

Estimating the Remaining Useful Life of Bearings Using Weibull Function Fitting on IMF

Zahra Talebi, Mortaza H. Sadeghi, Mir Mohammad Ettefagh*

Faculty of Mechanical Engineering, University of Tabriz, Iran

* ettefagh@tabrizu.ac.ir

Abstract

This study proposes a robust methodology for accurately estimating the Remaining Useful Life (RUL) of ball bearings in rotary machinery, which are critical components in many industrial systems. The approach utilizes vibration signal analysis, specifically Empirical Mode Decomposition (EMD), to extract meaningful features. Among the decomposed Intrinsic Mode Functions (IMFs), the one with the highest energy is selected to represent the degradation process. The variance of this selected IMF is modeled using a Weibull distribution to reflect the trend of failure progression. Subsequently, a neural network, particularly the Simplified Fuzzy ARTMAP (SFAM), is trained to predict the remaining life based on the fitted Weibull trend. Finally, exponential smoothing is employed to enhance prediction stability. Experimental results validate the method's effectiveness in tracking degradation and provide accurate RUL estimates under various conditions.

Introduction

Condition monitoring and fault diagnosis, concepts initially derived from medical diagnostics, have found substantial applications in mechanical engineering. With the evolution of technology, particularly in the realm of artificial intelligence (AI) and data analytics, these methodologies have become pivotal in the maintenance of industrial systems. Bearings, being one of the most vital yet vulnerable components in rotating machinery, require continuous monitoring to prevent unexpected failures that may cause costly downtime and safety hazards. Traditional methods rely on predefined thresholds or reactive maintenance, often after initial damage is detected. However, this is inadequate in high-noise environments and where real-time prediction is essential. Hence, recent trends emphasize predictive maintenance using AI models such as Support Vector Regression (SVR), Long Short-Term Memory (LSTM), and Convolutional Neural Networks (CNN), often combined with signal processing techniques

like Hilbert-Huang Transform and EMD. This paper contributes to this domain by presenting a hybrid methodology combining statistical feature extraction, Weibull modeling, and neural network-based classification for robust RUL prediction.

Methodology

The proposed framework begins with vibration signal acquisition from test bearings subjected to various operational loads. These signals are decomposed into IMFs using EMD. IMFs are selected based on their contribution to the total signal energy, specifically focusing on those with the highest ratios. The selected IMF's variance is computed, which serves as an effective degradation indicator. To capture the progression of this degradation over time, the variance trend is modeled using a Weibull distribution. This statistical model allows capturing the non-linear and probabilistic nature of bearing wear. The resulting Weibull-fitted trend is then used to train a SFAM neural network, a structure known for its pattern classification efficiency and adaptability to non-stationary data. Unlike conventional neural networks, SFAM benefits from adaptive fuzzy logic to manage uncertainty in degradation patterns. To further improve the prediction's smoothness and minimize fluctuations, an exponential smoothing function is applied to the model's output, parameterized with a tunable smoothing constant (Z). This combination effectively reduces the influence of environmental noise and provides a more reliable RUL estimate.

Results and Discussion

The methodology was tested on experimental data from the Bearing3_1, Bearing2_1, and Bearing3_3 datasets, each subjected to different loads and operating durations. The IMF variance trends for selected components were accurately modeled using Weibull functions. The SFAM classifier demonstrated high accuracy in categorizing degradation levels and predicting the RUL. Importantly, tuning the exponential smoothing factor significantly impacted prediction quality. For example, with $Z=0.85$, the prediction error dropped to less than 13% in some test cases [9]. Additionally, the comparative results revealed that models using Weibull-fitted data significantly outperformed those trained directly on raw IMF variance values. As shown in Figures 11 to 14, the proposed algorithm closely tracked the actual degradation process and provided accurate lifetime predictions even under high-noise, real-world-like conditions. The improved prediction accuracy is particularly relevant for industrial applications where maintenance planning and operational continuity are critical [9][13][14].

Conclusion

This research successfully introduces a hybrid data-driven approach for estimating the remaining useful life of industrial bearings. By combining EMD-based feature extraction, Weibull modeling, and SFAM neural networks, the method offers improved robustness, noise resilience, and accuracy compared to baseline approaches. The integration of exponential smoothing further enhances prediction consistency. These features make the method suitable for real-time industrial implementation. Future work may focus on dynamically adjusting smoothing parameters and integrating real-time feedback for continuous model adaptation [9][16].

References

- [1] C. Ferreira, G. Gonçalves, Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods, *Journal of Manufacturing Systems*, 63 (2022) 550-562.
- [2] S. Ramezani, A. Moini, M. Riahi, Prognostics and health management in machinery: A review of methodologies for RUL prediction and roadmap, *International Journal of Industrial Engineering and Management Science*, 6(1) (2019) 38-61.
- [4] L. Liao, Discovering prognostic features using genetic programming in remaining useful life prediction, *IEEE Transactions on Industrial Electronics*, 61(5) (2013) 2464-2472.
- [5] T. Benkedjouh, K. Medjaher, N. Zerhouni, S. Rechak, Remaining useful life estimation based on nonlinear feature reduction and support vector regression, *Engineering Applications of Artificial Intelligence*, 26(7) (2013) 1751-1760.
- [7] J. Zhang, P. Wang, R. Yan, R.X. Gao, Long short-term memory for machine remaining life prediction, *Journal of manufacturing systems*, 48 (2018) 78-86.
- [9] J.B .Ali, B. Chebel-Morello, L. Saidi, S. Malinowski, F. Fnaiech, Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network, *Mechanical Systems and Signal Processing*, 56 (2015) 150-172.
- [13] M.Y. Asr, M.M. Ettefagh, R. Hassannejad, S.N. Razavi, Diagnosis of combined faults in Rotary Machinery by Non-Naive Bayesian approach, *Mechanical Systems and Signal Processing*, 85 (2017) 56-7.
- [14] P. Wang, Z. Long, G. Wang, A hybrid prognostics approach for estimating remaining useful life of wind turbine bearings, *Energy Reports*, 6 (2020) 173-182.
- [16] P. Banker, Simplified Fuzzy ARTMAP, in, 2021.

تخمین عمر مفید باقیمانده بلبرینگ با استفاده از برازش تابع ویبول بر روی تابع مود ذاتی

زهرا طالبی^۱، مرتضی-همایون صادقی^۲، میرمحمد اتفاق^{۳*}

دانشکده مهندسی مکانیک، دانشگاه تبریز، تبریز، ایران

* ettefagh@tabrizu.ac.ir

چکیده

بلبرینگ‌ها کاربرد بسیار گسترده‌ای در صنعت دارند و نیاز به تخمین دقیق عمر مفید آن‌ها بسیار حیاتی است. در بسیاری از پژوهش‌های پیشین، تخمین عمر مفید تنها پس از ایجاد خرابی اولیه در بلبرینگ ممکن بوده است، در حالی که شرایط واقعی بهره‌برداری معمولاً همراه با نویز زیاد است و تشخیص عیوب اولیه را بسیار دشوار می‌کند. در این پژوهش، روش جدیدی برای تخمین عمر باقی‌مانده بلبرینگ‌های صنعتی ارائه شده است که با استفاده از توابع مود ذاتی، توانایی تشخیص عیوب در مراحل اولیه بهبود یافته است. در این روش، سیگنال‌های ارتعاشی بلبرینگ ابتدا با استفاده از روشی به نام تجزیه به توابع مود ذاتی تحلیل می‌شوند و یکی از این توابع که بیشترین تأثیر در نمایش روند خرابی و عیب را دارد، با روش پیشنهادی مبتنی بر انرژی انتخاب می‌شود. سپس واریانس آن تابع محاسبه شده و تابع ویبول بر روی آن برازش می‌شود. داده‌های حاصل برای آموزش شبکه عصبی مورد استفاده قرار می‌گیرند و نتایج به کمک هموارسازی نمایی بهبود می‌یابند. ارزیابی این الگوریتم با داده‌های تجربی نشان می‌دهد که مدل به خوبی قادر است روند خرابی بلبرینگ را پیش‌بینی کرده و عمر باقی‌مانده را با دقت مناسب تخمین بزند.

