

Amirkabir Journal of Civil Engineering

Amirkabir J. Civil Eng., 57(2) (2025) 363-380 DOI: 10.22060/ceej.2025.22437.7977

Vibrational-Based Damage Localization of Bending Frames Using CNNs

Shahin Ghazvineh, Gholamreza Nouri* ^(D), Seyed Hossein Hosseini Lavassani ^(D)

Faculty of Engineering, Kharazmi University, Tehran, Iran.

ABSTRACT: The challenge of identifying damage-indicative features that are robust to noise in time-series data has long hindered the effectiveness of traditional machine learning-based structural damage detection methods. The time-consuming preprocessing procedures required by these methods also contributed to reduced accuracy and performance. However, the advent of deep learning has led to an increased exploration of the use of deep architectures in structural health monitoring. Despite these advancements, many deep learning approaches are resource-intensive and require significant data for training, making them less feasible for real-time applications. As a solution, we propose using 2-D convolutional neural networks (2-D CNNs) that integrate feature extraction and classification into a single entity. Our method employs a network of lighted CNNs instead of deep ones and utilizes raw acceleration signals as input, overcoming the limitations of previous approaches. Using lighted CNNs, in which eachone is optimized for a specific element, increases the accuracy and makes the network faster to perform. Also, a new framework is proposed for decreasing the data required in the training phase. We verified our method on Qatar University Grandstand Simulator (QUGS) benchmark data provided by Structural Dynamics Team. The results showed an improvement in accuracy over other methods, and the running time was adequate for real-time applications.

Review History:

Received: Jun. 03, 2023 Revised: Nov. 17, 2024 Accepted: Dec. 20, 2024 Available Online: Feb. 06, 2025

Keywords:

Structural Damage Detection Machine Learning Deep Learning Structural Health Monitoring Convolutional Neural Networks

1-Introduction

Structural damages in civil engineering structures are inevitable due to environmental, operational, and human factors. Given the progressive nature of damage, regular inspections are essential to enhance serviceability, prevent reduced lifespan, and ensure safety. Structural damage detection methods are broadly categorized into global and local approaches. Among global methods, vibration-based techniques have gained significant attention due to their ability to identify, quantify, and localize damages using acceleration signals [1-3]. Traditional machine learning methods require manual extraction of damage-sensitive features from time-series data, making them challenging and time-consuming [4]. In recent years, the advent of deep learning has revolutionized the field by enabling automatic feature extraction and classification [5, 6]. However, deep architectures demand high computational resources and extensive data, making them unsuitable for real-time applications [7, 8].

To address these challenges, this study proposes a novel approach based on two-dimensional Convolutional Neural Networks (2-D CNNs) that integrates feature extraction and classification into a single framework. Unlike deep networks, our method uses shallow CNNs, optimized for individual structural elements, to achieve high accuracy with reduced computational costs. The elimination of preprocessing steps, combined with the use of raw acceleration signals for damage detection, ensures the method's suitability for real-time structural health monitoring.

2- Proposed Method

Building on the need for efficient damage detection, the proposed framework employs a decentralized architecture where a separate CNN is assigned to monitor the health of each structural element. This approach not only reduces computational complexity but also facilitates simultaneous damage detection across multiple elements. Each CNN comprises two convolutional layers for feature extraction and a fully connected layer for classification. These layers are carefully optimized to strike a balance between accuracy and processing speed.

A distinctive aspect of this methodology is the use of three accelerometers for each structural element. By incorporating data from multiple sensors, the method reduces the volume of training data required while maintaining high accuracy [9, 10]. Furthermore, raw acceleration signals from a large-scale laboratory structure are directly fed into the CNNs, bypassing traditional preprocessing steps. During the training phase, balanced datasets are created by equalizing the number

*Corresponding author's email: r.nouri@khu.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. Arrangement of accelerometers at joints (locations of damage scenarios)

of healthy and damaged samples for each element. This ensures the robustness and reliability of the CNNs in diverse conditions.

3- Validation and Results

To evaluate the efficacy of the proposed method, validation was conducted using data from the Qatar University Grandstand Simulator (QUGS), a large-scale experimental steel structure [11]. Damage scenarios were simulated by loosening bolts at joint connections, and dynamic responses were recorded using 30 accelerometers. The study encompassed 13 scenarios, including single and multiple damages, providing a comprehensive testbed for the framework.

The results revealed an impressive average accuracy of 99.8% on training data and 99.6% on validation data. The CNNs successfully localized damages in all scenarios, achieving probabilities greater than 98.4% for damaged joints while maintaining probabilities below 3.1% for healthy joints. Additionally, the method's superior performance in scenarios with proximal sensor placement underscored the importance of strategic sensor positioning.

Further analysis was conducted to investigate the impact of sensor placement on detection accuracy. Two scenarios were evaluated using data from sensors positioned far from the damaged locations. For Joint 1, data from sensors near Joint 10 were used, and for Joint 10, data from distant sensors near Joint 1 were employed. The results showed a decrease in detection accuracy compared to scenarios where sensors were proximal to the damage. Specifically, validation accuracy dropped to 94.8% and 93.9% for Joints 1 and 10, respectively. Despite this decline, the method still demonstrated acceptable performance, confirming its robustness even under less favorable conditions. These findings emphasize the advantage of selecting sensors closer to the damage for optimal results.

In terms of computational efficiency, the method processed each second of input signals in approximately 2 milliseconds, meeting the stringent requirements for realtime processing [10]. The shallow architecture allowed the system to operate efficiently on standard computing hardware, thereby enhancing its accessibility and scalability for practical applications.

4- Conclusion

This study presents a fast, accurate, and efficient framework for structural damage detection using 2-D CNNs. The decentralized approach not only ensures high accuracy by optimizing each CNN for specific elements but also maintains computational efficiency. By utilizing raw acceleration signals without preprocessing, the method addresses the critical limitations of traditional approaches, making it highly suitable for real-time applications. Validation on a large-scale experimental structure demonstrated the method's robustness and effectiveness in detecting and localizing damages under various scenarios. These results highlight the practical applicability of the proposed framework in structural health monitoring systems, contributing to enhanced safety and serviceability in civil engineering structures.

References

- [1] S. Teng, G. Chen, P. Gong, G. Liu, F. Cui, Structural damage detection using convolutional neural networks combining strain energy and dynamic response, Meccanica, Springer Netherlands, 2020, pp. 945-959.
- [2] C.R. Farrar, S.W. Doebling, D.A. Nix, Vibrationbased structural damage identification, Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2001, pp. 131-149.

- [3] W. Fan, P. Qiao, Vibration-based damage identification methods: A review and comparative study, Structural Health Monitoring, SAGE PublicationsSage UK: London, England, 2011, pp. 83-111.
- [4] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, D.J. Inman, Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks, Journal of Sound and Vibration, Elsevier, 2017, pp. 154-170.
- [5] K. He, X. Zhang, S. Ren, J. Sun, Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016, pp. 770-778.
- [6] J. Han, H. Chen, N. Liu, C. Yan, X. Li, CNNs-Based RGB-D Saliency Detection via Cross-View Transfer and Multiview Fusion, IEEE Transactions on Cybernetics, 2018, pp. 3171-3183.
- [7] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, D.J. Inman, 1D convolutional neural networks and applications: A survey, Mechanical Systems and Signal

Processing, The Author(s), 2021, pp. 107398.

- [8] S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci, M. Gabbouj, 1-D Convolutional Neural Networks for Signal Processing Applications, ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing Proceedings, 2019, pp. 8360-8364.
- [9] O. Abdeljaber, O. Avci, M.S. Kiranyaz, B. Boashash, H. Sodano, D.J. Inman, 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data, Neurocomputing, Elsevier B.V., 2018, pp. 1308-1317.
- [10] O. Avci, O. Abdeljaber, S. Kiranyaz, D. Inman, Convolutional Neural Networks for Real-Time and Wireless Damage Detection, in, 2020, pp. 129-136.
- [11] O. Abdeljaber, A. Younis, O. Avci, N. Catbas, M. Gul, O. Celik, H. Zhang, Dynamic Testing of a Laboratory Stadium Structure, Geotechnical and Structural Engineering Congress 2016, American Society of Civil Engineers, Reston, VA, 2016, pp. 1719-1728.

نشريه مهندسي عمران اميركبير

نشریه مهندسی عمران امیرکبیر، دوره ۵۷، شماره ۲، سال ۱۴۰۴، صفحات ۳۶۳ تا ۳۸۰ DOI: 10.22060/ceej.2025.22437.7977



مکانیابی خرابی بر پایه پاسخهای دینامیکی در قابهای خمشی با استفاده از شبکه عصبی پیچشی شاهین قزوینه، غلامرضا نوری^{ه ©}، سید حسین حسینی لواسانی[©]

ساهین فروینه، علامرصا نوری ، سید حسین حسینی لواسان

دانشکده فنی مهندسی، دانشگاه خوارزمی، تهران، ایران.

