



Imam Khomeini International University

Vol. 8, No. 2, Summer 2023



نشریه مهندسی منابع معدنی

Journal of Mineral Resources Engineering
(JMRE)

Research Paper

Estimating the Reserve of Lake- Siah Iron Ore Body by Geostatistical and Artificial Network Methods

Mousavi S.J.¹, Shayestehfar M.R.^{2*}, Maarefvand P.³

1- Ph.D Student, Dept. of Mining Engineering, Shahid Bahonar University of Kerman, Kerman, Iran

2- Associate Professor, Dept. of Mining Engineering, Shahid Bahonar University of Kerman, Kerman, Iran

3- Assistant Professor, Dept. of Mining Engineering, Amirkabir University of Technology, Tehran, Iran

Received: 02 Oct. 2021

Accepted: 25 Dec. 2021

Abstract: Investments and progress of mining projects depend on the quantity and quality of mineral resources and reserves; therefore, it is significant to know the reliability of the ore deposit estimation based on various methods. This research has investigated the role of geostatistics and artificial neural networks in modeling, estimating the concentration of exploration blocks, and estimating mining reserves. Spatial distribution modeling of iron values has been performed using three methods of ordinary kriging, Gaussian simulation, and artificial neural networks. To construct the block model of ore deposit, 29 exploratory boreholes with an average depth of 142.75 meters and a total length of 4139.9 meters were used. After drawing the variograms, the search ellipse was calculated, and a 3D model was obtained to estimate the concentration by ordinary kriging and Gaussian sequential simulation methods. Also, modeling and estimating the concentration was done by the artificial neural network method. Results showed that the artificial neural network technique has high validity. Also, due to its ease of use and no need for extra variographic calculations can be an appropriate alternative to geostatistical and simulation approaches. Finally, based on different cut-offs, the concentration-volume curve was drawn. The results show that this ore body has 439 million tons of ore with an average concentration of 42 % per 20% cut-off concentration.

Keywords: : Ordinary kriging, Sequential Gaussian simulation, Artificial neural network, Concentration-volume curve, Lake-siah.

How to cite this article

Mousavi, S. J., Shayestehfar, M. R., and Maarefvand, P. (2023). "Estimating the reserve of Lake- Siah iron ore body by geostatistical and artificial network methods". Journal of Mineral Resources Engineering, 8(2): 19-40.

DOI: [10.30479/JMRE.2022.16295.1549](https://doi.org/10.30479/JMRE.2022.16295.1549)

*Corresponding Author Email: shayeste@uk.ac.ir

COPYRIGHTS



©2023 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

Ore concentration is one of the main variables that characterize the value of an orebody. Almost every mining project begins with determining ore concentration distribution in 3D space, a problem often reduced to modeling the spatial variability of ore concentration values [1,2]. Spatial modeling of the concentration variability in a deposit directly impacts the evaluation of recovery functions, such as the volume, metal quantity, and mean concentration above cut-offs [3]. A reliable reserve and concentration estimation of an ore deposit will help the industries to make an investment decision on mining projects [3]. Thus, ore concentration estimation is a significant factor of ore deposit value evaluation and profitable mining operations. Also, choosing the proper estimation method for optimal reserve with the minimum error is major in mining engineering operations.

The major problem of concern to the mining engineers is selecting an appropriate method to estimate the ore concentration and reserve estimation. Because an ore deposit has a complex structure with many parameters involved, the most significant parameter is the distribution of ore concentrations.

In mining studies, geostatistical techniques are preferred due to concentration and recoverable reserve estimations. Geostatistical methods are more suitable, reliable, and preferable for modeling and the spatial distribution of the ore concentrations [3-5]. Various researchers [6,7] have successfully adopted this method for concentration/reserve estimation of different deposits around the world. Nowadays, geostatistical simulation and neural networks (NNs) methods are the prevalent techniques used for ore concentration estimation. However, these models work under fundamentally different frameworks. Geostatistical simulation is a technique that reproduces spatial heterogeneity of datasets. Many algorithms such as sequential Gaussian simulation (SGS) have been used for simulating continuous regionalized variables in the last three decades. SGS is fast and has shown good efficiency in the implementation [8]. Kriging is the base of most geostatistical simulation approaches, including sequential Gaussian simulation, widespread in earth science applications [9]. Moreover, they are linear models based on the local neighborhood structure. On the other hand, a NN has a non-linear distribution, which is robust for noisy and extreme-value data.

METHODS

Techniques used in research, such as geostatistics, SGS, and ANN are introduced. The chief venture in ordinary kriging is to build a variogram from the dissipate point set to be interpolated. A variogram comprises two parts: an experimental variogram and a model variogram. Geostatistical simulation methodologies allow the generation of several results with the same probability of occurrence, which can then together be treated for local uncertainty evaluation purposes (SGS).

In this research, we investigate the estimation of ore concentration distribution to identify abilities and weak points for concentration variation modeling. Geostatistical and machine learning approaches such as neural networks are used to estimate the iron concentration in an orebody. The performance of these methods is compared to each other. We compared geostatistical and ANN methods for estimating the concentration and reserve of an orebody. The effectiveness of these techniques is illustrated in the estimation of iron concentration values and reserve in the Lake Siah orebody in central Iran. Subsequently, the results of these methods are compared, and the observed differences are evaluated and analyzed.

FINDINGS AND ARGUMENT

Spatial distribution modeling of iron ore has been carried out employing geostatistics techniques such as OK and SGS. Also, non-linear modeling has been performed using ANN that provided an alternative option for concentration estimation in the study area. The study aimed to compare the estimates of OK, SGS, and ANN and identify which technique produces a more accurate estimate of the mineral reserves. This study had tested using drill hole data from a real undeveloped deposit in Iran. Block value prediction obtained employing kriging, simulation, and ANN model have been compared for the suitability of the methods. Experimental variograms of Fe concentration have been calculated in different directions to investigate anisotropy. Based on the results, the orebody was anisotropic, and the anisotropy type was geometric.

CONCLUSIONS

A comparison of Fe predicted values obtained by application of kriging, simulation, and ANN models more or less maintain similar distribution patterns in all three models that are close to the actual data. The

biggest challenges in using geostatistics lie in the failure in variogram modeling, non-stationarity, and normality of the data. SGS had a less smoothing effect on data than OK and honors spatial variability of data. Hence it provides a better estimation of mining blocks. For these reasons, SGS preferred the OK for ore and waste selection. Also, this study showed that the right choice of the training algorithm grants maximizing the predictive capability of the ANN models. The LM method had been recognized as the best training algorithm for concentration predictions. The precision of predictive ability was measured for concentration estimation. Results showed when the ANN model is available, can provide a significant advantage in reserve estimation. Also, the results obtained from the concentration distribution showed that neural networks offer a valid alternative approach to the problem of ore concentration estimation while requiring considerably less knowledge and time. Consequently, we suggested carrying out the concentration modeling employing these three approaches to obtain alternative scenarios for improved mine planning in ore deposits.