کلمات کلیدی

ماشین دوار، بلبرینگ، عیب‌یابی، عمر مفید، یادگیری ماشین

مفاهیم عیب‌یابی و پیش‌بینی برای اولین بار در دانش پزشکی برای تشخیص بیماری‌ها و پیشگیری آن‌ها مورد استفاده قرار گرفتند؛ بعدها با گسترش دانش این مفاهیم در حوزه‌های دیگری از جمله صنعت نیز راه پیدا کردند و برای مانیتور کردن و نظارت بر سیستم‌های صنعتی مورد استفاده قرار گرفتند. در مهندسی مکانیک، عیب‌یابی بر مساله پیدا کردن عیوب موجود در سیستم‌ها با توجه به رفتار سیستم و ویژگی‌های آن دلالت دارد. در گامی فراتر عیوب تشخیص داده شده و شدت آن‌ها برای تخمین عمر مفید باقیمانده سیستم‌ها و قطعات، مورد استفاده قرار می‌گیرند [۱].

روش‌های مختلفی برای عیب‌یابی و تخمین عمر مفید باقیمانده قطعات و سیستم‌های مکانیکی وجود دارند که می‌توان آن‌ها را به سه دسته کلی روش‌های بر پایه‌ی شبیه‌سازی و مدل‌سازی، روش‌های داده‌محور و روش‌های ترکیبی تقسیم‌بندی کرد. در دهه‌های اخیر با توسعه‌ی تکنولوژی و دانش هوش مصنوعی، استفاده از روش‌های داده‌محور در پایش وضعیت سیستم‌ها، عیب‌یابی و تخمین عمر مفید باقیمانده مورد توجه ویژه‌ای قرار گرفته است و تحقیقات بسیاری در خصوص استفاده از این روش‌های نوین انجام شده است [۲].

با توجه به اینکه بلبرینگ‌ها بخشی از اجزا مهم صنعت هستند و در اغلب سیستم‌های صنعتی و ماشین‌آلات دوار مورد استفاده قرار می‌گیرند به عنوان نمونه اولیه موجود برای ارائه‌ی ایده این پژوهش مورد استفاده قرار می‌گیرند. با در نظر گرفتن اهمیت بلبرینگ‌ها در سیستم‌های صنعتی و خطوط تولید، خرابی آن‌ها می‌تواند باعث ایجاد خسارت‌های بسیار و حتی موجب توقف سیستم‌ها و یا خطوط تولید گردد. لذا؛ تعمیر و نگهداری این قطعات در زمان مناسب نه تنها می‌تواند تاثیر قابل توجهی در جلوگیری از خرابی ناگهانی سیستم‌ها داشته باشد، بلکه استفاده بهینه از این قطعات در بالاترین سطح عملکردشان می‌تواند باعث بهبود عملکرد کل سیستم گردد [۳].

در سال‌های اخیر با توجه به اهمیت موضوع عیب‌یابی و تخمین عمر مفید باقی‌مانده قطعات و همچنین گسترش دانش هوش مصنوعی تحقیقات بسیاری در این خصوص انجام گرفته است [۳] که در ادامه تعدادی از تحقیقات انجام گرفته در این زمینه مورد بررسی قرار می‌گیرند. لینیخیالینائو^۱ [۴] به کمک روش برنامه‌ریزی ژنتیکی الگوریتمی ارائه داد که می‌توانست از ترکیب مشخصه‌های آماری پارامتری را به دست آورد که رشد و تشدید عیوب را به وضوح نشان می‌دادند در حالیکه پارامترهای مورد استفاده قبلی دقت کافی را در نشان دادن تشدید عیوب نداشتند. بنکدجوج^۲ و همکارانش [۵] از روشی دو مرحله‌ای برای تخمین عمر مفید باقی‌مانده استفاده کردند که ترکیبی از دو مرحله آنالیز و آفلاین بود. در این روش ابتدا در مرحله آفلاین مدل‌های تخریب به شبکه‌ی عصبی آموزش داده می‌شد و سپس در مرحله آفلاین با استفاده از الگوهای تخریب آموزش داده شده، وضعیت بلبرینگ و عمر مفید باقیمانده‌ی آن سنجیده می‌شد.

¹ Liao,L.

² Benkedjough

خیولین ونگ^۱ و همکارانش [۶] روشی را با استفاده از مدل گاوسی^۲ و رگرسیون بردار پشتیبان^۳ ارائه دادند که در آن ابتدا فرآیند تخریب به کمک مدل گاوسی شبیه‌سازی شد و از آن برای تعیین آستانه خرابی اولیه استفاده شد سپس با ترکیب رگرسیون بردار پشتیبان و الگوریتم حداقل میانگین مربع مدل مناسب برای تخمین عمر مفید بلبرینگ ساخته شد. شبکه عصبی شبکه عصبی با واحد حافظه بلندمدت کوتاه‌مدت^۴ توسط جیانجینگ^۵ و همکارانش [۷] برای تخمین عمر مفید ماشین‌های دوار مورد استفاده قرار گرفت. احمد زکریایی و همکارانش [۸] روشی بر اساس ترکیبی از شبکه کانولوشنی و شبکه عصبی با واحد حافظه بلندمدت کوتاه‌مدت ارائه دادند. در این روش ابتدا با استفاده از یک لایه کانولوشنی مشخصه‌های محلی مستقیمی از سیگنال‌های به دست آمده از سنسورها استخراج شدند و سپس لایه‌ی شبکه عصبی با واحد حافظه بلندمدت کوتاه‌مدت جهت شبیه‌سازی فرآیند تخریب مورد استفاده قرار گرفته است. سپس عمر مفید باقیمانده به وسیله‌ی خروجی لایه‌ی شبکه عصبی با واحد حافظه بلندمدت کوتاه‌مدت پیش‌بینی می‌شود. جوهر بن علی و همکارانش [۹] برای تخمین عمر مفید باقی‌مانده بلبرینگ‌ها از ترکیب شبکه‌ی عصبی تطبیقی فازی با یادگیری نظارتی و تابع توزیع ویبول استفاده کردند. در این روش سه پارامتر آماری برای آموزش شبکه‌ی عصبی مورد استفاده قرار گرفته‌است. ابتدا تابع توزیع ویبول بر روی پارامترهای آماری محاسبه شده از سیگنال‌های ارتعاشی برازش شده و سپس به منظور آموزش شبکه مورد استفاده قرار گرفته‌اند. در نهایت با استفاده از تابع هموارسازی نتایج به دست آمده از شبکه عصبی برای تخمین عمر مفید بلبرینگ‌ها مورد استفاده قرار می‌گیرد. در تحقیق مشابه دیگری که توسط ژنگ^۶ و همکارانش انجام گرفته [۱۰] تخمین عمر مفید باقیمانده بلبرینگ‌ها با استفاده از ترکیب شبکه‌ی عصبی نایو-بیز^۷ و تابع هموارسازی نمایی صورت گرفته است و همچنین از الگوریتم نایو-بیز برای طبقه‌بندی داده‌های ورودی استفاده نموده‌اند.

