



Data-driven and unsupervised damage detection in frame structures using deep neural networks

Omid Allahyari Pargu¹ , Gholamreza Nasirpour² , Akbar Asgharzadeh-Bonab^{*2} ,
Amirhossein Babapour³

1. M.Sc, Department of Civil Engineering, Faculty of Engineering, Kharazmi University, Tehran, Iran

1. Assistant professor, Department of Science and Technology Studies, AJA Command and Staff University, Tehran, Iran

1. M.Sc. Student, Department of Mechanical Engineering, Semnan University, Semnan, Iran

Abstract

Damage detection, aimed at preventing overall structural failure and enabling planned repair and rehabilitation, has been a significant research focus in recent years. Data-driven structural health monitoring through structural response analysis constitutes the core of contemporary studies. This approach utilises artificial intelligence tools, particularly artificial neural networks, to eliminate the need for complex preprocessing of time-series data and achieve more accurate results compared to traditional structural health monitoring and damage detection methods. In this study, an unsupervised deep neural network (convolutional autoencoder) is proposed to reconstruct input data and employ the reconstruction error as a damage-sensitive feature. The findings demonstrate that the proposed model achieves highly accurate damage detection across various structural conditions, despite being trained solely on healthy structural data. Moreover, the model exhibits favourable performance in terms of the number of training parameters and computational effort. Finally, to validate the effectiveness of the model, the results are compared with those of similar studies, demonstrating superior accuracy.

Keywords

Structural Damage Detection
Structural Health Monitoring
Anomaly Detection
Deep Neural Networks
Unsupervised Learning

Received: 05.07.2025

Revised: ---.---.---

Accepted: 31.08.2025

*Corresponding Author

Akbar Asgharzadeh-Bonab

Email

a.asgharzadeh@urmia.ac.ir

1- Introduction

Structural health monitoring (SHM) and damage detection aim to provide a system that, in the event of damage, issues an alert to prevent overall structural failure and enables timely repair and rehabilitation of affected areas. This process is carried out through vibration-based methods, where sensor data are collected and analyzed. Over the past decades, both data-driven and model-based vibration methods have been dominant approaches in SHM research. Data-driven methods offer

advantages such as reduced cost, ease of implementation, and real-time inspection capability [1-2]. Unlike model-based approaches, Data-driven methods rely on statistical models, accelerate decision-making and yield more robust results in noisy environments, without requiring prior information or assumptions about the structure [3-4]. In data-driven SHM, the type of data used is crucial. Most recent studies adopt supervised approaches that require access to both healthy and

How to Cite this Article:

[1] O. Allahyari Pargu, G. Nasirpour, A. Asgharzadeh-Bonab, and A. Babapour, "Data-driven and unsupervised damage detection in frame structures using deep neural networks," *Journal of Science and Technology in Mechanical Engineering*, Vol. 4, No. 2, pp. 65–81, 2026. <https://doi.org/10.22034/stme.2025.532643.1142>. (in Persian)



©2026 the authors. Published by Technical and Vocational University (TVU), Tehran, Iran. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution-Noncommercial 4.0 International (CC BY-NC License) (<https://creativecommons.org/licenses/by-nc/4.0/>)

E-ISSN: 2981-2232

damaged data for pattern recognition or classification. However, collecting and labeling damage data is often costly, time-consuming, and sometimes infeasible. Therefore, developing methods that match the nature of available structural data is essential for continuous monitoring and reliable damage detection.

The main contribution of this paper is an unsupervised, data-driven damage detection method with a novel framework and architecture for frame-like structures, relying solely on healthy data. The proposed approach employs acceleration response measurements from the undamaged structure. Statistical indicators from a hybrid model are used as damage-sensitive features. As a result, reliable structural state identification is achieved even under varying operational conditions. The proposed method is validated using the Los Alamos three-story test structure [5].

2- Research Methods

This study introduces an unsupervised, data-driven damage detection method for frame-like structures that relies solely on healthy-state information. The approach is based on anomaly detection concepts. In this framework, the normal behavior of structural data is collected and labeled over a specified time period to form a reference baseline. The trained model then evaluates incoming data and determines whether they conform to the baseline (normal) or deviate from it (anomalous). During the anomaly-based detection process, structural responses in their current healthy condition are continuously collected to establish the baseline state. Once the model is trained, future test data (capturing structural features at later times) are compared against this baseline, and any deviation indicates the occurrence of damage. Machine learning models and artificial neural networks are employed due to their strong learning capacity, computational efficiency, ability to process large datasets, and capability to capture complex patterns [6].

3- Results

The developed Deep Neural Network model (Convolutional Autoencoder (CAE)) in this study demonstrates several notable advantages that justify its effectiveness in learning and reconstructing data. The CAE effectively reduces the dimensionality of the input data (the latent layer dimension is one-eighth of the original input), while preserving spatial hierarchies. The symmetric CAE structure (with convolution and deconvolution layers) identifies key features during the encoding stage and effectively reconstructs them during decoding. Results demonstrate the strong performance of the model in distinguishing between healthy and damaged structural states, even under varying operational conditions and nonlinear relationships between states.

4- Conclusion

In this study, an unsupervised, data-driven method for damage detection in frame-like structures was developed. The reconstruction error of a Convolutional Autoencoder (CAE) proved to be a reliable and powerful indicator for structural damage identification. Damage detection was carried out directly using vibration responses under environmental excitation on the LANL benchmark structure, without resorting to complex preprocessing such as signal processing techniques or dimensionality reduction algorithms. The proposed CAE model was trained exclusively on healthy-state data and successfully identified different structural states, with results evaluated through various figures and tables.

The effectiveness of the CAE in accurately recognizing structural conditions is evident, even in the presence of complex dependencies and interactions between different states. Designed with multiple layers, effective dimensionality reduction, and a symmetric architecture, the CAE achieved a strong balance between feature learning and data reconstruction. Experimental findings show that the model achieved a reconstruction error of 0.226% (corresponding to an accuracy of 99.774%) in detecting damage scenarios. In addition, the model

demonstrated efficiency in terms of trainable parameters (231,940 parameters) and computational effort (requiring only 4.5 minutes of training on the benchmark dataset).

5- References

- [1] M. Azimi, A. Dadras Eslamlou, and G. Pekcan, "Data-driven structural health monitoring and damage detection through deep learning: A state-of-the-art review," *Sensors*, Vol. 20, No. 10, p. 2778, 2020. doi: [10.3390/s20102778](https://doi.org/10.3390/s20102778)
- [2] Z. Yuan, S. Zhu, C. Chang, X. Yuan, Q. Zhang, and W. Zhai, "An unsupervised method based on convolutional variational auto-encoder and anomaly detection algorithms for light rail squat localization," *Construction and Building Materials*, Vol. 313, p. 125563, 2021. doi: [10.1016/j.conbuildmat.2021.125563](https://doi.org/10.1016/j.conbuildmat.2021.125563)
- [3] K. Eltouny and X. Liang, "Large-scale structural health monitoring using composite recurrent neural networks and grid environments," *Computer-Aided Civil and Infrastructure Engineering*, Vol. 38, No. 3, pp. 271–287, 2023. doi: [10.1111/mice.12841](https://doi.org/10.1111/mice.12841)
- [4] M. Z. Sarwar and D. Cantero, "Probabilistic autoencoder-based bridge damage assessment using train-induced responses," *Mechanical Systems and Signal Processing*, Vol. 208, p. 111046, 2024. doi: [10.1016/j.ymssp.2024.111046](https://doi.org/10.1016/j.ymssp.2024.111046).
- [5] E. Figueiredo, G. Park, J. Figueiras, C. Farrar, and K. Worden, "Structural health monitoring algorithm comparisons using standard data sets," Los Alamos National Lab, 2009. doi: [10.2172/947958](https://doi.org/10.2172/947958)
- [6] C. Farrar, S. Doebling, and D. Nix, "Vibration-based structural damage identification," *Philos. Trans. R. Soc. A*, Vol. 359, No. 1778, pp. 131–149, 2001. doi: [10.1098/rsta.2000.0735](https://doi.org/10.1098/rsta.2000.0735)



تشخیص داده‌محور و بدون نظارت آسیب در سازه‌های قابی شکل، با به‌کارگیری مدل‌های شبکه

عصبی عمیق

امید اللهیاری پرگو^۱، غلامرضا نصیرپور^۲، اکبر اصغرزاده بناب^{۳*}، امیر حسین باباپور^۳

۱- کارشناس ارشد، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه خوارزمی، تهران، ایران

۲- استادیار، گروه مطالعات علم و فناوری، دانشگاه فرماندهی و ستاد آجا، تهران، ایران

۳- دانشجوی کارشناسی ارشد، دانشکده مهندسی مکانیک، دانشگاه سمنان، سمنان، ایران

چکیده

تشخیص آسیب، باهدف جلوگیری از خرابی کلی سازه، ترمیم و بازسازی برنامه‌ریزی شده، حوزه تحقیقات مهم سال‌های اخیر بوده‌است. پایش سلامت سازه با رویکرد داده‌محور بوسیله تحلیل پاسخ سازه موضوع اصلی پژوهش‌های سال‌های اخیر است. در این رویکرد با به‌کارگیری ابزار هوش مصنوعی خصوصاً شبکه‌های عصبی مصنوعی، نیاز به پیش‌پردازش پیچیده داده‌های سری زمانی را برطرف شده و نتایج دقیق‌تری نسبت به رویکردهای گذشته پایش سلامت سازه و تشخیص آسیب حاصل شده‌ست. در این پژوهش، یک شبکه عصبی عمیق بدون نظارت، (خودمزگذار پیشی) باهدف بازسازی داده ورودی و استفاده از خطای بازسازی آن به‌عنوان شاخص حساس به آسیب ارائه شده‌است. یافته‌ها نشان داده است مدل مورد نظر، با دقت ۹۹/۷۷۴٪، نتایج دقیقی در تشخیص آسیب وضعیت مختلف سازه با وجود آموزش صرفاً بر اساس داده‌های سالم سازه به همراه داشته؛ همچنین مدل موردنظر از نظر تعداد پارامترهای آموزش و تلاش محاسباتی عملکرد مطلوبی ارائه داده‌است. در انتها جهت اثبات کارایی مدل، نتایج با پژوهش‌های مشابه مقایسه گردیده که حاکی از نتایجی دقیق‌تر از آن‌ها است.

