



Imam Khomeini International University  
Vol. 9, No. 3, Autumn 2024



نشریه مهندسی منابع معدنی  
Journal of Mineral Resources Engineering  
(JMRE)

## Research Paper

# Converting Drone Magnetic Data to Ground Data Using Artificial Intelligence

Kianpour F.<sup>1</sup>, Alimoradi A.<sup>2</sup>, Shahsavani H.<sup>3\*</sup>

1- M.Sc, Dept. of Mining Engineering, Faculty of Technical & Engineering, Imam Khomeini International University, Qazvin, Iran

2- Assistant Professor, Dept. of Mining Engineering, Faculty of Technical & Engineering, Imam Khomeini International University, Qazvin, Iran

3- Associate Professor, Dept. of Mining, Faculty of Engineering, University of Kurdistan, Sanandaj, Iran

Received: 09 Jul. 2023

Accepted: 11 Dec. 2023

**Abstract:** Mineral exploration necessitates a comprehensive approach that involves analyzing various geophysical, geological, and geochemical datasets, in addition to employing efficient and effective methodologies. Successfully addressing this challenge involves integrating and analyzing diverse geographic data, which often come in different formats and possess distinct features, with the aid of innovative applications. One promising technique involves utilizing artificial intelligence to convert low-resolution drone-collected data into high-resolution ground data. For this particular investigation, three supervised regression models—linear regression, random forest, and enhanced gradient—were implemented in the Python programming environment using magnetometric data obtained from both UAV and Proton ground devices. After evaluating the statistical results, including metrics such as mean square error and mean absolute error, it was determined that the enhanced gradient model outperformed the others. This model exhibited respective values of 0.0004 and 0.01 for training data, 0.001 and 0.02 for experimental data, and 0.001 and 0.01 for validation data. Additionally, the enhanced gradient model demonstrated stability, leading to its selection as the preferred model for prediction purposes.

**Keywords:** Airborne geophysics, Magnetometric, Drone, Artificial intelligence.

### How to cite this article

Kianpour, F., Alimoradi, A., and Shahsavani, H. (2024). "Converting drone magnetic data to ground data using artificial intelligence". Journal of Mineral Resources Engineering, 9(3): 41-59.

DOI: [10.30479/JMRE.2024.19020.1651](https://doi.org/10.30479/JMRE.2024.19020.1651)

\*Corresponding Author Email: [h.shahsavani@uok.ac.ir](mailto:h.shahsavani@uok.ac.ir)

COPYRIGHTS



©2024 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

Exploration of mineral reserves at ground level poses a significant challenge as direct evidence is often lacking. The identification of these reserves and mineralizations is crucial, given the diverse properties of mineral resources and the complex geological conditions in which they are found [1]. Several techniques have been developed to address this challenge, including geology, geochemical exploration, geophysical exploration, and remote sensing [2]. Among these techniques, magnetic data plays a prominent role in geophysics. Magnetic data can be collected using both ground-based methods, which offer high resolution but are costly, and aerial methods, which provide lower resolution but are more cost-effective. Among the aerial methods, drones have emerged as a preferred choice due to their ability to operate at lower altitudes, resulting in improved accuracy. To achieve optimal results in magnetic exploration while minimizing time and costs, there is a need for an optimal method that bridges the gap between these approaches. In this context, the use of artificial intelligence and a diverse range of algorithms can offer a promising solution, enabling the utilization of magnetic data in a more efficient and accurate manner. Artificial neural networks (ANNs) present an advantage over traditional experimental and statistical methods, as they do not require prior knowledge about the underlying relationship between the data [3]. This makes ANNs particularly well-suited for modelling complex and often nonlinear data, which exhibit significant variability due to their inherent nature. By leveraging the power of ANNs, it becomes possible to develop a new method that can effectively analyze magnetic data, reduce processing time, and provide data with minimal errors.

In 2017, Stephen Cohn et al. conducted a study on Australian Eastern gold mines, where they successfully utilized random forests applied to geophysical data (magnetic and radiometric) and remote sensing to map lithological features. This study demonstrated the effectiveness of random forest in classifying magnetic data [4]. In 2019, Jinfeng Lee et al. focused on air electromagnetic studies and employed four deep convolutional neural networks to analyze the collected parameters. Through the application of artificial and aerial data, this algorithm not only generated accurate depth images but also exhibited robustness to noise [5]. In 2020, John Stephen Kayude and Yusri Yusup utilized a combined Python and Matlab framework in a study conducted in Nigeria. They applied artificial intelligence and data mining techniques to determine, identify, and map the subsurface structure and desired properties of target minerals in the study area [6]. These examples highlight the successful utilization of artificial neural networks in analyzing earth science data. However, previous studies have primarily focused on processing and interpreting the resulting data, emphasizing the need for improved accuracy and cost-effectiveness in the earlier stages.

The objective of this study is to develop a suitable method that leverages artificial intelligence to combine the advantages of both ground and aerial methods. The aim is to achieve high accuracy while minimizing the time, costs, life risks, and coverage limitations associated with traditional approaches. The proposed method should optimize the point-to-point equivalence of the two methods—air and ground—and streamline the necessary processes. The data obtained through this approach can then be further analyzed and interpreted, ensuring more reliable and expedited results compared to existing methods.

## METHODS


The objective of the algorithm in this study is to establish the relationship between the input and output data through the artificial intelligence network. By training the network on the available input-output pairs, it can learn the underlying patterns and associations in the data. Once the relationship is discovered, the trained network can be used to predict the output for new input data. Given the nature of the problem, it is necessary to select algorithms that are capable of performing prediction or regression tasks. Since both the input and output values are specified, the algorithm selection should focus on regression algorithms that can accurately estimate the relationship between the variables.

In this study, three regression algorithms were employed: linear regression, random forest, and gradient boosting. These algorithms were evaluated based on their statistical performance across the training, testing, and validation datasets. The algorithm that demonstrated the best statistical results in terms of accuracy and error metrics across these sections would be considered the superior algorithm for predicting the desired values.

## FINDINGS AND ARGUMENT

After collecting and correcting the data obtained from both the UAV and the proton, the magnetic field

intensity maps were generated using Geosoft software (Figures 1A and 1B). The initial dataset consisted of 442 points from the proton and 31,382 points from the UAV. To ensure data quality, points within a three-meter range were filtered out, resulting in 129 remaining points (Figure 1C). The longitude, latitude, and air magnetic field intensity were considered as the input data, while the ground magnetism served as the target or output data.



**Figure 1.** **A:** map of intensity of the magnetic field of earth’s harvest data, **B:** aerial with harvest profile and **C:** map of ground and air adaptation points and the intensity of the magnetic field resulting from these points

To train and evaluate the network, approximately 10% of the data (13 points) were randomly set aside as validation data, while the remaining 116 points were split into 80% training data and 20% testing data. The three models (linear regression, random forest, and gradient boosting) were assessed for their performance. Although all models performed well, linear regression showed weaker performance compared to the other two models. Random forest and gradient boosting demonstrated better results, with gradient boosting being selected as the superior algorithm (Table 1). The stability of the gradient boosting network was also evaluated by analyzing the error range and standard deviation, which indicated that the network was stable (Table 2).

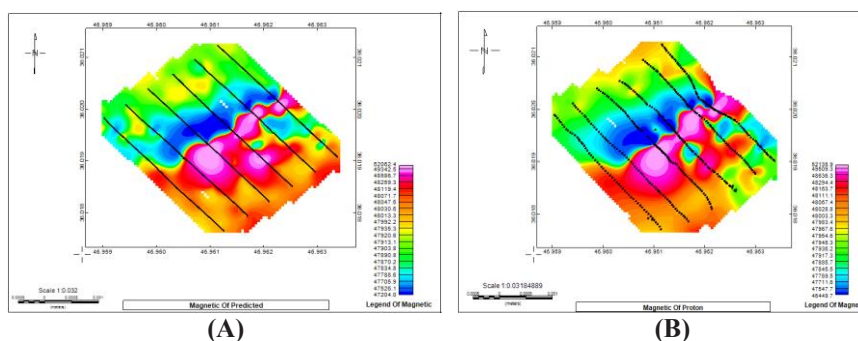
**Table 1.** The results of the statistical components of the three models implemented in three stages of training, testing, and validation

Model		Mean absolute error	Mean squared error	Median absolute error	Explain variance score	R2 score	Root mean squared error
Random Forest	Train	0.009915782	0.000548293	0.002260187	0.965535858	0.965266866	0.023415661
	Test	0.026276936	0.001992696	0.014750688	0.845481272	0.840042657	0.044639627
	Validation	0.030589285	0.003562773	0.004164696	0.777435639	0.742619828	0.059688967
Liner Regression	Train	0.02549339	0.002157063	0.012479316	0.863354905	0.863354905	0.046444196
	Test	0.035233822	0.003296804	0.019957522	0.738483457	0.735359586	0.0574178
	Validation	0.035782305	0.003635427	0.015244726	0.746539572	0.737371167	0.060294504
Gradient Boosting	Train	0.012999734	0.000406561	0.007611715	0.974245252	0.974245252	0.020163368
	Test	0.025387113	0.001233268	0.015777321	0.901472653	0.901003333	0.035117917
	Validation	0.019955882	0.001226281	0.009685084	0.932825116	0.911411546	0.035018302

**Table 2.** Statistical results of the Gradient Boosting Network Stability Test

	Minimum	Maximum	Average	Standard deviation
Train	0.009605411	0.023519841	0.018394747	0.002349633
Test	0.014355825	0.178974683	0.048994088	0.032010111
Validation	0.017289743	0.138338533	0.04521458	0.029094517

In the final step, the complete set of aerial data (31,382 points) was input into the gradient boosting network for prediction, resulting in the generation of predicted output data. These predicted data were then transformed into a magnetic intensity map using Geosoft software and compared with the magnetic intensity map obtained from the proton. The comparison revealed a high degree of agreement in terms of the location, intensity, and shape of the magnetic anomalies in both maps (Figure 2).