در اغلب پژوهش‌های قبلی انجام شده به منظور ارائه‌ی روشی جهت تخمین عمر مفید باقیمانده بلبرینگ‌ها لازم است تا خرابی اولیه‌ی در بلبرینگ اتفاق بیفتد تا مبنای تخمین زمان عمر باقیمانده بلبرینگ قرار گیرد [۲] در حالیکه ممکن است در عمل و خارج از محیط آزمایشگاهی این خرابی اولیه به قدری ناچیز باشد که عوامل محیطی مانند نویز یا تاثیر سیگنال سایر قطعات بر روی سیستم مانع از آشکار شدن این عیب اولیه شوند. در روش مورد استفاده در این پژوهش از استخراج توابع مود ذاتی و برازش تابع ویبول بر آن‌ها برای افزایش کیفیت داده‌های آموزش شبکه‌های عصبی استفاده شده‌است که در تحقیقات قبلی مورد استفاده قرار نگرفته‌است. ابتدا توابع مود ذاتی سیگنال ارتعاشی استخراج می‌شوند و سپس با استفاده از روشی بر پایه‌ی انرژی، تابع مود ذاتی که دارای بیشترین نسبت انرژی به انرژی کل سیگنال می‌باشد انتخاب می‌شود. بدین صورت تاثیر نویزهای محیطی و سایر عوامل خارجی حذف می‌گردد. همچنین شبکه‌ی عصبی مورد استفاده در این پژوهش سیگنال‌های به دست آمده را بدون نیاز به خرابی اولیه در چند سطح طبقه‌بندی می‌کند که هریک

¹ Wang,X.

² Gaussian

³ Support Vector Regression (SVR)


⁴ Long Short-Term Memory (LSTM)

⁵ Zhang,J.

⁶ Zhang,N.

⁷ Naïve Bayes

از آن‌ها درصد خرابی بلبرینگ در آن مرحله را نشان می‌دهد. در آخر با استفاده از تابع هموارسازی نمایی روند خرابی بلبرینگ و عمر مفید باقیمانده آن محاسبه می‌گردد. فلوچارت شکل (۱) روند پردازش اولیه داده‌ها را به ترتیب نشان می‌دهد



شکل ۱- فلوچارت مراحل روش ارائه شده در این پژوهش

Figure 1- Flowchart illustrating the steps of the method presented in this research.

۲- پردازش اولیه سیگنال ارتعاشی

۲-۱ استخراج تابع مود ذاتی^۱ مناسب با استفاده از روش تجزیه‌ی تجربی^۲


روش‌های پردازش سیگنال کلاسیک، آن‌ها را بر اساس خطی بودن و پایداری در دامنه‌های زمان و فرکانس مورد ارزیابی قرار می‌دهند. در حالیکه سیگنال‌های به دست آمده از ماشین آلات دوار طبیعتی غیرخطی و ناپایدار دارند و نتایج به دست آمده از روش‌های کلاسیک برای پردازش این سیگنال‌ها به نتایج غیرواقعی و اشتباه منتج می‌گردد [۱۱]. رویکردهای متنوعی برای پردازش سیگنال‌های غیرخطی و ناپایدار وجود دارد که روش EMD یکی از قدرتمندترین روش‌ها برای پردازش چنین سیگنال‌هایی می‌باشد. این روش سیگنال‌های غیرخطی و ناپایدار را به اجزای ارتعاشی و متعامد تجزیه می‌کند که تحت عنوان تابع مود ذاتی شناخته می‌شوند و هریک از آن‌ها می‌توانند بخشی از ویژگی‌های فیزیکی و رفتاری سیستم را نشان دهند [۱۲]. استخراج توابع مود ذاتی یک سیگنال، که اصطلاحاً فرآیند غربال نامیده می‌شود، براساس این فرض‌ها انجام می‌گیرد که: (۱) هر سیگنال از تعدادی اجزای اصلی تشکیل شده است که دارای ویژگی‌های

^۱ Intrinsic Mode Function (IMF)

^۲ Empirical Mode Decomposition (EMD)

ذاتی سیگنال اصلی هستند. (۲) هر سیگنال خطی و غیرخطی حداقل باید دارای یک نقطه ماکزیمم و یک نقطه مینیموم باشد. (۳) در صورتی که سیگنال مورد بررسی نقاط اکسترمم نداشته و فقط نشان دهنده نقاط عطف باشد، می‌توان با مشتق‌گیری دوباره یا چندباره نقاط اکسترمم را ظاهر کرد. (۴) سیگنال بین نقاط اکسترمم آن تعریف می‌گردد. بعلاوه، توابع مود ذاتی استخراج شده باید دارای دو ویژگی مهم باشند: (۱) تعداد نقاط اکسترمم و نقاطی که در آن سیگنال خط محور صفر را قطع می‌کند باید برابر بوده و یا حداکثر فقط یک عدد اختلاف داشته باشند. (۲) در هر شرایطی مقدار میانگین منحنی پوش بالایی و پوش پایینی باید صفر باشد [۱۳].

به منظور ادامه روند پژوهش و اعمال الگوریتم پیشنهادی بر روی داده‌های واقعی، داده‌های به دست آمده از یک مجموعه آزمایشگاهی مورد استفاده قرار می‌گیرد. در این فرآیند داده برداری، سیگنال‌های ارتعاشی مربوط به ۱۵ بلبرینگ ساچمه‌ای ساده از لحظه‌ی شروع به کار تا خرابی کامل تحت سه حالت بارگذاری مختلف جمع‌آوری شده‌اند [۱۴]. مشخصات فیزیکی بلبرینگ‌ها در جدول (۱) نوشته شده‌است. شکل (۲) ستاپ آزمایشگاهی مورد استفاده برای داده‌برداری را نشان می‌دهد. در این پژوهش سیگنال‌های ارتعاشی مربوط به بلبرینگی که بیش‌ترین طول عمر را نسبت به سایر بلبرینگ‌ها داشته‌است (Bearing3_1) جهت آموزش شبکه‌ی عصبی مورد استفاده قرار گرفته‌است. جدول (۲) مشخصات داده‌های مورد استفاده را نشان می‌دهد.