REFERENCES

- [1] Badel, M., Angorani, S., and Panah, M. S. (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.
- [2] Rezaei, A., Hassani, H., Moarefvand, P., and Golmohammadi, A. (2019). "Grade 3D Block Modeling and Reserve Estimation of the C-North Iron Skarn Ore Deposit, Sangam, NE Iran". *Global Journal of Earth Science and Engineering*, 6: 23-37.
- [3] Battalgazy, N., and Madani, N. (2019). "Categorization of mineral resources based on different geostatistical simulation algorithms: a case study from an iron ore deposit". *Natural Resources Research*, 28(4): 1329-1351.
- [4] Afeni, T. B., Akeju, V. O., and Aladejare, A. E. (2020). "A comparative study of geometric and geostatistical methods for qualitative reserve estimation of limestone deposit". *Geoscience Frontiers*, 12(1): 243-253. DOI: <https://doi.org/10.1016/j.gsf.2020.02.019>.
- [5] Silva, D., and Almeida, J. (2017). "Geostatistical Methodology to Characterize Volcanogenic Massive and Stockwork Ore Deposits". *Minerals*, 7(12): 238. DOI: 10.3390/min7120238.
- [6] Abdessattar, L., Dimitriy, N., and Messaoud, M. (2019). "Geostatistical Modeling by the Ordinary Kriging in the Estimation of Mineral Resources on the Kieselguhr Mine, Algeria". In: *IOP Conference Series: Earth and Environmental Science*. IOP Publishing, 362(1): 012051. DOI: 10.1088/1755-1315/362/1/012051.
- [7] Marzeihe, S. K., Hassan, M., Hossein, H., and Parviz, M. (2013). "Determining the best search neighbourhood in reserve estimation, using geostatistical method: a case study anomaly no. 12a iron deposit in central Iran". *Journal of the Geological Society of India*, 81: 581-585.
- [8] Jafrasteh, B., Fathianpour, N., and Su'arez, A. (2016). "Advanced machine learning methods for copper ore grade estimation". In: *Near Surface Geoscience 2016-22nd European Meeting of Environmental and Engineering Geophysics*.
- [9] Sarkar, B. C. (2014). "Geostatistics: concepts and applications in mineral deposit modeling for exploration and mining". *Journal Indian Geological Congress*, 6(1): 3-26.



تخمین ذخیره کانسار سنگ آهن لکه سیاه با روش‌های زمین آماری و شبکه مصنوعی

سید جعفر موسوی^۱، محمدرضا شایسته فر^{۲*}، پرویز معارف وند^۳

۱- دانشجوی دوره دکتری، گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان، کرمان

۲- دانشیار، گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان، کرمان

۳- دانشیار، دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر، تهران

پذیرش: ۱۴۰۰/۱۰/۰۴

دریافت: ۱۴۰۰/۰۷/۱۰

چکیده

سرمایه‌گذاری‌ها و پیشرفت پروژه‌های معدنی بستگی به کمیت و کیفیت منابع و ذخایر معدنی دارد، بنابراین اطلاع از اعتبار تخمین ذخیره معدنی بر اساس روش‌های گوناگون اهمیت فراوانی دارد. این پژوهش به بررسی نقش زمین‌آمار و شبکه عصبی مصنوعی در مدل‌سازی، تخمین عیار بلوک‌های اکتشافی و تخمین ذخیره کانسار پرداخته است. مدل‌سازی توزیع فضایی مقادیر آهن با استفاده از سه روش کریجینگ معمولی، شبیه‌سازی متوالی گاوسی و شبکه عصبی مصنوعی انجام شده است. برای ساخت مدل بلوکی کانسار، از ۲۹ گمانه اکتشافی با میانگین عمق ۱۴۲/۷۵ متر و مجموع طول ۴۱۳۹/۹ متر استفاده شد. تحلیل‌های آماری بر روی ۱۲۴۷ داده کامپوزیت شده ۲ متری انجام شد. پس از بررسی‌های آماری، واریوگرافی سه‌بعدی برای شناخت ناهمسانگردی منطقه و انتخاب بهترین واریوگرام و بیضوی جستجو برای متغیر آهن، انجام و مدل سه‌بعدی کانسار برای تخمین عیار به روش‌های کریجینگ معمولی و شبیه‌سازی متوالی گاوسی به دست آمد. همچنین مدل‌سازی و تخمین عیار به روش شبکه عصبی مصنوعی انجام گرفت. اعتبارسنجی نتایج به دست آمده از روش شبکه عصبی مصنوعی نشان داد که این تخمین اعتبار بسیار خوبی دارد و به علت سادگی استفاده و عدم نیاز به محاسبات سنگین واریوگرافی جایگزین مناسبی برای روش‌های زمین‌آمار کریجینگ و شبیه‌سازی متوالی گاوسی است. در ادامه نیز بر اساس عیار حدهای مختلف، میزان تناژ و عیار متوسط محاسبه و نمودار عیار-تناژ رسم شد. نتایج نشان می‌دهد که این کانسار به ازای عیار حد ۲۰ درصد، ۴۳۹ میلیون تن ماده معدنی با عیار متوسط ۴۲ درصد دارد.

کلمات کلیدی

کریجینگ معمولی، شبیه‌سازی متوالی گاوسی، شبکه عصبی مصنوعی، منحنی عیار-تناژ، کانسار لکه سیاه.

استناد به این مقاله

موسوی، س. ج.، شایسته فر، م. ر.، معارف وند، پ.؛ ۱۴۰۲؛ "تخمین ذخیره کانسار سنگ آهن لکه سیاه با روش‌های زمین آماری و شبکه مصنوعی". نشریه مهندسی منابع معدنی، دوره هشتم، شماره ۲، ص ۴۰-۱۹.

DOI: 10.30479/JMRE.2022.16295.1549



۱- مقدمه

در صنعت معدن، ارزش اقتصادی یک ذخیره معدنی با استفاده از یک مدل منبع که از اندازه‌گیری مستقیم منبع موجود ساخته شده، تخمین زده می‌شود. این مدل‌ها تا حد زیادی تحت تاثیر کمیت، کیفیت و توزیع فضایی اندازه‌گیری مستقیم موجود برای ویژگی‌های مورد بحث (به عنوان نمونه، عیارها) قرار دارند. با توجه به کاهش منابع معدنی و افزایش هزینه‌های استخراج و فرآوری به روزرسانی روش‌های اکتشافی برای مدل‌سازی دقیق‌تر و قابل اعتمادتر کانسارها و اندیس‌های معدنی نیاز است [۱].

