



Imam Khomeini International University

Vol. 10, No. 2, Summer 2025



نشریه مهندسی منابع معدنی

Journal of Mineral Resources Engineering
(JMRE)

Research Paper

Improving the 3D Estimation of Copper Grade in Sarcheshme Copper Deposit using Deep Learning Methods

Norouzi H.¹, Fathianpour N.^{2*}

1- M.Sc, Dept. of Mining Engineering, Isfahan University of Technology, Isfahan, Iran

2- Associate Professor, Dept. of Mining Engineering, Isfahan University of Technology, Isfahan, Iran

Received: 16 Aug. 2024

Accepted: 22 Dec. 2024

Abstract: Minimizing grade estimation errors through modern methods is crucial for optimizing mining operations and mitigating the risk of economic failure in mining projects. The current research is an attempt to enhance the three-dimensional estimation of copper grades in the Sarcheshmeh copper deposit by employing advanced deep-learning techniques and comparing their outcomes with those of traditional geometric methods. The Sarcheshmeh copper deposit is among the largest porphyry copper deposits located within the Urmia-Dokhtar volcanic belt, south of Kerman in central Iran. In this study, data from a number of 526 boreholes containing 38,006 core samples assayed for total copper were deployed. The average copper grade in the samples is 0.54 percent, with a maximum value of 3.43. Prior to grade estimation, preprocessing steps were performed, including outlier correction and data compositing. The anisotropy ellipsoid of the copper grade was determined using the covariance matrix. Two methods were applied for grade estimation: a deep learning algorithm based on the ResNet-50 architecture and the inverse distance weighting (IDW) method, a conventional geometric approach. Validation results indicated that the ResNet-50 algorithm, with an RMSE of 0.45, outperformed the IDW method, which had an RMSE of 0.6.

Keywords: Grade modeling, Neural networks, Deep learning methods, Inverse distance weighting method, Grade estimation.

How to cite this article

Norouzi, H., and Fathianpour, N. (2025). "Improving the 3D estimation of copper grade in Sarcheshme copper deposit using deep learning methods". Journal of Mineral Resources Engineering, 10(2): 71-89.

DOI: 10.30479/jmre.2025.20784.1712

*Corresponding Author Email: fathian@iut.ac.ir

COPYRIGHTS



©2025 by the authors. Published by Imam Khomeini International University.

This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) (<https://creativecommons.org/licenses/by/4.0/>)

INTRODUCTION

One of the most critical steps in evaluating the quality of mineralization in mineral deposits is estimating the grade of the deposit. The challenge associated with this issue lies in estimating the mineral grade within the deposit. The mineral concentration throughout a deposit is influenced by a number of factors, including the spatial dependency among samples and geological and structural settings of the sought mineralization [1]. Deep learning is one of the subsets of the machine learning class of methods that has made significant achievements in many areas in recent years. Unlike other machine learning methods, deep learning methods automatically benefit from discovering data features and patterns in models with complex structures [2]. Considering that most geological phenomena occur in the space-time domain and have heterogeneity, the variability of the behavior of these phenomena is usually nonlinear and often complex. Therefore, due to the powerful intelligent methods to reveal complex nonlinear behaviors, it is necessary to use these methods to identify nonlinear behaviors in geological phenomena [3].

METHODS

This research assumes that the variability of most geological phenomena is nonlinear, and intelligent methods can also reveal these complex nonlinear behaviors. To better guide the modeling methods, the primary data were divided into three groups tagged as training, validation, and test, which were trained using the training data and different methods, followed by evaluating their performances through test data. The performance of the methods was also evaluated using the RMSE objective function. By evaluating the results, the ResNet-50 convolutional neural network demonstrated the best performance, while the inverse distance weighting method showed the weakest performance. The inverse distance weighting method is one of the geometric interpolation methods in which the estimation weights are determined based on the inverse of the distance of the points entered in the estimation concerning the center of the estimated block. Microsoft introduced the ResNet convolutional neural network. ResNet is an abbreviation for two words: Residual Network [4]. This architecture solved the problem of training deep networks using residual structure. This residual structure is known as the residual block, the main task of which is to connect the primary inputs to the output of the next layer [5]. Figure1 shows the flowchart used in the spatial modeling of the grade in current research.




Figure 1. The workflow of the grade estimation process in the study area

FINDINGS AND ARGUMENT

Local-scale surveys were conducted to evaluate and compare the performance of each estimation method during both the training and testing phases of the network using the corresponding stage data. Next, their results were evaluated both quantitatively and qualitatively. It was found that in the training phase, the ResNet-50 method with an RMSE value of 0.3 has the lowest error, representing a method based on convolutional neural

networks. Among the geometric methods, the inverse distance weighting method with an RMSE value of 0.57 has the highest error. Therefore, it can be concluded that in the training step, among all the methods used in copper grade estimation, the ResNet-50 architecture with the lowest amount of error has the best performance, and the inverse distance weighting method with the highest amount of error has the weakest performance. Quantitative checks were made for the test data, and it was found that ResNet-50 with RMSE equal to 0.45 has the lowest amount of error, and the inverse distance weighting method with RMSE equal to 0.6 has the highest error. Therefore, through considering both the training and test steps, the best performance belongs to the ResNet-50 method, while the weakest performance is related to the inverse distance weighting method. Figure 2 shows the results of qualitative visual evaluation of model performances on test data.




Figure 2. The results of the qualitative evaluation of the network performance of the test data for the methods **A:** ResNet-50 and **B:** IDW

CONCLUSIONS

To assess the effectiveness of the methods used for copper grade estimation in this research, the training phase included evaluating the performance of deep convolutional networks based on residual structures, recognized as one of the most efficient deep neural network architectures. Quantitative and qualitative comparisons revealed that the ResNet-50 convolutional neural network achieved the best performance with an RMSE of 0.36, while the inverse distance weighting method had the weakest performance with an RMSE of 0.57 during the training stage. Following the evaluation of each method's training quality, their performance was further analyzed through testing scenarios. These evaluations were done according to qualitative and quantitative criteria and on a local scale. Finally, it is concluded that the ResNet-50 convolutional neural networks demonstrate the capability to learn complex spatial and nonlinear relationships within the data while effectively generalizing across different scales, from local to broader field extents. Their performance surpasses that of traditional geometric methods.

REFERENCES

- [1] Bishop, C. M. (1995). *"Neural networks for pattern recognition"*. Clarendon Press, Oxford University Press, Oxford, pp. 482.
- [2] Krizhevsky, A., and Sutskever, I., and Hinton, G. E. (2012). *"ImageNet classification with deep convolutional neural networks"*. In: Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q. (Eds.), *Advances in Neural Information Processing Systems*, Vol. 25, Curran Associates, Inc., Red Hook, NY, 1097-1105.
- [3] Rendu, J. M. (2017). *"Risk Management in Evaluating Mineral Deposits"*. Society for Mining, Metallurgy, and Exploration, Inc., May 22, pp. 320.
- [4] He, K., Zhang, X., Ren, Sh., and Sun, J. (2016). *"Deep Residual Learning for Image Recognition"*. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 770-778. DOI: <https://doi.org/10.1109/CVPR.2016.90>.
- [5] Waterman, G. C., and Hamilton, R. L. (1975). *"The Sar Cheshmeh porphyry copper deposit"*. *Economic Geology*, 70(3): 568-576.



بهبود تخمین سه بعدی عیار مس در گستره کانسار مس سرچشمه با روش های یادگیری عمیق

حامد نوروزی^۱، نادر فتحیانپور^۲*

۱- کارشناسی ارشد، گروه مهندسی معدن، دانشکده مهندسی معدن، دانشگاه صنعتی اصفهان، اصفهان

۲- دانشیار، گروه مهندسی معدن، دانشکده مهندسی معدن، دانشگاه صنعتی اصفهان، اصفهان

پذیرش: ۱۴۰۳/۱۰/۰۲

دریافت: ۱۴۰۳/۰۵/۲۶

چکیده

امروزه کاهش خطای تخمین عیار با استفاده از روش های نوین، نقش تعیین کننده ای در بهینه سازی عملیات معدنکاری و کاهش ریسک عدم موفقیت اقتصادی پروژه های معدنی ایفا می کند. هدف از تحقیق حاضر ارایه روشی برای بهبود تخمین سه بعدی عیار مس در گستره کانسار مس سرچشمه با استفاده از روش های هوشمند یادگیری عمیق و مقایسه با نتایج روش های مرسوم و متداول هندسی است. کانسار مس سرچشمه یکی از بزرگ ترین کانسارهای مس پورفیری و روی کمر بند آتشفشانی ارومیه-دختر در جنوب استان کرمان در ایران مرکزی واقع شده است. در این پژوهش، از ۵۲۶ گمانه در دسترس، حاوی ۳۸۰۰۶ نمونه مغزه عیارسنجی شده برای عیار مس کل استفاده شده است. میانگین عیار مس در نمونه ها برابر با ۰/۵۴ و حداکثر مقدار آن ۳/۴۳ درصد به دست آمده است. قبل از انجام تخمین عیار مس، پیش پردازش هایی شامل اصلاح داده های خارج از ردیف و هم پایه سازی داده ها روی داده ها انجام شد و در نهایت بیضوی ناهمسانگردی عیار مس با استفاده از ماتریس کوواریانس به دست آمد. برای تخمین عیار مس، از دو روش شامل الگوریتم یادگیری عمیق با معماری ResNet-50 و وزن دهی عکس فاصله به عنوان نماینده روش های متداول هندسی استفاده گردید که در نهایت و در مرحله بررسی عملکرد روش های یاد شده از طریق اعتبارسنجی مشخص شد که نتایج الگوریتم ResNet-50 با مقدار RMSE برابر ۰/۴۵ عملکرد بهتری نسبت به روش وزن دهی عکس فاصله با مقدار RMSE برابر ۰/۶ داشته است.

