Amirkabir Journal of Mechanical Engineering

Amirkabir J. Mech. Eng., 55(12) (2024) 301-304
DOI: 10.22060/mej.2024.22469.7629

Investigating Noise Reduction in Signal Analysis in Rotary Machines Fault Diagnosing by Neural Network

Hamed Pourhashem, Ali jamali *, Nader Nariman-zade, Ali Chaibakhsh

Faculty of Mechanical Engineering, University of Guilan, Rasht, Iran

ABSTRACT: Fault diagnosis of mechanical systems is of special importance for better system performance as well as its protection. In this work, a rotary machine laboratory system is used to generate signals. The obtained data are placed in the pre-processing process. In this article, to improve the performance of signal analysis, the combined analysis methods using signal features and Kalman filter are proposed. First, the Kalman filter is used to reduce the signal noise. In the following, for signal pre-processing, the features of the signal in the time domain and frequency domain are suggested, which have been used as one-dimensional signal pre-processing. In the following, several neural networks such as support vector machine, multilayer perceptron, and convolutional neural networks have been used to analyze the obtained features. To check the results, the data is divided into training data and validation data. Accuracy results for validation data are examined in different methods. The results indicate the better performance of the AlexNet convolutional neural network in the presence of the Kalman filter noise reduction. In this case, this network has reached an average of 96.1% accuracy for validation data, which has been improved compared to other classifiers and fault diagnosis without noise reduction.

Review History:

Received: Jun. 12, 2023
Revised: Mar. 10, 2024
Accepted: Mar. 19, 2024
Available Online: Mar. 30, 2024

Keywords:

Fault diagnosis
Noise Reduction
Kalman Filter
Neural Network
Signal Processing

1- Introduction

Today, intelligent fault diagnosis has become a crucial aspect of the mechanical system. The faults can lead to severe damage and complications. Hence, early detection of defects in the early stages is of paramount importance. In this context, the processing of vibration signals for rotary mechanical systems can prove to be highly effective in fault detection before system failure. Here is a brief summary of the tasks involved in detecting faults in rotary machinery.

Junior et al. employed signal pre-processing techniques for fault diagnosis in rotating machinery [1]. Zakizadeh et al. utilized vibration analysis in conjunction with support vector machine algorithms to diagnose faults in the rotary blower systems of Alstom locomotives [2]. Shekarzadeh et al. introduced an independent component analysis and particle batch optimization for diagnosing defects in centrifuge bearings [3]. Several noise reduction methods, including the integration of Kalman filtering with signal analysis techniques, yield promising results in this field [4].

This article presents a novel approach that combines feature extraction and the Kalman filter noise reduction for fault diagnosis. Features are extracted from clean signals in the time and frequency domains. The preprocessed data are utilized as training data for different networks. By utilizing the capabilities of neural networks, the article aims to enhance the accuracy and effectiveness of fault diagnosis.

2- Experimental Data Collection

In this study, vibration data from a rotary machine is utilized. Figure 1 illustrates the configuration of the system, which consists of an alternating current motor connected to a rod mounted on three bearings. The system also includes discs that can cause the disk to become unbalanced. Two sensors are placed on the first and second bearings from the right side to record signal data. The bearing locations are indicated in Figure 1.

To capture validation signals from this rotary machine, three types of faults are introduced: bearing ball defects, rod imbalance, and bearing outer ring defects. Additionally, signals are recorded in a healthy system state. To record the signals in various system states (both faulty and healthy), the motor feeding frequency is varied between 8 and 30 Hz in 2 Hz increments and it has a rated speed of 2825 rpm at a feeding frequency of 50 Hz and a power rating of 370 watts.

During data recording, the healthy system state is considered as the baseline. In the case of bearing ball failure, the defective bearing is placed in three different positions as depicted in Figure 1. Similarly, for the outer ring failure, the defective bearing is placed in three positions. As for rod imbalance, weights are added to each of the six discs mounted on the rotating rod. Overall, there are 13 system modes considering the general states of healthy and faulty systems. Data recording is done across 12 different motor

*Corresponding author's email: ali.jamli@guilan.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.

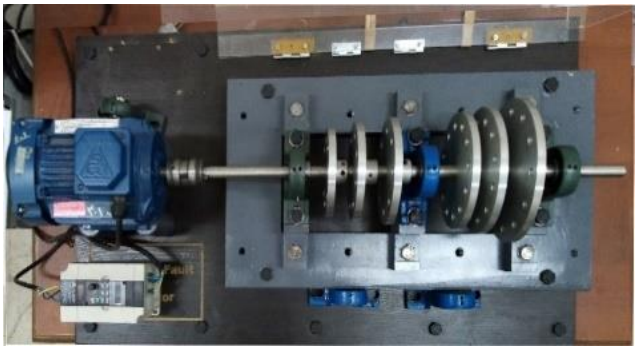

Fig. 1. Laboratory rotating machine for data recording

Table 1. The mean of the validation data accuracy for each classifier for each Kalman noise reduction mode

	$R = 0.25$	$R = 0.5$	$R = 0.75$	Not denoise
Classifier	Mean	Mean	Mean	Mean
SVM	0.935	0.942	0.922	0.910
MLP	0.948	0.948	0.935	0.955
Inception	0.942	0.948	0.935	0.948
AlexNet	**0.961**	**0.961**	**0.955**	**0.955**

Table 2. The mean and variance of the accuracy of the validation data for all classifiers for each Kalman noise reduction mode

Noise reduction mode	Mean	Variance
$R = 0.25$	0.947	0.0012
$R = 0.5$	**0.95**	0.0014
$R = 0.75$	0.937	**0.009**
Without Noise reduction	0.942	0.0017

feeding frequencies, resulting in a total of 156 primary data points. Each of these 156 primary data points includes two one-minute signals (due to the two sensors in the system) and four labels indicating the system state (healthy or faulty). The signals are recorded at a rate of 10,000 pulses per second.

A targeted random method is employed to split the data into training and validation sets. About 20% of the 156 data points are allocated as validation data. In each case of system mode, 2 or 3 validation data points are randomly selected. To ensure robustness in the analysis, the data division is performed five times, allowing for better analysis of the results.

3- Feature Extraction

To analyze the signals, feature extraction is performed in both the time and frequency domains. Fourteen features are extracted in the time domain [5], while nine features are extracted in the frequency domain [6].

In the time domain, the signal is directly processed for feature extraction. In the frequency domain, prior to feature extraction, the signal spectrum must be obtained. The signal can be transformed to the frequency domain by Fast Fourier Transform (FFT).

4- Evaluation of Neural Network Training Results

As previously explained, 23 features are extracted from each signal, resulting in 46 numerical values recorded for each data point. Therefore, the input data dimensions for the MLP and SVM neural networks are 125 x 46, representing 125 data points out of the total 156 (considered as training data). Additionally, for CNN models with Inception and AlexNet architectures, the input data is reshaped into a 2D format to enable analysis with 2D convolutional tools. Consequently, the last feature is omitted, and the remaining 45 features are arranged as a 5 x 9 matrix, resulting in input dimensions of 125 x 5 x 9 for the CNN network.

To assess the impact of signal noise reduction, since the variance of the system noise is unknown, trial and error method is used to set different values (0.25, 0.5, and 0.75) for the measurement noise covariance R. Therefore, the noise of desired signal is reduced in three modes, while a mode without noise reduction is also considered during feature extraction. Considering the influence of data division on the neural network training results, each classifier is trained in five different data divisions, and the mean value of the results is shown in table 1. The results indicate that the AlexNet network performs better than the others

To compare the effect of noise reduction achieved by the Kalman filter, the mean and variance of the accuracy for all validation data are calculated for each noise reduction mode in Table 2. It is observed that the best accuracy for evaluation data is obtained when the measurement noise covariance R is set to 0.5. Consequently, the accuracy is improved compared to the mode without noise reduction. The accuracy results for validation data show less variation when the measurement noise covariance is set to $R = 0.75$. Finally, based on tables 1 and 2, it can be concluded that the AlexNet neural network yields the best results in reducing Kalman filter noise with an R-value of 0.5.

5- Conclusions

The objective of this study was to examine the influence of noise reduction through the utilization of the Kalman filter on fault detection in the rotary machine. The laboratory data underwent noise reduction using the Kalman filter in various modes. Subsequently, features were extracted from the signals. Various neural networks, including SVM, MLP, Inception, and AlexNet, were trained using these datasets.

In the investigation of signal noise reduction, the AlexNet network consistently outperformed other methods. The

best accuracy results were obtained with the measurement noise covariance $R = 0.5$. The AlexNet network achieved an accuracy of 96.1% with $R = 0.5$. Comparing the average results for different noise reduction modes across all classifiers, an accuracy of 95% was achieved with a measurement noise covariance of $R = 0.5$, which showed improvement compared to the mode without noise reduction.

Future work could involve optimizing the covariance values of Q and R in the Kalman filter for signal noise reduction. Since the noise covariance of the recorded signals is unknown, these values can be determined through optimization methods to further enhance the performance of the system.

References

[1] R.F. Ribeiro Junior, I.A. dos Santos Areias, M.M. Campos, C.E. Teixeira, L.E.B. da Silva, G.F. Gomes, Fault detection and diagnosis in electric motors using convolution neural network and short-time fourier transform, Journal of Vibration Engineering & Technologies, (2022) 1-12.

[2] M. Zakizadeh, A. Jamali, M. Rafeeyan, A. Chaibakhsh, Monitoring and Troubleshooting Alstom Locomotive Blowers using Vibration Analysis and Support Vector Machine, Amirkabir Journal of Science & Research (Mechanical Engineering), 54(8) (2022) 1833-1850 (in Persian).

[3] M. Shekarzadeh, M. Sadegh Alayy, Centrifugal pump bearings Fault diagnosis using the combination of independent component analysis methods and particle swarm optimization, Journal of New Applied and Computational Findings in Mechanical Systems, 3(1) (2023) 53-61 (in Persian).

[4] P. Talwar, K. Cecil, Adaptive Filter and EMD Based De-Noising Method of ECG Signals: A Review, American Journal of Multidisciplinary Research & Development (AJMRD), 5(03) (2023) 09-14.

[5] M.A. Sattari, G.H. Roshani, R. Hanus, E. Nazemi, Applicability of time-domain feature extraction methods and artificial intelligence in two-phase flow meters based on gamma-ray absorption technique, Measurement, 168 (2021) 108474.

[6] J.J. Saucedo-Dorantes, A.Y. Jaen-Cuellar, M. Delgado-Prieto, R. de Jesus Romero-Troncoso, R.A. Osornio-Rios, Condition monitoring strategy based on an optimized selection of high-dimensional set of hybrid features to diagnose and detect multiple and combined faults in an induction motor, Measurement, 178 (2021) 109404.

HOW TO CITE THIS ARTICLE

H. Pourhashem, A. jamali , N. Nariman-zade, A. Chaibakhsh, Investigating Noise Reduction in Signal Analysis in Rotary Machines Fault Diagnosing by Neural Network, Amirkabir J. Mech Eng., 55(12) (2024) 301-304.

DOI: 10.22060/mej.2024.22469.7629

This page intentionally left blank

نشریه مهندسی مکانیک امیرکبیر

نشریه مهندسی مکانیک امیرکبیر، دوره ۵۵، شماره ۱۲، سال ۱۴۰۲، صفحات ۱۴۲۳ تا ۱۴۴۲
DOI: 10.22060/mej.2024.22469.7629

بررسی کاهش نویز در تحلیل سیگنال در عیب‌یابی ماشین‌های دوار توسط شبکه عصبی

حامد پورهاشم، علی جمالی*، نادر نریمان زاده، علی چائی بخش

دانشکده مهندسی مکانیک، دانشگاه گیلان، گیلان، ایران.

خلاصه: عیب‌یابی سیستم‌های مکانیکی برای عملکرد بهتر سیستم و همچنین محافظت از آن، دارای اهمیت ویژه‌ای می‌باشد. در این پژوهش از یک سیستم آزمایشگاهی ماشین دوار برای تولید سیگنال استفاده شده است. داده‌های بدست آمده در فرآیند پیش پردازش قرار می‌گیرند. در این مقاله برای بهبود عملکرد تحلیل سیگنال روش ترکیبی تحلیل توسط ویژگی‌های سیگنال و فیلتر کالمن پیشنهاد می‌شود. ابتدا برای کاهش نویز سیگنال‌ها از فیلتر کالمن استفاده می‌شود. و در ادامه برای پیش پردازش سیگنال ویژگی‌های سیگنال در حوزه زمان و حوزه فرکانس پیشنهاد می‌شود که از آن به عنوان پیش‌پردازش یک بعدی سیگنال استفاده شده است. در ادامه برای تحلیل ویژگی‌های بدست آمده از کلاس‌بندهای ماشین بردار پشتیبان، شبکه عصبی پرسپترون چند لایه و شبکه عصبی پیچشی استفاده شده است. برای بررسی نتایج داده‌ها به دسته داده‌های آموزشی و داده‌های صحت سنجی تقسیم‌بندی می‌شود. نتایج دقت برای داده‌های صحت سنجی در روش‌های مختلف مورد بررسی قرار می‌گیرد. نتایج حاکی از عملکرد بهتر شبکه عصبی پیچشی الکس‌نت در حضور فرآیند کاهش نویز با فیلتر کالمن می‌باشد. این شبکه به طور میانگین به دقت ۹۶/۱ درصد برای داده‌های صحت سنجی رسیده است که نسبت به سایر کلاس‌بندها و همچنین نسبت به عیب‌یابی بدون کاهش نویز، دقت آن بهبود یافته است.

