



## Damage Assessment of a Cable-Stayed Bridge Based on Effective Empirical Mode Features using Empirical Wavelet Transform

H. Babajanian Bisheh<sup>1</sup>, Gh. Ghodrati Amiri<sup>2<\*</sup>, M. Nekooei<sup>1</sup>, E. Darvishan<sup>3</sup>

<sup>1</sup> Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.

<sup>2</sup> Natural Disasters Prevention Research Center School of Civil Engineerin Iran University of Science and Technology

<sup>3</sup> Department of Civil Engineering, Roudehen Branch, Islamic Azad University, Roudehen, Iran.

**ABSTRACT:** Intelligent damage detection of civil infrastructures is vital to improve damage prediction performance and reduce maintenance costs. Therefore, the development of efficient techniques for detecting structural damages in an early stage is extremely important to support making decisions on structure repair. In this paper, a new damage detection method based on effective frequency band with empirical wavelet transform for a cable-stayed bridge was proposed which consists of two stages: (1) signal processing and feature extraction, (2) damage identification by combining effective features. In the first stage, structural response data was decomposed into empirical modes using empirical wavelet transform to obtain the component related to structural damage, and a set of features as damage-sensitive features were extracted from the frequency spectrum of modes. A support vector machine was applied to evaluate the results. In the second stage, by applying feature selection methods, an optimal subset of features that carries the most significant information about the structural damage was obtained as a damage index. Next, it was used in the feature extraction process. To verify the proposed damage detection method, response data obtained from a cable-stayed bridge, the Yonghe Bridge, was employed. Results showed that the second and third empirical modes obtained from the empirical wavelet analysis contain fault information and using its corresponding frequency spectrum in the feature extraction process improves detection performance by about 5% compared to conventional methods. It also increases the detection accuracy to about 94% by employing effective feature combinations rather than a single feature.

### Review History:

Received: Jul. 27, 2019

Revised: Jul. 29, 2019

Accepted: Jul. 29, 2019

Available Online: Aug. 19, 2019

### Keywords:

Damage Detection

Empirical Wavelet Transform

Feature Selection

Cable-Stayed Bridge

Feature Extraction.

### 1- Introduction

Intelligent damage identification of civil infrastructure systems in an early stage is essential for Structural Health Monitoring (SHM) to prevent catastrophic failures and reduce maintenance costs. Thus, research and development of damage identification techniques are needed to achieve accurate detection automatically [1-2]. Vibration-based methods that utilize changes in measured vibration response of the structures for damage detection have received considerable attention in the last two decades. The basic idea of these methods is that modal parameters are functions of physical properties of the structure, and damage changes dynamic characteristics affecting the measured vibration response [3]. Vibration-based damage detection methods include three steps: signal monitoring, signal processing, and data interpretation [4]. Signal processing extracting useful features from structural signals is the key component and the most challenging issue [5]. The main processing techniques are based on time, frequency, and time-frequency analysis. Each signal processing method has its advantages and disadvantages, which may influence the performance of the damage detection procedure. Thus, choosing a signal

processing technique for detecting damage is essential to avoid erroneous results or false alarms. In this paper, the proposed approach is an extension of a method proposed by Ghodrati *et al.* [6]. The first stage of this study is aimed at increasing the accuracy of damage detection by applying Empirical Wavelet Transform (EWT) and extracting features from the frequency spectrum of modes. In the second stage, an effective empirical mode is obtained, and the combination of mode features is proposed as a damage index to improve the performance of the damage detection process by using feature selection methods. A Support Vector Machine (SVM) is used as a classifier to investigate the ability of each feature set. The proposed approach is verified using a numerical dataset and a real dataset recorded from a cable-stayed bridge, the Yonghe Bridge, as a benchmark problem.

### 2- Methodology

#### 2- 1- Feature Extraction

Feature extraction is a crucial step for signal processing to extract the suitable features in the time-frequency domain. The extracted features can reflect the relevant and useful information of damage from vibration signals. The features

\*Corresponding author's email: ghodrati@iust.ac.ir



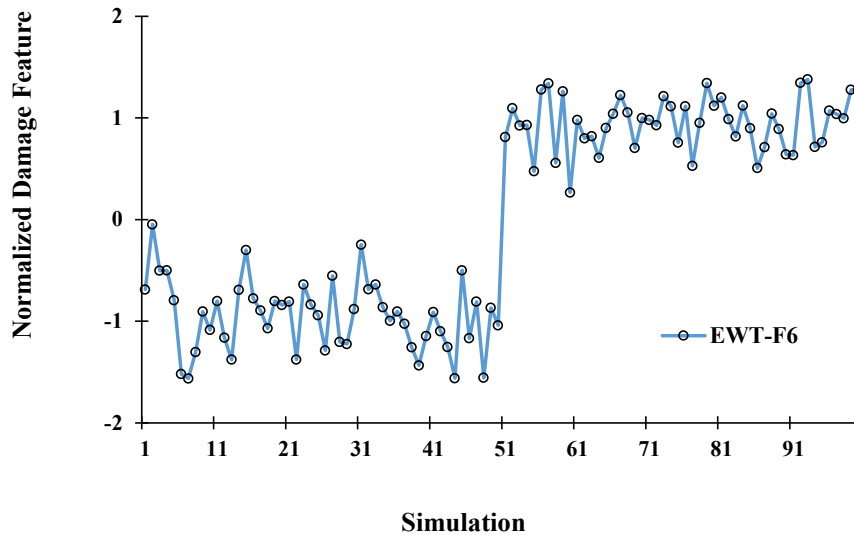


Fig. 1. Normalized damage feature extracted from 3rd empirical mode.

Table 1. Selected features by feature selection methods and classification accuracy.

Feature Selection Method	Optimal Feature Set	Accuracy (%)
FS	F10, F8	93
GA	F2, F4, F6, F10	94
RF	F2, F3, F1, F6, F8	93

correspond to spectral shape properties and statistical properties of the spectrum are used in this paper. These descriptors consist of mean, variance, root mean square, spectral crest factor, spectral flatness, spectral slope, spectral skewness, spectral spread, spectral kurtosis, and spectral flux [6].

2- 2- Empirical Wavelet Transform

The Empirical Wavelet Transform (EWT) is an adaptive data analysis technique to extract various modes of a time-domain signal by defining a series of wavelet filters. The EWT decomposes the input signal to narrow sub-bands in the time-frequency domain [7].

2- 3- Feature Selection And Svm Classifier

Feature selection is the procedure of selecting a subset of important and relevant features and includes four key steps, namely, subset generation, subset evaluation, stopping criteria, and result validation [8]. In this paper, the Forward Selection (FS), Genetic Algorithm (GA), and Random Forest (RF) methods are employed for feature selection.

The support vector machine (SVM) is a linear machine learning algorithm that can be applied to classify one or more classes successfully by locating the optimal separation plane (boundaries) between various classes [9]. The SVM separates input data by a linear hyperplane:

$$f(x) = w \cdot x + b = \sum_{k=1}^m w_k \cdot x_k + b = 0 \tag{1}$$

Where  $b$  is a scalar, and  $w$  is the weight vector.

3- Results and Discussion

This paper aims to obtain a damage index for detecting damage in a cable-stayed bridge. The data decomposes into empirical modes using EWT, and spectral features are then extracted from the frequency spectrum of the modes. Normalization is performed before the feature selection process to avoid slow training speed and data singularity. For each empirical mode, the important features are selected and combined using feature selection methods to improve the detection performance. Finally, the SVM classifier is an automated decision-making tool for classification tasks is used to find the effective empirical model and damage index. In the classification part, 70% of data is selected randomly as the train set and the other 30% as the test set. Cross-validation is performed to investigate how the results of a classification scheme will generalize to an independent data set. The repeated random sub-sampling validation method is employed here for cross-validation. Notably, all calculations were carried out using MATLAB software.

The proposed approach is validated using a suite of numerical and full-scale studies (a cable-stayed bridge in China and a Bridge Health Monitoring Benchmark Problem). For the numerical study, an accelerometer located on the model is considered to record the vertical accelerations. The gusset plates at node N1 are eliminated, and the moment of the transverse beam connecting at this node is released. Also, 10% white noise is added artificially. Fig. 1 depicts the effectiveness of the proposed method, which gives an average accuracy of 100%.

For the full-scale study, the available data consists of 24h records (24 parts of 1h length). Data in the healthy and damaged conditions are recorded on 17 January and 31 July 2008, respectively. The sampling frequency of data is 100 Hz.

The results in Table 1 show the subset of important features extracted from an effective empirical mode and classification accuracy obtained by SVM. The results showed that the 2<sup>nd</sup> and 3<sup>rd</sup> empirical modes are efficient for the feature extraction process. Using the proposed approach improved the identification performance to about 94% accuracy.

#### 4- Conclusions

In this study, a novel detection approach based on features extracted from an effective empirical mode in EWT is proposed to perform automatic damage identification of the bridges. Efficient extracted features are chosen and combined as an optimal feature set through feature selection methods to improve final results and reduce false alarms or misclassification. The feature selection methods consist of the forward selection, genetic algorithm, and random forest methods. This approach is verified using a suite of numerical and full-scale studies. The numerical study has shown that the performance of empirical mode features is highly promising for the task of damage identification. The results confirm that the proposed algorithm yields an average classification accuracy of 100% for a numerical benchmark problem. Besides, for the case of a full-scale study (Yonghe bridge), the damage is detected with an average accuracy of about 94%. The feature subset consists of  $F2$ ,  $F4$ ,  $F6$ , and  $F10$  obtained by the genetic algorithm. Also, the peak accuracy is about 93% achieved by the forward selection and random forest methods.

#### References

- [1] M. Radziński, Ł. Doliński, M. Krawczuk, M. Palacz, Damage localisation in a stiffened plate structure using a propagating wave, *Mechanical Systems and Signal Processing*, 39(1-2) (2013) 388-395.
- [2] N.T.S. Board, U.S.N.T.S. Board, Collapse of I-35W Highway Bridge, Minneapolis, Minnesota, August 1, 2007, Createspace Independent Pub, 2008.
- [3] M.J. Whelan, M.V. Gangone, K.D. Janoyan, R. Jha, Real-time wireless vibration monitoring for operational modal analysis of an integral abutment highway bridge, *Engineering Structures*, 31(10) (2009) 2224-2235.
- [4] D. Goyal, B. Pabla, The vibration monitoring methods and signal processing techniques for structural health monitoring: a review, *Archives of Computational Methods in Engineering*, 23(4) (2016) 585-594.
- [5] J.P. Amezcua-Sanchez, H. Adeli, Signal processing techniques for vibration-based health monitoring of smart structures, *Archives of Computational Methods in Engineering*, 23(1) (2016) 1-15.
- [6] H. Babajanian Bisheh, G. Ghodrati Amiri, M. Nekooei, E. Darvishan, Damage detection of a cable-stayed bridge using feature extraction and selection methods, *Structure and Infrastructure Engineering*, 15(9) (2019) 1165-1177.
- [7] J. Gilles, Empirical wavelet transform, *IEEE transactions on signal processing*, 61(16) (2013) 3999-4010.
- [8] J. Toivola, J. Hollmén, Feature extraction and selection from vibration measurements for structural health monitoring, in: *International Symposium on Intelligent Data Analysis*, Springer, 2009, pp. 213-224.
- [9] S. Yin, X. Gao, H.R. Karimi, X. Zhu, Study on support vector machine-based fault detection in tennessee eastman process, in: *Abstract and Applied Analysis*, Hindawi, 2014.

#### HOW TO CITE THIS ARTICLE

H. Babajanian Bisheh, Gh. Ghodrati Amiri, M. Nekooei, E. Darvishan, *Damage Assessment of a Cable-Stayed Bridge Based on Effective Empirical Mode Features using Empirical Wavelet Transform*. *Amirkabir J. Civil Eng.*, 53(3) (2021) 271\_24

DOI: [10.22060/ceej.2020.16849.6368](https://doi.org/10.22060/ceej.2020.16849.6368)







## تشخیص خرابی در پل کابلی مبتنی بر ویژگی های مود تجربی مؤثر در تبدیل موجک تجربی

حسین باباجانین<sup>۱</sup>، غلامرضا قدرتی امیری<sup>۲\*</sup>، مسعود نکویی<sup>۱</sup>، احسان درویشان<sup>۳</sup>

<sup>۱</sup> گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

<sup>۲</sup> مرکز مطالعات مخاطرات طبیعی، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران.