کلمات کلیدی

تشخیص آسیب سازه‌ای
پایش سلامت سازه
تشخیص ناهنجاری
شبکه عصبی عمیق
یادگیری بدون نظارت

دریافت مقاله: ۱۴۰۴/۰۴/۱۴

بازنگری مقاله: ---/--/---

پذیرش مقاله: ۱۴۰۴/۰۶/۰۹

*نویسنده مسئول

اکبر اصغرزاده بناب

ایمیل

a.asgharzadeh@urmia.ac.ir

۱- مقدمه

نویز نتایج مؤثرتری ارائه می‌دهند. همچنین، این روش‌ها نیاز به اطلاعات پیشین و مفروضات اولیه در مورد سیستم سازه ندارند [۵]. روش‌های داده‌محور SHM به دلیل ماهیت غیرمخرب و عدم وابستگی به اطلاعات قبلی درباره محل، نوع یا گستره آسیب، بسیار جذاب هستند [۶].

با فرض پایش و تشخیص آسیب داده محور، نوع داده بکارگرفته‌شده مهم است. تشخیص داده‌محور بر اساس دسترسی به اطلاعات سالم و آسیب‌دیده سازه (تشخیص الگو، دسته‌بندی) رویکرد غالب پژوهش‌های اخیر بوده است [۷]. در این رویکرد الگوریتم‌ها و مدل‌ها، به هر دو گروه داده مرتبط با وضعیت سالم و آسیب‌دیده سازه

پایش سلامت سازه و تشخیص آسیب، فراهم‌سازی سامانه‌ای است که در صورت بروز آسیب و خسارت، با هشدار، از خرابی کلی سازه جلوگیری کند و زمینه را برای ترمیم و بازسازی نقاط آسیب‌دیده فراهم سازد. این کار به‌وسیله جمع‌آوری و تحلیل پاسخ سازه توسط حسگرها انجام می‌شود که روش‌های ارتعاشی نامیده می‌شوند. روش‌های ارتعاشی مبتنی بر داده [۱] و مدل در چند دهه اخیر رویکردهای غالب پژوهش‌های حوزه SHM بوده‌اند. از جمله مزایای این روش‌ها کاهش هزینه، سهولت اجرا و امکان بازرسی بلادرنگ است [۲ و ۳]. برخلاف روش‌های مدل‌محور، روش‌های داده‌محور مبتنی بر مدل‌های آماری هستند [۴]؛ فرآیند تصمیم‌گیری را سریع‌تر نموده و در محیط‌های پر

How to Cite this Article:

[1] O. Allahyari Pargu, G. Nasirpour, A. Asgharzadeh-Bonab, and A. Babapour, "Data-driven and unsupervised damage detection in frame structures using deep neural networks," *Journal of Science and Technology in Mechanical Engineering*, Vol. 4, No. 2, pp. 65-81, 2026. <https://doi.org/10.22034/stme.2025.532643.1142>. (in Persian)



این رویکرد تنها از داده‌های پاسخ شتاب اندازه‌گیری شده از سازه در وضعیت سالم استفاده می‌کند.

شاخصه‌های آماری خطای بازسازی یک مدل ترکیبی، متشکل از شبکه عصبی خودرمزگذار و شبکه عصبی پیچشی، به‌عنوان شاخصه حساس به آسیب، در نظر گرفته شده است. علاوه بر هدف اصلی مبنی بر تشخیص بدون نظارت آسیب، در این مقاله مدلی از شبکه‌های عصبی عمیق ارائه شده است؛ که بدون نیاز به پیش‌پردازش زمان‌بر (از جمله الگوریتم‌های پردازش سیگنال یا الگوریتم‌های کاهش داده)، ویژگی‌های حساس به آسیب صرفاً از داده‌های خام حسگرها استخراج شده‌است. سپس تشخیص وضعیت سازه با دقتی قابل‌توجه حتی با وجود شرایط متغیر بهره‌برداری صورت پذیرفته است. سازه مینا سه طبقه آزمایشگاه لس‌آلاموس جهت ارزیابی مدل بکار گرفته شده است. در ادامه در بخش دوم، مشخصات سازه مینا مورد بررسی، توضیح داده شده‌است. در بخش سوم، چارچوب رویکرد پیشنهادی و معماری مدل پیشنهادی با جزئیات شرح داده شده است. نتایج پژوهش در بخش چهارم و در نهایت در بخش پنجم به جمع‌بندی پرداخته شده است.

۲- مدل اعتبارسنجی (سازه آزمایشگاه لس‌آلاموس)

سازه مینا آزمایشگاه ملی لوس‌آلاموس یک قاب سه طبقه آلومینیومی است [۱۳]. این قاب آن‌طور که در شکل ۱ نشان داده شده است، با اتصالات پیچ و مهره‌ای ساخته شده و هر طبقه، شامل چهار ستون به ارتفاع ۱۷۷ میلی‌متر، طول و عرض ۲۵ میلی‌متر و ضخامت ۶ میلی‌متر به صفحات آلومینیومی مربع شکل با ضلع ۳۰۵ میلی‌متر و ضخامت ۲۵ میلی‌متر متصل است. سازه سه طبقه موردنظر تنها امکان در راستای x را دارد. یک موتور الکترومغناطیسی تحریک را به پایه سازه اعمال می‌کند. چهار شتاب‌سنج در هر طبقه جهت جمع‌آوری پاسخ آن نصب شده‌اند.

برای شبیه‌سازی رفتار غیرخطی در سازه، ستونی کوتاه از سقف آخرین طبقه در تماس با یک ضربه‌گیر نصب شده بر روی طبقه پایین آن، طراحی شده‌است. فاصله ستون و ضربه‌گیر قابل تنظیم است. این مکانیسم جهت شبیه‌سازی ترک‌های خستگی، آسیب در اتصالات سازه و شل شدن پیچ‌ها نیز مورد استفاده قرار گرفته است. با کاهش فاصله ستون و ضربه‌گیر اندرکنش آن‌ها با یکدیگر بیشتر شده و شاهد تأثیر

نیاز دارند. درحالی‌که جمع‌آوری و برچسب‌گذاری داده‌های آموزشی خصوصاً در وضعیت آسیب‌دیده، زمان‌بر، پرهزینه و گاهی غیرعملی است. نتیجتاً پژوهش و توسعه روش‌هایی متناسب با ماهیت اطلاعات موجود سازه‌ها، در زمینه پایش مداوم و تشخیص آسیب^۱ ضروری به‌نظر می‌رسد. ترکیب روش‌های داده‌محور و شبکه‌های عصبی مصنوعی^۲ این مهم را برآورده می‌سازد. این مدل‌ها با تحلیل داده‌ی حسگرها حاصل از ارتعاشات سازه، رفتار غیرخطی سازه می‌آموزند، سپس با استفاده از دانش فراگرفته‌شده، وضعیت داده‌های ورودی جدید را تعیین می‌کنند. قازی‌مقدم و حسین‌زاده یک خودرمزگذار ترکیبی همراه با مکانیزم توجه، برای شناسایی آسیب‌های سازه‌ای توسعه داده و ارزیابی کردند. آن‌ها از نسبت انحراف معیار به قله به‌عنوان ویژگی حساس به آسیب برای کمی‌سازی تفاوت بین وضعیت‌های سالم و ناشناخته بر اساس برآورد آستانه و کشف مکان آسیب استفاده کردند [۸]. در پژوهش دیگری یک خودرمزگذار متغیر برای تقریب توزیع داده‌ها بر اساس آموزش روی داده‌های خام بدون آسیب پیشنهاد شد. سپس، یک ماشین بردار پشتیبانی یک کلاسه برای تشخیص شرایط مختلف بر اساس خطای بازسازی به‌کار برده شد [۹]. در مطالعه‌ای دیگر، پژوهشگران از یک خودرمزگذار متغیر چندهدفه به‌عنوان روشی برای ترکیب داده‌ها برای استخراج ویژگی‌های حساس به آسیب از پاسخ‌های اندازه‌گیری شده و تشخیص آسیب استفاده کردند. علاوه بر این، آن‌ها از توابع فاصله بین امتیازات ناهنجاری هر گره حسگری برای مکان‌یابی و پیش‌بینی شدت آسیب سازه‌ای استفاده کردند [۱۰].