تاریخچه داوری:
دریافت: ۱۴۰۲/۰۳/۲۲
بازنگری: ۱۴۰۲/۱۲/۲۰
پذیرش: ۱۴۰۲/۱۲/۲۹
ارائه آنلاین: ۱۴۰۳/۰۱/۱۱

کلمات کلیدی:
عیب‌یابی
کاهش نویز
فیلتر کالمن
شبکه عصبی
پردازش سیگنال

۱- مقدمه

با توجه به پیشرفت در سیستم‌های مکانیکی و افزایش اهمیت در تعمیر و نگهداری آنها، عیب‌یابی هوشمند این سیستم‌ها نیز همواره از اهمیت بیشتری برخوردار می‌شود. عیب در سیستم‌ها می‌تواند منجر به آسیب‌های جدی به سیستم شود و باعث ایجاد مشکلات بزرگتری شود. از این رو شناسایی عیب در مراحلی که هنوز به صورت جدی پیشرفت نکرده است، حائز اهمیت می‌باشد. افزایش اعتمادپذیری سیستم و همچنین تضمین امنیت آن اهمیت عیب‌یابی را افزایش می‌دهند. این موضوع در سیستم‌های دوار نظیر پمپ‌ها، کمپرسورها، توربین‌ها و موتورها که از اجزای مهم سیستم‌های مکانیکی می‌باشند، نیز از اهمیت ویژه‌ای برخوردار است. در مواردی افزایش هزینه‌های مصرفی مانند مصرف انرژی بیشتر و در نتیجه آلایندگی بیشتر که از عیب سیستم ناشی می‌شوند، مشاهده می‌شود و این در حالی است که سیستم ظاهرا درست کار می‌کند. از این رو عیب‌یابی می‌تواند عیب‌های مخفی سیستم را آشکار سازد و به نحوی مصرف انرژی و هزینه‌های مشابه را کاهش دهد. در مجموع برای داشتن عملکرد بهینه یک سیستم و تنظیم بهتر آن در بازده و عملکرد، عیب‌یابی امری مهم در سیستم‌های متفاوت به ویژه سیستم‌های دوار باشد.

استفاده عملی عیب‌یابی ماشین‌های دوار را می‌توان در صنایع تولیدی مانند صنعت خودروسازی، تولیدات فولاد، صنایع پتروشیمی و مواردی دیگر که ماشین‌های دوار در آنها نقش کلیدی دارند، مشاهده نمود. با استفاده از سیستم‌های عیب‌یابی ماشین دوار، می‌توان توقفات ناگهانی خطوط تولید را به حداقل رساند و عیب‌هایی که به طور معمول به دلیل فرسایش و استهلاک در ماشین‌های دوار اتفاق می‌افتد را به صورت زودهنگام شناسایی و رفع نمود. در صنایع نفت و گاز، ماشین‌های دوار نقش بسیار مهمی در فرآیندهای حیاتی مانند حفاری، پمپاژ، فرآوری و... دارند. ازین رو استفاده از سیستم‌های عیب‌یابی ماشین دوار می‌تواند به بهبود کارایی، ایمنی و کاهش هزینه‌ها در این صنعت نیز کمک کند. در صنایع پیشرفته‌تر مانند صنعت هواپیما، فضا، الکترونیک و... نیز از ماشین‌های دوار پیچیده و حساس استفاده می‌کنند. که این موضوع اهمیت عیب‌یابی سیستم‌های دوار را افزایش می‌دهد. به طور

* نویسنده عهده‌دار مکاتبات: ali.jamli@guilan.ac.ir

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

کلی، عیب‌یابی ماشین دوار در هر صنعتی که از ماشین‌های دوار استفاده می‌شود، اهمیت دارد و می‌تواند به بهبود عملکرد، افزایش بهره‌وری، کاهش هزینه‌ها و افزایش ایمنی کمک کند.

در این راستا می‌توان برای سیستم‌های مکانیکی نظیر ماشین‌های دوار، جعبه دنده و مواردی این چنین، پردازش سیگنال‌های ارتعاشی را پیشنهاد داد. این سیگنال‌ها می‌توانند در تشخیص عیب بسیار موثر عمل کرده و قبل از اینکه عیب سیستم آشکار شود آن عیب را شناسایی کنند. برای این منظور روش‌های متعددی پیشنهاد شده است که در این بین به کارهای انجام شده در عیب‌یابی سیستم‌های دوار و همچنین اهمیت پردازش سیگنال در آن اشاره می‌شود.

روش تبدیل فوریه زمان کوتاه[1] یکی از روش‌های تحلیل در حوزه زمان–فرکانس می‌باشد که به عنوان مثال جونیور و همکاران برای عیب‌یابی سیستم موتور الکتریکی در ماشین دوار از آن به عنوان پیش پردازش سیگنال استفاده کرده‌اند [۱]. زکی‌زاده و همکاران برای عیب‌یابی سیستم دوار بلوئر لکوموتیوهای آلستوم از آنالیز ارتعاشی و ماشین بردار پشتیبان استفاده کردند. در این پژوهش جهت کاهش تعداد ویژگی‌ها از آزمون فیلتر تی استفاده شده است [۲]. در مرجع [۳] برای عیب‌یابی یاتاقان غلتشی که از اصلی‌ترین اجزاء در ماشین‌های دوار می‌باشد، روشی مبتنی بر بررسی محتوای منحنی پوش سیگنال‌های اندازه‌گیری شده، ارائه شده است. شکارزاده و همکاران در مرجع [۴] برای تشخیص عیب یاتاقان‌های سانتریفیوژ با استفاده از داده‌های آزمایشگاهی، روش تحلیل مولفه‌های غیروابسته و بهینه‌سازی دسته ذرات را ارائه دادند. در این پژوهش از ویژگی‌ها در حوزه زمان استفاده شد. در مرجع [۵] نویسندگان برای تشخیص عیب ماشین دوار با استفاده از روش تحلیل اجزای اصلی ابعاد ویژگی‌ها را کاهش داده و با استفاده از شبکه فازی–عصبی و شبکه عصبی چند لایه عیب‌یابی را انجام دادند.

استخراج ویژگی از سیگنال به صورت یک بعدی در تحلیل سیگنال می‌تواند بسیار مفید باشد که به نمونه‌هایی از آن نیز اشاره شد. از جمله برتری‌های این روش سادگی و محاسبات کمتر آن نسبت به تحلیل دو بعدی سیگنال می‌باشد و در عین حال این روش می‌تواند موثر باشد. در مراجع [۶، ۷] نویسندگان از ویژگی‌های حوزه زمان و استخراج یک بعدی ویژگی‌ها برای عیب‌یابی یاتاقان‌ها استفاده کرده است. بررسی آنالیز خود همبستگی ویژگی‌ها نیز می‌تواند در تحلیل سیگنال برای عیب‌یابی موثر واقع شود [۸]. استخراج ویژگی‌ها در حوزه زمان و حوزه فرکانس می‌تواند به همراه تجزیه سیگنال‌ها به صورت چند بعدی نیز انجام شود که روش تجزیه حالت تجربی[2] روشی مناسب برای تجزیه یک سیگنال است [۹].

علاوه بر پردازش سیگنال در حوزه‌های مختلف، کاهش نویز سیگنال‌ها حائز اهمیت می‌باشد. اهمیت این موضوع از آن جهت است که سیگنال‌هایی که از یک سیستم گرفته می‌شوند عموما تحت تاثیر اغتشاشات و نویزهای خارجی مانند امواج الکترومغناطیس قرار می‌گیرند. در این زمینه برای سیگنال ارتعاشی ماشین دوار، روش حذف نویز با کمک تجزیه مد تجربی و بررسی شباهت بین تابع چگالی احتمال سیگنال اصلی با مودهای آن توسط نظامیوند و همکاران در مرجع [۱۰] ارائه شد. استفاده از روش آستانه‌گذاری نرم بعد از تجزیه سیگنال روش موجک تجربی، می‌تواند در کاهش نویز سیگنال‌ها موثر باشد. این روش در مرجع [۱۱] برای سیگنال‌های ارتعاشی ماشین دوار پیشنهاد شده است. در مرجع [۱۲] از روش ترکیبی تبدیل موجک کسری[3] برای کاهش نویز سیگنال استفاده شده است، به این صورت که از تبدیل موجک برای کاهش نویز و از تبدیل فوریه کسری برای تحلیل در حوزه زمان–فرکانس استفاده شده است. در مرجع [۱۳] نمونه‌هایی از نویزهای مختلف که می‌تواند در عیب‌یابی سیستم هیدروژنراتور اتفاق بیفتد، مورد بررسی قرار گرفته است. علاوه بر روش تبدیل موجک که پیشتر به آن اشاره شد، فیلتر کالمن هم نیز می‌تواند در کاهش نویز موثر باشد. یکی از کابردهای این روش کاهش نویزهای رنگی موثر است [۱۴]. نویسندگان در مرجع [۱۵] یک روش جدید ترکیبی فیلتر کالمن بدون عطر[4] و منطق فازی ارائه دادند که برای تنظیم کوواریانس نویز اندازه‌گیری به صورت تطبیقی از منطق فازی استفاده می‌شود. ترکیب فیلتر کالمن و همچنین روش تجزیه مد تجربی نیز می‌تواند در کاهش نویز موثر باشد [۱۶]. از دیگر کاربردهای فیلتر کالمن در عیب‌یابی می‌توان تخمین حالات برای سیستم را نام برد که به عنوان مثال در تشخیص عیب حس گر می‌تواند موثر باشد [۱۷]. عیب‌یابی با تخمین زاویه گام تیغه و موقعیت قرقره سوپاپ توربین باد شناور توسط فیلتر کالمن، از دیگر کارهایی است که در این زمینه انجام شده است [۱۸].

در عیب‌یابی سیستم‌ها بعد از مرحله پیش پردازش سیگنال استفاده از ابزارهای یادگیری ماشین[5] بسیار موثر است. در این بین می‌توان ماشین بردار پشتیبان[6] [۱۵] و یا شبکه‌های عصبی پیچشی[7] [۱۹] و یا شبکه عصبی

1 Short time Fourier transform

2 Empirical Mode Decomposition
3 fractional Wavelet Transform
4 Unscented Kalman filter
5 Machine Learning
6 Support Vector Machine
7 Convolutional Neural Network

پرسپترون چند لایه[1] [۲۰] را به عنوان روش‌هایی مرسوم یادگیری ماشین در عیب‌یابی سیستم‌ها مثال زد. ترکیب این روش‌ها با یکدیگر و همچنین ترکیب آنها با پیش پردازش‌های مختلف می‌تواند نتایج خوبی ارائه دهد. به عنوان مثال در مرجع [۲۰] پارامترهای شبکه عصبی پرسپترون توسط فیلتر کالمن بدون عطر تنظیم می‌شود. در مرجع [۲۱] نویسندگان با ترکیب روش ماشین بردار پشتیبان و تبدیل استوکویل[2] و با انتخاب اکتشافی ویژگی‌ها روشی برای تشخیص عیب اولیه در سیم پیچ‌های استاتور یک موتور القایی ارائه داده‌اند. نویسندگان در [۲۲] برای عیب‌یابی باتری لیتیوم-یونی با مدلسازی باتری و محاسبه خطای باقیمانده، شدت نویز را توسط فیلتر کالمن بدون عطر کاهش دادند و از آن برای داده‌های آموزشی روش ماشین بردار پشتیبان استفاده کرده‌اند. در نمونه دیگر زمالی و همکاران در مرجع [۲۳] برای عیب‌یابی توربین باد با استفاده از فیلتر کالمن به عنوان تخمین‌گر حالت باقیمانده‌های مناسب را ایجاد کردند و با از شبکه فازی-عصبی برای ارزیابی و کلاس‌بندی عیب‌ها استفاده کردند.

همانطور که تاکید شد، کاهش نویز سیگنال‌ها همواره در عیب‌یابی سیستم بسیار موثر می‌باشد. باید توجه داشت محدودیت‌هایی مانند عدم اطلاع دقیق از قدرت نویز و یا به عبارت دیگر میزان آلودگی سیگنال به نویز می‌تواند چالش برانگیز باشد. از این رو پارامترهای یک فیلتر در کاهش نویز سیستم بسیار دخیل هستند و تنظیم دقیق آنها نیز بسیار حائز اهمیت است، به نحوی که کیفیت سیگنال کاهش نیابد و در عین حال اطلاعات غیرمفید نیز از آن حذف شود و در نتیجه دقت و عملکرد سیستم عیب‌یابی افزایش یابد. در این پژوهش علاوه بر کاهش نویز و طبقه‌بندی سیگنال‌ها تنظیم پارامتر نامعلوم کوواریانس نویز مد نظر قرار داده شده است.

در این مقاله روشی جدید برای عیب‌یابی ماشین دوار مبتنی بر استخراج ویژگی در هر دو حوزه زمان و فرکانس و ترکیب آن با روش فیلتر کالمن و شبکه عصبی، ارائه می‌شود. ابتدا سیگنال‌های اولیه توسط فیلتر کالمن نویززدایی می‌شوند. برای این منظور از آنجایی که اطلاعات دقیق در مورد نویز وجود ندارد، کوواریانس نویز سیگنال با آزمایش و تکرار بدست آورده شد. در ادامه با استخراج ویژگی در حوزه زمان و همچنین استخراج ویژگی در حوزه فرکانس که با کمک روش تبدیل سریع فوریه[3] داده‌های اولیه برای پردازش نهایی آماده می‌شوند. در ادامه این داده‌های اولیه به عنوان داده‌های آموزشی به شبکه عصبی‌های مختلف تغذیه می‌شوند.

1 Multilayer perceptron
2 Stockwell transform
3 Fast Fourier Transform

در قسمت دوم این مقاله نحوه جمع‌آوری داده‌های آزمایشگاهی و آماده سازی آن توضیح داده می‌شود. در قسمت سوم فیلتر کالمن معرفی می‌شود و فرآیند کاهش نویز سیگنال در این قسمت بیان می‌شود. در ادامه در قسمت چهارم از این مقاله نحوه استخراج ویژگی‌ها در حوزه زمان و فرکانس بیان می‌شود و در قسمت پنجم از این مقاله نتایج نهایی آموزش شبکه‌های عصبی مختلف برای داده‌های آماده شده نمایش داده می‌شود.

