



## Identification and damage detection of beam-like structure using vibration signals based on simulated model, real healthy state and deep convolutional neural network

Z. Mousavia<sup>1</sup>, M. M. Etefagh<sup>1\*</sup>, M. H. Sadeghi<sup>1</sup>, S. N. Razavi<sup>2</sup>

<sup>1</sup>Faculty of Mechanical Engineering, University of Tabriz, Tabriz, Iran

<sup>2</sup>Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

**ABSTRACT:** Condition monitoring of mechanical systems, such as structures and rotating machines is always a major challenge. This paper is presented a new method for damage detection of real mechanical systems in presence of the uncertainties such as modeling errors, measurement errors, varying loading conditions, and environmental noises based on a simulated model and real healthy state. In this method, data of a real healthy system is used to updating the parameters of the simulated model. Some parts of the signals that are not related to the nature of the system are removed using the complete ensemble empirical mode decomposition method. A deep convolutional network is designed to learn damage-sensitive features from raw frequency data of simulated model and real healthy state. Raw frequency data is extracted from vibration signals using the power spectral density method. In order to train the proposed deep network, raw frequency data of the simulated model and real healthy state are used. Then, raw frequency data of the real model are used to test the proposed deep network. The proposed method is validated using an experimental beam structure. The results show that using the proposed algorithm for identification and damage detection of the beam-like structure has more accuracy with respect to the other comparative methods.

### Review History:

Received: May, 12, 2019

Revised: Feb. 10, 2020

Accepted: May, 03, 2020

Available Online: May, 25, 2020

### Keywords:

Condition monitoring

Beam-like structure

Vibration signal

Deep neural network.

## 1- Introduction

Mechanical systems are widely used in the industrial sector and are key and important equipment. Condition monitoring of these systems is always a major challenge and can extend their lifespan. The vibrational signals extracted from mechanical systems contain useful information, and by examining the physical characteristics of these signals, damages can be detected in different parts of them. The forces applied to mechanical systems are subjected to many changes; therefore, data acquisition from mechanical systems under different loads is difficult and expensive. Also, in mechanical systems, the extraction of damage data is not really cost-effective, and generally only data on a healthy state is available; so, using artificial damage data based on simulated model instead of real ones is a feasible approach to addressing the problem [1].

Feature extraction plays a crucial role in the damage detection of mechanical systems. Traditional feature extraction methods are not well capable of extracting damage-sensitive features [2]. In recent years, the use of deep neural networks to extract the effective features has attracted the attention of many researchers [3]. Deep neural networks have been widely and successfully used for image and signal processing in the time and frequency domain [2, 4-5].

In this paper, a new method for damage detection of mechanical systems is presented. The first purpose of this paper is to present a method for damage detection of

mechanical systems in presence of the uncertainties such as modeling errors, measurement errors, varying loading conditions and environmental noises. The second purpose of this paper is to design a deep convolutional neural network in order to learn the damage-sensitive features from raw

frequency data of the simulated model and real healthy state despite the various uncertainties. The third aim of this paper is to train the proposed deep network based on frequency data of the simulated model under simple loading condition and real healthy state, and then to evaluate the deep network with frequency data of real model under complex loading condition (for more realistic assumptions). In the proposed method, the simulated model parameters are updated based on the real model data. Some parts of the vibration signals that are not related to the nature of the system have been removed using the Complete Ensemble Empirical Mode Decomposition (CEEMD) method. Frequency data are obtained from the vibration signals using the Power Spectral Density (PSD) method. To evaluate the proposed method, a beam-like structure in a laboratory environment has been used as a case study.

## 2- Methodology

In this section, at first the Finite Element (FE) and experimental models of the beam structure is explained. Then, the proposed algorithm for damage detection of the beam structure is expressed.

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






Fig. 1. The FE beam model.




Fig. 2. The experimental setup of the beam-like structure.

### 2-1- FE model

Considering the small deformations and linear behavior of the system, a FE model of the simply supported Euler-Bernoulli beam structure is created. The vibration equation of the beam can be written as follows [6-8]:

$$M_b \ddot{Z} + C_b \dot{Z} + K_b Z = F(t)$$

where  $Z$ ,  $\dot{Z}$  and  $\ddot{Z}$  are the displacement, velocity and acceleration vectors of the beam structure and  $M_b$ ,  $K_b$  and  $C_b$  displays the mass, stiffness and damping matrices of the whole structure, respectively. To solve the Eq. (1), the ode45 method is used in MATLAB software. The FE beam model is shown in Fig. 1.

The FE beam model is excited only from one point at node No. 8 with random excitation which is generated with white Gaussian noise.

### 2-2- Experimental model

Fig. 2 shows the experimental setup of the beam structure. Two shakers I and II are connected to the structure at nodes No. 5 and No. 8 to excite the structure. The uncorrelated forces used for excitation are white Gaussian noise. Two accelerometers I and II are mounted along the beam at nodes No. 6 and No. 7 for extracting the dynamic responses of the structure.

### 2-3- The proposed algorithm

In this section, the main procedure of the proposed algorithm based on deep learning is listed as follows (see Fig. 3):

- (a) Extracting the dynamic responses corresponding to different states of experimental and FE models.
- (b) Data preprocessing.
- (c) Removing some of the signal parts using the CEEMD method [9] and reconstructing the signals using the proper Intrinsic Mode Functions (IMFs).

- (d) Generating raw frequency data from dynamic responses using PSD method.
- (e) Dividing the data into three parts, namely training data based on FE model and experimental healthy state, validation data and testing data based on the experimental model.
- (f) Designing a deep convolutional neural network in order to learn the damage-sensitive features from raw frequency data of the FE model and experimental healthy state.
- (g) Investigating the performance of the proposed deep network to damage detection of experimental structure.

### 3- Results and Discussion

In this section, the damage detection of the beam structure under complex loading conditions with two random excitations using the proposed algorithm is checked after evaluating the accuracy of the FE model. In order to evaluate the accuracy of the FE model, the natural frequencies of the healthy structure are obtained and compared with each other using different methods [10] (see Table 1).

After ensuring that the FE model is accurate, the frequency data of the reconstructed signals of the FE model under a random excitation and the experimental healthy state is used as the training data of the proposed deep network to extracting the damage-sensitive features. Then, the frequency data of the reconstructed signals of the experimental model under two random excitations is used to evaluating the proposed deep network. The confusion matrix of the proposed algorithm is shown in Table 2. A network [11] with two hidden layers is used to compare the results of the proposed algorithm. Table 3 presents the accuracy of the proposed algorithm compared to the other methods. The results show that the proposed method is able to detect the damages of the real structure with more accuracy with respect to the other comparative methods.

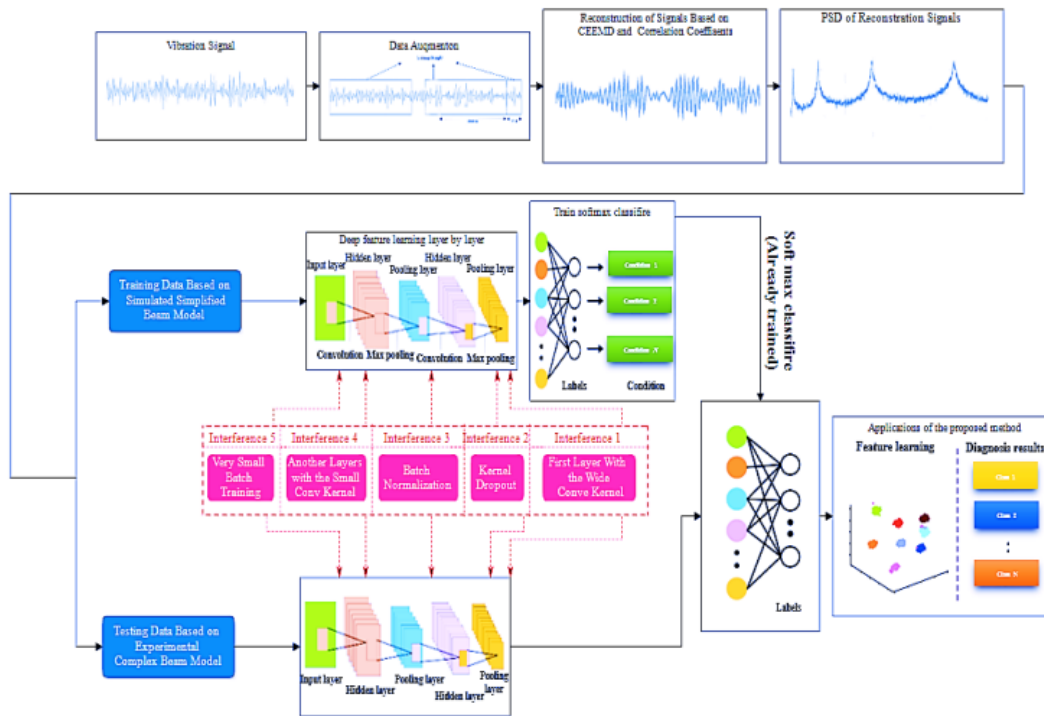


Fig. 3. The block diagram of the proposed algorithm.

Table 1. Comparison of the obtained natural frequencies for the healthy structure using different methods.

Mode No.	Natural Frequency (Hz)			Error (%)		
	Analytical Solution	Experimental Model	FE Model	Experimental Model	FE Model	FE compared with Experimental
		PSD	PSD	PSD - Analytical	PSD - Analytical	PSD-PSD
1	35.81	38	38	6.11	6.11	0.0
2	143.26	136	140	5.06	2.27	2.9
3	322.34	344	324	6.71	0.51	5.8
4	473.06	472	472	0.2	0.2	0.0
5	895.41	880	880	1.7	1.7	0.0

Table 2. Classes and lumped become non-italic.

Considered States	Classes	Class 1	Class 2	Class 3	Class 4	Class 5	Accuracy%
Healthy	Class 1	106	0	0	0	0	100
Damaged (Added lumped mass with severity 0.1 kg in element 3)	Class 2	0	106	0	0	0	100
Damaged (Added lumped mass with severity 0.2 kg in element 3)	Class 3	0	0	105	0	0	99.06
Damaged (Added lumped mass with severity 0.1 kg in element 8)	Class 4	0	0	0	106	0	100
Damaged (Added lumped mass with severity 0.2 kg in element 8)	Class 5	0	0	0	5	101	95.28

**Table 3. The accuracy of the proposed algorithm compared to the comparative methods.**

Methods	Feature learning from raw data	Accuracy%
Perceptron Network	Frequency data of vibration signals	75.85 ± 2.2
Perceptron Network	Frequency data of reconstructed vibration signals	81.70 ± 2.5
Proposed Network	Frequency data of vibration signals	94.53 ± 4.1
Proposed Network	Frequency data of reconstructed vibration signals	<b>98.87 ± 5.3</b>

#### 4- Conclusions

This paper is proposed a new method for damage detection of mechanical systems in the presence of different uncertainties based on the FE model, real healthy state, and deep neural network. The FE model parameters are updated on the basis of a real healthy state. Some parts of the signals which are not related to the nature of the system are removed using the CEEMD method. To train the proposed deep network, only the frequency data of the FE model and the real healthy state are used. After that, the frequency data of the real model are used to evaluate the proposed network. Frequency data is extracted from vibration signals using PSD method. Two major interferences affect the proposed network, namely the wide kernel in the first convolution layer and the small kernels in the remaining convolutional layers. A beam structure in the laboratory environment is used to evaluate the proposed method. The results show that the proposed network is able to detect the damages of the real structure using the FE model data and the real healthy state.

#### References

- [1] Y. Chen, G. Peng, C. Xie, W. Zhang, C. Li, S. Liu, ACDIN: Bridging the gap between artificial and real bearing damages for bearing fault diagnosis, *Neurocomputing*, 294 (2018) 61-71.
- [2] L. Jing, M. Zhao, P. Li, X. Xu, A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox, *Measurement*, 111 (2017) 1-10.[3]
- [3] H. Adeli, X. Jiang, *Intelligent infrastructure: neural networks, wavelets, and chaos theory for intelligent transportation systems and smart structures*, CRC press, 2008.
- [4] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, R.X. Gao, Deep learning and its applications to machine health monitoring, *Mechanical Systems and Signal Processing*, 115 (2019) 213-237.[5]F. Jia, Y. Lei, J. Lin, X. Zhou, N. Lu, Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data, *Mechanical Systems and Signal Processing*, 72 (2016) 303-315.
- [5] ]W. Weaver Jr, P.R. Johnston, *Structural dynamics by finite elements*, Prentice-Hall Englewood Cliffs (NJ), 1987.
- [6] I. Chowdhury, S.P. Dasgupta, Computation of Rayleigh damping coefficients for large systems, *The Electronic Journal of Geotechnical Engineering*, 8(0) (2003) 1-11.
- [7] S. Wu, S. Law, Vehicle axle load identification on bridge deck with irregular road surface profile, *Engineering Structures*, 33(2) (2011) 591-601.
- [8] M.E. Torres, M.A. Colominas, G. Schlotthauer, P. Flandrin, A complete ensemble empirical mode decomposition with adaptive noise, in: 2011 IEEE international conference on acoustics, speech and signal processing (ICASSP), IEEE, 2011, pp. 4144-4147.
- [9] S.S. Rao, F.F. YAP, *Upper Saddle River: Mechanical vibrations*, in, Prentice Hall, 2011.
- [10] M. Hagan, H. Demuth, M. Beale, O. De Jesús, *Neural network design vol. 20: Pws Pub*, in, Boston, 1996.
- [11] W. Zhang, C. Li, G. Peng, Y. Chen, Z. Zhang, A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load, *Mechanical Systems and Signal Processing*, 100 (2018) 439-453.

#### HOW TO CITE THIS ARTICLE

Z. Mousavia, M.M. Etefagh, M.H. Sadeghi, S.N. Razavi, *Identification and damage detection of beam-like structure using vibration signals based on simulated model, real healthy state and deep convolutional neural network*, *Amirkabir J. Mech. Eng.*, 53(4) (2021) 523-526.