شکل ۲- ستاپ آزمایشگاهی استفاده شده جهت داده‌برداری

Figure 2 - Utilized setup for data collection

جدول ۱- مشخصات بلبرینگ‌های استفاده شده

Table 1- Specifications of the Bearings Used


مقدار	پارامتر	مقدار	پارامتر
۳۹/۸۰ mm	قطر رینگ بیرونی	۲۹/۳۰ mm	قطر رینگ داخلی
۳۴/۵۵ mm	قطر متوسط بلبرینگ	۷/۹۲ mm	قطر ساچمه‌ها

جدول ۲-	زاویه‌ی تماس	°	تعداد ساچمه‌ها	۸
	مقدار نیروی دینامیک	۱۲/۸۲ kN	مقدار نیروی دینامیک	۶/۶۵ kN
مشخصات داده های تجربی مورد استفاده [۱۵]				

Table 2 - Specifications of the Experimental Data Used

شرایط بارگذاری	نام بلبرینگ	مدت عمر بلبرینگ
نیرو: ۱۲ kN فرکانس: ۳۵ Hz	Bearing1_1	۲ ساعت و ۳ دقیقه
	Bearing1_2	۲ ساعت و ۴۱ دقیقه
	Bearing1_3	۲ ساعت و ۳ دقیقه
	Bearing1_4	۲ ساعت و ۲ دقیقه
	Bearing1_5	۵۲ دقیقه
نیرو: ۱۱ kN فرکانس: ۳۷/۵ Hz	Bearing2_1	۸ ساعت و ۱۱ دقیقه
	Bearing2_2	۲ ساعت و ۴۱ دقیقه
	Bearing2_3	۸ ساعت و ۵۳ دقیقه
	Bearing2_4	۴۲ دقیقه
	Bearing2_5	۵ ساعت و ۳۹ دقیقه
نیرو: ۱۰ kN فرکانس: ۴۰ Hz	Bearing3_1	۴۲ ساعت و ۱۸ دقیقه
	Bearing3_2	۴۱ ساعت و ۳۶ دقیقه
	Bearing3_3	۶ ساعت و ۱۱ دقیقه
	Bearing3_4	۲۵ ساعت و ۱۵ دقیقه
	Bearing3_5	۱ ساعت و ۵۴ دقیقه

شکل (۳) توابع مود ذاتی محاسبه شده برای یکی از سیگنال‌های ارتعاشی مورد استفاده را به عنوان یک نمونه نشان می‌دهد. همانگونه که در این شکل نیز نشان داده شده‌است هر سیگنال ارتعاشی از تعدادی تابع مود ذاتی تشکیل می‌شود که دارای دامنه‌ی فرکانسی متفاوتی هستند که از فرکانس بالا به پایین به دست می‌آیند. با کاهش فرکانس، مقدار انرژی تابع مود ذاتی نیز کاهش پیدا می‌کند و ممکن است نتوان اطلاعات مورد نیاز را به درستی از آن به دست آورد.



شکل ۳- توابع مود ذاتی به دست آمده از سیگنال ارتعاشی

Figure 3 - Intrinsic Mode Functions obtained from the vibration signal


محاسبه نسبت انرژی تابع مود ذاتی به انرژی کل سیگنال می‌تواند در انتخاب تابع مود ذاتی مناسب جهت محاسبات بعدی و استخراج اطلاعات، روشی کارآمد باشد. نسبت انرژی مجموع سه تابع مود ذاتی اول نسبت به انرژی کل سیگنال محاسبه شده در جدول (۳) نشان می‌دهد که مجموع انرژی سه تابع مود ذاتی اول معادل بیش از ۹۰ درصد انرژی کل سیگنال است.

جدول ۳-مقایسه سطح انرژی سه تابع مود ذاتی اول و نسبت مجموع آن‌ها به انرژی کل سیگنال اصلی

Table 3 - Comparison of the energy levels of the first three intrinsic mode functions and their cumulative ratio to the total energy of the original signal


ردیف	انرژی تابع مود ذاتی اول (E1)	انرژی تابع مود ذاتی دوم (E2)	انرژی تابع مود ذاتی سوم (E3)	انرژی سیگنال اصلی (E)	$\frac{E1+E2+E3}{E}$
۱	۰/۲۴۵۸	۰/۰۸۴۲	۰/۰۷۶۶	۰/۴۲۵۷	۰/۹۵۵۴
۲	۰/۲۵۱۱	۰/۰۷۷۲	۰/۰۷۹۶	۰/۴۲۱۳	۰/۹۶۸۲
۳	۰/۲۵۷۴	۰/۰۵۹۰	۰/۰۹۲۲	۰/۴۲۰۳	۰/۹۷۲۴
۴	۰/۲۸۵۹	۰/۰۵۶۶	۰/۰۶۲۴	۰/۴۱۶۹	۰/۹۷۱۲

در ادامه شکل‌های (۴) و (۵) اختلاف انرژی مابین سه تابع مود ذاتی اول و سایر توابع مود ذاتی استخراج شده از سیگنال و همچنین تاثیر این اختلاف انرژی در نشان دادن تشدید عیوب را نشان می‌دهند. به این منظور پس از استخراج توابع مود ذاتی سیگنال ارتعاشی مربوط به Bearing3_1، واریانس مربوط به آن محاسبه شده و در شکل‌های (۴) و (۵) نشان داده شده‌است.



شکل ۴- واریانس محاسبه شده برای توابع مود ذاتی استخراج شده از سیگنال ارتعاشی Bearing3_1

Figure 4 - Calculated variance of the IMFs extracted from the Bearing3_1 vibration signal



شکل ۵- بزرگنمایی قسمت انتهایی نمودار شکل (۴)

Figure 5 - Magnified view of the final segment of the plot in figure 4

شکل های (۴) و (۵) نشان می دهند که سه تابع مود ذاتی اول نسبت به سایر توابع مود ذاتی روند تغییرات را با شدت بیشتری دنبال می کنند. با توجه به این نکته و در نظر گرفتن مقادیر نسبت انرژی به دست آمده، تابع مود ذاتی اول جهت استفاده در مراحل بعدی پژوهش و آموزش شبکه عصبی مورد استفاده قرار می گیرند.

۲-۲ استخراج پارامتر آماری مناسب

استخراج پارامترهای مناسبی که با دنبال کردن تغییرات آن‌ها بتوان شدت عیوب و در نتیجه عمر مفید باقیمانده بلبرینگ‌ها را دنبال کرد و تخمین زد، تاثیر تعیین کننده‌ای در نتیجه تخمین عمر باقی مانده دارد. تعداد زیادی پارامتر آماری وجود دارند که در عیب یابی سیستم‌ها و پیش‌بینی عمر مفید باقیمانده آن‌ها مورد استفاده قرار می‌گیرند. به عنوان مثال ماکزیمم یک تابع و ریشه میانگین مربعات به ترتیب برای تشخیص عیوب شدید از سیگنال‌های ارتعاشی و پیدا کردن قطعات نابالانس در سیستم مورد استفاده قرار می‌گیرند. همچنین واریانس و انحراف استاندارد پارامترهای مناسبی برای تحلیل داده‌های تصادفی و سیستم‌های ناپایدار هستند. برخی از آن‌ها در ادامه به همراه روابط ریاضی مربوط عنوان شده‌اند.

