



Predicting the remaining useful life of the product based on vibration signals and genetic algorithm

Mojtaba Khakbazan¹, Saeid Ramezani ^{*2}, Mustafa Yousefi Tezerjan³

1- Ph.D. student of industrial engineering at Ivanki University.

2*- Member of the Faculty of Industrial Engineering, Faculty of Technology and Engineering, Imam Hossein University (AS), Tehran, Iran.

3- Member of the Faculty of Applied Science University, Alborz, Iran.

Abstract

In today's competitive world, maintaining product quality and accurately predicting its useful life is of particular importance. Sudden failures such as bearing failures can have significant financial and time effects on production. In order to deal with these challenges, this research presents an intelligent model based on vibration analysis and genetic algorithms, which is able to predict the remaining useful life of bearings with high accuracy. The proposed model consists of four parts: the quality indicators prediction part, the initial state of deterioration part, the information integration part and the optimization part. This model not only helps improve maintenance strategies, but also leads to increased productivity and profitability of companies by reducing unexpected downtime periods. Experimental results show that the performance of our model is better than conventional methods such as autoregression models, especially thanks to the use of optimized parameters in different steps.

Keywords: Life prediction ,genetic algorithm, data mining, product marketing

Citation:

Khakbazan, M., Ramezani, S., & Yousefi Tezerjan, M. (2023). Predicting the remaining useful life of the product based on vibration signals and genetic algorithm. *Journal of Intelligent Marketing Management*, 4(1), 63- 81 .



پیش بینی عمر مفید باقی مانده محصول بر اساس سیگنال های ارتعاشی و الگوریتم ژنتیک

مجتبی خاکبازان^۱، سعید رمضانی^{۲*}، مصطفی یوسفی طرزجان^۳

۱- دانشجوی دکتری مهندسی صنایع دانشگاه ایوانکی.

۲- عضو هیئت علمی گروه مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه جامع امام حسین (ع)، تهران، ایران.

۳- عضو هیئت علمی دانشگاه جامع علمی کاربردی، البرز، ایران.

چکیده

در دنیای رقابتی امروز، حفظ کیفیت محصول و پیش بینی دقیق عمر مفید آن از اهمیت ویژه ای برخوردار است. خرابی های ناگهانی مانند خرابی بلبرینگ می توانند تأثیرات مالی و زمانی قابل توجهی بر تولید داشته باشند. به منظور مقابله با این چالش ها، این تحقیق یک مدل هوشمند بر پایه ی تحلیل ارتعاشات و الگوریتم های ژنتیک را ارائه می دهد که قادر است عمر مفید باقی مانده ی بلبرینگ ها را با دقت بالا پیش بینی کند. مدل پیشنهادی شامل چهار بخش است: بخش پیش بینی شاخص های کیفیت، بخش تعیین وضعیت اولیه ی زوال، بخش تلفیق اطلاعات و بخش بهینه سازی. این مدل نه تنها به بهبود استراتژی های تعمیر و نگهداری کمک می کند بلکه با کاهش دوره های توقف غیرمنتظره، به افزایش بهره وری و سودآوری شرکت ها نیز منجر می شود. نتایج تجربی نشان می دهند که عملکرد مدل ما از روش های مرسوم مانند مدل های خودرگرسیون بهتر است، به ویژه به لطف استفاده از پارامترهای بهینه یابی شده در مراحل مختلف.

کلیدواژه ها: پیش بینی عمر، الگوریتم ژنتیک، داده کاوی، بازاریابی محصول.

استناد:

خاکبازان، مجتبی و رمضانی، سعید و یوسفی طرزجان، مصطفی. (۱۴۰۲). پیش بینی عمر مفید باقی مانده محصول بر اساس سیگنال های ارتعاشی و الگوریتم ژنتیک. مدیریت بازاریابی هوشمند، ۴(۱). ۶۳-۸۱.

تاریخ دریافت: ۱۴۰۱/۱۱/۰۹

تاریخ ویرایش: ۱۴۰۱/۱۲/۰۳

تاریخ پذیرش: ۱۴۰۲/۰۱/۲۰

تاریخ انتشار: ۱۴۰۲/۰۱/۲۰

<https://doi.org/JABM.3.2.15564.35125656565047>

نشریه مدیریت بازاریابی هوشمند، ۱۴۰۲، دوره ۴، شماره ۱، پیاپی ۱۹

ناشر: نشریه مدیریت بازاریابی هوشمند

نوع مقاله: علمی پژوهشی

© نویسندگان



مقدمه

برای محدود کردن حرکت نسبی و در عین حال کاهش اصطکاک بین قطعات متحرک، بلبرینگ‌های اجزای متحرک (REB) یکی از پرکاربردترین عناصر در ماشین آلات صنعتی هستند. پیش‌آگهی و مدیریت سلامت بلبرینگ‌ها برای ایمنی، قابلیت اطمینان و اثربخشی سیستم‌های مکانیکی اهمیت دارد [۱، ۲]. ادبیات نشان می‌دهد که نزدیک به نیمی از خرابی‌های موتور مربوط به تخریب بلبرینگ‌ها است [۳]. به این ترتیب، تخمین عمر مفید باقیمانده (RUL) (یعنی پیش‌آگهی زمان تا خرابی) بلبرینگ‌ها در سال‌های اخیر توجه زیادی را به خود جلب کرده است [۴]. پیش‌بینی RUL به کاربران کمک می‌کند تا وضعیت بلبرینگ‌ها را نظارت کنند و زمان باقی‌مانده قبل از وقوع خرابی را تخمین بزنند. در مقایسه با تشخیص خطا، که در چند دهه گذشته به خوبی بررسی شده است، مسئله پیش‌بینی RUL که در این مقاله مورد بررسی قرار می‌گیرد، موضوعی نسبتاً جدید و چالش‌برانگیز به دلیل حجم عظیمی از عدم قطعیت‌های محیط و شرایط عملیاتی است [۵].

به‌طور کلی، رویکردهای پیش‌بینی RUL را می‌توان به رویکردهای مبتنی بر مدل و مبتنی بر داده طبقه‌بندی کرد. هدف رویکردهای مبتنی بر مدل ساختن یک مدل فیزیکی برای نشان دادن تخریب بلبرینگ دورانی است [۶]. ساخت یک مدل زوال فیزیکی دقیق به دلیل حساسیت پارامترهای مدل و محیط‌های عملیاتی دارای نویز دشوار است. این امر کاربردهای عملی رویکردهای مبتنی بر مدل را محدود می‌کند. از سوی دیگر، روش‌های مبتنی بر داده از فناوری گسترده در پردازش سیگنال و یادگیری ماشین بهره می‌برند و فرآیند تخریب بلبرینگ‌ها را بدون هیچ‌گونه اطلاع از خرابی فیزیکی استنتاج می‌کنند [۷]. چارچوب پیش‌آگهی رویکردهای مبتنی بر داده عمده‌تاً شامل سه مرحله است: ۱) استخراج ویژگی از سیگنال‌های حس‌گرهای نویزی، که به ایجاد شاخص سلامت (HI) برای یادگیری رفتار خرابی سیستم کمک می‌کند، ۲) مدل‌های خرابی با استفاده از تکنیک‌های آماری یا یادگیری ماشینی بر روی بلبرینگ آموزش داده می‌شوند و ۳) شاخص خرابی بلبرینگ‌های آزمایشی را می‌توان براساس مدل آموزش داده شده در مرحله دوم تخمین زد. سپس، فرآیند خرابی ناشناخته را می‌توان با استفاده از تکنیک‌های رگرسیون پیش‌بینی کرد.

