

Research article

DOI: 10.22034/IJME.2025.2055780.2039

OPEN ACCESS

Predicting Maximum Particle Velocity from Blasting Using Deep Learning Methods in Open-Pit Mines

Davoud Mohammadi Sarqini¹, Mohammad Ataei², Reza Mikaeil^{3*}, Akbar Esmailzadeh⁴

¹ Ph.D. Candidate, Faculty of Mining, Petroleum and Geophysics, Shahrood University of Technology, Iran

² Professor, Faculty of Mining, Petroleum and Geophysics, Shahrood University of Technology, Iran

³ Associate Professor, Faculty of Industries and Mining Technologies, Urmia University of Technology, Iran

⁴ Assistant Professor, Faculty of Industries and Mining Technologies, Urmia University of Technology, Iran

| Article info | Abstract |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p>Received: 12 December 2024 Revised: 19 August 2025 Accepted: 25 August 2025</p> <p>Keywords Vibrating Waves Peak Particle Velocity Blasting Distance, Explosive Amount Deep Learning.</p> <p>*Corresponding author Reza Mikaei reza.mikaeil@gmail.com</p> | <p>Mining blasting operations significantly impact economic production but risk damaging surrounding infrastructure, necessitating accurate prediction of induced seismic vibrations. This study analyzes blast data from Gol-Gohar and Sungun mines and employs deep learning (DL) to predict peak particle velocity (PPV) as a function of distance and explosive charge. DL's performance ($R^2=0.952$, $RMSE=2.670$, $MAPE=2.003\%$) surpassed SVM, SGD, and AdaBoost in comparative analysis. Its architectural flexibility and adaptability to complex mining-related variables yielded superior results. The findings highlight DL's efficacy in high-uncertainty scenarios, offering a robust tool for seismic risk mitigation in mining. Thus, DL-based approaches are recommended for similar geotechnical challenges.</p> |

How to cite this article

Sarqini, D.M., Ataei, M., Mikaeil, R., Esmailzadeh, A., 2025, Predicting Maximum Particle Velocity from Blasting Using Deep Learning Methods in Open-Pit Mines. Journal of Mining Engineering, 20(2): 26-52. (in Persian with English Abstract)
<https://doi.org/10.22034/ijme.2025.2055780.2039>



©2025 The author(s). Published by [Iranian Society of Mining Engineering](#).

This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers.

EXTENDED ABSTRACT

1. Introduction

Blasting is the most common and effective method for fragmenting rock masses in large-scale open-pit mines [1]. However, blasting generates unwanted side effects, including ground vibrations that can propagate over long distances and cause damage to nearby infrastructure [2-4]. A key parameter for assessing blast-induced ground vibration is the Peak Particle Velocity (PPV) [5]. Accurate prediction of PPV is critical for safe blast design, minimizing environmental impacts, and ensuring compliance with safety regulations [6].

Conventional empirical formulas and regression-based models often fail to achieve sufficient accuracy due to the nonlinear, site-dependent nature of the blasting process. Advanced computational techniques such as genetic algorithms, fuzzy systems, and artificial neural networks have been applied in recent years. Nevertheless, these approaches may still lack robustness when confronted with highly complex or large-scale datasets. Deep learning (DL), a subfield of artificial intelligence, has emerged as a powerful method for modelling nonlinear systems with large and heterogeneous data. This study applies deep learning to predict PPV using blasting data collected from Sungun Copper Mine and Golgohar Iron Mine in Iran.

2. Methodology

This research used field data from over 1,000 blasting events conducted at the Sungun Copper and Golgohar Iron open-pit mines. Ground vibrations were monitored using Instanetel Minimate Plus seismographs equipped with geophones and microphones to record three-axis ground motion and air overpressure. For each blast event, the total charge weight per delay and the distance between the blast and the monitoring station were recorded, along with the corresponding PPV.

To prepare the data, preprocessing steps included outlier removal, normalization, and variable scaling. Outliers were identified using boxplots, and normalization ensured compatibility across variable scales. After preprocessing, the dataset was split into training (70%), validation (15%), and testing (15%) subsets.

The proposed DL model was a feedforward neural network with 7 hidden layers, each containing 10-700 neurons. Rectified Linear Unit (ReLU) activation was adopted, and weights were initialized using a uniform distribution. Optimization was performed using the Adam optimizer with an adaptive learning rate. Hyperparameters such as batch size and number of epochs were tuned iteratively to minimize error metrics. The model's predictive performance was assessed using Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), and the coefficient of determination (R^2). To evaluate the robustness of DL, results were compared with three alternative models: Support Vector Machine (SVM), Adaptive Boosting (ADA), and Stochastic Gradient Descent (SGD).

3. Findings and argument

The DL model demonstrated superior performance compared to conventional machine learning approaches. Table 1 summarizes the evaluation metrics obtained for each model. As shown, DL consistently achieved higher R^2 and lower RMSE and MAPE.

Table 1. Evaluators' values for selected prediction models.

| Model | R^2 | RMSE (mm/s) | MAPE (mm/s) |
|----------------------|-------|-------------|-------------|
| <i>Deep Learning</i> | 0.932 | 1.527 | 0.124 |
| <i>SVM</i> | 0.911 | 3.631 | 1.887 |
| <i>ADA</i> | 0.845 | 4.773 | 2.786 |
| <i>SGD</i> | 0.809 | 5.308 | 2.119 |

The results indicate that DL achieved an R^2 of 0.932, which implies a strong correlation between predicted and observed PPV values. Furthermore, DL achieved the lowest RMSE (1.527 mm/s) and MAPE (0.124), confirming its ability to minimize prediction errors. By contrast, traditional methods such as SGD performed poorly, with relatively high RMSE and lower predictive accuracy.

Graphical analyses provided additional evidence of DL model superiority. Scatter plots of observed versus predicted PPV values demonstrated that DL predictions were closely aligned with the 1:1 line, whereas other models exhibited greater dispersion. Residual error plots showed that DL errors were symmetrically distributed around zero, indicating robustness and lack of bias. A Taylor diagram further highlighted the DL model's higher correlation and lower variance compared to benchmark models.

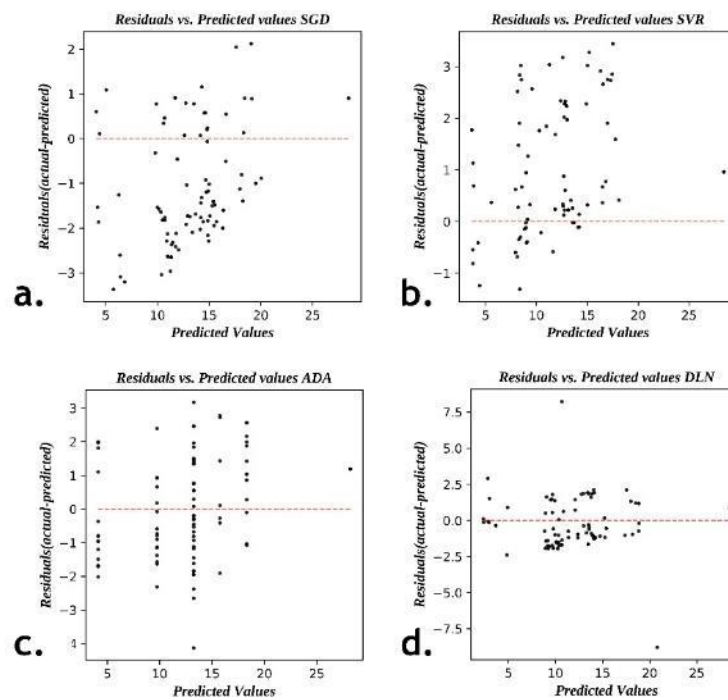


Figure 1. Scatter plot of predicted vs. observed PPV values for DL and alternative models.

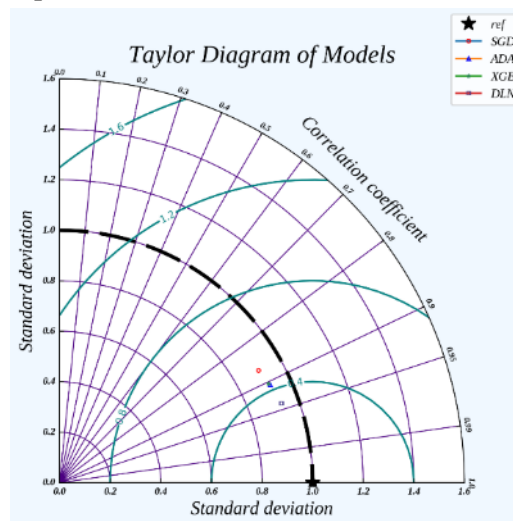


Figure 2. Taylor diagram comparing DL's superior accuracy and stability.

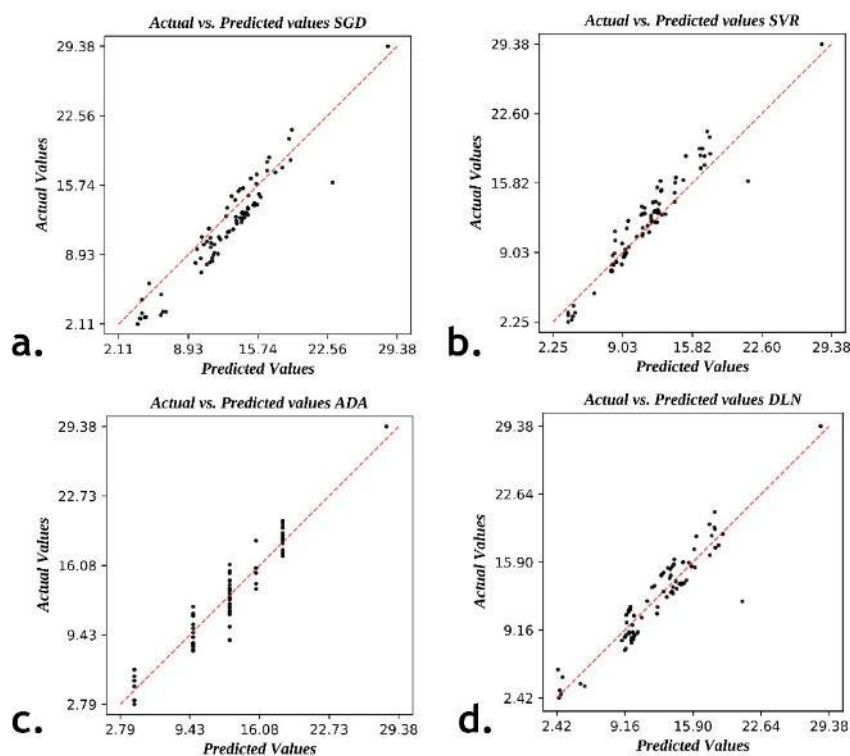


Figure 3. Residual error distribution across models, highlighting the robustness of DL.

The improved accuracy of DL can be attributed to its ability to capture complex nonlinear relationships between input parameters and PPV. Unlike empirical formulas or shallow learning models, DL leverages multiple hidden layers and nonlinear activation functions to approximate intricate mappings. The availability of a relatively large dataset (~1000 events) further enhanced the model's learning capacity and generalization ability.

It is important to note that blasting-induced PPV is influenced not only by distance and charge weight but also by geological and structural parameters, such as rock type, joint orientation, and bench geometry. While this study focused on two primary parameters for simplicity, inclusion of additional variables in future research could further improve predictive performance and site-specific adaptability. The results also suggest that DL could be integrated into real-time monitoring systems, where continuous feedback from field sensors could dynamically update predictions and inform safer blasting practices.

4. Conclusions

This study successfully applied a deep learning model to predict blast-induced PPV in two large-scale open-pit mines in Iran. The DL model outperformed SVM, ADA, and SGD across R^2 , RMSE, and MAPE, demonstrating higher predictive accuracy and robustness. Graphical validation further confirmed DL's capability to generalize across diverse blasting conditions.

The study highlights DL as a valuable decision-support tool in mine blasting operations, capable of reducing risks associated with blast-induced ground vibrations. Future directions include incorporating additional geotechnical variables, exploring hybrid models, and developing real-time predictive frameworks to support sustainable and safe mining practices.

5. References

- [1] Dindarloo, S.R., "Prediction of blast-induced ground vibrations via genetic programming." *International Journal of Mining Science and Technology*, Vol. 25, No. 6, pp. 1011–1015, 2015.

-
- [2] Ghasemi, E., Kalhori, H., Bagherpour, R., “A new hybrid ANFIS–PSO model for prediction of PPV.”, *Engineering with Computers*, Vol. 32, pp. 607–614, 2016.
- [3] Hasanipanah, M., et al., “Estimation of blast-induced ground vibration using soft computing framework.” *Engineering with Computers*, Vol. 33, pp. 951–959, 2017.
- [4] Arthur, C.K., et al., “Gaussian process regression for blast vibration prediction.” *Engineering with Computers*, Vol. 36, No. 1, pp. 29–42, 2020.
- [5] Bui, X.N., et al., “UAV and intelligent prediction of blast vibrations.” *Natural Resources Research*, Vol. 29, No. 2, pp. 771–790, 2020.
- [6] Zhang, W., et al., “PPV of vibration events in underground coal mines.” *Measurement*, Vol. 169, 2021.



