

Amirkabir Journal of Mechanical Engineering

Amirkabir J. Mech. Eng., 53(Special Issue 6) (2021) 899-902 DOI: 10.22060/mej.2020.18553.6843

Damage detection of offshore jacket structure using dynamic responses based on simulated model, intact state of real model and deep auto-encoder neural network

Z. Mousavi^{1,} S. Varahram¹, M. M. Ettefagh1^{*}, M. Ho. Sadeghi¹, S. Na. Razavi²

ABSTRACT: Since the maintenance and repairing costs of mechanical systems, such as structures and

rotating machines are significantly high, one way to reduce these costs is to consider some approaches

before any operational work to check for damages in such systems. In this study, a new method is

presented for damage detection of offshore jacket structures in the presence of various uncertainties,

such as modeling errors, measurement errors and environmental noises, based on the simulated model and intact state of the real model. In the proposed method, real intact structure data is used to update the simulated model parameters. Some parts of the signal that are not related to the nature of the system

are removed using the complete ensemble empirical mode decomposition method. Frequency data is

extracted from the vibrational signals using the frequency domain decomposition method. A deep auto-

encoder neural network is designed to learn the damage-sensitive features from the frequency data and

to damage detection of the structure. In order to train the proposed deep network, frequency data of the

simulated model and real intact state are used; then the frequency data of the real structure is used to test the proposed deep network. The results show that the proposed method is capable for damage detection

of the offshore jacket structure with more accurate results than the other comparative methods.

¹Faculty of Mechanical Engineering, University of Tabriz, Tabriz, Iran. ² Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran.

Review History:

Received: Jun. 07, 2020 Revised: Oct. 07, 2020 Accepted: Oct. 25, 2020 Available Online: Nov, 1, 2020

Keywords:

Condition monitoring Offshore jacket structure Model updating Deep neural network

1-Introduction

Offshore jacket structures are the most general types of offshore structures and play an important role in shallow and medium waters in the oil and gas industry. In addition, they are used as jacket substructure for offshore wind turbines in deep water (30-60 m). Therefore, damage detection of offshore jacket structures is highly necessary in order to ensure their safety.

In recent years, machine learning has been used as an effective tool for damage detection of mechanical systems. Artificial neural networks are a set of machine learning algorithms that are divided into two general categories; shallow neural networks and deep neural networks. In deep networks, the features are automatically extracted and the accuracy of these algorithms is higher than the shallow networks [1-2].

A new method for damage detection of mechanical systems is presented in this paper. The first aim of this paper is to provide a method for damage detection of mechanical systems in the presence of various uncertainties. One of the benefits of deep learning is that it can learn damagesensitive features from raw data in the presence of various uncertainties. Accordingly, the second aim of this paper is to design a deep auto-encoder network to learn the damagesensitive features from raw frequency data. Data collection in industrial environments is difficult and even impossible,

and generally, only intact data is available [3]. Accordingly, the third aim of this paper is to train the proposed deep network based on the frequency data of simulated model and intact state of the real model, and then to evaluate the deep network with the frequency data of real model. In the proposed method, the simulated model parameters are updated based on the intact data of real model. Some parts of the vibration signals that are not related to the nature of the system are removed using the Complete Ensemble Empirical Mode Decomposition (CEEMD) method [4]. Frequency data is obtained from the vibration signals using the Frequency Domain Decomposition (FDD) method [5]. An offshore jacket structure model in the laboratory is used as a case study to evaluate the proposed method.

2- Methodology

In this section, at first, the simulated and laboratory models of the offshore jacket structure are described. The proposed algorithm for damage detection of the offshore jacket structure is then expressed.

2-1- Finite Element (FE) model of the offshore jacket structure

An initial three-dimensional finite element model of the offshore jacket structure is created using Abaqus software, taking into account the small deformations and linear

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



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





Fig. 1. Finite element model of the offshore jacket structure in intact state.

Fig. 2. The laboratory offshore jacket model in intact state.



Fig. 3. Extracted dynamic responses using 12 accelerometers mounted on the structure.

behavior of the system. The created finite element model in the intact state is shown in Fig. 1. The dimensions of the finite element model are created exactly according to the dimensions of the real structure (Fig. 2). The structure has five stories, all of which are horizontally braced and two middle stories are diagonally braced.

2-2- Laboratory model of the offshore jacket structure

In this study, an offshore jacket structure model (Fig. 2) was designed and installed in the Tabriz University Modal and Vibration Analysis Laboratory. A shaker is used to produce an artificial excitation force. The shaker is connected to one of the vertical columns in the middle section of the third story using a ring-type fixture [6]. 12 Accelerometers are mounted on the structure to extract the dynamic responses. Fig. 3 shows the dynamic responses extracted using the 12 accelerometers mounted on the structure.

2-3- The proposed damage detection algorithm

The major procedure of the proposed damage detection algorithm is listed as follows (see Fig. 4):

(a) Extracting the dynamic responses corresponding to different states of finite element and laboratory models.

(b) Data preprocessing and Finite element model updating [7].

(c) Selecting the Proper Intrinsic Mode Functions) IMFs) using CEEMD method and signal reconstruction.

(d) Generating raw frequency data from dynamic responses using FDD method.

(e) Dividing the data into three parts, namely training data based on finite element model and the intact state of the laboratory model, validation data and testing data based on laboratory model.

(f) Designing a Deep Auto-Encoder (DAE) neural network in order to learn the damage-sensitive features from



Fig. 4. The block diagram of the proposed algorithm.



Fig. 5. The FE models for different damage states.

raw frequency data of the finite element model and the intact state of the laboratory model.

(g) Investigating the performance of the proposed deep network for damage detection of the laboratory structure.

3- Results and Discussion

The results of the proposed algorithm for damage detection of the offshore jacket structure are presented in this section. In order to evaluate the accuracy of the results of the finite element model, the mean values of the natural frequencies of the intact structure for both finite element and laboratory models are obtained using FDD method and compared with each other (see Table. 1).

After ensuring that the finite element model is accurate, the frequency data of the reconstructed signals of the finite element model and intact state of the laboratory model are used as the training data of the proposed deep network for extracting the damage-sensitive features. Then, the frequency data of the reconstructed signals of the Laboratory model is used for evaluating the proposed deep network. This study is based on 5 states in 3 scenarios for both finite element and laboratory models. The created finite element models for different damage states of the structure are shown in Fig. 5



Fig. 6. Confusion matrices of the proposed algorithm (a) Scenario of 2-Class; (b) Scenario of 3-Class; (c) Scenario of 5-Class.

which the braces marked with red color are removed in each damage state. Also, the confusion matrix [8] of the proposed algorithm is shown in Fig. 6.

4- Conclusions

This paper presents a new damage detection method based on the finite element model and the intact state of the real model, in the presence of different uncertainties using deep network. The finite element model parameters are updated on

Mode No.	Natu	Error (%)			
	Laboratory Model	FE M	odel	FE Model compared with Laboratory Model FDD-FDD	
	David an EDD	Based of	n FDD		
	Based on FDD	Before updating	After updating	Before updating	After updating
1	14.25	14.98	14.46	5.1%	1.5%
2	-	-	-	-	-
3	51.36	53.93	52.10	5.0%	1.4%
4	80.13	80.84	80.36	0.88%	0.29%
5	-	-	-	-	-
6	104.33	103.56	104.15	0.73%	0.17%

Table 1. Comparison of the mean values of the natural frequencies for the intact structure using different methods before and after undating

the basis of real intact 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 finite element model and the real intact state are used. After that, the frequency data of the real model is used to evaluate the proposed network. Frequency data is extracted from vibration signals using FDD method. An offshore jacket structure in the laboratory environment is used to evaluate the proposed algorithm. The results show that, the proposed deep network is able to detect the damages of the real structure using the finite element model data and the real intact state.

References

- H. Ahmed, M.L.D. Wong, A.K. Nandi, Intelligent condition monitoring method for bearing faults from highly compressed measurements using sparse overcomplete features, Mechanical Systems and Signal Processing, 99 (2018) 459-477.
- [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] 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.

- [4] 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.
- [5] J.-H. Yi, J.-S. Park, S.-H. Han, K.-S. Lee, Modal identification of a jacket-type offshore structure using dynamic tilt responses and investigation of tidal effects on modal properties, Engineering Structures, 49 (2013) 767-781.
- [6] 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.
- [7] A. Mojtahedi, M.L. Yaghin, Y. Hassanzadeh, M. Ettefagh, 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.
- [8] 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. Mousavi, S. Varahram, M. M. Ettefagh, M. Ho. Sadeghi, S. Na. Razavi, Damage detection of offshore jacket structure using dynamic responses based on simulated model, intact state of real model and deep auto-encoder neural network, Amirkabir J. Mech. Eng., 53(Special Issue 6) (2021) 899-902.



DOI: 10.22060/mej.2020.18553.6843

نشريه مهندسي مكانيك اميركبير



نشریه مهندسی مکانیک امیرکبیر، دوره ۵۳، شماره ویژه ۶، سال ۱۴۰۰، صفحات ۳۷۸۳ تا ۳۸۰۸ DOI: 10.22060/mej.2020.18553.6843

عیبیابی سازه جکتی فراساحلی با استفاده از پاسخهای دینامیکی بر پایه مدل شبیهسازیشده، حالت سالم مدل واقعی و شبکه عصبی خود رمزنگار عمیق

زهره موسوی'، سینا ورهرام'، میر محمد اتفاق'*، مرتضی همایون صادقی'، سید ناصر رضوی ً

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

تاریخچه داوری: دریافت: ۱۳۹۹/۰۳/۱۸ بازنگری: ۱۳۹۹/۰۷/۱۶ پذیرش: ۱۳۹۹/۰۸/۰۴ ارائه آنلاین: ۱۳۹۹/۰۸/۲۸

> **کلمات کلیدی:** پایش وضعیت سازہ جکتی فراساحلی بهروزرسانی مدل شبکه عصبی عمیق

۱ – مقدمه

در صنعت، سیستمهای مکانیکی و سازهها بهعنوان تجهیزات اساسی و مهم به شمار میروند و بهطور گسترده مورد استفاده قرار میگیرند؛ بنابراین پایش وضعیت آنها امری ضروری است. علاوه بر این پایش وضعیت سازههای فراساحلی که بهطور مداوم در معرض عیوب مختلف درنتیجه تغییرات نیروهای محیطی هستند، از اهمیت بالاتری برخوردار است. سازههای جکتی فراساحلی متداول ترین نوع سازههای دریایی هستند و نقش بسزایی در صنایع نفت و گاز در آبهای کمعمق و متوسط دارند. علاوه بر این، آنها بهعنوان زیر ساختارهای جکتی برای توربینهای بادی فراساحلی^۲ در آبهای عمیق (۶۰–۳۰ متر) مورد استفاده قرار می گیرند. عیبیابی بهموقع سازه جکتی فراساحلی بهمنظور شناسایی عیوب احتمالی و تضمین ایمنی آن امری لازم است، اما انجام تستهای تعمیر و نگهداری در شرایط عملیاتی

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

2

پرهزینه و حتی گاهی غیرممکن است؛ بنابراین، استفاده از روشهای مناسب و قدرتمند برای شناسایی عیوب سازه در جلوگیری از توقّف کامل و بروز خسارات جانی و مالی بسیار کارآمد است.