مطالعات نشان داده است، تشخیص آسیب مبتنی بر DNNs، تشخیص آسیب را دقیق، سریع و ایمن کرده است [۵]. همچنین می‌تواند مشکلات داده‌های حجیم^۳ SHM را مدیریت کند [۱۱] و با فناوری‌های جدیدی مانند اینترنت اشیا^۴، شبکه‌های حسگر بی‌سیم^۵ و محاسبات ابری^۶ [۱۲] سازگار است. امکان پردازش مستقیم داده‌ها فراهم است. می‌تواند ارتباط غیرخطی و گاه همراه با هم‌پوشانی میان وضعیت سالم و وضعیت آسیب‌دیده سازه کشف کند. روش موردنظر توانایی در نظر گرفتن تغییرات بهره‌برداری را داشته و نسبت به آن مقاوم است. از این رو نوآوری اصلی این مقاله، یک روش تشخیص داده‌محور و بدون نظارت آسیب، با چارچوب و معماری نوین؛ در سازه‌های قابی شکل، صرفاً بر اساس دسترسی به اطلاعات سالم است.

⁴ Internet of Things (IOT)

⁵ Wireless Sensor Networks (WSNs)

⁶ Cloud Computing

¹ Damage Detection

² Deep Neural Networks


³ Big Data

برای وضعیت‌های ۳ تا ۷، فاصله ضربه‌گیر و ستون به ترتیب مطابق با جدول ۱ تغییر داده شده‌است. در وضعیت‌های ۹ تا ۱۱ سناریوهای آسیب به همراه تغییرات شرایط بهره‌برداری با افزودن جرم در طبقات پایه و اول در نظر گرفته شده‌است. داده‌برداری برای هر یک از سناریوهای معرفی شده طی ده تکرار و در هر یک از دفعات اندازه‌گیری، با فرکانس ۳۲۰ هرتز و به تعداد ۸۱۹۲ نمونه اندازه‌گیری شده است [۱۳].

۳- رویکرد پیشنهادی

رویکرد پیش‌روی این مقاله، یک روش تشخیص داده‌محور و بدون نظارت آسیب، در سازه‌های قابی شکل؛ صرفاً بر اساس دسترسی به اطلاعات سالم است. این رویکرد مبتنی بر مفاهیم تشخیص ناهنجاری است. در این راستا، رفتار داده هنجار طی دوره زمانی مشخص جمع‌آوری و برچسب‌گذاری می‌شود. با استفاده از آن، مدل آموزش داده‌شده و نهایتاً مدل موردنظر با دریافت داده‌ی جدید، وضعیت آن را بررسی نموده و هنجار یا ناهنجار بودن آن، اعلام خواهد شد [۱۴] و [۱۵]. طی پروسه تشخیص آسیب مبتنی بر تشخیص ناهنجاری، اطلاعات از وضعیت سالم سازه (در حقیقت همان شرایط کنونی و فعلی است) در زمان‌های مختلف جمع‌آوری شده و وضعیت مبنا شکل می‌گیرد. پس از آموزش مدل با وضعیت مبنا، داده‌های آزمون (ویژگی‌هایی از سازه در زمان آتی) با وضعیت مبنا مقایسه و ارزیابی شده و نسبت به وضعیت آن‌ها گزارش می‌شود. در نتیجه، هرگونه انحراف، نشان‌دهنده‌ی وقوع آسیب در سازه است. قدم اول در ایجاد یک سامانه تشخیص آسیب، ایجاد یک شبکه از حسگرها به منظور جمع‌آوری پیوسته اطلاعات از نقاط حساس سازه است. حجم عظیمی از داده‌های استخراج‌شده از حسگرها، در راستای تعیین وضعیت سازه و اقدامات پس‌از آن، تحلیل و بررسی می‌گردند. مدل‌های مبتنی بر یادگیری ماشین و شبکه‌های عصبی مصنوعی به دلیل توانایی‌شان در یادگیری قوی و کارایی محاسباتی، همچنین پردازش حجم زیادی از داده‌ها و یادگیری الگوهای پیچیده، بکار گرفته شده‌اند [۱۶]. شکل ۲ چارچوب کلی رویکرد پیشنهادی نمایش داده است. در ادامه به توضیح مبانی مدل‌های بکار گرفته شده پرداخته شده و در انتها مدل پیشنهادی با ذکر جزئیات در فلسفه طراحی، پارامترهای طراحی و نحوه آموزش و عملکرد تبیین گشته است.

بیشتر رفتار غیرخطی در سازه خواهیم بود. شرایط مختلف داده‌برداری به صورت کلی در چهار گروه تقسیم می‌شوند. گروه اول، شرایط پایه است. گروه دوم شامل شرایط پایه‌ای است که در آن سازه تغییراتی در سختی به دلیل تغییرات بهره‌برداری داشته است. گروه سوم تداعی کننده شرایط آسیب غیرخطی که توسط یک ضربه‌گیر ایجاد شده است. گروه چهارم شامل شرایط ترکیب آسیب‌های غیرخطی و تغییرات بهره‌برداری است.

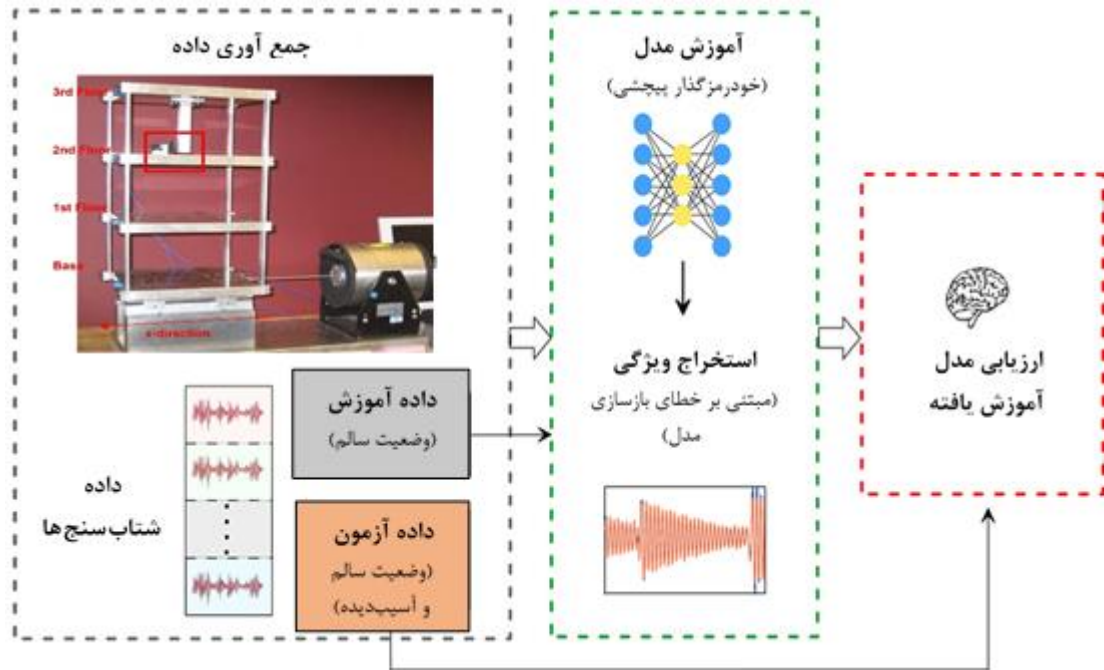


شکل ۱: سازه مبنا آزمایشگاه لس‌آلاموس [۱۳]

جدول ۱: سناریوهای داده‌برداری سازه لس‌آلاموس [۱۳]

وضعیت	برچسب وضعیت (سناریو)
وضعیت ۱	جرم ۱/۲ کیلوگرم طبقه اول
وضعیت ۲	جرم ۱/۲ کیلوگرم طبقه همکف
وضعیت ۳	شکاف ۰/۱۳ میلی‌متری
وضعیت ۴	شکاف ۰/۱۰ میلی‌متری
وضعیت ۵	شکاف ۰/۰۵ میلی‌متری
وضعیت ۶	شکاف ۰/۱۵ میلی‌متری
وضعیت ۷	شکاف ۰/۲۰ میلی‌متری
وضعیت ۸	وضعیت مبنا
وضعیت ۹	جرم ۱/۲ کیلوگرم طبقه اول، شکاف ۰/۲ میلی‌متری
وضعیت ۱۰	جرم ۱/۲ کیلوگرم طبقه اول، شکاف ۰/۱ میلی‌متری
وضعیت ۱۱	جرم ۱/۲ کیلوگرم طبقه همکف، شکاف ۰/۲ میلی‌متری

وضعیت‌های مختلف داده‌برداری از پاسخ شتاب سازه (سناریوها) در جدول ۱ نشان داده شده است. وضعیت پایه، وضعیت ۸ است. وضعیت‌های ۱ و ۲ وضعیت سالم سازه به همراه شبیه‌سازی از شرایط بهره‌برداری بیان شده‌است. در راستای شبیه‌سازی سناریوهای آسیب،



شکل ۲: چارچوب کلی رویکرد پژوهش حاضر

۳-۱- شبکه عصبی پیچشی (درهم تنیده)

شبکه‌های عصبی پیچشی نوعی شبکه عصبی مصنوعی پیش‌خور^۱ با عملکرد نظارت‌شده‌اند. کاربرد اصلی این شبکه‌ها برای وظایف مبتنی بر ورودی از نوع تصویر است؛ اما با ایجاد تغییراتی، بر روی سایر انواع داده‌ها از جمله سری‌های زمانی کاربرد هستند. در مقایسه با شبکه‌های عصبی متعارف^۲، در این شبکه‌ها پارامترهای موردنیاز برای آموزش مدل، کاهش می‌یابد و در مواجهه با پیچیدگی‌های محاسباتی، عملکرد بسیار مناسب‌تری دارند [۱۷]. هدف اصلی در طراحی شبکه‌های پیچشی (درهم‌تنیده)، تشخیص وابستگی‌های محلی در داده‌های ورودی است. بدین معنی که شبکه‌های پیچشی اثر همسایگی و ارتباط داده‌ها با یکدیگر را می‌یابند. این مزیت این امکان را به این شبکه‌ها می‌دهد؛ که الگوهای پیچیده‌تر را به یک روش سلسله‌مراتبی با ترکیب ویژگی‌های سطح پایین و ویژگی‌های سطح بالا، شناسایی کند [۱۸].