برای استخراج ویژگی‌ها از سیگنال‌های خام، تجزیه و تحلیل دامنه زمان، دامنه فرکانس و دامنه زمان-فرکانس معمولاً اتخاذ می‌شود. در میان آن‌ها، تحلیل زمان-فرکانس به دلیل توانایی آن در توصیف سیگنال‌های گذرا در طول زمان و حوزه‌های فرکانس کارآمدترین است [۸]. تکنیک‌های شناخته‌شده فرکانس زمانی برای استخراج ویژگی‌های بلبرینگ شامل تبدیل فوریه کوتاه مدت [۹]، موجک‌ها [۱۰] و برخی تبدیلات [۱۱، ۱۲] است. پیاده‌سازی تبدیل فوریه کوتاه مدت با قابلیت تفکیک فرکانس زمانی محدود شده است. برای مثال، تشخیص فرکانس‌های پایین با پنجره‌های کوتاه دشوار است. از سوی دیگر، موجک‌ها تصاویر غنی تری نسبت به تبدیل فوریه کوتاه مدت ارائه می‌دهند. با این حال، اثربخشی آن‌ها به تخمین پارامتر و کیفیت سیگنال تحلیل شده بستگی دارد.

رویکردهای پیش‌بینی RUL مبتنی بر داده عمده‌تاً مبتنی بر تکنیک‌های آماری و یادگیری ماشینی هستند، مانند شبکه‌های عصبی مصنوعی (ANN) [۱۳]، سیستم‌های منطق فازی [۱۳] و مدل‌های رگرسیون خودکار (AR) [۱۴]. هزینه محاسباتی ANN از نظر بهینه سازی وزن مدل نسبتاً بالا است. عملکرد مدل‌های AR و سیستم‌های منطق فازی به ترتیب نیازمند روند دقیق مشاهدات تاریخی و داده‌های آموزشی با کیفیت بالا هستند. اخیراً، یادگیری عمیق در زمینه‌های تحقیق و صنعت ادغام شده است و سایر تکنیک‌های یادگیری ماشینی

¹ Rolling Element Bearings

² Remaining Useful Life

را در وظایف تشخیص گفتار و تشخیص تصویر شکست داده است [۱۵]. مدل یادگیری عمیق در کشف انتزاعات سطح بالا از داده‌های برچسب گذاری شده با استفاده از یک الگوریتم پس انتشار خوب عمل می‌کند [۱۶]. به طور خاص، به جای طراحی ویژگی‌های ایجاد شده توسط انسان، به‌طور خودکار بازنمایی ویژگی‌ها را یاد می‌گیرد. به‌عنوان شناخته‌شده‌ترین مدل در یادگیری عمیق، در سال‌های اخیر، CNN بر مسائل تشخیص در حوزه بینایی رایانه تسلط دارد، که با سه ویژگی، یعنی اتصالات محلی، وزن‌های مشترک، و ادغام محلی متمایز می‌شود [۱۷، ۱۸]. دو مشخصه اول نشان می‌دهد که مدل CNN به پارامترهای کم‌تری برای شناسایی اطلاعات محلی نسبت به پرسپترون چند لایه نیاز دارد، در حالی که آخرین مشخصه تغییرناپذیری به شبکه‌ها را تضمین می‌کند. به‌طور معمول، CNN یک بعدی برای یادگیری فضای پنهان ارتعاشات سری زمانی حسی ورودی، که با موفقیت زیادی برای تشخیص گفتار و وظایف خواندن اسناد اعمال شده است، به کار گرفته می‌شود.

با این حال، بسیاری از رویکردهای موجود دو نقص زیر را دارند: (۱) زمان وقوع خطا (FOT) نادیده گرفته می‌شود یا به صورت ذهنی انتخاب می‌شود. (۲) داده‌های آموزش و آزمایش از توزیع داده‌های یکسانی پیروی می‌کنند. FOT نامناسب یا شامل اطلاعات نامرتب مانند نویز می‌شود یا اطلاعات تخریب حیاتی را کاهش می‌دهد. مدل پیش‌آگهی آموزش داده شده با مجموعه داده در یک شرایط کاری نمی‌تواند به‌خوبی روی مجموعه داده از شرایط کاری متفاوت دیگر به دلیل اختلاف توزیع تعمیم دهد. در [۱۹]، برای رسیدگی به این دو کاستی، ابتدا از مدل پنهان مارکوف (HMM) برای تشخیص خودکار تغییر حالت استفاده می‌شود تا بتوان FOT را پیدا کرد. سپس یک روش یادگیری انتقال جدید مبتنی بر پرسپترون چند لایه (MLP) برای حل مشکل اختلاف توزیع ارائه می‌شود. مطالعه آزمایشی بر روی تخمین RUL بلبرینگ برای نشان دادن اثربخشی روش پیشنهادی تجزیه و تحلیل می‌شود. نتایج نشان می‌دهد که چارچوب پیشنهادی می‌تواند FOT را به‌طور تطبیقی تشخیص دهد، در عین حال عملکرد پیش‌آگهی قابل انتقال قابل اعتماد را تحت شرایط کاری مختلف ارائه می‌کند.

[۲۰] یک روش جدید برای پیش‌بینی RUL بلبرینگ‌ها ارائه می‌کند که می‌تواند مرحله تخریب را از طریق اندازه‌گیری‌های بدون بُعد ارزیابی کند و از پیش‌بینی بهینه RUL از طریق مدل ردیابی خرابی ترکیبی بهره‌برداری کند. دو اندازه‌گیری جدید شدت ارتعاش بلبرینگ‌ها را با توجه به مقدار ارتعاش معمولی منعکس می‌کند. آن‌ها می‌توانند حساسیت به نقص اولیه بلبرینگ‌ها را بهبود بخشند و نوسانات را کاهش دهند. علاوه بر این، آن‌ها برای تشخیص زمان شروع پیش‌بینی و تعیین آستانه شکست بدون بُعد مفید هستند. طبقه‌بندی کننده SVM برای ارزیابی مرحله خرابی بلبرینگ استفاده می‌شود، که به دلیل قابلیت تعمیم عالی و پایه ریاضی، دقت طبقه‌بندی بالایی را نشان می‌دهد. به‌عنوان ورودی، اندازه‌گیری‌های برازش براساس مدل خرابی تعمیم‌یافته برای آموزش طبقه‌بندی کننده SVM استفاده می‌شود. به‌عنوان خروجی، پنج مرحله خرابی تعریف شده است. با این حال، اندازه‌گیری‌های واقعی به‌عنوان ورودی در فرآیند پیش‌بینی استفاده می‌شود. با توجه به نتایج طبقه‌بندی، یک مدل ردیابی خرابی ترکیبی برای بهره‌برداری از پیش‌بینی بهینه RUL با ردیابی فرآیند خرابی بلبرینگ‌ها استفاده می‌شود.

انواع روش‌های مبتنی بر داده برای پیش‌بینی RUL جزء کلیدی برای بلبرینگ‌های غلتکی پیشنهاد شده‌اند. دقت مدل پیش‌بینی RUL مبتنی بر داده تا حد زیادی به روش استخراج ویژگی‌های خرابی عملکرد بستگی دارد. ناهمگونی فردی و تفاوت شرایط کاری بلبرینگ‌های غلتکی منجر به منحنی‌های مختلف کاهش عملکرد بلبرینگ‌های غلتکی می‌شود که منجر به عدم تطابق بین مدل پیش‌بینی RUL ایجاد شده توسط بلبرینگ‌های غلتکی آموزشی و بلبرینگ‌های غلتکی آزمایشی می‌شود. اگر مشخصه‌ای یافت شود که بتواند منحنی کاهش عملکرد هر بلبرینگ را منعکس کند و نشانگر را برای تعیین گره و فاصله قابل پیش‌بینی دوره کاهشی ارائه دهد، دقت مدل

پیش‌بینی RUL بهبود می‌یابد. برای حل این مشکل، یک روش استخراج ویژگی جدید مبتنی بر روش مبتنی بر داده، یعنی روش مشتق منحنی برازش حداکثر چگالی طیف توان (FDMPD)، برای استخراج ویژگی‌های تخریب عملکرد بلبرینگ‌های غلتکی یکسان یا مشابه از داده‌های نظارت در مقاله [۲۱] مورد استفاده قرار گرفت. FDMPD می‌تواند منحنی‌های ویژگی تخریب عملکرد چرخه عمر را ایجاد کند، که روندی یکسان را برای بلبرینگ‌های مختلف دنبال می‌کند. این منحنی‌ها نقطه شروع بلبرینگ‌ها برای ورود به دوره انحطاط را تعریف می‌کنند و مرحله کار بلبرینگ‌ها را به سه بخش تقسیم می‌کنند:

مرحله اولیه: بلبرینگ‌ها در این مرحله عملکرد خوبی دارند و هیچ نشانه‌ای از خرابی ندارند.