DOI: [10.22060/mej.2020.17380.6586](https://doi.org/10.22060/mej.2020.17380.6586)





## شناسایی و عیب‌یابی سازه تیری شکل با استفاده از سیگنال‌های ارتعاشی بر پایه مدل شبیه‌سازی شده، حالت سالم واقعی و شبکه عصبی کانولوشنال عمیق

زهره موسوی<sup>۱</sup>، میر محمد اتفاق<sup>۱\*</sup>، مرتضی همایون صادقی<sup>۱</sup>، سید ناصر رضوی<sup>۲</sup>

۱- دانشکده مهندسی مکانیک، دانشگاه تبریز، تبریز، ایران  
۲- دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

### تاریخچه داوری:

دریافت: ۱۳۹۸/۰۸/۲۲

بازنگری: ۱۳۹۸/۱۱/۲۱

پذیرش: ۱۳۹۹/۰۲/۱۴

ارائه آنلاین: ۱۳۹۹/۰۳/۰۵

### کلیمات کلیدی:

پایش وضعیت

سازه تیری شکل

سیگنال ارتعاشی

شبکه عصبی عمیق

**خلاصه:** پایش وضعیت سیستم‌های مکانیکی اعم از سازه‌ها، ماشین‌های دوار همواره یکی از چالش‌های مهم محسوب می‌شود. در این مقاله روش جدیدی برای شناسایی و عیب‌یابی سازه تیری شکل در حضور عدم قطعیت‌هایی مانند خطاهای مدل‌سازی، خطاهای اندازه‌گیری، تغییرات بارگذاری و نویزهای محیطی بر پایه مدل شبیه‌سازی شده و حالت سالم واقعی ارائه شده است. در این روش، داده‌های سیستم سالم واقعی برای به‌روزرسانی پارامترهای مدل شبیه‌سازی شده استفاده شده است. برخی از بخش‌های سیگنال که مربوط به ذات سیستم نیستند با استفاده از روش تجزیه مود تجربی دسته‌ای کامل، حذف شده‌اند. یک شبکه عصبی کانولوشنال عمیق، به‌منظور یادگیری ویژگی‌های حساس به عیب از داده خام فرکانسی مدل شبیه‌سازی شده و حالت سالم واقعی طراحی شده است. داده‌های خام فرکانسی با استفاده از روش چگالی طیفی توان از سیگنال‌های ارتعاشی استخراج شده‌اند. به‌منظور آموزش شبکه عمیق پیشنهادی از داده‌های خام فرکانسی مدل شبیه‌سازی شده و حالت سالم واقعی استفاده می‌شود. پس از آن داده‌های خام فرکانسی مدل واقعی برای ارزیابی شبکه عمیق پیشنهادی استفاده می‌شود. روش پیشنهادی با استفاده از سازه تیری شکل آزمایشگاهی ارزیابی شده است. نتایج حاصل نشان می‌دهد که استفاده از الگوریتم پیشنهادی برای شناسایی و عیب‌یابی سازه تیری شکل صحت بالاتری نسبت به سایر روش‌های مقایسه‌ای دارد.

### ۱- مقدمه

از عوامل مختلفی مانند افزایش بارگذاری و تغییر شرایط محیطی هستند. انجام تست‌های تجربی برای سیستم‌های مکانیکی پیچیده واقعی به‌خصوص در حالت‌های معیوب، بسیار پرهزینه است، از این رو با گسترش سیستم‌های کامپیوتری، استفاده از مدل‌سازی دینامیکی به‌منظور شناسایی و عیب‌یابی سیستم‌های مکانیکی می‌تواند ضمن کاهش هزینه‌ها، راهکاری مفید باشد.

در سال‌های اخیر استفاده از شبکه‌های عصبی<sup>۱</sup> به‌ویژه شبکه‌های عصبی عمیق<sup>۲</sup> مورد توجه بسیاری از محققان قرار گرفته است [۱]. عملکرد شبکه‌های عصبی تا حد زیادی تحت تأثیر ویژگی‌های ورودی

سیستم‌های مکانیکی به‌طور گسترده در صنعت به کار گرفته شده‌اند و از جمله تجهیزات کلیدی و مهم به شمار می‌آیند. سیگنال‌های ارتعاشی گرفته‌شده از این سیستم‌ها حاوی اطلاعات مفیدی بوده و با بررسی ویژگی‌های فیزیکی این سیگنال‌ها، می‌توان به وجود عیب در بخش‌های مختلف آن‌ها پی برد. پایش وضعیت سیستم‌های مکانیکی، روندی است که با تشخیص به‌موقع عیب در قسمت‌های مختلف سیستم، می‌توان از توقف کامل و بروز خسارات جانی و مالی جلوگیری کرد. پایش وضعیت سیستم‌های مکانیکی می‌تواند باعث کاهش آسیب‌ها و افزایش طول عمر آن‌ها شود. این آسیب‌ها ناشی

1 Artificial Neural Networks (ANNs)

2 Deep Neural Networks (DNNs)

\* نویسنده‌دار مکاتبات: ettefagh@tabrizu.ac.ir



هستند، لذا نقاط ضعف در ویژگی‌های ورودی مانند حساسیت به نویز، ممکن است که از عملکرد بهتر شبکه‌های عصبی جلوگیری نماید. شبکه‌های عصبی عمیق به‌طور گسترده و با موفقیت‌های زیادی در پردازش تصویر و سیگنال‌ها در حوزه زمان و فرکانس مورد استفاده قرار گرفته است [۲-۴]. الگوریتم‌های یادگیری عمیق زیرمجموعه‌ای از الگوریتم‌های یادگیری ماشین هستند که هدف آن‌ها کشف چندین سطح از بازنمایی توزیع شده از داده‌های ورودی است. برخی از مزایای الگوریتم‌های یادگیری عمیق نسبت به الگوریتم‌های یادگیری ماشین عبارت‌اند از؛ در این الگوریتم‌ها به‌صورت خودکار استخراج ویژگی‌ها و کاهش آن‌ها صورت می‌پذیرد، همچنین دقت این الگوریتم‌ها نسبت به الگوریتم‌های یادگیری ماشین بیشتر است. در مقابل این مزایا، این الگوریتم‌ها معایبی نیز دارند که برخی از این معایب عبارت‌اند از؛ این الگوریتم‌ها نیازمند مجموعه داده‌های آموزشی نسبتاً زیادی هستند که جمع‌آوری داده‌های حجیم امری زمان‌بر است.

داده‌های سیستم‌های مکانیکی را می‌توان به دو دسته کلی مصنوعی و واقعی تقسیم کرد. داده‌های واقعی را می‌توان از سیستم‌های واقعی یا سیستم‌های آزمایشگاهی به‌دست آورد. عبدالجابر و همکاران [۵] از شبکه عصبی کانولوشنال عمیق<sup>۱</sup> برای شناسایی عیوب سازه خرابا شکل استفاده کردند. آن‌ها بیان کردند که روش پیشنهادی آن‌ها، علاوه بر اینکه ویژگی‌ها را به‌صورت خودکار استخراج می‌کند، دقت بالاتری نیز نسبت به پژوهش‌های پیشین دارد. در پژوهش‌های پیشین شبکه‌های عمیق برای آموزش، نیازمند اندازه‌گیری‌های قابل‌توجهی به‌ویژه در سازه‌های بزرگ بودند، لذا به‌منظور غلبه بر این محدودیت، آن‌ها روشی مبتنی بر شبکه کانولوشنال ارائه دادند که نیاز به دو مجموعه اندازه‌گیری، صرف‌نظر از اندازه سازه داشت. جی و همکاران [۶] از یک شبکه عصبی عمیق خود رمزنگار<sup>۲</sup> برای تشخیص عیوب ماشین‌آلات دوار استفاده کردند. آن‌ها بیان کردند که این شبکه توانایی بالایی در استخراج ویژگی‌های عیب از سیگنال‌های ارتعاشی، به‌صورت خودکار دارد. در این پژوهش از سیگنال‌های جعبه‌دنده و یاتاقان برای اعتبارسنجی استفاده شده است. روش ارائه‌شده نشان داد که ویژگی‌های آموخته‌شده معنی‌دار، غیرتکراری و تغییرناپذیر بوده، لذا برای پایش وضعیت سیستم‌های

مکانیکی بسیار مؤثر هستند. در آخر با مقایسه این روش با روش‌های تشخیصی که معمولاً استفاده می‌شوند، برتر بودن روش پیشنهادی تأیید شد. ژانگ و همکاران [۷] یک مدل جدید یادگیری عمیق را برای تشخیص عیوب مختلف ماشین دوار تحت محیط نویزی ارائه دادند. آن‌ها از سیگنال ارتعاشی بدون هیچ‌گونه پردازشی به‌عنوان ورودی شبکه استفاده کردند. در این پژوهش بارگذاری‌های داده‌های آموزش و آزمایش متفاوت بودند. آن‌ها از فیلترهایی با سایز بزرگ در لایه اول کانولوشنال برای استخراج ویژگی‌های مطلوب و سرکوب نویزهای فرکانس بالا و از فیلترهای با سایز کوچک برای بقیه لایه‌های کانولوشنال استفاده کردند. همچنین برای سازگاری محیط داده‌های آزمایش با مدل پیشنهادی از ویژگی‌های آماری داده‌های آزمایش در مدل نیز استفاده کردند. نتایج نشان داد که روش پیشنهادی از دقت بالایی نسبت به مطالعات پیشین برخوردار است. جینگ و همکاران [۳] روشی را بر پایه یادگیری عمیق برای عیب‌یابی ماشین دوار ارائه دادند. در این پژوهش یک شبکه کانولوشنال عمیق برای یادگیری ویژگی‌ها از داده‌های فرکانسی سیگنال‌های ارتعاشی ارائه شد. نتایج روش پیشنهادی با داده‌های زمانی و زمان-فرکانسی نیز مقایسه شد و نتایج نشان داد که روش پیشنهادی قادر است ویژگی‌ها را از داده‌های فرکانسی به‌طور خودکار استخراج کند و دقت بالاتری نسبت به روش‌های مقایسه‌ای به‌دست آورد. از آنجاکه استخراج داده‌های معیوب سازه واقعی تحت بارگذاری‌های مختلف عملاً غیرممکن است، لذا استفاده از روش‌های مبتنی بر داده واقعی، رفته‌رفته در حال کاهش است؛ بنابراین استفاده از داده‌های مصنوعی بر پایه مدل دینامیکی شبیه‌سازی شده می‌تواند راه‌حل مفیدی باشد.

مدل شبیه‌سازی شده بر پایه المان محدود که به‌صورت شناخته‌شده امروزی است، توسط تورنر و همکارانش برای تحلیل سازه هواپیما استفاده شد و به‌عنوان یکی از پیشرفت‌های کلیدی در توسعه روش عناصر محدود ارائه شد [۸]. لین و همکاران [۹] به بررسی تشخیص عیوب سازه تیری شکل و استخراج ویژگی‌ها با استفاده از یادگیری عمیق پرداختند. آن‌ها پاسخ‌های دینامیکی را برای سناریوهای مختلف عیب از طریق مدل المان محدود به‌دست آوردند و نشان دادند که در شبکه‌های عمیق کانولوشنال لایه‌ها به‌عنوان فیلترهای عبور باند نقش دارند که مرکز آن‌ها فرکانس‌های طبیعی سازه است. همچنین نشان دادند که وقتی لایه‌ها عمیق‌تر می‌شوند، شبکه حتی مفهوم مود

1 Deep Convolutional Neural Network (DCNN)

2 Autoencoder (AE)


سیستم واقعی را با دقت نسبتاً خوبی پیش‌بینی کرد. فلاحیان و همکاران [۱۳] روشی را برای ارزیابی عیوب سازه‌ها تحت تغییرات دما ارائه دادند. در این مطالعه، از یک روش ترکیبی بر پایه شبکه‌های عمیق استفاده شد. روش بیان‌شده با مدل عددی به‌روزرسانی شده سازه پل و داده‌های آزمایشگاهی این سازه ارزیابی شد. نتایج نشان داد که روش ارائه‌شده در تشخیص عیوب سازه تحت تغییرات دما نسبت به روش‌های مقایسه‌ای عملکرد بهتری دارد.

بر اساس مطالعات پیشین، به‌طور کلی استخراج داده‌های معیوب از سیستم‌ها به دو صورت انجام شده است؛ (۱) استخراج داده‌ها از سیستم واقعی یا سیستم آزمایشگاهی؛ استخراج داده‌های معیوب از سیستم واقعی عملاً امکان‌پذیر نیست و به‌طور کلی فقط داده‌های حالت سالم را می‌توان از آن استخراج نمود. همچنین ساخت سیستم‌های پیچیده مکانیکی در آزمایشگاه و استخراج داده‌ها از آن‌ها عملاً غیرممکن و پرهزینه است و فقط می‌توان سازه‌های ساده دینامیکی را در آزمایشگاه مدل کرد. (۲) استخراج داده‌ها از مدل دینامیکی شبیه‌سازی‌شده؛ بین پاسخ دینامیکی سیستم‌های واقعی مکانیکی با پاسخ دینامیکی گرفته‌شده از مدل شبیه‌سازی‌شده به دلیل عدم قطعیت‌های موجود مانند خطاهای مدل‌سازی، خطاهای اندازه‌گیری، تغییرات بارگذاری و نویزهای محیطی تا حدی اختلاف وجود دارد. در بیشتر مطالعات پیشین برای نزدیک کردن پاسخ‌های دینامیکی مدل ساده شبیه‌سازی‌شده به مدل واقعی از روش به‌روزرسانی پارامترهای مدل شبیه‌سازی‌شده استفاده شده است. نحوه به‌روزرسانی پارامترهای مدل دینامیکی یا از طریق مقایسه داده‌های سالم و معیوب مدل دینامیکی با داده‌های سالم و معیوب مدل واقعی، یا با مقایسه داده‌های سالم مدل دینامیکی با داده‌های سالم مدل واقعی انجام می‌گیرد. همان‌طور که بیان شد استخراج داده‌های معیوب از مدل واقعی پرهزینه و عملاً غیرممکن است؛ بنابراین، استفاده از داده‌های معیوب برای به‌روزرسانی مدل شبیه‌سازی‌شده عملاً امکان‌پذیر نیست. همچنین می‌توان بیان کرد که بیشتر ویژگی‌های ارائه‌شده در ادبیات فن بر پایه پردازش سیگنال و آمار ویژگی‌های بهینه‌ای نیستند، زیرا حتی محققین باتجربه ممکن است مدت‌زمان زیادی را برای آزمایش اینکه، کدام شاخص آماری یا کدام روش پردازش سیگنال و یا مشتقات آن‌ها، به عیب سازه حساس هستند، اختصاص دهند. همچنین استخراج ویژگی‌ها از یک سیستم مکانیکی به سیستم مکانیکی دیگر

سازه‌ای را نیز به‌صورت مستقل یاد می‌گیرد. آن‌ها بیان کردند که روش پیشنهادی ارائه‌شده قابل‌اعمال و تعمیم به سیستم‌های مکانیکی دیگر نیز است. جو و همکاران [۱۰] روشی برای تشخیص عیوب سازه جکت دریایی<sup>۱</sup> با استفاده از پارامترهای مودال و شبکه‌های عصبی پیشنهاد دادند. آن‌ها با استفاده از مدل المان محدود سازه جکت، سناریوهای عیب را با کاهش مدول الاستیسیته در المان‌ها، ایجاد کردند و از پارامترهای مودال مدل المان محدود به‌عنوان ورودی شبکه استفاده کردند. نتایج نشان داد که روش ذکرشده از دقت قابل‌توجهی برخوردار است. یکی از مشکلاتی که در حین استفاده از مدل شبیه‌سازی‌شده به‌جای سیستم واقعی پیش می‌آید، اختلاف بین داده‌های مدل شبیه‌سازی‌شده با داده‌های سیستم واقعی است. با استفاده از تکنیک به‌روزرسانی پارامترهای مدل شبیه‌سازی‌شده بر پایه داده حالت سالم واقعی، می‌توان تا حدی مدل شبیه‌سازی‌شده را به سیستم واقعی نزدیک کرد و درنهایت ویژگی‌های مشترک بین آن‌ها را به‌دست آورد.

