

Amirkabir Journal of Mechanical Engineering

Amirkabir J. Mech. Eng., 54(2) (2022) 93-96 DOI: 10.22060/mej.2021.20023.7153

A New Machine Learning Method for Ball Bearing Condition Monitoring Based on Vibration Analysis

M. R. Kaji¹, J. Parvizian^{1*}, M. Silani¹, H. W. van de Venn²

¹ Department of Mechanical Engineering, Isfahan University of Technology, Isfahan, Iran. ² Institute of Mechatronic Systems, Zurich University of Applied Sciences, 8401 Winterthur, Switzerland.

ABSTRACT: In recent years, with the advent of the Fourth Industrial Revolution concepts and the development of artificial intelligence technologies, new approaches such as the digital twin have been introduced. In a digital twin, a virtual counterpart of the physical system during its whole life is created, with abilities such as analyzing, evaluating, optimizing, and predicting. The first step in creating a digital twin model is to construct a (multi) digital health indicator that describes different aspects of the physical component state during the whole life of the component. In this research, a new method for constructing health indicators based on vibration measurement and a deep learning model has been introduced. For this purpose, the Continuous Wavelet Transform was used to convert the raw vibration signals into twodimension images; Then, the deep learning model was used to extract features from the images and the health indicator is constructed based on the differences of the images in normal and failure stages. In this article, various Autoencoder architectures are discussed, and it is demonstrated that the Convolutional Autoencoder has better performance in terms of detecting incipient faults. The performance of the proposed model is evaluated by the vibration data of the bearing, and the constructed health indicator exhibited a monotonically increasing degradation trend and had good performance in terms of detecting incipient faults.

1-Introduction

Performance degradation is an inevitable part of each asset that can lead to machinery damage, severe financial losses, or even personal injury. In order to prevent or eliminate the failure of the asset, condition monitoring methods have been developed. Condition monitoring methods are mainly categorized in run-to-failure maintenance, preventive maintenance, and predictive maintenance. Among these approaches, predictive maintenance provides better reliability [1]. The first step in predictive maintenance implementation is to construct a (multi) health indicator that describes different aspects of the physical component state during the whole life of the component. This health indicator should represent the deviation between the initial conditions of the component and its actual conditions during its lifetime [2]. constructing a health indicator can be performed in three steps: (1) signal acquisition; (2) signal processing; and (3) feature extraction [3]. Vibration measurement provides a very efficient way of monitoring the dynamic conditions of a machine. Traditional analysis method of the vibration data such as fast Fourier transform, Wavelet transform have two deficiencies: (1) Feature selection is heavily dependent on prior knowledge and diagnostic expertise. Moreover, it often focuses on a



*Corresponding author's email: japa@iut.ac.ir

Copyrights for this article are retained by the author(s) with publishing rights granted to Amirkabir University Press. The content of this article is subject to the terms and conditions of the Creative Commons Attribution 4.0 International (CC-BY-NC 4.0) License. For more information, please visit https://www.creativecommons.org/licenses/by-nc/4.0/legalcode.



Received: May, 08, 2021 Revised: Aug. 26, 2021 Accepted: Aug. 27, 2021 Available Online: Sep. 01, 2021

Keywords:

Condition monitoring Artificial intelligence Deep learning Vibration analysis Digital twin

specific fault type, thus it may be unsuitable for other faults. (2) In real industries, acquired signals are usually exposed to environmental noises, and are transient and non-stationary [4]. As a step toward the development of a single framework for system health management, this paper proposes a method to construct a health indicator from the vibrational signal, based on unsupervised deep learning. This method establishes an online construction of a health indicator in the sense that the input data can be acquisitioned while the equipment is being exploited. The proposed method is applicable for equipment that operates under stationary and non-stationary conditions and does not require expert knowledge.

2- Methodology

In order to construct the health indicator automatically, a method based on deep learning algorithm is proposed in this study. For this purpose, the image of Continuous Wavelet Transform (CWT) of the raw vibrational signal of the ball bearing are used as the deep learning model input. The method consists of three main stages. In the first stage, the healthy vibrational signal from the ball bearing is acquired. The CWT image of the healthy vibrational signal of the ball bearing is used as the training repository for deep learning model. In this



Fig. 1. (a) CWT image of healthy stage, (b) CWT image of failure stage.

stage, it is assumed that the bearing is in healthy conditions and it is free from the defects at the beginning of its life cycle. In the next stage, the deep learning model is trained by the CWT image of bearing in healthy condition. Finally, in the third stage, throughout the bearing failure phase, the health indicator is constructed. For this purpose, the difference in values of the bottleneck nodes values between the failure stage and the healthy stage of the bearing is measured by using the Mahalanobis Distance formula. In order to evaluate the effectiveness of the proposed method, the bearing dataset, generated by the National Science Foundation (NSF) University of Cincinnati Center for Intelligent Maintenance Systems (IMS), is employed [5].

3- Signal Processing

The purpose of CWT of the raw vibrational signal is to preprocess the raw vibration in the time-frequency domain and convert a 1D signal to a 2D image, as the input of the deep learning model. The wavelet transform can analyze a localized area of a large signal without losing the spectral information contained therein. Therefore, the wavelet transform can reveal some hidden aspects of the signal which other techniques fail to detect [6]. The degradation process of the bearing generally includes two stages: the normal operation stage and the failure stage. During a normal operation stage of the bearing, a sliding window is used to capture the vibrational signal, and for each window, the power spectrum of the CWT is used to convert a 1-D vibrational signal into a 2-D image. The transformed image contains both time and frequency domains information and can represent the non-stationary and transient evolution of the signal.

4- Deep Learning Model

In this study, two types of Autoencoder deep learning models are completely studied and the best one is selected. An autoencoder is an unsupervised neural network used for feature extraction and dimensionality reduction and is characterized by having the same number of nodes in the inputs and outputs layers [7]. The main role of the deep learning model is to learn to extract the main features of the CWT image in healthy and faulty conditions of the ball bearing. Therefore, an autoencoder model which is able to predict the input layer more accurately in the output layer, is more suitable. Comparison between deep Autoencoder (AE) and Convolutional Autoencoder (CAE) has been performed and it is demonstrated that the CAE model is superior.

5- Construction of Health Indicator

After the CAE model is trained by the healthy CWT image of the bearing, a health indicator is constructed for the failure stage automatically. A suitable health indicator is expected to exhibit a monotonically increasing trend and should be robust to noise and stochastic fluctuations. The CAE model is to learn to extract distribution characteristics of the healthy CWT image through its deep structure and to reproduce images similar to the training dataset with a small reconstruction error in the output layer. Once the failure stage started for the bearing, damage evolution of bearing leads to a more turbulent vibration pattern in CWT images. Fig. 1 demonstrates the CWT mage in the healthy and failure stage. When the CWT image of the failure stage is input to the trained CAE model, the dissimilarity between the extracted vector of features in normal stage images and the faulty sample image is measured to demonstrate the corresponding degradation indicator. For this purpose, the extracted features in the bottleneck layer are used to estimate the distance between the normal stage and the failure stage by the Mahalanobis Distance formula. This strategy is used to construct health indicator during the failure stage. In this method, the feature extraction and health indicator construction are performed automatically by the CAE model.