**Figure 2. A:** map of intensity of magnetic field of earth harvest data with harvest profile and **B:** magnetic square intensity map of development of gradient boosting network with harvest profile

## CONCLUSIONS

In the current era, the rising costs and challenges associated with discovering new mineral resources have necessitated the development of improved approaches to mineral exploration. Artificial intelligence has emerged as a promising solution for solving problems that lack specific mathematical relationships and where causation is not clearly defined. In this study, magnetic data collected by a drone-connected sensor were processed using Python programming to convert the data into ground data. The resulting magnetic intensity map was then compared to the map obtained from ground data collected by a proton magnetometer in Geosoft software. To ensure data quality, a filtering process was applied to the aerial and ground data, removing points that were less than 3 meters apart. This filtering reduced the dataset to 129 data points. A validation dataset comprising 10% of the total data was randomly selected, while the remaining data was split into 80% for training and 20% for testing. Three models—linear regression, random forest, and gradient boosting—were evaluated for their performance in converting the aerial data to ground data. Among these models, gradient boosting demonstrated superior statistical criteria compared to the other two models and was therefore chosen as the optimal model for projecting and forecasting the aerial data. The gradient boosting model exhibited an average squared error of 0.0004 and an average absolute error of 0.01 in the training data. In the testing data, the corresponding values were 0.01 and 0.02, respectively. For the validation data, the model achieved an average squared error of 0.01 and an average absolute error of 0.01. Stability tests confirmed the reliability of the gradient boosting model, as indicated by low fluctuations in root mean square error (RMSE) values and a low standard deviation across the training, testing, and validation data. Finally, the complete set of aerial data was converted to ground data using the gradient boosting model. The resulting ground data was compared to the proton data as a magnetic intensity map, demonstrating the accuracy and efficacy of the selected regression approach. Both maps exhibited high similarity, affirming the accuracy of the conversion process.

## REFERENCES

- [1] Bahri, E., Alimoradi, A., and Yousefi, M. (2021). "Mineral Potential Modeling of Porphyry Copper Deposits using Continuously-Weighted Spatial Evidence Layers and Union Score Integration Method". *Journal of Mining and Environment (JME)*, 12(3): 743-751. (In Persian)
- [2] Alimoradi, A., Maleki, B., Karimi, A., Sahafzadeh, M., and Abbasi, S. (2020). "Integrating Geophysical Attributes with New Cuckoo Search Machine Learning Algorithm to Estimate Silver Grade Values—Case Study: Zarshouran Gold Mine". *Journal of Mining and Environment*, 11(3): 865-879. (In Persian)
- [3] Fathi, M., Alimoradi, A., and Hemati Ahoori, H. (2021). "Optimizing Extreme Learning Machine Algorithm using Particle

- Swarm Optimization to Estimate Iron Ore Grade*". Journal of Mining and Environment (JME), 12(2): 397-411. (In Persian)
- [4] Kuhn, S., Cracknell, M. J., and Reading, A. J. (2017). "*Lithologic mapping using Random Forests applied to geophysical and remote-sensing data: A demonstration study from the Eastern Goldfields of Australia.*" Geophysics, 83(4): 183-193.
- [5] Li, J., Liu, Y., Yin, C., Ren, X., and Yang, S. (2019). "*Fast imaging of time-domain airborne EM data using deep learning technology*". Geophysics, 85(5): 1942-2156.
- [6] Kayode, J. S., and Yusup, Y. (2020). "*A novel fusion Python application of data mining techniques to evaluate airborne magnetic datasets*". Journal of arXiv: Signal Processing, pp. 13. DOI: <https://doi.org/10.48550/arXiv.2006.07236>.



دوره نهم، شماره ۳، پاییز ۱۴۰۳، صفحه ۴۶ تا ۵۹  
Vol. 9, No. 3, Autumn 2024, pp. 46-59



نشریه مهندسی منابع معدنی  
Journal of Mineral Resources Engineering  
(JMRE)

علمی-پژوهشی

## تبدیل داده‌های مغناطیس‌سنجی پهپادی به داده‌های زمینی با استفاده از هوش مصنوعی

فرانک کیان پور<sup>۱</sup>، اندیشه علیمرادی<sup>۲</sup>، هاشم شاهسونی<sup>۳\*</sup>

- ۱- کارشناسی ارشد، گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین
- ۲- استادیار، گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین
- ۳- دانشیار، گروه مهندسی معدن، دانشکده مهندسی، دانشگاه کردستان، سنندج، کردستان

پذیرش: ۱۴۰۲/۰۹/۱۲

دریافت: ۱۴۰۲/۰۹/۱۲

### چکیده

اکتشاف مواد معدنی یک کار چند رشته‌ای است که نیاز به توجه همزمان از مجموعه داده‌های ژئوفیزیک، زمین‌شناسی و ژئوشیمیایی متفاوت به انضمام روش‌های کارآمد و موثر جدید دارد. این مساله به ادغام موثر و تجزیه و تحلیل داده‌های مختلف جغرافیایی با فرمت‌ها و ویژگی‌های مختلف با کمک برنامه‌های کاربردی جدید نیاز دارد. داده‌هایی که با استفاده از پهپاد (داده‌های با تفکیک پذیری پایین) برداشت می‌شوند، قابلیت تبدیل شدن به داده‌های زمینی (تفکیک‌پذیری بالا) با استفاده از روش‌های جدیدی مانند هوش مصنوعی را دارند. در این مطالعه با استفاده از داده‌های مغناطیس‌سنجی برداشت شده به وسیله پهپاد و دستگاه زمینی پروتون در محیط برنامه‌نویسی پایتون، سه مدل رگرسیون نظارت شده اجرا شده است. این سه مدل، شامل رگرسیون خطی، جنگل تصادفی و گرادیان تقویت شده است که در نهایت گرادیان تقویت شده با توجه به نتایج آماری بهتر شامل میانگین خطای مربع و میانگین خطای مطلق در داده‌های آموزشی به ترتیب ۰/۰۱ و ۰/۰۰۰۴ و در داده‌های آزمایشی به ترتیب ۰/۰۰۱ و ۰/۰۰۲ و در داده‌های اعتبارسنجی به ترتیب ۰/۰۰۱ و ۰/۰۱ و همچنین به علت پایدار بودن شبکه به عنوان مدل مورد استفاده برای پیش‌بینی انتخاب شد.

### کلمات کلیدی

ژئوفیزیک هوایی، مغناطیس‌سنجی، پهپاد، هوش مصنوعی.

### استناد به این مقاله

کیان پور، ف.، علیمرادی، ا.، شاهسونی، ه.؛ ۱۴۰۳؛ "تبدیل داده‌های مغناطیس‌سنجی پهپادی به داده‌های زمینی با استفاده از هوش مصنوعی".  
نشریه مهندسی منابع معدنی، دوره نهم، شماره ۳، ص ۴۱-۵۹.

DOI: 10.30479/JMRE.2024.19020.1651



حق مؤلف © نویسندگان

ناشر: دانشگاه بین‌المللی امام خمینی (ره)

نویسنده مسئول و عهده دار مکاتبات Email: [h.shahsavani@uok.ac.ir](mailto:h.shahsavani@uok.ac.ir)