۲- جمع آوری داده‌های آزمایشگاهی

همانطور که در قسمت قبل بیان شد، در این پژوهش از داده‌های آزمایشگاهی سیستم ماشین دوار استفاده می‌شود. از دلایل استفاده از داده‌های آزمایشگاهی می‌توان به بررسی اصول بنیادی سیستم‌های دوار در یک محیط کنترل شده آزمایشگاهی اشاره کرد، که این می‌تواند برای ساخت یک مدل واقعی با دقت بالا و همچنین عیب‌یابی آن حائز اهمیت باشد. به این ترتیب می‌توان عیب‌های مختلف این سیستم را در یک محیط با خطرهای احتمالی کمتری شبیه‌سازی کرد و قابلیت اطمینان آن را زیر نظر گرفت و در ادامه این سیستم اولیه را برای یک محیط واقعی تعمیم داد. از جمله دیگر مزایای داده‌های آزمایشگاهی بررسی روش‌های نوین و تکنولوژی‌های جدید است که برای پیشرفت در یک زمینه بسیار حائز اهمیت می‌باشد. مقایسه روش‌های مختلف و ایده‌های نوین نیز با داده‌های آزمایشگاهی میسر می‌شود. در حالی که اگر ایده‌های جدید بر روی یک سیستم واقعی پیاده شود، در صورت عدم موفقیت‌آمیز بودن آن، می‌تواند منجر هزینه‌های سنگین شود. از این رو بررسی داده‌های آزمایشگاهی علاوه بر اهداف آموزشی و تئوری در پیشرفت تکنولوژی‌های موجود می‌توان بسیار موثر واقع شود.

سیستم آزمایشگاهی مورد استفاده در این پژوهش در شکل ۱ نمایش داده شده است. سیستم مذکور شامل یک موتور جریان متناوب[4] می‌شود که به یک میله متصل است و این میله بر روی سه یاتاقان سوار می‌شود. این سیستم دارای دیسک‌هایی است که می‌توان برای عیب عدم تعادل از آن استفاده کرد. برای ثبت داده‌های سیگنال از دو سنسور شتاب‌سنج استفاده شده است که بر روی یاتاقان اول و دوم (از سمت راست) استفاده شده است. محل قرار گیری یاتاقان‌ها در شکل ۱ معلوم است. به این ترتیب در عیب‌یابی یاتاقان‌ها، علاوه بر یاتاقان‌های دارای سنسور، یاتاقان بدون سنسور نیز مورد تحلیل قرار می‌گیرد. در نحوه قرار گیری سنسورها با فاصله دادن آنها از موتور

4 Alternating current

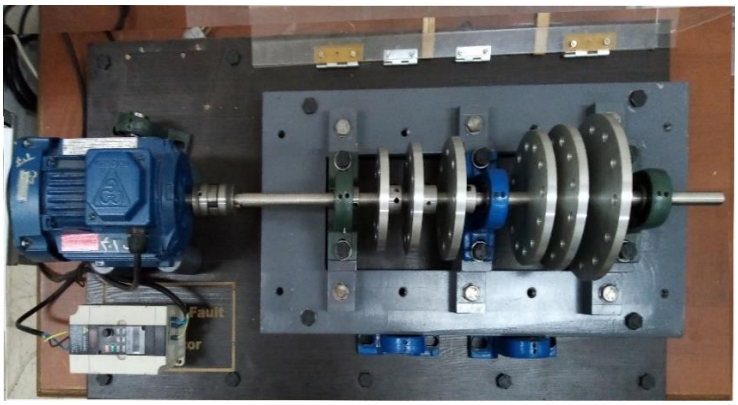

شکل ۱. ماشین دوار آزمایشگاهی جهت ثبت داده

Fig. 1. Laboratory rotating machine for data recording

و مبدل فرکانس در ورودی موتور، تلاش شده تا اثرات نویز را کاهش داد، هر چند همواره نویز به سیگنال‌های سیستم وارد می‌شود، اما با این کار تلاش برای به حداقل رساندن آن شده است.

برای ثبت سیگنال‌های آزمایشی در سیستم ماشین دوار، سه نوع عیب به سیستم وارد می‌شود. عیب‌های وارده شامل عیب ساچمه یاتاقان (عیب کلاس ۱)، عیب رینگ خارجی یاتاقان (عیب کلاس ۲) و نابالانس بودن میله (عیب کلاس ۳) می‌باشد. علت در نظر گرفتن این عیب‌ها این است که میله و یاتاقان اجزای اصلی و مشترک سیستم‌های مکانیکی دوار می‌باشند. عیب نابالانس بودن میله یکی از عیب‌های رایج در سیستم‌های دوار می‌باشد که عوامل مختلفی می‌تواند منجر شود. این عیب می‌تواند در فرآیند تولید و یا نصب میله بوجود آید، که یکی از دلایل آن می‌تواند تراز کردن نادرست میله باشد. از عوامل دیگر در بروز این مشکل لرزش و یا ارتعاشات نامطلوب در سیستم است که می‌تواند ناشی از بارهای نامطلوب بر روی میله و یا عیب‌های احتمالی بوجود آمده در سیستم باشد. عیب‌های در نظر گرفته شده برای یاتاقان جزء عیب‌های متداول یاتاقان‌ها در سیستم‌های دوار می‌باشد که به دلایل مختلفی از جمله عدم گریس‌کاری مناسب، ورود ذرات غبار یا فلزی بوجود می‌آید. همچنین بهم خوردن توازن میله و سایش یکطرفه نیز می‌تواند باعث ایجاد عیب‌های یاتاقان شود. در ثبت سیگنال برای سیستم علاوه بر حالات معیوب سیستم، در حالت سیستم سالم نیز از سنسورها سیگنال دریافت می‌شود.

برای ثبت سیگنال در هر حالت از معیوب یا سالم بودن سیستم، فرکانس تغذیه موتور را در بازه ۸ تا ۳۰ هرتز با گام ۲ هرتز تغییر دادیم یعنی فرکانس تغذیه موتور به صورت ۸، ۱۰، ۱۲، .... ، ۳۰ هرتز می‌باشد. موتور استفاده شده دارای دور نامی ۲۸۲۵ دور بر دقیقه در فرکانس تغذیه ۵۰ هرتز است و توان ۳۷۰ وات دارد.

در حالت کلی برای ثبت داده سیستم، یک حالت سالم برای سیستم در نظر گرفته شده است. در حالت عیب ساچمه یاتاقان، یاتاقان معیوب در سه موقعیت مطابق شکل ۱ قرار می‌گیرد. در حالت عیب رینگ خارجی یاتاقان مشابه حالت قبل یاتاقان معیوب در سه موقعیت قرار می‌گیرد و برای عیب نابالانس بودن میله، وزنه بر هم زننده تعادل بر روی هر کدام از شش دیسک سوار بر میله دوار قرار می‌گیرد (شکل ۱). پس در مجموع با توضیحات داده شده در حالت کلی سیستم معیوب و سالم، ۱۳ حالت برای سیستم داریم. در نتیجه با توجه به اینکه داده‌ها در این ۱۳ حالت در ۱۲ فرکانس تغذیه مختلف برای موتور ثبت می‌شوند، در نتیجه ۱۵۶ داده اولیه ساخته می‌شود. هر کدام از این ۱۵۶ داده اولیه شامل دو سیگنال یک دقیقه‌ای (دو سنسور در سیستم وجود دارد) و ۴ برچسب حالت سیستم یعنی سالم، عیب ۱، عیب ۲ و عیب ۳ است که عیب‌ها به ترتیب بیانگر عیب ساچمه یاتاقان، عیب رینگ خارجی یاتاقان عیب نابالانس بودن میله می‌باشند. برای ثبت هر داده سیگنال، در هر ثانیه ۱۰۰۰ نمونه ثبت شده است.

به این ترتیب با توجه به بالا بودن فرکانس داده‌برداری و رزولوشن بالای سیگنال، شناسایی دقیق‌تر جزئیات به خصوص در فرکانس‌های بالاتر امکان‌پذیر می‌شود. این امر در سیگنال‌های پویا و ارتعاشی اهمیت بیشتری

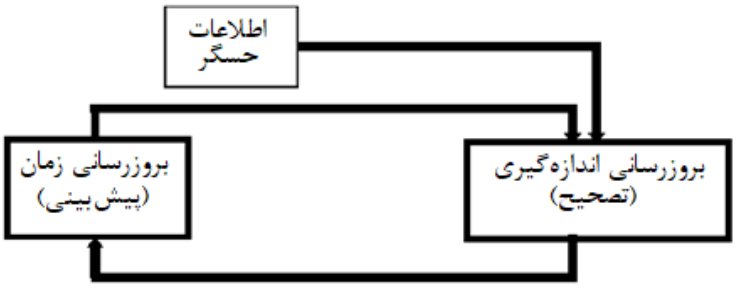

شکل ۲. فرآیند الگوریتم فیلتر کالمن [۲۵]

Fig. 2. Kalman filter algorithm process

دارد تا جزییات دقیق‌تری از سیگنال شناسایی شود. برای ثبت دقیق‌تر اطلاعات زمانی و شناسایی بهتر ویژگی‌های حوزه زمان، زمان ثبت سیگنال یک دقیقه در نظر گرفته شد. در مجموع در سیگنال‌هایی که فرکانس بالای داده‌برداری وجود دارد، زمان بیشتر در ثبت اطلاعات می‌تواند برای جمع‌آوری اطلاعات موثر واقع شود و با افزایش زمان سیگنال می‌توان اثرات نویز را در ویژگی‌های موجود در سیگنال کاهش داد. افزایش بیش از حد فرکانس داده‌برداری و همچنین زمان ثبت داده‌ها نیازمند حافظه بیشتر برای ذخیره داده‌ها و همچنین پردازش پیچیده‌تر داده‌ها می‌باشد. از این رو سیگنال‌های با فرکانس بالا و زمان ثبت بالا نیازمند سخت‌افزار قوی‌تری می‌باشند.

برای جداسازی داده‌های آموزشی و داده‌های صحت سنجی از روش تصادفی هدفمند استفاده شده است. ۳۱ داده از ۱۵۶ داده (چیزی حدود ۲۰ درصد) به عنوان داده‌های صحت سنجی استفاده می‌شود. برای این منظور در هر حالت از عیب ۲ یا ۳ داده برای صحت سنجی کنار گذاشته می‌شود. برای مثال در حالت عیب ساچمه یاتاقان شماره ۱ (از سمت راست یاتاقان اول) که در ۱۲ دور موتور متفاوت ثبت شده است، به صورت تصادفی ۲ یا ۳ سیگنال برای داده صحت سنجی انتخاب می‌شود. برای کاهش اثر جداسازی داده‌ها (آموزشی و صحت سنجی) بر روی نتایج نهایی پژوهش ، این جداسازی را ۵ بار انجام شده است تا نتایج را بتوان بهتر تحلیل کرد. یعنی در حالت کلی ۵ نوع دسته داده آموزشی و صحت سنجی ایجاد می‌شود.

۳- فیلتر کالمن

فیلتر کالمن یک روش حداقل مربعات خطای بازگشتی بیزین[1] برای تخمین سیگنال‌هایی است که در یک فرآیند تغییر پیدا کرده و یا در قسمت مشاهده سیگنال نویز وجود داشته است. از فیلتر کالمن می‌توان برای فرآیندهای متغیر با زمان[2] و همچنین فرآیندهای تغییر ناپذیر با زمان[3] استفاده کرد. این فیلتر از توزیع احتمال که در سیگنال و نویز وجود دارد، استفاده می‌کند و فرض می‌شود فرآیندهای گاوسی با میانگین صفر هستند. این فیلتر همچنین فرض می‌کند که پارامترهای مدل سیگنال و تولید نویز و معادلات اندازه‌گیری[4] از قبل مشخص هستند [۲۴, ۲۵]. فرآیند الگوریتم فیلتر کلمن در شکل ۲ نمایش داده شده است.