خلاصه: در الگوریتمهای تشخیص خرابی سازه مبتنی بر روشهای سنتی یادگیری ماشین، استخراج ویژگیهای حساس به خرابی از دادههای سری زمانی یک مسئله چالش برانگیز است. همچنین این روشها نیازمند به پیش پردازش در دادههای خام هستند که خود فرایند پردازش را کندتر می کند. تلاشهای زیادی برای غلبه بر این محدودیتها با گسترش یادگیری عمیق در زمینه پایش سلامت سازه صورت گرفته است. با این حال، از آنجایی که اکثر این سیستمها دارای معماریهای عمیق هستند، به رایانههای با سلامت از محدودیتها با گسترش یادگیری عمیق در زمینه پایش بردازش را کندتر می کند. تلاشهای زیادی برای غلبه بر این محدودیتها با گسترش یادگیری عمیق در زمینه پایش مسلامت سازه صورت گرفته است. با این حال، از آنجایی که اکثر این سیستمها دارای معماریهای عمیق هستند، به رایانههایی با توان محاسباتی بالا و همینطور میزان قابل توجهی داده در طول مرحله آموزش نیاز دارند که در نتیجه برای کاربردهای برخط مناسب آستخراج ویژگی و طبقهبندی سریع به طور همزمان، ارائه می شود. این روش از یک CNN کم عمق استفاده می کند که سیگنالهای استخراج ویژگی و طبقهبندی سریع به طور همزمان، ارائه می شود. این روش از یک CNN کم عمق استفاده می کند که سیگنالهای آزمایشگاهی مقاس بزرگ به عنوان ورودی شبکه دریافت می کند. برای بررسی توانایی الگوریتم پیشنهاد شده از داده یه به دست آمده از یک سازه دارای دوسته می زرگ به عنوان ورودی شبکه استفاده شده است. به طور میانگین روش پیشنهاد شده از دادهی به دست آمده از یک سازه بر وی در وی و عربه می دریافت می کند. برای بررسی توانایی الگوریتم پیشنهاد شده از دادهی به دست آمده از یه سازه بر وی در وی در این می از یک سیکنال های در می توانایی الگوریتم پیشنهاد شده از دادهی به دست آمده از یک سره می زری می در وی در ماه در داون می در در این می درسی توانایی الگویابی دارای داده می خرد برای در در می توانایی الگرین وی پیشنهاد شده از دادهی به دست آمده از ی در می توان ورودی شبکه دریافت می کند. برای برسی توانایی الگویابی زاری دارهی دارای دوست آرمان مرون پیشنهاد شده از داری دفت در ای در در می توانایی رای وی توانیی بالای الگویابی آن دارد. همچنین در وی دادههای آموزشتی از وی می توان می دان ۲ میلی ثانیه بررسی کند که در استاندارهای پردازش برخا قرار دارد. می نمان از در داموانی وی توانی را در دردن ترمان ۲ می می نمان از توانیی با

تاریخچه داوری: دریافت: ۱۴۰۳/۰۳/۱۳ بازنگری: ۱۴۰۳/۰۸/۲۷ پذیرش: ۱۴۰۳/۰۹/۳۰ ارائه آنلاین: ۱۴۰۳/۱۱/۱۸

کلمات کلیدی: تشخیص خرابی سازه یادگیری ماشین یادگیری عمیق پایش سلامت سازه شبکه عصبی پیچشی

۱ – مقدمه

خرابی سازهای در سازههای عمرانی به دلیل تأثیرات محیطی، عملیاتی و سایر عوامل انسانی اجتناب ناپذیر است. با توجه به ماهیت پیشرونده آسیب، بازرسی منظم سازههای عمرانی برای بهبود قابلیت سرویس دهی، جلوگیری از کاهش عمر سازه و فروریزش آن و در نتیجه حفاظت از جان ساکنین ضروری است. بنابراین، تشخیص خرابی به یک موضوع جذاب در زمینه نظارت بر سلامت سازه برای بسیاری از محققان مهندسی عمران تبدیل شده است [۱–۳].

تشخیص خرابی سازه به روشهای تشخیص محلی و کلی دستهبندی میشود [۴]. به عنوان یکی از زیر مجموعههای روشهای کلی، تعداد فزایندهای از مطالعات تحقیقاتی بر روی روشهای تشخیص خرابی مبتنی بر ارتعاش به دلیل قابلیت شناسایی، تعیین کمیت و مکانیابی آسیبهای سازه از طریق پردازش سیگنالهای شتابسنج انجام شده است [۵–۷]. روشهای

* نویسنده عهدهدار مکاتبات: r.nouri@khu.ac.ir

مبتنی بر ارتعاش را میتوان به دو زیرمجموعه مبتنی بر مدل (پارامتری) و مبتنی بر سیگنال (ناپارامتری) طبقه بندی کرد [۸]. در روشهای پارامتری، آسیب به صورت تغییر در پارامترهایی مانند پارامترهای مدال (مانند فرکانس طبیعی و شکل مد)، میرایی و شاخصهای سختی ظاهر میشود. برعکس، روشهای ناپارامتری میتوانند آسیب ناشی از سیگنالهای اندازه گیری شده را بدون دانستن هیچ اطلاعاتی در مورد مدل سازه شناسایی کنند [۹].

در سالهای اخیر استفاده از رویکردهای بر پایه یادگیری ماشینی به دلیل قابلیت تحلیل خودکار دادهها و همین طور افزایش حجم دادههای درد دسترس، در حوزه تشخیص خرابی سازه رایج شده است. یک روش تشخیص خرابی سازه مبتنی بر یادگیری ماشینی شامل سه مرحله است: پیش پردازش دادههای اندازه گیری شده، استخراج ویژگیهای حساس به خرابی و دستهبندی ویژگیها با استفاده از یک طبقهبندی برای نشان دادن سالم یا آسیب دیده بودن سازه [۸]. بر این اساس، مشکل اصلی روشهای سنتی مبتنی بر یادگیری ماشینی، نیاز آنها به استخراج دستی ویژگیهای حساس

به خرابی است که در کارهای عملی چالش برانگیز است. عمدتاً، عملکرد روشهای یادگیری ماشینی به این ویژگیهای دستچین شده بستگی دارد، که برای به دست آوردن آنها نیاز به آزمون و خطا است. از آنجایی که استخراج این ویژگیها ویژگی برای تشخیص آسیب در سازههای شهری کلیدی است، توسعه روشهای استخراج خودکار ویژگی ضروری است [۱۰].

با رشد توان محاسباتی کامپیوترها، یادگیری عمیق، به عنوان یک زیر کلاس از یادگیری ماشینی، به یک راه حل امیدوار کننده در بسیاری از زمینهها مانند بینایی کامپیوتر [۱۱, ۱۲]، تشخیص گفتار [۱۳] و پردازش سیگنال [۱۴–۱۸] تبدیل شده است. به لطف توانایی استخراج خودکار مدلهای یادگیری عمیق، مشکل نیاز به ویژگیهای دستچین شده حذف شده است [۱۹]. یکی از محبوبترین مدلهای یادگیری عمیق، شبکه عصبی پیچشی⁽ (CNN) است که میتواند ویژگیها را از دادههای خام استخراج کرده، آنها را یاد گرفته و طبقهبندی کند. بر این اساس، روشهای بسیاری

مدرس و همکاران [۲۰] یک رویکرد جدید برای تشخیص و شناسایی آسیب در تصاویر بر پایه CNN معرفی و عملکرد آن را با چهار الگوریتم دیگر با استفاده از تصاویر نویزدار و بدون نویز مقایسه کردند. نتایج نشان داد که CNN دو بعدی ذکر شده در هر دو سناریو دقیق تر از سایر روش ها عمل می کند. به همین ترتیب، شیهاوالدین و همکاران [۲۱] روش دیگری بر پایه شبکههای عصبی پیچشی دو بعدی ارائه کردند که از تصاویر برای تشخیص اًسیب بر روی پرههای توربین بادی استفاده می کرد. اگرچه شبکههای عصبی پیچشی دو بعدی در ابتدا برای ورودی تصویر توسعه یافتهاند، این الگوریتم برای پردازش ارتعاش نیز استفاده شده است. این روشها برای استفاده از شبکههای عصبی پیچشی دو بعدی به تغییر شکل دادههای ورودی الگوریتم روی می آورند. در برخی روشها سیگنالهای ارتعاش سازه به تصویر [۹] تبدیل شده، در برخی دادههای کرنش در آرایش دو بعدی قرار گرفته است [۲۲] و در برخی دیگر با کنار هم قرار دادن پاسخهای دینامیکی سازه یک ماتریس دو بعدی تشکیل شده است [۲۳, ۲۴]. از سوی دیگر، استفاده از معماریهای یک بعدی CNN برای پردازش سیگنال رایج است. بر این اساس، چندین تحقیق در مورد استفاده از این شبکه برای حل مسائل تشخیص خرابی در سازه با استفاده از سیگنالهای شتاب دامنه-زمانی انجام شده است [۲۵–۲۸]. برخی از محققین نیز از انواع دیگری از دادههای ورودی