OPEN ACCESS

DOI: 10.22034/IJME.2025.2055780.2039

مقاله پژوهشی

پیش‌بینی حداکثر سرعت ذرات ناشی از انفجار با استفاده از روش یادگیری عمیق در معادن روباز

داود محمدی سرقینی^۱، محمد عطایی^۲، رضا میکاییل^{۳*}، اکبر اسمعیل زاده^۴

^۱ دانشجوی دکتری، دانشکده مهندسی معدن، دانشگاه صنعتی شاهرود، ایران

^۲ استاد دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود، ایران

^۳ دانشیار گروه مهندسی معدن، دانشکده صنایع و فناوری‌های معدنی، دانشگاه صنعتی ارومیه، ایران

^۴ استادیار گروه مهندسی معدن، دانشکده صنایع و فناوری‌های معدنی، دانشگاه صنعتی ارومیه، ایران

| اطلاعات مقاله | چکیده |
|--------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| تاریخ دریافت: ۱۴۰۳/۱۲/۲۲ | معدن یکی از مهم‌ترین بخش‌های پیشران اقتصادی هر کشور محسوب می‌شوند که میزان تولید آن‌ها وابستگی زیادی به کیفیت فرآیند انفجار دارد؛ که از متداول‌ترین شیوه‌های استخراج به شمار می‌آید. یکی از چالش‌های اساسی در طی این فرآیند، آسیب‌های جدی وارد شده به تاسیسات جانبی است. بنابراین، در زمان احداث و بهره‌برداری از این تاسیسات، بررسی و پیش‌بینی لرزه‌های ایجاد شده ضرورت دارد. بدین منظور با جمع‌آوری داده‌های مربوط به انفجارها و لرزه‌های ثبت‌شده در دو معدن گلگهر سیرجان و سونگون اهر و پس از تحلیل و توصیف آن‌ها، اقدام به پیش‌بینی حداکثر سرعت ذرات براساس مسافت و مقدار ماده منفجره انجام شد. برای دستیابی به این هدف، با توجه به حجم و ماهیت داده‌ها، از روش یادگیری عمیق استفاده گردید. در این مطالعه، با جستجوی مقادیر بهینه برای هاپیر پارامترها از طریق آزمون و خطا، تلاش شد نتایج قابل قبول بدست آید. ضریب تعیین، خطای درصد میانگین مطلق و ریشه میانگین مربع خطا، به عنوان شاخص‌های ارزیابی کیفیت مدل در نظر گرفته شدند. برای قضاوت بهتر در خصوص عملکرد روش انتخاب شده، نتایج آن با سه روش دیگر شامل ماشین بردار پشتیبان، گرادیان کاهشی تصادفی و روش تقویت سازگار؛ مقایسه گردید. مقادیر ضریب تعیین برای چهار روش یادشده به ترتیب برابر با ۰/۹۵۲، ۰/۸۰۹، ۰/۸۴۵ و ۰/۹۱۱ بدست آمد. همچنین، مقدار شاخص ریشه میانگین مربع خطا برای این چهار روش به ترتیب برابر با ۲/۶۷۰، ۵/۳۰۸، ۴/۷۷۳ و ۳/۶۳۱ بود. مقادیر شاخص خطای درصد میانگین مطلق نیز به ترتیب ۲/۱۱۹، ۲/۷۸۶ و ۱/۸۸۷ بدست آمد. با توجه به این شاخص‌ها، روش یادگیری عمیق به دلیل انعطاف در معماری و انطباق بهتر با ویژگی‌های مسأله، عملکرد مطلوب‌تری داشته است. در نتیجه می‌توان بیان کرد که در مسائلی با پیچیدگی بالا و عدم قطعیت، مانند مسائل مرتبط با حوزه‌های معدنی، روش‌های مبتنی بر یادگیری عمیق توانمندی مناسبی ارائه می‌دهند. |
| تاریخ بازنگری: ۱۴۰۴/۰۵/۲۸ | |
| تاریخ پذیرش: ۱۴۰۴/۰۶/۰۴ | |
| واژه‌های کلیدی | |
| امواج لرزه‌ای | |
| حداکثر سرعت ذره | |
| فاصله انفجار | |
| مقدار ماده منفجره | |
| یادگیری عمیق | |
| *نویسنده مسئول | |
| رضا میکاییل | |
| reza.mikaeil@gmail.com | |

استناد به این مقاله:

سرقینی، داود؛ عطایی، محمد؛ میکاییل، رضا؛ اسمعیل زاده، اکبر؛ ۱۴۰۴. پیش‌بینی حداکثر سرعت ذرات ناشی از انفجار با استفاده از روش یادگیری عمیق در معادن. نشریه مهندسی معدن. ۲۰(۲): ۲۶-۵۲. <https://doi.org/10.22034/ijme.2025.2055780.2039>

۱- مقدمه

استخراج معادن روباز به روش چال‌زنی و انفجار، اگرچه مزایای زیادی دارد، اما منجر به تولید لرزه‌هایی می‌شود که در مناطق اطراف گسترش می‌یابند. این لرزه‌ها می‌توانند خسارات جدی به تأسیسات و ساختمان‌هایی که در شعاع اثر انفجار قرار دارند، وارد کنند. آگاهی از شدت لرزه، بر پایه‌ی مقدار ماده منفجره مصرف‌شده و فاصله از محل انفجار، نقش مهمی در کاهش و کنترل خسارات ناشی از آن ایفا می‌کند. براین اساس، در این پژوهش تلاش شده است با استفاده از داده‌های مربوط به فاصله و مقدار ماده منفجره، میزان لرزه ایجادشده در مناطق مجاور محل انفجار پیش‌بینی شود. داده‌های مورد استفاده در این تحقیق از طریق اندازه‌گیری‌های میدانی در حین عملیات انفجار در دو معدن روباز سونگون اهر و گل‌گهر سیرجان جمع‌آوری شده‌اند. با توجه به اهمیت این موضوع، پژوهشگران زیادی تاکنون به پیش‌بینی میزان لرزه‌های ناشی از انفجار پرداخته‌اند. در ادامه، به برخی از مهم‌ترین مطالعات انجام‌شده در این زمینه اشاره خواهد شد.

دیندارلو^۱ در سال ۲۰۱۵ به بررسی و پیش‌بینی میزان لرزش ناشی از انفجار با استفاده از الگوریتم ژنتیک پرداخت. در این تحقیق، از ۹ متغیر ورودی برای پیش‌بینی فرکانس لرزش در فواصل مختلف از سینه‌کار انفجار استفاده شد. ضریب تعیین بالا با خطای درصد میانگین مطلق نشان دهنده مناسب بودن الگوریتم در پیش‌بینی میزان لرزش بود [۱]. قاسمی و همکاران^۲ در سال ۲۰۱۶ یک رویکرد ترکیبی جدیدی مبتنی بر ترکیب سیستم استنتاج عصبی-فازی و بهینه‌سازی آن توسط ازدحام ذرات برای پیش‌بینی حداکثر سرعت ذرات در طول پله‌ی انفجاری در معدن روباز ارائه دادند. مدل‌ها براساس داده‌های واقعی حاصل از ۱۲۰ مورد انفجار در معدن مس سرچشمه مورد آموزش و آزمایش قرار گرفتند. نتایج بدست آمده از مقایسه‌ی مدل‌ها نشان داد که مدل سیستم استنتاج عصبی-فازی سازگار و بهینه‌سازی ازدحام ذرات، نتایج بهتری را در مقایسه با سایر مدل‌ها فراهم می‌آورد [۲]. حسینی‌پناه و همکاران^۳ در سال ۲۰۱۷ در طی تحقیقاتشان به بررسی لرزش زمین ناشی از

انفجار در اطراف سد بختیاری با استفاده از الگوریتم ژنتیک پرداختند. آن‌ها در مطالعاتشان، معادلاتی را جهت پیش‌بینی لرزش زمین توسط این الگوریتم توسعه دادند. حداکثر وزن خرج در هر تاخیر و فاصله‌ی بین جایگاه ثبت داده‌ها و نقطه‌ی انفجار را به عنوان ورودی، برای مدل‌سازی، مورد استفاده قرار دادند. پارامتر حداکثر سرعت ذره برای ارزیابی لرزش زمین به عنوان خروجی مدل در نظر گرفته شد. آن‌ها با در نظر گرفتن ۸۵ مورد انفجار، حداکثر سرعت ذره را به طور دقیق اندازه‌گیری کردند. سپس نتایج را با چند مدل پیش‌بینی تجربی مقایسه کردند. نتایج نشان داد که الگوریتم ژنتیک با توجه به شاخص‌های میانگین مجموع مربعات خطا و ضریب تعیین چندگانه، مدل قابل قبولی نسبت به مدل‌های پیش‌بینی تجربی برای پیش‌بینی حداکثر سرعت ذره است [۳]. فرجی اصل و همکاران^۴ در سال ۲۰۱۷ در مطالعه‌ی خود تلاش کردند تا با استفاده از شبکه عصبی مصنوعی و الگوریتم کرم شب‌تاب، پارامترهای مناسب طراحی الگوی انفجار را به منظور کاهش خرد شدگی‌های نامناسب و پرتاب سنگ، طراحی کنند. بدین منظور بعد از برداشت داده‌ها و انتخاب موثرترین پارامترها در پرتاب و خردشدگی سنگ، مدل شبکه عصبی مصنوعی را توسعه دادند و سپس نتایج آن را توسط الگوریتم کرم شب‌تاب برای فرآیند بهینه‌سازی توسعه دادند. نتایج حاصل از مدل‌سازی و بهینه‌سازی، به ترتیب یک کاهش ۴۲/۹ و ۳۲/۹ درصدی از پرتاب سنگ و خردشدگی را نشان داد [۴]. نگوین و همکاران^۵ در سال ۲۰۱۹، لرزش زمین و حداکثر سرعت ذره ناشی از انفجار معدن روباز زغال‌سنگ را با استفاده از محاسبات نرم مورد پیش‌بینی قرار دادند. در این تحقیق از چندین شاخص آماری همچون ضریب تعیین، میانگین مجموع مربعات خطا و خطای مطلق میانگین برای ارزیابی کیفیت مدل‌های پیش‌بینی استفاده شد. نتایج حاصل از بررسی‌ها نشان از دقت بالای مدل در پیش‌بینی حداکثر سرعت ذره و همچنین ارتباط معنی‌دار میان اختلاف ارتفاع بین محل انفجار و مکان ثبت داده‌ها داشته است [۵]. آرتور و همکاران^۶ در سال ۲۰۱۹ در مقاله خود یک مدل پیش‌بینی جدیدی مبتنی بر رگرسیون فرآیند گاوسی به منظور پیش‌بینی لرزش زمین ناشی از انفجار ارائه کردند. آنان

^۴ Faraji Asl et al., 2017^۵ Nguyen et al., 2019^۶ Arthur et al., 2019^۱ Dindarloo, 2015^۲ Ghasemi et al., 2016^۳ Hosseini-Panah et al., 2017

پیش‌بینی حداکثر سرعت ذرات پیشنهاد دادند. مجموعه داده‌های استفاده شده در این تحقیق متشکل از حداکثر وزن خرج در هر تاخیر، فاصله افقی، فاصله شعاعی و فاصله شعاعی اصلاح شده بین ایستگاه نظارت و انفجار در سایت معدن مس سونگون بوده است. مقایسه عملکرد مدل جدید پیشنهادی با شاخص‌های آماری نشان دهنده برتری مدل ترکیبی الگوریتم ژنتیک مبتنی بر شبکه عصبی مصنوعی در برابر پیش‌بینی‌کننده‌های تجربی و سیستم استنتاج عصبی-فازی است. در نهایت نتایج نشان دهنده کارایی روش ترکیبی الگوریتم ژنتیک مبتنی بر شبکه عصبی مصنوعی پیشنهادی در یافتن معماری مطلوب شبکه عصبی مصنوعی در پیش‌بینی حداکثر سرعت ذرات است [۱۰]. نگوین و همکاران^۵ در سال ۲۰۲۰ با استفاده از شبکه عصبی مصنوعی، انفجار هوای ناشی از عملیات انفجار در معدن روباز زغال‌سنگ دیونای ویتنام را پیش‌بینی کردند. پارامترهای مورد استفاده در این مدل‌ها شامل خرج در هر تاخیر، بارسنگ، فاصله‌داری، طول گل‌گذاری، خرج ویژه، رطوبت هوا و فاصله‌ی جایگاه ثبت داده‌ها بودند. نتایج حاصل از تحقیق نشان داد که مدل شبکه‌های عصبی چند لایه، دقیق‌ترین پیش‌بینی را نسبت به مدل‌های قبلی ارائه می‌دهند [۱۱]. ژانگ و همکاران در سال ۲۰۲۱، به بررسی و ارزیابی حداکثر سرعت ذره ناشی از انفجار در معادن زیرزمینی زغال پرداختند. این مطالعه در مورد رابطه بین بزرگی رویدادهای معدنی و حداکثر سرعت ذره و افزایش تنش ناشی از آن‌ها بحث کرد که مرجع مهمی برای مطالعه مکانیسم و هشدار اولیه ترکیدگی سنگ دارد [۱۲]. ژانگ و همکاران^۶ در سال ۲۰۲۱، به پیش‌بینی حداکثر سرعت ذره ناشی از انفجار در معادن روباز با استفاده از روش مبتنی بر هوش مصنوعی پرداختند. در پژوهش آن‌ها، تلفیقی از روش‌های ماشین یادگیری افراطی و بهینه‌سازی چند وجهی ارائه شد تا حداکثر سرعت ذرات را براساس ۱۳۷ رویداد انفجار پیش‌بینی کرده و دقت بالاتری نسبت به مدل‌های سنتی به دست آورد [۱۳]. زنگ و همکاران^۷ در سال ۲۰۲۱، به بررسی و پیش‌بینی حداکثر سرعت ذره با استفاده از یادگیری ماشین تلفیقی پرداختند. این مطالعه نشان داد که ترکیبی از مدل‌های

در پژوهش خود ۲۱۰ انفجار در معدن روباز واقع در کشور غنا را بررسی نمودند که از این میان ۱۳۰ داده در توسعه‌ی آموزش مدل و ۸۰ داده‌ی باقی‌مانده به منظور ارزیابی عملکرد مدل استفاده شد. در ادامه مدل با سایر روش‌های پیش‌بینی مورد ارزیابی و مقایسه قرار گرفت. نتایج نشان داد که رویکرد رگرسیون فرآیند گاوسی پیشنهادی، می‌تواند لرزش زمین را با دقت بهتری نسبت به سایر روش‌های استاندارد پیش‌بینی نماید [۶]. بویی و همکاران^۱ در سال ۲۰۱۹، به مطالعه اثرات انفجار در یک معدن روباز در کشور ویتنام پرداختند. در طی انجام این تحقیق ۲۵ مورد انفجاری، مورد بررسی قرار گرفت. آن‌ها در این پژوهش، از ترکیب مدل‌های خوشه‌بندی فازی و شبکه عصبی شبه برگشتی به یک مدل ترکیبی جدید برای پیش‌بینی لرزش زمین ناشی از انفجار، دست یافتند. نتایج حاصل از بررسی‌ها نشان داد که مدل ترکیبی جدید ارائه شده، دقت بالاتری از مدل‌هایی قدیمی همچون شبکه عصبی مصنوعی، جنگل تصادفی و شبکه عصبی شبه برگشتی دارد [۷]. فانگ و همکاران^۲ در سال ۲۰۱۹، به بررسی و پیش‌بینی میزان لرزش زمین، ناشی از انفجار بر مبنای الگوریتم مبتنی بر قواعد پنجگانه و الگوریتم رقابت استعماری پرداختند. در پژوهش صورت گرفته، الگوریتم رقابت استعماری برای بهینه‌کردن قواعد پنجگانه، در نظر گرفته شد. یافته‌های تحقیق حاکی از آن بود که مدل پیشنهادی ترکیبی جدید، بالاترین دقت را در مقایسه با سایر روش‌ها، فراهم می‌آورد [۸]. یانگ و همکاران^۳ در سال ۲۰۱۹ به پیش‌بینی لرزش زمین ناشی از انفجار با استفاده از روش‌های هوش مصنوعی ترکیبی پرداختند. مطالعه‌ی آنان مبتنی بر رگرسیون بردار پشتیبان بهینه شده با الگوریتم کرم شب‌تاب، الگوریتم ژنتیک و الگوریتم بهینه‌سازی ازدحام ذرات بود. در طی انجام این تحقیق، از ۹۰ مجموعه داده‌ی جمع‌آوری شده از دو معدن روباز استفاده نمودند. نتایج حاصل از بررسی‌ها نشان داد که روش ترکیبی از کارایی بیشتری نسبت به سایر مدل‌های ترکیبی مبتنی بر ماشین بردار پشتیبان برخوردار است [۹]. عظیمی و همکاران^۴ در سال ۲۰۱۹، روش ترکیبی الگوریتم ژنتیک مبتنی بر شبکه عصبی مصنوعی را به منظور

^۵ Nguyen et al., 2020^۶ Zhang et al., 2021^۷ Zeng et al., 2021^۱ Bui et al., 2019^۲ Fang et al., 2019^۳ Yang et al., 2019^۴ Azimi et al., 2019

شاخص‌هایی نظیر درصد خطای مطلق میانگین (MAPE)، ریشه میانگین مربع خطا (RMSE) و ضریب تعیین (R^2) استفاده شد. همچنین به منظور مقایسه عملکرد، سه روش دیگر شامل تقویت سازگار، گرادیان کاهشی تصادفی و ماشین بردار پشتیبان به عنوان مدل‌های مرجع مورد ارزیابی قرار گرفتند.