مرحله انحطاط: بلبرینگ‌ها در این مرحله شروع به خرابی می‌کنند و عملکرد آن‌ها کاهش می‌یابد.

مرحله خرابی: بلبرینگ‌ها در این مرحله از کار افتاده‌اند و باید تعویض شوند.

بر اساس این منحنی‌ها، ماشین یادگیری افراطی (KELM) می‌تواند برای ایجاد یک مدل جدید پیش‌بینی RUL از بلبرینگ‌ها استفاده شود. این مدل جدید می‌تواند به طور مؤثر پیش‌بینی RUL بلبرینگ‌ها را انجام دهد. برای تأیید اعتبار این مدل، کل داده‌های چرخه عمر بلبرینگ‌ها مورد استفاده قرار می‌گیرند. نتایج تجربی نشان می‌دهند که مدل پیش‌بینی RUL ایجاد شده می‌تواند با دقت بالایی RUL بلبرینگ‌ها را پیش‌بینی کند. این مدل همچنین از مزایای سرعت، پایداری و کاربرد برخوردار است.

مقاله [۲۲] از CNN در تخمین RUL بلبرینگ‌ها، به عنوان یک مسئله پیش‌آگهی، برای یادگیری در مورد رفتار تخریب غیرخطی با توجه به داده‌های ارتعاش خام و یک برجسب استخراج شده استفاده می‌کند. به جای استفاده از تکنیک CNN برای انجام پیش‌بینی سری زمانی، کارکرد اصلی مدل CNN در این مقاله آشکار کردن وابستگی‌های پنهان بین داده‌های آموزشی ارتعاش و شاخص خرابی بلبرینگ است، که از مزایای کامل CNN در استخراج خودکار ویژگی‌ها استفاده می‌کند.

پیش‌بینی دقیق RUL یک مشکل حیاتی و چالش‌برانگیز در زمینه پیش‌بینی و مدیریت سلامت (PHM) بوده است که هدف آن تصمیم‌گیری در مورد اینکه کدام جزء نیاز به تعویض دارد، است. در مقاله [۲۳]، یک شبکه عصبی مصنوعی عمیق جدید به نام شبکه حافظه بلندمدت کوتاه‌مدت مبتنی بر پیچش (CLSTM) برای پیش‌بینی RUL ماشین‌آلات دوار با استخراج داده‌های ارتعاش درجا پیشنهاد شده است. برخلاف تحقیقات قبلی که به سادگی یک شبکه عصبی کانولوشنال (CNN) را به یک شبکه حافظه طولانی‌مدت کوتاه‌مدت (LSTM) به صورت سری متصل می‌کند، شبکه پیشنهادی عملیات کانولوشن را هم روی انتقالات ورودی به حالت و حالت به حالت LSTM انجام می‌دهد که هر دو حاوی اطلاعات زمان-فرکانس و زمانی سیگنال‌ها، نه تنها حفظ مزایای LSTM، بلکه ویژگی‌های زمان-فرکانس را نیز در بر می‌گیرد. ساختار کانولوشنال در LSTM توانایی ضبط وابستگی‌های طولانی‌مدت و استخراج ویژگی‌ها از حوزه زمان-فرکانس را به طور همزمان دارد. با چیدن CLSTM چندگانه لایه به لایه و تشکیل یک معماری رمزگذاری-پیش‌بینی، مدل یادگیری عمیق برای پیش‌بینی RUL در این مقاله ایجاد شده است. آزمایش‌های خرابی تا خرابی روی یاتاقان‌ها انجام می‌شود و پاسخ‌های ارتعاشی جمع‌آوری می‌شود. با استفاده از الگوریتم پیشنهادی، RUL پیش‌بینی می‌شود و به عنوان مقایسه، عملکرد روش‌های دیگر، از جمله CNN‌های عمیق و LSTM عمیق، با استفاده از همان مجموعه داده ارزیابی می‌شود. مطالعه مقایسه‌ای نشان می‌دهد که شبکه CLSTM پیشنهادی عملکرد بهتری نسبت به الگوریتم‌های یادگیری عمیق فعلی در پیش‌بینی RUL و پیش‌آگاهی سیستم با توجه به دقت و کارایی محاسباتی بهتر دارد.

در سیستم‌های میکاترونیکی، بلبرینگ یکی از اجزای مکانیکی پر کاربرد است و خرابی آن می‌تواند منجر به حوادث جدی و خسارات اقتصادی سنگین شود. بنابراین، پیش‌بینی RUL بلبرینگ بسیار ضروری است. برای پیش‌بینی دقیق RUL بلبرینگ، یک نوع جدید از

شبکه عصبی بازگشتی گیت‌دار با گیت‌های توجه دوگانه، به نام واحد توجه دوگانه گیت‌دار (GDAU)، در [۲۴] ارائه شده است. با استفاده از داده‌های ارتعاش چرخه عمر به دست آمده از یک بلبرینگ، سریه‌ای از میانگین مربعات ریشه (RMS) در لحظات زمانی مختلف به عنوان بردار HI محاسبه می‌شود. سپس، دنباله HI مورد نظر توسط GDAU بر اساس بردار HI موجود پیش‌بینی و سپس RUL بلبرینگ برآورد می‌شود. نتایج آزمایشگاهی نشان می‌دهد که GDAU پیشنهادی می‌تواند به طور مؤثری RUL بلبرینگ‌ها را پیش‌بینی کند و دقت پیش‌بینی و سرعت همگرایی بالاتری نسبت به روش‌های پیش‌بینی متعارف دارد.

پیش‌بینی RUL یک موضوع داغ در زمینه تعمیر و نگهداری پیشگیرانه است که به جلوگیری از خرابی‌های غیرمنتظره و بهبود قابلیت اطمینان کمک می‌کند. رفتارهای مختلف خرابی بلبرینگ ناشی از حالت‌های خرابی متعدد ممکن است منجر به توزیع ناهمگونی ویژگی‌ها شود که بر عملکرد مدل پیش‌بینی تأثیر می‌گذارد. برای پیش‌بینی دقیق RUL بلبرینگ در شرایط مختلف خرابی، یک شبکه عصبی کانولوشنال قابل انتقال (TCNN) برای یادگیری ویژگی‌های تغییرناپذیر پیشنهاد شده است. در روش پیشنهادی [۲۳]، از یک شبکه عصبی کانولوشنال برای استخراج ویژگی‌های تخریب استفاده می‌شود. سپس، چندین اختلاف میانگین بیشینه هسته در هدف بهینه‌سازی گنجانده شده است تا توزیع ناهمگونی کاهش یابد. TCNN آموزش دیده را می‌توان با تغذیه داده‌ها برای پیش‌بینی RUL استفاده کرد. اثربخشی آن با استفاده از مجموعه داده خرابی بلبرینگ تأیید می‌شود. عملکرد سازگاری دامنه را به طور مؤثر بهبود می‌بخشد و عملکرد پیش‌بینی RUL بهتری را به دست می‌آورد.