6- Results and Discussion

The trained deep learning model is used to construct



Fig. 2. Bearing health indicator during failure stage.

health indicator by estimating the distance of the values of the bottleneck nodes between the normal stage and failure stage. The results show that the constructed health indicators are smoother, and gradually increasing, while the degradation trends are effectively captured as well. Furthermore, the results prove that the proposed method is able to detect early bearing defects and abnormal bearing health conditions. Moreover, this method provides a health indicator that is well correlated with progressively increasing bearing degradations. The constructed health indicator for the one IMS bearing is shown in Fig. 2.

7- Conclusion

In this study, a new method for condition monitoring of the bearing based on artificial intelligence is proposed. The proposed method includes three main stage. In the first stage, the raw vibration signal of the bearing in a healthy state is converted to two-dimensional images using the CWT technique. In the next stage, an autoencoder model is trained by the healthy CWT images of the bearing. In this study, two different type of autoencoder model are studied and it is shown that the CAE model has a more accurate output than the AE model. Finally, the CWT image of the failure stage is fed to the trained CAE model and the distance between the values of bottleneck nodes in healthy and failure state is measured by Mahalanobis Distance formula, then the health indicator is constructed. The experimental results on the IMS bearing data set show the effectiveness of the proposed method.

References

- L.Z. Zepeng Liu, A Review of Failure modes, Condition Monitoring and Fault Diagnosis Methods for Large-Scale Wind Turbine Bearings, Measurement, 149 (2020).
- [2] Z.H. Fan Xu, Fangfang Yang, Dong Wang, Kwok Leung Tsui, Constructing a Health Indicator for Roller Bearings by Using a Stacked Auto-Encoder with an Exponential Function to Eliminate Concussion, Appl. Soft Comput., 89 (2020).
- [3] D.N.W. Wihan Booyse, Stephan Heyns, Deep Digital Twins for Detection, Diagnostics and Prognostics, Mech. Syst. Signal Process, 140 (2020).
- [4] S.V.K. Prashant P. Kharche, Review of Fault Detection in Rolling Element Bearing, International Journal of Innovative Research in Advanced Engineering, 1(5) (2014) 169-174.
- [5] PCoE Datasets, Bearing Data Set, Intelligent Maintenance Systems (IMS), University of Cincinnati, in.
- [6] K.-C.L.G.G. Yen, Wavelet Packet Feature Extraction for Vibration Monitoring, IEEE Transactions on Industrial Electronics, 47(3) (2000) 650 - 667.
- [7] W.L. Zhuyun Chen, Multisensor Feature Fusion for Bearing Fault Diagnosis Using Sparse Autoencoder and Deep Belief Network, IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, 66(7) (2017) 1693-1702.

HOW TO CITE THIS ARTICLE

M. R. Kaji, J. Parvizian, M. Silani, H. W. van de Venn, A New Machine Learning Method for Ball Bearing Condition Monitoring Based on Vibration Analysis, Amirkabir J. Mech Eng., 54(2) (2022) 93-96. DOI: 10.22060/mej.2021.20023.7153



This page intentionally left blank

نشریه مهندسی مکانیک امیرکبیر



نشریه مهندسی مکانیک امیرکبیر، دوره ۵۴، شماره ۲، سال ۱۴۰۱، صفحات ۴۶۵ تا ۴۸۰ DOI: 10.22060/mej.2021.20023.7153

پایش وضعیت یاتاقانهای غلتشی به روش ارتعاشی با بهره گیری از مدل یاد گیری ماشین

محمدرضا کاجی '، جمشید پرویزیان*'، محمد سیلانی' ، هانس ورنر ون د وین

۱- دانشکده مهندسی مکانیک، دانشگاه صنعتی اصفهان، اصفهان، ایران. ۲- پژوهشکده سیستمهای مکاترونیک، دانشگاه علمی کاربردی زوریخ، زوریخ، سوئیس.

تاريخچه داورى: **خلاصه:** در سال های اخیر با ظهور انقلاب صنعتی چهارم و توسعه فناوری های هوش مصنوعی، رویکردهای نوینی در زمینه نگهداری دریافت: ۱۴۰۰/۰۲/۱۸ و تعمير افزارگان معرفی شدهاند؛ که از آن جمله می توان به همزاد ديجيتال اشاره نمود. اولين گام براي ايجاد همزاد ديجيتال يک افزار، ساخت شاخصهای کمّی و کیفی است که برای توصیف لحظهای افزار در طی مدت بهرهبرداری به کار میرود. در این پژوهش یک روش نوین برای ساخت شاخص سلامت افزارگان براساس اندازهگیری ارتعاشات و مدل های یادگیری عمیق معرفیشده است. برای این منظور دادههای ارتعاشی خام تجهیز با استفاده از تبدیل موجک پیوسته به تصاویر دوبعدی تبدیل خواهند شد. سپس با استفاده از یک مدل یادگیری عمیق، میزان تفاوت تصاویر وضعیت سالم و معیوب افزار تشخیص دادهشده و شاخص سلامت ایجاد می شود. مدل ارائهشده مىتواند بهصورت خودكار شاخص سلامت را ايجاد نمايد و نيازمند دانش متخصص خبره براى تفسير نتايج آناليز ارتعاشي نیست. همچنین، آموزش مدل یادگیری عمیق بهصورت بدون نظارت بوده و تنها با استفاده از دادههای ارتعاشی وضعیت سالم تجهیز صورت میپذیرد و بنابراین نیازمند دادههای خرابی پیشین نیست. عملکرد مدل پیشنهادشده توسط دادههای ارتعاشی یاتاقان مورد ارزیابی قرار گرفته که نشان از توانایی قابل قبول شاخص سلامت در تشخیص آغاز خرابی و چگونگی روند رشد آن دارد.

بازنگری: ۱۴۰۰/۰۶/۰۴ پذیرش: ۱۴۰۰/۰۶/۰۵ ارائه أنلاين: ١۴٠٠/٠۶/١٠ كلمات كليدى: پايش وضعيت

> هوش مصنوعی یادگیری عمیق أناليز ارتعاشات همزاد ديجيتال

۱ – مقدمه

اکثر افزارگان مکانیکی همچون هواپیماها، کشتیها، توربینها و موتورها معمولاً در شرایط محیطی سخت و به مدت طولانیمدت فعالیت می کنند. ازاین رو واماندگی و خرابی این افزارگان اجتناب ناپذیر است. وجود واماندگی برای یک افزار منجر به خاموشی، افزایش هزینه تعمیرات، تأخیر در انجام وظایف، ایجاد هزینههای جانی و مالی برای افزارگان و یا واحد تولیدی می گردد [۱]. به منظور پیش گیری و یا رفع خرابی یک افزار، عملیات نگهداری و تعمیر صورت می گیرد. عملیات نگهداری و تعمیر، به مجموعهای از فعالیتهای فنی و اقدامات اصلاحی مرتبط گفته می شود که بهمنظور نگهداری و یا بازیابی سیستمها در وضعیت کاری سالم صورت می پذیرد [۲]. بهطورکلی رویکردهای موجود برای نگهداری و تعمیر در دو دسته تعمیرات اصلاحی و تعمیرات پیشگیرانه میتوان دستهبندی نمود. در رویکرد تعميرات اصلاحي پسازآنكه شكست و خرابي افزار صورت پذيرفت، اقدامات اصلاحی انجام می گیرند؛ درحالی که در رویکرد پیشگیرانه بهمنظور جلوگیری

از شكست، اقدامات اصلاحي بهصورت پيش دستانه صورت مي پذيرند [٣].