در سالهای اخیر یادگیری ماشین بهعنوان ابزاری مناسب برای انتخاب ویژگیها بهمنظور عیبیابی سیستمهای مکانیکی موردتوجه قرار گرفته است. شبکههای عصبی مصنوعی^۲ مجموعهای از الگوریتمها هستند که در یادگیری ماشین برای مدلسازی دادهها استفاده میشوند. استفاده از شبکههای عصبی برای تشخیص عیوب، روشهای جدیدی را برای پایش وضعیت فراهم میکند. شبکههای عصبی به دو دسته کلی تقسیم میشوند؛ شبکههای عصبی کمعمق^۴ و شبکههای عصبی عمیق⁶. شبکههای عصبی عمیق به طور گسترده و با موفقیتهای زیادی در پردازش تصویر و سیگنالها در حوزه زمان و فرکانس مورد استفاده قرار گرفتهاند [۱–۳]. هدف

¹ Condition Monitoring

Offshore Wind Turbines

^{*} نویسنده عهدهدار مکاتبات: ettefagh@tabrizu.ac.ir

³ Artificial Neural Network (ANN)

⁴ Shallow Neural Networks (SNN)

⁵ Deep Neural Networks (DNN)

الگوریتمهای یادگیری عمیق کشف چندین سطح از بازنمایی توزیعشده از دادههای ورودی است. برخی از مزایای الگوریتمهای یادگیری عمیق نسبت به الگوریتمهای کمعمق عبارتاند از؛ در این الگوریتمها بهصورت خودکار استخراج ویژگیها و کاهش آنها صورت میپذیرد، همچنین دقت این الگوریتمها نسبت به الگوریتمهای کمعمق بیشتر است. در مقابل این مزایا، این الگوریتمها معایبی نیز دارند که برخی از این معایب عبارتاند از؛ جمع آوری دادههای حجیم امری زمان بر است. معماریهای مختلف یادگیری عمیق، مانند شبکههای عصبی عمیق کانولوشنال^۱، شبکههای باور عمیق^۲ و شبکههای خود رمزنگار^۳ برای کاهش ابعاد دادههای ورودی و استخراج ویژگیهای مطلوب استفاده میشوند [۴]. یک مرور کلی از کاربرد شبکههای عصبی عمیق برای پایش وضعیت سیستمهای مکانیکی در مرجع [۵] ارائه شدهاست.

دادههای سیستمهای مکانیکی را میتوان به دو دسته کلی مصنوعی و واقعی که بر پایه الگوریتمهای داده محور ٔ هستند، تقسیم کرد. دادههای واقعی را می توان از سیستمهای واقعی یا سیستمهای آزمایشگاهی بهدستآورد که بهدستآوردن این دادهها بهخصوص در حالتهای معیوب، بسیار پرهزینه است. در مقابل، بهدست آوردن دادههای مصنوعی آسان تر و کمهزینه تر از دادههای واقعی است، زیرا می توان با استفاده از مدل های شبیه سازی شده این دادهها را استخراج کرد. الگوریتمهای دادهمحور بهطور مؤثر در تشخیص عیوب سیستم مکانیکی موفق بودهاند. بسیاری از الگوریتمهای دادهمحور مبتنی بر الگوریتمهای یادگیری ماشین هستند. احمد و همکاران [۵] یک روش عیبیابی هوشمند را برای تشخیص عیوب یاتاقانها از اندازه گیری های فشرده شده بر پایه حسگری فشرده مورد بررسی قرار دادند. در این مطالعه، تأثیرات یک شبکه عصبی خود رمزنگار بر عملکرد عیبیابی بررسی شد. نتایج نشان داد که این روش در مقایسه با روشهای موجود، قادر بهدستیابی به سطح بالاتری از صحت برای تشخیص عیوب است. ژانگ و همکاران [۶] روش جدیدی را بر اساس یادگیری عمیق برای تشخیص عیوب بیرینگ در محیط نویزی و تحت شرایط بارگذاری مختلف ارائه دادند. در این روش سیگنالهای زمانی خام بدون هیچ گونه پیش پردازشی بهعنوان ورودی به شبکه عمیق داده شدند. نتایج نشان داد که روش ارائهشده، توانایی

1 Convolution Deep Neural Networks (CDNN)

شناسایی عیوب بیرینگ در محیط نویزی و بارگذاریهای مختلف را دارد. جینگ و همکاران [Y] روشی را برای شناسایی عیوب گیربکس بر پایه یادگیری ویژگی با استفاده از شبکههای عمیق ارائه دادند. در این مطالعه یک شبکه کانولوشنال عمیق برای یادگیری ویژگیها بهطور مستقیم از دادههای فرکانسی سیگنالهای ارتعاشی ارائه شد و عملکرد آن با یادگیری ویژگیها از دادههای زمانی خام و دادههای ترکیبی زمان و فرکانس مقایسه شد. نتایج نشان داد که روش ذکرشده قادر به یادگیری ویژگیهای مطلوب از دادههای فرکانسی و دستیابی بهدقت بالاتر از سایر روشهای مقایسهای است. ازآنجاکه جمعآوری دادههای عیوب واقعی بسیار دشوار و حتی غیرممکن این و بهطورکلی فقط دادههای عیوب واقعی بسیار دشوار و حتی غیرممکن ندارد که استفاده از روشهای مبتنی بر الگوریتمهای دادهمحور بهسرعت در است و بهطورکلی فقط دادههای حالت سالم در اختیار است، جای تعجب ندارد که استفاده از روشهای مبتنی بر الگوریتمهای دادهمحور بهسرعت در است و بهطورکلی فقط دادههای میتنی بر الگوریتمهای دادهمحور بهسرعت در اندارد که استفاده از روشهای مبتنی بر الگوریتمهای دادهمحور دهسرعت در ندارد که استفاده از روشهای مبتنی بر الگوریتمهای دادهمحور به است ندارد که استفاده از روشهای میتنی بر الگوریتمهای دادهمحور به سرعت در ندارد که استفاده از روشهای میتنی میرامحل برای حل این مسئله، استفاده ندارد دی استی میوب مصنوعی به جای واقعی است [۸]. بر این اساس، استفاده از رویکرد مدل شبیه سازی شده و حالت سالم مدل واقعی می تواند یک راه حل مفید باشد.

گو و همکاران [۹] رویکردی را برای تشخیص عیوب سازههای جکتی فراساحلی با استفاده از آنالیز مودال و شبکههای عصبی پیشنهاد کردند. در این مطالعه، مدل المان محدود^ه و شاخصهای تشخیص عیب برای ترکیب ویژگیهای مودال و فرکانسهای طبیعی پیشنهاد شدند. درنهایت از این دادهها برای آموزش شبکههای عصبی و تشخیص عیوب استفاده شد که نتايج حاصل از محاسبات نشان داد كه روش ارائه شده كاملا دقيق است. لیو و همکاران [۱۰] روش جدیدی را مبتنی بر آنالیز مودال برای تشخیص عیوب سازههای جکتی فراساحلی ارائه دادند. در پژوهش ارائهشده، مدل المان محدود شبیه سازی شده برای حالتهای مختلف عیب در حضور نویزها و عدم قطعیتهای مختلف توسعه داده شد. این مطالعه دقت و اثربخشی روش ارائه شده را در حضور نویزها و عدم قطعیتهای مختلف نشان داد. هنگامی که از دادههای شبیهسازی شده بهجای دادههای واقعی استفاده می شود، به علت عدم قطعیتهای مختلف تفاوتهایی بین ویژگیهای دینامیکی آنها ظاهر می شود؛ بنابراین، بهروزرسانی مدل شبیه سازی شده بر اساس دادههای حالت سالم واقعی و استخراج ویژگیهای حساس به عیب و مشترک بین دادههای شبیه سازی شده و واقعی ضروری است. بااین حال، استخراج این ویژگیها با روشهای استخراج ویژگی سنتی بهخوبی امکان پذیر نیست [۸].

مجتهدی و همکاران [۱۱] یک روش عیبیابی را برای سازه جکتی

² Deep Belief Networks (DBN)

³ Deep Auto-Encoders (DAE)

⁴ Data-driven algorithms

⁵ Finite Element (FE) model

فراساحلی با استفاده از مدل بهروزرسانی شده و منطق فازی ارائه دادند. در این مطالعه، یک مدل پایه المان محدود بر اساس مدل أزمایشگاهی سازه جكتى فراساحلى باهدف پايش وضعيت طولانىمدت اين نوع سازهها ایجاد شد. اثربخشی روش ارائهشده برای پایش وضعیت سازه آزمایشگاهی با استفاده از ایجاد سناریوهای عیوب مختلف در مدل المان محدود، موردبررسی قرار گرفت. دینگ و همکاران [۱۲]، رویکرد جدیدی را بر پایه الگوریتم خوشهبندی برای تشخیص عیوب سازهای با خطاهای نامشخص ناشی از عدم قطعیتهای مختلف ارائه دادند. در این مطالعه، تابع هدف بر اساس دادههای مودال توسعه یافت. مطالعه عددی بر روی سازه خرپا شکل و همچنین مطالعه تجربی بر روی سازه قاب فلزی آزمایشگاهی بهمنظور ارزیابی بیشتر روش پیشنهادی انجام شد. نتایج تحقیقات عددی و تجربی با نتايج چند الگوريتم تكاملي مقايسه شد كه نشان داد كه اين روش در شناسایی عیوب سازهای نتایج بهتری نسبت به روشهای مقایسهای دارد. فلاحیان و همکاران [۱۳]، یک روش طبقهبندی ترکیبی بر پایه کدینگ تُنُک و شبکه عصبی عمیق، برای ارزیابی عیوب سازهای در دماهای مختلف ارائه دادند. این روش با استفاده از یک مدل عددی پل و دادههای تجربی آن تأیید شد. نتایج بهدست آمده، اثربخشی روش بیان شده در شرایط مختلف دمایی را نشان داد.

در این مقاله روش جدیدی برای پایش وضعیت سیستمهای مکانیکی ارائهشدهاست. اولین هدف این مقاله ارائهدادن روشی برای عیبیابی سیستمهای مکانیکی در حضور عدم قطعیتهای مختلف مانند خطاهای مدلسازی، خطاهای اندازهگیری 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 مورداستفاده قرارگرفتهاست. یکی از مزایای استفاده از یادگیری عمیق این است که در حضور عدم قطعیتهای مختلف میتواند ویژگیهای حساس به عیب را از دادهها بیاموزد. بر این اساس، دومین هدف این مقاله طراحی یک شبکه خود رمزنگار و عیبیابی سیستم مکانیکی واقعی در حضور عدم قطعیتهای مختلف است. در شبکه پیشنهادی، طبقهبندی پیش آموزش^۳ با روش بدون نظارت^۴ و

انجام می شود و سپس طبقه بندی با آموزش مجدد عبا استفاده از الگوریتم پس انتشار خطا^۷ برای تنظیم دقیق^۸ ابر پارامترهای شبکه عمیق پیشنهادی انجام می شود (مرحله دوم). در محیطهای صنعتی جمع آوری دادههای معیوب دشوار و حتى غيرممكن است و بهطوركلى فقط داده حالت سالم در اختيار است، بنابراین ارائهدادن روشی برای عیبیابی سیستمهای مکانیکی بر پایه عیبهای شبیهسازی شده و داده حالت سالم مدل واقعی، لازم و ضروری است. بر این اساس، سومین هدف این مقاله آموزشدادن شبکه عمیق پیشنهادی بر اساس دادههای فرکانسی مدل شبیهسازی شده و حالت سالم واقعی است و سپس ارزیابی شبکه عمیق با دادههای فرکانسی مدل واقعی 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^۰ حذف شدهاند. دادههای فرکانسی با استفاده از روش تجزیه حوزه فرکانس^{۱۰} از سیگنالهای ارتعاشی بهدستآمدهاند. برای ارزیابی روش پیشنهادی از سازه جکتی فراساحلی در محیط آزمایشگاهی بهعنوان یک مطالعه موردی استفاده شدهاست.

