



Semnan University

Journal of Modeling in Engineering


Journal homepage: <https://modelling.semnan.ac.ir/>

ISSN:



Research Article

Frequency Analysis of Cracked Beams Using Machine Learning Algorithms

Rasta Razeghian^a, Massoud Mir^{a,*} 

^a Department of Mechanical Engineering, Faculty of Advanced Technologies, Quchan University of Technology, Quchan, Iran

PAPER INFO

Paper history:

Received: 2025-01-21

Revised: 2025-06-12

Accepted: 2025-06-17

Keywords:

Machine learning;
Cracked beam;
Natural frequency;
Python;
Multi layer perceptron;
Gradient boosting
regression.

ABSTRACT

The presence of cracks in a beam changes the dynamic characteristics of the beam. Therefore, to assess the condition of the beam, its natural frequencies must be examined. In this study, using a numerical solution based on the Rayleigh method, the natural frequencies of a beam with two cracks are calculated based on the depth and location of the cracks. Next, using the Python programming language, the aforementioned mathematical relationship is entered into this program to solve this relationship sequentially for different inputs by creating iterative loops. The goal of this is to produce a dataset that can be used to train machine learning algorithms such as random forest regression, gradient boosting regression, multilayer perceptron, and decision tree regression to predict the natural frequency. The key innovation in this study is the use of a network search method to determine the optimal amount of data for each algorithm, which increases accuracy and introduces a new criterion for comparison called "required data volume". The study found that increasing the size of the dataset generally increases the prediction accuracy of the algorithms. In addition, algorithms that predict a single output have higher accuracy compared to those that predict multiple outputs. The study demonstrates the effective use of machine learning algorithms for predicting natural frequencies. The gradient boosting regression algorithm with an accuracy of 84.10% and the random forest regression algorithm with an accuracy of 83.73% emerged as the superior methods for predicting beam frequencies.

DOI: <https://doi.org/10.22075/jme.2025.36673.2800>

© 2026 Published by Semnan University Press.

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

* Corresponding author.

E-mail address: massoudmir@qiet.ac.ir

How to cite this article:

M. Mir and R. Razeghian, "Frequency analysis of cracked beams using machine learning," Journal of Modeling in Engineering, 24 84 (2026): 213-226, doi: 10.22075/jme.2025.36673.2800

آنالیز فرکانسی تیر ترک‌دار به کمک الگوریتم‌های یادگیری ماشین

رستا رازقیان^۱، مسعود میر^{۱*}

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۳/۱۱/۰۲	وجود ترک در تیر، مشخصه‌های دینامیکی تیر را تغییر می‌دهد. بنابراین، برای ارزیابی وضعیت تیر، فرکانس‌های طبیعی آن باید بررسی شوند. در این مطالعه، با استفاده از یک راه‌حل عددی بر اساس روش رایلی، فرکانس‌های طبیعی یک تیر با دو ترک بر اساس عمق و موقعیت ترک محاسبه می‌شود. در ادامه با استفاده از زبان برنامه نویسی پایتون، رابطه ریاضی مذکور را در این برنامه وارد کرده تا با ایجاد حلقه‌های تکرار این رابطه را به صورت پی در پی برای ورودی‌های متفاوت حل کند، هدف از این امر تولید مجموعه داده‌ای است که از آن برای آموزش الگوریتم‌های یادگیری ماشین از جمله رگرسیون جنگل تصادفی، رگرسیون افزایش گرادبان، پرسپترون چندلایه و رگرسیون درخت تصمیم جهت پیش‌بینی فرکانس طبیعی استفاده شود. نوآوری کلیدی در مطالعه این استفاده از یک روش جستجوی شبکه‌ای برای تعیین مقدار بهینه داده برای هر الگوریتم است که دقت را افزایش داده و معیار جدیدی جهت مقایسه به نام «حجم داده مورد نیاز» را معرفی می‌کند. این تحقیق نشان داد افزایش اندازه مجموعه داده‌ها معمولاً دقت پیش‌بینی الگوریتم‌ها را افزایش می‌دهد علاوه بر این الگوریتم‌هایی که یک خروجی را پیش‌بینی می‌کنند، در مقایسه با آن‌هایی که چندین خروجی را پیش‌بینی می‌کنند، دقت بالاتری دارند. این مطالعه استفاده مؤثر از الگوریتم‌های یادگیری ماشین را برای پیش‌بینی فرکانس‌های طبیعی نشان می‌دهد. الگوریتم رگرسیون تقویت گرادبان با دقت ۹۷/۷۵ و الگوریتم رگرسیون جنگل تصادفی با دقت ۹۵/۷۴ به عنوان روش‌های برتر برای پیش‌بینی فرکانس‌های تیر ظاهر شدند.
بازنگری مقاله: ۱۴۰۴/۰۳/۲۲	
پذیرش مقاله: ۱۴۰۴/۰۳/۲۷	
واژگان کلیدی: یادگیری ماشین، تیر دارای ترک، فرکانس طبیعی، پایتون، پرسپترون چندلایه‌ای، رگرسیون تقویت گرادبان.	
DOI: https://doi.org/10.22075/jme.2025.36673.2800	
© 2026 Published by Semnan University Press. This is an open access article under the CC-BY 4.0 license. (https://creativecommons.org/licenses/by/4.0/)	

۱- مقدمه

و افزایش دسترسی به داده‌های حسگر، محققان به توسعه مدل‌های هوشمندی پرداخته‌اند که می‌توانند به طور مؤثر فرکانس‌های طبیعی را در ساختارهای تیرهای پیچیده با ترک‌های متعدد شناسایی و تحلیل کنند. این مطالعه روش‌های تحلیلی سنتی را با تکنیک‌های پیشرفته یادگیری ماشین ترکیب می‌کند تا درک عمیق‌تری از نحوه تأثیر الگوهای ترک بر ارتعاشات تیر به دست آورد. با استفاده از اطلاعاتی مبتنی بر داده، درک دقیق‌تری از چگونگی تأثیر

ارزیابی، شناسایی و رسیدگی به وضعیت سازه‌ها به شدت حائز اهمیت می‌باشد. وجود ترک و آسیب منجر به ایجاد مناطق تمرکز تنش موضعی و در نتیجه افزایش انعطاف‌پذیری سازه می‌شود. این امر باعث کاهش فرکانس‌های طبیعی ارتعاش سازه و تغییر شکل آن نیز می‌شود. بنابراین، تسهیل در تشخیص زودهنگام ترک‌ها ضروری است. با پیشرفت در الگوریتم‌های یادگیری ماشین

* پست الکترونیک نویسنده مسئول: massoudmir@qiet.ac.ir

۱. گروه مهندسی مکانیک، دانشکده فناوری های نوین، دانشگاه صنعتی قوچان، قوچان، ایران

استناد به این مقاله:

برای آزمایش سازه‌های دارای ترک تاکنون تغییرات زیادی در حوزه علوم کامپیوتر رخ داده که مستقیماً حوزه علوم محاسباتی را تحت تأثیر قرار داده است. یکی از این تغییرات توسعه درزمینه یادگیری ماشین می‌باشد. این یک ایده ۶۰ساله می‌باشد که نام آن در سال ۱۹۵۹ توسط یک دانشمند کامپیوتر آمریکایی، آرتور ساموئل ابداع شده است [۶]. گیلیچ و همکاران [۷]، استفاده از ابزارهای یادگیری ماشین مانند جنگل تصادفی (RF)^۳ و شبکه‌های عصبی مصنوعی (ANN)^۲ را برای ارزیابی ترک‌ها در یک تنظیم تیر کنسول منشوری معرفی نمودند. این روش به طور دقیق موقعیت‌های ترک را مشخص می‌کند و شدت آن‌ها را با دقت قابل توجهی تعیین می‌کند و نرخ خطای زیر ۰/۶ درصد را نشان می‌دهد. نتایج بر قابلیت اطمینان این رویکرد جدید برای ارزیابی آسیب در تحلیل ساختاری تأکید می‌کند. هاین و جانسکا [۸]، به تشخیص، محلی سازی و برآورد شدت ترک در تیرهای اویلر-برنولی در پایه پاسترناک پرداختند. با استفاده از شبکه‌های عصبی مصنوعی یا جنگل‌های تصادفی با فرکانس طبیعی و داده‌های شکل حالت، پیش‌بینی‌های دقیق ویژگی ترک به دست آوردند. سها و یانگ [۹]، کاربردهای شبکه عصبی را در تحلیل فرکانس طبیعی برای پایش سلامت ساختاری بررسی کردند و جایگزینی برای تکنیک‌های اجزای محدود ارائه دادند. آن‌ها از مجموعه داده‌های تست ارتعاش آماری و شبیه‌سازی‌های مونت کارلو برای پیش‌بینی دقیق فرکانس‌ها استفاده می‌کنند که با معادله برازش منحنی اعتبارسنجی می‌شوند و اثربخشی آن را در ارزیابی جابه‌جایی‌های فرکانس ناشی از سطوح متفاوت آسیب نشان می‌دهند.