۲- روش شناسی

کنترل و مدیریت پیامدهای ناشی از انفجار در معادن روباز، یکی از چالش‌های اصلی پیش‌روی طراحان معدن است. لرزش‌های ناشی از انفجار از مهم‌ترین و مخرب‌ترین اثرات جانبی این عملیات به شمار می‌روند. ساختمان‌هایی که در محدوده تأثیر انفجار قرار دارند، ممکن است دچار آسیب‌های کوتاه‌مدت یا بلندمدت شوند؛ از جمله ترک در دیوارها، شکست شیشه‌ها، سقوط اشیاء، و در موارد شدیدتر، حتی ریزش سازه. هدف این پژوهش، تأمین داده‌های کافی برای تعیین محدوده تأثیر انفجار و فراهم‌سازی ایمنی مناسب برای ساختمان‌های مستقر در محدوده معدن است.

برای این منظور، پژوهشی کمی و واقع‌گرایانه با هدف بررسی ارتباط میان پارامترهای تأثیرگذار با شدت لرزه‌های ناشی از انفجار طراحی شد. با توجه به ماهیت مسئله، نوع تحقیق از نوع استقرایی بوده و طراحی آن بر پایه اندازه‌گیری، مشاهده و گردآوری داده‌ها از دو مطالعه موردی در معادن سونگون اهر و گل‌گهر سیرجان انجام گرفته است. داده‌های گردآوری‌شده مربوط به مقطع زمانی مشخصی نیستند و در طول دوره انفجارهای انجام‌شده در این دو معدن ثبت شده‌اند.

دستیابی به هدف پژوهش نیازمند استفاده از شاخصی معتبر برای سنجش میزان لرزش ناشی از انفجار است. در میان شاخص‌های موجود، «حداکثر سرعت ذره» (PPV) یکی از رایج‌ترین و جامع‌ترین شاخص‌ها به شمار می‌رود. بنابراین، حداکثر سرعت ذره (بر حسب میلی‌متر بر ثانیه) به عنوان سنج‌ای قابل اعتماد از شدت لرزه انتخاب شده و در این پژوهش، نقش متغیر وابسته را ایفا می‌کند. از میان پارامترهای تأثیرگذار بر این شاخص، دو عامل «مقدار ماده منفجره» و «فاصله از محل انفجار» به عنوان متغیرهای مستقل در نظر گرفته شدند. در واقع، با دانستن فاصله از محل انفجار و مقدار

تقویت‌کننده می‌تواند مؤثرترین پارامترهای مؤثر بر مقادیر حداکثر سرعت ذره را شناسایی و با دقت بالایی پیش‌بینی کند [۱۴]. سونکار و همکاران^۱ در سال ۲۰۲۲، رویکردی جدید از یادگیری ماشین را با استفاده از جنگل تصادفی تقویت‌شده برای پیش‌بینی حداکثر سرعت ذرات ناشی از انفجار ارائه دادند. این نشان می‌دهد که مدل جنگل تصادفی تقویت‌شده با دستیابی به مقادیر میانگین مربعات خطای کمتر و خطای میانگین مربعات ریشه از رویکردهای سنتی بهتر عمل می‌کند. این مدل از طریق اعتبارسنجی بر روی مجموعه‌ای از ۲۰۰ رکورد انفجار از سایت فرودگاه بین‌المللی در هند، تأیید و دقت پیش‌بینی بالای آن را به نمایش گذاشت [۱۵]. چندراهاس و همکاران^۲ در سال ۲۰۲۴، تلفیقی از الگوریتم تقویتی افراطی و الگوریتم ژنتیک را جهت ارزیابی و پیش‌بینی حداکثر سرعت ذرات مورد استفاده قرار دادند. این مطالعه مجموعه‌ای از داده‌های معدن مختلف شامل، مقدار کل ماده منفجره و الگوی انفجار را در خود جای داده است. در این تحقیق همچنین یک برنامه تحت وب را برای تسهیل پیش‌بینی حداکثر سرعت ذرات و میانگین اندازه خردایش برای مهندسان معدن در محل توسعه داده شد [۱۶]. یوان و همکاران^۳ در سال ۲۰۲۵، به بررسی و پیش‌بینی حداکثر سرعت ذرات ناشی از انفجار با استفاده از روش یادگیری ماشین تقویتی دسته بندی شده پرداختند. مدل پیشنهادی از دقت پیش‌بینی بالاتر نسبت به سایر روش‌ها، به‌ویژه در شرایط پیچیده زمین‌شناسی ارائه می‌دهد. میانگین مربعات خطای ریشه و میانگین خطای مطلق مدل به ترتیب برابر با ۰/۲۸ و ۰/۱۷ میلی‌متر بر ثانیه (mm/s) گزارش شد که درجه بالایی از تناسب را با داده‌های مشاهده شده را نشان می‌دهد [۱۷]. با توجه به اهمیت آگاهی از میزان لرزش ناشی از انفجارهای معدن روباز بر سازه‌های اطراف، و با توجه به مطالعات پیشین، در این پژوهش تلاش شده است با ایجاد پایگاه داده‌ای شامل مقادیر لرزه، فاصله از محل انفجار و مقدار ماده منفجره، و با بهره‌گیری از روش شبکه یادگیری عمیق مبتنی بر هوش مصنوعی، شدت لرزه پیش‌بینی شود. پس از گردآوری و پیش‌پردازش داده‌ها، یک معماری مناسب برای شبکه یادگیری عمیق طراحی شد و سپس پیش‌بینی شدت لرزه انجام گرفت. برای ارزیابی عملکرد مدل شبکه یادگیری عمیق، از

^۳ Yuan et al., 2025

^۱ Sonkar et al., 2022

^۲ Chandrahass et al., 2024

سونگون ۴۶ درجه و ۴۳ دقیقه طول شرقی و ۳۸ درجه و ۴۲ دقیقه عرض شمالی است.

سونگون پورفیری، دایکی و تراکیتی-بازالتی، سه نوع سنگ عمده در معدن هستند که طراحی در این تحقیق، بر اساس آن‌ها صورت گرفته است. سونگون پورفیری سنگ میزبان مس است که واحد اصلی لیتولوژی سونگون را تشکیل می‌دهد و ترکیبی از کوارتز مونزونیت و گرانودیوریت قطع شده توسط دایک است. سونگون پورفیری شامل دگرسانی زون پتاسیک، فلیک و آرژیلیک است. توده مونزونیتی به‌عنوان سنگ میزبان حجم بسیار زیادی از محدوده استخراجی معدن را شامل می‌شود. این توده از لحاظ مکانیک سنگی دارای درزه‌های جوش خورده، خالی و گاه به‌همراه مواد پرکننده بسیار اندکی است. دگرسانی سطح درزه‌ها در حد متوسط بوده و سطح درزه‌ها بیش‌تر به‌صورت موج‌دار قابل تشخیص‌اند. دسته دوم یعنی دایک‌های دیوریت تا کوارتز-دیوریت اغلب بیش‌ترین نوع دایک‌ها در سونگون پورفیری هستند. دسته سوم توده تراکیتی-بازالت که توده سنگ غالب باطله در محدوده جنوبی پیت معدن است، از لحاظ سنگ‌شناسی به خانواده آندزیت - بازالت متعلق بوده و توده سنگی بسیار درزه‌دار است. درزه‌های توده سنگ حاضر دارای بازشدگی و مواد پرکننده زیاد از جنس رس فشرده‌اند. طبیعت درزه‌دار این توده سنگ مشکلات زیادی را در انفجار ایجاد می‌کند.

ماده منفجره، می‌توان میزان لرزه را پیش‌بینی کرد و فاصله‌ایم برای احداث سازه‌ها را تعیین نمود. بر اساس چارچوب تعریف‌شده، این پژوهش شامل دو بخش اصلی است. بخش اول مربوط به گردآوری پایگاه داده‌ای شامل متغیر وابسته و متغیرهای مستقل متناظر آن است. در بخش دوم، تلاش می‌شود تا الگوی حاکم بر روابط بین متغیرها شناسایی گردد.

برای ایجاد پایگاه داده مورد نیاز و با توجه به ماهیت مسئله، دو معدن بزرگ روباز به‌عنوان مطالعات موردی انتخاب شدند. این دو معدن عبارت‌اند از: معدن مس سونگون اهر و معدن آهن گل‌گهر سیرجان. علت انتخاب این دو معدن، مقیاس بزرگ عملیات استخراج و فراوانی انفجارهای انجام‌شده در آن‌هاست. در ادامه، خلاصه‌ای از مشخصات این دو معدن ارائه می‌شود.

۳- مطالعات موردی

اولین مورد مطالعاتی بررسی شده در این تحقیق، معدن مس سونگون واقع در فلات آذربایجان به‌عنوان بخشی از فلات بزرگ ایران می‌باشد. در این منطقه، کانسار مس سونگون در بخشی از رشته کوه‌های قره داغ استان آذربایجان شرقی در ۱۰۰ کیلومتری شمال شرقی تبریز و ۲۵ کیلومتری شمال شهرستان ورزقان، در همسایگی جمهوری آذربایجان و ارمنستان واقع شده است. کانسار مس سونگون در یک منطقه کوهستانی با ارتفاع متوسط ۲۰۰۰ متر نسبت به سطح دریا و در بخشی از رشته کوه‌های قره داغ قرار گرفته است. حداکثر ارتفاع محدوده معدن از سطح دریا ۲۷۰۰ متر است. مختصات جغرافیایی منطقه مس



شکل ۱. موقعیت مکانی معادن مورد مطالعه روی نقشه ایران ۴- جمع آوری داده‌ها

۴- جمع آوری داده‌ها

لرزه‌ها در سه محور قائم، افقی و عرضی را داراست و به ژئوفون و میکروفون مجهز است. ژئوفون وظیفه ثبت لرزش‌های زمین را بر عهده دارد و میکروفون نیز امکان ثبت پدیده‌هایی همچون انفجار هوا را فراهم می‌سازد. همچنین داده‌های ثبت‌شده با تاریخ و زمان دقیق ذخیره شده و قابل بازیابی هستند. دستگاه قابلیت ثبت تک‌رویداد یا ثبت مستمر دارد. شکل ۲، مشخصات کلی یکی از ایستگاه‌های برداشت و نمونه‌ای از داده‌های ثبت‌شده را نمایش می‌دهد. داده‌های این پژوهش از دو معدن با شرایط ژئومکانیکی متفاوت (سونگون اهر و گل‌گهر سیرجان) جمع‌آوری شده‌اند و مطالعات پیشین نیز نشان می‌دهند که رابطه بین حداکثر سرعت ذره با وزن ماده منفجره و فاصله از محل انفجار در شرایط ژئومکانیکی مختلف یکسان نیست [۱۸، ۱۹]. در این پژوهش، برای تحلیل این ناهمگنی و دستیابی به همبستگی‌های معنادار، روش‌های زیر به کار گرفته شد. ابتدا داده‌های هر معدن به صورت مجزا تحلیل شد تا تأثیر شرایط خاص هر سایت (مانند خواص سنگ‌ها، هندسه معدن، و پارامترهای انفجار) بر روابط بین متغیرها بررسی شود. سپس با استفاده از روش‌های استاندارد سازی (مانند نرمال‌سازی بر اساس ویژگی‌های ژئومکانیکی یا مقیاس‌دهی پارامترها)، داده‌های دو معدن در یک چارچوب یکپارچه قرار گرفتند تا امکان تحلیل ترکیبی فراهم شود.




دومین مورد مطالعاتی بررسی شده در این تحقیق، معدن آهن گل‌گهر سیرجان است. زون ساختاری سندج-سیرجان که معدن در آن قرار دارد محدوده‌ای در جنوب شرقی شهر سیرجان قرار دارد. رخنمون‌های سنگی این معدن از دگرگونی سنگ‌های سازند گل‌گهر تشکیل شده است. رخساره‌های این منطقه قالباً دگرگونی از نوع ضعیف (شیست) و یا دگرگونی از نوع متوسط (آمفیبولیت) است. ذخیره‌های شناخته شده‌ی این منطقه عبارت‌اند از شمس‌آباد اراک و نوار معدنی آهن سندج-همدان که در همین زون یعنی زون سندج-سیرجان قرار گرفته‌اند. شکل ۱ موقعیت مکانی دو معدن مطالعه شده در این پژوهش را نشان می‌دهد.

برای بررسی دقیق لرزش‌های ناشی از انفجار در معادن روباز، از دستگاه‌های لرزه‌نگار به منظور ثبت داده‌های لرزه‌ای استفاده شد. این دستگاه‌ها به حسگرهای الکترومغناطیسی مجهز هستند که حرکات مکانیکی زمین را به پالس‌های الکتریکی تبدیل کرده و به وسیله مدارهای دیجیتال یا آنالوگ ثبت می‌کنند. اطلاعات به دست آمده، پایه تحلیل‌های لرزه‌ای و تطبیق با استانداردهای ایمنی قرار می‌گیرد.

در این پژوهش، از دستگاه Minimate Plus ساخت شرکت InstanTel استفاده شد. (شکل ۲). این دستگاه قابلیت ثبت



| | |
|--------------------------------------------|----------------------------------|
| Crushed Bench Deposit(transforming) | 5.2187 North - Tail |
| Hole Number | 33 |
| Hole diameter(in) | 5.6 |
| Overall Drilling Length(m) | 462 |
| Average Hole Depth(m) | 14 |
| Total Consumed Explosives | 5300 Kg(ANFO) |
| Explosion System | 66 kg(cartridge emulsion) |
| Distance to Device(m) | Nanel |
| | 650 |



| Trigger | Tran Peak (mm/s) | Vert Peak (mm/s) | Long Peak (mm/s) | Mic Peak (dB) | PVS (mm/s) | Peak Acceleration(g) | Peak Displacement (mm) |
|---------|------------------|------------------|------------------|---------------|------------|----------------------|------------------------|
| Tran | 1/27 | 0/762 | 0/889 | 119/9 | 1/51 | 0/0530 | 0/0246 Tran |

شکل ۲. دستگاه لرزه نگار و مشخصات مکانی یکی از ایستگاه‌های برداشت به همراه داده‌های برداشت شده.

