



## Real-time fault-tolerant controller of induction motors using optimized CNN-LSTM deep neural network based on vibration-acoustic data and proposed control algorithm

Abdolah Safari dehnavi<sup>\*1</sup> , Vahid Safari dehnavi<sup>2</sup>

1. Instructor, Department of Agriculture Engineering, Technical and Vocational University (TVU), Tehran, Iran
2. Ph.D. Student, Department of Electrical Engineering, Amirkabir University of Technology (Tehran Polytechnic), Tehran, Iran

### Abstract

Predictive maintenance and speed control of rotating machines are crucial in modern industries due to the reduction of maintenance costs and the improvement of efficiency and reliability. This paper presents a method for fault diagnosis and speed control of induction motors. The proposed method employs two algorithms for fault diagnosis. In the first algorithm, a novel method for extracting statistical, frequency, and energy features is utilized, along with machine learning algorithms for fault classification. If the fault detection accuracy of the first algorithm is not suitable, the second algorithm is used. This algorithm utilizes a convolutional neural network (CNN) and an optimized long short-term memory (LSTM) model. In this network, feature extraction and selection are performed automatically. We present a new algorithm for optimizing layers and parameters through an adaptive ant colony algorithm and likelihood functions. The proposed methods are tested on three datasets. In the first dataset collected for this research, the focus is on the healthy state, bearing fault, and uncoupled condition. In the second dataset, we focus on the defects of the inner and outer rings of the bearing. In the third dataset, eight cases are considered, including seven cases with defects in the stator and rotor, and one healthy case. Vibration and acoustic data are used for fault diagnosis. Then, a control algorithm, including a fractional-order optimal control controller, is presented to control the motor speed, especially when it is under fault conditions. The results indicate that the first algorithm is suitable for the first and second datasets, while the second algorithm is more suitable for the third dataset.

### Keywords

Preventive Maintenance  
Speed Control  
Machine Learning  
Deep Neural Network  
Vibration and Acoustic Data

Received: 11.07.2025

Revised: 19.08.2025

Accepted: 22.09.2025

### \*Corresponding Author

Abdolah Safari dehnavi

Email

[asafari@tvu.ac.ir](mailto:asafari@tvu.ac.ir)

## 1- Introduction

Motors are essential and functional components in various industries, including manufacturing, agriculture, and power systems. According to the World Energy Organization, in 2016, more than 50 percent of the world's electrical energy consumption was accounted for by motors. Despite improvements in motor efficiency, this percentage is expected to increase by 2040. Additionally, according to IEEE Standard 493, the average failure

rate of motors with a voltage of less than 1000 V is 8.24%. In the event of a motor failure, the time required to shut down and replace the motor is 42 to 75 hours [1]. In a survey of 75 factories, these factories had 100,114 motors, with an average of 1521 motors per factory [1]. According to the Niroo Research Institute, approximately 2 million motors are used in the Iranian industry, and around 60 million motors are used in the domestic sector.

### How to Cite this Article:

[1] A. Safari Dehnavi and V. Safari Dehnavi, "Real-time fault-tolerant controller of induction motors using optimized CNN-LSTM deep neural network based on vibration-acoustic data and proposed control algorithm," *Journal of Science and Technology in Mechanical Engineering*, Vol. 4, No. 2, pp. 113–138, 2026. [Online]. Available: <https://doi.org/10.22034/stme.2025.533639.1144> (in Persian)



Given the high price of motors, diagnosing motor faults is of great importance.

Due to their extensive use, motors are constantly exposed to various mechanical and electrical stresses that can lead to faults. These faults can arise from inherent problems or adverse operating conditions, leading to motor failure. As a result, if the fault is not detected in time, it will lead to further breakdowns and losses in the entire system. To improve performance, the issues of motor fault diagnosis and speed control have garnered the attention of experts and researchers in recent years [1, 2]. The importance of effective fault diagnosis and condition monitoring of motors cannot be overstated, as they play a vital role in minimizing damage, extending the device's life, increasing its availability, and reducing maintenance time and costs. Fault detection is important in preventing unexpected failures and preventing severe damage to the entire drive system. Condition monitoring of motors increases reliability and reduces maintenance costs [3]. The implementation cost is about \$200, considering the combination of modular software and hardware. Considering the cost of low-power industrial motors, which range from \$150 to \$200, it is cost-effective to diagnose and repair motors before they fail.

Additionally, this cost savings is further increased by reducing downtime in the event of a motor failure. Various components of a motor are susceptible to damage, and several factors, including overload, unbalanced loads, and mechanical stresses, can contribute to these conditions. As shown in Figure 1, motor failures are typically categorized into four main types: bearing failures, stator failures, rotor failures, and other types of failures [4]. Bearing problems are the most common type of failure among various types [5]. Studies conducted by General Electric and IEEE-IGA have shown that bearing failures are the leading cause of motor failure, highlighting the critical role of bearing failure detection in the monitoring of rotating machinery.

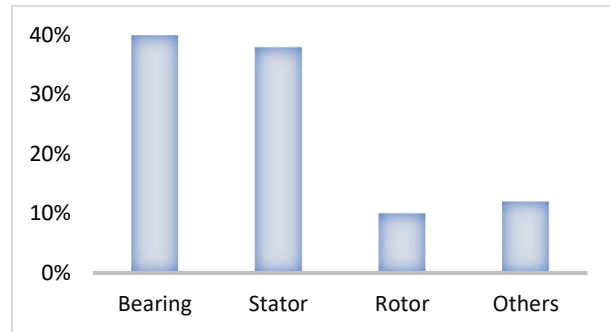


Figure 1: Percentage of motor faults.

## 2- Research Methods

This section introduces the proposed method for fault detection and speed control of motors. In this paper, we use three datasets with two different algorithms. In the first algorithm, we utilize feature extraction based on statistical, frequency, and energy features, along with automatic feature selection. In the second algorithm, we use automatic feature extraction. In this method, the dataset is first obtained, and then the channel selection process is performed. In this case, based on the type of faults, we select the appropriate data for the existing hardware equipment, ensuring that the detection accuracy is optimal and the detection is performed at the lowest cost.

The dataset collected in this study includes temperature, motor current, vibration, and acoustic signals. Then, we use vibration and acoustic data according to the faults, which in this study focus on mechanical faults. After that, we perform preprocessing, including notch filtering and wavelet transform. Then the window selection process is performed, and the segmented data is fed into the first algorithm. If the accuracy is not suitable, the second algorithm and the optimized deep neural network are used. The structure of the layers and parameters of this network are optimally determined using the adapted ant colony algorithm. Finally, the designed controller controls the motor's speed. For speed control, we used PWM and SPWM. In this case, two PID controllers and one optimal controller are used. In the initial stage, according to the principle of simplicity, the PID controller is used. Suppose the PID controller cannot control the speed correctly. In this case, a fractional-order optimal

controller is used to achieve the desired speed, which can be achieved by adjusting the adjustable voltage and current parameters. In the next stage, if a fault occurs in the motor, the second PID controller enters the control algorithm and tries to control the speed using the simplest controller.

### 3- Results

In datasets with low fault detection complexity, the first algorithm, which incorporates feature extraction and feature selection through classification using machine learning algorithms, yields good results. The first and second datasets were classified using the first algorithm; the execution time for this algorithm on one instance is less than 30 milliseconds. Initially, all features were used with the feature selection algorithm. In the next step, the number of features was reduced to two using the PCA method, and the results were satisfactory. Further reduction of features led to a sharp decrease in accuracy. In the third dataset, the complexity of fault detection is higher. The data were classified into two states: with and without load, at four different speeds, and in eight states, including one healthy state and seven faulty states. Machine learning algorithms were not suitable in this case, so a deep neural network was used instead. The classification result using the first vibration sensor was the best. The result is better if a combination of vibration and acoustic sensors is used. The results for fault detection based on the deep neural network are shown in Figure 2.

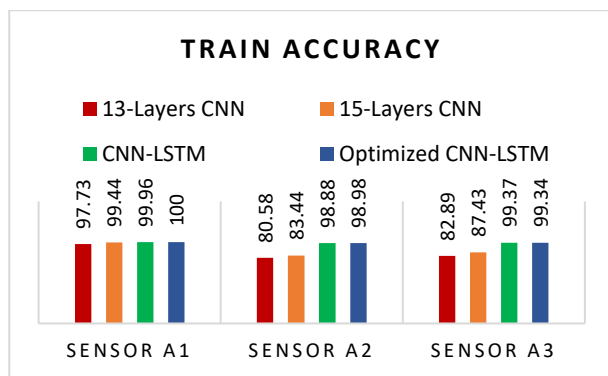


Figure 2: Comparison of deep neural networks

### 4- Conclusion

This paper presents a hybrid approach for fault detection and speed control of induction motors under different operating conditions. The results showed that the first classification algorithm, which uses feature extraction, feature selection, and machine learning algorithms, performs well on low-complexity datasets. The algorithm was trained on two datasets: the first contained two faults and one healthy state, and the second contained six faults and one healthy state. It reached the desired accuracy in a shorter time (average 2 seconds). However, the second algorithm, which utilizes CNN and LSTM deep neural networks, performed better on higher-complexity datasets that contain different loads and speeds. Optimizing the network structure and parameters using the adaptive ant colony algorithm significantly improved both detection accuracy and processing time.

Additionally, the combined use of vibration and acoustic data yielded higher fault detection accuracy. Additionally, the PID controller and the fractional-order optimal controller provided effective control over the motor speed under fault conditions. They were able to control the speed when a fault occurred effectively. The proposed method enhances the reliability of rotating systems, such as motors, reduces maintenance costs, and improves safety. As a result, this method can be used as an effective solution in the industry to improve the performance and safety of rotating machines.

### 5- References

- [1] V. S. Dehnavi and M. Shafiee, "Fault diagnosis of induction motors using novel measurement techniques and data fusion," *Measurement*, Vol. 256, Art. No. 118135, 2025, doi: [10.1016/j.measurement.2025.118135](https://doi.org/10.1016/j.measurement.2025.118135).
- [2] K. S. Krishna Veni and N. S. Kumar, "Diagnosis of bearing fault in induction motor using Bayesian optimization-based ensemble classifier," *Electrical Engineering*, Vol. 106, pp. 1895–1905, 2023, doi: [10.1007/s00202-023-02040-w](https://doi.org/10.1007/s00202-023-02040-w).

---

[3] A. Almounajjed, A. K. Sahoo, and M. K. Kumar, "Condition monitoring and fault detection of induction motor based on wavelet denoising with ensemble learning," *Electrical Engineering*, Vol. 104, pp. 2859–2877, 2022, doi: [10.1007/s00202-022-01523-6](https://doi.org/10.1007/s00202-022-01523-6).

[4] O. AlShorman *et al.*, "Sounds and acoustic emission-based early fault diagnosis of induction motor: A review study," *Advances in Mechanical*

*Engineering*, Vol. 13, Art. No. 168781402199691, 2021, doi: [10.1177/1687814021996915](https://doi.org/10.1177/1687814021996915).

[5] V. S. Dehnavi and M. Shafiee, "Inner and outer bearing fault diagnosis of electrical motors using a proposed algorithm and vibration signals," in *Proc. 14th Int. Conf. Information and Knowledge Technology (IKT)*, 2023, pp. 175–180, doi: [10.1109/IKT62039.2023.10433018](https://doi.org/10.1109/IKT62039.2023.10433018)



## کنترل کننده تحمل پذیر عیب بلادرنگ موتورهای القایی با استفاده از شبکه عصبی عمیق CNN-LSTM بهینه شده مبتنی بر داده‌های ارتعاش-آکوستیک و الگوریتم کنترل پیشنهادی

عبداله صفری دهنوی<sup>۱</sup>، وحید صفری دهنوی<sup>۲</sup>

۱- مربی، گروه مهندسی کشاورزی، دانشگاه ملی مهارت، تهران، ایران

۲- دانشجوی دکتری، گروه مهندسی برق کنترل، دانشگاه صنعتی امیرکبیر، تهران، ایران

### چکیده

تعمیرات پیشگیرانه و کنترل سرعت ماشین‌های دوار به دلیل کاهش هزینه‌های نگهداری، بهبود کارایی و قابلیت اطمینان در صنایع مدرن حیاتی هستند. این مقاله روشی برای تشخیص عیب و کنترل سرعت موتورهای القایی ارائه می‌دهد. روش پیشنهادی از دو الگوریتم برای تشخیص عیب استفاده می‌کند: در الگوریتم اول، از یک روش نوین برای استخراج ویژگی‌های آماری، فرکانسی و انرژی و همچنین از الگوریتم‌های یادگیری ماشین برای کلاس‌بندی عیب استفاده می‌شود. اگر دقت تشخیص عیب الگوریتم اول مناسب نباشد، از الگوریتم دوم استفاده می‌شود. این الگوریتم از شبکه عصبی کانولوشنی (CNN) و حافظه کوتاه‌مدت بلند (LSTM) بهینه شده استفاده می‌کند. در این شبکه، استخراج و انتخاب ویژگی به‌طور خودکار انجام می‌شود. ما یک الگوریتم جدید برای بهینه‌سازی لایه‌ها و پارامترها از طریق الگوریتم تطبیق یافته کلونی مورچگان و توابع احتمال ارائه دادیم. روش‌های پیشنهادی روی سه مجموعه داده آزمایش شده‌اند. در مجموعه داده اول که در این پژوهش جمع‌آوری شده است، تمرکز بر حالت سالم، عیب یاتاقان و عدم کوپل صحیح هست. در مجموعه داده دوم، بر روی عیوب حلقه‌های داخلی و خارجی یاتاقان تمرکز می‌کنیم. در مجموعه داده سوم، هشت حالت شامل هفت عیب موجود در استاتور و روتور و یک حالت سالم، در نظر گرفته شده است و از داده‌های ارتعاش و آکوستیک برای تشخیص عیب استفاده شده است. سپس، یک الگوریتم کنترلی، شامل یک کنترل کننده کنترل بهینه مرتبه کسری برای کنترل سرعت موتور به‌ویژه هنگامی که تحت عیب است، ارائه می‌شود. نتایج نشان می‌دهد که الگوریتم اول برای مجموعه داده اول و دوم و الگوریتم دوم برای مجموعه داده سوم مناسب بود.

### کلمات کلیدی

تعمیرات پیشگیرانه  
کنترل سرعت  
یادگیری ماشین  
شبکه عصبی عمیق  
داده‌های ارتعاش و آکوستیک

دریافت مقاله: ۱۴۰۴/۰۴/۲۰

بازنگری مقاله: ۱۴۰۴/۰۵/۲۸

پذیرش مقاله: ۱۴۰۴/۰۶/۳۱

\*نویسنده مسئول

عبداله صفری دهنوی

ایمیل

[asafari@nus.ac.ir](mailto:asafari@nus.ac.ir)

### ۱- مقدمه

خاموشی و جایگزینی موتور هست [۱]. در بررسی ۷۵ کارخانه، این کارخانه‌ها دارای ۱۱۴,۱۰۰ موتور بودند که به‌صورت متوسط هر کارخانه ۱۵۲۱ موتور داشت [۱]. مطابق اعلام پژوهشگاه نیرو، در صنعت ایران حدود ۲ میلیون موتور مورد استفاده قرار می‌گیرند و در بخش خانگی حدود ۶۰ میلیون موتور مورد استفاده قرار گرفته است. با توجه به قیمت بالای موتورها، تشخیص عیب موتورها اهمیت بالایی دارد. به دلیل کاربرد گسترده، موتورها دائماً در معرض تنش‌های


موتورها اجزای اساسی و کاربردی در صنایع تولیدی، کشاورزی و سیستم‌های قدرت هستند. مطابق اعلام سازمان انرژی جهان در سال ۲۰۱۶، بیش از ۵۰ درصد مصرف انرژی الکتریکی جهان متعلق به موتورها هست و علیرغم بهبود بهره‌وری موتورها تا سال ۲۰۴۰ این درصد افزایش خواهد یافت. همچنین مطابق استاندارد ۴۹۳ IEEE، به‌صورت متوسط نرخ خرابی موتورهای با ولتاژ کمتر از ۱۰۰۰ ولت برابر با ۸/۲۴٪ هست و در صورت خرابی موتور، ۴۲ تا ۷۵ ساعت زمان

### How to Cite this Article:

[1] A. Safari Dehnavi and V. Safari Dehnavi, "Real-time fault-tolerant controller of induction motors using optimized CNN-LSTM deep neural network based on vibration-acoustic data and proposed control algorithm," *Journal of Science and Technology in Mechanical Engineering*, Vol. 4, No. 2, pp. 113-138, 2026. [Online]. Available: <https://doi.org/10.22034/stme.2025.533639.1144> (in Persian)



مختلف عیوب هستند [۵]. مطالعات انجام شده توسط شرکت جنرال الکتریک و IEEE-IGA نشان داده است که عیوب یاتاقان علت اصلی خرابی موتور هستند و این امر نقش حیاتی تشخیص عیب یاتاقان را در نظارت بر ماشین آلات دوار برجسته می‌کند.