ادامه مقاله بهصورت زیر تدوین شدهاست؛ در بخش ۲ مواد و روشها بررسی خواهندشد. در بخش ۳، الگوریتم پیشنهادی مورد استفاده در این مقاله ارائه داده می شود. در بخش ۴ نتایج شبیه سازی و مقایسه با روشهای دیگر مورد بحث قرار می گیرد؛ درنهایت، بخش ۵ مربوط به نتیجه گیری است.

۲- مواد و روشها

در این بخش در ابتدا مدلسازی دینامیکی و آزمایشگاهی سازه جکتی فراساحلی، بهعنوان یک مطالعه موردی، شرح داده می شود. پس از آن روش های تجزیه مود تجربی دسته ای کامل، تجزیه حوزه فرکانس و شبکه عصبی عمیق ارائه خواهند شد.

۲- ۱- مدلسازی المان محدود سازه جکتی فراساحلی

با درنظر گرفتن تغییر شکلهای کوچک و رفتار خطی سیستم، یک مدل سهبعدی المان محدود اولیه از سازه فلزی جکتی فراساحلی با استفاده از نرمافزار آباکوس ایجاد شده است. اصطلاح "اولیه" نشان میدهد که مدل

¹ Ensemble classification method

² Sparse coding

³ Pre-training classification

⁴ Unsupervised

⁵ Softmax layer

⁶ Re-training classification

⁷ Back-Propagation (BP) algorithm

⁸ Fine tuning

⁹ Complete Ensemble Empirical Mode Decomposition (CEEMD)

¹⁰ Frequency Domain Decomposition (FDD) method





شکل ۲. مدل سازه جکتی فراساحلی در مقیاس اَزمایشگاهی در حالت سالم Fig. 2. The laboratory offshore jacket model in intact state.

(شکل ۲) که در آزمایشگاه آنالیز مودال و ارتعاشات دانشگاه تبریز طراحی و نصب شدهاست، استفاده میشود. تجهیزات آزمایشگاهی شامل یک سیستم پردازشگر داده^۱، یک لرزاننده^۲، ۱۲ شتابسنج^۳ با حساسیتهای مختلف، یک نیروسنج^۴، یک لپتاپ، یک اسیلوسکوپ^۵، یک آمپلیفایر^{*} و کابلهای انتقال است. ۱۲ شتابسنج که شامل سه مجموعه از چهار شتابسنج هستند برای است در جهت x و دو شتاب سنج دیگر در جهت y بر روی هر طبقه شتابسنج در جهت x و دو شتاب سنج دیگر در جهت y بر روی هر طبقه نصبشدهاند. شکل ۳ موقعیت ۱۲ شتابسنج نصبشده بر روی ۴ ستون نصبشدهاند. شکل ۳ موقعیت ۱۲ شتابسنج نصبشده بر روی ۴ ستون ناوه را نشان میدهد؛ شتابسنجهای Id و Ed و شتابسنجهای 2*b* اسازه را نشان میدهد؛ شتابسنجهای Id و Ed و شتابسنجهای مشابه از لرزاننده برای تولید نیروی تحریک مصنوعی و از مبدل نیرو برای ثبت در بالا و پایین آن به همان روش نصب میشوند (شکل ۳). در این مطالعه، از لرزاننده برای تولید نیروی تحریک مصنوعی و از مبدل نیرو برای ثبت مین یرو استفاده میشود. نیروی تولیدشده در لرزاننده، نویز سفید گوسین^۷ با

1 National Instrument

- 2 Shaker
- 3 Accelerometer
- 4 Force transducer
- 5 Oscilloscope
- 6 Power amplifier
- 7 White Gaussian noise

شکل ۱. مدل المان محدود سازه جکتی فراساحلی در حالت سالم. Fig. 1. Finite element model of the offshore jacket

structure in intact state.

المان محدود به دلیل عدم قطعیتهای مختلف می تواند دقیق نباشد؛ بنابراین، مدل اولیه مبنایی برای بهروزرسانی پارامترهای مدل در نظر گرفته می شود. مدل المان محدود ایجادشده در حالت سالم در شکل ۱ نشان داده شده است. برای تمامی اعضا، مدول اولیه یانگ (E)، ضریب پواسون (V)، چگالی (ρ) و ضریب میرایی (\tilde{Z}) بهترتیب ۲۰۰ گیگا پاسکال، ۲/۰، ۲/۰۰ کیلوگرم بر مترمکعب و ۱۰ /۰ است. اتصالات مشترک، صلب در نظر گرفته شده و شرط مرزی گیردار در قسمت زیرین سازه اعمال شده است. تمامی اعضای این مدل با المانهای دوبعدی تیر مش بندی شدهاند که امکان تغییر شکل ابعاد سازه واقعی ایجاد می شود (شکل ۲). ارتفاع سازه ۲ متر، ابعاد پایینی سازه ابعاد سازه واقعی ایجاد می شود (شکل ۲). ارتفاع سازه ۲ متر، ابعاد پایینی سازه دارای پنج طبقه است که در تمامی طبقهها از میلههای برشی افقی و در یایههای اصلی ۱/۶ سانتیمتر و قطر میلههای برشی افقی و مورب ۲/۱ پایههای اصلی ۱/۶ سانتیمتر و قطر میلههای برشی افقی و مورب ۲/۱

۲- ۲- مجموعه تجهیزات آزمایشگاهی سازه جکتی فراساحلی
 در این مطالعه از مدل سازه جکتی فراساحلی در مقیاس آزمایشگاهی



شکل ۳. موقعیت و جهت شتابسنجهای نصب شده بر روی ۴ ستون سازه



است که شامل تمامی فرکانسها در این محدوده میباشد [۱۱]. لرزاننده به بخش میانی ستون I در طبقه سوم با استفاده از یک فیکسر حلقهای ساختهشده از آلیاژ برنج و یک استینگر انعطاف پذیر^۱ با سختی محوری بالا^۲ که از انجام هرگونه گشتاور تحریک یا بارگیری چرخشی جلوگیری میکند، به سازه متصل شدهاست [۱۵]. فاصله بین نقطه تحریک و انتهای طبقه سوم ۸/۱۱ سانتیمتر است. در شکل ۴ پاسخهای دینامیکی استخراج شده با استفاده از ۱۲ شتاب سنج نصب شده بر روی سازه نشان داده شدهاست.

سازه به یک صفحه فولادی با ضخامت ۱ سانتیمتر جوش دادهشده و پسازآن با یک پایه بتنی به زمین وصل شدهاست. شکل ۵ بخشهای مختلف تجهیزات آزمایشگاهی را نشان میدهد. شتابسنجها و مبدل نیرو با کابلهای انتقال سیگنال به سیستم پردازشگر داده وصل میشوند. سیگنالهای ارتعاشی به مدت ۳۰ ثانیه با استفاده از نرمافزار لب ویو^۳ با فرکانس نمونهبرداری ۲۰۰۰ هرتز ثبت میشوند و سپس این سیگنالها وارد نرمافزار متلب میشوند تا فرآیند پردازش روی آنها صورت بگیرد. در این مطالعه آزمایشهای اولیه بر روی سازه سالم انجام میگیرد، پسازآن،

آزمایشها برای حالتهای مختلف عیب که با حذف کردن میلههای برشی مورب مختلف ایجاد میشوند، تکرار میشوند. بهمنظور بررسی قابلیت اطمینان پذیربودن نتایج در فرآیند آزمایشهای تجربی، در هر مرحله، آزمایشها چندین مرتبه تکرار شدند؛ در نهایت بهصورت تصادفی برای هر حالت، ۵ تکرار انتخاب شده و میانگین آنها برای آنالیزهای بعدی مورد استفاده قرار گرفته است. رویکردی مشابه با مدل آزمایشگاهی، برای مدل المان محدود نیز انجام میشود؛ مدل المان محدود دقیقاً از همان مکان تحریک شده و پاسخهای شتاب سنجها از ۱۲ موقعیت مختلف در جهتهای x و y مانند مدل آزمایشگاهی استخراج می شوند.

۲- ۳- تجزیه مود تجربی دستهای کامل

تجزیه مود تجربی دستهای کامل [۱۶] 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^۴ خود تجزیه خواهد شد. جزئیات این روش در مرجع [۱۶] ارائهشدهاست.

Flexible stingers

² High axial stiffness

³ LabVIEW Signal Express software

⁴ Intrinsic Mode Functions (IMF)



Fig. 4. Extracted dynamic responses using 12 accelerometers mounted on the structure.

۲- ۴- روش تجزیه حوزه فرکانس

روش تجزیه حوزه فرکانس، یک روش آنالیز مودال بر مبنای فقط خروجی^۱ است که برای شناسایی پارامترهای مودال سازهها و سیستمهای مکانیکی استفاده میشود [۱۷]. در این روش، فقط پاسخهای خروجی اندازه گیریشده از سیستمهای مکانیکی برای تجزیه وتحلیل موردنیاز است؛ بنابراین، نیازی به استفاده از نیروهای تحریک در این روش نیست. در این روش ابتدا ماتریس چگالی طیفی توان^۲ پاسخهای دینامیکی محاسبه شده و سپس روش تجزیه مقادیر تکین^۳ بر روی آنها اعمال میشود و به کمک آن، مقادیر فرکانسهای طبیعی و شکل مودها به دست میآیند. با استخراج پیکهای نمودار مقادیر تکین، فرکانسهای طبیعی مرتبط با سیستم مکانیکی حاصل میشوند [۱۷]. جزئیات این روش در مرجع [۱۷] ارائه شده است.

۲- ۵- شبکه عصبی عمیق

در سالهای اخیر، شبکههای عصبی عمیق نسبت به سایر روشهای یادگیری ماشین، توجه بیشتری را به خود جلب کردهاند. در شبکههای عمیق

مبتنی بر خود رمزنگارها، ابتدا الگوریتم خود رمزنگار [۴] چندین بار استفاده می شود که به آن شبکه عمیق پیش آموزش گفته می شود؛ در این مرحله، خروجی هر لایه ورودی لایه بعدی است. سپس شبکه عمیق به منظور نظارت^۴ بر طبقهبندی با الگوریتم پس انتشار خطا [۱۸] دوباره آموزش داده می شود. الگوریتم خود رمزنگار یک الگوریتم یادگیری بدون نظارت است که هدف خروجی آن، داده ورودی است و از الگوریتم پس انتشار خطا استفاده می کند [۴]. همان طور که در شکل ۶ نشان داده شده است، شبکه خودرمزنگار شامل دو بخش، یعنی بخش رمزنگاریی^۵ و بخش رمزگشایی^۶ است که بخش رمزنگاریی یک بردار ویژگی را از داده های ورودی تولید می کند و بخش

بخش رمزنگاریی یک عملگر استخراج ویژگی است که یک بردار ویژگی را از ورودی x_i محاسبه میکند و میتواند بهصورت زیر محاسبه شود:

$$h(x_i) = f_{\theta}(x_i) \tag{1}$$

¹ Output-only Modal Analysis (OMA) method

² Power Spectral Density (PSD) matrix

³ Singular-value decomposition (SVD)

⁴ Supervised

⁵ Encoder

⁶ Decoder



شکل ۵. بخشهای مختلف تجهیزات آزمایشگاهی.