روش‌های سنتی استخراج ویژگی، به‌خوبی قادر به استخراج ویژگی‌های حساس به عیب که بین مدل شبیه‌سازی‌شده و سیستم واقعی مشترک باشند، نیستند؛ بنابراین استفاده از روش‌های که بتوانند ویژگی‌های حساس به عیب را به‌صورت خودکار از داده‌ها استخراج نمایند، امری ضروری تلقی می‌گردد. جو و همکاران [۱۱] به بررسی شناسایی عیب سازه تیری‌شکل بر پایه مدل المان محدود، تحت شرایط دمایی مختلف با استفاده از شبکه‌های عصبی پرداختند. در این پژوهش از تغییرات دما همراه با فرکانس‌های طبیعی به‌عنوان ورودی شبکه استفاده شده است. آن‌ها از یک شاخص جدید برای تشخیص اختلاف بین الگوهای حالت سالم و معیوب استفاده کردند. برای ارزیابی روش بیان‌شده، از یک سازه تیری شکل آزمایشگاهی استفاده شد. نتایج نشان داد که روش پیشنهادی همراه با شاخص جدید ارائه‌شده، توانایی تشخیص عیوب سازه آزمایشگاهی تحت تغییرات دما و محیط نویزی را دارد. چن و همکاران [۱۲] اختلاف بین داده‌های واقعی و مصنوعی را برای تشخیص عیب یاتاقان بر پایه شبکه عصبی عمیق مورد بررسی قرار دادند. در این شبکه، سیگنال‌های خام به‌عنوان ورودی شبکه عمیق استفاده شدند. نتایج نشان داد که با آموزش شبکه عمیق با داده‌های عیب مصنوعی، می‌توان عیب‌های

1 Offshore jacket structure



شکل ۱. المان خمشی [14].

Fig. 1. Bending element [14].

فقط داده حالت سالم در اختیار است، بنابراین ارائه‌دادن روشی برای عیب‌یابی سیستم‌های مکانیکی بر پایه عیب‌های شبیه‌سازی شده و داده حالت سالم واقعی، لازم و ضروری است. بر این اساس، سومین هدف این مقاله آموزش دادن شبکه عمیق پیشنهادی بر اساس داده‌های فرکانسی مدل شبیه‌سازی شده تحت بارگذاری ساده و حالت سالم واقعی است و سپس ارزیابی شبکه عمیق با داده‌های فرکانسی مدل واقعی تحت بارگذاری پیچیده‌تر (به‌منظور فرضیات واقع‌بینانه‌تر) است. در روش پیشنهادی، به‌روزرسانی پارامترهای مدل شبیه‌سازی شده بر پایه داده‌های سالم مدل واقعی انجام گرفته است. برخی از بخش‌های سیگنال‌ها که مربوط به ذات سیستم نیستند با استفاده از روش تجزیه مود تجربی دسته‌ای کامل<sup>۱</sup> حذف شده‌اند. داده‌های فرکانسی با استفاده از روش چگالی طیفی توان<sup>۲</sup> از سیگنال‌های ارتعاشی به‌دست آمده‌اند. برای ارزیابی روش پیشنهادی از سازه تیری شکل در محیط آزمایشگاهی تحت بارگذاری پیچیده به‌عنوان یک مطالعه موردی استفاده شده است.

ادامه مقاله به‌صورت زیر تدوین شده است؛ در بخش ۲ مواد و روش‌ها بررسی خواهند شد. در بخش ۳، الگوریتم پیشنهادی مورد

متفاوت بوده و نمی‌توان بیان کرد که ویژگی‌های انتخابی برای یک مسئله برای مسئله دیگر هم قابل قبول است؛ بنابراین استفاده از روش‌های که بتوانند ویژگی‌های حساس به عیب را به‌صورت خودکار از داده‌های هر سیستم استخراج نمایند، امری ضروری تلقی می‌گردد. بر اساس مشکلات ارائه‌شده در مطالعات پیشین، در این مقاله روش جدیدی برای پایش وضعیت سیستم‌های مکانیکی ارائه شده است. اولین هدف این مقاله ارائه‌دادن روشی برای عیب‌یابی سیستم‌های مکانیکی در حضور عدم قطعیت‌هایی مانند خطاهای مدل‌سازی، خطاهای اندازه‌گیری، تغییرات بارگذاری و نویزهای محیطی است. همان‌طور که بیان شد یادگیری عمیق به‌طور گسترده و با موفقیت‌های زیادی در پردازش تصویر و سیگنال‌ها در حوزه زمان و فرکانس مورد استفاده قرار گرفته است. یکی از مزایای استفاده از یادگیری عمیق این است که در حضور عدم قطعیت مختلف می‌تواند ویژگی‌های حساس به عیب را از داده‌ها بیاموزد. بر این اساس، دومین هدف این مقاله طراحی یک شبکه عصبی کانولوشنال عمیق، به‌منظور یادگیری ویژگی‌های حساس به عیب از داده فرکانسی خام و عیب‌یابی سیستم مکانیکی واقعی در حضور عدم قطعیت‌های مختلف طراحی شده است. در محیط‌های صنعتی جمع‌آوری داده‌های معیوب تحت بارگذاری‌های مختلف دشوار و حتی غیرممکن است و به‌طور کلی

1 Complete Ensemble Empirical Mode Decomposition (CEEMD)

2 Power spectral Density (PSD)



با استفاده از همین روش می‌توان نیروهای گره‌ای را نیز به‌دست آورد:

$$p(t) = \{p_1, p_2, p_3, p_4\} = \{p_{y1}, M_{z1}, p_{y2}, M_{z2}\} \quad (4)$$

عبارات  $p_{y1}$  و  $p_{y2}$  نشانگر نیرو در جهت  $y$  و نمادهای  $M_{z1}$  و  $M_{z2}$  نشانگر گشتاور در جهت  $z$  در آن نقاط هستند. برای المان خمشی شکل ۱ یک ماتریس تابع شکل مکعبی به‌صورت رابطه زیر در نظر گرفته می‌شود [۱۴]:

$$H = \begin{Bmatrix} f_1 \\ f_2 \\ f_3 \\ f_4 \end{Bmatrix} = \begin{Bmatrix} 2\frac{x^3}{L^3} - 3\frac{x^2}{L^2} + 1 \\ \frac{x^3}{L^2} - 2\frac{x^2}{L} + x \\ -2\frac{x^3}{L^3} + 3\frac{x^2}{L^2} \\ \frac{x^3}{L^2} - \frac{x^2}{L} \end{Bmatrix} \quad (5)$$

این چهار تابع شکل در شکل ۱ قابل‌مشاهده هستند و  $L$  طول المان است. این توابع شکل نشان‌دهنده تغییرات  $v$  در راستای طول المان به علت مقادیر واحد جابه‌جایی‌های گره‌ای  $q_1$  تا  $q_4$  است. این توابع شکل که از روش درون‌یابی به‌دست‌آمده‌اند، به توابع شکل مکعبی درون‌یاب هرمیتی<sup>۱</sup> معروف هستند. ماتریس‌های جرم و سفتی المان‌های تیر با استفاده از توابع شکل درون‌یاب هرمیتی قابل‌استخراج هستند در نتیجه برای هر المان خواهیم داشت [۱۴]:

$$M_e = \frac{\rho AL}{420} \begin{bmatrix} 156 & 22L & 54 & -13L \\ 22L & 4L^2 & 13L & -3L^2 \\ 54 & 13L & 156 & -22L \\ -13L & -3L^2 & -22L & 4L^2 \end{bmatrix} \quad (6)$$

استفاده در این مقاله ارائه داده می‌شود. در بخش ۴ نتایج شبیه‌سازی و مقایسه با روش‌های دیگر مورد بحث قرار می‌گیرد؛ در نهایت، بخش ۵ مربوط به نتیجه‌گیری است.

## ۲- مواد و روش‌ها

در این بخش در ابتدا مدل‌سازی دینامیکی و آزمایشگاهی سازه تیری شکل، به‌عنوان یک مطالعه موردی، شرح داده می‌شود. پس از آن روش تجزیه مود تجربی دسته‌ای کامل، شبکه‌های عصبی مصنوعی و شبکه‌های عصبی کانولوشنال بررسی خواهند شد.

### ۲-۱- مدل‌سازی سازه تیری شکل با روش المان محدود

با در نظر گرفتن تغییر شکل‌های کوچک و رفتار خطی سیستم، یک مدل المان محدود "اولیه" از تیر اویلر-برنولی دو سر مفصل با استفاده از نرم‌افزار متلب ایجاد شده است. اصطلاح "اولیه" نشان می‌دهد که مدل المان محدود به دلیل عدم قطعیت‌های مختلف می‌تواند دقیق نباشد؛ بنابراین، مدل اولیه مبنایی برای به‌روزرسانی پارامترهای مدل در نظر گرفته می‌شود. شکل ۱ یک المان خمشی را نشان می‌دهد که صفحه  $xy$  صفحه اصلی خمش است [۱۴]. مطابق شکل ۱ جابه‌جایی کلی  $v$  در جهت  $y$  حرکت می‌کند؛ بنابراین:

$$u(t) = v \quad (1)$$

یک نیروی متناظر  $b_y$  (نیروی واحد طول) نیز در جهت  $y$  اثر می‌کند؛ بنابراین:

$$b(t) = b_y \quad (2)$$

در شکل ۱ در گره ۱ دو جابه‌جایی‌های گره‌ای  $q_1$  و  $q_2$  داریم که حرکت انتقالی در جهت  $y$  و  $q_2$  چرخش در جهت  $z$  است. به‌طور مشابه در گره ۲ جابه‌جایی‌های گره‌ای  $q_3$  و  $q_4$  را داریم؛ بنابراین بردار جابه‌جایی را می‌توان به این صورت نوشت:

$$q(t) = \{q_1, q_2, q_3, q_4\} = \{v_1, \theta_{z1}, v_2, \theta_{z2}\} \quad (3)$$

که  $\theta_{z1} = \frac{dv_1}{dx}$  و  $\theta_{z2} = \frac{dv_2}{dx}$  است.

که در رابطه قبل  $Z$ ،  $\dot{Z}$  و  $\ddot{Z}$  به ترتیب بردارهای جابه‌جایی، سرعت و شتاب گره‌های سازه تیری شکل هستند. جهت حل معادله (۱۱) از روش ode45 در نرم‌افزار متلب استفاده می‌شود؛ بنابراین باید معادلات به فرم قابل حل برای متلب استخراج شوند. فرم قابل حل برای دستور ode45 به صورت  $\dot{Y} = T(Y, t)$  است. لذا باید معادله (۱۱) به این فرم بازنویسی شود. بدین منظور چنین فرض می‌شود:

$$Z = Y_1 \quad \& \quad \dot{Z} = Y_2 \quad (12)$$

پس خواهیم داشت:

$$\dot{Y}_1 = Y_2 \quad (13)$$

همچنین در این صورت معادله (۱۱) به صورت زیر بازنویسی می‌شود:

$$M_b \dot{Y}_2 + C_b Y_2 + K_b Y_1 = F(t) \quad (14)$$

حال اگر معادله (۱۴) به صورت ماتریسی نوشته شود، خواهیم داشت:

$$\begin{bmatrix} I_n & 0 \\ 0 & M_b \end{bmatrix} \begin{Bmatrix} \dot{Y}_1 \\ \dot{Y}_2 \end{Bmatrix} + \begin{bmatrix} 0 & -I_n \\ K_b & C_b \end{bmatrix} \begin{Bmatrix} Y_1 \\ Y_2 \end{Bmatrix} = \begin{Bmatrix} 0 \\ F(t) \end{Bmatrix} \quad (15)$$

در نهایت معادله به صورت زیر نوشته می‌شود:

$$K_e = \frac{2EI}{L^3} \begin{bmatrix} 6 & 3L & -6 & 3L \\ 3L & 2L^2 & -3L & L^2 \\ -6 & -3L & 6 & -3L \\ 3L & L^2 & -3L & 2L^2 \end{bmatrix} \quad (7)$$

که در آن  $E$ ،  $\rho$ ،  $A$ ،  $I$  به ترتیب ممان اینرسی، مساحت سطح مقطع، چگالی و مدول یانگ را نشان می‌دهند. معمولاً در سیستم‌ها با درجات آزادی بالا ماتریس دمپینگ به صورت مجموع ضرایبی از ماتریس‌های جرم و سفتی به صورت زیر تعریف می‌شود [۱۵]:

$$[C_b] = \bar{\alpha} [M_b] + \bar{\beta} [K_b] \quad (8)$$

که به این نوع میرایی، میرایی تناسبی می‌گویند.  $M_b$ ،  $K_b$  و  $C_b$  به ترتیب ماتریس جرم، سفتی و میرایی کل سازه را نشان می‌دهند. برای سیستم با درجات آزادی بالا، حدس اولیه منطقی برای ضرایب  $\bar{\alpha}$  و  $\bar{\beta}$  مربوط به میرایی تناسبی دشوار است. برای غلبه کردن بر این مشکل می‌توان تخمین منطقی مقادیر  $\bar{\alpha}$  و  $\bar{\beta}$  را به صورت زیر ارائه نمود [۱۵]:


$$\bar{\beta} = \frac{2\xi_1 \omega_1 - 2\xi_2 \omega_2}{\omega_1^2 - \omega_2^2} \quad (9)$$

و با جایگذاری  $\bar{\beta}$  در فرمول زیر مقدار  $\bar{\alpha}$  نیز به دست می‌آید:

$$2\xi_1 \omega_1 = \bar{\alpha} + \bar{\beta} \omega_1^2 \quad (10)$$

که در فرمول‌های بالا  $\xi_1$  نسبت دمپینگ برای مود اول سیستم،  $\omega_1$  فرکانس طبیعی اول سیستم،  $\xi_2$  نسبت دمپینگ برای مود دوم سیستم و  $\omega_2$  فرکانس طبیعی دوم سیستم است. با در نظر گرفتن میرایی تناسبی برای سازه تیری شکل و اعمال شرایط مرزی، معادله ارتعاشی کل تیر را می‌توان به صورت زیر نوشت [۱۶]:

$$M_b \ddot{Z} + C_b \dot{Z} + K_b Z = F(t) \quad (11)$$



شکل ۲: مدل المان محدود تیر  
**Fig. 2. The FE beam model.**




شکل ۳. تجهیزات آزمایشگاهی: (۱) سیستم جمع‌آوری داده پالس (۲) لرزاننده (۳) شتاب‌سنج (۴) نیروسنج (۵) لپ‌تاپ (۶) آمپلی‌فایر (۷) کابل‌های انتقال.