معادلات سیستمی که فیلتر کالمن به آن اعمال می‌شود، به صورت معادلات (۱) و (۲) در نظر گرفته می‌شود.

$$x(m)=A\,x(m-1)+B\,u(m)+e(m) \qquad (۱)$$

$$y(m)=H\,x(m)+n(m) \qquad (۲)$$

در سیستم معرفی شده $x(m)$ یک سیگنال p بعدی یا پارامتر حالت در لحظه m می‌باشد. A ماتریس انتقال حالت $p\times p$ است. ماتریس B ماتریس کنترل $p\times n$ می‌باشد که n ابعاد ورودی کنترل است. $u(m)$ ورودی کنترلی n بعدی است و $e(m)$ ورودی p بعدی به عنوان تحریک نامرتبط در ورودی است، این سیگنال یک فرآیند گاوسی با میانگین صفر و کوواریانس Q در نظر گرفته می‌شود. $n(m)$ نیز بردار نویز در اندازه‌گیری با ابعاد M در خروجی است و دارای میانگین صفر و کوواریانس R است. M ابعاد خروجی

1 Bayesian recursive least square error

2 time-varying

3 time-invariant

4 Channel distortion

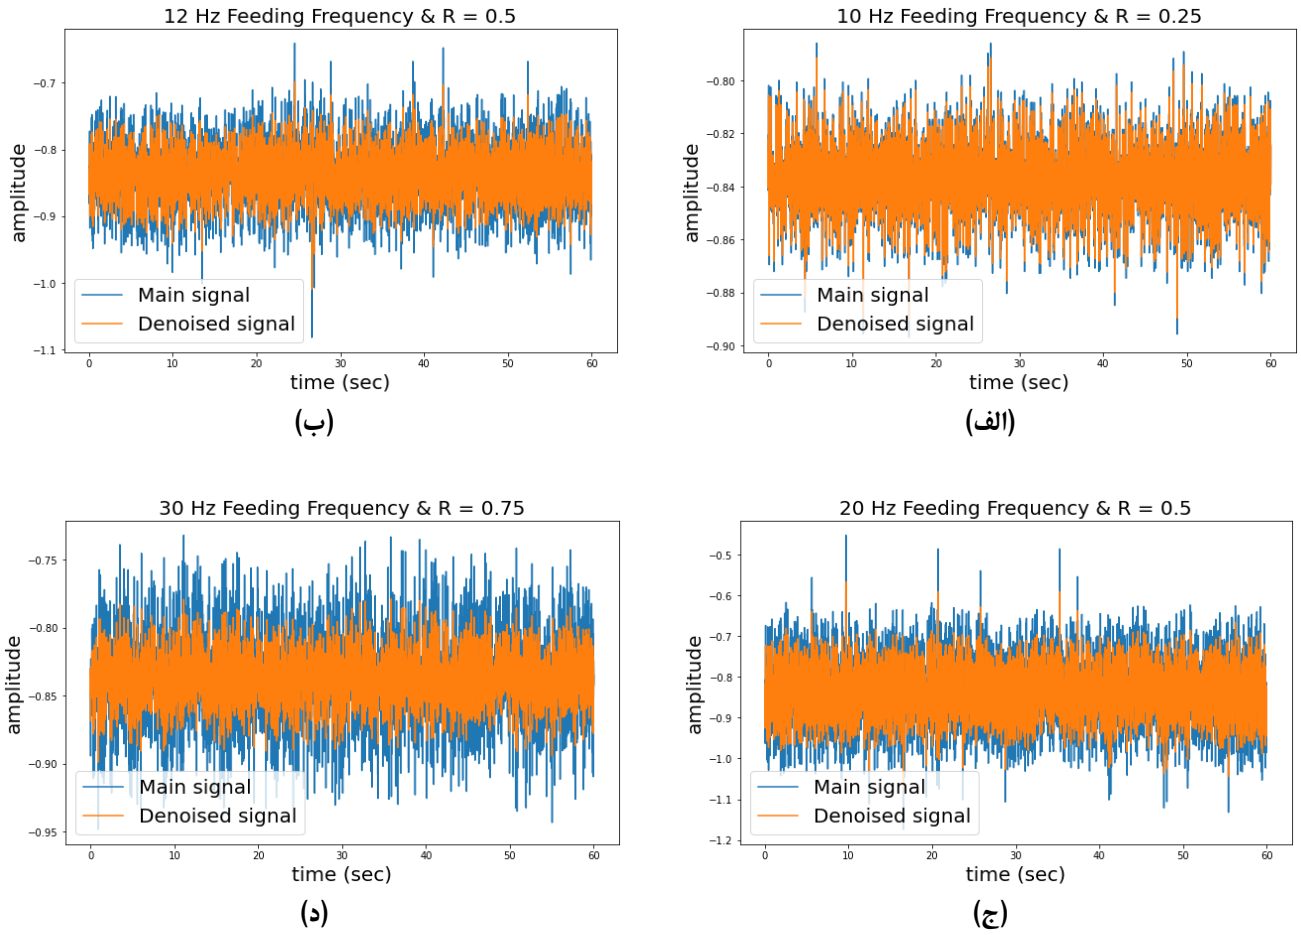

شکل ۳.نمونه سیگنال سیستم و کاهش نویز آن به ازاء (الف) سیستم سالم (ب) سیستم با عیب ساچمه یاتاقان (ج) سیستم با عیب رینگ خارجی یاتاقان (د) سیستم با عیب نابالانس بودن میله

Fig. 3. System signal sample and its noise reduction for (a) Healthy system (b) System with bearing ball fault (c) System with bearing outer ring fault (d) System with shaft unbalance fault

$y(m)$ می‌باشد. در نهایت H نیز یک ماتریس اعوجاج کانال با ابعاد $M\times p$ است.

در این پژوهش با توجه به اینکه فیلتر کالمن بر روی سیگنال یک بعدی اعمال می‌شود، فرض می‌شود نویز در معادلات اندازه‌گیری سیستم وارد شده است. برای این منظور پارامتر کوواریانس مرتبط با نویز مدل سیگنال صفر در نظر گرفته شده است. در معادلات اندازه‌گیری برای پارامتر کوواریانس R با توجه به اینکه اطلاعات دقیقی از آن موجود نیست، به صورت سعی و خطا سه مقدار ۰/۲۵ و ۰/۵ و ۰/۷۵ داده شده است. در واقع این مقدار R برای نویز سیگنال اندازه‌گیری شده در سنسور در نظر گرفته شده است. پارامتر R در بروز رسانی مدل و تصحیح پیش‌بینی‌ها بکار می‌رود.

شکل ۳ مثال‌هایی از سیگنال‌های اصلی و سیگنال‌های نویززدایی شده توسط فیلتر کالمن در این پژوهش را نمایش می‌دهد. همانطور که از این شکل مشخص است، هرچه کوواریانس نویز معادلات اندازه‌گیری بزرگ‌تر در نظر گرفته شود سیگنال نویززدایی شده دارای اندازه کوچک‌تری و قدرت کمتری می‌شود. شکل ۴ نیز طیف توان سیگنال‌ها قبل و بعد از کاهش نویز توسط فیلتر کالمن را نمایش می‌دهد. همانطور که از شکل ۴ مشخص است، فرکانس‌های بالا بعد از کاهش نویز تضعیف می‌شوند.

برای بررسی دقیق‌تر تاثیر کاهش نویز انجام شده بر روی سیگنال‌ها

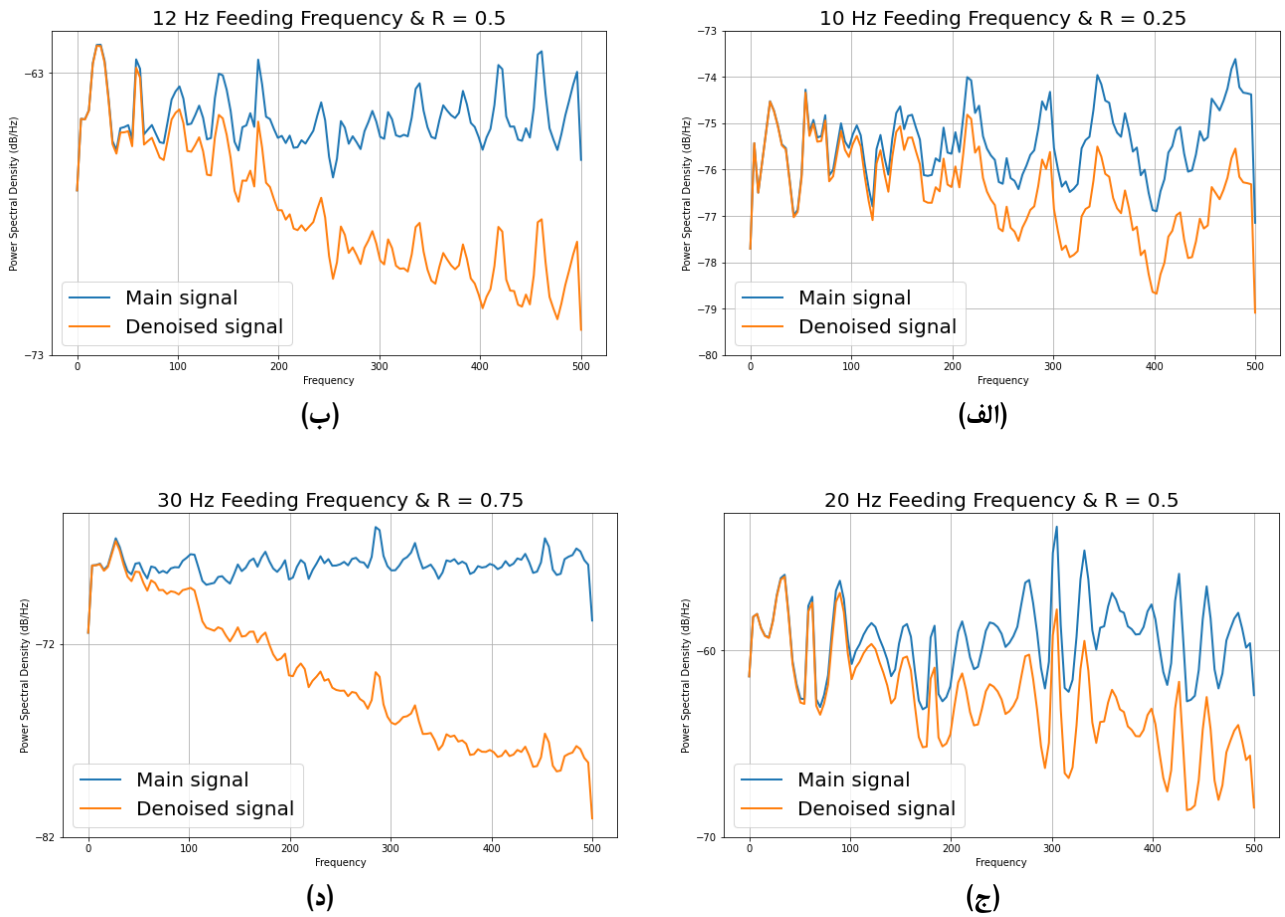

شکل ۴. تغییرات چگالی طیف توان بعد از کاهش نویز توسط فیلتر کالمن در (الف) سیستم سالم (ب) سیستم با عیب ساچمه یاتاقان (ج) سیستم با عیب رینگ خارجی یاتاقان (د) سیستم با عیب نابالانس بودن میله

Fig. 4. Power spectral density changes after noise reduction by Kalman filter in (a) Healthy system (b) System with bearing ball fault (c) System with bearing outer ring fault (d) System with shaft unbalance fault

از معیار نرخ سیگنال به نویز[1] استفاده می‌شود. نرخ سیگنال به نویز در واقع نسبت قدرت سیگنال اصلی و نویز را در واحد dB نمایش می‌دهد و به نحوی بیانگر کیفیت سیگنال می‌باشد [۲۶]. به این ترتیب با توجه به اینکه ۱۵۶ سیگنال مختلف توسط دو سنسور ثبت شده‌اند، مقادیر نسبت نویز به سیگنال برای هر کدام از این سیگنال‌ها محاسبه شد و در شکل ۵ بیشینه مقدار نرخ سیگنال به نویز در کاهش نویز کل سیگنال‌ها که توسط سنسورهای ۱ و ۲ ثبت شده‌اند، نمایش داده می‌شود. این نمایش به ازاء کوواریانس‌های اندازه گیری متفاوت در روش فیلتر کالمن می‌باشد.

1 Signal to Noise Ratio

برای بررسی عملکرد فیلتر کالمن در کاهش نویز، از یک فیلتر پایین‌گذر باترورث[2] مرتبه ۴ استفاده شده است [۲۷] و با آن مقایسه شده است. هر چه مرتبه فیلتر پایین‌گذر باترورث بیشتر شود، بعد از فرکانس قطع، قدرت طیف سیگنال بیشتر کاهش پیدا می‌کند و قبل از آن قدرت طیف سیگنال کمتر کاهش پیدا می‌کند. استفاده از فیلتر مرتبه ۴ تا حد معقولی می‌تواند در کاهش توان فرکانس‌های بالای فرکانس قطع و همچنین حفظ توان فرکانس‌های پایین‌تر از فرکانس قطع مناسب باشد. با توجه به اینکه چگالی طیف توان سیگنال‌های ارتعاشی در فرکانس‌های متفاوت به صورت یکنواخت است، در

2 Butterworth

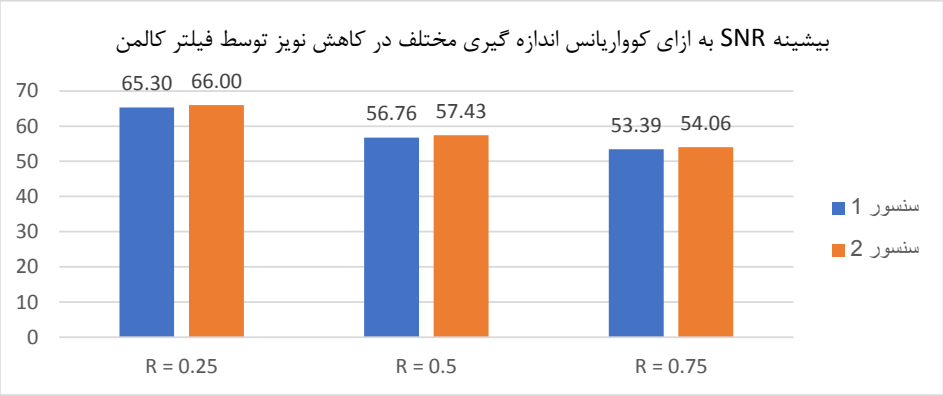

شکل ۵. بیشینه نرخ سیگنال به نویز در سیگنال‌های مختلف هر سنسور بعد از کاهش نویز توسط فیلتر کالمن در کوواریانس اندازه‌گیری متفاوت

Fig. 5. Maximum Signal to Noise Ratio in different signals of each sensor after noise reduction by Kalman filter for different measurement covariance