در حوزه نظارت بر سلامت سازه، مواد سازنده تیر به طور قابل توجهی بر نتایج تشخیص ترک و ارزیابی آسیب تأثیر می‌گذارد. محققان مواد مختلفی را بررسی کرده‌اند که هرکدام چالش‌ها و مزیت‌های منحصر به فردی را ارائه می‌کنند. به عنوان مثال جنا [۱۰]، بر یافتن ترک در تیرهای کامپوزیت تقویت شده با استفاده از آزمایش‌ها و هوش مصنوعی متمرکز شده است. با ترکیب داده‌های آزمایش‌ها با شبکه‌های عصبی مصنوعی، به طور دقیق عمق ترک را تعیین و اندازه‌گیری می‌کند و نشان می‌دهد که چگونه جهت فیبر بر سختی تیر تأثیر می‌گذارد. این روش غیرمخرب هوش مصنوعی برای تشخیص عیب در مواد

عمق و موقعیت ترک بر فرکانس‌های طبیعی جستجو می‌شود. انجام چنین مطالعه‌ای اطلاعات ارزشمندی را در مورد سلامت سازه، طول عمر آن و احتمال آسیب یا تخریب بیشتر در صورت عدم توجه به آن ارائه می‌کند. در نتیجه، روش‌هایی که تشخیص و محلی سازی سریع ترک‌ها را امکان‌پذیر می‌سازند به‌عنوان کانون تحقیقات در دو دهه گذشته ظاهر شده است [۱۱].

پیشرفت در روش‌های عددی و تجربی به طور قابل توجهی محاسبه فرکانس‌های طبیعی و تشخیص ترک‌ها در سازه‌ها را بهبود بخشیده است. به طور خاص، کیم و تون [۱۲]، در کار خود روش جدیدی را برای تعیین فرکانس‌های طبیعی و تشخیص ترک‌های متعدد در تیرها معرفی کردند. آن‌ها یک فرمول قطعی را استخراج کردند که شدت ترک را در ضریب ریلی ادغام می‌کند و محاسبات پیچیده فرکانس را برای تیرهایی با تعداد ترک‌های مختلف ساده می‌کند. این تکنیک ابتکاری، همراه با روش اسکن ترک، ابزار قابل‌اعتمادی را برای تشخیص ترک‌های ناشناخته با استفاده از داده‌های فرکانس ارائه می‌دهد که از طریق شبیه‌سازی‌های عددی و مطالعات تجربی تأیید شده است. هوسین و لیپ [۱۳]، با تحقیق بر نانو تیرهای دوتایی مخروطی، از روش سری مکلورن و نظریه‌هایی مانند نظریه تیر اویلر-برنولی و نظریه ارینگن استفاده کردند. با مدل‌سازی سیستم با یک ترک و تجزیه و تحلیل عواملی مانند شدت ترک، این مطالعه نشان می‌دهد که چگونه جنبه‌های مختلف به طور قابل توجهی بر فرکانس طبیعی و پاسخ دینامیکی تأثیر می‌گذارند. گله بان و مرادی [۱۴]، از تبدیل هیلبرت-هوانگ به عنوان یک روش پردازش سیگنال استفاده کردند. به منظور محاسبه فرکانس‌های طبیعی تیر ترک‌دار، تئوری تیموشنکو بکار گرفته شده است. سپس با استفاده از سیگنال‌های ارتعاشی تیر ترک‌دار، فرکانس‌های طبیعی تجربی به کمک تبدیل فوریه سریع و تبدیل هیلبرت - هوانگ محاسبه شده‌اند. جمشیدی مقدم و مرادی [۱۵]، در پژوهش خود ارتعاشات آزاد تیر کمانه شده ترک‌دار به کمک روش کوادراتور دیفرانسیلی بررسی کردند. جهت بررسی صحت روش عددی ارائه شده و نتایج حاصل را با نتایج روش اجزاء محدود مقایسه می‌کنند. نتایج به دست آمده دقت بسیار خوب و کارایی روش پیشنهادی را نشان می‌دهد.

³ Artificial Neural Networks² Random Forest

چقدر است و با چه سرعتی در حال رشد هستند و می‌تواند برای بسیاری از انواع مختلف سازه‌ها مفید باشد. فلیه و همکاران [۱۵]، تشخیص عیب در سیستم‌های دوار را با محاسبه فرکانس‌های طبیعی یک شفت سالم با عمق ترک‌های متفاوت را مورد بررسی قرار دادند. با استفاده از تحلیل المان محدود در ANSYS، یک مدل شبکه عصبی مصنوعی با حداکثر خطای ۰/۶۷ درصد به دست آوردند که دقت آن پیش‌بینی قابل‌اعتماد را برای فرکانس‌های طبیعی در سیستم‌های دوار ارائه می‌دهد. عمر و خان [۱۶]، چگونگی انتشار ترک‌ها تحت بارها و دماهای مختلف را با استفاده از طیف وسیعی از ابزارهای یادگیری ماشین، از جمله تقویت گرادیان برای کامپوزیت‌ها و Ridge و k- نزدیک‌ترین همسایه برای پلیمرها و فلزات، بررسی کردند. تجزیه و تحلیل کامل آن‌ها از داده‌های تجربی، ارزیابی مدل‌ها از طریق میانگین مربعات خطا، کارایی آن‌ها را در پیش‌بینی رفتار ترک به طور دقیق در شرایط مختلف ارائه می‌دهد. ابلا و همکاران [۱۷]، بر روی تشخیص ترک در تیرهای اویلر-برنولی در حال چرخش با سرعت کم با استفاده از یک مدل رفتاری که قبلاً توسط خودشان توسعه داده شده است، تمرکز دارند. با ادغام فرکانس‌های طبیعی مدل با الگوریتم بهینه‌سازی خرگوش مصنوعی (ARO)^۶ بر اساس تاکتیک‌های بقای خرگوش، پارامترهای ترک مانند موقعیت و عمق به طور دقیق تخمین زده می‌شوند و زمینه را برای شناسایی ترک در سازه‌های تیر دوار از طریق روش بررسی سلامت فراهم می‌کند.

در سال‌های اخیر، استفاده از عکس‌ها و تصاویر به طور فزاینده‌ای در قلمرو هوش مصنوعی، به‌ویژه برای بهبود تجزیه و تحلیل ساختاری و تشخیص عیب، اهمیت یافته است. آراویند و همکاران [۱۸]، از پردازش تصویر، الگوریتم‌های یادگیری ماشین و برنامه‌نویسی پایتون برای طبقه‌بندی انواع شکست در تیرهای ژئوپلیمر و بتنی معمولی استفاده کردند و به دقت بالا، به ویژه با طبقه‌بندی بردار پشتیبان، دست یافتند. وو و لیو [۱۹]، با استفاده از تکنیک‌های یادگیری عمیق، بر توسعه مدل‌هایی برای ساختن آنالیز تصویر ترک تمرکز دارند که پیشرفت‌های قابل توجهی را در کارایی تشخیص نشان می‌دهند. مطالعه آن‌ها

کامپوزیتی مؤثر است. وو و لی [۱۱]، از یک مدل تقویت گرادیان شدید (XGB)^۴ برای پیش‌بینی اندازه ترک تیرهای فولادی بر اساس نوسانات فرکانس طبیعی استفاده کردند که دقت نظارت بر سلامت سازه را بالا می‌برد. با ادغام نتایج روش المان محدود با تقویت گرادیان شدید، ارزیابی دقیق آسیب و محلی سازی آن به دست می‌آید که نتیجه امیدوارکننده‌ای را برای کاربردهای عملی در مراقبت از سلامت سازه نشان می‌دهد. راویچاندان و همکاران [۱۲]، یک مدل ترک منحنی را در یک تیر کامپوزیت آلومینیومی بازایستی بررسی کردند و اعماق و مکان‌های مختلف ترک را مورد بحث قرار دادند. روش‌های محاسباتی و تجربی، از جمله روش مربعات دیفرانسیل، برای تحلیل فرکانس‌های طبیعی تیرهای ترک‌خورده و پیشنهاد یک سیستم نظارت بر سلامت سازه برای سازه‌های مرکب استفاده می‌شود. اعتبارسنجی با استفاده از MATLAB2019a و مقایسه با شبکه‌های عصبی مصنوعی، یافته‌های تحقیق را افزایش می‌دهد. شیرازی و همکاران [۱۳]، به نظارت بر سلامت ساختاری از طریق تجزیه و تحلیل داده‌های ارتعاشی تیرهای پلاستیکی تقویت‌شده با الیاف شیشه پرداختند و از شبکه^۵ 1D-CNN برای طبقه‌بندی مکان‌ها و شدت ترک بر اساس بازخورد ارتعاشی استفاده کردند. این مدل دقت قابل توجه ۹۵٪ برای نمونه‌های با یک ترک، ۹۳٪ برای موارد با دو ترک، و ۹۲٪ برای حالت‌های ترکیبی را نشان می‌دهد. این روش نه تنها کارایی پیش‌بینی را افزایش می‌دهد، بلکه با استفاده از داده‌های ارتعاشی خام، تشخیص آسیب در زمان واقعی را نیز امکان‌پذیر می‌کند.