مانند پاسخهای دامنه فرکانس [۲۹] یا شکل مود اول سازه [۳۰] استفاده کردهاند. بسیاری از روشهای ذکر شده قبلی، با افزودن لایههای پیچشی بیشتر به مدلهای خود، از معماری عمیق استفاده میکنند که فرایند آموزش را نیازمند حجم زیادی از داده میکند و پردازش آن از نظر محاسباتی گران و زمانبر است. در یک مطالعه متفاوت، آوچی و همکاران^{*} [۳۱] یک CNN تک بعدی را معرفی کردند که تنها از دو حالت سازه، یعنی کاملاً آسیب دیده و دست نخورده، به عنوان ورودی مرحله آموزش برای تعیین میزان آسیب سازه استفاده میکند. همین طور روش غیرمتمرکز دیگری بر پایه CNN پیشنهاد شد. برای این منظور، یک شبکه مجزا برای هر سنسور آموزش داده شد تا آسیب دیدگی عضو مربوط به همان سنسور را در یک قاب فولادی کنترل کند. این الگوریتم عملکرد قابل قبولی در زمینه سرعت پردازش از خود نشان داد.

بنابراین، نویسندگان این مقاله روش جدید تشخیص خرابی سازه مبتنی بر ارتعاش را بر پایه CNN دو بعدی به منظور تشخیص وجود آسیب و مکانیابی آن در صورت وجود، ارائه می کنند. این روش غیرمتمرکز در نظر گرفته میشود و تنها از دادههای خام شتاب بدون هیچ گونه آمادهسازی یا مهندسی ویژگی استفاده می کند. هدف ما دستیابی به روشی دقیق است که به زمان کم برای ارزیابی نمونههای جدید نیاز دارد و میتوان آن را با دادههای کمتری نسبت به روشهای سنتی آموزش داد. تمرکز زدایی اجازه می دهد تا با بهینهسازی هر شبکه برای هر عضو از سازه، دقت افزایش یابد در حالی که معماریها فشرده و غیر عمیق هستند. از این رو، پیچیدگی محاسباتی کاهش مییابد و هر یک از شبکهها را میتوان در زمان کوتاهتری آموزش داد و آزمایش کرد. نویسندگان عملی بودن روش پیشنهادی را با استفاده از دادههای شتاب مجموعه دادههای سازه آزمایشگاهی شبیهساز جایگاه تماشاگران دانشگاه قطر [۳۳–۳۵] ارزیابی کردند.

این پژوهش به شرح زیر تنظیم شده است: روش پیشنهادی در بخش ۲، شامل شرح مختصری از CNN، روش آموزش و آزمایش آن معرفی شده است. در بخش ۳، سازه معیار توضیح داده شده و اجرای روش پیشنهادی نشان داده شده است. نتایج ارزیابی روش پیشنهادی نیز در این بخش گنجانده شده است. در نهایت، نتیجه گیری مورد بحث قرار می گیرد.

^{1.} Convolutional Neural Network

^{2.} Modarres et al

^{3.} Shihavuddin et al.

^{4.} Avci





Fig. 1. Schematic of the proposed method

۲- روش پیشنهادی

هدف از این بخش ارائه یک الگوریتم سریع و کارآمد برای تشخیص خرابی در سازه آزمایشگاهی بزرگمقیاس است. در روش پیشنهادی ابتدا باید سازه مورد نظر سنسورگذاری شود و پاسخ شتاب سازه برای پردازش توسط شبکه پیشنهادی جمع آوری شود. سپس یک CNN به منظور تشخیص خرابی در هر عضو آموزش داده می شود. هر کدام از این شبکهها وظیفه نظارت بر سلامت یک عضو را بر عهده دارند. تمام پردازشها بر روی دادههای خام شتاب سنج انجام می شود که با حذف مرحله پیش پردازش هزینه محاسباتی و در نتیجه زمان محاسبات کاهش می یابد. در این پژوهش از دادههای یک سازه آزمایشگاهی بزرگ مقیاس برای بررسی عملکرد الگوریتم پیشنهادی استفاده خواهد شد و در نهایت دقت الگوریتم با استفاده از معیارهای مختلف بررسی می شود. شکل ۱ خلاصهای از روش پیشنهادی ارائه می دهد.

حرکت هستههای تشخیص الگوی CNN دو بعدی در کنار پارامترهای قابل یادگیری بیشتر، قابلیت یادگیری این الگوریتم را در مقایسه با نوع یک بعدی آن افزایش می دهد. استفاده از CNN دو بعدی همچنین به ما اجازه می دهد تا داده های مورد نیاز برای مرحله آموزش را با تغییر فرم ورودی، همانطور که در بخش آموزش بحث خواهیم کرد، کاهش دهیم. معماری و شرح مختصری از هر لایه از CNN های آموزش داده شده در بخش های بعدی ارائه شده است و سپس مراحل آموزش و آزمایش توضیح داده می شود.

۲- ۱- معماري الگوريتم پيشنهادي

از آنجا که هدف اصلی این پژوهش رسیدن به دقت بالا در عین سریع بودن است روش پیشنهادی از یک معماری متفاوت غیر متمرکز برای تعیین خرابی در سازه استفاده می کند. این بدین معنا است که به جای آموزش یک شبکه عمیق برای تمام سازه، وظیفه پایش سلامت بین چندین شبکه تقسیم شده است. اولین مزیت این کار بالا رفتن سرعت عمل و کاهش پیچیدگی محاسباتی خواهد بود. در این معماری هر شبکه CNN مسئول بررسی سلامت تنها یک عضو از سازه است. بدین ترتیب برخلاف روشهای متمرکز امکان بررسی همزمان خرابی در چند عضو نیز فراهم میشود. هر یک از NNها از یک معماری ساده پیروی می کنند که در شکل ۲ مشاهده میشود.

هر شبکه CNN شامل دو بلوک پیچشی برای تشخیص الگوهای موجود در دادههای ورودی و یک لایه طبقهبند برای کلاس بندی اطلاعات استخراج شده توسط بخش قبلی است. برای بالا بردن راندمان روش پیشنهادی، هر یک از این شبکهها به طور مجزا و برای تشخیص خرابی در یک المان بهینه سازی شدهاند. در ادامه توضیح مختصری از هر لایه CNN داده می شود.

۲- ۱- ۱- لایه پیچشی

لایه پیچشی جوهر اصلی CNN است که آن را از سیستمهای یادگیری ماشین قبلی متمایز می کند. در این لایه، یک فرآیند ریاضی برای استخراج ویژگیها از ورودی استفاده می شود. این عملیات ریاضی ضرب نقطه ای بین



بردار ویژگی های استخراج شده :FF بلایه ادغام :PL بلایه پیچشی , RL

شکل ۲. معماری شبکه پیشنهادی

Fig. 2. Architecture of the proposed network

مجدد تقريباً هر نوع شبکه عصبی است. این الگوریتم میانگین و واریانس هر دسته ورودی را محاسبه میکند و سپس آنها را به ترتیب به ۰ و ۱ تغییر مه،دهد. از آنجایه، که BN در یک دسته کوچک انجام می شود، از نظر محاسباتی کارآمد است و همچنین امکان استفاده از نرخ یادگیری بالاتر را فراهم می کند.

۲- ۱- ۳- تابع فعال سازی

یکی از حیاتیترین اجزای یک شبکه عصبی، توابع فعالسازی آن است. این توابع به شبکه خاصیت غیرخطی بودن میدهند و ورودی را قابل یادگیری تر می کنند. تابع فعال سازی در یک شبکه عصبی نحوه تبدیل مجموع وزنی ورودی به خروجی از یک گره یا گرههای یک لایه از شبکه را تعريف مي كند. در سال هاي اخير تابع فعال سازي واحد خطى اصلاح شده ^ (ReLU) [۳۷, ۳۶] به دلیل توانایی آن در حل مؤثر مشکل ناپدید شدن گرادیان، که یک مسئله رایج در توابع فعالسازی سیگموئید بود، محبوبیت گستردهای پیدا کرده است [۳۸]. علاوه بر این، ReLU از نظر محاسباتی کارآمد است و روند آموزش شبکه را سریعتر میکند. این تابع از رابطه F=max(0, x) يېروي مي کند.