## ۱- مقدمه

بین داده‌ها نیست، بنابراین این روش به خوبی برای مدل‌سازی رفتار پیچیده و غالباً غیرخطی داده‌های علوم زمین که طبق ماهیت اغلب تنوع زیادی از خود نشان می‌دهند، مناسب است. در سال ۲۰۱۷ استغفان کوهن و همکاران در یک مطالعه اثباتی از معادن طلای شرقی استرالیا برای نقشه‌برداری لیتولوژیک از طبقه‌بندی جنگل‌های تصادفی اعمال شده به داده‌های ژئوفیزیک (مغناطیس‌سنجی و رادیومتریک) و سنجش از راه دور استفاده کردند. این روش عملکرد مناسب جنگل تصادفی را در طبقه‌بندی داده‌های مغناطیس‌سنجی نشان می‌دهد [۶]. در سال ۲۰۱۹ جینگ فنگ لی و همکاران در یک بررسی بر روی الکترومغناطیس‌سنجی در حوزه زمان، از چهار شبکه عصبی عمیق کانولوشن برای به روزرسانی پارامترها استفاده کردند. این الگوریتم پس از اعمال بر روی داده‌های مصنوعی و داده‌هایی هوایی، نشان داد که نه تنها موجب تولید عکس‌های عمقی سودمند می‌شود، بلکه به نوبه‌ها نیز حساسیت زیادی ندارد [۷]. در سال ۲۰۲۰ جان استفن کایود و یوسری یوسپ در یک مطالعه در نیجریه یک برنامه کاربردی جدید ترکیبی پایتون و متلب را به کار گرفتند که از تکنیک‌های داده‌کاوی در هوش مصنوعی برای تعیین، شناسایی و ترسیم الگوی ساختاری زیر سطح از سنگ‌های منبع برای ویژگی‌های مورد نظر در منطقه مورد مطالعه استفاده می‌کرد. تکنیک‌های ابزار یادگیری ماشین به تعریف سنگ منبع ناهنجاری مغناطیسی و عمق‌های مختلف این ویژگی‌های سنگ منبع زیرسطحی کمک کرد [۸]. این موارد نمونه‌هایی از کاربرد موفق شبکه‌های عصبی مصنوعی در داده‌های علوم زمین هستند، اما در مطالعات یاد شده مشخص شد که در گذشته بیشتر بر روی نحوه پردازش و تفسیر داده‌های حاصله تمرکز شده است، بنابراین در مرحله قبل‌تر، به دست آوردن داده‌هایی با بیش‌ترین تفکیک‌پذیری و کمترین هزینه و در کمترین زمان امری ضروری است. در این بررسی هدف به دست آوردن یک روش مناسب با کمک هوش مصنوعی است تا بتوان به کمک آن مزیت‌های دو روش زمینی و هوایی را با هم یکجا به دست آورد و داده‌های با تفکیک‌پذیری بالا و در عین حال با زمان برداشت کم، هزینه پایین‌تر، خطرات جانی کمتر و منطقه تحت پوشش بیشتر به دست آورد. این روش باید بتواند حداقل معادل‌سازی نقطه به نقطه را در دو روش هوایی به زمینی انجام داده و پردازش‌های لازم را انجام دهد. در مراحل بعدی می‌توان داده‌های آماده شده را برای بررسی‌ها و تفاسیر مورد نیاز به کار برد و اطمینان

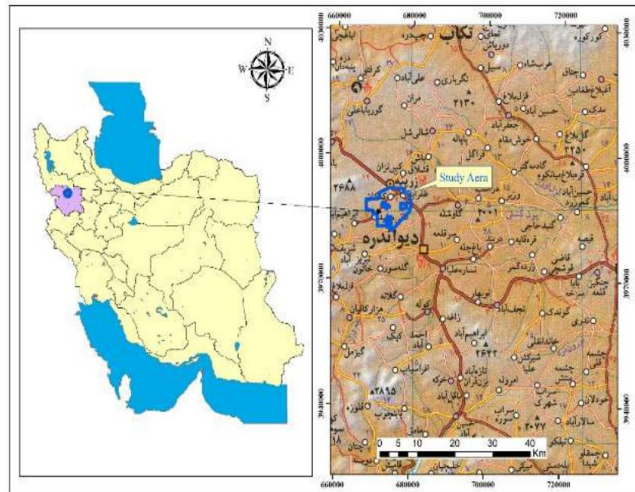
با توجه به اینکه بسیاری از ذخایر معدنی در سطح زمین، شواهد مستقیم قابل مشاهده‌ای از خود نشان نمی‌دهند، بنابراین شناسایی محل تجمع این ذخایر و کانی‌سازی‌ها از چالش‌های اکتشاف است [۱]. برای این کار، برخی از تکنیک‌ها با توجه به تنوع منابع معدنی و خصوصیات آنها و تنوع شرایط طبیعی حاکم در محیط‌های پیچیده زمین‌شناسی توسعه یافته است. این تکنیک‌ها شامل زمین‌شناسی، اکتشاف ژئوشیمیایی، اکتشاف ژئوفیزیکی و سنجش از دور هستند [۲]. همچنین روش‌های اکتشافی به دسته‌های مستقیم و غیرمستقیم تقسیم می‌شوند. در میان این‌ها، روش‌های ژئوفیزیکی غیرمستقیم در مقایسه با روش‌های مستقیم از لحاظ زمان و هزینه مقرون به صرفه‌تر هستند [۳]. داده‌های مغناطیس‌سنجی از داده‌های بسیار پرکاربرد در ژئوفیزیک محسوب می‌شوند. از این داده‌ها می‌توان در اکتشافات مختلف اعم از معادن فلزی، نفت و گاز، مطالعات ساختاری و نظایر آن استفاده کرد [۴]. برداشت داده‌های مغناطیس‌سنجی به دو صورت زمینی و هوایی (هواپیما و بالگرد) صورت می‌گیرد [۵]. برداشت داده‌های مغناطیس‌سنجی زمینی تفکیک‌پذیری بسیار بالایی نسبت به برداشت‌های هوایی دارد ولی زمان اجرا و هزینه بالاتری در پی خواهد داشت. اخیراً کاربرد پهپادها در برداشت‌های ژئوفیزیک به ویژه مغناطیس‌سنجی بسیار مورد توجه واقع شده است. با استفاده از پهپادها می‌توان سرعت برداشت داده‌های مغناطیس‌سنجی را افزایش داد، ولیکن تفکیک‌پذیری آنها نیز به دلیل ارتفاع پایین و سرعت کمتر پرواز بسیار بالاتر از داده‌های هوایی برداشت شده به وسیله هواپیما و بالگرد است. برای دستیابی به نتایج بهینه در اکتشافات مغناطیس‌سنجی در کمترین زمان و هزینه ممکن، استفاده از یک روش بهینه لازم و ضروری به نظر می‌رسد. در روش مغناطیس‌سنجی هوابرد رسیدن به داده‌هایی با خطای کمتر و تفکیک‌پذیری بالا سخت و دشوار است، از این رو استفاده از پهپاد تا حدی خطای اندازه‌گیری میدان مغناطیسی را کاهش می‌دهد ولی این خطا را به سمت صفر میل نمی‌دهد، بنابراین به روشی جدید بر پایه هوش مصنوعی و الگوریتم‌های متنوع که بتواند با استفاده از این داده‌ها و صرف هزینه و زمان کم داده‌هایی با خطای کمتر را در اختیار بگذارد، احتیاج است. مزیت شبکه‌های عصبی مصنوعی (ANN) نسبت به روش‌های سنتی تجربی و آماری این است که نیازی به معرفی دانش قبلی در مورد ماهیت رابطه

شرقی و  $36^{\circ}18'$  تا  $36^{\circ}21'$  درجه عرض شمالی قرار دارد. این محدوده از باختر به شهرستان مریوان و از طرف شمال به شهرستان سقز محدود می‌شود. از لحاظ زمین‌شناسی این محدوده در جنوب شرق برگه‌ی چاپان (ایران خواه: ۵۳۶۲) و در شمال شرق برگه‌ی باینجوب (۵۳۶۱) واقع شده است. محدوده مورد مطالعه در تقسیم‌بندی پهنه‌های ساختمانی ایران در زون سنندج- سیرجان و در ورقه‌های زمین‌شناسی ۱:۱۰۰۰۰۰ ایران‌خواه و باینجوب قرار گرفته که نمای کلی از منطقه در شکل ۱ به نمایش گذاشته شده است. واحدهای

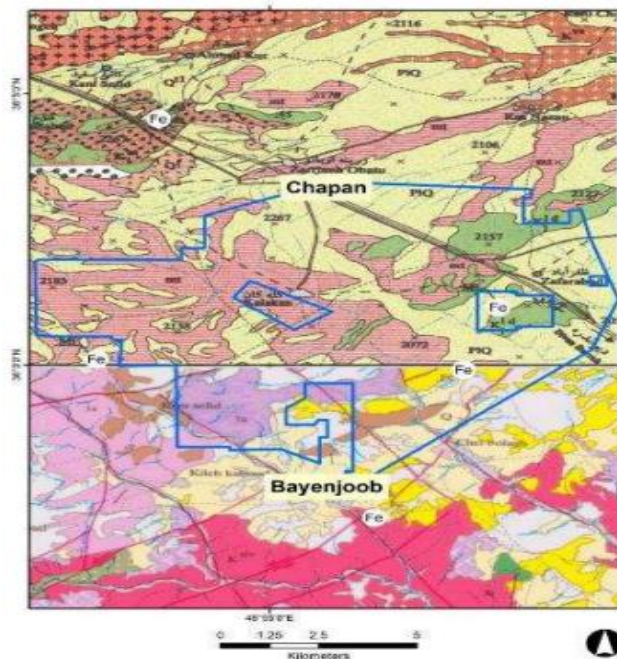
داشت که نتایج قابل قبول‌تر و سریع‌تری نسبت به روش‌های فعلی به دست می‌آید.