<sup>۳</sup> گروه مهندسی عمران، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران.

### تاریخچه داوری:

دریافت: ۱۳۹۸/۰۵/۰۷

بازنگری: ۱۳۹۹/۰۵/۰۵

پذیرش: ۱۳۹۹/۰۵/۰۷

ارائه آنلاین: ۱۳۹۹/۰۵/۲۸

### کلمات کلیدی:

شناسایی آسیب

تبدیل موجک تجربی

انتخاب ویژگی، پل کابلی

استخراج ویژگی

**خلاصه:** شناسایی هوشمندانه خسارت در سازه های زیربنایی از جمله پل ها به منظور بهبود عملکرد پیش بینی آسیب و کاهش هزینه نگهداری ضروری است. بنابراین، توسعه روش های کارآمد برای تشخیص به موقع آسیب در سازه و تصمیم گیری نسبت به تعمیر آن از اهمیت زیادی برخوردار است. در این مقاله، یک روش جدید مبتنی بر ویژگی های باند فرکانسی مؤثر در تحلیل تبدیل موجک تجربی به منظور تشخیص آسیب در پل کابلی ارائه شد که شامل دو بخش است: (۱) پردازش سیگنال و استخراج ویژگی، (۲) تشخیص آسیب با استفاده از ترکیب ویژگی های مؤثر. در بخش اول، داده های پاسخ سازه با استفاده از تبدیل موجک تجربی به مودهای تجربی تجزیه گردید و مجموعه ای از ویژگی ها به عنوان مشخصه حساس به خرابی از طیف فرکانس مودها استخراج شد. به منظور ارزیابی نتایج از طبقه بند ماشین بردار پشتیبان استفاده گردید. در بخش دوم، برای کاهش خطای الگوریتم شناسایی آسیب، با استفاده از روش های انتخاب ویژگی، یک زیرمجموعه بهینه حاوی اطلاعات مربوط به آسیب سازه ای شامل ترکیبی از ویژگی های مهم به عنوان شاخص خرابی تعیین گردید. برای اعتبارسنجی روش پیشنهادی از داده های پاسخ پل کابلی یونگ استفاده شد. نتایج نشان داد که دومین و سومین مود تجربی حاصل از تحلیل موجک تجربی حاوی اطلاعات مرتبط با خرابی بوده و بکارگیری طیف فرکانسی متناظر آن در فرآیند استخراج ویژگی، عملکرد شناسایی را نسبت به روش های متداول حدود ۵ درصد بهبود می دهد. همچنین استفاده از ترکیب ویژگی های مؤثر بجای یک ویژگی تنها، دقت شناسایی را به حدود ۹۴ درصد افزایش می دهد.

### ۱- مقدمه

اقتصادی و جانی را به همراه داشته است. بیشتر چنین خرابیها را می توان با بررسیهای اولیه از وضعیت موجود سازه ها ترمیم نمود و از گسترش خرابی در سازه و فروریختن آن جلوگیری به عمل آورد. پل I-۳۵W در میناپولیس در سال ۲۰۰۷ یک خرابی فاجعهبار را در دهانه اصلی خرابی عرشه تجربه کرد. در نتیجه سقوط این پل ۱۳ نفر جان باختند و ۱۴۵ نفر نیز زخمی شدند. همچنین با از کارافتادگی سیستم حمل و نقل، خساراتی در سایر بخشها و زیربخشهای اقتصادی در پی داشت [۲]. بخش مرکزی پل سونگسو به طول بیش از ۴۸ متر واقع در پایتخت کشور کره بطور ناگهانی در طی بهرهبرداری فرو ریخت که ۳۲ نفر جان باختند و نیز ۱۷ نفر در این حادثه زخمی شدند [۳]. در سال ۲۰۱۳ پل I-۵ رودخانه اسکجیت

پلهای بزرگراه یا راهآهن تحت بارهای مرده و ترافیک عبوری همراه با بارهای شدید طی خطرات طبیعی به عنوان مهمترین بخش سیستم زیربنایی حمل و نقل در نظر گرفته میشوند. شکست ناگهانی پلها می تواند منجر به خسارت گسترده اقتصادی و جانی گردد. بنابراین، برای اطمینان از سلامت آنها، نگهداری و حفظ سیستم سازه ای در طول عمر آن ضروری است. پایش سلامت سازه های و شناسایی آسیب سازه های در پلها، یک موضوع پژوهشی است که طی سالهای اخیر مورد توجه بوده است [۱]. تاکنون نمونه های زیادی از انواع خرابیها و فروریزشها در پلها به ثبت رسیده است که در پی وقوع آنها، خسارات

\* نویسنده عهده دار مکاتبات: ghodrati@iust.ac.ir



حین بهره‌برداری به سبب بارهای زنده همراه با خراب شدن در طول زمان دچار فروریزش سازه‌های شد [۴].

تحقیقات زیادی در زمینه روشهای مبتنی بر ارتعاش به دلیل توانایی آنها در تشخیص آسیبهای سازه‌های که قابل مشاهده حین بازرسی بصری نیستند انجام شده است [۵]. این فرآیند شامل پایش پلها در طول زمان با استفاده از تاریخچه زمانی ثبت شده از پاسخ سازه (شتاب، تغییر مکان و غیره) توسط سنسورها می باشد. بطور کلی ایده اصلی روشهای مبتنی بر ارتعاش این است که آسیب، خواص فیزیکی سازه و مشخصات دینامیکی آنها را تغییر می دهد و این تغییر در پاسخ ارتعاشی اندازه گیری شده تأثیرگذار است [۶]. روش شناسایی آسیب مبتنی بر ارتعاش شامل سه مرحله اصلی است: دریافت سیگنال، پردازش سیگنال و تفسیر داده ها. هدف از پردازش سیگنال که جزء اصلی روش مبتنی بر ارتعاش است، استخراج ویژگی حساس به خرابی میباشد که این ویژگیها باید قادر به نشان دادن تغییرات در سیگنالهای ارتعاشی باشند [۷]. روشهای مبتنی بر ویژگی که در تحقیقات مورد استفاده قرار گرفته اند شامل روشهای حوزه زمان، حوزه فرکانس و حوزه زمان-فرکانس می باشد [۸].

ویژگیهای حوزه زمان جنبه های زمانی سیگنال را نشان میدهد که سریع و بطور مستقیم بر روی داده های سری زمانی قابل استخراج است (مانند میانگین، انحراف معیار، جذر میانگین مربعات و غیره) [۹, ۱۰]. ویژگیهای حوزه فرکانس نشاندهنده محتوای فرکانسی و جنبه‌های طیفی بدست آمده از تبدیل سریع فوریه میباشد [۱۱] و [۱۲] مانند انرژی در باند فرکانسهای مختلف، ضرایب فوریه و سایر ویژگیهای حوزه زمان-فرکانس مانند تمرکز انرژی، سطح دامنه، باندهای زمان-فرکانس، توزیع زمان-فرکانس، با استفاده از ابزارهای مختلف پردازش سیگنال برای نشان دادن اطلاعات سیگنال در هر دو حوزه زمان و فرکانس به کار می روند. این روشها مانند تبدیل موجک، توزیع ویگنر ویل، تبدیل فوریه زمان-کوتاه، تبدیل هیلبرت هوآنگ است. وانگ و شای [۱۳] در سال ۲۰۱۸ یک شاخص خرابی مبتنی بر تبدیل بسته های موجک (WPT) برای شناسایی آسیب در سازه‌ها پیشنهاد کردند. آنها پس از تجزیه سیگنال با WPT از شاخص اختلاف انحنای انرژی (ECD) استفاده کردند. نتایج تحقیقات آنها نشان داد که شاخص ECD به سطوح پایین آسیب حساس است. زو و وو [۱۴] در سال ۲۰۰۷ یک الگوریتم تشخیص

آسیب مبتنی بر انرژی پاسخ شتاب در سازه پل با دهانه بلند ارائه دادند. نتایج نشان داد با استفاده از شاخص مذکور می توان موقعیت مکانی آسیب را تشخیص داد. شین و همکاران [۱۵] در سال ۲۰۱۹ روش اصلاحی تبدیل موجک تجربی را برای شناسایی پارامترهای مودال بر اساس پاسخهای اندازه گیری شده دینامیکی ارائه دادند. عادل و همکاران [۱۶] در سال ۲۰۱۷ با استفاده از الگوریتم طبقه‌بندی سیگنالهای چندگانه، تبدیل موجک تجربی و تبدیل هیلبرت، روشی برای تشخیص پارامترهای مودال در سازه ساختمانی پیشنهاد دادند. به منظور استخراج ویژگی مناسب از سیگنالهای ارتعاشی و تشخیص آسیب، لی و همکاران [۱۷] در سال ۲۰۱۷ روش تبدیل فرکانس-زمان (تبدیل S) را برای تحلیل سیگنالهای ارتعاشی تیر بتنی مسلح تحت بارهای مختلف بکار بردند. آنها از شاخص تغییر انرژی حداکثر استفاده کردند. لی و همکاران [۱۸] در سال ۲۰۱۵ از روش تبدیل موجک فشرده (SWT) برای استخراج ویژگی خرابی سازه‌های استفاده کردند. آنها یک شاخص خرابی متغیر زمان مبتنی بر فرکانسهای لحظه ای استخراج شده و فاکتورهای مشارکت مودال ارائه دادند. درویشان [۱۹] در سال ۲۰۱۸ با استفاده از پردازش سیگنال دامنه زمان-فرکانس به شناسایی آسیب در سازه پل کابلی پرداخت و ضمن مقایسه چند روش در این حوزه، روش تبدیل موجک تجربی را به عنوان روشی مؤثر در تشخیص خرابی پیشنهاد داد.


در مرحله تفسیر داده ها، یک سیستم تصمیم گیری اتوماتیک برای طبقه بندی وضعیت سازه به لحاظ سلامت مورد نیاز است. در سالهای اخیر، ترکیبی از روشهای هوش مصنوعی و پردازش سیگنال توجه بسیاری از محققان را به خود جلب کرده است. تعدادی از رایجترین روشهای طبقه بند مورد استفاده در شناسایی آسیب سازه‌های شامل شبکه عصبی مصنوعی، منطق فازی و ماشین بردار پشتیبان است [۲۰، ۲۱ و ۲۲] قادری و شعبانی [۲۳] روشی برای تشخیص آسیب در سازه بر مبنای پارامترهای مودال و پاسخ دینامیکی با استفاده از الگوریتم گرگ خاکستری بهبود یافته ارائه دادند.

هر یک از روشهای پردازش سیگنال که ذکر شد دارای مزایا و معایب خاص می باشد که ممکن است نتایج نهایی فرآیند شناسایی آسیب را تحت تأثیر قرار دهد؛ بطوریکه برخی از آنها برای یک کاربرد خاص مناسب بوده و برای سایر مسائل کاربردی نامناسب است. همچنین به سبب وجود اطلاعات نامربوط و نویز در سیگنالهای

جدول ۱. مشخصات مقاطع اعضای پل آزمایشگاهی

Table 1. Physical parameters of the bridge model

نوع عضو	پهنا (mm)	عرض (mm)	ضخامت (mm)
تیر اصلی	۵/۹۲	۸/۵۷	۴/۳
تیر عرضی	۵/۹۲	۷/۶۲	۴/۳
پایه	۱۶/۴۸	۳۱/۰۴	۵/۸



شکل ۱. مدل سازه پل: (a) شکل فیزیکی مدل آزمایشگاهی، (b) موقعیت گره ها و آسیب [۲۳]

Fig. 1. Bridge Model; (a) the physical model used for the benchmark experiments, and (b) node numbers and damage location

است منجر به افزایش خطای تشخیص (تشخیص اشتباه) گردد. مقاله حاضر در راستای ادامه پژوهش انجام شده توسط قدرتی امیری و همکاران [۲۴] است که با ارائه الگوریتم جدیدی به شناسایی خرابی در سازه پل کابلی یونگ می پردازد. در الگوریتم پیشنهادی

ارتعاشی پاسخ سازه، نوع ویژگی انتخابی یا خصیصه حساس به خرابی و روش انتخابی استخراج ویژگی در نتایج شناسایی آسیب تأثیرگذار است. بنابراین، انتخاب روش پردازش سیگنال برای ارزیابی آسیبهای سازه ای مهم بوده و چنانچه روش مورد استفاده مناسب نباشد ممکن



شکل ۲. نمایی از پل کابلی یونگ [۳۶]

Fig. 2. General view of the Yonghe Bridge

مودهای تجربی تجزیه گردید و مجموعه‌های از ویژگیها از طیف فرکانس مودهای مختلف استخراج شد. برای ارزیابی نتایج و مقایسه آن با روشهای متداول استخراج ویژگی از طبقه بند ماشین بردار پشتیبان استفاده گردید. در بخش دوم، به منظور بهبود عملکرد فرآیند شناسایی آسیب، ترکیبی از ویژگیهای مهم باند فرکانسی مؤثر که حاوی اطلاعات مرتبط با خرابی است به عنوان شاخص خرابی تعیین شد. الگوریتم پیشنهادی با استفاده از داده های شبیه سازی شده مدل عددی پل آزمایشگاهی و مجموعه داده های ارتعاشی ثبت شده از یک پل کابلی واقعی (پل یونگ) که از سوی موسسه تحقیقات هاربین ارائه شد مورد اعتبارسنجی قرار گرفت.