کلمات کلیدی

مدل سازی عیار، شبکه های عصبی، روش های یادگیری عمیق، روش وزن دهی عکس فاصله، تخمین عیار.

استناد به این مقاله

نوروزی، ح.، فتحیانپور، ن.؛ ۱۴۰۴؛ "بهبود تخمین سه بعدی عیار مس در گستره کانسار مس سرچشمه با روش های یادگیری عمیق". نشریه مهندسی منابع معدنی، دوره دهم، شماره ۲، ص ۸۹-۷۱.

DOI: 10.30479/jmre.2025.20784.1712



۱- مقدمه


یکی از مهم‌ترین مراحل ارزیابی کیفیت کانی‌زایی در ذخایر معدنی تخمین عیار کانسار است. از مشکلات مرتبط با این موضوع، تخمین عیار ماده معدنی در هنگام بهره‌برداری در معدن است. غلظت کانه‌زایی در کانسار، وابسته به محل قرارگیری آن‌ها همچنین چینش زمین‌شناسی و ویژگی‌های ساختاری کانسار است [۱]. یادگیری عمیق^۱ یکی از زیرمجموعه‌های یادگیری ماشین^۲ است که در سال‌های اخیر دستاوردهای چشمگیری را در طیف وسیعی از مسایل به دست آورده است. برخلاف دیگر روش‌های یادگیری ماشین، یادگیری عمیق به صورت خودکار از کشف خودکار ویژگی‌ها و الگوهای داده‌ها در مدل‌های با ساختار پیچیده بهره می‌برد [۲]. از کاربردهای یادگیری عمیق در اکتشاف مواد معدنی و معدنکاری می‌توان به مواردی مانند طبقه‌بندی و خوشه‌بندی داده‌های چند متغیره زمین‌شناسی، ژئوفیزیکی و ژئوشیمیایی، رگرسیون و تخمین عیار [۳]، حفاری [۴]، انفجار [۵]، حمل‌ونقل [۶]، خردایش و فرآوری [۷] اشاره کرد. در ادامه مطلب می‌توان به چهار بخش گسترده از برنامه‌هایی اشاره کرد که در موضوعات علوم زمین جهت‌های امیدوارکننده‌ای را برای به کار بردن یادگیری ماشین فراهم کرده‌اند که شامل بارزسازی اشیاء و حوادث، تخمین متغیرهای علوم زمین، پیش‌بینی بلندمدت متغیرهای علوم زمین و استخراج ارتباط بین داده‌های علوم زمین هستند [۸]. چند ویژگی مشترک در داده‌های علوم زمین وجود دارد که باعث می‌شود بتوان از روش‌های مبتنی بر یادگیری ماشین در آن‌ها استفاده کرد. بعضی از این ویژگی‌ها از فرایندهای علوم زمین نشأت می‌گیرند و بعضی دیگر از آن‌ها به دلیل استفاده از روش‌هایی است که در جمع‌آوری داده‌ها از آن‌ها استفاده می‌شود. در ادامه می‌توان به بعضی از این ویژگی‌ها شامل ساختارهای مکانی-زمانی، ناهمگنی فضایی و زمانی، ابعاد زیاد داده‌ها، فقدان تعاریف درست از پدیده‌ها، کمیاب بودن داده، چند منبعی، قدرت تفکیک متفاوت، کیفیت پایین داده‌ها، تعداد ناکافی نمونه‌ها و کمبود داده‌های واقعی زمینی اشاره کرد [۸]. با توجه به اینکه اغلب پدیده‌های زمین‌شناسی در حوزه مکان-زمان رخ می‌دهند و در این حوزه ناهمگونی نیز دارند، بر همین مبنا می‌توان اذعان کرد که تغییرپذیری رفتار این پدیده‌ها معمولاً به صورت غیرخطی و اغلب پیچیده است، بنابراین این ضرورت احساس می‌شود که با توجه به توانایی بالای روش‌های هوشمند در آشکارسازی

رفتارهای پیچیده غیرخطی، از این روش‌ها برای آشکارسازی و شناسایی رفتارهای غیرخطی موجود در پدیده‌های زمین‌شناسی استفاده شود. لازم به ذکر است که داده‌های مورد استفاده در این پژوهش علاوه برداشتن ابعاد بالا، دارای ناهمگونی در بعد مکان-زمان نیز هستند. هدف از انجام این تحقیق، بررسی عملکرد روش‌های مختلف تخمین عیار بلوک‌های معدنی و امکان استفاده از روش برتر در کاهش خطرپذیری عملیات معدنکاری است که خود آن به عوامل متعددی وابسته است. در این پژوهش دو عامل مهم یعنی فرآیند تخمین عیار و روش تخمین عیار ماده معدنی که تاثیر مهمی بر موضوعات اقتصادی و خطرپذیری سرمایه‌گذاری در معادن دارند، مد نظر قرار گرفته‌اند و تحقیقات در راستای کاهش ریسک ناشی از این دو چالش انجام می‌شود. با کاهش خطرپذیری ناشی از این دو عامل می‌توان بخش عمده‌ای از خطرپذیری عملیات معدنکاری را کاهش داد [۹]. به عنوان مثال، کاپاگریدیس و دنبی^۳ [۱۰] از شبکه‌های عصبی مصنوعی برای مدل‌سازی تغییرات فضایی عیار و تخمین عیار ماده معدنی استفاده کردند. نتایج پژوهش انجام شده نشان می‌دهد که از شبکه‌های عصبی می‌توان به عنوان روشی جایگزین برای تخمین عیار ماده معدنی استفاده کرد. پژوهشگران فوق در پژوهشی دیگر از یک شبکه عصبی مدولار نیز برای تخمین عیار استفاده کردند که نتایج برتری نسبی را نسبت به روش کریجینگ معمولی نشان می‌دهد [۱۱]. همچنین، سامانتا^۴ و همکاران [۱۲] پس از استفاده از الگوریتم ژنتیک برای تقسیم داده‌های معدنی به سه قسمت آموزشی، اعتبارسنجی و آزمون، شبکه‌های عصبی پرسپترون چندلایه^۵ و کریجینگ معمولی را در تخمین عیار ماده معدنی مقایسه و نتایج خود را مبنی بر مناسبت‌تر بودن شبکه عصبی نسبت به روش‌های زمین‌آماري، بیان کردند. در یک پژوهش دیگر چترجه^۶ و همکاران [۱۳] از شبکه‌های عصبی MLP و کریجینگ معمولی برای تخمین عیار در یک کانسار سنگ‌آهک استفاده و در نهایت شبکه‌های عصبی را به عنوان روش مناسب معرفی کردند. سامانتا و باندوپادهای [۱۴] از شبکه‌های عصبی با تابع پایه شعاعی برای تخمین عیار مواد معدنی استفاده و قابلیت این شبکه را در تخمین عیار ماده معدنی ارزیابی کردند. این پژوهشگران به مناسب بودن نتایج به دست آمده از این روش در مقابل روش‌های زمین‌آماري دست یافتند. در تحقیقی که توسط بادل و همکاران [۱۵] انجام شد، روش‌های کریجینگ شاخص میانه و شبکه عصبی را در تخمین عیار آهن معدن

جلال آباد شهرستان زرنند مقایسه کردند و برتری کریجینگ شاخص میانه را در تخمین عیار آهن نسبت به شبکه عصبی نشان دادند. در مطالعه ای دیگر که توسط بوکار^۷ و همکاران [۱۶] انجام شد از شبکه های عصبی ساده MLP برای تخمین عیار ماده معدنی استفاده کردند. در تحقیقی دیگر که توسط گسوامی و همکاران [۱۷] انجام گرفت از شبکه عصبی رگرسیون تعمیم یافته با ورودی های متشکل از سه مولفه مختصات جغرافیایی و ۱۰ مولفه مربوط به نوع سنگ های متفاوت برای تخمین عیار استفاده شده است. در این تحقیق، تقسیم بندی داده ها به صورت تصادفی به دو قسمت آموزشی و آزمون صورت گرفت به طوری که خواص داده های آموزش و آزمون، نزدیک به هم باشد. در نهایت، قابلیت تعمیم روش مورد استفاده با شبکه عصبی ساده MLP و کریجینگ معمولی مقایسه شد و پژوهشگران در این تحقیق شبکه عصبی را به عنوان روش مناسب معرفی کردند. در تحقیقی که توسط جفرسته و فتحیانپور [۱۸] برای تخمین عیار گمانه های اکتشافی معدن مس سرچشمه انجام گرفت، با ارایه نتایج حاصل از مقایسه روش های یادگیری ماشین رگرسیون فرآیند گاوسی، شبکه عصبی، روش های زمین آماری کریجینگ معمولی و کریجینگ شاخص نشان دادند که روش فرآیندهای گاوسی، نسبت به سایر روش های دیگر، تخمین بسیار مناسبی در این کانسار داشته است. در پژوهشی دیگر که توسط ملیحه عباس زاده و همکاران [۱۹] و با هدف تخمین عیار مس در معدن مس پورفیری ایجو، واقع در استان کرمان با استفاده از روش یادگیری ماشین انجام شد، قابلیت های هرکدام از روش های شبکه عصبی پرسپترون چندلایه و سیستم ارتباط نرو- فازی تطبیقی به صورت تکی و ترکیبی مورد ارزیابی قرار گرفت و نشان داده شد که ارایه یک مدل ترکیبی عملکرد بهتری دارد. در رابطه با استفاده از شبکه های عصبی کانولوشنی نیز در پژوهشی که توسط نایانگ^۸ و همکاران انجام شد از شبکه عصبی کانولوشنی گوگل نت برای پیش بینی و استخراج ویژگی های مرتبط باکانی زایی کانسار طلا در یک کانسار طلا در منطقه فن ژیان^۹ چین استفاده کردند و توانستند با صحت ۹۳/۱ درصد، به پیش بینی این ویژگی ها اقدام کنند [۲۰]. گمز^{۱۰} و همکاران نیز در ارتباط با تخمین عیار به وسیله مدل های مبتنی بر یادگیری ماشین، توانسته اند با استفاده از مدل های یادگیری فوق العاده^{۱۱} و یادگیری فوق العاده تجمعی^{۱۲} در تخمین عیار کانسارهای طلا عیار بالا به نتایج مطلوبی در

