



Prognostics of rolling element bearings using shock pulse method and vibration method records and employing feedforward neural-network

M. Behzad , A. Davoodabadi, H. A. Arghand

School of Mechanical Engineering, Sharif University of Technology, Tehran, Iran

ABSTRACT: Early fault detection of the rolling element bearings has a very important role in increasing the reliability of rotating machines. It leads to better decision-making for maintenance activities. In recent decades, the shock pulse method has been developed to detect faults in the early stage of rolling element bearings degradation. In this paper, the accuracy of the remaining useful life estimation using extracted features from vibration signals and that from the shock pulse method are compared. In this regard, a set of accelerated life tests on rolling element bearings were designed and performed. Both shock pulse signals and vibration signals of the under-test rolling element bearings were recorded. Then two models based on feed-forward neural-network are developed to predict the remaining useful life of rolling element bearings. In the first model, only extracted features from vibration signals are fed for remaining useful life prediction. In the second model, the extracted features from shock pulse method are fed too. The results show that using shock pulse method-based features improves the accuracy of remaining useful life estimation. Also, using the health indicators extracted from vibration analysis and shock pulse method leads to a better estimating of the degradation behavior.

Review History:

Received: Mar. 23, 2020
Revised: Sep. 20, 2020
Accepted: Jan. 25, 2020
Available Online: Nov. 27, 2020

Keywords:

Rolling element bearings
Condition monitoring
Vibration analysis
Shock pulse method
Neural-network

1- Introduction

Accurate failure time estimation of mechanical components plays a significant role in enhancing the reliability and maintenance schedule of the machines. Rolling Element Bearings (REBs) failures are the most probable failure mode of the industrial rotating machinery [1]. Therefore, many researchers have studied the prognostics methods for the REB. The majority of the researches are used vibration data for prognostics. One of the main categories of prognostic approaches is known as data-driven methods. These methods have been developed extensively in the last two decades [2, 3]. Generally, data-driven methods are categorized into statistical methods and Artificial Intelligence (AI) methods. All AI methods include two stages. In the first stage, Condition Monitoring (CM) data of some run-to-failure tests are used for training and developing an AI model. Then, in the second stage, the trained model is employed for predicting the Remaining Useful Life (RUL) of the other similar components by using their CM data history. In recent decades, Shock Pulse Method (SPM) has been developed to detect faults in the early stage of REBs degradation. Some papers have compared the capabilities of vibration analysis and SPM in REBs early fault detection [4-7]. However, reviewing the literature, the features extracted from the SPM have not been used for prognostics of REBs.

In this study, a set of accelerated life tests have been planned and conducted and vibration data, as well as shock

pulse data, have been recorded regularly during the whole life of each REB. Two models based on the Feedforward Neural Network (FFNN) have been developed to predict the RUL of REBs for studying the effect of input features. Comparing the prediction results of the two models show that the accuracy increases as the SPM feature are employed for RUL prediction.

2- Methodology

In this research, the FFNN method is employed for the RUL prediction of the REBs. The proposed algorithm is summarized in a flowchart shown in Fig. 1. Also, Figs. 2 and 3 show the structures of two proposed FFNN models. These two models include two layers. The Levenberg-Marquardt (LM) backpropagation algorithm is used for training the model. The output of both models are the estimated normal RUL (estimated RUL per useful life). The inputs of model 1 are the current life (time), the Root Mean Square (RMS) of the last acceleration signal and its derivative ($dRMS$), and the introduced vibration health indicator (T_v) which is defined as the elapsed time from the first detection of the defect by vibration signal analysis. The inputs of model 2 are those of model 1 as well as the extracted feature from SPM (H_{Dm}) and its derivative (dH_{Dm}), and the SPM health indicator (T_s) which is defined as the elapsed time from the first detection of the defect by SPM.

*Corresponding author's email: m_behzad@sharif.edu



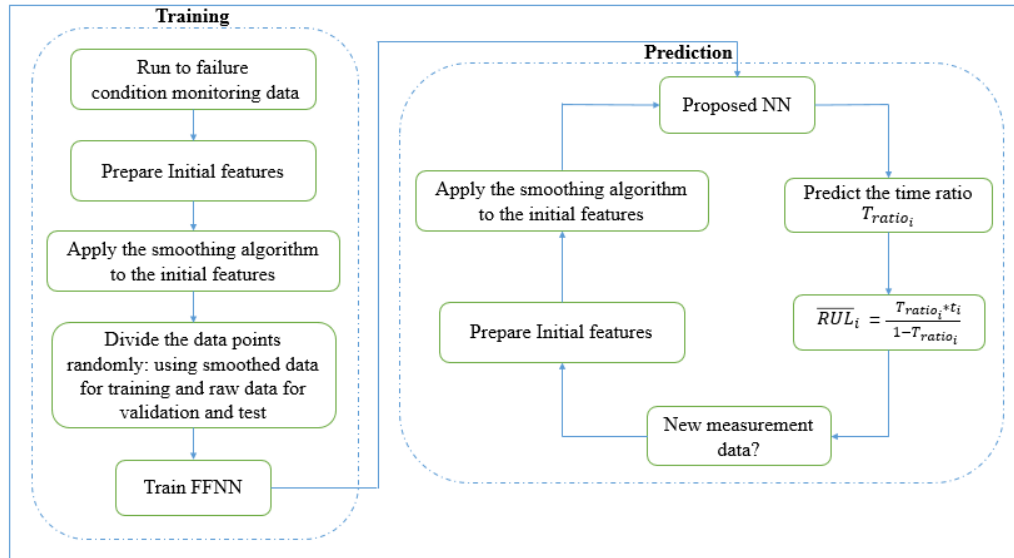


Fig. 1. The proposed algorithm for RUL prediction of REBs




Fig. 2. The structure of the first proposed model




Fig. 3. The structure of the second proposed model

3- Experimental Setup

To compare SPM and vibration analysis, a set of accelerated life tests on REBs were designed and conducted. The test rig is shown in Fig. 4. It hosts a test REB at one end of the shaft. Two larger REBs also support the shaft. The shaft is coupled to an AC electromotor (as a driver of the system) through a pulley and belt mechanism. Experiments were performed in

constant operating conditions including 2000 rpm rotational speed and 9000 N radial load. Both shock pulse and vibration of test REB were recorded during the test through a shock pulse sensor and an accelerometer, respectively. Totally, six run-to-failure tests were conducted and their results will be analyzed in the next section.




Fig. 4. The test-rig for the REB accelerated-life test

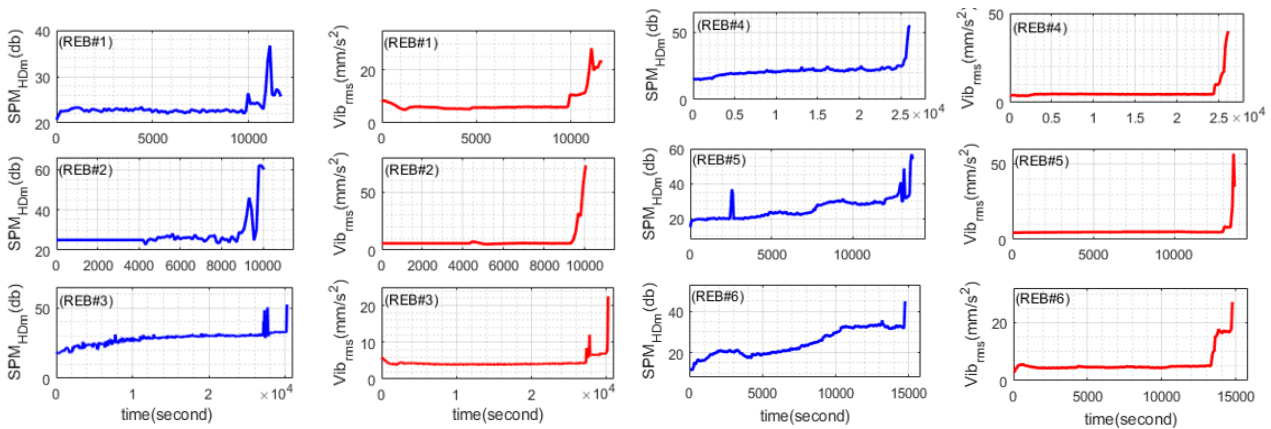


Fig. 5. The comparison between the trend of SPM_{HDm} and V_{rms} for all six accelerated-life experiments

Table 1. The average of two introduced errors for all 15 cases of two proposed models

Average error (%)	err_{30-90}	Err_{30-90}	err_{30-90}	Err_{30-90}
	33.7	58.2	22.1	40.4

4- Results and Discussion

The trend of RMS extracted from the vibration acceleration signals (Vib_{rms}), and the trend of HDm , extracted from the shock pulse signals (SPM_{HDm}) for all accelerated-life tests of REBs are plotted in Fig. 5. All possible cases of selecting four tests out of six tests (15 cases) are considered for training the two models. Then, each trained model is employed for predicting the RUL of the two other remaining tests in each case. The parameter Err_{30-90} is introduced to investigate and compare the error of two proposed models. This parameter is defined as the maximum error of predicted time ratio T_{ratio} between 0.3 and 0.9 of the whole life of test REB. In the same way, err_{30-90} is introduced the average value of error between 0.3 and 0.9 of the whole life. Table 1 reports the average of two introduced errors for all 15 cases for each model.

The reported results correspond to the thirty predictions in 15

cases. Because of the space limitation, only two predictions (out of thirty) are presented here. To this aim, the results of training the two models with data of REBs 3, 4, 5, and 6 and applying them fore predicting REB 1 are depicted in Figs. 6 and 7.

5- Conclusions

In this paper, two data-driven models based on the use of FFNN were developed to predict the RUL of REBs. In the first model, only extracted features from vibration signals were used for RUL prediction. In the second model, the extracted features from SPM were used too. The results showed that the performance of the second model in which the features extracted from SPM were considered as input, led to results with less error. Meanwhile, using the health indicators extracted from vibration analysis and SPM leads to a better estimating of the degradation behavior.




Fig. 6. Predicting RUL of REB 1 with Model 1 (with training datasets including REBs 3, 4, 5, and 6)




Fig. 7. Predicting RUL of REB 1 with Model 2 (with training datasets including REBs 3, 4, 5, and 6)

References

- [1] P. Albrecht, J. Appiarius, E. Cornell, D. Houghtaling, R. McCoy, E. Owen, D.J.I.t.o.e.c. Sharma, Assessment of the reliability of motors in utility applications, (3) (1987) 396-406.
- [2] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, J.J.M.S. Lin, S. Processing, Machinery health prognostics: A systematic review from data acquisition to RUL prediction, 104 (2018) 799-834.
- [3] M. Behzad, H.A. Arghand, A.J.P.o.t.I.o.M.E. Rohani Bastami, Part C: Journal of Mechanical Engineering Science, Remaining useful life prediction of ball-bearings based on high-frequency vibration features, 232(18) (2018) 3224-3234.
- [4] N. Tandon, K.J.N. Kumar, V. Worldwide, Detection of defects at different locations in ball bearings by vibration and shock pulse monitoring, 34(3) (2003) 9-16.
- [5] N. Tandon, G. Yadava, a.K.J.M.s. Ramakrishna, s. processing, A comparison of some condition monitoring techniques for the detection of defect in induction motor ball bearings, 21(1) (2007) 244-256.
- [6] A.D. Mehdi Behzad, Hesam Addin Arghand, Using Shock Pulse Method for Early Fault Detection of Rolling Element Bearings and Comparing with Vibration Envelope Technique, Amirkabir J. Mech. Eng., (2019).
- [7] T.J.A.S.I.W.P. Sundström, SPM Instruement AB, An introduction to the SPM HD method, (2010).

HOW TO CITE THIS ARTICLE

M. Behzad , A. Davoodabadi, H. A. Arghand, Prognostics of rolling element bearings using shock pulse method and vibration method records and employing feedforward neural-network, Amirkabir J. Mech. Eng., 53(Special Issue 4) (2021) 601-604.