درک اثرات بار و دما و متحرک بودن سیستم برای تشخیص و تجزیه و تحلیل دقیق ترک‌ها در اجزای سازه بسیار مهم است. گوین و همکاران [۱۴]، بر شناسایی ترک‌های متعدد در سازه‌ها تحت باری متحرک با استفاده از روشی به نام تحلیل موجک بر روی سیگنال‌های جابه‌جایی تمرکز کردند. این مطالعه روش جدیدی را معرفی می‌کند که با استفاده از الگوریتم‌های یادگیری عمیق، نگاه به بخش‌های ثابت و در حال تغییر این سیگنال‌ها را برای یافتن مکان و چگونگی شکل‌گیری ترک‌ها ترکیب می‌کند. این تحقیق کمک می‌کند تا مشخص شود ترک‌ها کجا هستند، تعداد آن‌ها

⁶ Artificial Rabbits Optimization

⁴ Extreme Gradient Boosting

⁵ 1-D Convolutional Neural Network

مکان‌های در x_{c1} و x_{c2} قرار دارند، بر سطح این تیر رسم شده است.



شکل ۱- تیری ساده با دو ترک

$f(a_1)$ انعطاف‌پذیری مقطعی بدون بعد یک تیر ترک‌خورده را نشان می‌دهد. انعطاف‌پذیری به عنوان یک معیار حیاتی عمل می‌کند، که منعکس‌کننده میزان تغییر شکل یک ماده در هنگام قرار گرفتن در معرض نیروهای خارجی است که در این مثال، ارتباط نزدیکی با وجود ترک دارد. محاسبه انعطاف‌پذیری با رابطه زیر تعیین می‌شود:

$$f(a_j) = 2 \left(\frac{a_j}{1-a_j} \right)^2 (5.93 - 19.69a_j + 37.14a_j^2 - 35.64a_j^3 + 13.12a_j^4) \quad (1)$$

در معادله (۱)، اندیس j اعداد ۱ و ۲ را به خود اختصاص می‌دهد که بیانگر ترک اول یا دوم است. a_j نشان‌دهنده نسبت عمق بدون بعد می‌باشد که به صورت $a_j = d_j/h$ تعریف شده است. این معادله تأثیر عمیق ترک‌ها بر سختی و انعطاف‌پذیری تیر را نشان می‌دهد.

روش رایلی به عنوان یک تکنیک قوی برای تخمین فرکانس‌های طبیعی سازه‌ها، به ویژه تیرها ظاهر می‌شود. بر اساس اصل بقای انرژی، این روش ادعا می‌کند که در حداکثر جابه‌جایی (انحراف) یک سیستم ارتعاشی، در حالت دلخواه n حداکثر انرژی پتانسیل $U_{max,n}$ با حداکثر انرژی جنبشی $T_{max,n}$ برابر می‌باشد.

با حل روش ذکر شده برای تیری با مشخصات فوق نتیجه زیر حاصل می‌شود:

$$\omega_n = \omega_{n,nc} \left[\frac{3+6H}{3+12H+2n^4\pi^4(h/l)^2G} \right]^{1/2} \quad (2)$$

که در آن $\omega_{n,nc}$ نشان‌دهنده n امین فرکانس طبیعی تیر سالم و بدون آسیب است.

با استفاده از شبکه‌های عصبی کانولوشنال عمیق، شناسایی و تجزیه و تحلیل ترک را پیش می‌برد، از روش‌های پردازش تصویر برای کمی کردن نتایج تقسیم‌بندی استفاده می‌کند. محققان مختلف با استفاده از تکنیک‌های پیچیده مانند سری مک لورن، اسکن ترک باهوش مصنوعی و غیره پیشرفت‌های قابل‌توجهی در تشخیص ترک و تعیین فرکانس طبیعی در تیرها داشته‌اند اما با بررسی‌های انجام شده مشخص گردید تا کنون تحقیقی به پیش‌بینی فرکانس‌های طبیعی تیری که در شکل (۱) آورده شده است به وسیله الگوریتم‌های تحقیق حاضر (که در ادامه توضیحات جامع‌تری در مورد آن‌ها داده می‌شود) نپرداخته است. این مطالعات نه تنها قابلیت‌های تحلیل سازه را افزایش داده‌اند، بلکه پیچیدگی‌های موجود در تحلیل‌های دینامیکی و تأثیر عمیق عوامل مختلف بر فرکانس‌های طبیعی در سیستم‌های تیر را نیز روشن کرده‌اند. رویکردهای پیشرفته، مانند شبکه‌های عصبی مصنوعی و تکنیک‌های گسترش مودال، راه را برای پیش‌بینی دقیق ترک و نظارت بر سلامت سازه هموار کرده‌اند و از ارزیابی‌های دقیق در ساختارهای مختلف مواد اطمینان می‌دهند. ادغام فناوری‌های یادگیری ماشین پیشرفته و هوش مصنوعی متدولوژی‌های تشخیص ترک را متحول می‌کند و امکان تشخیص آسیب در زمان واقعی را با دقت استثنایی در طبقه‌بندی ترک‌ها و پیش‌بینی رفتار آن‌ها فراهم می‌کند.

در این مطالعه چند الگوریتم قدرتمند یادگیری ماشین نظیر: رگرسیون جنگل تصادفی (RFR)^۷، رگرسیون تقویت‌کننده گرادیان (GBR)^۸، پرسپترون چندلایه‌ای (MLP)^۹ و رگرسیون درخت تصمیم (DTR)^{۱۰} مورد استفاده قرار می‌گیرد و با ارزیابی کامل عملکرد الگوریتم‌های پیش‌بینی و تجزیه و تحلیل نقاط قوت و ضعف در حجم‌های مختلف داده و پارامترهای خروجی، بر تأثیر قابل توجه ویژگی‌های ترک بر فرکانس‌های طبیعی تأکید می‌شود.

۲- شرح فیزیکی سیستم

یک تیر دارای ترک با تکیه‌گاه ساده همان‌طور که در شکل (۱) نشان داده شده است دارای طول l می‌باشد. مقطع این تیر به صورت مستطیل با ارتفاع h و عرض b در نظر گرفته شده است. دو ترک در عمق‌های d_1 و d_2 که به ترتیب در

⁹ Multi Layer Perceptron

¹⁰ Decision Tree Regression

⁷ Random Forest Regression

⁸ Gradient Boosting Regression

می‌گیرد: رگرسیون و طبقه‌بندی. رگرسیون خروجی‌های پیوسته را به صورت اعداد حقیقی پیش‌بینی می‌کند، در حالی که طبقه‌بندی، نمونه‌های داده جدید را بر اساس داده‌های آموزشی برچسب‌گذاری شده، در کلاس‌های از پیش تعریف‌شده دسته‌بندی می‌کند. این تمایز برای انتخاب الگوریتم‌ها و تکنیک‌های مناسب برای توسعه برنامه‌های یادگیری ماشین بسیار مهم است.

تحلیل مسئله نشان می‌دهد که یک مدل رگرسیون مناسب است. مدل RegressorChin از کتابخانه Sklearn پیاده‌سازی شده است، زیرا الزامات تحقیق را برآورده می‌کند. این مدل به طور مؤثر چندین متغیر ورودی را مدیریت می‌کند و در عین حال چندین متغیر خروجی تولید می‌کند و یک رویکرد تحلیلی جامع ارائه می‌دهد.

یکی از ویژگی‌های قابل توجه RegressorChin توانایی آن در محاسبه ارتباطات پیچیده بین متغیرهای ورودی و خروجی می‌باشد که پردازش زنجیره‌وار داده‌ها را آسان می‌کند، این مشخصه بسیار مهم است؛ زیرا به ما اجازه می‌دهد تا روابط موجود در مجموعه داده را کشف و مهار کنیم. در ادامه، مجموعه‌ای از الگوریتم‌های تثبیت شده در حوزه یادگیری تحت نظارت استفاده می‌شود. این الگوریتم‌ها به طور سیستماتیک در ارتباط با مدل هسته RegressorChin اعمال می‌شوند. از طریق ارزیابی دقیق نرخ خطا و تجزیه و تحلیل مقایسه‌ای، الگوریتم‌هایی که کمترین حاشیه خطا را نشان می‌دهند، شناسایی می‌شوند. هدف، اطمینان از این می‌باشد که روش‌های انتخاب‌شده عملکرد بهینه را در پیش‌بینی فرکانس‌های طبیعی ساختار مورد نظر ارائه می‌کنند. در بخش بعدی مروری مختصر از الگوریتم‌های به کاررفته در این تحقیق ارائه می‌شود.