مقایسه با روش کریجینگ دست یابند. این پژوهشگران نشان دادند که نتایج به دست آمده در روش یادگیری فوق العاده تجمعی نسبت به روش یادگیری فوق العاده نیز مطلوب تر است [۲۱]. موسوی و همکاران نیز در پژوهشی که با هدف مقایسه روش های مختلف تخمین و شبیه سازی عیار یک کانسار آهن در مرکز ایران انجام دادند، روش های کریجینگ معمولی و همچنین شبکه عصبی مصنوعی پرسپترون چندلایه را با یکدیگر مقایسه و در نهایت روش شبکه عصبی مصنوعی را به عنوان روش مطلوب این کار پیشنهاد کردند [۲۲]. راهول سینگ^{۱۳} و همکاران نیز با استفاده از یک مدل ترکیبی شامل کریجینگ و شبکه عصبی رگرسیون تعمیم یافته به ارزیابی عیار کانسار آهن در کمربند کانی زایی سینگ بهوم- بونایی^{۱۴} اقدام کردند. این پژوهشگران قبل از معرفی شبکه عصبی رگرسیون تعمیم یافته، به مقایسه و ارزیابی نتایج حاصل از شبکه های عصبی پرسپترون چندلایه، شبکه عصبی پایه شعاعی و همچنین شبکه عصبی بازگشتی نیز اقدام کرده بودند [۲۳]. در پژوهشی دیگر که توسط سعید سلطانی مقدم و همکاران انجام گرفت، از یک روش ترکیبی شامل روش های شبکه عصبی مصنوعی پس انتشار و الگوریتم بهینه سازی ازدحام ذرات برای تخمین عیار اکسید آلومینیم در یکی از کانسارهای بوکسیت ایران استفاده شد. این پژوهشگران از الگوریتم بهینه سازی یاد شده برای بهینه سازی پارامترهای روش تخمین استفاده کردند و سپس نتایج آن را با روش های شبکه عصبی پس انتشار و کریجینگ معمولی مورد مقایسه قرار دادند و در نهایت برتری مدل ترکیبی بر مبنای الگوریتم بهینه سازی ازدحام ذرات و همچنین شبکه عصبی پس انتشار نسبت به دو روش دیگر را نشان دادند [۲۴]. پژوهش دیگری نیز در رابطه با تخمین عیار مس توسط انتشاری باتلیله تسائیه^{۱۵} انجام شد که در این پژوهش از هفت ویژگی شامل مختصات (طول، عرض، عمق)، ویژگی زمین شناسی (آلتراسیون و لیتولوژی) و شیب و آزیموت برای تخمین عیار مس در معدن جگوار^{۱۶} واقع در استرالیا استفاده شد. ارزیابی ها و مقایسه های انجام شده بین روش شبکه عصبی مصنوعی چندلایه و تکنیک های یادگیری ماشین رگرسیون خطی، رگرسیون نزدیکترین همسایگی، رگرسیون درخت تصادفی، ماشین تقویت گرادیان و درخت تصمیم افزایشی انجام و در نهایت مشخص شد که شبکه عصبی پرسپترون عملکرد مناسب تری نسبت به دیگر روش ها داشته است. نتیجه دیگری که پژوهشگران در این پژوهش به آن دست یافتند این بوده است که ویژگی های مربوط به لیتولوژی،


عیار ماده معدنی استفاده شده است که از میان آن‌ها می‌توان به دو روش پردازش‌های گاوسی و شبکه عصبی کانولوشنی به عنوان روش‌های موفق در این بخش نام برد. در تعدادی از پژوهش‌ها، برخی از پژوهشگران به این نتیجه پی برده‌اند که استفاده از یک روش ترکیبی که شامل توانمندی‌های روش‌های زمین‌آمار و هوشمند باشد، قابلیت بهتری را نسبت به استفاده مجزا از هر کدام از روش‌ها ارائه می‌کند. در نهایت و با بررسی کلیه مطالعات قبلی در دسترس می‌توان ادعا کرد که در اغلب پژوهش‌های مرتبط با موضوع تخمین عیار، روش‌های هوشمند عملکرد بهتری را نسبت به روش‌های هندسی و زمین‌آمار داشته‌اند، بنابراین بر اساس نتایج قبلی، در این تحقیق سعی شده است تا عملکرد یک الگوریتم هوشمند از مجموعه روش‌های شبکه‌های عصبی عمیق که برای تخمین عیار ماده معدنی قابلیت بهتری از خود نشان داده‌اند را با روش متداول وزن‌دهی عکس فاصله به عنوان نماینده روش‌های هندسی تخمین عیار، مقایسه و پیشنهاداتی برای به کارگیری آن‌ها در بررسی‌های فنی و اقتصادی کانسارها و کاهش ریسک و عدم قطعیت مطالعات اکتشافی ارائه کرد. در این پژوهش از شبکه‌های عصبی هم‌آمیختگی (کانولوشنی) یک بعدی با هدف استخراج ویژگی از داده‌ها استفاده شده است. از این شبکه‌ها برای استخراج ویژگی روی سیگنال‌های یک بعدی استفاده می‌شود که توانسته‌اند عملکرد قابل قبولی را داشته باشند و در حوزه‌های متفاوتی از پردازش سیگنال مانند کنترل و نظارت بر ضربان قلب، [۲۸]، بارسازی گسل‌ها در پدیده‌های زمین‌شناسی [۲۹]، ارزیابی و پیش‌بینی ساختار پروژه [۳۰] و موارد متعدد دیگری کاربرد داشته باشند. ساختار اصلی شبکه عصبی کانولوشن یک بعدی در شکل ۱ نشان داده شده است.



شکل ۱: معماری شبکه عصبی کانولوشن یک بعدی

بیشترین تاثیر را بر روی نتایج تخمین عیار مس داشته است [۲۵]. در پژوهشی دیگر که توسط زاکي^{۱۷} و همکاران با هدف تخمین عیار طلا انجام شد، نتایج به دست آمده از روش‌های زمین آماری کریجینگ شاخص و کریجینگ معمولی با روش‌های یادگیری ماشین جنگل تصادفی، نزدیکترین همسایگی، رگرسیون فرآیندهای گاوسی، درخت تصمیم، شبکه عصبی تمام متصل مقایسه شدند. در این پژوهش برای بهینه‌سازی وزن‌های تکنیک‌های یادگیری ماشین از الگوریتم بهینه‌سازی شکارچیان دریایی استفاده شد. آنچه در این پژوهش به عنوان روش مناسب عیار طلا ارائه گردید یک روش ترکیبی بر مبنای ادغام دو روش نزدیکترین همسایگی و جنگل تصادفی با الگوریتم بهینه‌سازی شکارچیان دریایی است که عملکرد مناسب‌تری نسبت به روش‌های زمین آماری داشته است. در این پژوهش از داده‌های مربوط به مختصات گمانه‌ها و همچنین نوع سنگ به عنوان داده ورودی استفاده شد [۲۶]. اخیراً نیز پژوهشی با هدف مقایسه عملکرد روش‌های مبتنی بر یادگیری عمیق، یادگیری ماشین و همچنین روش‌های متداول زمین آماری تخمین در ایجاد نقشه‌های دوبعدی عیار پتاسیم توسط باتل گزی^{۱۸} و همکاران صورت گرفته است که در آن نتایج حاصل از پنج روش رگرسیون بردار پشتیبان، شبکه عصبی پرسپترون چندلایه، کریجینگ ساده، نزدیکترین همسایگی و شبکه عصبی کانولوشنی با یکدیگر مقایسه شدند و در نهایت روش شبکه عصبی کانولوشنی به عنوان روش مناسب و دارای عملکرد بهتر نسبت به دیگر روش‌ها معرفی شد [۲۷]. با بررسی روند پژوهش‌های انجام شده می‌توان نتیجه گرفت که اغلب پژوهشگران در ابتدا از روش شبکه‌های عصبی پرسپترون چندلایه به عنوان یک روش هوشمند برای تخمین عیار استفاده کردند. در ادامه با مشخص شدن توانایی‌های روش توابع پایه شعاعی در آشکارسازی رفتار غیرخطی داده‌ها، این روش نیز مورد استفاده پژوهشگران قرار گرفته است، اما استقبال چندانی از آن نشده است و به نظر می‌رسد که با توجه به عملکرد خوب تکنیک پس انتشار خطا در تخمین عیار، این روش توانسته است که مورد استقبال پژوهشگران قرار بگیرد. از جمله شبکه‌های عصبی دیگری که توسط پژوهشگران مورد بررسی قرار گرفته‌اند می‌توان به شبکه‌های عصبی رگرسیون عمومی و ماشین بردار پشتیبان اشاره کرد. در ادامه با توجه به توانایی‌های بالای روش‌های یادگیری ماشین و یادگیری عمیق در بارسازی رفتار غیرخطی داده‌ها، از این روش در تخمین

از داده‌های آزمون، عملکرد آن‌ها مورد ارزیابی قرار گرفت. در شکل ۲ به فرآیندهای مورد استفاده در مدلسازی فضایی عیار اشاره شده است. برای بهینه‌سازی روش‌های یادگیری عمیق، توابع فعال‌سازی و همچنین الگوریتم‌های بهینه‌سازی مختلفی بررسی شدند و سپس بهینه‌ترین آن‌ها انتخاب شد. عملکرد روش‌ها نیز با استفاده از تابع هدف RMSE مورد ارزیابی قرار گرفت. در پایان کار و پس از تخمین داده‌های عیار مس بر روی شبکه سه بعدی ساخته شده، نتایج هرکدام از آن‌ها با توجه به معیارهای خطا، بررسی و اعتبارسنجی و روش مناسب نیز معرفی شد. بر مبنای نتایج به دست آمده می‌توان گفت که بهترین عملکرد مربوط به شبکه عصبی کانولوشنی ResNet-50 و ضعیف‌ترین عملکرد نیز مربوط به روش وزن‌دهی عکس فاصله است.