هسته لغزنده و ورودی لایه پیچشی و سپس جمع حاصل آن با یک عدد ثابت است. یک لایه پیچشی شامل چندین هسته با وزنهای قابل یادگیری است که یک ماتریس جدید به نام نقشه ویژگی از ورودیها ایجاد می کند که سپس به لایه بعدی داده می شود. تعداد کانال های ورودی در هسته و دادههای ورودی باید یکسان باشد. به طور معمول با استفاده از لایه گذاری صفر در این لایه از کوچک شدن نقشه ویژگی جلوگیری می شود. شکل ۳ عملکرد یک هسته پیچشی^۳ ۳ در ۳ را بر روی یک پنجره داده ۷ در ۷ همراه با لايه گذاري صفر نشان ميدهد.

۲- ۱- ۲- نرمال سازی دستهای

از آنجایی که روند آموزش دسته^۴ به دسته انجام می شود، توزیع غیر يكنواخت هر دسته مي تواند به طور قابل توجهي مانع همگرايي شود. سرجي یافی⁶ و کریستین سزجدی² [۳۶] یک روش نرمال سازی دستهای^۷ (BN) را برای غلبه بر این مشکل ارائه کردند که به نام تغییر متغیر کمکی داخلی شناخته می شود. نرمال سازی دستهای یک روش قدر تمند برای یارامترسازی

- 3. Convolutional Kernel
- 4. Batch
- 5. Sergey Ioffe
- 6. Christian Szegedy
- 7. Batch Normalization

^{8.} Rectified Linear Unit

^{1.} Feature Map

^{2.} Padding





۲- ۱- ۴- لایه ادغام

یک لایه ادغام در معماری شبکه عصبی در تلاش است با حفظ اطلاعات حیاتی موجود در دادهها و کاهش همزمان حجم آنها اندازه نقشه ویژگی را کاهش دهد. علاوه بر این لایه ادغام یادگیری را مستقل تر از تغییرات جزئی دادههای ورودی می کند. به عنوان دو نوع متداول آن می توان به ادغام حداکثر و ادغام میانگین اشاره کرد. ادغام میانگین یک پنجره را در نقشه ویژگی حرکت می دهد و میانگین مقادیر موجود در پنجره را محاسبه می کند، در حالی که ادغام حداکثر بیشترین مقدار را گرفته و بقیه را نادیده می گیرد. از مزیتهای ادغام حداکثر افزایش سرعت محاسبات نسبت به ادغام میانگین است. شکل ۴ نحوه عملکرد ادغام حداکثر را نشان می دهد.

۲- ۱- ۵- حذف تصادفی

برای اولین بار، سریواستاوا و همکاران^۲ [۳۹] این روش را به عنوان راه حلی ساده برای مشکل بیش برازش پیشنهاد کردند. به طور خلاصه حذف تصادفی برخی از واحدها را به طور موقت در مرحله آموزش غیر فعال کرده و



Fig. 4. Max pooling operator

۲- ۱- ۶- طبقهبند

پس از استخراج ویژگیها توسط لایههای پیچشی، به منظور طبقهبندی شدن در یکی از گروههای موجود نتایج وارد این لایه میشوند. در CNN، طبقهبند یک لایه کاملاً متصل^۳ (FC) است که بردار ویژگیها را طبقهبندی می کند. یک لایه FC در طبقهبند دودویی به دنبال ایجاد مرزی بین ویژگیها به منظور ارائه بهترین نتایج طبقهبندی ممکن در دادههای آموزشی است. هر نورون در یک لایه FC به تمام لایههای قبلی متصل است. همانطور که در رابطه (۱) نشان داده شده است، هر مقدار ورودی *u* در وزن *w* ضرب شده و با بایاس[‡] *d* جمع می شود و در نهایت، تمام نتایج جمع میشوند. در این

^{1.} Pooling

^{2.} Srivastava et al.

^{3.} Fully Connected

^{4.} Bias

روش، وزن w و بایاس b پارامترهای قابل یادگیری هستند. خروجی لایه FC یک بردار N بعدی است که N تعداد کلاسهای مسئله است و در این حالت N برابر با ۲ است.

$$y = \sum u \times w + b \tag{1}$$

۲– ۱– ۷– تابع هزینه

برای محاسبه خطای شبکههای عصبی مصنوعی از توابعی به نام تابع هزینه^۱ یا تابع هزینه استفاده می شود. در فرایند تعیین وزن ها و بایاس ها در هر مرحله از آموزش، خطای پیش بینی شبکه با توجه به برچسب دادههای ورودی محاسبه می شود. در ادامه خطای محاسبه شده معیار به روز رسانی دوباره وزن ها و بایاس ها قرار گرفته و این چرخه تا رسیدن به نتایج مطلوب ادامه پیدا می کند. برای محاسبه خطای پیش بینی شبکههای CNN به طور معمول از الگوریتم آنتروپی متقاطع [۴۰] به عنوان تابع هزینه استفاده می شود. تابع هزینه آنتروپی متقاطع یک روش برای محاسبه تفاوت بین برچسب های واقعی و خروجی های پیش بینی شده است.

۲– ۱– ۸– بهینهساز

بهینه سازها الگوریتمهایی هستند که برای تغییر ویژگیهای شبکه عصبی مانند وزن و نرخ یادگیری^۲ به منظور کاهش هزینه استفاده می شوند. نحوه تغییر وزنها یا نرخ یادگیری شبکه عصبی برای کاهش هزینه توسط بهینه سازهایی که استفاده می شوند تعریف می شود. الگوریتمهای بهینه سازی وظیفه کاهش هزینه و ارائه دقیق ترین نتایج ممکن را بر عهده دارند. در مرحله آموزش معماری پیشنهادی، الگوریتم بهینه ساز آدام^۳ [۴۱] به جای الگوریتم سنتی شیب نزولی تصادفی^۴ (SGD) استفاده می شود. این الگوریتم به عنوان محبوب ترین روش در یادگیری عمیق برای بهینه سازی هزینه شناخته می شود.

۲– ۲– آموزش مدل پیشنهادی

روش پیشنهادی سلامت هر عضو از سازه را به طور جداگانه و با استفاده از یک CNN دو بعدی خاص ارزیابی می کند. این رویکرد غیرمتمر کز امکان تشخیص آسیبهای متعدد در سازه را به طور همزمان فراهم می کند. آموزش

CNNها شامل استفاده از سیگنالهای خام شتاب، هم در شرایط اسیب دیده و هم در شرایط دست نخورده، برای آموزش یک CNN به ازای هر عضو است. در این مرحله به دو دلیل به جای استفاده از سیگنال یک بعدی از ماتریسی شامل سه سیگنال یک بعدی به عنوان ورودی سیستم استفاده شده است. دلیل اول استفاده از CNN دو بعدی است که استفاده از ورودی دو بعدی را می طلبد. اما دلیل دوم و مهمتر، کاهش نیاز به دادههای جدید برای آموزش است در حالی که دقت شبکه افت نکند. فرض کنید برای رسیدن به دقت هدف، نیاز به N نقطه داده برای هر عضو وجود دارد. در صورت استفاده از دادههای مربوط به تنها یک شتابسنج برای هر عضو، در نهایت در سازه مفصلی معیار به 30 imes N خط داده برای آموزش هر عضو نیاز است. این ۳۰ مفصلی معیار به N imes 30بدین معناست که به ازای هر شتابسنج نیاز به ثبت N سطر داده است. اما در صورت استفاده از دادههای دو شتابسنج دیگر به عنوان داده کمکی برای أموزش شبکه برای هر عضو، این تعداد تقریبا به یک سوم کاهش مییابد. بدین ترتیب به منظور فراهم کردن N خط داده مورد نیاز برای هر عضو تنها N/3 نقطه داده از هر شتاب سنج مورد نیاز است. در نتیجه مقدار داده مورد استفاده در کل فرایند به $N \! \times \! 10$ کاهش می یابد، در حالی که دقت همچنان بالا است. بدین ترتیب برای پایش سلامت هر عضو سه شتابسنج از نزدیک ترین شتاب سنجها به آن عضو انتخاب و از دادههای آنها در فرایند آموزش شبکه مربوطه استفاده شده است. انتظار میرود ویژگیهای خرابی در شتابسنجهای نزدیکتر به عضو مورد نظر بیشتر دیده شود. همین طور که در بخش مربوط به نتایج خواهیم دید، استفاده از این روش دقت بسیار بالایی نیز برای الگوریتم به همراه خواهد آورد.