در الگوریتم DTR یکی از نقاط قوت، تفسیر شهودی آن می‌باشد، زیرا به نحوه تفکر و پیش‌بینی نتیجه توسط انسان‌ها با طرح سؤالات بسیار نزدیک است. این یک روش ناپارامتریک می‌باشد به این معنی که این مدل فرض دقیقی در مورد توزیع متغیر نتیجه ندارد [۲۱]. الگوریتم GBR یکی دیگر از مدل‌های پژوهش می‌باشد که هدف آن پیش‌بینی مقادیر عددی پیوسته است. این الگوریتم مجموعه‌ای تکراری از مدل‌های درختی می‌باشد که به صورت متوالی مرتب شده‌اند تا مدل بعدی از خطای مدل قبلی درس بگیرد و یک مدل پیش‌بینی قوی‌تری بسازد [۲۲]. الگوریتم RFR چندین درخت تصمیم را که برای

$$\omega_{n,nc} = \left(\frac{n\pi}{l}\right)^2 \sqrt{\frac{EI}{\rho A}} \quad (3)$$

$$H = \frac{h}{l} [f(a_1) \sin^2(n\pi\bar{x}_{c1}) + f(a_2) \sin^2(n\pi\bar{x}_{c2})] \quad (4a)$$

$$G = J^2 \bar{x}_{c1}^2 (1 - \bar{x}_{c1})^2 + F^2 \bar{x}_{c2}^2 (1 - \bar{x}_{c2})^2 + JF \bar{x}_{c1} \bar{x}_{c2} (\bar{x}_{c1}^2 + \bar{x}_{c2}^2 + 2) - JF \bar{x}_{c1} (\bar{x}_{c1}^2 + 3\bar{x}_{c2}^2) \quad (4b)$$

$$J = f(a_1) \sin(n\pi\bar{x}_{c1}) \quad (4c)$$

$$F = f(a_2) \sin(n\pi\bar{x}_{c2}) \quad (4d)$$

توجه به این نکته ضروری است که \bar{x}_c از معادله زیر به دست می‌آید:

$$\bar{x}_c = \frac{x_c}{l} \quad (5)$$

متغیر x_c موقعیت ترک را نشان می‌دهد. با نرمال کردن مقدار از طریق معادله (۵)، به یک کمیت بدون بعد تبدیل می‌شود. این رویکرد مقایسه رفتار ترک در مواد یا سازه‌هایی با اندازه‌ها و نسبت‌های مختلف را آسان می‌کند.

ادغام روش رایلی [۲۰] برای تعیین تحلیلی فرکانس‌های طبیعی با تکنیک‌های پیشرفته یادگیری ماشین، چارچوبی قدرتمند برای مدل‌سازی رفتار سازه‌های تیر تحت شرایط مختلف ارائه می‌دهد. این رویکرد باعث افزایش دقت پیش‌بینی می‌شود، به‌ویژه در حالت‌هایی که آسیب ساختاری ممکن است خطرات قابل توجهی ایجاد کند.

۳- روش حل مسئله

۳-۱- یادگیری ماشین

یادگیری ماشین به عنوان زیرمجموعه‌ای از هوش مصنوعی، الگوریتم‌هایی را توسعه می‌دهد که به رایانه‌ها اجازه می‌دهد بدون برنامه‌نویسی صریح، از داده‌ها یاد بگیرند و بهبود یابند. این الگوریتم‌ها با استفاده از روش‌های آماری، الگوها و روابط موجود در داده‌ها را شناسایی می‌کنند تا در موقعیت‌های جدید پیش‌بینی یا تصمیم‌گیری کنند. هدف اصلی، دستیابی به پیش‌بینی‌های دقیق با بهینه‌سازی توابع هدف و تنظیم پارامترهای مدل است.

۳-۲- حل مسئله با یادگیری ماشین

یک گام کلیدی در پیاده‌سازی الگوریتم‌های یادگیری ماشین، انتخاب نوع مدل مناسب است که در دو دسته قرار

اهداف رگرسیون طراحی شده‌اند، یکپارچه می‌کند. پیش‌بینی‌ها از میانگین پیش‌بینی‌های تولید شده توسط هر درخت به دست می‌آیند. جنگل تصادفی به دلیل توانای آن در مدیریت روابط پیچیده بین متغیرها و عملکرد خوب در انواع مختلف داده‌ها شناخته می‌شوند [۲۳]. الگوریتم MLP یک الگوریتم قدرتمند برای حل مسائل یادگیری تحت نظارت است. پرسپترون چندلایه‌ای دارای چندین مزیت مانند توانایی در یادگیری روابط پیچیده غیرخطی، مدیریت داده‌های با ابعاد بالا و تعمیم قوی برای نمونه‌های دیده نشده می‌باشد [۲۴].

۳-۳- محاسبه خطا

محاسبه خطا جزء کلیدی علم یادگیری ماشین است که برای توسعه، ارزیابی و اصلاح مدل‌های پیش‌بینی ضروری می‌باشد. این رویکرد میزان مطابقت پیش‌بینی‌های یک مدل با نتایج واقعی را ارائه می‌دهد. با استفاده از معیارهای خطا، مانند میانگین خطای مطلق، ریشه میانگین مربعات خطا، یا دقت طبقه‌بندی، عملکرد یک مدل را به طور عینی سنجیده می‌شود. این ارزیابی کمی نه تنها به شناسایی مناطقی که مدل ممکن است ضعیف عمل کند کمک می‌کند، بلکه مقایسه بین الگوریتم‌های مختلف را آسان و انتخاب مؤثرترین رویکرد را برای یک مشکل خاص راهنمایی می‌کند.

یکی از روش‌های کاربردی در زمینه محاسبه خطا در مباحث رگرسیونی روش R^2 (R-squared) است که یک روش متریک آماری می‌باشد و برای ارزیابی عملکرد مدل‌های رگرسیون با اندازه‌گیری نسبت واریانس در متغیر وابسته که از روی متغیرهای مستقل قابل پیش‌بینی است، استفاده می‌شود. به طور خاص، R^2 از طریق معادله زیر محاسبه می‌شود:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (11)$$

که در معادله (۱۱) SS_{res} مجموع مربعات باقیمانده (تفاوت بین مقادیر مشاهده شده و پیش‌بینی شده) و SS_{tot} مجموع مجذورات (کل واریانس در متغیر وابسته) می‌باشد.

از دیگر روش اعتبارسنجی مدل‌های یادگیری ماشین با اضافه کردن معیارهایی مانند MSE و MAE می‌باشد. MSE میانگین مربعات خطاها بین مقادیر پیش‌بینی شده و واقعی را اندازه‌گیری می‌کند که به دلیل اثر مربع سازی،

۴-۳- بررسی تأثیر نویز داده‌ها

در یادگیری ماشین، افزودن نویز به داده‌های ورودی کمک می‌کند که مدل‌های قوی‌تری ایجاد شود. این مدل‌ها می‌توانند به داده‌های دیده نشده تعمیم بهتری داشته باشند و عدم قطعیت‌های ذاتی موجود در داده‌ها را در نظر بگیرند. یکی از روش‌های متداول و کاربردی در این زمینه اضافه کردن نویز گاوسی و همچنین نویز سفید است. نویز گاوسی معمولاً برای مدل‌سازی عدم قطعیت در مسائل یادگیری ماشین استفاده می‌شود، زیرا به طور دقیق تغییرپذیری طبیعی موجود در بسیاری از مجموعه داده‌های دنیای واقعی را منعکس می‌کند. این نوع نویز با توزیع نرمال با منحنی زنگوله‌ای^{۱۱} شکل مشخص می‌شود که با میانگین (μ) و انحراف معیار (σ) آن تعریف می‌شود. تابع چگالی احتمال برای نویز گاوسی را می‌توان به صورت زیر بیان کرد:

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (12)$$

نویز سفید با نمایش یک فرآیند تصادفی با توان ثابت در تمام فرکانس‌ها، عملاً نشان می‌دهد که هیچ الگو یا همبستگی در داده‌ها وجود ندارد. این نویز شامل دنباله‌ای از متغیرهای تصادفی غیر همبسته با میانگین صفر و واریانس ثابت (σ^2) است. ویژگی آماری نویز سفید را می‌توان با مقدار مورد انتظار بیان کرد:


$$E[X(t)] = 0 \quad (13)$$

$$E[X(t)X(s)] = \sigma^2 \delta(t-s) \quad (14)$$

که در آن $\delta(t-s)$ تابع دلتای دیراک است و نشان می‌دهد نویز در نقاط زمانی مختلف غیر همبسته است. در یادگیری ماشین، نویز سفید را می‌توان به مجموعه داده‌ها یا ورودی‌های مدل اضافه کرد تا استحکام الگوریتم‌ها در برابر نوسانات تصادفی را آزمایش کند و به محققان این امکان را می‌دهد تا تعیین کنند که مدل‌ها چقدر خوب

¹¹ Bell curve

نکته قابل توجه این است که پاتیل و مایتی [۲۵] نتایج خود را با استفاده از روش المان محدود (FEM) تأیید کرده‌اند که حاشیه خطا آن کمتر از ۵٪ است. از این رو می‌توان نتیجه گرفت مرجع [۲۰] هم معیاری تحلیلی-عددی-ارابه می‌دهد که به فرمول تحلیلی منجر می‌شود که برای داده سازی در هوش مصنوعی بسیار مناسب است و با روش المان محدود (FEM) حداکثر ۵٪ اختلاف دارد.