**Fig. 3. Experimental equipment: (1) Pulse Data acquisition (2) shaker (3) accelerometer (4) force transducer (5) windows-based laptop (6) power amplifier (7) signal transfer cable.**

در این مقاله، سازه تیری شکل آلومینیومی با سطح مقطع مستطیلی با طول ۰/۸۲ متر، عرض ۰/۰۲۰۴۷ متر و ضخامت ۰/۰۱۰۴۵ متر استفاده شده است. ابعاد مدل المان محدود دقیقاً با توجه به ابعاد مدل آزمایشگاهی ایجاد شده است (شکل ۴). برای سازه تیری شکل، مدول یانگ اولیه ۷۰ گیگا پاسکال، ضریب پواسون ۰/۳۳ و چگالی ۲۷۱۰ کیلوگرم بر متر مکعب است. سازه به ۱۱ المان (از نود صفر تا نود ۱۱) گسسته‌سازی می‌شود که طول هر المان ۰/۰۷۴ متر است. مدل المان محدود تیر اوپلر-برنولی دو سر مفصل در شکل ۲ آورده شده است.

$$\begin{Bmatrix} \dot{Y}_1 \\ \dot{Y}_2 \end{Bmatrix} = \text{inv} \begin{bmatrix} I_n & 0 \\ 0 & M_b \end{bmatrix} \left\{ \begin{array}{l} - \begin{bmatrix} 0 & -I_n \\ K_b & C_b \end{bmatrix} \begin{Bmatrix} Y_1 \\ Y_2 \end{Bmatrix} \\ + \begin{Bmatrix} 0 \\ F(t) \end{Bmatrix} \end{array} \right\} \quad (16)$$

معادله (۱۶) همان فرم قابل حل روش بیان شده است. با جایگذاری ماتریس‌های  $M_b$ ،  $K_b$  و  $C_b$  در رابطه (۱۶)، پاسخ‌های دینامیکی سازه تیری شکل استخراج می‌شوند.



شکل ۴: تجهیزات آزمایشگاهی سازه تیری شکل.

Fig. 4. The experimental setup of the beam-like structure.




شکل ۵. بخش‌های مختلف تجهیزات آزمایشگاهی سازه تیری شکل.

Fig. 5. Different parts of the experimental setup of the beam-like structure.

سیستم جمع‌آوری داده پالس<sup>۱</sup>، دو لرزاننده<sup>۲</sup>، دو شتاب‌سنج، دو نیروسنج، یک لپ‌تاپ، دو آمپلی‌فایر و کابل‌های انتقال است. در شکل

- 
- 1 Pulse Data acquisition
  - 2 Shaker

۲-۲- مجموعه تجهیزات آزمایشی سازه تیری شکل برای مدل‌سازی آزمایشگاهی، تجهیزات آزمایشگاهی سازه تیری شکل با تکیه‌گاه دو سر مفصل در آزمایشگاه دینامیک و ارتعاشات دانشگاه تبریز طراحی و نصب شد. تجهیزات آزمایشگاهی شامل یک



شکل ۶. مدل عمومی از یک شبکه عصبی [19].

Fig. 6. General model of a neural network [19].

حالت‌های مختلف عیب با اضافه کردن جرم متمرکز با شدت‌های مختلف در المان‌های مختلف سازه تکرار می‌شود. رویکردی مشابه با مدل آزمایشگاهی، برای مدل المان محدود نیز انجام می‌شود. پاسخ‌های شتاب‌سنج‌ها از نودهای ۶ و ۷ مطابق با مدل آزمایشگاهی با فرکانس  $8/192$  کیلوهرتز از سازه استخراج شده و در نرم‌افزار متلب پردازش می‌شوند. تنها تفاوت مدل المان محدود با مدل آزمایشگاهی این است که مدل المان محدود تنها از نود ۸ با نیروی تصادفی تحریک می‌شود (شکل ۲)، در صورتیکه مدل آزمایشگاهی از نودهای ۵ و ۸ با نیروی‌های تصادفی غیر همبسته تحریک می‌شوند (شکل ۴). جزئیات نحوه استخراج داده‌های هر دو مدل برای حالت‌های مختلف در بخش‌های ۳-۱ و ۳-۲ توضیح داده شده است. بخش‌های مختلف تجهیزات آزمایشگاهی سازه تیری شکل در شکل ۵ قابل مشاهده است

#### ۲-۳- تجزیه مود تجربی دسته‌ای کامل

تجزیه مود تجربی دسته‌ای کامل [۱۸] یک ابزار مناسب برای تحلیل سیگنال‌های غیرخطی و غیرثابت مانند سیگنال‌های ارتعاشی است. هر سیگنال با استفاده از روش تجزیه مود تجربی دسته‌ای کامل به مجموعه‌ای از توابع مود ذاتی<sup>۵</sup> خود تجزیه خواهد شد. جزئیات این روش در مرجع [۱۸] ارائه شده است.

#### ۲-۴- شبکه‌های عصبی مصنوعی

شبکه عصبی یک روش الهام‌گرفته‌شده از ساختار مغز انسان است

۳ تجهیزات آزمایشگاهی نشان داده شده است.

شتاب‌سنج‌ها در نودهای ۶ و ۷ برای استخراج پاسخ‌های دینامیکی به سازه متصل شده‌اند (شکل ۴). علت انتخاب این نودها برای استخراج پاسخ‌های دینامیکی این است که نقاط میانی تیر به‌عنوان نقاط شکمی شکل مودهای فرد محسوب می‌شوند بنابراین داده‌های ثبت‌شده از این نقاط اطلاعات مودهای فرد را به‌طور کامل در اختیار خواهد گذاشت. علاوه بر این، این نقاط برای شکل مودهای زوج به‌عنوان نقاط غیرگره‌ی هستند، بنابراین با استفاده از این نقاط اطلاعات مودهای زوج نیز در پاسخ‌های ثبت‌شده وجود خواهد داشت. دو لرزاننده در نودهای ۵ و ۸ با دو استینگر انعطاف‌پذیر<sup>۱</sup> با سختی محوری بالا<sup>۲</sup> [۱۷] برای تحریک به سازه متصل شده‌اند (شکل ۴). سیگنال‌های نیرو غیر همبسته<sup>۳</sup> برای ایجاد تحریک‌های تصادفی، نویز سفید گوسین در رنج فرکانسی مطلوب صفر تا  $1600$  هرتز هستند که این شامل همه فرکانس‌ها در رنج فرکانسی مطلوب است. نمونه‌ها با فرکانس نمونه‌برداری  $8/192$  کیلوهرتز داده‌برداری شده‌اند و سیگنال‌ها توسط کابل‌های انتقال به سیستم جمع‌آوری داده پالس منتقل می‌شوند تا پس از ورود به کامپیوتر توسط نرم‌افزار پالس<sup>۴</sup> ذخیره شوند. برای استفاده از این داده‌های خام، سیگنال‌ها در قالب نقاط دیجیتالی ذخیره‌شده در ماتریس، وارد نرم‌افزار متلب می‌شوند تا فرآیند پردازش روی آن‌ها صورت بگیرد. در این مقاله آزمایش‌های اولیه بر روی سازه سالم انجام می‌گیرد، پس‌از آن، آزمایش‌ها برای

- 1 Flexible stingers
- 2 High axial stiffness
- 3 Uncorrelated
- 4 Pulse Lab Shop

5 Intrinsic Mode Functions (IMF)

ورودی با استفاده از فیلتر انجام می‌دهد.

• لایه ادغام: این لایه ابعاد نورون‌های خروجی از لایه کانولوشن را کاهش داده و باعث کاهش شدت محاسبات و همچنین جلوگیری از پدیده بیش برآزش می‌شود. در این پژوهش از لایه ادغام بیشینه<sup>۷</sup> استفاده شده است که فقط مقادیر بیشینه در هر نگاشت ویژگی را انتخاب کرده و باعث کاهش تعداد نورون‌های خروجی می‌شود.

• لایه تمام متصل: این لایه دارای اتصال کامل به تمام فعال‌سازی‌ها در لایه قبلی است.

• لایه حذف تصادفی: از این لایه به منظور جلوگیری از پدیده بیش برآزش استفاده می‌شود [۲۲]. نحوه کار آن به این صورت است که در هر مرحله از آموزش، هر نورون با احتمالی از شبکه بیرون انداخته شده به طوری که نهایتاً یک شبکه کاهش داده شده باقی می‌ماند.

• لایه نرمال‌ساز دسته‌ای: این لایه به منظور نرمال‌سازی داده‌ها در داخل شبکه انجام می‌شود [۲۲]. تبدیل لایه نرمال‌سازی دسته‌ای به شرح زیر است:

$$\begin{aligned} \mu_B &= \frac{1}{n} \sum_{i=1}^n y_i^{(l-1)} \\ \sigma_B^2 &= \frac{1}{n} \sum_{i=1}^n (y_i^{(l-1)} - \mu_B)^2 \\ \hat{y}^{(l-1)} &= \frac{y^{*(l-1)} - \mu_B}{\sqrt{(\sigma_B^2 + \varepsilon)}} \\ z^{*(l)} &= \gamma^{(l)} \hat{y}^{(l-1)} + \beta^{(l)} \end{aligned} \quad (17)$$

که  $\sigma_B^2$  و  $\mu_B$  به ترتیب میانگین و واریانس دسته هستند.  $\varepsilon$  یک ثابت کوچک برای ثبات عددی،  $l$  شماره لایه،  $y^{*(l-1)}$  بردار ورودی به لایه نرمال‌ساز،  $z^{*(l)}$  بردار خروجی نرمال‌شده مربوط به یک نورون،  $\gamma^{(l)}$  و  $\beta^{(l)}$  به ترتیب پارامترهای مربوط به مقیاس و تغییر نرخ یادگیری هستند.

• تابع رلوو<sup>۸</sup>: پس از هر لایه کانولوشن، یک تابع فعال‌سازی اعمال می‌شود. تابع فعال‌سازی یک عملگر است که خروجی را به مجموعه‌ای از ورودی‌ها نگاشت می‌کند و برای غیرخطی کردن ساختار شبکه استفاده می‌شود [۱۹]. در این رساله از تابع رلوو به عنوان

که با هدف حل مسائل مختلف به تقلید از ذهن انسان به وجود آمده است. در شکل ۶ یک شبکه عصبی مصنوعی نشان داده شده است. همان‌گونه که از این شکل مشخص است، شبکه از تعدادی واحد پردازشی به نام نورون، در چندین لایه مختلف ساخته شده است. نورون‌های موجود در هر لایه باهم هیچ‌گونه ارتباطی ندارند. به منظور حل مسئله توسط مدل شبکه عصبی، نیاز است تا وزن‌های مناسب برای هر لایه تعیین شوند. پس از تعیین ابرپارامترهای مدل مانند نرخ یادگیری، تعداد لایه‌های پنهان، تعداد نورون‌های هر لایه، توابع فعال‌ساز و غیره، وزن‌های بهینه مرتبط با هر لایه به کمک داده‌های آموزش محاسبه می‌شوند و در نهایت شبکه با داده‌های آزمایش ارزیابی می‌شود.

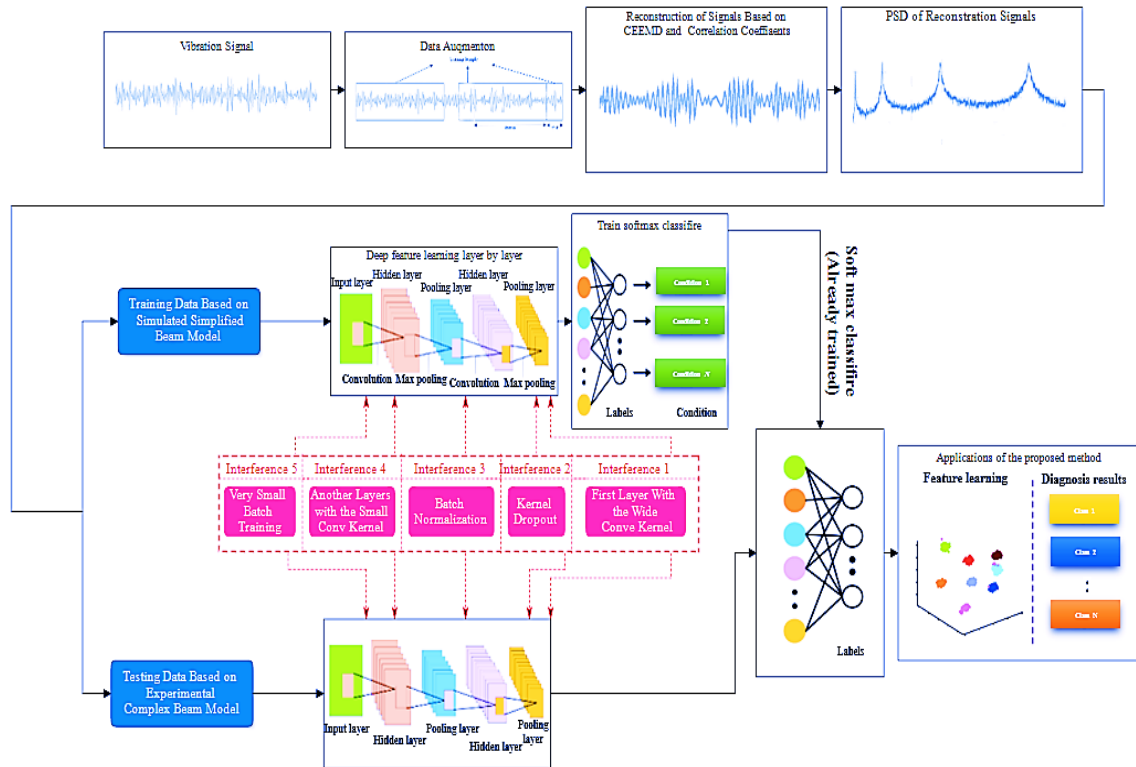
شبکه عصبی کانولوشنال عمیق در واقع یک شبکه عصبی بهبودیافته است [۱۹]. در شبکه‌های عمیق یادگیری ویژگی به صورت سلسله مراتبی انجام می‌گیرد. یادگیری ویژگی برای استخراج خودکار ویژگی‌ها و الگوهای مشترک استفاده می‌شود تا از این ویژگی‌ها در فرآیند دسته‌بندی استفاده شود. در این شبکه چندین لایه با روشی قدرتمند در کنار هم برای یادگیری ویژگی‌ها آموزش می‌بینند [۱۹]. همانند شبکه عصبی، تصمیم خروجی نهایی شبکه کانولوشنال عمیق بر اساس وزن و بایاس لایه‌های قبلی در ساختار شبکه است. در هر شبکه عصبی کانولوشنال دو مرحله برای آموزش وجود دارد؛ مرحله انتشار پیشرو و مرحله پس انتشار<sup>۱</sup> [۲۰]. الگوریتم پس انتشار، روشی برای محاسبه گرادیان تابع اتلاف نسبت به وزن‌هاست. به طور کلی، یک شبکه کانولوشنال از سه لایه اصلی تشکیل می‌شود که عبارت‌اند از: لایه کانولوشن<sup>۲</sup>، لایه ادغام<sup>۳</sup> و لایه تمام متصل<sup>۴</sup> [۱۹، ۲۱]. برای جلوگیری از فرآیند بیش برآزش و بهبود عملکرد شبکه می‌توان از لایه‌های حذف تصادفی<sup>۵</sup> و نرمال‌سازی دسته‌ای<sup>۶</sup> نیز استفاده کرد. همچنین در شبکه‌های عصبی نیاز است پس از هر لایه از تابع فعال‌سازی استفاده شود که در ادامه این لایه‌ها و توابع اجمالاً معرفی می‌شوند.