Fig. 5. Different parts of experimental equipment.



شکل ۶. معماری شبکه خود رمزنگار.

Fig. 6. Auto-Encoder network architecture.

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

با درنظرگرفتن مجموعه آموزشی $\{x^{(1)}, c^{(1)}, ..., x^{(m)}, c^{(m)}\}$ از نمونههای برچسبخورده m و ویژگیهای ورودی $x^{(i)} \in \mathbb{R}^n$ ، تخمین احتمال ($x^{(i)} \in \mathbb{R}^n$ برای هر مقدار از i = k تا X، میتواند با استفاده از رگرسیون سافت مکس محاسبه شود. رگرسیون سافت مکس با چند لیبل $c^{(i)} \in \{1,...,K\}$

$$\sigma_{\theta}(x) = \frac{e^{(\theta^{(j)T}x)}}{\sum_{j=1}^{K} e^{(\theta^{(j)T}x)}} = \begin{bmatrix} P(c=1|x;\theta) \\ P(c=2|x;\theta) \\ \vdots \\ P(c=K|x;\theta) \end{bmatrix}$$
(\$\$

for
$$j = 1, \dots K$$
; $\theta^{(j)} \in \mathbb{R}^n$

که $\theta^{(J)}$ و K بهترتیب پارامترهای مدل رگرسیون سافت مکس و تعداد کلاسها هستند. مقادیر خروجی $\sigma_{\theta}(x)$ بین صفر تا یک و جمع آنها برابر یک است.

۳- الگوریتم عیبیابی پیشنهادی

در این بخش، روش پیشنهادی برای تشخیص عیوب سازه جکتی فراساحلی توضیح دادهشدهاست. شکل ۷ بلوک دیاگرام روش پیشنهادی را نشان میدهد. جزئیات هر مرحله در بخشهای بعدی توضیح داده شدهاست.

۳– ۱– دادهها

بهطورکلی، بهمنظور بررسی عملکرد روشهای عیبیابی، میتوان سناریوهای عیوب فرضی در سازه ایجاد کرد. در این مطالعه، همان طور که قبلاً بیان شد، سناریوهای مختلف عیب با حذف کردن میلههای برشی مورب در سازه ایجاد میشوند، به گونهای که سختی سازه در یک جهت خاص کاهش یابد. حذف کردن میلههای مختلف برشی از سازه، باعث جابهجایی فرکانسها و تغییر شکل مودها میشود. مطالعه حاضر بر پایه ۵ حالت مختلف که $h(x_i)$ بردار ویژگی و f_{Θ} عملگر استخراج ویژگی است. بخش رمزگشایی یک تابع بازیابی g_{Θ} است که فضای ورودی را از بردار ویژگی بازسازی می کند به گونهای که:

$$\overline{x}_{i} = g_{\theta}(h(x_{i})) \tag{7}$$

شبکه خود رمزنگار تلاش میکند تقریبی را یاد بگیرد که $\overline{x_i}$ شبیه به x_i بشد، به این معنی که سعی میکند به کمترین خطای بازسازی x_i بشد، به این معنی که سعی میکند به کمترین خطای بازسازی $E(x_i, \overline{x_i})$ که اختلاف بین i_i و $\overline{x_i}$ را اندازه گیری میکند، برسد. درواقع، شبکه خود رمزنگار بهعنوان یک شبکه چند لایه پرسپترون توسعه دادهشده است که انسجام و به دنبال آن غیرخطینگی را در بخشهای رمزنگاری و رمزگشایی حفظ میکند:

$$h(x_i) = s_f(W + b^*) \tag{(Y)}$$

$$g_{\theta}(h(x_i)) = s_g(\bar{W} + c^*) \tag{(4)}$$

که S_f و S_g بهترتیب توابع فعالیت بخشهای رمزنگاریی و رمزگشایی هستند، مانند سیگموئید و رلو^۲، b^* و c^* بردارهای بایاس، W و \overline{W} ماتریسهای وزن بخشهای رمزنگاریی و رمزگشایی هستند.

به طور کلی، در شبکه های عصبی پس از هر لایه، یک تابع فعال سازی قرار می گیرد. تابع فعال سازی یک عملگر است که خروجی را به مجموعه ای از ورودی ها نگاشت می کند و برای غیر خطی کردن ساختار شبکه استفاده می شود [۱۹]. در این مطالعه از تابع رلوو به عنوان تابع فعال سازی در بخش های رمزنگاریی و رمزگشایی استفاده شده است و این ویژگی را دارد که غیر خطی بودن را به ساختار شبکه اعمال کند؛ بنابراین در برابر تغییرات جزئی در ورودی مقاوم است. رابطه (۵) تابع رلوو را نشان می دهد. در این تابع، اگر مقدار D بزر گتر از صفر باشد، خروجی D است و اگر مقدار D کوچک تر یا مساوی صفر باشد، خروجی صفر است.

¹ Sigmoid

² Relu

شکل ۷. بلوک دیاگرام روش پیشنهادی.

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

در ۳ سناریو برای هر دو مدل المان محدود و آزمایشگاهی انجام شده است که شامل؛ حالت سالم، حذف میله برشی مورب طبقه چهارم از وجه دوم (D1)، حذف میله برشی مورب طبقه سوم از وجه دوم (D2)، حذف میله برشی مورب طبقه چهارم از وجه سوم (D3) و حذف میله برشی مورب طبقه سوم از وجه سوم (D4) می باشد. سناریوهای مختلف عیب در جدول ۱ ارائه شده است. علاوه بر این، مدل های المان محدود برای حالت های مختلف عیب، در شکل ۸ نشان داده شده است که میله های برشی مشخص شده با رنگ قرمز، در هر حالت عیب از سازه حذف می شوند. در روش پیشنهادی در این مقاله، از مدل المان محدود سازه و حالت سالم آزمایشگاهی برای داده های آموزش و از مدل آزمایشگاهی برای داده های ارزیابی استفاده می شود.

۳- ۲- بهروزرسانی مدل المان محدود و پیش پردازش دادهها

در روش پیشنهادی، هر سیگنال ارتعاشی برای هر یک از حالتهای عیب توسط نرمالیزاسیون Z-score ⁽ نرمالیزه شده است [۲۰]. بهطورکلی، بین ویژگیهای دینامیکی مدلهای المان محدود و واقعی به دلیل عدم

قطعیتهای مختلف مانند خطاهای مدل سازی، کمی اختلاف وجود دارد که ممکن است باعث هشدارهای کاذب در فرآیند عیبیابی شود؛ بنابراین، تنظیم پارامترهای مدل المان محدود اولیه و بهروزرسانی آنها برای به حداقل رساندن خطای مدل سازی بر پایه دادههای مدل واقعی ضروری است. در مطالعه حاضر، مدل المان محدود سازه جکتی فراساحلی بر پایه فرکانسهای طبیعی مدل سالم آزمایشگاهی بهروزرسانی شده است. در مراحل بعدی، اطلاعات استخراجشده از مدل بهروزرسانی شده و مدل سالم آزمایشگاهی به عنوان دادههای آموزش برای تشخیص عیوب مدل آزمایشگاهی استفاده می شوند.

بهروزرسانی مدل المان محدود با تغییر چگالی و مدول یانگ به گونهای انجام می شود که فرکانس های طبیعی مدل سالم المان محدود با فرکانس های طبیعی مدل سالم آزمایشگاهی مطابقت داشته باشند. استفاده از مدل المان محدود برای تولید داده های شبیه سازی شده، به صحت مدل بستگی دارد. مدل المان محدود با استفاده از یک الگوریتم بهینه سازی استاندارد برای حل یک مسئله مقید به روزرسانی می شود. تابع هدف به منظور کم کردن خطا می تواند به صورت زیر بیان شود [۱۱–۱۲، ۲۱–۲۲]:

¹ Normalization of Z-score

جدول ۱. سناریوهای مختلف عیب.

Table 1. Different scenarios of damage.

حالتهای درنظرگرفتهشده	سناريوهای مختلف
سالم، معيوب (D4 & D3 & D2 & D1)	۲–کلاس
سالم، معيوب (D1 & D3)، معيوب (D2 & D4)	۳–کلاس
سالم، معيوب (D1)، معيوب (D2)، معيوب (D3)، معيوب (D4)	۵–کلاس

شکل ۸. مدل های المان محدود برای حالت های مختلف عیب.

Fig. 8. The FE models for different damage states.

$$F = \sum_{i=1}^{n} \left(\frac{\left| f_{Exp(i)} - f_{FE(i)}(\rho, E) \right|}{f_{Exp(i)}} \right)^{2}$$
(Y)

که $f_{Exp(i)}$ فرکانسهای طبیعی بهدستآمده از مدل آزمایشگاهی، $f_{Exp(i)}$ فرکانسهای طبیعی محاسبه د فرکانسهای طبیعی و $f_{FE(i)}$ فرکانسهای طبیعی محاسبه شده از مدل المان محدود $f_{FE(i)}$ فرکانسهای طبیعی محاسبه شده از مدل المان محدود با پارامترهای بین ۸۰۵۰ kg/m³ و ۷۷۰۰ kg/m³ ح $\rho < \lambda \cdot \delta \cdot kg/m^3$ و طبیعی به دست آمده در محدوده فرکانس کاری از صفر هرتز تا ۱۲۰ هرتز در طبیعی به دست آمده در محدوده فرکانس کاری از صفر هرتز تا ۱۲۰ هرتز در فرایند به روزرسانی مدل استفاده می شوند [۱۱]. اگر فرکانسهای طبیعی مدل سالم المان محدود با فرکانسهای طبیعی مدل سالم آزمایشگاهی مطابقت داشته باشند، مقدار تابع هدف به حداقل مقدار خود می رسد.

در روش پیشنهادی این مطالعه، از تکنیک همپوشانی برای دادهافزایی استفاده میشود [۶، ۲۳]. افزایش تعداد دادهها باعث افزایش صحت و جلوگیری از پدیده بیش برازش میشود. در این مطالعه پاسخهای دینامیکی شتاب سنجهای 1، 10 و 1 که بر روی ستون I نصب شدهاند، برای استخراج ویژگیهای مختلف و تشخیص عیوب سازه مورد استفاده قرار میگیرند. تعداد نمونهها و طول آنها با دقت انتخاب شدهاند تا به حداکثر نرخ صحت و سرعت در عیبیابی سازه برسند. در هر حالت از مدل المان محدود، محت و سرعت در عیبیابی سازه برسند. در هر حالت از مدل المان محدود، این صورت ۵ نوع داده با ابعاد ۲۰۰۰۰ × ۳ خواهیم داشت که در آن ۵ تعداد حالتهای مختلف، ۳ تعداد پاسخهای دینامیکی و ۲۰۰۰۰ طول هر پاسخ دینامیکی (۲۰۰۰ × ۱۰) یا نقاط نمونه برداری است. پس از آن، هر پاسخ دینامیکی با ستفاده از تکنیک همپوشانی با شیفت زمانی مشخصی،

¹ Sigmoid

- شکل ۹. دادهافزایی با استفاده از تکنیک هم پوشانی برای دادههای آموزش.
- Fig. 9. Data augmentation using overlap technique for training data.