شکل ۲- اثر عمق ترک اول بر روی اولین فرکانس طبیعی یک تیر دارای دو ترک که موقعیت ترک اول و دوم به ترتیب ۰/۳ و ۰/۶ و عمق ترک دوم ۰/۵ از سطح تیر

شکل (۲)، رابطه بین عمق ترک اول و اولین فرکانس طبیعی تیر و همچنین مقایسه روش عددی و شبیه‌سازی را مورد بررسی قرار می‌دهد. منحنی مشکی به عنوان یک منحنی مرجع عمل می‌کند و معیاری را ارائه می‌دهد که بر اساس آن می‌توان عملکرد تکنیک‌های یادگیری ماشین در این تحقیق را ارزیابی کرد.

قابل ذکر است، در حالی که الگوریتم‌های هوش مصنوعی روندی به طور کلی مشابه دارند، اما با افزایش عمق ترک، نوسانات قابل توجهی نسبت به منحنی مرجع [۲۰] را نیز نشان می‌دهند. این نوسانات نشان می‌دهد که برخی از مدل‌ها ممکن است برای ثبت دقیق پیچیدگی‌های داده‌ها با مشکل مواجه شوند. با این حال، منحنی‌های رگرسیون تقویت گرادیان (GBR) و رگرسیون جنگل تصادفی (RFR) به دلیل عملکرد نسبتاً پایدار و همسویی نزدیک‌تر با منحنی مرجع در کل محدوده، نسبت به سایر الگوریتم‌ها برتر هستند. این سازگاری نشان می‌دهد که این مدل‌ها در گرفتن روابط پیچیده موجود در داده‌ها مهارت دارند که اثربخشی آن‌ها را برای این نوع تحلیل افزایش می‌دهند.

می‌توانند عدم قطعیت را در داده‌هایی که با آن‌ها مواجه می‌شوند، مدیریت کنند.

۳-۵- بررسی عدم قطعیت

عدم قطعیت در یادگیری ماشین به غیر قابل پیش‌بینی بودن ذاتی خروجی‌های مدل اشاره دارد که از دو منبع اصلی ناشی می‌شود: عدم قطعیت تصادفی^{۱۲} که مرتبط با تغییرات تصادفی و عدم قطعیت معرفتی^{۱۳} که ناشی از کمبود دانش می‌باشند. درک و تخمین این عدم قطعیت برای تصمیم‌گیری قوی، ارزیابی مدل و مدیریت ریسک بسیار مهم است و به متخصصان این امکان را می‌دهد تا با اطمینان بیشتری پیچیدگی‌های برنامه‌های دنیای واقعی را پیمایش کنند.

در این تحقیق بر عدم قطعیت تصادفی تمرکز شده است، زیرا به تغییرپذیری در پیش‌بینی‌های مدل ناشی از نویز تصادفی در داده‌ها مربوط می‌شود. برای محاسبه عدم قطعیت تصادفی از رابطه زیر استفاده می‌شود:

$$\text{عدم قطعیت تصادفی} = \frac{1}{N} \sum_{i=1}^N (y_i - \mu_i)^2 \quad (15)$$


که در آن N تعداد نمونه‌ها، y_i مقدار واقعی و μ_i مقدار پیش‌بینی شده برای نمونه i ام است.

۴- بحث و بررسی نتایج

در این مطالعه تأثیر ترک‌های تیر در مقادیر فرکانس‌های طبیعی مورد بررسی قرار می‌گیرد و به دنبال آن سعی بر آن می‌شود که از علم یادگیری ماشین برای نوشتن نزدیک‌ترین کد دستوری جهت تعیین فرکانس‌های طبیعی تیر ترک‌دار استفاده شود. برای رسیدن به این هدف الگوریتم‌های مختلفی به کار گرفته و همچنین به تحلیل و مقایسه میزان خطاها هر یک پرداخته می‌شود. در شکل (۲) منحنی مربوط به مرجع [۲۰] به عنوان معیاری در نظر گرفته می‌شود که از این پس تمام الگوریتم‌ها بر اساس آن ارزیابی می‌شوند. مرجع [۲۰] نتایج خود را با تحقیق انجام شده بوسیله پاتیل و مایتی [۲۵] مقایسه و صحت‌سنجی کرده که این دو مقاله سطح بالایی از سازگاری را نشان می‌دهند و دارای درصد اختلاف نزدیک به صفر می‌باشد.

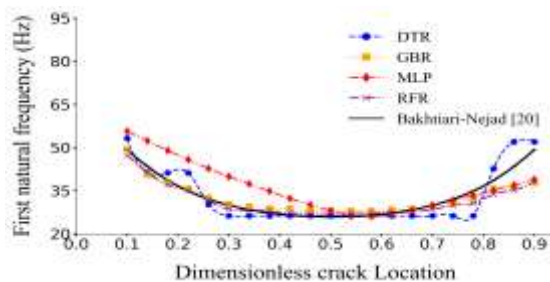
¹³ Epistemic Uncertainty

¹² Aleatoric uncertainty



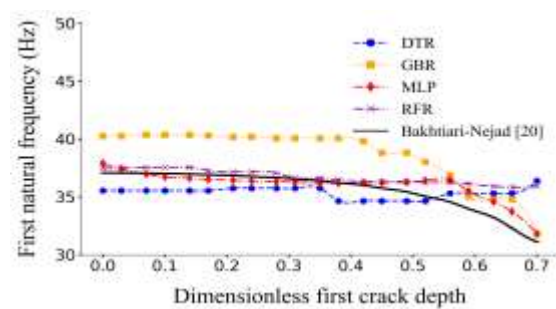
شکل ۵- اثر عمق ترک بر روی دومین فرکانس طبیعی یک تیر دارای ترک در موقعیت ۰/۶ از سر تیر

در شکل (۵) تأثیر عمق ترک بر روی دومین فرکانس طبیعی مورد بررسی قرار می‌گیرد. مقایسه شکل (۴) و (۵) نتیجه می‌دهد که مقادیر فرکانس دوم اعداد بزرگتری نسبت به فرکانس اول را به خود اختصاص می‌دهند اما با این وجود باز هم با عمق ترک رابطه عکس داشته و با افزایش عمق ترک مقادیر فرکانس دوم رو به کاهش می‌باشند. مدل پرسپترون چندلایه (MLP) به عنوان مؤثرترین پیش‌بینی کننده ظاهر می‌شود و توانایی خود را در مدیریت پیچیدگی و حفظ دقت در تمام اعماق بررسی شده نشان می‌دهد. در همین حال، الگوریتم‌های رگرسیون درخت تصمیم (DTR)، رگرسیون تقویت گرادیان (GBR) و رگرسیون جنگل تصادفی (RFR) محدودیت‌هایی را در دقت پیش‌بینی خود، به ویژه در عمق ترک بیشتر نشان می‌دهند که نیاز به توجه دقیق هنگام انتخاب مدل‌ها برای برنامه‌های نظارت بر سلامت سازه بیان می‌کنند.




شکل ۶- اثر مکان ترک بر روی اولین فرکانس طبیعی یک تیر دارای ترک در عمق ۰/۸ از سطح تیر

شکل (۶) برای تیری با یک ترک نشان می‌دهد که چگونه اولین فرکانس طبیعی تیر بر اساس مکان ترک، با عمق ترک مشخص شده ۰/۸ تغییر می‌کند. منحنی مرجع نشان می‌دهد زمانی که ترک در بخش میانی تیر قرار دارد مقدار فرکانس طبیعی مجدد افت می‌کند و هر چه مکان ترک به سمت سر تیر جابجا می‌شود بر مقدار فرکانس نیز افزوده می‌شود. بنابراین ترک در بخش میانی تیر باعث



شکل ۳- اثر عمق ترک اول بر روی اولین فرکانس طبیعی یک تیر دارای دو ترک که موقعیت ترک اول و دوم به ترتیب ۰/۳ و ۰/۶ و عمق ترک دوم ۰/۷ از سطح تیر

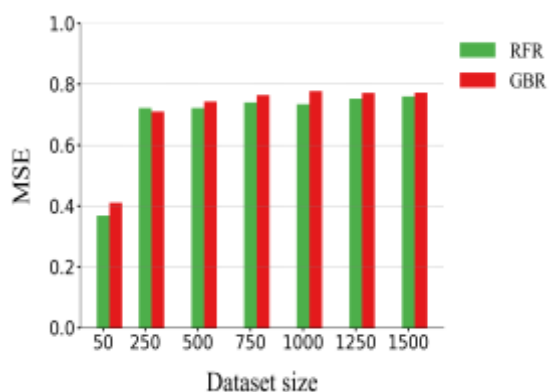
در شکل (۳) عمق ترک دوم از ۰/۵ به ۰/۷ افزایش پیدا کرده که این امر سبب کاهش کلی مقادیر فرکانس طبیعی اول شده است علاوه بر این با افزایش تدریجی عمق ترک اول مقادیر فرکانس مجدد همانند شکل (۲) سیر نزولی نشان می‌دهند. در ادامه منحنی MLP با پیش‌بینی قوی خود را به لیست الگوریتم‌های برتر در این شکل اضافه می‌کند.