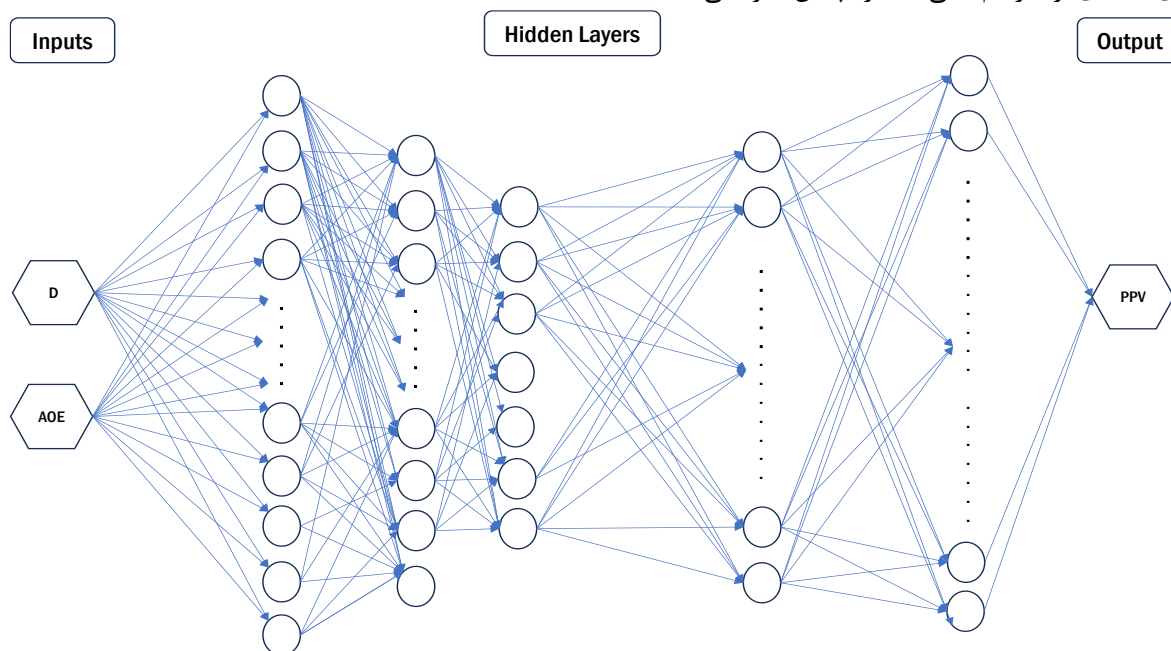
۵- روش یادگیری عمیق

امکان کنترل بر عوامل محیطی وجود ندارد، پیش‌بینی رفتار زمین به امری دشوار و پیچیده تبدیل می‌شود. بنابراین، تحلیل و رفتارنگاری این‌گونه محیط‌ها برای اهداف پیش‌بینی، نیازمند بهره‌گیری از ابزارهایی با قدرت تطبیق‌پذیری و انعطاف بالا است. از سوی دیگر، همان‌طور که در بخش قبل بیان شد، حدود ۱۰۰۰ داده از عملیات انفجار گردآوری شده است که از نظر حجم، میزان قابل توجهی برای تحلیل‌های مبتنی بر یادگیری ماشین به‌شمار می‌رود.

با توجه به مباحث مطرح‌شده، برای شناسایی الگوی رفتاری میان پارامترهای ورودی (فاصله از محل انفجار و مقدار ماده منفجره) و پارامتر خروجی (حداکثر سرعت ذره)، از روش یادگیری عمیق استفاده شد. یادگیری عمیق دارای معماری‌های متنوعی است. برای تحلیل داده‌های جدولی، شبکه عصبی تغذیه‌شونده پیشرو (Feedforward Neural Network) گزینه‌ای مناسب به‌شمار می‌رود. سایر معماری‌ها نظیر شبکه‌های بازگشتی (RNN) یا شبکه‌های کانولوشنی (CNN) بیشتر برای داده‌های سری‌زمانی، تصویری یا متنی کاربرد دارند. در معماری طراحی‌شده، شبکه شامل یک لایه ورودی با دو نورون، هفت لایه پنهان و یک لایه خروجی با یک نورون است. شکل ۳ شمای کلی معماری شبکه طراحی شده را نشان می‌دهد.

داشتن توانایی پیش‌بینی در مواجهه با پدیده‌های مختلف، امکان برنامه‌ریزی دقیق‌تر را فراهم می‌کند. هوش مصنوعی با بهره‌گیری از ابزارهای گوناگون، می‌تواند پیش‌بینی‌های قابل اعتمادی را ارائه دهد. یادگیری ماشین به عنوان یکی از زیرمجموعه‌های اصلی هوش مصنوعی، مجموعه‌ای گسترده از ابزارهای پیش‌بینی را در اختیار دارد که شبکه عصبی مصنوعی یکی از مهم‌ترین آن‌هاست. در میان روش‌های مبتنی بر شبکه عصبی، یادگیری عمیق به‌عنوان یکی از کارآمدترین ابزارهای هوش مصنوعی شناخته می‌شود. در واقع، یادگیری عمیق به شبکه‌های عصبی پیچیده‌تر و با ساختار بزرگ‌تر اطلاق می‌شود که از جنبه‌های مختلف با شبکه‌های عصبی ساده تفاوت دارند. چارچوب و معماری شبکه‌های یادگیری عمیق، انعطاف‌پذیری بالایی در برخورد با مسائل پیچیده و داده‌های حجیم فراهم می‌آورد. نوع چارچوب شبکه، تعداد لایه‌های پنهان، تعداد نورون‌ها در هر لایه، توابع فعال‌ساز، روش‌های مقداردهی وزن، الگوریتم‌های بهینه‌سازی و سایر هاپرپارامترها، همگی در طراحی و عملکرد یک شبکه یادگیری عمیق نقش تعیین‌کننده‌ای دارند.

فضای حاکم بر محیط زمین‌شناختی، به‌دلیل ماهیت طبیعی و خودتنظیم آن، امکان کنترل یا مدیریت مستقیم بر پارامترهای کلیدی را فراهم نمی‌کند. در چنین شرایطی که



شکل ۳. معماری شبکه یادگیری عمیق استفاده شده در پژوهش.

تأثیر قابل توجهی بر عملکرد نهایی مدل داشته باشند. افزون بر معماری شبکه، انتخاب نوع تابع بهینه‌ساز (Optimizer)، تعداد تکرار مراحل آموزش (Epochs) و اندازه دسته‌های ورودی (Batch Size) از جمله هاپیر پارامترهای کلیدی مؤثر بر دقت و راندمان مدل هستند. جدول ۱ مقادیر انتخاب شده برای هر کدام از هاپیر پارامترهای فوق‌الذکر آورده شده است.

در طراحی یک شبکه یادگیری عمیق، علاوه بر تعیین تعداد لایه‌های پنهان، تعداد نورون‌های هر لایه و تابع فعال‌ساز، پارامترهایی نظیر روش مقداردهی اولیه هسته (Kernel_INITIALIZER)، مقداردهی اولیه بایاس، و توابع تنظیم‌کننده (Regularizers) نیز باید مشخص شوند. هر یک از این هاپیر پارامترها دارای دامنه تنظیم خاص خود هستند و می‌توانند

جدول ۱. مقادیر هاپیر پارامترهای شبکه یادگیری عمیق بکار رفته در پژوهش.

| شماره لایه مخفی | تعداد نورون‌ها | تنظیم‌کننده سوگیری | شروع‌کننده سوگیری | شروع‌کننده محاسبات مرکزی | تابع فعال‌سازی | تنظیم‌کننده محاسبات مرکزی | تنظیم‌کننده محاسبات فعال‌سازی |
|-----------------|----------------|--------------------|-------------------|--------------------------|----------------|---------------------------|-------------------------------|
| ۱ | ۱۰ | ۰/۰۰۰۰۱ | یکنواخت | نرمال ناقص | خطی اصلاح شده | ۰/۰۰۰۰۱ | ۰/۰۰۰۰۱ |
| ۲ | ۲۰ | ۰/۰۰۰۰۱ | یکنواخت | نرمال ناقص | خطی | ۰/۰۰۰۰۱ | ۰/۰۰۰۰۱ |
| ۳ | ۵۰ | ۰/۰۰۰۰۱ | یکنواخت | نرمال ناقص | خطی | ۰/۰۰۰۰۱ | ۰/۰۰۰۰۱ |
| ۴ | ۱۰۰ | ۰/۰۰۰۰۱ | یکنواخت | نرمال ناقص | خطی | ۰/۰۰۰۰۱ | ۰/۰۰۰۰۱ |
| ۵ | ۲۰۰ | ۰/۰۰۰۰۱ | یکنواخت | نرمال ناقص | خطی | ۰/۰۰۰۰۱ | ۰/۰۰۰۰۱ |
| ۶ | ۴۰۰ | ۰/۰۰۰۰۱ | یکنواخت | نرمال ناقص | خطی | ۰/۰۰۰۰۱ | ۰/۰۰۰۰۱ |
| ۷ | ۷۰۰ | ۰/۰۰۰۰۱ | یکنواخت | نرمال ناقص | خطی | ۰/۰۰۰۰۱ | ۰/۰۰۰۰۱ |

۶- نتایج و بحث

اولین مرحله از پژوهش حاضر، بررسی و مطالعه کم و کیف داده‌ها است. برای داشتن نتایج قابل قبول از مدل سازی پیش‌بینی محور، کیفیت داده‌های ورودی بسیار تعیین‌کننده است. بهترین مدل‌ها و الگوریتم‌ها در مواجهه ورودی‌های بی کیفیت، نمی‌توانند کمترین توقعات را پیش‌بینی کنند. لذا پایش و پالایش داده‌ها قبل از ورود آن‌ها به مدل، از مهم‌ترین مراحل دسترسی به مدل خوب است. این مرحله تحت عنوان پایش پالایش داده‌ها نامیده می‌شود. در ادامه مراحل مختلف فرایند پایش پالایش ارائه شده است.

برای داشتن احاطه بر وضعیت کلی داده‌ها، محاسبه برخی ویژگی‌های آماری آن‌ها، اجتناب ناپذیر است. برای این منظور، خلاصه‌ای از وضعیت آماری داده‌ها، در قالب جدول ۲ آورده شده است. این جدول شامل اطلاعاتی از تعداد، میانگین، انحراف معیار و چارک‌های داده‌ها است. در جدول ۲ کل ماده منفجره نماد مقدار کل ماده منفجره مصرف شده بر حسب کیلوگرم و فاصله از محل انفجار، نماد فاصله‌ی لرزه سنج از مرکز ثقل چال

برای ارزیابی کیفیت عملکرد مدل یادگیری عمیق، از شاخص‌های متعددی استفاده شده است که هر یک با ساختار محاسباتی خاص خود، ابعاد مختلفی از کارکرد مدل را منعکس می‌کنند. این شاخص‌ها شامل معیارهای عددی و نمایش‌های گرافیکی هستند. برای جلوگیری از اطاله متن، ساختار محاسباتی هر یک از این شاخص‌ها و تفسیر آن‌ها، در بخش نتایج به صورت هم‌زمان ارائه خواهد شد. شایان ذکر است که ارزیابی عملکرد مدل صرفاً بر پایه شاخص‌ها نمی‌تواند به تنهایی بیانگر کیفیت نهایی آن باشد. در واقع، قضاوت دقیق درباره عملکرد مدل زمانی امکان‌پذیر است که نتایج آن با سایر مدل‌ها مقایسه شود. برای این منظور، از سه مدل مرجع شامل ماشین بردار پشتیبان (SVM)، روش تقویت تطبیقی (Adaptive Boosting) و الگوریتم گرادین کاهشی تصادفی (SGD) برای مدل‌سازی داده‌ها استفاده شد. برای آشنایی با الگوریتم‌های محاسباتی هر کدام از روش‌های به منابع [۱۷-۱۹] مراجعه شود.