شکل ۱: درصد عیوب موتور

#### ۱-۱- مرور پیشینه

این بخش، پیشینه پژوهش را در سه بخش ارائه می‌دهد. ابتدا، مؤثرترین داده‌ها برای تشخیص عیوب مکانیکی و الکتریکی بررسی می‌شوند. مطالعات قبلی از دما، سیگنال‌های الکتریکی، شار، ارتعاش و سیگنال‌های آکوستیک برای تشخیص عیوب موتورها استفاده کرده‌اند. جدول ۱ داده‌های مناسب برای تشخیص هر نوع عیب و مزایا و معایب هر روش را برای انتخاب بهترین روش برای تشخیص هر نوع عیب مقایسه می‌کند. سپس روش‌های پردازش سیگنال زمانی، فرکانسی و زمانی-فرکانسی ارائه می‌شود. در نهایت، الگوریتم‌های کلاس‌بندی را معرفی می‌کنیم. این بخش الگوریتم‌های یادگیری ماشین و شبکه‌های عصبی عمیق را معرفی می‌کند که اخیراً در کاربردهای تشخیص عیب استفاده شده‌اند.

مکانیکی و الکتریکی مختلفی قرار دارند که می‌تواند منجر به عیب شود. این عیوب می‌توانند از مشکلات ذاتی یا شرایط عملیاتی نامطلوب ناشی شوند و به خرابی موتور منجر شوند. در نتیجه، اگر عیب به موقع تشخیص داده نشود، عیب ایجاد شده منجر به خرابی و تلفات بیشتر در کل سیستم می‌شود. برای بهبود عملکرد، موضوعات تشخیص عیب موتور و کنترل سرعت در سال‌های اخیر توجه متخصصان و محققان را به خود جلب کرده است [۲ و ۱]. اهمیت تشخیص مؤثر عیب و پایش وضعیت موتورها را نمی‌توان نادیده گرفت، زیرا آن‌ها نقش حیاتی در به حداقل رساندن آسیب، افزایش عمر دستگاه، افزایش در دسترس بودن دستگاه و کاهش زمان و هزینه‌های نگهداری دارند. تشخیص عیوب در جلوگیری از خرابی‌های غیرمنتظره و جلوگیری از آسیب شدید به کل سیستم درایو مهم است. پایش وضعیت موتورها، قابلیت اطمینان را افزایش داده و هزینه‌های نگهداری را کاهش می‌دهد [۳]. هزینه پیاده‌سازی با توجه به ترکیب نرم‌افزار و سخت‌افزار ماژولار برابر با ۲۰۰ دلار هست؛ با توجه قیمت موتورهای توان پایین صنعتی که حدود ۱۵۰ تا ۲۰۰ دلار هست، تشخیص عیب و اصلاح موتورها قبل از خرابی آن‌ها صرفه اقتصادی دارد؛ به علاوه این صرفه‌جویی با کاهش زمان خاموشی در حالتی که موتور دچار عیب شود، بیشتر می‌شود. اجزای مختلف یک موتور مستعد آسیب هستند و عوامل مختلفی از جمله اضافه بار، بارهای نامتعادل و تنش‌های مکانیکی باعث ایجاد این شرایط می‌شوند.

همان‌طور که در شکل ۱ نشان داده شده است، عیوب موتور معمولاً به عیوب یاتاقان، عیوب استاتور، عیوب روتور و برخی عیوب دیگر تقسیم می‌شوند [۴]. مشکلات یاتاقان رایج‌ترین نوع در بین انواع

جدول ۱: داده‌های مورداستفاده برای تشخیص عیب

نوع داده‌های موتور	مناسب‌ترین عیوب قابل تشخیص	مزایا	معایب
تحلیل دما با حسگرهای ترموکوپل	الکتریکی	- استفاده آسان برای اندازه‌گیری دمای بدنه موتور - نرخ نمونه‌برداری پایین	- تشخیص زمانی که عیب گسترش یافته است - پیاده‌سازی دشوار برای هسته آهنی در کاربردهای صنعتی
دما با تصاویر حرارتی [۶]	الکتریکی	- استفاده آسان	- حسگر گران قیمت - تشخیص عیب تنها در مراحلی که عیب پیشرفت داشته است
تحلیل الکتریکی (جریان و ولتاژ) [۷]	مکانیکی و الکتریکی	- کم‌هزینه (با استفاده از داده‌بردارهای فرکانس متوسط) - نصب ساده	- اثر بخشی محدود در تشخیص برخی عیوب مکانیکی مانند ناهم‌راستایی یا سایش تدریجی، به ویژه آن‌هایی که تأثیر کمی بر سیگنال‌های الکتریکی مانند جریان یا ولتاژ دارند
شار پراکنده [۸]	مکانیکی و الکتریکی	- غیرتهاجمی - کم‌هزینه	- وابستگی به نویز
ارتعاش [۹]	مکانیکی و الکتریکی	- وابستگی کم به نویز - تشخیص زود هنگام عیب	- داده‌بردارهای گران قیمت
آکوستیک [۱۰]	مکانیکی و الکتریکی	- تشخیص زود هنگام عیب	- وابستگی به نویز

شبکه‌های عصبی کانولوشنی دوبعدی: این مدل‌ها معمولاً برای داده‌های تصویری استفاده می‌شوند، اما با تبدیل داده‌های ارتعاش و آکوستیک به داده‌های دوبعدی، برای تشخیص عیب موتور نیز تطبیق داده شده‌اند. آن‌ها همچنین برای تشخیص عیب بر اساس تصاویر دمایی نیز استفاده می‌شوند. این شبکه‌ها ویژگی‌ها را از این تصاویر برای کلاس‌بندی عیب‌ها استخراج می‌کنند. بر اساس مطالعات ارائه‌شده، این شبکه‌ها دقت مناسبی از ۸۸/۳٪ تا ۹۹/۹٪ را در تشخیص انواع مختلف عیب موتورها نشان داده‌اند [۲۱-۲۳]. یکی از محدودیت‌های این شبکه‌ها ساختارهای پیچیده و نیاز به محاسبات زمان‌بر هست.

شبکه‌های عصبی کانولوشنی یک‌بعدی: این مدل‌ها برای پردازش سیگنال‌های یک‌بعدی طراحی شده‌اند. آن‌ها معمولاً از نظر محاسباتی ساده‌تر از شبکه‌های عصبی کانولوشنی دوبعدی هستند و همین امر آن‌ها را برای مجموعه داده‌های بزرگ مناسب می‌کند. این شبکه‌ها با تجزیه و تحلیل سیگنال‌های ارتعاش از چندین حسگر یا محورهای مختلف داده‌های شتاب‌سنج، با موفقیت در تشخیص عیب موتورها مورد استفاده قرار گرفته‌اند [۲۴-۲۶]. تعیین لایه‌ها و پارامترهای این شبکه‌ها بسیار مهم است و در برخی از مجموعه داده برای استفاده در سری‌های زمانی به اندازه کافی دقیق نیستند.

شبکه‌های عصبی بازگشتی و LSTM: این مدل‌ها به‌طور خاص برای تعیین همبستگی در داده‌های متوالی طراحی شده‌اند. آن‌ها شامل مکانیسم‌های مناسبی برای مدیریت مؤثر وابستگی‌های بلندمدت در داده‌ها هستند. این شبکه‌ها همچنین برای تشخیص عیب موتورها استفاده می‌شوند و در کاربردهای مختلف، از جمله تشخیص عیب با استفاده از داده‌های ارتعاش و تصاویر حرارتی به دقتی از ۸۸٪ تا ۱۰۰٪ دست می‌یابند [۲۷-۲۹].

جدول ۲ مقایسه‌ای از روش‌های ارائه‌شده در مقاله‌ها برای تشخیص عیب و مزایا و معایب آن‌ها را ارائه می‌دهد. همان‌طور که در جدول ۲ نشان داده شده است، ساختار برخی از شبکه‌ها به‌صورت تجربی یا بر اساس تجربه متخصصان انسانی به دست آمده است و ارائه روشی که بتواند به یافتن خودکار ساختار مناسب برای هر مسئله استفاده شود، مفید است.

سیگنال‌های الکتریکی برای تشخیص عیوب الکتریکی و مکانیکی مورد استفاده قرار گرفته‌اند، منتها غالباً اثربخشی آن‌ها برای تشخیص عیوب الکتریکی و برخی از عیوب مکانیکی خاص نشان داده شده است [۱۱]؛ از جمله عیوبی که به‌صورت مؤثر با استفاده از سیگنال جریان قابل تشخیص هستند، می‌توان به عیوب اتصال کوتاه، عیب میله شکسته روتور و عیوب عایقی اشاره کرد [۱۲]. سیگنال‌های تولیدشده توسط حسگرهای دما، ارتعاش و آکوستیک را می‌توان به‌عنوان داده‌های سری زمانی در نظر گرفت. تکنیک‌های مختلف حوزه زمان، فرکانس و زمان-فرکانس معمولاً برای استخراج ویژگی‌ها از این سیگنال‌ها استفاده می‌شوند. در حوزه زمان، روش‌های استخراج ویژگی مانند محاسبات جذر میانگین مربعات و رویکردهای آماری استفاده می‌شوند [۱۳]. تکنیک‌های دامنه و تحلیل طیفی در حوزه فرکانس مورد استفاده قرار می‌گیرند [۱۴]. روش‌های حوزه زمان-فرکانس، مانند تبدیل موجک، تبدیل فوریه زمان کوتاه و تبدیل هیلبرت نیز به‌طور گسترده مورد استفاده قرار می‌گیرند [۱۵]. تحلیل حوزه زمان روشی ساده برای ارزیابی سلامت موتور ارائه می‌دهد و آن را به روشی در دسترس تبدیل می‌کند. از سوی دیگر، تکنیک‌های حوزه فرکانس می‌توانند فرکانس‌های خاص عیب را به دلیل عدم حساسیت ذاتی به نویز، بدون نیاز به دانش قبلی از ویژگی‌های عیب، از نویز جدا کنند [۱۶]. با این حال، تحلیل حوزه فرکانس برای سیگنال‌های غیرایستا که معمولاً در عمل با آن‌ها مواجه می‌شویم، مناسب نیست. این محدودیت توسط تحلیل زمان-فرکانس برطرف می‌شود که به‌طور مؤثر سیگنال‌های ایستا و غیرایستا را مدیریت می‌کند و آن را به‌طور فزاینده‌ای محبوب می‌کند [۱۷]؛ بنابراین، این پژوهش از تحلیل‌های حوزه زمان و زمان-فرکانس استفاده می‌کند. در [۱۸] یک ساختار رهبر-پیرو برای جمع‌آوری داده‌های بیولوژیکی استفاده می‌شود، در این مقاله با توسعه ایده ساختار ارائه‌شده به جمع‌آوری داده‌های چند سنسوری می‌پردازد.

الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق به‌طور مؤثر برای تشخیص عیب در موتورها استفاده شده‌اند. روش‌های مورد استفاده برای تشخیص عیب در زیر ارائه شده‌اند:

الگوریتم‌های یادگیری ماشین: این الگوریتم‌ها برای تشخیص عیب‌های مکانیکی و الکتریکی مانند یاتاقان‌ها استفاده شده‌اند. با این حال، دقت آن‌ها زمانی که مجموعه داده مورد استفاده انواع مختلفی از عیب را داشته باشد، نامناسب است [۱۹ و ۲۰].

## جدول ۲: روش‌های تشخیص عیب

نویسندگان	روش	معایب
چویا و همکاران [۳۰]، گائو و همکاران [۳۱]	شبکه عصبی کانولوشنی یک‌بعدی	وابستگی به متخصص انسانی [۳۲]
وانگ و همکاران [۳۳]	شبکه عصبی کانولوشنی دو‌بعدی	وابستگی به متخصص انسانی [۳۲]
چن و همکاران [۳۴]	شبکه عصبی کانولوشنی یک‌بعدی	استخراج نامناسب ویژگی‌ها [۳۲]
شارما و همکاران [۳۵]	شبکه عصبی کانولوشنی دو‌بعدی	استخراج نامناسب ویژگی‌ها [۳۲]
ژائو و همکاران [۳۶]	شبکه عصبی کانولوشنی یک‌بعدی	عملکرد ضعیف در شرایط کاری مختلف شامل سرعت‌ها، بارها و نوع سنسورهای متفاوت

## ۲-۱- نوآوری و ساختار مقاله

استفاده از روش‌های یادگیری عمیق، دقت و کارایی تشخیص عیب در موتورها را به‌طور قابل توجهی بهبود می‌بخشد و در نتیجه به کاهش هزینه‌های تعمیر و نگهداری کمک می‌کند. در این مقاله، شبکه‌های عصبی کانولوشنی یک‌بعدی با LSTM در یک ساختار عصبی عمیق ترکیبی ترکیب شده‌اند تا عملکرد سیستم‌های تشخیص عیب را بهبود بخشند. در این ساختار، ورودی شبکه شامل سیگنال‌های ارتعاش و آکوستیک دریافتی از موتور است و خروجی شبکه نوع عیب موتور را نشان می‌دهد. یکی از جنبه‌های مهم شبکه‌های عصبی عمیق، تعیین ساختار لایه‌ها، تعداد لایه‌های مورد استفاده و پارامترهای هر لایه است. این مقاله روشی را از طریق الگوریتم تطبیق‌یافته کلونی مورچگان برای تعیین خودکار ساختار بهینه برای شبکه‌های عصبی عمیق ارائه می‌دهد. همچنین این پژوهش، روشی ترکیبی مبتنی بر کنترل بهینه مرتبه کسری با ترکیب با کنترل کننده PID ارائه می‌دهد. در ساختار کنترل پیشنهادی، کنترل کننده PID کنترل ولتاژ-فرکانس را انجام می‌دهد. اگر سرعت با ریپل به‌دقت مناسبی نرسد، از کنترل کننده مکمل بهینه برای کاهش ریپل با کنترل ولتاژ استفاده می‌شود. در این کنترل کننده، سرعت و جریان‌های موتور وارد واحد کنترل می‌شوند و ولتاژ خروجی اضافی به ولتاژ اصلی اضافه می‌شود تا وضعیت سرعت موتور بهبود یابد.

ترکیب تشخیص عیب و کنترل سرعت در سیستم‌های مدرن موتور-محور برای افزایش قابلیت اطمینان و عملکرد بسیار مهم است. تشخیص عیب امکان تشخیص شرایط غیرعادی در موتور را فراهم می‌کند، در حالی که کنترل سرعت به سیستم انعطاف‌پذیری لازم برای تنظیم تطبیقی رفتار موتور در پاسخ به این عیوب را می‌دهد. این رویکرد ترکیبی از آسیب و خرابی احتمالی جلوگیری می‌کند و کارایی کلی سیستم را بهبود می‌بخشد.

علاوه بر این، استفاده از تکنیک‌های کنترل تحمل‌پذیر عیب تضمین می‌کند که سیستم می‌تواند عملکرد پایدار خود را حتی در صورت بروز عیب یا اغتشاش بدون کاهش قابل توجه عملکرد حفظ کند [۳۷-۳۹] که در این مقاله، با در نظر گرفتن پیشینه، سیستم‌های بهبود یافته ارائه می‌شود. روش‌های کنترل تحمل‌پذیر عیب به موتور اجازه می‌دهند تا به‌صورت کارآمد به کار خود ادامه دهد و اثرات عیوب را جبران کند. این رویکرد به ویژه در کاربردهای صنعتی که حفظ عملکرد مداوم ضروری است و با هدف کاهش زمان از کارافتادگی و هزینه‌های نگهداری انجام می‌شود، ارزشمند است. این ترکیب از تشخیص عیب، کنترل سرعت تطبیقی و تکنیک‌های کنترل تحمل‌پذیر عیب، یک راه‌حل قدرتمند برای مدیریت عیب در موتورها است و به بهبود تاب‌آوری و طول عمر آن‌ها کمک می‌کند.

کنترل کننده ارائه شده یک روش کنترل ترکیبی شامل کنترل بهینه و کنترل PID هست. در این کنترل کننده، شرایط مطلوب با کمینه ولتاژ ورودی که باعث جلوگیری از آسیب به موتور شود، انجام می‌شود.

روش پیشنهادی یک روش دو مرحله‌ای بلادرنگ هست؛ این کنترل کننده دو بخشی به‌صورت موازی عمل می‌کند و در صورتی که یک از کنترل کننده‌ها خراب شود، کنترل موازی اصلاح را انجام می‌دهد. این روش، یک رویکرد کنترل تحمل‌پذیر عیب هست که هم در زمانی که موتور سالم هست و هم در زمان عیب، کنترل را به خوبی انجام می‌دهد. همچنین به‌منظور در نظر گرفتن مزایای کنترل مقاوم، از پیش پردازش و حذف اغتشاش و نویز استفاده شد.