## ۲- مطالعه مدل عددی پل آزمایشگاهی و مدل واقعی پل کابلی

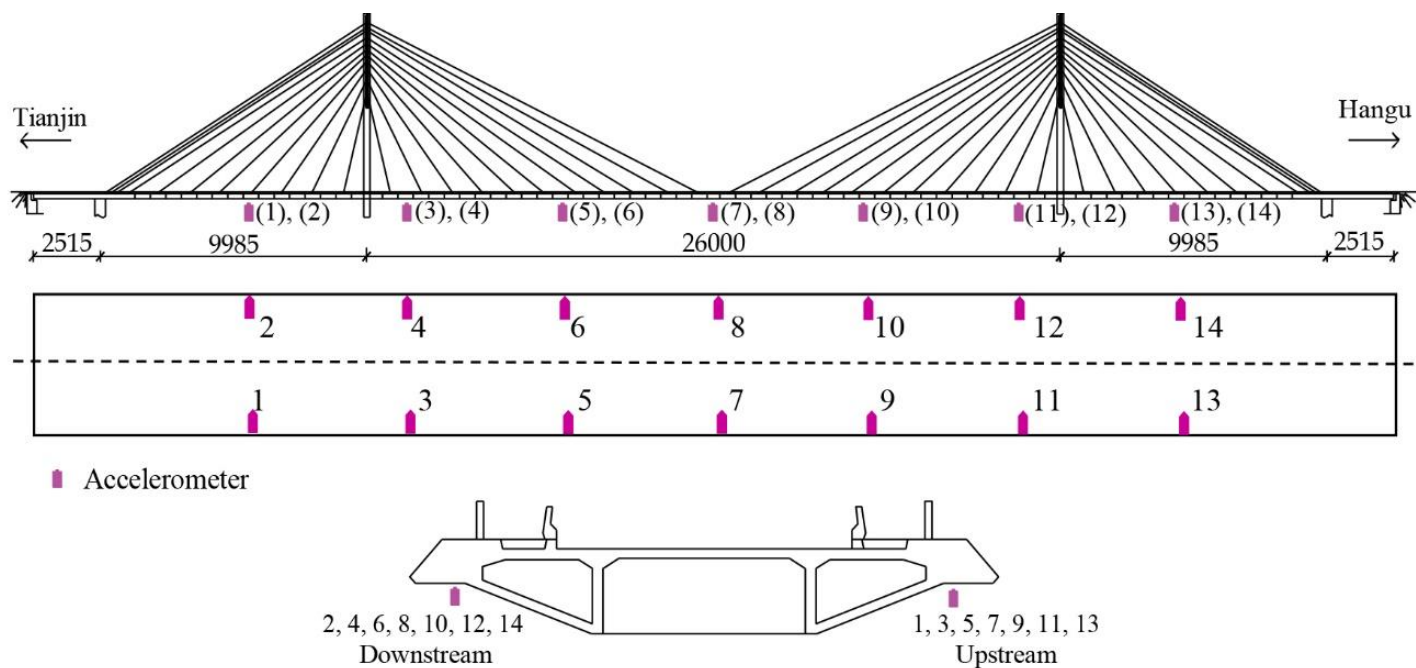
### یونگ

در مقاله حاضر روش پیشنهادی با استفاده از داده‌های ارتعاشی مربوط به پل واقعی کابلی (پل یونگ) صحت سنجی شد. همچنین به منظور اطمینان از عملکرد فرآیند شناسایی آسیب، روش پیشنهادی

با استفاده از یک روش پردازش سیگنال کارا، شاخص خرابی مبتنی بر ویژگیهای باند فرکانسی مؤثر سیگنال پاسخ سازه ارائه شد که در آن از اطلاعات کلیه باندهای طیف فرکانسی پاسخ استفاده نمیگردد. به منظور تجزیه سیگنالهای پاسخ به مودهای مختلف و استخراج ویژگیهای آن، استفاده از روش EWT پیشنهاد شد تا با انتخاب مود تجربی مؤثر نگرانیهایی نظیر اختلاط مودها (وجود فرکانسهای مشترک در مودهای مختلف مانند روش EMD) که در سیگنالهای پیچیده مانند پاسخ سازه پل کابلی سبب تشخیص کاذب میشود، مرتفع گردد. همچنین به منظور بهبود دقت تشخیص خرابی، باند فرکانسی مؤثر تعیین و ترکیب ویژگیهای آن به عنوان شاخص خرابی پیشنهاد شد. به عبارت دیگر با محدود کردن طیف فرکانسی پاسخ سیگنال، اطلاعات اضافی و غیرمرتبط حذف گردید و با بکارگیری فرآیند استخراج و انتخاب ویژگی در یک مود تجربی (باند فرکانسی مؤثر)، شاخص خرابی تعیین شد.

در بخش اول مقاله، به منظور تجزیه سیگنالها و یافتن مولفه مرتبط با خرابی، داده ها با استفاده از تبدیل موجک تجربی به





شکل ۳. نمایی از مشخصات طولی پل یونگ و موقعیت سنسورهای نصب شده [۲۷]

Fig. 3. Elevation of Yonghe Bridge with the main dimensions and location of installed sensors



شکل ۴. آسیب های رخ داده در پل یونگ شامل ترک در (a) بخش میانی عرشه و (b) آسیب در پایه های بتنی پل [۲۸]

Fig. 4. Damage patterns of Yonghe Bridge (a) cracks at the closure segment and (b) damaged concrete piers of the bridge

#### ۱-۲- مدل عددی پل BHM

به منظور صحت سنجی روش پیشنهادی شناسایی آسیب، داده های شبیه سازی مدل عددی پل آزمایشگاهی که از سوی دانشگاه فلوریدا و

با استفاده از داده های شبیه سازی شده مدل عددی پل آزمایشگاهی که از سوی دانشگاه فلوریدا و دانشگاه واشنگتن ارائه شد، مورد اعتبار سنجی قرار گرفت.

بازگشایی شد و داده های پاسخ عرشه (شتاب) در وضعیت سلامت پل ثبت شد. در آگوست ۲۰۰۸، حین بازرسی دو نوع آسیب جدی در دو دهانه کناری (ترک جدی در قسمت های خارجی عرشه) و پایهها (خسارت جزئی تکیه گاه های عمودی به سبب بارگذاری بیش از حد) شناسایی شد (شکل ۴). این خرابیها به عنوان الگوهای واقعی آسیب بودند و از داده های اندازه گیری شده در این وضعیت از پل می توان برای آزمایش توانایی روشهای تشخیص خرابی استفاده نمود. به نظر می آید که درجه آسیب سازهای به تدریج با گذشت زمان توسعه یافت. بنابراین داده های شتاب از ژانویه تا آگوست سال ۲۰۰۸ اندازه گیری شد که احتمالاً پل با اضافه بار به تدریج آسیب دید [۲۶]. اطلاعاتی که در اختیار محققان گرفته، شامل داده هایی است که مربوط به وضعیت سالم و آسیب دیده پل می باشد. داده های مربوط به وضعیت سالم پل شامل ۲۴ داده ۱ ساعته از تاریخچه زمانی شتاب عرشه پل بوده که در ۱۷ ژانویه ۲۰۰۸ با فرکانس نمونه برداری ۱۰۰ هرتز ثبت شد. بخش دوم داده های موجود شامل اندازه گیریهای شتاب زمانی است که پس از چند ماه، در ۳۱ جولای ۲۰۰۸ در موقعیتهای مشابه ثبت شد. مجموعه داده ها شامل سریهای زمانی ۱ ساعته با فرکانس نمونه برداری ۱۰۰ هرتز می باشد که برای ۲۴ ساعت تکرار شده است [۲۶]. در این مقاله، برای صحت سنجی روش پیشنهادی شناسایی آسیب، از مجموعه داده های اندازه گیری شده در ژانویه و جولای ۲۰۰۸ به عنوان داده های مربوط به وضعیتهای سالم و آسیب دیده پل کابلی یونگ استفاده گردید.

### ۳- استخراج ویژگی

استخراج ویژگی گام مهمی برای پردازش سیگنال و روش کلیدی در شناسایی آسیب سازه ای در سطوح مختلف شامل وجود آسیب، نوع آسیب، محل آن و میزان شدت خسارت محسوب میگردد. استخراج ویژگی مبتنی بر پردازش سیگنال به سبب پیچیدگی پاسخ سازهای به بارگذاری دینامیکی، موضوع چالش برانگیز در حوزه پایش سلامت سازه است [۲۷]. الگوریتمهای پردازش سیگنال برای پایش سلامت سازه با استفاده از سیگنالهایی که اغلب آلوده به نویز و پیچیده اند، ویژگیها را شناسایی می کنند. روشهای پردازش سیگنال زیادی در تحقیقات پایش سلامت سازه مبتنی بر ارتعاش مورد استفاده قرار گرفته است. رایجترین آنها شامل تبدیل فوریه، تبدیل فوریه زمان

دانشگاه واشنگتن ارائه شد مورد استفاده قرار گرفت. مدل فیزیکی پل دارای دو دهانه به طول ۵/۴۹ متر با تیرهای پیوسته در جهت طولی و عرض ۰/۹۲ متر میباشد و تیرهایی در جهت عرضی با فواصل یکسان تیرهای طولی را بهم متصل میکند. ارتفاع ستونهای پل ۱/۰۷ متر می باشد که در شکل ۱ نشان داده شده است. پایه ها، تیرهای اصلی و تیرهای عرضی دارای مقاطع فولادی H شکل با مشخصات ارائه شده در جدول ۱ می باشد. مدل اجزای محدودی پل شامل ۱۸۱ عنصر خطی، ۱۷۶ گره و ۱۰۵۶ درجه آزادی است که در مدلسازی با نرم افزار کد نویسی MATLAB مورد استفاده قرار گرفت [۲۵]. سنسور شتابسنج در موقعیت  $N^2$  برای ثبت پاسخ تاریخچه زمانی شتاب تحت بارگذاری تصادفی در نظر گرفته شد. بارگذاری دینامیکی در موقعیت  $N^1$  اعمال شد و داده های پاسخ از مدل جمعآوری شد و ۱۰ درصد نویز سفید بطور مصنوعی به آن اضافه شد. سطح نویز اضافه شده شامل ۱۰ درصد حداکثر جذر میانگین مربعات سیگنال شتاب میباشد. آسیب اعمال شده شامل آزادسازی لنگر اتصال تیر عرضی و حذف صفحات اتصال در موقعیت  $N^1$  میباشد.

### ۲-۲- پل مرجع یونگ

پل یونگ یکی از نخستین پلهای کابلی ساخته شده در کشور چین است که شهرهای تیانجین و هانگو را به هم متصل میکند (شکل ۲). طول این پل ۵۱۰ متر است که شامل یک دهانه میانی به طول ۲۶۰ متر و دو دهانه کناری به طول ۹۹/۸۵ و ۲۵/۱۵ متر در هر طرف میباشد. عرض پل ۱۱ متر و ارتفاع برجها ۶۰/۵ متر است.