• لایه کانولوشن: شامل فیلترهایی (کرنل‌ها) است که روی داده ورودی به شبکه می‌لغزند. این لایه، عمل کانولوشن را روی داده

- 1 Backpropagation (BP)
- 2 Convolution
- 3 Pooling
- 4 Fully Fonnected (FC)
- 5 Dropout
- 6 Batch normalization (BN)

7 Max-Pooling

8 Relu



شکل ۷. بلوک دیاگرام الگوریتم پیشنهادی.

Fig. 7. The block diagram of the proposed algorithm.

$$\sigma(\delta)_i = \frac{e^{\delta_i}}{\sum_{j=1}^k e^{\delta_j}} \quad \text{for } i=1, \dots, k \quad (19)$$

$$\delta = (\delta_1, \dots, \delta_k) \in R^k$$

که در آن  $\delta$  ورودی شبکه است و مقادیر خروجی  $\sigma(\delta)$  بین صفر و یک بوده که مجموع آن‌ها برابر یک است [۱۹].

### ۳- الگوریتم عیب‌یابی پیشنهادی

هدف اصلی در این مقاله ارائه الگوریتمی به‌منظور شناسایی و عیب‌یابی سیستم‌های مکانیکی در حضور عدم قطعیت‌های مختلف با استفاده از سیگنال ارتعاشی بر پایه مدل شبیه‌سازی شده با بارگذاری ساده، حالت سالم واقعی و شبکه عصبی عمیق است. نحوه عملکرد

فعال‌سازی در لایه‌های کانولوشن استفاده شده است و این ویژگی را دارد که غیرخطی بودن را به ساختار شبکه اعمال کند؛ بنابراین در برابر تغییرات جزئی در ورودی مقاوم است. رابطه (۱۸) تابع رلوو را نشان می‌دهد. در این تابع، اگر مقدار  $d$  بزرگتر از صفر باشد، خروجی  $d$  است و اگر مقدار  $d$  کوچکتر یا مساوی صفر باشد، خروجی صفر است.

$$R(d) = \begin{cases} d & \text{if } d > 0 \\ 0 & \text{otherwise} \end{cases} \quad (18)$$

تابع سافت‌مکس<sup>۱</sup>: این تابع توزیع احتمالی کلاس‌های خروجی را محاسبه می‌کند؛ بنابراین در لایه تمام متصل آخر از تابع سافت‌مکس برای پیش‌بینی اینکه کدام سیگنال ورودی به حالت‌های مختلف عیب مربوط است، استفاده می‌شود و رابطه‌ی آن به فرم زیر است:

1 Softmax

جدول ۱. کلاس‌های مختلف عیب.

Table 1. Different classes of damage.

نوع عیب	کلاس
سالم	۱
المان ۳ جرم اضافه شده ۰/۲ کیلوگرم	۲
المان ۳ جرم اضافه شده ۰/۷ کیلوگرم	۳
المان ۸ جرم اضافه شده ۰/۲ کیلوگرم	۴
المان ۸ جرم اضافه شده ۰/۷ کیلوگرم	۵

۳-۱-داده‌ها

به‌طور کلی، به‌منظور بررسی عملکرد روش‌های عیب‌یابی، می‌توان سناریوهای عیوب فرضی در سازه ایجاد کرد. برای شبیه‌سازی سناریوی عیب در مدل المان محدود و مدل واقعی سازه تیری‌شکل، از افزایش جرم متمرکز با شدت‌های مختلف در المان‌های مختلف استفاده می‌شود. در این مقاله ۵ حالت مختلف برای مدل شبیه‌سازی شده دینامیکی و مدل واقعی آزمایشگاهی در نظر گرفته شده است که شامل: حالت سالم (کلاس ۱)، حالت معیوب مربوط به اضافه‌شدن جرم ۰/۲ کیلوگرم در المان ۳ (کلاس ۲)، حالت معیوب مربوط به اضافه‌شدن جرم ۰/۷ کیلوگرم در المان ۳ (کلاس ۳)، حالت معیوب مربوط به اضافه‌شدن جرم ۰/۲ کیلوگرم در المان ۸ (کلاس ۴) و حالت معیوب مربوط به اضافه‌شدن جرم ۰/۷ کیلوگرم در المان ۸ (کلاس ۵) است. جدول ۱ کلاس‌های مختلف عیب برای مدل شبیه‌سازی شده و مدل واقعی آزمایشگاهی را نشان می‌دهد. اضافه‌کردن جرم متمرکز به سازه، باعث جابه‌جایی فرکانس‌ها و تغییر شکل مودها می‌شود.

در روش پیشنهادی این مقاله، داده‌های مدل المان محدود تحت یک نیروی تحریک تصادفی در نود ۸ (که در این مقاله به آن «مدل ساده شبیه‌سازی شده» می‌گوییم) و حالت سالم واقعی به‌عنوان داده آموزش شبکه پیشنهادی استفاده می‌شوند. از آنجاکه در محیط‌های صنعتی شرایط بارگذاری به‌صورت مرتب در حال تغییر هستند، مدل واقعی آزمایشگاهی با دو نیروی تصادفی (به‌منظور فرضیات واقع‌بینانه‌تر) تحریک می‌شود؛ بنابراین، داده‌های مدل واقعی آزمایشگاهی تحت دو نیروی تحریک تصادفی در نودهای ۵ و ۸ (که در این مقاله به آن «مدل آزمایشگاهی» می‌گوییم) به‌عنوان

الگوریتم پیشنهادی در زیر به‌اختصار بیان شده است:

۱) ابتدا مدل‌سازی دینامیکی سازه تیری‌شکل (به‌عنوان یک مطالعه موردی) با استفاده از روش المان محدود انجام خواهد شد و حل عددی آن با استفاده از کدنویسی در محیط متلب مهیا می‌شود. پس از آن پاسخ‌های دینامیکی از سناریوهای عیوب فرضی، از مدل المان محدود تحت یک نیروی تحریک تصادفی و همچنین مدل واقعی آزمایشگاهی تحت دو نیروی تحریک تصادفی استخراج می‌گردند.

۲) نرمال کردن داده‌ها.

۳) افزایش داده‌ها با استفاده از روش هم‌پوشانی.

۴) حذف برخی از بخش‌های سیگنال‌ها که مربوط به ذات سیستم نیستند با استفاده از روش تجزیه مود تجربی دسته‌ای کامل و ضرایب همبستگی.

۵) استفاده از پاسخ‌های دینامیکی بازسازی شده به‌منظور استخراج داده‌های فرکانسی با استفاده از روش چگالی طیفی توان.

۶) تقسیم مجموعه داده‌ها به سه مجموعه شامل مجموعه آموزشی بر پایه مدل ساده شبیه‌سازی شده و حالت سالم واقعی، مجموعه اعتبارسنجی و مجموعه آزمایشی بر پایه مدل واقعی آزمایشگاهی.


۷) انتخاب معماری و ساختار مناسب برای شبکه عصبی عمیق

با استفاده از نرم‌افزار پایتون، به‌منظور شناسایی و عیب‌یابی.

۸) بررسی عملکرد شبکه عمیق طراحی شده برای شناسایی و عیب‌یابی سازه با استفاده از مجموعه داده‌های آزمایشی.

شکل ۷ بلوک دیاگرام الگوریتم پیشنهادی را نشان می‌دهد.





شکل ۸. داده‌افزایی با استفاده از تکنیک هم‌پوشانی برای مدل المان محدود.

Fig. 8. Data augmentation using the overlap technique for FE model.

به‌گونه‌ای انجام می‌شود که فرکانس‌های طبیعی مدل سالم المان محدود با فرکانس‌های طبیعی مدل سالم آزمایشگاهی مطابقت داشته باشند [۲۶-۲۳]. سپس از مدل المان محدود به‌روز شده برای تشخیص عیوب مدل آزمایشگاهی سازه تیری شکل استفاده می‌شود. در روش پیشنهادی هر سیگنال ارتعاشی توسط نرمالیزاسیون بین صفر و یک نرمالیزه شده [۱۲]، پس از آن از تکنیک هم‌پوشانی برای داده‌افزایی استفاده می‌شود. افزایش تعداد داده‌ها باعث افزایش دقت و جلوگیری از پدیده بیش‌برازش می‌شود. روند این هم‌پوشانی برای داده‌های آموزش در شکل ۸ نشان داده شده است. تعداد نمونه‌های هر کلاس مدل ساده شبیه‌سازی شده و مدل آزمایشگاهی به ترتیب ۴۷۸ و ۱۱۸ است.

### ۳-۲- انتخاب توابع مود ذاتی مناسب و بازسازی سیگنال‌ها

همان‌طور که قبلاً بیان شد با استفاده از روش تجزیه مود تجربی دسته‌ای کامل می‌توان بخش‌هایی از سیگنال که مربوط به ذات اصلی سیستم نیستند را از سیگنال اصلی حذف نمود. پاسخ‌های دینامیکی مدل ساده شبیه‌سازی شده و مدل واقعی آزمایشگاهی با استفاده از روش تجزیه مود تجربی دسته‌ای کامل به توابع مود ذاتی خود تجزیه می‌شوند. با استفاده از ضریب همبستگی توابع مود ذاتی مدل ساده شبیه‌سازی شده و حالت سالم مدل آزمایشگاهی با سیگنال‌های مربوط به خود، توابع مود ذاتی که بیشترین ضریب همبستگی را دارند انتخاب می‌شوند. ضریب همبستگی روشی پارامتریک است که برای

داده آزمون استفاده می‌شوند. به‌منظور شبیه‌سازی عیوب مختلف در مدل المان محدود، از افزایش جرم متمرکز  $M_1$  و  $M_2$  در المان‌ها، به‌صورت زیر استفاده می‌شود:

$$M_{e(d)} = M_{e(u)} + M_1 \cdot (H^T(x) \cdot H(x)) \Big|_{x=0} + M_2 \cdot (H^T(x) \cdot H(x)) \Big|_{x=1} \quad (20)$$

$$M_1 = M_2 = \frac{M_{add}}{2}$$

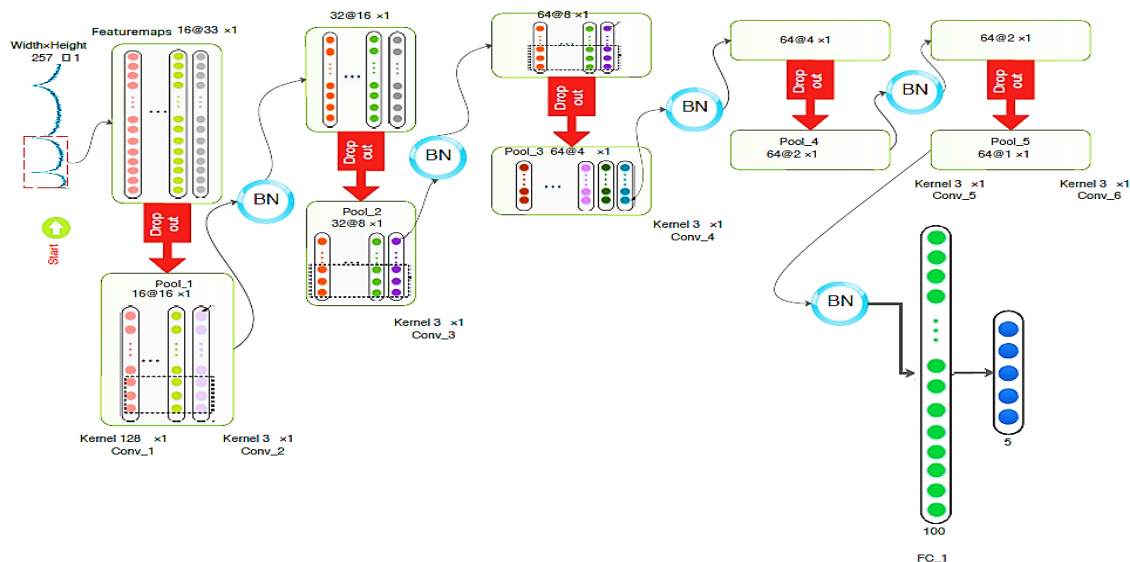
که در آن  $M_e$  ماتریس جرم هر المان و زیرنویس‌های  $u$  و  $d$  به ترتیب حالت سالم و معیوب،  $M_{add}$  جرم متمرکز اضافه‌شده و  $x$  فاصله جرم اضافه‌شده در هر المان را نشان می‌دهد. در این مقاله، پاسخ‌های دینامیکی شتاب‌سنج نصب‌شده در نود ۷ برای استخراج ویژگی‌ها و عیب‌یابی سازه تیری شکل استفاده شده است.