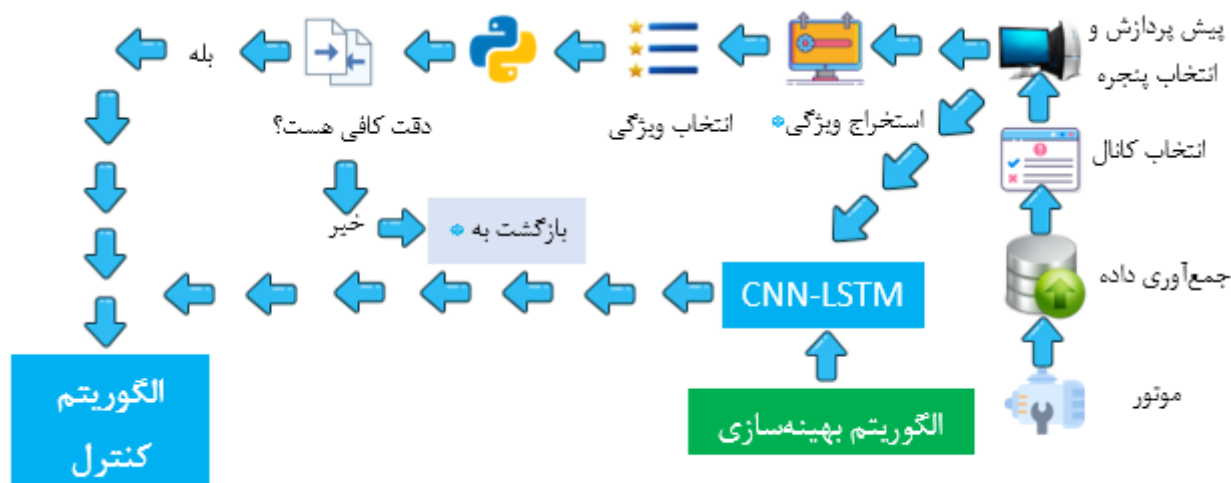
ساختار مقاله به شرح زیر است:

بخش ۲ روش پیشنهادی برای تشخیص عیب و کنترل سرعت را ارائه می‌دهد. این بخش دو الگوریتم را ارائه می‌دهد: الگوریتم اول از یادگیری ماشین برای تشخیص عیب استفاده می‌کند و الگوریتم دوم از یک شبکه عصبی عمیق بهبود یافته استفاده می‌کند. نتایج شبیه‌سازی در بخش ۳ و نتیجه‌گیری در بخش ۴ ارائه شده است.

## ۲- روش پیشنهادی

می‌کنیم. فرآیند تشخیص عیب در شکل ۲ نشان داده شده است. در این روش، ابتدا مجموعه داده به دست می‌آید و سپس فرآیند انتخاب کانال انجام می‌شود. در این حالت، با توجه به نوع عیوب، داده‌های مناسب برای تجهیزات سخت‌افزاری موجود را طبق جدول ۱ انتخاب می‌کنیم تا دقت تشخیص مناسب باشد و این تشخیص با کمترین هزینه انجام شود.

این بخش روش پیشنهادی برای تشخیص عیب و کنترل سرعت موتورها را معرفی می‌کند. در این مقاله، از سه مجموعه داده با دو الگوریتم متفاوت استفاده می‌کنیم. در الگوریتم اول، از استخراج ویژگی از طریق ویژگی‌های آماری، فرکانسی و انرژی و انتخاب خودکار ویژگی استفاده می‌کنیم. در الگوریتم دوم، از استخراج خودکار ویژگی استفاده



شکل ۲: روش پیشنهادی

می‌توان به آن دست یافت. در مرحله بعد، اگر عیبی در موتور رخ دهد، کنترل کننده PID دوم وارد الگوریتم کنترل می‌شود و سعی می‌کند سرعت را با استفاده از ساده‌ترین کنترل کننده کنترل کند.

### ۲-۱- مجموعه‌های داده مورد استفاده

در این مقاله، ما از سه مجموعه داده برای بررسی الگوریتم‌های پیشنهادی استفاده کردیم. مجموعه داده اول شامل داده‌های موتور القایی با توان  $3/4$  اسب بخار و جریان نامی  $4/1$  آمپر در سرعت‌های  $950$  و  $1425$  دور بر دقیقه، ولتاژ  $220$  ولت و کلاس عایق B است. مجموعه داده شامل سه حالت عیب یاتاقان، عدم کوپل صحیح و حالت سالم است. سیگنال‌های ارتعاشی با استفاده از شتاب‌سنج با حساسیت  $0.3125 \text{ V/g}$  با پهنای باند تا  $3000$  هرتز و دامنه  $\pm 16 \text{ g}$  و سیگنال‌های آکوستیک با سنسور اکوستیویتی  $(-37 \text{ dBV/Pa}$  تا  $-39 \text{ dBV/Pa})$  و نویز ذاتی  $(65 \text{ dBV/Pa } (A - \text{weighted @ } 94 \text{ dB SPL}))$  جمع‌آوری شده‌اند، برای ثبت داده از ست‌آپ ارائه شده در [۱] استفاده شده است. نرخ نمونه‌برداری سیگنال‌ها  $44/1$  کیلوهرتز است و هر حالت شامل مجموعه‌ای از داده‌های زمان-فرکانس می‌باشد که قابلیت

مجموعه داده‌های جمع‌آوری شده در این پژوهش شامل دما، جریان موتور، ارتعاش و سیگنال‌های آکوستیک است. پس از آن، متناسب با عیوب که در این پژوهش تمرکز بر عیوب مکانیکی هست، از داده‌های ارتعاش و آکوستیک استفاده می‌کنیم. پس از آن، پیش‌پردازش شامل فیلتر ناچ و تبدیل موجک را انجام می‌دهیم. سپس فرآیند انتخاب پنجره انجام می‌شود و داده‌های بخش‌بندی شده، به الگوریتم اول وارد می‌شوند. در صورت عدم مناسب بودن دقت، از الگوریتم دوم و از شبکه عصبی عمیق بهینه شده استفاده می‌شود. ساختار لایه‌ها و پارامترهای این شبکه با استفاده از الگوریتم تطبیق داده‌شده کلونی مورچگان به صورت بهینه تعیین می‌شوند. در نهایت، کنترل کننده طراحی شده سرعت موتور را کنترل می‌کند. برای کنترل سرعت، از PWM و SPWM استفاده کردیم. در این حالت، از دو کنترل کننده PID و یک کنترل کننده بهینه استفاده می‌شود. در مرحله اولیه، طبق اصل سادگی، از کنترل کننده PID استفاده می‌شود. در صورتی کنترل کننده PID نتواند سرعت را به درستی کنترل کند. در آن صورت، از کنترل کننده بهینه مرتبه کسری برای دستیابی به سرعت مناسب استفاده می‌شود که با تنظیم پارامترهای ولتاژ و جریان قابل تنظیم

سیگنال‌های دیجیتال و آنالوگ و قابلیت اتصال به کامپیوتر از طریق USB و بلوتوث را دارد. پس از اتصال به کامپیوتر، دستورات توقف عملکرد موتور از طریق نرم‌افزار MATLAB ارسال می‌شود و در صورت نیاز، این برد عملکرد موتور را متوقف می‌کند.



شکل ۴: برد کنترلی استفاده شده


در مجموعه داده دوم از داده‌های [۴۰] استفاده می‌کنیم و بر عیوب یاتاقان تمرکز می‌کنیم و در مجموعه داده سوم [۴۱]، طیف جامع‌تری از عیوب بررسی شده است. در مجموعه داده دوم، فرکانس نمونه‌برداری ۲۵/۶ کیلوهرتز است. طبق فرآیند جمع‌آوری داده‌ها، سیگنال‌های موتور سالم در بسته‌های ۱۲۰ ثانیه‌ای ثبت شده‌اند، در حالی که سیگنال‌های موتورهای معیوب در بسته‌های ۶۰ ثانیه‌ای ثبت شدند. در این مجموعه داده، سه حالت خطای ۰/۳ میلی‌متر، ۱ میلی‌متر و ۳ میلی‌متر برای حلقه‌های داخلی و خارجی عیوب یاتاقان در نظر گرفته شده است و این عیوب در بارهای ۰، ۲ و ۴ نیوتن متر بررسی و ثبت شده‌اند. در مجموعه داده سوم، فرکانس نمونه‌برداری ۴۲ کیلوهرتز است، ضبط‌ها به مدت ۱۰ ثانیه انجام شد و هفت عیب در این حالت بررسی شده است. در این مجموعه داده‌ها، مجموعه‌ای متنوع از عیوب مکانیکی و الکتریکی شامل عدم تعادل روتور، شکستگی میله‌های روتور، ناهمراستایی روتور، روتور خمیده، یاتاقان‌های معیوب، سیم‌پیچ استاتور، عدم تعادل ولتاژ و تک فاز شدن در شرایط تحت بار و بی‌باری و در چهار سرعت مختلف در نظر گرفته شده است.

## ۲-۲- پیش‌پردازش

هدف ما در پیش‌پردازش سیگنال‌های ارتعاشی، افزایش کیفیت آن‌هاست. برای دستیابی به این هدف، از فیلترهای ناچ، موجک و روش‌های آماری استفاده می‌کنیم. این روش‌ها به‌طور خاص برای حذف نویز و اختلال ناخواسته از سیگنال طراحی شده‌اند و در نتیجه کیفیت کلی آن را بهبود می‌بخشند. فرکانس برق شهر با استفاده از یک فیلتر

تحلیل عیوب مکانیکی و شبیه‌سازی شرایط عملیاتی مختلف را فراهم می‌آورد. نرخ نمونه‌برداری ۴۴/۱ کیلوهرتز با توجه به نیازهای مقاله در تشخیص عیب انتخاب شده است. عیوب یاتاقان و عدم کوپل صحیح باعث ایجاد ضربه‌هایی در سیگنال‌های آکوستیک و ارتعاش در فرکانس‌های بالا می‌شوند که با جمع‌آوری این سیگنال‌ها می‌توان تشخیص عیب و همچنین مکان وقوع عیب را با دقت بالاتری تشخیص داد. این فرکانس‌ها به‌وسیله تبدیل موجک و تحلیل بسته‌های موجک استخراج می‌شوند. در این مقاله، به‌منظور استفاده هم‌زمان و مؤثر از سیگنال‌های آکوستیک و ارتعاش، نیاز به یکسان‌سازی فرکانسی داریم. در صورت یکسان نبودن سیگنال‌ها نیاز به توسعه روش‌های یکسان‌سازی فرکانسی از جمله روش‌های درون‌یابی اسپلاین هست. به‌علاوه، استفاده از سخت‌افزار با قابلیت ثبت سیگنال‌های فرکانس بالا می‌تواند منجر به انعطاف برای تشخیص سایر عیوب شود.

تصویر موتورها استفاده شده برای ثبت داده در شکل ۳ نشان داده شده است. در این حالت، از یک برد به همراه سنسور ترموکوپل برای ثبت دمای بدنه، برد فرکانس بالا ۸ کانال، سنسور ارتعاش و آکوستیک استفاده می‌شود. به‌منظور ثبت داده‌های ارتعاش، دسته موتور به بدنه ثابت می‌شود و سنسور به دسته موتور متصل می‌شود.



شکل ۳: موتورهای ارائه شده در مجموعه داده اول

به‌منظور جمع‌آوری داده دمایی برای تشخیص اولیه عیب، تحلیل داده لبه‌ای روی برد و ارسال دستورات کنترلی بلادرنگ برای ورود الگوریتم کنترلی تکمیلی یا توقف عملکرد موتور از برد ارائه شده در شکل ۴ استفاده می‌شود. این برد دارای رله‌های روی برد، قابلیت پردازش

$$H_p = - \sum_{i=1}^{N_p} \frac{|w_{p,i}|^2}{\|w_p\|^2} \ln \left( \frac{|w_{p,i}|^2}{\|w_p\|^2} \right) \quad (5)$$

با استفاده از (۵)، رابطه (۶) به دست می آید.

$$\tilde{w}_{p,i} = \text{sign}(w_{p,i}) \max\{|w_{p,i}| - \beta_{p,i} \sigma_p, 0\}, \beta_{p,i} = \frac{\sigma_p^2}{|w_{p,i}|^2 + \epsilon} \quad (6)$$

که در آن،  $\sigma_p$  تخمین نویز مناسب  $(|w_p = \text{finest}|) / 0.6745k$  و  $\epsilon \ll 1$  هست. این روش، اتلاف انرژی را به حداقل می رساند که منجر به موازنه بایاس-واریانس  $\mathbb{E}[(w_{p,i} - \tilde{w}_{p,i})^2]$  می شود. برای انتخاب موجک مادر  $\psi_0$  و پارامترهای مقیاس  $\theta$ ، معادله (۷) را حل می کنیم. برای انتخاب موجک مادر  $\psi_0$  و پارامترهای مقیاس  $\theta$ ، معادله زیر را حل می کنیم:

$$\min_{\theta} \lambda_3 \text{Kurt}(w(\theta))^{-1} + \lambda_4 \text{RE}(x, \tilde{x}(\theta)) \quad (7)$$

که در آن  $\text{Kurt}(w) = \mathbb{E}[w^4] / (\mathbb{E}[w^2])^2 - 3$  باعث افزایش پاسخ ضربه ای در  $w = \mathcal{W}_{\theta}(x)$  می شود. در این روش،  $\tilde{x}(\theta)$  تبدیل معکوس ضرایب حذف نویز است. با ترکیب موارد ارائه شده به صورت (۸)، هدف پیش پردازش به صورت مؤثر انجام می شود.

$$\min_{\mathbf{h}, \theta, \mathcal{P}} \underbrace{\int_{\Omega_{\text{pass}}} |H_{\text{notch}}(e^{j\omega}; \mathbf{h}) - 1|^2 d\omega}_{\text{notch-ripple}} + \lambda_1 \sum_{p \in \mathcal{P}} \text{RE}_p + \lambda_2 \sum_{p \in \mathcal{P}} H_p + \lambda_3 \text{Kurt}(w(\theta))^{-1} + \lambda_4 \text{RE}(x, \tilde{x}(\theta)) \quad (8)$$

با توجه به نرخ نایکوئیست، بالاترین فرکانسی که می توانیم بدون اعوجاج در داده های دیجیتال داشته باشیم  $22/0.5$  کیلوهرتز هست، همچنین به منظور حذف سیگنال های اغتشاش که فرکانس پایین هستند، داده های  $10$  هرتز تا  $22/0.5$  کیلوهرتز را مورد تحلیل قرار می دهیم؛ بدین منظور، نیاز به استفاده از موجک db8 و سطح تجزیه  $11$  هست، در این حالت جزء تقریب  $A_{11}$  حذف و اجزای جزئیات  $D_1 - D_{11}$  بازسازی می شوند که بازه فرکانسی مورد نظر را می دهد؛ همچنین به منظور کاهش نویز فرکانس بالا، روی  $D_1 - D_2$  آستانه گذاری نرم به کار رفته است.

### ۲-۳- انتخاب پنجره

انتخاب یک پنجره مناسب منوط به پیکربندی بهینه اندازه و موقعیت پنجره است که برای الگوریتم های به کار رفته در پردازش سیگنال ضروری است. این روش با در نظر گرفتن ویژگی های سیگنال، به دنبال

ناچ در مجموعه داده ها حذف می شود. مجموعه داده اول در ایران ثبت شده که دارای فرکانس برق  $50$  هرتز، مجموعه داده دوم در کره جنوبی و مجموعه داده سوم در کانادا ثبت شده اند و هر دو فرکانس  $60$  هرتز دارند. در این بخش فرآیند پیش پردازش ارائه می شود:

در این بخش،  $x(t)$  سیگنال ارتعاش جمع آوری شده از موتور می باشد که به صورت (۱) نشان داده می شود.

$$x(t) = s(t) + n(t) + \eta(t) \quad (1)$$

که در آن  $s(t)$  مؤلفه ساختاری سیگنال،  $n(t)$  تداخل باند باریک برای حذف اغتشاش فرکانس برق و  $\eta(t)$  نویز با مشخصات  $\mathbb{E}[\eta] = 0, \text{Var}[\eta] = \sigma^2$  است. ما  $n(t)$  را با طراحی یک فیلتر ناچ مرتبه دوم  $IIR$  به نام  $H_{\text{notch}}(z)$  که ضرایب آن  $\mathbf{h} = \{h_0, h_1, h_2\}$  است و در (۲) صدق می کند، حذف می کنیم.

$$\min_{\mathbf{h}} \int_{\omega \in \Omega_{\text{pass}}} |H_{\text{notch}}(e^{j\omega}; \mathbf{h}) - 1|^2 d\omega \quad \text{s.t.} \quad H_{\text{notch}}(e^{j\omega_0}; \mathbf{h}) = 0 \quad (2)$$

که برای فرکانس  $60$  هرتز،  $\omega_0 = 2\pi \cdot 60 / f_s$  است. همچنین  $\Omega_{\text{pass}}$  باند تشخیصی را پوشش می دهد. در نتیجه (۳) را به دست می آوریم.

$$H_{\text{notch}}(z) = \frac{1 - 2\cos(\omega_0)z^{-1} + z^{-2}}{1 - 2r\cos(\omega_0)z^{-1} + r^2z^{-2}} \quad (3)$$

سپس با حل  $\min_r \int_{\Omega_{\text{pass}}} |H(e^{j\omega}) - 1|^2 d\omega$ ،  $r \in (0, 1)$  انتخاب می شود. در مرحله بعد، تجزیه موجک گسسته را انجام می دهیم؛ در این حالت، اگر  $\mathcal{D} = \{\psi_{\theta}\}$  کتابخانه ای از موجک های تحلیلی  $\psi_{\theta}(t) = s^{-1/2} \psi_0((t - \tau)/s)$  با پارامترهای  $\theta = (s, \tau)$  باشد، آنگاه ضرایب  $w_p[k] = \langle x, \psi_{p,k} \rangle$  برای گره  $p$  در موقعیت  $k$  تا سطح  $J$  محاسبه می شوند. در این حالت، یک زیرمجموعه بهینه از گره های  $\{1, \dots, P\}$  را با به حداقل رساندن معیار ترکیبی (۴) را انتخاب می کنیم.

$$J(\mathcal{P}) = \lambda_1 \sum_{p \in \mathcal{P}} \text{RE}_p + \lambda_2 \sum_{p \in \mathcal{P}} H_p \quad (4)$$

که در آن  $\text{RE}_p = \|w_p - \tilde{w}_p\|^2$  خطای بازسازی است و (۲) آنتروپی شانون گره  $p$  است. برای حذف نویز هر ضریب  $w_{p,i}$ ، انقباض واریانس وزن دار (۴) را معرفی می کنیم.

$$x_m[n] = x[n + mH]w[n; \theta^*] \quad (۱۴)$$

#### ۲-۴- الگوریتم اول

هدف این الگوریتم دستیابی به دقت کلاس بندی مناسب با استفاده از الگوریتم های استخراج و انتخاب ویژگی و یادگیری ماشین است. اگر دقت کلاس بندی اولیه کمتر از معیارهای مورد نظر باشد، فرآیند انتخاب ویژگی و کلاس بندی را تکرار می کنیم. این فرآیند تکراری ما را قادر می سازد تا الگوریتم را به طور مداوم اصلاح و بهبود بدهیم تا به دقت مطلوب برسیم. این الگوریتم شامل مراحل و بخش های مختلفی است که در بخش زیر مورد بحث قرار گرفته است.