DOI: 10.22060/mej.2020.18253.6786





تخمین عمر مفید باقی مانده یاتاقان غلتشی با استفاده از داده‌های روش شاک پالس و ارتعاشات و به کارگیری شبکه عصبی پیشخور

مهدی بهزاد*، علی داودآبادی، حسام الدین ارغند

دانشکده مهندسی مکانیک، دانشگاه صنعتی شریف، تهران، ایران

تاریخچه داوری:

دریافت: ۱۳۹۹/۰۱/۲۴

بازنگری: ۱۳۹۹/۰۶/۳۰

پذیرش: ۱۳۹۹/۰۸/۰۴

ارائه آنلاین: ۱۳۹۹/۰۹/۰۷

کلمات کلیدی:

یاتاقان غلتشی

پایش وضعیت

آنالیز ارتعاشات

روش شاک پالس

شبکه عصبی

خلاصه: تشخیص زودهنگام عیب در یاتاقان‌های غلتشی نقش بسیار تاثیرگذاری بر افزایش قابلیت اعتماد تجهیزات و بهینه‌نمودن تصمیم‌های آینده‌ی برای بهره‌برداری از تجهیزات دوار دارد. در دهه‌های اخیر روشی به نام شاک پالس برای تشخیص عیب در یاتاقان‌های غلتشی توسعه داده شده است که قابلیت تشخیص رشد عیب از مراحل اولیه را دارد. هدف از انجام پژوهش حاضر، مقایسه بین دقت پیش‌بینی عمر مفید باقی‌مانده یاتاقان غلتشی تنها با استفاده از داده‌های پایش وضعیت ارتعاشات و با استفاده از ترکیب داده‌های پایش وضعیت ارتعاشات و روش شاک پالس می‌باشد. در این راستا مجموعه‌ای از آزمایش‌های عمر پرشتاب یاتاقان غلتشی روی یک پلتفرم تجربی طرح‌ریزی و انجام شده است. مقادیر ارتعاشات و شاک پالس تست‌های عمر پرشتاب یاتاقان غلتشی هم‌زمان از لحظه شروع تا پایان خرابی به کمک دو سنسور ارتعاشات و شاک پالس اندازه‌گیری و روند تغییرات آنها ثبت شده است. سپس با استفاده از شبکه عصبی مصنوعی مدلی برای پیش‌بینی عمر مفید باقی‌مانده یاتاقان غلتشی توسعه داده شده است و مقایسه‌ای بین استفاده از خصیصه‌های آنالیز ارتعاشات و شاک پالس روی دقت پیش‌بینی انجام گردیده است. در نهایت نشان داده می‌شود که استفاده از داده‌های روش شاک پالس باعث بهبود دقت پیش‌بینی زمان وقوع خرابی یاتاقان‌های غلتشی و منجر به نتایج با خطای کمتر می‌گردد.

۱- مقدمه

امکان انجام تعمیر یا تعویض آن قطعه به علت شرایط بهره‌برداری، پرهزینه‌بودن و دشواری تعمیرات و حتی غیرممکن‌بودن تعمیرات فراهم نباشد. لذا در این شرایط استفاده‌کننده از تجهیز علاقمند است که ضمن دانستن وضعیت تجهیز در حال استفاده و عیوب مربوط به آن، بداند تا چه مدت دیگر می‌تواند پیش از این که تجهیزش از کار بیفتد از تجهیز خود به شکل ایمن استفاده کند. در این صورت امکان حداکثر بهره‌برداری از تجهیز توأم با تامین امنیت و برنامه‌ریزی دقیق برای تعمیر تجهیز جهت جلوگیری از واردشدن خسارت‌های بعدی وجود خواهد داشت. ضمن اینکه در برخی از شرایط ممکن است که خسارت‌های ناشی از خرابی غیر قابل جبران باشد و در این صورت دانستن وضعیت تجهیز و تخمین مدتی که می‌توان از تجهیز به صورت ایمن استفاده کرد اهمیت ویژه‌ای خواهد داشت.

نگهداری ماشین‌های صنعتی از دیرباز از جمله مسائل مهم در صنعت بوده است. مطابق گزارش‌های منتشرشده یاتاقان‌های غلتشی که کاربرد بسیار گسترده‌ای در بیشتر ماشین‌آلات و تجهیزات دوار دارند، جزو حساس‌ترین قطعات در این تجهیزات از نظر آمار خرابی محسوب می‌شوند و بیشترین تعداد خرابی‌های تصادفی این قبیل تجهیزات مربوط به قطعات مذکور است [۱، ۲]. باید توجه داشت که در بسیاری از موارد و کاربردها تعیین وجود عیب کافی نیست، بلکه پیش‌بینی زمان وقوع خرابی یک قطعه یا تجهیز و تخمین عمر مفید باقی‌مانده‌ی آن برای کاربر تجهیز مهم است. زیرا در اکثر مواقع علیرغم دانستن غیرعادی‌بودن وضعیت یک قطعه در تجهیز ممکن است

*نویسنده عهده‌دار مکاتبات: m_behzad@sharif.edu



عصبی بازگشتی^۸، دینامیک رشد خرابی را مدلسازی نموده و به طور کارآمدتری فرآیند تنزل و عمر مفید باقی مانده را پیش بینی نمودند. دسته‌ی دیگری از محققان، بر روی انتخاب مناسب ورودی‌های شبکه عصبی تمرکز کرده‌اند [۱۰، ۱۱]. از جمله اولین مطالعات صورت گرفته در این زمینه، می‌توان به مقاله‌ی جبرائیل^۹ و همکاران [۱۲] در سال ۲۰۰۴ اشاره نمود. در این تحقیق، از شبکه‌ی عصبی پیش‌خور^{۱۰} جهت تخمین عمر مفید باقی مانده استفاده شده است. در این مدل، دامنه‌ی ارتعاش در فرکانس عیب و هارمونیک‌های آن به عنوان ورودی شبکه و عمر مفید باقی مانده به عنوان خروجی آن در نظر گرفته شده است. در پژوهشی دیگر، محمد^{۱۱} و همکاران [۱۳] با به کار بردن مدلی بر مبنای شبکه عصبی پیش‌خور از مشخصه‌های زمان، ریشه میانگین مربعات^{۱۲} و کورتوسیس^{۱۳} برای پیش‌بینی عمر مفید باقی مانده استفاده کردند. همچنین، تیان^{۱۴} [۱۴] جهت جلوگیری از تاثیر نویز و اغتشاشات بر الگوی آموزشی، تابع تعمیم یافته وایبل^{۱۵} را روی خصیصه‌های مورد استفاده برازش نموده و حاصل آن را به عنوان ورودی شبکه عصبی پیش‌خور در نظر گرفت. در پژوهشی دیگر، بهزاد و همکاران [۱۵، ۱۶] از دامنه ارتعاشات فرکانس بالا در طیف فرکانسی به عنوان خصیصه‌ای برای پیش‌بینی عمر مفید باقی مانده به کمک شبکه عصبی پیش‌خور استفاده کردند و نشان دادند که استفاده از این خصیصه، در مقایسه با به کار بردن سطح ارتعاشات به عنوان ورودی مدل، منجر به بهبود دقت پیش‌بینی عمر مفید باقی مانده خواهد شد.

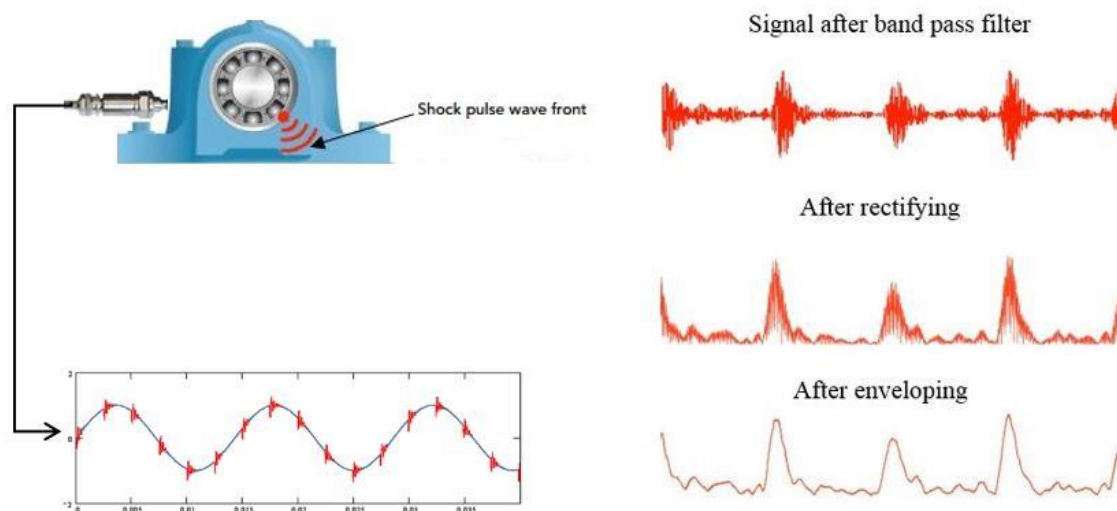
استفاده از آنالیز ارتعاشات برای تشخیص عیب یاتاقان‌های غلتشی متداول است. با این حال، روش متفاوتی در دهه‌های اخیر به نام روش شاک پالس^{۱۶} برای تشخیص عیب یاتاقان‌های غلتشی ابداع شد. این روش که توسط یک شرکت سوئدی توسعه یافته و به کار گرفته شده است [۱۷]، قابلیت تشخیص عیب یاتاقان را در مراحل اولیه رشد ترک^{۱۷} دارد. در برخی پژوهش‌های انجام شده، عملکرد و دقت این روش با سایر روش‌های پایش وضعیت و عیب‌یابی از جمله پایش ارتعاشات به منظور تشخیص زود هنگام عیوب یاتاقان غلتشی مقایسه

پیش‌بینی عمر مفید باقی مانده در مورد قطعاتی بیشتر مورد توجه است که تنزل^۱ آنها به صورت تدریجی باشد و بنابراین، تخمین زمان خرابی آنها بتواند به برنامه‌ریزی برای بهره‌برداری و تعمیرات آنها کمک کند. خوشبختانه، در مورد یاتاقان‌های غلتشی، رشد عیب با مکانیزم خستگی تماس غلتشی^۲، یک روند تنزل تدریجی است و ممکن است بستگی به شرایط کاری، از زمان تشخیص وجود عیب در یک یاتاقان غلتشی تا خرابی کامل آن چند ماه زمان وجود داشته باشد. بنابراین، در صورت پیش‌بینی هرچه دقیق‌تر زمان خرابی نهایی، بهره‌بردار می‌تواند با خیال آسوده در این مدت از تجهیز استفاده کند [۳، ۴].

تحقیقات بسیاری در زمینه‌ی پیش‌بینی عمر مفید باقی مانده انجام شده است. منظور از عمر مفید باقی مانده یاتاقان غلتشی مدت زمانی است که سیستم کارکرد موثر خواهد داشت و مبنای آن رسیدن مشخصه سلامت به سطح آستانه خرابی^۳ از پیش تعیین شده است [۵] که به عنوان مثال ممکن است بر اساس توصیه‌های استاندارد و مراجع راهنما انتخاب شده باشد. از به روزترین و جامع‌ترین بررسی‌ها بر روی این تحقیقات، می‌توان به مقاله‌ی لی^۴ و همکاران [۶] در سال ۲۰۱۸ اشاره نمود. آنها با ارائه‌ی روند رو به رشد تعداد مقالات انتشار یافته در بیست سال اخیر، اهمیت روزافزون این حوزه را نشان دادند؛ به نحوی که مقالات ۵ سال اخیر ۶۰ درصد از مقالات دو دهه‌ی گذشته را در بر می‌گیرند. توسعه روش‌های هوش مصنوعی و به کار بردن آن‌ها در مسائل مختلف مهندسی از جمله در پیش‌بینی عمر تجهیزات در دو دهه اخیر مورد توجه بسیاری از محققان بوده است. یکی از مهمترین و رایج‌ترین روش‌های هوش مصنوعی که کاربرد آن در بسیاری از شاخه‌های مهندسی از جمله در زمینه پیش‌بینی عمر مفید باقی مانده توسعه پیدا کرده است روش شبکه عصبی مصنوعی^۵ است. در برخی پژوهش‌ها، تمرکز روی به کارگیری الگوریتم‌های مختلف و نوع شبکه‌ی عصبی مورد استفاده قرار گرفت [۷]. ونگ^۶ و همکاران [۸] از شبکه‌ی عصبی دینامیکی مویک در تخمین عمر مفید باقی مانده استفاده کردند. در پژوهشی دیگر، کویی^۷ و همکاران [۹] با استفاده از شبکه‌ی

8 Recurrent
9 N. Gebraeel
10 Feed Forward Neural Network
11 A. Mahamad
12 Root Mean Square (RMS)
13 Kurtosis
14 Z. Tian
15 Generalized Weibull Function
16 Shock Pulse Method
17 Crack Initiation

1 Degradation
2 Rolling Contact Fatigue: RCF
3 Failure Threshold (FT)
4 Y.Lei
5 Artificial Neural Network: ANN
6 P.Wang
7 Q.Cui



شکل ۱. روند استخراج انولوپ سیگنال شاک پالس [22]

Fig. 1. The procedure of extracting the envelope for the shock pulse signals [22]


۲- خصیصه شاک پالس

روش شاک پالس توسط ایویند شول^۱ در سال ۱۹۶۹ میلادی ابداع شد و شرکت اس پی ام اینسترومنت^۲ در سال ۱۹۷۰ در سوئد تاسیس گردید [۱۷] و اقدام به توسعه تجهیزات اندازه گیری با استفاده از این روش جهت پایش وضعیت یاتاقان های غلتشی کرد. شاک پالس ها امواج الاستیک هستند که در مواد جامد منتشر می شوند. تکنولوژی شاک پالس بر این واقعیت علمی مبتنی است که وجود عیب در یاتاقان های غلتشی پالس های ضربه ای و در فرکانس های بسیار بالاتر از دور ماشین ایجاد می کنند. در این روش همه ی سیگنال ها در فرکانس پایین و میانه که می تواند ناشی از گردش ماشین و هارمونیک های آن، پرها، چرخ دنده ها و ... باشد، حذف می شود و با استفاده از سنسور شاک پالس امواج فرکانس ۳۲ kHz (که معادل با فرکانس طبیعی سنسورهای شاک پالس است) ۵ تا ۷ برابر تقویت می شود و سبب می گردد که سیگنال های بسیار ضعیف ناشی از ایجاد و رشد ترک در اجزای یاتاقان های غلتشی قابل تشخیص و اندازه گیری باشند. در این روش پس از اندازه گیری سیگنال یاتاقان معیوب توسط دستگاه اندازه گیری، ابتدا فیلتر میان گذر اعمال می شود. با اعمال این فیلتر مولفه های فرکانسی بیشتر و کمتر حذف می شوند. سپس عملیات

شده است [۱۸-۲۱]. با این حال، طبق بررسی انجام شده در ادبیات خصیصه های استخراج شده از روش شاک پالس برای پیش بینی عمر مفید باقی مانده ی یاتاقان های غلتشی استفاده نشده است.