برای هر عضو i دادههای حالت آسیب دیده و آسیب ندیده به صورت روابط (۲) و (۳) خواهد بود.

$$U_i = \begin{bmatrix} U_{i1} & U_{i2} & U_{i3} \end{bmatrix}$$
(Y)

$$D_i = \begin{bmatrix} D_{i1} & D_{i2} & D_{i3} \end{bmatrix}$$
(Y)

که در آن U_i و U_i به ترتیب ماتریس سیگنال حالت سالم و حالت آسیب دیده برای عضو *i* است. همینطور U_{i1} , U_{i2} و U_{i3} بردار سیگنال D_{i1} بنده از سه شتابسنج نزدیک به عضو *i* هستند. به طور مشابه D_{i1} D_{i1} بردار سیگنالهای مربوط به حالت آسیب دیده عضو *i* هستند. برای اینکه اثر خرابی در سایر اعضا در تشخیص خرابی عضو *i* تاثیری

^{1.} Loss Function

^{2.} Learning Rate

^{3.} Adam

^{4.} Stochastic Gradient Descent

نداشته باشد، از دادههای حالت خراب سایر اعضا نیز در دادههای آموزشی حالت سالم عضو *i* استفاده شده است. با این تکنیک شبکه مربوط به عضو *i* تنها خرابی مربوط به همان عضو را یاد می گیرد.

همانطور که در بخش قبلی نیز اشاره شد، CNN فقط می تواند دادههای با طول معین را دریافت کند؛ در نتیجه ابتدا دادهها به طولهای مساوی *S_f* تقسیم و برچسب گذاری شدند. در این فرایند به حالت سالم برچسب ۰ و حالت آسیب دیده برچسب ۱ اختصاص داده شد.

در روابط (۴) و (۵) به ترتیب ماتریسهای با طول ثابت حالت سالم و حالت آسیب دیده عضو *i* نشان داده شده است.

$$U_{i} = \begin{bmatrix} U_{i1,1} & U_{i2,1} & U_{i3,1} \\ U_{i1,2} & U_{i2,2} & U_{i3,2} \\ \vdots & \vdots & \vdots \\ U_{i1.N_{u}} & U_{i2.N_{u}} & U_{i3.N_{u}} \end{bmatrix}$$
(*)

$$D_{i} = \begin{bmatrix} D_{i1,1} & D_{i2,1} & D_{i3,1} \\ D_{i1,2} & D_{i2,2} & D_{i3,2} \\ \vdots & \vdots & \vdots \\ D_{i1.N_{u}} & D_{i2.N_{u}} & D_{i3.N_{u}} \end{bmatrix}$$
(δ)

در این روابط N_d و N_u به ترتیب تعداد فریمهای حالت خراب و سالم عضو i هستند. همین طور در روابط (۶) و (۷)، زامین فریم سیگنال حالت آسیب دیده و سالم نشان داده شده است که هر فریم دارای ابعاد $S_f \times 3$ میباشد.

$$UF_{i,j} = \begin{bmatrix} U_{i1,j} & U_{i2,j} & U_{i3,j} \end{bmatrix}$$
(?)

$$DF_{i,j} = \begin{bmatrix} D_{i1,j} & D_{i2,j} & D_{i3,j} \end{bmatrix}$$
(Y)

با فرض اینکه سیگنال هر شتابسنج شامل S_u و S_d نمونه به ترتیب برای حالتهای آسیبدیده و سالم یک عنصر معین است، تعداد کل فریمها در موارد آسیبدیده و سالم به صورت زیر تعیین می شود (روابط (۸) و (۹)).

$$N_u = \frac{S_u}{S_f} \tag{A}$$

$$N_d = \frac{S_d}{S_f} \tag{9}$$

با توجه به اینکه آسیب در سایر اعضای سازه به عنوان شرایط سالم برای یک عضو در نظر گرفته میشود، مقادیر N_u و N_a به طور قابل توجهی متفاوت هستند و در نتیجه یک مجموعه داده نامتعادل برای آموزش ایجاد میشود. برای غلبه بر این مشکل، در مرحله تکهتکه کردن سیگنال اصلی، به تعداد مساوی داده از هر سناریویی که عضو i در آن سالم است انتخاب شد، دادهها به تکههایی با طول مساوی تقسیم و مجموعه داده ساخته شده به صورت تصادفی مرتب شد. سپس تعداد M_a داده اول به عنوان فریمهای سالم برای آموزش ایتخاب و استفاده شد. با انجام این عملیات ساختمان دادههای مورت ایتخاب و استفاده شد. با انجام این عملیات ساختمان دادههای آموزش ایتخاب و استفاده شد. با انجام این عملیات ساختمان دادههای آموزش ایتخاب و استفاده شد. با داده این عملیات ساختمان سالم برای آموزش ایتخاب و استفاده شد. با دیده و سالم متعادل شد.

۲- ۳- آزمایش مدل پیشنهادی

پس از آماده سازی دادههای آموزشی هر CNN باید به طور مجزا به ازای تعداد حلقههای مشخصی⁽ بر روی دادههای مربوط به عضو خود آموزش ببیند. الگوریتم پسانتشار^۲ به منظور آموزش شبکه در این بخش استفاده شده است. به منظور جلوگیری از مشکل بیش برازش در فاز آموزش شبکهها، بهینهترین وزنهای شبکه با توجه به عملکرد آنها بر روی دادههای آزمایشی ذخیره شد.

در آخرین مرحله نیز باید عملکرد شبکه مورد نظر بر روی دادههایی که شبکه آنها را ندیده ارزیابی شود. برای پیش بینی دادههای جدید از سه مرحلهی زیر استفاده می کنیم.

- دادههای جدید را به طولهای مساوی $\mathbf{S_f}$ تقسیم میشوند.
- برای هر فریم داده ورودی حالت خراب به عنوان ۱ و حالت سالم با ۰ طبقهبندی می شود.

درصد احتمال خراب بودن $`` عضو <math>DP_i \ i \ OP_i$ ، را از رابطه (۱۰) به دست می آید.

$$DP_i = \frac{\sum_{j=1}^{n_i} L_{i,j}}{n_i} \times 100 \tag{(1)}$$

^{1.} Epoch

^{2.} Backpropagation

^{3.} Damage Possibility



شکل ۵. چینش شتابسنجها در اتصالات (محل سناریوهای خرابی)؛ Fig. 5. Arrangement of accelerometers at joints (locations of damage scenarios)

که در آن $L_{i,j}$ ، *ز*امین فریم پردازش شده توسط شبکه *i*ام است. انتظار می ورود برای اعضای آسیب دیده مقدار DP_i به ۱۰۰ و برای حالتهای سالم به ۰ نزدیکتر باشد.

۳- اعتبارسنجی روش پیشنهادی

در این بخش، روش پیشنهادی این مطالعه با استفاده از دادههای یک سازه معیار در زمینه پایش سلامت ارزیابی می شود. برای این منظور، در زیربخش های بعدی، ابتدا سازه معیار معرفی می گردد. سپس اعتبار روش پیشنهادی در این مطالعه مورد بررسی قرار می گیرد. در نهایت در بخش آخر، سرعت CNNها مورد بحث قرار می گیرد.

۳– ۱– سازه معیار

در این مطالعه به منظور بررسی عملیاتی الگوریتم پیشنهادی، از دادههای مربوط به یک سازه آزمایشگاهی بزرگ مقیاس استفاده شده است. این سازه آزمایشگاهی' (QUGS) که توسط محققین دانشگاه قطر ساخته شده است، یک شبیهسازی از جایگاه تماشاگران در ورزشگاه است. سازه QUGS در

شکل ۵ نشان داده شده است. QUGS یک سازه فولادی آزمایشگاهی با هشت شاهتیر و ۲۵ تیر پرکننده که بر روی چهار ستون قرار دارند، است. شبیه ساز جایگاه تماشاگران برای میزبانی از ۳۰ تماشاگر با ابعاد ۴/۲ متر × ۴/۲ متر طراحی شده است [۳۵]. به منظور ثبت پاسخهای دینامیکی سازه ۴/۳ متر طراحی شده است [۳۵]. به منظور ثبت پاسخهای دینامیکی سازه ۳۰ شتاب سنج بر روی تیرهای اصلی و در محل مفصل ها تعبیه شده است. خرابی در سازه مورد بررسی از طریق شل کردن پیچها در اتصالات تیر به نیر شبیه سازی شده است. همچنین نیروی محرکه لرزاننده مورد استفاده نویز سفید بوده و داده ها در فرکانس نمونه برداری ۱۰۲۴ هرتز از تمامی شتاب سنجها به طور همزمان جمع آوری شده اند. این روش برای هر مورد دو بار تکرار شده و نتایج به صورت دو مجموعه داده ارائه شده است.

