavelet power spectrum of failure stage.

$$\omega(a, b, f(t), \psi(t)) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{a}} \psi\left(t - \frac{b}{a}\right) dt \quad (1)$$

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.

برای نشان دادن مزایای استفاده از تبدیل موجک پیوسته، نمایش سیگنال در حوزه زمان و طیف توانی تبدیل موجک متناظر با آن برای دو حالت سیگنال ارتعاشی یاتاقان سالم و یاتاقان معیوب برای نمونه در شکل ۴ نشان داده شده‌اند.

در آنالیز تبدیل موجک با مقایسه تابع موجک مادر با سیگنال پایه، مقادیر جابجایی و اتساع تابع موجک مادر به دست می‌آید. از آنجا که انتخاب تابع موجک مادر وابسته به شکل سیگنال پایه می‌باشد، انتخاب مناسب آن تأثیر به سزایی در دقت نتایج دارد. به طور کلی هر میزان شکل تابع موجک مادر به سیگنال پایه شبیه‌تر باشد، نتایج دقیق‌تری را به همراه خواهند داشت. روش‌های متفاوتی برای ارزیابی شباهت میان سیگنال هدف و تابع موجک مادر معرفی شده‌اند، که از آن میان می‌توان به بازرسی چشمی اشاره نمود. در این روش تلاش می‌شود تا تابع موجک مادری که هماهنگی بیشتری با سیگنال هدف دارد بر اساس معیار چشمی انتخاب شود [۲۹].

تابع  $f(t)$  را تابعی پیوسته و انتگرال‌پذیر در نظر بگیرید (که در اینجا همان سیگنال هدف است)، در این صورت تبدیل موجک پیوسته تابع  $f(t)$  با استفاده از تابع موجک مادر  $\psi(t)$  به صورت رابطه (۱) تعریف می‌گردد [۲۹]:

### ۳-۲-۱- مدل خود رمزگذار عمیق

در یک مدل خود رمزگذار عمیق، در بخش رمزگذار لایه ورودی صرفاً توسط تعدادی لایه متوالی با ترکیب نورون‌های کاهشی به لایه تنگنا متصل می‌شوند. در بخش رمزگشا، ترکیب قرینه بخش رمزگذار استفاده می‌شوند تا از لایه تنگنا به لایه خروجی متصل شود [۳۰]. در یک مدل خود رمزگذار عمیق، ساختار مدل با تعیین تعداد لایه‌های بخش رمزگذار و رمزگشا و تعداد نورون‌ها در هر لایه مشخص می‌شود [۳۱]. لایه ورودی مدل، تصویر رنگی تبدیل موجک در هر پنجره ارتعاشی با اندازه  $60 \times 60$  پیکسل است. از آنجا که تصویر ورودی به صورت رنگی و سه کانال است، هر دو لایه ورودی و خروجی دارای  $10800 (3 \times 60 \times 60)$  نورون خواهند بود. تعداد نورون‌های در نظر گرفته شده برای لایه تنگنا دو است. بنابراین تصویر دوبعدی ورودی به یک بردار دوتایی در لایه تنگنا تبدیل می‌شود  $(\mathbb{R}^2 \rightarrow \mathbb{R}^{60 \times 60})$  در مدل خود رمزگذار عمیق از چیدمان با هفت لایه میانی به صورت ساختار کاملاً متصل استفاده شده است؛ به نحوی که همه نورون‌ها در یک لایه به تمامی نورون‌ها در لایه بعدی متصل می‌باشند. نمونه‌ای تصاویر ورودی و تصاویر خروجی (پیش‌بینی شده) متناظر با مدل خود رمزگذار عمیق در شکل ۵ نشان داده شده‌اند. همان‌گونه که نشان داده شده، علی‌رغم تبعیت کلی تصاویر خروجی از تصاویر ورودی، کیفیت تصاویر پایین می‌باشند، که نتیجه دقت پایین در استخراج ویژگی‌های کامل تصاویر است.

### ۳-۲-۲- مدل خود رمزگذار همگشتی

مدل خود رمزگذار همگشتی از ترکیب دو مدل خود رمزگذار عمیق و مدل شبکه عصبی همگشتی حاصل شده است. در مدل خود-رمزگذار همگشتی برای بهبود توانایی مدل در استخراج ویژگی‌های اصلی و کاهش حجم داده‌های پردازش، پیش از لایه‌های خود-رمزگذار کاملاً متصل، لایه‌های ضرب پیچشی و ادغام [۳۲] اضافه می‌شوند. استفاده از این لایه‌ها قبل از لایه‌های خود-رمزگذار، علاوه بر بهبود فرآیند استخراج ویژگی، اندازه داده‌های ورودی به لایه‌های خود-رمزگذار را نیز کاهش می‌دهند. در نتیجه به دلیل 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 [۳۳]. برای آموزش مدل خود-رمزگذار همگشتی به صورت غیر نظارت‌شده، لازم است تا لایه‌های ضرب پیچشی و ادغام، قبل و پس از مدل خود رمزگذار عمیق به طور قرینه بکار گرفته شوند [۲۶]. در شکل ۶ ساختار شماتیک مدل خود رمزگذار همگشتی ارائه شده است.