به بازههای ۲ ثانیهای (طول سیگنال ۴۰۰۰) تقسیم می شود که روند این هم پوشانی در شکل ۹ نشان داده شده است. درواقع هر پاسخ دینامیکی به ۳۰۰ نمونه ۲ ثانیه ای تقسیم خواهد شد؛ بنابراین تعداد نمونه ها برای هر حالت از مدل المان محدود (۴۰۰۰ × ۳) × ۲۰۰ و برای مجموع حالتهای مختلف این مدل (۴۰۰۰ × ۳) × ۲۰۰ خواهد شد. رویکردی مشابه با مدل المان محدود، برای مدل آزمایشگاهی نیز انجام می شود؛ در هر حالت از مدل آزمایشگاهی، ۳۰ ثانیه (طول سیگنال ۲۰۰۰۶) از پاسخهای دینامیکی ثبت می شوند؛ در این صورت ۵ نوع داده با ابعاد ۲۰۰۰۶ × ۳ خواهیم داشت که در آن ۵ تعداد حالتهای مختلف، ۳ تعداد پاسخهای دینامیکی و ۲۰۰۰۶ طول هر پاسخ دینامیکی (۲۰۰۰ × ۳۰) یا نقاط نمونه برداری است. پس از آن، هر پاسخ دینامیکی با استفاده از تکنیک هم پوشانی با شیفت زمانی مشخصی، به بازههای ۲ ثانیه ای تقسیم می شود. درواقع هر پاسخ دینامیکی به ۱۰۰ نمونه بازههای ۲ ثانیه ای تقسیم می شود. درواقع هر پاسخ دینامیکی به دالت از مدل آزمایشگاهی (۴۰۰۰ × ۳) در ۲ خواه هم پاسخ دینامیکی به ۱۰۰ نمونه

۳- ۳- انتخاب توابع مود ذاتی مناسب و بازسازی سیگنال ها

سیگنالهای ارتعاشی استخراجشده از سیستمهای مکانیکی همیشه در معرض اطلاعات اضافی و نامربوط به ذات اصلی سیستم هستند که ممکن است باعث ایجاد خطا یا کاهش دقت در یادگیری ویژگیها و فرآیند تشخیص عیب شود. این امر مستلزم حذف اطلاعات اضافی و انتخاب مؤلفههای اصلی

سیگنال بدون از بین بردن اطلاعات اصلی عیب است [۲۶–۲۴]؛ بنابراین، برخی از بخشهای سیگنال با استفاده از روش تجزیه مود تجربی دستهای کامل قابل حذف هستند. توابع مود ذاتی استخراجشده از تجزیه سیگنال، بهصورت متوالی از محدوده فرکانس بالا تا فرکانس پایین هستند [–۲۵ ۲۶]. توابع مود ذاتی شامل اطلاعات مربوط به عیب سیگنالهای ارتعاشی سازه هستند و اطلاعات عیب معمولاً در محدوده فرکانس بالا سیگنالهای ارتعاشی متمرکز شدهاند [۲۵]. انتخاب توابع مود ذاتی مناسب میتواند زمان محاسبات را کاهش، فرآیندهای یادگیری و تشخیص عیب را دقیق *تر* کند [۲۵]. از آنجاکه توابع مود ذاتی شامل اصلی *تر*ین اطلاعات مربوط به عیبهای سازهای هستند، توابع مود ذاتی مناسب را میتوان با استفاده از آنتروپی جایگشتی^۱ انتخاب کرد [۲۵]. از مزایای آنتروپی جایگشتی میتوان به تعریف ساده، سرعت بالا محاسبات آن اشاره کرد.

در این مطالعه، بهمنظور انتخاب توابع مود ذاتی مناسب، پاسخهای دینامیکی مدل المان محدود سازه و حالت سالم آزمایشگاهی با استفاده از روش تجزیه مود تجربی دستهای کامل به توابع مود ذاتی خود تجزیه میشوند. پسازآن، توابع مود ذاتی که بالاترین مقدار آنتروپی جایگشتی را دارند انتخاب میشوند [۲۶–۲۵]. بر اساس آنتروپی شانون، آنتروپی جایگشتی یک سری زمانی را میتوان به صورت زیر تعریف کرد:

¹ Permutation Entropy (PE)

$$PE = H_p(D) = -\sum_{\pi_j \in A_D} p(\pi_j) \ln(p(\pi_j))$$
(A)

برای هر سری زمانی دلخواه $\{s(t), t = 1, 2, ..., N\}$ با توجه به تئوری جاسازی، بردار جاسازی در زمان i به صورت زیر تعریف می شود:

$$S_i^D = [s(i), s(i+\tau), s(i+2\tau), ..., s(i+(D-1)\tau)]$$
(9)
 $i = 1, 2, ..., N$

که در آن au و D بهترتیب پارامتر تأخیر زمانی و بعد جاسازی au هستند. برای هر جابجایی π_j فرکانس نسبی $p(\pi_j)$ میتواند به صورت زیر تعریف شود:

$$\mathbf{p}(\pi_j) = \frac{\#\#\left\{\mathbf{S}_i^D has \ type \ \pi_j \left| 1 \le j \le N - (D-1)\tau\right\}\right.}{N - (D-1)\tau} \tag{1.1}$$

که در آن ## تعداد را ارائه میدهد. مطابق مرجع [۲۶] مقادیر منطقی برای پارامترهای تأخیر زمانی و بعد فضای جاسازی بهترتیب ۱ تا ۴ و ۳ تا ۹ است. در این مطالعه تخصیص ۳=D و $1 = \tau$ برای استخراج جایگشت سریهای زمانی به کار گرفته شده است. همچنین، می توان آنتروپی جایگشتی را در فاصله ۰ تا ۱ به صورت زیر نرمالایز کرد:

$$\mathbf{H}_{p} = \frac{\mathbf{H}_{p}(D)}{\ln(D!)} = -\frac{1}{\ln(D!)} \sum_{i=1}^{k} \mathbf{p}(\pi_{j}) \ln(\mathbf{p}(\pi_{j}))$$
(11)

پس از انتخاب توابع مود ذاتی مناسب در مدلهای المان محدود و آزمایشگاهی، سیگنالهای اصلی با استفاده از این توابع مود ذاتی بازسازی میشوند. سیگنالهای ارتعاشی که بر اساس توابع مود ذاتی مناسب و مؤثر بازسازی شدهاند میتوانند در فرآیندهای یادگیری و تشخیص عیب عملکرد بهتری داشتهباشند [۲۶–۲۴].

۳– ۴– شبکه عمیق پیشنهادی

هدف اصلی این مطالعه، ارائهدادن الگوریتمی برای یادگیری ویژگیهای زیر کامل^۴ حساس به عیب از دادههای ورودی به منظور عیبیابی سیستمهای مکانیکی است. روش پیشنهادی، یک الگوریتم یادگیری چند مرحلهای از ویژگیهای غیرخطی بوده که هر مرحله یک نوع تغییر ویژگی محسوب میشود. در این الگوریتم از شبکه عصبی عمیق با چندلایه پنهان که هر لایه به لایههای بعدی با یک ترکیب غیرخطی متصل شده است، استفاده میشود. برای پیادهسازی شبکه عمیق پیشنهادی از کتابخانه کراس در زبان برنامهنویسی پایتون استفادهشده است.

رویکرد پیشنهادی برای آموزش شبکه عمیق (شکل ۱۰) شامل دو مرحله آموزش است؛ یعنی، مرحله پیش آموزش با استفاده از الگوریتم یادگیری بدون نظارت بر اساس خود رمزنگارها و لایه رگرسیون سافت مکس که به آن مرحله عمیق^ه گفته میشود (مرحله اول) و آموزش مجدد با استفاده از الگوریتم پس انتشار خطا که مرحله تنظیم دقیق² (مرحله دوم) نامیده میشود. شکل ۱۰ نحوه آموزش شبکه عصبی عمیق پیشنهادی را نشان میدهد. در مرحله پیشآموزش، دادههای ورودی بدون برچسبگذاری^۷ برای استخراج ویژگیهای زیر کامل، مورداستفاده قرار میگیرند. در شبکه پیشنهادی تعداد نورونهای لایههای پنهان (a_i) کمتر از تعداد ویژگیهای ورودی (m)است؛ یعنی m < i < m در هر لایه مخفی (i) که $a_{i-1} < i < m$

شکل ۱۱ تصویری از روند پیش آموزش شبکه عمیق پیشنهادی با ۴ لایه پنهان را برای تشخیص عیوب سازه جکتی فراساحلی نشان میدهد. با تعیین تعداد نورونها در هر لایه پنهان کوچکتر از ویژگیهای ورودی، هر خود رمزنگار ویژگیهای مفیدی را از دادههای ورودی بدون برچسبگذاری، میآموزد. در مرحله اول یادگیری، از یک رمزنگار با تابع فعالسازی رلو برای یادگیری ویژگیهای زیر کامل از دادههای ورودی استفاده میگردد که در آن یادگیری ویژگیهای زیر کامل از دادههای ورودی استفاده میگردد که در آن برای مرحله دوم یادگیری استفاده میشوند. پسازآن رمزنگارهای ۲، ۳ و از خود رمزنگارهای دوم، سوم و چهارم با تعداد واحدهای پنهان $_2$ گ، $_6$ از خود رمزنگارهای دوم، سوم و چهارم با تعداد واحدهای پنهان $_2$ م یو $_4$

⁴ Under-complete features

⁵ Deep stage

⁶ Fine-tuning stage

⁷ Unlabelled

¹ Time lag parameter

² Embedding dimension

³ Relative frequency

شكل ١٠. نحوه أموزش شبكه عصبي عميق پيشنهادي.

Fig. 10. Training process of the proposed deep neural network.

Fig. 11. The pre-training process of the proposed deep network with 4 hidden layers

ویژگیهای زیر کامل آخرین لایه پنهان، عیوب سازه را تشخیص میدهد.

تعداد کل دادههای آموزش و آزمون بهترتیب ۱۵۰۰ و ۵۰۰ است که ۵۰ نمونه از دادههای آزمون برای اعتبارسنجی استفاده میشود. تمامی ابر پارامترهای شبکه پیشنهادی برای رسیدن به بهترین نرخ همگرایی با استفاده از روش سعی و خطا بهدقت تنظیم شدهاند. درنهایت تابع خطا آنتروپی متقابل^۱، بهینه کننده آدام^۲ [۶] با نرخ یادگیری ۰/۰۰۰۱ و اندازه دسته ۱۰ برای آموزش شبکه پیشنهادی مورداستفاده قرار گرفتهاست. بعد از آموزش شبکه پیشنهادی، ارزیابی با استفاده از ۴۵۰ نمونه از دادههای آزمون صورت می گیرد.

۴- کاربرد روش پیشنهادی برای عیبیابی سازه جکتی فراساحلی

در این قسمت، نتایج روش پیشنهادی برای عیبیابی سازه جکتی فراساحلی ارائهشدهاست. این بخش به چندین زیر بخش تقسیمشده است: (۱) ارزیابی مدل المان محدود شبیهسازی شده بر پایه دادههای آزمایشگاهی. (۲) انتخاب توابع مود ذاتی مناسب و بازسازی سیگنالهای ارتعاشی. (۳) عیبیابی سازه جکتی فراساحلی.