شبکه‌های عصبی پیچشی دو نوع هستند: شبکه‌های یک‌بعدی و شبکه‌های دوبعدی. در شبکه‌های عصبی پیچشی یک‌بعدی، داده‌های ورودی یک‌بعدی هستند و نیاز به پیش‌پردازش ندارند. به دلیل

پیکربندی ساده و فشرده نسبت به نوع دوبعدی، پیاده‌سازی سخت‌افزاری آن‌ها در زمانی کوتاه و با هزینه کم امکان‌پذیر است. این شبکه‌ها به‌ویژه در مواجهه داده‌های آموزشی کم، عملکرد قابل قبولی دارند. همچنین به دلیل ساده‌تر بودن ساختار شبکه‌های پیچشی یک‌بعدی، امکان آموزش با تعداد کمتر داده فراهم است و زمان کمتری جهت آموزش نیاز است [۱۹]. در شکل ۳ ساختار شبکه‌های عصبی پیچشی نشان داده شده است. این شبکه‌ها از لایه‌های ورودی، لایه پیچشی (شامل ناحیه دریافت، فیلتر^۳ هسته، طول گام^۴، تابع فعال‌ساز^۵، لایه سازی^۶ (پدینگ))، لایه انتخاب^۷ (رای‌گیری یا جمع‌کننده) و لایه تماماً متصل^۸ لایه تماماً متصل از نورون‌های شبکه‌های عصبی متعارف (شبکه پرسپترون چندلایه) تشکیل شده است [۱۷].

۳-۲- شبکه عصبی خودرمزگذار

خودرمزگذار^۹ نوعی شبکه عصبی مصنوعی، برای یادگیری ویژگی‌های اصلی داده‌های ورودی، به‌صورت بدون نظارت است. فرآیند خودرمزگذاری از دو بخش تشکیل شده است: بخش رمزگذار و بخش رمزگشا. این شبکه به‌صورت متعارف شامل یک لایه ورودی، چندین لایه پنهان و یک لایه خروجی است. لایه پنهان رمزگذار ویژگی‌هایی

⁶ Padding

⁷ Pooling Layer

⁸ Fully-Connected Layer

⁹ Autoencoder

¹ Feed Forward Neural Network

² Multilayer Perceptron (MLP)

³ Kernel

⁴ Stride

⁵ Activation Function

۳-۳- مدل پیشنهادی (مدل ترکیبی خودرمزگذار پیچشی)

▪ فلسفه طراحی

کاهش ابعاد، فشرده‌سازی و استخراج ویژگی‌های اصلی و کلیدی از داده‌های ورودی، بدون اطلاع از ماهیت و برچسب آن‌ها، هدف اصلی به‌کارگیری شبکه‌های خودرمزگذار است. از طرفی طراحی خودرمزگذار در حالت کوچک‌تر شدن ابعاد ورودی موجب ارائه داده‌های کم‌حجم و فشرده خواهد شد. پردازش داده‌های کم‌حجم و فشرده آسان‌تر است؛ با سرعت بیشتری انجام می‌شود و بار محاسباتی کمتری دارد. از این‌رو تصمیم‌گیری بر اساس این داده‌ها ساده‌تر خواهد بود.


از سویی دیگر، پژوهش‌ها پیشین کارایی شبکه‌های پیچشی به‌منظور کشف و شناسایی ارتباطات محلی و الگو داده‌ها، خصوصاً در مسئله موردبررسی این پژوهش (سری زمانی‌های چندمتغیره حاصل از سامانه پایش سلامت) نشان داده‌اند [۲۳-۲۵]. لازم به ذکر است پژوهش‌های [۲۳-۲۵] بر اساس پایش نظارت‌شده توسعه داده شده‌اند و هیچ‌یک کارایی این شبکه در حالت نظارت‌نشده نسنجیده‌اند.

از این‌رو با توجه به دغدغه محقق و اهداف پژوهش حاضر مبنی بر تشخیص بدون نظارت آسیب، تلفیق دو نوع شبکه فوق‌الذکر در راستای الف) تشخیص آسیب بدون نظارت با بهره‌گیری از خودرمزگذارها و ب) کشف ارتباط میان داده‌های سیستم پیچیده و غیرخطی مورد بررسی با استفاده از شبکه‌های عصبی پیچشی، مورد بررسی قرار گرفته است. ذکر این نکته ضروری است که شبکه خودرمزگذار به تنهایی می‌تواند یک نمای فشرده از ویژگی‌های اصلی و کلیدی ارائه دهد؛ اما امکان تفکیک ویژگی‌های وضعیت سالم و وضعیت آسیب‌دیده سازه، با وجود ارتباط غیرخطی و هم‌پوشانی میان آن‌ها در حاله‌ای از ابهام است. از طرفی به‌کارگیری شبکه‌های پیچشی به‌تنهایی نیازمند اطلاع از وضعیت داده‌های ورودی است که با هدف پژوهش حاضر در تضاد است؛ اما در ترکیب با خودرمزگذارها، موجب ارائه ویژگی‌های مناسب در عین حفظ ماهیت بدون نظارت خواهد شد. در این مقاله یک خودرمزگذار پیچشی به‌منظور استخراج خودکار ویژگی از پاسخ ثبت‌شده حسگرهای شتاب سنج سازه ارائه شده‌است.

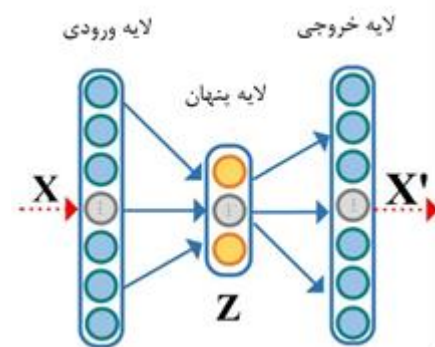
▪ پارامترهای طراحی

CAE این شبکه یک شبکه خودرمزگذار است که در لایه‌های رمزگذار آن از فرآیند پیچش یا کانولوشن و در لایه‌های رمزگشا از کانولوشن ترانهاده ساخته‌شده است [۲۶]. کانولوشن ترانهاده عملیاتی برای بازسازی داده‌های ورودی است که خروجی آن، دارای ابعادی برابر با

را از ورودی یاد می‌گیرد، درحالی‌که لایه پنهان رمزگشا تلاش می‌کند تا ورودی را بازسازی کند. در این میان داده‌های لایه پنهان، ویژگی‌های آموخته‌شده از داده‌های ورودی هستند. یک خودرمزگذار تک‌لایه کافی نیست تا ویژگی‌های نمایانگر از داده‌های خام را استخراج کند. از این‌رو مفهوم، خودرمزگذار عمیق متشکل از چندین لایه توسعه یافت [۲۰]. خودرمزگذارها برای کاهش ابعاد و یادگیری ویژگی‌ها استفاده‌شده‌اند [۲۱]. ویژگی‌های یاد گرفته‌شده در لایه‌های پنهان این شبکه‌ها، داده‌های اصلی را به شکل مناسبی توصیف می‌کنند. خودرمزگذار یک ابزار یادگیری عمیق بدون نظارت است؛ که از تکرار فرآیند پس انتشار خطا برای آموزش خود به‌منظور بازسازی ورودی‌های شبکه استفاده می‌کند. در طول فرآیند آموزش، خودرمزگذار با کاهش خطای بازسازی به‌روزرسانی می‌شود [۲۰]. در شکل ۴ ساختار یک خودرمزگذار متعارف نشان داده شده‌است.



شکل ۳: ساختار شبکه CNN [۱۷]



شکل ۴: ساختار شبکه خودرمزگذار [۲۲]

کپی کردن ورودی به خروجی ممکن است بی‌فایده به نظر برسد. از طرفی خروجی رمزگشا کاربرد خاصی ندارد. از این‌رو محدودیت‌های مختلفی بر روی شبکه اعمال می‌گردد. یکی از این محدودیت‌ها، کوچک‌تر بودن لایه پنهان است. این اقدام شبکه را مجبور به یادگیری یک نمای فشرده از ورودی‌ها می‌کند. در این نوع خودرمزگذار امکان کشف ویژگی‌های بارز از داده‌ها را با توجه به ابعاد کمتر از ورودی در لایه پنهان وجود دارد [۲۲].

آموزش شبکه‌های عصبی عمیق به دلیل محدودیت‌های پردازشی، امکان پردازش کل داده در هر دوره وجود ندارد. لذا در فرآیند آموزش، زیرنمونه‌هایی (دسته^۴) از کل داده در هر دوره، به‌صورت قطعه به قطعه به شبکه داده می‌شود.

