

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, Tabriz, Iran

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.

Review History:

Received: Sep. 16, 2024
Revised: Mar. 09, 2025
Accepted: May, 21, 2025
Available Online: May, 27, 2025

Keywords:

Rotary Machinery
Ball Bearing
Diagnostics
Remaining Useful Life
Machine Learning

1- 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.

2- 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.

3- 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

*Corresponding author's email: ettefagh@tabrizu.ac.ir

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 [6]. 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 [6][7][8].

4- 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 [6][9].

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.
- [3] L. Liao, Discovering prognostic features using genetic programming in remaining useful life prediction, *IEEE Transactions on Industrial Electronics*, 61(5) (2013) 2464-2472.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] M.Y. Asr, M.M. Etefagh, 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.
- [8] 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.
- [9] P. Banker, Simplified Fuzzy ARTMAP, in, 2021.



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

زهره طالبی، مرتضی-همایون صادقی، میرمحمد اتفاق* 

دانشکده مهندسی مکانیک، دانشگاه تبریز، تبریز، ایران.

تاریخچه داوری:

دریافت: ۱۴۰۳/۰۶/۲۶

بازنگری: ۱۴۰۳/۱۲/۱۹

پذیرش: ۱۴۰۴/۰۲/۳۱

ارائه آنلاین: ۱۴۰۴/۰۳/۰۶

کلمات کلیدی:

ماشین دوار

بلبرینگ

عیب یابی

عمر مفید

یادگیری ماشین

خلاصه: 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.

۱- مقدمه

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 تأثیر 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

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 اسفاده 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 دسته‌ی کلی روش‌های بر پایه‌ی شبیه‌سازی و مدل‌سازی، روش‌های داده محور و روش‌های ترکیبی تقسیم‌بندی کرد. در دهه‌های اخیر با توسعه‌ی تکنولوژی و دانش هوش مصنوعی، استفاده از روش‌های داده محور در پایش وضعیت

* نویسنده عهده‌دار مکاتبات: ettefagh@tabrizu.ac.ir



تخمین عمر مفید بلبرینگ‌ها مورد استفاده قرار می‌گیرد. در تحقیق مشابه دیگری که توسط ژنگ^۸ و همکارانش انجام گرفته [۱۰] تخمین عمر مفید باقیمانده بلبرینگ‌ها با استفاده از ترکیب شبکه‌ی عصبی نایو-بیز^۹ 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 اولیه‌ای 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 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

۲- پردازش اولیه سیگنال ارتعاشی


۲-۱- استخراج تابع مود ذاتی^{۱۰} مناسب با استفاده از روش تجزیه‌ی تجربی^{۱۱}

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

انجام گرفته در این زمینه مورد بررسی قرار می‌گیرند. لینخیالینائو^[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. بنکدجوح^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 مرحله‌ی آفلاین مدل‌های تخریب به شبکه‌ی عصبی آموزش داده می‌شد و سپس در مرحله‌ی آنالیز با استفاده از الگوهای تخریب آموزش داده شده، وضعیت بلبرینگ و عمر مفید باقیمانده‌ی آن سنجیده می‌شد. خیولین ونگ^۳ و همکارانش^[۶] روشی را با استفاده از مدل گاوسی^۴ و رگرسیون بردار پشتیبان^۵ 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^۶ توسط جیانجینگ^۷ 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 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 شبیه سازی فرآیند تخریب مورد استفاده قرار گرفته است. سپس عمر مفید باقیمانده به وسیله‌ی خروجی لایه‌ی شبکه عصبی با واحد حافظه بلندمدت کوتاه‌مدت پیش‌بینی می‌شود. جوهرین 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

1. Liao,L.
2. Benkedjouh
3. Wang,X.
4. Gaussian
5. Support Vector Regression (SVR)
6. Long Short-Term Memory (LSTM)
7. Zhang,J.

8. Zhang,N.
9. Naïve Bayes
10. Intrinsic Mode Function (IMF)
11. Empirical Mode Decomposition (EMD)




شکل ۱. فلوچارت مراحل روش ارائه شده در این پژوهش

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

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 (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.

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 ذاتی سیگنال اصلی هستند. (۲) هر سیگنال خطی و غیرخطی حداقل باید دارای یک نقطه ماکزیمم و یک نقطه مینیمم 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].