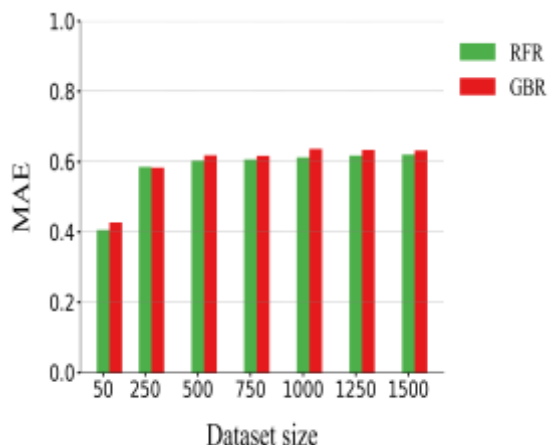
شکل ۴- اثر عمق ترک بر روی اولین فرکانس طبیعی یک تیر دارای ترک در موقعیت ۰/۶ از سر تیر

شکل (۴) رابطه بین عمق ترک واقع در ۰/۶ از سطح تیر و تغییرات اولین فرکانس طبیعی آن را که بر حسب هر تیر (Hz) اندازه‌گیری شده است، نشان می‌دهد. تغییرات مقادیر اولین فرکانس طبیعی بر اساس عمق ترک بر روی شکل نشان دهنده رابطه عکس بین آن‌ها می‌باشد. در ادامه مقایسه بین پیش‌بینی الگوریتم‌ها با منحنی مرجع قرار گرفته است. در شکل (۴) با توجه به وجود تنها یک ترک، هر الگوریتم ۲ پارامتر ورودی (عمق و مکان ترک دوم) کمتر از شکل‌های (۲) و (۳) دارند که این موضوع باعث افزایش در دقت پیش‌بینی شده است. اکثر الگوریتم‌ها دقت قابل قبولی را به ثبت رسانده‌اند با این وجود الگوریتم MLP یک روند پیش‌بینی شده قوی را نشان می‌دهد که به خوبی با منحنی مرجع همسو می‌شود.

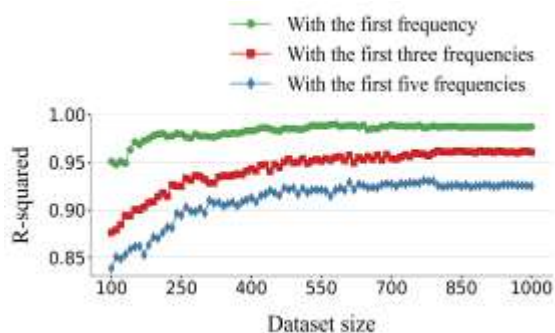
نشان می‌دهد، دقت خوبی در مجموعه داده‌های کوچک‌تر دارد و با افزایش اندازه حجم داده‌ها جهت پیش‌بینی، دقت الگوریتم هم رشد می‌کند. با این حال، GBR به طور مداوم از RFR در سراسر صفحه برتری دارد و در نهایت با حجم داده‌های بزرگ‌تر به بهترین عملکرد خود می‌رسد. در این تحقیق هر دو الگوریتم به رشد حجم داده پاسخ مثبت نشان می‌دهد و دقت پیشینی آن‌ها افزایش پیدا می‌کند.



شکل ۹- تأثیر حجم دیتاست در دقت (با روش MSA) برای الگوریتم‌های یادگیری ماشین




شکل ۱۰- تأثیر حجم دیتاست در دقت (با روش MAE) برای الگوریتم‌های یادگیری ماشین

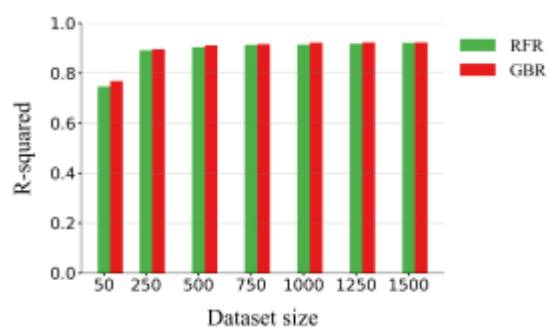


شکل ۱۲- تأثیر تعداد پارامترهای پیش‌بینی شده در دقت برای الگوریتم GBR

آسیب‌پذیری و احتمال تخریب بیشتر می‌شود. عملکرد الگوریتم‌ها در شکل (۶) به وضوح نشان می‌دهد الگوریتم‌های قوی در این آزمایش نیز GBR، RFR و MLP می‌باشند.




شکل ۷- اثر مکان ترک اول بر روی اولین فرکانس طبیعی یک تیر دارای دو ترک که عمق ترک اول و دوم به ترتیب ۰/۳ و ۰/۶ و مکان ترک دوم ۰/۸ از سر تیر




شکل ۸- تأثیر حجم دیتاست در دقت (با روش R-squared) برای الگوریتم‌های یادگیری ماشین

در شکل (۷) مجدد دو ترک بر روی سطح تیر در نظر گرفته شده است و اثر مکان بر روی اولین فرکانس تیر مورد تحلیل قرار گرفته است. نتایج نشان می‌دهد فرکانس اول تیر با دو ترک همانند شکل (۶) (تیر با یک) در بخش میانی دچار افت می‌شود. البته این کاهش مقادیر فرکانس بسیار کمتر از حالت شکل (۶) و نهایتاً حدود ۵ هرتز می‌باشد. الگوریتم DTR جز الگوریتم‌های ضعیف مجموعه می‌باشد و برعکس، منحنی MLP منحنی مرجع را از نزدیک دنبال می‌کند و قابلیت‌های پیش‌بینی قوی و درک عمیق الگوهای داده را نشان می‌دهد و آن را به عنوان یک انتخاب قابل اعتماد برای مدل‌سازی دقیق قرار می‌دهد.

شکل (۸) تجزیه و تحلیل مقایسه‌ای از دقت دو الگوریتم برتر یادگیری ماشین با روش R-squared (R^2) ارائه می‌کند: GBR و RFR، که در اندازه‌های داده‌های مختلف از ۵۰ تا ۱۵۰۰ ارزیابی می‌شوند. RFR عملکرد قوی را



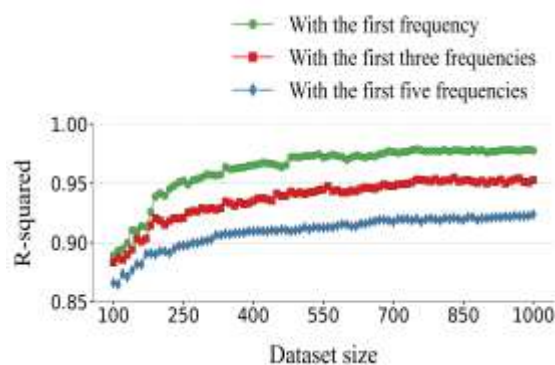
شکل ۱۴- اثر عمق ترک اول بر روی اولین فرکانس طبیعی یک تیر دارای دو ترک که موقعیت ترک اول و دوم به ترتیب ۰/۳ و ۰/۶ و عمق ترک دوم ۰/۵ از سطح تیر بر اساس نویز گوسی



شکل ۱۵- اثر عمق ترک اول بر روی اولین فرکانس طبیعی یک تیر دارای دو ترک که موقعیت ترک اول و دوم به ترتیب ۰/۳ و ۰/۶ و عمق ترک دوم ۰/۵ از سطح تیر بر اساس نویز سفید

همان طور که در شکل‌های (۱۴) و (۱۵) ملاحظه می‌شود پیش‌بینی‌ها دقت مطلوب‌تری به خود گرفته است. استفاده از نویز گاوسی منجر به نمایش دقیق‌تر داده‌ها می‌شود و دقت پیش‌بینی‌ها را مشخص می‌کند، زیرا نویز حول یک مقدار میانگین متمرکز شده و امکان حفظ روندهای اساسی را فراهم می‌کند و در عین حال سطح قابل کنترلی از تغییرپذیری را ارائه می‌دهد. به طور کلی، نتایج نشان می‌دهد که نویز گاوسی وضوح دقت پیش‌بینی‌ها را به طور مؤثرتری نسبت به نویز سفید بهبود می‌بخشد و عملکرد برتر خود را در حفظ یکپارچگی سیگنال اساسی در میان تصادفی بودن نشان می‌دهد. با مقایسه شکل‌های (۱۴) و (۱۵) با شکل (۲) می‌توان دریافت که افزودن نویز بر پیش‌بینی الگوریتم‌ها تأثیر چندانی ندارد و الگوریتم‌ها به نویز مقاوم می‌باشند.