همان‌طور که قبلاً بیان شد بین پاسخ‌های دینامیکی مدل شبیه‌سازی شده و مدل آزمایشگاهی به‌دلیل عدم قطعیت‌های مختلف مانند خطاهای مدل‌سازی، کمی اختلاف وجود دارد؛ بنابراین، به‌روزرسانی مدل المان محدود اولیه بر اساس مدل واقعی و تنظیم برخی از پارامترهای آن برای به حداقل رساندن خطای مدل‌سازی ضروری است. در مطالعه حاضر، مدل المان محدود سازه تیری شکل بر اساس فرکانس‌های طبیعی حالت سالم مدل آزمایشگاهی به‌روز شده است. به‌روزرسانی با تغییر مدول الاستیسیته مدل المان محدود

جدول ۲. جزئیات معماری شبکه کانولوشنال پیشنهادی.

Table 2. Architecture details of the proposed convolutional network.

شماره	نوع لایه	اندازه و گام فیلتر	تعداد فیلتر	شکل خروجی
۱	کانولوشن ۱	$128 \times 1 / 8 \times 1$	۱۶	$33 \times 16$
۲	ادغام ۱	$1 \times 1 / 2 \times 1$	-	$16 \times 16$
۳	کانولوشن ۲	$3 \times 1 / 1 \times 1$	۳۲	$16 \times 32$
۴	ادغام ۲	$2 \times 1 / 2 \times 1$	-	$8 \times 32$
۵	کانولوشن ۳	$3 \times 1 / 1 \times 1$	۶۴	$8 \times 64$
۶	ادغام ۳	$2 \times 1 / 2 \times 1$	-	$4 \times 64$
۷	کانولوشن ۴	$3 \times 1 / 1 \times 1$	۶۴	$4 \times 64$
۸	ادغام ۴	$2 \times 1 / 2 \times 1$	-	$2 \times 64$
۹	کانولوشن ۵	$3 \times 1 / 1 \times 1$	۶۴	$2 \times 64$
۱۰	ادغام ۵	$2 \times 1 / 2 \times 1$	-	$1 \times 64$
۱۱	تمام متصل	۱۰۰	-	۱۰۰
۱۲	سافت مکس	۵	-	۵



شکل ۹. معماری شبکه کانولوشنال پیشنهادی.


Fig. 9. The proposed convolutional network architecture.

که در رابطه بالا  $X_1$  و  $X_2$  بردارهای ویژگی سیگنال‌هایی است که ضریب همبستگی برای آن‌ها محاسبه می‌شود و دارای  $N$  عضو می‌باشند و  $\mu_{X_1}$  و  $\mu_{X_2}$  میانگین‌های مربوط به این دو بردار هستند. در این مقاله پس از انتخاب توابع مود ذاتی مناسب، سیگنال‌های اصلی بازسازی می‌شوند. پس از آن، داده‌های فرکانسی در رنج فرکانسی صفر تا ۱۶۰۰ هرتز با استفاده از روش چگالی طیفی توان از داده‌های زمانی بازسازی شده به دست می‌آیند. داده‌های فرکانسی استخراج شده از

داده‌هایی با توزیع نرمال استفاده می‌شود. ضریب همبستگی از رابطه زیر به دست می‌آید [۲۷]:

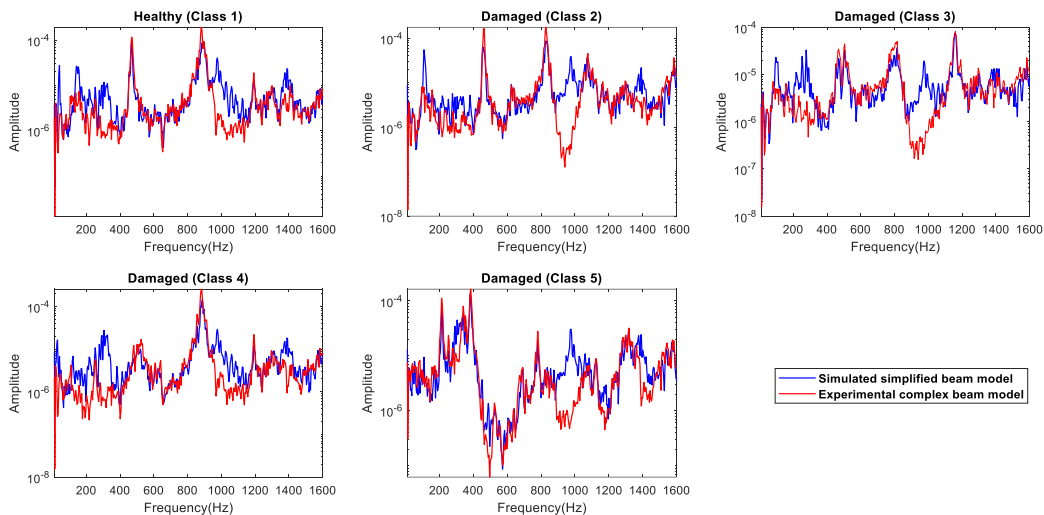
$$\hat{n} = \frac{\sum_{i=1}^N (X_{1i} - \mu_{X_1})(X_{2i} - \mu_{X_2})}{\left(\sum_{i=1}^N (X_{1i} - \mu_{X_1})\right)^{\frac{1}{2}} \left(\sum_{i=1}^N (X_{2i} - \mu_{X_2})\right)^{\frac{1}{2}}} \quad (21)$$

$$\mu_{X_1} = \frac{1}{N} \sum_{i=1}^N X_{1i} \quad \mu_{X_2} = \frac{1}{N} \sum_{i=1}^N X_{2i}$$



**Fig. 10.** The samples allocation to be used in the proposed algorithm for 2 steps of training and testing

شکل ۱۰: تخصیص نمونه‌های مورد استفاده در الگوریتم پیشنهادی برای دو مرحله آموزش و آزمون.



شکل ۱۱. مقایسه طیف فرکانسی سیگنال ارتعاشی نرمال شده مدل‌های المان محدود و آزمایشگاهی

**Fig. 11.** Comparison of the frequency spectrum of the normalized vibrational signal of FE and experimental models.

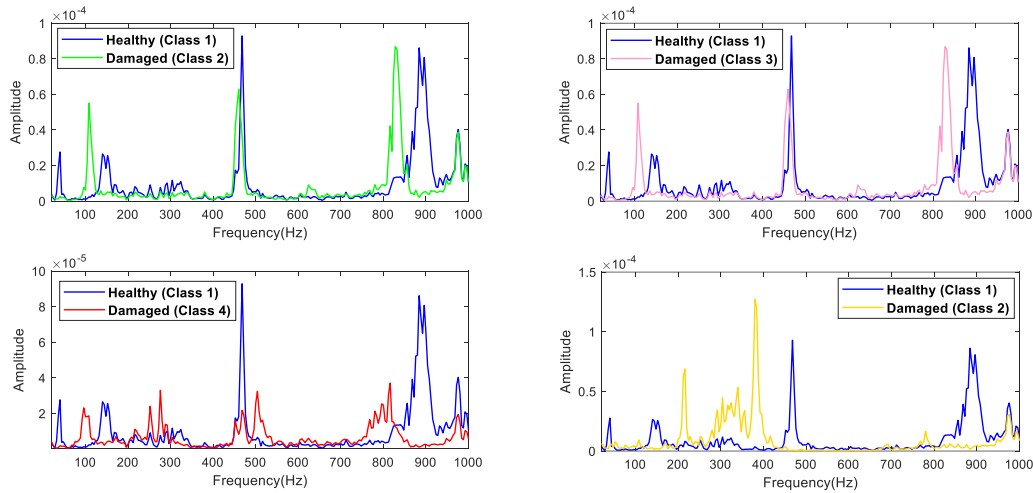
۴ بار دیگر تکرار می‌شود؛ (۳) خروجی معماری قبلی به یک ماتریس دویعدی متصل می‌شود؛ (۴) دویایه تمام متصل برای دسترسی به لایه خروجی استفاده می‌شود. در این معماری در لایه اول از فیلتر کانولوشن با اندازه بزرگ<sup>۱</sup> (۱۲۸×۱) و در لایه‌های بعدی از فیلترهایی با اندازه کوچک‌تر<sup>۲</sup> (۳×۱) استفاده شده است. استفاده از فیلتر با اندازه بزرگ در لایه اول در مقایسه با فیلتر با اندازه کوچک، بهتر می‌تواند نویزهای فرکانس بالا را از بین ببرد. استفاده از فیلترها با اندازه کوچک در لایه‌های بعدی کانولوشن باعث بازنمایی بهتری از سیگنال ورودی می‌شود و در نتیجه عملکرد شبکه را بهبود می‌بخشد. برای لایه اول کانولوشن از گام ۸ و برای بقیه لایه‌های کانولوشن و لایه‌های ادغام بیشینه گام ۲ در نظر گرفته شده است. جدول ۲ جزئیات معماری شبکه

1 Wide convolution kernel  
2 Small convolution kernel

مدل ساده شبیه‌سازی شده و حالت سالم مدل آزمایشگاهی (تعداد کل آن‌ها برای ۵ کلاس مختلف ۲۳۹۰ است) به عنوان داده آموزش شبکه پیشنهادی و داده‌های فرکانسی استخراج شده از مدل آزمایشگاهی (تعداد کل آن‌ها برای ۵ کلاس مختلف ۵۹۰ است) به عنوان داده آزمون استفاده می‌شوند.

### ۳-۳- معماری شبکه کانولوشنال پیشنهادی

برای پیاده‌سازی شبکه کانولوشنال از کتابخانه کراس در زبان برنامه‌نویسی پایتون استفاده شده است. معماری شبکه عصبی عمیق نیز به صورت زیر انتخاب شده است: (۱) یک لایه کانولوشن با تابع غیرخطی رلو همراه با لایه حذف تصادفی و لایه نرمال‌سازی دسته‌ای، سپس یک لایه ادغام بیشینه اضافه می‌شود؛ (۲) معماری مرحله قبل



شکل ۱۲. طیف فرکانسی مدل المان محدود برای حالت‌های مختلف عیب.

Fig. 12. Frequency spectrum of the FE model for various states.

جدول ۳. مقایسه فرکانس‌های طبیعی به‌دست آمده برای سازه سالم با استفاده از روش‌های مختلف.

Table 3. Comparison of the obtained natural frequencies for the healthy structure using different methods.

خطا (%)			فرکانس طبیعی (هرتز)			شماره مود
مدل المان محدود و آزمایشگاهی	مدل المان محدود	مدل آزمایشگاهی	مدل المان محدود	مدل آزمایشگاهی	روش تحلیلی	
چگالی طیفی توان- چگالی طیفی توان	تحلیلی- چگالی طیفی توان	تحلیلی- چگالی طیفی توان	روش چگالی طیفی توان	روش چگالی طیفی توان		
۰/۰	۶/۱۱	۶/۱۱	۳۸	۳۸	۳۵/۸۱	۱
۲/۹	۲/۲۷	۵/۰۶	۱۴۰	۱۳۶	۱۴۳/۲۶	۲
۵/۸	۰/۵۱	۶/۷۱	۳۲۴	۳۴۴	۳۲۲/۳۴	۳
۰/۰	۰/۲۰	۰/۲۰	۴۷۲	۴۷۲	۴۷۳/۰۶	۴
۰/۰	۱/۷۰	۱/۷۰	۸۸۰	۸۸۰	۸۹۵/۴۱	۵

و آزمون ۲۳۹۰ و ۵۹۰ است که ۶۰ نمونه از داده‌های آزمایش برای اعتبارسنجی استفاده می‌شود. برای تعیین ابر پارامترهای شبکه پیشنهادی از روش سعی و خطا استفاده شده است و در نهایت تابع خطا آنتروپی متقابل<sup>۱</sup>، بهینه‌کننده آدام<sup>۲</sup> [۲۲] با نرخ یادگیری ۰/۰۰۰۱ و روش پس‌انتشار خطا با اندازه دسته ۱۰ برای آموزش

کانولوشنال پیشنهادی مورد استفاده را نشان می‌دهد. طبق جدول ۲ کاهش بعد در لایه‌های پنهان از ۲۵۷ (طول داده‌های فرکانسی) به ۶۴ (تعداد ویژگی‌های بهینه انتخابی) ادامه یافته است و در نهایت بردار ویژگی انتخاب شده به دو لایه تمام متصل با تابع غیرخطی سیگموئید و سافت‌مکس جهت شناسایی عیوب مختلف متصل می‌شود. معماری شبکه کانولوشنال پیشنهادی در شکل ۹ نشان داده شده است.

همان‌طور که در بخش ۳-۳ بیان شد، تعداد کل داده‌های آموزش

1 Cross-entropy loss function  
2 Adam optimizer

جدول ۴. میانگین ضرایب همبستگی توابع مود ذاتی با سیگنال‌های ارتعاشی مربوط به آن‌ها برای مدل المان محدود و حالت سالم آزمایشگاهی.