در اواخر سال ۱۹۸۷، این پل برای عبور بار ترافیکی افتتاح شد و پس از ۱۹ سال بهره برداری، ترکهایی به عرض ۲ سانتیمتر در وجه پائین عرشه میانی مشاهده گردید و کابلها بطور جدی دچار خوردگی شدند. به همین دلیل عملیات تعمیر و نگهداری قابل توجهی انجام شد. عملیات بهسازی پل یونگ بین سالهای ۲۰۰۵ تا ۲۰۰۷ انجام شد و عرشه میانی، مقاومسازی و کلیه کابلها تعویض شدند. برای اطمینان از ایمنی آینده این پل، سیستم پایش سلامت سازه به منظور پایش و جمعآوری داده های سری زمانی توسط موسسه مرکز تحقیقات فناوری هاربین طراحی و اجرا شد. سیستم پایش شتاب شامل چهارده شتاب سنج است که به طور دائمی و متقارن در دو طرف عرشه نصب شد (شکل ۳). این پل در پایان سال ۲۰۰۷ برای عبور بار ترافیکی

جدول ۲. ویژگی های طیف فرکانسی سیگنال [۲۴]

Table 2. Signal frequency spectrum characteristics

Parameter	Equation
واریانس	$F1 = \frac{\sum_{m=1}^M (y(m) - F1)^2}{M - 1} \quad (1)$
جذر میانگین مربعات	$F2 = \sqrt{\frac{\sum_{m=1}^M (y(m))^2}{M}} \quad (2)$
میانگین	$F3 = \frac{\sum_{m=1}^M y(m)}{M} \quad (3)$
ضریب اوج طیفی	$F4 = \frac{\max_{0 \leq k \leq K/2-1}  X(k, n) }{\sum_{k=0}^{K/2-1}  X(k, n) } \quad (4)$
ضریب تناسب طیفی	$F5 = \frac{K/2 \sqrt{\prod_{k=0}^{K/2-1}  X(k, n) }}{\sum_{k=0}^{K/2-1}  X(k, n) } = \frac{\exp\left(\frac{2}{K} \cdot \sum_{k=0}^{K/2-1} \log( X(k, n) )\right)}{\sum_{k=0}^{K/2-1}  X(k, n) } \quad (5)$
شیب طیفی	$F6 = \frac{\sum_{k=0}^{K/2-1} (k - \mu_k) ( X(k, n)  - \mu_{ X })}{\sum_{k=0}^{K/2-1} (k - \mu_k)^2} = \frac{K \sum_{k=0}^{K/2-1} k \cdot  X(k, n)  - \sum_{k=0}^{K/2-1} k \cdot \sum_{k=0}^{K/2-1}  X(k, n) }{K \cdot \sum_{k=0}^{K/2-1} k^2 - \left(\sum_{k=0}^{K/2-1} k\right)^2} \quad (6)$
چولگی طیفی	$F7 = \frac{2 \sum_{k=0}^{K/2-1} ( X(k, n)  - \mu_{ X })^3}{K \cdot \sigma_{ X }^3} \quad (7)$
پخش شدگی طیفی	$F8 = \sqrt{\frac{\sum_{k=0}^{K/2-1} (k - S_1)^2 \cdot  X(k, n) ^2}{\sum_{k=0}^{K/2-1}  X(k, n) ^2}} \quad (8)$
کشیدگی طیفی	$F9 = \frac{2 \sum_{k=0}^{K/2-1} ( X(k, n)  - \mu_{ X })^4}{K \cdot \sigma_{ X }^4} - 3 \quad (9)$
شار طیفی	$F10 = \frac{\sqrt{\sum_{k=0}^{K/2-1} ( X(k, n)  -  X(k, n-1) )^2}}{K / 2} \quad (10)$

#### ۴- تبدیل موجک تجربی

تبدیل موجک تجربی (EWT) یک رویکرد نسبتاً جدید است که توسط گیل [۳۱] برای استخراج مدهای مختلف سیگنال ارائه شد. با تعریف مجموعه ای از فیلترهای موجک که با سیگنال پردازش شده سازگارند، تمام حالتها می توانند استخراج شوند. فرض میشود سیگنال حوزه زمان  $x(t)$  شامل تعدادی تابع مدهای ذاتی باشد. در این روش، طیف فرکانسی هر سیگنال به  $N$  بخش برای استخراج مدهای تجربی تقسیمبندی می شود و برای تقسیم بندی محور فوریه به  $N$  بخش،  $I-N$  بیشینه محلی در طیف سیگنال یا بیشترین دامنه تعیین می شود. تقسیم بندی طیف فوریه برای جداسازی و استخراج مدهای مختلف، ایده کلیدی در روش EWT است که با استفاده از موجکهای تجربی انجام می شود و ساخت خانواده ای از موجکهای تجربی، معادل تشکیل مجموعه ای از فیلترهای میانگذر است [۲۹].

$\omega_n$  به عنوان مرز طیف فوریه مورد نیاز برای تجزیه و تحلیل EWT، و هر قطعه با یک فاصله  $[\omega_n, \omega_{n+1}]$  فیلتر می شود که  $\omega_n = \pi$  و  $\theta = \omega_0$ . یک فاز گذرا با عرض  $2\tau_n$  برای هر  $\omega_n$  تعریف می شود و هر  $\tau_n$  به طبق رابطه (۱۱) بیان می گردد [۳۲].

$$\tau_n = \gamma \times \omega_n \quad (11)$$

$$0 < \gamma < \min_n \frac{\dot{\omega}_{n+1} - \dot{\omega}_n}{\dot{\omega}_{n+1} + \dot{\omega}_n} \quad (12)$$

تابع مقیاس تجربی و موجکهای تجربی [۲۹] به شرح زیر تعریف میشوند:

$$\hat{\phi}_n = \begin{cases} 1 & \text{if } |\omega| \leq (1-\gamma)\omega_n \\ \cos \left[ \frac{\pi}{2} \beta \left( \left( \frac{1}{2\gamma\omega_n} \left( (1-\gamma)\omega_n \right) \right) \right) \right] & \text{if } (1-\gamma)\omega_n < |\omega| < (1+\gamma)\omega_n \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

کوتاه، تبدیلات ویولت و تبدیل هیلبرت هوآنگ می باشد که در بخش مقدمه به آنها اشاره شد. اساساً استخراج ویژگی فرآیندی است که داده ها از ابعاد بالاتر به فضایی با ابعاد پائین تر تبدیل میشوند و مهم ترین داده ها از دادههای خام بازیابی می گردد. یکی از راههای استخراج ویژگی، محاسبه مشخصه دینامیکی سازه یا طراحی مشتقات آنها به منظور دستیابی به حساسیت بالا در برابر آسیب است که با نظارت بر تغییرات این مشخصهها میتوان خسارت را تشخیص داد [۲۹]. اصلترین عامل در دستیابی به عملکرد مطلوب در فرآیند شناسایی، استخراج ویژگیهای ایده آل می باشد، بطوریکه بتواند اطلاعات مربوط به آسیب سازههای را تا حد امکان بطور کامل منعکس نماید. عملکرد مطلوب در فرآیند شناسایی میتواند دقت بالا در مسأله طبقه بندی باشد. به عبارت دیگر با استفاده از یک مجموعه جدید حاصل از فرآیند استخراج ویژگی باید بتوان تغییر در وضعیت سازه (وجود خرابی) را با دقت بالا نشان داد [۳۰، ۳۱]. در این مقاله، از ویژگیهای طیف فرکانسی سیگنال پاسخ برای استخراج اطلاعات استفاده شد. این ویژگیها شامل مشخصات آماری طیف و مشخصات شکل طیفی است که در جدول ۲ ارائه شده است. مشخصات آماری طیف شامل واریانس، جذر میانگین مربعات و میانگین میباشد و مشخصات شکل طیفی شامل پارامترهای به شرح ذیل است:

- ضریب اوج طیفی (F۴): این ویژگی با مقایسه مقدار حداکثر طیف و مجموع رشته طیف، تعیین می شود.
- ضریب تناسب طیفی (F۵): با مقایسه میانگین هندسی و میانگین حسابی مقادیر طیفی به دست می آید.
- شیب طیفی (F۶): به شیب طیفی مربوط می شود. شیب طیفی با استفاده از یک رگرسیون خطی در مقادیر دامنه طیفی محاسبه میشود. شیب طیفی به طور خطی وابسته به مرکز جرم طیفی است.
- چولگی طیفی (F۷): عدم تقارن طیف را حول مقدار میانگین آن نشان میدهد.
- پخش شدگی طیفی (F۸): پخش شدگی طیف را حول مقدار میانگین ارائه می دهد.
- کشیدگی طیفی (F۹): توزیع مقادیر طیفی و مقدار شباهت آن را با توزیع گاوسی شکل نشان می دهد.
- شار طیفی (F۱۰): مقدار تغییر شکل طیفی را نشان می دهد.

$$f_0(t) = W_x(0, t) * \phi_1(t) \quad (19)$$

$$f_k(t) = W_x(k, t) * \psi_k(t) \quad (20)$$

و سیگنال بازسازی شده را میتوان از روابط (۲۱) و (۲۲) تعیین نمود:

$$\hat{x}(t) = W_x(0, t) * \phi_1(t) + \sum_{n=1}^N W_x(n, t) * \psi_n(t) \quad (21)$$

$$\hat{x}(t) = F^{-1} \left( W_x(0, \omega) * \hat{\phi}_1(\omega) + \sum_{n=1}^N W_x(n, \omega) * \hat{\psi}_n(\omega) \right) \quad (22)$$

### ۵- انتخاب ویژگی

انتخاب ویژگی، فرآیند انتخاب یک زیرمجموعه از ویژگیهای مهم و مرتبط به منظور حذف اطلاعات اضافی است که منجر به بهبود دقت در مسائل طبقه‌بندی میگردد. برخی از ویژگیهای استخراجی ممکن است حساسیت کمتری نسبت به آسیب از خود نشان دهند بطوریکه انتخاب این ویژگیها به عنوان ورودی روشهای دسته‌بندی، سبب کاهش دقت عملکرد الگوریتم شناسایی آسیب می‌گردد. روشهای انتخاب ویژگی به چهار مرحله تقسیم می‌شوند: (۱) تابع تولیدکننده، (۲) تابع ارزیابی، (۳) شرط خاتمه و (۴) تابع تعیین اعتبار [۳۳]. با در نظر گرفتن ارتباط بین انتخاب ویژگیها و الگوریتمهای طبقه‌بندی، این روشها عموماً به سه دسته تقسیم می‌شوند که شامل رویکرد فیلتر، رویکرد بسته‌بندی و رویکرد توکار است. روشهای فیلتر مبتنی بر خواص داده‌های ذاتی است و ویژگیهای مربوطه را با استفاده از امتیاز رتبه‌بندی میکند. رویکرد بسته‌بندی با استفاده از یک مدل پیشبینی و نرخ خطای طبقه‌بندی، ویژگیها را انتخاب می‌کند. روشهای توکار ویژگیهای مهم را طی فرآیند ساخت مدل ایجاد می‌کند و از مزایای هر دو مدل فیلتر و بسته‌بندی برای افزایش دقت در مدل‌های طبقه‌بندی استفاده می‌کند [۳۴]. در این مقاله، از الگوریتم ژنتیک و انتخاب رو به جلو به عنوان روشهای بسته‌بندی و از الگوریتم جنگل تصادفی به عنوان روشی با رویکرد توکار جهت انتخاب ویژگیهای مؤثر استفاده شد.