در این پژوهش، پیش بینی عمر مفید باقیمانده ی یاتاقان های غلتشی با استفاده از شبکه عصبی پیشخور و در نظر گرفتن خصیصه های استخراج شده از آنالیز ارتعاشات و روش شاک پالس مورد مطالعه قرار گرفته است. نوآوری نخست مقاله حاضر استفاده از زمان عمر سپری شده از شروع رشد عیب به عنوان یکی از ورودی های شبکه عصبی است و نشان داده شده است که اعمال آن موجب بهبود دقت پیش بینی عمر مفید باقی مانده می شود. دو مدل داده محوری مبتنی بر شبکه عصبی بر اساس بکارگیری همین ایده در مقاله پیشنهاد شده است. در مدل نخست فقط خصیصه ی استخراج شده از سیگنال ارتعاشات به عنوان ورودی در نظر گرفته شده است. در مدل پیشنهادی دوم علاوه بر خصیصه ی استخراج شده از سیگنال ارتعاشات، خصیصه ی استخراج شده از روش شاک پالس نیز به عنوان ورودی به مدل شبکه عصبی داده شده است و استفاده از خصیصه ی مذکور برای هدف پیش بینی عمر مفید باقی مانده به عنوان نوآوری دیگر مقاله حاضر ارائه می گردد. در نتایج ارائه شده، نشان داده شده است که استفاده از خصیصه ی استخراج شده از روش شاک پالس موجب افزایش دقت پیش بینی گردیده است.

1 Eivind Schoel
2 SPM Instrument



شکل ۲. پلتفرم انجام آزمایش‌های عمر پرشتاب یاتاقان غلتشی

Fig. 2. The rolling element bearings accelerated-life experiments test-rig

جدول ۱. عمر یاتاقان تست و نوع خرابی مشاهده شده در شش آزمایش

Table 1. Test bearing life and the observed failure mode in six run-to-failure experiments

شماره تست	عمر مفید یاتاقان غلتشی (ثانیه)	نوع خرابی مشاهده شده در پایان تست
۱	۱۱۶۷۰	رینگ داخلی
۲	۱۰۰۵۱	ساجمه
۳	۳۰۲۰۵	ساجمه
۴	۲۶۲۹۴	رینگ داخلی
۵	۱۳۷۰۴	ساجمه
۶	۱۴۷۴۲	ساجمه

مقدار پالس که می توان آن را جزء توزیع گوسی برازش شده در نظر گرفت به عنوان مقدار پالس ماکزیمم در نظر گرفته می شود. لازم است توجه شود که لزوماً مقدار پالس ماکزیمم انتخاب شده در سیگنال برابر با بزرگترین پالس اندازه گیری شده نمی باشد. زیرا ممکن است بزرگترین پالس مشاهده شده فاصله قابل توجهی از دیگر داده های توزیع برازش شده داشته و دامنه توزیع به ازای آن پالس بسیار کم باشد. در این صورت این پالس جزء توزیع نرمال در نظر گرفته نمی شود [۲۲، ۲۱].

در هنگام عیب یابی به کمک آنالیز ارتعاشات، تشخیص عیب زمانی امکان پذیر است که ذرات از سطوح اجزا جدا شوند و به اصطلاح

یکسوسازی روی سیگنال ها انجام شده و منحنی انولوپ استخراج می شود. روند مذکور در شکل ۱ نشان داده شده است. در این فرآیند، پس از پردازش های انجام شده روی سیگنال خام، خصیصه^۱ مهمی به نام پالس های بلند یا ماکزیمم^۲ که نمایشگر وجود عیوب در سطوح یاتاقان های غلتشی می باشد، استخراج می شود. مقدار پالس ماکزیمم نشان دهنده قوی ترین دامنه شاک پالس است که در طول زمان داده برداری یافت می شود. نحوه ی محاسبه این پارامتر بدین صورت است که یک توزیع نرمال گوسی برای تمام پالس های موجود در یک سیگنال اندازه گیری شده برازش می گردد. سپس بزرگترین

1 Feature
2 HDm



شکل ۳. خرابی مشاهده شده در هر کدام از یاتاقان‌ها پس از دمونتاژ آن در انتهای هر آزمایش

Fig. 3. The observed damage in each of the REBs after disassembly at the end of each test

سنسور ارتعاشات روی یاتاقان انجام شده است. در این آزمایش‌ها یاتاقان مورد مطالعه تحت بارگذاری شدید قرار داشت و داده‌های آن از ابتدای نصب تا زمان خرابی نهایی ثبت گردیده است. در این پلتفرم که در شکل ۲ نشان داده شده است، یک سنسور ارتعاشات، یک سنسور شاک‌پالس و همچنین یک سنسور دما روی یاتاقان مورد تست قرار گرفته است. یاتاقان مورد تست در این آزمایش‌ها از نوع یاتاقان‌های شیار عمیق با کد ۶۹۰۷ می‌باشد. آزمایش‌های عمر پرشتاب در شرایط کاری ثابت با سرعت 2000 rpm و بار شعاعی $N9000$ انجام شده است. فرکانس نمونه‌برداری سنسور شتاب‌سنج و سنسور شاک‌پالس به ترتیب $25/6 \text{ kHz}$ و 102 kHz می‌باشد. در مجموع شش آزمایش عمر پرشتاب یاتاقان غلتشی برای هدف پژوهش حاضر انجام شده است که در جدول ۱ مدت زمان عمر این شش یاتاقان تست ارائه شده است. در این آزمایش‌ها رسیدن دامنه شتاب به مقدار $30g$ به عنوان آستانه خرابی یاتاقان غلتشی و معیار توقف تست در نظر گرفته شده است. در شکل ۳ خرابی مشاهده شده در اجزای هر کدام از یاتاقان‌ها پس از دمونتاژ آن در انتهای هر آزمایش نشان داده است.

سطح پوسته‌پوسته^۱ شود. حال آنکه روش شاک‌پالس بر اساس ماهیت فیزیکی آن، قابلیت تشخیص عیب را در مرحله اولیه شروع رشد ترک^۲ دارد، که ممکن است مدت‌ها قبل از جدا شدن اولین ذرات از سطوح و ایجاد عیب ظاهری باشد. توضیحات تفصیلی در مورد جزئیات اندازه‌گیری سیگنال و پردازش آن در روش شاک‌پالس در مقاله قبلی نویسندگان [۲۱] ارائه شده است. خواننده علاقه‌مند می‌تواند جهت اطلاع بیشتر به مرجع [۲۱، ۲۲] مراجعه نماید.

۳- آزمایش‌های عمر پرشتاب یاتاقان غلتشی

در آزمایشگاه ارتعاشات دانشگاه صنعتی شریف به منظور مطالعه روی پیش‌بینی خرابی و مدیریت سلامت یاتاقان‌های غلتشی و توسعه روش‌های پیش‌بینی خرابی در این اجزا، مجموعه‌ای از آزمایش‌های عمر پرشتاب یاتاقان غلتشی روی یک پلتفرم آزمایشگاهی (شکل ۲) طرح‌ریزی شد. در راستای اهداف پژوهش حاضر، شش تست عمر پرشتاب یاتاقان‌های غلتشی روی این پلتفرم انجام گردید. در این آزمایش‌ها به طور همزمان اندازه‌گیری توسط سنسور شاک‌پالس و

1 Spalling

2 Crack initiation

۴- پیش‌بینی وقوع خرابی یاتاقان‌های غلتشی با استفاده از

شبکه عصبی

روش شبکه عصبی یک ساختار الهام‌گرفته از سیستم عصبی و عملکرد نرون‌ها در دستگاه اعصاب موجودات زنده است که قابلیت یادگیری ارتباط بین ورودی و خروجی‌های موجود را دارد و می‌تواند ارتباطات پیچیده بین ورودی‌ها و خروجی‌های یک سیستم را مدل‌سازی کند. یک شبکه عصبی ممکن است متشکل از چندین لایه باشد و در هر لایه، تعدادی نرون و یک مقدار بایاس قرار می‌گیرند. همچنین معمول است که در خروجی هر لایه یا در خروجی لایه آخر از یک تابع غیر خطی (به عنوان مثال تابع سیگموئید^۱) استفاده شود. ورودی‌ها پس از ضرب شدن در ضرایب وزنی به تمام نرون‌های لایه اول اعمال می‌شوند و خروجی هر نرون در لایه‌ی اول نیز با اعمال ضرایب وزنی به نرون‌های لایه بعدی وارد می‌شود. در فرآیند آموزش شبکه عصبی، هدف اصلی تعیین ضرایب وزنی نرون‌ها و مقادیر بایاس هر لایه است، به گونه‌ای که ارتباط خروجی و ورودی در داده‌های مورد استفاده در آموزش به بهترین شکل ایجاد شود. هر چه تعداد لایه‌ها و نرون‌های هر لایه بیشتر باشد، ساختار شبکه عصبی پیچیده‌تر می‌شود. اما باید توجه داشت که بایستی ساختار شبکه عصبی متناسب با مساله مورد نظر انتخاب شود و پیچیده‌تر کردن ساختار شبکه عصبی لزوماً منجر به بهتر شدن عملکرد شبکه عصبی نخواهد بود. در مرحله آموزش شبکه عصبی لازم است داده‌های آموزش را به سه دسته تقسیم کرد که شامل داده‌های آموزشی، داده‌های صحنه‌سنجی و داده‌های تست می‌شود. بهتر است که تقسیم‌بندی داده‌ها به این سه گروه نیز به صورت تصادفی انجام شود. از داده‌های آموزشی برای محاسبه خروجی و اصلاح وزن‌ها استفاده می‌شود. اما از داده‌های صحنه‌سنجی صرفاً برای بررسی کیفیت آموزش در هر مرحله استفاده می‌شود و معیار توقف الگوریتم آموزش نیز بر اساس خطای عملکرد شبکه روی داده‌های صحنه‌سنجی در هر مرحله از اصلاح وزن‌ها است. داده‌های تست هیچ نقشی در فرآیند آموزش ندارد و تنها پس از آنکه آموزش تکمیل شد و الگوریتم آموزش متوقف گردید، از داده‌های تست برای مشاهده کیفیت شبکه نهایی استفاده می‌شود. معمولاً در تقسیم‌بندی داده‌ها، سهم بیشتر مربوط به داده‌های آموزشی است و البته باید توجه داشت که داده‌های صحنه‌سنجی و تست نیز به حد کافی باشند.