شکل (۹) و (۱۱) نشان دهنده میزان دقت به دو روش MAE و MSE برای دو الگوریتم RFR و GBR می‌باشد. با مقایسه تجمیعی بین سه روش ارائه شده در شکل‌های (۸)، (۹) و (۱۰) برای بررسی دقت الگوریتم‌ها، GBR در همه روش‌ها بیشترین دقت را دارد. علاوه بر این موضوع لازم به ذکر است با توجه به نوع مسئله و همچنین داده‌های آموزشی بهترین روش برای محاسبه میزان دقت الگوریتم‌ها R-squared می‌باشد.



شکل ۱۳- تأثیر تعداد پارامترهای پیش‌بینی‌شده در دقت برای الگوریتم RFR

شکل (۱۲) و شکل (۱۳) برای دیتاست‌های مختلف، دقت با استفاده از روش R^2 محاسبه می‌شود و همچنین الگوریتم‌های مورد استفاده RFR و GBR می‌باشند. هر الگوریتم چهار ورودی، عمق و مکان ترک‌های اول و دوم را می‌گیرد و خروجی را در سه حالت متفاوت پیش‌بینی می‌کند: در حالت اول، خروجی تنها فرکانس اول را نشان می‌دهد، در حالت دوم، خروجی سه فرکانس اول و در حالت سوم، خروجی شامل پنج فرکانس اول می‌باشد. همان طور که اندازه مجموعه داده افزایش می‌یابد، واضح است که هر منحنی یک‌روند صعودی کلی را در دقت نشان می‌دهند. قابل‌ذکر است در حالت اول که خروجی الگوریتم تنها فرکانس اول را نشان می‌دهد به طور مداوم سطح دقت بالاتری دارد که نشان دهنده تناسب بهتر در مقایسه با سایر حالت‌ها می‌باشد.

در شکل‌های (۱۴) و (۱۵)، شکل (۲) به ترتیب با نویز گوسی و نویز سفید همراه شده و مورد بررسی قرار گرفته شد.

پس از بررسی دقیق این الگوریتم‌ها، رگرسیون تقویت‌کننده گرادیان را به عنوان مناسب‌ترین الگوریتم برای مطالعه خود شناسایی و انتخاب کرده‌ایم. توانایی آن در مدیریت مجموعه داده‌های پیچیده و دقت بالای آن در بسیاری از حالت‌های پیش‌بینی، به خوبی با اهداف ما برای پیش‌بینی دقیق فرکانس‌های طبیعی همسو است. علاوه بر این، قدرت تفسیری رگرسیون تقویت‌کننده گرادیان، همراه با انعطاف‌پذیری و سازگاری آن از طریق تنظیم هایپرپارامتر، توسعه یک مدل پیش‌بینی قابل اعتماد متناسب با نیازهای ما را تسهیل می‌کند.

استفاده از الگوریتم‌های یادگیری ماشین، نیاز به محاسبات دستی یا مدل‌سازی تحلیلی را از بین می‌برد و راه‌حل کارآمدتر و قابل‌اعتمادتری برای تشخیص ترک و ارزیابی یکپارچگی ساختاری ارائه می‌دهد. علاوه بر این، مطالعه همگرایی را می‌توان برای ارزیابی تیرهایی با ابعاد و خواص مواد مختلف گسترش داد و درک جامع‌تری از رفتار آن‌ها ارائه کرد. در نتیجه، نتایج این مطالعه کاربرد موفقیت‌آمیز الگوریتم‌های یادگیری ماشین را در پیش‌بینی فرکانس‌های طبیعی در تیرهای دو ترک نشان می‌دهد.

از جمله راهبردها برای افزایش اثر بخشی روش‌های این تحقیق، توسعه یک رابط کاربری برای اپراتورهای صنعتی می‌باشد. این رابط کاربری از قدرت مدل‌های عددی پیچیده که با روش‌های پیشرفته یادگیری ماشین ادغام شده، استفاده می‌کند و نتایج آن‌ها را از طریق یک پلت فرم چشمی ارائه می‌کند. با انجام این کار، اپراتورها به ابزارهای لازم برای تصمیم‌گیری آگاهانه و به موقع در مورد فعالیت‌های تعمیرات و نگهداری سازه مجهز می‌شوند. از دیگر تلاش‌های تحقیقاتی آینده می‌تواند بر روی رفتار وابسته به زمان ترک‌ها باشند و پیچیدگی‌های چگونگی تأثیر رشد و انتشار ترک بر فرکانس‌های طبیعی در طول زمان را بررسی کنند. درک این رابطه برای ارزیابی دقیق یکپارچگی سازه و پیش‌بینی شکست‌های احتمالی بسیار مهم است. در نهایت یکی دیگر از تحقیقات آینده می‌تواند بر تجزیه و تحلیل دقیق‌تر هندسه‌های مختلف ترک و تأثیر آن‌ها بر رفتار تیر متمرکز شود.

۵- نتیجه‌گیری

این مطالعه عملکرد چندین الگوریتم یادگیری ماشین نظیر رگرسیون جنگل تصادفی (RFR)، رگرسیون تقویت‌کننده

در جدول ۱ عدم قطعیت تصادفی چهار الگوریتم مورد بحث در این تحقیق برای فرکانس‌های اول، دوم و سوم با ۵۰۰ داده مورد آزمایش قرار گرفته شد.

جدول ۱- مقادیر عدم قطعیت تصادفی برای سه فرکانس

طبیعی اول

	DTR	GBR	MLP	RFR
ω_1	0.010	0.009	0.026	0.008
ω_2	0.033	0.059	0.179	0.039
ω_3	0.065	0.111	0.219	0.087

نتایج، همان‌طور که در جدول ۱ ارائه شده است، نشان می‌دهد که در بین الگوریتم‌ها، روش RFR به طور مداوم کمترین عدم قطعیت را در تمام فرکانس‌ها، به ویژه در فرکانس طبیعی اول (ω_1) و فرکانس طبیعی دوم (ω_2) نشان می‌دهد، در حالی که MLP بر خلاف RFR رتبه آخر را به خود اختصاص داده و سطوح عدم قطعیت نسبتاً بالاتری را، به ویژه در فرکانس طبیعی سوم (ω_3) نشان می‌دهد. الگوریتم‌های GBR و DTR به ترتیب رتبه‌های دوم و سوم را در این آزمایش به دست آوردن. این تنوع، اهمیت انتخاب الگوریتم مناسب را برای اطمینان از عملکرد پیش‌بینی بهینه برجسته می‌کند.

در این مطالعه، رگرسیون جنگل تصادفی (RFR) در مدیریت مجموعه داده‌های بزرگ و کاهش بیش‌برازش عالی عمل می‌کند. رگرسیون تقویت‌کننده گرادیان (GBR) توانایی قابل توجه در مدیریت مجموعه داده‌های پیچیده با روابط و تعاملات غیرخطی دارد و همچنین پرسپترون چندلایه (MLP) به دلیل معماری یادگیری عمیق خود در ثبت روابط پیچیده مؤثر است. رگرسیون درخت تصمیم (DTR) به دلیل سادگی و سهولت تفسیر نتایج، محبوب است. با این حال، این مزایا با عدم قطعیت‌هایی همراه هستند. دقت پیش‌بینی به شدت به کیفیت و تنوع مجموعه داده‌ها وابسته است و برخی از الگوریتم‌ها، به ویژه RFR، ممکن است در مواردی با مجموعه داده‌های کوچک‌تر، مستعد بیش‌برازش باشند. علاوه بر این، عملکرد این الگوریتم‌ها می‌تواند به انتخاب ابر پارامترها حساس باشد، که می‌تواند منجر به تغییرپذیری در نتایج شود. پرداختن به این عدم قطعیت‌ها برای افزایش قابلیت اطمینان و کاربرد رویکردهای یادگیری ماشین در نظارت بر سلامت سازه و تشخیص ترک حیاتی است.

۸. RFR به طور مداوم کمترین عدم قطعیت را در تمام فرکانس‌ها، به ویژه در فرکانس طبیعی اول (ω_1) و فرکانس طبیعی دوم (ω_2) نشان می‌دهد. این نتایج نه تنها درک ما از مکانیک تیرهای دارای ترک را افزایش می‌دهد، بلکه یک چارچوب قابل اعتماد برای پیش‌بینی فرکانس‌های طبیعی، تشخیص زود هنگام نقص‌های ساختاری را آسان می‌کند و راهبردهای تعمیر و نگهداری پیشگیرانه را قادر می‌سازد که از خرابی‌های فاجعه بار جلوگیری کند.