شکل ۲: فرآیند در نظر گرفته شده در مدلسازی فضایی عیار

روش پیاده‌سازی معماری شبکه عصبی کانولوشن یک بعدی روی داده‌ها به این صورت است که داده‌ها به عنوان ورودی و در قالب سیگنال یک بعدی وارد شبکه شده و پس از آن کرنل کانولوشنی بر روی آنها اعمال می‌شود و ویژگی‌های مهم آنها را استخراج و وارد لایه بعدی می‌کند. کانولوشن یک بعدی در قالب رابطه ۱ بر روی داده‌ها اعمال می‌شود.

$$y_j^I = f(b_j^I + \sum_{i \in M_j} \text{conv1D}(w_{ij}^{I-1}, x_i^{I-1})) \quad (1)$$

که در آن:

y_j^I : خروجی نورون j در لایه I

تابع $f(*)$: یک تابع غیرخطی

b_j^I : نیز عدد بایاس نورون j در لایه I

x_i^{I-1} : ماتریس خروجی نورون i در لایه $I-1$

w_{ij}^{I-1} : ماتریس وزن‌های نورون i به j در لایه $I-1$ [۳۱]

۲- روش‌شناسی پژوهش

در این پژوهش فرض بر این است که تغییرپذیری اکثر پدیده‌های زمین‌شناسی به صورت غیرخطی و پیچیده و چند منشایی است و روش‌های هوشمند نیز توانایی بالایی در آشکارسازی این رفتارهای پیچیده غیرخطی دارند، بنابراین شناسایی این رفتارها مستلزم استفاده از روش‌های مبتنی بر اطلاعات داده و یا روش‌های هوشمند است. نحوه انجام کار در این پژوهش به این صورت است که در ابتدا بخشی از داده‌ها که مربوط به گمانه‌های افقی می‌باشند و با هدف بررسی‌های ژئوتکنیکی حفر شده بودند حذف شدند و سپس بر مبنای تجزیه و تحلیل اطلاعات آماری داده‌ها، این داده‌ها روی طول مناسب کامپوزیت شدند. در ادامه و با هدف جلوگیری از همگرایی کاذب تخمین عیار مس، داده‌های پرت به وسیله روش دورفل اصلاح شدند. برای اعمال فرضیات روش‌های مورد استفاده در تخمین، داده‌ها با استفاده از روش تبدیل امتیازی به نرمال، نرمال شدند و برای آن‌ها نیز یک شبکه سه بعدی در نظر گرفته شد تا با استفاده از آن، افق‌های مختلف تخمین زده شوند. ناهمسانگردی داده‌های عیار مس نیز با استفاده از ماتریس کوواریانس آنها محاسبه و سپس از اطلاعات آن در تخمین عیار استفاده شد. با هدف مقایسه هرچه بهتر توانایی هرکدام از روش‌ها، داده‌های اصلی به سه گروه آموزش، اعتبارسنجی و آزمون تقسیم شدند که با استفاده از داده‌های آموزش، روش‌های مختلف آموزش دیدند و سپس با استفاده

۳- روش‌های متداول مورد استفاده در تخمین عیار

در مدل‌سازی فضایی ویژگی‌های کانسارها، چون اطلاعات نسبت به مجهولات محدود هستند، از تخمین‌گرها استفاده می‌شود. این تخمین‌گرها بر مبنای معیارهای مختلفی تقسیم‌بندی شده‌اند. یکی از این معیارها، تقسیم‌بندی آنها بر مبنای روش‌های زمین آماری و غیر زمین آماری است. بر همین مبنای تخمین‌گرها را می‌توان به دو گروه تخمین‌گرهای غیر زمین آماری و زمین آماری (جدول ۱) تقسیم‌بندی کرد. برای هر کدام از این دو نوع نیز معیارهای متفاوتی برای تقسیم‌بندی وجود دارد.

از میان روش‌های یاد شده، یک روش به عنوان نماینده روش‌های غیر زمین آماری برای تخمین‌گرها انتخاب شده است که شامل روش وزن‌دهی عکس فاصله به عنوان نماینده روش‌های هندسی است. معیار دیگری برای تقسیم‌بندی تخمین‌گرها وجود دارد که آن‌ها را بر مبنای هوشمند بودن و غیرهوشمند بودن تقسیم‌بندی می‌کند که از میان روش‌های هوشمند می‌توان به روش‌های مبتنی بر یادگیری عمیق اشاره کرد. در ادامه، تئوری روش‌های مورد استفاده برای تخمین عیار مس ارائه می‌شود.

۳-۱- روش وزن‌دهی عکس فاصله

این روش یکی از روش‌های درون‌یابی هندسی است که در آن وزن‌های تخمین بر اساس عکس فاصله نقاط شرکت‌کننده در تخمین نسبت به مرکز بلوک مورد تخمین، تعیین می‌شود. در این روش واریوگرام استفاده نمی‌شود و تاثیر مقادیر در تخمین یک بلوک با افزایش فاصله، کم می‌شود. در این روش، تخمین با استفاده از رابطه ۲ اعمال می‌شود:

$$Z_i = \sum_{j=1}^n \lambda_{i,j} Z_j / \sum_{j=1}^n \lambda_{i,j} \quad (2)$$

که در آن:

$\lambda_{i,j}$: فاصله دونقطه از یکدیگر

Z_i : مقدار نقطه معلوم


تخمین‌گرهای هندسی توانایی شناسایی ساختارهای حاکم بر محیط تخمین را ندارند و به همین دلیل، کمتر در مدل‌سازی ساختارهای پیچیده استفاده می‌شوند [۳۳].

۳-۲- شبکه عصبی کانولوشنی ResNet


حوزه یادگیری ماشین طی سال‌های اخیر و با ظهور شبکه‌های عصبی مصنوعی پیچیدگی‌های قابل‌توجهی پیدا کرده است. این معماری‌های هوش مصنوعی به مراتب از معماری‌های قبلی خود در حل مسایل یادگیری ماشین عملکرد بهتری داشته‌اند. یکی از تاثیرگذارترین آن‌ها، معماری شبکه‌های عصبی کانولوشنی است [۳۴]. شبکه عصبی کانولوشنی ResNet توسط شرکت ماکروسافت معرفی گردید و توانست در چالش ILSVRC در سال ۲۰۱۵ با دقت ۹۶ درصد، مقام اول را کسب کند. کلمه ResNet مخفف کلمه Residual Network است [۳۵]. این معماری توانست مشکل آموزش شبکه‌های عمیق را با استفاده از ساختار باقیمانده (شکل ۳) حل کند. این ساختار باقیمانده اصطلاحاً به بلوک باقیمانده معروف است که کار اصلی آن اتصال ورودی‌های اصلی به خروجی لایه بعد است. با این کار حتماً می‌توان اطمینان حاصل کرد که لایه بعدی، چیز جدیدتری نسبت به لایه قبلی برای یادگیری دارد، زیرا با استفاده از این بلوک می‌توان اطمینان حاصل کرد که خود داده‌های لایه قبلی نیز به همراه خروجی لایه جدید در یادگیری شرکت می‌کنند. در این شبکه ارتباطاتی خارج از ساختار کانولوشنالی وجود دارد که در بین لایه‌ها در نظر گرفته شده است تا در مرحله

جدول ۱: برخی از تخمین‌گرهای متداول مورد استفاده [۳۲]

روش‌های زمین آماری		روش‌های غیر زمین آماری	
تک متغیره	چند متغیره	نزدیکترین همسایه	اسپیلان ها و سطوح روند محلی
کریجینگ ساده	کریجینگ عام	شبکه نامنظم مثلثی	درونیابی
کریجینگ معمولی	کریجینگ ساده با میانگین محلی متفاوت	همسایه طبیعی	درخت رگرسیون
کریجینگ بلوکی	کریجینگ با میل خارجی	وزندهی عکس فاصله	سری فوریه
کریجینگ فاکتوریل	کو کریجینگ ساده	مدل های رگرسیون	نرخ کاهش
کریجینگ دوگانه	کو کریجینگ معمولی	آنالیز روند سطحی	
کریجینگ شاخص	کو کریجینگ معمولی استاندارد	اسپیلان صفحه ای دو بعدی	
کریجینگ منفصل	کریجینگ مولفه های اصلی		



شکل ۳: ساختار بلوک باقیمانده در شبکه کانولوشنی ResNet [۳۷]



شکل ۴: نقشه زمین‌شناسی کانسار مس سرچشمه در افق ۲۴۰۰ متر [۳۷]


۴-۱- معرفی داده‌ها

مجموعه داده‌ها شامل ۵۲۶ گمانه هستند که مجموع طول حفاری آن‌ها برابر با ۱۱۳۹۷۰/۳۶ متر است. میانگین شیب حفاری در این داده‌ها برابر با ۷۶/۳ درجه و کمترین و بیشترین شیب حفاری به ترتیب برابر با ۴۴ و ۹۰ درجه است. تعداد


پس انتشار خطا، خطای هر لایه را به لایه قبلی انتقال دهد تا بتوان شبکه را عمیق‌تر کرد و آن را سریع‌تر آموزش داد. در این معماری، چالش محوشدگی گرادیان و یا انفجار گرادیان با قرار دادن لایه هنجارساز دسته‌ای حل شده است. مشکل کاهش بوده است که در این معماری حل شده است، مشکل کاهش بوده است که در شبکه‌های عمیق با افزایش تعداد لایه‌ها و به اشباع رفتن شبکه رخ می‌دهد. اشباع شبکه عصبی زمانی اتفاق می‌افتد که نورون‌ها مقادیری نزدیک به حداکثر محدوده تابع فعالسازی را خروجی می‌دهند. این مشکل از طریق اصلاحاتی که در معماری شبکه صورت گرفته است حل شده است [۳۶]. در این پژوهش از مدل شبکه ResNet-50 استفاده شده است، عدد ۵۰ نشان‌دهنده عمق لایه‌های این معماری است، بنابراین می‌توان گفت که معماری ResNet-50 جزو شبکه‌های بسیار عمیق محسوب می‌شود.