#### ۲-۴-۱ استخراج و انتخاب ویژگی

ما از ویژگی های آماری، آنتروپی شانون، انرژی سیگنال، فرکانسی و مقادیر حداکثر و حداقل مطابق با (۱۵) در یک پنجره برای کلاس بندی حالت های مختلف سیگنال استفاده کردیم.

$$\left\{ \begin{aligned} f_1 &= \log \left( \left| \frac{1}{N} \sum_i x_i \right| + \varepsilon \right) \\ f_2 &= \log \left( \sqrt{\frac{1}{N} \sum_i (x_i - \mu)^2 + \varepsilon} \right) \\ f_3 &= \min(\log|x_i| + \varepsilon), f_4 = \max(\log|x_i| + \varepsilon) \\ f_{5,6} &= \log \left( \left| \frac{1}{N} \sum_i (x_i - \mu)^k \right| + \varepsilon \right), k = 3, 4 \\ f_7 &= - \sum_n S_j \times \log(S_j + \varepsilon) \\ f_8 &= \sum_{n/2} \log(S_j^2) + \sum_{n/2} \log(S_j^2) \\ f_9 &= \log \left( \sum_{k=0}^{N-1} |X[k]|^2 + \varepsilon \right) \\ f_{10} &= \sum_{k=0}^{N-1} \left( \frac{|X[k]|^2}{\sum |X[\cdot]|^2} \right) \cdot \log \left( \frac{|X[k]|^2}{\sum |X[\cdot]|^2} + \varepsilon \right) \\ f_{11} &= \frac{\sum_{k=0}^{N-1} k |X[k]|^2}{\sum_{k=0}^{N-1} |X[k]|^2} \\ f_{12} &= \frac{\sqrt{\sum_{k=0}^{N-1} (k - f_{11})^2 |X[k]|^2}}{\sum_{k=0}^{N-1} |X[k]|^2} \end{aligned} \right. \quad (۱۵)$$

با تجزیه و تحلیل این ویژگی ها، می توانیم اطلاعات معناداری را از سیگنال استخراج کرد و از آن برای شناسایی عیوب استفاده کنیم. ما سیگنال ها را بر اساس طول پنجره تقسیم می کنیم تا اطلاعات مورد نظر برای استخراج ویژگی را به دست آوریم. این فرآیند تقسیم بندی تضمین می کند که هر بخش حاوی داده های کافی برای تجزیه و تحلیل دقیق است. پس از پنجره بندی، ویژگی های معادله (۱۵) برای هر پنجره محاسبه می شوند. پس از آن، از روش زیر برای انتخاب ویژگی های مؤثر استفاده می کنیم:

بهینه سازی تعادل بین اندازه پنجره و رزولوشن فرکانس است. یک پنجره بزرگ ممکن است رزولوشن فرکانسی بهتری ایجاد کند ولی به قیمت کاهش رزولوشن زمانی. در مقابل، یک پنجره کوتاه تر ممکن است رزولوشن زمانی بهبود یافته را بدهد ولی این اقدام با از دست دادن رزولوشن فرکانسی همراه است. در زیر الگوریتم انتخاب پنجره تطبیقی ارائه می شود:

اگر  $x[n]$  دنباله سیگنال ارتعاشی گسسته باشد که با نرخ  $f_s$  نمونه برداری شده است و  $w[n; \theta]$  یک پنجره پارامتری با طول  $L$  باشد، که از دنباله های پرولیت سفروئیدال گسسته<sup>۱</sup> یا از پنجره های کایزر با پارامتر  $\beta$  باشد. در این حالت، ما به دنبال حداکثر رساندن تمرکز فرکانس تحت یک محدودیت زمانی ثابت با حل معادله (۹) هستیم.

$$\max_{\theta=(L,\beta)} C(\theta) \text{ where } C(\theta) = \frac{\sum_{k=-K}^K |W(e^{j2\pi k/N}; \theta)|^2}{\sum_{k=-N/2}^{N/2-1} |W(e^{j2\pi k/N}; \theta)|^2} \quad (۹)$$

که در آن:

$$W(e^{j\omega}; \theta) = \sum_{n=0}^{L-1} w[n; \theta] e^{-j\omega n}, K = [W_{\text{cut}} N / (2\pi)] \quad (۱۰)$$

$W_{\text{cut}}$  لبه باند عبور برای هارمونیک های عیب هست. برای پنجره های در نظر گرفته شده،  $C(\theta)$  به  $w[n; L, W_{\text{band}}]$  به بزرگ ترین مقدار ویژه ماتریس توپلیتز کاهش می یابد و پنجره بهینه مربوط به بردار ویژه است:

$$T_{ij} = \frac{\sin(2\pi W_{\text{band}}(i-j)/f_s)}{\pi(i-j)}, 0 \leq i, j < L \quad (۱۱)$$

برای پنجره کایزر، رابطه (۱۲) برقرار هست.

$$w[n; \beta] = \frac{I_0[\beta \sqrt{1 - ((2n - L + 1)/(L - 1))^2}]}{I_0(\beta)} \quad (۱۲)$$

ما را از طریق جستجوی شبکه ای و گرادیان با در نظر گرفتن  $L/f_s \leq \Delta t_{\text{max}}$  و  $\beta \leq \beta_{\text{max}}$ ، پارامترهای  $L$  و  $\beta$  را به صورت زیر بهینه می کنیم:

$$\theta^* = \arg \max_{L_{\text{min}} \leq L \leq L_{\text{max}}, \beta \geq 0} C(L, \beta) \quad (۱۳)$$

پس از تعیین پنجره بهینه  $w[n; \theta^*]$  می توان سیگنال را با اندازه گام  $H \leq L^*/2$  به صورت (۱۴) پنجره گذاری کرد.

<sup>1</sup> Discrete Prolate Spheroidal Sequences

• به روز رسانی  $S_{t+1} = S_t \cup \{j^*\}$ ,  $C_{t+1} = C_t \setminus \{j^*\}$ ,  $t \leftarrow t + 1$

توقف الگوریتم: اگر  $|S_t| \geq m$  و حداکثر ویژگی‌ها به دست آید یا تغییر در دقت  $\Delta \text{Acc} < \delta$  در  $k$  تکرار متوالی به مقدار ثابتی برسد. مرحله نهایی: پس از به دست آمدن مجموعه نهایی  $S_T$ ، برای هر  $j \in S_T$ ، اگر حذف  $j$  دقت را بهبود بخشد:

$$\text{If } \text{Acc}(S_T \setminus \{j\}) \geq \text{Acc}(S_T) \Rightarrow S_T := S_T \setminus \{j\} \quad (۲۰)$$

در نتیجه، این الگوریتم برای بهینه‌سازی (۲۱) استفاده می‌شود که  $|S| \leq m$  را نتیجه می‌دهد.

$$\max_{S \subseteq \{1, \dots, d\}, |S| \leq m} \left[ \sum_{j \in S} (\alpha_1 D(f_j) + \alpha_2 I(f_j; Y) - \alpha_3 R(f_j, S)) + \alpha_4 \cdot \text{Acc}_{\text{val}}(F[:, S]) \right] \quad (۲۱)$$

در این حالت، از معادله (۱۶) تا (۱۹) برای انتخاب ویژگی‌های مؤثر استفاده شده است؛ در معادله (۱۶) اثر افزودن ویژگی بر دقت الگوریتم بررسی می‌شود. در معادله (۱۷)، نسبت واریانس بین کلاس‌ها به درون کلاسی سنجیده می‌شود و تضمین کننده توانایی ویژگی‌ها در جداسازی کلاس‌ها است. معادله (۱۸)، نشان دهنده میزان وابستگی بین ویژگی‌ها و کلاس عیب هست. همچنین با استفاده از معادله (۱۹)، از انتخاب ویژگی‌های تکراری یا مشابه جلوگیری می‌شود.

#### ۲-۴-۲ الگوریتم‌های کلاس‌بندی

برای دستیابی به نتیجه مطلوب، باید الگوریتم‌های یادگیری ماشین مناسب را با دقت انتخاب کرد و برای مجموعه داده‌ها استفاده کنیم. در این حالت، الگوریتم‌های زیر به‌طور مناسب و با توجه به مسئله انتخاب شده‌اند:

جدول ۳: الگوریتم‌های یادگیری ماشین

الگوریتم‌ها	مجموعه الگوریتم	ردیف
Simple, medium, complex tree algorithms	اول	۱
Linear SVM, medium Gaussian SVM, quadratic SVM, cubic SVM, coarse Gaussian SVM	دوم	۲
Fine KNN, medium KNN, coarse KNN, cosine KNN, cubic KNN, Weighted KNN	سوم	۳
Ensemble (bagged tree), Ensemble (subspace discriminant), Ensemble (Subspace KNN)	چهارم	۴

اگر  $F = [f_1, \dots, f_d] \in \mathbb{R}^{N \times d}$  ماتریس ویژگی‌ها،  $y \in \{1, 2, \dots, C\}^N$  برچسب کلاس‌ها،  $\mathcal{S} \subseteq \{1, \dots, d\}$  مجموعه فعلی بهترین ویژگی‌های انتخاب شده و  $\mathcal{C} = \{1, \dots, d\} \setminus \mathcal{S}$  ویژگی‌های کاندید که هنوز انتخاب نشده‌اند باشد. هدف ما به حداکثر رساندن دقت طبقه‌بندی  $\text{Acc}(\mathcal{S})$  با انتخاب زیرمجموعه‌ای از ویژگی‌های  $\mathcal{S}^*$  از طریق بهینه‌سازی تکراری است. این بهینه‌سازی توسط یک تابع هدف بر اساس دقت کلاس‌بندی انجام می‌شود. برای هر ویژگی  $j \in \mathcal{C}$ ، تابع (۱۶) را تعریف می‌کنیم. تابع هزینه ارائه شده در معادله (۱۶) از چهار بخش تشکیل شده است که هر بخش متناسب با مسئله و با دقت انتخاب شده است و ضعف‌های روش‌های تک معیاره را پوشش می‌دهد. در این روش، هدف دستیابی به حداکثر جدایی بین ویژگی‌ها، حداکثر ارتباط بین ویژگی‌ها و کلاس عیب، اعمال جریمه برای انتخاب ویژگی تکراری یا مشابه و در نظر گرفتن اثر مستقیم اضافه کردن یک ویژگی بر دقت کلاس‌بندی هست.

$$U_t(j) = \underbrace{\alpha_1 \cdot D(f_j)}_{\text{Discriminative Power}} + \underbrace{\alpha_2 \cdot I(f_j; Y)}_{\text{Relevance}} - \underbrace{\alpha_3 \cdot R(f_j, S_t)}_{\text{Redundancy}} + \underbrace{\alpha_4 \cdot \frac{\partial \text{Acc}(S_t \cup \{j\})}{\partial j}}_{\text{Marginal Accuracy Gain}} \quad (۱۶)$$

که در آن،  $D(f_j)$  به صورت (۱۷) نشان داده می‌شود و میزان مؤثر بودن ویژگی  $f_j$  در جداسازی کلاس‌ها از طریق نسبت واریانس بین کلاس‌ها را اندازه‌گیری می‌کند،  $I(f_j; Y)$  مطابق (۱۸) میزان وابستگی بین  $f_j$  و  $Y$  را نشان می‌دهد و  $R(f_j, S_t)$  که در (۱۹) نشان داده شده، بیانگر همبستگی با ویژگی‌های از پیش انتخاب شده است.

$$D(f_j) = \frac{\sum_{c=1}^C N_c (\mu_j^c - \mu_j)^2}{\sum_{c=1}^C \sum_{i: y_i=c} (f_j^{(i)} - \mu_j^c)^2 + \varepsilon} \quad (۱۷)$$

$$I(f_j; Y) = \sum_{y \in Y} \sum_{v \in f_j} P(y, v) \log \frac{P(y, v)}{P(y)P(v)} \quad (۱۸)$$

$$R(f_j, S_t) = \frac{1}{|S_t|} \sum_{k \in S_t} \rho(f_j, f_k), \rho(f_j, f_k) = \frac{\text{Cov}(f_j, f_k)}{\sigma_j \sigma_k} \quad (۱۹)$$

در زیر الگوریتم تکراری انتخاب ویژگی ارائه می‌شود، در ابتدا مقادیر اولیه به صورت  $S_0 = \emptyset$ ,  $C_0 = \{1, \dots, d\}$ ,  $t = 0$  می‌شود. فرآیند زیر به منظور دستیابی به حالت بهینه تکرار می‌شود:

فرآیند زیر به منظور دستیابی به حالت بهینه تکرار می‌شود:

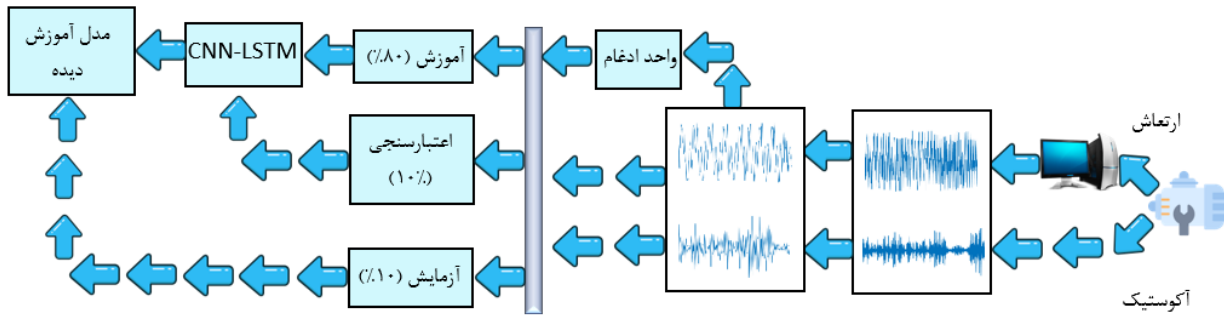
• برای هر  $j \in C_t$ ، مقدار  $U_t(j)$  محاسبه می‌شود.

• انتخاب  $j^* = \arg \max_{j \in C_t} U_t(j)$

## ۲-۵- الگوریتم دوم

آموزش شبکه عصبی عمیق را نشان می‌دهد. در ابتدا، مجموعه داده‌ها را به ۸۰٪ برای آموزش، ۱۰٪ برای اعتبارسنجی و ۱۰٪ برای آزمایش تقسیم کردیم. پس از آن، فرآیند پنجره‌بندی را اعمال کردیم و هر مجموعه داده به پنجره‌های زمانی تقسیم شد. اگر دقت تشخیص عیب رضایت‌بخش باشد، الگوریتم با همان طول پنجره انجام می‌شود.