## ۲- محدوده مورد مطالعه

محدوده مورد نظر در روستای کلکان از توابع بخش گرفتو در حدود ۱۵ کیلومتری شمال غرب شهرستان دیواندره در شمال استان کردستان قرار دارد. محدوده مورد مطالعه خود بخشی از محدوده اکتشافی بزرگ ظفرآباد به وسعت ۷۲ کیلومتر مربع است و در موقعیت جغرافیایی  $46^{\circ}59'$  تا  $46^{\circ}43'$  درجه طول



(الف)



(ب)

شکل ۱: (الف) موقعیت محدوده مورد مطالعه و راه‌های دسترسی به آن و (ب) نقشه زمین‌شناسی منطقه



واحدها، گره‌ها یا گیرنده‌ها نامیده می‌شوند. در کاربردهای علوم زمین، گیرنده‌های چندلایه (MLP) معمولاً مورد استفاده قرار می‌گیرد که در آن عناصر پردازش معمولاً به صورت لایه‌ای مرتب می‌شوند: یک لایه ورودی، یک لایه خروجی و یک یا چند لایه میانی که لایه‌های پنهان نامیده می‌شوند و عملکرد آن‌ها به وسیله روابط ۱ و ۲ شرح داده شده است (شکل ۲-الف).

$$I_j = \theta_j + \sum_{i=1}^n W_{ji} X_i \quad (1)$$

$$y_j = f(I_j) \quad (2)$$

که در این روابط:

$I_j$ : سطح فعال شدن گره  $j$

$w_{ji}$ : وزن اتصال بین گره‌های  $i$  و  $j$

$x_i$ : ورودی از گره  $i$ ,  $i = 1, \dots, n$

$\theta_j$ : آستانه گره  $j$

$y_j$ : خروجی گره  $j$

$f(I_j)$ : تابع انتقال است (شکل ۲-ب) [۱۲].

هر گره در یک لایه خاص از طریق اتصالات وزنی به بسیاری از گره‌های دیگر متصل می‌شود. وزن‌های اسکالر قدرت اتصالات بین نورون‌های بهم پیوسته را تعیین می‌کنند. یک نورون خاص، ورودی وزنی خود را از بسیاری از نورون‌های عصبی متصل به هم دریافت می‌کند که از آن‌ها وزن جمع شده و یک آستانه اضافه می‌شود. نتیجه جمع از طریق یک تابع انتقال (گام به گام، سیگموئید) برای تولید خروجی نورون منتقل می‌شود [۱۳].


سنگی موجود در منطقه شامل سنگ آهک مرمری شده، کالک شیست، شیست، گنیس، آهک‌های دوباره تبلور یافته و سنگ‌های متاسوماتیکی (اسکانی) است.

### ۳- شبکه‌های عصبی مصنوعی

پردازش شبکه عصبی مصنوعی شامل الگوریتم‌های کامپیوتری است که انواع مختلفی از مسایل را حل می‌کند. این مسایل شامل طبقه‌بندی، برآورد پارامتر، پیش‌بینی پارامتر، تشخیص الگو، اجرا و تکمیل، وابستگی و ارتباط، فیلتر کردن و بهینه‌سازی است [۹].

شبکه‌های عصبی در واقع الهام گرفته از ساختار پیچیده مغز انسان هستند که در آن میلیون‌ها سلول عصبی از طریق ارتباطی که با هم دارند به حل مسایل یا ذخیره‌سازی اطلاعات می‌پردازند. شبکه‌های عصبی مصنوعی نوعی هوش مصنوعی است که سعی در تقلید از عملکرد مغز و سیستم عصبی انسان دارد [۱۰]. ANN‌ها شبیه‌سازی ریاضی سیستم‌های عصبی انسان هستند و از فرآیند یادگیری از نمونه‌های موجود برای به دست آوردن توانایی تشخیص الگوهای در بین آنها استفاده می‌کنند. در ANN، نورون‌ها در لایه‌هایی قرار می‌گیرند که نورون‌های هر لایه با نورون‌های لایه مجاور مرتبط هستند [۱۱]. شبکه ANN از نمونه داده‌های آرایه شده به الگوریتم یاد می‌گیرد و قادر به گرفتن روابط دقیق در داده‌ها است، حتی اگر روابط زمینه‌ای (فیزیکی) ناشناخته باشد یا برای توضیح دشوار باشد.

شبکه عصبی متشکل از تعدادی نورون مصنوعی است که



شکل ۲: الف) طرح معمولی ANN و ب) فعال‌سازی عملکرد انتقال در شبکه ANN

برای تخمین روابط بین متغیرها است. تحلیل رگرسیون در تفهیم اینکه چگونه مقدار متغیر وابسته با تغییر هر کدام از متغیرهای مستقل و با ثابت بودن دیگر متغیرهای مستقل تغییر خواهد کرد کمک می‌کند [۱۵]. رگرسیون به صورت گسترده برای پیش‌بینی و همچنین برای شناخت ارتباط میان متغیر مستقل و وابسته و شکل این روابط استفاده می‌شود. بسیاری از مسایل داده‌کاوی را می‌توان به صورت یک مساله رگرسیون بیان کرد که در نهایت یک مدل پیش‌بینی‌کننده آموزش و طراحی می‌شود که می‌تواند با در دست داشتن نقاطی از یک رابطه ریاضی مخفی یا موجود، تمامی آن رابطه را بازسازی و یا شبیه‌سازی کند و به ما در یافتن ارتباط‌های موجود میان متغیرها و خروجی‌ها کمک کند. از مهم‌ترین روش‌های رگرسیون می‌توان رگرسیون خطی، رگرسیون لجستیک و رگرسیون جنگل تصادفی را نام برد.

### ۳-۲- جنگل تصادفی (RF)<sup>۲</sup>

جنگل تصادفی طبقه‌بندی‌کننده‌های گروهی بسیار قدرتمند و انعطاف‌پذیر بر اساس درخت تصمیم‌گیری هستند [۱۶]. جنگل تصادفی یک روش یادگیری ماشین نظارت شده برای طبقه‌بندی و رگرسیون است که چندین درخت تصمیم مستقل را برای ساخت یک مدل پیش‌بینی با تجمیع راه‌انداز یا "کیسه‌گذاری"<sup>۴</sup> ترکیب می‌کند [۱۷]. در کیسه‌گذاری، درختان تصمیم با استفاده از درصد زیادی از نمونه‌های آموزش به طور تصادفی و با جایگزینی، برای مطابقت با اندازه اصلی نمونه‌های آموزشی انتخاب می‌شوند. نمونه‌های باقیمانده، نمونه‌های "خارج از کیف" (OOB)<sup>۵</sup> را نشان می‌دهند و برای ارزیابی خطای مربوط به هر درخت تصمیم‌گیری ایجاد شده مورد استفاده قرار می‌گیرند.

درخت تصمیم‌گیری<sup>۶</sup> یک ابزار برای پشتیبانی از تصمیم است که از درخت‌ها برای مدل کردن استفاده می‌کند. درخت تصمیم به طور معمول در تحقیق‌ها و عملیات مختلف استفاده می‌شود. این مدل هم برای مسایل دسته‌بندی و هم برای پیش‌بینی استفاده می‌شود [۱۸]. یک درخت تصمیم‌گیری به طور معمول با یک گره اولیه شروع می‌شود که پس از آن پیامدهای احتمالی به صورت شاخه‌هایی از آن منشعب شده و هر کدام از آن پیامدها به گره‌های دیگری منجر شده که آن‌ها هم به نوبه خود شاخه‌هایی از احتمالات دیگر را ایجاد می‌کنند که این ساختار شاخه‌شاخه سرانجام به نموداری شبیه به یک درخت مبدل می‌شود.

انتشار اطلاعات در MLP از لایه ورودی (جایی که داده‌های ورودی ارائه می‌شود) شروع می‌شود. لایه بعدی ورودی‌های وزنی را از هر گره در لایه ورودی دریافت می‌کند، سپس وزن‌ها جمع می‌شوند و از طریق یک تابع انتقال عبور می‌کنند تا خروجی گره تولید شود، سپس وزن شده و به سلول‌های عصبی در لایه بعدی منتقل می‌شود. شبکه با استفاده از یک قانون یادگیری وزن‌های خود را تا جایی که مجموعه‌ای از وزن‌ها را پیدا کند که با کمترین خطای ممکن، نقشه ورودی-خروجی را تولید کند تنظیم می‌کند. این فرآیند مرحله یادگیری یا آموزش نامیده می‌شود.

### ۳-۱- یادگیری تحت نظارت

یادگیری تحت نظارت زمانی رخ می‌دهد که یک الگوریتم از داده‌ها و پاسخ‌های مربوط به هدف که شامل مقادیر عددی یا برجسب‌های پیوسته مانند کلاس‌ها یا برجسب‌ها است، برای پیش‌بینی پاسخ صحیح، زمانی که با نمونه‌های جدید روبه‌رو می‌شود [۱۴]، مورد استفاده قرار می‌گیرد. رویکرد نظارت شده در واقع مشابه یادگیری انسانی تحت نظارت معلم است. معلم نمونه خوبی را برای دانش آموز به یاد می‌آورد و سپس دانش آموزان از این نمونه‌های خاص، قوانین عمومی را به دست می‌آورند. در یادگیری ماشین، شما معلم هستید که داده‌ها را برای حل مساله ارائه می‌دهید. دانش آموز الگوریتم است که معمولاً به عنوان پیش‌بینی‌کننده یا یک مدل شناخته می‌شود که می‌تواند پس از آموختن از داده‌های ارائه شده، یک راه‌حل را پیش‌بینی کند. داده‌ها شامل ویژگی‌هایی مانند توالی‌های آموزنده داده‌های عددی و غیرعددی هستند، هر کدام یک ویژگی از هدف و پاسخ مرتبط با آن (یا نتیجه) را نشان می‌دهند که راه حل یادگیری است.