1 sigmoid function

۴-۱- معرفی خصیصه برای توصیف تنزل کیفیت یاتاقان غلتشی

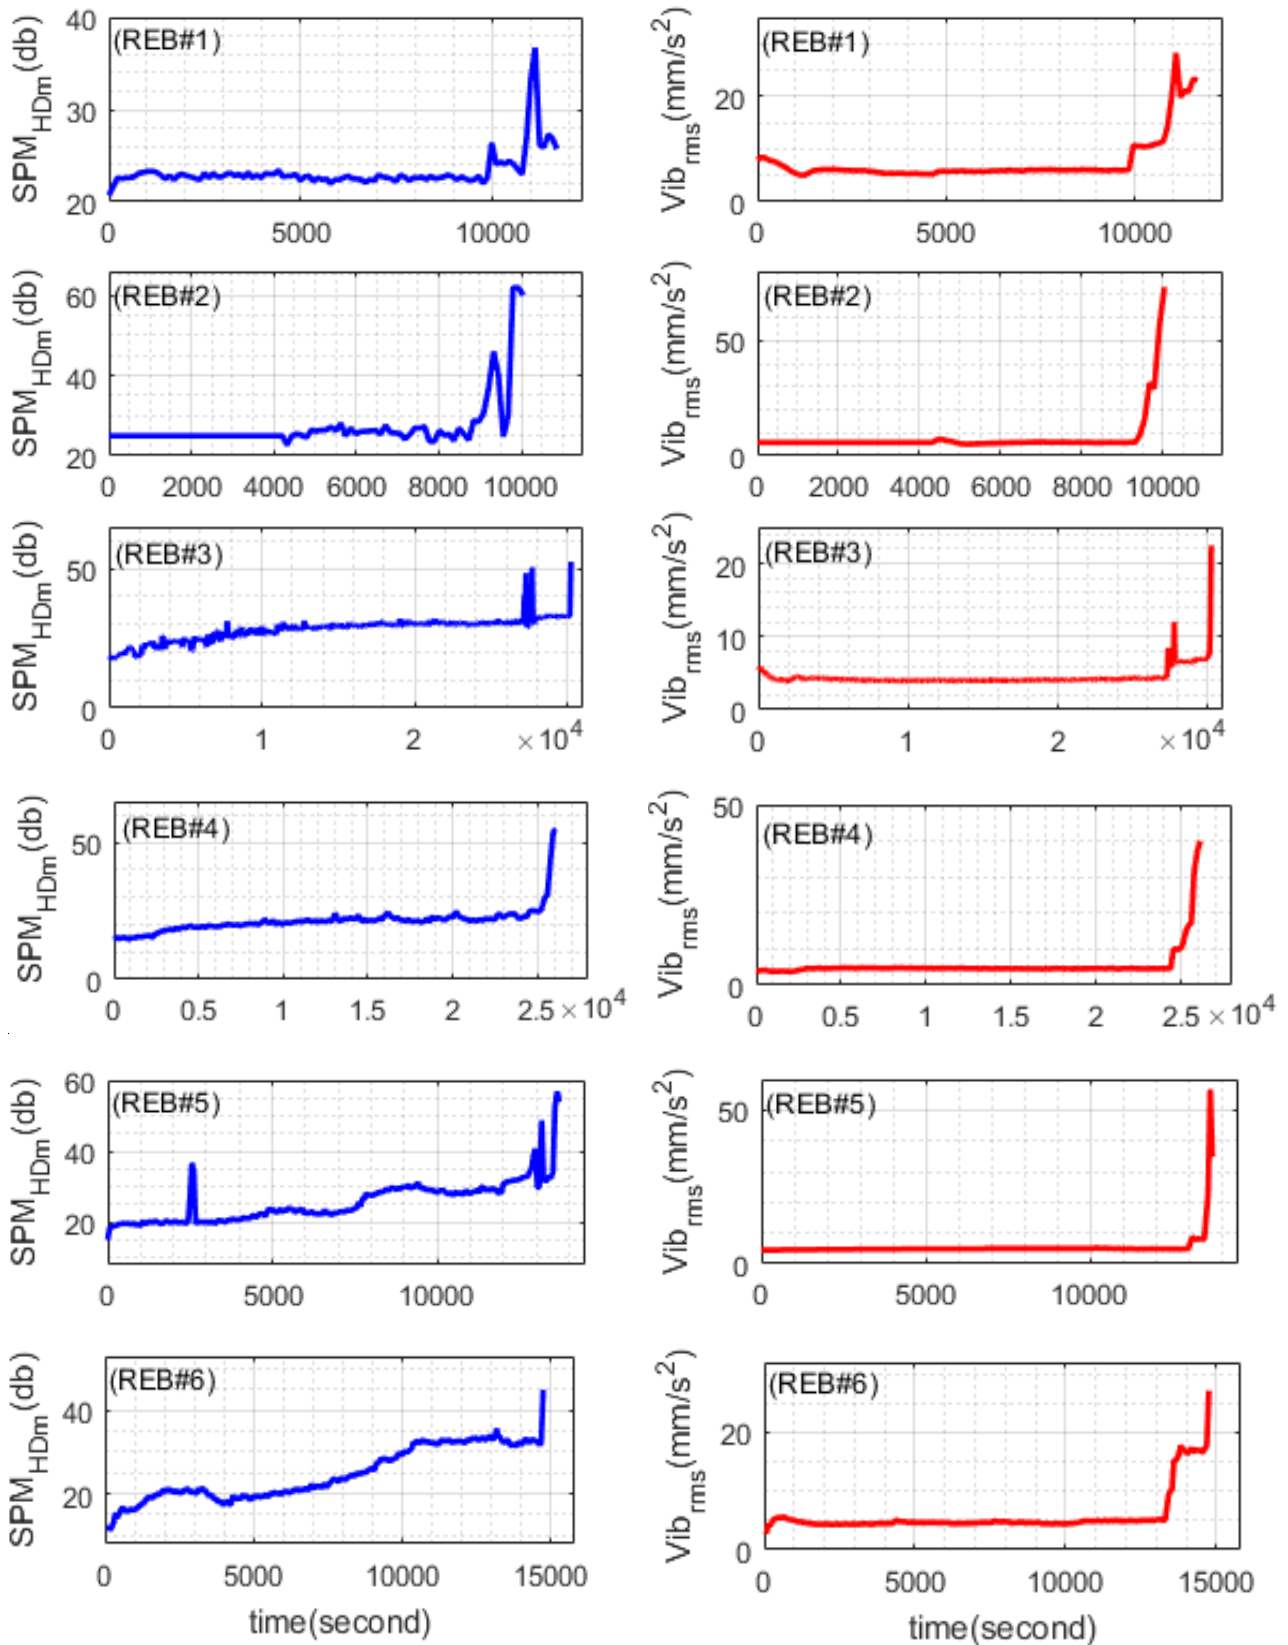
یکی از مهمترین گام‌های اثر گذار در عملکرد روش‌های داده‌محور از جمله شبکه عصبی انتخاب مناسب خصیصه‌های ورودی می‌باشد. در یاتاقان‌های غلتشی زمانی که عیب در مراحل ابتدایی رشد خود می‌باشد، ضربات ناشی از عیب در سیگنال زمانی ارتعاشات بسیار ضعیف است. زیرا عیوب اولیه یاتاقان‌های غلتشی پالس‌های بسیار کم‌انرژی و در فرکانس‌های بالا تولید می‌کند که عملاً این پالس‌ها در سیگنال ارتعاشات قابل مشاهده نمی‌باشند. برای تخمین عمر مفید باقی‌مانده یاتاقان غلتشی به خصیصه‌ای که بتواند روند وقوع عیب را از مراحل اولیه عیب تا شرایط تنزل یاتاقان به خوبی نشان دهد، نیاز می‌باشد. دو ویژگی مهم و مطلوب خصیصه مناسب برای تعقیب روند تنزل یاتاقان این است که اولاً رفتاری یکنوا^۲ داشته باشد و ثانیاً تغییرات آن بر اساس شرایط تنزل یاتاقان باشد. خصیصه‌ی مهم و رایج در ادبیات موضوع که بیانگر عیب یاتاقان نیز است، خصیصه ریشه میانگین مربعات سیگنال ارتعاشی^۳ می‌باشد. این خصیصه در بسیاری از مواقع، ابزاری مناسب برای تعقیب روند خرابی می‌باشند. خصیصه مهم دیگری که می‌تواند بیانگر رشد عیب یاتاقان در طول زمان باشد خصیصه‌ی پالس ماکزیمم ثبت‌شده با روش شاک پالس^۴ است. روند تغییرات ریشه میانگین مربعات سیگنال ارتعاشی و مقدار پالس ماکزیمم ثبت‌شده به روش شاک پالس، نسبت به زمان برای هر شش تست عمر پرشتاب انجام شده، در شکل ۴ نشان داده شده است. لازم به ذکر است که روند تغییرات ریشه میانگین مربعات سیگنال ارتعاشی و مقدار پالس ماکزیمم ثبت‌شده به روش شاک پالس به صورت آنلاین با استفاده از سیستم پایش وضعیت آنلاین اینتلینووا^۵ شرکت پارسی‌تک اندازه‌گیری شده است. سیستم پایش وضعیت آنلاین اینتلینووا دارای یک کنترلر هوشمند (واحد فرماندهی) می‌باشد که از طریق آن اطلاعات سنسورهای ارتعاشاتی و شاک پالس دریافت شده و به کامپیوتر منتقل می‌گردد. سیستم کنترلر کلیه عملیات اخذ اطلاعات، ذخیره‌سازی، پایش و آنالیز را انجام می‌دهد. سنسورها توسط ماژول‌های ارتعاشات و شاک پالس به سیستم کنترلر اتصال می‌یابد. به هر ماژول می‌توان ۸ سنسور متصل نمود. کلیه اطلاعات اخذشده از سنسورها توسط ماژول‌ها به سیستم کنترلر و از آنجا به

2 Monotonic

3 Vib

4 SPM_{rms}^{HDM}

5 Intellinova



شکل ۴. روند تغییرات ریشه میانگین مربعات سیگنال ارتعاشی و پالس ماکزیمم شاک پالس نسبت به زمان برای هر شش تست عمر پرشتاب انجام شده

Fig. 4. The trend of SPM_{HDm} and V_{rms} for all six accelerated-life experiments

نویز داده‌ها می‌شود و به الگوریتم هموارسازی^۳ داده‌ها مرسوم است. در پژوهش حاضر طول پنجره زمانی برابر با ۵ در نظر گرفته شده است و خصیصه‌های مورد نظر از طریق رابطه (۱) هموار می‌شوند:

$$V_{s_i} = \frac{1}{5} \sum_{j=0}^4 V_{i-j} \quad (1)$$

که در آن V مقدار اولیه خصیصه و V_s مقدار خصیصه پس از هموارشدن است. پس از این مرحله، نوبت به مرتب‌کردن داده‌ها به عنوان ورودی و هدف شبکه عصبی پیشخور می‌رسد. نکته مهمی که در این مرحله بسیار حائز اهمیت است و در آموزش صحیح شبکه عصبی نقش دارد این است که به طور معمول شبکه عصبی پیشخور برای مسائل استاتیکی کاربرد دارد. حال آنکه رشد عیب و تخمین عمر مفید باقی‌مانده یک مساله دینامیکی است. لذا در نگاه اول به نظر می‌رسد با توجه به ماهیت دینامیکی مساله بهتر است از شبکه عصبی بازگشتی استفاده گردد که از خروجی آن نیز مقداری به صورت پس‌خوراند به ورودی داده می‌شود. اما یک راه دیگر برای در نظر گرفتن ماهیت دینامیک مساله این است که از همان شبکه عصبی پیشخور استفاده شود با این شرط که علاوه بر مقادیر پارامترها، مقادیر مشتق پارامترها نیز به عنوان پارامتر ورودی در نظر گرفته شود. یک موضوع مهم دیگر در انتخاب ورودی‌های شبکه عصبی این است که زمان (عمر یاتاقان غلتشی در هر لحظه) نیز می‌تواند به عنوان ورودی در نظر گرفته شود. لازم است توجه شود که انجام این کار هم دارای مزیت و هم دارای ایراد است. مزیت انجام این کار به این است که زمان یک پارامتر همواره صعودی است. بنابراین در مدتی که سایر پارامترها ثابت هستند، این پارامتر در حال افزایش است و با این کار می‌توان از شبکه انتظار داشت که ضمن ثابت‌بودن سایر پارامترها گذر زمان و سپری‌شدن عمر را درک کند و آن را در پیش‌بینی عمر مفید باقی‌مانده لحاظ کند. حال آنکه اگر زمان به عنوان ورودی شبکه عصبی داده نشود و ورودی صرفاً خصیصه‌های ارتعاشی مانند ریشه میانگین مربعات سیگنال ارتعاشی و پالس ماکزیمم شاک پالس باشد، در مدتی که یاتاقان غلتشی در وضعیت سلامت و عادی خود است و هنوز هیچ عیبی مشاهده نشده است، تمام ورودی‌ها همواره

کامپیوتر منتقل می‌گردد. نرم‌افزار قدرتمند کاندمستر روبي^۱ که دارای عملکردهای مختلف است اطلاعات دریافت‌شده را طبق نیاز کاربر پایش، آنالیز و ارائه می‌نماید.


همانطور که مشاهده می‌شود، مطابق شکل ۴ در بیشتر موارد خصیصه ریشه میانگین مربعات سیگنال ارتعاشی نسبت به خصیصه پالس ماکزیمم شاک پالس روند رشد ناشی ایجاد و توسعه عیب را دیرتر آغاز کرده است. لذا انتظار می‌رود انتخاب خصیصه پالس ماکزیمم شاک پالس به عنوان ورودی شبکه عصبی، سبب بهبود عملکرد شبکه عصبی برای تخمین عمر یاتاقان غلتشی شود. برای بررسی این موضوع، یک بار تنها ریشه میانگین مربعات سیگنال ارتعاشی به عنوان ورودی و بار دیگر ترکیب ریشه میانگین مربعات سیگنال ارتعاشی و پالس ماکزیمم شاک پالس به عنوان ورودی‌های مدل شبکه عصبی مورد بررسی قرار خواهد گرفت که در بخش بعدی جزئیات دقیق‌تر این مدل‌ها معرفی خواهد شد.