• آموزش و عملکرد

روش پیشنهادی این مقاله صرفاً از اطلاعات داده‌های وضعیت سالم سازه استفاده کرده است. در سازه مبنا موردبررسی، چهار حسگر، داده‌های وضعیت‌های مختلف را جمع‌آوری می‌کنند، از این‌رو یک سری زمانی چهار کاناله باید تحلیل شود. به‌منظور تشخیص آسیب و ارزیابی وضعیت‌های مختلف سازه، خطای بازسازی مدل CAE (مقدار تابع L_{MSLE} برای ورودی) به‌عنوان شاخص حساس به آسیب در نظر گرفته شده است.

به‌منظور آموزش مدل، یک پنجره به طول ۱۰۲۴ با گام‌های ۳۲ تایی، بر روی سری زمانی ۴ کاناله مرتبط با داده‌های وضعیت سالم، لغزنده شده است. نتیجتاً ماتریس ورودی به مدل CAE ابعاد (۱۰۲۴×۴) دارد. در مجموع ۲۹ سری داده برای وضعیت‌های مختلف سالم سازه و ۸۰ سری داده برای وضعیت‌های مختلف آسیب‌دیده سازه گزارش شده است. همان‌طور که پیش‌ازین تشریح گردید؛ در هر بار داده‌برداری ۸۱۹۲ نمونه برداشت شده است. با لغزاندن پنجره‌ای به طول ۱۰۲۴ با گام‌های ۳۲ تایی، در مجموع ۷۳۹۲ پنجره برای وضعیت‌های سالم سازه و ۲۰۴۴۸ پنجره برای وضعیت‌های آسیب‌دیده سازه ایجاد شده است. این تکنیک ازدیاد داده موجب آموزش هر چه بهتر مدل خواهد شد. نتیجتاً عملکرد مناسب‌تر آن را در پی خواهد داشت.

تقسیم کل داده‌ها به سه مجموعه داده، آموزشی^۵، اعتبارسنجی^۶ و آزمایشی^۷ انجام شده است. مجموعه داده آموزشی برای آموزش مدل، مجموعه داده اعتبارسنجی برای تنظیم پارامترها و مجموعه داده آزمایشی برای آزمودن عملکرد الگوریتم استفاده می‌شود. طی پروسه آموزش مدل از مجموعه‌های داده آموزشی و اعتبارسنجی استفاده می‌گردد. مدل CAE این پژوهش با ۸۰٪ و ۱۰٪ داده‌های وضعیت سالم آموزش دیده است و اعتبارسنجی شده است. تمامی داده‌های مرتبط با وضعیت آسیب‌دیده سازه و مابقی ۱۰٪ داده‌های وضعیت سالم به‌عنوان

ابعاد داده‌های اولیه است. در شکل ۵ معماری شبکه CAE پیشنهادی، نشان داده شده است. همچنین جدول ۲ پارامترهای شبکه CAE بیان شده است.

یکی از پارامترهای اصلی طراحی شبکه‌های عصبی تابع هزینه است. تابع هزینه در هر نوبت از آموزش، میزان خطای پیش‌بینی را ارائه می‌دهد تا شبکه عصبی در مسیر یادگیری خود هر بار اصلاح گردد و به بهترین خروجی برسد. در این مسیر ارائه مقدار خطا توسط تابع هزینه صورت می‌گیرد [۲۷]. در این پژوهش از تابع هزینه میانگین توان دوم لگاریتم خطا L_{MSLE} برای آموزش CAE استفاده شده است. مقدار تابع از رابطه (۱) محاسبه می‌شود که در این رابطه، n تعداد کل داده‌ها، y_i مقادیر اصلی و \tilde{y}_i مقادیر پیش‌بینی شده است:

$$L_{MSLE} = \frac{1}{n} \sum_{i=1}^n [\log(1 + y_i) - \log(1 + \tilde{y}_i)]^2 \quad (1)$$

الگوریتم بهینه‌سازی^۱ پارامتر دیگری در طراحی شبکه عصبی است. الگوریتم‌های بهینه‌سازی با به‌کارگیری مقدار تابع هزینه به‌صورت مکرر الگوریتم‌های مشخصی را اعمال کرده تا به بهترین پاسخ ممکن برسند. این توابع در شبکه‌های عصبی باهدف بهبود فرآیند آموزش، پارامترهای شبکه در لایه‌های مختلف را در راستای هدف موردنظر تنظیم می‌کنند.

جدول ۲: پارامترهای شبکه خودرمزگذار پیچشی

مقادیر هابیر پارامترهای خودرمزگذار پیچشی	
تعداد کل لایه‌ها	۱۲
اندازه دسته آموزش	۱۶
دفعات آموزش	۲۰۰
پارامترهای قابل آموزش	۲۳۱۹۴۰
زمان آموزش (دقیقه)	۴
تابع بهینه‌یابی	ADAM
تابع فعال‌سازی لایه‌ها	Tanh
تابع هزینه	MSLE

نرخ یادگیری^۲، اندازه گام‌ها در الگوریتم بهینه‌سازی را مشخص می‌کند. تعداد دفعات^۳ آموزش، تعداد دفعاتی است که داده‌های آموزش در اختیار شبکه گذاشته می‌شود و شبکه داده‌ها را می‌بیند. در روند

⁵ Train

⁶ Validation

⁷ Test


¹ Optimization Function

² Learning Rate

³ Epochs

⁴ Batch size

داده آزمون (تست) پس از آموزش شبکه برای ارزیابی عملکرد شبکه مورد استفاده قرار گرفته‌اند.



شکل ۵: معماری مدل CAE پژوهش حاضر

۴- نتایج

در شکل ۶ عملکرد مدل CAE آموزش داده شده در مواجهه با مجموعه داده تست و اعتبارسنجی نشان داده شده است. محور افقی، میانگین خطای بازسازی ۴ کانال توسط مدل CAE و محور عمودی تعداد نمونه‌هاست. حجم زردرنگ مربوط به بخشی از داده‌های آزمون است که نماینده وضعیت آسیب‌دیده سازه‌اند. حجم آبی‌رنگ مربوط به بخش مرتبط با وضعیت سالم سازه در داده‌های آزمون (۱۰٪ کل داده‌های سالم سازه) جهت ارزیابی کارایی مدل نشان داده شده است. حجم قهوه‌ای رنگ نشان‌دهنده داده‌های مرتبط با اعتبارسنجی (۱۰٪ کل داده‌های سالم سازه) است. در شکل خط عمودی آبی بیشینه تمام مقادیر میانگین خطای بازسازی ۴ کانال توسط مدل CAE داده‌های وضعیت سالم سازه و خط عمودی زردرنگ کمینه تمامی مقادیر میانگین خطای بازسازی ۴ کانال توسط مدل CAE داده‌های وضعیت آسیب‌دیده سازه است.

به منظور اطمینان از عملکرد مدل، تمام داده سازه مینا مورد بررسی، به‌عنوان ورودی به مدل آموزش‌یافته، داده شدند. مقادیر میانگین خطای بازسازی ۴ کانال مدل CAE در شکل ۷ نمایش داده شده است. خط عمودی قرمز، مرز جداکننده داده‌های وضعیت سالم و آسیب‌دیده است. خط افقی قرمز بر مبنای مقدار بیشینه خطای بازسازی داده‌های سالم رسم شده است. نتایج حاکی از موفقیت مدل پیشنهادی در جداسازی داده‌های مرتبط با وضعیت سالم و آسیب‌دیده سازه است. محور افقی شکل، تعداد کل پنجره‌های وضعیت‌های سالم و آسیب‌دیده سازه را نشان می‌دهد. محور عمودی میانگین خطای بازسازی پنجره‌های ورودی (۴ کانال) به مدل CAE است.

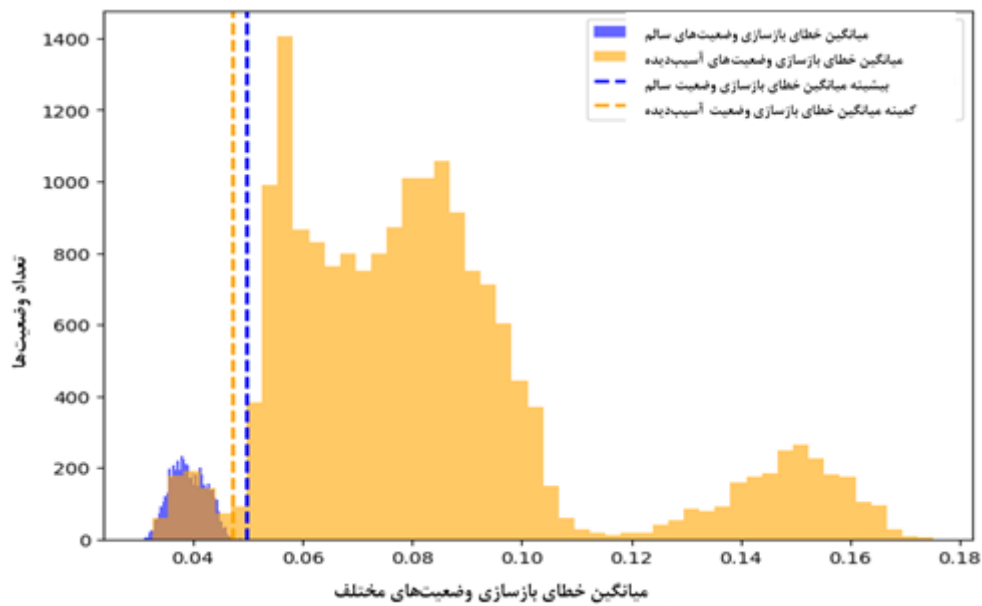
جدول ۳: خطای بازسازی خودمرزگذار پیش‌بینی