پیچیدگی مجموعه داده سوم برای تشخیص عیب بسیار زیاد است زیرا داده‌ها در چهار سرعت مختلف و دو حالت (تحت بار و بدون بار) ثبت شده‌اند. در این حالت، شرایط تحت بار و بدون بار در سرعت‌های مختلف برای یک عیب خاص در یک کلاس واحد گروه‌بندی می‌شوند. بنابراین، داده‌ها به هشت کلاس مجزا تقسیم می‌شوند. شکل ۵ فرآیند



شکل ۵: الگوریتم دوم

در این فرآیند، نه تنها انتخاب لایه‌ها بهینه می‌شود (وجود یا عدم وجود لایه‌هایی مانند CNN، LSTM یا Dropout)، بلکه پارامترهای هر لایه (تعداد واحدها، اندازه هسته و نرخ Dropout) نیز برای بهبود عملکرد بهینه می‌شوند. نتیجه این است که یک توپولوژی شبکه عصبی عمیق بهینه شده با تنظیمات پارامترهای مناسب به بالاترین عملکرد در سیستم مورد نظر دست می‌یابد و نیاز به تلاش دستی برای تنظیم مدل را به حداقل می‌رساند. الگوریتم پیشنهادی برای بهینه‌سازی ساختار شبکه عصبی عمیق با استفاده از الگوریتم تطبیق یافته کلونی مورچگان در زیر ارائه شده است:

## الگوریتم ۱

## الف: فضای جستجو و نمادگذاری

انتخاب نوع لایه‌ها:

$$V = \{Conv_{k \times k}, Pool_{p \times p}, Dropout(d), LSTM(u), Dense(h)\}$$

که در آن،  $Conv_{k \times k}$  لایه کانولوشن با اندازه هسته  $k \in \{3, 5, 7\}$  با فیلترها  $f \in \{16, 32, 64, 128\}$  هست.

$Pool_{p \times p}$  حداکثر یا میانگین ادغام با  $p \in \{2, 3\}$  و  $Dropout(d)$  نرخ حذف با  $d \in \{0.1, 0.2, \dots, 0.5\}$  هست.

$LSTM(u)$  با تعداد واحدهای  $u \in \{32, 64, 128, 256\}$  و  $Dense(h)$  با اندازه  $h \in \{8, 16, 64, 128, 256, 512\}$  هست.

## ۲-۵-۱ بهینه‌سازی ساختار شبکه

این مقاله از الگوریتم تطبیق یافته کلونی مورچگان برای بهینه‌سازی معماری و پارامترهای شبکه عصبی عمیق از جمله لایه‌های CNN، LSTM، MaxPooling و Dropout استفاده می‌کند. هدف اصلی این روش یافتن مؤثرترین چیدمان لایه‌ها و پیکربندی‌های مربوط به آن‌ها برای به حداکثر رساندن عملکرد مدل برای تشخیص عیب است. الگوریتم تطبیق یافته کلونی مورچگان با مقاردهای اولیه مجموعه‌ای از لایه‌های مناسب و پارامترهای آن‌ها شروع می‌شود. هر عامل در جمعیت به‌طور تصادفی یک شبکه عصبی پیشنهادی ایجاد می‌کند، با این تفاوت که انتخاب لایه‌ها و تنظیمات آن‌ها به‌صورت احتمالی بر اساس مقادیر فرمون و مقادیر پارامترهای اکتشافی انجام می‌شود. سپس، شبکه تولیدشده با استفاده از مجموعه اعتبارسنجی برای اندازه‌گیری عملکرد آن آموزش داده شده و ارزیابی می‌شود. این الگوریتم دارای مزایایی نسبت به الگوریتم‌های جستجوی تصادفی هست. الگوریتم کلونی مورچگان، به‌منظور تعیین ساختار شبکه از تجربه‌های قبلی و بهترین نتایج قبلی استفاده می‌کند که منجر به بهینه‌سازی پایدارتر می‌شود. در این الگوریتم می‌توانیم بر اساس ساختار گراف، یک شبکه بهینه با پارامترهای بهینه تشکیل دهیم. همچنین این روش از توابع احتمالاتی و به‌صورت گسسته استفاده می‌کند که منجر به کاهش زمان اجرا و بهینه‌سازی الگوریتم می‌شود.

$$\begin{aligned}\mu_t(\theta) &= k_\theta^T (K + \sigma^2 I)^{-1} \mathbf{y}, \sigma_t^2(\theta) \\ &= k(\theta, \theta) - k_\theta^T (K + \sigma^2 I)^{-1} k_\theta\end{aligned}$$

#### ذ: ارزیابی و به‌روزرسانی فرمون

هر معماری  $\theta^{(m,t)}$  را آموزش داده و ارزیابی می‌کنیم (با شرط توقف زودهنگام)، سپس مقدار هزینه  $y^{(m,t)}$  را ذخیره می‌کنیم. به‌روزرسانی بیزین:  $(\theta^{(m,t)}, y^{(m,t)})$  را به مجموعه داده‌های مرحله  $t$  یعنی  $D_t$  اضافه می‌کنیم و سپس میانگین و واریانس  $\mu_t, \sigma_t$  را مجدداً محاسبه می‌کنیم.

مجموعه بهینه  $\mathcal{S}_t$  را انتخاب می‌کنیم: یعنی  $q$  درصد از بهترین معماری‌ها با کم‌ترین هزینه را انتخاب می‌کنیم.

برای هر یال  $(u \rightarrow v)$  در معماری‌هایی که در مجموعه بهینه هستند، مقدار فرمون اضافه می‌شود با رابطه بالا، که در آن  $y(\theta)$  مقدار هزینه و  $\varepsilon$  یک مقدار کوچک برای جلوگیری از تقسیم بر صفر هست.

$$\Delta \tau_{uv}^{(t)} = \frac{y}{y(\theta) + \varepsilon}, \varepsilon > 0$$

تبخیر و به‌روزرسانی فرمون: مقدار جدید فرمون روی یال  $(u \rightarrow v)$  از ترکیب تبخیر مقدار قبلی با نرخ  $\rho$  و مجموع مقادیر فرمون رسوب‌گذاری شده توسط معماری‌های بهینه به‌دست می‌آید.

$$\tau_{uv}^{(t+1)} = (1 - \rho) \tau_{uv}^{(t)} + \sum_{\theta \in \mathcal{S}_t} \Delta \tau_{uv}^{(t)}, \rho \in (0, 1)$$

#### ر: جستجو از طریق نمونه‌گیری تامپسون

برای تنوع‌بخشی بیشتر جستجو، در هر نقطه تصمیم‌گیری، نمونه‌گیری  $P_{uv} \sim \mathcal{N}(\mu_{uv}, \sigma_{uv}^2)$  را انجام می‌دهیم و  $\mu_{uv}$  را با  $-\tilde{f}_{uv}$  در  $P_{uv}$  جایگزین می‌کنیم.

#### ۲-۵-۲ شبکه بهینه شده

جدول ۴ مشخصات شبکه عصبی عمیق بهینه شده به‌دست‌آمده با استفاده از الگوریتم تطبیق یافته کلونی مورچگان را نشان می‌دهد. این شبکه دارای لایه‌های CNN، Maxpooling، LSTM، Flatten و dense هست. الگوریتم بهینه‌سازی کلونی مورچگان با استفاده از تعداد مورچه‌ها ۳۰، نرخ تبخیر  $\alpha = 1, 0, 4$  و  $\beta = 2$  اجرا شده است. این مقادیر پس از آزمون‌های متعدد و با هدف توازن بین سرعت همگرایی و دقت انتخاب شده‌اند.

گراف  $G = (V, E)$  که در آن  $E$  انتقال‌های معتبر را اعمال می‌کند (Conv  $\rightarrow$  Pool، آخرین لایه کانولوشن LSTM  $\rightarrow$  Conv و Dense  $\rightarrow$  output که فقط یک‌بار اجرا می‌گردد).

معماری  $\theta = [(v_0, p_0), (v_1, p_1), \dots, (v_L, p_L)]$  با طول  $L$  هست که در آن هر  $(v_i, p_i)$  نوع لایه انتخاب‌شده و پارامتر آن است.

#### ب: تشکیل تابع هزینه

تابع هزینه را به‌صورت زیر انتخاب می‌کنیم:

$$\min_{\theta \in \Theta} \text{Cost}(\theta) = \sum_{i=1}^5 \alpha_i f_i(\theta)$$

که در آن:

$$\begin{aligned}f_1(\theta) &= 1 - \text{Acc}_{\text{train}}(\theta), f_2(\theta) = 1 - \text{Acc}_{\text{val}}(\theta) \\ f_3(\theta) &= 1 - \text{Acc}_{\text{test}}(\theta), f_4(\theta) = \frac{N_P(\theta)}{N_P^{\max}}, f_5(\theta) = \frac{T_{\text{train}}(\theta)}{T^{\max}}\end{aligned}$$

در این رابطه،  $N$  تعداد پارامترها و  $T$  زمان آموزش هست. وزن‌های  $\alpha_i > 0$  اهمیت دقت را تنظیم می‌کند. با توجه به اینکه هدف کنترل تحمل‌پذیر عیب بلادرنگ هست، ضرایب پارامترهای زمان بزرگ‌تر انتخاب می‌شود.

#### ج: قانون تصمیم‌گیری در الگوریتم کلونی مورچگان

برای هر یال جهت‌دار  $(u \rightarrow v) \in E$  فرمون  $\tau_{uv}^{(t)}$  و مقدار اکتشاف ایستا  $\eta_{uv} = h_{\text{CNN}}(u, v)$  یا  $h_{\text{LSTM}}(u, v)$  انتخاب می‌شوند. در گره  $u$ ، مورچه  $v$  را با احتمال زیر انتخاب می‌کند:

$$P_{uv}^{(t)} = \frac{(\tau_{uv}^{(t)})^\alpha (\eta_{uv})^\beta \exp(\kappa \mu_{uv}^{(t)})}{\sum_{w \in \mathcal{N}(u)} (\tau_{uw}^{(t)})^\alpha (\eta_{uw})^\beta \exp(\kappa \mu_{uw}^{(t)})}$$

که در آن  $\alpha, \beta > 0$  وزن فرمون و مقدار اکتشافی و  $\mu_{uv}^{(t)}$  هزینه میانگین جایگزین گوسی برای افزودن یک یال  $(u \rightarrow v)$  هست.  $\kappa \geq 0$  ضریب تنظیم کننده استفاده از مدل بیزین هست.

هر عامل به‌طور متوالی با عبور از گره ورودی از طریق لایه‌های CNN به‌صورت اختیاری از لایه LSTM و سپس لایه‌های Dense می‌گذرد تا به خروجی برسد و  $\theta$  را بسازد.

#### د: فرآیند گاوسی

مجموعه داده  $D_t = \{(\theta^{(m,t)}, y^{(m,t)})\}$  را با  $y = \text{Cost}(\theta) + \varepsilon$  فرض  $f(\theta) \sim \mathcal{N}(0, \sigma^2)$  داریم. در این حالت، با فرض  $f(\theta) \sim \mathcal{GP}(0, k(\theta, \theta'))$  توزیع به‌صورت زیر به دست می‌آید:

جدول ۴: مشخصات شبکه مورد استفاده در الگوریتم دوم

Layer	Layer name	Kernel × unit	Specifications	Output shape	#parameters
1	Conv 1D	5 × 64	Activation= ReLu, Strides=1	(None,996, 64)	384
2	MaxPooling 1D	-	Strides=2	(None,498, 64)	0
3	Conv 1D	3 × 32	Activation= ReLu, Strides=1	(None,496, 64)	12352
4	MaxPooling 1D	-	Strides=2	(None,248, 64)	0
5	Conv 1D	3 × 128	Activation= ReLu, Strides=1	(None,246, 128)	24704
6	MaxPooling 1D	-	Strides=2	(None, 123, 128)	0
7	Conv 1D	3 × 64	Activation= ReLu, Strides=1	(None,121, 64)	24640
8	MaxPooling 1D	-	Strides=2	(None,60, 64)	0
9	LSTM	64 Unit	return_sequences=True	(None,60, 32)	12416
10	LSTM	32 Unit	-	(None,64)	24832
11	Flatten	-	-	(None,64)	0
12	Dense	1 × 32	Relu	(None,32)	2080
13	Dense	1 × 8	Softmax	(None,8)	264

۲-۶- مدل ریاضی موتور و طراحی کنترل کننده

موتورهای القایی به دلیل قابلیت اطمینان و نگهداری کم هزینه، در کاربردهای مختلفی مورد استفاده قرار می گیرند. به دلیل استفاده در کاربردهای توان بالا، موتور القایی به یک سیستم درایو با کارایی بالا نیاز دارد تا عملکرد آن را به طور دقیق و کارآمد کنترل کند. مدل موتور القایی [۴۲] به صورت معادله (۱۶) و معادلات شار به صورت معادله (۱۷) نشان داده شده است.

$$\begin{bmatrix} V_{sq} \\ V_{sd} \\ V_{rq} \\ V_{rd} \end{bmatrix} = \begin{bmatrix} R_s + s^\alpha L_s & 0 & s^\alpha L_m & 0 \\ 0 & R_s + s^\alpha L_s & 0 & s^\alpha L_m \\ s^\alpha L_m & \omega_r L_m & R_r + s^\alpha L_r & \omega_r L_r \\ -\omega_r L_m & s^\alpha L_m & -\omega_r L_r & R_r + s^\alpha L_r \end{bmatrix} \times \begin{bmatrix} i_{sq} \\ i_{sd} \\ i_{rq} \\ i_{rd} \end{bmatrix} \quad (24)$$

عبارت  $s^\alpha$  در معادله (۱۸) عملگر لاپلاس است. با تعریف حالت های برداری به عنوان جریان های استاتور و روتور، مدل موتور القایی را می توان به صورت معادله (۱۹) نوشت.

$$\begin{bmatrix} \frac{d^\alpha i_{sd}}{dt} \\ \frac{d^\alpha i_{sq}}{dt} \\ \frac{d^\alpha i_{rd}}{dt} \\ \frac{d^\alpha i_{rq}}{dt} \end{bmatrix} = \begin{bmatrix} R_s L_r & -\omega_r L_m^2 & -R_r L_m & -\omega_r L_m L_r \\ \omega_r L_m^2 & R_s L_r & \omega_r L_m L_r & -R_r L_m \\ -R_s L_m & \omega_r L_m L_s & R_r L_s & \omega_r L_r L_s \\ -\omega_r L_m L_s & -R_s L_m & -\omega_r L_r L_s & R_r L_s \end{bmatrix} \times \frac{1}{L_m^2 - L_r L_s} \times \begin{bmatrix} i_{sq} \\ i_{sd} \\ i_{rq} \\ i_{rd} \end{bmatrix} + \frac{1}{L_m^2 - L_r L_s} \times \begin{bmatrix} -L_r & 0 & L_m & 0 \\ 0 & L_r & 0 & L_m \\ L_m & 0 & -L_s & 0 \\ 0 & L_m & 0 & -L_s \end{bmatrix} \times \begin{bmatrix} v_{sd} \\ v_{sd} \\ v_{rd} \\ v_{rq} \end{bmatrix} \quad (25)$$

گشتاور را می توان به صورت مکانیکی به صورت معادله (۲۰) نوشت.

$$T_e = J \frac{d\omega_m}{dt} + B\omega_m + T_L = \frac{J}{P} \frac{d\omega_r}{dt} + \frac{B}{P} \omega_r + T_L \quad (26)$$

که در آن  $J$  اینرسی،  $B$  ضریب گرانروی،  $T_L$  گشتاور بار،  $\omega_r$  سرعت زاویه ای روتور برحسب رادیان بر ثانیه و  $\omega_m$  سرعت موتور برحسب رادیان بر ثانیه است. همچنین، معادله گشتاور را می توان به صورت الکتریکی به صورت معادله (۲۱) نوشت.

$$T_e = \frac{3}{2} P (\varphi_{sd} i_{sq} - \varphi_{sq} i_{sd}) \quad (27)$$

$$T_e = \frac{3}{2} P L_m (i_{sq} i_{rd} - i_{sd} i_{rq})$$

که در آن  $P$  تعداد جفت قطبها است. شکل ۶ کنترل کننده سرعت موتور شبیه سازی شده در سیمولینک را نشان می دهد. همان طور که در شکل ۶ نشان داده شده است. ما ساختاری با سه کنترل کننده برای کنترل سرعت موتور در حالت های سالم و معیوب

$$\begin{cases} V_{sd} = R_s i_{sd} + \frac{d^\alpha \varphi_{sd}}{dt} \\ V_{sq} = R_s i_{sq} + \frac{d^\alpha \varphi_{sq}}{dt} \\ V_{rd} = R_r i_{rd} + \frac{d^\alpha \varphi_{rd}}{dt} - \omega_r \varphi_{rd} \\ V_{rq} = R_r i_{rq} + \frac{d^\alpha \varphi_{rq}}{dt} + \omega_r \varphi_{rq} \end{cases} \quad (22)$$