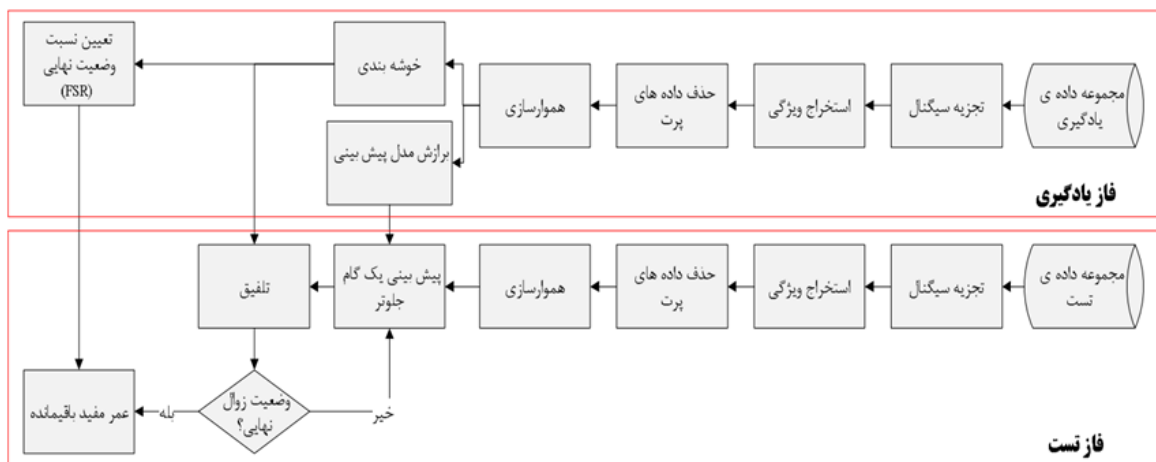
بلبرینگ یک جزء کلیدی در ماشین‌های دوار است که پیش‌بینی RUL آن یک مسئله ضروری در ایجاد سیستم نگهداری مبتنی بر شرایط (CBM) است. با این حال، رویکردهای مبتنی بر داده اخیر برای پیش‌بینی RUL یاتاقان هنوز به دانش قبلی برای استخراج ویژگی‌ها، ایجاد شاخص سلامت و تنظیم آستانه نیاز دارد که در عصر داده‌های بزرگ ناکارآمد است. در مقاله [۲۵]، یک روش مبتنی بر داده خالص برای پیش‌بینی RUL یاتاقان با دانش اولیه کم ارائه شده است. این روش شامل سه مرحله است: استخراج ویژگی‌ها، پیش‌بینی HI و محاسبه RUL. در مرحله اول، پنج مقدار انرژی باندگذر طیف فرکانس به عنوان ویژگی استخراج می‌شوند. سپس، یک شبکه عصبی بازگشتی مبتنی بر چارچوب رمزگذار-رمزگشا با مکانیسم توجه برای پیش‌بینی مقادیر HI پیشنهاد می‌شود که به طور نزدیک با مقادیر RUL در این مقاله طراحی شده است. در نهایت، مقدار نهایی RUL را می‌توان از طریق رگرسیون خطی به دست آورد. آزمایش‌های انجام شده روی مجموعه داده از PRONOSTIA و مقایسه با سایر رویکردهای جدید نشان می‌دهد که روش پیشنهادی عملکرد بهتری را ارائه می‌دهد.

در مقاله [۲۶]، دو روش یادگیری عمیق برای پیش‌بینی RUL بلبرینگ‌ها ارائه شده است. این روش‌ها دارای ویژگی انتها به انتها هستند که داده‌های خام را به عنوان ورودی می‌گیرند و RUL پیش‌بینی شده را مستقیماً تولید می‌کنند. این روش‌ها TSMC-CNN و TSMC-CNN-ALSTM هستند که به ترتیب مخفف شبکه عصبی کانولوشنال چند کاناله سری زمانی و TSMC-CNN یکپارچه با شبکه حافظه طولانی-کوتاه مدت هستند. روش‌های پیشنهادی یک سری زمانی را به چندین کانال تقسیم می‌کنند و از شبکه عصبی کانولوشنال (CNN)، شبکه LSTM و مکانیسم مبتنی بر توجه برای افزایش عملکرد استفاده می‌کنند. CNN برای استخراج ویژگی‌ها از داده‌های با چندین کانال به خوبی عمل می‌کند. تقسیم یک سری زمانی به چندین کانال به CNN کمک می‌کند تا رابطه بین نقاط داده را استخراج کند. شبکه LSTM برای پردازش داده‌های زمانی عالی است. مکانیسم مبتنی بر توجه به شبکه LSTM اجازه می‌دهد تا برای دقت پیش‌بینی بهتر، روی ویژگی‌های مختلف در مراحل زمانی مختلف تمرکز کند. مجموعه داده‌های عملکرد بلبرینگ

PRONOSTIA برای ارزیابی و مقایسه عملکرد روش‌های پیشنهادی اعمال می‌شود. نتایج مقایسه نشان می‌دهد که روش‌های پیشنهادی از نظر میانگین خطای مطلق (MAE) و میانگین مربعات ریشه (RMSE) پیش‌بینی RUL، عملکرد بهتری نسبت به سایر روش‌ها دارند. ساختار این مقاله به شرح زیر است. بخش دوم چارچوب پیشنهادی پیش‌بینی RUL را با جزئیات فنی ارائه می‌کند. در بخش سوم، نتایج تجربی حاصل از آزمایش‌های تخریب بلبرینگ انجام می‌شود. در نتیجه، عملکرد چارچوب پیشنهادی تایید می‌شود و نتایج نشان‌دهنده بهبود دقت در پیش‌بینی RUL در مقایسه با هشت رویکرد پیشرفته و دو روش آزمایش طراحی شده در این مقاله است. بخش چهارم خلاصه‌ای از مقاله و بحث در مورد کارهای آینده ارائه می‌دهد.

آموزش شاخص تخریب و الگوریتم پیش‌بینی RUL

روش پژوهش حاضر مبتنی بر روش تحقیق صورت گرفته در پژوهش [۲۷] انجام می‌شود. شکل چارچوب روش مرجع برای به‌دست آوردن تقریبی عمر مفید باقیمانده تجهیز را نمایش می‌دهد. مطابق با این شکل، فرآیند تخمین عمر مفید باقیمانده در دو فاز انجام می‌شود: فاز آزمایش و فاز یادگیری.



شکل ۱: مدل پژوهش [۲۷].

فاز یادگیری

در این بخش فاز یادگیری روش مرجع را توضیح می‌دهیم:

تجزیه سیگنال

در گام اول از تعیین شاخص سلامت، با استفاده از تبدیل گسسته موجک (DWT) سیگنال‌های ارتعاشات حذف می‌شود و همچنین مورد تجزیه قرار می‌گیرد. در تحقیقات گذشته، به‌کارگیری تقریب سوم (A3) تا پنجم (A5) موجک دایشز چهار (D4) برای تحلیل سیگنال ارتعاشات پیشنهاد شده است [۲۸]. همچنین در پژوهش پایه تقریب چهارم (A4) موجک D4 به کار رفته است.