مقادیر تابع هزینه پس از ۲۰۰ دفعه آموزش		
MSLE	MSE	MAE
۰/۰۰۰۳۴۶	۰/۰۰۱۵	۰/۰۲۶۳


جدول ۴: عملکرد شبکه خودمرزگذار پیش‌بینی

مدل توسعه داده شده	خطا		
	کل	نوع دو	نوع یک
خودمرزگذار پیش‌بینی	٪۰/۲۲۶	٪۰/۲۳۵	٪۰/۰

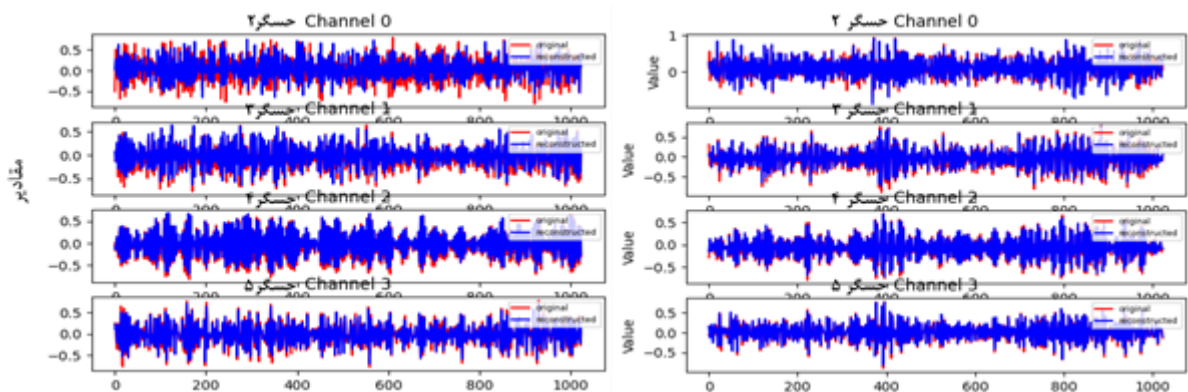
به منظور اطمینان از عملکرد مدل، تمام داده سازه مینا مورد بررسی، به‌عنوان ورودی به مدل آموزش‌یافته، داده شدند. مقادیر میانگین خطای بازسازی ۴ کانال مدل CAE در شکل ۷ نمایش داده شده است. خط عمودی قرمز، مرز جداکننده داده‌های وضعیت سالم و آسیب‌دیده است. خط افقی قرمز بر مبنای مقدار بیشینه خطای بازسازی داده‌های سالم رسم شده است. نتایج حاکی از موفقیت مدل پیشنهادی در جداسازی داده‌های مرتبط با وضعیت سالم و آسیب‌دیده سازه است. محور افقی شکل، تعداد کل پنجره‌های وضعیت‌های سالم و آسیب‌دیده سازه را نشان می‌دهد. محور عمودی میانگین خطای بازسازی پنجره‌های ورودی (۴ کانال) به مدل CAE است.



شکل ۶: عملکرد مدل CAE روی سازه LANL



شکل ۷: مقادیر میانگین خطای بازسازی CAE روی تمامی داده‌های سازه LANL



شکل ۸: مصورسازی نتایج CAE، الف) داده مرتبط با وضعیت سالم سازه، ب) داده مرتبط با وضعیت آسیب‌دیده سازه

استفاده از MSE و MAE در آموزش خودرمزگذارها مرسوم‌اند اما نتایج بیانگر عملکرد مناسب‌تر MSLE نسبت به آن‌ها است. برای نمونه سیگنال‌های بازسازی‌شده یکی از ورودی‌های CAE، در وضعیت سالم و آسیب‌دیده در شکل ۸ نشان داده شده‌اند. نقاط قرمز رنگ

در جدول ۳ مقادیر خطای آموزش انتهایی فرآیند آموزش مدل CAE گزارش شده‌است. در جدول مقادیر تابع خطای میانگین توان دوم لگاریتم خطا (MSLE)، میانگین توان دوم خطا (MSE) و میانگین قدر مطلق خطا (MAE) گزارش شده‌اند. علیرغم اینکه

مواقعی که حفظ جان کاربران از اهمیت بسزایی برخوردار است؛ نیاز به شناسایی تمامی وضعیت محتمل آسیب است. به عبارت دیگر نیاز است که مقدار خطای نوع دوم باید بسیار کم باشد و اگر خطایی هم تولید شد در گروه مرتبط با وضعیت سالم سازه که به اشتباه آسیب‌دیده گزارش شده است، قرار گیرد؛ اما گاهی صحت بیشتر هدف مسئله خواهد بود. به طور مثال اگر در حوزه تشخیص سلامت سازه نیاز به سامانه‌ای با اعتماد بالا باشد؛ بایستی صحت الگوریتم قابل قبول بوده به نحوی که اعلان آسیب به صورت اشتباه در آن کم باشد تا هزینه‌های پایش و بازرسی‌های سازه در کمترین مقدار ممکن قرار گیرد. بررسی نتایج این پژوهش خصوصاً نتایج گزارش شده جدول ۴ بیانگر توازن بین هر دو نوع خطا در عین مقادیر پایین هر دو آن‌هاست.

۴-۲- تحلیل مقایسه‌ای با پژوهش‌های پیشین

به منظور اثبات کارایی، نتایج پژوهش حاضر با چندین نمونه از پژوهش‌های گذشته با شرط یکسان بودن سازه مینا بررسی شده، تحلیل و مقایسه گردید. پژوهش حاضر و پژوهش‌های مقایسه‌شده از نظر سازه بررسی شده، نحوه و نوع داده‌برداری و وضعیت‌های داده‌برداری یکسان و مقید توضیحات و شرایط مرجع [۱۳] هستند. در پژوهش سانتوس و همکاران^۱ [۲۸] با رویکرد تشخیص آسیب مبتنی بر تشخیص ناهنجاری روی سازه سه طبقه LANL، شاخص‌های حساس به آسیب به وسیله ضرایب مدل‌های اتورگسیو^۲ استخراج گردید و توسط الگوریتم‌های مختلف تشخیص ناهنجاری آسیب در سازه تشخیص داده شد. نتایج پژوهش آن‌ها در جدول ۵ ارائه شده است. در مقام مقایسه با نتایج پژوهش حاضر، در ردیف انتهایی جدول مذکور نتایج این پژوهش ارائه شده است. بهبود قابل توجه نتایج پژوهش حاضر نسبت به پژوهش کاملاً مشهود است. در پژوهش دیگری توسط بالاسمو و همکاران^۳، ضرایب کپسترال معیار مل^۴ به عنوان ویژگی‌های حساس به آسیب از سازه مینا سه طبقه LANL استخراج گردید [۲۹]. در جدول ۶ نتایج پژوهش آن‌ها (استفاده از بردار میانگین و ماتریس کوواریانس ویژگی‌های استخراج شده به عنوان شاخص حساس به آسیب) نشان داده شده است. در ردیف انتهایی جدول مذکور نتایج این پژوهش ارائه شده است. نتایج پژوهش حاضر از برتری قابل توجهی نسبت به پژوهش آن‌ها داراست.

در روش‌های کلاسیکی مانند AANN، LOF، JF، SVD و سایرین، نظیر آنچه در پژوهش [۲۸] بکار گرفته شده است؛ استخراج

قسمت‌هایی از سیگنال اند که توسط CAE بازسازی نشده‌اند. به وضوح پیداست در وضعیت آسیب‌دیده نقاط قرمز رنگ نسبت به وضعیت سالم، بیشتر است. در جدول ۴ عملکرد و نتایج مدل CAE، خطای نوع I و نوع II (خطای نوع یک، خطای مثبت؛ وضعیتی از سازه آسیب‌دیده شناخته می‌شود که در واقعیت آسیب‌دیده نیست و خطای نوع دو، خطای منفی؛ وضعیتی از سازه سالم شناخته می‌شود که در واقعیت آسیب‌دیده است) روی داده‌های آزمون (تمامی داده‌های وضعیت آسیب‌دیده به علاوه ۱۰٪ داده مرتبط با وضعیت سالم)، گزارش شده است.

۴-۱- تحلیل نتایج

مدل CAE توسعه داده شده این مقاله دارای جنبه‌های مثبت قابل توجهی است؛ که کارایی آن در یادگیری و بازسازی داده‌ها توجیه ساخته است. ساختار مدل با لایه‌های کانولوشنی متعدد، منجر به استخراج ویژگی‌های مختلفی از داده‌های ورودی شده است. استفاده از اندازه‌های فیلتر متفاوت به مدل کمک می‌کند تا ویژگی‌ها در مقیاس‌های مختلف شناسایی گردند. از طرفی با استفاده از گام‌های بزرگ‌تر از ۱ در لایه‌های رمزگذار و رمزگشا، مدل به طور مؤثری ابعاد ویژگی ورودی را کاهش داده است (ابعاد لایه پنهان خود رمزگذار یک‌هشتم مقدار اولیه آن است)؛ در حالی که سلسله‌مراتب فضایی را حفظ نموده است. ساختار متقارن CAE (با کانولوشن‌ها و کانولوشن‌های معکوس) ویژگی‌های مهم را در مرحله رمزگذاری شناسایی کرده، سپس آن‌ها را در مرحله رمزگشایی به طور مؤثر بازسازی کرده است. افزایش و کاهش تدریجی تعداد فیلترها منجر به یادگیری توأمان ویژگی‌های سطح بالا و پایین شده است. لایه‌های پیچشی ترانهاد در رمزگشا موجب بازسازی داده ورودی با ویژگی‌های یاد گرفته شده، شده است. مجموع این عوامل منجر به عملکرد قابل توجه و مناسب مدل، در تشخیص و جداسازی وضعیت‌های مختلف سازه، اعم از حالات سالم و آسیب‌دیده شده است. این مهم حتی با وجود شرایط متغیر بهره‌برداری و وجود ارتباط غیرخطی میان وضعیت‌های مختلف حاصل گشته است. مصورسازی نتایج در قسمت قبل، هم‌پوشانی بسیار کم و غیر قابل توجه در تشخیص و تمایز وضعیت‌های سالم و آسیب‌دیده سازه نشان داده است.