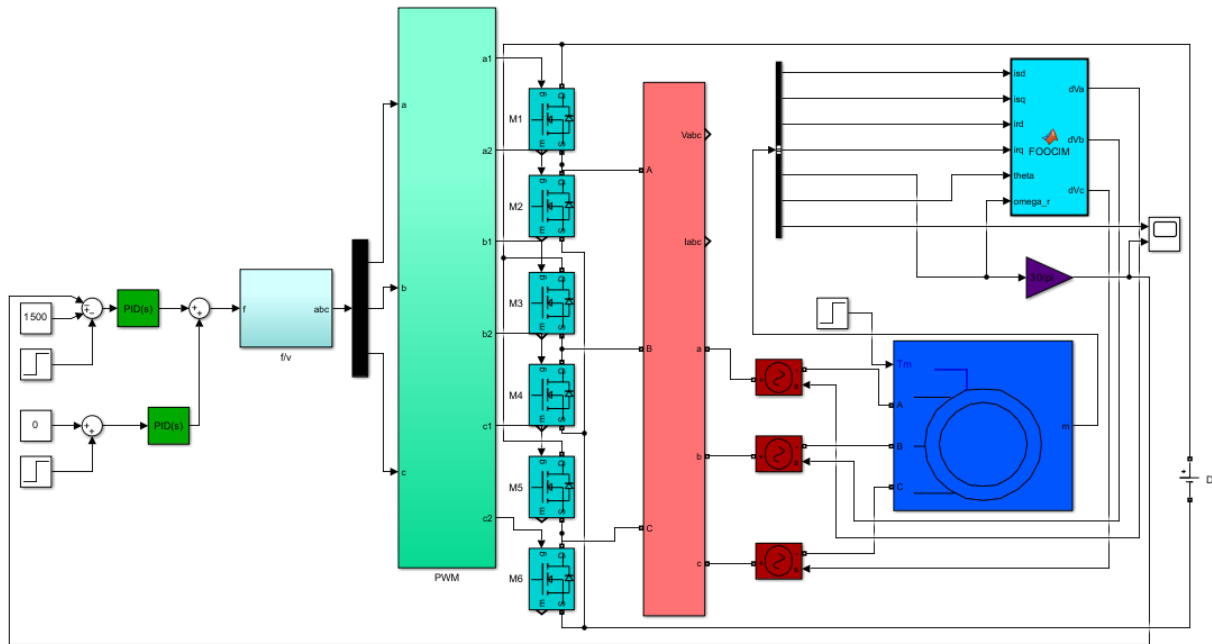
$$\begin{cases} \varphi_{sd} = L_s i_{sd} + L_m i_{rd} \\ \varphi_{sq} = L_s i_{sq} + L_m i_{rq} \\ \varphi_{rd} = L_m i_{sd} + L_r i_{rd} \\ \varphi_{rq} = L_m i_{sq} + L_r i_{rq} \end{cases} \quad (23)$$

که در آن  $\alpha$  مرتبه مشتق گیری است،  $V_{sq}$  و  $V_{sd}$  ولتاژهای استاتور هستند و  $i_{sq}$ ،  $i_{rd}$ ،  $i_{rq}$ ،  $i_{sd}$  مربوط به محورهای  $d$  و  $q$  جریان استاتور و جریان روتور هستند.  $\varphi_{sd}$ ،  $\varphi_{rd}$ ،  $\varphi_{rq}$ ،  $\varphi_{sq}$  شار استاتور و روتور،  $R_r$  و  $R_s$  مقاومت های استاتور و روتور،  $L_s$  و  $L_r$  به ترتیب نشان دهنده اندوکتانس استاتور و روتور هستند و  $L_m$  اندوکتانس متقابل است. معادلات ماشین القایی در حالت مرجع ثابت را می توان با استفاده از مؤلفه های d-q به صورت معادله (۱۸) نوشت.

کنترل بهینه به صورت معادله (۲۲) تعریف می کنیم. در این حالت، برای حل مسئله کنترل بهینه مرتبه کسری، از یک روش عددی استفاده می شود زیرا مشتقات چپ و راست به طور هم زمان ظاهر می شوند.

$$J = \frac{1}{2} \int_{t_0}^{t_f} \left[ \begin{pmatrix} x(t) - \Gamma(t) \\ u(t) \end{pmatrix}^T \begin{bmatrix} Q & 0 \\ 0 & R \end{bmatrix} \begin{pmatrix} x(t) - \Gamma(t) \\ u(t) \end{pmatrix} \right] dt \quad (28)$$

طراحی کردیم. در حالتی که موتور هیچ عیبی ندارد، از کنترل کننده PID اول استفاده می شود. در حالت های معیوب، یک کنترل کننده PID به ساختار کنترل کننده مرکزی اضافه می شود. اگر کنترل کننده های PID نتایج نامناسبی داشته باشند، کنترل کننده بهینه مرتبه کسری وارد ساختار کنترل شده و سرعت موتورها را با واحدهای کنترل ولتاژ کنترل می کند. در این حالت، تابع هزینه را برای



شکل ۶: کنترل کننده سرعت موتور

در این حالت، با انتخاب ورودی کنترلی (۳۰)، تابع هزینه به صورت (۳۲) بهینه می شود.

$$V(x, t) = \min_{u(\cdot)} \frac{1}{2} \int_t^{t_f} [(x - \Gamma)^T Q (x - \Gamma) + u^T R u] dt \quad (32)$$

با استفاده از  $h = (t_f - t_0)/N$  بازه  $[t_0, t_f]$  را به  $N$  زیر بازه تبدیل می کنیم در این حالت  $t_j = t_0 + jh, j = 0, \dots, N$  با در نظر گرفتن  $m \geq 0$  و تعریف (۳۳) که از ارائه گرناوالد-لتنیکوف به دست آمده، کنترل بهینه به مقادیر مورد نظر همگرا می شود.

$$b_m^{(j+1)} = h^\alpha [(m+1)^\alpha - m^\alpha], a_m^{(j+1)} = h^\alpha [(j-m+2)^\alpha - 2(j-m+1)^\alpha + (j-m)^\alpha] \quad (33)$$

مقادیر اولیه:  $x_0 = x(t_0), \omega_0 = \omega_r(t_0)$

حدس اولیه:  $u_j^{(0)}, j = 0, \dots, N$

برای هر تکرار در روش شوتینگ از  $k = 0$  تا همگرایی:

- پیمایش رو به جلو برای  $j = 0$  تا  $N - 1$ :

به منظور حل کنترل بهینه، متغیرهای شبه حالت را به صورت  $\lambda_x(t) \in \mathbb{R}^4, \lambda_\omega(t) \in \mathbb{R}$  در نظر می گیریم. به منظور دستیابی به کنترل بهینه، ابتدا لازم هست که شرایط لازم کنترل بهینه را به دست آوریم. با در نظر گرفتن تابع همیلتونین به صورت (۲۹)، شرایط لازم کنترل بهینه به صورت (۳۰) به دست می آید.

$$H(z, u, \lambda, t) = \frac{1}{2} (x - \Gamma)^T Q (x - \Gamma) + \frac{1}{2} u^T R u + \lambda_x^T [A(\omega_r)x + Bu] + \lambda_\omega h(x, \omega_r) \quad (29)$$

$$\begin{cases} {}_t D_t^\alpha \lambda_x(t) = -\frac{\partial H}{\partial x} = -Q(x - \Gamma) - [\partial_x(Ax)]^T \lambda_x - [\partial_x h]^T \lambda_\omega \\ -\dot{\lambda}_\omega(t) = \frac{\partial H}{\partial \omega_r} = \lambda_x^T \frac{\partial A}{\partial \omega_r} x + \lambda_\omega \frac{\partial h}{\partial \omega_r} \\ \lambda_x(t_f) = 0, \lambda_\omega(t_f) = 0 \\ \frac{\partial H}{\partial u} = Ru + B^T \lambda_x = 0 \Rightarrow u^*(t) = -R^{-1} B^T \lambda_x(t) \end{cases} \quad (30)$$

که در آن،  $\omega_r$  از رابطه (۳۱) به دست می آید.

$$\dot{\omega}_r(t) = \frac{1}{J} [T_e(x(t)) - T_L] \rightarrow \dot{\omega}_r(t) = h(x(t), \omega_r(t)) \quad \omega_r(t_0) = \omega_{r0} \quad (31)$$

محاسبه رو به جلو  $\{x_j, \omega_j, u_j\}$ ، محاسبه رو به عقب

$$\|\lambda_{x,N}\| + \|\lambda_{\omega,N}\| \text{ نهایی و بررسی مانده نهایی}$$

• به روزرسانی حدس شبه حالت به صورت (۴۰):

$$\lambda^{(k+1)} = \alpha_{\text{relax}} \lambda^{(\text{new})} + (1 - \alpha_{\text{relax}}) \lambda^{(k)} \quad (40)$$

تکرار تا باقیمانده به کمتر از حد مطلوب برسد.

در ادامه تخمین مبتنی بر توابع متعامد ارائه می‌شود، یکی از مزایای توابع متعامد تضمین همگرایی مناسب هست. از جمله موارد دیگر که توابع متعامد را از سایر روش‌های عددی متمایز می‌کند، عدم وابستگی ضریب جملات جدید به ضریب جملات قبلی هست و با به دست آوردن ضریب جملات جدید، ضریب جملات قبلی تغییری نمی‌کند. در این حالت، با تغییر متغیر  $\tau = (t - t_0)/(t_f - t_0) \in [0,1]$  توابع را بر اساس پایه‌های ژاکوبی  $\{P_n^{(\gamma,\delta)}(\tau)\}_{n=0}^M$  گسترش می‌دهیم. در این حالت، تقریب توابع به صورت (۴۱) هست.

$$x(t) \approx \sum_{n=0}^M X_n P_n(\tau), \omega_r(t) \approx \sum_{n=0}^M W_n P_n(\tau), \lambda_x(t) \approx \sum_{n=0}^M L_n P_n(\tau), u(t) \approx \sum_{n=0}^M U_n P_n(\tau) \quad (41)$$

ضرایب متغیرها را به فرم برداری فشرده  $X, W, L, U \in \mathbb{R}^{(M+1) \times d}$  نمایش می‌دهیم. برای نمایش ماتریس‌های عملیاتی:

مشتق کسری:  $D^{(\alpha)} \in \mathbb{R}^{(M+1) \times (M+1)}$  وجود دارد به طوری که

$${}_{t_0} D_t^\alpha [P(\tau)] \approx D^{(\alpha)} P(\tau)$$

مشتق معمولی:  $D^{(1)}$  برای  $\partial_\tau$  چند جمله‌ای‌های ژاکوبی.

معادلات حالت اصلی و معادلات شبه حالت را به روش گالرکین در برابر هر پایه  $P_i$ ، به علاوه شرط اولیه و شرایط مرزی اعمال می‌کنیم. این منجر به چهار بلوک معادلات جبری می‌شود:

$$D^{(\alpha)} X - \mathcal{A}(W)X - BU = 0$$

که در آن،  $\mathcal{A}(W) = \sum_{k=0}^M W_k A_k$  و  $A_k$  تصویرهای از پیش محاسبه شده از  $A(\omega)$  بر حسب  $P_k$  هستند.

$$D^{(1)} W - h(X, W) = 0$$

$$RU + B^T L = 0$$

شرایط ایستایی:  $RU + B^T L = 0$  دینامیک شبه حالت (۴۲):

$$D^{*(\alpha)} L = Q(X - \Gamma) + \mathcal{A}(W)^T L + (\partial_x h)^T L_\omega \quad (42)$$

• پیش بینی با استفاده از (۳۴):

$$x_{j+1}^p = x_0 + \frac{1}{\Gamma(\alpha)} \sum_{m=0}^j b_{j-m}^{(j+1)} [A(\omega_m)x_m + Bu_m^{(k)}], \omega_{j+1}^p = \omega_j + h_r h(x_j, \omega_j) \quad (34)$$

• اصلاح با استفاده از (۳۵):

$$x_{j+1} = x_0 + \frac{1}{\Gamma(\alpha)} \sum_{m=0}^j a_{j-m}^{(j+1)} [A(\omega_m)x_m + Bu_m^{(k)}] + \frac{a_0^{(j+1)}}{\Gamma(\alpha)} [A(\omega_{j+1}^p)x_{j+1}^p + Bu_{j+1}^{(k)}] \quad (35)$$

سپس حالت مکانیکی را به صورت تفاضلی به روزرسانی می‌کنیم و معادله (۳۶) را حل می‌کنیم.

$$\omega_{j+1} = \omega_j + h_r \times h(x_{j+1}, \omega_{j+1}) \quad (36)$$

• کنترل را در هر گره جدید از طریق تکرار شبه حالت قبلی مطابق (۳۷) محاسبه می‌کنیم.

$$u_{j+1}^{(k)} = -R^{-1} B^T \lambda_{x,j+1}^{(k)} \quad (37)$$

که در آن  $\lambda_x^{(k)}$  آخرین پیمایش رو به عقب است. در ادامه از روش پس‌رو برای شبه حالت استفاده می‌کنیم:

شرایط نهایی با نادیده گرفتن حافظه نهایی:  $\lambda_{x,N} = 0, \lambda_{\omega,N} = 0$  برای  $j = N$  به صورت کاهشی تا ۱:

• پیش بینی با استفاده از (۳۸):

$$\lambda_{x,j-1}^p = \frac{1}{\Gamma(\alpha)} \sum_{m=j}^{N-1} b_{m-j}^{*(m)} [Q(x_m - \Gamma_m) + A(\omega_m)^T \lambda_{x,m} + (\partial_x h)^T \lambda_{\omega,m}] \quad (38)$$

که در آن،  $b^*$  وزن‌های راست هستند. به طور مشابه،  $\lambda_{\omega,j-1}^p$  را از طریق آدامز-بشفورث معمولی به صورت معادله (۳۹) پیش‌بینی می‌کنیم.

$$-\lambda_\omega = \lambda_x^T \partial_\omega A x + \lambda_\omega \partial_\omega h \quad (39)$$

• اصلاح: از فرمول آدامز با وزن‌های  $a^*$ ، مشابه با اصلاح‌کننده پیش‌رو، استفاده می‌کنیم.

• حلقه تکرار شوتینگ: از آنجا که  $\{u_j\}$  به  $\{\lambda_{x,j}\}$  وابسته است و برعکس، پیمایش رو به عقب در یک حلقه بیرونی قرار می‌دهیم:

شرایط مرزی به صورت (۴۳):

$$u(t) = \sum_{n=0}^M U_n P_n \left( \frac{t - t_0}{t_f - t_0} \right) \quad (45)$$

$$\text{At } \tau = 0: x(0) = x_0, \omega(0) = \omega_0, \text{ At } \tau = 1: \lambda_x(1) = 0, \lambda_\omega(1) = 0 \quad (43)$$

### ۳- نتایج

این بخش نتایج الگوریتم‌های کلاس‌بندی و کنترل کننده را ارائه می‌دهد. در جدول ۵ نتایج برای مجموعه داده اول با استفاده از الگوریتم اول، در شکل ۷ جدا پذیری تعدادی از داده‌های مجموعه داده اول و در شکل ۸ و جدول ۶، نتایج الگوریتم کلاس‌بندی اول برای مجموعه داده دوم ارائه شده است. این الگوریتم، عیوب روی حلقه‌های داخلی و خارجی یاتاقان را در سه حالت ۰/۳ میلی‌متر، ۱ میلی‌متر، ۳ میلی‌متر و حالت سالم در نظر می‌گیرد. هر حالت در سه بار ۰ نیوتن‌متر، ۲ نیوتن‌متر و ۴ نیوتن‌متر در نظر گرفته شده است. هر عیب با بارهای مختلف در یک مجموعه گروه‌بندی شده و هفت کلاس برای این حالت در نظر گرفته شده است.