براساس دور رویکرد معرفی شده، سه دسته روش اصلی نگهداری و تعمیر

زمان خرابی افزار را پیشبینی نمود [8]. اولین و مهمترین گام برای پیادهسازی اين روشها، ساخت شاخصهاي سلامت است. شاخص سلامت توصيف كننده فاصله بین شرایط اولیه و سالم افزار با هرلحظه از آن در طول زمان رشد خرابی است. بنابراین باگذشت زمان و رشد میزان خرابیها در تجهیز، میزان این فاصله بیشتر شده و انتظار میرود شاخص سلامت بتواند این روند را بهخوبی توصیف کند [۲]. بهطورکلی ساخت شاخص سلامت دربرگیرنده سه مرحله است که عبارتاند از: (۱) جمع آوری سیگنال مناسب، (۲) پردازش سیگنال و (۳) استخراج ویژگیهای معنیدار از سیگنال بهعنوان شاخص سلامت [۷].

(Creative Commons License) حقوق مؤلفین به نویسندگان و حقوق ناشر به انتشارات دانشگاه امیرکبیر داده شده است. این مقاله تحت لیسانس آفرینندگی مردمی (Creative Commons License) در فرمائید. هر در دسترس شما قرار گرفته است. برای جزئیات این لیسانس، از آدرس https://www.creativecommons.org/licenses/by-nc/4.0/legalcode دیدن فرمائید.

پس از خرابی، نگهداری و تعمیر پیشگیرانه و نگهداری و تعمیر پیش گویانه را می توان تعیین نمود [۴]. در این میان روشهای مبتنی بر نگهداری و تعمیر پیش گویانه، بخصوص برای افزارگان سنگین، نسبت به دودسته روش دیگر جامعتر و کارآمدتر است [۵]. در روشهای نگهداری و تعمیر پیش گویانه، وضعیت هرلحظه افزار با توجه به آنالیز دادههای جمع آوری شده رصد می شود؛ تا بتوان

^{*} نویسنده عهدهدار مکاتبات: japa@iut.ac.ir

برای قطعات مکانیکی انواع مختلف دادهها قابل جمع آوری است که از آن جمله میتوان به دادههای ارتعاشی، صوتی، ترموگرافی و آنالیز روغن و ذرات سایشی اشاره نمود. برای بیشتر قطعات مکانیکی، بخصوص قطعات دوار، سیگنالهای ارتعاشی حاوی اطلاعات بسیار مفیدی برای پایش وضعیت میباشند. این سیگنالها میتوانند به خوبی عیوب دینامیکی تجهیز مانند نابالانسی، غیر همراستایی، شل شدن و لقی مکانیکی، سایش، آسیب و نمیدگی شفت را نشان دهند. برای قطعات دوار توسعه هر نوع عیب خاص منجر به تغییر رفتار دینامیکی سیستم میشود، که در الگوی ارتعاشی تجهیز اثرگذار خواهد بود [۱]. با توجه به گستردگی و کارایی سیگنالهای ارتعاشی در پایش وضعیت، در این مطالعه سیگنالهای ارتعاشی به عنوان دادههای خام در نظر گرفته شدهاند.

روشهای پردازش سیگنالهای ارتعاشی در سه حوزه زمان، فرکانس و زمان_ فرکانس دسته بندی می شوند [۸]. استفاده از روش های استخراج ویژگی در حوزه زمان نیازمند ثبت دادههای ارتعاشی در طول مدتزمان طولانی بهمنظور استنباط الگوهای ایجاد و رشد خرابی است. برای بسیاری از قطعات و خرابی های پیچیده، به دلیل حجم بالای داده موردنیاز و یا در دسترس نبودن دادهها، استفاده از این نوع آنالیز غیرممکن است [۹]. آنالیزهای سیگنال در حوزه فرکانس بهطور گسترده توسط محققان برای استخراج ویژگی و ساخت شاخص سلامت مورداستفاده قرارگرفته است [۸]. از منظر أناليز ارتعاشات، عيوب قطعات مكانيكي را مي توان به دودسته كلي طبقهبندی نمود: عیوب دورهای و عیوب گذرا. سیگنالهای ارتعاشی برای عیوب دورهای ماهیت سینوسی داشته و دارای الگو تکرارشونده یکسان در طول زمان هستند. برای این سیگنالها استفاده از روشهای آنالیز در حوزه فركانس همچون تبديل فوريه را مىتوان بهخوبى استفاده نمود، زيرا كه در تبدیل فوریه از تابع تحلیل سینوسی بهعنوان تابع پایه استفاده می شود [۱۰]. برخلاف عیوب دورهای، از روشهای آنالیز حوزه فرکانس برای تحلیل سیگنالهای عیوب گذرا نمی توان استفاده کرد. برای عیوب گذرا، سیگنالهای ارتعاشی در طی زمان تغییر کرده و ماهیت تکرارشونده ندارند. على رغم اين، اين سيگنال ها معمولاً حاوى اطلاعاتي ارزشمند از چگونگي ایجاد و رشد خرابیها میباشند که با استفاده از آنالیزهای حوزه زمان و یا فركانس نمى توان به أن دست يافت [٩].

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

فرکانسی درگذر زمان را آشکار سازند، و بنابراین اطلاعات سودمندی را از هر دو حوزه زمان و فرکانس ارائه میکنند. از میان روشهای آنالیز حوزه زمان– فرکانس، روش تبدیل موجک پیوسته^۱ برای این مطالعه انتخاب گردیده شده است. تبدیل موجک روشی جدید و نیرومند برای تحلیل سیگنالها است که میتواند تغییرات محلی جزئی در سیگنال را بهخوبی آشکار سازند [۱۱].

پس از دادهبرداری و پردازش آنها، ویژگیهای مناسب که مُعرف وضعیت افزار باشند، باید استخراج شوند. این ویژگیها باید رابطه مستقیم با خرابی افزار داشته و بتوانند ایجاد و رشد خرابیها را توصیف نمایند. روشهای موجود در ساخت شاخص سلامت از نگاه شیوه استخراج ویژگی از دادهها را میتوان در دو دسته رویکرد مبتنی بر تحلیلی فیزیکی و داده محور طبقهبندی نمود [۱۲]. در سالهای اخیر، رویکردهای داده محور بهطور گسترده و موفقیت آمیز در زمینههای پایش وضعیت و مدیریت پیش گویی و صحت استفاده شدهاند [۱۳ و ۱۴]. در این روشها، تلاش می شود تا با استفاده از حجم زیادی از دادههای عملکردی روند و ویژگی معنادار به صورت خودکار از دادههای پردازش شده، استخراج شوند.