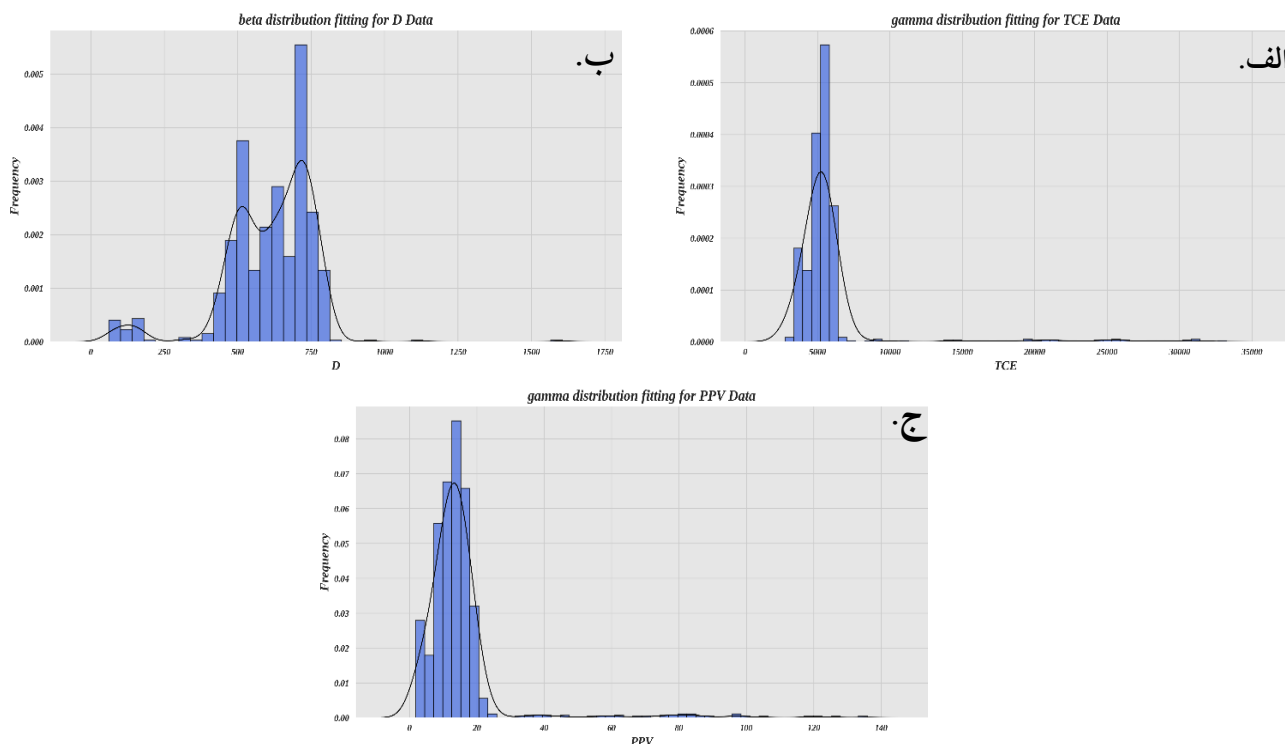
پس از تحلیل جداگانه رفتار هر متغیر، در مرحله بعد لازم است نوع ارتباط میان متغیرهای ورودی بررسی شود. نحوه ارتباط میان متغیرهای ورودی نقش مهمی در تحلیل و تفسیر رفتار مدل ایفا می‌کند. در این مرحله، از جمله ابزارهای مؤثر می‌توان به ترسیم نمودارهای پراکندگی و محاسبه ضرایب همبستگی میان متغیرها اشاره کرد. شکل ۵ نحوه توزیع و پراکندگی دو متغیر فاصله از محل انفجار و مقدار کل ماده منفجره را نمایش می‌دهد. برای این منظور از نمودار کانتوری استفاده شده است تا الگوی پراکندگی داده‌ها نسبت به یکدیگر به صورت بصری بهتر قابل تشخیص باشد. بر اساس این نمودار، به نظر می‌رسد که دو متغیر مذکور دارای توزیع نسبتاً یکنواخت و پراکنده‌ای هستند و وابستگی مشخصی میان آن‌ها مشاهده نمی‌شود. این موضوع نشان‌دهنده وضعیت مناسب متغیرهای ورودی و نبود همبستگی شدید میان آن‌هاست. به عبارت دیگر، پدیده هم‌خطی (Multicollinearity) بین متغیرهای ورودی وجود ندارد و همبستگی معناداری میان آن‌ها دیده نمی‌شود. برای بررسی کمی پدیده هم‌خطی، یکی از ابزارهای رایج و قدرتمند، استفاده از ماتریس همبستگی بین متغیرهای ورودی است. شکل ۶، ضریب همبستگی بین دو متغیر فاصله از محل انفجار و مقدار ماده منفجره مصرفی را نمایش می‌دهد. همان‌طور که در این شکل مشاهده می‌شود، ضریب همبستگی بین این دو متغیر برابر با $0/011$ است؛ عددی بسیار پایین که نشان‌دهنده عدم وابستگی خطی معنادار بین آن‌هاست و احتمال بروز پدیده هم‌خطی را به‌طور مؤثر کاهش می‌دهد. از جمله آثار منفی پدیده هم‌خطی می‌توان به ناپایداری مدل، افزایش واریانس ضرایب و کاهش دقت پیش‌بینی اشاره کرد.

های انفجاری بر حسب متر و حداکثر سرعت ذره، نماد حداکثر سرعت ذره بر حسب میلی‌متر بر ثانیه است. با در نظر گرفتن جدول ۲ مشخص است که داده‌ها، در یک بازه قابل انطباق بر هم نیستند که می‌تواند اثر بسیار بدی بر روند رفتار شناسی مدل بگذارد که می‌بایست حل شود. از سوی دیگر، محاسبه چارک‌های داده‌ها می‌تواند در شناسایی داده‌های پرت کمک کند.

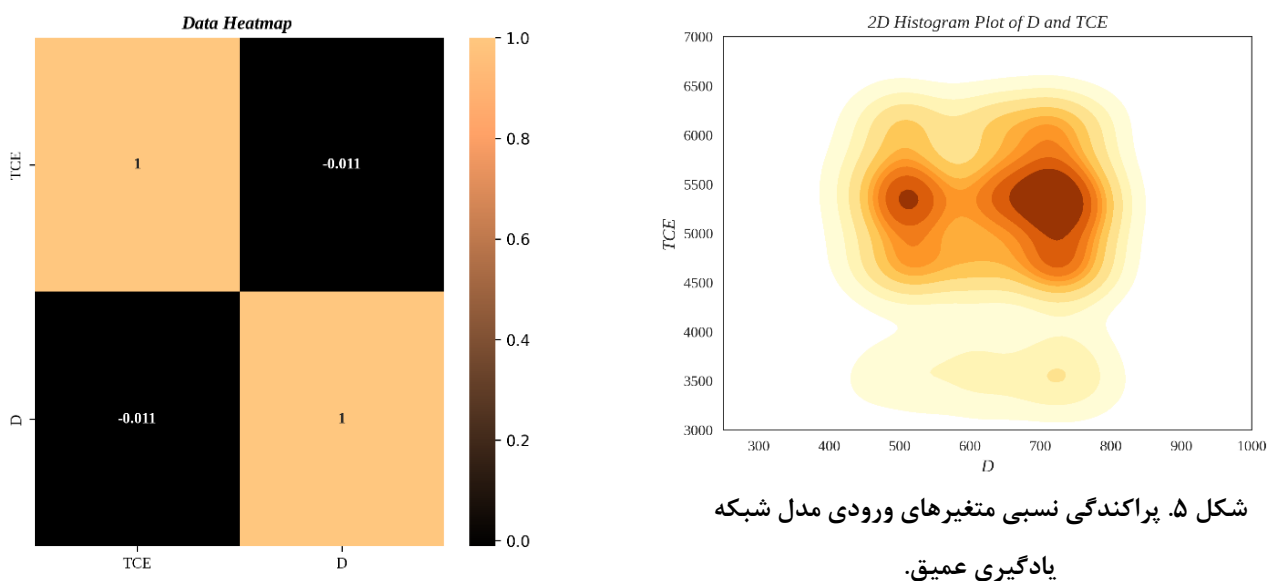
از ویژگی‌های اساسی هر مجموعه داده می‌توان به موقعیت مرکزی، پراکندگی، میزان انحراف و به‌طور کلی، شکل توزیع آن اشاره کرد. داشتن توزیع مناسب و دامنه مقادیر متنوع از الزامات یک پایگاه داده‌ی مناسب برای مدل‌سازی است. چنانچه داده‌ها تنها شامل تعداد محدودی مقدار باشند، مدل نمی‌تواند الگوی رفتاری مؤثری از آن‌ها استخراج کند. همچنین، آگاهی از نوع توزیع احتمال داده‌ها می‌تواند نقش مهمی در شناخت ساختار آماری و رفتار عمومی داده‌ها ایفا کند. بر این اساس، در این مرحله با ترسیم هیستوگرام داده‌ها، ویژگی‌های توزیع، مرکز، پراکندگی و شکل کلی داده‌ها بررسی می‌شود. لذا در ادامه در قالب شکل ۴، هیستوگرام و بهترین تابع توزیع برازش یافته به آن‌ها آورده شده است. با در نظر گرفتن هیستوگرام داده‌ها، مشخص است که داده‌ها، از نظر بخش شدگی دارای وضعیت قابل قبولی بوده و می‌توانند طیف قابل قبولی از مقادیر را در اختیار مدل قرار دهند. در این مرحله علاوه بر ترسیم هیستوگرام، با برازش توابع توزیع مختلف بر داده‌ها می‌توان مناسب‌ترین تابع توزیع را شناسایی و معرفی کرد. براساس نتایج بدست آمده، تابع بتا بهترین برازش را برای داده‌های مربوط به فاصله از محل انفجار نشان می‌دهد، در حالی که برای کل ماده منفجره و حداکثر سرعت ذره، تابع گاما مناسب‌ترین توزیع شناخته شد.

جدول ۲. شاخص‌های آماری مهم داده‌ها قبل از فرایند پیش پردازش.

| آماره | مقدار کل ماده منفجره (کیلوگرم) | فاصله (متر) | حداکثر سرعت ذره (میلی‌متر بر ثانیه) |
|---------------|--------------------------------|-------------|-------------------------------------|
| تعداد داده‌ها | ۱۰۰۲ | ۱۰۰۲ | ۱۰۰۲ |
| میانگین | ۵۷۸۷/۲۵ | ۶۰۹/۶۴ | ۱۴/۷۲ |
| انحراف معیار | ۳۶۰۸/۸۷ | ۱۵۱/۰۹ | ۱۳/۵۵ |
| کوچکترین داده | ۲۷۷۰ | ۶۲ | ۱/۸۵ |
| چارک اول | ۴۷۱۵/۲۵ | ۵۲۱ | ۹/۵۳ |
| چارک میانی | ۵۲۹۹/۵ | ۶۴۴ | ۱۲/۹۷ |
| چارک سوم | ۵۶۶۴ | ۷۲۱ | ۱۶/۱۰ |
| بزرگترین داده | ۳۳۲۵۰ | ۱۶۰۶ | ۱۳ |



شکل ۴. توابع توزیع متغیرهای ورودی و خروجی مدل شبکه یادگیری عمیق: الف. تابع توزیع فاصله، ب. تابع توزیع حداکثر سرعت ذره، ج. تابع توزیع مقدار ماده منفجره بکار رفته




شکل ۵. پراکندگی نسبی متغیرهای ورودی مدل شبکه یادگیری عمیق.


شکل ۶. جدول مقادیر همبستگی متغیرهای ورودی مدل شبکه یادگیری عمیق.

داده‌ها داشته باشند. منشأ داده‌های پرت متنوع است که بررسی آن‌ها در اینجا مدنظر نیست؛ با این حال، شناسایی و حذف اثر آن‌ها یکی از مهم‌ترین گام‌های پیش‌پردازش داده‌ها محسوب می‌شود. برای شناسایی داده‌های پرت، روش‌های متعددی وجود دارد که از میان آن‌ها، استفاده از نمودار جعبه‌ای یکی از

پس از بررسی وضعیت داده‌های ورودی و اطمینان از مناسب بودن شرایط برای جلوگیری از وقوع پدیده هم‌خطی، مرحله بعد بررسی مقادیر داده‌ها است. هدف این مرحله، شناسایی و مدیریت داده‌های پرت است. داده‌های پرت می‌توانند اثرات منفی قابل توجهی در فرآیند جستجوی الگوی حاکم بر



شکل ۸. نمودار جعبه ای فاصله ای محل مرکز ثقل ثقل چال‌های انفجاری و مراحل حذف داده‌های پرت.




شکل ۹. نمودار جعبه ای مقدار ماده منفجره بکار رفته و مراحل حذف داده‌های پرت.

بعد از مرحله حذف داده‌های پرت، نوبت به هم مقیاس کردن داده‌های ورودی می‌رسد. هم مقیاس کردن داده‌ها یکی از مهم‌ترین مراحل پیش پردازش محسوب می‌شود. با نگاهی به ساختار داده‌ها، قابل مشاهده است که بازه متغیره‌های ورودی با هم و با متغیر خروجی یکسان نبوده و بزرگی مقادیر متفاوت است.

مشکل هم مقیاس نبودن داده‌ها باعث می‌شود مدل نسبت به مقادیر بزرگ‌تر حساسیت بیشتری نشان دهد. به عبارت دیگر، متغیرهایی با مقادیر بالاتر اثرگذاری بیشتری بر رفتار مدل

کارآمدترین روش‌ها به شمار می‌رود. نمودار جعبه‌ای با نمایش سه چارک داده‌ها، مقادیر خارج از چارک اول و سوم را به عنوان داده‌های پرت شناسایی می‌کند. شکل‌های ۷، ۸ و ۹ نمودار جعبه‌ای داده‌های ورودی و خروجی را در سه حالت نشان می‌دهند: همراه با داده‌های پرت، پس از حذف داده‌های پرت، و پس از جایگزینی داده‌های پرت. لازم به ذکر است که در مواجهه با داده‌های پرت، دو رویکرد اصلی وجود دارد: حذف داده‌های پرت (که موجب کاهش تعداد داده‌ها می‌شود) یا جایگزینی آن‌ها با آماره‌های مختلف مجموعه داده‌ها. یکی از روش‌های رایج جایگزینی، استفاده از مقادیر حداقل و حداکثر داده‌ها است. در این پژوهش، این روش به عنوان راهکار پیش‌پردازش داده‌ها اتخاذ شده است.

بعد از حل مشکل داده‌های پرت، بار دیگر برای کنترل وضعیت داده‌ها، چگونگی اثرپذیری آن‌ها از مراحل مختلف طی شده، آماره‌های مربوط به آن‌ها بررسی می‌شود. جدول ۳ خلاصه ای از وضعیت آماری داده‌ها و تغییرات آن‌ها نسبت به حالت اولیه را نشان می‌دهد. با توجه به جدول ۳ مشخص است که تغییرات اساسی در بازه داده‌ها رخ داده است که منجر به تغییرات سایر آماره‌های آن شده است.



شکل ۱۰. نمودار جعبه ای حداکثر سرعت ذره و مراحل حذف داده‌های پرت.

دارند، درحالی‌که متغیرهای کوچک‌تر ممکن است نقش کمتری ایفا کنند. چنین شرایطی موجب کاهش تعمیم‌پذیری و پایداری مدل شده و سطح عدم قطعیت پیش‌بینی‌ها را افزایش می‌دهد؛ در نتیجه، اعتماد به نتایج مدل کاهش می‌یابد. برای جلوگیری از این مشکل، هم مقیاس‌سازی داده‌های ورودی یک گام بسیار مهم محسوب می‌شود. لازم به ذکر است که داده‌های خروجی نیازی به تغییر مقیاس ندارند. روش‌های متعددی برای هم‌مقیاس‌سازی وجود دارد که هرکدام تأثیر خاصی بر فرآیند مدل‌سازی دارند. از مهم‌ترین این روش‌ها می‌توان به نرمال‌سازی، استانداردسازی و هم‌بازه‌سازی اشاره کرد. در روش هم‌بازه‌سازی، داده‌ها یا در یک بازه مشخص نگاشت می‌شوند یا

بر اساس مقدار ماکزیمم مقیاس‌بندی می‌گردند. هرکدام از این روش‌ها می‌تواند بر کارایی مدل اثرگذار باشد. در این پژوهش، با توجه به ارزیابی عملکرد مدل، از تکنیک نگاشت داده‌ها در بازه مربوط به داده‌های خروجی استفاده شده است. جدول ۴ خلاصه‌ای از وضعیت آماری داده‌ها پس از هم‌مقیاس‌سازی را نشان می‌دهد. با توجه به داده‌های این جدول مشخص است که مقادیر ورودی در یک بازه مشخص تصویر شده‌اند و اثر بزرگی نسبی داده‌ها بر مدل حذف شده است. لازم به ذکر است که داده‌های خروجی بدون تغییر باقی مانده‌اند. در نهایت، داده‌های ورودی آماده ورود به مدل هستند.