تفسیر معیارهای ارزیابی عملکرد مدل، به بستر و هدف به کارگیری آن‌ها وابسته است. در بحث تشخیص آسیب برای حفظ کارایی سازه و

³ Balsamo et al.

⁴ Mel-frequency cepstral coefficients (MFCCs)

¹ Santos et al.

² Autoregressive

جدول ۵: مقایسه نتایج پژوهش حاضر و پژوهش سانتوس و همکاران [۲۸]

مدل	خطا	
	نوع یک	نوع دو
AANN	٪۹/۷۸	٪۱/۳۵
MSD	٪۹/۳۳	٪۱/۱۰
SVD	٪۶/۴۴	٪۳/۶۲
One-class SVM	٪۸/۰۰	٪۰/۷۵
SVDD	٪۸/۲۲	٪۰/۷۵
KPCA	٪۴/۶۷	٪۱/۶۲
GKPCA	٪۵/۳۳	٪۱/۱۲
خودرمزگذار پیچشی	٪۰/۱۰	٪۰/۲۳۵

جدول ۶: مقایسه نتایج پژوهش حاضر و پژوهش بالاسمو و همکاران [۲۹]

مدل توسعه داده شده	خطا	
	نوع یک	نوع دو
ضرایب کیسترال	٪۱/۱۱	٪۱/۲۵
ضرایب اتورگرسیو	٪۱/۴۸	٪۲/۵۰
خودرمزگذار پیچشی	٪۰/۱۰	٪۰/۲۳۵

۵- جمع بندی

در این پژوهش، یک روش تشخیص داده‌محور و بدون نظارت آسیب، در سازه‌های قابی شکل، توسعه داده شد. خطای بازسازی خودرمزگذار پیچشی، روشی مطمئن و توانمند برای تشخیص آسیب سازه‌های کشف شد. تشخیص آسیب با به‌کارگیری مستقیم پاسخ‌های ارتعاشی حاصل از تحریک محیطی روی سازه مبنا LANL، تحت شرایط متغیر بهره‌برداری، بدون مبادرت به پیش‌پردازش پیچیده نظیر استفاده از روش‌های پردازش سیگنال یا الگوریتم‌های کاهش ابعاد صورت گرفت. مدل توسعه داده شده، صرفاً بر اساس داده‌های وضعیت سالم سازه آموزش یافته است. وضعیت‌های مختلف سازه را به‌درستی تشخیص داده است و نتایج طی نمودارها و جداول متنوع مورد ارزیابی قرار گرفت. اثربخشی مدل CAE در شناسایی دقیق وضعیت سازه، باوجود درهم‌تنیدگی و وابستگی پیچیده بین حالات مختلف سازه، مشهود است. مدل CAE این پژوهش، باهدف بازسازی داده ورودی و

ویژگی‌ها دستی است یا به‌صورت محدود و غیر تطبیقی انجام می‌شود. در مقابل، CAE توانایی یادگیری خودکار ویژگی‌های سلسله‌مراتبی و غیرخطی از داده‌های خام، بدون نیاز به پیش‌پردازش یا انتخاب ویژگی را دارد. برخلاف AANN که ساختاری مسطح دارد، CAE با استفاده از لایه‌های کانولوشنی، می‌تواند الگوهای محلی و فضایی مهم را شناسایی کند. برخلاف SVD و KPCA که به تحلیل‌های خطی یا نیمه‌خطی متکی هستند، CAE به‌صورت ذاتی توانایی درک ارتباطات غیرخطی پیچیده در داده‌ها را دارد. مدل CAE، به‌ویژه برای داده‌های سری‌های زمانی چندکاناله، ویژگی‌های مکانی و زمانی داده‌ها را حفظ می‌کند. درحالی‌که روش‌هایی مانند LOF و Isolation Forest فقط به داده‌ها به‌عنوان نقاطی در فضای ویژگی نگاه می‌کنند و اطلاعات ساختاری یا ترتیب زمانی در آن‌ها گم می‌شود. در CAE، فرایند کاهش ابعاد از طریق لایه‌های کانولوشن انجام می‌شود. این موضوع برخلاف روش‌هایی مثل SVD و KPCA که کاهش ابعاد را بر پایه معیارهای ایستا و کلی انجام می‌دهند. در CAE این کاهش ابعاد به‌صورت تطبیقی و بهینه‌شده بر اساس هدف بازسازی انجام می‌شود. در سناریوهای تشخیص آسیب با شرایط متغیر بهره‌برداری و روابط غیرخطی، مدل CAE با ساختار غیرخطی و عمیق خود، بهتر از مدل‌هایی مانند LOF یا One-Class SVM (با ساختار داده‌های ساده و توزیع پذیر)، قابلیت تعمیم و تطبیق بالاتری با داده‌های واقعی دارد. در پژوهش کائوس و همکاران^۱ در سال ۲۰۲۴، از چهار مدل اتورگرسیو (AR، ARMA، ARX و ARMAX) جهت مدل‌سازی سری زمانی‌های چندمتغیره سازه مبنا سه‌طبقه LANL و استخراج ویژگی‌های حساس به آسیب از آن‌ها استفاده گردید [۳۰]. نتایج قابل قبولی همچون پژوهش حاضر حاصل گردید؛ اما زمان محاسبه ضرایب مدل‌های اتورگرسیو ARMA، ARX و ARMAX به ترتیب ۳۳/۸ دقیقه، ۱۸/۴ دقیقه و ۲/۷ ساعت گزارش گردیده است. این در حالی است که در رویکرد پیشنهادی این پژوهش، زمان آموزش مدل CAE، ۴/۵ دقیقه بوده است. در واقع روش‌های مدل‌سازی سری زمانی مانند ARMA، ARX و ARMAX به زمان محاسباتی بسیار بالایی برای استخراج ویژگی نیاز دارند. درحالی‌که CAE با توجه به پیکربندی موازی‌پذیر خود در پردازنده‌های گرافیکی، زمان آموزش بسیار کمتری داشته است.

¹ Kauss et al.

2024 (in Persian). doi: [10.22034/jmeut.2024.60099.3368](https://doi.org/10.22034/jmeut.2024.60099.3368)

[2] M. Azimi, A. Dadras Eslamlou, and G. Pekcan, "Data-driven structural health monitoring and damage detection through deep learning: A state-of-the-art review," *Sensors*, Vol. 20, No. 10, p. 2778, 2020. doi: [10.3390/s20102778](https://doi.org/10.3390/s20102778)

[3] Z. Yuan, S. Zhu, C. Chang, X. Yuan, Q. Zhang, and W. Zhai, "An unsupervised method based on convolutional variational auto-encoder and anomaly detection algorithms for light rail squat localization," *Construction and Building Materials*, Vol. 313, p. 125563, 2021. doi: [10.1016/j.conbuildmat.2021.125563](https://doi.org/10.1016/j.conbuildmat.2021.125563)

[4] K. Eltouny and X. Liang, "Large-scale structural health monitoring using composite recurrent neural networks and grid environments," *Computer-Aided Civil and Infrastructure Engineering*, Vol. 38, No. 3, pp. 271–287, 2023. doi: [10.1111/mice.12841](https://doi.org/10.1111/mice.12841)

[5] M. Z. Sarwar and D. Cantero, "Probabilistic autoencoder-based bridge damage assessment using train-induced responses," *Mechanical Systems and Signal Processing*, Vol. 208, p. 111046, 2024. doi: [10.1016/j.ymsp.2024.111046](https://doi.org/10.1016/j.ymsp.2024.111046)

[6] O. Avci, O. Abdeljaber, S. Kiranyaz, M. Hussein, M. Gabbouj, and D. Inman, "A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications," *Mechanical Systems and Signal Processing*, Vol. 147, p. 107077, 2021. doi: [10.1016/j.ymsp.2020.107077](https://doi.org/10.1016/j.ymsp.2020.107077)

[7] A. Asgharzadeh Bonab, G. Nasirpour, and A. Allahyari Pargo, "A comparative study and accurate approach for damage detection of frame structures based on deep neural network models," *Mechanical Engineering, University of Tabriz*, Vol. 54, No. 1, pp. 71–80, 2025 (in Persian). doi: [10.22034/jmeut.2025.63709.3467](https://doi.org/10.22034/jmeut.2025.63709.3467)

[8] S. Ghazimoghadam and S. A. A. Hosseinzadeh, "A novel unsupervised deep learning approach for vibration-based damage diagnosis using a multi-head self-attention LSTM autoencoder,"

استفاده از خطای بازسازی آن، با لایه‌های کانولوشنی متعدد، کاهش ابعاد مؤثر و ساختار متقارن، به‌خوبی تعادل بین یادگیری و بازسازی را برقرار نموده است. یافته‌ها نشان می‌دهد، مدل CAE با خطای ۰/۲۲۶٪ (دقت ۹۹/۷۷۴٪) نتایج دقیقی در تشخیص آسیب سناریوهای مختلف به همراه داشته‌است. همچنین مدل موردنظر از نظر تعداد پارامترهای آموزش (۲۳۱۹۴۰ پارامتر) و تلاش محاسباتی (نیاز به ۴/۵ دقیقه جهت آموزش روی داده‌های سازه مورد بررسی) عملکرد مطلوبی دارد. جهت اثبات کارایی مدل پیشنهادی، نتایج با پژوهش مشابه روی سازه مینا یکسان مقایسه گردیده‌است. مقایسه عملکرد CAE با الگوریتم‌های کلاسیک نشان داد، این مدل از دقت، تعمیم‌پذیری و سرعت بالاتری برخوردار است و در شرایط پیچیده مانند تغییرات بهره‌برداری، عملکردی پایدار دارد.