۴-۲- الگوریتم پیشنهادی برای تخمین عمر مفید باقی‌مانده یاتاقان غلتشی

شبکه عصبی مصنوعی یکی از روش‌های داده‌محور است که در مسئله پیش‌بینی عمر یاتاقان‌های غلتشی به طور گسترده‌ای از آن استفاده می‌شود [۶، ۷]. در پروژه حاضر الگوریتمی بر اساس استفاده از شبکه عصبی پیشخور ارائه می‌شود. لازم به توضیح است که ساختار کلی این الگوریتم تا حدودی مبتنی بر پژوهش‌های انجام‌شده قبلی است [۱۶]. در گام آموزش، ابتدا خصیصه‌های مورد نظر از روی داده‌های پایش وضعیت استخراج می‌شوند. در زمان داده‌برداری معمولاً نوساناتی مقادیر ارتعاشات را تحت تأثیر قرار می‌دهند. ضمناً ممکن است در نقاطی شاهد تغییرات ناگهانی خصیصه‌ها باشیم که این موضوع بر خلاف روند افزایشی و یکنواخت رشد عیب مورد انتظار در یاتاقان‌های غلتشی می‌باشد. از همین رو جهت کاهش مقدار خطا بهتر است تا با انتخاب یک پنجره متحرک^۲ زمانی مناسب، از داده‌های روی این پنجره میانگین‌گیری شود و مقدار میانگین جایگزین مقدار انتهای پنجره زمانی متحرک شود. این کار به عنوان یک پیش‌پردازش اولیه روی روند ثبت‌شده از داده‌های خام، منجر به کاهش نوسانات و

1 Condmaster Ruby
2 Moving Window

3 Smoothing Algorithm



شکل ۵. روند تغییرات ریشه میانگین مربعات سیگنال ارتعاشی و پالس ماکزیمم شاک پالس نسبت به زمان برای تست اول و نمایش لحظه t_s و t_v
 Fig. 5. The trend of SPM_{HDm} and V_{rms} for the first accelerated-life experiment and the presentation of T_v and T_s moment

جدول ۲. مقادیر t_s و t_v برای شش تست انجام شده

Table 2. The values of T_v and T_s for six run-to-failure tests

t_s (second)	t_v (second)	شماره تست
۹۸۵۶	۹۸۵۶	۱
۸۸۴۴	۹۳۲۷	۲
۳۴۲۷	۲۷۲۶۸	۳
۲۴۳۷۹	۲۴۳۷۹	۴
۷۱۶۱	۱۲۹۸۴	۵
۵۰۵۱	۱۳۲۹۰	۶

را وارد کند. همچنین برای افزایش کارایی آموزش صحیح تر شبکه عصبی، دو پارامتر دیگر که بیانگر وضعیت سلامت یاتاقان (یعنی سالم یا معیوب) می باشند به عنوان ورودی در نظر گرفته می شوند. این پارامترها هم بر حسب زمان تعریف می شود و به صورت رابطه (۲) و (۳) محاسبه می شود.

$$T_s = \begin{cases} 0 & t < t_s \\ t - t_s & t > t_s \end{cases} \quad (2)$$

$$T_v = \begin{cases} 0 & t < t_v \\ t - t_v & t > t_v \end{cases} \quad (3)$$

در روابط فوق t_s و t_v بیانگر آخرین زمانی است که به ترتیب خصیصه‌ی ریشه میانگین مربعات سیگنال ارتعاشی و پالس ماکزیمم شاک پالس مسطح بوده و هنوز روند رشد خود را آغاز نکرده‌اند (شکل

ثابت است. بنابراین نمی توان انتظار داشت که با گذر زمان مقدار عمر باقی مانده پیش بینی شده تغییر کند. در این صورت عملاً شبکه قابلیت یادگیری تخمین عمر مفید باقی مانده پیش از شروع رشد عیب را نخواهد داشت. اما از سوی دیگر باید در نظر داشت که عمر سپری شده و عمر مفید باقی مانده با هم رابطه خطی دارند. به طوری که مجموع عمر سپری شده یاتاقان غلثشی و مقدار عمر باقی مانده آن همواره ثابت و برابر با کل عمر آن یاتاقان خواهد بود. این رابطه خطی می تواند منجر گردد تا شبکه عصبی به گونه‌ای آموزش ببیند که این رابطه خطی را کشف کرده و در نتیجه مقدار عمر باقی مانده را صرفاً از روی عمر سپری شده تخمین بزند. برای جلوگیری از این وقوع این مشکل لازم است که بیش از یک مجموعه داده برای آموزش استفاده شود و عمر نهایی مجموعه داده‌های مختلف نیز با یکدیگر فرق کند. در این صورت به ازای ورودی‌های یکسان زمانی، مقادیر خروجی (یعنی عمر باقی مانده) متفاوت خواهد بود و بنابراین شبکه عصبی یاد می گیرد که برای تخمین عمر مفید باقی مانده اثر پارامترهای دیگر

شبکه به حد کافی آموزش ببیند و رفتار کلی مد نظر را یاد بگیرد و بیش‌برازش^۳ شبکه عصبی روی داده‌ها رخ ندهد. بیش‌برازش به این معناست که شبکه عصبی حتی اغتشاشات و نویزهای ورودی و هدف را نیز مدل‌سازی کند. وقوع این موضوع مطلوب نیست و چنانچه رخ دهد، گرچه خطای عملکرد شبکه روی داده‌های آموزشی کاهش می‌یابد، اما منجر به اشکال در عملکرد شبکه روی داده‌های جدید و افزایش خطای پیش‌بینی روی دیگر داده‌ها می‌شود. یک روش موثر برای جلوگیری از وقوع بیش‌برازش شبکه عصبی این است که معیار توقف شبکه عصبی بر اساس خطای اعمال شبکه روی داده‌های صحنه‌سنجی تعریف شود. برای اطمینان از این موضوع حتی بهتر است که یک مقدار مشخصی نویز تصادفی به داده‌های صحنه‌سنجی اضافه شود تا در اثر نوسانات تصادفی داده‌های صحنه‌سنجی، مدل سیر کلی داده‌ها و خصیصه‌ها را یاد بگیرد. برای این منظور در پژوهش حاضر، از داده‌های هموارشده برای آموزش و از داده‌های غیرهموار (خام) برای صحنه‌سنجی استفاده می‌شود. این روش منجر به همان نتیجه مطلوب‌شده و مانع از وقوع بیش‌برازش شبکه می‌گردد. پس از آماده‌سازی، مرتب‌کردن و دسته‌بندی داده‌ها آموزش شبکه عصبی با دادن ورودی‌های و هدف‌ها طبق ساختار معرفی شده، انجام می‌شود و در انتهای گام آموزش، مدل داده محور شبکه عصبی ایجاد می‌شود. حال این مدل آماده است که در گام پیش‌بینی مورد استفاده قرار گیرد. در گام پیش‌بینی در مرحله نخست خصیصه‌ها از داده‌های اندازه‌گیری استخراج می‌شود. سپس الگوریتم هموارسازی (با همان طول پنجره‌ای که در مرحله آموزش مورد نظر بود) روی خصیصه‌ها اعمال می‌شود. در ادامه، ورودی‌های شبکه عصبی طبق ساختار مورد نظر آماده می‌شود و به شبکه‌ی آموزش داده‌شده در گام آموزش خورنده می‌شود. شبکه عصبی با دریافت ورودی‌ها، خروجی T_{ratio} را تولید می‌کند که همان نسبت عمر مفید باقی‌مانده یاتاقان غلتشی است. با در دست داشتن این خروجی، تخمین عمر مفید باقی‌مانده از رابطه‌ی (۵) بدست می‌آید:

$$\frac{t_i}{RUL_i} = \frac{1 - T_{ratio_i}}{T_{ratio_i}} \quad (5)$$

در شکل ۶ فلوجارت روند پیش‌بینی عمر توسط مدل داده‌محور

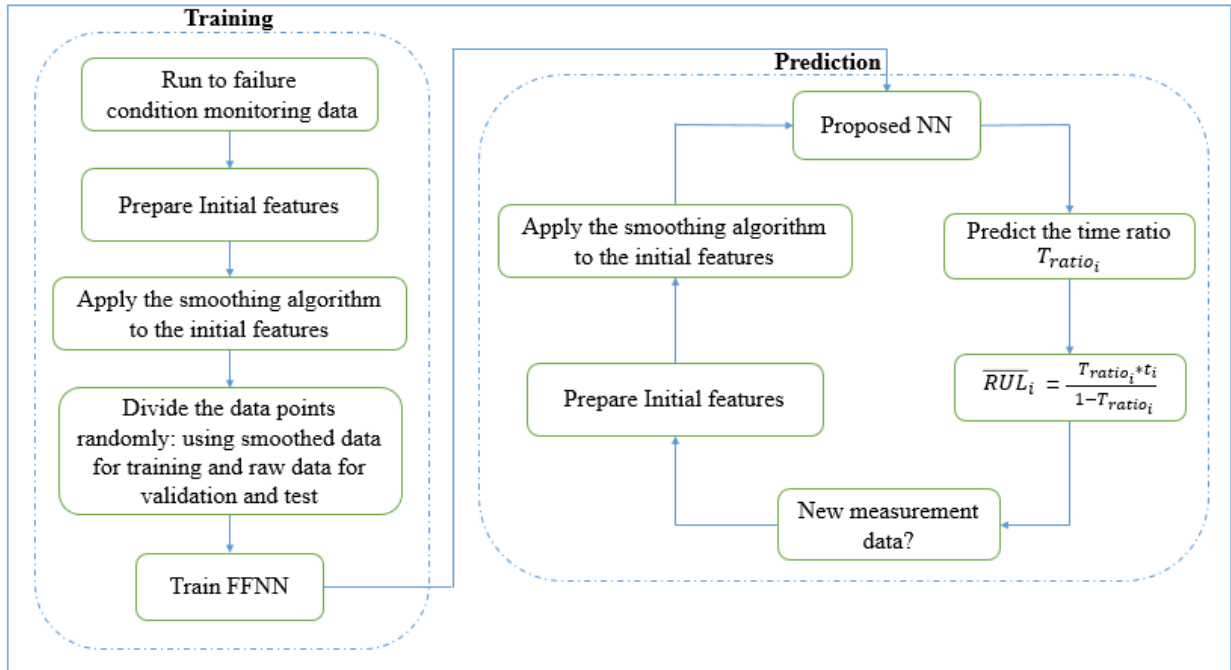
(۵). T_s و T_v هم به ترتیب پارامترهایی برای نشان دادن وضعیت سلامت یاتاقان تست از نظر وضعیت ارتعاشات و از نظر وضعیت شاک پالس می‌باشد. در جدول ۲ مقادیر زمانی t_s و t_v برای شش تست انجام شده، گزارش شده است. معیار تشخیص برای لحظه شروع روند رشد خصیصه، در نظر گرفتن ده درصد رشد در خصیصه بوده است. البته این نکته نیز لحاظ شده است که روند رشد پس از آن ادامه‌دار بوده باشد و ضمناً علائم وجود عیب نیز در مراحل بعدی، وجود عیب را تایید کند. به طوری که اگر رشد ناگهانی در یک خصیصه دیده شود و بعد از مدت کوتاهی وضعیت خصیصه به شرایط سابق آن باز گردد، این نقطه به عنوان وقوع عیب در نظر گرفته نشده است. برای مثال افزایش ناگهانی روند خصیصه‌ی پالس ماکزیمم شاک پالس در زمان حدود ۳۰۰۰ ثانیه در تست پنجم نمونه‌ای از همین موارد است. برای عملکرد بهتر شبکه عصبی بهتر است خروجی به صورت عددی بین صفر تا یک تعریف شود [۱۳-۱۵]. برای این منظور خروجی شبکه عصبی به جای مقدار عمر، نسبت عمر باقی‌مانده یاتاقان غلتشی در نظر گرفته می‌شود که به صورت نسبت عمر مفید باقی‌مانده به عمر مفید^۱ یاتاقان غلتشی، مطابق با رابطه (۴) تعریف می‌شود.

$$T_{ratio_i} = \frac{UL - t_i}{UL} \quad (4)$$

در رابطه فوق UL کل عمر مفید یاتاقان غلتشی است. پایان عمر تجهیز لحظه‌ای در نظر گرفته می‌شود که خصیصه تنزل یاتاقان غلتشی برای اولین بار از آستانه‌ی خرابی عبور نماید. پس از تعریف و مرتب‌کردن ورودی‌ها و خروجی نوبت به دسته‌بندی داده‌های مورد استفاده در گام آموزش می‌رسد. در این مرحله کلیه داده‌های آموزشی به سه دسته تقسیم می‌شود. ۶۰ درصد از داده‌ها برای آموزش و ۳۰ درصد داده‌ها نیز برای صحنه‌سنجی و ۱۰ درصد مابقی نیز برای تست عملکرد شبکه عصبی در نظر گرفته می‌شود. برای آموزش این شبکه عصبی از الگوریتم لوبنبرگ-مارکوارت^۲ استفاده خواهد شد که اساس آن اصلاح ضرایب وزنی پس از مرحله محاسبه خروجی و مقایسه خطای خروجی نسبت به خروجی مطلوب است. موضوع مهمی که در مرحله آموزش باید مورد توجه قرار گیرد این است که


1 Usful Life (UL)
2 Levenberg-Marquart

3 Overfitting



شکل ۶. الگوریتم پیشنهادی برای تخمین عمر مفید باقی‌مانده یاتاقان غلتشی

Fig. 6. The proposed algorithm for RUL prediction of REBs



شکل ۷. ساختار شبکه عصبی به کاررفته در مرجع [۱۶]


Fig. 7. The structure of the neural network structure in reference [16]

مفید باقی‌مانده یاتاقان غلتشی، از الگوریتم معرفی شده در بخش قبل با پارامترهای ورودی متفاوت استفاده می‌شود. مدل شبکه عصبی پیشخور بکاررفته در مرجع [۱۶] به عنوان یک مدل به کاررفته در ادبیات مورد مطالعه و استفاده قرار می‌گیرد. ساختار مدل مذکور مطابق با شکل ۷ می‌باشد. در این مدل فقط از خصیصه‌های مربوط به ارتعاشات و زمان سپری شده از ابتدای عمر به عنوان ورودی شبکه

توسعه داده شده در این پژوهش نشان داده است.