شکل ۲. ستاپ آزمایشگاهی استفاده شده جهت داده برداری

Fig. 2. Utilized setup for data collection

جدول ۱. مشخصات بلبرینگ های استفاده شده

Table 1. Specifications of the Bearings Used

پارامتر	مقدار	پارامتر	مقدار
قطر رینگ داخلی	۲۹/۳۰ mm	قطر رینگ بیرونی	۳۹/۸۰ mm
قطر ساچمه ها	۷/۹۲ mm	قطر متوسط بلبرینگ	۳۴/۵۵ mm
زاویه ی تماس	۰°	تعداد ساچمه ها	۸
مقدار نیروی دینامیک	۱۲/۸۲ kN	مقدار نیروی دینامیک	۶/۶۵ kN

پس از استخراج توابع مود ذاتی سیگنال ارتعاشی مربوط به Bearing3_1، واریانس مربوط به آن محاسبه شده و در شکل های (۴) و (۵) نشان داده شده است.

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 بیش تری 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.


محاسبه نسبت انرژی تابع مود ذاتی به انرژی کل سیگنال می تواند 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 می دهد که مجموع انرژی سه تابع مود ذاتی اول معادل بیش از ۹۰ درصد انرژی کل سیگنال است.

در ادامه شکل های (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 می دهند. به این منظور

جدول ۲. مشخصات داده های تجربی مورد استفاده [۱۵]

Table 2. Specifications of the Experimental Data Used

شرایط بارگذاری	نام بلبرینگ	مدت عمر بلبرینگ
نیرو: ۱۲kN فرکانس: ۳۵Hz	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: ۱۱kN فرکانس: ۳۷/۵Hz	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: ۱۰kN فرکانس: ۴۰Hz	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 به دست آمده از سیگنال ارتعاشی

Fig. 3. Intrinsic Mode Functions obtained from the vibration signal

جدول ۳. مقایسه سطح انرژی سه تابع مود ذاتی اول و نسبت مجموع آن ها 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



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

Fig. 4. Calculated variance of the IMFs extracted from the Bearing3_1 vibration signal


۲-۲- استخراج پارامتر آماری مناسب

استخراج پارامترهای مناسبی که با دنبال کردن تغییرات آن ها بتوان شدت عیوب و در نتیجه عمر مفید باقیمانده بلبرینگ ها را دنبال کرد و تخمین زد، تاثیر تعیین کننده ای در نتیجه تخمین عمر باقی مانده دارد. تعداد زیادی پارامتر آماری وجود دارند که در عیب یابی سیستم ها و پیش بینی عمر مفید باقیمانده آن ها مورد استفاده قرار می گیرند. به عنوان مثال ماکزیمم یک تابع و ریشه میانگین مربعات به ترتیب برای تشخیص عیوب شدید از سیگنال های ارتعاشی و پیدا کردن قطعات نابالانس در سیستم مورد استفاده قرار می گیرند. همچنین واریانس و انحراف استاندارد پارامترهای مناسبی

برای تحلیل داده های تصادفی و سیستم های ناپایدار هستند. برخی از آن ها در ادامه به همراه روابط ریاضی مربوط عنوان شده اند.

$$Peak = \max\{|x_i|\} \quad (1)$$

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



شکل ۵. بزرگنمایی قسمت انتهایی نمودار شکل (۴)

Fig. 5. Magnified view of the final segment of the plot in Fig. 4

واریانس، شدت عیوب موجود در قطعات و تشدید آن با گذر زمان را بهتر از کرتسیس نمایش می‌دهد.

$$Var = \frac{\sum_{i=1}^n (x_i - MeanValue)^2}{n-1} \quad (3)$$

۳-۲- برازش تابع 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.

$$SD = \sqrt{\frac{\sum_{i=1}^n (x_i - MeanValue)^2}{n-1}} \quad (4)$$


$$Kurtosis = \sqrt{\frac{\sum_{i=1}^n (x_i - MeanValue)^4}{SD^4(n-1)}} \quad (5)$$

$$WD(t, \beta, \eta, K, Y) = Y + K \frac{\beta}{\eta \beta} t^{(\beta-1)} \quad (6)$$

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

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 شده است. 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 شده است؛

1. Kurtosis
2. Variance



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

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


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 شده‌است شبکه عصبی فوق از سه لایه تشکیل گردیده‌است: 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.

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

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.


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




شکل ۷. تابع ویبول برازش شده بر روی یکی از سیگنال های واریانس تابع مود ذاتی

Fig. 7. Weibull fit applied to the variance of an Intrinsic Mode Function signal




شکل ۸. تابع ویبول برازش شده بر روی یکی از سیگنال های واریانس تابع مود ذاتی

Fig. 8. Weibull fit applied to the variance of an Intrinsic Mode Function signal



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

Fig. 9. Main structure of SFAM neural network



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

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


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.

$$S_t = ZI_t + (1-Z)S_{t-1} \quad (7)$$

در رابطه‌ی فوق Z ثابت هموارسازی بوده که تحت عنوان ضریب فراموشی نیز شناخته می‌شود و مقداری در بازه‌ی صفر و یک دارد، 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.