تاکنون مدلهای یادگیری عمیق همچون شبکههای عصبی همگشتی^۲ [10]، شبکه عصبی بازگشتی^۳ [۱۶]، شبکه عصبی خود-رمزگذار^۴ [۱۷] و شبکه عصبی مولد تخاصمی⁶ [۱۸] بهطور موفقیتآمیز برای استخراج ویژگی از سیگنالهای ارتعاشی بکار گرفته شدهاند. مدلهای توسعه یافته یادگیری عمیق، بیشتر بر مبنای یادگیری نظارتشده و برای مسائل طبقهبندی استفاده شده اند. برای این گونه مسائل، به دست آوردن داده های عملکردی برای مراحل مختلف خرابی افزار ضروری است تا با استفاده از آنها بتوان پایگاههای داده سالم و ناسالم برچسبدار برای حالت مختلف عملکردی را ایجاد نمود [۱۹]. این پایگاههای داده برچسبدار برای آموزش مدلهای یادگیری عمیق بکار گرفته می شوند و چنانچه متنوع تر و گسترده تر باشند، نتایج دقیقتری را به همراه خواهند داشت. ایجاد این پایگاههای داده نیازمند تعداد زیادی از نمونههای شکست و خرابی است که برای بسیاری از افزارگان، بخصوص افزارگان با قابلیت اطمینان بالا و یا حساس، هزینهبر و یا غیرممکن است. بنابراین محدودیت اصلی برای ساخت شاخص سلامت در اکثر مطالعات، عدم در دسترس بودن دادههای خرابی گسترده برای آموزش مدلهای یادگیری عمیق است [۲۰].

- 3 Recurrent neural networks
- 4 Autoencoder neural networks
- 5 Generative adversarial networks

¹ Continuous wavelet transform

² Convolutional neural networks

برای پاسخ به محدودیت ذکرشده، توسعه مدلهای یادگیری عمیق مبتنی بر یادگیری بی نظارت که تنها از دادههای شرایط کاری سالم برای ساخت شاخص سلامت استفاده كنند، ضرورى است [٢١]. هدف از اين مطالعه ارائه یک روش نوین برای ساخت شاخص سلامت برای یاتاقان های غلتشی با استفاده از مدلهای یادگیری عمیق است. از یاتاقانهای غلتشی برای تحمل بارهای شعاعی و محوری و کاهش اصطکاک در بسیاری از افزارگان دورانی استفاده می شوند. واماندگی در یاتاقان ها عامل بیش ۵۰٪ از خرابیها در افزارگان دوار است و بنابراین توسعه روشهای پایش وضعیت برای آنها همواره موردتوجه محققان بوده است [۲۲]. واماندگی در یاتاقانها در ابتدا با افزایش سطح ارتعاشات، سروصدا و کاهش راندمان افزار همراه است و نهایتاً می تواند منجر به شکست ناگهانی و یا خرابی های فاجعهبار شود. مُدهای غالب در واماندگی یاتاقانها عبارتاند از: خستگی، سایش، خوردگی و تغییر شکلهای پلاستیک؛ که ناشی از عواملی همچون انتخاب نامناسب ياتاقان، محيط كارى نامناسب، ناهمراستايى، مونتاژ اشتباه، روانكارى ضعيف، اعمال بار اضافه، و خطاهای ساخت است. بنابراین می توان نتیجه گرفت که در اکثر مواقع رشد و توسعه خرابیها در یاتاقانها به صورت تدریجی و قابل پیش بینی صورت می پذیرند [۲۳].

بهطور سنتی روش های نگهداری و تعمیر یاتاقان ها بخصوص در افزارگان حساس مانند توربین ها، بر اساس رویکرد نگهداری و تعمیر پیشگیرانه است؛ که به دلیل عدم استفاده از ظرفیت کامل افزار، منجر به اتلاف هزینههای گسترده میشود. برای کاهش این هزینه ها، روش های پایش وضعیت متنوعی بر اساس اندازه گیری صدا، پایش جریان مصرفی، سنجش مقدار ذرات ساینده در روانکار، آنالیز ارتعاشات و ترموگرافی برای یاتاقان ها توسعه داده شده است [۳۳]. از آنجا که تغییر در سطح ارتعاشی یاتاقان از اولین نشانه های ایجاد و رشد خرابی است، روش آنالیز ارتعاشات به طور گسترده برای یاتاقان ها در صنایع استفاده می شود [۳۳]. صرف نظر از نوع عیب موجود در یاتاقان، سیگنال های ارتعاشی خرابی از اثر متقابل میان سطح آسیب و سطوح متحرک ایجاد خواهند شد و درنتیجه آنالیز ارتعاشات قادر به شناسایی عیوب خواهد بود [۲۴].

مدل یادگیری عمیق پیشنهادی در این پروژه صرفاً با دادهها در وضعیت سالم افزار آموزش دیده می شود و برای حالتهای پایدار و گذرا قابل استفاده است. برای استفاده از این مدل، سیگنال های ارتعاشی یاتاقان به صورت بر خط در طول عمر افزار با استفاده از فناوری های اینترنت اشیاء به سرور ابری انتقال یافته و پردازش می شوند. در سرور

ابری داده ارتعاشی در وضعیت سالم افزار در یک پایگاه داده جمع آوری و پردازش شده و سپس مدل یادگیری عمیق توسط این پایگاه آموزش داده می شود. نهایتاً در طول مرحله ایجاد و رشد خرابی ها در یاتاقان، شاخص سلامت با استفاده از مدل آموزش دیده و داده های ارتعاشی بر خط، محاسبه می شود.

۲- دادههای تجربی

برای ارزیابی عملکرد شاخص سلامت پیشنهادشده در این مطالعه، از نتایج آزمونهای تجربی ارائهشده در مرجع [۲۵] استفادهشده است. افزارگان آزمون مورداستفاده توسط این پایگاه داده در شکل ۱ نشان دادهشده است. افزارگان آزمون شامل یک موتور جریان متناوب است که توسط یک تسمه و فزارگان آزمون شامل یک موتور جریان متناوب است که توسط یک تسمه به شفت متصل شده است. شفت مذکور توسط چهار یاتاقان شیار عمیق دو ردیفِ مهارشده است و هر یاتاقان بار شعاعی ۶۰۰۰ پوندی را تحمل می کند. سرعت دورانی شفت ثابت و برابر با ۲۰۰۰ دور بر دقیقه انتخابشده است. بر روی پایه هر یاتاقان یک سنسور شتاب سنج با نرخ دادهبرداری KHz بر روی پایه هر یاتاقان یک سنسور شتاب سنج با نرخ دادهبرداری اتاقان اندازه گیری شده است. تعداد نقطه داده در طی هر بار اندازه گیری برابر با ۱۰۲۴۸۰ است. فرآیند اجرای آزمون و دادهبرداری تا ظُهور نشانههای خرابی در ساچمهها و یا کُنسهای یاتاقانها ادامه داشته است، که نتیجه آن به دست آوردن توأمان دادههای ارتعاشی در وضعیت سالم و معیوب در طی طول عمر یاتاقانها است [۲۵].