$$Peak = \max \{ |x_i| \} \quad \text{معادله (۱)}$$

$$RMS = \frac{1}{n} \sqrt{\sum_{i=1}^n x_i^2} \quad \text{معادله (۲)}$$

$$Var = \frac{\sum_{i=1}^n (x_i - \text{MeanValue})^2}{n-1} \quad \text{معادله (۳)}$$


$$SD = \sqrt{\frac{\sum_{i=1}^n (x_i - \text{MeanValue})^2}{n-1}} \quad \text{معادله (۴)}$$

$$Kurtosis = \sqrt{\frac{\sum_{i=1}^n (x_i - \text{MeanValue})^4}{SD^4(n-1)}} \quad \text{معادله (۵)}$$

در روابط فوق x_i نشان دهنده‌ی داده‌ی i ام، $Peak$ نشان دهنده‌ی بیشینه مقدار داده‌ها، n تعداد داده‌ها، RMS ریشه میانگین مربعات، Mean Value میانگین داده‌ها، Var مقدار واریانس داده‌ها و SD مقدار انحراف معیار داده‌ها را نشان می‌دهد که نحوه‌ی محاسبه آن در رابطه‌ی انحراف معیار (۴) نشان داده شده‌است. از میان پارامترهای آماری عنوان شده فوق، پارامترهای کرتسیس^۱ و واریانس^۲ بیشترین استفاده را برای عیب‌یابی و رصد شدت عیوب موجود در قطعات دارند. باتوجه به نمودارهای به دست آمده در این پژوهش که در شکل (۶) نیز یک نمونه از آن نمایش داده شده‌است؛ واریانس، شدت عیوب موجود در قطعات و تشدید آن با گذر زمان را بهتر از کرتسیس نمایش می‌دهد.

^۱ Kurtosis

^۲ Variance



شکل ۶- مقایسه نمودار واریانس و کورتسیس در نمایش روند خرابی برای تابع مود ذاتی اول Bearing3_1

Figure 6 - Variance vs. kurtosis comparison for tracking degradation in the first IMF of Bearing3_1


۳-۲ برازش تابع توزیع ویبول

براساس پژوهش‌های قبلی انجام گرفته تابع توزیع ویبول به خوبی می‌تواند شدت عیوب موجود در سیستم‌های مکانیکی و قطعات آن‌ها را تحت بارهای تصادفی نشان دهد [۹]. رابطه‌ی این توزیع در رابطه (۶) نشان داده شده است که رابطه‌ی اصلاح شده‌ای است که تحت عنوان تابع جهانی نرخ شکست ویبول شناخته می‌شود و با نماد WD در رابطه‌ی (۶) نشان داده شده است.

$$WD(t, \beta, \eta, K, Y) = Y + K \frac{\beta}{\eta \beta} t^{\beta-1} \quad \text{معادله (۶)}$$


این رابطه از سه پارامتر اصلی تشکیل شده است. پارامتر $\beta > 0$ به عنوان پارامتر شکل شناخته می‌شود. $\eta > 0$ پارامتر مقیاس نام دارد. K پارامتری است که برای تصویر کردن داده‌های مورد نظر در بازه مطلوب مورد استفاده قرار می‌گیرد و ثابت Y مقدار تابع را در نقطه صفر نشان می‌دهد و t نشان دهنده پارامتر زمان است [۹]. برازش تابع ویبول بر روی داده‌های مورد استفاده نه تنها روند تغییرات سیگنال‌ها را به خوبی نمایش می‌دهد، بلکه داده بهتری برای آموزش شبکه عصبی می‌باشد چرا که نویزهای موجود در سیگنال‌ها، که به دلایلی مانند عوامل محیطی ایجاد می‌گردند، حذف می‌شوند و شبکه عصبی روند خرابی بلبرینگ را بهتر آموزش می‌بیند. شکل‌های (۷)

و (۸) نمودار توابع ویبول برازش شده بر روی تعدادی از سیگنال‌های تابع مود ذاتی استخراج شده مورد استفاده در این پژوهش را به عنوان نمونه نشان می‌دهد.



شکل ۷- تابع ویبول برازش شده بر روی یکی از سیگنال‌های واریانس تابع مود ذاتی

Figure 7 - Weibull fit applied to the variance of an Intrinsic Mode Function signal




شکل ۸- تابع ویبول برازش شده بر روی یکی از سیگنال‌های واریانس تابع مود ذاتی

Figure 8 - Weibull fit applied to the variance of an Intrinsic Mode Function signal

۳- شبکه عصبی تطبیقی فازی با یادگیری نظارتی

پس از برازش تابع ویبول بر روی سیگنال‌های مورد نظر، توابع به دست آمده برای آموزش شبکه‌ی عصبی مورد استفاده قرار می‌گیرند تا به کمک شبکه عصبی تطبیقی فازی با یادگیری نظارتی عمر مفید باقیمانده بلبرینگ‌ها تخمین زده شود. این شبکه برای اولین بار در سال

۱۹۹۳ توسط کاسوبا ارائه شد و نسخه اصلاح شده‌ای از شبکه عصبی تطبیقی فازی^۱ بود که الگوریتم آن ساده تر شده و به همین دلیل تحت عنوان شبکه تطبیقی فازی ساده شده^۲ نیز شناخته می‌شود [۱۶]. این شبکه قادر است داده‌های جدید را فرا گیرد بدون اینکه داده‌های قبلی را فراموش کند به همین دلیل برای پردازش داده‌های سری زمانی شبکه مناسبی است. همانگونه که در شکل (۹) نشان داده شده است شبکه عصبی فوق از سه لایه تشکیل گردیده است: لایه ورودی F_1 ، لایه مقایسه F_2 ، و لایه خروجی F^{ab} . در ابتدا تمام نورون‌های موجود در لایه اول به تمام نورون‌های موجود در لایه دوم متصل هستند و تمامی اتصالات دارای وزنی بین صفر و یک می‌باشند.



شکل ۹- ساختار کلی شبکه عصبی تطبیقی فازی با یادگیری نظارتی


Figure 9 - Main structure of SFAM neural network

هر نورون در لایه‌ی دوم نشان دهنده یک دسته‌بندی از داده‌ها است که به وسیله بردار وزن آن شناخته شده و از سایر دسته‌بندی‌ها متمایز می‌گردد. شبکه‌ی عصبی تطبیقی فازی با یادگیری نظارتی براساس نوعی کدگذاری که اصطلاحاً کدگذاری مکمل نام دارد کار می‌کند. این عملیات شامل گرفتن بردار ورودی به طول b و الحاق آن به مکمل آن است. بردار حاصل باید به لایه F_1 ارائه شود. بنابراین، بُعد M لایه F_1 دو برابر بُعد بردار ورودی است. لایه‌ی F^{ab} به وسیله بردار وزنی W^{ab} به صورت کامل به لایه‌ی F_2 متصل است تا بدینوسیله در مرحله‌ی تست شبکه‌ی عصبی کلاس و دسته‌بندی مناسب داده‌های ورودی را تشخیص دهد. داده‌های ورودی شبکه که برای آموزش شبکه عصبی مورد استفاده قرار می‌گیرند توابع ویبول برازش شده بر روی واریانس محاسبه شده از تابع مود ذاتی سیگنال‌های ارتعاشی هستند. خروجی‌های شبکه‌ی عصبی مورد نظر a کلاس است که در آن دسته‌بندی اول نشان‌دهنده‌ی حالت سالم بلبرینگ‌ها و هریک از $a-1$ کلاس نشان‌دهنده‌ی مرحله‌ای از خرابی بلبرینگ‌ها هستند. مقدار a با توجه به پارامترهای شبکه و ثابت‌های به دست آمده برای برازش تابع ویبول بر روی سیگنال‌های ورودی می‌تواند تغییر کند. مقدار بهینه این متغیر با توجه به پژوهش‌های قبلی ۷ کلاس است [۹]. شکل (۱۰) دسته بندی به دست آمده برای داده‌های ورودی شبکه‌ی عصبی تطبیقی فازی با یادگیری نظارتی، که تابع