۴- محدوده مورد مطالعه

معدن مس سرچشمه در استان کرمان و در پنجاه کیلومتری جنوب شهرستان رفسنجان واقع شده و یکی از مهم‌ترین معادن ایران است. این معدن تقریباً در موقعیت جغرافیایی ۵۶ درجه طول شرقی و ۳۰ درجه عرض جغرافیایی واقع شده است. از دیدگاه زمین‌شناسی ایران، محدوده مورد بررسی در بین دو پهنه سندانج- سیرجان و ایران مرکزی واقع شده است. به عبارت دیگر این محدوده بر روی کمربند آتشفشانی ارومیه- دختر واقع شده است. ذخیره این معدن متشکل از یک ترکیب رسوبی و آتشفشانی است. ناحیه کانی‌سازی در این کانسار به صورت کلی شامل سه بخش اصلی توده استوک سرچشمه پورفیری، توده آندزیتی و دایک‌های اولیه است. دایک‌های ثانویه در این کانسار، فاقد کانی‌زایی هستند. عامل اصلی کانی‌زایی در این کانسار، استوک پورفیری سرچشمه است که نام آن به صورت محلی انتخاب شده است و ترکیب اصلی آن گرانودیوریت است. استوک سرچشمه پورفیری پس از نفوذ به مرکز منطقه و توف‌های آندزیتی توانسته است گستره‌ای به وسعت دو کیلومتر مربع را تحت دگرسانی و همچنین کانی‌زایی قرار دهد. از لحاظ واحدهای سنگی، این کانسار شامل سنگ‌های آندزیت، گرانودیوریت، کوارتز چشمی، استوک سرچشمه پورفیری و پورفیری دانه‌ریز تاخیری است (شکل ۴). شکل ۴ نشان‌دهنده نقشه زمین‌شناسی معدن مس سرچشمه در افق عمقی ۲۴۰۰ متر نسبت به سطح دریا است [۳۸].



شکل ۵: جانمایی گمانه‌های مورد بررسی در معدن مس سرچشمه



شکل ۶: هیستوگرام فراوانی عیار مس

ورودی استفاده شده است. در حالی که برای روش شبکه عصبی کانولوشنی ResNet-50 از هفت متغیر یاد شده استفاده شده است.

۴-۳- تقسیم‌بندی داده‌ها

با هدف مقایسه هرچه بهتر روش‌های مورد استفاده در این پژوهش، داده‌های اصلی به سه گروه داده‌های آزمون، آموزش و اعتبارسنجی تقسیم شدند و ۷۰ درصد از آن‌ها به عنوان داده آموزش، ۱۵ درصد به عنوان داده اعتبارسنجی و ۱۵ درصد به عنوان داده آزمون در نظر گرفته شدند [۳۹]. برای تقسیم‌بندی داده‌ها از روش نمونه‌برداری تصادفی میان لایه‌ای استفاده شد. با استفاده از این روش ضمن حفظ تصادفی بودن نمونه‌برداری داده‌ها برای تقسیم‌بندی آن‌ها، حداکثر تلاش برای تعمیم ویژگی‌های آماری داده‌های اصلی به فضای داده‌های اعتبارسنجی و آزمون نیز صورت می‌گیرد.

کل نمونه‌ها برابر با ۳۸۰۰۶ نمونه است که همگی آن‌ها آنالیز عیارسنجی دارند. میانگین عیار مس در این داده‌ها برابر با ۰/۵۶ و حداکثر آن نیز برابر با ۳/۴ درصد است. میانگین فاصله بین دو گمانه که در همسایگی همدیگر قرار دارند برابر با ۵۰ متر است (شکل ۵).

داده‌های مورد استفاده در این پژوهش شامل هفت متغیر اصلی هستند که سه مورد آن مربوط به موقعیت مکانی (طول، عرض، عمق) هر نمونه است. چهارمین متغیر نیز نشان‌دهنده عیار مولیبدن است که همبستگی ۵۰ درصدی با عیار مس دارد. پنجمین ویژگی معرف نوع آلتراسیون و ششمین متغیر نیز معرف نوع سنگ است. هفتمین متغیر نیز عیار مس است که به عنوان متغیر هدف مورد استفاده قرار می‌گیرد. از این متغیرها برای تخمین عیار مس در فضای کانسار استفاده می‌شود. متغیر هدف همان مقدار عیار مس کل (مس سولفیدی + مس اکسید) است. از بین این هفت متغیر، پنج متغیر طول، عرض، عمق، عیار مس و عیار مولیبدن به صورت کمی ضبط شده‌اند، اما دو متغیر دیگر یعنی آلتراسیون و نوع سنگ به صورت کیفی هستند که قبل از استفاده از آن‌ها در روش‌های هوشمند، با تبدیل مقادیر معلوم به عدد ۱ و مقادیر مجهول به عدد صفر به مقادیر کمی تبدیل شده‌اند. توزیع مقادیر عیار مس نشان می‌دهد که این داده‌ها چولگی شدید مثبت دارند (شکل ۶). مقدار بالای ضریب تغییرات $\sigma/\bar{X} = 1.091$ (انحراف از معیار $\bar{X}$: میانگین) نشان می‌دهد که مقادیر شدیدی در داده‌ها وجود دارد.

در بیشترین مکان‌های نمونه‌برداری شده، مقدار مس نسبتاً کم است و فقط مکان‌های کمی دارای مقدار زیادی مس هستند. نسبت زیاد ماکزیمم به میانگین $X_{\max}/\bar{X} = 6.1$ بدین معنی است که برای به دست آوردن پیش‌بینی‌های قابل‌اعتماد لازم است تا مناطق با غلظت کم و زیاد، با دقت بالا مدل‌سازی شوند. این مشکل به شدت بر عملکرد برخی از روش‌های پیش‌بینی کننده تاثیر می‌گذارد.

۴-۲- داده‌های مورد استفاده در روش‌های مختلف تخمین

هرکدام از روش‌های مورد استفاده بنابر محدودیت‌ها و فرضیاتی که دارند، مقادیر مختلفی از داده‌ها را به عنوان ورودی می‌پذیرند. بیشترین محدودیت مربوط به روش‌های وزن‌دهی عکس فاصله هستند. برای روش وزن‌دهی عکس فاصله از متغیر طول، عرض، عمق و عیار مس به عنوان متغیر

۴-۴- پیش پردازش داده ها و پارامترهای تخمین

برای شناسایی و ارزیابی خصوصیات رفتاری داده های مورد استفاده در این پژوهش، پیش پردازش هایی شامل حذف گمانه های افقی که با مقاصد ژئوتکنیکی حفر شده بودند، اصلاح داده های خارج از ردیف، نرمال سازی داده ها (به دلیل امکان استفاده از روش های زمین آماری با داده های ورودی یکسان)، یکپارچه سازی داده ها، شبکه بندی سه بعدی، و شناسایی بیضوی ناهمسانگردی برای عیار مس، بر روی داده ها صورت گرفت. طول بهینه برای کامپوزیت سازی برابر با سه متر در نظر گرفته شد. برای اصلاح داده های خارج از ردیف نیز از روش دورفل استفاده شده است. بر مبنای این روش تعداد ۳۹۵ داده به عنوان داده خارج از ردیف شناسایی شدند و سپس برای شناسایی حد آستانه داده های خارج از ردیف، در ابتدا میانگین و انحراف از معیار داده ها به دست آمد و سپس بر مبنای تعداد نمونه ها و نمودار معرفی شده برای روش دورفل، حد آستانه آن برابر با ۴/۲ در نظر گرفته شد (جدول ۲).

بر مبنای نتایج به دست آمده تمامی داده های بالاتر از مقدار ۳/۴۲ به عنوان داده پرت شناسایی شدند و سپس مقدار آن ها با مقدار ۰/۷۵ بزرگترین داده بدون در نظر گرفتن داده های پرت جایگزین شد. برای نرمال سازی داده ها نیز از روش تبدیل امتیازی به نرمال استفاده شده است (شکل ۷). معیارها و روش های متفاوتی برای نرمال کردن داده های مورد استفاده در این پژوهش وجود دارد. در همه این روش ها و با هر مبنایی، داده ها به گونه ای نرمال می شوند که شرط های مورد انتظار محقق شوند. بدین منظور برای نرمال سازی از روش تبدیل امتیازی به نرمال استفاده شده است.