۳- روش پیشنهادی برای ساخت شاخص سلامت

برای ساخت خودکار شاخص سلامت در این مطالعه، از مدل های یادگیری عمیق استفاده شده است. به طور کلی فرآیند ساخت شاخص سلامت در روش پیشنهادی دارای سه گام اصلی است. در گام اول داده های ارتعاشی افزار در طی مدتزمان عملکرد آن به صورت برخط جمع آوری و پردازش می شوند. برای این امر، داده های جمع آوری شده در طی پنجره های زمانی ثابت در طی طول مدت عمر تجهیز به طور خودکار جمع آوری می شود. داده های ارتعاشی افزار به دودسته داده های وضعیت سالم افزار و داده های وضعیت خرابی افزار دسته بندی می شوند و برای هر دو دسته داده ارتعاشی، تبدیل موجک پیوسته محاسبه شده و سیگنال های ارتعاشی یک بعدی به تصاویر دوبعدی تبدیل خواهد شد.



شکل ۱. افزارگان مورداستفاده در طی آزمایش های پایگاه داده مرجع [۲۵].

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

برای هر پنجره ارزیابی در وضعیت سالم افزار است. در طی فرآیند آموزش، مدل خود-رمزگذار آموزش می بیند که بتواند مشخصه های اصلی تصاویر تبدیل موجک در وضعیت سالم را به طور خودکار استخراج کند و تصاویر را با حداقل تعداد نورون در لایه تنگنا فشرده سازی کند [۲۱].





در گام دوم، مدل یادگیری عمیق صرفاً با استفاده از تصاویر تبدیل موجک دادههای ارتعاشی در وضعیت سالم افزار آموزش داده می شود. مدل یادگیری عمیق توسعهیافته در این پروژه از انواع دسته مدل های خود-رمزگذار است. شبکههای عصبی خود-رمزگذار دستهای از مدلها بدون نظارت میباشند که برای استخراج ویژگیها، کاهش ابعاد و حذف نُوفهها استفاده می شوند [۲۶]. مهمترین مشخصه این شبکهها، داشتن تعداد یکسان از نورونها در لايه ورودي و لايه خروجي شبكه است، بهنحويكه شبكه أموزش مي بيند تا مقادیر لایه ورودی را عیناً در لایه خروجی پیشبینی کند. همان گونه که در شکل ۲ نشان داده شده است، یک شبکه خود-رمز گذار ساده حداقل از سه لایه ورودی، میانی و خروجی تشکیلشده است. از منظر تعداد نورون در هر لایه، لایه ورودی و لایه خروجی همانند یکدیگر بوده و لایه میانی از دولایه دیگر تعداد نورون کمتری دارد. در یک مدل خود-رمزگذار لایه میانی با کمترین تعداد نورون را لایه تنگنا مینامند. از آنجاکه تعداد نورون ها در لایه تنگنا کمتر از دولایه دیگر است، شبکه خود-رمزگذار آموزش می بیند تا مقادیر ورودی را در لایه تنگنا فشردهسازی نماید و بر اساس همین مقادیر لایه تنگنا، مقادیر ورودی را در خروجی بازسازی نماید [۲۷]. بنابراین یک شبکه خود-رمزگذار از دو قسمت اصلی تشکیل شده است: قسمت رمزگذار که وظیفه نگاشت مقادیر ورودی به کدهای فشردهشده در لایه تنگنا را دارد و قسمت رمزگشا که وظیفه بازسازی مقادیر کدهای فشردهشده در خروجی را دارد. ورودی مدل خود-رمزگذار در مرحله آموزش، تصاویر تبدیل موجک



شکل ۳. روش پیشنهادی برای ساخت شاخص سلامت.

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

در گام سوم، پس از آموزش مدل و در مرحله اجرا، تصاویر تبدیل موجک پیوسته برای هر بازه ارزیابی در وضعیت خراب افزار به ورودی مدل داده می شود و اعداد نورون ها در لایه تنگنا متناسب با نوع تصویر، تغییر خواهند کرد. به این ترتیب که اعداد در نورون های لایه تنگنا برای تصاویر مشابه، به طور تقریبی یکسان خواهد بود و هر میزان تفاوت تصاویر بیشتر باشد، میزان اعداد در نورون های لایه تنگنا متفاوت تر خواهند بود. با ایجاد و رشد خرابی ها در افزار، تصاویر تبدیل موجک متفاوت تری ایجاد خواهند شد و درنتیجه مدل خود-رمزگذار می تواند میزان تفاوت تصاویر را به طور فودکار به دست آورد. از آن جاکه لایه تنگنا شامل فشرده ترین و کامل ترین ویژگی های استخراجی است، می تواند برای مقایسه تصاویر به کار رود. بنابراین، مقدار بردار لایه تنگنا برای هرلحظه از وضعیت خرابی افزار با بردار لایه تنگنا در وضعیت سالم توسط رابطه ماهالانوبیز مقایسه شده و شاخص سلامت ایجاد خواهد شد (شکل ۳).

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

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

۳- ۱- پردازش سیگنالهای اولیه

هدف از استفاده ابزار تبدیل موجک پیوسته در این پروژه، ایجاد تصاویر متمایز متناسب با میزان رشد خرابی است؛ بهنحوی که تصاویر ایجادشده در طول عمر افزار بتواند مراحل ایجاد و رشد خرابیها را بهخوبی نشان دهند. پس از ایجاد این تصاویر توسط تبدیل موجک پیوسته، وظیفه مدل یادگیری عمیق آن است که بتواند میزان تفاوت تصاویر را بهصورت خودکار تعیین نماید. تبدیل موجک پیوسته، وظیفه مدل پردازش سیگنال های غیرثابت و گذرا پردازش سیگنال های غیرثابت و گذرا پردازش سیگنال های غیرثابت و گذرا ستفاده میشود. با استفاده از تبدیل موجک پیوسته میتوان تغییرات حوزه فرکانس یک سیگنال است، که بهویژه در پردازش سیگنالهای غیرثابت و گذرا پیوسته، همانند تبدیل فوریه از تبدیل موجک پیوسته میتوان تغییرات حوزه فرکانس یک سیگنال را در طی یک بازه زمان نشان داد. در تبدیل موجک پیوسته، همانند تبدیل فوریه از ضرب داخلی یک تابع تحلیلی در سیگنال و تابع محلط استفاده میشود. تابع تحلیل مورداستفاده در تبدیل فوریه، تابع مختلط هدف برای اندازه گیری میزان شباهت موجود میان سیگنال و تابع محلطی نمایی استفاده میشود. تابع تحلیل مورداستفاده در تبدیل موجک پیوسته، میتوان تغییرات حوزه مینوسته، همانند تبدیل فوریه از ضرب داخلی یک تابع تحلیلی در سیگنال موجک نابت و مختاب موجک مین بای داد. در تبدیل موجک موجک میوسته میتوان تغییرات حوزه مرکانس یک سیگنال را در طی یک بازه زمان نشان داد. در تبدیل موجک پیوسته، همانند تبدیل فوریه از ضرب داخلی یک تابع تحلیلی در سیگنال و تابع مختلط مدف برای اندازه گیری میزان شباهت موجود میان سیگنال و تابع مختلط نمایی (ψ (t)) شناخته میشود [۲۸].