¹ FUZZY ARTMAP

² Simplified FUZZY ARTMAP

ویبول برازش شده بر روی تابع مود ذاتی اول می‌باشد، را نشان می‌دهد. در واقع در این مرحله شبکه‌ی عصبی به وسیله‌ی داده‌هایی که از روند خرابی بلبرینگ‌های واقعی جمع‌آوری شده است (Bearing3_1) آموزش داده می‌شود و روند خرابی بلبرینگ‌ها را به تعداد محدودی مرحله یا سطح خرابی تقسیم‌بندی می‌کند.



شکل ۱۰- دسته‌بندی به دست آمده برای داده ورودی شبکه عصبی پس از آموزش شبکه با ویبول برازش شده بر واریانس تابع مود ذاتی مربوط به Bearing3_1

Figure 10 - Classification of neural network input data after training with Weibull fit on the variance of the intrinsic mode function for Bearing3_1


دسته‌بندی‌های به دست آمده از آموزش شبکه‌ی عصبی (شکل ۱۰) به دلیل گسسته بودن و دقت پایین، به طور مستقیم جهت تخمین عمر مفید باقیمانده بلبرینگ‌ها قابل استفاده نیستند به همین دلیل در مراحل بعدی، به منظور رسیدن به یک تخمین پیوسته و با دقت بالا، تابع هموارسازی برای رسیدن به عمر مفید باقیمانده بلبرینگ‌ها مورد استفاده قرار می‌گیرد. رابطه ریاضی تابع هموارسازی در رابطه (۷) نشان داده شده‌است.

$$S_t = ZI_t + (1-Z)S_{t-1} \quad \text{معادله (۷)}$$

در رابطه‌ی فوق Z ثابت هموارسازی بوده که تحت عنوان ضریب فراموشی نیز شناخته می‌شود و مقداری در بازه‌ی صفر و یک دارد، I_t مقدار واقعی واریانس تابع مود ذاتی اول در لحظه‌ی t است و S_{t-1} مقدار واریانس است که شبکه‌ی عصبی در لحظه‌ی $t-1$ تخمین می‌زند که در واقع سطح خرابی بلبرینگ را براساس دسته‌بندی‌های به دست آمده در شکل (۱۰) در آن لحظه نشان می‌دهد و براساس آن مقدار واریانس تابع مود ذاتی در لحظه‌ی t محاسبه می‌گردد که براساس آن عمر مفید باقی‌مانده بلبرینگ تعیین می‌گردد.

۴- نتایج و بحث


در پژوهش انجام گرفته به منظور تخمین عمر مفید باقیمانده بلبرینگ های صنعتی، داده های ارتعاشی یک مجموعه ای آزمایشی مورد استفاده قرار گرفتند. ابتدا توابع مود ذاتی مربوط به سیگنال های ارتعاشی جمع آوری شده، استخراج شدند و پس از انتخاب تابع مود ذاتی مناسب با استفاده از روش انرژی و برازش تابع ویبول بر روی آن، مورد بهره برداری قرار گرفتند. در ادامه به منظور ارزیابی صحت و دقت عملکرد الگوریتم ارائه شده، شبکه ای عصبی با استفاده از داده های جمع آوری شده از همان مجموعه ای آزمایشگاهی مورد ارزیابی قرار می گیرد. همچنین، به منظور سنجش تاثیر برازش تابع ویبول و استفاده از نتیجه ای آن برای آموزش شبکه، بار دیگر شبکه عصبی با تابع مود ذاتی انتخاب شده بدون برازش تابع ویبول آموزش دیده و خطای حاصل محاسبه و با حالت قبل مقایسه گردیده است که نتایج در جداول (۴) و (۵) ارائه شده اند. شکل (۱۱) عملکرد شبکه ای عصبی را در تخمین عمر مفید Bearing3_1، که برای آموزش شبکه ای عصبی نیز مورد استفاده قرار گرفته بود را پس از اعمال تابع هموارسازی نشان می دهد.



شکل ۱۱- نتیجه عملکرد شبکه در شبیه سازی روند خرابی بلبرینگ و تخمین عمر مفید باقیمانده برای Bearing3_1

Figure 11 - Network performance results in simulating the bearing failure trend and estimating the remaining useful life for Bearing3_1


شکل (۱۲) نتایج حاصل از تخمین عمر بلبرینگ Bearing3_2 را در مقایسه با بلبرینگ Bearing3_1 نشان می دهد. هردو بلبرینگ تحت حالت بارگذاری سوم بوده و مشخصات فیزیکی و ابعادی یکسانی دارند. در عمل بلبرینگ Bearing3_2 طول عمر کمتری نسبت به بلبرینگ Bearing3_1 داشته است (با توجه به جدول ۲). نتایج تخمین عمر هر دو بلبرینگ به وسیله شبکه عصبی نشان می دهد که الگوریتم پیشنهادی به خوبی توانسته است روند خرابی هردو بلبرینگ را پیش بینی کند.



شکل ۱۲-مقایسه داده های تجربی و نتایج تخمین عمر Bearing3_1 و Bearing3_2

Figure 12 - Comparison of experimental data and estimated remaining useful life results for Bearing3_1 and Bearing3_2

ثابت هموارسازی Z تاثیر بسیار زیادی در عملکرد و دقت شبکه عصبی دارد. شکل (۱۳) نتایج تخمین عمر مفید باقیمانده Bearing3_3 را نشان می‌دهد. این بلبرینگ در عمل در مدت ۳۷۱ دقیقه به صورت کامل خراب شده است درحالیکه آموزش شبکه عصبی با بلبرینگ با طول عمر ۲۵۳۸ (Bearing3_1) دقیقه انجام گرفته است. لذا؛ زمانی که هموار سازی با ثابت Z کوچک انجام می‌شود، شبکه عملکرد مناسبی را نشان نمی‌دهد. با توجه به شکل (۱۳) با افزایش مقدار Z دقت عملکرد شبکه افزایش یافته و روند خرابی بلبرینگ را بهتر دنبال و پیش‌بینی می‌کند.