۴– ۱– ارزیابی مدل المان محدود شبیه سازی شده بر پایه داده های آزمایشگاهی

بهمنظور ارزیابی صحت مدل المان محدود، فرکانسهای طبیعی سازه جکتی فراساحلی با استفاده از روشهای مختلف بهدست آمده و با یکدیگر مقایسه میشوند. بهمنظور ساماندهی اطلاعات ارائهشده، این زیر بخش به زیر بخشهای زیر تقسیم میشود: (۱) بهدستآوردن پارامترهای مودال با استفاده از آنالیز مودال تجربی^۳. (۲) بهدستآوردن پارامترهای مودال با استفاده از آنالیز مودال عددی^۴ بر پایه مدل المان محدود و روش مقادیر ویژه⁶. (۳) بهدستآوردن پارامترهای مودال با استفاده از روش آنالیز مودال بر مبنای فقط خروجی بهصورت تجربی و عددی. (۴) مقایسه پارامترهای مودال بهدستآمده با استفاده از روشهای بیانشده.

در روش آنالیز مودال تجربی، سازه توسط نیروهای خاصی (بهعنوان ورودی) تحریک میشود و سیگنالهای ارتعاشی پاسخ، ثبت میشوند (بهعنوان خروجی)؛ بنابراین، پارامترهای مودال بر پایه ورودی و خروجی با استفاده از تابع پاسخ فرکانسی² استخراج میشوند. تابع پاسخ فرکانس را میتوان بهصورت زیر بیان کرد [۲۷]:

$$H(\omega) = \frac{S_{xx}(\omega)}{S_{xf}(\omega)} \tag{17}$$

که (ω) $S_{xx}(\omega)$ و (ω) بهترتیب چگالی طیفی توان و چگالی طیفی متقاطع^v سیگنالهای خروجی و ورودی هستند. زیرنویسهای x و f م بهترتیب سیگنالهای خروجی و ورودی را نشان میدهند. شکل ۱۲ توابع پاسخ فرکانسی را برای ۱۲ شتابسنج نصبشده بر روی ۴ ستون مدل سالم آزمایشگاهی را در محدوده فرکانس ۰ هرتز تا ۲۰۰ هرتز نشان میدهد (شکل ۳ را ببینید). همان طور که ملاحظه می گردد، شتابسنجهای مشابه نصبشده بر روی هر ستون سازه دارای فرکانسهای طبیعی تقریباً یکسانی هستند.

در شکل ۱۳، توابع پاسخ فرکانسی بهدست آمده با استفاده از شتاب سنج *a*1 برای حالتهای مختلف نشان داده شده است. همان طور که مشاهده می شود، حالتهای مختلف عیب، نمودارهای تابع پاسخ فرکانسی خاص خود را ارائه می دهند که با تابع پاسخ فرکانسی حالت سالم متفاوت است.

همچنین مقادیر میانگین^۸ و انحراف معیار^۴ فرکانسهای طبیعی [۲۹–۲۹] برای حالتهای مختلف با استفاده از توابع پاسخ فرکانسی همه شتابسنجها، در محدوده فرکانس کاری صفر هرتز تا ۱۲۰ هرتز در جدول ۲ ارائهشدهاست. انتظار میرود که ایجاد یک عیب سازهای منجر به کاهش فرکانسهای طبیعی شود؛ بااینحال، بررسی فرکانسهای طبیعی برای عیب D4، نشان میدهد که در فرکانس طبیعی اول افزایش مقدار وجود دارد که میتواند ناشی از عدم قطعیتهای مختلف مانند خطاهای اندازه گیری و نویزهای محیطی در فرآیند آزمایش باشد [۱۳].

۴- ۱- ۱- آنالیز مودال تجربی

⁶ Frequency Response Function (FRF)

⁷ Cross Spectral Density (CSD)

⁸ Mean

⁹ Standard deviations (Std)

¹ Cross-entropy loss function

² Adam optimizer

³ Experimental Modal Analysis (EMA) method

⁴ Numerical Modal Analysis (NMA)

⁵ Eigenvalues method

شکل ۱۲. توابع پاسخ فرکانسی برای ۱۲ شتاب سنج نصب شده بر روی ٤ ستون مدل سالم آزمایشگاهی. الف) ستون I. ب) ستون II. ج) ستون III. د) ستون IV.

Fig. 12. Frequency response functions for 12 accelerometers mounted on the 4 columns of the lab-scale intact model. a) Column I. b) Column II. c) Column III. d) Column IV.

شکل ۱۳. توابع پاسخ فرکانسی برای حالتهای مختلف عیب.

Fig. 13. Frequency response functions for different damage states.

جدول ۲. مقادیر میانگین و انحراف معیار فرکانسهای طبیعی برای حالتهای مختلف با استفاده از توابع پاسخ فرکانسی همه شتابسنجها.

(D4)	عيب	(D3)	عيب	(D2)	عيب	(D1)	عيب (لم	سا	
انحراف معيار	میانگین	انحراف معيار	میانگین	انحراف معيار	میانگین	انحراف معيار	میانگین	انحراف معيار	میانگین	شماره مود
۰ /۳۲	14/08	• /٣ •	۱۳/۹۸	• /٣ •	14/17	• /٣ ١	۱۲/۸۲	۰/۳۴	14/41	١
۰/۲۱	۱۸/۸۱	•/77	۲۰/۱۳	٠/٢٨	۲۰/۸۲	•/7۴	71/11	+ / Y V	۲۱/۵۰	۲
+ /۳۴	۵۰/۴۲	•/٣۶	49/82	٠/٣٧	۵•/۸۸	۰ /۳۵	۵۰/۶۲	۰/۳۶	۵۱/۵۲	٣
+/17	۷۸/۳۵	٠/١٣	۲ ۹/•۲	٠/١۴	٧۶/١٠	•/\\	۲۹/۱۳	•/\Y	V9/44	۴
• /٣ •	۸۵/۲۴	۰/۳۲	٨٧/٨٩	۰ /۳ ۱	۸۷/۶۴	۰ /۳۳	$\lambda\lambda/\gamma$)	۰/۳۴	۸۸/۳۳	۵
٠/٢٢	۱۰۲/۵۷	۰/۲۱	۹۸/۳۳	•/77	1 • 3/22	۰/۲۳	۹۷/۸۸	۰/۲۳	۱۰۳/۶۵	۶

Table 2. Mean values and standard deviations of the natural frequencies for different states using frequency response functions of all accelerometers.

جدول ۳. فرکانس های طبیعی به دست آمده از آنالیز مودال عددی بریایه روش مقادیر ویژه.

Table 3. The obtained natural frequencies from numerical modal analysis based on eigenvalues method.

عيب (D4)	عيب (D3)	عيب (D2)	عيب (D1)	سالم	نوع مود	شماره مود
10/108	10/889	10/419	10/881	10/784	خمشى	١
T • /9 T I	۲ • /۸۳ •	۲۰/۴۱۳	Т • /99 Л	۲ • /V۶۹	پیچشی	٢
54/1.7	۵۱/۲۱۳	54/4.1	۵۳/۶۹۷	54/38.	خمشى	٣
४९/४९४	Y 9/81Y	γλ/γγ۵	۲۹/۵۹۱	V9/57F	خمشى	۴
٨٩/٢٧٧	٨٩/٢٩١	۸۹/۳۵۲	٨٨/۶۲٩	9 • / 9) V	پیچشی	۵
1•٣/۴•	१८/१۴१	1 • ٣/۴٧	१९/९ ٣٣	1.47/41	پیچشی	۶

۲-۱-۲ آنالیز مودال عددی

فرکانسهای طبیعی و شکل مودهای سازه با استفاده از روش مقادیر ویژه [۳۰] و با استفاده از تکنیک Block Lanczos استخراج می شوند [۳۱]. فرکانس.های طبیعی بهدستآمده قبل از بهروزرسانی مدل، در محدوده فرکانس کاری ۰ هرتز تا ۱۲۰ هرتز با استفاده از آنالیز مودال عددی در جدول ۳ ارائه شده است. همان طور که ملاحظه می گردد، حالت های مختلف عیب بر روی فرکانس های طبیعی سازه اثر می گذارند.

۴- ۱- ۳- آنالیز مودال عددی و تجربی بر مبنای فقط خروجی

در آنالیز مودال عددی سازه جکتی فراساحلی بریایه مدل المان محدود، 💫 همان طور که در بخش ۴–۲ بیان شد، روش تجزیه حوزه فرکانس فقط به پاسخهای خروجی اندازهگیریشده نیاز دارد. در این بخش از روش تجزیه حوزه فركانس براى استخراج دادههاى فركانسى سازه استفاده مىشود. شکل ۱۴ نمونهای از سیگنال ارتعاشی نرمال شده مدل های المان محدود و آزمایشگاهی سازه جکتی فراساحلی برای حالتهای مختلف عیب با استفاده از روش تجزیه حوزه فرکانس در محدوده فرکانس کاری صفر هرتز تا ۱۲۰ هرتز را نشان میدهد. با توجه به نتایج شکل ۱۴، ملاحظه می گردد که نمودارهای مقادیر تکین هر دو مدل تقریباً رفتار مشابهی دارند، اما عدم

شکل ۱۴. نمونهای از سیگنال ار تعاشی نرمال شده مدل های المان محدود و آزمایشگاهی سازه جکتی فراساحلی برای حالت های مختلف عیب با استفاده از روش تجزیه حوزه فرکانس

Fig. 14. sample of normalized vibration signal of finite element and Lab-Scale offshore jacket model for different damage states using frequency domain decomposition method.

قطعیتهای مختلف در سیستم باعث ایجاد اختلاف در دامنه پیکها در فرکانسهای مربوطه میشود. پیک نمودار مقادیر تکین، فرکانسهای طبیعی سازه را نشان میدهد که مقادیر میانگین آنها برای همه نمونهها در بخش بعدی آوردهشدهاست. لازم به ذکر است ازآنجاکه تحریک ورودی لرزاننده در محاسبات آنالیز مودال بر مبنای فقط خروجی وارد نمیشود، برخی فرکانسهای طبیعی در محدوده فرکانس موردنظر به خوبی در نمودارهای مقادیر تکین ظاهر نمیشوند.

۴- ۱- ۴- مقایسه پارامترهای مودال

به منظور بررسی بهتر نتایج، خطاهای به دست آمده از مقادیر میانگین فرکانس های طبیعی برای سازه سالم در محدوده فرکانس کاری صفر هرتز تا ۱۲۰ هرتز با استفاده از روش های عددی (قبل و بعد از به روزرسانی) و تجربی در جدول ۴ نشان داده شده است. همان طور که از جدول ۴ ملاحظه می گردد، خطاهای به دست آمده از مقادیر میانگین فرکانس های طبیعی ۱، ۲، ۳، ۴، ۵ و ۶ مدل المان محدود بر پایه روش مقادیر ویژه پس از به روزرسانی با توجه به فرکانس های طبیعی به دست آمده از مدل آزمایشگاهی مبتنی بر روش آنالیز مودال تجربی به ترتیب تقریباً ۴/ ۱، ۷/ ۱، ۱/۱، ۶/۶ ، ۸/۸ ، و ۱/۳ / درصد است. همچنین خطاهای به دست آمده از مقادیر میانگین فرکانس های طبیعی ۱، ۳، ۴ و ۶ مدل المان محدود بر پایه روش آنالیز مودال بر مبنای

فقط خروجی پس از بهروزرسانی با توجه به فرکانسهای طبیعی بهدست آمده از مدل آزمایشگاهی مبتنی بر روش آنالیز مودال بر مبنای فقط خروجی به ترتیب تقریباً ۱/۵، ۱/۴، ۲۹/۰ و ۱/۷ ۰ درصد است. این مقایسهها نشان میدهد که مدل المان محدود بهروز شده بهاندازه کافی دقیق است تا نمایانگر رفتار دینامیکی سازه باشد [۱۱، ۲۱].