۳- ۲- نتایج سناریوهای اصلی

در این مرحله، برای اعتبارسنجی روش پیشنهادی، برای ده مفصل از سازه ذکر شده عملیات پایش سلامت انجام شده است. مجموعه داده مورد استفاده شامل دادههای به دست آمده از این ده مفصل است، که در مجموع ۱۳ سناریو متفاوت را تشکیل میدهد. این سناریوها شامل ده مورد آسیب منفرد در هر یک از مفصلها، دو مورد آسیب دو عضوی و حالت سالم سازه

^{1.} Qatar University Grandstand Simulator

جدول ۱. نحوه انتخاب شتابسنج برای هر مفصل

Table 1. Selection of accelerometers for each joint

شماره مفصل									
١	٢	٣	۴	۵	۶	٧	٨	٩	١.
۶ – ۲ – ۱	۳ – ۲ – ۱	4 - 4 - 4	۵ - ۴ - ۳	۶ – ۵ – ۴	۷ – ۶ – ۵	$\lambda - Y - P$	$9 - \lambda - V$	۱۰ – ۹ – ۸	۵ – ۹ – ۵

جدول ۲. نتایج الگوریتم پیشنهادی بر روی دادههای آموزش، آزمایش و اعتبارسنجی

ه ا ، که	مجموعه داده آموزش	مجموعه داده آزمایش	مجموعه داده اعتبارسنجي
سماره سبكه	دقت	دقت	دقت
١	۱/۰۰۰	•/٩٩٨	•/٩٩٨
٢	•/٩٩٨	•/٩٩٨	•/٩٨١
٣	•/٩٩٩	•/٩٩٦	•/٩٩٤
۴	۱/۰۰۰	•/٩٩٩	١/٠٠٠
۵	•/٩٨٩	•/٩٩٦	•/٩٩٦
۶	۱/۰۰۰	•/٩٩٩	•/٩٩٩
٧	۱/۰۰۰	۱/۰۰۰	۱/۰۰۰
٨	•/٩٩٩	•/٩٩٧	•/٩٩٧
٩	۱/۰۰۰	•/٩٩٧	•/٩٩٩
١.	•/٩٩٧	•/٩٩٨	•/٩٩٣

Table 2. Results of the proposed algorithm on training, testing, and validation data

است. هر مجموعه داده شامل ۲۶۲۱۴۴ نمونه شتاب ثبت شده در ۲۵۶ ثانیه است. بدین منظور، ۵۰ درصد از مجموعه داده الف به سیگنالهایی با طول ثابت ۲۵۶ نمونه تقسیم شدند تا ده CNN دوبعدی را با استفاده از روش توضیح داده شده آموزش دهند. همینطور ۱۲/۵ درصد از دادههای همین مجموعه برای آزمایش CNNها استفاده شد. علاوه بر این، ۵۰ درصد از مجموعه داده ب نیز به عنوان مجموعه داده اعتبارسنجی مورد بررسی قرار گرفت.

CNN جدول ۱ انتخاب شتابسنجها را نشان میدهد. معماری پایه هر CNN از معماری بیان شده در شکل ۲ پیروی می کند اما انتخاب ابرپارامترها در هر CNN با استفاده از جستجوی حریصانه برای هر عضو به صورت جداگانه بهینهسازی شده است. CNNها با زبان برنامهنویسی پایتون نوشته شدهاند

و رایانه مورد استفاده در این پژوهش دارای سیپییو^۱ -Intel Core i7 بوده است. 4720HQ و کارت گرافیک^۲ NVIDIA GTX 950m بوده است.

پس از آموزش، روش پیشنهادی به طور متوسط دقت ۹۹/۸ درصد بر روی مجموعه دادههای آموزشی و ۹۹/۶ درصد را بر روی مجموعه دادههای اعتبارسنجی نشان داد. جزئیات دقت هر CNN در مجموعه دادههای ذکر شده در جدول ۲ ارائه شده است. همانطور که مشاهده می شود روش پیشنهادی علاوه بر دقت میانگین بالا، در هر یک اعضا نیز حداقل ۹۹/۷ درصد دقت را حفظ کرده که نشان دهنده قدرت بالای شبکه در تشخیص خرابی در تمامی حالتها است.

^{1.} Central Processing Unit (CPU)

^{2.} Graphics Processing Unit (GPU)

	شماره اتصال									
سناريوی خرابی)	۲	٣	۴	۵	۶	٧	٨	٩	١٠
١	१९/۲	•/•	•/•	•/•	•/•	•/•	• / •	•/•	•/٨	•/•
۲	•/•	۱۰۰/۰	•/•	•/•	•/•	•/•	•/•	•/•	•/•	•/•
٣	•/•	•/•	१९/ ४	•/•	٣/١	•/•	•/•	• /٨	•/•	•/•
۴	•/•	•/•	۱/۶	۱۰۰/۰	•/•	•/•	•/•	•/•	۱/۶	•/•
۵	•/•	• / •	• / •	•/•	१९/ ४	•/•	•/•	•/•	•/•	• / •
۶	•/•	• / •	• / •	•/•	• / •	۱۰۰/۰	•/•	•/•	•/•	• / •
٧	•/•	•/٨	• / ٨	•/•	• / •	•/•	۱۰۰/۰	•/•	•/•	• / •
٨	•/•	۱/۶	• / •	•/•	• / •	•/•	•/•	१९/۲	•/•	• / •
٩	•/•	• / •	• / •	•/•	• / •	•/•	•/•	•/•	१९/۲	• / ٨
۱.	•/٨	• / •	• / •	•/•	• / •	•/٨	•/•	•/•	•/•	۱۰۰/۰
۵-۱	٩٨/۴	• / •	• / •	•/•	٩٨/۴	•/•	•/•	•/•	•/•	• / •
۴-۳	•/•	• / •	٩٨/۴	۹۹/۲	• / •	• / •	•/•	۲/۳	•/•	• / ٨
بدون خرابی	•/•	•/•	• / •	•/•	• / •	•/•	•/•	•/•	•/٨	۱/۶
دقت بر اساس هر اتصا	१९/४۶	१९/८४	99/84	۹۹/۹۴	۹٩/۵٨	۹۹/۹۴	۱۰۰/۰۰	१९/४•	१९/४•	१९/४۶

جدول ۳. نتایج روش پیشنهادی در سناریوهای مختلف خرابی

Table 3. Results of the proposed method in various damage scenarios

در ادامه مجموعه دادههای آزمایش برای نشان دادن نحوه مکانیابی خرابی استفاده شده است. جدول ۳ مقدار DP محاسبه شده توسط شبکه CNNها را برای هر مفصل در سازه نشان میدهد. در تمام ۱۳ سناریو، مقدار DP محاسبه شده مفصلهای آسیب دیده بیش از ۹۸/۴ درصد بوده است، در حالی که این مقدار برای مفصلهای سالم از ۳/۱ درصد عبور نکرده است. اختلاف واضح در مقدار DP محاسبه شده برای مفصلها در دو حالت سالم و خراب نشان دهنده عملکرد تقریبا بینقص روش معرفی شده در این پژوهش است.

تحلیل دادههای جدول ۳ نشان میدهد که روش پیشنهادی در شناسایی و تشخیص خرابیها در سناریوهای مختلف بسیار موفق عمل کرده است. به طور مثال، در سناریوی خرابی شماره ۱، مقدار PD محاسبه شده برای اتصال شماره ۱ به ۹۹/۲ رسیده است که نشاندهنده قابلیت بالای روش در تشخیص دقیق خرابیهاست. همچنین، در سناریوی خرابی شماره ۷، تنها اتصالات شماره ۲ و ۳ دچار خطای اندکی شدهاند (DP=۰/۸) که با توجه

به احتمال خرابی محاسبه شده برای مفصل آسیب دیده (۱۰۰) و اختلاف واضح بین این دو مقدار، خطای پیش آمده قابل چشم پوشی است. از سوی دیگر، سناریوی بدون خرابی نیز نشان میدهد که روش پیشنهادی در شرایط عادی و بدون وجود خرابی نیز میتواند با دقت بالایی عمل کند، که این امر اهمیت توانایی روش در تشخیص عدم وجود خرابی را مورد تأکید قرار میدهد. نتایج همچنین نشان میدهند که روش پیشنهادی قادر به تمایز بین سناریوهای خرابی همزمان است. در سناریوی ۱–۵، خرابی اتصالات ۱ و ۵، خرابی در هر دو مفصل با دقت بالایی، احتمال خرابی برای سایر اتصالات ب داده شده است؛ این در حالی است که احتمال خرابی برای سایر اتصالات به درستی عدد صفر محاسبه شده است. در مجموع، نتایج حاکی از آن است که روش پیشنهادی میتواند به عنوان یک راهکار موثر و قابل اعتماد در تشخیص خرابیها در سناریوهای مختلف مورد استفاده قرار گیرد. در شکل ۶ نمودار تشخیص خرابی ای در ای ۳ سناریوی مشخص خرابی از طریق نمودار نشان داده شده است.