شکل ۱۳-مقایسه داده های تجربی و نتایج تخمین عمر Bearing3_3 با استفاده از شبکه عصبی و مقادیر ثابت هموارسازی متفاوت

Figure 13 - Comparison of experimental data and RUL estimates for Bearing3_3 using the neural network with various fixed smoothing parameters

رابطه (۸) جهت محاسبه خطای شبکه‌ی عصبی در تخمین عمر بلبرینگ‌ها مورد استفاده قرار می‌گیرد. در این رابطه n برابر با تعداد داده برداشت شده، S_t مقدار واریانس پیش‌بینی شده و l_t مقدار تجربی واریانس در آن لحظه می‌باشد.

معادله (۸)

$$e = \frac{1}{n} \sum_{t=1}^n |S_t - I_t|$$

در پژوهش انجام گرفته ثابت هموارسازی Z، به عنوان یک پارامتر ثابت و به صورت دستی تعیین گردیده است که این مساله میزان دقت عملکرد شبکه را کاهش می دهد. رابطه ی (۸) می تواند به عنوان تابعی جهت تخمین دقیق مقدار این پارامتر، با برقراری ارتباط میان خطای لحظه ای و ثابت هموارسازی، مورد استفاده قرار گیرد که به عنوان پژوهشی دیگر مورد بررسی و تحقیق می باشد.


جدول (۴) مقدار خطای محاسبه شده برای شبکه ی عصبی در هر یک از تست های انجام شده را نشان می دهد. لازم به توجه است که آموزش شبکه با استفاده از تابع ویبول برازش شده بر روی Bearing3_1 صورت گرفته است.

جدول ۴- خطای محاسبه شده در تخمین عمر با توجه به ثابت هموارسازی برای بلبرینگ های تست شده تحت بارگذاری حالت سوم

Table 4 - Estimation errors of RUL based on smoothing constants for bearings tested under Load Condition 3

بلبرینگ	ثابت هموارسازی Z	خطای شبکه e آموزش با تابع ویبول	خطای شبکه e آموزش بدون تابع ویبول	عمر واقعی بلبرینگ (دقیقه)	عمر پیش بینی شده (دقیقه) با تابع ویبول
Bearing3_3	۰/۰۵	۰/۴۶۵۵	۰/۵۵۹۷	۳۷۱	۱۹۸
Bearing3_3	۰/۲۰	۰/۳۸۱۱	۰/۴۷۰۵	۳۷۱	۲۲۹
Bearing3_3	۰/۵۰	۰/۲۴۶۰	۰/۲۹۲۰	۳۷۱	۲۷۹
Bearing3_3	۰/۷۰	۰/۱۸۰۲	۰/۱۷۳۰	۳۷۱	۳۰۴
Bearing3_3	۰/۸۵	۰/۱۳۲۷	۰/۰۸۳۴	۳۷۱	۳۲۱
Bearing3_3	۰/۹۵	۰/۱۰۱۰	۸/۹۳۵۴	۳۷۱	۳۳۳

شکل (۱۴) نتایج حاصل از تخمین عمر مفید باقیمانده بلبرینگ Bearing2_1 را تحت بارگذاری حالت دوم نشان می دهد. عمر واقعی این بلبرینگ از لحظه ی شروع به کار تا خرابی کامل آن ۴۹۱ دقیقه بوده است در حالیکه شبکه عصبی با بلبرینگی که به مدت ۲۵۳۸ دقیقه کار کرده است (Bearing3_1)، آموزش داده شده است. به همین دلیل تابع هموارساز با ثابت هموارسازی کوچک توانایی شبیه سازی مناسب رفتار بلبرینگ را ندارد و با افزایش این ثابت رفتار پیش بینی شده به رفتار واقعی بلبرینگ نزدیک تر می شود. کار کرده است



شکل ۱۴-مقایسه داده های تجربی و نتایج تخمین عمر بلبرینگ Bearing2_1 با مقادیر ثابت هموارسازی متفاوت

Figure 14 - Comparison of experimental data and RUL estimates for Bearing2_1 using different fixed smoothing parameters

جدول (۵) مقدار خطای شبکه معادل با هر ثابت هموارسازی را برای Bearing2_1 نشان می دهد. براساس این جدول، باوجود اینکه بلبرینگ Bearing2_1 تحت بارگذاری متفاوتی از شرایطی بوده است که شبکه عصبی براساس آن آموزش دیده است، با افزایش مقدار ثابت هموارسازی دقت عملکرد شبکه عصبی و تابع هموارسازی نیز افزایش پیدا می کند و شبکه به خوبی می تواند روند خرابی و کاهش عمر بلبرینگ را دنبال کند.

جدول ۵-خطای محاسبه شده در تخمین عمر با توجه به ثابت هموار سازی برای Bearing2-1 (بلبرینگ ۱ تحت بارگذاری حالت دوم)

Figure 5 - Estimation errors of RUL based on smoothing constants for Bearing2_1 (Bearing 1 under Load Condition 2)

بلبرینگ	ثابت هموارسازی Z	خطای شبکه e آموزش با تابع ویبول	خطای شبکه e آموزش بدون تابع ویبول	عمر واقعی بلبرینگ (دقیقه)	عمر پیشبینی شده (دقیقه) با تابع ویبول
Bearing2_1	۰/۰۵	۰/۲۰۶۰	۰/۲۱۲۴	۴۹۱	۳۸۹
Bearing2_1	۰/۲۰	۰/۱۸۶۷	۰/۱۹۳۴	۴۹۱	۳۹۹
Bearing2_1	۰/۵۰	۰/۱۴۸۵	۰/۱۵۵۲	۴۹۱	۴۱۸
Bearing2_1	۰/۷۰	۰/۱۲۴۴	۰/۱۳۱۲	۴۹۱	۴۲۹
Bearing2_1	۰/۹۰	۰/۱۰۲۳	۰/۱۰۹۴	۴۹۱	۴۴۰
Bearing2_1	۰/۹۵	۰/۰۹۷۶	۰/۱۰۴۸	۴۹۱	۴۴۳

۵- جمع بندی

در این پژوهش روش جدیدی جهت تخمین عمر مفید باقی مانده بلبرینگ‌های صنعتی با استفاده از توابع مود ذاتی سیگنال‌های ارتعاشی و شبکه عصبی تطبیقی فازی معرفی گردید. نتایج به دست آمده از پژوهش نشان می‌دهند که الگوریتم معرفی شده به خوبی می‌تواند روند خرابی بلبرینگ را بدون اطلاع از وضعیت قبلی آن دنبال کرده و نشان دهد. همچنین نتایج به دست آمده، که در جداول ۴ و ۵ ارائه شده‌اند، نشان می‌دهند که استفاده برآزش تابع ویبول بر توابع مود ذاتی مناسب سیگنال‌های ارتعاشی، دقت عملکرد شبکه‌ی عصبی را بالاتر می‌برد و می‌توان ادعا کرد که استفاده از تابع مود ذاتی مناسب در سایر شبکه‌های عصبی نیز می‌تواند دقت عملکرد شبکه‌ی عصبی را افزایش دهد. همچنین برآزش تابع ویبول بر روی سیگنال‌ها نیز کیفیت آموزش شبکه‌ی عصبی را افزایش می‌دهد و شبکه می‌تواند روند خرابی بلبرینگ‌ها را بهتر آموزش ببیند. تابع هموارسازی، بخش مهمی از الگوریتم معرفی شده است که تعیین ثابت هموارسازی مناسب می‌تواند به افزایش دقت نتایج به دست آمده کمک کند. براساس آنچه ذکر شد ثابت هموارسازی می‌تواند براساس خطای محاسبه شده پیش‌بینی شده و دقت عملکرد الگوریتم را افزایش دهد که به عنوان پژوهش دیگری مورد بررسی قرار خواهد گرفت.