تابع موجک مادر استفاده شده برای این سیگنال‌ها، تابع موجک مورلت می‌باشد [۲۸]. طیف توانی تبدیل موجک نشان‌دهنده تغییرات توزیع انرژی سیگنال ارتعاشی برای فرکانس‌های مختلف در طی زمان است. در حالی که برای سیگنال در وضعیت سالم نوسانات دوره‌ای و با دامنه کم قابل مشاهده است، برای سیگنال در وضعیت خرابی نوسانات شدیدتر و با دامنه بزرگ‌تر قابل مشاهده است. برای سیگنال در وضعیت سالم، بیشینه انرژی در طیف توانی در فرکانس‌های بالا تمرکز داشته، در حالی که برای سیگنال در وضعیت خرابی انفجار انرژی در بازه فرکانسی وسیع‌تر رخ می‌دهد. همان‌گونه که قابل مشاهده است تبدیل موجک می‌تواند به خوبی میان سیگنال سالم و معیوب تمایز قائل کند و تصاویر متفاوت ایجاد نماید.

### ۳-۲- توسعه مدل یادگیری عمیق

همان‌گونه که پیش‌از این اشاره شده، در این مطالعه از دسته مدل‌های خود-رمزگذار استفاده شده است. هدف از مدل خود-رمزگذار در این پروژه، توسعه مدل‌های است که بتوانند تصاویر ورودی را به خوبی در خروجی بازسازی کنند و در عین حال کمترین تعداد نورون را در لایه تنگنا داشته باشند. به این ترتیب می‌توان اطمینان حاصل نمود که کمترین و در عین حال دقیق‌ترین ویژگی‌های معرف تصاویر استخراج شده‌اند. تصاویر مورد استفاده برای آموزش مدل خود-رمزگذار، تصاویر حاصل از آنالیز تبدیل موجک سیگنال‌های ارتعاشی در وضعیت سالم افزار می‌باشند.

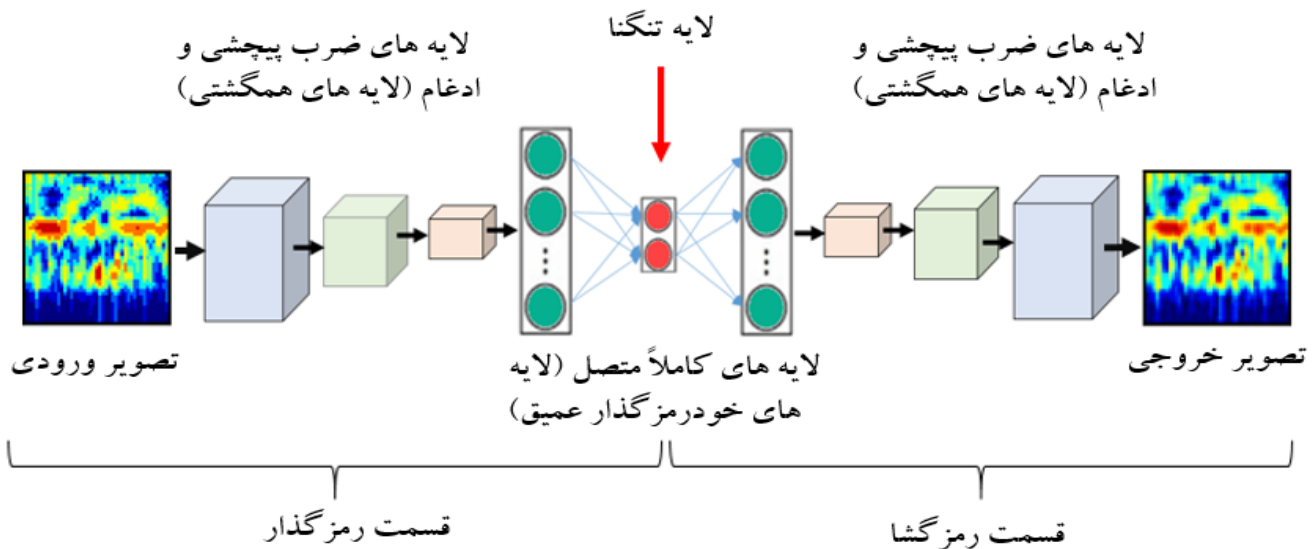
انواع مدل‌ها مختلفی را می‌توان بر اساس مفهوم شبکه خود-رمزگذار ارائه نمود که از جمله آن‌ها می‌توان به مدل خود رمزگذار عمیق<sup>۱</sup>، خود رمزگذار همگشتی<sup>۲</sup> و خود رمزگذار متغیر<sup>۳</sup> اشاره نمود. در این پروژه دو ساختار مختلف از انواع مدل خود-رمزگذار پیشنهاد و بررسی شده است. مدل‌های مورد مطالعه در این پروژه عبارت‌اند از خود-رمزگذار عمیق و خود-رمزگذار همگشتی. انتخاب بهینه ساختار و چیدمان مناسب لایه‌های در هر نوع شبکه عصبی برای حصول به حداکثر نتیجه مطلوب، مبتنی بر سعی و خطا است. هر میزان شباهت تصویر ورودی و تصویر بازسازی شده در خروجی بیشتر باشد دقت مدل در استخراج ویژگی‌های معنادار در لایه تنگنا بیشتر است و نشان از دقت بالای مدل خواهد داشت.