شکل ۶. محاسبه احتمال آسیبدیدگی در سناریوهای خرابی در مفصل الف) شماره ۹ ب) شماره ۱۰ ج) شماره ۱ و ۵ به طور همزمان د) شماره ۳ و ٤ به طور همزمان؛

Fig. 6. Damage probability estimation in damage scenarios for joint: a) number 9 b) number 10 c) numbers 1 and 5 simultaneously d) numbers 3 and 4 simultaneously

۳– ۳– بررسی خرابی با استفاده از سنسورهای دور از محل خرابی

همانطور که پیشتر اشاره شد، فرض این پژوهش بر این بوده که سنسورهای نزدیکتر به محل خرابی دادههای با ارزشتری به منظور تشخیص و مکانیابی خرابی در سازه ارائه میدهند. از این رو به منظور بررسی این فرضیه، در این بخش دو سناریوی دیگر خرابی اینبار با استفاده از دادههای مربوط به دورترین سنسورها بررسی شده و نتایج با سناریوهای اصلی مقایسه می شود.

دو مفصل انتخاب شده برای این بخش مفصلهای شماره ۱ و ۱۰ هستند که بیشترین فاصله مکانی را نسبت به یکدیگر دارند. برای بررسی خرابی در مفصل شماره ۱ از سه سنسور نزدیک به مفصل ۱۰ (سنسورهای شماره ۵، ۹ و ۱۰) و برای تشخیص خرابی مفصل ۱۰ از دورترین سنسورهای

ممکن نسبت به همان مفصل (سنسورهای شماره ۱، ۲ و ۶) استفاده شده است. در ادامه به همان نسبتهای قبلی دادههای آموزشی و اعتبارسنجی انتخاب شده و برای تشخیص خرابی در این دو مفصل، دو شبکه عصبی پیچشی به شرحی که در بخش ۲ آمده آموزش داده شده است. جدول ۴ نتایج این دو سناریو را با حالت اصلی آنها مقایسه میکند.

همانطور که از جدول ۴ مشخص است، در هر دو سناریوی بررسی شده دقت تشخیص خرابی در روش پیشنهاد شده (انتخاب سنسورهای نزدیک) بالاتر است. در سناریوهای مربوط به مفصلهای ۱ و ۱۰، دقت در استفاده از سنسورهای نزدیک به ترتیب ۹۹۸/۰ و ۹۸۱/۰ در مجموعه داده اعتبارسنجی بدست آمده است، در حالی که در سناریوهای مربوط به سنسورهای دور، دقت به ترتیب به ۹۴۸/۰ و ۹/۹۳۹ کاهش مییابد. این نتایج نشان میدهد که جدول ۴. مقایسه نتایج روش پیشنهادی در سناریوهای تشخیص خرابی با سنسورهای نزدیک و دور از محل خرابی

	مجموعه داده آموزش	مجموعه داده اعتبارسنجى
 سناريو	دقت	دقت
مفصل ۱- سنسورهای نزدیک	۱/۰۰۰	٠/٩٩ <u>٨</u>
مفصل ۱- سنسورهای دور	•/٩٧۴	•/٩۴٨
مفصل ۱۰- سنسورهای نزدیک	•/٩٩٨	٠/٩٨١
مفصل ۱۰- سنسورهای دور	٠/٩۶١	• /9٣٩

 Table 4. Comparison of the proposed method results in damage detection scenarios with sensors near and far from the damage location

جدول ۵. زمان مورد نیاز روش پیشنهادی برای پردازش سیگنال ورودی بر حسب میلی ثانیه

Table 5. Processing	time required	by the proposed	method for the inp	ut signal (in milliseconds)
---------------------	---------------	-----------------	--------------------	-----------------------------

		شماره شبکه										
		١	۲	٣	۴	۵	۶	۷	٨	٩	۱۰	میانگین
GPU	۳۲ ثانیه پاسخ شتاب	۶٩	۷٣	۶٩	۶٩	۶٩	۶٩	٩	٩	۷۳	49	۶۷/۸
	یک فریم شامل ۱۲۸ نمونه شتاب	٠/۵	• /۶	٠/۵	•/۵	•/۵	• /۵	•/۵	• /۵	• /۶	٠/۴	•/۵
CPU	۳۲ ثانیه پاسخ شتاب	Υ٨	٨٢	٨٢	۲۱	Y٨	٧۴	٨٠	۷۶	٨٢	49	V۵/٣
	یک فریم شامل ۱۲۸ نمونه شتاب	•/8	•/۶	• 8	• 8	• /8	• 8	• /8	• 8	• 8	۰/۴	• /۶

روش پیشنهاد شده با استفاده از سنسورهای نزدیک به محل خرابی مؤثرتر است و فرض اولیه این پژوهش را تایید میکند. از آنجا که سنسورهای نزدیک اطلاعات بیشتری در مورد خرابی جمعآوری میکنند، پیشنهاد میشود که این سنسورها در اولویت انتخاب برای تشخیص خرابی قرار بگیرند.

با این حال، حتی با استفاده از سنسورهای دور، دقت تشخیص خرابی در محدوده قابل قبول قرار دارد. در هر دو سناریو بررسی شده با سنسورهای دور، دقت بالاتر از ۰/۹۳۹ برای مجموعه دادههای آموزش و اعتبارسنجی نشان میدهد که این روش حتی زمانی که سنسورها در فاصله بیشتری از محل خرابی قرار دارند قابل اطمینان است. بنابراین اگرچه استفاده از سنسورهای نزدیک ترجیح داده میشود، اما سنسورهای دور نیز میتوانند به عنوان یک گزینه مناسب جایگزین در سناریوهای مختلف عمل کنند.

۳– ۴– سرعت پردازش شبکهها

به منظور محاسبه سرعت عملکرد شبکه CNN پیشنهادی، ۳۳ ثانیه از پاسخ شتاب سازه توسط هر یک از شبکههای آموزش داده شده بر روی CPU و GPU پردازش و زمان متوسط برای هر دسته سیگنال محاسبه شد. این عملیات ۳۰ بار تکرار و میانگین گیری شد تا نتایج قابل اعتماد به دست آید. همانطور که در جدول ۵ نشان داده شده است، میانگین زمان برای پردازش یک سیگنال ۳۲ ثانیهای حدود ۶۸ میلی ثانیه بر روی GPU و ۷۳ میلی ثانیه با استفاده از CPU بوده است. همانطور که مشاهده می شود زمان مورد نیاز برای پردازش یک فریم در هنگام استفاده از CPU یا GPU تفاوت قابل توجهی نداشته است که دلیل آن معماری نسبتا فشرده شبکه است. با این حال، زمان مورد نیاز برای طبقهبندی یک سیگنال یک ثانیهای

منابع

- J.M. Ko, Y.Q. Ni, Technology developments in structural health monitoring of large-scale bridges, Engineering Structures, 2005, pp. 1715-1725.
- [2] F. Magalhães, A. Cunha, E. Caetano, Vibration based structural health monitoring of an arch bridge: From automated OMA to damage detection, Mechanical Systems and Signal Processing, 2012, pp. 212-228.
- [3] A.B. Noel, A. Abdaoui, T. Elfouly, M.H. Ahmed, A. Badawy, M.S. Shehata, Structural Health Monitoring Using Wireless Sensor Networks: A Comprehensive Survey, IEEE Communications Surveys and Tutorials, 2017, pp. 1403-1423.
- [4] S. Teng, G. Chen, P. Gong, G. Liu, F. Cui, Structural damage detection using convolutional neural networks combining strain energy and dynamic response, Meccanica, Springer Netherlands, 2020, pp. 945-959.
- [5] C.R. Farrar, S.W. Doebling, D.A. Nix, Vibrationbased structural damage identification, Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2001, pp. 131-149.
- [6] W. Fan, P. Qiao, Vibration-based damage identification methods: A review and comparative study, Structural Health Monitoring, SAGE PublicationsSage UK: London, England, 2011, pp. 83-111.
- [7] S. Das, P. Saha, S.K. Patro, Vibration-based damage detection techniques used for health monitoring of structures: a review, Journal of Civil Structural Health Monitoring, 6(3) (2016) 477-507.
- [8] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, D.J. Inman, Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks, Journal of Sound and Vibration, Elsevier, 2017, pp. 154-170.
- [9] H. Liu, Y. Zhang, Deep learning-based brace damage detection for concentrically braced frame structures under seismic loadings, Advances in Structural Engineering, 2019, pp. 3473-3486.
- [10] L. Jing, M. Zhao, P. Li, X. Xu, A convolutional neural

برای هر CNN تقریباً ۲ میلی ثانیه است که نشان میدهد این روش نه تنها دقت بسیار بالایی دارد بلکه سرعت پردازش آن نیز بالا بوده و استانداردهای مورد نیاز برای پردازش برخط را دارا می باشد.