¹ Mahalanobis



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

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

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

نتیجه آنالیز تبدیل موجک تابع مختلط $W_n(s)$ خواهد بود. این تبدیل را میتوان به قسمت حقیقی $\{W_n(s)\}$ و قسمت موهومی $\Re\{W_n(s)\}$ و قسمت موهومی $\Im\{W_n(s)\}$ تقسیم نمود. درنهایت طیف توانی تبدیل موجک برابر با $\Im\{W_n(s)\}$ خواهد بود.

برای نشان دادن مزایای استفاده از تبدیل موجک پیوسته، نمایش سیگنال در حوزه زمان و طیف توانی تبدیل موجک متناظر با آن برای دو حالت سیگنال ارتعاشی یاتاقان سالم و یاتاقان معیوب برای نمونه در شکل ۴ نشان دادهشدهاند. در آنالیز تبدیل موجک با مقایسه تابع موجک مادر با سیگنال پایه، مقادیر جابجایی و اتساع تابع موجک مادر به دست میآید. از آنجا که انتخاب تابع موجک مادر وابسته به شکل سیگنال پایه میباشد، انتخاب مناسب آن تأثیر به سزایی در دقت نتایج دارد. بهطورکلی هر میزان شکل تابع موجک مادر به سیگنال پایه شبیهتر باشد، نتایج دقیقتری را به همراه خواهند داشت. روشهای متفاوتی برای ارزیابی شباهت میان سیگنال هدف و تابع موجک مادر معرفیشدهاند، که از آن میان میتوان به بازرسی چشمی اشاره نمود. در این روش تلاش میشود تا تابع موجک مادری که هماهنگی بیشتری با سیگنال هدف دارد بر اساس معیار چشمی انتخاب شود [۲۹].

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

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

۳- ۲- توسعه مدل یادگیری عمیق

همان گونه که پیش ازاین اشاره شده، در این مطالعه از دسته مدل های خود-رمزگذار استفاده شده است. هدف از مدل خود-رمزگذار در این پروژه، توسعه مدل های است که بتوانند تصاویر ورودی را به خوبی در خروجی بازسازی کنند و درعین حال کمترین تعداد نورون را در لایه تنگنا داشته بازساند. به این ترتیب می توان اطمینان حاصل نمود که کمترین و درعین حال دقیق ترین ویژگی های مُعرف تصاویر استخراج شده اند. تصاویر مورداستفاده برای آموزش مدل خود-رمزگذار، تصاویر حاصل از آنالیز تبدیل موجک سیگنال های ارتعاشی در وضعیت سالم افزار می باشند.

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

۳- ۲- ۱- مدل خود رمزگذار عمیق

در یک مدل خود رمزگذار عمیق، در بخش رمزگذار لایه ورودی صرفاً توسط تعدادی لایه متوالی با ترکیب نورون های کاهشی به لایه تنگنا متصل می شوند. در بخش رمزگشا، ترکیب قرینه بخش رمزگذار استفاده می شوند تا از لایه تنگنا به لایه خروجی متصل شود [۳۰]. در یک مدل خود رمزگذار عمیق، ساختار مدل با تعیین تعداد لایههای بخش رمزگذار و رمزگشا و تعداد نورون ها در هر لایه مشخص می شود [۳۱]. لایه ورودی مدل، تصویر رنگی تبدیل موجک در هر پنجره ارتعاشی با اندازه ۶۰×۶۰ پیکسل است. از آنجاکه تصویر ورودی بهصورت رنگی و سه کانال است، هر دولایه ورودی و خروجی دارای ۱۰۸۰۰(۱۰۸۰۰=۳×۶۰×۶۰۶) نورون خواهند بود. تعداد نورونهای در نظر گرفته شده برای لایه تنگنا دو است. بنابراین تصویر دوبعدی ورودی به یک بردار دوتایی در لایه تنگنا تبدیل می شود ($\mathbb{R}^{5 imes 5 imes 7} o \mathbb{R}^7$) در مدل خود رمزگذار عمیق از چیدمان با هفت لایه میانی بهصورت ساختار كاملاً متصل استفاده شده است؛ به نحوى كه همه نورون ها در يك لايه به تمامی نورون ها در لایه بعدی متصل میباشند. نمونه ای تصاویر ورودی و تصاویر خروجی (پیش بینی شده) متناظر با مدل خود رمز گذار عمیق در شکل ۵ نشان دادهشدهاند. همان گونه که نشان دادهشده، علی رغم تبعیت کلی تصاویر خروجی از تصاویر ورودی، کیفیت تصاویر پایین میباشند، که نتیجه دقت پایین در استخراج ویژگیهای کامل تصاویر است.

۳- ۲- ۲- مدل خود رمزگذار همگشتی

مدل خود رمزگذار همگشتی از ترکیب دو مدل خود رمزگذار عمیق و مدل شبکه عصبی همگشتی حاصل شده است. در مدل خود – رمزگذار همگشتی برای بهبود توانایی مدل در استخراج ویژگیهای اصلی و کاهش حجم دادههای پردازش، پیش از لایههای خود – رمزگذار کاملاً متصل، لایههای ضرب پیچشی و ادغام [۳7] اضافه می شوند. استفاده از این لایهها قبل از لایههای خود – رمزگذار، علاوه بر بهبود فرآیند استخراج ویژگی، اندازه دادههای ورودی به لایههای خود – رمزگذار را نیز کاهش می دهند. در نتیجه به دلیل کاهش اندازه ورودی، تعداد نورون ها در لایههای خود – رمزگذار کاهش یافته و تعداد پارامترهای آموزش کمتر می گردد، که این کار خود می تواند در همگرایی و سرعت حل تأثیرگذار باشد [۳۳]. برای آموزش مدل خود – رمزگذار همگشتی به صورت غیر نظارت شده، لازم است تا لایههای ضرب پیچشی و ادغام، قبل و پس از مدل خود رمزگذار عمیق به طور قرینه بکار گرفته شوند [۶۲]. در شکل ۶ ساختار شماتیک مدل خود رمزگذار همگشتی ارائه شده است.

¹ Deep autoencoder

² Convolutional autoencoder

³ Variational autoencoder



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

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



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

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

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

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



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

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

هرگز ندیده است نیز بررسی نمود. از آنجا که مدل تنها با مجموعهای از تصاویر در وضعیت سالم آموزشدیده است، تصاویری با میزان درصد خرابی متفاوت بهعنوان ورودی مدل در نظر گرفته و تصاویر پیشبینیشده به همراه مقادیر نورونهای لایه تنگنا درشکل ۸ نشان دادهشدهاند. همان گونه که مشاهده میشود، مدل خود رمزگذار همگشتی توانسته بهخوبی از تصاویری که در مرحله آموزش هرگز ندیده است تبعیت کند و تصاویری باکیفیت مطلوب پیشبینی نماید. علاوه بر آن، مقادیر نورونها در لایه تنگنا بهخوبی با افزایش خرابی از مقادیر نورونها در حالت سالم فاصله می گیرند. بنابراین میتوان اطمینان حاصل نمود که مقادیر دوتایی استخراجشده در لایه تنگنا بهخوبی میتوانند ارائهدهنده وضعیت تصویر باشند و بهعنوان ابزار ساخت شاخص سلامت بکار روند.