¹ Discrete Wavelet Transform

استخراج ویژگی

در گام دوم تعیین شاخص سلامت، آن دسته از ویژگی‌هایی از ارتعاشات استخراج می‌شود که بتوانند نماینده خوبی برای نمایش وضعیت زوال باشند. ویژگی‌های جذر میانگین مربعات و کشیدگی بیشتر از سایر ویژگی‌ها جهت تحلیل سیگنال‌های ارتعاش استفاده می‌شوند [۱۳]. از کاستی‌های این دو ویژگی، به‌ویژه جهت تخمین عمر مفید باقیمانده، می‌توان به رفتار نوسانی شدید آن‌ها اندکی پیش از خرابی کامل اشاره کرد. پژوهش‌گران جهت رویارویی با این مسئله از ویژگی آر.ام.اس-آنتروپی (RMSE) استفاده کردند [۲۹]:

$$RMSE = \frac{1}{n} \sum_{i=1}^n -RMS(i) \log(RMS(i)) \quad (1)$$

در پژوهش [۲۷] از ویژگی جدید پیشنهادی جدیدی به نام KURTOSISE (Entropy Kurtosis) برای طراحی مدل روند زوال به کار رفته است (رابطه (۲)). نزدیکی مقیاس این ویژگی برای نمونه‌های مختلف (به‌عنوان مثال پاتاقان‌های مختلف) مزیت استفاده از کشیدگی به جای جذر میانگین مربعات است.

$$KURTOSISE = \frac{1}{n} \sum_{i=1}^n Kurtosise(i) \log(Kurtosise(i)) \quad (2)$$

حذف داده‌های پرت و هموارسازی

در آخرین گام تعیین شاخص سلامت، پژوهش [۲۷] از فیلتر همپل^۱ و فیلتر میانگین متحرک جهت پاک کردن داده‌های پرت و سهولت مسیر ویژگی استفاده شد. فیلتر همپل داده‌های پرت را شناسایی و پاک می‌کند. این فیلتر برای هر نمونه سری زمانی، میانه کل نمونه و میانه شش داده اطراف هر داده (سه داده در هر طرف) را به دست می‌آورد. قابل ذکر است انحراف استاندارد هر نمونه را با استفاده از انحراف مطلق از میانه محاسبه می‌کند. اگر اختلاف میان یک نمونه تا میانه اطراف آن، بیش از سه انحراف معیار باشد، با آن میانه جایگزین می‌شود [۳۰]:

$$y_s(i) = \frac{1}{2N+1} (y(i+N) + y(i+N-1) + \dots + y(i-N)) \quad (3)$$

به طوری که $y_s(i)$ مقدار هموار شده i امین داده، N تعداد داده‌های مجاور در هر سمت $y(i)$ و $2N+1$ محدوده در نظر گرفته شده است.

خوشه‌بندی

جهت تعیین وضعیت زوال، شاخص سلامت، خوشه‌بندی می‌شود. هر خوشه، نشان‌دهنده یکی از وضعیت‌های زوال است. حد پایین خوشه نهایی، با بیشترین مقدار شاخص سلامت، نمایشگر خرابی کامل است و همچنین به‌عنوان آستانه پیش‌بینی در نظر گرفته می‌شود. در این روش، ترکیب داده‌ها برای تعیین وضعیت زوال با احتمال تعلق به هر یک از خوشه‌ها تعیین می‌شود. این احتمال با در نظر گرفتن نزدیکی به مراکز خوشه‌ها به دست می‌آید. بدین منظور از الگوریتم مبتنی بر مرکز C-میانگین فازی استفاده شده است. C-میانگین فازی، یکی از روش‌های خوشه‌بندی است که به هر داده اجازه می‌دهد تا به چندین خوشه با درجات عضویت مختلف تعلق داشته باشد [۳۱].

¹ RMS-Entropy

² Hampel

برازش مدل پیش‌بینی

اخیراً، پیشرفت‌های مهمی در زمینه مدل‌سازی ساختارهای غیرخطی سری‌های زمانی مشاهده می‌شود و بهبودهای قابل توجهی روی روش‌های کلاسیک مدل‌سازی خطی و غیرخطی صورت پذیرفته است [۳۲]. در تحقیق، از مدل مارکوف رژیم سویچینگ خودرگرسیون برای پیش‌بینی شاخص سلامت استفاده می‌شود. این مدل از معروف‌ترین مدل‌های غیرخطی سری‌های زمانی است. قابلیت روش برای تبیین تغییرات رژیم میانگین و نوسان ویژگی‌های مسئله دلیل استفاده از این روش به حساب می‌آید. به‌طور کلی، فرآیند زوال تجهیزات و وقوع خرابی‌هایی نظیر خوردگی، فرسایش، ترک و سایر حالت‌های خرابی بر سطوح مختلف ویژگی، تغییر رژیم در مسیر آن است. یک مدل مارکوف رژیم سویچینگ را می‌توان در حالت کلی به همراه متغیرهای بیرونی و خودرگرسیون به صورت زیر نوشت:

$$y_t = \sum_{i=1}^{N_{S_e}} \beta_i x_{i,t}^{N_{S_e}} + \sum_{j=1}^{N_{S_a}} \alpha_j y_{t-j}^{N_{S_a}} + \sum_{k=1}^{N_{S_e}} \gamma_k x_{k,t}^{S_e} + \sum_{z=1}^{N_{S_a}} \eta_z y_{t-z}^{S_a} + \varepsilon_t \quad (4)$$

برای مطالعه بیشتر به [۳۳] مراجعه شود.

تعیین نسبت وضعیت نهایی

معمولاً شاخص سلامت بعد از گذشت مدتی تغییر رفتار می‌دهد. این تغییر رفتار در نوسان‌های شدید شاخص سلامت مشخص می‌شود و عموماً نشان‌دهنده فرارسیدن زمان خرابی کامل تجهیز است. به همین علت، پیش‌بینی بر اساس مدل‌های خودرگرسیون احتمال دارد در وضعیت نهایی دقیق نباشد. در پژوهش پایه برای برطرف کردن این مشکل، از رابطه بین خوشه نهایی و زمان اجرا تا خرابی استفاده شد؛ که نسبت وضعیت نهایی (Final State Ratio; FSR) نامیده می‌شود. با فرض تکرار الگوی وضعیت‌های زوال در داده‌های از پیش ثبت شده (داده‌های یادگیری) برای آینده، نسبت وضعیت نهایی به صورت زیر تعریف می‌گردد:

$$FSR = \frac{t_{End} - t_{FS}}{t_{End}} \quad (5)$$

به طوری که t_{End} زمان اجرا تا خرابی و t_{FS} زمان ورود به خوشه آخر است. در فاز یادگیری، نسبت وضعیت نهایی برای هر بلبرینگ محاسبه می‌گردد و برای پیش‌بینی مدت زمان خوشه نهایی مورد استفاده واقع می‌شود.

فاز آزمایش

در آزمایش، عمر مفید باقیمانده برای هر یک از بلبرینگ‌ها تقریب زده می‌شود. به همین دلیل، شاخص سلامت، همانند فاز یادگیری برای بلبرینگ تقریب زده می‌شود. بعد از آن وضعیت زوال با پیش‌بینی شاخص سلامت به دست آمده از ارتعاش حسگر افقی و عمودی و تلفیق آنها تعیین می‌شود. این سیکل ادامه خواهد یافت تا به خوشه نهایی برسد.

پیش‌بینی یک گام جلوتر

در این مرحله، با فرض اینکه به عنوان زمان فعلی، شاخص سلامت تجهیز آزمایش با استفاده از مدل‌هایی که در فاز یادگیری برازش شده‌اند برای شبیه‌سازی می‌شود.

تلفیق

دمپستر تئوری ریاضی شواهد را ارائه نمود و شفر آن را توسعه داد [۳۴]. از مهم‌ترین نتایج این نظریه تلفیق باورهای موجود درباره یک حالت و یا حالاتی از یک سیستم است. نظرها در مورد رویدادها از دید افراد مختلف یکسان نیست اما با کمک این نظریه می‌توان

شواهد موجود را ترکیب نمود. در مجموع، هدف از ادغام اطلاعات به دست آمده از منابع مختلف، ساده سازی و کاهش داده های حجیم است که از منابع چندگانه به دست می آید.

تخمین RUL

پس از تعیین وضعیت (خوشه) HI پیش بینی شده با استفاده از روش تلفیق، اگر HI در خوشه پایانی وارد شده باشد، RUL با استفاده از معادله زیر محاسبه می شود:

$$RUL = TT + (t_{End} - t_{FS}) = TT + \left(\frac{t_{FS} FSR}{1 - FSR} \right) \quad (6)$$

که TT مدت زمان تا ورود به خوشه نهایی است.