فرآیند یادگیری معمولاً با استفاده از آموزش اطلاعات نشان داده شده است. علاوه بر این، باید در مسایل، رگرسیون و طبقه‌بندی را تشخیص داد که هدف در رگرسیون یک مقدار عددی و در طبقه‌بندی یک متغیر کیفی است (مانند یک کلاس یا برجسب). یک مثال از رگرسیون قیمت متوسط خانه‌ها را در یک منطقه تعیین می‌کند و یک مثال طبقه‌بندی، بین گونه‌های حیوانی یا گیاهی بر اساس ویژگی‌های فیزیکی آن‌ها، گونه خاصی را تشخیص می‌دهد.

### ۳-۲- رگرسیون

در مدل‌های آماری، تحلیل رگرسیون، یک فرآیند آماری

با پایان ارزیابی درخت اول وزن‌های داده اصلاح شده و سپس درخت دوم با توجه به این وزن‌ها رشد می‌کند. هدف این مرحله بهبود پیش‌بینی درخت اول است. خطای اندازه‌گیری از گروه جدید یعنی مجموع درخت اول و دوم محاسبه می‌شود، سپس درخت سوم بر اساس وزن‌های اصلاح شده جدید در راستای بهبود عملکرد مجموعه رشد داده می‌شود. این کار برای تعداد مشخصی درخت ادامه می‌یابد. درختان بعدی کمک می‌کنند تا ویژگی‌هایی که به وسیله درختان قبل کشف نشده‌اند را بیابیم. بیشترین تفاوت این الگوریتم با الگوریتم Ada Boost در تشخیص ضعف‌های مجموعه در راستای تقویت مجموعه است. این موضوع در گرادیان تقویت شده با استفاده از شیب تابع خطا و در Ada Boost با کنترل وزن‌های بزرگ انجام می‌گیرد. تفاوت عمده این روش با جنگل تصادفی این است که جنگل تصادفی درخت‌ها در کنار یکدیگر یک شبکه را می‌سازند، اما درخت‌های تصمیم در این الگوریتم در راستای یکدیگر شبکه را می‌سازند (شکل ۳).

### ۳-۵- رگرسیون خطی<sup>۱</sup> (LR)

رگرسیون خطی یکی از ساده‌ترین الگوریتم‌های یادگیری ماشین است که تحت روش یادگیری نظارت شده قرار می‌گیرد و برای حل مسایل رگرسیون استفاده می‌شود. برای پیش‌بینی متغیر وابسته پیوسته از متغیرهای مستقل استفاده می‌شود. هدف از رگرسیون خطی یافتن بهترین خط برازش است که بتواند خروجی را برای متغیر وابسته پیوسته پیش‌بینی کند. اگر برای پیش‌بینی از یک متغیر مستقل منفرد استفاده شود، آن را رگرسیون خطی ساده می‌نامند و اگر بیش از دو متغیر مستقل وجود داشته باشد، چنین رگرسیونی را رگرسیون

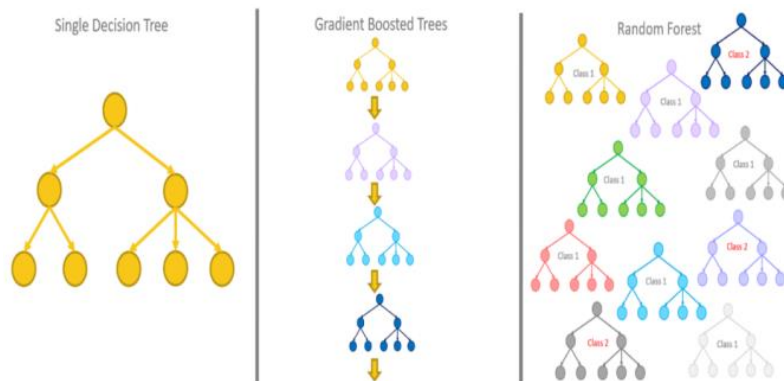
از آنجا که RF تعداد K درخت تصمیم ایجاد می‌کند، مقدار پیش‌بینی شده (P) با میانگین مقادیر پیش‌بینی شده (T) به طور کلی برای درختان داده می‌شود:

$$P = \frac{1}{K} \sum_{k=1}^K T \quad (3)$$

رگرسیون RF که ترکیبی از چندین درخت تصمیم مستقل است، به طور قابل توجهی در برابر داده‌های پرت و بیش‌برازش<sup>۲</sup> مقاوم است [۱۹]. با این حال، در مواردی که داده‌ها برای پیش‌بینی خود به کار می‌روند، تعداد نمونه‌های داده‌های آموزشی تاثیر قابل توجهی بر عملکرد مدل پیش‌بینی دارد. داده‌های آموزشی کم ممکن است به عملکرد کم‌برازش<sup>۳</sup> مدل منجر شود، یعنی یک مدل ساده که نشان‌دهنده داده‌ها نیست. از سوی دیگر، مقدار زیادی از داده‌های آموزشی به حالت بیش‌برازش منجر می‌شود که در آن با تغییرات جزئی در داده‌ها (به عنوان مثال نویزها و داده‌های پرت) مدل عملکرد پیش‌بینی ضعیفی را نشان می‌دهد.

### ۳-۴- الگوریتم گرادیان تقویت شده<sup>۴</sup> (GB)

الگوریتم گرادیان تقویت شده جزو الگوریتم‌های یک پارچه با عملکرد بالا و پایدار است که توانایی بالایی در کنترل داده‌های نویز و پیش‌بینی قدرتمند در پیش‌بینی داده‌های غیرخطی دارد. الگوریتم گرادیان تقویت شده الگوریتمی بر پایه درخت تصمیم است و با توسعه روش Ada Boost به وجود آمده است. در این روش‌ها قوی کردن الگوریتم‌های ضعیف و تبدیل به الگوریتم‌های قوی‌تر اساس کار تقویت است. الگوریتم Ada Boost با آموزش درخت تصمیم کار خود را آغاز کرده و سپس به هر مشاهده، وزن برابر تعلق می‌گیرد.



شکل ۳: مقایسه الگوریتم جنگل تصادفی و گرادیان تقویت شده

حرف یونانی آلفا ( $\alpha$ ): نشان‌دهنده بایاس است که ثابت است،  
حرف بتا ( $\beta$ ): یک بردار ضرایب است که یک مدل رگرسیون خطی از بایاس برای ایجاد پیش‌بینی استفاده می‌کند.

#### ۴- روش مطالعه

##### ۴-۱- انتخاب و انطباق مکانی داده‌های هوایی و زمینی

بعد از برداشت داده‌ها و انجام تصحیحات لازم، داده‌های برداشت شده به وسیله پهپاد و پروتون به صورت نقشه‌های شدت میدان مغناطیسی در نرم‌افزار ژئوسافت<sup>۱۳</sup> درآمدند (شکل ۴).

تعداد نقاط برداشت شده به وسیله پروتون ۴۴۲ نقطه و نقاط ممز ۳۱۳۸۲ نقطه است. در برداشت هوایی به علت آنکه انطباق دقیق شبکه برداشت بر شبکه‌ی برداشت زمینی از نظر مکانی امکان‌پذیر نیست، بنابراین انطباق نقاط در برداشت هوایی و زمینی دور از انتظار است. در این مطالعه برای رفع این مشکل از فیلتر کردن داده‌های هوایی با فاصله مکانی کمتر

خطی چندگانه می‌نامند. با یافتن بهترین خط برازش، الگوریتم رابطه بین متغیر وابسته و متغیر مستقل را برقرار می‌کند و رابطه باید ماهیت خطی داشته باشد. خروجی برای رگرسیون خطی فقط باید مقادیر پیوسته مانند قیمت، سن، حقوق و نظایر آن باشد.

رگرسیون خطی اولین انتخاب بیشتر تمرین‌کنندگان ماشین یادگیری در هنگام ساخت مدل‌ها برای مقایسه، به عنوان یک راه حل خطی (یک استاندارد اساسی)، برخلاف بیشتر راه‌حل‌های پیچیده‌تر است. همچنین از مدل‌های خطی برای کشف ویژگی‌های کلیدی در یک مساله استفاده شده و با این مجموعه ویژگی‌ها آزمایش انجام داده و دیدگاهی را نسبت به روش‌های ایجاد ویژگی‌های جدید به دست می‌آورند.

رگرسیون خطی با ترکیب کردن از طریق مجموع وزن‌های ویژگی‌های عددی کار می‌کند. رگرسیون خطی این کار را با اضافه کردن یک مقدار ثابت به نام بایاس (مجموع کلی) به داده‌ها انجام می‌دهد. بایاس نقش مهمی در تولید پیش‌بینی‌های پیش‌فرض ایفا می‌کند، به ویژه هنگامی که برخی از ویژگی‌ها از دست رفته است (و همچنین زمانی که ارزش صفر است).

رگرسیون خطی شامل چند مرحله است:

۱. مقداردهی تصادفی پارامترها برای تابع فرضی؛ یعنی در واقع ابتدا یک معادله خطی با مقادیر رندوم را در نظر می‌گیریم.
۲. محاسبه خطا با استفاده از یک تابع زیان<sup>۱۱</sup> که در آن می‌بینیم خطی که به صورت فرضی در نظر گرفتیم، چقدر با مقادیر واقعی فاصله دارد.
۳. در این مرحله لازم است پارامترها را با توجه به مشتقات جزئی و نرخ یادگیری به‌روزرسانی کنیم که در واقع این کار را الگوریتم گرادیان نزولی<sup>۱۲</sup> انجام می‌دهد.