تقدیر و تشکر

ندارد.

تعارض منافع

نویسنده اعلام می‌کند که در مورد انتشار این مقاله تعارض منافع وجود ندارد.

تاییدیه اخلاقی

نویسندگان متعهد میشوند که مطالب این مقاله را در هیچ مجله دیگری به چاپ نرسانده‌اند.

مشارکت‌های نویسندگان

رستا رازقیان: مسئول انجام کدنویسی، نگارش پیش نویس مقاله، تهیه نمودارها، تحلیل نتایج
مسعود میر: ایده، مشاوره علمی، نظارت بر اجرا، بازبینی و اصلاح نهایی، تفسیر نتایج

منابع مالی

ندارد.

گرایان (GBR)، پرسپترون چندلایه (MLP) و رگرسیون درخت تصمیم‌گیری (DTR) را برای پیش‌بینی فرکانس‌های طبیعی یک تیر با دو ترک ارائه می‌دهد. مقایسه نتایج به دست آمده با روش عددی-تحلیلی [۲۰] نشان دهنده دقت بسیار بالا روش ارائه شده می‌باشد. در ادامه نتایج حاصل شده آورده شده است:

۱. افزایش اندازه مجموعه داده‌ها تا حد معینی به طور کلی دقت پیش‌بینی الگوریتم‌ها را بهبود می‌بخشد.
۲. پیش‌بینی یک یا چند پارامتر برای خروجی بر روی دقت تأثیرگذار است و شواهد نشان می‌دهد اگر الگوریتم یک پارامتر را برای خروجی پیش‌بینی کند دقت آن بسیار بیشتر می‌شود.
۳. الگوریتم رگرسیون تقویت گرایان با دقت ۹۷/۷۵ و الگوریتم رگرسیون جنگل تصادفی با دقت ۹۵/۷۴ بیشترین دقت را در بین تمام روش‌ها دارند.
۴. بیشتر از حجم ۱۰۰۰ داده آموزشی، تغییر در دقت الگوریتم‌ها ناچیز است و تنها منجر به سرعت خروجی کندتر می‌شود.
۵. زمانی که عمق ترک کمتر است دقت الگوریتم‌ها به مراتب خیلی بیشتر می‌شود.
۶. ضعیف‌ترین الگوریتم در این مطالعه الگوریتم رگرسیون درخت تصمیم با نهایت دقت ۸۳/۶۰ است.
۷. قدرت پیش‌بینی تمامی الگوریتم‌ها در سطح بسیار قابل قبولی است به طوری که با اعمال نویز باز هم تمامی الگوریتم‌ها با حجم دیتاست ۱۰۰۰، دقت بالای ۸۰٪ را حفظ می‌کنند.

مراجع

- [1] Dimarogonas, Andrew d. "Vibration of Cracked Structures: A State of the Art Review." *Engineering Fracture Mechanics* 55, no. 5 (1996): 831-57.
- [2] Khiem, N.T., and L.K. Toan. "A Novel Method for Crack Detection in Beam-Like Structures by Measurements of Natural Frequencies." *Journal of Sound and Vibration* 333, no. 18 (2014): 4084-103.
- [3] Hossain, Mainul, and Jaan Lellep. "Analysis of Free Vibration of Tapered Cracked Double Nanobeams Using Maclaurin Series." *Engineering Research Express*, (2022).
- [4] Geleban, Muhammad Reza, and Shapor Moradi. "Crack detection in beams using the Hilbert-Huang transform." *Journal of Modeling in Engineering* 16, no. 52 (2018): 27-40. (in Persian)
- [5] Jamshidi Moghadam, Peyman, and Sapor Moradi. "Free vibrations of a cracked post-arched beam using the differential quadrature method." *Journal of Modeling in Engineering* 11, no. 34 (2013): 1-16. (in Persian)
- [6] Samuel, A. L. "Some Studies in Machine Learning Using the Game of Checkers." *IBM Journal of Research and Development* 3, no. 3 (1959): 210-29.

- [7] Gillich, Nicoleta, Cristian Tufisi, Christian Sacarea, Catalin V. Rusu, Gilbert-Rainer Gillich, Zeno-Iosif Praisach, and Mario Ardeljan. "Beam Damage Assessment Using Natural Frequency Shift and Machine Learning." *Sensors* 22, no. 3 (2022).
- [8] Hein, Helle, and Ljubov Jaanuska. "Quantification of Cracks in Beams on the Pasternak Foundation Using Haar Wavelets and Machine Learning." *Proceedings of the Estonian Academy of Sciences* 71, no. 1 (2022): 16-29.
- [9] Saha, Prattasha, and Mijia Yang. "A Neural Network Approach to Estimate the Frequency of a Cantilever Beam with Random Multiple Damages." *Sensors* 23, no. 18 (2023).
- [10] Jena, Pankaj Charan. "Fault Assessment of Frc Cracked Beam by Using Neuro-Fuzzy Hybrid Technique." *Materials Today: Proceedings* 5, no. 9 (2018): 19216-23.
- [11] Vu, Van Tuan, and Anh Tuan Le. "Identification of Damage in Steel Beam by Natural Frequency Using Xgb Model." *Journal of Science and Technique*, no. 1859-0209 (2023).
- [12] Ravichandran, Ashok, Prases K Mohanty, Abdullah Naser M Asiri, and Saiful Islam. "Inclined Curved Crack Composite Beam: Experimental and Computational Analysis with Recycled Aluminum Composite Materials and Comparison with an Artificial Neural Network." *OAS OMEGA* 9 (2024): 4395-411.
- [13] Shirazi, Muhammad Irfan, Samir Khatir, Djilali Boutchicha, and Magd Abdel Wahab. "Feature Extraction and Classification of Multiple Cracks from Raw Vibrational Responses of Composite Beams Using 1d-Cnn Network." *Composite Structures* 327 (2024).
- [14] Nguyen, Thanh Q., Luan C. Vuong, Canh M. Le, Nhi K. Ngo, and H. Nguyen- Xuan. "A Data-Driven Approach Based on Wavelet Analysis and Deep Learning for Identification of Multiple-Cracked Beam Structures under Moving Load." *Measurement* 162 (2020).
- [15] Flaieh, Enass H., Farouk Omar Hamdoon, and Alaa Abdulhady Jaber. "Estimation the Natural Frequencies of a Cracked Shaft Based on Finite Element Modeling and Artificial Neural Network." *International Journal on Advanced Science Engineering and Information Technology* 10, no. 4 (2020).
- [16] Omar, Intisar, Muhammad Khan, and Andrew Starr. "Comparative Analysis of Machine Learning Models for Predicting Crack Propagation under Coupled Load and Temperature." *Applied Sciences* 13, no. 12 (2023).
- [17] Muñoz-Abella, Belén, Lourdes Rubio, and Patricia Rubio. "Identification of Cracks in Low-Speed Rotating Slender Cracked Beams Using Frequencies and Artificial Rabbit Algorithm." *Latin American Journal of Solids and Structures* 21, no. 2 (2024).
- [18] N, Aravind, Nagajothi S, and Elavenil S. "Machine Learning Model for Predicting the Crack Detection and Pattern Recognition of Geopolymer Concrete Beams." *Construction and Building Materials* 297 (2021).
- [19] Wu, Xinhua, and Xiujie Liu. "Building Crack Identification and Total Quality Management Method Based on Deep Learning." *Pattern Recognition Letters* 145 (2021): 225-31.
- [20] Bakhtiari-Nejad, F., A. Khorram, and M. Rezaeian. "Analytical Estimation of Natural Frequencies and Mode Shapes of a Beam Having Two Cracks." *International Journal of Mechanical Sciences* 78 (2014): 193-202.
- [21] James, Gareth, Daniela Witten, Trevor Hastie, and Robert Tibshirani. *An Introduction to Statistical Learning with Applications in R*. 2013.
- [22] Alanazi, Abdullah. "Using Machine Learning for Healthcare Challenges and Opportunities." *Informatics in Medicine Unlocked* 30 (2022).
- [23] Ao, Yile, Hongqi Li, Liping Zhu, Sikandar Alia, and Zhongguo Yang. "The Linear Random Forest Algorithm and Its Advantages in Machine Learning Assisted Logging Regression Modeling." *Journal of Petroleum Science and Engineering* 74 (2019): 776-789.
- [24] Khadija El Bouchefry PhD, and Rafael S. de Souza PhD. "Chapter 12 - Learning in Big Data: Introduction to Machine Learning." (2020): 225-49.
- [25] Patil, D.P., and S.K. Maiti. "Detection of multiple cracks using frequency measurements." *Engineering Fracture Mechanics* (2003): 1553-1572.