۳-۳- اندازه گیری شاخص سلامت

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

داده شده است، با رشد خرابی ها فاصله مقادیر نورون ها نسبت به وضعیت سالم افزایش می یابند. برای اندازه گیری این فاصله، از رابطه ماهلانوبیز [۳۳] استفاده شده است. رابطه ماهالانوبیز یک معیار فاصله چند متغیره مؤثر است که می تواند فاصله بین یک بردار با توزیع برداری را اندازه گیری کند. این رابطه در تشخیص ناهنجاری های چند متغیره بسیار کارآمد است [۳۳].

برای محاسبه رابطه ماهالانوبیز، در ابتدا از دادههای وضعیت سالم افزار مجموعه برداری $X^h = \{xh, xh, ..., xh_m\}$ مجموعه برداری نورونهای لایه مجموعه برداری $X_i^h = \{xh, xh, ..., xh_m\}$ تنگنا انتخاب می شوند به نحوی که $\{y_{1,VT}\} = \{y_{1,VT}\}$ مرای مجموعه انتخابی X^h مردد. همچنین برای X^h مردار میانگین V_{τ}^m V_{τ}^m محاسبه می گردد. همچنین برای مجموعه برداری X^h ماتریس کوواریانس نیز محاسبه می شود. ماتریس کوواریانس نیز محاسبه می مدود که اعضای آن هم مجموعه برداری ماتریس مربعی دو در دو و متقارن خواهد بود که اعضای آن هم مستگی میان پارامترهای مختلف مجموعه را نشان می دهند. درنهایت فاصله ماهالانوبیز در طی هر بازه ارزیابی برای X^h ماتریس (رابطه (۲) محاسبه می شود:

$$(MD)^{\Upsilon} = (X - \mu)^{T} C^{-1} (X - \mu)$$
 (Y)

میزان درصد پیشرفت خرابی



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

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



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

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



شکل ۱۰. نمودار ارتعاشی برای چهار یاتاقان که در انتهای آزمایش دارای نشانههای از خرابی بودهاند در سه آزمون تجربی. (الف) یاتاقان سوم در آزمون اول، (ب) یاتاقان چهارم از آزمون اول، (ج) یاتاقان اول از آزمون دوم و (د) یاتاقان سوم از آزمون سوم. دادههای خام از مرجع [۲۵]. Fig. 10. Vibration diagram for four bearings at the end of the test with signs of failure in three experimental tests. (a) subset 1 bearing 3, (b)subset 1 bearing 4, (c) subset 2 bearing 1, (d) subset 3 bearing 3 [25].

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

۴- نتایج تجربی

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

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

جدول ۱. جزییات مرتبط با پایگاه داده IMS

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

یاتاقان سوم از آزمون اول	یاتاقان چهارم از آزمون اول	یاتاقان اول از آزمون دوم	یاتاقان سوم از آزمون سوم	
۶۰۰۰	۶۰۰۰	۶	۶	بار شعاعی (پوند-نیرو)
۲۰۰۰	7	7	7	سرعت (دور بر دقيقه)
حلقه داخلى	ساچمەھاي دورانى	حلقه خارجي	حلقه خارجي	نوع عيب
۳۴ روز و۱۲ ساعت	۳۴ روز و ۱۲ ساعت	۶ روز و ۲۰ ساعت	۴۵ روز و ۹ ساعت	کل مدتزمان آزمون
<i>۶۱۰۶۹</i>	۴۳۳۸۱	19148	7	تعداد تصاوير سالم
۲۷ روز و ۲۰ ساعت	۱۹ روز و ۲۰ ساعت	۳ روز و ۲۱ ساعت	۴۱ روز و ۲ ساعت	زمان شروع خرابي
۱۹۸۰۰	٣١٠٩٠	1478.	7.78.	تعداد تصاوير معيوب

از آنجاکه دادههای ارتعاشی برای هر یاتاقان در طی آزمایش اجرا تا شکست بهدستآمدهاند، برای هر آزمایش هر دو دسته داده ارتعاشی در وضعیت سالم و معیوب وجود دارند. در کاربردهای عملی، یک افزار بهطور تدریجی و در طی تکامل مجموعهای از حالتهای خرابی، از وضعیت سالم به وضعیت معیوب تبدیل میشود. علاوه بر آن، برای هر افزار عدم قطعیتهای بالای در مورد شرایط کاری و خواص افزار وجود دارد. در نتیجه امکان تعیین یک حد از آستانه مشخص و از پیش تعیینشده که بتواند وضعیت سالم را از وضعیت معیوب جدا نماید، وجود ندارد. برای تعیین زمان آغاز خرابی و جدا وضعیت میوب جدا نماید، وجود ندارد. برای تعیین زمان آغاز خرابی و جدا وضعیت معیوب از معیار پاتو [۲۷] استفاده می شود. اگر میانگین دامنه نقطه کردن سیگنالهای ارتعاشی در وضعیت سالم از سیگنالهای ارتعاشی در فرای قرار بگیرد، پنجره ارزیابی مذکور جزء بازه وضعیت سالم قلمداد میشود و خرابی قرار بازه خرابی و خلا ونار بگیرد، پنجره ارزیابی مذکور جزء بازه وضعیت سالم قلمداد میشود و پازه قرار بگیرد، آغاز بازه ایجان و رشد خرابی متوالی (مثلاً ۵۰۰ پنجره) فراتر از بازه پاتو قرار گیرد، آغاز بازه ایجاد و رشد خرابی تشخیص داده میشود. پس از بازه پاتو قرار گیرد، آغاز بازه ایجاد و رشد خرابی تشخیص داده میشود. پس از بازه پاتو قرار گیرد، آغاز بازه ایجاد و رشد خرابی تشخیص داده میشود. پس از

آموزش مدل خود-رمزگذار همگشتی با تصاویر سالم، با استفاده از رابطه ماهالانوبیز فاصله مقادیر گره تنگنا در هر پنجره ارزیابی در طی مرحله خرابی با مقادیر گره تنگنا در وضعیت سالم محاسبهشده و شاخص سلامت ساخته می شود. نمودارهای شاخص سلامت ایجادشده برای چهار یاتاقان پایگاه داده مرجع [26] در شکل ۱۱ نشان داده شده است.

همان گونه که مشاهده می شود، نمودارهای شاخص سلامت، دارای روند افزایشی و یکنواخت بوده و می تواند میزان پیشرفت تخریب را به طور مؤثر نشان دهند. همچنین با مقایسه این نمودارها با نمودارهای مقادیر ارتعاشات اندازه گیری شده در طول عمر یاتاقانها (شکل ۱۰) به خوبی مشخص می شود که روش پیشنهادی توانایی تشخیص عیوب اولیه یاتاقان را دارد و نسبت به هر سه حالت خرابی اصلی در یاتاقانها دارای حساسیت است. شاخص سلامت معرفی شده در این مطالعه می تواند روند روبه افزایش رشد تخریبها را توصیف نماید و می تواند برای تخمین عمر مفید باقی مانده یاتاقان بکار رود.