مدل‌سازی و تخمین ذخیره کانسار جزو مهم‌ترین فعالیت‌های معدنکاری است که پیش‌نیاز طراحی معدن و برنامه‌ریزی تولید در طول بهره‌برداری از آن است، بنابراین محاسبه ذخیره مهم‌ترین هدف عملیات اکتشافی است و امکان‌پذیری استخراج کانسار منوط به داشتن ذخیره بالا و با وضعیت مناسب است. از طرف دیگر، تخمین عیار نیز، یکی از مراحل بسیار مهم در محاسبات ذخیره در تمامی ذخایر معدنی است [۲]. علت این امر ممکن است وابستگی زیاد پروژه‌های معدنی به مقدار دقیق عیار و نیاز به داشتن دانش وسیعی از معدنکاری، برای تخمین عیار و سپس تناژ ماده معدنی باشد. از جهتی دیگر، مقادیر عیار تاثیر قابل توجهی بر روی برنامه‌ریزی‌ها، طراحی و مدیریت معدن دارند. تخمین ذخیره کانسارها، اساس ارزیابی اقتصادی منابع معدنی را فراهم می‌کند. از جهتی سودآوری ذخیره به صحت برآورد ذخیره بستگی دارد. برآورد دقیق ذخایر معدنی، به صنایع در تصمیم‌گیری در مورد سرمایه‌گذاری و دولت در سیاست‌گذاری کمک خواهد کرد. عمده‌ترین نگرانی مهندسان طراحی، انتخاب روش مناسب برای تعیین ماده معدنی در محل است. انتخاب روش‌های نامناسب در برآورد ذخیره ممکن است به خطای $\pm 50\%$ در تخمین منجر شود [۳]. اهمیت انتخاب روش‌های مناسب تخمین برای ارزیابی پروژه و برنامه‌ریزی کوتاه‌مدت و بلندمدت کانسارها ضروری است.

مدل‌سازی فضایی تغییرپذیری عیار در یک ذخیره به طور مستقیم به پارامترهای مهمی چون تناژ، مقدار فلز و میانگین عیاری در برابر عیار حد بستگی دارد [۴]. تخمین عیار/ذخیره معدنی یک فرآیند بسیار مهم در یک پروژه معدنی در طول خط تولید برای کنترل عیار است و به دانشی دقیق از عیار و تناژ برای برنامه‌ریزی کوتاه‌مدت و بلندمدت نیاز دارد [۵].

یک تخمین عیار و ذخیره قابل اعتماد از یک ذخیره معدنی در جهت ایجاد یک تصمیم سرمایه‌گذاری بر روی پروژه‌های معدنی به صنایع کمک خواهد کرد [۶]. بنابراین تخمین عیار ماده معدنی یک فاکتور بسیار مهم در ارزیابی مقدار ذخیره معدنی و عملیات معدنکاری سودآور است. همچنین انتخاب یک روش پیشنهادی برای ذخیره بهینه با حداقل خطا در عملیات معدنکاری خیلی مهم است. مدل بلوکی بهترین مرجع برای ارزیابی ذخیره است. چرا که عیار هر بلوک با استفاده از عیار نمونه‌ها تعیین می‌شود.

زمین‌آمار به عنوان یک روش تخمین، نه تنها به دلیل توانایی صریح آن در شناخت رابطه فضایی موجود بین نمونه‌های مجاور، بلکه به دلیل توانایی بیان این رابطه از نظر کمی، مورد توجه خاص زمین‌شناسان و مهندسان معدن است. محققان مختلف این روش را با موفقیت برای تخمین ذخایر معدنی مختلف به کار برده‌اند [۷-۱۰]. روش‌های زمین‌آماري به میزان قابل ملاحظه‌ای در شناخت عیار، تناژ و رده‌بندی صحیح ذخیره کانسار به طراح کمک می‌کند. منشا چنین امری در قابلیت‌های ذاتی این روش‌ها همچون نااریب بودن خطای تخمین، ارایه واریانس تخمین، توجه به تداوم و پیوستگی ماهیت فضایی داده‌ها است. در مطالعات معدنی، روش‌های زمین‌آماري برای تخمین عیار و ذخیره قابل‌بازایی در مقایسه با روش‌های دیگر ارجحیت داده شده است. چرا که روش‌های زمین‌آماري بسیار مناسب و قابل اعتماد برای مدل‌سازی و توزیع فضایی عیارهای ماده معدنی و ذخیره‌اند [۵، ۱۲، ۱۱].

ذخایر معدنی بر اساس ارزیابی عیارها و تناژها از طریق یک روش تخمین از قبیل کریجینگ ساده، کریجینگ معمولی، کریجینگ لاگ نرمال، کریجینگ شاخص، کوکریجینگ، کریجینگ عمومی و شبیه‌سازی تصادفی مانند شبیه‌سازی متوالی گاوسی و شبیه‌سازی شاخص متوالی ارزیابی می‌شوند [۱۳]. اهمیت انتخاب روش‌های مناسب تخمین برای ارزیابی پروژه و برنامه‌ریزی کوتاه‌مدت و بلندمدت کانسارها ضروری است. در طول سال‌ها، روش‌های متعددی مانند روش‌های کلاسیک و روش زمین‌آماري برای تخمین ذخیره ماده معدنی تکامل یافته است [۱۸-۱۴].

بر حسب اینکه تخمین زمین‌آماري در چه شرایطی از نظر ساختار داده‌ها، توزیع داده‌ها، روند تغییرات داده‌ها، وجود یا عدم وجود روند، درجه ناهم‌هنگی و پیوستگی و هدف تخمین فاز اکتشافی انجام می‌گیرد، با حفظ اصول کریجینگ روش‌هایی برای غلبه بر نوع خاصی از مسایل توسعه یافته است.

کریجینگ معمولی و شبیه سازی متوالی گاوسی و همچنین شبکه عصبی مصنوعی برای تخمین عیار- تناژ کانسار آهن لکه سیاه است.

۲- روش های مورد استفاده

در این بخش، روش های به کار برده شده برای مدل سازی عیاری و تخمین ذخیره کانسار لکه سیاه معرفی می شوند.