۴- نتیجهگیری

یکی از چالش های اصلی در تشخیص خرابی سازه، تشخیص ویژگی های حساس به خرابی در سازه است [۴۲]. این مقاله با ارائه یک چار چوب تشخیص و محل یابی سریع و دقیق خرابی در سازه بر اساس شبکه عصبی پیچشی دوبعدی، به این مشکل پرداخته است. روش پیشنهادی شامل یک فرایند غیرمتمرکز است که در آن به هر عضو از سازه یک شبکه عصبی پیچشی اختصاص داده می شود. از آن جا که ابرپارامترهای هر یک از این شبکههای عصبی پیچشی برای یک عضو خاص بهینه سازی شده است، این روش توانست دقت تشخیص خرابی را به ۹۹/۶ درصد برساند. همینطور از پاسخ شتاب یک سازه بزرگمقیاس آزمایشگاهی برای اعتبارسنجی روش پیشنهاد

- یافتههای اعتبارسنجی نشان میدهند که روش پیشنهادی در شناسایی آسیبهای سازهای در هر دو حالت تکآسیب و دوآسیب، کارآمدی قابل توجهی دارد.
- الگوریتم پیشنهادی قابلیت استخراج ویژگیهای خرابی را به طور مستقیم از سیگنالهای شتاب خام را داشته و نیازی به هیچ پیش پردازش یا استخراج ویژگی ندارد.
- استفاده از سیگنالهای دو شتابسنج اضافی در داده ورودی، منجر به کاهش مقدار اطلاعات مورد نیاز برای آموزش شبکههای عصبی پیچشی میشود. علاوه بر این، این رویکرد امکان پیادهسازی یک شبکه عصبی پیچشی دوبعدی را فراهم میکند که همگرایی سریعتر و قابلیت یادگیری بیشتری نسبت به یک شبکه عصبی پیچشی یک بعدی دارد.
- بر خلاف روشهای سنتی، این تکنیک غیرمتمرکز است و هر شبکه عصبی پیچشی از یک ساختار ساده پیروی میکند. بنابراین، الگوریتم پیشنهادی به توان محاسباتی کمتری نیازمند است و میتوان آن را بر روی رایانههای متوسط نیز اجرا کرد.
- همانطور که در بخش اعتبارسنجی نشان داده شده است، زمان لازم برای ارزیابی دادههای جدید در این الگوریتم بسیار پایین بوده و استانداردهای پردازش برخط را دارا میباشد.

condition assessment techniques, Engineering Structures, Elsevier Ltd, 2021.

- [20] C. Modarres, N. Astorga, E.L. Droguett, V. Meruane, Convolutional neural networks for automated damage recognition and damage type identification, Structural Control and Health Monitoring, John Wiley and Sons Ltd, 2018, pp. e2230.
- [21] A.S.M. Shihavuddin, X. Chen, V. Fedorov, A.N. Christensen, N.A.B. Riis, K. Branner, A.B. Dahl, R.R. Paulsen, Wind turbine surface damage detection by deep learning aided drone inspection analysis, Energies, MDPI AG, 2019, pp. 676.
- [22] K. Lee, N. Byun, D.H. Shin, A Damage Localization Approach for Rahmen Bridge Based on Convolutional Neural Network, KSCE Journal of Civil Engineering, 2020.
- [23] Y. Yu, C. Wang, X. Gu, J. Li, A novel deep learningbased method for damage identification of smart building structures, Structural Health Monitoring, 2019, pp. 143-163.
- [24] B.K. Oh, S.H. Lee, H.S. Park, Damage localization method for building structures based on the interrelation of dynamic displacement measurements using convolutional neural network, Structural Control and Health Monitoring, 2020, pp. 1-16.
- [25] 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.
- [26] T. Zhang, S. Biswal, Y. Wang, SHMnet: Condition assessment of bolted connection with beyond humanlevel performance, Structural Health Monitoring, 2020, pp. 1188-1201.
- [27] M. Azimi, G. Pekcan, Structural health monitoring using extremely compressed data through deep learning, Computer-Aided Civil and Infrastructure Engineering, 2020, pp. 597-614.
- [28] H.V. Dang, M. Raza, T.V. Nguyen, T. Bui-Tien, H.X. Nguyen, Deep learning-based detection of

network based feature learning and fault diagnosis method for the condition monitoring of gearbox, Measurement: Journal of the International Measurement Confederation, Elsevier B.V., 2017, pp. 1-10.

- [11] K. He, X. Zhang, S. Ren, J. Sun, Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016, pp. 770-778.
- [12] J. Han, H. Chen, N. Liu, C. Yan, X. Li, CNNs-Based RGB-D Saliency Detection via Cross-View Transfer and Multiview Fusion, IEEE Transactions on Cybernetics, 2018, pp. 3171-3183.
- [13] T.N. Sainath, B. Kingsbury, G. Saon, H. Soltau, A.-r. Mohamed, G. Dahl, B. Ramabhadran, Deep Convolutional Neural Networks for Large-scale Speech Tasks, Neural Networks, 64 (2015) 39-48.
- [14] F. Ordóñez, D. Roggen, Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition, Sensors, 2016, pp. 115.
- [15] S. Kiranyaz, T. Ince, M. Gabbouj, Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks, IEEE Transactions on Biomedical Engineering, 2016, pp. 664-675.
- [16] 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, 2018, pp. 439-453.
- [17] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, D.J. Inman, 1D convolutional neural networks and applications: A survey, Mechanical Systems and Signal Processing, The Author(s), 2021, pp. 107398.
- [18] S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci, M. Gabbouj, 1-D Convolutional Neural Networks for Signal Processing Applications, ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings, 2019, pp. 8360-8364.
- [19] S. Sony, K. Dunphy, A. Sadhu, M. Capretz, A systematic review of convolutional neural network-based structural

O. Celik, H. Zhang, Dynamic Testing of a Laboratory Stadium Structure, Geotechnical and Structural Engineering Congress 2016, American Society of Civil Engineers, Reston, VA, 2016, pp. 1719-1728.

- [36] X. Glorot, A. Bordes, Y. Bengio, Deep Sparse Rectifier Neural Networks, in, JMLR Workshop and Conference Proceedings, 2011, pp. 315-323.
- [37] V. Nair, G.E. Hinton, Rectified linear units improve Restricted Boltzmann machines, ICML 2010 -Proceedings, 27th International Conference on Machine Learning, 2010, pp. 807-814.
- [38] A. Krizhevsky, I. Sutskever, G.E. Hinton, ImageNet classification with deep convolutional neural networks, Communications of the ACM, 2017, pp. 84-90.
- [39] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, Dropout: A simple way to prevent neural networks from overfitting, Journal of Machine Learning Research, 2014, pp. 1929-1958.
- [40] B.Y. Goodfellow lan, Courville Aaron, Deep Learning
 Ian Goodfellow, Yoshua Bengio, Aaron Courville -Google Books, MIT Press, 2016, pp. 800.
- [41] D.P. Kingma, J.L. Ba, Adam: A method for stochastic optimization, 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, International Conference on Learning Representations, ICLR, 2015.
- [42] R. Doroudi, S.H.H. Lavassani, M. Shahrouzi, Damage detection for long-span bridges through support vector machine, wavelet transform, and multivariate empirical mode decomposition, Int. J. Struct. Eng., 14(2) (2024) 164-185

structural damage using time-series data, Structure and Infrastructure Engineering, Taylor & Francis, 2020, pp. 1-20.

- [29] Z. Mousavi, M.M. Ettefagh, M.H. Sadeghi, S.N. Razavi, Developing deep neural network for damage detection of beam-like structures using dynamic response based on FE model and real healthy state, Applied Acoustics, Elsevier Ltd, 2020, pp. 107402.
- [30] T. Guo, L. Wu, C. Wang, Z. Xu, Damage detection in a novel deep-learning framework: a robust method for feature extraction, Structural Health Monitoring, 2020, pp. 424-442.
- [31] O. Avci, O. Abdeljaber, S. Kiranyaz, D. Inman, Structural damage detection in real time: Implementation of 1D convolutional neural networks for SHM applications, Conference Proceedings of the Society for Experimental Mechanics Series, 2017, pp. 49-54.
- [32] O. Avci, O. Abdeljaber, S. Kiranyaz, M. Hussein, D.J. Inman, Wireless and real-time structural damage detection: A novel decentralized method for wireless sensor networks, Journal of Sound and Vibration, Elsevier Ltd, 2018, pp. 158-172.
- [33] O. Abdeljaber, O. Avci, M.S. Kiranyaz, B. Boashash, H. Sodano, D.J. Inman, 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data, Neurocomputing, Elsevier B.V., 2018, pp. 1308-1317.
- [34] O. Avci, O. Abdeljaber, S. Kiranyaz, D. Inman, Convolutional Neural Networks for Real-Time and Wireless Damage Detection, in, 2020, pp. 129-136.
- [35] O. Abdeljaber, A. Younis, O. Avci, N. Catbas, M. Gul,

چگونه به این مقاله ارجاع دهیم Sh. Ghazvineh, Gh. R. Nouri, S. H. Hosseini Lavassani, Vibrational-Based Damage Localization of Bending Frames Using CNNs, Amirkabir J. Civil Eng., 57(2) (2025) 363-380.

DOI: <u>10.22060/ceej.2025.22437.7977</u>