است. لایه‌ی F^{ab} به وسیله‌ی 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 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.

دسته‌بندی‌های به دست آمده از آموزش شبکه‌ی عصبی (شکل ۱۰) به



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

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

Bearing3_1 داشته است (با توجه به جدول ۲). نتایج تخمین عمر هر

دو بلبرینگ به وسیله شبکه عصبی نشان می‌دهد که الگوریتم پیشنهادی به خوبی توانسته است روند خرابی هردو بلبرینگ را پیش‌بینی کند.

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 در حالیکه آموزش شبکه عصبی با بلبرینگی 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.


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.

$$e = \frac{1}{n} \sum_{t=1}^n |S_t - l_t| \quad (8)$$

۴- نتایج و بحث


در پژوهش انجام گرفته به منظور تخمین عمر مفید باقیمانده بلبرینگ های صنعتی، داده‌های ارتعاشی یک مجموعه‌ی آزمایشی مورد استفاده قرار گرفتند. ابتدا توابع مود ذاتی مربوط به سیگنال‌های ارتعاشی جمع‌آوری شده، استخراج شدند و پس از انتخاب تابع مود ذاتی مناسب با استفاده از روش انرژی و برازش تابع ویبول بر روی آن، مورد بهره‌برداری قرار گرفتند. در ادامه به منظور ارزیابی صحت و دقت عملکرد الگوریتم ارائه شده، شبکه‌ی عصبی با استفاده از داده‌های جمع‌آوری شده از همان مجموعه‌ی آزمایشگاهی مورد ارزیابی قرار می‌گیرد. همچنین، به منظور سنجش تاثیر برازش تابع ویبول و استفاده از نتیجه‌ی 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 شده‌اند. شکل (۱۱) عملکرد شبکه‌ی عصبی را در تخمین عمر مفید Bearing3_1، که برای آموزش شبکه‌ی عصبی نیز مورد استفاده قرار گرفته بود را پس از اعمال تابع هموارسازی نشان می‌دهد.

شکل (۱۲) نتایج حاصل از تخمین عمر بلبرینگ Bearing3_2 را در مقایسه با بلبرینگ Bearing3_1 نشان می‌دهد. 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



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

Fig. 12. Comparison of experimental data and estimated remaining useful life results for Bearing3_1 and Bearing3_2



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

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

جدول (۴) مقدار خطای محاسبه شده برای شبکه‌ی عصبی در هر یک از تست‌های انجام شده را نشان می‌دهد. لازم به توجه است که آموزش شبکه با استفاده از تابع ویبول برازش شده بر روی Bearing3_1 صورت گرفته‌است.


شکل (۱۴) نتایج حاصل از تخمین عمر مفید باقیمانده بلبرینگ Bearing2_1 را تحت بارگذاری حالت دوم نشان می‌دهد. عمر واقعی این

در پژوهش انجام گرفته ثابت هموارسازی Z ، به عنوان یک پارامتر ثابت و به صورت دستی تعیین گردیده‌است که این مساله میزان دقت عملکرد شبکه را کاهش می‌دهد. رابطه‌ی (۸) می‌تواند به عنوان تابعی جهت تخمین دقیق مقدار این پارامتر، با برقراری ارتباط میان خطای لحظه‌ای و ثابت هموارسازی، مورد استفاده قرار گیرد که به عنوان پژوهشی دیگر مورد بررسی و تحقیق می‌باشد.

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 پیشبینی شده (دقیقه)
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. مقایسه داده های تجربی و نتایج تخمین عمر بلبرینگ Bearing2_1 با مقادیر ثابت هموارسازی متفاوت

Fig. 14. Comparison of experimental data and RUL estimates for Bearing2_1 using different fixed smoothing parameters

می شود. کار کرده است

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

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

جدول ۵. خطای محاسبه شده در تخمین عمر با توجه به ثابت هموار سازی برای Bearing2_1 (بلبرینگ ۱ تحت بارگذاری حالت دوم)

Table 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 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

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.