**Table 4. The correlation coefficients mean of intrinsic mode functions with vibrational signals corresponding to them for the FE model and the experimental healthy state.**

تابع مود ذاتی ۶	تابع مود ذاتی ۵	تابع مود ذاتی ۴	تابع مود ذاتی ۳	تابع مود ذاتی ۲	تابع مود ذاتی ۱	
۰/۲۰	۰/۱۵	۰/۲۹	۰/۳۸	۰/۴۰	۰/۸۹	حالت سالم (مدل المان محدود)
۰/۱۸	۰/۲۱	۰/۲۸	۰/۲۷	۰/۲۱	۰/۷۰	کلاس ۲ (مدل المان محدود)
۰/۲۹	۰/۲۷	۰/۲۴	۰/۳۱	۰/۴۲	۰/۸۱	کلاس ۳ (مدل المان محدود)
۰/۱۴	۰/۴۶	۰/۴۵	۰/۳۲	۰/۲۴	۰/۷۵	کلاس ۴ (مدل المان محدود)
۰/۲۱	۰/۲۸	۰/۳۰	۰/۳۵	۰/۴۶	۰/۷۲	کلاس ۵ (مدل المان محدود)
۰/۱۵	۰/۱۶	۰/۴۴	۰/۳۷	۰/۵۲	۰/۷۴	حالت سالم (مدل آزمایشگاهی)
تابع مود ذاتی ۷	تابع مود ذاتی ۸	تابع مود ذاتی ۹	تابع مود ذاتی ۱۰	تابع مود ذاتی ۱۱		
۰/۱۰	۰/۰۷	۰/۰۳	۰/۰۰	۰/۰۰	۰/۱۰	حالت سالم (مدل المان محدود)
۰/۱۱	۰/۰۷	۰/۰۲	۰/۰۰	۰/۰۰	۰/۱۱	کلاس ۲ (مدل المان محدود)
۰/۰۵	۰/۰۳	۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۵	کلاس ۳ (مدل المان محدود)
۰/۱۳	۰/۰۸	۰/۰۹	۰/۰۳	۰/۰۲	۰/۱۳	کلاس ۴ (مدل المان محدود)
۰/۰۳	۰/۰۲	۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۳	کلاس ۵ (مدل المان محدود)
۰/۰۹	۰/۰۳	۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۹	حالت سالم (مدل آزمایشگاهی)

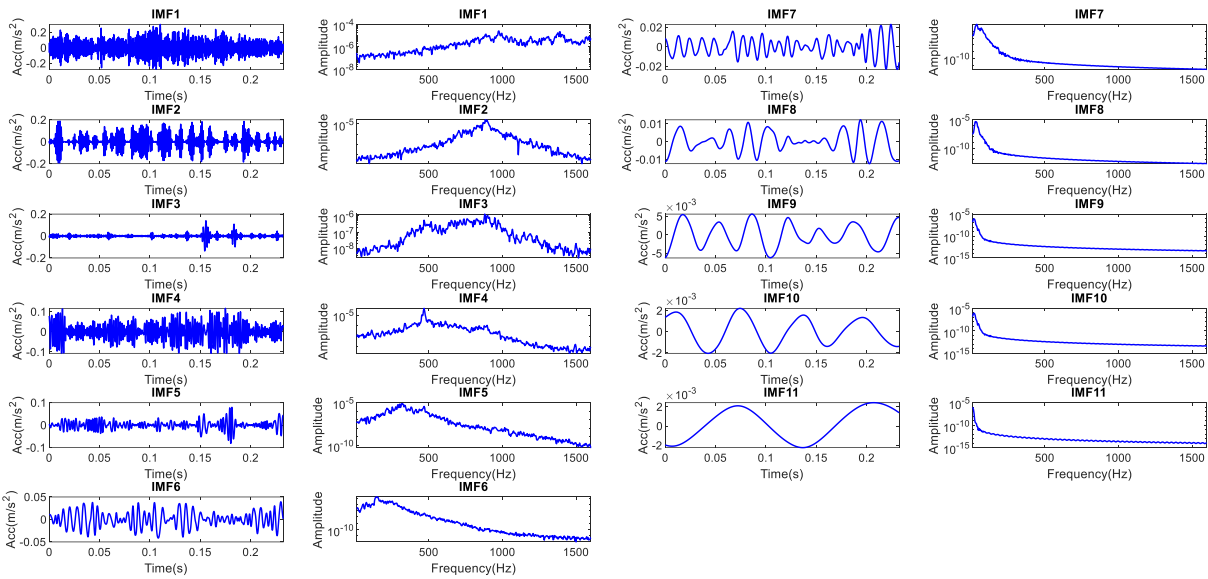
#### ۴-۱- ارزیابی مدل المان محدود شبیه‌سازی شده بر پایه داده‌های آزمایشگاهی

به منظور ارزیابی صحت مدل المان محدود، فرکانس‌های طبیعی سازه تیری شکل با استفاده از روش‌های مختلف به دست آمده و با یکدیگر مقایسه می‌شوند. در این بخش، ابتدا فرکانس‌های طبیعی سازه با استفاده از روش چگالی طیفی توان بر پایه پاسخ‌های دینامیکی مدل آزمایشگاهی و مدل المان محدود استخراج می‌شوند. پس از آن فرکانس‌های طبیعی سازه با استفاده از حل تحلیلی نیز به دست می‌آیند و در نهایت این فرکانس‌ها با یکدیگر مقایسه خواهند شد. برای به دست آوردن پاسخ‌های دینامیکی مدل المان محدود با استفاده از معادله (۱۶) ابتدا باید ماتریس  $C_b$  محاسبه گردد که با محاسبه  $\bar{\alpha}$  و  $\bar{\beta}$ ، می‌توان ماتریس  $C_b$  را به دست آورد. برای به دست آوردن

شبکه پیشنهادی مورد استفاده قرار گرفته است. بعد از آموزش شبکه پیشنهادی، ارزیابی با استفاده از ۵۳۰ نمونه از داده‌های آزمون صورت می‌گیرد. شکل ۱۰ تخصیص نمونه‌های استفاده شده در الگوریتم پیشنهادی را نشان می‌دهد.

#### ۴-۲- کاربرد روش پیشنهادی برای عیب‌یابی سازه تیری شکل واقعی

در این قسمت، نتایج روش پیشنهادی برای عیب‌یابی سازه تیری شکل تحت بارگذاری پیچیده ارائه شده است. این بخش به چندین زیر بخش تقسیم شده است: (۱) ارزیابی مدل المان محدود شبیه‌سازی شده بر پایه داده‌های آزمایشگاهی. (۲) انتخاب توابع مود ذاتی و بازسازی سیگنال‌های ارتعاشی. (۳) عیب‌یابی سازه تیری شکل تحت بارگذاری پیچیده.



شکل ۱۳. توابع مود ذاتی برای یک نمونه از حالت سالم مدل ساده مدل المان محدود در حوزه زمان و فرکانس.

Fig. 13. Intrinsic mode functions for a sample of the healthy FE model in the time and frequency domain.

$$\omega_n = (\beta_n L_i)^2 \sqrt{\frac{EI}{\rho A L_i^4}} \quad (22)$$

$$\beta_n = n\pi, \quad n = 1, 2, 3, \dots$$

که در آن  $L_i$  و  $n$  به ترتیب طول سازه و شماره مود را نشان می‌دهند.

بر اساس جدول ۳، با مقایسه فرکانس‌های طبیعی به دست آمده برای هر دو مدل بر پایه روش چگالی طیفی توان با فرکانس‌های طبیعی به دست آمده از حل تحلیلی ملاحظه می‌گردد که بیشترین خطا تقریباً ۶٪ است که با توجه به وجود عدم قطعیت‌های مختلف این مقدار خطا قابل قبول است. همچنین با مقایسه فرکانس‌های طبیعی به دست آمده از هر دو مدل با استفاده از روش چگالی طیفی توان ملاحظه می‌گردد که بیشترین خطا تقریباً ۵٪ است که با توجه به وجود عدم قطعیت‌های مختلف این مقدار خطا قابل قبول است و می‌توان بیان کرد که شبیه‌سازی مدل المان محدود، دقت قابل قبولی دارد.

$\bar{\alpha}$  و  $\bar{\beta}$ ، نسبت‌های دمپینگ ۰/۰۵ در نظر گرفته شده است که با جایگذاری این مقادیر در رابطه ۹ و ۱۰ می‌توان  $\bar{\alpha}$  و  $\bar{\beta}$  را به دست آورد. شکل ۱۱ طیف‌های فرکانسی یک نمونه سیگنال ارتعاشی سازه تیری شکل مدل ساده شبیه‌سازی شده و مدل آزمایشگاهی را برای حالت‌های مختلف در مقیاس لگاریتمی نشان می‌دهد.

همان‌طور که از شکل ۱۱ ملاحظه می‌گردد، طیف‌های فرکانسی هر دو مدل رفتار تقریباً مشابهی دارند، اما عدم قطعیت‌های مختلف مانند خطاهای مدل‌سازی، خطاهای اندازه‌گیری، تغییرات بارگذاری و نویزهای محیطی باعث ایجاد اختلاف در برخی از دامنه‌ها می‌گردد. طیف فرکانسی یک نمونه سیگنال ارتعاشی سازه تیری شکل مدل ساده شبیه‌سازی شده برای حالت‌های مختلف عیب در مقیاس خطی در شکل ۱۲ رسم شده و با حالت سالم مقایسه شده است. همان‌طور که ملاحظه می‌گردد، وجود عیب در سازه باعث تغییر دامنه و شیفت فرکانسی نسبت به حالت سالم می‌گردد.

به منظور بررسی بیشتر نتایج، ۵ فرکانس طبیعی اول برای سازه سالم با استفاده از روش‌های مختلف در جدول ۳ آورده شده است. در این جدول برای به دست آوردن فرکانس‌های طبیعی تحلیلی از فرمول زیر استفاده شده است [۲۸]:

جدول ۵. ماتریس درهم‌ریختگی الگوریتم پیشنهادی.

Table 5. Confusion Matrix of the proposed algorithm.

نوع عیب	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	صحت %
کلاس ۱	۱۰۶	۰	۰	۰	۰	۱۰۰
کلاس ۲	۰	۱۰۶	۰	۰	۰	۱۰۰
کلاس ۳	۰	۰	۱۰۵	۱	۰	۹۹/۰۶
کلاس ۴	۰	۰	۰	۱۰۶	۰	۱۰۰
کلاس ۵	۰	۰	۰	۵	۱۰۱	۹۵/۲۸

جدول ۶. صحت الگوریتم پیشنهادی در مقایسه با روش‌های مقایسه‌ای.

Table 6. The accuracy of the proposed algorithm compared to the comparative methods.

روش‌ها	یادگیری ویژگی از داده خام	صحت %
شبکه پرسپترون	داده‌های فرکانسی سیگنال‌های زمانی	$75/2 \pm 85/2$
شبکه پرسپترون	داده‌های فرکانسی سیگنال‌های زمانی بازسازی شده	$81/2 \pm 70/5$
شبکه عمیق پیشنهادی	داده‌های فرکانسی سیگنال‌های زمانی	$94/4 \pm 53/1$
روش پیشنهادی	داده‌های فرکانسی سیگنال‌های زمانی بازسازی شده	$98/5 \pm 87/3$

مشخص است، با افزایش شماره توابع مود ذاتی، محتویات فرکانسی که مربوط به ذات سیستم هستند نیز از بین می‌روند؛ بنابراین با توجه به جدول ۴ و شکل ۱۳، می‌توان توابع مود ذاتی ۱ تا ۶ در مدل ساده شبیه‌سازی شده و مدل آزمایشگاهی را به‌عنوان توابع مود ذاتی مناسب انتخاب کرد. بعد از انتخاب توابع مود ذاتی مناسب، سیگنال‌های اصلی همه نمونه‌ها با استفاده از این توابع مود ذاتی بازسازی می‌شوند. این کار باعث می‌شود که اطلاعات اضافی و غیر مربوط به ذات سیستم حذف شوند.

#### ۳-۴- عیب‌یابی سازه تیری شکل تحت بارگذاری پیچیده

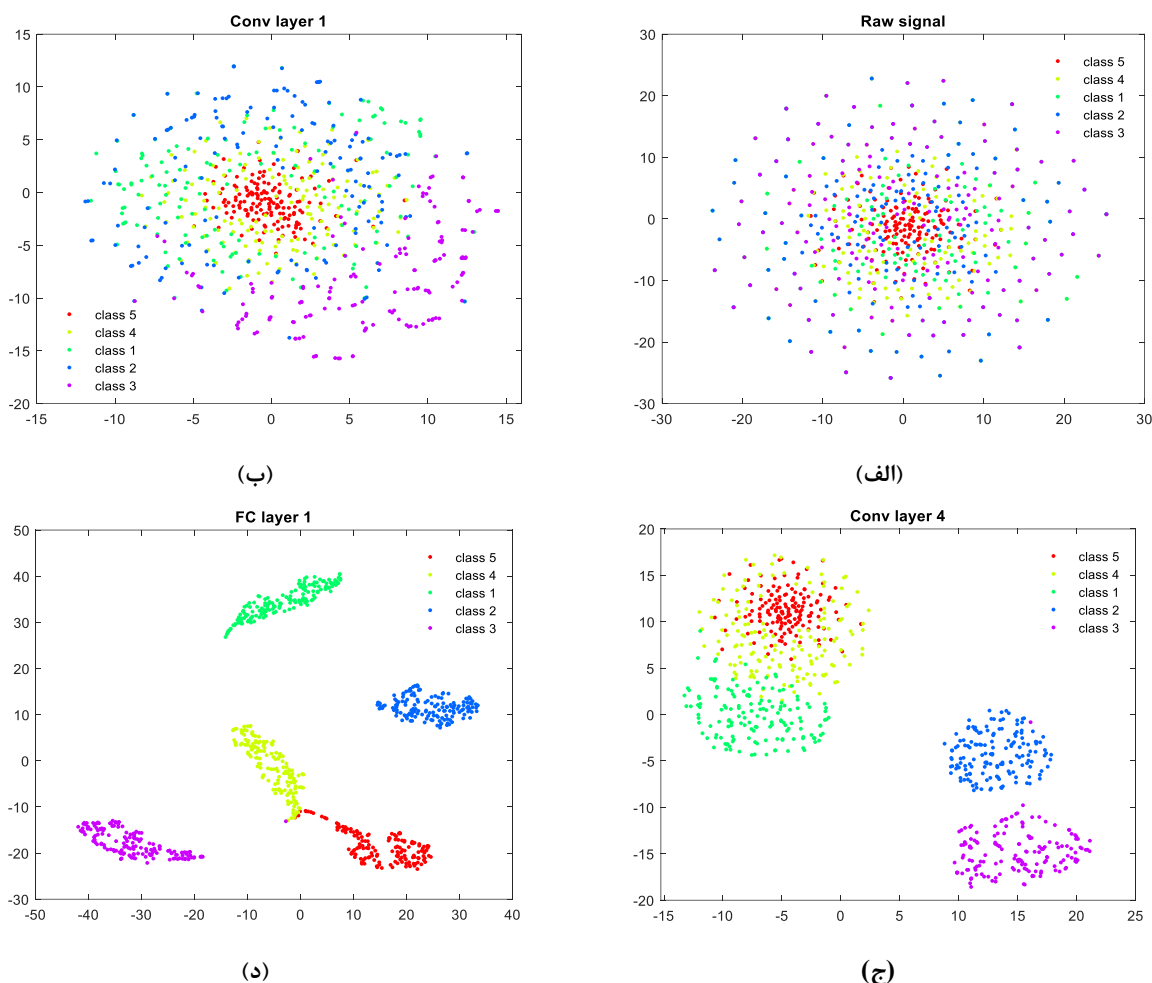
در این بخش، طیف فرکانسی سیگنال‌های بازسازی شده مدل ساده شبیه‌سازی شده و حالت سالم آزمایشگاهی در رنج فرکانسی صفر تا ۱۶۰۰ هرتز به‌عنوان ورودی به شبکه عمیق کانولوشنال پیشنهادی برای استخراج ویژگی‌های حساس به عیب ارائه خواهند شد. پس از آن طیف فرکانسی حالت‌های مختلف مدل آزمایشگاهی به‌عنوان ارزیابی شبکه پیشنهادی به کار برده می‌شوند. برای ارزیابی عملکرد الگوریتم

#### ۲-۴- انتخاب توابع مود ذاتی و بازسازی سیگنال‌های ارتعاشی

پس از اطمینان از صحت مدل‌سازی، بر اساس بخش ۳-۳، میانگین ضرایب همبستگی همه نمونه‌ها با سیگنال‌های ارتعاشی مربوط به خود (ضریب همبستگی بین سیگنال اصلی و هر تابع مود ذاتی) برای توابع مود ذاتی ۱ تا ۱۱ در هر کلاس مدل ساده شبیه‌سازی شده و حالت سالم مدل آزمایشگاهی در جدول ۴ آمده است.