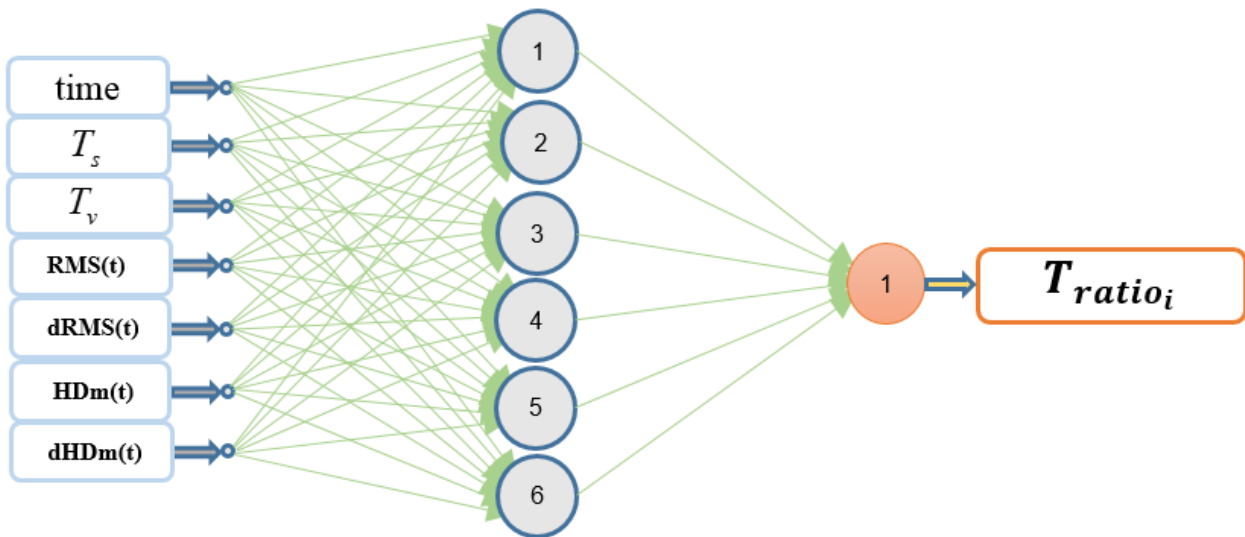
۳-۴- تخمین عمر یاتاقان غلتشی به کمک شبکه عصبی و به کارگیری داده‌های تجربی

به منظور مقایسه کاربرد خصیصه‌ی استخراج شده از شاک پالس با خصیصه‌ی استخراج شده از سیگنال ارتعاشات برای تخمین عمر



شکل ۸. ساختار شبکه عصبی مدل پیشنهادی اول

Fig. 8. The neural network structure of the first proposed model



شکل ۹. ساختار شبکه عصبی مدل پیشنهادی دوم

Fig. 9. The neural network structure of the second proposed model

لایه می‌باشد که لایه اول (لایه پنهان^۱) شامل شش نرون بوده و از یک تابع سیگموئید در خروجی این لایه استفاده شده است. در لایه دوم از تابع خطی^۲ برای خروجی نهایی استفاده شده است. تعداد نرون‌های لایه پنهان بر اساس آزمون و خطا بر مبنای کمینه خطای میانگین مشخص شده است. ساختار دو مدل پیشنهادی در شکل‌های ۸ و ۹ نشان داده شده است.

عصبی استفاده می‌شود. دو مدل پیشنهادی مقاله‌ی حاضر نیز که با اعمال اصلاحاتی روی همین مدل توسعه داده شده‌اند نیز در ادامه توضیح داده خواهد شد.

در مدل پیشنهادی اول فقط از خصیصه‌های مربوط به ارتعاشات و زمان و مشخصه سلامت یا تاقان به عنوان ورودی شبکه عصبی استفاده می‌شود و در مدل پیشنهادی دوم علاوه بر ورودی‌های مدل پیشنهادی اول، از خصیصه‌های استخراج‌شده به کمک روش شاک پالس نیز به عنوان ورودی دیگر مدل استفاده می‌گردد. این دو مدل متشکل از دو

1 hidden layer
2 linear function

جدول ۳. محاسبه خطای هر مدل برای همه حالت‌های مختلف داده‌های آموزش و تست

Table 3. The error of each model for all different case of training and test data

خطای هر مدل برای حالت‌های مختلف						داده‌های تست	داده‌های آموزش
مدل دوم پیشنهادی		مدل اول پیشنهادی		مدل مرجع [۱۶]			
err _{۹-۳۰}	Err _{۹-۳۰}	err _{۹-۳۰}	Err _{۹-۳۰}	err _{۹-۳۰}	Err _{۹-۳۰}		
۱۳/۲	۴۹/۳	۲۰/۹	۲۹/۹	۳۱/۶	۳۵/۵	۱	۳ و ۴ و ۵ و ۶
۱۰/۳	۲۱/۴	۱۱/۱	۱۷/۲	۲۲/۳	۳۲/۵	۲	
۱۳/۲	۳۱/۸	۱۲/۳	۲۱/۱	۲۴/۵	۲۶/۳	۱	۳ و ۴ و ۵ و ۶
۳۶/۲	۵۶/۵	۴۲/۶	۶۳/۶	۴۴/۵	۶۲/۱	۳	
۲۱/۱	۳۲/۳	۲۵/۴	۶۲	۲۵/۷	۶۳/۳	۱	۳ و ۴ و ۵ و ۶
۴۲/۳	۵۹/۵	۴۵/۶	۶۱/۴	۵۳/۶	۷۰/۳	۴	
۱۷/۲	۲۵/۸	۳۰/۲	۵۲	۳۲/۲	۵۴/۴	۱	۳ و ۴ و ۵ و ۶
۳۰/۶	۳۱/۲	۴۸/۵	۳۴/۱	۴۸/۱	۳۶/۶	۵	
۱۵/۱	۱۷/۸	۳۹/۱	۸۱/۴	۴۳/۲	۸۶/۴	۱	۳ و ۴ و ۵ و ۶
۱۸/۵	۳۲/۴	۲۵/۷	۴۱/۸	۲۹/۶	۴۶/۳	۶	
۲۴/۱	۴۶/۱	۲۲/۴	۸۵/۵	۲۵/۱	۸۴/۴	۲	۳ و ۴ و ۵ و ۶
۲۳/۲	۵۶/۸	۲۴/۲	۵۹/۸	۲۶/۲	۶۰/۲	۳	
۱۳/۹	۲۴/۸	۲۸/۳	۲۸/۱	۲۹/۴	۳۳/۵	۲	۳ و ۴ و ۵ و ۶
۴۲/۱	۴۴/۲	۴۵/۱	۸۴/۴	۴۴/۲	۸۶/۲	۴	
۱۲/۵	۲۴/۸	۲۳/۱	۴۳/۳	۲۲/۷	۴۳/۱	۲	۳ و ۴ و ۵ و ۶
۲۵/۴	۳۲/۴	۲۴/۷	۴۳/۱	۲۵/۲	۴۵/۳	۵	
۲۰/۷	۴۳/۵	۴۱/۷	۷۲/۱	۴۲/۳	۷۳/۵	۲	۳ و ۴ و ۵ و ۶
۲۲/۸	۴۳/۲	۳۲/۷	۴۶/۲	۳۳/۲	۴۷/۱	۶	
۲۳/۶	۴۱/۲	۵۳/۲	۷۲/۴	۵۰/۲	۷۳/۹	۳	۳ و ۴ و ۵ و ۶
۲۴/۲	۳۲/۴	۳۵/۵	۵۴/۱	۳۴/۵	۵۵/۳	۴	
۳۰/۱	۴۶/۲	۳۶/۳	۵۵/۹	۳۶/۵	۵۶/۳	۳	۳ و ۴ و ۵ و ۶
۲۴/۱	۵۴/۲	۵۵/۲	۸۸/۵	۵۴/۶	۸۸/۷	۵	
۱۱/۱	۴۸/۶	۵۲/۱	۷۶/۷	۴۹/۹	۷۷/۲	۳	۳ و ۴ و ۵ و ۶
۱۴/۳	۵۲/۲	۶۴/۸	۸۳/۲	۶۶/۵	۷۹/۴	۶	
۲۹/۲	۳۵/۲	۳۰/۲	۸۴/۲	۳۲/۵	۸۴/۲	۴	۳ و ۴ و ۵ و ۶
۲۵/۴	۳۲/۱	۴۱/۸	۴۶/۲	۳۸/۹	۴۸/۲	۵	
۲۱/۱	۴۶/۲	۳۷/۶	۷۲/۵	۳۶/۵	۷۳/۵	۴	۳ و ۴ و ۵ و ۶
۱۶/۷	۴۲/۱	۲۱/۹	۵۵/۱	۲۲/۲	۵۷/۳	۶	
۲۱/۴	۶۹/۷	۲۱/۶	۴۶/۹	۲۵/۵	۴۷/۹	۵	۳ و ۴ و ۵ و ۶
۱۹/۲	۶۵/۶	۳۵/۷	۸۲/۳	۳۶/۵	۸۴/۷	۶	
۲۲/۰۶	۴۰/۳۷	۳۳/۷۲	۵۸/۱۹	۳۶/۲۶	۶۰/۴۵		میانگین خطا

روی داده‌های دو یاتاقان دیگر اعمال می‌شود. این کار برای تمام ترکیب‌های ممکن برای انتخاب چهار یاتاقان از شش یاتاقان انجام می‌شود و نتایج آن‌ها برای بررسی و مقایسه عملکرد در نظر گرفته می‌شود. از آنجایی که مدل مبتنی بر شبکه عصبی به خاطر انتخاب اولیه‌ی تصادفی ضرایب وزنی دارای عدم قطعیت است و هیچگاه دو

برای دو مدل پیشنهادی و مدل به‌کاررفته در مرجع [۱۶]، حالت‌های مختلف داده‌های یاتاقان مورد نظر برای آموزش و پیش‌بینی لحاظ می‌گردد. بدین صورت که هر بار داده‌های چهار یاتاقان از شش یاتاقان مورد نظر برای آموزش مدل داده‌محور استفاده می‌شود و بعد مدل آموزش داده‌شده به منظور پیش‌بینی عمر مفید باقی‌مانده

در بازه بهره‌برداری نرمال یا شروع خرابی بسیار حائز اهمیت است و تخمین عمر مفید باقی‌مانده در ابتدای نصب و همچنین در اواخر عمر از نظر کاربردی کمتر اهمیت دارد. نتیجه‌ی درصد حداکثر و میانگین خطای رخ داده به ازای تمام حالت‌های مختلف برای دو مدل مورد نظر در جدول ۳ گزارش شده است. در مجموع ۱۵ حالت مختلف برای انتخاب داده‌های چهار یاتاقان از شش یاتاقان وجود دارد که در جدول ۳ مشخص شده است. به ازای هر حالت آموزش دو یاتاقان دیگر برای پیش‌بینی در نظر گرفته شده است و نتیجه‌ی خطای هر پیش‌بینی به ازای دو مدل پیشنهادی و همچنین مدل استفاده‌شده در مرجع [۱۶] در یک سطر این جدول گزارش شده است. همچنین در سطر آخر این جدول میانگین خطای پیش‌بینی روی همه‌ی حالات ترکیب یاتاقان‌ها به ازای این سه مدل مورد نظر قابل مشاهده است.