جدول ۳. وضعیت کلی داده‌ها بعد از حذف داده‌های پرت

| آماره | مقدار کل ماده منفجره (کیلوگرم) | فاصله (متر) | حداکثر سرعت ذره (میلیمتر بر ثانیه) |
|---------------|--------------------------------|-------------|------------------------------------|
| تعداد داده‌ها | ۱۰۰۲ | ۱۰۰۲ | ۱۰۰۲ |
| میانگین | ۵۲۰۰/۰۴ | ۶۱۷/۲۵ | ۱۲/۸۳ |
| انحراف معیار | ۷۴۵/۸۱ | ۱۲۲/۵۹ | ۴/۸۷ |
| کوچکترین داده | ۳۷۶۶/۵ | ۳۲۱ | ۲/۹۶ |
| چارک اول | ۴۷۱۵/۲۵ | ۵۲۱ | ۹/۵۳ |
| چارک میانی | ۵۲۹۹/۵ | ۶۴۴ | ۱۲/۹۷ |
| چارک سوم | ۵۶۶۴ | ۷۲۱ | ۱۶/۱۱ |
| بزرگترین داده | ۶۶۱۲/۷۵ | ۹۲۱ | ۲۲/۶۸ |

جدول ۴. مقادیر آماری داده‌ها بعد از انجام فرایند هم‌مقیاس‌سازی.

| آماره | مقدار کل ماده منفجره (کیلوگرم) | فاصله (متر) | حداکثر سرعت ذره (میلیمتر بر ثانیه) |
|---------------|--------------------------------|-------------|------------------------------------|
| تعداد داده‌ها | ۱۰۰۲ | ۱۰۰۲ | ۱۰۰۲ |
| میانگین | ۳/۹۹ | ۲۲/۳۷ | ۱۴/۵۱ |
| انحراف معیار | ۴/۳۱ | ۵/۹۹ | ۱۲/۰۴ |
| کوچکترین داده | ۱ | ۱ | ۲/۳۴ |
| چارک اول | ۲/۶۶ | ۱۸/۷۹ | ۹/۵۳ |
| چارک میانی | ۳/۴۱ | ۳۲/۸۲ | ۱۲/۹۷ |
| چارک سوم | ۳/۸۸ | ۲۶/۹۷ | ۱۶/۱۱ |
| بزرگترین داده | ۳۰ | ۲۹/۹۹ | ۸۵/۹۹ |

های خاصی است که در عین حال که انعکاس دهنده‌ی میزان انحراف مقادیر پیش‌بینی شده از مقادیر واقعی است ولی گاهاً تعبیر و تفسیر آن نیاز به خرج داده احتیاط است. روش

میانگین درصد خطای مطلق، از متداول‌ترین سنجه‌های آماری است که برای مطالعه رفتار مدل‌های پیش‌بینی کننده، استفاده می‌شود. ماهیت محاسباتی این سنجه، همراه با ویژگی

پشتیبان، با فاصله ای بسیار کم، عملکرد بهتری را ارائه داد است. میزان برتری محاسباتی مدل ماشین بردار پشتیبان، نسبت به مدل مبتنی بر یادگیری عمیق برابر با ۰/۰۰۴ یا همان ۰/۴ درصد است. از نظر عملکردی با در نظر گرفتن شاخص میانگین درصد خطای مطلق، مدل مبتنی بر روش تقویتی سازگار، در رتبه سوم و مدل مبتنی بر روش گرادیان تصادفی کاهشی، بدترین عملکرد را داشته است. با توجه به نتایج بدست آمده برای این مدل‌ها، و در نظر گرفتن ماهیت پردازش شده داده‌ها، مدل یادگیری عمیق در پیش‌بینی مقدار لرزه به وجود آمده بر اساس فاصله و مقدار مواد منفجره بکار رفته، عملکرد قابل قبولی را از خود نشان داده است.

همبستگی بالای مقادیر اندازه‌گیری شده و مقادیر پیش‌بینی شده توسط مدل‌ها، از نشانه‌های بسیار خوبی برای عملکرد قابل قبول آن‌ها است. برای مطالعه مقدار هم رفتاری و هم بستگی داده‌ها پیش‌بینی شده و داده‌های واقعی، شاخص وجود دارد که ضریب تعیین (R^2)، نامیده می‌شود. ضریب تعیین؛ در تعریف پایه‌ای خود، معیاری از کیفیت برازش داده‌ها بر یک مدل رفتاری است. ولی در فضای کاری مربوط به پیش‌بینی رفتاری، شاخصی از چگونگی نزدیکی مقادیر واقعی و مقادیر پیش‌بینی شده و به عبارت دقیق‌تر میزان همبستگی آن‌ها است. برای محاسبه مقدار ضریب تعیین، می‌توان از رابطه ۲، استفاده کرد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

در رابطه ۲، \bar{y} ، نماد میانگین داده‌های واقعی است. بقیه پارامترها، قبلاً معرفی شده است. ضریب تعیین، بیان می‌کند که مقادیر مشاهده شده، تا چه حدی بر مدل رفتاری پیش‌بینی شده منطبق هستند. در حالت کلی مقادیر ضریب تعیین، بین ۱ تا منفی بینهایت قرار می‌گیرند. مقادیر نزدیک به یک معمولاً نشان از کارایی قابل قبول مدل رفتاری و مقادیر نزدیک به صفر و حتی مقادیر منفی نشان از عملکرد غیرقابل قبول مدل در پیش‌بینی رفتار داده‌ها است. لازم به ذکر است که شاخص ضریب تعیین، همانند سایر معیارهای ارزیابی عملکرد مدل‌های پیش‌بینی، دارای محدودیت‌ها و نقاط ضعف خاص خود است. عواملی مانند مقیاس داده‌ها، ماهیت آن‌ها و روش‌های پیش‌پردازش می‌توانند بر رفتار این شاخص اثرگذار باشند. در برخی موارد، مقادیر بالای ضریب تعیین ممکن است ناشی از وجود ایراد در مدل باشد. برای مثال، داده‌های پرت می‌توانند باعث کاهش اعتماد به این شاخص شوند، زیرا ضریب تعیین

محاسباتی این شاخص، از نقاط قوت آن بوده و به راحتی قابل محاسبه است. رابطه ۱ فرمول محاسباتی آن را نشان می‌دهد.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (1)$$

در رابطه ۱، y_i ، نماد مقادیر اندازه‌گیری شده، \hat{y}_i ، نماد مقادیر پیش‌بینی شده و n ، تعداد داده‌های است. در حقیقت، میانگین درصد خطای مطلق، معیاری از میزان صحت مدل است. به دلیل گزارش این معیار بر حسب درصد، امکان تفسیر و ارائه آن ساده‌تر از سایر شاخص‌ها، است. علی‌رغم نقاط قوت بیان شده، این شاخص، دارای نقاط ضعف منحصر به فرد خود است که لازم است در مرحله تفسیر نتایج، حتماً در نظر گرفته شود. میانگین درصد خطای مطلق، با توجه به ساختار محاسباتی آن، در مواجهه با مقادیر واقعی صفر، توانایی محاسباتی خود را از دست می‌دهد. زیرا تقسیم بر صفر معنای ریاضی ندارد. همچنین این شاخص گاهی مدل‌های بی کیفیت که از صحت و دقت کافی برخوردار نیستند را با محاسبه مقادیر پایین خود، به عنوان مدل خوب ارزیابی می‌کند. از اصلی‌ترین محدودیت‌های این شاخص، این را می‌توان بیان کرد که با نزدیک شده مقادیر واقعی و پیش‌بینی شده به صفر، علی‌رغم نزدیکی مقادیر واقعی و پیش‌بینی شده به هم، باز مقدار شاخص خطا، به سمت مقادیر بالا حرکت خواهد کرد. این سنجح حساس به مقیاسی است که داده‌های در آن قرار دارند. لذا استفاده از این شاخص برای داده‌های غیر هم مقیاس می‌تواند همراه با بروز خطا در ارزیابی عملکرد واقعی مدل پیش‌بینی کننده شود. بر همین اساس استفاده از این شاخص برای مقایسه عملکرد یک مدل در مواجهه با داده‌های مختلف، منطقی نیست. لذا توصیه‌ها همیشه به استفاده از سایر شاخص‌ها، در کنار این معیار برای ارزیابی جامع مدل پیش‌بینی کننده است.


با توجه به توضیحات ارائه شده، در این کار پژوهشی برای ارزیابی میزان کارایی مدل مبتنی بر یادگیری عمیق، اقدام به محاسبه مقدار میانگین درصد خطای مطلق، شد. شکل ۱۰، نمودار نشان دهنده مقادیر میانگین درصد خطای مطلق، است که برای مدل یادگیری عمیق و مدل‌های ماشین بردار پشتیبان، تقویتی سازگار، گرادیان تصادفی تنزلی بدست آمده است. با در نظر گرفتن مقادیر میانگین درصد خطای مطلق، برای مدل‌های مختلف، مشخص می‌شود که مدل‌های مبتنی بر آموزش عمیق و ماشین بردار پشتیبان، کمترین میانگین درصد خطای مطلق، را ارائه داده‌اند. در این بین مدل مبتنی بر ماشین بردار

نسبت به داده‌های پرت بسیار حساس است. همچنین وقوع پدیده هم‌خطی میان داده‌های ورودی می‌تواند منجر به بالا بودن غیرواقعی ضریب تعیین شده و ضعف واقعی مدل را پنهان کند. از سوی دیگر، این شاخص هیچ تفسیر مستقیمی از علل رفتار مدل یا منشأ خطاها ارائه نمی‌دهد. بنابراین، استفاده از ضریب تعیین در کنار سایر شاخص‌ها، رویکرد جامع‌تری برای ارزیابی کیفیت مدل پیش‌بینی‌کننده فراهم می‌کند. با وجود این محدودیت‌ها، در این مطالعه مقادیر ضریب تعیین برای مدل‌های منتخب محاسبه و در قالب شکل ۱۱ ارائه شده است. همان‌طور که در این شکل مشاهده می‌شود، مدل مبتنی بر یادگیری عمیق با مقدار ۰/۹۳۲ بهترین عملکرد را از نظر این شاخص نشان داده است. با توجه به هم‌مقیاس‌سازی داده‌ها، حذف داده‌های پرت و بررسی عدم وقوع پدیده هم‌خطی، می‌توان نتیجه گرفت که مقدار ضریب تعیین، بازتاب قابل اعتمادی از عملکرد مدل است. مدل‌های مبتنی بر ماشین بردار پشتیبان، تقویت تطبیقی و گرادیان کاهشی تصادفی در رتبه‌های بعدی قرار گرفتند. در مجموع، عملکرد دو مدل یادگیری عمیق و ماشین بردار پشتیبان در این شاخص قابل توجه است.


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (۳)$$

شاخص میانگین ریشه مربعات خطا (RMSE) علاوه بر ارائه شرایط هم‌سویی میان داده‌های واقعی و پیش‌بینی‌شده، با تمرکز بر خطاهای بزرگ، به شناسایی نواحی‌ای از داده‌ها کمک می‌کند که مدل در مواجهه با آن‌ها عملکرد مناسبی ندارد. به دلیل همین ویژگی، RMSE در مقایسه با سایر شاخص‌ها رویکردی محافظه‌کارانه‌تر داشته و سطح اطمینان بیشتری را فراهم می‌کند. در واقع، RMSE وزن بیشتری به خطاهای بزرگ‌تر می‌دهد که این امر آن را از شاخص میانگین خطای مطلق (MAE) متمایز و در عین حال نسبت به داده‌های پرت حساس‌تر می‌سازد. این حساسیت ناشی از فرآیند توان دوم‌گیری اختلاف مقادیر واقعی و پیش‌بینی‌شده در محاسبه RMSE است. لازم به ذکر است که این شاخص نیز تحت تأثیر مقیاس داده‌ها قرار دارد و هم‌مقیاس‌سازی داده‌های ورودی نقش مهمی در نتایج آن ایفا می‌کند. در این مطالعه، از RMSE برای ارزیابی عملکرد مدل استفاده شده است. بر این اساس، شکل ۱۲، مقادیر RMSE را برای مدل‌های منتخب نشان می‌دهد. طبق این شکل، مدل مبتنی بر یادگیری عمیق در این شاخص نیز عملکرد بهتری نسبت به سایر مدل‌ها داشته است. مقدار RMSE برای مدل یادگیری عمیق برابر با ۱/۵۲۷ محاسبه شد که نشان‌دهنده کوچکتر بودن خطاهای مدل مذکور است. در این شاخص نیز مدل مبتنی بر ماشین بردار پشتیبان در رتبه دوم قرار گرفته است.


وضعیت پراکندگی داده‌های اندازه‌گیری شده، پیرامون مدل رفتاری پیش‌بینی شده نیز از نکات مهم در فرآیند مطالعه کیفیت یک مدل رفتاری پیش‌بینی‌کننده، محسوب می‌شود. شاخص میانگین ریشه مجذور خطا، معیاری است که نشان‌دهنده ی همین رفتار مدل است. شاخص میانگین ریشه مجذور خطا، شاخصی است که انحراف معیار باقیمانده‌های مقادیر واقعی از مقادیر پیش‌بینی شده را منعکس می‌کند. این معیار، پارامتری است که نسبت به مقیاس خطاهای رخ داده در فرآیند پیش‌بینی استاندارد سازی نشده و این در حالی است که شاخص ضریب تعیین، شاخصی استاندارد شده است. مقادیر شاخص میانگین ریشه مجذور خطا، از صفر شروع شده و به



شکل ۱۰. مقادیر میانگین درصد خطای مطلق مدل شبکه یادگیری عمیق و سه مدل منتخب.



شکل ۱۱. مقادیر ضریب تعیین مدل شبکه یادگیری عمیق و سه مدل منتخب.



شکل ۱۲. مقادیر میانگین مجذور مربعات خطای مدل شبکه یادگیری عمیق و سه مدل منتخب.