### ۵-۱- روش انتخاب روبه‌جلو

$$\hat{\psi}_n(\omega) = \begin{cases} 1 & \text{if } \omega_n + \tau_n \leq |\omega| \leq \omega_{n+1} - \tau_{n+1} \\ \cos \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\tau_{n+1}} \left( |\omega| - \left( \omega_{n+1} - \tau_{n+1} \right) \right) \right) \right] & \\ \sin \left[ \frac{\pi}{2} \beta \left( \frac{1}{2\tau_n} \left( |\omega| - \left( \omega_n + \tau_n \right) \right) \right) \right] & \\ 0 & \text{if } \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n \\ & \text{otherwise} \end{cases} \quad (14)$$

که  $\beta(x)$  یک تابع دلخواه است و در بازه  $[0, 1]$  تعریف شده است و رابطه (۱۵) را برآورده میکند:

$$\beta(x) = \begin{cases} 0 & \text{if } x \leq 0 \\ \beta(x) + \beta(1-x) = 1 & \forall x \in [0, 1] \\ 0 & \text{if } x \geq 1 \end{cases} \quad (15)$$

تابع  $\beta(x)$  از رابطه (۱۶) تعیین میشود.

$$\beta(x) = x^4 (35 - 84x + 70x^2 - 20x^3) \quad \forall x \in [0, 1] \quad (16)$$

با در نظر گرفتن اطلاعات بخش طیف فوریه به معادلات (۱۳) و (۱۴)، بانک فیلتری موجک تجربی ساخته می‌شود. پس از حاصل شدن تابع مقیاس و موجکهای تجربی، ضرایب جزییات به شرح رابطه (۱۷) بیان می‌گردد:

$$W_x(n, t) = \int x(\tau) \psi_n(\tau - t) d\tau = F^{-1} \left( \hat{X}(\omega) \overline{\hat{\psi}_n(\omega)} \right) \quad (17)$$

ضرایب تقریبی بر اساس رابطه (۱۸) تعیین میگردد:

$$W_x(0, t) = \int x(\tau) \phi_n(\tau - t) d\tau = F^{-1} \left( \hat{X}(\omega) \overline{\hat{\phi}_n(\omega)} \right) \quad (18)$$

سپس مودهای تجربی که از سیگنال تجزیه شده است طبق روابط (۱۹) و (۲۰) بیان می‌گردد:

(۲۳) و (۲۴) بیان می‌گردد [۳۷]:

$$J_c = \sum_{j=1}^C p_i J_i \quad (23)$$

$$J_i = \left(1/n_i\right) \sum_{k=1}^n \left(x_k^i - m_i\right)^T \left(x_k^i - m_i\right) \quad (24)$$

کلاس  $I=i, \dots, c, m_i$  بردار میانگین کلاس  $i$  و  $n_i$  تعداد نمونه‌های کلاس  $i$  است.

همچنین فاصله بین کلاسها طبق رابطه (۲۵) بیان می‌گردد.

$$J_b = \sum_{j=1}^C p_i (m_i - m)^T (m_i - m) \quad (25)$$

GA با دو هدف پردازش میشود. هدف اول تعیین حداقل در فاصله درونکلاسی است و هدف دوم تعیین حداکثر در فاصله متوسط میانکلاسی است. برای این منظور، تابع ارزیاب طبق رابطه (۲۶) تعریف می‌شود:

$$J = J_i + (1/J_b) \quad (26)$$

با توجه به روابط بالا، کروموزومی که تابع ارزیاب را به حداقل میرساند انتخاب می‌گردد و در نتیجه، ویژگیهای بهینه میتوانند انتخاب شوند. پس از انتخاب ویژگیها، از الگوریتم ماشین بردار پشتیبان برای طبقه بندی وضعیت سازه به لحاظ وجود خرابی استفاده می‌گردد.

### ۳-۵- جنگل تصادفی

جنگل تصادفی، یک الگوریتم یادگیری بسیار دقیق مبتنی بر ایده تجمعی مدل برای طبقه بندی با ابعاد بزرگ و ناسازگار و وظایف رگرسیونی است [۳۸]. ایده کلیدی در چارچوب جنگلهای تصادفی، رشد تعداد زیادی از درختهای تصمیم بیطرفانه از نمونه های تصادفی داده های آموزشی با جایگزینی است، که در آن هر یک از درختها برای یک کلاس رأی میدهد. یکی از مزایای کلیدی جنگلهای تصادفی این است که میتوانند نمره اهمیت هر یک از ویژگیها را در پیشبینی کلاسها اندازهگیری نماید. در این راستا روش انتخاب خودکار ویژگی با توجه به نمرات اهمیت می تواند منجر به انتخاب ویژگیهای مرتبط و متمایز کننده گردد. به عبارت دیگر، به منظور

این روش از تابع ارزیابی مبتنی بر نرخ خطای طبقه بندی کننده جهت انتخاب استفاده می کند (بدون توجه به نوع تابع تولیدکننده استفاده شده) و روشی با رویکرد بسته بند میباشد. این روش، با یک مجموعه خالی شروع میکند، سپس در هر تکرار یک ویژگی با استفاده از تابع ارزیابی مورد استفاده، به مجموعه جواب اضافه می کند، این کار را تکرار می کند تا زمانی که تعداد ویژگی لازم انتخاب شود و منجر به جوابی با حداقل خطا گردد. مشکل این روش این است که ویژگی اضافه شده در صورتیکه مناسب نباشد، از مجموعه جواب حذف نمی شود [۳۵].

### ۲-۵- الگوریتم ژنتیک

الگوریتم ژنتیک (GA)، که توسط هالند معرفی شد، یک ابزار مؤثر و عمومی برای بهینه سازی محاسباتی مبتنی بر مفهوم تکامل بیولوژیکی است [۳۶]. این روش در اغلب شاخه های مهندسی مورد استفاده قرار میگیرد و در بیشتر موارد راه حلهای نزدیک به بهینه را نتیجه میدهد. این الگوریتم در فضاهای جستجوی باینری عمل میکند و یک جمعیت را از راه حلهای بالقوه مدیریت میکند. در این روند، راهحل مورد نیاز مسأله به گونه ای تعریف می گردد که قابل نمایش به وسیله یک کروموزوم باشد. کیفیت راهحلهای احتمالی توسط یک تابع ارزیاب مورد ارزیابی قرار میگیرد. در GA، جمعیت اولیه بطور تصادفی توسط سه عملگر ایجاد میشود: انتخاب، تقاطع یا ترکیب مجدد و جهش. در این مقاله از الگوریتم ژنتیک برای حذف ویژگیهای غیر مرتبط استفاده میشود. در مسئله انتخاب ویژگی، تمرکز اصلی در نشان دادن فضای همه زیرمجموعه های ممکن از مجموعه ویژگیهای داده شده است. برای دستیابی به این هدف، کروموزومها به عنوان یک ماسک برای ویژگیها تعریف میگردند. به عبارتی، هر کروموزوم زیرمجموعه ای از ویژگیها است. اندازه کروموزوم (تعداد ژنها) برابر با تعداد ویژگیهایی است که مشخصات سازه آسپیدیده را نشان میدهد. یک کروموزوم در شکل رشته باینری (صفر یا یک) نمایش داده میشود و "یک" به این معنی است که ویژگی متناظر انتخاب شده است و "صفر" نشان دهنده ویژگی رها شده (ویژگی غیرمرتبط) می باشد. اهداف GA به یک فاصله کوچکتر درون کلاس و فاصله بین کلاسهای بزرگتر مربوط می شود. فاصله درون کلاس به شرح روابط

که  $y_i$  خروجی هر کلاس مربوط به داده آموزشی  $i$  ام است. هدف پیدا کردن صفحه‌های استکه نقاط هر یک از کلاسها را از هم جدا کند و بیشترین حاشیه را بین دو کلاس ایجاد کند. در این حالت تابع تصمیمگیری  $f(x)$  به فرم رابطه (۲۹) بیان میگردد. [۳۷]:

$$f(x) = w \cdot x + b = \sum_{k=1}^m w_k \cdot x_k + b = 0 \quad (29)$$

برای محاسبه بردار وزن  $w$  و  $b$  که مقادیر اسکالر هستند، باید مسأله بهینه‌سازی در حالت غیرخطی با استفاده از توابع هسته که در روابط (۳۰) و (۳۱) نشان داده شده است حل گردد.

$$\min \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j K(X_i, X_j) - \sum_{i=1}^n \alpha_i \quad (30)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C \quad (31)$$

$C$  ضریب جریمه در خطای آموزش  $X_i$  متناظر با  $\alpha_i$  که بزرگتر از صفر و کوچکتر از  $C$  است.  $K(X_i, X_j)$  تابع هسته (کرل) میباشد. جدول ۳ توابع کرل معروف که معمولاً در آموزش ماشین بردار پشتیبان از آنها استفاده میشود را نشان میدهد.

#### ۷- الگوریتم پیشنهادی شناسایی آسیب

این مقاله که در راستای ادامه تحقیقات انجام شده توسط قدرتی امیری و همکاران [۲۴] است مبتنی بر اطلاعات کلیه باندهای فرکانسی نمیشد و با هدف یافتن ویژگیهای باند فرکانسی مؤثر با استفاده از تبدیل موجک تجربی برای شناسایی خسارت در پل کابلی است. به طور خاص در این مقاله، روشی برای بهبود عملکرد شناسایی آسیب با استفاده از ویژگیهای مود تجربی مؤثر و ترکیب آنها ارائه شد. به منظور صحت سنجی، روش پیشنهادی بر روی داده های عددی و داده واقعی آزمایش شد. این روش شامل مراحل زیر است که در شکل ۵ نشان داده شده است:

۱- داده ها شامل سریهای زمانی پاسخ سازه (شتاب ثبت شده توسط سنسورهای نصب شده برعرشه پل) در دو وضعیت سالم و آسیبدیده پل است. به منظور استخراج ویژگی، سیگنالهای ارتعاشی با استفاده از تبدیل موجک تجربی، به مودهای تجربی

یافتن فهرست مرتب شده از ویژگیها با توجه به اهمیت آنها، با استفاده از مدل جنگل تصادفی میتوان اهمیت هر متغیر را در مدل نهایی ثبت نمود. الگوریتم انتخاب ویژگی با استفاده از نمرات اهمیت حاصل از یک جنگل تصادفی معمولی، حداقل تعداد ویژگیها با قابلیت بالا در جداسازی را انتخاب میکند. یکی از مهمترین ویژگیهای این روش، استفاده از برآورد خطای خارج از کیسه (OOB) است. OOB مجموعه نمونههای است که در آموزش درخت کنونی استفاده نمیگردد و برای تخمین خطا استفاده میشود. این برآورد داخلی خطای تعمیم، سبب افزایش دقت طبقه‌بندی درختی میگردد. روش اندازه‌گیری اهمیت جایگزین، یکی از ابزارهای مورد استفاده برای اندازه‌گیری اهمیت ویژگیها میباشد. اهمیت ویژگی  $(FI)$  با افزایش میانگین خطا محاسبه میشود. زمانی که ارزش ویژگی  $X_i^j$  بطور تصادفی به واسطه یکی از مقادیر آن از مجموعه  $OOB \text{ set } X_{i\_oob}^j$  تغییر کند، مقدار  $FI$  به شرح رابطه (۲۷) بیان میگردد [۳۹]

$$FI(X^j) = \frac{1}{nb\_trees} \sum_t \left( \left| err(X_i^j) - err(X_{i\_oob}^j) \right| \right) \quad (27)$$

#### ۶- ماشین بردار پشتیبان

ماشینهای بردار پشتیبان (SVM)، که توسط وپنیک ارائه شد، به طور فزایندهای برای مسائل طبقه بندی به دلیل عملکرد رضایت‌بخش و قابل تعمیم برای نمونه های با اندازه کم و ابعاد بالا مورد استفاده قرار میگیرند. SVM برای تفکیک دو کلاس از هم، با یک فرآیند بهینه سازی، مرزها را با حداکثر اختلاف از دادههای آموزشی جستجو می کند و با استفاده از آنها سطح جداکننده مرز تصمیم گیری (برصفحه) بهینه را تعیین میکند. به عبارت دیگر، با حداکثر نمودن حاشیه که بیشترین فاصله را از هر طرف با هر یک از کلاسها دارد، خطای عمومی را کاهش می دهد [۴۰]. در مسائلیکه دادهها بصورت خطی جداپذیر نباشند، دادههای آموزشی با استفاده از یک تابع تبدیل به فضای با ابعاد بالاتر نگاشت میشوند. با فرض داشتن  $n$  داده آموزشی در یک فضای با ابعاد  $N$  و دو کلاس برای هر یک از دادهها میتوان رابطه (۲۸) را نوشت.

$$S = \left\{ (x_i, y_i) \mid x_i \in R^N, y_i \in \{-1, 1\}, i = 1, 2, \dots, l \right\} \quad (28)$$

تجزیه شدند. کلیه محاسبات بصورت کدنویسی شده در نرم افزار متلب (MATLAB ۲۰۱۴) انجام شد.