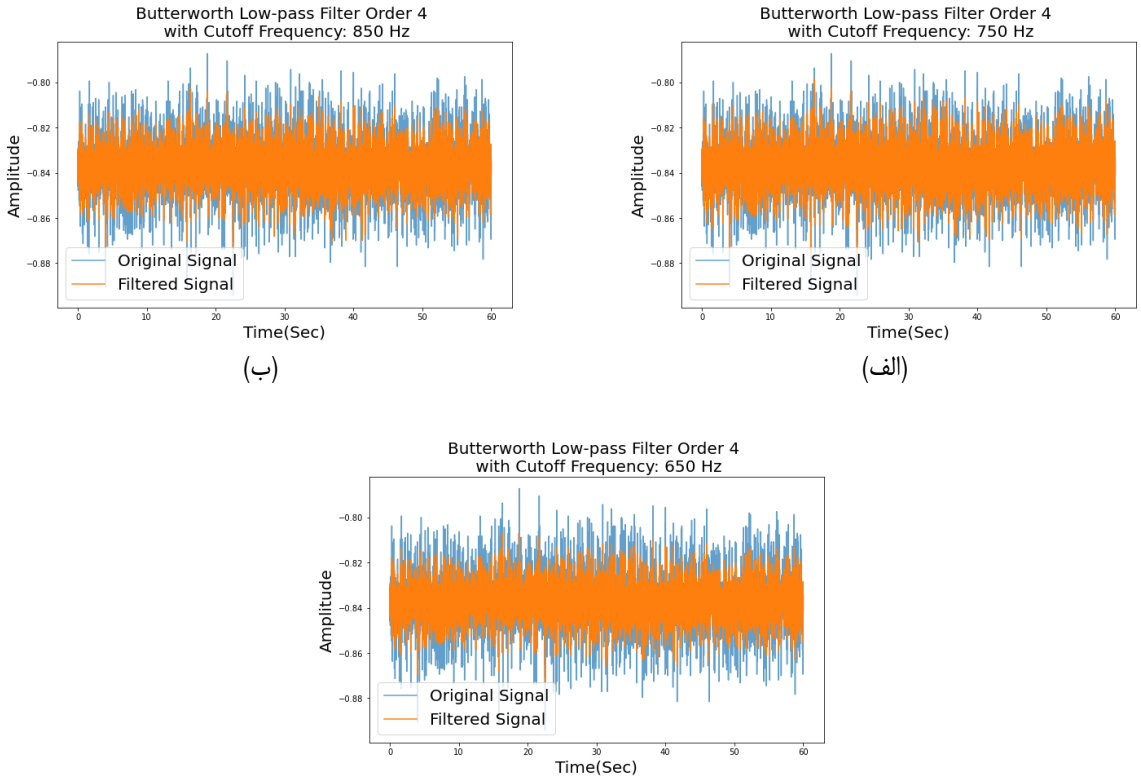

شکل ۶. سیگنال سیستم سالم در فرکانس تغذیه موتور ۱۴ هرتز و کاهش نویز آن در فرکانس قطع (الف) ۸۵۰ هرتز (ب) ۷۵۰ هرتز (ج) ۶۵۰ هرتز

Fig. 6. Healthy system signal at 14 Hz motor feeding frequency and noise reduction for cut-off frequency (a) 850 Hz (b) 750 Hz (c) 650 Hz

این حالت هم مشابه فیلتر کالمن با استفاده از سعی خطا، بهترین فرکانس قطع انتخاب می‌شود. نتایج چگالی طیف توان سیگنال‌های ارتعاشی و همچنین اثر کاهش نویز آن در سه فرکانس قطع متفاوت برای سیگنال سیستم سالم در فرکانس تغذیه موتور ۱۴ هرتز در شکل ۶ نمایش داده شده است. در این شکل برای فرکانس‌های قطع، با توجه به اینکه فرکانس داده‌برداری ۱۰۰۰ هرتز می‌باشد، مقادیر ۶۵۰، ۷۵۰ و ۸۵۰ هرتز در نظر گرفته شده است. این فرکانس‌ها به نحوی انتخاب شدند که اطلاعات اصلی سیگنال از دست نرود. کاهش بیش از حد این فرکانس‌ها می‌تواند منجر به

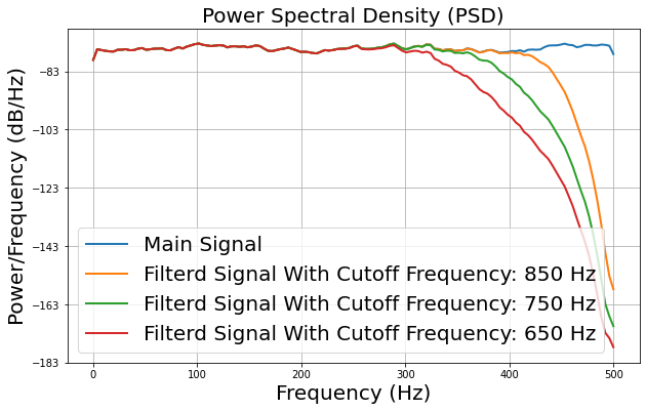

شکل ۷. تغییرات چگالی طیف توان بعد از کاهش نویز توسط فیلتر پایین‌گذر در سیگنال سیستم سالم در فرکانس تغذیه موتور ۱۴ هرتز

Fig. 7. Power spectral density changes after noise reduction by low-pass filter in healthy system signal at 14 Hz motor feeding frequency

از بین رفتن اطلاعات مهم سیگنال شود.

در شکل ۷ تغییرات طیف توان برای سیگنال فیلتر شده توسط فیلتر پایین‌گذر با فرکانس‌های قطع متفاوت، نمایش داده می‌شود. با مقایسه شکل ۷ و شکل ۴ به راحتی می‌توان دریافت که در فیلتر پایین‌گذر عملا یک سری فرکانس‌ها حذف می‌شوند، اما در فیلتر کالمن فرکانس‌های بالا نهایتا در حد ۱۰ dB تضعیف شده است. این در حالی است که این مقدار در شکل ۷ برای فیلتر پایین‌گذر تقریبا ۱۰۰dB می‌باشد. باید توجه داشت که در یک سیگنال ارتعاشی با فرکانس داده برداری بالا اطلاعات در فرکانس‌های بالا نیز حائز اهمیت می‌باشد.

۴- استخراج ویژگی‌ها برای تحلیل سیگنال‌ها

برای تحلیل سیگنال‌ها از استخراج ویژگی در حوزه زمان و فرکانس استفاده می‌شود. برای استخراج ویژگی‌ها از داده‌های سیگنال، ویژگی‌هایی در حوزه زمان و حوزه فرکانس در نظر گرفته شده است. در این پژوهش از ۱۴ ویژگی در حوزه زمان و ۹ ویژگی در حوزه فرکانس استفاده می‌شود. جدول ۱ ویژگی‌ها در حوزه زمان را نشان می‌دهد و در جدول ۲ ویژگی‌های در حوزه فرکانس معرفی می‌شوند.

در جدول ۱ مقدار m طول سیگنال است و X_{sd} مقدار واریانس سیگنال می‌باشد و به صورت معادله (۳) است و در جدول ۲ پارامتر $S(k)$ مقدار طیف سیگنال می‌باشد و k طول طیف سیگنال است. f_k نیز مقدار فرکانس به ازاء kمین داده در طول طیف سیگنال است.

$$x_{sd} = \sqrt{\frac{1}{m-1}\sum_{n=1}^{m}\left(x(n)-F_1\right)^2} \qquad (۳)$$

برای استخراج ویژگی در حوزه زمان، سیگنال به طور مستقیم در روابط جدول ۱ قرار داده می‌شود. در حوزه فرکانس، قبل از استخراج ویژگی باید ابتدا طیف[1] سیگنال را استخراج کرد. برای این کار توسط تحلیل تبدیل سریع فوریه، سیگنال وارد حوزه فرکانس می‌شود و طیف سیگنال بدست می‌آید. از تبدیل سریع فوریه به عنوان روشی برای افزایش سرعت تبدیل فوریه گسسته[2] استفاده می‌شود. برای استفاده از تبدیل سریع فوریه طول طیف آن باید توانی از دو به صورت $N = 2^n$ باشد [۳۱]. در ادامه ویژگی‌های جدول ۲ بر روی طیف سیگنال اعمال می‌شود تا ویژگی‌های در حوزه فرکانس نیز بدست آید.

۵- بررسی نتایج آموزش شبکه‌های عصبی

با توجه به توضیحات داده شده در قسمت قبل ۲۳ ویژگی از هر سیگنال استخراج می‌شود، و هر داده ما دارای دو سیگنال می‌باشد، در نتیجه در هر

1 Spectrum
2 Discrete Fourier Transform

جدول ۱. ویژگی‌های حوزه زمان [۶, ۲۸, ۲۹]

Table 1. Features of the time domain

نام ویژگی	معادله	نام ویژگی	معادله
مقدار میانگین	$F_1=\frac{1}{m}\sum_{n=1}^{m}x(n)$	فاکتور ترخیص[1]	$F_8=\frac{F_4}{F_2}$
مربع ریشه اندازه	$F_2=\left(\frac{1}{m}\sum_{n=1}^{m}\sqrt{\lvert x(n)\rvert}\right)^2$	فاکتور اندازه	$F_9=\frac{F_3}{F_1}$
مربع ریشه میانگین	$F_3=\sqrt{\frac{1}{m}\sum_{n=1}^{m}(x(n))^2}$	فاکتور ضربه	$F_{10}=\frac{F_4}{F_1}$
اوج	$F_4=\max\lvert x(n)\rvert$	اوج به اوج	$F_{11}=\max\lvert x_n\rvert-\min\lvert x_n\rvert$
اسکیونس[2]	$F_5=\frac{\sum_{n=1}^{m}(x(n)-F_1)^3}{(m-1)X_{sd}^3}$	فاکتور حاشیه	$F_{12}=\frac{F_4}{F_3}$
کورتوسیس[3]	$F_6=\frac{\sum_{n=1}^{m}(x(n)-F_1)^4}{(m-1)X_{sd}^4}$	فاکتور جمع ۱	$F_{13}=\log(F_6+F_3)$
فاکتور کرست[4]	$F_7=\frac{F_4}{F_3}$	فاکتور جمع ۲	$F_{14}=\log\left(F_6^{F_7}+\left(\frac{F_3}{0.078}\right)^{F_{11}}\right)$

جدول ۲. ویژگی‌های حوزه فرکانس [۳۰]

Table 2. Features of the frequency domain

نام ویژگی	معادله	نام ویژگی	معادله
مقدار میانگین	$F_{15}=\frac{1}{k}\sum_{k=1}^{K}S(k)$	ضریب تغییر پذیری	$F_{20}=\frac{F_{18}}{X_{17}}$
واریانس	$F_{16}=\frac{1}{k-1}\sum_{k=1}^{K}(S(k)-F_{15})^2$	اسکیونس	$F_{21}=\frac{\sum_{k=1}^{K}(f_k-X_{17})^3S(k)}{KF_{18}^3}$
مرکز فرکانس	$X_{17}=\frac{\sum_{k=1}^{K}f_kS(k)}{\sum_{k=1}^{K}S(k)}$	کورتوسیس	$F_{22}=\frac{\sum_{k=1}^{K}(f_k-X_{17})^4S(k)}{KF_{18}^4}$
ریشه واریانس	$F_{18}=\sqrt{\frac{1}{k}\sum_{k=1}^{K}(f_k-X_{17})^2S(k)}$	نرخ مربع ریشه میانگین	$F_{23}=\frac{\sum_{k=1}^{K}(f_k-X_{17})^{0.5}S(k)}{K\sqrt{F_{18}}}$
مربع ریشه میانگین	$F_{19}=\sqrt{\frac{\sum_{k=1}^{K}f_k^2S(k)}{\sum_{k=1}^{K}S(k)}}$		

[1] Clearance
[2] Skewness
[3] Kurtosis
[4] crest

داده ۴۶ عدد ثبت می‌شود. در نتیجه ابعاد داده‌های ورودی آموزشی ۱۲۵ در ۴۶ می‌باشد (۱۲۵ داده از ۱۵۶ داده آموزشی هستند). این داده‌ها به عنوان ورودی شبکه‌های عصبی پرسپترون چند لایه و شبکه ماشین بردار پشتیبان و برای شبکه‌های عصبی پیچشی با ساختار الهام و الکس‌نت، در نظر گرفته می‌شود.

کلاس‌بند ماشین بردار پشتیبان با توجه به قابلیت کاربرد در داده‌های با ابعاد بالا به خوبی می‌تواند با ویژگی‌های استخراج شده در عیب‌یابی ماشین دوار کار کند. این روش معمولاً دارای کارآیی خوبی برای مسائل دسته‌بندی می‌باشد و می‌تواند در مواقعی که داده‌ها جداپذیر هستند، عملکرد بسیار خوبی داشته باشد. شبکه پرسپترون چند لایه به دلیل انعطاف پذیری زیاد در مدلسازی و توانایی تطبیق با الگوهای پیچیده معمولاً در مسائل پیچیده‌تر کارآمد هستند. این روش می‌تواند ویژگی‌های پیچیده و توزیع نامنظم داده‌های یک بعدی را یاد بگیرد. شبکه پیچشی الکس‌نت نیز به خوبی برای تشخیص الگوهای پیچیده در تصاویر عمل می‌کند، که می‌تواند برای تشخیص عیوب در ماشین‌های دوار مفید باشد. از این رو از ویژگی چند بعدی بودن این روش و کارایی بالا و انعطاف پذیری این شبکه عصبی که در مسابقات داده‌های بینایی ماشین بسیار موفق بوده، می‌توان در داده‌های مختلف استفاده کرد. معماری الهام مشابه شبکه الکس‌نت با استفاده از ماژول‌های پیچش با اندازه‌های مختلف، انعطاف پذیری بالایی در معماری شبکه‌ای خود دارد که می‌تواند منجر به عملکرد بهتر در تشخیص الگوها و ویژگی‌های پیچیده شود. همچنین دارای ساختار کوچک‌تر نسبت به الکس‌نت می‌باشد. از این رو در این پژوهش این شبکه به عنوان شبکه پیچشی با ساختار کوچک مورد ارزیابی قرار گرفت.

با تنظیم داده‌ها و ویژگی‌های مناسب به عنوان ورودی به این مدل‌ها همچنین تنظیم صحیح پارامترهای مدل‌ها، می‌توان عملکرد این شبکه‌ها را افزایش داد و استفاده از این شبکه‌ها می‌تواند به دقت و کارایی مدل در تشخیص و پیش‌بینی عیوب در ماشین‌های دوار کمک کند.