- 1 Deep autoencoder
- 2 Convolutional autoencoder
- 3 Variational autoencoder



شکل ۵. مقایسه تصاویر ورودی و خروجی در مدل خود-رمزگذار عمیق.

Fig. 5. Comparison of the input and output images in the simple autoencoder model.



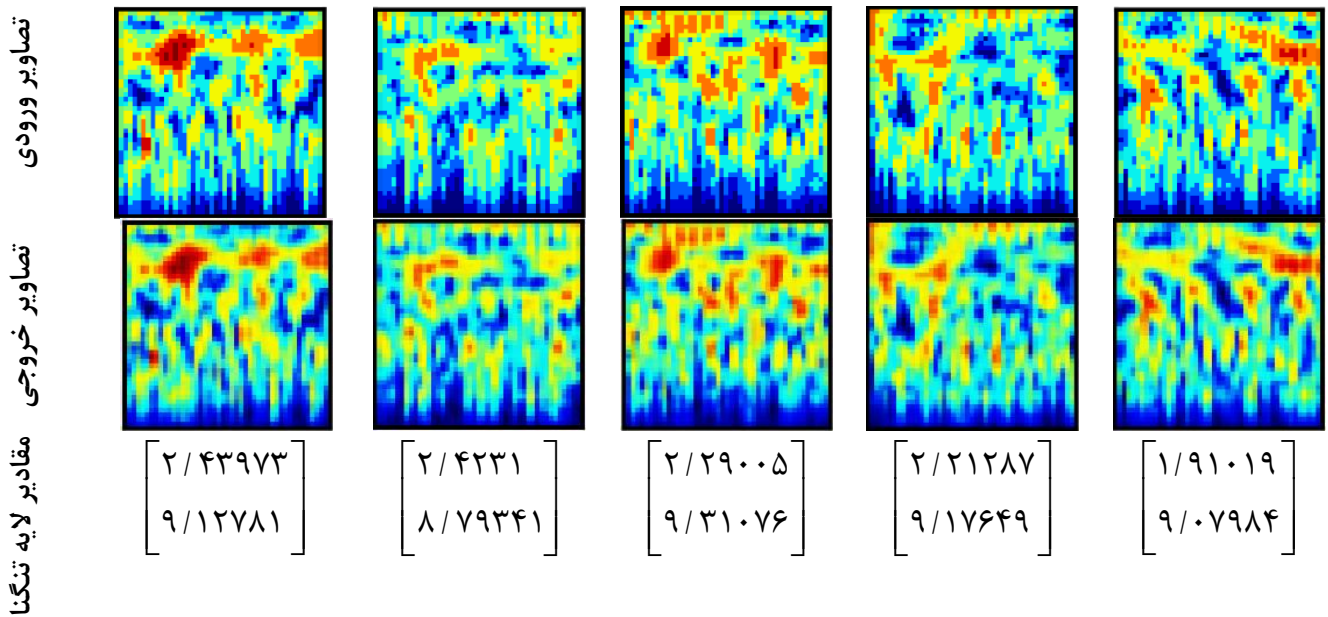
شکل ۶. تصویر شماتیک از لایه های مختلف مدل خود-رمزگذار همگشتی.

Fig. 6. The overall convolutional autoencoder architecture model used.

همان گونه که مشاهده می شود تصاویر پیش بینی شده در خروجی به خوبی از تصاویر ورودی تبعیت کرده و دارای کیفیت مناسباند که نشان از استخراج دقیق ویژگی ها از تصاویر در لایه تنگنا است. باید توجه داشت که ممکن است مدل در مرحله آموزش صرفاً مقادیر ورودی را حفظ و در خروجی تکرار نماید، بنابراین باید خروجی مدل را به ازای تصاویری که مدل در مرحله آموزش

در اینجا نیز همانند مدل خود رمزگذار عمیق لایه ورودی و لایه خروجی ۱۰۸۰۰ نورون خواهند داشت و تعداد نورون های لایه تنگنا برابر دو خواهد بود. نمونه ای از تصاویر ورودی و خروجی مدل برای وضعیت سالم با استفاده از مدل توسعه داده شده به همراه مقادیر نورون های لایه تنگنا در شکل ۷ نشان داده شده است.





شکل ۷. مقایسه تصاویر ورودی و خروجی در مدل خود-رمزگذار همگشتی به همراه مقادیر لایه تنگنا

Fig. 7. Comparison of the input and output images for the healthy stage in the convolutional autoencoder accompanied with bottleneck nodes values.

داده شده است، با رشد خرابی‌ها فاصله مقادیر نورون‌ها نسبت به وضعیت سالم افزایش می‌یابند. برای اندازه‌گیری این فاصله، از رابطه ماهالانویز [۳۴] استفاده شده است. رابطه ماهالانویز 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 [۳۴].