۲- ویژگیهای ارائه شده در جدول ۲ از طیف فرکانس مودهای تجربی استخراج شدند. این ویژگیها به مشخصات آماری و شکل طیف فرکانسی سیگنالهای پاسخ مربوط میشود. به منظور ارزیابی توانایی هریک از ویژگیهای مستخرج از مودهای تجربی در شناسایی آسیب از الگوریتم ماشین بردار پشتیبان به عنوان طبقه‌بند استفاده گردید. در روند طبقه‌بندی، ۷۰٪ از دادهها به طور تصادفی به عنوان مجموعه آموزشی و ۳۰٪ مابقی به عنوان دادههای آزمایشی در نظر گرفته شد. برای قابل تعمیم و مستقل نمودن نتایج تحلیل نسبت به داده های آموزشی، روش اعتبارسنجی متقابل (اعتبارسنجی تصادفی زیرنمونه تکراری یا مونت کارلو) بکار گرفته شد. ماشین بردار پشتیبان به عنوان یک طبقه بند متمایز کننده بین دو کلاس توسط یک ابرصفحه جدا کننده تعریف می شود. با دریافت دادههای آموزشی برچسب خورده (ماتریس ویژگیهای استخراج شده از مودهای تجربی مربوط به وضعیت سالم و آسیب دیده)، الگوریتم با ایجاد مدل یک ابرصفحه جدا کننده بهینه را خروجی میدهد که بر اساس آن نمونه های جدید (نمونه های آزمایش) را طبقه بندی میکند. میزان دقت در تشخیص کلاس نمونه های جدید توسط مدل، توانایی ویژگیها را در فرآیند شناسایی مشخص می نماید.

۳- به منظور بهبود عملکرد شناسایی، ویژگیهای مؤثر و مرتبط با آسیب با استفاده از روشهای انتخاب ویژگی ترکیب شدند و مجموعههای از ویژگیهای مؤثر برای هر یک از مودهای تجربی حاصل شد. به منظور بررسی دقت عملکرد شناسایی با توجه به نوع روش انتخاب ویژگی، مطالعه مقایسه‌ای انجام شد. این روشها، شامل انتخاب روبه جلو، الگوریتم ژنتیک و روش جنگل تصادفی است. با توجه به اینکه بردارهای ویژگی دارای دامنه متفاوتی می باشند، عملیات نرمالسازی بردارهای ویژگی قبل از انجام روند انتخاب ویژگی با استفاده از رابطه (۳۲) به منظور اجتناب از کاهش سرعت آموزش در مدل انجام شد [۴۲].

$$v_{nj} = \frac{v_j - \mu_j}{\sigma_j} \quad (32)$$

و  $v_{nj}$  و  $v_j$  مقادیر بعد و قبل از عملیات نرمالسازی است و  $\mu_j$

$\sigma_j$  میانگین و انحراف معیار بردار ویژگی است.  
۴- در نهایت از SVM به عنوان ابزار تصمیمگیری در طبقه بندی برای ارزیابی مودهای تجربی و یافتن مود مؤثر به عنوان شاخص خرابی در شناسایی آسیب پل کابلی استفاده گردید. مبنای تصمیم گیری برای تشخیص خرابی میزان دقت طبقه‌بند است که نشان دهنده میزان تمایز داده های پاسخ در وضعیت سالم پل نسبت به وضعیت آسیب دیده پل میباشد. مود تجربی که ماتریس ویژگی طیف فرکانسی آن طی فرآیند استخراج و انتخاب ویژگی دارای بیشترین دقت در نشان دادن تمایز بین حالت سالم و آسیب دیده (دو کلاس) باشد، به عنوان مود تجربی مؤثر انتخاب می شود.

#### ۸- نتایج و بحث

در این بخش ابتدا روش پیشنهادی شناسایی آسیب با استفاده از داده های شبیه سازی مدل عددی پل آزمایشگاهی مورد اعتبارسنجی قرار گرفت. داده های پاسخ سازه شامل ۵۰ نمونه سیگنال شتاب در حالت سالم و ۵۰ نمونه سیگنال شتاب در وضعیت آسیب دیده است. پس از تحلیل EWT بر روی داده ها و استخراج ویژگیها از مودهای تجربی، نتایج حاکی از دقت بالای ویژگیها در شناسایی آسیب می باشد. با استفاده از الگوریتم پیشنهادی، زیرمجموعه بهینه شامل یک ویژگی تنها به عنوان شاخص خرابی میباشد که با توجه به نوع روش انتخاب ویژگی تعیین میگردد و در تمامی حالات نتایج رضایتبخش حاصل میگردد. در صورت استفاده از روشهای الگوریتم ژنتیک و جنگل تصادفی، به ترتیب ویژگیهای  $F^2$  و  $F^4$  که استخراج شده از دومین مود تجربی است انتخاب می گردد. با بکارگیری روش انتخاب رو به جلو، ویژگی  $F^6$  (مستخرج از سومین مود تجربی) به عنوان شاخص خرابی تعیین می شود که در تمامی حالات دقت ۱۰۰ درصد در فرآیند شناسایی آسیب حاصل می گردد (شکل ۶ و ۷). نتایج حاصل از تحلیل مدل عددی نشان می دهد که ویژگیهای انتخابی به عنوان شاخص خرابی با توجه به نوع روش انتخاب ویژگی متفاوت است و ویژگیهای استخراج شده از تحلیل EWT بطور مؤثر خرابی را در پل آزمایشگاهی نشان می دهد (جدول ۴).




جدول ۳. توابع کرنل آموزش ماشین بردار پشتیبان [۴۱]

Table 3. Kernel functions of SVM

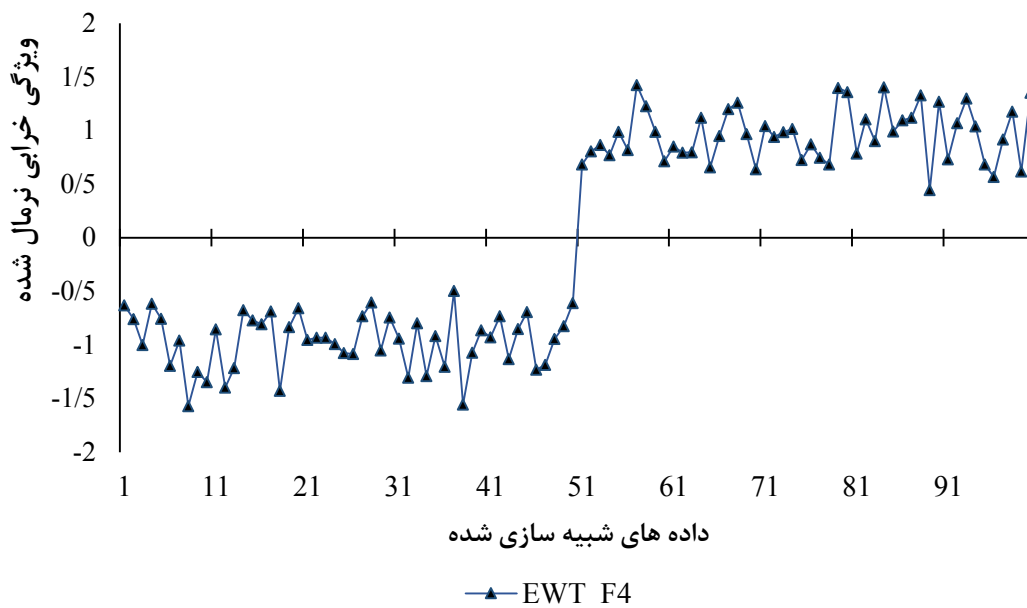
kernel	$K(x, x')$
linear	$x \cdot x'$
polynomial	$(x \cdot x')^d$ or $(c + x \cdot x')^d$
Gaussian radial	$\exp(-x - x'^2 / 2\sigma^2)$
Sigmoid	$\tanh(\alpha_0(x, x') + \beta_0)$

$c, \sigma, d, \alpha_0, \beta_0$  are kernel parameters.




شکل ۵. نمودار روش پیشنهادی شناسایی آسیب

Fig. 5. The proposed framework of damage detection



شکل ۶. ویژگی خرابی نرمال شده مستخرج از مود دوم تجربی

Fig. 6. Normalized damage feature extracted from 2nd empirical mode




شکل ۷. ویژگی خرابی نرمال شده مستخرج از مود سوم تجربی

Fig. 7. Normalized damage feature extracted from 3rd empirical mode

جدول ۴. ویژگی انتخاب شده حاصل از تحلیل EWT و روش انتخاب ویژگی


Table 4. Selected feature from EWT and feature selection methods

روش انتخاب ویژگی	ویژگی انتخاب شده	دقت تشخیص (%)
انتخاب رو به جلو	F6	۱۰۰
الگوریتم ژنتیک	F4	۱۰۰
جنگل تصادفی	F2	۱۰۰



شکل ۸. عملکرد ویژگی‌های استخراج شده از سیگنال پاسخ سازه (شتاب) در شناسایی آسیب

Fig. 8. Performance of features extracted from structural response signal (acceleration) in damage detection



شکل ۹. عملکرد ویژگی‌های استخراج شده از مودهای تجربی (ویژگی‌های مرتبط با مشخصات آماری طیف) در شناسایی آسیب

Fig. 9. Performance of features extracted from empirical modes (features related to statistical properties) in damage identification

میدهد آخرین مود تجربی (مود ۸) فاقد اطلاعات خرابی است و ویژگیهای مستخرج از آن دارای دقت حدود ۵۰٪ می باشد.

از میان ویژگیهای مرتبط با شکل طیف فرکانس، حداکثر دقت مربوط به ویژگی  $F10$  و  $F6$  بوده که به ترتیب از طیف فرکانس سومین و دومین مود تجربی استخراج شده است و دارای دقت حدود ۸۸٪ است. نتایج نشان داد که مودهای دوم و سوم تجربی در تحلیل موجد تجربی حاوی اطلاعات خرابی است. با استخراج ویژگی از طیف فرکانس مود تجربی، عملکرد فرآیند شناسایی آسیب نسبت به حالت متداول (استخراج ویژگی بطور مستقیم از طیف فرکانس سیگنال شتاب) حدود ۵٪ بهبود می یابد. به عبارت دیگر، با بکارگیری روش استخراج ویژگی در تحلیل تبدیل موجد تجربی، خطای تشخیص آسیب حدود ۵٪ کاهش می یابد.

نتایج تحلیل نشان داد برخی از ویژگیها قادرند اطلاعات مربوط به خرابی را در مقایسه با سایر ویژگیها با دقت بیشتری از خود نشان دهند که انتخاب و ترکیب برخی از آنها میتواند اطلاعات خرابی را با دقت بالاتری نشان دهد و در نتیجه منجر به افزایش دقت شناسایی آسیب گردد. از اینرو در بخش دوم، با شناسایی و انتخاب ویژگیهای مؤثر و ترکیب آنها، خطای تشخیص مورد ارزیابی قرار گرفت. انتخاب تعداد ویژگیها و نوع ویژگیهای حاوی اطلاعات مهم و مرتبط با خرابی سازه‌های با استفاده از روشهای انتخاب ویژگی تعیین میگردد. هدف اصلی از انتخاب ویژگی، به حداکثر رساندن دقت طبقه بندی (کم کردن میزان خطای حاصل از طبقه بندی) و کم کردن تعداد ویژگیها است. در چنین شرایطی ویژگیهای نامناسب و اضافی که قدرت تمایز کمتری بین دادههای مربوط به وضعیت سالم و آسیب دیده سازه دارند حذف میشوند و تعدادی از ویژگیهایی که شامل اطلاعات مناسبی هستند و می توانند بین کلاسهای الگو تمایز ایجاد کنند باقی می مانند. به منظور مطالعه مقایسه ای، از سه روش انتخاب ویژگی با رویکردهای مختلف شامل الگوریتم ژنتیک، جنگل تصادفی و انتخاب رو به جلو استفاده شد. روش انتخاب رو به جلو از یک مجموعه تهی عملیات جستجو را آغاز می کند و ویژگیهایی را به مجموعه اضافه میکند تا دقت طبقه‌بندی را افزایش دهد که نتایج آن برای مودهای مختلف تجربی در جدول ۵ نشان داده شده است.