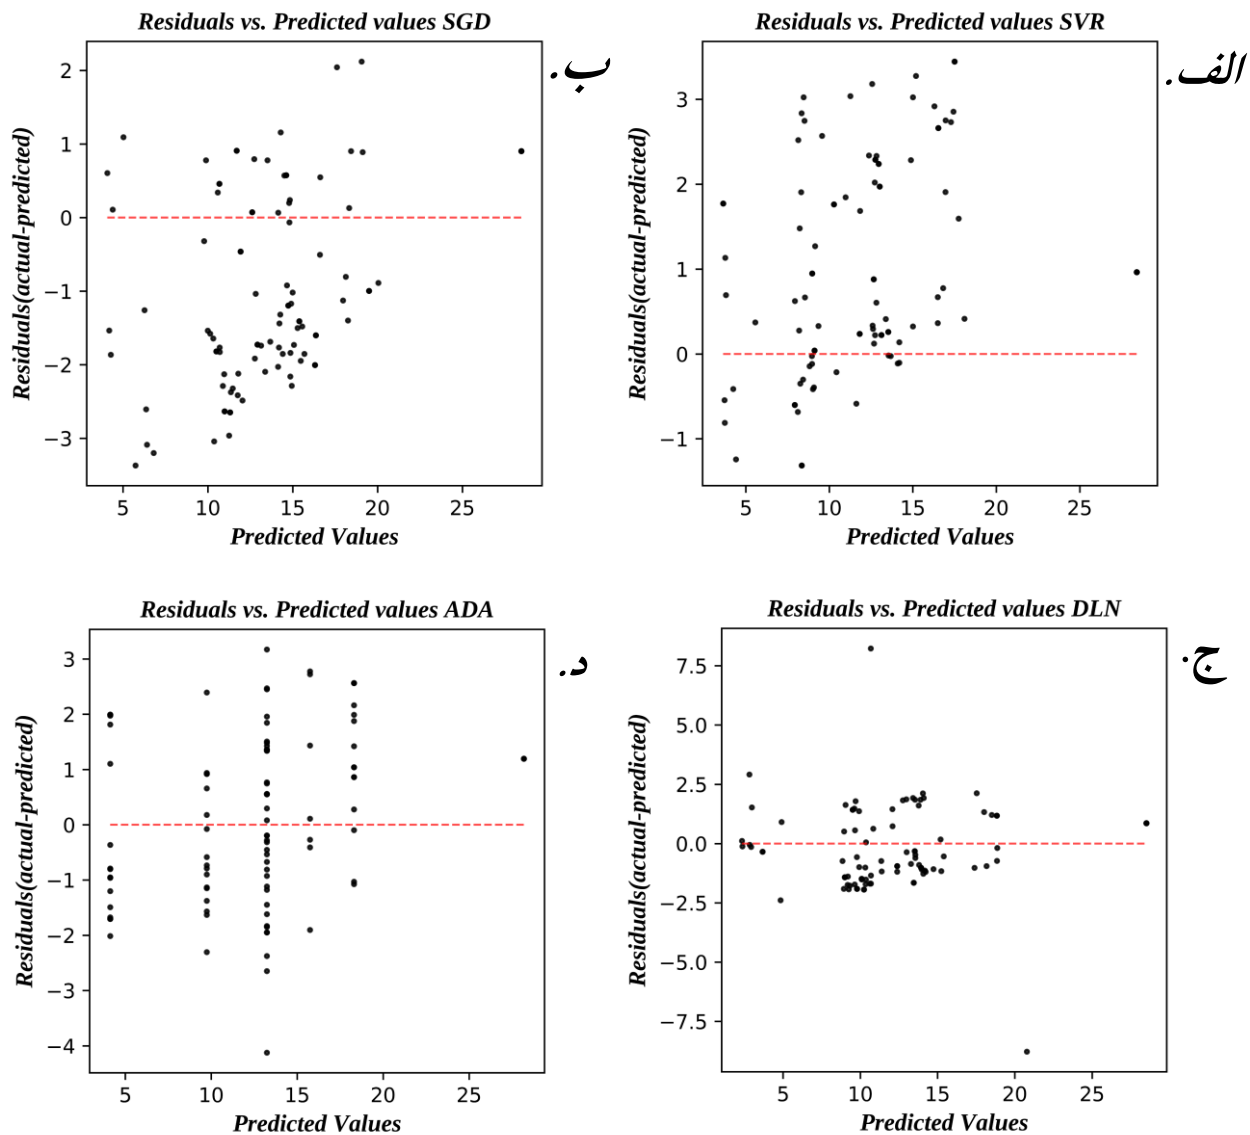
واقعی مدل پیش‌بینی‌کننده فراهم آورد. همانطور که شکل‌های ۱۰، ۱۱، ۱۲ نشان داده شده است، مدل مبتنی بر یادگیری عمیق در هر سه شاخص عملکرد رضایت‌بخشی داشته و بهترین مقادیر را به دست آورده است. این امر سطح بالایی از اطمینان و اعتماد به نتایج مدل را ایجاد می‌کند. دلیل اصلی به کارگیری توأمان این سه شاخص آن است که در صورت ضعف احتمالی یکی از آن‌ها، سایر شاخص‌ها بتوانند این کاستی را آشکار کنند و ارزیابی جامعی از عملکرد مدل ارائه دهند.

با توجه به مقادیر سه شاخص ارزیابی عملکرد مدل‌های رفتاری منتخب، مشخص می‌شود که مدل مبتنی بر یادگیری عمیق در پیش‌بینی لرزش براساس حداکثر سرعت ذره و با در نظر گرفتن فاصله و میزان ماده منفجره، هم از نظر صحت و هم از نظر دقت خروجی‌ها، عملکرد قابل قبولی ارائه داده است. مقادیر شاخص‌های میانگین ریشه مربعات خطا، ضریب تعیین و میانگین درصد خطای مطلق ممکن است در استفاده انفرادی، ناپایداری یا سطح اطمینان کافی نداشته باشند؛ اما استفاده هم‌زمان از این شاخص‌ها، می‌تواند بازتاب دقیق‌تری از کیفیت

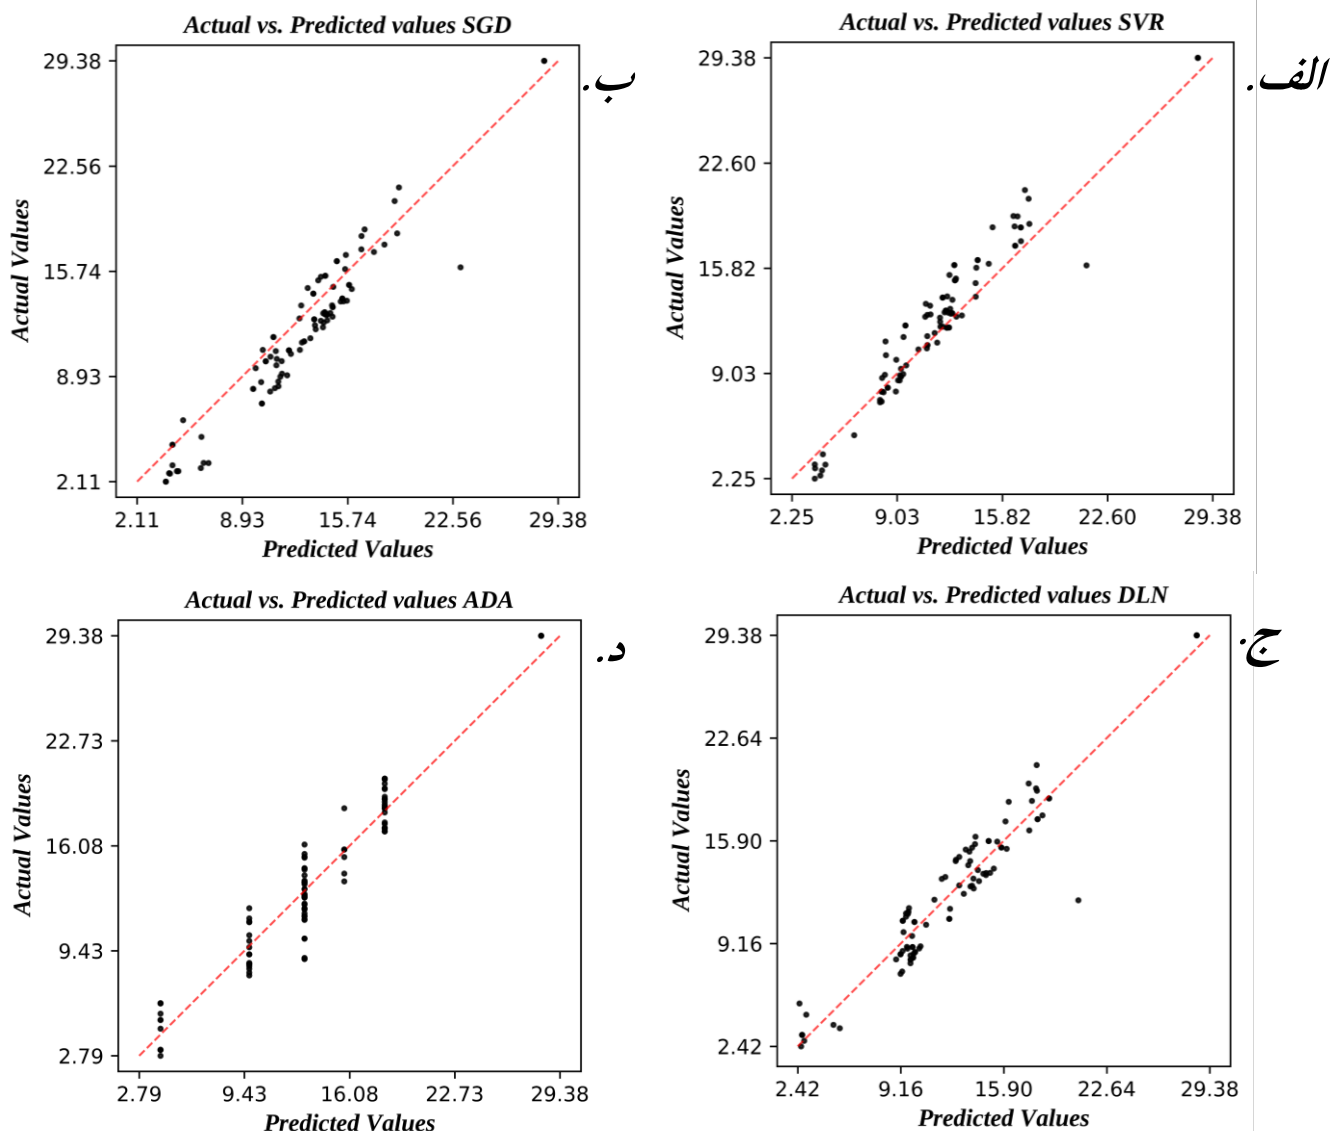
مدل ارائه دهد. یکی از ابزارهای گرافیکی مؤثر در این زمینه، نمایش نمودار خطاهای باقیمانده است که در آن اندیس داده‌ها روی محور افقی و مقادیر خطای باقیمانده روی محور عمودی نمایش داده می‌شوند. خطای باقیمانده بیانگر فاصله میان مقادیر پیش‌بینی‌شده و واقعی است. اگر یک مدل عملکرد قابل قبولی داشته باشد، پراکندگی داده‌ها در این نمودار دو ویژگی کلیدی خواهد داشت: نخست، تراکم بالای مقادیر خطای باقیمانده حول محور افقی که نشان‌دهنده خطای صفر است؛ و دوم، توزیع متقارن داده‌ها بدون پیروی از الگوی خاص. چنین نمایش نموداری امکان ارزیابی جامع عملکرد مدل را فراهم می‌آورد. علاوه بر این، نمودار همبستگی میان داده‌های واقعی و پیش‌بینی شده نیز ابزار مفیدی برای بررسی عملکرد مدل محسوب می‌شود. در این پژوهش، به‌منظور تکمیل فرآیند ارزیابی، هر دو نمودار فوق ترسیم شدند. شکل ۱۳ و شکل ۱۴ نمودارهای دقت پیش‌بینی برای مدل‌های گرادیان تصادفی کاهشی، ماشین بردار پشتیبان، تقویتی سازگار و شبکه یادگیری عمیق، آورده شده است.

ارزیابی کیفیت عملکرد مدل‌های رفتاری مبتنی بر داده‌ها از جنبه‌های مختلف امکان‌پذیر است. یکی از رایج‌ترین روش‌ها برای سنجش میزان کارایی مدل‌ها، استفاده از شاخص‌های عددی است. این شاخص‌ها با توجه به ساختار محاسباتی خود، جنبه‌های مختلف عملکرد یک مدل پیش‌بینی‌کننده را ارزیابی و گزارش می‌کنند. با این حال، همان‌طور که در بخش قبل به نقاط ضعف این پارامترهای عددی اشاره شد، اتکا صرف به این شاخص‌ها می‌تواند منجر به ارزیابی ناقص یا حتی گمراه‌کننده از عملکرد مدل شود. به‌منظور جلوگیری از چنین خطاهایی و دستیابی به دیدگاهی جامع‌تر نسبت به کیفیت واقعی مدل، استفاده از تحلیل‌های گرافیکی و نموداری در کنار شاخص‌های عددی بسیار مفید است. بر این اساس، در این بخش از پژوهش، عملکرد مدل‌ها به‌صورت نموداری نیز بررسی شده است.

خطای باقیمانده هر پیش‌بینی یکی از مهم‌ترین شاخص‌های ارزیابی کارایی مدل‌ها است. با این حال، بررسی مقادیر منفرد یا حتی میانگین آن‌ها به‌تنهایی نمی‌تواند تصویر کاملی از کیفیت



شکل ۱۳. وضعیت پراکندگی نقاط واقعی و پیش‌بینی شده نسبت به شاخص خطای صفر.



شکل ۱۴. وضعیت پراکندگی نقاط واقعی و پیش‌بینی شده نسبت به شاخص خطای صفر و نیم‌ساز ربع اول برای مدل یادگیری عمیق و سه مدل منتخب.

وابسته به تجربه و دانش فرد تحلیل‌گر است، که این امر قضاوت بر اساس آن‌ها را دشوار می‌سازد. برای رفع این محدودیت، به‌کارگیری یک معیار نموداری و انطباق آن با شاخص‌های عددی می‌تواند بسیار مفید باشد. یکی از روش‌های متداول، نمایش هم‌زمان داده‌های واقعی و پیش‌بینی‌شده بر اساس اندیس داده‌ها است. در چنین نموداری، میزان انطباق داده‌ها را می‌توان به‌صورت بصری ارزیابی کرد؛ به‌طوری‌که در صورت عملکرد مناسب مدل، دو خط گذرنده از داده‌های واقعی و پیش‌بینی‌شده بسیار نزدیک به هم بوده و فاصله بین آن‌ها کم خواهد بود. در مقابل، بروز خطاهای بزرگ موجب افزایش جدایش این دو نمودار می‌شود. برای انجام مقایسه کمی میان مدل‌ها، مساحت بین دو خط به‌عنوان یک شاخص عددی


با بررسی این شکل‌ها مشخص است که تراکم و تقارن داده‌ها حول خط خطای صفر در مدل مبتنی بر یادگیری عمیق نسبت به سایر مدل‌ها وضعیت مطلوب‌تری دارد. همچنین، نمودار همبستگی داده‌های واقعی و پیش‌بینی‌شده نشان می‌دهد که این مدل از عملکرد بهتری برخوردار است. به‌طور کلی، استفاده از نمودارها این امکان را فراهم می‌سازد که عملکرد مدل‌ها به‌صورت آبی و جامع ارزیابی شود. استفاده از روش‌های نموداری در کنار مزایای خود، دارای محدودیت‌هایی نیز هست. مهم‌ترین ضعف این روش‌ها، مقایسه غیرکمی خروجی‌ها است؛ زیرا این مقایسه‌ها عمدتاً بر اساس شاخص‌های بصری انجام می‌شوند و به‌شدت تحت تأثیر سلیقه و قضاوت فردی قرار دارند. درواقع کیفیت تحلیل نمودارها

عمیق، برابر با ۳۰/۴۵۹ محاسبه شد که نشان‌دهنده انطباق بالای داده‌های پیش‌بینی‌شده با داده‌های واقعی و قابلیت اعتماد بالای این مدل است.