۲-۱- کریجینگ معمولی

کریجینگ یک ابزار آماری است که برای برآورد عیار بلوک به صورت ترکیب خطی از نمونه های موجود در داخل بلوک و یا در نزدیکی آن به کار می رود، که بر منطق میانگین متحرک وزن دار استوار و از این رو دارای حداقل واریانس است. از مهم ترین ویژگی های کریجینگ آن است که به ازای هر تخمین، خطای مرتبط با آن را می توان محاسبه کرد. بر اساس همین خاصیت امکان تعیین موقعیت بهینه نمونه برداری های آتی وجود دارد [۲۶]. کریجینگ معمولی که پرکاربردترین ابزار تخمین در زمین آماری است [۲۷]، یک روش تخمین محلی است که وزن ها را به گونه ای اختصاص می دهد که خطای تخمین به حداقل برسد [۲۸]. در کریجینگ معمولی عیار یک بلوک یعنی $Z^*_{(V)}$ به وسیله ترکیب خطی از اطلاعات همجوار به ترتیب رابطه ۱ تخمین زده می شود.

$$Z^*_{(V)} = \sum_{i=1}^n \lambda_i Z_{(v_i)} \quad (1)$$

که در آن:

$Z^*_{(V)}$: مقدار تخمینی برای بلوک (V) (عیار تخمینی)

n : تعداد نمونه های نزدیک یا همجوار بلوک (V)

$Z_{(v_i)}$: مقدار نمونه در موقعیت V_i

λ_i : ضریب وزنی اعمال شده بر نمونه i است.

۲-۲- شبیه سازی زمین آماری

روش شبیه سازی زمین آماری در سال ۱۹۷۰ توسط ژورنل مطرح شده است. روش شبیه سازی متوالی گاوسی، یکی از روش های معمول و انعطاف پذیر است که امروزه در بسیاری از شبیه سازی ها که بر روی پارامترهایی چون عیار انجام می گیرد، فراوان استفاده می شود [۲۹]. روش شبیه سازی گاوسی، از مهم ترین روش های غیرخطی زمین آماری است.

طی سه دهه گذشته، از زمین آمار برای توصیف تنوع مکانی و پیش بینی عیاری استفاده شده است. کریجینگ معمولی، مفیدترین روش تخمین آماری است که بهترین برآوردگر نااریب خطی نیز نامیده می شود [۲۰، ۱۹]. مهم ترین مشخصات منفی برآوردگرهای میانگین متحرک مانند کریجینگ اثر هموارسازی و کاهش دامنه تغییرات متغیرهاست. از شبیه سازی زمین آماری برای غلبه بر این مساله و جلوگیری از اثر هموارسازی چنین روش های تخمینی به طور گسترده استفاده می شود [۲۱].

در روش های زمین آماری و شبیه سازی، عواملی مانند ساختار زمین شناسی، محیط تشکیل، شکل ذخیره، تیپ کانسار، درجه کانی سازی در تخمین عیار موثرند، بنابراین تلاش هایی انجام گرفت تا از تخمین گرهای غیرخطی شبیه شبکه عصبی مصنوعی برای غلبه بر ارتباط فضایی پیچیده استفاده شود و سایر عوامل غیر از فاصله را در تخمین دخیل کند [۲۲]. امروزه رویکرد شبکه عصبی مصنوعی در بسیاری از شاخه های مهندسی اعمال شده است. در سال های اخیر، به نظر می رسد شبکه های عصبی مصنوعی، از میان ابزارهای متعدد محاسبات نرم، به عنوان ابزاری قابل اعتماد برای تخمین ذخیره در بین متخصصان به دلیل توانایی اثبات شده آن ها در مدل سازی رابطه غیرخطی که معمولاً با داده های نمونه همراه است، محبوبیت پیدا کرده باشد [۲۵-۲۳].

در این پژوهش، روش های گوناگون زمین آماری برای مدل سازی بلوک های اکتشافی به کار گرفته خواهد شد. روش های زمین آماری پیشرو که بر مبنای همبستگی مطالعه شده به وسیله بررسی واریوگرام استوار است، علاوه بر پیش بینی عیار، میزان خطا و در نهایت توزیع خطا را ارائه می دهد که به نوبه خود یکی از ویژگی های مثبت این روش است. متأسفانه کمینه کردن خطا (که خود ویژگی منحصر به فرد دیگر این روش هاست)، سبب هموارشدگی در داده های درون یابی شده می شود که خود یکی از مشکلات مهم این روش است، بدین سبب از روش شبیه سازی زمین آماری برای جبران این مشکل استفاده می شود. روش های شبیه سازی گاوسی که مبتنی بر ویژگی های آنتروپی و هم پیوندی بنا شده است، مشکل هموارشدگی داده های درون یابی شده را اصلاح می کنند. البته رهیافت شبیه سازی، رهیافتی احتمال محور است که خود نیازمند ارزیابی عدم قطعیت است.

هدف از پژوهش حاضر مقایسه عملکرد مدل سازی و تخمین توزیع عیار ماده معدنی آهن به روش های غیرخطی

این الگوریتم به داده‌های استاندارد نرمال برای انجام شبیه‌سازی نیاز دارد. برای هر گره که در آن عمل شبیه‌سازی انجام می‌گیرد، روش شبیه‌سازی گاوسی، یک هیستوگرام محلی ایجاد می‌کند که از آن یک مقدار (عدد) به طور تصادفی به عنوان مقدار شبیه‌سازی شده بیرون کشیده می‌شود. مراحل اصلی شبیه‌سازی متوالی گاوسی به قرار زیر است [۳۰]:

- (۱) رسم هیستوگرام داده‌های اولیه و تبدیل این داده‌ها به استاندارد نرمال $(N(0,1))$
- (۲) رسم واریوگرام با استفاده از داده‌های نرمال استاندارد شده

- (۳) انتخاب یک مسیر (شبکه) تصادفی برای شبیه‌سازی
- (۴) تخمین داده‌ها بر روی شبکه انداخته شده با استفاده از یکی از روش‌های کریجینگ و رسم هیستوگرام با داشتن میانگین و واریانس تخمین در هر نقطه
- (۵) بیرون کشیدن یک عدد به طور تصادفی از هیستوگرام رسم شده

- (۶) شرطی کردن داده‌ها
- (۷) تکرار مراحل قبل تا اینکه کلیه شبکه دارای عدد شود.
- (۸) برای انجام شبیه‌سازی دیگر، کلیه مراحل قبل دوباره تکرار می‌شوند.
- (۹) تبدیل معکوس داده‌ها به حالت قبل
- (۱۰) اعتبارسنجی نتایج

شاید بزرگ‌ترین مشکل برای استفاده از روش شبیه‌سازی گاوسی، انتخاب شعاع جستجو باشد. انتخاب شعاع همسایگی کوچک به شرطی‌سازی ضعیف داده‌ها منجر می‌شود [۳۱].