باوجود نتایج قابل توجه، این پژوهش با محدودیت‌هایی نیز همراه بوده است. مدل تنها با داده‌های وضعیت سالم آموزش‌دیده و فرض شده که تمامی داده‌های آموزشی، بدون آسیب هستند. در شرایط واقعی، ممکن است داده‌های آموزشی نیز شامل ناهنجاری‌های پنهان باشند. هرچند مدل در برابر تغییرات جزئی مقاوم بوده است، اما شرایط محیطی مانند دما و رطوبت، به‌صورت مستقیم در آموزش مدل لحاظ نشده‌اند. از طرفی در سناریوهای واقعی تشخیص آسیب، عدم قطعیت در اندازه‌گیری و برچسب‌گذاری اجتناب‌ناپذیر است و در این پژوهش لحاظ نشده است.

همچنین پیشنهاد می‌شود در پژوهش‌های آینده موضوعاتی نظیر؛ الف) ادغام شرایط محیطی در فرایند یادگیری، ب) به‌کارگیری مدل برای شرایط برخط و سازه‌های واقعی و ج) استفاده از مدل‌های ترکیبی با امکان یادگیری چندوظیفه‌ای؛ بررسی بشود. در مجموع، نتایج این پژوهش نشان داد که استفاده از خودمزمگذار پیچشی، می‌تواند جایگزین مناسبی برای روش‌های کلاسیک در سازه‌های پیچیده و غیرخطی باشد. با رفع محدودیت‌های موجود و گسترش کاربردهای مدل، می‌توان آن را در چارچوب‌های پیشرفته‌تر پایش سلامت سازه و تشخیص آسیب تعمیم داد.

۶- منابع

[1] A. Asgharzadeh Bonab, H. Kalb Khani, and S. Bijanvand, "A machine learning-based approach for linear and nonlinear damage detection in structures using combined deep temporal and time-frequency features," *Mechanical Engineering, University of Tabriz*, Vol. 54, No. 1, pp. 71–80,

- [17] K. O'Shea, "An introduction to convolutional neural networks," *arXiv preprint*, arXiv:1511.08458, 2015. Available: <https://doi.org/10.48550/arXiv.1511.08458>
- [18] G. Marcus, "Deep learning: A critical appraisal," *arXiv preprint*, arXiv:1801.00631, 2018. Available: doi: [10.48550/arXiv.1801.00631](https://doi.org/10.48550/arXiv.1801.00631)
- [19] R. M. Schmidt, "Recurrent neural networks (RNNs): A gentle introduction and overview," *arXiv preprint*, arXiv:1912.05911, 2019. Available: doi:[10.48550/arXiv.1912.05911](https://doi.org/10.48550/arXiv.1912.05911)
- [20] Y. J. Cha, R. Ali, J. Lewis, and O. Büyüköztürk, "Deep learning-based structural health monitoring," *Automation in Construction*, Vol. 161, p. 105328, 2024. doi: [10.1016/j.autcon.2024.105328](https://doi.org/10.1016/j.autcon.2024.105328).
- [21] D. Kwon, H. Kim, J. Kim, S. C. Suh, I. Kim, and K. Kim, "A survey of deep learning-based network anomaly detection," *Cluster Computing*, Vol. 22, pp. 949–961, 2019. doi: [10.1007/s10586-018-3081-1](https://doi.org/10.1007/s10586-018-3081-1)
- [22] S. Chen and W. Guo, "Auto-encoders in deep learning — A review with new perspectives," *Mathematics*, Vol. 11, No. 8, p. 1777, 2023. doi: [10.3390/math11081777](https://doi.org/10.3390/math11081777)
- [23] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, and D. J. Inman, "Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks," *Journal of Sound and Vibration*, Vol. 388, pp. 154–170, 2017. doi: [10.1016/j.jsv.2016.08.050](https://doi.org/10.1016/j.jsv.2016.08.050)
- [24] S. Sharma and S. Sen, "One-dimensional convolutional neural network-based damage detection in structural joints," *Journal of Civil Structural Health Monitoring*, Vol. 10, No. 5, pp. 1057–1072, 2020. doi: [10.1007/s13349-020-00423-3](https://doi.org/10.1007/s13349-020-00423-3)
- [25] Z. Teng, S. Teng, J. Zhang, G. Chen, and F. Cui, "Structural damage detection based on real-time vibration signal and convolutional neural network," *Applied Sciences*, Vol. 10, No. 14, p. 4720, 2020. doi: [10.3390/app10144720](https://doi.org/10.3390/app10144720)
- [9] A. Pollastro, G. Testa, A. Bilotta, and R. Prevete, "Semi-supervised detection of structural damage using variational autoencoder and a one-class support vector machine," *IEEE Access*, 2023. doi: [10.1109/ACCESS.2023.3291674](https://doi.org/10.1109/ACCESS.2023.3291674)
- [10] A. Anaissi, S. M. Zandavi, B. Suleiman, M. Najj, and A. Braytee, "Multi-objective variational autoencoder: An application for smart infrastructure maintenance," *Applied Intelligence*, Vol. 53, No. 10, pp. 12047–12062, 2023. doi: [10.1007/s10489-022-04321-z](https://doi.org/10.1007/s10489-022-04321-z)
- [11] D. Terzis, "Monitoring innovation metrics in construction and civil engineering: Trends, drivers and laggards," *Developments in the Built Environment*, Vol. 9, 2022. doi: [10.1016/j.dibe.2022.100054](https://doi.org/10.1016/j.dibe.2022.100054)
- [12] H. Dang, M. Tatipamula, and H. Nguyen, "Cloud-based digital twinning for structural health monitoring using deep learning," *IEEE Trans. Ind. Informatics*, Vol. 18, No. 6, pp. 3820–3830, 2021. doi: [10.1109/TII.2021.3064907](https://doi.org/10.1109/TII.2021.3064907)
- [13] E. Figueiredo, G. Park, J. Figueiras, C. Farrar, and K. Worden, "Structural health monitoring algorithm comparisons using standard data sets," Los Alamos National Lab, 2009. doi: [10.2172/947958](https://doi.org/10.2172/947958)
- [14] R. Chalapathy and S. Chawla, "Deep learning for anomaly detection: A survey," *arXiv preprint*, arXiv:1901.03407, 2019. Available: doi: [10.48550/arXiv.1901.03407](https://doi.org/10.48550/arXiv.1901.03407)
- [15] S. Samudra, M. Barbosh, and A. Sadhu, "Machine learning-assisted improved anomaly detection for structural health monitoring," *Sensors*, Vol. 23, No. 7, p. 3365, 2023. doi: [10.3390/s23073365](https://doi.org/10.3390/s23073365)
- [16] C. Farrar, S. Doebling, and D. Nix, "Vibration-based structural damage identification," *Philos. Trans. R. Soc. A*, Vol. 359, No. 1778, pp. 131–149, 2001. doi: [10.1098/rsta.2000.0735](https://doi.org/10.1098/rsta.2000.0735)

- [29] L. Balsamo, R. Betti, and H. Beigi, "A structural health monitoring strategy using cepstral features," *Journal of Sound and Vibration*, Vol. 333, No. 19, pp. 4526–4542, 2014. doi: [10.1016/j.jsv.2014.05.040](https://doi.org/10.1016/j.jsv.2014.05.040)
- [30] K. Kauss, V. Alves, F. Barbosa, and A. Cury, "Semi-supervised structural damage assessment via autoregressive models and evolutionary optimization," *Structures*, Vol. 59, p. 105762, 2024. doi: [10.1016/j.structures.2024.105762](https://doi.org/10.1016/j.structures.2024.105762)
- [26] K. Berahmand, F. Daneshfar, E. Salehi, Y. Li, and Y. Xu, "Autoencoders and their applications in machine learning: A survey," *Artificial Intelligence Review*, Vol. 57, No. 2, p. 28, 2024. doi: [10.1007/s10462-023-10478-w](https://doi.org/10.1007/s10462-023-10478-w)
- [27] U. Michelucci, "An introduction to autoencoders," *arXiv preprint*, arXiv:2201.03898, 2022. Available: doi: [10.48550/arXiv.2201.03898](https://doi.org/10.48550/arXiv.2201.03898)
- [28] A. Santos, E. Figueiredo, M. Silva, C. Sales, and J. Costa, "Machine learning algorithms for damage detection: Kernel-based approaches," *Journal of Sound and Vibration*, Vol. 363, pp. 584–599, 2016. doi: [10.1016/j.jsv.2016.05.033](https://doi.org/10.1016/j.jsv.2016.05.033)