جدول ۵. مقدار مساحت بین نمودارهای گذرنده از نقاط واقعی و پیش‌بینی.

| DLN | ADA | SVR | SGD | مدل |
|--------|--------|---------|---------|-------|
| ۳۰/۴۵۹ | ۴۴/۱۴۵ | ۱۱۰/۰۹۲ | ۱۴۴/۱۴۴ | مساحت |
| | | | | جدایش |


انتخاب شد. بر این اساس، پس از ترسیم خطوط مربوط به داده‌های واقعی و پیش‌بینی‌شده، اندازه مساحت بین آن‌ها محاسبه شد. شکل ۱۵ خطوط گذرنده از داده‌های واقعی و پیش‌بینی‌شده را برای مدل‌های منتخب نشان می‌دهد. همان‌طور که در این شکل مشاهده می‌شود، مدل مبتنی بر شبکه یادگیری عمیق بهترین عملکرد را داشته و میزان جدایش بین خطوط در این مدل کمتر از سایر مدل‌ها است. برای ارزیابی دقیق‌تر، مقادیر مساحت بین دو خط در جدول ۵ ارائه شده است. بر اساس این جدول، مقدار مساحت برای مدل یادگیری




الف



ب



ج




د

شکل ۱۵. وضعیت انطباق نمودارهای گذرنده از نقاط واقعی و پیش‌بینی شده برای مدل یادگیری عمیق و سه مدل منتخب

تعریف، فراوانی به تعداد تکرار داده‌ها در بازه‌های از پیش تعیین‌شده اطلاق می‌شود. شناسایی فراوانی خطاها در بازه‌های مختلف و تعیین بازه‌هایی با بیشترین فراوانی می‌تواند تصویری دقیق‌تر از عملکرد مدل ارائه دهد. در این راستا، استفاده از نمودار فراوانی تجمعی نسبی جامعه خطاها ابزار مؤثری است.

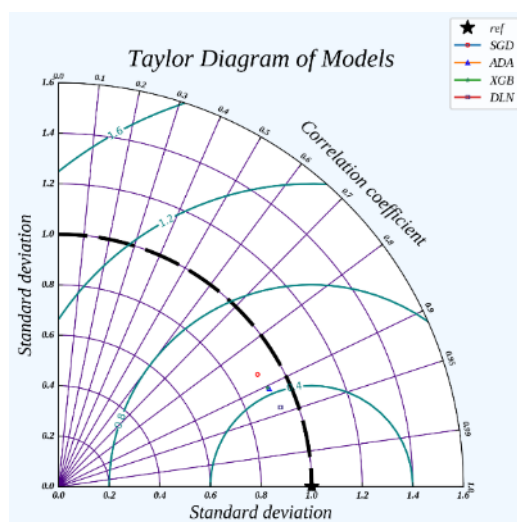
بررسی وضعیت آماری خطاهای ناشی از پیش‌بینی توسط مدل رفتاری از جنبه‌های مختلف می‌تواند نقش مهمی در اطمینان‌بخشی نسبت به عملکرد مدل ایفا کند. یکی از جنبه‌های مهم در تحلیل مدل‌های رفتاری داده‌ها، ارزیابی فراوانی خطاهای رخ داده در فرآیند پیش‌بینی است. براساس

نسبی خطاها در برابر میانگین خطای مطلق ترسیم شده است. شکل ۱۶ وضعیت منحنی فراوانی تجمعی خطاها براساس میانگین خطای مطلق نمایش می‌دهد. همان‌طور که از شکل ۱۶ مشخص است، منحنی مدل مبتنی بر یادگیری عمیق در بازه‌های کوچک خطا، فراوانی تجمعی نسبی بالاتری داشته و به قسمت فوقانی نمودار نزدیک‌تر شده است. این وضعیت نشان‌دهنده عملکرد بهتر و پایدارتر مدل یادگیری عمیق نسبت به سایر مدل‌های منتخب است.



شکل ۱۶. نمودار فراوانی تجمعی خطاهای مدل یادگیری عمیق و سه مدل منتخب.

نمودار تی‌لور، ابزاری قدرتمند برای نمایش هم‌زمان سه شاخص کلیدی عملکرد مدل‌های پیش‌بینی است. این سه شاخص عبارتند از: انحراف معیار خطاها (Standard Deviation)، ضریب همبستگی (Correlation Coefficient) و میانگین مربع خطاها (RMSE). در این نمودار، بهترین حالت ممکن به‌عنوان یک نقطه مرجع با مقدار ایده‌آل شاخص‌ها مشخص می‌شود. هرچه نقطه نمایش‌دهنده مدل به این نقطه مرجع نزدیک‌تر باشد، نشان‌دهنده انطباق و دقت بیشتر مدل است. در شکل ۱۷، نمودار تی‌لور مدل‌های منتخب ترسیم شده است. در این نمودار، مربع نماد مدل مبتنی بر یادگیری عمیق است که نزدیک‌ترین وضعیت را به نقطه مرجع دارد. این نزدیکی نشان‌دهنده بالاترین ضریب همبستگی و کمترین میزان انحراف معیار و خطای پیش‌بینی است. به همین دلیل، نمودار تی‌لور نیز عملکرد دقیق‌تر و مطلوب‌تر مدل مبتنی بر یادگیری عمیق را نسبت به سایر مدل‌ها تأیید می‌کند.



شکل ۱۷. نمودار تی‌لور مدل یادگیری عمیق و سه مدل منتخب.

داده‌های مورد استفاده شامل فاصله از محل انفجار و مقدار ماده منفجره بود که از دو معدن روباز سونگون اهر و گل‌گهر سیرجان جمع‌آوری شدند. متغیر خروجی، حداکثر سرعت ذره در نظر گرفته شد. نتایج حاصل از مدل یادگیری عمیق نشان داد که

۷- نتیجه‌گیری

در این پژوهش، با هدف پیش‌بینی شدت لرزه‌های ناشی از انفجار در معادن روباز، از روش یادگیری عمیق استفاده شد.

به خاطر حمایت‌ها و راهنمایی‌های مفیدی که در طول فرایند بازبینی انجام دادند، سپاسگزاریم.

۱۰- منابع

- [1] Dindarloo, S.R., 2015. Prediction of blast-induced ground vibrations via genetic programming. *International Journal of Mining Science and Technology* 25(6): 1011–5.
- [2] Ghasemi, E., Kalhori, H., Bagherpour, R., 2016. A new hybrid ANFIS–PSO model for prediction of peak particle velocity due to bench blasting. *Engineering with Computers* 32: 607–14.
- [3] Hasanipناه, M., Golzar, S.B., Larki, I.A., Maryaki, M.Y., Ghahremanians, T., 2017. Estimation of blast-induced ground vibration through a soft computing framework. *Engineering with Computers* 33: 951–9.
- [4] Asl, P.F., Monjezi, M., Hamidi, J.K., Armaghani, D.J., 2018. Optimization of flyrock and rock fragmentation in the Tajareh limestone mine using metaheuristics method of firefly algorithm. *Engineering with Computers* 34: 241–51.
- [5] Nguyen, H., Bui, X.-N., Tran, Q.-H., Moayedi, H., 2019. Predicting blast-induced peak particle velocity using BGAMs, ANN and SVM: a case study at the Nui Beo open-pit coal mine in Vietnam. *Environmental Earth Sciences* 78(15): 479.
- [6] Arthur, C.K., Temeng, V.A., Ziggah, Y.Y., 2020. Novel approach to predicting blast-induced ground vibration using Gaussian process regression. *Engineering with Computers* 36(1): 29–42.
- [7] Bui, X.-N., Choi, Y., Atrushkevich, V., Nguyen, H., Tran, Q.-H., Long, N.Q., et al., 2020. Prediction of blast-induced ground vibration intensity in open-pit mines using unmanned aerial vehicle and a novel intelligence system. *Natural Resources Research* 29(2): 771–90.
- [8] Fang, Q., Nguyen, H., Bui, X.-N., Nguyen-Thoi, T., 2020. Prediction of blast-induced ground vibration in open-pit mines using a new technique based on imperialist competitive algorithm and M5Rules. *Natural Resources Research* 29(2): 791–806.
- [9] Yang, H., Nikafshan Rad, H., Hasanipناه, M., Bakhshandeh Amnieh, H., Nekouie, A., 2020. Prediction of vibration velocity generated in mine blasting using support vector regression improved by optimization algorithms. *Natural Resources Research* 29(2): 807–30.
- [10] Azimi, Y., Khoshrou, S.H., Osanloo, M., 2019. Prediction of blast induced ground vibration (BIGV) of quarry mining using

این روش، در مقایسه با سه مدل مرجع شامل ماشین بردار پشتیبان، گرادیان کاهشی تصادفی و تقویت تطبیقی، از دقت و صحت بالاتری برخوردار است. به‌طور خاص، مدل یادگیری عمیق به‌ترتیب مقادیر ۰/۱۲۴، ۰/۹۳۲، ۱/۵۲۷ را برای شاخص‌های RMSE، R^2 و MAPE کسب کرد. نمودارهای تطبیق نیز عملکرد بهتر این مدل را تأیید کردند. دلیل اصلی این برتری، ساختار محاسباتی انعطاف‌پذیر شبکه‌های یادگیری عمیق است که با بهره‌گیری از لایه‌ها و عملگرهای پیچیده، توانایی تطبیق با رفتارهای غیرخطی و پیچیده زمین را فراهم می‌سازد. البته باید توجه داشت که انتخاب هایپر پارامترهای مدل از طریق آزمون و خطا انجام شده است که می‌تواند به‌عنوان یکی از محدودیت‌های پژوهش تلقی شود. همچنین افزایش تنوع داده‌ها و ورود پارامترهای دیگر مانند جنس سنگ، شیب، و شرایط زمین‌شناسی می‌تواند در آینده دقت و تعمیم‌پذیری مدل را افزایش دهد. در مجموع، مدل یادگیری عمیق، عملکردی دقیق و پایدار در پیش‌بینی لرزه‌های ناشی از انفجار براساس فاصله و مقدار ماده منفجره ارائه داد و می‌تواند به‌عنوان ابزاری مؤثر در تحلیل و کنترل مخاطرات لرزه‌ای در معادن روباز مورد استفاده قرار گیرد.

با وجود ترکیب داده‌های مربوط به دو معدن سونگون اهر و گل‌گهر سیرجان در مدل نهایی، باید توجه داشت که این دو معدن دارای شرایط زمین‌شناسی، نوع ماده معدنی، و ساختار باطله‌ای متفاوتی هستند. از آنجا که نوع سنگ، بافت زمین‌شناسی و وضعیت درزه‌ها نقش قابل توجهی در رفتار لرزه‌های ناشی از انفجار دارند، پیشنهاد می‌شود در ادامه پژوهش، مدل‌سازی به صورت تفکیک‌شده برای هر معدن انجام گیرد. چنین رویکردی می‌تواند دقت مدل را افزایش داده و تفسیرپذیری بهتری از رفتار لرزه‌ای محیط ارائه دهد. با توجه به حجم بالای داده‌های جمع‌آوری‌شده، این تفکیک در سطح داده و تحلیل نیز کاملاً امکان‌پذیر خواهد بود.

۸- تعارض منافع

هیچ‌گونه تعارض منافی توسط نویسندگان بیان نشد.

۹- قدردانی

از داوران محترم برای نظرهای دقیق و بازخوردهای سازنده‌ای که به بهبود و ارتقاء کیفی این مقاله کمک شایانی کردند، صمیمانه تشکر می‌کنیم. همچنین از سردبیر محترم

- [16] Chandrahas, N.S., Choudhary, B.S., Venkataramayya, M.S., Yewuhalashet, F., 2024. An inventive approach for simultaneous prediction of mean fragmentation size and peak particle velocity using futuristic datasets through improved techniques of genetic XG Boost algorithm. *Mining, Metallurgy & Exploration* 41(5): 2391–405.
- [17] Yuan, H., Zou, Y., Li, H., Ji, S., Gu, Z., He, L., et al., 2025. Assessment of peak particle velocity of blast vibration using hybrid soft computing approaches. *Journal of Computational Design and Engineering* 12(2): 154–76.
- [18] حسن، مومیوند، ۱۳۹۲. پیش‌بینی سرعت ذره‌ای حداکثر لرزش زمین ناشی از انفجار با استفاده از تحلیل نتایج حاصل از شرایط متعدد ژئومکانیکی. همایش انجمن زمین‌شناسی مهندسی و محیط زیست ایران.
- [19] حسن، مومیوند، ۱۴۰۲. خردایش سنگ و کنترل پیامدهای ناشی از انفجار. ۱، ارومیه: دانشگاه ارومیه.
- hybrid genetic algorithm optimized artificial neural network. *Measurement* 147: 106874.
- [11] Nguyen, H., Bui, X.-N., Bui, H.-B., Mai, N.-L., 2020. A comparative study of artificial neural networks in predicting blast-induced air-blast overpressure at Deo Nai open-pit coal mine, Vietnam. *Neural Computing and Applications* 32(8): 3939–55.
- [12] Zhang, W., Nian-Jie., Ren, J., Li, C., 2021. Peak particle velocity of vibration events in underground coal mine and their caused stress increment. *Measurement* 169: 108520, Doi: 10.1016/J.MEASUREMENT.2020.108520.
- [13] Zhang, X., Nguyen, H., Choi, Y., Bui, X.-N., Zhou, J., 2021. Novel Extreme Learning Machine-Multi-Verse Optimization Model for Predicting Peak Particle Velocity Induced by Mine Blasting. *Natural Resources Research*, Doi: 10.1007/s11053-021-09960-z.
- [14] Zeng, J., Roussis, P., Mohammed, A., Maraveas, C., Fatemi, S., Armaghani, D., et al., 2021. Prediction of Peak Particle Velocity Caused by Blasting through the Combinations of Boosted-CHAID and SVM Models with Various Kernels. *Applied Sciences* 11: 3705, Doi: 10.3390/APP11083705.
- [15] Sonkar, R., Dhekne, P.Y., Londhe, N.D., 2022. Prediction of Peak Particle Velocity of Blast-induced Ground Vibrations using Boosted Regression Trees Authored. *Journal of Mines, Metals and Fuels*: 203–13.