۲-۳- روش شبکه عصبی مصنوعی

طی ۳۰ سال گذشته، زمین‌آمار به ثابت‌ترین روش برای تخمین عیار تبدیل شده است. با این حال، زمین‌آمار بر اساس پیش‌فرض‌های خاصی در مورد توزیع فضایی عیارهای ماده معدنی داخل کانسار بنا شده است. اثرات این مفروضات به ایجاد روش‌های بسیار پیچیده‌تری منجر شده است که برای کاربرد موثر به دانش زیادی نیاز دارند. نیاز به یک روش جدید برای تخمین عیار ماده معدنی برای غلبه بر مشکلات به کارگیری روش‌های متداول مانند زمین‌آمار احساس می‌شود. یک رویکرد جایگزین که به ویژه در دهه گذشته مورد توجه قرار گرفته است، استفاده از سیستم‌های شبکه عصبی مصنوعی برای تخمین عیار است. شبکه‌های عصبی مصنوعی اساسی عملکرد موجود در داده‌ها را از نمونه‌هایی که در دسترس آن‌ها

قرار گرفته است می‌آموزند. برای آموزش شبکه، داده‌های عیار در موقعیت گمانه‌های حفر شده به صورت مرتب به شبکه نشان داده می‌شود تا آموزش ببینند. با ارایه تعداد کافی از مثال‌های آموزشی، شبکه رابطه بین الگوهای ورودی، مختصات و الگوهای خروجی مانند عیار کانسار را می‌یابد و سپس این رابطه را برای درون‌یابی عیار بین گمانه‌ها تعمیم می‌دهد [۲۴]. یک شبکه عصبی رابطه متقابل ورودی و خروجی را از طریق گروهی از واحدهای پردازشی به نام نورون ضبط می‌کند. نورون‌ها در مجموعه‌ای از لایه‌های نورون‌های ورودی، پنهان و خروجی قرار گرفته‌اند. لایه ورودی از ورودی‌ها، یک یا چند لایه مخفی از تعدادی نورون پنهان تشکیل شده و لایه خروجی از خروجی‌ها تشکیل شده است، بنابراین یک شبکه عصبی سه یا چند لایه دارد. هر نورون ورودی در ارتباط با هر نورون لایه پنهان است، همان‌طور که نورون لایه پنهان از طریق مجموعه‌ای از وزن‌های اتصال به هر گره لایه خروجی متصل می‌شود. معمولاً وزن‌های اتصال، از طریق فرآیندی به نام آموزش، با معرفی مجموعه‌ای از الگوهای ورودی-خروجی شناخته شده به شبکه تنظیم می‌شوند، به طوری که وزن‌های نهایی خروجی‌هایی نزدیک به خروجی‌های واقعی تولید می‌کنند. از طریق فرآیند آموزش، شبکه خصوصیات عمومی رابطه ورودی و خروجی یک سیستم را فرا می‌گیرد و بنابراین فراتر از نقاط داده آموزش کار می‌کند.

۲-۴- منحنی عیار- تناژ

منحنی عیار- تناژ نمایشی بصری از تاثیر عیارهای حد بر ذخایر معدنی است. منحنی‌های عیار و تناژ می‌توانند چندین عامل اصلاح کننده را به طور همزمان برای تخمین ذخایر معدنی در نظر بگیرند. منحنی عیار- تناژ یکی از ابزارهای بسیار مهم است که مدیران معدن را قادر می‌سازد تا برنامه صحیح بلندمدت، متوسط و کوتاه‌مدت را برای فرآیند تولید در ذخایر معدنی ارایه دهند. ترسیم منحنی‌های تناژ-عیار مورد نیاز است تا تناژ در عیارهای مختلف به دست آید. با توجه به داده‌های عیاری از هر بلوک، ما می‌توانیم ذخیره معدنی را بر اساس عیار حدهای مختلف محاسبه کنیم [۳۲].

۳- کانسار لکه سیاه


ناحیه معدنی بافق یکی از مهم‌ترین ایالت‌های فلزایی در ایران محسوب می‌شود که میزبان بزرگ‌ترین ذخایر آهن غیررسوبی یا گرمابی است [۳۳]. این ناحیه با بیش از ۱/۷

۴- بحث

در مرحله اولیه اکتشاف آهن در منطقه مورد مطالعه، برای دستیابی به اطلاعات عمقی، حفاری در یک شبکه با فواصل متغیر با ۲۹ گمانه انجام شده است. فاصله شبکه حفاری‌ها در قسمت‌های داخلی با توجه به این که به صورت عمودی حفر شده‌اند، حدود ۵۰ متر بوده و در حاشیه‌ها زیاد شده است. کل حفاری انجام شده ۴۲۷۳٫۱ متر است. عمق گمانه‌ها از ۳۴ متر تا ۱۹۴ متر با عمق متوسط ۱۴۲ متر متغیر است. پایگاه داده زمین‌شناسی شامل جزییات سنگ‌شناسی، ساختاری و کانی‌شناسی است. بررسی فایل آنالیز نمونه‌ها نشان می‌دهد که در ۱۲۴۷ نمونه آنالیز شده محدوده مورد مطالعه، حداقل و حداکثر طول نمونه‌ها به ترتیب ۰٫۴ و ۷۴٫۸۵ متر است. به طور متوسط از هر ۲ متر طول حفاریات از کانسنگ احتمالی به عنوان یک نمونه مورد آنالیز قرار گرفته است. در مجموع از حدود ۴۲۷۳٫۱ متر حفاری از گمانه‌ها، حدود ۱۲۴۷ متر

میلیارد تن ذخیره آهن- فسفر- منگنز در بیش از ۳۴ آنومالی مغناطیس هوایی، محدوده‌ای به وسعت ۷۵۰۰ کیلومترمربع را پوشش می‌دهد. عیار آهن در آن‌ها بین ۵۰ تا ۷۰ درصد وزنی برآورد شده است [۳۴].

کانسار آهن $\pm$ آپاتیت لکه‌سیاه در ایالت فلزایی بافق- ساغند و پهنه ساختاری ایران مرکزی قرار دارد (شکل ۱) [۳۵]. کانسار آهن $\pm$ آپاتیت لکه‌سیاه در استان یزد به وسعت تقریبی ۵ کیلومترمربع در مختصات جغرافیایی $31^{\circ} 46' 47''$ و $55^{\circ} 42' 56''$ طول شرقی و $31^{\circ} 46' 47''$ عرض شمالی در فاصله ۴۰ کیلومتری شمال شرق بافق، بین معادن منیتیت- آپاتیت اسفوردی و سرب و روی کوشک واقع شده است. راه دستیابی به این کانسار از طریق جاده آسفالت بافق- بهاباد پس از طی ۳۸ کیلومتر از مسیر آبراهه‌های شمالی جاده به طرف کانسار امکان‌پذیر است. در این کانسار توده‌های منیتیت و هماتیت به همراه کانی‌های باطله آپاتیت و کوارتز در مرحله کانی‌سازی اصلی تشکیل شده‌اند.