همان‌طور که از جدول ۴ ملاحظه می‌شود هرچه شماره توابع مود ذاتی افزایش می‌یابد، مقدار ضریب همبستگی کاهش می‌یابد. ضرایب همبستگی توابع مود ذاتی ۷ تا ۱۱ نزدیک به صفر هستند، در صورتیکه ضرایب همبستگی توابع مود ذاتی ۱ تا ۶ که در جدول ۴ برجسته شده‌اند، بزرگتر از توابع مود ذاتی دیگر هستند. این نشان‌دهنده آن است که توابع مود ذاتی ۱ تا ۶ شامل اطلاعات بیشتری از سیگنال اصلی هستند. شکل ۱۳، توابع مود ذاتی ۱ تا ۱۱ را برای یک نمونه از حالت سالم مدل ساده شبیه‌سازی شده در حوزه زمان و فرکانس نشان می‌دهد.

همان‌گونه که از طیف‌های فرکانسی توابع مود ذاتی شکل ۱۳



شکل ۱۴. نمودار پراکندگی برای داده‌های آزمون. الف) سیگنال خام. ب) لایه اول کانولوشنال. ج) لایه چهارم کانولوشنال. د) لایه اول تمام متصل.

Fig. 14. T-Sen diagrams for testing data: (a) the raw time signal, (b) the Conv layer 1, (c) the Conv layer 4, (d) FC layer 1.

۵ نمایش داده شده است. همان‌طور که از جدول ۵ ملاحظه می‌شود، الگوریتم پیشنهادی می‌تواند همه کلاس‌ها را با صحت بالای ۹۰٪ از یکدیگر متمایز نماید.

برای مقایسه نتایج روش پیشنهادی، از شبکه پرسپترون<sup>۲</sup> [۳۱]-۳۰ با دو لایه مخفی<sup>۳</sup> استفاده شده است. برای تعیین ابر پارامترهای شبکه پرسپترون از روش سعی و خطا استفاده شده است و در نهایت تابع هدف میانگین مربعات<sup>۴</sup> و الگوریتم لونیگ-مارکواریت<sup>۴</sup> برای آموزش شبکه مورد استفاده قرار گرفته است. تعداد نورون‌ها در

پیشنهادی از معیار ارزیابی صحت طبق رابطه زیر استفاده می‌گردد [۲۹]:

$$\text{صحت} = \frac{TP+TN}{TP+TN+FP+FN} \quad (23)$$

که در آن TP موارد مثبتی است که به درستی مثبت تشخیص داده شده است. FP، موارد منفی است که به اشتباه مثبت تشخیص داده شده است. TN، موارد منفی است که به درستی منفی تشخیص داده شده است. FN، موارد مثبتی است که به اشتباه منفی تشخیص داده شده است. ماتریس درهم‌ریختگی<sup>۱</sup> با الگوریتم پیشنهادی در جدول

1 Confusion matrix

2 Multi-Layer Perceptron (MLP)  
3 Mean Squared Error (MSE)  
4 Levenberg-Marquardt



آموزش شبکه عمیق پیشنهادی تنها از داده‌های فرکانسی مدل ساده شبیه‌سازی شده و حالت سالم مدل آزمایشگاهی استفاده شد. پس از آن از داده‌های فرکانسی مدل آزمایشگاهی برای ارزیابی روش پیشنهادی استفاده شد. در این پژوهش نشان داده شد که انتخاب فیلتر با اندازه بزرگ در لایه اول باعث می‌شود که شبکه کانولوشنال طراحی شده نسبت به نویز حساسیت کمتری داشته و قدرت تشخیص عیوب مختلف در شرایط محیطی واقعی را داشته باشد. همچنین نشان داده شد که استفاده از فیلترها با اندازه کوچک در لایه‌های بعدی کانولوشن باعث بازنمایی بهتری از سیگنال ورودی شده و در نتیجه عملکرد شبکه را بهبود می‌بخشد.

نتایج نشان داد که با استفاده از داده‌های مدل ساده شبیه‌سازی شده و حالت سالم واقعی، شبکه پیشنهادی قادر به شناسایی و عیب‌یابی سازه تیری شکل تحت بارگذاری پیچیده است. همچنین روش پیشنهادی صحت بالاتری نسبت به سایر روش‌های مقایسه‌ای با ورودی‌های یکسان دارد و این نشان می‌دهد که روش پیشنهادی حساسیت کمتری به تغییرات بارگذاری دارد.

اگرچه سازه تیری شکل یک سیستم ساده مکانیکی است ولی می‌توان بیان کرد که روش پیشنهادی پتانسیل آن را دارد که برای شناسایی و عیب‌یابی بیشتر سیستم‌های پیچیده مکانیکی تحت بارگذاری‌های پیچیده نیز استفاده شود. همچنین می‌توان برای کارهای آینده از روش‌های ترکیبی پردازشی برای بهبود عملکرد روش پیشنهادی استفاده کرد.

### منابع و مراجع

- [1] H. Adeli, X. Jiang, Intelligent infrastructure: neural networks, wavelets, and chaos theory for intelligent transportation systems and smart structures, CRC press, 2008.
- [2] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, R.X. Gao, Deep learning and its applications to machine health monitoring, Mechanical Systems and Signal Processing, 115 (2019) 213-237.
- [3] L. Jing, M. Zhao, P. Li, X. Xu, A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox, Measurement,

لایه‌های مخفی شبکه پرسپترون، ۱۵۰، ۱۰۰ و نرخ یادگیری ۰/۰۰۰۱ در نظر گرفته شده است. جدول ۶ صحت الگوریتم پیشنهادی را در مقایسه با روش‌های مقایسه‌ای ارائه می‌دهد.

همان‌گونه که ملاحظه می‌شود وقتی از شبکه پیشنهادی با داده‌های فرکانسی سیگنال‌های زمانی بازسازی شده به‌عنوان ورودی استفاده می‌شود، صحت تشخیص عیوب مختلف تقریباً ۹۸٪ است. همچنین وقتی از شبکه پیشنهادی با داده‌های فرکانسی سیگنال‌های زمانی استفاده می‌شود، صحت تشخیص عیوب تقریباً ۹۴٪ است. وقتی از شبکه پرسپترون با داده‌های فرکانسی سیگنال‌های زمانی بازسازی شده و داده‌های فرکانسی سیگنال‌های زمانی به‌عنوان ورودی استفاده می‌شود، صحت به ترتیب ۸۱٪ و ۷۵٪ می‌شود. در شکل ۱۳ نمودار پراکندگی<sup>۱</sup> [۲۲] برای داده‌های آزمون ارائه شده است. در این شکل پراکندگی نمونه‌های سیگنال خام زمانی، پراکندگی نمونه‌ها در لایه اول و چهارم کانولوشنال و همچنین پراکندگی نمونه‌ها در لایه اول تمام متصل نشان داده شده است. همان‌طور که از شکل ۱۴ ملاحظه می‌شود هر چه شبکه پیشنهادی عمیق‌تر می‌شود، جداسازی نمونه‌های کلاس‌های مختلف از یکدیگر راحت‌تر می‌شود.

### ۵- نتیجه‌گیری

در این مقاله روش جدیدی برای شناسایی و عیب‌یابی سیستم‌های مکانیکی در حضور عدم قطعیت‌های مختلف بر پایه مدل المان محدود تحت بارگذاری ساده با یک نیروی تحریک تصادفی (مدل ساده شبیه‌سازی شده)، حالت سالم واقعی و شبکه عصبی عمیق ارائه شد. برای ارزیابی روش پیشنهادی از سازه تیری شکل تحت بارگذاری پیچیده‌تر با دو نیروی تحریک تصادفی در محیط آزمایشگاهی (مدل آزمایشگاهی) استفاده شد. به‌روزرسانی پارامترهای مدل شبیه‌سازی شده بر پایه داده‌های سالم مدل آزمایشگاهی انجام گرفت. برخی از بخش‌های سیگنال‌ها که مربوط به ذات سیستم نیستند با استفاده از روش تجزیه مود تجربی دسته‌ای حذف شدند. یک شبکه کانولوشنال عمیق برای یادگیری ویژگی‌ها از داده‌های فرکانسی و شناسایی عیوب سازه طراحی شد. داده‌های فرکانسی با استفاده از روش چگالی طیفی توان از پاسخ‌های دینامیکی به‌دست آمدند. برای

- 17(4) (2018) 747-762.
- [14] W. Weaver Jr, P.R. Johnston, Structural dynamics by finite elements, Prentice-Hall Englewood Cliffs (NJ), 1987.
- [15] I. Chowdhury, S.P. Dasgupta, Computation of Rayleigh damping coefficients for large systems, The Electronic Journal of Geotechnical Engineering, 8(0) (2003) 1-11.
- [16] S. Wu, S. Law, Vehicle axle load identification on bridge deck with irregular road surface profile, Engineering Structures, 33(2) (2011) 591-601.
- [17] S. Varahram, P. Jalali, M.H. Sadeghi, S. Lotfan, Experimental Study on the Effect of Excitation Type on the Output-Only Modal Analysis Results, Transactions of FAMENA, 43(3) (2019) 37-52.
- [18] M.E. Torres, M.A. Colominas, G. Schlotthauer, P. Flandrin, A complete ensemble empirical mode decomposition with adaptive noise, in: 2011 IEEE international conference on acoustics, speech and signal processing (ICASSP), IEEE, 2011, pp. 4144-4147.
- [19] I. Goodfellow, Y. Bengio, A. Courville, Deep learning, MIT press, 2016.
- [20] S.-L. Hung, H. Adeli, Parallel backpropagation learning algorithms on Cray Y-MP8/864 supercomputer, Neurocomputing, 5(6) (1993) 287-302.
- [21] Z. Mousavi, T.Y. Rezaei, S. Sheykhivand, A. Farzamnia, S. Razavi, Deep convolutional neural network for classification of sleep stages from single-channel EEG signals, Journal of neuroscience methods, (2019) 108312.
- [22] W. Zhang, C. Li, G. Peng, Y. Chen, Z. Zhang, A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load, Mechanical Systems and Signal Processing, 100 (2018) 439-453.
- [23] A. Mojtahedi, M.L. Yaghin, Y. Hassanzadeh, M. Etefagh, M. Aminfar, A. Aghdam, Developing a robust SHM method for offshore jacket platform using model updating and fuzzy logic system, Applied Ocean Research, 33(4) (2011) 398-411.
- [24] A. Mosallam, T. Zirakian, A. Abdelaal, A. Bayraktar, Health monitoring of a steel moment-resisting frame subjected to seismic loads, Journal of Constructional Steel 111 (2017) 1-10.
- [4] F. Jia, Y. Lei, J. Lin, X. Zhou, N. Lu, Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data, Mechanical Systems and Signal Processing, 72 (2016) 303-315.
- [5] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, D.J. Inman, Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks, Journal of Sound and Vibration, 388 (2017) 154-170.
- [6] F. Jia, Y. Lei, L. Guo, J. Lin, S. Xing, A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines, Neurocomputing, 272 (2018) 619-628.
- [7] W. Zhang, G. Peng, C. Li, Y. Chen, Z. Zhang, A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals, Sensors, 17(2) (2017) 425.
- [8] M. Turner, Stiffness and deflection analysis of complex structures, journal of the Aeronautical Sciences, 23(9) (1956) 805-823.
- [9] Y.z. Lin, Z.h. Nie, H.w. Ma, Structural damage detection with automatic feature-extraction through deep learning, Computer-Aided Civil and Infrastructure Engineering, 32(12) (2017) 1025-1046.
- [10] J. Guo, J. Wu, J. Guo, Z. Jiang, A Damage Identification Approach for Offshore Jacket Platforms Using Partial Modal Results and Artificial Neural Networks, Applied Sciences, 8(11) (2018) 2173.
- [11] J. Gu, M. Gul, X. Wu, Damage detection under varying temperature using artificial neural networks, Structural Control and Health Monitoring, 24(11) (2017) e1998.
- [12] Y. Chen, G. Peng, C. Xie, W. Zhang, C. Li, S. Liu, ACDIN: Bridging the gap between artificial and real bearing damages for bearing fault diagnosis, Neurocomputing, 294 (2018) 61-71.
- [13] M. Fallahian, F. Khoshnoudian, V. Meruane, Ensemble classification method for structural damage assessment under varying temperature, Structural Health Monitoring,

- models for the MARK-AGE data, Mechanisms of ageing and development, 151 (2015) 45-53.
- [28] S.S. Rao, F.F. YAP, Upper Saddle River: Mechanical vibrations, in, Prentice Hall, 2011.
- [29] S. Kim, J.-H. Choi, Convolutional neural network for gear fault diagnosis based on signal segmentation approach, Structural Health Monitoring, 18(5-6) (2019) 1401-1415.
- [30] M. Hagan, H. Demuth, M. Beale, O. De Jesús, Neural network design vol. 20: Pws Pub, in, Boston, 1996.
- [31] V.N. Ghate, S.V. Dudul, Optimal MLP neural network classifier for fault detection of three phase induction motor, Expert Systems with Applications, 37(4) (2010) 3468-3481.
- Research, 140 (2018) 34-46.
- [25] Z. Ding, J. Li, H. Hao, Z.-R. Lu, Structural damage identification with uncertain modelling error and measurement noise by clustering based tree seeds algorithm, Engineering Structures, 185 (2019) 301-314.
- [26] E. Barton, C. Middleton, K. Koo, L. Crocker, J. Brownjohn, Structural finite element model updating using vibration tests and modal analysis for NPL Footbridge-SHM demonstrator, in: Journal of Physics: Conference Series, IOP Publishing, 2011, pp. 012105.
- [27] E. Giampieri, D. Remondini, M.G. Bacalini, P. Garagnani, C. Pirazzini, S.L. Yani, C. Giuliani, G. Menichetti, I. Zironi, C. Sala, Statistical strategies and stochastic predictive

چگونه به این مقاله ارجاع دهیم

Z. Mousavia, M.M. Etefagh, M.H. Sadeghi, S.N. Razavi, Identification and damage detection of beam-like structure using vibration signals based on simulated model, real healthy state and deep convolutional neural network, AmirKabir J. Mech Eng., 53(4) (2021) 2193-2216.

DOI: [10.22060/mej.2020.17380.6586](https://doi.org/10.22060/mej.2020.17380.6586)