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 می‌شوند به نحوی که  $x_i^h = \{v_1, v_2\}$  برای مجموعه انتخابی  $X^h$  بردار میانگین  $\mu = \frac{1}{m} \sum_{i=1}^m v_i^m$  محاسبه می‌گردد. همچنین برای مجموعه برداری  $X^h$  ماتریس کوواریانس نیز محاسبه می‌شود. ماتریس کوواریانس، ماتریسی مربعی دو-در-دو و متقارن خواهد بود که اعضای آن همبستگی میان پارامترهای مختلف مجموعه را نشان می‌دهند. در نهایت فاصله ماهالانویز در طی هر بازه ارزیابی برای  $X^{each\ interval}$  بر اساس رابطه (۲) محاسبه می‌شود:

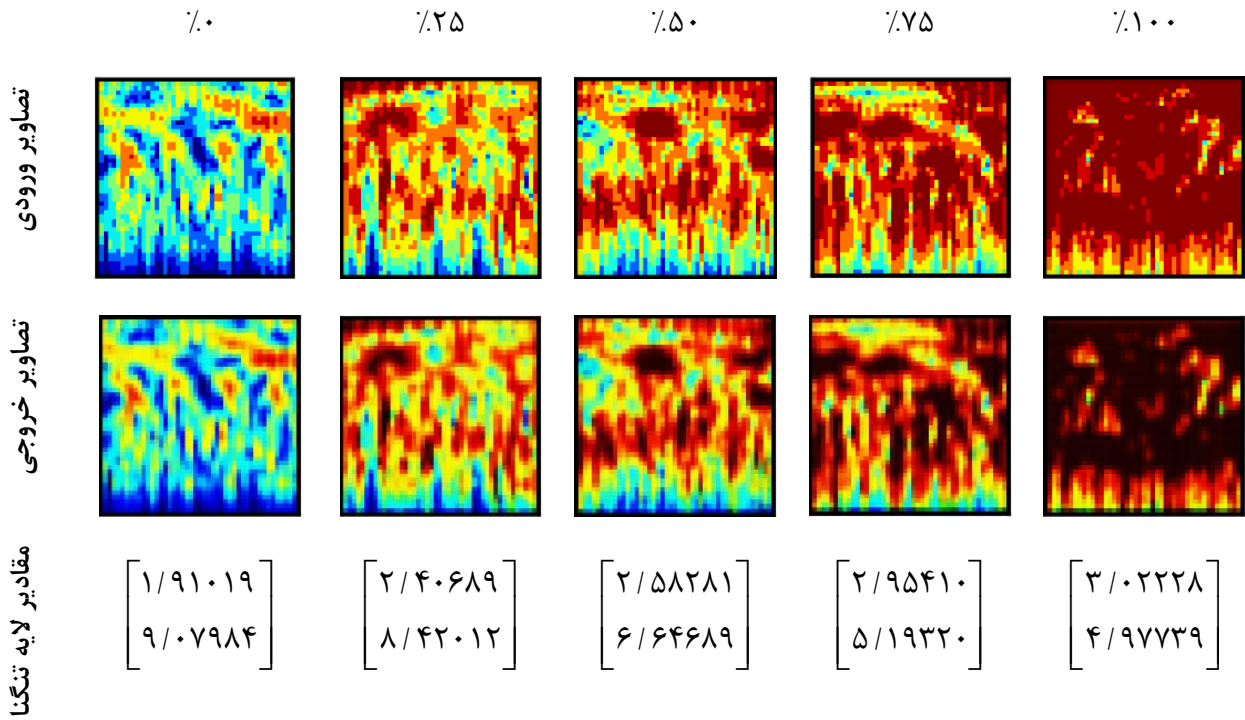
$$(MD)^2 = (X - \mu)^T C^{-1} (X - \mu) \quad (2)$$

هرگز ندیده است نیز بررسی نمود. از آن‌جا که مدل تنها با مجموعه‌ای از تصاویر در وضعیت سالم آموزش دیده است، تصاویری با میزان درصد خرابی متفاوت به‌عنوان ورودی مدل در نظر گرفته و تصاویر پیش‌بینی شده به همراه مقادیر نورون‌های لایه تنگنا در شکل ۸ نشان داده شده‌اند. همان‌گونه که مشاهده می‌شود، مدل خود رمزگذار همگشتی توانسته به‌خوبی از تصاویری که در مرحله آموزش هرگز ندیده است تبعیت کند و تصاویری با کیفیت مطلوب پیش‌بینی نماید. علاوه بر آن، مقادیر نورون‌ها در لایه تنگنا به‌خوبی با افزایش خرابی از مقادیر نورون‌ها در حالت سالم فاصله می‌گیرند. بنابراین می‌توان اطمینان حاصل نمود که مقادیر دوتایی استخراج شده در لایه تنگنا به‌خوبی می‌توانند ارائه‌دهنده وضعیت تصویر باشند و به‌عنوان ابزار ساخت شاخص سلامت بکار روند.

### ۳-۳- اندازه‌گیری شاخص سلامت


پس از آموزش مدل خود-رمزگذار همگشتی با داده‌های وضعیت سالم، نوبت به ساخت شاخص سلامت در طی دوره ایجاد و رشد خرابی افزار است. برای ساخت شاخص سلامت، میزان فاصله دوری مقادیر نورون‌های لایه تنگنا برای هر پنجره ارزیابی در وضعیت خرابی با میانگین مقادیر نورون‌های لایه تنگنا در وضعیت سالم محاسبه می‌شوند. همان‌گونه که در شکل ۹ نشان

### میزان درصد پیشرفت خرابی




شکل ۸. مقایسه تصاویر ورودی و خروجی در مدل خود-رمزگذار همگستری به همراه مقادیر لایه تنگنا.