مطابق با نتایج ارائه‌شده در جدول ۲ مدل پیشنهادی دوم از نظر خطای پیش‌بینی (هم از نظر میانگین خطا و هم از نظر حداکثر خطا) وضعیت بهتری نسبت مدل پیشنهادی اول و مدل مرجع [۱۶] داشته است. لذا می‌توان بیان نمود که اضافه‌کردن خصیصه‌ی روش شاک‌پالس به عنوان پارامتر ورودی شبکه موجب بهبود دقت پیش‌بینی عمر مفید باقی‌مانده یاتاقان غلتشی شده است.

از آنجا که تعداد پیش‌بینی‌های انجام‌شده بسیار زیاد است، نمایش نمودار تمام پیش‌بینی‌ها امکان‌پذیر نیست. از این رو، در ادامه تنها نمودار یک پیش‌بینی روی هر یک از یاتاقان‌ها (به عنوان یاتاقان تست) نمایش داده می‌شود. در هر مورد نیز داده‌های به‌کاررفته برای آموزش مدل در توضیحات شکل مربوطه مشخص شده است. در ابتدا در شکل‌های ۱۰ تا ۱۲ نتایج پیش‌بینی روی یاتاقان‌های ۱ تا ۶ با استفاده از مدل شبکه عصبی مرجع [۱۶] ارائه شده است.

همان‌طور که پیش‌تر تاکید شد، از آنجایی که تعداد پیش‌بینی‌های انجام‌شده بسیار زیاد است، نمایش نمودار تمام پیش‌بینی‌ها امکان‌پذیر نیست. از این رو، در ادامه تنها نمودار یک پیش‌بینی به کمک دو مدل پیشنهادی روی هر یک از یاتاقان‌ها (به عنوان یاتاقان تست) نمایش داده می‌شود. در شکل‌های ۱۳ تا ۱۸ نتایج پیش‌بینی روی یاتاقان‌های ۱ تا ۶ با دو مدل پیشنهادی ارائه شده است. در هر مورد نیز داده‌های به‌کاررفته برای آموزش مدل در توضیحات شکل مربوطه مشخص شده است. بررسی کلی این نمودارها (شکل‌های ۱۰ تا ۱۸) نشان می‌دهد که مدل پیشنهادی دوم رفتار مناسب‌تر و دقیق‌تری در

بار آموزش با شرایط و داده‌های یکسان منجر به بدست‌آمدن مدل واحد نخواهد شد، الگوریتمی برای کاهش اثر این عدم قطعیت در نظر گرفته می‌شود. بدین صورت که در هر حالت که چهار یاتاقان برای آموزش و دو یاتاقان دیگر برای پیش‌بینی انتخاب می‌شود، فرآیند آموزش و پیش‌بینی ده مرتبه به طور کامل انجام و تکرار می‌شود و بهترین شبکه‌ی آموزش داده شده بر اساس معیار کمترین خطای متوسط به عنوان نتیجه‌ی نهایی آن ترکیب در نظر گرفته می‌شود و نتایج مربوط به آن گزارش خواهد شد. برای مقایسه‌ی بین نتایج دو مدل مورد نظر، دو معیار تعریف می‌شود. معیار اول، حداکثر خطای پیش‌بینی در بازه زمانی ۰٫۳ تا ۰٫۹ عمر هر یاتاقان غلتشی است که از روی اختلاف عمر مفید باقی‌مانده تخمین زده شده توسط شبکه^۱، و عمر مفید باقی‌مانده واقعی^۲ در هر لحظه به صورت زیر تعریف می‌شود که $0.3 \leq T_i \leq 0.9$:


$$Err_{30-90} = \max\left(\frac{RUL_i - \overline{RUL}_i}{RUL_i}\right) \quad (6)$$

معیار دیگر مورد استفاده میانگین مقدار خطای تمام پیش‌بینی‌های انجام‌شده در بازه‌ی زمانی ۰٫۳ تا ۰٫۹ عمر هر یاتاقان غلتشی است که به صورت زیر تعریف می‌شود:

$$err_{30-90} = \frac{1}{n_1 - n_2 + 1} \sum_{i=n_1}^{n_2} \left(\frac{RUL - \overline{RUL}}{RUL_i}\right) \begin{cases} T_{n_1} = 0.3 \\ T_{n_2} = 0.9 \end{cases} \quad (7)$$

دلیل انتخاب بازه ۰٫۳ تا ۰٫۹ عمر برای بررسی خطا این است که در ابتدای عمر ممکن است که نوساناتی در ارتعاشات یاتاقان دیده شود که وضعیت گذرا داشته باشد و بعد از مدتی یاتاقان به شرایط پایا می‌رسد. از طرفی در اواخر عمر یاتاقان هم به علت وجود خرابی معمولاً رفتار روند ارتعاشات به صورت ناپایدار و ضربه‌ای می‌شود و ممکن است خطای زیاد در پیش‌بینی مدل دیده شود. ضمن اینکه باید توجه داشت که پیش‌بینی عمر مفید باقی‌مانده به طور معمول


1 \overline{RUL}_i
2 RUL_i



شکل ۱۰. استفاده از ساختار شبکه عصبی مرجع [۱۶] در پیش‌بینی عمر مفید یاتاقان غلتشی

(راست: با داده‌های آموزش تست ۵.۴.۳ و ۶ برای پیش‌بینی تست ۱، چپ: با داده‌های آموزش تست ۵.۴.۳ و ۶ برای پیش‌بینی تست ۲)

Fig. 10. Predicting RUL of REB with the neural network structure in [16] (right: training datasets: 3, 4, 5, and 6, prediction datasets: 1; left: training datasets: 3, 4, 5, and 6, prediction datasets: 2)




شکل ۱۱. استفاده از ساختار شبکه عصبی مرجع [۱۶] در پیش‌بینی عمر مفید یاتاقان غلتشی

(راست: با داده‌های آموزش تست ۵.۴.۲ و ۶ برای پیش‌بینی تست ۳، چپ: با داده‌های آموزش تست ۵.۳.۲ و ۶ برای پیش‌بینی تست ۴)

Fig. 11. Predicting RUL of REB with the neural network structure in [16] (right: training datasets: 2, 4, 5, and 6, prediction datasets: 3; left: training datasets: 2, 3, 5, and 6, prediction datasets: 4)

به عنوان ملاک پیش‌بینی مناسب و عملکرد تخمین قابل قبول مدل دانست. بلکه رفتار پیش‌بینی مدل بر اساس شباهت رفتار بین داده‌های آموزش و تست بایستی توجیه‌پذیر باشد. به عنوان مثال در مورد نمودار مربوط به پیش‌بینی روی یاتاقان ۳ که در شکل ۱۵ نشان داده شده است، نکته حائز اهمیتی وجود دارد. علی‌رغم اینکه ممکن

پیش‌بینی عمر مفید باقی‌مانده یاتاقان غلتشی فراهم می‌کند. توجه به این نکته مهم است که پیش‌بینی با استفاده از روش پیشنهادشده لزوماً به تخمین عمر کمتر و یا بیشتر از مقدار واقعی منجر نمی‌شود و این موضوع بیشتر به داده‌های مورد استفاده در گام آموزش و گام پیش‌بینی بستگی دارد. باید توجه داشت که تنها معیار خطا را نباید



شکل ۱۲. استفاده از ساختار شبکه عصبی مرجع [۱۶] در پیش‌بینی عمر مفید یاتاقان غلتشی (راست: با داده‌های آموزش تست ۳، ۲، ۱ و ۴ برای پیش‌بینی تست ۵، چپ: با داده‌های آموزش تست ۳، ۲، ۱ و ۴ برای پیش‌بینی تست ۶)


Fig. 12. Predicting RUL of REB with the neural network structure in [16] (right: training datasets: 1, 2, 3, and 4, prediction datasets: 5; left: training datasets: 1, 2, 3, and 4, prediction datasets: 6)

مثبت کند. حال که این اتفاق رخ نداده است، در ادامه‌ی پیش‌بینی مدل متوجه شده است که ادامه رفتار یاتاقان مورد تست بیشتر شبیه به یاتاقان ۵ خواهد بود که عمر بیشتری نسبت به سه یاتاقان دیگر داشته است. بنابراین ادامه پیش‌بینی را بر اساس آنچه از رفتار این یاتاقان آموخته است، تخمین زده است. این عملکرد موفق مدل اهمیت انتخاب مناسب ورودی‌ها را برای دستیابی به نتیجه مطلوب می‌رساند که در این مقاله مورد توجه بوده است.

۵- نتیجه‌گیری

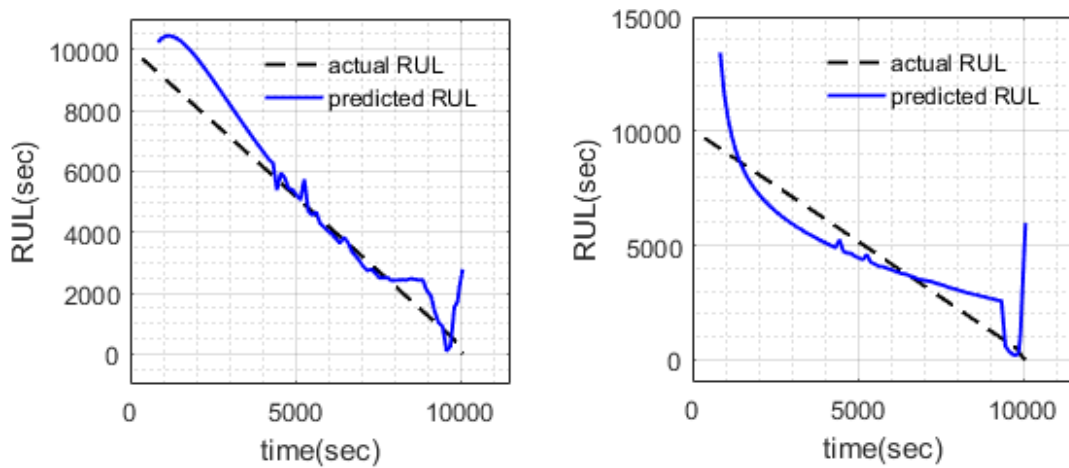
در این مقاله دو مدل داده‌محور بر اساس استفاده از شبکه عصبی پیش‌خور برای پیش‌بینی عمر مفید یاتاقان‌های غلتشی توسعه داده شد. ورودی‌های مدل اول عمر یاتاقان، عمر گذشته از زمان شروع تنزل، مقدار و شیب خصیصه ریشه میانگین مربعات سیگنال ارتعاشی آن بوده است. در مدل دوم علاوه بر ورودی‌های مدل اول، مقدار و شیب خصیصه پالس ماکزیمم شاک پالس نیز به عنوان ورودی در نظر گرفته شده است. نتایج نشان داد که عملکرد مدل دوم که خصیصه‌های استخراج‌شده از سیگنال شاک پالس نیز به عنوان ورودی در نظر گرفته شده‌اند منجر به نتایج با خطای کمتری شده است. ضمناً استفاده از عمر گذشته از زمان شروع تنزل هر خصیصه به

است خطا در پیش‌بینی انجام‌شده توسط هر دو مدل پیشنهادی زیاد به نظر برسد، ولی باید توجه کرد که عملکرد هر دو مدل روی این یاتاقان بسیار خوب و کاملاً توجیه‌پذیر بوده است. همانطور که ملاحظه می‌شود، داده‌های مورد استفاده برای آموزش هر دو مدل مربوط به یاتاقان‌های ۲، ۴، ۵ و ۶ بوده است که به ترتیب عمر آنها ۱۰۰۵۱ ثانیه، ۲۶۲۹۶ ثانیه، ۱۳۷۰۴ ثانیه و ۱۴۷۴۲ ثانیه بوده است. حال آنکه یاتاقان ۳ (یاتاقان تست) ۳۰۲۰۵ ثانیه عمر کرده است. از آنجایی که سه داده از چهار داده مورد استفاده برای آموزش عمری در حدود ۱۰ تا ۱۵ هزار ثانیه داشته‌اند، مدل نیز در ابتدای کار عمری در حدود ۱۵ الی ۲۰ هزار ثانیه را پیش‌بینی کرده است که برآوردی از رفتار چهار یاتاقان مورد استفاده در آموزش است. رفته‌رفته نیز متناسب با گذشت عمر یاتاقان، از مقدار عمر پیش‌بینی شده کاسته است. اما در زمان حدود ۱۲ هزار ثانیه، پیش‌بینی مدل شروع به تغییر کرده است. به گونه‌ای که مدل ۱ حدود ۱۰۰۰۰ ثانیه و مدل ۲ حدود ۵۰۰۰ ثانیه به تخمین عمر مفید باقی‌مانده قبلی اضافه کرده است. به نظر می‌رسد که استفاده از T_p به عنوان ورودی عامل این به روز رسانی موفقیت آمیز بوده است. به گونه‌ای که هر دو مدل انتظار داشته‌اند در این بازه زمانی (حدود ۱۲۰۰۰ ثانیه) فرآیند تنزل و شروع رشد خصیصه ارتعاشات آغاز شود و T_p به جای مقدار صفر شروع به گرفتن مقادیر