با یکپارچه‌سازی معادلات ارائه شده، به  $F(x, W, L, U) = 0$  می‌رسیم که ابعاد این سیستم برابر با  $(m + 1 + m + 1)(M + 1)$  به علاوه شرایط مرزی هست. در این حالت، از روش نیوتن-کانتروویچ برای حل این مسئله استفاده می‌شود. با مشتق‌گیری از هر بلوک نسبت به  $x, W, L, U$ ، تابع توزیع ژاکوبین را تشکیل می‌دهیم. حدس اولیه به صورت درونیابی خطی از  $(x_0, \omega_0)$  تا  $(\Gamma(t_f), 0)$  و تکرار فرآیند تا زمانی که  $\|F\|$  به مقدار مطلوب (۲۷) برسد.

$$\begin{pmatrix} X \\ W \\ L \\ U \end{pmatrix}^{(k+1)} = \begin{pmatrix} X \\ W \\ L \\ U \end{pmatrix}^{(k)} - [DF(\cdot)^{(k)}]^{-1} F(\cdot)^{(k)} \quad (44)$$

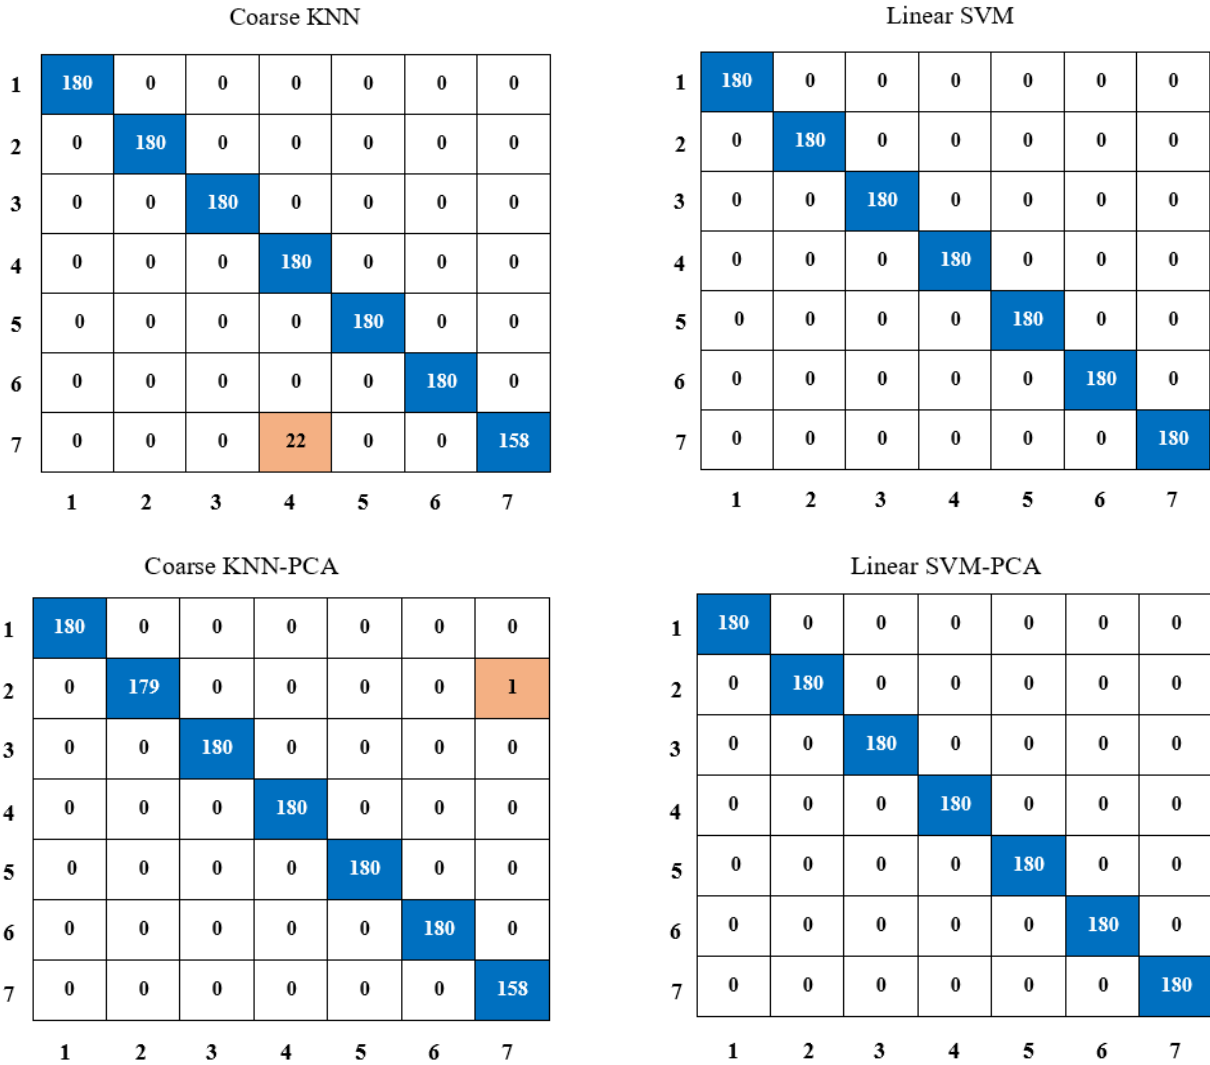
در نهایت، کنترل بهینه به صورت (۴۵) به دست می‌آید.

جدول ۵: نتایج الگوریتم اول برای مجموعه داده اول

#	Algorithm	Train accuracy	Train time	Test accuracy
1	Linear SVM	74.80	0.75	72.72
2	Fine KNN	100	0.16	95.45
3	Coarse KNN	100	0.08	90.90
4	Cosine KNN	81.10	0.07	77.27
5	Fine Tree	89.76	0.13	86.36
6	Coarse Tree	55.11	0.03	54.54
7	Ensemble- Bagged Trees	100	0.61	90.90
8	Ensemble- Subspace Discriminant	87.40	1.14	86.36
9	Ensemble- Subspace KNN	100	0.77	90.90
10	Narrow neural network	81.10	2.69	77.27



شکل ۷: نمایش جداپذیری ویژگی‌ها در کلاس‌های مورد نظر



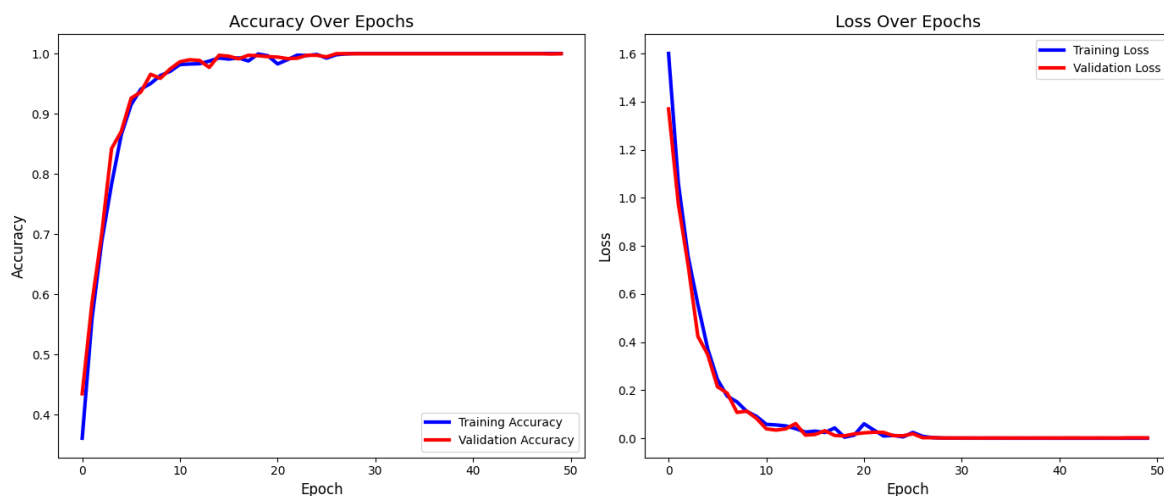
شکل ۸: ماتریس‌های درهم‌ریختگی الگوریتم اول

جدول ۶: نتایج الگوریتم اول برای مجموعه داده دوم

#	Algorithm	Accuracy	Train time	Accuracy-PCA 2 features	Train time-PCA
1	Linear SVM	100	2.317	100	3.051
2	Quadratic SVM	100	2.547	100	2.897
3	Cubic SVM	100	2.721	100	3.547
4	Medium Gaussian SVM	100	2.547	100	3.117
5	Coarse Gaussian SVM	100	2.024	99.8	3.865
6	Fine KNN	100	1.756	100	2.763
7	Medium KNN	100	1.489	99.9	2.492
8	Coarse KNN	98.3	1.647	99.9	2.785
9	Cosine KNN	100	1.478	99.8	2.478
10	Cubic KNN	100	1.571	99.9	2.632
11	Weighted KNN	100	1.712	99.9	2.142
12	Fine Tree	99.9	1.988	99.8	2.158
13	Medium Tree	99.9	2.375	99.8	2.657
14	Ensemble- Bagged Trees	100	3.223	99.8	4.054
15	Ensemble- Subspace Discriminant	100	3.574	97.6	9.216

همان طور که در جدول ۶ مشاهده می شود، در بین الگوریتم هایی که با مجموعه ویژگی کامل به دقت ۱۰۰٪ رسیده اند، الگوریتم Cosine KNN با زمان ۱/۴۷۸ ثانیه کوتاه ترین زمان آموزش را داشته است. همچنین، در بین الگوریتم هایی که با دو ویژگی به دقت ۱۰۰٪ رسیده اند، الگوریتم Fine KNN با زمان ۲/۷۶۳ ثانیه کوتاه ترین زمان آموزش را داشته است. با استفاده از روش PCA، در برخی از الگوریتم ها دقت کاهش پیدا می کند و در همه الگوریتم ها زمان آموزش افزایش می یابد که نشانگر این هست که ویژگی های انتخاب شده توسط الگوریتم انتخاب ویژگی جداپذیری مناسبی داشتند و برای کاربردهای

بلادرنگ مناسب هستند. نتایج الگوریتم دوم در شکل ۹ و شکل ۱۰ و جدول ۷ نشان داده شده است. در این الگوریتم، ۲۱۵۰۳ داده برای آموزش، ۲۶۸۸ داده برای اعتبارسنجی و ۲۶۸۸ داده برای آزمایش استفاده شده است. در جدول ۷، A1 نشان دهنده اولین حسگر ارتعاش، A2 نشان دهنده دومین حسگر ارتعاش، A3 نشان دهنده سومین حسگر ارتعاش و Acou نشان دهنده حسگر آکوستیک است. شکل ۱۱ و شکل ۱۲ نتایج الگوریتم کنترل برای کنترل سرعت موتور را نشان می دهند.




شکل ۹: نتایج کلاس بندی برای حسگر اول

جدول ۷: نتایج الگوریتم دوم


Network	Sensors	Train accuracy	Sensitivity	F1 Score	Train time	Validation accuracy	Test accuracy	Number of parameters
13-Layers CNN [43]	A1	97.73	97.76	97.72	-	-	-	-
15-Layers CNN [43]	A1	99.44	99.44	99.44	-	-	-	-
CNN-LSTM [43]	A1	99.96	99.96	99.96	9617.431	-	-	127784
CNN-LSTM-Attention	A1	99.81	99.81	99.81	6752.21	99.81	99.89	135016
<b>Proposed CNN-LSTM</b>	<b>A1</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>6118.137</b>	<b>99.96</b>	<b>99.96</b>	<b>65672</b>
13-Layers CNN [43]	A2	80.58	80.48	80.59	-	-	-	-
15-Layers CNN [43]	A2	83.44	83.43	83.42	-	-	-	-
CNN-LSTM [43]	A2	98.88	98.87	98.88	9789.228	-	-	127784
<b>Proposed CNN-LSTM</b>	<b>A2</b>	<b>98.98</b>	<b>98.98</b>	<b>98.98</b>	<b>4032.095</b>	<b>96.21</b>	<b>96.19</b>	<b>65672</b>
13-Layers CNN [43]	A3	82.89	82.91	82.85	-	-	-	-
15-Layers CNN [43]	A3	87.43	87.35	87.33	-	-	-	-
CNN-LSTM [43]	A3	99.37	99.36	99.36	9870.883	-	-	127784
CNN [43]	-	72.73	-	-	-	-	-	-
ChebyNet [44]	-	65.80	-	-	-	-	-	-
MLP [44]	-	63.1	-	-	-	-	-	-
Self-Training [44]	-	48.71	-	-	-	-	-	-
ME-GNN [44]	-	97.7	-	-	-	-	-	-
Proposed CNN-LSTM	A3	99.34	99.34	99.34	5076.251	97.28	97.17	65672
Proposed CNN-LSTM	Acou	97.39	97.39	97.39	3924.012	95.16	95.08	65672
Proposed CNN-LSTM	A1, A2, A3	99.94	99.94	99.94	15612.234	99.63	99.73	65672
<b>Proposed CNN-LSTM</b>	<b>A1, A2, Acou</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>15273.091</b>	<b>100</b>	<b>100</b>	<b>65672</b>
<b>Proposed CNN-LSTM</b>	<b>A1, A3, Acou</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>16175.287</b>	<b>100</b>	<b>100</b>	<b>65672</b>

الگوریتم در دوره‌های کمتری به دقت مورد نظر می‌رسد که باعث کاهش زمان کلی می‌شود. در این حالت، در صورت استفاده از داده‌های سنسور ارتعاش ۱، ارتعاش ۲ و آکوستیک، الگوریتم طی ۱۵ تکرار و در زمان ۴۵۸/۹۲۷ ثانیه به دقت ۱۰۰٪ می‌رسد. همچنین در صورت استفاده از سنسور ارتعاش اول، سنسور ارتعاش دوم و آکوستیک، الگوریتم طی ۱۰ تکرار و در زمان ۳۱۸۵/۳۷۶ ثانیه به دقت ۱۰۰٪ می‌رسد.


تمام نتایج ارائه شده در جدول ۷ برای ۵۰ تکرار است. همان‌طور که در جدول ۷ مشاهده می‌شود، الگوریتم پیشنهادی CNN-LSTM پارامترهای کمتری، زمان آموزش کمتر و دقت مناسبی دارد. همچنین، نتایج حسگر ارتعاش A1 بهتر از سایر حسگرها است. به‌طور کلی، حسگرهای ارتعاش نتایج بهتری نسبت به حسگرهای آکوستیک داشتند و هنگامی که ترکیبی از حسگرهای ارتعاش و آکوستیک استفاده می‌شود، زمان آموزش در هر دوره افزایش می‌یابد. با این حال،



شکل ۱۰: مقایسه شبکه‌های عصبی عمیق



شکل ۱۱: سرعت و گشتاور موتور قبل و بعد از وقوع عیب



شکل ۱۲: جریان استاتور در محور  $d-q$  قبل و بعد از وقوع عیب

هست که می‌تواند به صورت بلادرنگ اطلاعات را ارسال و دریافت کند. اگر وضعیت جدیدی در سیستم به وجود آمد که در مجموعه داده وجود نداشت و با حالت سالم و عیوب بررسی شده تطبیق نداشت، این حالت همراه با مشخصات ثبت شده به پایگاه داده ارسال می‌شود. در صورتی که فرکانس وقوع عیب زیاد باشد، در این صورت این حالت به عنوان یک کلاس جدید تعریف می‌شود. برای کنترل سرعت، از الگوریتم پیشنهادی استفاده شد. در زمان ۵، یک عیب رخ می‌دهد؛ حداکثر یک ثانیه برای جمع‌آوری داده‌ها برای یک پنجره، اجرای الگوریتم طبقه‌بندی و استفاده از کنترل کننده صرف می‌شود؛ در ثانیه ۶، از کنترل کننده اضافی استفاده می‌شود و کنترل مناسب به طور مناسب انجام می‌شود.

#### ۴- نتیجه‌گیری

این مقاله یک روش ترکیبی برای تشخیص عیب و کنترل سرعت موتورهای القایی تحت شرایط عملیاتی مختلف ارائه می‌دهد. نتایج نشان داد که الگوریتم کلاس‌بندی اول که از الگوریتم‌های استخراج ویژگی، انتخاب ویژگی و یادگیری ماشین استفاده می‌کند، در مجموعه داده‌های با پیچیدگی کم عملکرد خوبی دارد. آموزش این الگوریتم در مجموعه داده‌های اول شامل ۲ عیب و یک حالت سالم، در مجموعه داده دوم شامل شش عیب و یک حالت سالم بود؛ و در زمان کمتری (به طور متوسط ۲ ثانیه) به دقت مورد نظر رسید. با این حال، الگوریتم دوم، که از شبکه‌های عصبی عمیق CNN و LSTM استفاده می‌کند، عملکرد بهتری در داده‌های با پیچیدگی بالاتر شامل بارهای مختلف و سرعت‌های مختلف، ارائه داد. بهینه‌سازی ساختار و پارامترهای شبکه با استفاده از الگوریتم تطبیق یافته کلونی مورچگان به طور قابل توجهی

همان‌طور که نشان داده شده است، در مجموعه داده‌هایی با پیچیدگی تشخیص عیب کم، الگوریتم اول که شامل استخراج ویژگی و انتخاب ویژگی با استفاده از طبقه‌بندی با الگوریتم‌های یادگیری ماشین است، نتایج مناسبی دارد. مجموعه داده اول و دوم با استفاده از الگوریتم اول طبقه‌بندی شد؛ اجرای این الگوریتم برای یک نمونه کمتر از ۳۰ میلی‌ثانیه است. در ابتدا، از تمامی ویژگی‌ها با الگوریتم انتخاب ویژگی استفاده شد و در مرحله بعد، تعداد ویژگی‌ها با استفاده از روش PCA به دو ویژگی کاهش یافت و نتایج مناسب بود. کاهش بیشتر ویژگی‌ها منجر به کاهش شدید دقت شد. در مجموعه داده سوم، پیچیدگی تشخیص عیب بیشتر است؛ داده‌ها به دو حالت با بار و بدون بار و در چهار سرعت مختلف و هشت حالت، شامل یک حالت سالم و هفت حالت معیوب، طبقه‌بندی شده‌اند. الگوریتم‌های یادگیری ماشین در این مورد مناسب نبودند و از یک شبکه عصبی عمیق استفاده شد. نتیجه کلاس‌بندی با استفاده از اولین حسگر ارتعاش بهترین بود. اگر از ترکیب حسگرهای ارتعاش و آکوستیک استفاده شود، نتیجه بهتر است.