Fig. 8. Comparison of the input and output images for the failure stage in the convolutional autoencoder model accompanied with bottleneck nodes values.



شکل ۹. مقایسه مقادیر نورون اول و دوم برای تصاویر در وضعیت سالم و معیوب.

Fig. 9. Comparison of the first and second neuron values for healthy and failure stages.



شکل ۱۰. نمودار ارتعاشی برای چهار یاتاقان که در انتهای آزمایش دارای نشانه‌های از خرابی بوده‌اند در سه آزمون تجربی. (الف) یاتاقان سوم در آزمون اول، (ب) یاتاقان چهارم از آزمون اول، (ج) یاتاقان اول از آزمون دوم و (د) یاتاقان سوم از آزمون سوم. داده‌های خام از مرجع [۲۵].

Fig. 10. Vibration diagram for four bearings at the end of the test with signs of failure in three experimental tests. (a) subset 1 bearing 3, (b) subset 1 bearing 4, (c) subset 2 bearing 1, (d) subset 3 bearing 3 [25].

چهارم در ساچمه‌ها دچار آسیب شده‌اند. برای آزمایش دوم، تنها یاتاقان اول و در کُسن خارجی و برای آزمایش سوم نیز تنها یاتاقان سوم در کُسن خارجی دارای نشانه‌های خرابی بوده‌اند. مابقی یاتاقان‌ها در آزمون‌ها سالم مانده‌اند. از آن‌جا که پس از انجام سه آزمون، تنها این چهار یاتاقان دارای نشانه‌های از خرابی بوده‌اند و شامل داده‌های وضعیت سالم و معیوب می‌باشند، تنها این چهار یاتاقان برای بررسی در این مطالعه انتخاب شده‌اند که در این صورت هر سه نوع عیب اصلی در یاتاقان‌ها در این چهار یاتاقان وجود دارند. ارتعاشات خام اندازه‌گیری شده برای این چهار یاتاقان در شکل ۱۰ نشان داده شده‌اند. جزییات مرتبط با پایگاه داده IMS در جدول ۱ نشان داده شده است.

که در رابطه ۲،  $C^{-1}$  معکوس ماتریس کوواریانس و  $\mu$  بردار میانگین برای مجموعه داده وضعیت سالم بوده و  $X$  بردار مقادیر لایه تنگنا برای بازه ارزیابی موردنظر است.

#### ۴- نتایج تجربی

برای صحنه سنجی روش پیشنهادی ساخت شاخص سلامت، از داده‌های ارتعاشی آزمون‌های مرجع [۲۵] که پیش‌ازاین معرفی گردید، استفاده شده است. مجموعه آزمون‌های مرجع [۲۵] شامل سه آزمون اجرا تا شکست است. برای آزمایش اول، یاتاقان سوم در قسمت کُسن داخلی و یاتاقان

جدول ۱. جزییات مرتبط با پایگاه داده IMS

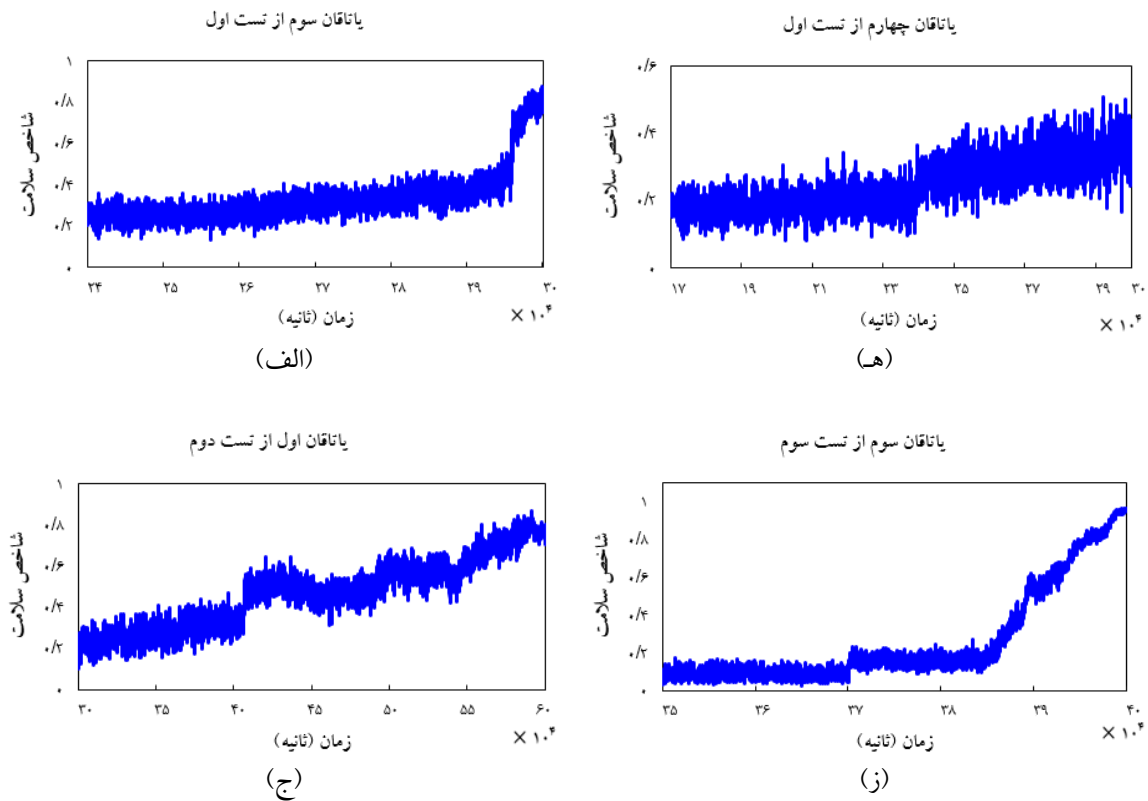
Table 1. Description of IMS bearing dataset. The failure thresholds and the healthy and faulty samples were identified by the adaptive failure threshold