با هدف درونیابی در بین داده های مورد استفاده و جداسازی افق های خاص، شبکه ای سه بعدی بر روی داده ها ایجاد شد. اگر پیش پردازش بر روی داده ها اعمال نشود، ممکن است به شدت بر روی همگرایی الگوریتم محاسبات اثر بگذارد. از این رو معمولاً قبل از اعمال مدل به شبکه عصبی، نرمال سازی بر روی داده ها انجام می شود. در این پژوهش نرمال سازی از طریق کم شدن مقدار داده ($\bar{X}$) از کمینه داده ها و سپس تقسیم بر تفاضل بیشینه داده و کمینه آن ها، انجام می شود.

$$Z = \frac{X - \text{Min}(x)}{\text{Max}(x) - \text{Min}(x)} \quad (3)$$

شبکه عصبی مورد استفاده در این پژوهش، با استفاده از الگوریتم پس انتشار خطا آموزش دیده است. برای دستیابی

جدول ۲: مقادیر به دست آمده برای روش دورفل


۰/۵۷۸۴۲۱۹۶۲	$\bar{x}$
۰/۶۸۳۲۹۲۸۹۶	S
۴/۲	g
۳/۴۴۸۲۵۲۱۲۵	$\bar{x} + (g \times s)$
۳/۴۳۹۴	حد آستانه بزرگترین داده
۳/۴۳۹۴	بزرگترین داده
۲/۵۷۹۵۵	بزرگترین داده




شکل ۷: هیستوگرام فراوانی توزیع عیار مس پس از نرمال کردن داده ها

به مقدار کمینه تابع هدف تعداد نوروها برابر با ۲۰۱۶ در نظر گرفته شده است. در این پژوهش از تابع فعال سازی^{۱۹} غیرخطی ReLU^{20} استفاده شده است، غیرخطی بودن تابع فعال سازی باعث می شود که مدل راحت تر بتواند به داده ها تطبیق داده شود و خاصیت تعمیم پذیری بهتری داشته باشد. علاوه بر استفاده از تابع ReLU ، از سه تابع فعال سازی دیگر یعنی ELU^{21} ، تانژانت هذلولی و سیگموئید نیز استفاده شده است که در نهایت مشخص شد که تابع ReLU عملکرد بهتری را نسبت به دیگر توابع فعال سازی دارد. تابع هدف از دیگر پارامترهای استفاده شده است. تابع هدف ابزاری برای بررسی عملکرد یک شبکه است که باید آن را به حداقل رساند. در این پژوهش از تابع هدف جذر خطای حداقل مربعات (RMSE) به عنوان معیاری برای بررسی عملکرد شبکه استفاده شده است. این تابع معمول ترین شکل تابع هدف در مسایل رگرسیون غیرخطی است.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^N [y^{(n)} - O^{(n)}]^2} \quad (4)$$



شکل ۸: واریوگرافی جهتی در جهت زوایای بیضوی ناهمسانگردی



شکل ۹: واریوگرافی جهتی در جهت زوایای مشخص شده

جدول ۳: خطای روش‌های مورد استفاده در تخمین برای داده‌های آموزش و آزمون

روش	آموزش RMSE	آزمون RMSE
ResNet-50	۰٫۳	۰٫۴۵
IDW	۰٫۵۷	۰٫۶

فاصله با مقدار RMSE برابر با ۰٫۵۷ دارای بیشترین خطا بوده است، بنابراین می‌توان گفت که در مرحله آموزش در بین همه روش‌های مورد استفاده در تخمین عیار مس، معماری ResNet-50 با کمترین میزان خطا بهترین عملکرد و روش وزن‌دهی عکس فاصله با بیشترین مقدار خطا ضعیف‌ترین عملکرد را داشته است (شکل‌های ۱۰ و ۱۱). برای داده‌های آزمون نیز بررسی‌های کمی انجام و مشخص شد که روی ResNet-50 با RMSE برابر با ۰٫۴۵ دارای کمترین مقدار خطا و روش وزن‌دهی عکس فاصله با RMSE برابر با ۰٫۶ دارای بیشترین خطا بوده است. به عنوان نتیجه کلی می‌توان

که در آن:

N : تعداد داده‌های مورد بررسی

$y^{(n)}$: مقادیر تخمین زده شده


$O^{(n)}$: مقادیر مشاهده شده است.

با حداقل‌سازی تابع هدف می‌توان وزن‌ها و دیگر پارامترهای شبکه را محاسبه کرد. اگر فرض کنیم که خطا توزیع گوسی داشته باشد، حداقل‌سازی RMSE با حداقل‌سازی تابع درست‌نمایی برابر است.


در این پژوهش از الگوریتم SGDM^{۲۲} به عنوان الگوریتم بهینه‌سازی استفاده شده است. گرادین کاهشی تصادفی، روشی مبتنی بر تکرار برای بهینه‌سازی یک تابع مشتق‌پذیر به نام تابع هدف است که یک تقریب تصادفی از روش گرادین کاهشی است. هنگامی که ویژگی تکانه به عنوان یکی از روش‌های زیرمجموعه این روش استفاده می‌شود، مسیر انتخاب پارامتر در حال جستجو خیلی تغییر نمی‌کند و نوسانات شدید وجود نخواهد داشت [۳۷]. با هدف درونیابی در بین داده‌های مورد استفاده و جداسازی افق‌های خاص و تعیین شده، یک شبکه سه‌بعدی با ابعاد ۱۲×۱۲×۶ متر ایجاد شد. برای تعیین ناهمسانگردی‌های احتمالی در کل محدوده کانسار از روش مولفه‌های اصلی استفاده گردید. در ابتدا با استفاده از روش مولفه‌های اصلی جهت‌های ناهمسانگردی را مشخص کرده و سپس با استفاده از واریوگرافی جهتی در جهت زوایای مشخص شده، شعاع تأثیر هر کدام از جهات ناهمسانگردی مشخص شدند. در شکل ۸ واریوگرام‌های رسم شده در جهت محورهای بزرگ، متوسط و کوچک ناهمسانگردی عیار مس و در شکل ۹ واریوگرام‌های جهتی در جهت‌های مشخص شده در شکل ترسیم شده‌اند.

۵- مقایسه عملکرد روش‌های مورد استفاده در تخمین

برای بررسی و مقایسه عملکرد هر کدام از روش‌های مورد استفاده در تخمین در فرآیند آموزش و آزمون شبکه بر روی داده‌های مربوط به هر فرآیند، بررسی‌هایی در مقیاس محلی انجام و سپس نتایج آن‌ها به صورت کمی و کیفی ارزیابی شد. در جدول ۳، نتایج محاسبه خطا برای داده‌های آموزش و آزمون مورد استفاده در روش‌های تخمین آورده شده است. با بررسی‌های صورت گرفته مشخص شد که در مرحله آموزش، روش ResNet-50 با مقدار RMSE برابر با ۰٫۳ دارای کمترین خطا به عنوان روش مبتنی بر شبکه‌های عصبی کانولوشنی است. در بین روش‌های هندسی نیز، روش وزن‌دهی عکس




شکل ۱۲: نتایج ارزیابی کیفی عملکرد شبکه روی داده های آزمون
برای روش ResNet-50




شکل ۱۳: نتایج ارزیابی کیفی عملکرد شبکه روی داده های آزمون
برای روش وزن دهی عکس فاصله

RMSE مربوط به هر روش استفاده شد. معیار اول یعنی ضریب تشخیص رگرسیون، با علامت R^2 در معادلات رگرسیون مشخص می شود. این ضریب نشان دهنده مقدار همبستگی میان دو دسته و معرف کیفیت تخمین مقادیر عیار مس در هر روش است. در این پژوهش بجای گزارش مقدار این ضریب، بجای استفاده از R^2 از جذر آن یعنی R استفاده شده است. این عدد مقداری بین صفر و ۱ دارد. هرچه مقدار R به عدد ۱ نزدیک تر باشد، نشان دهنده عملکرد بهتر آن روش در تخمین عیار مس است. بر مبنای این معیار می توان گفت که روش ResNet-50 با مقدار ضریب تعیین برابر با ۰/۸۱ دارای بهترین عملکرد و روش، وزن دهی عکس فاصله با ضریب تعیین ۰/۴۸ دارای ضعیف ترین عملکرد بوده است. بر مبنای معیار دوم، یعنی میزان RMSE برای مقادیر تخمین زده شده، می توان



شکل ۱۰: نتایج ارزیابی کیفی عملکرد شبکه روی داده های آموزش
برای روش ResNet-50



شکل ۱۱: نتایج ارزیابی کیفی عملکرد شبکه روی داده های آموزش
برای روش وزن دهی عکس فاصله

گفت که در هر مرحله آموزش و آزمون بهترین عملکرد مربوط به روش ResNet-50 و ضعیف ترین عملکرد مربوط به روش وزن دهی عکس فاصله است (شکل های ۱۲ و ۱۳).


۵-۱- اعتبارسنجی متقابل

برای بررسی هر کدام از روش ها در تخمین عیار مس، عملکرد هر کدام از آن ها با استفاده از اعتبار سنجی متقابل ارزیابی شد. در این روش، داده های آزمون که به وسیله روش های مختلف تخمین زده شدند، در مقابل مقادیر اصلی خودشان قرار می گیرند و سپس با استفاده از روش رگرسیون خطی، میزان همبستگی بین این دو گروه داده سنجیده می شود (شکل های ۱۴ و ۱۵). این نتایج در جدول ۴ ارایه شده اند. برای مقایسه نتایج اعتبارسنجی متقابل روش های تخمین، از دو معیار ضریب تشخیص رگرسیون و همچنین میزان


۵-۲- خطای باقیمانده

یکی دیگر از معیارهای کنترل و ارزیابی عملکرد روش‌ها در تخمین عیار مس، خطای باقیمانده روش‌ها است. خطای باقیمانده از تفاضل مقدار واقعی عیار مس با مقدار تخمین زده شده، به وسیله هر روش به دست می‌آید. با در نظر گرفتن این معیار و سپس ترسیم هیستوگرام خطای باقیمانده هر کدام از روش‌ها و بررسی سه ویژگی میزان تقارن، میزان کشیدگی و مقدار انحراف از معیار می‌توان نتیجه گرفت که بهترین عملکرد مربوط به ResNet-50 و ضعیف‌ترین عملکرد مربوط به وزن‌دهی عکس فاصله است (جدول‌های ۵ و ۶ و شکل‌های ۱۶ و ۱۷).