شبکه عصبی پرسپترون چند لایه بکار برده شده در این پژوهش دارای ۳۰ لایه مخفی است و از شبکه ماشین بردار پشتیبان با هسته خطی[1] استفاده شده است. برای تحلیل ویژگی‌ها توسط ابزارهای ۲ بعدی در شبکه عصبی پیچشی، ورودی شبکه را به صورت ۲ بعدی در آوردیم. برای این منظور از ویژگی آخر صرف نظر کردیم و ۴۵ ویژگی را به صورت ماتریس ۵ در ۹ در آوردیم. در نتیجه برای شبکه عصبی پیچشی ابعاد ورودی داده‌های آموزشی به صورت ۱۲۵ در ۵ در ۹ می‌باشد.

برای بررسی تاثیر کاهش نویز سیگنال توسط فیلتر کالمن، از آنجایی که اطلاعی در مورد کوواریانس نویز سیستم نداریم، برای کوواریانس R در نویز اندازه‌گیری سیگنال، به صورت سعی و خطا مقادیر ۰/۲۵، ۰/۵ و ۰/۷۵ قرار داده شده است. یعنی قبل از استخراج ویژگی سیگنال مورد نظر در سه حالت نویززدایی می‌شود و یک حالت بدون کاهش نویز نیز از سیگنال ویژگی استخراج می‌شود.

از آنجایی که تقسیم‌بندی داده‌های ارزیابی و داده‌های آموزشی در نتایج آموزش شبکه‌ها تاثیر گذار هستند، کلاس‌بندهای نام برده در پنج تقسیم‌بندی مختلف داده‌ها آموزش داده می‌شود. نتایج آموزش شبکه‌های عصبی استفاده شده در جدول‌های ۳، ۴، ۵ و ۶ نمایش داده شده است. این جدول‌ها نتایج را برای هر کلاس‌بند، به ازاء تقسیم داده‌های مختلف و حالات مختلف کاهش نویز توسط فیلتر کالمن نمایش می‌دهند.

در ادامه کار در دو حالت نتایج با هم مقایسه شده‌اند: یکی برای دقت شبکه عصبی و دیگری برای تاثیر کاهش نویز. برای مقایسه بهتر دقت کلاس‌بندها میانگین و واریانس کل داده‌های ارزیابی به ازاء کلاس‌بندهای مختلف در جدول ۷ نمایش داده شده است. در جدول ۷ میانگین و واریانس دقت داده‌های ارزیابی در هر کلاس‌بند برای کل نتایج، در حالت بدون کاهش نویز و۳ حالت کاهش نویز اندازه‌گیری شده است. همانطور که از این جدول مشخص است شبکه عصبی الکس‌نت دارای بهترین میانگین دقت برای داده‌های ارزیابی در تمامی حالات کاهش نویز می‌باشد و شبکه عصبی پرسپترون چند لایه دارای کمترین واریانس دقت برای داده‌های ارزیابی است، یعنی پراکندگی کمتری در نتایج دقت داده‌های ارزیابی دارد. در مجموع با توجه به اینکه شبکه عصبی الکس‌نت شبکه عصبی عمیق‌تری نسبت به سایر شبکه‌ها می‌باشد به دقت بالاتری برای داده‌های ارزیابی رسیده است.

برای مقایسه اثر کاهش نویز توسط فیلتر کالمن، میانگین و واریانس دقت کل داده‌های ارزیابی به ازاء نوع کاهش نویز سیگنال محاسبه شده است و نتایج در جدول ۸ نمایش داده شده است. با توجه به جدول ۸ می‌توان متوجه شد که در کاهش نویز با فیلتر کالمن به ازاء کوواریانس $R = ۰/۵$ در نویز اندازه‌گیری، بهترین دقت برای داده‌های ارزیابی را داریم. در نتیجه با استفاده از فیلتر کالمن این دقت نسبت به حالت بدون کاهش نویز بهبود داده شده است. همچنین نتایج دقت داده‌های ارزیابی در کوواریانس نویز اندازه‌گیری $R = ۰/۵$ نسبت به حالتی که کاهش نویز وجود نداشته باشد، پراکندگی کمتری دارد.

1 Linear kernel

جدول ۳. نتایج دقت آموزش شبکه ماشین بردار پشتیبان

Table 3. SVM network accuracy results

تقسیم‌بندی داده	نوع داده	کاهش نویز فیلتر کالمن با R =۰/۲۵	کاهش نویز فیلتر کالمن با R =۰/۵	کاهش نویز فیلتر کالمن با R =۰/۷۵	بدون کاهش نویز
۱	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۰۳	۰/۹۳۵	۰/۹۳۵	۰/۸۷۱
۲	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۱	۱	۰/۹۶۸	۰/۹۶۸
۳	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۶۸	۰/۹۶۸	./۹۳۵	./۹۶۸
۴	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	./۸۷۱	./۸۷۱	./۸۷۱	./۸۷۱
۵	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	./۹۳۵	./۹۳۵	./۹۰۳	./۸۷۱

جدول ۴. نتایج دقت آموزش شبکه عصبی پرسپترون چند لایه

Table 4. Multi-layer perceptron network accuracy results

تقسیم‌بندی داده	نوع داده	کاهش نویز فیلتر کالمن با R =۰/۲۵	کاهش نویز فیلتر کالمن با R =۰/۵	کاهش نویز فیلتر کالمن با R =۰/۷۵	بدون کاهش نویز
۱	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۶۸	۰/۹۶۸	۰/۹۳۵	۱
۲	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۳۵	۰/۹۳۵	۰/۹۰۳	۰/۹۳۵
۳	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۳۵	۰/۹۳۵	۰/۹۳۵	۰/۹۳۵
۴	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۳۵	۰/۹۳۵	۰/۹۳۵	۰/۹۳۵
۵	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸

جدول ۵. نتایج دقت آموزش شبکه عصبی الکس‌نت

Table 5. AlexNet network accuracy results

تقسیم‌بندی داده	نوع داده	کاهش نویز فیلتر کالمن با R =۰/۲۵	کاهش نویز فیلتر کالمن با R =۰/۵	کاهش نویز فیلتر کالمن با R =۰/۷۵	بدون کاهش نویز
۱	داده آموزش	۰/۹۶	۰/۹۷۶	۰/۹۹۲	۰/۹۶۸
	داده ارزیابی	۰/۹۳۵	۰/۹۰۳	۰/۹۳۵	۰/۹۳۵
۲	داده آموزش	۰/۹۲۸	۰/۹۹۲	۰/۹۶۸	۰/۹۸۴
	داده ارزیابی	۱	۱	۱	۱
۳	داده آموزش	۰/۹۸۴	۰/۹۵۲	۰/۹۸۴	۰/۹۹۲
	داده ارزیابی	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸
۴	داده آموزش	۰/۹۶۸	۰/۹۸۴	۰/۹۰۴	۰/۹۱۲
	داده ارزیابی	۰/۹۶۸	۰/۹۶۸	۰/۹۳۵	۰/۹۳۵
۵	داده آموزش	۰/۹۲	۰/۸۴	۰/۹۲	۰/۹۴۴
	داده ارزیابی	۰/۹۳۵	۰/۹۶۸	۰/۹۳۵	۰/۹۳۵

جدول ۶. نتایج دقت آموزش شبکه عصبی الهام

Table 6. Inception network accuracy results

تقسیم‌بندی داده	نوع داده	کاهش نویز فیلتر کالمن با R =۰/۲۵	کاهش نویز فیلتر کالمن با R =۰/۵	کاهش نویز فیلتر کالمن با R =۰/۷۵	بدون کاهش نویز
۱	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸
۲	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۱	۱	۰/۹۶۸	۱
۳	داده آموزش	۱	۱	۰/۹۱۲	۱
	داده ارزیابی	۰/۹۳۵	۰/۹۳۵	۰/۹۰۳	۰/۹۶۸
۴	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۰۳	۰/۹۶۸	۰/۹۳۵	۰/۹۰۳
۵	داده آموزش	۱	۱	۱	۱
	داده ارزیابی	۰/۹۰۳	۰/۸۷۱	۰/۹۰۳	۰/۹۰۳

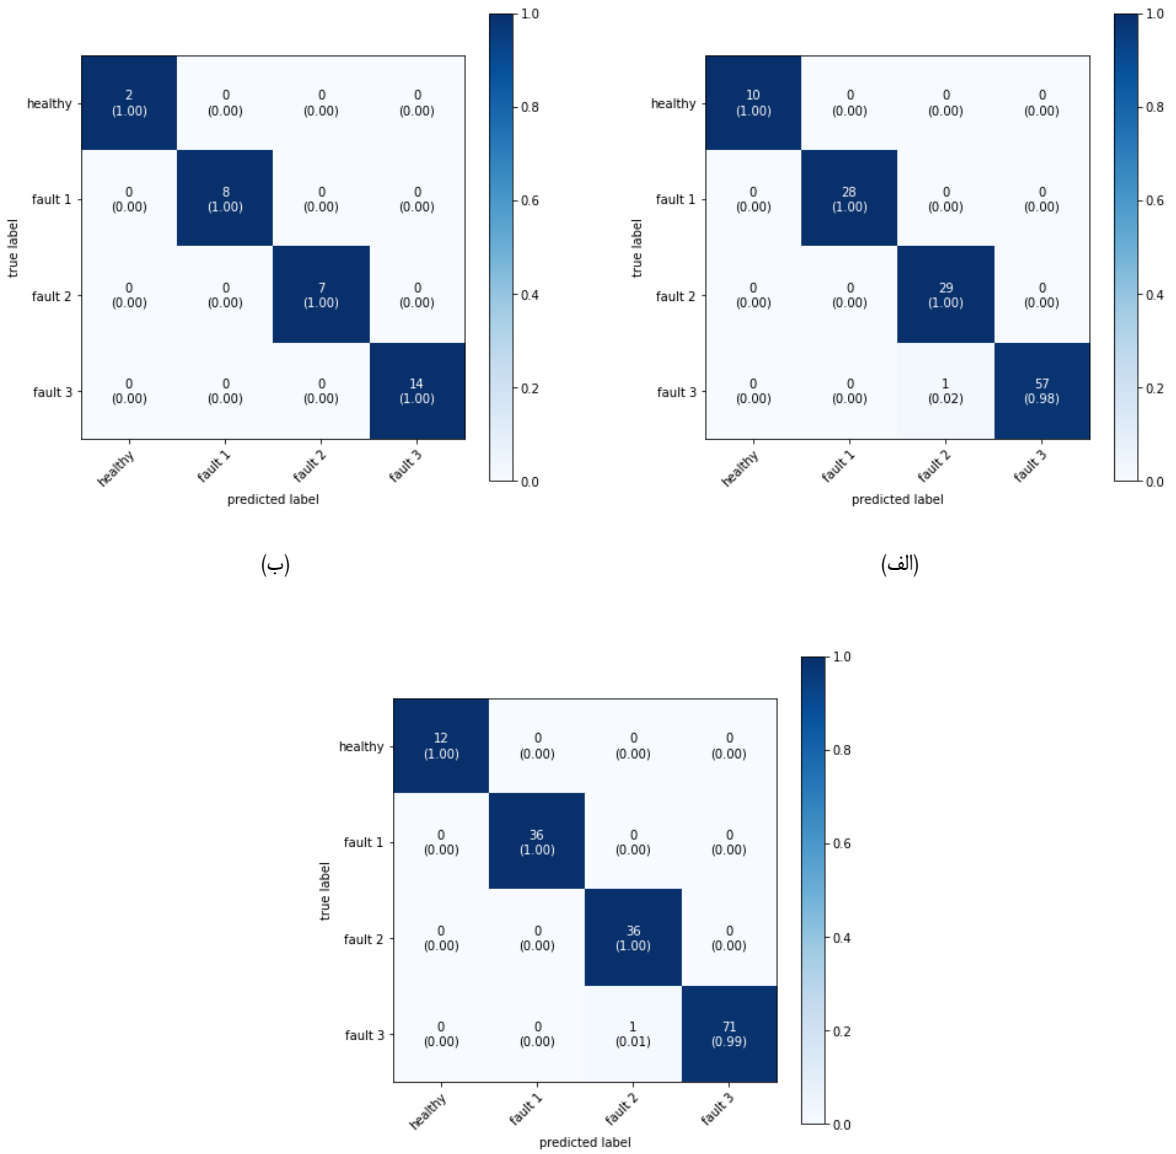

شکل ۸. ماتریس سردرگمی برای شبکه عصبی الکس‌نت در حالت کاهش نویز با کوواریانس در نویز اندازه‌گیری در تقسیم‌بندی شماره ۲ برای (الف) داده‌های آموزشی (ب) داده‌های ارزیابی (ج) کل داده‌ها

Fig. 8. Confusion matrix for AlexNet neural network in noise reduction mode with covariance in measurement noise in division number 2 for (a) training data (b) validation data (c) total data

در ادامه با توجه به اینکه بهترین نتایج در حالت کاهش نویز با کوواریانس نویز اندازه‌گیری $R = ۰/۵$ بدست آمده است، مقایسه میانگین و واریانس دقت داده‌های ارزیابی برای شبکه عصبی‌های مختلف در این حالت کاهش نویز بررسی می‌شود. برای این منظور با توجه به جدول ۷ همانطور که انتظار می‌رفت شبکه عصبی الکس‌نت در حالت کاهش نویز با کوواریانس نویز اندازه‌گیری $R = ۰/۵$ بهترین دقت برای داده‌های ارزیابی را دارد. با توجه به اینکه شبکه عصبی الکس‌نت در حالت کاهش نویز $R = ۰/۵$ در تقسیم‌بندی شماره ۲ داده‌ها بهترین عملکرد را داشته است، ماتریس سردرگمی[1] آن به عنوان نمونه در شکل ۸ نمایش داده شده است. همچنین برای بررسی بهتر نتایج شبکه عصبی الکس‌نت در حالت کاهش نویز با کوواریانس $R = ۰/۵$ در نویز اندازه‌گیری، در شکل ۹ منحنی مشخصه عملکرد سیستم[2] به همراه محاسبه سطح زیر نمودار آن[3] نمایش داده شده است.