۵- جمع بندی

در این پژوهش روش جدیدی جهت تخمین عمر مفید باقی مانده بلبرینگ های صنعتی با استفاده از توابع مود ذاتی سیگنال های ارتعاشی و شبکه عصبی تطبیقی فازای معرفی گردید. نتایج به دست آمده از پژوهش نشان می دهند که الگوریتم معرفی شده به خوبی می تواند 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 شده اند، نشان می دهند که استفاده برآزش تابع ویبول بر توابع مود ذاتی مناسب سیگنال های ارتعاشی، دقت عملکرد شبکه ی عصبی را بالاتر می برد و می توان ادعا کرد که استفاده از تابع مود ذاتی مناسب در سایر شبکه های عصبی نیز می تواند دقت عملکرد شبکه ی عصبی را افزایش دهد. همچنین برآزش تابع ویبول بر روی سیگنال ها نیز کیفیت آموزش شبکه ی عصبی را افزایش می دهد و شبکه می تواند روند خرابی بلبرینگ ها را بهتر آموزش ببیند. تابع هموارسازی، بخش مهمی از الگوریتم معرفی شده است که تعیین ثابت هموارسازی مناسب می تواند به افزایش دقت نتایج به دست آمده کمک کند. براساس آنچه ذکر شد ثابت هموارسازی می تواند براساس خطای محاسبه شده پیش بینی شده و دقت عملکرد الگوریتم را افزایش دهد که به عنوان پژوهش دیگری مورد بررسی قرار خواهد گرفت.

۶- فهرست علائم

علائم انگلیسی

علائم انگلیسی	علائم فارسی
<i>EMD</i>	<i>Empirical Mode Decomposition</i>
<i>E</i>	مقدار انرژی سیگنال ارتعاشی اصلی
<i>E1</i>	مقدار انرژی تابع مود ذاتی اول سیگنال ارتعاشی
<i>E2</i>	مقدار انرژی تابع مود ذاتی دوم سیگنال ارتعاشی
<i>E3</i>	مقدار انرژی تابع مود ذاتی سوم سیگنال ارتعاشی
<i>Hz</i>	هرتز
<i>IMF</i>	<i>Intrinsic Mode Function</i> ، (تابع مود ذاتی)
<i>K</i>	پارامتر اسکیل تابع ویبول
<i>kN</i>	کیلو نیوتون
<i>Kurtosis</i>	کرتوسیس
<i>I</i>	مقدار واقعی واریانس تابع مود ذاتی سیگنال
<i>LSTM</i>	<i>Long Short-Term Memory</i> ، (شبکه ی عصبی حافظه ی کوتاه مدت طولانی)
<i>Max</i>	بیشینه
<i>Mean Value</i>	مقدار میانگین
<i>S</i>	مقدار واریانس تابع مود ذاتی اول محاسبه شده با شبکه ی عصبی
<i>SD</i>	انحراف استاندارد
<i>SFAM</i>	<i>Simplified Fuzzy ArtMap</i>

remaining life prediction for rolling element bearings, Journal of Failure Analysis and Prevention, 15(4) (2015) 548-554.

- [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.
- [8] A.Z. Hinch, M. Tkiouat, Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network, Procedia Computer Science, 127 (2018) 123-132.
- [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.
- [10] 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.
- [11] N.E. Huang, N.O. Attoh-Okine, The Hilbert-Huang transform in engineering, CRC Press, 2005.
- [12] N.E. Huang, S.S. Shen (Eds.), Introduction to the Hilbert-Huang Transform and Its Related Mathematical Problems, World Scientific, Singapore, 2005.
- [13] M.Y. Asr, M.M. Etefagh, 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.
- [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.
- [15] 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.

تعداد داده‌ها در یک سیگنال	n
$Root\ Mean\ Square$ ، (ریشه‌ی میانگین مربعات)	RMS
$Remaining\ Useful\ Life$ ، (عمر مفید باقیمانده)	RUL
زمان	t
واریانس	Var
واریانس محاسبه شده برای تابع مود ذاتی اول ... دهم	$Var_IMF_1,...,10$
تابع جهانی نرخ شکست ویبول	WD
عرض از مبدا تابع ویبول	Y
ثابت هموارسازی	Z
علائم یونانی	
پارامتر شکل تابع ویبول	β
پارامتر مقیاس تابع ویبول	η

منابع

- [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.
- [3] N. Kumar, R. Satapathy, Bearings in aerospace, application, distress, and life: a review, Journal of Failure Analysis and Prevention, 23(3) (2023) 915-947.
- [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.
- [6] X.-l. Wang, H. Gu, L. Xu, C. Hu, H. Guo, A SVR-based

چگونه به این مقاله ارجاع دهیم

Z. Talebi, M. H. Sadeghi, M. M. Ettefagh, *Estimating the Remaining Useful Life of Bearings Using Weibull Function Fitting on IMF*, Amirkabir J. Mech Eng., 57(1) (2025) 105-122.

DOI: [10.22060/mej.2025.23526.7776](https://doi.org/10.22060/mej.2025.23526.7776)