روش پیشنهادی مبتنی بر الگوریتم ژنتیک

همان طور که می دانیم الگوریتم ژنتیک با نماد GA روشی برای جستجو در علوم رایانه به منظور پیدا کردن راه حل تقریبی مسائل بهینه سازی و جستجو است و نوع خاصی از الگوریتم های هوش جمعی محسوب می شود. GA از مفاهیمی در زیست همچون جهش و وراثت بهره می گیرد. الگوریتم ژنتیک از فنون برنامه نویسی در هوش مصنوعی به حساب می آید و از تکامل ژنتیکی به شکل الگویی برای حل مسئله بهره برداری می کند. هر مسئله مورد بررسی دارای ورودی های است؛ که از یک فرایندی الگوبرداری شده از تکامل ژنتیکی به راه حل ها می رسد و در ادامه راه حل ها به صورت نامزدها با استفاده از تابع برازش ارزیابی می شوند و در صورت فراهم شدن شرط خروج مسئله الگوریتم پایان می پذیرد. این الگوریتم به طور کلی الگوریتمی تکرارشونده است؛ که غالب بخش های آن به شکل تصادفی انتخاب می شوند. گونه هایی از جمعیت فعلی ادامه نسل دارند که بهترین خصوصیات را بر طبق قانون انتخاب طبیعی داشته باشند و گونه های فاقد این خصوصیات در طی زمان به تدریج از بین می روند. از ترکیب کروموزوم های بهتر، نسل های بهتری پدید خواهد آمد. برخی مواقع جهش هایی در کروموزوم ها نیز پیش می آید؛ که امکان بهتر شدن نسل بعد فراهم می شود. حل مسائل در الگوریتم ژنتیک همچنین با استفاده از این ایده عملی می شود. با توجه به روال الگوریتم ژنتیک الگوریتم پیشنهادی را معرفی و تفسیر می کنیم؛ البته قبل از آن به معیار ارزیابی که همان تابع برازندگی است می پردازیم:

معرفی تابع برازندگی

برای ارزیابی هر راه حل یا همان ترکیب ویژگی ها از معیار صحت برای کروموزوم استفاده می شود:

$$RMSE_{RUL} = \sqrt{\frac{\sum_{i=1}^n (RUL_i^{Predicted} - RUL_i^{Real})^2}{n}} \quad (7)$$

که در این رابطه $RUL_i^{Predicted}$ عمر مفید باقیمانده تخمینی نمونه i ام است که توسط که توسط الگوریتم به دست آمده و n تعداد نمونه ها در دادگان است. RUL_i^{Real} مقدار عمر مفید باقیمانده واقعی است.

معرفی جواب های مسئله به عنوان کروموزوم

چندین جواب در ابتدای کار الگوریتم ژنتیک به طور تصادفی برای مسئله تولید می شود. به این مجموعه جواب جمعیت اولیه اطلاق می شود و هر جواب در ژنتیک یک کروموزوم نامیده می شود. با ترکیب کروموزوم های بهتر با استفاده از عملگرهای الگوریتم ژنتیک و

ایجاد جهش در آن‌ها جمعیت جدید ایجاد می‌شود. در انتها جمعیت فعلی، با جمعیت جدید حاصل از تقاطع و جهش کروموزوم‌ها ترکیب می‌شود.

این قسمت وظیفه ترکیب ویژگی‌ها در الگوریتم پیشنهادی را دارد. از الگوریتم ژنتیک برای دستیابی به بهترین ترکیب ویژگی‌ها در روش پیشنهادی جهت رسیدن به جواب نزدیک به بهینه استفاده شده است. هر کروموزوم در الگوریتم پیشنهادی از تعدادی اعداد تشکیل شده است؛ که حاکی از نوع تبدیل گسسته موجک (شامل ۳۰ نوع موجک)، تقریب مورد استفاده (هشت دسته)، نوع ویژگی (شش نوع ویژگی)، فیلتر حذف داده‌های پرت و هموارسازی (چهار فیلتر)، تعداد خوشه‌ها (دو تا پنج) و نوع روش پیش‌بینی (سه روش) خواهد بود.

ایجاد جمعیت اولیه

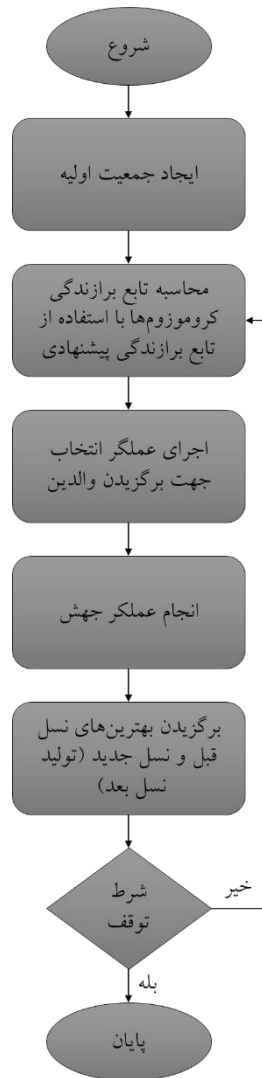
جمعیت اولیه در الگوریتم ژنتیک یعنی اینکه ما تعدادی جواب مسئله داریم و از آنجایی که ما یک کروموزوم را در واقع یک جواب می‌دانیم در نتیجه در این گام تنها لازم است چندین کروموزوم یا ذره ساخته شود. یکی از مهم‌ترین نکات در این گام این است که این جمعیت کاملاً تصادفی ایجاد می‌شود.

معرفی عملگرهای انتخاب در ژنتیک

برای انتخاب کروموزوم‌ها، روش‌های مختلفی در الگوریتم‌های ژنتیک وجود دارند که معمول‌ترین آن‌ها انتخاب Elitist (انتخاب مناسب‌ترین عضو هر اجتماع)، انتخاب Roulette (انتخاب هر عنصر بر اساس احتمال تجمعی گرفته‌شده از عدد برآزش)، انتخاب Scaling (انتخاب بر اساس عدد برآزش وقتی تفاوت‌های کوچکی بین کروموزوم‌هاست)، انتخاب Tournament (انتخاب با استفاده از رقابت بین اعضای مجموعه‌ها)، انتخاب Hierarchical، انتخاب Steady-State و انتخاب Rank.

معرفی عملگرهای تولید مثل در ژنتیک

ترکیب یا تقاطع اساسی‌ترین و مهم‌ترین مرحله در الگوریتم ژنتیک است. هر جفت والد با هم ترکیب خواهند شد و یک فرزند جدید به وجود می‌آید. نقطه ترکیب به صورت تصادفی در میانه ژن‌ها انتخاب می‌شود. فرزندان با جابه‌جایی ژن‌های والدین به وجود می‌آیند. این جابه‌جایی از ابتدای ژن‌ها تا نقطه ترکیب به شکل متناظر صورت می‌پذیرد و فرزندان جدید به جمعیت افزوده خواهند شد. پس از شکل‌گیری فرزندان برخی از ژن‌های درون آن‌ها دچار جهش خواهند شد که احتمال تصادفی بودن این جهش معمولاً کم در نظر گرفته می‌شود. ایجاد تمایز و تنوع بین جمعیت و جلوگیری از همگرایی زودرس جمعیت به یک پاسخ خاص هدف اصلی جهش عنوان شده است. خلاصه الگوریتم GA پیشنهادی در فلوچارت شکل قابل مشاهده است.



شکل ۲: فلوجارت روش پیشنهادی بر پایه الگوریتم ژنتیک.