1 Confusion Matrix
2 Receiver Operating Characteristics (ROC)
3 Area under the ROC curve (AUC)

جدول ۷. میانگین و واریانس دقت برای داده‌های ارزیابی در آموزش برای هر کلاس بند به ازاء حالات مختلف کاهش نویز فیلتر کالمن

Table 7. Mean and variance of accuracy for the validation data for each classifier's training according to different Kalman filter noise reduction mode

	کل حالات کاهش نویز		کاهش نویز فیلتر کالمن با R =۰/۲۵		کاهش نویز فیلتر کالمن با R =۰/۵		کاهش نویز فیلتر کالمن با R =۰/۷۵		بدون کاهش نویز	
روش کلاس بندی	میانگین	واریانس	میانگین	واریانس	میانگین	واریانس	میانگین	واریانس	میانگین	واریانس
ماشین بردار پشتیبان	۰/۹۲۷	۰/۰۰۲۱	۰/۹۳۵	۰/۰۰۲۶	۰/۹۴۲	۰/۰۰۲۳	۰/۹۲۲	۰/۰۰۱۴	۰/۹۱۰	۰/۰۰۲۸
پرسپترون چند لایه	۰/۹۴۷	**۰/۰۰۰۵**	۰/۹۴۸	**۰/۰۰۰۳**	۰/۹۴۸	**۰/۰۰۰۳**	۰/۹۳۵	**۰/۰۰۰۵**	۰/۹۵۵	**۰/۰۰۰۸**
الهام	۰/۹۴۴	۰/۰۰۱۵	۰/۹۴۲	۰/۰۰۱۸	۰/۹۴۸	۰/۰۰۲۴	۰/۹۳۵	۰/۰۰۱۱	۰/۹۴۸	۰/۰۰۱۹
الکس‌نت	**۰/۹۵۸**	۰/۰۰۰۸	**۰/۹۶۱**	۰/۰۰۰۷	**۰/۹۶۱**	۰/۰۰۱۳	**۰/۹۵۵**	۰/۰۰۰۸	**۰/۹۵۵**	۰/۰۰۰۸

جدول ۸. میانگین و واریانس دقت داده‌های ارزیابی در آموزش برای کل کلاس بندها در هر حالت کاهش نویز فیلتر کالمن

Table 8. Mean and variance of accuracy of the validation data for entire classifier's training according Kalman filter noise reduction mode

نوع کاهش نویز	میانگین	واریانس
R =۰/۲۵	۰/۹۴۷	۰/۰۰۱۲
R =۰/۵	**۰/۹۵**	۰/۰۰۱۴
R =۰/۷۵	۰/۹۳۷	**۰/۰۰۹**
بدون کاهش نویز	۰/۹۴۲	۰/۰۰۱۷

ماتریس سردرگمی شکل ۸ نتایج شبکه عصبی الکس‌نت را برای داده‌های آموزشی و داده‌های تست به خوبی نشان می‌دهد. این شکل دقت سیستم عیب‌یابی برای کلاس‌های مختلف عیب را مشخص می‌سازد. با توجه به شکل ۸ (الف) تنها یک نمونه داده آموزشی عیب کلاس ۳ یعنی عیب نابالانس بودن میله به اشتباه کلاس ۲ یعنی عیب ساچمه یاتاقان تشخیص داده شده است و در باقی موارد نیز عیب کلاس‌های ۱ و ۲ یعنی عیب ساچمه یاتاقان و عیب رینگ خارجی یاتاقان بودن میله کاملا درست تشخیص داده شده است. در داده‌های تست نیز با توجه به شکل ۸ (ب) تمامی کلاس‌ها به درستی تشخیص داده شد. شکل ۸ (ج) داده‌ها را به صورت کلی بررسی می‌کند که در مجموع یک پیش‌بینی اشتباه در عیب کلاس ۳ داشتیم که کلاس ۲ تشخیص داده شد. شکل ۸ برای بهترین نتیجه‌ای که در جداول ۳ تا ۶ بدست آمد، بدست آمده است. همانطور که اشاره شد شبکه عصبی الکس‌نت به ازاء تقسیم‌بندی داده‌های شماره ۲ در حالت کاهش نویز با کوواریانس R =۰/۵ بهترین نتایج را داشته است.

در شکل ۹ منحنی مشخصه عملکرد سیستم به همراه محاسبه سطح زیر نمودار آن برای هر کلاس معیوب و همچنین سالم نمایش داده شده است. این نمودار، حساسیت[1] یا نرخ مثبت صحیح[2] نتایج را بر حسب متمم تشخیص‌پذیری[3] یا نرخ مثبت غلط[4] نتایج نشان می‌دهد. هر چه نمودار منحنی مشخصه عملکرد سیستم بالای خط نیم‌ساز قرار بگیرد در نتیجه

1 Sensitivity
2 True Positive Rate
3 Specificity
4 False Positive Rate

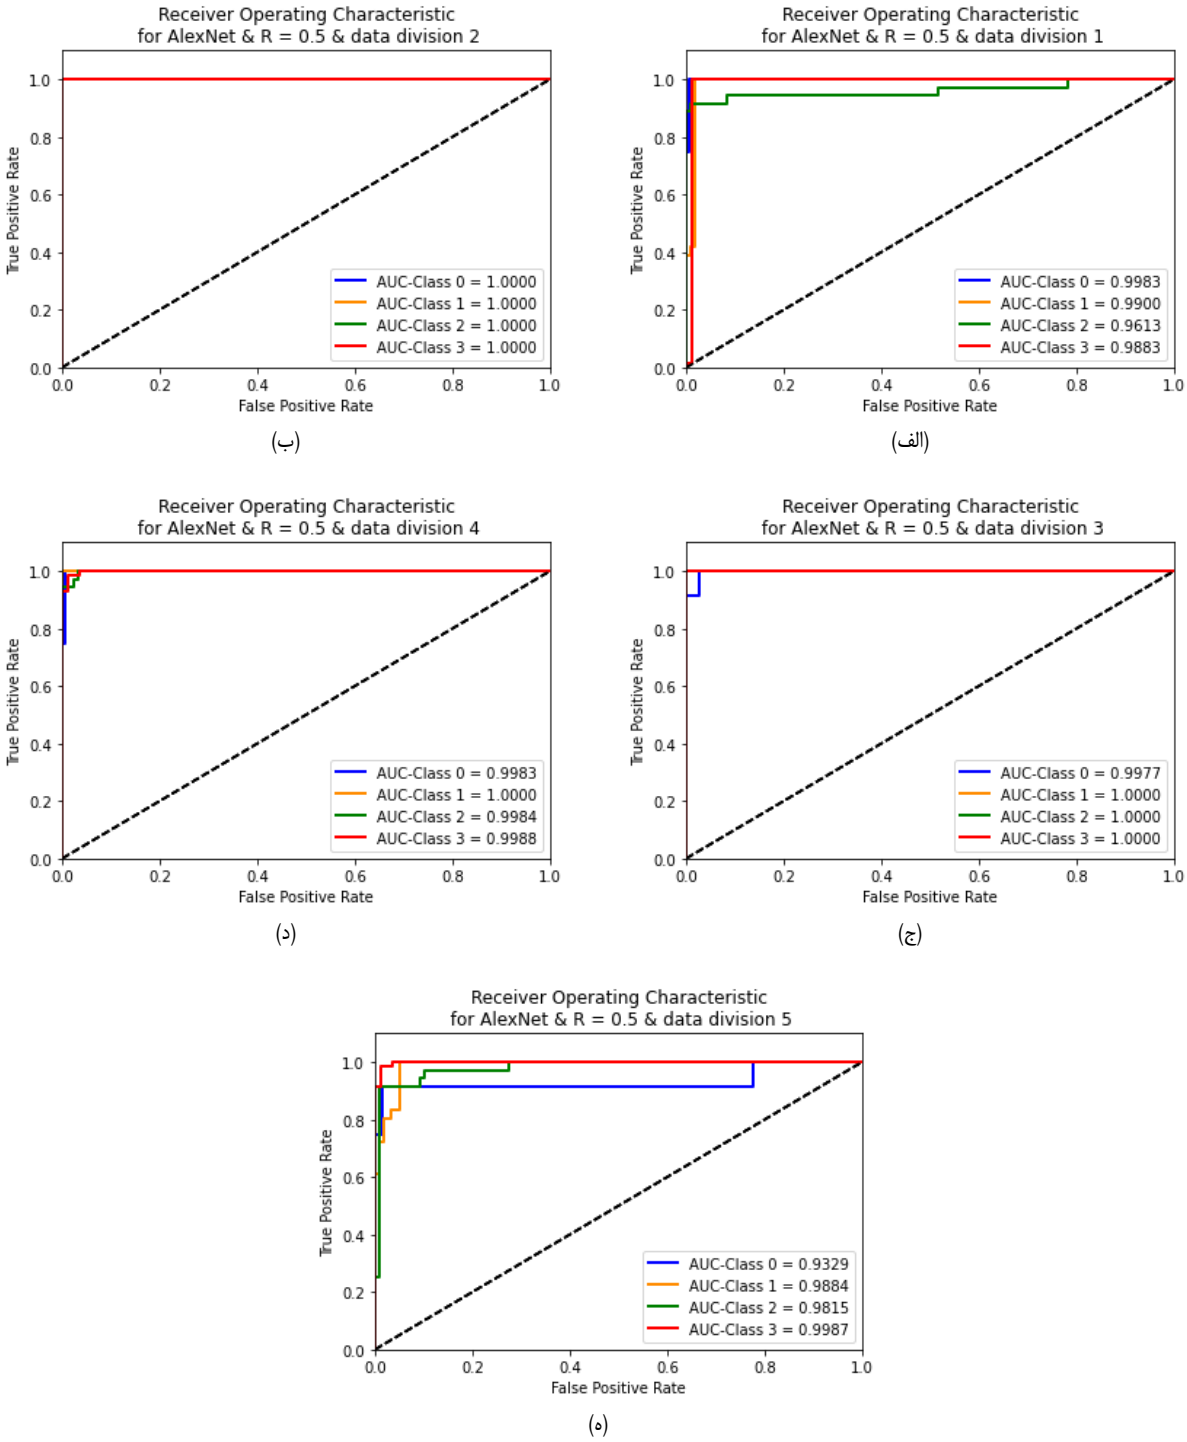

شکل ۹.منحنی مشخصه عملکرد سیستم به همراه محاسبه سطح زیر نمودار آن برای روش شبکه عصبی الکس‌نت در حالت کاهش نویز با کوواریانس R =۰/۵ در نویز اندازه‌گیری برای کل داده‌های آموزشی و ارزیابی در تقسیم‌بندی (الف) شماره ۱ (ب) شماره ۲ (ج) شماره ۳ (د) شماره ٤ (ه) شماره ٥

Fig. 9. ROC-AUC diagram for the AlexNet neural network in noise reduction mode with covariance $R = 0.5$ in the measurement noise for all training and validation data in (a) division 1, (b) division 2, (c) division 3, (d) division 4, and (e) division 5

جدول ۹. نتایج دقت آموزش شبکه عصبی الکس‌نت توسط داده‌های بدست آمده از فیلتر باترورث

Table 9. The accuracy results of the AlexNet neural network training using the data obtained from the Butterworth filter

تقسیم‌بندی داده	نوع داده	کاهش نویز با فرکانس قطع ۶۵۰ هرتز	کاهش نویز با فرکانس قطع ۷۵۰ هرتز	کاهش نویز با فرکانس قطع ۸۵۰ هرتز
۱	داده آموزش	۰/۹۲۸	۰/۹۲	۰/۹۵۲
	داده ارزیابی	۰/۹۰۳	۰/۹۳۵	۰/۹۰۳
۲	داده آموزش	۰/۹۶۸	**۰/۹۷۶**	۰/۹۷۶
	داده ارزیابی	۰/۹۶۸	**۱**	۰/۹۶۸
۳	داده آموزش	۰/۹۱۲	۰/۹۸۴	۰/۸۱۶
	داده ارزیابی	۰/۹۶۸	۰/۹۶۸	۰/۹۳۵
۴	داده آموزش	۰/۹۲	۰/۹۵۲	۰/۹۴۴
	داده ارزیابی	۰/۹۳۵	۰/۹۶۸	۰/۹۶۸
۵	داده آموزش	۰/۸۸	۰/۹۶۸	۰/۸۶۴
	داده ارزیابی	۰/۹۳۵	۰/۹۰۳	۰/۹۳۵

سطح زیر نمودار بیشتر است و در نتیجه عملکرد بهتری را شاهد خواهیم بود و اعتمادپذیری شبکه نیز بیشتر خواهد بود. در همین راستا اگر منحنی مشخصه عملکرد سیستم پایین خط نیم‌ساز قرار گیرد، عملکرد نامناسب سیستم را شاهد هستیم. با توجه به شکل ۹ بهترین جواب‌ها در تقسیم‌بندی شماره ۲ اتفاق افتاده است که به برای هر کلاس سطح زیر نمودار به مقدار ۱ رسیده است. در تقسیم‌بندی شماره ۳ و ۴ می‌توان گفت با دقت خوبی سطح زیر نمودار به ۱ رسیده است. در تقسیم‌بندی شماره ۱ و ۵ نیز برای بعضی از کلاس‌ها مقدار سطح زیر نمودار کاهش یافته است، که این مقدار ناچیز می‌باشد. در مجموع با توجه به شکل ۹ در روش استفاده از شبکه عصبی الکس‌نت در حالت کاهش نویز با کوواریانس $R = ۰/۵$ در نویز اندازه‌گیری، از اعتمادپذیری خوبی برخوردار هستیم.

با توجه به اینکه تا به اینجای کار شبکه عصبی الکس‌نت بهترین جواب‌ها را برای داده‌های نویززدایی شده توسط فیلتر کالمن را داشته است، از این شبکه عصبی برای داده‌های بدست آمده توسط فیلتر پایین‌گذر باترورث استفاده می‌شود و شبکه عصبی الکس‌نت توسط این داده‌ها آموزش داده می‌شود. نتایج بدست آمده شبکه الکس‌نت برای این داده‌ها در جدول ۹ نمایش داده شده است.