این روش با انتخاب یک زیرمجموعه بهینه شامل ویژگیهای ( $F10, F2, F7, F6, F8, F3, F1$ ) که از طیف فرکانس دومین

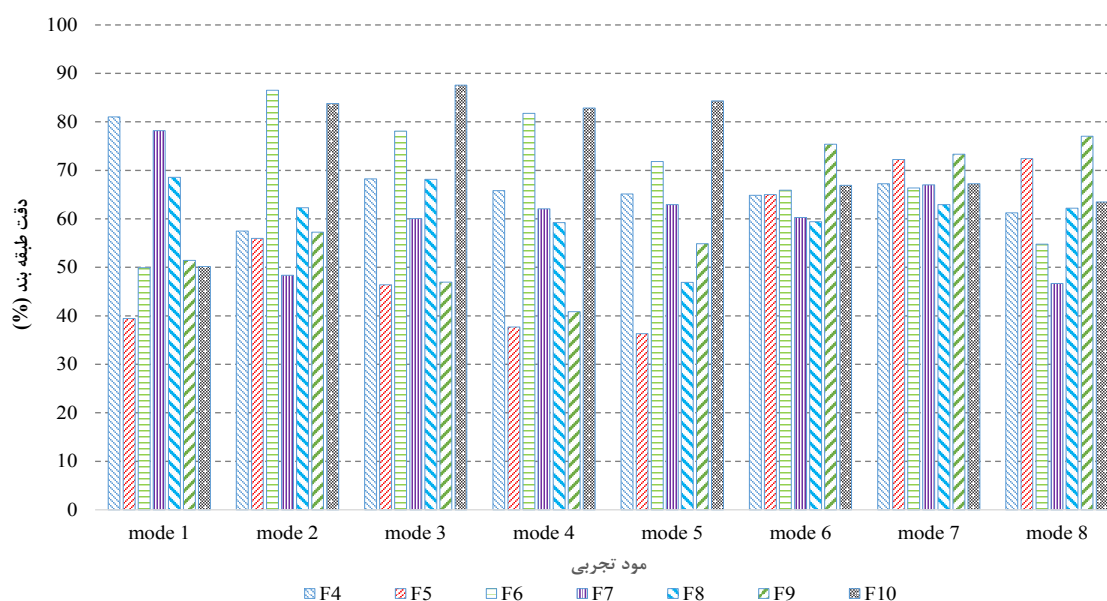
همچنین در تمامی روشهای انتخاب ویژگی، زیرمجموعه بهینه شامل یک ویژگی تنها می باشد که از دومین یا سومین مود تجربی استخراج می گردد و بیانگر کارایی روش پیشنهادی (استخراج ویژگی از مودهای ارتعاشی حاصل از تحلیل EWT) است. به منظور مقایسه روش پیشنهادی (استخراج ویژگی از مودهای تجربی) با روش متداول استخراج ویژگی [۲۴]، ویژگیها بطور مستقیم از طیف فرکانس داده های تاریخچه زمانی استخراج گردید. در این حالت زیرمجموعه بهینه حاصل از روش انتخاب رو به جلو شامل ویژگیهای  $F2$  و  $F5$  میباشد که با بکارگیری طبقه‌بند SVM دارای دقت حدود ۹۹٪ است. در مرحله بعد، الگوریتم پیشنهادی با استفاده از داده های واقعی پل یونگ مورد ارزیابی قرار گرفت.

روش پیشنهادی شناسایی آسیب با استفاده از مجموعه داده های زمانی سیگنال شتاب ثبت شده از عرشه پل یونگ، اعتبارسنجی شد. دادههای شتاب شامل ۲۴ سری زمانی ۱ ساعته مربوط به وضعیت سالم سازه و ۲۴ سری زمانی ۱ ساعته مربوط به وضعیت آسیب دیده سازه میباشد که به ترتیب در ۱۷ ژانویه ۲۰۰۸ و ۳۱ جولای ۲۰۰۸ ثبت شد. داده های زمانی با استفاده از تبدیل موجد تجربی به مودهای تجربی تجزیه شد و ویژگیهای ارائه شده در جدول ۲ از مودها استخراج گردید. به منظور ارزیابی عملکرد هریک از ویژگیهای استخراج شده از مودهای تجربی در شناسایی آسیب، از طبقه بند ماشین بردار پشتیبان استفاده شد. به منظور مقایسه روش پیشنهادی (استخراج ویژگی از مودهای تجربی) با روش متداول استخراج ویژگی، ابتدا ویژگیها بطور مستقیم از طیف فرکانس داده های تاریخچه زمانی استخراج گردید که نتایج در شکل ۸ نشان داده شده است. در این حالت حداکثر دقت ویژگی به عنوان شاخص حساس به خرابی مربوط به ویژگی  $F4$  می باشد که دارای دقت ۸۳٪ است. همچنین ویژگیهای  $F1, F2, F3$  با دقت حدود ۸۰٪ آسیب را در سازه نشان می دهد.

پس از تبدیل موجد تجربی، ویژگیهای ارائه شده در جدول ۲ از طیف فرکانس مودهای تجربی استخراج شد که مقادیر مربوط به دقت طبقه بند در اشکال ۹ و ۱۰ نشان داده شده است. از میان ویژگیهای مرتبط با مشخصات آماری طیف فرکانس، حداکثر دقت در شناسایی آسیب مربوط به ویژگی  $F1$  بوده که از طیف فرکانسی دومین مود تجربی استخراج شده و دارای دقت ۸۸٪ می باشد. شکل ۹ نشان

شده است، زیرمجموعه بهینه را به عنوان شاخص خرابی تعیین میکند. نتایج برای سایر مودها در جدول ۶ نشان داده شده است. در این حالت دقت عملکرد فرآیند تشخیص آسیب به ۹۴٪ بهبود یافت. به عبارتی خطای تشخیص حدود ۱۱٪ نسبت به روش متداول استخراج ویژگی کاهش یافت. نتایج نشان میدهد که همه مودهای تجربی (باند‌های فرکانسی) در شناسایی آسیب مؤثر نیستند و برخی از آنها بخصوص آخرین مود تجربی فاقد اطلاعات خرابی هستند. لذا با انتخاب یک مود تجربی و استفاده از ویژگیهای طیف فرکانسی آن

مود تجربی استخراج شده است، دقت طبقه بند را به ۹۳٪ افزایش داد. همچنین با بکارگیری روش استخراج و انتخاب ویژگی از طیف فرکانسی سومین مود تجربی و استفاده از یک زیرمجموعه بهینه شامل ویژگیهای ( $F8, F10$ ) خطای تشخیص بطور رضایتبخشی حدود ۱۰٪ نسبت به حالت متداول کاهش یافت. همچنین ترکیبی از ویژگیهای آخرین مود تجربی از کمترین دقت شناسایی (حدود ۸۲٪) برخوردار است. الگوریتم ژنتیک با انتخاب ویژگیهای ( $F2, F4, F6, F10$ ) که از طیف فرکانسی دومین مود تجربی استخراج



شکل ۱۰. عملکرد ویژگی‌های استخراج شده از مودهای تجربی (ویژگی‌های مرتبط با مشخصات شکل طیف) در شناسایی آسیب

Fig. 10. Performance of features extracted from empirical modes (features related to spectral shape properties) in damage identification

جدول ۵. دقت مجموعه بهینه ویژگی‌ها (ترکیب ویژگی‌ها) با استفاده از روش انتخاب رو به جلو در شناسایی آسیب

Table 5. Classification accuracy of selected feature subset obtained using the forward feature selection method for detecting damage

مود تجربی	مجموعه ویژگی بهینه	دقت (%)
mode 1	$F4, F2, F6$	۸۴
mode 2	$F1, F3, F8, F6, F7, F2, F10$	۹۳
mode 3	$F10, F8$	۹۳
mode 4	$F2$	۸۷
mode 5	$F10, F3, F1$	۸۶
mode 6	$F9, F1, F7, F6, F10, F8$	۹۲
mode 7	$F9, F10, F2, F6, F3, F1$	۸۶
mode 8	$F9, F4$	۸۲

جدول ۶. دقت مجموعه بهینه ویژگی‌ها (ترکیب ویژگی‌ها) با استفاده از روش الگوریتم ژنتیک در شناسایی آسیب

Table 6. Classification accuracy of selected feature subset obtained using Genetic algorithm method for detecting

مود تجربی	مجموعه ویژگی بهینه	دقت (%)
mode 1	<i>F3, F4, F5, F6, F7</i>	۸۵
mode 2	<i>F2, F4, F6, F10</i>	۹۴
mode 3	<i>F1, F3, F8, F10</i>	۸۶
mode 4	<i>F6, F8, F10</i>	۸۰
mode 5	<i>F2, F3, F4, F8, F9</i>	۸۴
mode 6	<i>F3, F5, F6, F7, F8, F10</i>	۸۸
mode 7	<i>F1, F3, F6, F7, F8, F9</i>	۸۷
mode 8	<i>F1, F3, F5, F7, F8, F9</i>	۷۸

جدول ۷. رتبه بندی ویژگی‌های استخراج شده از مودهای تجربی با استفاده از روش جنگل تصادفی


Table 7. Feature ranks extracted from empirical modes using random forest method

Feature No.	ویژگی	رتبه بندی							
		Mode 1	Mode 2	Mode 3	Mode 4	Mode 5	Mode 6	Mode 7	Mode 8
۱	<i>F1</i>	۴	۲	۱۰	۲	۱۰	۹	۹	۹
۲	<i>F2</i>	۳	۳	۶	۱	۱	۱۰	۵	۵
۳	<i>F3</i>	۶	۱	۲	۳	۲	۳	۳	۶
۴	<i>F4</i>	۷	۶	۳	۱۰	۷	۴	۱۰	۱۰
۵	<i>F5</i>	۲	۸	۱	۶	۴	۷	۴	۸
۶	<i>F6</i>	۸	۱۰	۸	۴	۳	۶	۷	۳
۷	<i>F7</i>	۹	۷	۴	۷	۶	۵	۲	۷
۸	<i>F8</i>	۱	۹	۷	۸	۹	۲	۶	۲
۹	<i>F9</i>	۱۰	۵	۵	۹	۵	۸	۱	۴
۱۰	<i>F10</i>	۵	۴	۹	۵	۸	۱	۸	۱

ترتیب اولویت که در جدول ۷ لیست شده است به مجموعه ویژگی‌ها اضافه میکند. زیرمجموعه ای از ویژگی‌ها به عنوان شاخص خرابی انتخاب می شود که دارای بیشترین دقت در فرآیند طبقه بندی باشد. روند تغییرات دقت طبقه‌بندی با اضافه نمودن ویژگی‌های مهم به ترتیب اولویت برای هر یک از مودهای تجربی در شکل ۱۱ نشان داده شده است. بالاترین دقت حدود ۹۳٪ مربوط به ویژگی‌های استخراج شده از دومین مود تجربی است و شاخص خرابی شامل ترکیبی از ویژگی‌ها (*F8, F6, F1, F3, F2*) میباشد. نتایج فوق نشان داد که

می‌توان دقت شناسایی را افزایش داد.