۴. تکرار این روند تا به حداقل رسیدن مقدار خطا همان‌طور که بیان شد، هدف از رگرسیون خطی رسیدن به یک معادله خطی مناسب با کمترین خطاست. در اینجا فرمول مشترک برای معادله رگرسیون خطی وجود دارد:


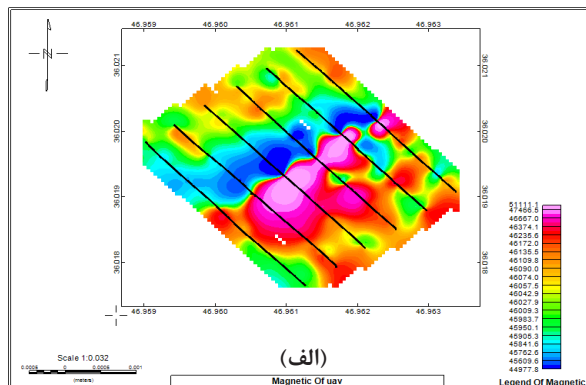
$$y = \beta X + \alpha \quad (۴)$$

که در آن:

$Y$ : بردار مقادیر پاسخ

نماد  $X$ : ماتریس ویژگی‌ها را برای استفاده از بردار فرضی

$Y$  تعیین می‌کند.  $X$  یک ماتریس است که فقط حاوی مقدار عددی است.



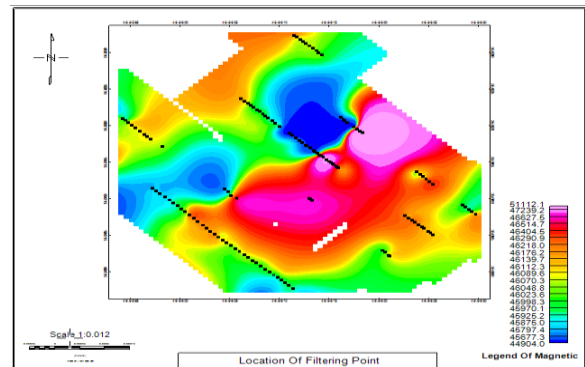
شکل ۴: الف) نقشه شدت میدان مغناطیسی داده‌های برداشت شده زمینی و ب) هوایی به همراه پروفیل برداشت

هوایی به عنوان داده ورودی و مقدار مغناطیس زمینی به عنوان داده هدف یا خروجی فرض شد. از این تعداد داده حدود ۱۰٪، یعنی ۱۳ عدد داده، به صورت تصادفی به عنوان داده اعتبارسنجی شبکه جدا شد و ۱۱۶ داده باقی مانده به عنوان داده‌های آموزشی و آزمایشی با نسبت ۸۰٪ به ۲۰٪ از کل داده‌ها به شبکه وارد شدند.

هدف الگوریتم‌ها باید به گونه‌ای باشد که بتواند با مقدار ورودی و خروجی داده شده به شبکه‌ی هوش مصنوعی، رابطه میان داده‌های ورودی و خروجی را کشف کند و با ورود داده‌های جدید این رابطه کشف شده را اعمال و خروجی را پیش‌بینی کند. در این مورد ما برای یافتن رابطه باید الگوریتم‌هایی را انتخاب کنیم که بتواند پیش‌بینی یا رگرسیون انجام دهد. همچنین چون مقدار ورودی و خروجی مشخص است، بنابراین الگوریتم به صورت نظارت شده است. در نتیجه الگوریتم یا الگوریتم‌های مورد استفاده باید رگرسیون نظارت شده باشد. الگوریتم‌هایی که برای پیش‌بینی به کار برده شد سه الگوریتم رگرسیون خطی، جنگل تصادفی و گرادیان تقویت شده است که در انتها الگوریتمی که بهترین نتایج آماری را در بخش آموزش، آزمایش و اعتبارسنجی داشته باشد به عنوان الگوریتم برتر برای پیش‌بینی مقادیر انتخاب می‌شود.

الگوریتم‌ها باید در محیط پایتون بررسی و نتایج با نمودارهای مختلف در سه مرحله آموزش، آزمایش و اعتبارسنجی نشان داده شوند [۲۰]. در نمودارها نتایج هر مرحله با داده‌های زمینی پروتون آورده شده است.

یا مساوی از ۳ متر از داده‌های زمینی استفاده شد؛ بنابراین داده‌هایی که بیشتر از ۳ متر فاصله مکانی داشتند از داده‌های اصلی حذف شدند. در نهایت تعداد داده‌هایی که باید در شبکه هوش مصنوعی از آن‌ها استفاده کنیم به ۱۲۹ عدد کاهش یافت و طول و عرض جغرافیایی این نقاط همان طول و عرض جغرافیایی نقاط هوایی در نظر گرفته شد (شکل ۵).




شکل ۵: نقشه نقاط انطباق داده شده زمینی و هوایی و شدت میدان مغناطیسی حاصل از این نقاط


#### ۴-۲- انتخاب مدل و اجرای شبکه با استفاده از هوش مصنوعی در محیط نرم‌افزاری پایتون

بعد از پیش‌پردازش و بررسی داده‌ها از نظر داده‌های صفر یا تکراری، مقادیر طول و عرض جغرافیایی و مقدار مغناطیس

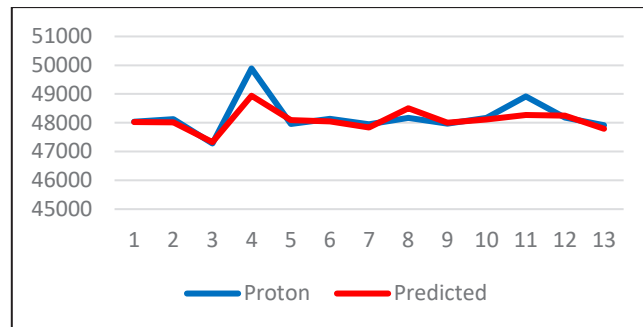
#### ۴-۲-۱- نتایج رگرسیون خطی



شکل ۷: مقادیر مغناطیس زمینی و پیش‌بینی شده در آزمایش رگرسیون خطی

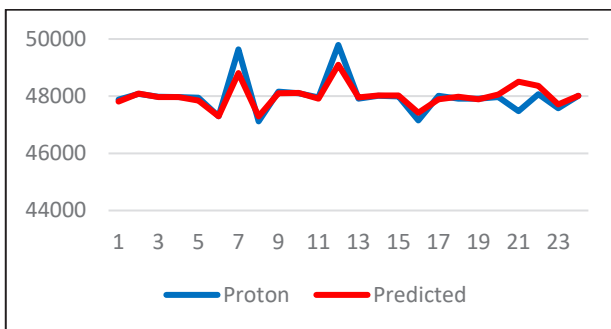


شکل ۶: مقادیر مغناطیس زمینی و پیش‌بینی شده در آموزش رگرسیون خطی




شکل ۸: مقادیر مغناطیس زمینی و پیش‌بینی شده در اعتبارسنجی رگرسیون خطی

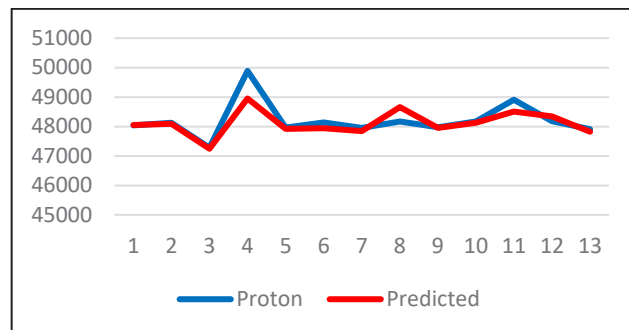
۲-۲-۴- نتایج رگرسیون جنگل تصادفی



شکل ۱۰: مقادیر مغناطیس زمینی و پیش‌بینی شده در آزمایش جنگل تصادفی

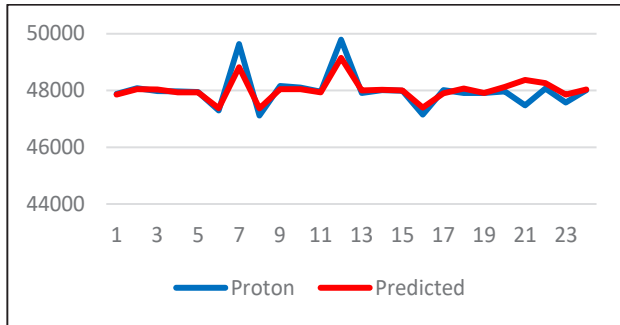


شکل ۹: مقادیر مغناطیس زمینی و پیش‌بینی شده در آموزش جنگل تصادفی




شکل ۱۱: مقادیر مغناطیس زمینی و پیش‌بینی شده در اعتبارسنجی جنگل تصادفی


## ۴-۲-۳- نتایج گرادیان تقویت شده



شکل ۱۳: مقادیر مغناطیس زمینی و پیش‌بینی شده در آزمایش گرادیان تقویت شده



شکل ۱۲: مقادیر مغناطیس زمینی و پیش‌بینی شده در آموزش گرادیان تقویت‌شده



شکل ۱۴: مقادیر مغناطیس زمینی و پیش‌بینی شده در اعتبارسنجی گرادیان تقویت شده

## ۴-۴- پایداری شبکه گرادیان تقویت شده


بررسی پایداری شبکه در حالت‌های مختلف، از پایگاه داده پنج بار داده‌های اعتبارسنجی به صورت تصادفی و با همان تعداد قبلی انتخاب شد. در هرکدام از این پنج دسته، شبکه در ۲۰ حالت تصادفی<sup>۱۴</sup> مختلف اجرا شد. نتایج (RMSE) در کل ۱۰۰ بار اجرای شبکه برای مراحل آموزش، آزمایش و اعتبارسنجی روی نمودار برده شد و انحراف معیار نیز محاسبه گردید. با توجه به تغییرات کم در محدوده خطا و همچنین پایین بودن انحراف معیار می‌توان پی برد که شبکه پایدار است (جدول ۲ و شکل‌های ۱۶، ۱۷ و ۱۸).