در این مقاله، در الگوریتم اول از ویژگی‌های آماری، انرژی و فرکانسی و در مجموعه دوم از شبکه عصبی عمیق استفاده شده است. تأثیر عیب‌ها در الگوهای سیگنال و همچنین فرکانس‌های خاصی ایجاد می‌شود. به منظور تعمیم روش ارائه شده برای تشخیص عیب سایر موتورها، دو اقدام انجام می‌شود؛ ابتدا، سیگنال‌ها نرمالیزه می‌شوند و در حالت دوم، در ابتدا موتور سالم اجرا می‌شود و پارامترهای مدل با مدل موتور مرجع که به وسیله داده‌های نرمالیزه آموزش داده شده، مقیاس می‌شوند. این اقدام، یک رویکرد نوآورانه مشابه با یادگیری انتقالی هست. روش ارائه شده در این مقاله، یک روش برخط (آنلاین)

ensemble learning,” *Electrical Engineering*, Vol. 104, pp. 2859–2877, 2022, doi: [10.1007/s00202-022-01523-6](https://doi.org/10.1007/s00202-022-01523-6).

[4] O. AlShorman *et al.*, “Sounds and acoustic emission-based early fault diagnosis of induction motor: A review study,” *Advances in Mechanical Engineering*, Vol. 13, Art. No. 168781402199691, 2021, doi: [10.1177/1687814021996915](https://doi.org/10.1177/1687814021996915).

[5] V. S. Dehnavi and M. Shafiee, “Inner and outer bearing fault diagnosis of electrical motors using a proposed algorithm and vibration signals,” in *Proc. 14th Int. Conf. Information and Knowledge Technology (IKT)*, 2023, pp. 175–180, doi: [10.1109/IKT62039.2023.10433018](https://doi.org/10.1109/IKT62039.2023.10433018).

[6] A. Glowacz, “Thermographic fault diagnosis of electrical faults of commutator and induction motors,” *Engineering Applications of Artificial Intelligence*, Vol. 121, Art. No. 105962, 2023, doi: [10.1016/j.engappai.2023.105962](https://doi.org/10.1016/j.engappai.2023.105962).

[7] L. Sheng *et al.*, “Research on gear crack fault diagnosis model based on permanent magnet motor current signal,” *ISA Transactions*, Vol. 135, pp. 188–198, 2023, doi: [10.1016/j.isatra.2022.10.001](https://doi.org/10.1016/j.isatra.2022.10.001).

[8] J. J. Saucedo-Dorantes *et al.*, “Automatic methodology for multiple fault detection in induction motor under periodic low-frequency fluctuating load based on stray flux signals,” *IEEE Transactions on Energy Conversion*, Vol. 38, No. 4, pp. 2744–2753, 2023, doi: [10.1109/TEC.2023.3294392](https://doi.org/10.1109/TEC.2023.3294392).

[9] J.-G. Jang *et al.*, “Vibration data feature extraction and deep learning-based preprocessing method for highly accurate motor fault diagnosis,” *Journal of Computational Design and Engineering*, Vol. 10, pp. 204–220, 2022, doi: [10.1093/jcde/qwac128](https://doi.org/10.1093/jcde/qwac128).

[10] A. Choudhary *et al.*, “Multi-input CNN based vibro-acoustic fusion for accurate fault diagnosis of induction motor,” *Engineering Applications of Artificial Intelligence*, Vol. 120, Art. No. 105872, 2023, doi: [10.1016/j.engappai.2023.105872](https://doi.org/10.1016/j.engappai.2023.105872).

[11] R. Kashfi and S. H. Karimizadeh, “Fault diagnosis methods for induction motors using motor current signal analysis,” in *Proc. 7th Int. Conf.*

دقت شناسایی و زمان پردازش را بهبود بخشید. همچنین، استفاده ترکیبی از داده‌های ارتعاشی و آکوستیک منجر به دقت بالاتر در تشخیص عیب شد. علاوه بر این، کنترل‌کننده PID و کنترل‌کننده بهینه مرتبه کسری در شرایط عیب، کنترل مناسبی بر سرعت موتور ارائه دادند. آن‌ها توانستند در هنگام وقوع عیب به صورت مؤثر سرعت را کنترل کنند. این روش پیشنهادی قابلیت اطمینان سیستم‌های دوار مانند موتورها را بهبود می‌بخشد، به کاهش هزینه‌های نگهداری کمک می‌کند و ایمنی را افزایش می‌دهد. در نتیجه، این روش می‌تواند به عنوان یک راهکار مؤثر در صنعت برای بهبود عملکرد و ایمنی ماشین‌های دوار مورد استفاده قرار گیرد.

#### ۴-۱- محدودیت‌ها و کارهای آینده

این مقاله برای تشخیص عیب و کنترل سرعت موتورهای توان پایین القایی ارائه شده است؛ برای اجرای الگوریتم روی موتورهای توان بالا نیاز به اجرای الگوریتم و تحلیل نتایج هست. همچنین برای عیوب نادر و خاص، نیاز به مجموعه داده کامل‌تری هست. در کارهای آینده، به منظور تشخیص طیف وسیع‌تری از عیوب می‌توان به عیوب دیگری مانند عیب میله‌های شکسته روتور پرداخت؛ در تشخیص این عیوب، می‌توان با ترکیب داده‌های جریان، آکوستیک و ارتعاش و روش‌های تلفیق داده به دقت مناسبی در تشخیص عیب دست یافت. همچنین می‌توان با استفاده از یادگیری انتقالی، تعمیم روش ارائه شده به موتورهای توان بالاتر را بررسی کرد. به علاوه، می‌توان از کنترل کامل‌تر مانند کنترل بهینه سینگولار مرتبه کسری و سایر الگوریتم‌های ابتکاری مانند الگوریتم بهینه‌سازی ملخ برای بهبود ساختار شبکه عصبی استفاده کرد.

#### ۵- منابع

[1] V. S. Dehnavi and M. Shafiee, “Fault diagnosis of induction motors using novel measurement techniques and data fusion,” *Measurement*, Vol. 256, Art. No. 118135, 2025, doi: [10.1016/j.measurement.2025.118135](https://doi.org/10.1016/j.measurement.2025.118135).

[2] K. S. Krishna Veni and N. S. Kumar, “Diagnosis of bearing fault in induction motor using Bayesian optimization-based ensemble classifier,” *Electrical Engineering*, Vol. 106, pp. 1895–1905, 2023, doi: [10.1007/s00202-023-02040-w](https://doi.org/10.1007/s00202-023-02040-w).

[3] A. Almounajjed, A. K. Sahoo, and M. K. Kumar, “Condition monitoring and fault detection of induction motor based on wavelet denoising with

- Art. No. 109142, 2023, doi: [10.1016/j.res.2023.109142](https://doi.org/10.1016/j.res.2023.109142).
- [20] R. R. Shubita *et al.*, "Fault detection in rotating machinery based on sound signal using edge machine learning," *IEEE Access*, Vol. 11, pp. 6665–6672, 2023, doi: [10.1109/ACCESS.2023.3237074](https://doi.org/10.1109/ACCESS.2023.3237074).
- [21] R. Rajabioun *et al.*, "Distributed bearing fault classification of induction motors using 2-D deep learning model," *IEEE Journal of Emerging and Selected Topics in Industrial Electronics*, Vol. 5, pp. 115–125, 2024, doi: [10.1109/JESTIE.2023.3323253](https://doi.org/10.1109/JESTIE.2023.3323253).
- [22] S. Ayankoso *et al.*, "Multisensory data-based fault diagnosis of induction motors using 1D and 2D convolutional neural networks," *Mechanisms and Machine Science*, pp. 1125–1135, 2024, doi: [10.1007/978-3-031-49421-5\\_92](https://doi.org/10.1007/978-3-031-49421-5_92).
- [23] E. Sonmez *et al.*, "A new deep learning model combining CNN for engine fault diagnosis," *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2023, doi: [10.1007/s40430-023-04537-8](https://doi.org/10.1007/s40430-023-04537-8).
- [24] P. Borghesani *et al.*, "A Fourier-based explanation of 1D-CNNs for machine condition monitoring applications," *Mechanical Systems and Signal Processing*, Vol. 205, Art. No. 110865, 2023, doi: [10.1016/j.ymsp.2023.110865](https://doi.org/10.1016/j.ymsp.2023.110865).
- [25] C. Celebioglu *et al.*, "Smartphone-based bearing fault diagnosis in rotating machinery using audio data and 1D convolutional neural networks," in *Proc. Int. Conf. Computer Systems and Technologies*, 2024, pp. 149–154, doi: [10.1145/3674912.3674918](https://doi.org/10.1145/3674912.3674918).
- [26] S. Ippili *et al.*, "Deep learning-based mechanical fault detection and diagnosis of electric motors using directional characteristics of acoustic signals," *Noise Control Engineering Journal*, Vol. 71, pp. 384–389, 2023, doi: [10.3397/1/377132](https://doi.org/10.3397/1/377132).
- [27] Y. Alkhanafseh *et al.*, "Advanced dual RNN architecture for electrical motor fault classification," *IEEE Access*, Vol. 12, pp. 2965–2976, 2024, doi: [10.1109/ACCESS.2023.3344676](https://doi.org/10.1109/ACCESS.2023.3344676).
- [28] A. Balamurugan *et al.*, "Fault diagnosis of three-phase induction motor using a hybrid ELSE-*Electrical, Computer and Mechanical Engineering*, Tehran, Iran, 2021 (in Persian).
- [12] B. Noori and M. Ojaghi, "Application of motor current signal analysis (MCSA) for stator core insulation fault diagnosis in three-phase induction motors," in *Proc. 8th Int. Conf. Electrical, Computer, Mechanical and Artificial Intelligence Engineering*, Mashhad, Iran, 2024 (in Persian).
- [13] M.-Q. Tran *et al.*, "Effective fault diagnosis based on wavelet and convolutional attention neural network for induction motors," *IEEE Transactions on Instrumentation and Measurement*, Vol. 71, pp. 1–13, 2022, doi: [10.1109/TIM.2021.3139706](https://doi.org/10.1109/TIM.2021.3139706).
- [14] H. Li *et al.*, "A normalized frequency-domain energy operator for broken rotor bar fault diagnosis," *IEEE Transactions on Instrumentation and Measurement*, Vol. 70, pp. 1–10, 2021, doi: [10.1109/TIM.2020.3009011](https://doi.org/10.1109/TIM.2020.3009011).
- [15] N. Jia *et al.*, "Intelligent fault diagnosis of rotating machines based on wavelet time-frequency diagram and optimized stacked denoising auto-encoder," *IEEE Sensors Journal*, Vol. 22, pp. 17139–17150, 2022, doi: [10.1109/JSEN.2022.3193943](https://doi.org/10.1109/JSEN.2022.3193943).
- [16] P. Gangsar and R. Tiwari, "Signal-based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review," *Mechanical Systems and Signal Processing*, Vol. 144, Art. No. 106908, 2020, doi: [10.1016/j.ymsp.2020.106908](https://doi.org/10.1016/j.ymsp.2020.106908).
- [17] H. Tao *et al.*, "Unsupervised cross-domain rolling bearing fault diagnosis based on time-frequency information fusion," *Journal of the Franklin Institute*, Vol. 360, pp. 1454–1477, 2023, doi: [10.1016/j.jfranklin.2022.11.004](https://doi.org/10.1016/j.jfranklin.2022.11.004).
- [18] V. Safari Dehnavi and M. Shafiee, "Data-driven control framework using fractional order singular optimal control and optimized metaheuristic algorithms," *Computers & Electrical Engineering*, Vol. 120, Art. No. 109728, 2024, doi: [10.1016/j.compeleceng.2024.109728](https://doi.org/10.1016/j.compeleceng.2024.109728).
- [19] H. Wang, J. Zheng, and J. Xiang, "Online bearing fault diagnosis using numerical simulation models and machine learning classifications," *Reliability Engineering & System Safety*, Vol. 234,

- [37] F. Pourdadashi Komachali *et al.*, “Design of unknown input fractional order proportional–integral observer for fractional order singular systems with application to actuator fault diagnosis,” *IET Control Theory & Applications*, Vol. 13, No. 14, pp. 2163–2172, 2019, doi: [10.1049/iet-cta.2018.5712](https://doi.org/10.1049/iet-cta.2018.5712).
- [38] V. S. Dehnavi and M. Shafiee, “LQR for generalized systems using metaheuristic algorithms based on disturbance observer,” in *Proc. 28th Iranian Conf. Electrical Engineering (ICEE)*, 2020, pp. 1–5, doi: [10.1109/ICEE50131.2020.9260723](https://doi.org/10.1109/ICEE50131.2020.9260723).
- [39] A. Safari Dehnavi and V. Safari Dehnavi, “Hardware-software cyber security platform for data protection in smart agricultural wireless sensor network with signal processing capability,” *Karafan Quarterly Scientific Journal*, in press, 2025, doi: [10.48301/kssa.2024.476579.2982](https://doi.org/10.48301/kssa.2024.476579.2982).
- [40] W. Jung *et al.*, “Vibration, acoustic, temperature, and motor current dataset of rotating machine under varying load conditions for fault diagnosis,” *Mendeley Data*, Vol. 6, 2023, doi: [10.17632/ZTMF3M7H5X.6](https://doi.org/10.17632/ZTMF3M7H5X.6).
- [41] M. Sehri and P. Dumond, “University of Ottawa electric motor dataset – vibration and acoustic faults under constant and variable speed conditions (UOEMD-VAFCVS),” *Mendeley Data*, Vol. 1, 2023, doi: [10.17632/MSXS4VJ48G.1](https://doi.org/10.17632/MSXS4VJ48G.1).
- [42] S. Adigintla and M. V. Aware, “Design and analysis of a speed controller for fractional-order-modeled voltage-source-inverter-fed induction motor drive,” *International Journal of Circuit Theory and Applications*, Vol. 50, pp. 2378–2397, 2022, doi: [10.1002/cta.3290](https://doi.org/10.1002/cta.3290).
- [43] M. Ertargin *et al.*, “Mechanical and electrical faults detection in induction motor across multiple sensors with CNN-LSTM deep learning model,” *Electrical Engineering*, 2024, doi: [10.1007/s00202-024-02420-w](https://doi.org/10.1007/s00202-024-02420-w).
- [44] Y. Li *et al.*, “Semi-supervised meta-path space extended graph convolution network for intelligent fault diagnosis of rotating machinery under time-varying speeds,” *Reliability Engineering & System Safety*, Vol. 251, Art. No. 110363, 2024.
- RNN technique,” *IETE Journal of Research*, pp. 1–10, 2024, doi: [10.1080/03772063.2024.2315199](https://doi.org/10.1080/03772063.2024.2315199).
- [29] C.-S. Tu *et al.*, “An audio-based motor-fault diagnosis system with SOM-LSTM,” *Applied Sciences*, Vol. 14, Art. No. 8229, 2024, doi: [10.3390/app14188229](https://doi.org/10.3390/app14188229).
- [30] J. Chuya-Sumba *et al.*, “Deep-learning method based on 1D convolutional neural network for intelligent fault diagnosis of rotating machines,” *Applied Sciences*, Vol. 12, No. 4, Art. No. 2158, 2022, doi: [10.3390/app12042158](https://doi.org/10.3390/app12042158).
- [31] S. Gao *et al.*, “Bearing fault diagnosis based on adaptive convolutional neural network with Nesterov momentum,” *IEEE Sensors Journal*, Vol. 21, No. 7, pp. 9268–9276, 2021, doi: [10.1109/JSEN.2021.3050461](https://doi.org/10.1109/JSEN.2021.3050461).
- [32] Z. Zhu *et al.*, “A review of the application of deep learning in intelligent fault diagnosis of rotating machinery,” *Measurement*, Vol. 206, Art. No. 112346, 2023, doi: [10.1016/j.measurement.2022.112346](https://doi.org/10.1016/j.measurement.2022.112346).
- [33] F. Wang *et al.*, “Cascade convolutional neural network with progressive optimization for motor fault diagnosis under nonstationary conditions,” *IEEE Transactions on Industrial Informatics*, Vol. 17, No. 4, pp. 2511–2521, 2020, doi: <https://doi.org/10.1109/TII.2020.3003353>.
- [34] P. Chen *et al.*, “An automatic speed adaption neural network model for planetary gearbox fault diagnosis,” *Measurement*, Vol. 171, Art. No. 108784, 2021, doi: [10.1016/j.measurement.2020.108784](https://doi.org/10.1016/j.measurement.2020.108784).
- [35] K. Sharma *et al.*, “Intelligent fault diagnosis of bearings based on convolutional neural network using infrared thermography,” *Proc. IMechE, Part J: Journal of Engineering Tribology*, Vol. 236, No. 12, pp. 2439–2446, 2022, doi: [10.1177/13506501221082746](https://doi.org/10.1177/13506501221082746).
- [36] X. Zhao *et al.*, “Intelligent fault diagnosis of gearbox under variable working conditions with adaptive intraclass and interclass convolutional neural network,” *IEEE Transactions on Neural Networks and Learning Systems*, Vol. 34, No. 9, pp. 6339–6353, 2022, doi: [10.1109/TNNLS.2021.3135877](https://doi.org/10.1109/TNNLS.2021.3135877).