شکل ۱: نقشه ساختاری بخش شرقی- مرکزی ایران و جایگاه پهنه‌ی زمین‌ساختی کاشمر- کرمان و کانسار لکه سیاه در آن (SSZ: پهنه‌ی سسندج- سیرجان، CIZ: پهنه‌ی ایران مرکزی، PB: بلوک پست بادام) [۳۵]

مقادیر پرعیار است (شکل ۲).

۴-۱-۱- بررسی وجود روند در داده‌ها

یکی از مسائلی که ممکن است تخمین‌های زمین‌آماري را دچار مشکل کند، وجود روند در داده‌ها است که باید شناسایی و حذف شود. برای بررسی وجود روند در داده‌ها باید میزان پراکندگی هر متغیر ناحیه‌ای در سه جهت X ، Y و Z بررسی شود.


جدول ۱: پارامترهای آماری عیارها در کل نمونه‌ها

پارامتر	P (%)	S (%)	FeO (%)	Fe (%)
تعداد نمونه	۱۲۴۷	۱۲۴۷	۱۲۴۷	۱۲۴۷
مینیموم	۰/۰۰۷۵	۰	۰/۵۴	۰/۵۳
ماکزیمم	۶/۲۷۵۴	۳/۳۵	۲۳/۵	۷۲/۳۴
میانگین	۰/۱۵۳۶۲۸	۰/۱۱۱۸۴۵	۱۱/۷۰۱۱۳	۳۷/۹۴۵۰۳
واریانس	۰/۱۴۲۲۳۹	۰/۰۷۵۶۷۵	۵۱/۲۲۳۷	۴۴۸/۷۸۸۲
انحراف معیار	۰/۳۷۷۱۴۶	۰/۲۷۵۰۹۱	۷/۱۵۷۰۷۴	۲۱/۱۸۴۶۲
چولیدگی	۸/۷۰۴۵۵۴	۶/۳۷۱۷۷۶	-۰/۰۳۲	-۰/۱۱۸۳۲
کشدگی	۱۰۴/۴۰۵	۴۸/۱۰۶۵۴	-۱/۴۳۰۶۱	-۱/۴۴۹۱۵

نمونه‌برداری انجام گرفته است و از داده‌های مربوطه برای مطالعه مدل‌سازی و تخمین استفاده می‌شود. به طور عمده طول نمونه‌های برداشت شده در حدود ۲ متر است و با توجه به ضخامت متوسط ماده معدنی در لاگینگ حفريات و رخنمون‌ها، طول و فاصله مناسب برای کامپوزیت کردن (یکسان‌سازی عیاری) حدود ۲ متر در نظر گرفته می‌شود.

۴-۱-۲ آنالیز آماری پایه


یکی از مهم‌ترین مراحل در تجزیه و تحلیل داده‌ها، بررسی‌های آماری نمونه‌های آنالیز شده است که طی آن پارامترهای آماری مورد نیاز به دست می‌آید. تعداد نمونه‌ها در محدوده لکه‌سیاه، ۱۲۴۷ نمونه است که برای این تعداد نمونه پارامترهای توزیع داده‌ها، مقدار میانگین، واریانس و انحراف معیار برای پارامترهای آنالیز شده محاسبه شده است (جدول ۱). مقادیر نمونه کامپوزیت حفاری برای مدل‌سازی توزیع فراوانی مقادیر آهن مورد تجزیه و تحلیل قرار گرفت. بررسی نمودارها نشان می‌دهد جامعه دارای توزیع دو مدي است که یک مد آن مربوط به مقادیر کم‌عیار و یک مد آن مربوط به




شکل ۲: توزیع فراوانی عیار آهن نمونه‌ها

گرفته است و موقعیت سطح فرسایش نسبت به توده به چه صورت است. شکل‌های ۳، ۴ و ۵، برای بررسی وجود روند در داده‌ها رسم شده است. با توجه به نمودارهای نشان داده شده، می‌توان نتیجه گرفت که متغیر آهن هیچ‌گونه روندی نشان نمی‌دهد.


در مورد ذخیره لکه سیاه، عیار آهن به عنوان تابعی از عمق در نظر گرفته و نمودار پراکندگی آن‌ها ترسیم شد تا در صورت مشاهده روند بارز در تغییرات عیار، این روند حذف شود. با توجه به روند تغییرات عیار آهن نسبت به عمق می‌توان نتیجه گرفت که توده اصلی کانسار در چه عمقی قرار



شکل ۳: نمودار روند تغییرپذیری متغیر آهن در امتداد محور X



شکل ۴: نمودار روند تغییرپذیری متغیر آهن در امتداد محور Y



شکل ۵: نمودار روند تغییرپذیری متغیر آهن در امتداد عمق

۴-۲- واریوگرافی

دومین مرحله در مدل‌سازی عیاری و پایه و اساس کلیه روش‌های تخمین و درون‌یابی زمین‌آماري، انجام مطالعات واریوگرافی و تعیین پارامترهای تخمین است. واریوگرافی شامل بررسی پیوستگی (همبستگی فضایی) و میزان تغییرات متغیر ناحیه‌ای (عیار ماده معدنی، درصد عناصر مزاحم، ضخامت و نظایر آن)، تعیین وضعیت همسانگردی و ناهمسانگردی توده معدنی و در نهایت تعیین ساختار فضایی و پارامترهای تخمین با استفاده از ابزار واریوگرام است. ما واریوگرام و تکنیک کریجینگ را برای درون‌یابی مقادیر مورد نیاز برای تخمین منابع معدنی به کار می‌بریم.

برای انجام تخمین مناسب و نیز تعیین پارامترهای مورد نیاز برای شبیه‌سازی لازم است تا مطالعات واریوگرافی صحیح انجام گیرد. در ابتدا برای پی بردن به جهت اصلی ناهمسانگردی واریوگرام غیرجهتی رسم شد و بعد از مشخص شدن جهت اصلی کانی‌زایی، واریوگرام جهتی رسم شد (شکل‌های ۶ و ۷) (جدول‌های ۲ و ۳). لازم به ذکر است که بهترین حالت انتخابی، حالتی در نظر گرفته شد که ۱: کمترین واریانس، ۲: کمترین اثر قطعه‌ای، ۳: بیشترین دامنه و ۴- بیشترین انطباق را با مدل برازش داده شده داشته باشد. در اصل هدف بر این است که واریوگرام جهت‌دار بررسی شود، بنابراین چون آزمون از صفر

تا ۳۶۰ و شیب هم از صفر تا ۹۰ تغییر می‌کند، برای بررسی واریوگرام در جهات مختلف، میزان افزایش شیب و آزمون با تغییرات ۱۵ درجه در نظر گرفته شد تا کل جهات پوشش داده شود. با توجه به واریوگرافی انجام گرفته، مشخصات بیضوی جستجو برای هر سه متغیر در جدول ۴، آمده است (شکل ۸). با توجه به مشخص شدن پارامترهای بهینه واریوگرام و بیضوی جستجو برای متغیر آهن، حال می‌توان از تخمینگر کریجینگ برای تخمین بلوک‌های عیاری استفاده کرد.