## ۴-۳- انتخاب مدل برتر

با توجه به نمودارها، هر سه الگوریتم نتایج قابل قبول در پیش‌بینی دارند و در مساله آموزش شبکه عملکرد خوبی داشتند و نتایج آن‌ها با داده‌های زمینی انطباق بسیار نزدیکی دارد، اما برای تشخیص بهترین الگوریتم نیاز داریم تا نتایج را با پارامترهای آماری مقایسه کنیم. با توجه به نتایج نمودارهای آماری، رگرسیون خطی نسبت به دو مدل دیگر عملکرد ضعیف‌تری داشته و همچنین نتایج جنگل تصادفی و گرادیان تقویت شده به همدیگر نزدیک بودند، اما گرادیان تقویت شده نتایج بهتری از خود نشان داد و به عنوان الگوریتم بهتر انتخاب شد (جدول ۱ و شکل ۱۵).

جدول ۱: نتایج مولفه‌های آماری سه مدل اجرا شده در سه مرحله آموزش، آزمایش و اعتبارسنجی

مدل	میانگین خطای مطلق	میانگین خطای مربع	خطای مطلق میانه	نمره‌ی واریانس مشخص	نمره‌ی R2	میانگین خطای جذر مربع
جنگل تصادفی	آموزش	۰٫۰۰۹۹۱۵۷۸۲	۰٫۰۰۰۵۴۸۲۹۳	۰٫۰۰۲۲۶۰۱۸۷	۰٫۹۶۵۵۳۵۸۵۸	۰٫۰۲۳۴۱۵۶۶۱
	آزمایش	۰٫۰۲۶۲۷۶۹۳۶	۰٫۰۰۱۹۹۲۶۹۶	۰٫۰۱۴۷۵۰۶۸۸	۰٫۸۴۵۴۸۱۲۷۲	۰٫۰۴۴۶۳۹۶۲۷
	اعتبارسنجی	۰٫۰۳۰۵۸۹۲۸۵	۰٫۰۰۳۵۶۳۷۷۳	۰٫۰۰۴۱۶۴۶۹۶	۰٫۷۷۷۴۳۵۶۳۹	۰٫۰۵۹۶۸۱۹۶۷
رگرسیون خطی	آموزش	۰٫۰۲۵۴۹۳۳۹	۰٫۰۰۲۱۵۷۰۶۳	۰٫۰۱۲۴۷۹۳۱۶	۰٫۸۶۳۳۵۴۹۰۵	۰٫۰۴۶۴۴۴۱۹۶
	آزمایش	۰٫۰۳۵۲۳۳۸۲۲	۰٫۰۰۳۲۹۶۸۰۴	۰٫۰۱۹۹۵۷۵۲۲	۰٫۷۳۸۴۸۳۴۵۷	۰٫۰۵۷۴۱۷۸
	اعتبارسنجی	۰٫۰۳۵۷۸۲۳۰۵	۰٫۰۰۳۶۳۵۴۲۷	۰٫۰۱۵۲۴۴۷۲۶	۰٫۷۴۶۵۳۹۵۷۲	۰٫۰۶۰۲۹۴۵۰۴
گرادینان تقویت شده	آموزش	۰٫۰۱۲۹۹۹۷۳۴	۰٫۰۰۰۴۰۶۵۶۱	۰٫۰۰۷۶۱۱۷۱۵	۰٫۹۷۴۲۴۵۲۵۲	۰٫۰۲۰۱۶۳۳۶۸
	آزمایش	۰٫۰۲۵۳۸۷۱۱۳	۰٫۰۰۱۲۳۳۲۶۸	۰٫۰۱۵۷۷۷۳۲۱	۰٫۹۰۱۴۷۲۶۵۳	۰٫۰۳۵۱۱۷۹۱۷
	اعتبارسنجی	۰٫۰۱۹۹۵۵۸۸۲	۰٫۰۰۱۲۲۶۲۸۱	۰٫۰۰۹۶۸۵۰۸۴	۰٫۹۳۲۸۲۵۱۱۶	۰٫۰۳۵۰۱۸۳۰۲



شکل ۱۵: مقایسه آماری مدل‌ها

جدول ۲: نتایج آماری آزمایش پایداری شبکه گرادینان تقویت شده


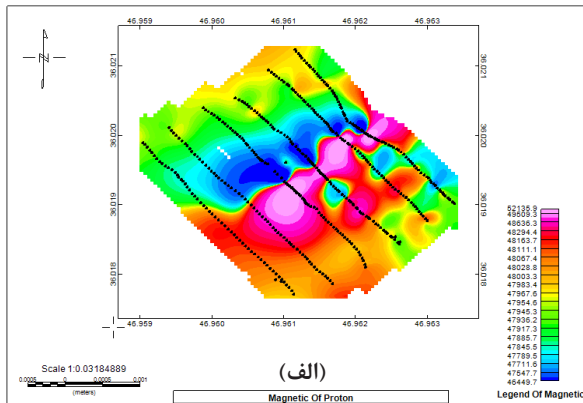
کمینه	بیشینه	میانگین	انحراف معیار
۰٫۰۰۹۶۰۵۴۱۱	۰٫۰۲۳۵۱۹۸۴۱	۰٫۰۱۸۳۹۴۷۴۷	۰٫۰۰۲۳۴۹۶۳۳
۰٫۰۱۴۳۵۵۸۲۵	۰٫۱۷۸۹۷۴۶۸۳	۰٫۰۴۸۹۹۴۰۸۸	۰٫۰۳۲۰۱۰۱۱۱
۰٫۰۱۷۲۸۹۷۴۳	۰٫۱۳۸۳۳۸۵۳۳	۰٫۰۴۵۲۱۴۵۸	۰٫۰۲۹۰۹۴۵۱۷

## ۵- نتایج

مغناطیسی در نرم‌افزار ژئوسافت درآمدند تا با نقشه‌ی شدت مغناطیسی برداشت شده به وسیله پروتون مقایسه شود. همان‌طور که در نقشه‌های شکل ۱۹ مشاهده می‌شود، محل، شدت و شکل آنومالی‌های مغناطیس در هر دو نقشه انطباق زیادی دارند.

در این مرحله از بررسی، کل داده‌های هوایی یعنی ۳۱۳۸۲ عدد داده وارد شبکه پیش‌بینی گرادینان تقویت شده گردید تا کار پیش‌بینی را انجام داده و همین تعداد داده خروجی به دست دهد. داده‌های پیش‌بینی شده به صورت نقشه شدت







شکل ۱۹: الف) نقشه شدت میدان مغناطیسی داده‌های برداشت شده زمینی به همراه پروفیل برداشت و ب) نقشه شدت میدان مغناطیسی حاصل از پیش‌بینی شبکه گرادیان تقویت شده به همراه پروفیل برداشت

#### ۶- بحث


در این مطالعه به علت آن که با تنها اطلاعاتی که سروکار داریم داده‌های برداشت شده است، بنابراین دقت در برداشت داده‌ها بسیار حائز اهمیت است. همچنان که دیدیم شبکه برداشت داده‌های هوایی و زمینی از نظر مکانی بر هم منطبق نبودند و به اجبار تعداد بسیار زیادی از داده‌ها را حذف کردیم، بنابراین سعی در انطباق مکانی برداشت داده‌ها می‌تواند به زیاد شدن تعداد داده‌های ورودی و در نتیجه بهتر شدن نتایج مدل‌ها کمک کند. هرچه حسگرهای مغناطیسی مورد استفاده در برداشت به ویژه برداشت با پهپاد، جدیدتر و سبک‌تر و دقیق‌تر باشند، هم نویز کاهش و هم دقت برداشت افزایش می‌یابد. مورد بعدی انتخاب یک رگرسیون نظارت‌شده مناسب برای پیش‌بینی و تبدیل داده‌های هوایی به زمینی است که اگرچه هر سه روش مورد استفاده در این مطالعه نتایج قابل اعتمادی داشتند، اما با مقایسه مولفه‌های



شکل ۱۶: نمودار نتایج RMSE برای گرادیان تقویت شده در ۱۰۰ بار اجرای شبکه با Random state های مختلف در مرحله آموزش



شکل ۱۷: نمودار نتایج RMSE برای گرادیان تقویت شده در ۱۰۰ بار اجرای شبکه با Random state های مختلف در مرحله آزمایش



شکل ۱۸: نمودار نتایج RMSE برای گرادیان تقویت شده در ۱۰۰ بار اجرای شبکه با Random state های مختلف در مرحله اعتبارسنجی

## ۷- مراجع

[۱] قدیانیلو، م.، یوسفی، م.، علیمردی، ا.؛ ۱۴۰۱؛ "شناسایی نواحی امیدبخش کانی‌سازی مس پورفیری در ناحیه چهارگنبد استان کرمان با استفاده از روش هوشمند یادگیری سریع". نشریه مهندسی منابع معدنی، دوره هفتم، شماره ۱، ص ۶۱-۳۹.