۴- ۲- انتخاب توابع مود ذاتی و بازسازی سیگنال های ارتعاشی

بر اساس بخش ۳–۳، مقادیر میانگین آنتروپی جایگشتی توابع مود ذاتی ۱ تا ۱۲ برای همه نمونههای مدل المان محدود جکتی فراساحلی و حالت سالم آزمایشگاهی در شکل ۱۵ ارائه شده و با یکدیگر مقایسه شدهاند.

با توجه به شکل ۱۵ میتوان بیان کرد که مقادیر آنتروپی جایگشتی اولین توابع مود ذاتی برای عیوب مختلف، تقریباً بالاتر از حالتهای سالم هستند [۲۶]. علاوه بر این، ملاحظه میگردد که حالتهای مختلف عیب و سالم روند مشابهی دارند حتی اگر مقادیر آنتروپی جایگشتی توابع مود ذاتی مربوط به آنها با یکدیگر متفاوت باشد. ملاحظه میگردد که با افزایش شماره توابع مود ذاتی، مقادیر آنتروپی جایگشتی کاهش مییابند و ۸ تابع مود ذاتی اول دارای مقادیر آنتروپی جایگشتی بالاتری از سایر توابع مود ذاتی هستند. با این دیدگاه و با توجه به بخش ۳–۳، اطلاعات عیب به طور کلی در محدوده فرکانس نسبتاً بالا متمرکز هستند [۲۵–۲۶]؛ میتوان نتیجه گرفت که ۸ تابع مود ذاتی اول شامل اطلاعات عیب بیشتری نسبت به سایر توابع

جدول ۴. مقایسه مقادیر میانگین فرکانسهای طبیعی برای سازه سالم با استفاده از روشهای مختلف قبل و بعد از بهروزرسانی.

 Table 4. Comparison of the mean values of the natural frequencies for the intact structure using different methods before and after updating.

('/.)	خطا	(فرکانس طبیعی (هر تز)				
<i>د</i> دود و آزمایشگاهی	مقايسه مدل المان مح	ن محدود	مدل المان	مدل آزمایشگاهی	شماره مود		
أناليز مودال تجربى	آناليز مودال عددى-اَ	ی (مقادیر ویژه)	آناليز مودال عدد				
بعد از بەروزرسانى	قبل از بەروزرسانى	بعد از بەروزرسانى	قبل از بەروزرسانى	انالیز مودال - تجربی			
1/4	۵/۹	14/87	۱۵/۲۶	14/41	١		
)/Y	٣/۴	T 1/1 T	۲۰/۷۷	۲١/۵٠	٢		
1/1	Δ/Δ	۵۲/۱۰	54/38	۵١/۵۲	٣		
•/•۶	•/\\	४१/४१	٧٩/۵٣	V9/44	۴		
•/\\	۲/۹	۸۹/۱۱	٩ • /٩٢	$\lambda\lambda/\Upsilon\Upsilon$	۵		
٠/١٣	٠/٢٣	۱ • ۳/۵ ۱	1•٣/۴1	۱ • ٣/۶۵	۶		
(%)	خطا	(
^ی دود و آزمایشگاهی	مقايسه مدل المان مح	ن محدود	مدل المان	مدل آزمایشگاهی	شماره		
أناليز مودال تجربى	آناليز مودال عددى-اَ				مود		
بعد از بەروزرسانى	قبل از بەروزرسانى	بعد از بەروزرسانى	قبل از بەروزرسانى	انالیز مودال - تجربی			
١/۵	۵/ ۱	14/48	١۴/٩٨	14/20	١		
_	-	_	_	_	٢		
١/۴	۵/۰	۵۲/۱۰	۵۳/۹۳	۵١/٣۶	٣		
٠/٢٩	•/\\	λ • /٣۶	۸۰/۸۴	٨٠/١٣	۴		
-	-	_	_	_	۵		
•/\\	٠/٧٣	۱۰۴/۱۵	۱۰۳/۵۶	۱ • ۴/۳۳	۶		

شکل ۱۵. مقایسه مقادیر میانگین آنتروپی جایگشتی توابع مود ذاتی ۱ تا ۱۲ همه نمونههای مدل المان محدود جکتی فراساحلی و حالت سالم آزمایشگاهی.

Fig. 15. Comparisons of permutation entropy mean values of all samples for IMF1 to IMF12 of the FE offshore jacket model and lab-scale intact state.

جدول ۵. صحت روش پیشنهادی برای عیبیابی با استفاده از مرحله اول و دوم.

Table 5. The accuracy of the proposed method for damage detection using the first and second stages.

	صحت./		مرحله
۵–کلاس	۳–کلاس	۲–کلاس	طبقەبندى
$f 1/\Delta \pm T/1$	$\Delta T/F \pm T/T$	$V\lambda/1\pm T/\lambda$	مرحله اول
$V1/TT \pm T/\Delta$	$\lambda\lambda/\gamma \pm 1/1$	$1 \cdot \cdot \pm t'/t$	مرحله دوم

مود ذاتی هستند [۲۴–۲۶]. علاوه بر این، هنگامی که شماره توابع مود ذاتی از ۸ بزرگ تر می شود، مقادیر آنتروپی جایگشتی توابع مود ذاتی برای حالتهای مختلف مدل المان محدود و حالت سالم آزمایشگاهی تقریباً یکسان می شوند و به حالت پایدار خود می رسند. از این دیدگاه، می توان بیان کرد که توابع مود ذاتی ۹ تا ۱۲ سهم کمی در تشخیص حالتهای مختلف دارند [۲۶]. بنابراین، ۸ تابع مود ذاتی اول که حاوی اطلاعات اصلی عیوب هستند به عنوان توابع مود ذاتی مؤثر در هر دو مدل انتخاب می شوند. پس از انتخاب توابع مود ذاتی مناسب، سیگنالهای اصلی همه نمونهها با استفاده از این توابع مود ذاتی بازسازی می شوند؛ این کار باعث می شود که اطّلاعات اضافی و غیر مربوط به ذات سیستم حذف شوند. پس ازآن، دادههای فرکانسی سیگنالهای

مدل المان محدود، برای آموزش شبکه عمیق پیشنهادی استفاده می شوند و دادههای فرکانسی سیگنالهای بازسازی شده همه نمونههای حالتهای مختلف آزمایشگاهی، برای ارزیابی شبکه عمیق پیشنهادی استفاده می شوند.

۴- ۳- عیبیابی سازه جکتی فراساحلی

در مرحله آخر، همان طور که قبلاً بیان شد، از دادههای مدل المان محدود شبیه سازی شده و دادههای سالم آزمایشگاهی برای آموزش شبکه عمیق پیشنهادی و از دادههای مدل آزمایشگاهی برای ارزیابی توانایی تشخیص عیوب مختلف شبکه پیشنهادی استفاده می گردد. در همین راستا، نمونههای مشابه نیز در شبکه عصبی پس انتشار خطا (۲، ۳۲–۳۴] استفاده شده و نتایج

¹ BackProagation Neural Network (BPNN)

محت./		داده ورودی	داده ورودی	نوع شىكە	روشها	
۵–کلاس	۳–کلاس	۲-کلاس	طبقەبندى			• • •
${\tt TP}/{\tt F}\pm{\tt T}/{\tt V}$	$\Delta 1/8 \pm T/T$	$\Delta/\Psi\pm \Lambda/\Lambda$	-	دادههای فرکانسی سیگنالهای ارتعاشی	شبکه پس انتشار خطا	روش ۱
$\mathrm{FT/TT}\pm\mathrm{T/A}$	$\Delta\Delta/\mathrm{YA}\pm\mathrm{Y/}\mathrm{S}$	$\cdots \pm \psi/\lambda$	_	دادههای فرکانسی سیگنالهای ارت ع اشی بازسازیشده	شبکه پس انتشار خطا	روش ۲
$8^{4/17} \pm ^{7/17}$	${\rm VP/1\pm W/F}$	98/7±4/8	مرحله دوم	دادههای فرکانسی سیگنالهای ارتعاشی	شبکه عمیق پیشنهادی	روش ۳
$V1/TT \pm T/\Delta$	$\lambda\lambda/\varphi \Psi\pm \chi/1$	۲/۲ <u>+</u> ۲/۲	مرحله دوم	دادههای فرکانسی سیگنالهای ارتعاشی بازسازیشده	شبکه عمیق پیشنهادی	روش پیشنهادی

جدول ۶. صحت روش پیشنهادی برای عیبیابی با استفاده از مرحله اول و دوم.

Table 6. The accuracy of the proposed method for damage detection using the first and second stages.

۱) برای سناریوهای ۲-کلاس، ۳-کلاس و ۵-کلاس بهترتیب تقریباً ٪۵۹،
٪۱۵ و ٪۹۳ است. مطابق این جدول، برای سناریو ۲-کلاس، صحت کلیه روش ها بالاتر از ٪۹۰ است. همچنین مشاهده می شود که صحت طبقهبندی روش پیشنهادی برای سناریوی ۳-کلاس حدوداً ٪۸۸ است، درحالی که صحت روش ۳، روش ۲ و روش ۱ برای سناریوی مشابه به ترتیب حدوداً ٪۹۰ است، درحالی که صحت روش ۳، روش ۲ و روش ۱ برای سناریوی مشابه به ترتیب حدوداً ٪۹۰ است. همچنین، صحت طبقهبندی روش پیشنهادی برای سناریوی ۵-کلاس حدوداً ٪۸۰ است، درحالی که صحت روش ۳، روش ۲ و روش ۱ برای سناریوی مشابه به ترتیب حدوداً ٪۹۰ است، درحالی که صحت روش ۳، روش ۲ و روش ۱ برای سناریوی مشابه به ترتیب حدوداً روش ۱ برای سناریوی مشابه به ترتیب حدوداً ناری سناریوی ۵-کلاس حدوداً ٪۹۰ است، درحالی که صحت روش ۳، روش ۲ و روش ۱ به ترتیب حدوداً ٪۹۰ یای می درحالی که صحت روش ۳، روش ۲ و روش ۲ بای سناریوی ۵-کلاس حدوداً ٪۹۰ یای سناریوی مشابه است. این می دهد که روش پیشنهادی نسبت به روشهای دیگر در تشخیص عیوب سازه (برای همه سناریوی ۲-کلاس را بهدرستی تشخیص شبکه پس انتشار خطا میتواند سناریوی ۲-کلاس را بهدرستی تشخیص دهد. بااین حال، تشخیص عیوب با این شبکه برای سناریوهای ۳-کلاس و ۵-کلاس با شکست مواجه شدهاست. برای برای سناریوهای ۳-کلاس و ۵-کلاس با شکست مواجه شدهاست. برای برسی بیشتر عملکرد روش پیشنهادی، ماتریسهای درهمریختگی¹ برای سناریوهای ۲-کلاس، پیشنهادی، ماتریسهای درهمریختگی¹ برای سناریوهای ۲-کلاس،

۵– نتیجهگیری

در این مقاله، یک روش جدید تشخیص عیب برپایه مدل المان محدود و حالت سالم مدل واقعی در حضور عدم قطعیتهای مختلف با استفاده از یادگیری عمیق ارائه شده است. در کاربردهای عملی معمولاً اندازه گیری

1 Confution matrix

آن با روش پیشنهادی مقایسه شدهاست. شبکه عصبی پس انتشار خطا از دو لایه پنهان (۱۰۰ و ۵۰) تشکیل شده و در آن تابع فعال سازی سیگموئید و نرخ یادگیری ۲۰۰۱/ ۰ در نظر گرفته شدهاست. برای ارزیابی عملکرد روش پیشنهادی از معیار ارزیابی صحت استفاده شدهاست [۳۵]. جدول ۵ صحت شبکه پیشنهادی از معیار ارزیابی صحت استفاده شدهاست از ۲۵]. جدول ۵ صحت شبکه پیشنهادی از معیار ارزیابی صحت استفاده شده می ارتعاشی بازسازی شده به عنوان داده های ورودی (روش پیشنهادی) را برای تشخیص عیوب سازه با استفاده از مرحله های اول و دوم نشان می دهد. همان طور که از این جدول ملاحظه می گردد، روش پیشنهادی با استفاده از مرحله دوم آموزش به نتایج بهتری دست می یابد.