۴-۳- اعتبارسنجی واریوگرام

یکی از روش‌های کنترل صحت مدل برازش شده به واریوگرام، روش اعتبارسنجی متقابل یا ارزش‌گذاری مجدد است. بدین منظور با استفاده از نتایج واریوگرام در هر مرحله، یکی از داده‌ها حذف و مقدار آن بر اساس داده‌های واقعی در محدوده جستجو تخمین زده، سپس پارامترهای خطای میانگین، توان دوم انحراف از میانگین و نسبت توان دوم انحراف از میانگین محاسبه شده‌اند (جدول ۵). برای اعتبارسنجی مدل برازش داده شده به واریوگرام از ۵۶۰۱۰ داده دارای فیلدهای اطلاعات موقعیت جغرافیایی و عیار آهن استفاده و سپس از روش ارزش‌گذاری مجدد مقادیر تخمینی و واریانس کریجینگ تمامی نقاط محاسبه شد. ضریب همبستگی مقادیر تخمینی و مقادیر واقعی برابر با ۰/۸۷، به دست آمد که مقداری مناسب

استاندارد نرمال تبدیل می شود. به این منظور که کلیه داده ها باید به استاندارد نرمال تبدیل شود که در نرم افزار Datamine این نرمال سازی انجام گرفت. بعد از نرمال کردن داده ها، به دست آوردن محورهای بیضوی جستجو و مشخصات آن ها (پارامترهای واریوگرافی) به روش شبیه سازی گاوسی متوالی نیز انجام شد. در پژوهش حاضر با استفاده از نرم افزار SGeMS، ۱۰ تحقق برای منطقه مورد نظر انجام گرفت. در روش های معمول برای به دست آوردن بهترین تحقق، واریوگرام های حاصل با واریوگرام کلی داده های اولیه مقایسه شده و تحقق های برتر از طریق میزان انطباق، انتخاب می شوند. بعد از به دست آوردن ۱۰ تحقق به تهیه نقشه مقدار میانگین اقدام شد که این نقشه با میانگین گیری از کل تحقق ها به دست می آید. این نقشه، مقدار متوسط نهایی تخمین را برای هر بلوک با میانگین گیری بین مقادیر حاصل از ۱۰ تحقق نشان می دهد. اساس این نقشه آن است که برای هر بلوک از ۱۰ مقدار شبیه سازی شده خاص آن بلوک میانگین حسابی گرفته می شود، بدین ترتیب میانگین از کل منطقه حاصل می شود، سپس داده ها معکوس شده (از حالت نرمال خارج شدند) و به بازه داده های اولیه بازگشته و سپس دوباره وارد نرم افزار شدند. داده های متغیر ناحیه ای عیار آهن که به توزیع نرمال تبدیل شده اند، بر اساس مدل


تشخیص داده شد (شکل ۹). با توجه به فضای تخمین و فاصله نمونه برداری، اندازه بلوک ها $2 \times 2 \times 2$ متر انتخاب و تخمین در نرم افزار دیتامین انجام شده است. بر اساس بررسی انجام گرفته حداقل و حداکثر نقاط شرکت کننده در تخمین ۴ و ۱۵ و ابعاد بلوک برای مدل سازی و شبیه سازی $2 \times 2 \times 2$ انتخاب شد.

۴-۴- تخمین عیار به روش کریجینگ


روش کریجینگ یکی از پرکاربردترین و کامل ترین روش های تخمین و درون یابی بوده که در آن بیشتر شرایطی که برای روش های تخمین گفته شده، در نظر گرفته می شود. یکی از ویژگی های منحصر به فرد کریجینگ، تعیین واریانس تخمین یا تعیین مقدار خطای هر تخمین است. نتایج حاصل از بلوک های تخمینی آهن در زون کانی زایی کانسار آهن لکه سیاه به همراه حفريات اکتشافی به روش کریجینگ معمولی در شکل ۱۰، ارایه شده است.

۴-۵- تخمین عیار به روش شبیه سازی متوالی گاوسی


در این بخش به تخمین عیار به روش شبیه سازی گاوسی متوالی در کانسار آهن لکه سیاه پرداخته شده است. داده های مربوط به متغیر ناحیه ای با استفاده از توابع چند جمله ای هرمیت به توزیع




شکل ۶: تعیین میزان همبستگی فضایی، اندازه شعاع تاثیر برای کانسار آهن لکه سیاه



(ب)



(الف)



(ج)

شکل ۷: الف) واریوگرام عیار آهن در کانسار آهن لکه‌سیاه و مدل برازش داده شده به آن، الف) در راستایی با آزمون ۱۵۰ و شیب صفر، ب) در راستایی با آزمون ۲۴۰ و شیب ۷۵ و ج) در راستایی با آزمون ۶۰ و شیب ۱۵

جدول ۳: مشخصات پارامترهای مدل واریوگرام جهت‌دار برای کانسار آهن لکه‌سیاه

مدل واریوگرام	آزمون	شیب	اثر قطعه‌ای	دامنه تأثیر (متر)	آستانه ۲ (%)
کروی	۲۴۰	۷۵	۱۳۷/۲۲۱	۸۵	۳۱۰/۱۲
کروی	۱۵۰	۰	۱۳۷/۲۲۱	۶۲	۳۱۰/۱۲
کروی	۶۰	۱۵	۱۳۷/۲۲۱	۱۰۸	۳۱۰/۱۲

جدول ۲: مشخصات پارامترهای مدل واریوگرام غیرجهتی برای کانسار آهن لکه‌سیاه


مدل واریوگرام	آزمون	شیب	اثر قطعه‌ای	دامنه تأثیر (متر)	آستانه ۲ (%)
کروی	-	-	۱۳۱/۸۱	۹۲	۳۲۶/۴۹

در صورتی که داده های حاصل از شبیه سازی بتواند نمودار توزیع داده های اولیه را مجددا تولید کند، اعتبار نتایج حاصل از شبیه سازی تایید می شود. مشخصات آماری نتایج در جدول ۶، ارائه شده است. آمارها نشان می دهند نتایج شباهت بالایی با یکدیگر دارند. نتایج مدل سازی E-type در شکل ۱۱ آورده شده است. این نقشه مقدار متوسط نهایی تخمینی برای هر بلوک با میانگین گیری بین مقادیر شبیه سازی شده حاصل از ۱۰ تحقق را نشان می دهد.