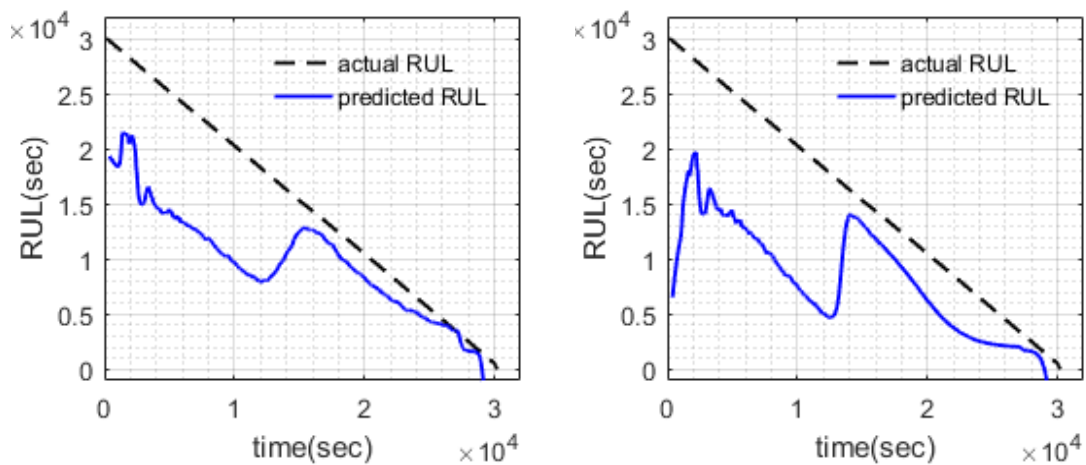
شکل ۱۳. پیش‌بینی عمر مفید یاتاقان غلتشی ۱ با داده‌های آموزش تست ۵، ۴، ۳ و ۶ (راست: مدل پیشنهاد اول، چپ: مدل پیشنهادی دوم)

Fig. 13. The RUL prediction of REB 1 with training data 3, 4, 5, and 6 (right: Model 1, left: Model 2)



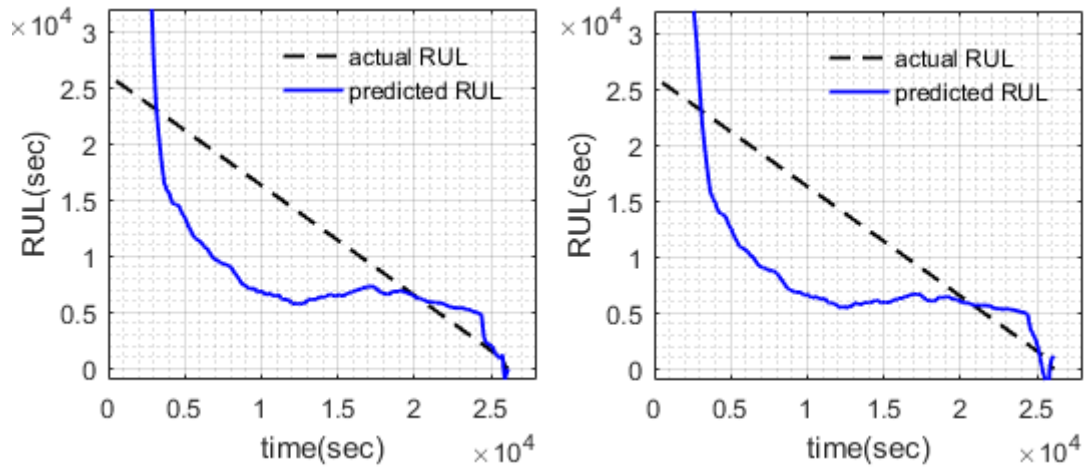
شکل ۱۴. پیش‌بینی عمر مفید یاتاقان غلتشی ۲ با داده‌های آموزش تست ۵، ۴، ۳ و ۶ (راست: مدل پیشنهاد اول، چپ: مدل پیشنهادی دوم)

Fig. 14. The RUL prediction of REB 2 with training data 3, 4, 5, and 6 (right: Model 1, left: Model 2)




شکل ۱۵. پیش‌بینی عمر مفید یاتاقان غلتشی ۳ با داده‌های آموزش تست ۵، ۴، ۳ و ۶ (راست: مدل پیشنهاد اول، چپ: مدل پیشنهادی دوم)

Fig. 15. The RUL prediction of REB 3 with training data 2, 4, 5, and 6 (right: Model 1, left: Model 2)



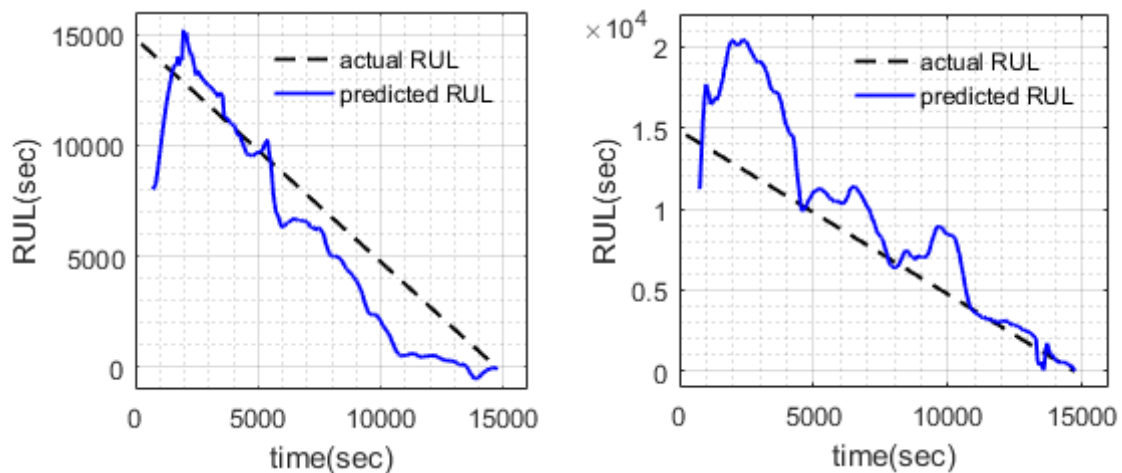
شکل ۱۶. پیش‌بینی عمر مفید یاتاقان غلتشی ۴ با داده‌های آموزش تست ۲، ۳، ۵، و ۶ (راست: مدل پیشنهاد اول، چپ: مدل پیشنهادی دوم)

Fig. 16. The RUL prediction of REB 4 with training data 2, 3, 5, and 6 (right: Model 1, left: Model 2)



شکل ۱۷. پیش‌بینی عمر مفید یاتاقان غلتشی ۵ با داده‌های آموزش تست ۱، ۲، ۳، و ۴ (راست: مدل پیشنهاد اول، چپ: مدل پیشنهادی دوم)

Fig. 17. The RUL prediction of REB 5 with training data 1, 2, 3, and 4 (right: Model 1, left: Model 2)



شکل ۱۸. پیش‌بینی عمر مفید یاتاقان غلتشی ۶ با داده‌های آموزش تست ۱، ۲، ۳، و ۴ (راست: مدل پیشنهاد اول، چپ: مدل پیشنهادی دوم)

Fig. 18. The RUL prediction of REB 6 with training data 1, 2, 3, and 4 (right: Model 1, left: Model 2)

- [9] Q. Cui, Z. Li, J. Yang, B. Liang, Rolling bearing fault prognosis using recurrent neural network, in: 29 2017th Chinese Control And Decision Conference (CCDC), IEEE, 2017, pp. 1201-1196.
- [10] X. Chen, Z. Shen, Z. He, C. Sun, Z.J.P.o.t.I.o.M.E. Liu, Part C: Journal of Mechanical Engineering Science, Remaining life prognostics of rolling bearing based on relative features and multivariable support vector machine, (2013) (12)227 2860-2849.
- [11] A.R. Bastami, A. Aasi, H.A.J.I.J.o.S. Arghand, T.o.E.E. Technology, Estimation of remaining useful life of rolling element bearings using wavelet packet decomposition and artificial neural network, 245-233 (2019) (1)43.
- [12] N. Gebraeel, M. Lawley, R. Liu, V.J.I.T.o.i.e. Parmeshwaran, Residual life predictions from vibration-based degradation signals: a neural network approach, 700-694 (2004) (3)51.
- [13] S. Saon, T.J.C. Hiyama, M.w. Applications, Predicting remaining useful life of rotating machinery based artificial neural network, 1087-1078 (2010) (4)60.
- [14] Z.J.J.o.I.M. Tian, An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring, 237-227 (2012) (2)23.
- [15] M. Behzad, H.A. Arghand, A.R.J.C.M. Bastami, D.E. Management, Rolling Element Bearings Prognostics Using High-Frequency Spectrum of Offline Vibration Condition Monitoring Data, (276 (2018).
- [16] M. Behzad, H.A. Arghand, A.J.P.o.t.I.o.M.E. Rohani Bastami, Part C: Journal of Mechanical Engineering Science, Remaining useful life prediction of ball-bearings based on high-frequency vibration features, (18)232 3234-3224 (2018).
- [17] R. Yang, J. Kang, J. Zhao, J. Li, H. Li, A case study of bearing condition monitoring using SPM, in: 2014 Prognostics and System Health Management Conference (PHM2014- Hunan), IEEE, 2014, pp. 698-695.
- [18] N. Tandon, K.J.N. Kumar, V. Worldwide, Detection of defects at different locations in ball bearings by vibration and shock pulse monitoring, 16-9 (2003) (3)34.
- [19] N. Tandon, G. Yadava, a.K.J.M.s. Ramakrishna, s.

عنوان ورودی نیز منجر به شناخت و تفکیک رفتارهای مختلف مورد استفاده در مرحله آموزش مدل می‌شود و می‌تواند به عملکرد بهتری در پیش‌بینی منجر شود.

قدردانی

نویسندگان مقاله لازم می‌دانند از شرکت صنعت آموز نوین پارسی (پارسی‌تک) به دلیل در اختیار قرار دادن تجهیزات اندازه‌گیری و کمک به انجام آزمایش‌ها تقدیر و تشکر به عمل آورند.

منابع

- [1] P. Albrecht, J. Appiarius, E. Cornell, D. Houghtaling, R. McCoy, E. Owen, D.J.I.t.o.e.c. Sharma, Assessment of the reliability of motors in utility applications, (-396 (1987 3 406.
- [2] C.J. Crabtree, D. Zappalá, P.J. Tavner, Survey of commercially available condition monitoring systems for wind turbines, (2014).
- [3] N.-H. Kim, D. An, J.-H. Choi, Prognostics and health management of engineering systems: An introduction, springer, 2016.
- [4] M.S. Kan, A.C. Tan, J.J.M.S. Mathew, S. Processing, A review on prognostic techniques for non-stationary and non-linear rotating systems, 20-1 (2015) 62.
- [5] C.J.I.-v.I.I.D.P. Monitoring, IO f. S, Diagnostics of machines-prognostics part 1: General guidelines, ((2004 14.
- [6] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, J.J.M.S. Lin, S. Processing, Machinery health prognostics: A systematic review from data acquisition to RUL prediction, 834-799 (2018) 104.
- [7] N. Gebraeel, J.J.I.T.o.R. Pan, Prognostic degradation models for computing and updating residual life distributions in a time-varying environment, (2008) (4)57 550-539.
- [8] G. Vachtsevanos, P. Wang, Fault prognosis using dynamic wavelet neural networks, in: 2001 IEEE Autotestcon Proceedings. IEEE Systems Readiness Technology Conference.(Cat. No. 01CH37237), IEEE, 2001, pp. -857 870.

- Shock Pulse Method for Early Fault Detection of Rolling Element Bearings and Comparing with Vibration Envelope Technique, AmirKabir J. Mech. Eng., (2019).
- [22] T.J.A.S.I.W.P. Sundström, SPM Instruement AB, An introduction to the SPM HD method, (2010).
- processing, A comparison of some condition monitoring techniques for the detection of defect in induction motor ball bearings, 256-244 (2007) (1)21.
- [20] R. Yang, J.J.V.P. Kang, Bearing fault detection of wind turbine using vibration and SPM, 178-173 (2016) 10.
- [21] A.D. Mehdi Behzad, Hesam Addin Arghand, Using

چگونه به این مقاله ارجاع دهیم

M. Behzad , A. Davoodabadi, H. A. Arghand, Prognostics of rolling element bearings using shock pulse method and vibration method records and employing feedforward neural-network, AmirKabir J. Mech. Eng., 53(Special Issue 4) (2021) 2557-2576.

DOI: [10.22060/mej.2020.18253.6786](https://doi.org/10.22060/mej.2020.18253.6786)