یاتاقان سوم از آزمون سوم	یاتاقان چهارم از آزمون اول	یاتاقان اول از آزمون دوم	یاتاقان سوم از آزمون سوم	
۶۰۰۰	۶۰۰۰	۶۰۰۰	۶۰۰۰	بار شعاعی (پوند-نیرو)
۲۰۰۰	۲۰۰۰	۲۰۰۰	۲۰۰۰	سرعت (دور بر دقیقه)
حلقه داخلی	ساقمه‌های دورانی	حلقه خارجی	حلقه خارجی	نوع عیب
۳۴ روز و ۱۲ ساعت	۳۴ روز و ۱۲ ساعت	۶ روز و ۲۰ ساعت	۴۵ روز و ۹ ساعت	کل مدت زمان آزمون
۶۱۰۶۹	۴۳۳۸۱	۱۹۱۴۶	۲۰۰۴۷۴	تعداد تصاویر سالم
۲۷ روز و ۲۰ ساعت	۱۹ روز و ۲۰ ساعت	۳ روز و ۲۱ ساعت	۴۱ روز و ۲ ساعت	زمان شروع خرابی
۱۹۸۰۰	۳۱۰۹۰	۱۴۷۸۰	۲۰۲۳۰	تعداد تصاویر معیوب

آموزش مدل خود-رمزگذار همگشتی با تصاویر سالم، با استفاده از رابطه ماهالانوبیز فاصله مقادیر گره تنگنا در هر پنجره ارزیابی در طی مرحله خرابی با مقادیر گره تنگنا در وضعیت سالم محاسبه شده و شاخص سلامت ساخته می‌شود. نمودارهای شاخص سلامت ایجاد شده برای چهار یاتاقان پایگاه داده مرجع [۲۵] در شکل ۱۱ نشان داده شده است.

همان‌گونه که مشاهده می‌شود، نمودارهای شاخص سلامت، دارای روند افزایشی و یکنواخت بوده و می‌تواند میزان پیشرفت تخریب را به‌طور مؤثر نشان دهند. همچنین با مقایسه این نمودارها با نمودارهای مقادیر ارتعاشات اندازه‌گیری شده در طول عمر یاتاقان‌ها (شکل ۱۰) به‌خوبی مشخص می‌شود که روش پیشنهادی توانایی تشخیص عیوب اولیه یاتاقان را دارد و نسبت به هر سه حالت خرابی اصلی در یاتاقان‌ها دارای حساسیت است. شاخص سلامت معرفی شده در این مطالعه می‌تواند روند روبه افزایش رشد تخریب‌ها را توصیف نماید و می‌تواند برای تخمین عمر مفید باقی‌مانده یاتاقان بکار رود.

از آنجا که داده‌های ارتعاشی برای هر یاتاقان در طی آزمایش اجرا تا شکست به‌دست آمده‌اند، برای هر آزمایش هر دو دسته داده ارتعاشی در وضعیت سالم و معیوب وجود دارند. در کاربردهای عملی، یک افزار به‌طور تدریجی و در طی تکامل مجموعه‌ای از حالت‌های خرابی، از وضعیت سالم به وضعیت معیوب تبدیل می‌شود. علاوه بر آن، برای هر افزار عدم قطعیت‌های بالای در مورد شرایط کاری و خواص افزار وجود دارد. در نتیجه امکان تعیین یک حد از آستانه مشخص و از پیش تعیین شده که بتواند وضعیت سالم را از وضعیت معیوب جدا نماید، وجود ندارد. برای تعیین زمان آغاز خرابی و جدا کردن سیگنال‌های ارتعاشی در وضعیت سالم از سیگنال‌های ارتعاشی در وضعیت معیوب از معیار پاتو [۲۷] استفاده می‌شود. اگر میانگین دامنه نقطه داده‌های ارتعاشی برای هر پنجره ارزیابی در بازه  $[\mu - 3\sigma, \mu + 3\sigma]$  قرار بگیرد، پنجره ارزیابی مذکور جزء بازه وضعیت سالم قلمداد می‌شود و چنانچه میانگین چندین پنجره ارزیابی متوالی (مثلاً ۵۰۰ پنجره) فراتر از بازه پاتو قرار گیرد، آغاز بازه ایجاد و رشد خرابی تشخیص داده می‌شود. پس از



شکل ۱۱. نمودار شاخص سلامت با استفاده از روش پیشنهادی در این پروژه برای یاتاقان‌های دارای نشانه‌های خرابی در پایگاه داده IMS. (الف) تا (د) نمودارهای شاخص سلامت اولیه. (هـ) تا (ح) نمودار شاخص سلامت هموارشده با استفاده از تابع هموارساز نمایی.