بهمنظور بهتر نشاندادن عملکرد روش پیشنهادی، صحت طبقهبندی با استفاده از روشهای دیگر نیز بهدست آمده و با روش پیشنهادی مقایسه شدهاست. جدول ۶ صحت روش پیشنهادی را در مقایسه با روشهای دیگر، برای تشخیص عیوب سازه جکتی فراساحلی آزمایشگاهی نشان میدهد.

مطابق این جدول، صحت گزارش شده روش پیشنهادی برای سناریوهای ۲-کلاس، ۳-کلاس و ۵-کلاس تقریباً ۲۰۰۸، ۲۸۸ و ۲۸۷ است، درحالی که صحت شبکه پیشنهادی با دادههای فرکانسی سیگنالهای ارتعاشی (روش ۳) برای سناریوهای ۲-کلاس، ۳-کلاس و ۵-کلاس به ترتیب تقریباً ۶۹۶، ۲۹۷ و ۶۴۶ است. صحت شبکه پس انتشار خطا با دادههای فرکانسی سیگنالهای ارتعاشی بازسازی شده (روش ۲) برای سناریوهای ۲-کلاس، ۳-طبقه و ۵-کلاس حدوداً ۲۰۰۲، ۵۵۸ و ۲۳۶ است، درحالی که صحت شبکه پس انتشار خطا با دادههای فرکانسی سیگنالهای ارتعاشی (روش

(ج) سناریوی ۵-کلاس.

شکل ۱۶. ماتریس درهمریختگی روش پیشنهادی؛ (الف) سناریوی ۲–کلاس، (ب) سناریوی ۳–کلاس، (ج) سناریوی ۵–کلاس. Fig. 16. Confusion matrices of the proposed algorithm (a) Scenario of 2-Class; (b) Scenario of 3-Class; (c) Scenario of 5-Class.

دارد؛ برای به حداقل رساندن این تفاوتها، در روش پیشنهادی پارامترهای مدل شبیه سازی شده با توجه به داده های سالم واقعی به روز رسانی شده اند. به منظور اعتبار سنجی روش پیشنهادی، از یک مدل سازه جکتی فر اساحلی به عنوان یک مطالعه موردی در محیط آزمایشگاهی و یک شبکه عمیق مؤثر با الگوریتم یادگیری ویژگی بدون نظارت برای استخراج ویژگی های حساس به عیب استفاده شده است. برخی از بخش های سیگنال های ارتعاشی که دادههای عیب سازههای واقعی دشوار است و بهطورکلی فقط دادههای حالت سالم در اختیار است؛ این محدودیت از استفاده از الگوریتمهای داده محور در محیطهای صنعتی جلوگیری می کند. یک روش ممکن برای حل این مشکل، استفاده از دادههای عیب شبیهسازیشده بهجای دادههای واقعی است. بااینحال، همیشه بین ویژگیهای دینامیکی سیستمهای شبیهسازیشده و واقعی بهدلیل عدم قطعیتهای مختلف تفاوتهایی وجود health monitoring, Mechanical Systems and Signal Processing, 115 (2019) 213-237.

- [6] 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.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] K. Liu, R.-J. Yan, C.G. Soares, Damage identification in offshore jacket structures based on modal flexibility, Ocean Engineering, 170 (2018) 171-185.
- [11] A. Mojtahedi, M.L. Yaghin, Y. Hassanzadeh, M. Ettefagh, 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.
- [12] 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.
- [13] M. Fallahian, F. Khoshnoudian, V. Meruane, Ensemble classification method for structural damage assessment under varying temperature, Structural Health Monitoring, 17(4) (2018) 747-762.

مربوط به ذات اصلی سیستم نیستند با استفاده از روش تجزیه مود تجربی دستهای کامل حذف شدهاند. روش تجزیه حوزه فرکانس برای استخراج دادههای فرکانسی استفادهشدهاست. پس از آن، ویژگیهای حساس به عیب توسط شبکه پیشنهادی استخراج میشوند. دادههای فرکانسی مدل المان محدود و حالت سالم واقعی برای آموزش شبکه عمیق پیشنهادی و دادههای فرکانسی سازه واقعی برای ارزیابی شبکه عمیق پیشنهادی استفادهشدهاست. شبکه پیشنهادی استفاده از دو مرحله، یعنی طبقهبندی پیش آموزش با روش بدون نظارت بر پایه شبکه عمیق خود رمزنگار و لایه سافت مکس (مرحله اول) و طبقهبندی با آموزش مجدد برپایه الگوریتم پس انتشار خطا برای تنظیم دقیق پارامترهای شبکه پیشنهادی (مرحله دوم) طراحی شدهاست.

حساس به عیب را از دادههای فرکانسی مدل المان محدود و حالت سالم مدل واقعی بیاموزد و صحت قابل قبولی برای تشخیص عیوب سازه واقعی در حضور عدم قطعیتهای مختلف مانند خطاهای مدل سازی، خطاهای اندازه گیری و نویزهای محیطی بهدست آورد.

منابع

- [1][1]S. Cofre-Martel, P. Kobrich, E. Lopez Droguett, V. Meruane, Deep convolutional neural network-based structural damage localization and quantification using transmissibility data, Shock and Vibration, 2019 (2019).
- [2] X. Wang, J. Jiao, J. Yin, W. Zhao, X. Han, B. Sun, Underwater sonar image classification using adaptive weights convolutional neural network, Applied Acoustics, 146 (2019) 145-154.
- [3] Y. Bao, Z. Tang, H. Li, Y. Zhang, Computer vision and deep learning–based data anomaly detection method for structural health monitoring, Structural Health Monitoring, 18(2) (2019) 401-421.
- [4] H. Ahmed, M.L.D. Wong, A.K. Nandi, Intelligent condition monitoring method for bearing faults from highly compressed measurements using sparse over-complete features, Mechanical Systems and Signal Processing, 99 (2018) 459-477.
- [5] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, R.X. Gao, Deep learning and its applications to machine

response based on FE model and real healthy state, Applied Acoustics, 168 (2020) 107402.

- [23] Z. Mousavi, T.Y. Rezaii, S. Sheykhivand, A. Farzamnia, S. Razavi, Deep convolutional neural network for classification of sleep stages from single-channel EEG signals, Journal of neuroscience methods, 324 (2019) 108312.
- [24] M. Li, H. Wang, G. Tang, H. Yuan, Y. Yang, An improved method based on CEEMD for fault diagnosis of rolling bearing, Advances in Mechanical Engineering, 6 (2014) 676205.
- [25] M. Kuai, G. Cheng, Y. Pang, Y. Li, Research of planetary gear fault diagnosis based on permutation entropy of CEEMDAN and ANFIS, Sensors, 18(3) (2018) 782.
- [26] X. Zhang, Y. Liang, J. Zhou, A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM, Measurement, 69 (2015) 164-179.
- [27] D. Formenti, M. Richardson, Parameter estimation from frequency response measurements using rational fraction polynomials (twenty years of progress), in: Proceedings of International Modal Analysis Conference XX, Citeseer, 2002.
- [28] B. Song, D. Casem, J. Kimberley, Dynamic Behavior of Materials, Volume 1: Proceedings of the 2013 Annual Conference on Experimental and Applied Mechanics, Springer Science & Business Media, 2013.
- [29] G. Deodatis, B.R. Ellingwood, D.M. Frangopol, Safety, reliability, risk and life-cycle performance of structures and infrastructures, CRC Press, 2014.
- [30] L. Meirovitch, Analytical methods in vibrations, (1967).
- [31] C. Rajakumar, C. Rogers, The Lanczos algorithm applied to unsymmetric generalized eigenvalue problem, International Journal for Numerical Methods in Engineering, 32(5) (1991) 1009-1026.
- [32] H.D. Beale, H.B. Demuth, M. Hagan, Neural

- [14] S. Teng, G. Chen, G. Liu, J. Lv, F. Cui, Modal Strain Energy-Based Structural Damage Detection Using Convolutional Neural Networks, Applied Sciences, 9(16) (2019) 3376.
- [15] 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.
- [16] 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.
- [17] J.-H. Yi, J.-S. Park, S.-H. Han, K.-S. Lee, Modal identification of a jacket-type offshore structure using dynamic tilt responses and investigation of tidal effects on modal properties, Engineering Structures, 49 (2013) 767-781.
- [18] S.-L. Hung, H. Adeli, Parallel backpropagation learning algorithms on Cray Y-MP8/864 supercomputer, Neurocomputing, 5(6) (1993) 287-302.
- [19] I. Goodfellow, Y. Bengio, A. Courville, Deep learning, MIT press, 2016.
- [20] U.R. Acharya, S.L. Oh, Y. Hagiwara, J.H. Tan, H. Adeli, Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals, Computers in biology and medicine, 100 (2018) 270-278.
- [21] 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.
- [22] Z. Mousavi, M.M. Ettefagh, M.H. Sadeghi, S.N. Razavi, Developing deep neural network for damage detection of beam-like structures using dynamic

- [34] Z. Mousavi, M. M. Ettefagh, S. 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, AUT Journal of Mechanical Engineering, 2020, (in Persian).
- [35] 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.

network design, Pws, Boston, (1996).

[33] S. Sheykhivand, T.Y. Rezaii, A. Farzamnia, M. Vazifehkhahi, Sleep Stage Scoring of Single-Channel EEG Signal based on RUSBoost Classifier, in: 2018 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET), IEEE, 2018, pp. 1-6.

چگونه به این مقاله ارجاع دهیم Z. Mousavi, S. Varahram, M. M. Ettefagh, M. Ho. Sadeghi, S. Na. Razavi, Damage detection of offshore jacket structure using dynamic responses based on simulated model, intact state of real model and deep auto-encoder neural network, Amirkabir J. Mech Eng., 53(Special Issue 6)(2021) 3783-3808. DOI: 10.22060/mej.2020.18553.6843

بی موجعه محمد ا