روش جنگل تصادفی ابتدا ویژگی‌ها را به ترتیب اهمیت آنها در شناسایی آسیب رتبه‌بندی میکند که در جدول ۷ برای هر یک از مودهای مختلف نشان داده شده است. به عنوان مثال پنج ویژگی مهم استخراج شده از طیف فرکانسی دومین مود تجربی شامل (*F3, F2, F1, F6, F8*) است. این ویژگی‌ها برای سومین مود تجربی شامل (*F1, F3, F2, F6, F10*) میباشد. این روش با یک زیرمجموعه شامل مهمترین ویژگی عملیات تکمیل را آغاز میکند و ویژگی‌ها را به



شکل ۱۱. دقت طبقه بند SVM با اضافه نمودن ویژگی های مؤثر استخراج شده از مودهای تجربی با استفاده از روش جنگل تصادفی

Fig. 11. Classification accuracy for SVM by adding effective features extracted from empirical modes using random forest method identification

در این مقاله، یک روش جدید برای تشخیص آسیب پلهای کابلی مبتنی بر استخراج ویژگی از طیف باند فرکانسی مؤثر سیگنال پاسخ سازه با استفاده از روشهای تبدیل موجک تجربی و انتخاب ویژگی ارائه شد. نخستین موضوعی که ارزیابی شد، قابلیت ویژگیهای استخراج شده از طیف فرکانس مود تجربی مؤثر در شناسایی آسیب و مقایسه آن با روشهای متداول استخراج ویژگی است. نتایج تحلیل بر روی داده های عددی بیانگر کارایی ویژگیهای مستخرج از باند فرکانسی مؤثر در شناسایی آسیب است که خرابی را با دقت ۱۰۰٪ در مدل عددی پل آزمایشگاهی نشان میدهد. نتایج تحلیل بر روی دادههای پاسخ پل کابلی یونگ نشان داد که دومین و سومین مود تجربی حاصل از تحلیل موجک تجربی حاوی اطلاعات مرتبط با خرابی بوده و بکارگیری طیف فرکانسی متناظر آن در فرآیند استخراج ویژگی، عملکرد شناسایی را نسبت به روشهای متداول حدود ۵٪ بهبود میدهد. استفاده از ویژگیهای مربوط به مشخصات آماری ( $F1$ ) و شکل طیف فرکانسی ( $F10, F6$ ) نسبت به سایر ویژگیهای ارائه شده

دومین مود تجربی در تحلیل تبدیل موجک تجربی حاوی اطلاعات خرابی است و در ترکیب با روشهای استخراج و انتخاب ویژگی ارائه شده می تواند به عنوان شاخص خرابی تعیین گردد و بطور مؤثر و با دقت رضایتبخشی خرابی را در سازه پل کابلی یونگ نشان دهد. برخلاف نتایج حاصل از صحتسنجی با داده های شبیه سازی شده که با یک ویژگی تنها به شاخص خرابی میرسد، در سازه پل کابلی مجموعه های از ویژگیها به عنوان شاخص خرابی تعیین میگردد. با توجه به نتایج حاصل از روشهای انتخاب ویژگی، ویژگیهای ضریب تناسب طیفی ( $F5$ ) و کشیدگی طیفی ( $F9$ ) در زیرمجموعه بهینه مشارکت ندارند و به عنوان ویژگی غیرمرتبط محسوب می شوند. برای تعمیم کاربرد این روش برای سایر پل ها و به منظور در نظر گرفتن اثرات شرایط محیطی، مطالعات موردی با وجود داده های ارتعاشی طولانی مدت مورد نیاز است.

## ۹- نتیجه گیری

- and signal processing techniques for structural health monitoring: a review, *Archives of Computational Methods in Engineering*, 23(4) (2016) 585-594.
- [8] J.P. Amezquita-Sanchez, H. Adeli, Signal processing techniques for vibration-based health monitoring of smart structures, *Archives of Computational Methods in Engineering*, 23(1) (2016) 1-15.
- [9] F. Kopsaftopoulos, S. Fassois, Vibration based health monitoring for a lightweight truss structure: experimental assessment of several statistical time series methods, *Mechanical Systems and Signal Processing*, 24(7) (2010) 1977-1997.
- [10] R.V. Farahani, D. Penumadu, Full-scale bridge damage identification using time series analysis of a dense array of geophones excited by drop weight, *Structural Control and Health Monitoring*, 23(7) (2016) 982-997.
- [11] X. Zhu, M. Cao, W. Ostachowicz, W. Xu, Damage Identification in Bridges by Processing Dynamic Responses to Moving Loads: Features and Evaluation, *Sensors*, 19(3) (2019) 463.
- [12] L. Qiao, A. Esmaily, H.G. Melhem, Signal pattern recognition for damage diagnosis in structures, *Computer-Aided Civil and Infrastructure Engineering*, 27(9) (2012) 699-710.
- [13] P. Wang, Q. Shi, Damage Identification in Structures Based on Energy Curvature Difference of Wavelet Packet Transform, *Shock and Vibration*, 2018 (2018).
- [14] Z.-D. Xu, Z. Wu, Energy damage detection strategy based on acceleration responses for long-span bridge structures, *Engineering Structures*, 29(4) (2007) 609-617.
- [15] Y. Xin, H. Hao, J. Li, Operational modal identification of structures based on improved empirical wavelet transform, *Structural Control and Health Monitoring*, 26(3) (2019) e2323.
- [16] J.P. Amezquita-Sanchez, H.S. Park, H. Adeli, A novel methodology for modal parameters identification of large smart structures using MUSIC, empirical wavelet transform, and Hilbert transform, *Engineering Structures*, 147 (2017) 148-159.
- [17] N. Liu, J. Xi, X. Zhang, Z. Liu, Damage detection of منجر به کاهش خطای تشخیص خرابی گردید و دقت شناسایی را به حدود ۸۸٪ افزایش داد. موضوع دوم که به آن پرداخته شد مسأله کاهش خطا در الگوریتم شناسایی آسیب است. یک زیرمجموعه بهینه شامل ویژگیهای مهم با استفاده از روشهای انتخاب ویژگی تعیین شد و از طیف فرکانس مود تجربی مؤثر استخراج گردید. نتایج نشان داد استفاده از ترکیب ویژگیهای مؤثر به جای یک ویژگی تنها در مرحله استخراج اطلاعات خرابی، دقت الگوریتم شناسایی را بطور قابل توجهی افزایش میدهد. با بکارگیری روشهای انتخاب رو به جلو، الگوریتم ژنتیک و جنگل تصادفی، دقت طبقه‌بند به ترتیب حدود ۹۳٪، ۹۴٪ و ۹۳٪ افزایش یافت. به عبارت دیگر با بکارگیری الگوریتم ژنتیک و استفاده از ترکیب ویژگیهای مهم مستخرج از طیف فرکانسی دومین مود تجربی شامل زیرمجموعه بهینه  $(F4, F2)$ ،  $(F10, F6)$  به عنوان شاخص خرابی، خطای تشخیص حدود ۱۱٪ کاهش مییابد.
- مراجع**
- [1] M. Radzieński, Ł. Doliński, M. Krawczuk, M. Palacz, Damage localisation in a stiffened plate structure using a propagating wave, *Mechanical Systems and Signal Processing*, 39(1-2) (2013) 388-395.
- [2] N.T.S. Board, U.S.N.T.S. Board, Collapse of I-35W Highway Bridge, Minneapolis, Minnesota, August 1, 2007, Createspace Independent Pub, 2008.
- [3] M. Kunishima, Collapse of the Korea seoul seongsu bridge JST Failure Knowledge Database/100 Selected Cases, (1994).
- [4] T.D. Stark, R. Benekohal, L.A. Fahnstock, J.M. LaFave, J. He, C. Wittenkeller, I-5 Skagit River bridge collapse review, *Journal of performance of constructed facilities*, 30(6) (2016) 04016061.
- [5] B. Dawson, Vibration condition monitoring techniques for rotating machinery, *The shock and vibration digest*, 8(12) (1976) 3.
- [6] M.J. Whelan, M.V. Gangone, K.D. Janoyan, R. Jha, Real-time wireless vibration monitoring for operational modal analysis of an integral abutment highway bridge, *Engineering Structures*, 31(10) (2009) 2224-2235.
- [7] D. Goyal, B. Pabla, The vibration monitoring methods



- [27] M.R. Kaloop, J.W. Hu, Stayed-cable bridge damage detection and localization based on accelerometer health monitoring measurements, *Shock and Vibration*, 2015 (2015).
- [28] ANCRiSST SHM benchmark problem, Harbin: Center of Structural Monitoring and Control of the Harbin Institute of Technology, <http://smc.hit.edu.cn>.
- [29] 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.
- [30] A. Lerch, *An introduction to audio content analysis: Applications in signal processing and music informatics*, Wiley-IEEE Press, 2012.
- [31] J. Gilles, Empirical wavelet transform, *IEEE transactions on signal processing*, 61(16) (2013) 3999-4010.
- [32] S. Nezamivand Chegini, F. Zarif, A. Bagheri, M. AliTavoli, Noise Removal from the Vibration Signals of the Rotating Machinery Using the Empirical Wavelet Transform and the Conventional Thresholding Methods, *Journal of Solid and Fluid Mechanics*, 9(1) (2019) 111-124 (in Persian).
- [33] J. Toivola, J. Hollmén, Feature extraction and selection from vibration measurements for structural health monitoring, in: *International Symposium on Intelligent Data Analysis*, Springer, 2009, pp. 213-224.
- [34] Guyon, A. Elisseeff, An introduction to variable and feature selection, *Journal of machine learning research*, 3(Mar) (2003) 1157-1182.
- [35] E. Alpaydin, *Introduction to machine learning*, MIT press, 2009.
- [36] H. Vafaie, K. De Jong, Genetic algorithms as a tool for feature selection in machine learning, in: *Proceedings Fourth International Conference on Tools with Artificial Intelligence TAI'92*, IEEE, 1992, pp. 200-203.
- [37] N.-T. Nguyen, H.-H. Lee, J.-M. Kwon, Optimal feature selection using genetic algorithm for mechanical fault detection of induction motor, *Journal of Mechanical Science and Technology*, 22(3) (2008) 490-496.
- simply supported reinforced concrete beam by S transform, in: *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, 2017, pp. 012133.
- [18] J.-L. Liu, Z.-C. Wang, W.-X. Ren, X.-X. Li, Structural time-varying damage detection using synchrosqueezing wavelet transform, *Smart Structures and Systems*, 15(1) (2015) 119-133.
- [19] E. Darvishan, Low cost damage detection of cable-stayed bridges using signal processing and machine learning, *Amirkabir Journal of Civil Engineering*, (2018), (in Persian).
- [20] A. Neves, I. González, J. Leander, R. Karoumi, Structural health monitoring of bridges: a model-free ANN-based approach to damage detection, *Journal of Civil Structural Health Monitoring*, 7(5) (2017) 689-702.
- [21] M. Chandrashekar, R. Ganguli, Structural damage detection using modal curvature and fuzzy logic, *Structural Health Monitoring*, 8(4) (2009) 267-282.
- [22] R. Ghiasi, M. Ghasemi, M. Sohrabi, Structural damage detection using frequency response function index and surrogate model based on optimized extreme learning machine algorithm, *Computational Methods in Engineering*, 36(1) (2017) 1-17, (in Persian).
- [23] P. Ghaderi and Y. Shabani, Damage Detection based on Modal Parameters and Dynamic Responses by using Enhanced Grey Wolf Optimization, *Amirkabir Journal of Civil Engineering*, (2019), (in Persian).
- [24] H. Babajanian Bisheh, G. Ghodrati Amiri, M. Nekooei, E. Darvishan, Damage detection of a cable-stayed bridge using feature extraction and selection methods, *Structure and Infrastructure Engineering*, 15(9) (2019) 1165-1177.
- [25] M. Gul, F.N. Catbas, Structural health monitoring and damage assessment using a novel time series analysis methodology with sensor clustering, *Journal of Sound and Vibration*, 330(6) (2011) 1196-1210.
- [26] S. Li, H. Li, Y. Liu, C. Lan, W. Zhou, J. Ou, SMC structural health monitoring benchmark problem using monitored data from an actual cable-stayed bridge, *Structural Control and Health Monitoring*, 21(2) (2014) 156-172.

- of the fifth annual workshop on Computational learning theory, ACM, 1992, pp. 144-152.
- [41] S. Yin, X. Gao, H.R. Karimi, X. Zhu, Study on support vector machine-based fault detection in tennessee eastman process, in: Abstract and Applied Analysis, Hindawi, 2014.
- [42] H. Wang, P. Chen, A feature extraction method based on information theory for fault diagnosis of reciprocating machinery, Sensors, 9(4) (2009) 2415-2436.
- [38] L. Breiman, Random forests, Machine learning, 45(1) (2001) 5-32.
- [39] H. Kawakubo, H. Yoshida, Rapid feature selection based on random forests for high-dimensional data, in: Proceedings of the International Conference on Parallel and Distributed Processing Techniques and Applications (PDPTA), The Steering Committee of The World Congress in Computer Science, Computer ..., 2012, pp. 1.
- [40] B.E. Boser, I.M. Guyon, V.N. Vapnik, A training algorithm for optimal margin classifiers, in: Proceedings

چگونه به این مقاله ارجاع دهیم

H. Babajanian Bisheh, Gh. Ghodrati Amiri, M. Nekooei, E. Darvishan, *Damage Assessment of a Cable-Stayed Bridge Based on Effective Empirical Mode Features using Empirical Wavelet Transform. Amirkabir J. Civil Eng., 53(3) (2021) 1201\_1222*

DOI: [10.22060/ceej.2020.16849.6368](https://doi.org/10.22060/ceej.2020.16849.6368)