Fig. 11. Constructed Health Indicator results for the four failure IMS bearing (a-d) raw health indicator, (e-h) modified health indicator.

همگشتی به صورت خودکار تفاوت تصاویر تبدیل موجک را ارزیابی و با استفاده از رابطه ماهالانویز شاخص سلامت را ایجاد می‌نماید. عملکرد روش پیشنهادی بر روی چهار دسته داده ارتعاشی اجرا تا شکست یاتاقان‌های غلتشی مورد ارزیابی قرار گرفت. شاخص سلامت ایجادشده برای هر چهار دسته داده توانایی قابل قبول در شناسایی آغاز خرابی دارد و می‌تواند روند رشد خرابی‌ها را تعقیب نماید. با توجه به عملکرد مناسب شاخص سلامت ارائه‌شده، پژوهش‌های آتی متمرکز بر استفاده از این رویکرد برای تعیین عمر مفید باقی‌مانده افزار است.

### منابع

- [1] L.Z. Zepeng Liu, A Review of Failure modes, Condition Monitoring and Fault Diagnosis Methods for Large-Scale Wind Turbine Bearings, Measurement, 149 (2020).
- [2] K.-L.T. Dong Wang, Qiang Miao Prognostics and Health Management: A Review of Vibration Based Bearing and

### ۵- نتیجه‌گیری

در این پژوهش یک روش نوین برای پایش وضعیت افزارگان با استفاده از فناوری هوش مصنوعی ارائه شده است. برای این منظور از یک مدل خود رمزگذار برای ساخت شاخص سلامت بهره برده شده است. در مدل پیشنهادی تنها از داده‌های ارتعاشی وضعیت سالم افزار برای آموزش استفاده می‌شود و بنابراین نیازمند داده‌های حالات مختلف خرابی تجهیز نیست. برای پیاده‌سازی این رویکرد، در گام اول داده‌های ارتعاشی خام با استفاده از تبدیل موجک پیوسته به تصاویر دوبعدی تبدیل می‌شوند. روش تبدیل موجک پیوسته ابزاری نیرومند است، که می‌تواند متناسب با ایجاد و رشد خرابی‌ها تصاویر متمایز ایجاد نماید. در گام دوم، یک مدل خود رمزگذار توسط تصاویر تبدیل موجک در وضعیت سالم آموزش دیده می‌شود. مدل خود رمزگذار ارائه شده در این پژوهش، مدل خود رمزگذار همگشتی است که نسبت به مدل‌های دیگر خود رمزگذار از دقت بالاتری برخوردار است. نهایتاً در گام سوم، در طی مدت ایجاد و رشد خرابی‌ها، مدل خود رمزگذار