روش ResNet-50 با چولگی برابر با ۱/۲- دارای متقارن‌ترین حالت و با مقدار کشیدگی برابر با ۸/۲ دارای




شکل ۱۶: هیستوگرام خطای باقیمانده برای روش رزنت-۵۰




شکل ۱۷: هیستوگرام خطای باقیمانده برای روش وزن‌دهی عکس فاصله

گفت که کمترین RMSE یعنی مقدار ۰/۳۶ مربوط به روش ResNet-50 و بیشترین مقدار آن یعنی ۰/۵۵ مربوط به روش وزن‌دهی عکس فاصله است. بر مبنای نتایج اعتبارسنجی نیز، می‌توان گفت که بهترین عملکرد مربوط به روش ResNet-50 و ضعیف‌ترین عملکرد مربوط به روش وزن‌دهی عکس فاصله است.



شکل ۱۴: اعتبارسنجی متقابل برای روش شبکه عصبی کانولوشنی ResNet-50



شکل ۱۵: اعتبارسنجی متقابل برای روش وزن‌دهی عکس فاصله

جدول شماره ۴: اطلاعات آماری به همراه میزان خطای محاسبه شده برای روش‌های مختلف تخمین در اعتبارسنجی متقابل





روش تخمین	Min	Max	Mean	STD	RMSE
ResNet-50	۰	۲/۲۶	۰/۵۵	۰/۵۲	۰/۳۶
IDW	۰	۲/۹۶	۰/۵۱	۰/۴۱	۰/۵۵

جدول ۵: مشخصات آماری خطای باقیمانده برای روش‌های تخمین

روش تخمین	Min	Max	Range	Skew
ResNet-50	-۲٫۶	۲	۴٫۷	-۱٫۲
IDW	-۳٫۳	۲٫۷	۶٫۰۳	-۱٫۱

جدول ۶: مشخصات آماری خطای باقیمانده برای روش‌های تخمین

روش تخمین	Mean	Median	STD	Kurt
ResNet-50	-۰٫۰۰۶	۰٫۰۲	۰٫۳۶	۸٫۲
IDW	-۰٫۰۴	۰٫۰۱	۰٫۵۵	۹



شکل ۱۸: الف) نقشه تغییرات عیار مس برای روش رزنت-۵۰، ب) نقشه تغییرات عیار مس برای روش وزن‌دهی عکس فاصله، ج) نقشه زمین‌شناسی کانسار مس سرچشمه در افق ۲۴۰۰ متر، د) نقشه تغییرات عیار مس در کانسار مس سرچشمه در افق ۲۴۰۰ متر

این افق به این دلیل بوده است که واحد پورفیری دانه‌ریز تاخیری، بیشترین حجم از توده سنگی آن را شامل می‌شود و کانی‌زایی بیشتری دارد، بنابراین روند تغییرات عیار در بخش‌های مختلف این افق، بهتر از دیگر افق‌ها بارزسازی می‌شود. ارزیابی‌های مربوط به این بخش به صورت کیفی هستند و از نقشه زمین‌شناسی معدن مس سرچشمه، به عنوان راهنمای کنترل و ارزیابی نتایج استفاده شده است. نتایج

کشیده‌ترین حالت و با مقدار انحراف از معیار ۰٫۳۶ دارای کمترین مقدار انحراف از معیار است.

۵-۳- نقشه تغییرات عیار

برای ارزیابی کیفی تخمین‌های انجام شده به وسیله روش‌های مختلف، نقشه تغییرات عیار مس برای افق ارتفاعی ۲۴۶۰ متری کانسار، ترسیم شد (شکل ۱۸). مبنای انتخاب

مربوط به این بخش با در نظر گرفتن توانایی هر کدام از روش‌ها در چهار بخش تخمین مناطق دارای عیار، بارزسازی مناطق فاقد عیار، بارزسازی هندسه کلی کانسار و بارزسازی دایک‌های فاقد عیار ارزیابی شدند. بر مبنای نقشه زمین‌شناسی، سه گروه دایک‌های فلدسپار پورفیری، بیوتیت پورفیری و همچنین هورنبلند پورفیری که فاقد کانی‌زایی هستند، یک‌روند شمال و شمال غرب به سمت جنوب و جنوب شرق دارند. وجود این دایک‌های غیرکانی‌ساز باعث ایجاد شکستگی‌هایی در قسمت اصلی واحد سنگی کانی‌ساز یعنی استوک سرچشمه پورفیری شده است و همین عامل معیاری برای کنترل بهتر نتایج است. بر مبنای این معیار، شبکه‌های عصبی کانولوشنی ResNet-50 عملکرد مناسب‌تری را نسبت به روش وزن‌دهی عکس فاصله در بارزسازی مشخصات یاد شده و روند دایک‌ها داشته است.

۶- نتیجه‌گیری

با هدف بررسی و ارزیابی عملکرد روش‌های مورد استفاده در تخمین عیار مس در این تحقیق، در مرحله آموزش عملکرد شبکه‌های عمیق کانولوشنی مبتنی بر ساختار باقیمانده‌ها به عنوان یکی از کارآمدترین معماری‌های شبکه‌های عصبی عمیق، ارزیابی شد. این بررسی‌ها در مقیاس محلی انجام شد و مربوط به رفتار هر روش در فضای کل کانسار نیست. بر طبق مقایسه کمی و کیفی صورت گرفته می‌توان گفت که روش شبکه عصبی کانولوشنی ResNet-50 با مقدار RMSE برابر با ۰/۳۶ بهترین عملکرد و روش وزن‌دهی عکس فاصله با RMSE برابر با ۰/۵۷ ضعیف‌ترین عملکرد در مرحله آموزش شبکه را دارد. پس از ارزیابی کیفیت آموزش هر کدام از روش‌ها، عملکرد آن‌ها روی داده‌های آزمون نیز ارزیابی و بررسی شد. این ارزیابی‌ها نیز با توجه به معیارهای کیفی و کمی و در مقیاس محلی صورت گرفت. در اعتبارسنجی متقابل، با در نظر گرفتن دو معیار ضریب تعیین رگرسیون و جذر میانگین مربعات می‌توان گفت که روش شبکه عصبی کانولوشنی ResNet-50 در بین سایر روش‌های مبتنی بر ساختار باقیمانده‌ها عملکرد بهتری داشته است. با در نظر گرفتن خطای باقیمانده به عنوان یکی از معیارهای مهم برای تحلیل و ارزیابی نتایج و بررسی سه معیار تقارن، چولگی و انحراف از معیار و تحلیل اطلاعات آماری خطای باقیمانده، این نتیجه به دست می‌آید که روش شبکه عصبی کانولوشنی ResNet-50 بهترین عملکرد در بین همه روش‌ها را داشته است و ضعیف‌ترین عملکرد نیز

مربوط به روش‌های وزن‌دهی عکس فاصله است. یکی دیگر از معیارهایی که می‌توان بر مبنای آن نتایج حاصل از روش‌های مختلف تخمین را بررسی کرد، تعداد و نوع متغیرهای ورودی برای هر روش است. با توجه به اینکه بیشترین محدودیت از لحاظ تعداد داده ورودی مربوط به روش وزن‌دهی عکس فاصله است، بنابراین ضعیف‌ترین نتیجه مربوط به این روش بوده است. روش‌های شبکه عصبی کانولوشنی با توجه به اینکه کمترین محدودیت را نسبت به تعداد، نوع و تئوری محاسبات داشته‌اند، عملکرد بهتری را از خود نشان داده‌اند. از مزیت‌های دیگر شبکه عصبی کانولوشنی که می‌توان به آن اشاره کرد عدم در نظر گرفتن روابط فاصله‌ای و تمرکز آنها بر مدل‌سازی روابط غیرخطی حاکم در داده‌ها در مرحله آموزش شبکه است، بنابراین این شبکه‌ها زمانی می‌توانند عملکرد بهتری در فرآیند تخمین عیار مس داشته باشند که دقت و اعتبار بالایی را در مرحله آموزش از خود نشان دهند. تغییرات لیتولوژی، آلتراسیون و ساختار گسترش کانی‌زایی و در نتیجه تغییرات پیچیده عیار در گستره سه بعدی کانسار، نقش و تاثیر مهمی در فرآیند یادگیری شبکه‌های عصبی دارند. در روش‌های هندسی نیز برخی از پارامترهای تخمین مانند حداقل و حداکثر تعداد نقاط شرکت‌کننده در تخمین، بیضوی ناهمسانگردی عیار، بیضوی جستجو و واریوگرام نقش مهمی در بهبود نتایج دارند و باید بهینه‌ترین حالت آن‌ها اعمال شود. در خاتمه، نتیجه می‌شود که شبکه‌های عصبی کانولوشنی ResNet-50 علاوه بر قابلیت یادگیری روابط پیچیده فاصله‌ای و غیرخطی بین داده‌ها، قدرت تعمیم در مقیاس‌های مختلف از محلی تا گستره کلی کانسار را داشته و عملکرد آن‌ها از روش‌های هندسی بهتر است.