علائم و اختصارات

علائم انگلیسی

<i>Empirical Mode Decomposition</i>	<i>EMD</i>
مقدار انرژی سیگنال ارتعاشی اصلی	<i>E</i>
مقدار انرژی تابع مود ذاتی اول سیگنال ارتعاشی	<i>E1</i>
مقدار انرژی تابع مود ذاتی دوم سیگنال ارتعاشی	<i>E2</i>
مقدار انرژی تابع مود ذاتی سوم سیگنال ارتعاشی	<i>E3</i>
هرتز	<i>Hz</i>
<i>Intrinsic Mode Function</i> ، (تابع مود ذاتی)	<i>IMF</i>
پارامتر اسکیل تابع ویبول	<i>K</i>
کیلو نیوتون	<i>kN</i>
کرتوسیس	<i>Kurtosis</i>
مقدار واقعی واریانس تابع مود ذاتی سیگنال	<i>l</i>
<i>Long Short-Term Memory</i> ، (شبکه‌ی عصبی حافظه‌ی کوتاه مدت طولانی)	<i>LSTM</i>
بیشینه	<i>Max</i>
مقدار میانگین	<i>Mean Value</i>
مقدار واریانس تابع مود ذاتی اول محاسبه شده با شبکه‌ی عصبی	<i>S</i>
انحراف استاندارد	<i>SD</i>
<i>Simplified Fuzzy ArtMap</i>	<i>SFAM</i>
تعداد داده‌ها در یک سیگنال	<i>n</i>
<i>Root Mean Square</i> ، (ریشه‌ی میانگین مربعات)	<i>RMS</i>
<i>Remaining Useful Life</i> ، (عمر مفید باقیمانده)	<i>RUL</i>
زمان	<i>t</i>
واریانس	<i>Var</i>
واریانس محاسبه شده برای تابع مود ذاتی اول دهم	<i>Var_IMF_1.....10</i>
تابع جهانی نرخ شکست ویبول	<i>WD</i>
عرض از مبدا تابع ویبول	<i>Y</i>
ثابت هموارسازی	<i>Z</i>
علائم یونانی	
پارامتر شکل تابع ویبول	β
پارامتر مقیاس تابع ویبول	η

- [١] C. Ferreira, G. Gonçalves, Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods, *Journal of Manufacturing Systems*, 63 (2022) 550-562.
- [٢] S. Ramezani, A. Moini, M. Riahi, Prognostics and health management in machinery: A review of methodologies for RUL prediction and roadmap, *International Journal of Industrial Engineering and Management Science*, 6(1) (2019) 38-61.
- [٣] N. Kumar, R. Satapathy, Bearings in aerospace, application, distress, and life :a review, *Journal of Failure Analysis and Prevention*, 23(3) (2023) 915-947.
- [٤] L. Liao, Discovering prognostic features using genetic programming in remaining useful life prediction, *IEEE Transactions on Industrial Electronics*, 61(5) (2013) 2464-2472.
- [٥] T. Benkedjouh, K. Medjaher, N. Zerhouni, S. Rechak, Remaining useful life estimation based on nonlinear feature reduction and support vector regression, *Engineering Applications of Artificial Intelligence*, 26(7) (2013) 1751-1760.
- [٦] X.-l. Wang, H. Gu ,L. Xu, C. Hu, H. Guo, A SVR-based remaining life prediction for rolling element bearings, *Journal of Failure Analysis and Prevention*, 15(4) (2015) 548-554.
- [٧] J. Zhang, P. Wang, R. Yan, R.X. Gao, Long short-term memory for machine remaining life prediction, *Journal of manufacturing systems*, 48 (2018) 78-86.
- [٨] A.Z. Hinch, M. Tkouat, Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network, *Procedia Computer Science*, 127 (2018) 123-132.
- [٩] J.B .Ali, B. Chebel-Morello, L. Saidi, S. Malinowski, F. Fnaiech, Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network, *Mechanical Systems and Signal Processing*, 56 (2015) 150-172.
- [١٠] N. Zhang, L. Wu ,Z. Wang, Y. Guan, Bearing remaining useful life prediction based on Naive Bayes and Weibull distributions, *Entropy*, 20(12) (2018) 944.
- [١١] N.E. Huang, N.O. Attoh-Okine, *The Hilbert-Huang transform in engineering*, CRC Press, 2005.
- [١٢] N.E. Huang, S.S. Shen (Eds.), *Introduction to the Hilbert-Huang Transform and Its Related Mathematical Problems*, World Scientific, Singapore, 2005.
- [١٣] M.Y. Asr, M.M. Ettefagh, R. Hassannejad, S.N. Razavi, Diagnosis of combined faults in rotary machinery by Non-Naive Bayesian approach, *Mechanical Systems and Signal Processing*, 85 (2017) 56–70. [١٤] P. Wang, Z. Long, G. Wang, A hybrid prognostics approach for estimating remaining useful life of wind turbine bearings, *Energy Reports*, 6 (2020) 173-182.
- [١٥] B. Wang, Y. Lei, N. Li, N. Li, A hybrid prognostics approach for estimating remaining useful life of rolling element bearings, *IEEE Transactions on Reliability*, 69(1) (2018) 401-412.
- [16] P. Banker, Simplified Fuzzy ARTMAP, *Proceedings of the International Conference on Artificial Intelligence and Machine Learning*, 2021, pp. 123–130.

Estimating the Remaining Useful Life of Bearings Using Weibull Function Fitting on IMF

Zahra Talebi¹, Mortaza H. Sadeghi², Mir Mohammad Etefagh^{3*}

Faculty of Mechanical Engineering, University of Tabriz, Iran

ABSTRACT

Bearings are essential components widely used in industrial systems and machinery. Their proper functioning is vital for the efficiency, reliability, and continuity of operations. A bearing failure can lead to serious equipment damage, unplanned downtime, and significant financial losses. Due to their critical role, various techniques have been developed for diagnosing faults and estimating the remaining useful life (RUL) of bearings. This research presents a novel method for predicting the RUL of industrial bearings using a data-driven approach based on vibration signal analysis. In the proposed method, the vibration signals collected from the bearing are first decomposed into several intrinsic mode functions using the empirical mode decomposition technique. From the extracted components, the intrinsic mode function that best reflects the progression of degradation is selected through an energy-based evaluation strategy. The variance of the selected function is then computed and modeled using a fitted Weibull distribution. The resulting trend is utilized to train a neural network designed to recognize degradation patterns and predict the remaining life. Finally, the network's output is refined using an exponential smoothing function. Experimental results confirm that the proposed algorithm can accurately follow the degradation trend and estimate the remaining useful life of the bearing under test.

KEYWORDS

Rotary Machinery, Ball Bearing, Diagnostics, Remaining Useful Life, Machine Learning