- Identification, *Signal Processing*, 130 (2017) 377–388.
- [15] J.-G.B. Youngji Yoo, A Novel Image Feature for the Remaining Useful Lifetime Prediction of Bearings Based on Continuous Wavelet Transform and Convolutional Neural Network, *Appl. Sci.*, 8(7) (2018).
- [16] S.S. Wathiq Abed, Robert Sutton, Amit Motwani A Robust Bearing Fault Detection and Diagnosis Technique for Brushless DC Motors Under Non-stationary Operating Conditions, *J. Control. Autom. Electr. Syst.*, 26 (2015) 241–254.
- [17] M.O. Jun He, Chen Yong, Danfeng Chen, Jing Guo, Yan Zhou, A Novel Intelligent Fault Diagnosis Method for Rolling Bearing Based on Integrated Weight Strategy Features Learning, *sensors*, 20(6) (2020).
- [18] Z.L. Hang Yin, Jiankai Zuo, Hedan Liu, Kang Yang, Fei Li, Wasserstein Generative Adversarial Network and Convolutional Neural Network (WG-CNN) for Bearing Fault Diagnosis, *Math. Probl. Eng.*, 2020 (2020).
- [19] S.Z. Shen Zhang, Bingnan Wang, Thomas G. Habetler, Deep Learning Algorithms for Bearing Fault Diagnostics—A Comprehensive Review, *IEEE Access* 8(2020) 29857 - 29881.
- [20] T.Y. Samir Khan, A Review on the Application of Deep Learning in System Health Management, *Mech. Syst. Signal Process*, 107 (2018) 241-265.
- [21] J.P.a.H.W.v.d.V. Mohammadreza Kaji, Constructing a Reliable Health Indicator for Bearings Using Convolutional Autoencoder and Continuous Wavelet Transform, *Appl. Sci.*, (2020).
- [22] T.G.H. Wei Zhou, Ronald G. Harley, Bearing Condition Monitoring Methods for Electric Machines: A General Review, in: 2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, Cracow, Poland, 2007.
- [23] S.V.K. Prashant P. Kharche, Review of Fault Detection in Rolling Element Bearing, *International Journal of Innovative Research in Advanced Engineering*, 1(5) (2014) 169-174.
- [24] S.C.S. P.K. Kankar, S.P. Harsha, Fault Diagnosis of Ball Bearings Using Continuous Wavelet Transform, *Appl. Gear Health Indicators*, *IEEE Access*, 6 (2017) 665 - 676.
- [3] B.S. Gandhare, Maintenance Strategy Selection, in: Ninth AIMS International Conference on Management, 2012.
- [4] R.K. Mobley, An introduction to predictive maintenance Butterworth-Heinemann, America, 2002.
- [5] B.S. Gandhare, Maintenance Strategy Selection, presented at the Ninth AIMS International Conference on Management, (2012).
- [6] B.A. Gandhare, Milind, Maintenance Strategy Selection, in: The 9th AIMS International Conference on Management, 2012.
- [7] N.L. Liang Guo, Feng Jia, Yaguo Lei, Jing Lin, A Recurrent Neural Network Based Health Indicator for Remaining Useful Life Prediction of Bearings, *Neurocomputing*, 240 (2017) 98–109.
- [8] S.H.U. Akhand Rai, A Aeviw on Signal Processing Techniques Utilized in the Fault Diagnosis of Rolling Element Bearings, *Tribol. Int.*, 96 (2016) 289-306.
- [9] K.-C.L.G.G. Yen, Wavelet Packet Feature Extraction for Vibration Monitoring, *IEEE Transactions on Industrial Electronics*, 47(3) (2000) 650 - 667.
- [10] M.S.H. J. L. Won Gi Lee, Sung-Ho Nam, YongHo Jeon, and Moon G. Lee, Failure Diagnosis System for a Ball-Screw by Using Vibration Signals, *Hindawi Publishing Corporation Shock and Vibration*, (2015).
- [11] G.P.C. Christopher Torrence, A Practical Guide to Wavelet Analysis, *American Meteorological Society*, 79(1) (1998) 61-78.
- [12] Y.H. C. C. P. Tsai, Ball Screw Preload Loss Detection Using Ball Pass Frequency, *Mechanical Systems and Signal Processing*, 48 (2014) 77-91.
- [13] J.L. Y. L. Feng Jia, Xin Zhou, and Na Lu, Deep Neural Networks: A Promising Tool for Fault Characteristic Mining and Intelligent Diagnosis of Rotating Machinery with massive Data, *Mechanical Systems and Signal Processing*, 72 (2016) 303-315.
- [14] W.-L.Q. Z.-Y. W. Chen Lu, Jian Ma, Fault Diagnosis of Rotary Machinery Components Using a Stacked Denoising Autoencoder-Based Health State

- Electronics 47(3) (2000) 650 - 667.
- [30] H.Y. Yasi Wang, Sicheng Zhao, Auto-Encoder Based Dimensionality Reduction, *Neurocomputing*, 184 (2015) 232-242.
- [31] F. Chollet, Keras: Deep Learning Library for Theano and Tensorflow.
- [32] H.T. Ahmed Ali Mohammed Al-Saffar, Mohammed Ahmed Talab, Review of Deep Convolution Neural Network in Image Classification, in: *International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications*, IEEE, Jakarta, Indonesia 2018.
- [33] A.M. Saleh Albelwi, A Framework for Designing the Architectures of Deep Convolutional Neural Networks, *Entropy*, 19(6) (2017).
- [34] M.H.L. Jeongyoun Ahn, Jung Ae Lee, Distance-Based Outlier Detection for High Dimension, Low Sample Size Data, *J. Appl. Stat.*, 46(1) (2019) 13-29.
- Soft Comput., 11 (2011) 2300–2312.
- [25] PCoE Datasets, Bearing Data Set, Intelligent Maintenance Systems (IMS), University of Cincinnati, in.
- [26] A.B. Andrea Borghesi, Luca Benini, Anomaly Detection using Autoencoders in High Performance Computing Systems, in: *The Thirty-First AAAI Conference on Innovative Applications of Artificial Intelligence*, Hawaii, USA, 2019.
- [27] G.G. Fangyi Wan, Chunlin Zhang, Qing Guo, Jie Liu, Outlier Detection for Monitoring Data Using Stacked Autoencoder, *IEEE Access* 7(2019) 173827 - 173837.
- [28] M.S.L. Ngui Wai Keng, Lim Meng Hee, Ahmed. M. Abdelrhman, Wavelet Analysis: Mother Wavelet Selection Methods, *Applied Mechanics and Materials*, 393 (2013) 953-958.
- [29] K.-C.L. G.G. Yen, Wavelet packet feature extraction for vibration monitoring, *IEEE Transactions on Industrial*

چگونه به این مقاله ارجاع دهیم

M. R. Kaji, J. Parvizian, M. Silani, H. W. van de Venn, A New Machine Learning Method for Ball Bearing Condition Monitoring Based on Vibration Analysis, *Amirkabir J. Mech Eng.*, 54(2) (2022) 465-480.

DOI: 10.22060/mej.2021.20023.7153