نتایج تحقیق

داده‌های پلتفرم پرونوستیا

پرونوستیا (PRONOSTIA) یک پلتفرم آزمایشگاهی است که برای تست و راستی آزمایی شناسایی خرابی بیرینگ و رویکردهای تشخیص و پیش‌بینی عیوب تهیه شده است. این پلتفرم در دپارتمان A انستیتوی FEMTO-ST طراحی شده است. هدف اصلی پرونوستیا، تهیه کردن داده‌های عمر واقعی است که فرآیند زوال بیرینگ را در کل طول عمر آن، یعنی تا خراب شدن کلی آن، توصیف نماید. پلتفرم پرونوستیا انجام آزمایش‌های عملیات تا خرابی را ممکن می‌سازد. برای پرهیز از انتشار خرابی به کل بستر آزمون (و به دلایل ایمنی)، زمانی که بزرگی ارتعاش سیگنال از ۲۰g تجاوز نماید، متوقف می‌شود. شکل ۶ مثالی از آنچه قبل و بعد از خرابی برای بلبرینگ‌ها رخ می‌دهد و همچنین سیگنال خام ارتعاش که طی کل آزمایش گردآوری شده است را نشان می‌دهد. توجه کنید که زوال بیرینگ‌ها

رفتارهای متفاوتی را از خود نشان می‌دهند و در نتیجه منجر به مدت آزمایش‌های متفاوت (تا خرابی) می‌گردد. مجموعه داده گردآوری شده توسط این سامانه، تحت سه شرایط تولید شده است:

- شرایط عملیاتی اول: rpm ۱۸۰۰ و rpm ۴۰۰۰
- شرایط عملیاتی دوم: rpm ۱۶۵۰ و rpm ۴۲۰۰
- شرایط عملیاتی سوم: rpm ۱۵۰۰ و rpm ۵۰۰۰

شش مجموعه داده اجرا تا خرابی برای ایجاد مدل‌های پیش‌بینی (مجموعه داده‌های یادگیری) فراهم شده است و تخمین عمر مفید باقی‌مانده برای ۱۱ بیرینگ دیگر خواسته شده است. سیگنال‌های ارتعاش و دما برای همه اجزای آزمایش جمع‌آوری شده است. هیچ فرضی برای نوع خرابی رخ داده وجود ندارد (هیچ اطلاعاتی درباره ریشه و منشأ زوال: ساچمه‌ها، حلقه داخلی، حلقه خارجی، قفسی و غیره وجود ندارد).

نتایج فاز تست

در فاز تست مقاله [۲۷]، در ابتدا وضعیت زوال بیرینگ، با استفاده از روش خوشه‌بندی تشریح شده، صورت پذیرفته است و سپس شبیه‌سازی مارکوف رژیم سویچینگ خودرگرسیون برای پیش‌بینی TT و عمر مفید باقی‌مانده با توجه به مطالب عنوان شده به دست آمده است. شبیه‌سازی برای ۱۰۰ مسیر (Path) انجام گرفته است و برای هر نقطه از مسیرها، مرحله زوال و TT تعیین شده است. با توجه به تابع توزیع احتمالی به دست آمده از TT‌های پیش‌بینی شده، TT نهایی بر اساس سه سطح برش ۵۰، ۱۰ و ۹۰ درصد به دست آمده است. همچنین برای هر بیرینگ تست، دو مقدار عمر مفید باقی‌مانده با توجه به دو بیرینگ یادگیری مربوطه در هر یک از شرایط محاسبه شده است. برای ارزیابی روش تلفیق پیشنهادی، نتایج به دست آمده در سه حالت مقایسه شده‌اند:

- تعیین عمر مفید باقی‌مانده با در نظر گرفتن سنسور افقی.
- تعیین عمر مفید باقی‌مانده با در نظر گرفتن سنسور عمودی.
- میانگین سنسورهای افقی و عمودی برای تعیین وضعیت زوال.

که در این حالت، به جای تلفیق سنسورهای افقی و عمودی، از مقدار میانگین دو سنسور برای تعیین وضعیت (خوشه) استفاده شده است. نرخ خطا به صورت رابطه زیر تعریف می‌گردد:

$$Er = \frac{RUL_i^{Real} - RUL_i^{Predicted}}{RUL_i^{Real}} 100\% \quad (8)$$

چون بیرینگ ۴-۱ پیش از پیش‌بینی به وضعیت نهایی وارد شده بود، عمر مفید باقیمانده آن از فرمول $\left(\frac{t_{FS} FSR}{1 - FSR} \right)$ محاسبه شده

است. در بیرینگ‌های ۱-۶، ۱-۴، ۱-۳، ۲-۶، ۲-۵، ۲-۴، ۷ و ۲-۷، ویژگی افقی، ویژگی مناسب‌تری برای پیش‌بینی عمر مفید بوده است و می‌توان گفت سهم بیشتری را در توصیف خرابی تجهیز دارد. در سایر بیرینگ‌های تست، ویژگی‌های عمودی عملکرد بهتری را در پیش‌بینی نشان داده‌اند. عمر مفید باقیمانده برای سه بیرینگ ۱-۶، ۱-۵ و ۳-۳ بیش از مقدار واقعی تخمین زده شده است (منفی بودن نرخ خطا)، در حالی که در ۱۲ بیرینگ باقی‌مانده، تخمین عمر کمتر از مقدار واقعی است. استفاده از روش تلفیق سنسورها نقش تعدیل‌کننده‌ای در خطای پیش‌بینی در مقایسه با پیش‌بینی فقط با سنسور افقی و فقط با سنسور عمودی داشته است؛ به عبارت دیگر، در برخی از بیرینگ‌ها تخمین عمر مفید باقیمانده بر اساس ویژگی افقی (بیرینگ‌های ۲-۷، ۲-۶، ۲-۵، ۲-۴، ۱-۶، ۱-۴، ۱-۳) و در برخی دیگر بر اساس ویژگی

عمودی (بیرینگ‌های ۳-۳، ۲-۳، ۱-۷، ۱-۵) دقیق‌تر است. از آنجایی که اطلاعاتی در خصوص فیزیک خرابی وجود ندارد و در نتیجه تصمیم‌گیری درباره انتخاب سنسور (افقی یا عمودی) برای تعیین وضعیت زوال و تعیین عمر مفید باقی‌مانده دشوار است، استفاده از روش تلفیق اطلاعات سنسورها می‌تواند مفید باشد. در نهایت، با در نظر گرفتن ۲۲ مورد پیش‌بینی (۱۰ حالت برای شرایط ۱۰، یک حالت برای شرایط دو و دو حالت برای شرایط سه)، در ۲۰ مورد، روش تلفیق عملکرد بهتری را نسبت به روش میانگین‌گیری از خود نشان داده است. برای ارزیابی روش پیش‌بینی مدل مارکوف رژیم سویچینگ خودرگرسیون، نتایج به‌دست‌آمده توسط این روش با دو روش خودرگرسیون، یعنی روش میانگین متحرک خودرگرسیون (ARMA) و شبکه عصبی خودرگرسیون (ANN)، با توجه به دو معیار امتیاز (SCORE) و خطای جذر میانگین مربعات (RMSE) مقایسه شده است:

$$A_i = \begin{cases} \exp^{-\ln(0.5)\left(\frac{Er_i}{5}\right)} & \text{if } Er_i \leq 0 \\ \exp^{+\ln(0.5)\left(\frac{Er_i}{20}\right)} & \text{if } Er_i > 0 \end{cases} \quad (9)$$

$$SCORE = \frac{1}{n} \sum_{i=1}^n A_i \quad (10)$$

معیار امتیاز به پیش‌بینی‌های بیش از حد، جریمه بیشتری نسبت به پیش‌بینی‌های کمتر از حد تخصیص می‌دهد. فرآیند تعیین پارامترهای خودرگرسیون (AR) و میانگین متحرک (MA) در مدل میانگین متحرک خودرگرسیون، مشابه با مدل مارکوف رژیم سویچینگ خودرگرسیون در فاز یادگیری است. در این فاز، مدل شبکه عصبی خودرگرسیون نیز آموزش داده شده بود. نرخ یادگیری، تعداد لایه‌های پنهان و تعداد نورون‌ها در هر لایه پنهان، برای هر یک از دو بیرینگ یادگیری تنظیم شده است. برای هر بیرینگ تست، نرخ خطای میانگین برای دو بیرینگ یادگیری محاسبه شد. در مقاله [۲۷] روش شبکه عصبی خودرگرسیون، با توجه به معیار امتیاز، عملکرد بهتری نسبت به دو روش دیگر داشت. اما با توجه به معیار خطای جذر میانگین مربعات، عملکرد مدل مارکوف رژیم سویچینگ خودرگرسیون، از عملکرد بهتری نسبت به دو روش دیگر برخوردار بود. در اینجا روش پیشنهادی مبتنی بر الگوریتم ژنتیک را با روش‌های قبلی مقایسه می‌کنیم:

جدول ۱: مقایسه روش پیشنهادی مبتنی بر الگوریتم ژنتیک با روش‌های قبلی

روش پیش‌بینی	امتیاز	خطای جذر میانگین مربعات
مارکوف رژیم سویچینگ	۰/۰۰۸۷۳۵	۲۲۳۳/۹۸
شبکه عصبی خودرگرسیون	۰/۰۱۲۶۲۸	۲۲۷۱/۸۱
روش پیشنهادی	۰/۰۱۳۵۲۱	۲۲۱۰/۰۸

بحث و نتیجه‌گیری

در این مقاله، یک مدل ارزیابی وضعیت زوال و تعیین عمر مفید باقیمانده برای بیرینگ بر مبنای الگوریتم ژنتیک ارائه شد. این مدل از چهار بخش اصلی تشکیل شده است:

- بخش پیش‌بینی شاخص سلامت: در این بخش، از روش مارکوف رژیم سویچینگ خودرگرسیون برای پیش‌بینی شاخص سلامت به‌دست‌آمده از داده‌های ارتعاشات استفاده شده است.

- بخش تعیین وضعیت زوال اولیه تجهیزات: در این بخش، از روش خوشه‌بندی فازی برای تعیین وضعیت زوال اولیه تجهیزات استفاده شده است.
- بخش تلفیق اطلاعات: در این بخش، از یک رویکرد جدید به تئوری دمپستر-شفر برای تلفیق اطلاعات سنسورها استفاده شده است.
- بخش بهینه‌سازی: در این بخش از الگوریتم ژنتیک برای بهبود کارکرد الگوریتم با استفاده از بهینه کردن پارامترهای الگوریتم پایه پرداخته شد.

در روش پیشنهادی، برای تلفیق اطلاعات سنسورها، از هر سنسور به‌عنوان یک شاهد (مرجع) استفاده شده است. احتمال تعلق سیستم به هر یک از وضعیت‌های زوال، بر اساس فاصله شاخص سلامت از مراکز خوشه‌ها تعیین می‌شود. همچنین در این مقاله، شاخص سلامت کرتسیسای مورد استفاده قرار گرفته شد، که توانایی تعدیل نوسانات شدید در آستانه خرابی را دارد. برای ارزیابی مدل، از مجموعه داده‌های انستیتو FEMTO-ST استفاده شد. نتایج ارزیابی و مقایسه نشان داد که روش پیشنهاد شده می‌تواند در مواردی استفاده شود که اطلاعات در مورد فیزیک خرابی وجود ندارد و باید از مدل داده‌محور استفاده شود. همچنین تصمیم‌گیری در مورد وضعیت زوال، با توجه به اطلاعات جداگانه سنسورها، می‌تواند گمراه‌کننده باشد. نتایج روش پیشنهادی این مطالعه عملکرد بهتری را نسبت به روش پایه نشان داد.

مراجع

- [1] H. Spikes, "T. A. Harris, Roller bearings analysis (John Wiley & Sons, Chichester, 1984. £76.70, 580pp)," *Journal of Synthetic Lubrication*, vol. 1, no. 4, pp. 314-315, 1985, doi: <https://doi.org/10.1002/jsl.3000010407>.
- [2] Y. Yuan, H.-T. Zhang, Y. Wu, T. Zhu, and H. Ding, "Bayesian learning-based model-predictive vibration control for thin-walled workpiece machining processes," *IEEE/ASME transactions on mechatronics*, vol. 22, no. 1, pp. 509-520, 2016.
- [3] A. Heng, S. Zhang, A. C. Tan, and J. Mathew, "Rotating machinery prognostics: State of the art, challenges and opportunities," *Mechanical systems and signal processing*, vol. 23, no. 3, pp. 724-739, 2009.
- [4] L. R. Rodrigues, "Remaining useful life prediction for multiple-component systems based on a system-level performance indicator," *IEEE/ASME Transactions on Mechatronics*, vol. 23, no. 1, pp. 141-150, 2017.
- [5] I. V. de Bessa, R. M. Palhares, M. F. S. V. D'Angelo, and J. E. Chaves Filho, "Data-driven fault detection and isolation scheme for a wind turbine benchmark," *Renewable Energy*, vol. 87, pp. 634-645, 2016.
- [6] Z.-Q. Wang, C.-H. Hu, and H.-D. Fan, "Real-time remaining useful life prediction for a nonlinear degrading system in service: Application to bearing data," *IEEE/ASME Transactions on Mechatronics*, vol. 23, no. 1, pp. 211-222, 2017.
- [7] X.-S. Si, W. Wang, C.-H. Hu, and D.-H. Zhou, "Remaining useful life estimation—a review on the statistical data driven approaches," *European journal of operational research*, vol. 213, no. 1, pp. 1-14, 2011.
- [8] J. Wang, P. Fu, L. Zhang, R. X. Gao, and R. Zhao, "Multilevel information fusion for induction motor fault diagnosis," *IEEE/ASME Transactions on Mechatronics*, vol. 24, no. 5, pp. 2139-2150, 2019.
- [9] H. Gao, L. Liang, X. Chen, and G. Xu, "Feature extraction and recognition for rolling element bearing fault utilizing short-time Fourier transform and non-negative matrix factorization," *Chinese Journal of Mechanical Engineering*, vol. 28, pp. 96-105, 2015.
- [10] R. Yan, R. X. Gao, and X. Chen, "Wavelets for fault diagnosis of rotary machines: A review with applications," *Signal processing*, vol. 96, pp. 1-15, 2014.
- [11] Q. Meng and L. Qu, "Rotating machinery fault diagnosis using Wigner distribution," *Mechanical Systems and Signal Processing*, vol. 5, no. 3, pp. 155-166, 1991.
- [12] A. Soualhi, K. Medjaher, and N. Zerhouni, "Bearing health monitoring based on Hilbert–Huang transform, support vector machine, and regression," *IEEE Transactions on instrumentation and measurement*, vol. 64, no. 1, pp. 52-62, 2014.
- [13] Z. Tian, "An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring," *Journal of intelligent Manufacturing*, vol. 23, pp. 227-237, 2012.
- [14] J. Z. Sikorska, M. Hodkiewicz, and L. Ma, "Prognostic modelling options for remaining useful life estimation by industry," *Mechanical systems and signal processing*, vol. 25, no. 5, pp. 1803-1836, 2011.
- [15] G. Hinton *et al.*, "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups," *IEEE Signal processing magazine*, vol. 29, no. 6, pp. 82-97, 2012.

- [32] L. Aguayo and G. A. Barreto, "Novelty detection in time series using self-organizing neural networks: A comprehensive evaluation," *Neural Processing Letters*, vol. 47, pp. 717-744, 2018.
- [33] L. Cui, X. Wang, Y. Xu, H. Jiang, and J. Zhou, "A novel switching unscented Kalman filter method for remaining useful life prediction of rolling bearing," *Measurement*, vol. 135, pp. 678-684, 2019.
- [34] G. Shafer, "A mathematical theory of evidence," in *A mathematical theory of evidence*: Princeton university press, 1976.