با توجه به جدول شماره ۹ می‌توان گفت شبکه عصبی الکس‌نت برای سیگنال‌های کاهش نویز یافته در فرکانس قطع ۷۵۰ هرتز توسط فیلتر باترورث بهترین جواب را داده است. در این حالت، بهترین جواب بدست آمده برای فیلتر باترورث در تقسیم بندی شماره ۳ داده‌ها اتفاق افتاده است و دقت عیب‌یابی با سیگنال‌های مربوطه برای داده‌های آموزشی ۱۰۰ درصد و برای داده‌های ارزیابی ۹۸ درصد می‌باشد. این در حالی است که بهترین دقت شبکه عصبی الکس‌نت در حالت کاهش نویز توسط فیلتر کالمن با کوواریانس اندازه‌گیری $R = ۰/۵$ مقدار دقت داده‌های آموزشی ۹۹ درصد و برای داده‌های ارزیابی ۱۰۰ درصد بوده است. در جدول ۹ میانگین دقت اندازه‌گیری برای داده‌های ارزیابی در فرکانس‌های ۶۵۰، ۷۵۰ و ۸۵۰ هرتز به ترتیب ۹۴/۲، ۹۵/۵ و ۹۴/۲ درصد می‌باشد که این مقادیر در مقایسه با میانگین داده‌های ارزیابی در روش کاهش نویز توسط فیلتر کالمن با $R = ۰/۵$ توسط شبکه عصبی الکس‌نت (جدول ۷)، کمتر می‌باشند. در مجموع با مقایسه جدول ۵ و جدول ۹ می‌توان بهبود کاهش نویز توسط فیلتر کالمن نسبت به روش‌های مرسوم کاهش نویز توسط فیلترهای پایین‌گذر را شاهد بود.

۶- جمع بندی

در این پژوهش ، هدف بررسی تاثیر کاهش نویز سیگنال توسط فیلتر کالمن برای عیب‌یابی سیستم ماشین دوار بوده است. برای این منظور از سیستم آزمایشگاهی ماشین دوار برای داده برداری استفاده شده است و در هر حالت از معیوب یا سالم بودن سیستم دو سیگنال ۱ دقیقه‌ای توسط دو سنسور ثبت شده است. این داده‌ها به عنوان داده‌های اولیه مورد استفاده قرار گرفته است. برای عیب‌یابی سیستم ابتدا داده‌ها توسط فیلتر کالمن در چند حالت نویززدایی می‌شود و در ادامه از سیگنال کاهش نویز یافته و یا سیگنال خام، ویژگی‌هایی در حوزه زمان و حوزه فرکانس استخراج می‌شود. سیگنال‌ها بعد از پیش پردازش به عنوان داده‌های آموزشی و داده‌های ارزیابی تقسیم‌بندی می‌شوند و با این داده‌ها شبکه‌های عصبی مختلف آموزش داده می‌شود. در این پژوهش از روش ماشین بردار پشتیبان و شبکه عصبی پرسپترون چند لایه و شبکه‌های عصبی پیچشی الهام و الکس‌نت استفاده می‌شود و این روش‌ها با هم مقایسه می‌شوند.

در قسمت ۵ این مقاله نتایج بدست آمده برای کلاس‌بندهای مختلف نمایش داده می‌شود. این نتایج به ازاء حالات مختلف کاهش نویز، در ۵ حالت تقسیم‌بندی داده‌ها انجام شده است. در مجموع با توجه به نتایج، عملکرد شبکه عصبی پیچشی الکس‌نت نسبت به سایر روش‌ها بهتر بوده است. در بررسی کاهش نویز سیگنال‌ها به ازاء کوواریانس اندازه‌گیری $R = ۰/۵$ بهترین نتایج حاصل شد. در نهایت نشان داده شد که شبکه عصبی پیچشی الکس‌نت نیز در کاهش نویز سیگنال با $R = ۰/۵$ نتایج بهتری داده است که ۹۶/۱ درصد رسیده است. با مقایسه میانگین نتایج برای حالات مختلف کاهش نویز در همه کلاس‌بنده، در کوواریانس اندازه‌گیری $R = ۰/۵$ به بهترین دقت یعنی ۹۵ درصد رسیده است که نسبت به حالت بدون کاهش نویز بهبود داده شده است. در نهایت روش کاهش نویز توسط فیلتر کالمن با روش فیلتر باترورث مقایسه شد و نتایج حاکی از بهبود عملکرد توسط فیلتر کالمن نشان بودند.

برای ادامه کار پیشنهاد می‌شود برای کاهش نویز سیگنال مقادیر کوواریانس Q و R در فیلتر کالمن مورد بررسی قرار گیرد. از آنجایی که سیگنال‌های واقعی که توسط حسگرها ثبت می‌شوند، دارای نویز با کوواریانس نامعلوم هستند، مقادیر کوواریانس Q و R را نمی‌توان به صورت دقیق مشخص کرد. این مقادیر می‌توانند توسط روش‌های بهینه‌سازی بدست آیند.

۷- فهرست علائم

A	ماتریس انتقال حالت
B	ماتریس کنترل
H	ماتریس اندازه‌گیری
u	ورودی کنترلی
$e(m)$	تحریک نامرتبط در ورودی در لحظه m
$n(m)$	نویز در اندازه‌گیری در لحظه m
R	واریانس نویز سیگنال اندازه‌گیری
Q	واریانس نویز سیگنال تحریک در ورودی
$x(n)$	سیگنال در حوزه زمان در لحظه n
F_i	ویژگی iم سیگنال
$S(k)$	اندازه طیف سیگنال در به ازاء kمین داده طیف
f_k	اندازه فرکانس به ازاء kمین داده طیف

منابع

[1] R.F. Ribeiro Junior, I.A. dos Santos Areias, M.M. Campos, C.E. Teixeira, L.E.B. da Silva, G.F. Gomes, Fault detection and diagnosis in electric motors using convolution neural network and short-time fourier transform, Journal of Vibration Engineering & Technologies, (2022) 1-12.

[2] M. Zakizadeh, A. Jamali, M. Rafeeyan, A. Chaibakhsh, Monitoring and Troubleshooting Alstom Locomotive Blowers using Vibration Analysis and Support Vector Machine, Amirkabir Journal of Science & Research (Mechanical Engineering), 54(8) (2022) 1833-1850 (in Persian).

[3] V.H. Farahani, Applying the envelope curve of vibration signals in condition monitoring and rolling bearings fault detection, Journal of Vibration & Sound, 2(3) (2013) 11-20 (in Persian).

[4] M. Shekarzadeh, M. Sadegh Alayy, Centrifugal pump bearings Fault diagnosis using the combination of independent component analysis methods and particle swarm optimization, Journal of New Applied and

Computational Findings in Mechanical Systems, 3(1) (2023) 53-61 (in Persian).

[5] M. Kamari, G. Payeganeh, K.N. Khajavi, Implementation of Neuro– Fuzzy and Multi-Layer Perceptron System Intelligent Techniques for Main Fault Diagnosis of Rotating Machinery, Amirkabir Journal of Science & Research (Mechanical Engineering), 45(2) (2013) 105-118 (in Persian).

[6] M.A. Sattari, G.H. Roshani, R. Hanus, E. Nazemi, Applicability of time-domain feature extraction methods and artificial intelligence in two-phase flow meters based on gamma-ray absorption technique, Measurement, 168 (2021) 108474.

[7] X. Wang, D. Mao, X. Li, Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network, Measurement, 173 (2021) 108518.

[8] R.-P. Nikula, K. Karioja, M. Pylvänäinen, K. Leiviskä, Automation of low-speed bearing fault diagnosis based on autocorrelation of time domain features, Mechanical Systems and Signal Processing, 138 (2020) 106572.

[9] A. Kafeel, S. Aziz, M. Awais, M.A. Khan, K. Afaq, S.A. Idris, H. Alshazly, S.M. Mostafa, An Expert System for Rotating Machine Fault Detection Using Vibration Signal Analysis, Sensors, 21(22) (2021) 7587.

[10] S. Nezamivand Chegini, Z. Karimi Rastehkenari, A. Bagheri, B. Ahmadi, Denoising vibration signals of rotating machines using probability density function, similarity measure and improved thresholding function, Amirkabir Journal of Science & Research (Mechanical Engineering), 53(Number 4 (Special Issue)) (2021) 2493-2512 (in Persian).

[11] S. Nezamivand Chegini, F. Zarif, A. Bagheri, A. Tavoli, Vibration signals denoise of rotating machines using experimental wavelet transform and common thresholding methods, Journal of Solid and Fluid Mechanics, 9(1) (2019) 111-124 (in Persian).

[12] V. Gupta, M. Mittal, Arrhythmia detection in ECG signal using fractional wavelet transform with principal component analysis, Journal of The Institution of Engineers (India): Series B, 101(5) (2020) 451-461.

[13] H. Ehya, A. Nysveen, T.N. Skreien, Performance evaluation of signal processing tools used for fault detection of hydrogenerators operating in noisy environments, IEEE Transactions on Industry Applications, 57(4) (2021) 3654-3665.

[14] Y. Gao, Y. Gao, B. Liu, Y. Jiang, Enhanced fault detection and exclusion based on Kalman filter with colored measurement noise and application to RTK, GPS Solutions, 25 (2021) 1-13.

[15] S. Mokhtari, K.K. Yen, A novel bilateral fuzzy adaptive unscented kalman filter and its implementation to nonlinear systems with additive noise, in: 2020 IEEE Industry Applications Society Annual Meeting, IEEE, 2020, pp. 1-6.

[16] P. Talwar, K. Cecil, Adaptive Filter and EMD Based De-Noising Method of ECG Signals: A Review, American Journal of Multidisciplinary Research & Development (AJMRD), 5(03) (2023) 09-14.

[17] F. Honarmand-Shazilehei, N. Pariz, M.B.N. Sistani, Sensor fault detection in a class of nonlinear systems using modal Kalman filter, ISA transactions, 107 (2020) 214-223.

[18] S. Cho, M. Choi, Z. Gao, T. Moan, Fault detection and diagnosis of a blade pitch system in a floating wind turbine based on Kalman filters and artificial neural networks, Renewable Energy, 169 (2021) 1-13.

[19] Y. Yao, J. Wang, M. Xie, Adaptive residual CNN-based fault detection and diagnosis system of small modular reactors, Applied Soft Computing, 114 (2022) 108064.

[20] M. Yakoubi, R. Hamdi, M.B. Salah, EEG enhancement using extended Kalman filter to train multi-layer perceptron, Biomedical Engineering: Applications, Basis and Communications, 31(01) (2019) 1950005.

[21] M. Singh, A.G. Shaik, Incipient fault detection in stator windings of an induction motor using stockwell transform and SVM, IEEE Transactions on Instrumentation and Measurement, 69(12) (2020) 9496-9504.

[22] S. Chatterjee, R.K. Gatla, P. Sinha, C. Jena, S. Kundu,

B. Panda, L. Nanda, A. Pradhan, Fault detection of a Li-ion battery using SVM based machine learning and unscented Kalman filter, Materials Today: Proceedings, 74 (2023) 703-707.

[23] Z. Zemali, L. Cherroun, N. Hadroug, A. Hafaifa, A. Iratni, O.S. Alshammari, I. Colak, Robust intelligent fault diagnosis strategy using Kalman observers and neuro-fuzzy systems for a wind turbine benchmark, Renewable Energy, 205 (2023) 873-898.

[24] M. Khodarahmi, V. Maihami, A review on Kalman filter models, Archives of Computational Methods in Engineering, 30(1) (2023) 727-747.

[25] R.I. Alfian, A. Ma'arif, S. Sunardi, Noise reduction in the accelerometer and gyroscope sensor with the Kalman filter algorithm, Journal of Robotics and Control (JRC), 2(3) (2021) 180-189.

[26] F. Li, Z. Luo, K. Bai, M. Yin, D. Zou, W. Wang, X. Wang, W. Tan, Q. Sui, Z. Li, Noise shaping enhanced DMT signal transmission utilizing low-resolution DAC, IEEE Photonics Journal, 13(6) (2021) 1-7.

[27] S.K. Mishra, M. Gupta, D.K. Upadhyay, Active realization of fractional order Butterworth lowpass filter using DVCC, Journal of King Saud University-Engineering Sciences, 32(2) (2020) 158-165.

[28] I.M. Khairuddin, S.N. Sidek, A.P.A. Majeed, M.A.M. Razman, A.A. Puzi, H.M. Yusof, The classification of movement intention through machine learning models: the identification of significant time-domain EMG features, PeerJ Computer Science, 7 (2021) e379.

[29] K. Zhang, J. Chen, T. Zhang, Z. Zhou, A compact convolutional neural network augmented with multiscale feature extraction of acquired monitoring data for mechanical intelligent fault diagnosis, Journal of Manufacturing Systems, 55 (2020) 273-284.

[30] J.J. Saucedo-Dorantes, A.Y. Jaen-Cuellar, M. Delgado-Prieto, R. de Jesus Romero-Troncoso, R.A. Osornio-Rios, Condition monitoring strategy based on an optimized selection of high-dimensional set of hybrid features to diagnose and detect multiple and combined faults in an induction motor, Measurement, 178 (2021) 109404.

[31] A.F. Khalil, S. Rostam, Machine Learning-based Predictive Maintenance for Fault Detection in Rotating Machinery: A Case Study, Engineering, Technology & Applied Science Research, 14(2) (2024) 13181-13189.

چگونه به این مقاله ارجاع دهیم

H. Pourhashem, A. jamali , N. Nariman-zade, A. Chaibakhsh, Investigating Noise Reduction in Signal Analysis in Rotary Machines Fault Diagnosing by Neural Network, Amirkabir J. Mech Eng., 55(12) (2024) 1423-1442.

DOI: 10.22060/mej.2024.22469.7629