۷- مراجع

- [1] Bishop, C. M. (1995). "Neural networks for pattern recognition". Oxford University Press, Oxford, pp. 482.
- [2] Krizhevsky, A., and Sutskever, I., and Hinton, G. E. (2012). "ImageNet classification with deep convolutional neural networks". In: Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q. (Eds.), Advances in Neural Information Processing Systems, Vol. 25, Curran Associates, Inc., Red Hook, NY, 1097-1105.
- [3] Xiong, Y., and Zuo, R. (2016). "Recognition of geochemical anomalies using a deep autoencoder network". Computers & Geosciences, 86: 75-82.

- [14] Samanta, B., and Bandopadhyay, S. (2009). "Construction of a radial basis function network using an evolutionary algorithm for grade estimation in a placer gold deposit". *Computers & Geosciences*, 35(8): 1592-1602.
- [15] Badel, M., Angorani, S., and Panahi, M. Shariat, (2011). "The application of median indicator Kriging and neural network in modeling mixed population in an iron ore deposit". *Computers & Geosciences*, 37(4): 530-540.
- [16] Abu Bakarr, J., Sasaki, K., Yaguba, J., and Abubakarr Karim, B. (2016). "Integration artificial neural network and geostatistics for optimum 3D geological block modeling in mineral reserve estimation: A case study". *International Journal of Mining Science and Technology*, 26(4): 581-585.
- [17] Goswami, A., Mishra, M., and Patra, D. (2017). "Investigation of general regression neural network architecture for grade estimation of an indian iron ore deposit". *Arabian Journal Geosciences*, 10(4): 80.
- [18] Jafrasteh, B., Fathianpour, N., and Suarez, A. (2018). "Comparison of machine learning methods for copper ore grade estimation". *Computational Geosciences*, 22(5): 1371-1383.
- [19] Abbaszadeh, M. (2021). "The copper grade estimation of porphyry deposits using machine learning algorithms and Henry gas solubility optimization". *Earth Science Informatics*, 14: 2049-2075.
- [20] Yang, N. (2021). "A Convolutional Neural Network of GoogLeNet Applied in Mineral Prospectivity Prediction Based on Multi-source Geoinformation". *Natural Resources Research*, 30: 3905-3923.
- [21] Erdogan Erten, G. (2021). "Grade estimation by a machine learning model using coordinate rotations". *Applied Earth Science*, 130: 57-61.
- [22] Mousavi, J., Shayestehfar, M., and Moarefvand, P. (2022). "Comparison of Various Estimation and Simulation Methods for Orebody Grade Variations Modeling". *Journal of Mining Science*, 58: 163-172.
- [23] Singh, R., Ray, D., and Sarkar, B. (2022). "Mineral deposit grade assessment using a hybrid model of kriging and generalized regression neural network". *Neural Computing and Applications*, 34: 10611-10627.
- [24] Soltani-Mohammadi, S., Hoseinian, F., Abbaszadeh, M., and Khodadadzadeh, M. (2022). "Grade estimation using a hybrid method of back-propagation artificial neural network and particle swarm optimization with integrated samples coordinate and local variability". *Computers and Geosciences*, 159: 104981.
- [4] He, M., Zhang, Z., Ren, J., Huan, J., Li, G., Chen, Y., and Li, N. (2019). "Deep convolutional neural network for fast determination of the rock strength parameters using drilling data". *International Journal of Rock Mechanics and Mining Sciences*, 123: 104084.
- [5] Guo, H., Zhou, J., Koopialipoor, M., Jahed Armaghani, D., and Tahir, M. M. (2019). "Deep neural network and whale optimization algorithm to assess flyrock induced by blasting". *Engineering with Computers*, 37: 173-186. DOI: <https://doi.org/10.1007/s00366-019-00816-y>.
- [6] Pradip, Gautham, B. P., Reddy, S., and Runkana, V. (2019). "Future of mining, mineral processing and metal extraction industry". *Transactions of the Indian Institute of Metals*, 72: 2159-2177. DOI: <https://doi.org/10.1007/s12666-019-01790-1>.
- [7] Wei, J., Guo, L., Xu, X., and Yan, G. (2015). "Soft sensor modeling of mill level based on convolutional neural network". *The 27th Chinese Control and Decision Conference, CCDC*, 23-25 May 2015, 4738-4743.
- [8] Karpatne, A., Ebert-Uphoff, I., Ravela, S., Babaie, H. A., and Kumar, V. (2018). "Machine learning for the geosciences: challenges and Opportunities". In: *IEEE Transactions on Knowledge and Data Engineering*, 31(8): 1544-1554. DOI: <https://doi.org/10.1109/TKDE.2018.2861006>.
- [9] Rendu, J. M. (2017). "Risk Management in Evaluating Mineral Deposits". *Society for Mining, Metallurgy, and Exploration, Inc.*, pp. 320.
- [10] Kapageridis, I. K., and Denby, B. (1998). "Neural network modelling of ore grade spatial variability". In: *Niklasson, L., Bodén, M., and Ziemke, T. (Eds.), ICANN 98. ICANN 1998. Perspectives in Neural Computing*. Springer, London. DOI: https://doi.org/10.1007/978-1-4471-1599-1_28.
- [11] Kapageridis, I. K., and Denby, B. (1998). "Ore grade estimation with modular neural network systems, A case study, *Information Technology in the Mineral Industry*". In: *Panagiotou, G. (Ed.), Information technology in the minerals industry (MineIT' 97)*. AA Balkema, Rotterdam.
- [12] Samanta, B., Bandopadhyay, S., and Ganguli, R. (2002). "Data segmentation and genetic algorithms for sparse data division in nome placer gold grade estimation using neural network and geostatistics". *Exploration and Mining Geology*, 11(1-4): 69-76. DOI: <https://doi.org/10.2113/11.1-4.69>.
- [13] Chatterjee, S., Bhattacharjee, A., Samanta, B., and Pal, S. K. (2006). "Ore grade estimation of a limestone deposit in india using an artificial neural network". *Applied GIS*, 2(1): 3.1-3.20.

- [36] Waterman, G. C., and Hamilton, R. L. (1975). "The Sar Cheshmeh porphyry copper deposit". *Economic Geology*, 70(3): 568-576.
- [37] Rohit, M. (2021). "ResNet-Understand and Implement from scratch". *Economic Geology*, 70: 568-576.
- [38] Murphy, K. P. (2012). "Machine Learning: A Probabilistic Perspective". The MIT Press, Cambridge, Massachusetts, pp. 1104.
- [39] Olivier, L. E., Maritz, M. G., and Craig, I. k. (2020). "Estimating Ore Particle Size Distribution using a Deep Convolutional Neural Network". *IFAC-PapersOnLine*, 53(2): 12038-12043.
- [25] Batlile, T. N. (2023). "Application of Artificial Neural Network for the Prediction of Copper Ore Grade". *Minerals*, 13: 628.
- [26] Zaki, M. M., Chen, S., Zhang, J., Feng, F., Khoreshok, A. A., Mahdy, M. A., and Salim, K. M. (2023). "A Novel Approach for Resource Estimation of Highly Skewed Gold Using Machine Learning Algorithms". *Minerals*, 12(7): 900. DOI: <https://doi.org/10.3390/min12070900>.
- [27] Battalgazy, N., Valenta, R., Gow, P., Spier, C., and Forbes, G. (2023). "Addressing Geological Challenges in Mineral Resource Estimation: A Comparative Study of Deep Learning and Traditional Techniques". *Minerals*, 13: 982.
- [28] Kiranyaz, S., Zabihi, M., Bahrami Rad, A., Ince, T., Hamila, R., and Gabbouj, M. (2020). "Real-time phonocardiogram anomaly detection by adaptive 1D Convolutional Neural Networks". *Neurocomputing*, 411: 291-301.
- [29] Li, Y., Zou, L., Jiang, L., and Zhou, X. (2019). "Fault Diagnosis of Rotating Machinery Based on Combination of Deep Belief Network and One-dimensional Convolutional Neural Network". *IEEE*, 7: 165710-165723.
- [30] Zhong, Y. (2021). "Risk Assessment and Prediction of Construction Project Based on 1D-CNN-Attention-BP". *World Journal of Engineering and Technology*, 9: 861-876.
- [31] Jana, G., Sharma, R., and Agrawal, A. (2020). "A 1D-CNN-Spectrogram Based Approach for Seizure Detection from EEG Signal". *Procedia Computer Science*, 167: 403-412.
- [32] Li, J., and Heap, A. D. (2008). "A review of Spatial Interpolation Methods for Environmental Scientists". *Geoscience Australia, Record 2008/23*, pp. 137.
- [33] Hassanipak, A. A., and Sharafodin, M. (2004). "GET: a function for Prefetional site selection borehole drilling". *Exploration and Mining Geology*, 13(1-4): 139-146.
- [34] O'Shea, K., and Nash, R. (2015). "An Introduction to Convolutional Neural Networks". *arXiv*. DOI: <https://doi.org/10.48550/arXiv.1511.08458>.
- [35] He, K., Zhang, X., Ren, Sh., and Sun, J. (2016). "Deep Residual Learning for Image Recognition". 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 770-778. DOI: <https://doi.org/10.1109/CVPR.2016.90>.

¹ Deep Learning² Machine Learning³ Kapageridis and Deny⁴ Samantha⁵ Multi-Layer Perceptron⁶ Chatterjee⁷ Baker⁸ Na Yang⁹ Feng Xian¹⁰ Gamze Erdogan Erten¹¹ Super learner¹² Ensemble super learner¹³ Rahoul Singh¹⁴ Singhbhum region¹⁵ Ntshiri Batlile Tsae¹⁶ Jaguar mine¹⁷ Mohamed M. Zaki¹⁸ Nurassyl Battalgazy¹⁹ Activation function²⁰ Rectified linear unit activation²¹ Exponential linear unit²² Stochastic Gradient Descent with Momentum