شکل ۱۱. نمودار شاخص سلامت با استفاده از روش پیشنهادی در این پروژه برای یاتاقانهای دارای نشانههای خرابی در پایگاه داده IMS. (الف) تا (د) نمودارهای شاخص سلامت اولیه. (هـ) تا (ح) نمودار شاخص سلامت هموارشده با استفاده از تابع هموارساز نمایی. Fig. 11. Constructed Health Indicator results for the four failure IMS bearing (a-d) raw health indicator, (e-h) modified health indicator.

۵- نتیجه گیری

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

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

منابع

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

Identification, Signal Processing, 130 (2017) 377-388.

- [15] J.-G.B. Youngji Yoo, A Novel Image Feature for the Remaining Useful Lifetime Prediction of Bearings Based on Continuous Wavelet Transform and Convolutional Neural Network, Appl. Sci., 8(7) (2018).
- [16] S.S. Wathiq Abed, Robert Sutton, Amit Motwani A Robust Bearing Fault Detection and Diagnosis Technique for Brushless DC Motors Under Non-stationary Operating Conditions, J. Control. Autom. Electr. Syst., 26 (2015) 241–254.
- [17] M.O. Jun He, Chen Yong, Danfeng Chen, Jing Guo, Yan Zhou, A Novel Intelligent Fault Diagnosis Method for Rolling Bearing Based on Integrated Weight Strategy Features Learning, sensors, 20(6) (2020).
- [18] Z.L. Hang Yin, Jiankai Zuo, Hedan Liu, Kang Yang, Fei Li, Wasserstein Generative Adversarial Network and Convolutional Neural Network (WG-CNN) for Bearing Fault Diagnosis, Math. Probl. Eng., 2020 (2020).
- [19] S.Z. Shen Zhang, Bingnan Wang, Thomas G. Habetler, Deep Learning Algorithms for Bearing Fault Diagnostics—A Comprehensive Review, IEEE Access 8(2020) 29857 - 29881.
- [20] T.Y. Samir Khan, A Review on the Application of Deep Learning in System Health Management, Mech. Syst. Signal Process, 107 (2018) 241-265.
- [21] J.P.a.H.W.v.d.V. Mohammadreza Kaji, Constructing a Reliable Health Indicator for Bearings Using Convolutional Autoencoder and Continuous Wavelet Transform, Appl. Sci., (2020).
- [22] T.G.H. Wei Zhou, Ronald G. Harley, Bearing Condition Monitoring Methods for Electric Machines: A General Review, in: 2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, Cracow, Poland, 2007.
- [23] S.V.K. Prashant P. Kharche, Review of Fault Detection in Rolling Element Bearing, International Journal of Innovative Research in Advanced Engineering, 1(5) (2014) 169-174.
- [24] S.C.S. P.K. Kankar, S.P. Harsha, Fault Diagnosis of Ball Bearings Using Continuous Wavelet Transform, Appl.

Gear Health Indicators, IEEE Access, 6 (2017) 665 - 676.

- [3] B.S. Gandhare, Maintenance Strategy Selection, in: Ninth AIMS International Conference on Management, 2012.
- [4] R.K. Mobley, An introduction to predictive maintenance Butterworth-Heinemann, America, 2002.
- [5] B.S. Gandhare, Maintenance Strategy Selection, presented at the Ninth AIMS International Conference on Management, (2012).
- [6] B.A. Gandhare, Milind, Maintenance Strategy Selection, in: The 9th AIMS International Conference on Management, 2012.
- [7] N.L. Liang Guo, Feng Jia, Yaguo Lei, Jing Lin, A Recurrent Neural Network Based Health Indicator for Remaining Useful Life Prediction of Bearings, Neurocomputing, 240 (2017) 98–109.
- [8] S.H.U. Akhand Rai, A Aeview on Signal Processing Techniques Utilized in the Fault Diagnosis of Rolling Element Bearings, Tribol. Int., 96 (2016) 289-306.
- [9] K.-C.L.G.G. Yen, Wavelet Packet Feature Extraction for Vibration Monitoring, IEEE Transactions on Industrial Electronics, 47(3) (2000) 650 - 667.
- [10] M.S.H. J. L. Won Gi Lee, Sung-Ho Nam, YongHo Jeon, andMoon G. Lee, Failure Diagnosis System for a Ball-Screw by Using Vibration Signals, Hindawi Publishing Corporation Shock and Vibration, (2015).
- [11] G.P.C. Christopher Torrence, A Practical Guide to Wavelet Analysis, American Meteorological Society, 79(1) (1998) 61-78.
- [12] Y.H. C. C. P. Tsai, Ball Screw Preload Loss Detection Using Ball Pass Frequency, Mechanical Systems and Signal Processing, 48 (2014) 77-91.
- [13] J.L. Y. L. Feng Jia, Xin Zhou, and Na Lu, Deep Neural Networks: A Promising Tool for Fault Characteristic Mining and Intelligent Diagnosis of Rotating Machinery with massive Data, Mechanical Systems and Signal Processing, 72 (2016) 303-315.
- [14] W.-L.Q. Z.-Y. W. Chen Lu, Jian Ma, Fault Diagnosis of Rotary Machinery Components Using a Stacked Denoising Autoencoder-Based Health State

Electronics 47(3) (2000) 650 - 667.

- [30] H.Y. Yasi Wang, Sicheng Zhao, Auto-Encoder Based Dimensionality Reduction, Neurocomputing, 184 (2015) 232-242.
- [31] F. Chollet, Keras: Deep Learning Library for Theano and Tensorflow.
- [32] H.T. Ahmed Ali Mohammed Al-Saffar, Mohammed Ahmed Talab, Review of Deep Convolution Neural Network in Image Classification, in: International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications, IEEE, Jakarta, Indonesia 2018.
- [33] A.M. Saleh Albelwi, A Framework for Designing the Architectures of Deep Convolutional Neural Networks, Entropy, 19(6) (2017).
- [34] M.H.L. Jeongyoun Ahn, Jung Ae Lee, Distance-Based Outlier Detection for High Dimension, Low Sample Size Data, J. Appl. Stat., 46(1) (2019) 13-29.

Soft Comput., 11 (2011) 2300–2312.

- [25] PCoE Datasets, Bearing Data Set, Intelligent Maintenance Systems (IMS), University of Cincinnati, in.
- [26] A.B. Andrea Borghesi, Luca Benini, Anomaly Detection using Autoencoders in High Performance Computing Systems, in: The Thirty-First AAAI Conference on Innovative Applications of Artificial Intelligence, Hawaii, USA, 2019.
- [27] G.G. Fangyi Wan, Chunlin Zhang, Qing Guo, Jie Liu, Outlier Detection for Monitoring Data Using Stacked Autoencoder, IEEE Access 7(2019) 173827 - 173837.
- [28] M.S.L. Ngui Wai Keng, Lim Meng Hee, Ahmed. M. Abdelrhman, Wavelet Analysis: Mother Wavelet Selection Methods, Applied Mechanics and Materials, 393 (2013) 953-958.
- [29] K.-C.L. G.G. Yen, Wavelet packet feature extraction for vibration monitoring, IEEE Transactions on Industrial

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



DOI: 10.22060/mej.2021.20023.7153

بی موجعه محمد ا