- [2] Bahri, E., Alimoradi, A., and Yousefi, M. (2021). "Mineral Potential Modeling of Porphyry Copper Deposits using Continuously-Weighted Spatial Evidence Layers and Union Score Integration Method". Journal of Mining and Environment (JME), 12(3): 743-751.
- [3] Alimoradi, A., Maleki, B., Karimi, A., Sahafzadeh, M., and Abbasi, S. (2020). "Integrating Geophysical Attributes with New Cuckoo Search Machine Learning Algorithm to Estimate Silver Grade Values-Case Study. Zarshouran Gold Mine". Journal of Mining and Environment (JME), 11(3): 865-879.
- [4] Nabighian, M. N., Grauch, V. J. S., Hansen, R. O., LaFehr, T. R., Li, Y., Peirce, J. W., Phillips, J. D., and Ruder, M. E. (2005). "The historical development of the magnetic method in exploration". Geophysics, 70(6): 33ND-61ND. DOI: 10.1190/1.2133784.

[۵] شاهسونی، ه.؛ ۱۴۰۰؛ "مروری بر استفاده از پهناد در مغناطیس‌سنجی هوابرد". پژوهش‌های ژئوفیزیک کاربردی، دوره هفتم، شماره ۳، ص ۲۴۰-۲۲۷. DOI: 10.22044/JRAG.2020.9500.1282.

- [6] Kuhn, S., Cracknell, M. J., and Reading, A. M. (2017). "Lithologic mapping using Random Forests applied to geophysical and remote-sensing data: A demonstration study from the Eastern Goldfields of Australia". Geophysics, 83(4): B183-B193. DOI: 10.1190/GEO2017-0590.1.
- [7] Li, J., Liu, Y., Yin, C., Ren, X., and Yang, S. (2019). "Fast imaging of time-domain airborne EM data using deep learning technology". Geophysics, 85(5): ISO-Z24.
- [8] Kayode, J. S., and Yusup, Y. (2020). "A novel fusion Python application of data mining techniques to evaluate airborne magnetic datasets". IEEE Dataport. DOI: https://dx.doi.org/10.21227/9s34-kc72.
- [9] Brown, M. P., and Poulton, M. M. (1996). "Locating Buried Objects for Environmental Site Investigations Using Neural Networks". Journal of Environmental and Engineering Geophysics, 1: 179-188.
- [10] Aminzadeh, F., and de Groot, P. (2006). "Neural Networks and Other Soft Computing Techniques with Applications in the Oil Industry". EAGE Publications, Houten, The Netherlands, pp. 164.
- [11] Alimoradi, A., Hajkarimian, H., Hemati Ahoori, H.,

آماری، بهترین روش یعنی رگرسیون گرادیان تقویت شده انتخاب شد.

## ۷- نتیجه‌گیری

در عصر حاضر با توجه به افزایش هزینه‌ها و دشواری کشف منابع معدنی جدید، نیاز به رویکردهای بهبود یافته در اکتشاف مواد معدنی وجود دارد. در میان روش‌های مهندسی، استفاده از هوش مصنوعی برای حل مسائلی که روابط ریاضی مشخصی ندارند و مدل علت و معلولی خاصی برای تعریف آنها وجود ندارد در حال افزایش است. در این مطالعه داده‌های مغناطیسی برداشت شده به وسیله حسگر ممز متصل به پهناد به داده‌های زمینی با استفاده از برنامه نویسی در محیط پایتون تبدیل شد و نقشه‌ی شدت مغناطیسی حاصل از آن با نقشه داده‌های برداشت شده به وسیله دستگاه زمینی پروتون در نرم‌افزار ژئوسافت مقایسه گردید.

به دلیل عدم انطباق مکانی و همچنین زیاد بودن تعداد داده‌های هوایی ممز نسبت به پروتون، داده‌ها با فیلتر مکانی نزدیک‌ترین داده‌های کمتر از ۳ متر فاصله فیلتر شدند و تعدادشان به ۱۲۹ داده کاهش یافت که با نسبت ۱۰ درصد داده‌های اعتبارسنجی، ۸۰ درصد داده‌های آموزش و ۲۰ درصد داده‌های آزمایش تقسیم‌بندی شدند. سه نوع مدل انتخابی برای این کار یعنی رگرسیون خطی، جنگل تصادفی و گرادیان تقویت شده عملکرد خوبی برای این تبدیل داشتند، اما گرادیان تقویت شده به علت دارا بودن معیارهای آماری بهتر نسبت به دو مدل دیگر به عنوان مدل برتر انتخاب و عمل پیش‌بینی داده‌های هوایی با استفاده از آن انجام شد. گرادیان تقویت شده دارای میانگین خطای مربع و میانگین خطای مطلق در داده‌های آموزشی به ترتیب ۰/۰۰۰۴ و ۰/۰۱ و در داده‌های آزمایشی به ترتیب ۰/۰۰۱ و ۰/۰۲ و در داده‌های اعتبارسنجی به ترتیب ۰/۰۱ و ۰/۰۱ رسیدند. همچنین در آزمایش‌های پایداری شبکه، گرادیان تقویت شده به علت نوسانات کم در مقادیر RMSE و همچنین مقدار انحراف معیار پایین در داده‌های آموزش، آزمایشی و اعتبارسنجی به عنوان یک شبکه پایدار تایید شد. در نهایت کل داده‌های هوایی اولیه با استفاده از رگرسیون گرادیان تقویت شده به داده‌های زمینی تبدیل و نتایج با داده‌های پروتون به صورت نقشه شدت مغناطیسی مقایسه شدند که انطباق بالای دو نقشه و دقت رگرسیون انتخابی را نشان داد.

in The Netherlands, 45: 5-32.

[19] Caruana, R., and Niculescu-Mizil, A. (2006). "An Empirical Comparison of Supervised Learning Algorithms". Proceedings of the 23rd International Conference on Machine Learning, Pittsburgh, June 2006, 25-29.

[20] Raschka, S., Patterson, J., and Nolet, C. (2020). "Machine Learning in Python: Main developments and technology trends in data science, machine learning, and artificial intelligence". Information, 11(4): 193.

and Salsabili, M. (2022). "Comparison between the performances of four metaheuristic algorithms in training a multilayer perceptron machine for gold grade estimation". International Journal of Mining and Geo-Engineering, 56-2(2022): 97-105.

[۱۲] راسل بیل، تام جکسون؛ ۱۳۹۳؛ "آشنایی با شبکه های عصبی". ترجمه محمود البرزی، انتشارات دانشگاه صنعتی شریف.

[13] Fathi, M., Alimoradi, A., and Hemati Ahoori, H. (2021). "Optimizing Extreme Learning Machine Algorithm using Particle Swarm Optimization to Estimate Iron Ore Grade". Journal of Mining and Environment (JME), 12(2): 397-411.

[14] Bandura, L., Halpert, A. D., and Zhang, Z. (2018). "Machine learning in the interpreter's toolbox: unsupervised, supervised, and deep learning applications". In Conference: SEG Technical Program Expanded Abstracts 2018, pp. 5520. DOI: <https://doi.org/10.1190/segam2018-2997015.1>.

[۱۵] احدی، س.، علیمرادی، ا.، سرخیل، ح.، کلهر محمدی، م.، فتحی، م.؛ ۱۴۰۲؛ "ارزیابی آلودگی فلزات سنگین و مواد آلی کنده ها و گل حفاری با استفاده از تکنیک الگوریتم رگرسیون یادگیری حدی هوش مصنوعی در یکی از میادین نفتی جنوب ایران". فصلنامه علوم محیطی، دوره ۲۱، شماره ۱، ص ۱۸۰-۱۶۳.

[16] Kriesel, D. (2009). "A Brief Introduction to Neural Networks". dkriesel.com, December 30.

[17] Breiman, L., Friedman, J., Olshen, R., and Stone, C. (1984). "Classification and Regression Trees". Chapman and Hall, Wadsworth, New York.

[18] Breiman, L. (2001). "Random Forests, Machine Learning". Kluwer Academic Publishers, Manufactured

<sup>1</sup> Artificial Neural Network

<sup>2</sup> Multy Layer Perceptrons

<sup>3</sup> Random Forest

<sup>4</sup> Bagging

<sup>5</sup> Out Of Bag

<sup>6</sup> Decision Tree

<sup>7</sup> Over Fitting

<sup>8</sup> Under Fitting

<sup>9</sup> Gradient Boosting

<sup>10</sup> Liner Resresion

<sup>11</sup> Cost Function

<sup>12</sup> Gradient Descent

<sup>13</sup> Oasis montaj

<sup>14</sup> Random state