واریوگرام به دست آمده از بررسی ساختار به تعداد ۱۰ مرتبه در داخل فضای بلوکی با استفاده از شبیه سازی متوالی گاوسی شبیه سازی شدند. بدین صورت که برای هر بلوک، ۱۰ داده حاصل از شبیه سازی موجود است. مقادیر شبیه سازی شده همگی در بازه +۱ و -۱ قرار دارند چرا که محصول شبیه سازی، مقادیر نرمال استاندارد است. در مرحله بعد، با استفاده از تابع برگشتی تعریف شده و نیز بازه تعریف شده اولیه، کلیه داده های حاصل از شبیه سازی به ابعاد اولیه خود تبدیل شدند.

جدول ۴: مشخصات فضای جستجو براساس دامنه واریوگرام در کانسار آهن لکه سیاه


شماره بیضوی	محورهای ناهمسانگردی	زاویه چرخش محور (درجه)	محور چرخش	شعاع جستجو (متر)	حداقل تعداد نقاط	حداکثر تعداد نقاط
۱	محور اصلی	۱۰۵	X	۱۰۸	۴	۱۵
	محور فرعی	۰	Y	۸۵	۴	۱۵
	محور نیمه اصلی	۶۰	Z	۶۲	۴	۱۵
۲	محور اصلی	۱۰۵	X	۱۶۲	۴	۱۵
	محور فرعی	۰	Y	۱۲۷٫۵	۴	۱۵
	محور نیمه اصلی	۶۰	Z	۹۳	۴	۱۵
۳	محور اصلی	۱۰۵	X	۲۳۷٫۶	۴	۱۵
	محور فرعی	۰	Y	۱۸۷	۴	۱۵
	محور نیمه اصلی	۶۰	Z	۱۳۶٫۴	۴	۱۵




شکل ۸: بیضوی ناهمسانگردی غیرجهتی همراه با گمانه های اکتشافی در کانسار آهن لکه سیاه (دید به سمت جنوب)

جدول ۵: پارامترهای مورد مطالعه اعتبارسنجی در کانسار آهن لکه‌سیاه

پارامتر	مقدار محاسبه شده	توضیح
میانگین خطا	-۰٫۰۰۰۴	مقدار مطلوب صفر است
توان دوم انحراف از میانگین	۰٫۲۷	هرچه کمتر باشد بهتر است
نسبت توان دوم انحراف از میانگین	۱٫۱	هرچه به یک نزدیکتر باشد، بهتر است




شکل ۹: نتایج حاصل از اعتبارسنجی مدل کروی برازش داده شده به واریوگرام کانسار لکه‌سیاه



شکل ۱۰: بلوک‌های تخمین خورده آهن در زون کانی‌زایی کانسار آهن لکه‌سیاه به همراه حفاریات اکتشافی به روش کریجینگ معمولی (دید انتخابی)

جدول ۶: مشخصات آماری نتایج حاصل از شبیه سازی در ۱۰ مرتبه شبیه سازی متفاوت

واریانس	میانگین	بیشینه	کمینه	تعداد	داده ها
۴۳۳,۰۵۹	۳۴,۲۳۸	۷۰,۹۶۰	۰,۵۳۰	۱۳۶۷	نمونه ها
۴۳۳,۳۴	۳۴,۲۱۲	۷۰,۹۵۱	۰,۰۰۳	۳۲۳۵۵۸	۱
۴۳۳,۲۱۱	۳۴,۱۹۳	۷۰,۹۵۷	۰,۰۱۰	۳۲۳۵۵۸	۲
۴۳۳,۹۱۰	۳۴,۲۷۱	۷۰,۹۱۹	۰,۰۰۰	۳۲۳۵۵۸	۳
۴۳۳,۰۹۰	۳۴,۲۵۱	۷۰,۹۵۵	۰,۰۱۳	۳۲۳۵۵۸	۴
۴۳۳,۶۶۴	۳۴,۱۶۶	۷۰,۹۲۵	۰,۰۰۸	۳۲۳۵۵۸	۵
۴۳۳,۷۲۴	۳۴,۱۴۶	۷۰,۹۳۹	۰,۰۰۵	۳۲۳۵۵۸	۶
۴۳۳,۷۶۹	۳۴,۲۷۵	۷۰,۹۶۰	۰,۰۰۱	۳۲۳۵۵۸	۷
۴۳۳,۷۱۹	۳۴,۱۹۶	۷۰,۹۵۵	۰,۰۰۶	۳۲۳۵۵۸	۸
۴۳۳,۱۰۱	۳۴,۲۰۸	۷۰,۹۴۱	۰,۰۰۴	۳۲۳۵۵۸	۹
۴۳۳,۲۷۴	۳۴,۲۰۶	۷۰,۹۳۸	۰,۰۰۳	۳۲۳۵۵۸	۱۰
۴۳۳,۷۶۹	۳۴,۲۱۳	۷۰,۹۶۰	۰,۰۰۰	۳۲۳۵۵۸	مجموع



شکل ۱۱: بلوک های تخمین خورده آهن در زون کانی زایی کانسار آهن لکه سیاه به همراه حفريات اکتشافی به روش شبیه سازی گاوسی (تحقق E-type) (دید انتخابی)


۴-۶- تخمین عیار به روش شبکه عصبی مصنوعی

برای تخمین عیار، ابتدا با استفاده از داده های گمانه های واقعی (گمانه ها که x , y , و z عیار دارند) به آموزش شبکه پرداخته شد که x , y و z به عنوان داده ورودی به شبکه عصبی و عیار به عنوان داده خروجی در نظر گرفته شد تا ارتباط میان x , y و z با عیار مشخص شود. در واقع چنین شبکه ای قادر است ارتباط بین مختصات فضایی و عیار مربوطه را شناخته و با منطق تعمیم برای سایر نقاط فضا، عیار را تخمین بزند. به

این ترتیب تعداد سلول های میانی به ۱۰ سلول افزایش داده شد تا نوسانات همگرایی در حد مطلوبی قرار گیرد. شبکه برای گره های مختلف آموزش داده شد و درصد خطا در مدل شبکه عصبی محاسبه گردید (جدول ۷). نتایج نشان داد که شبکه ای با ۸ گره مخفی دارای بهترین عملکرد و بهترین نتایج است. بعد از آموزش شبکه و دستیابی به الگوی توزیع عیار، تخمین عیار برای تمام بلوک ها در کانسار آهن لکه سیاه انجام گرفت. شکل ۱۲، نتایج این تخمین را نشان می دهد.

جدول ۷: نتایج به دست آمده از شبکه‌های عصبی مختلف (بهترین شبکه به صورت برجسته نشان داده شده است).

ردیف	تعداد نرون‌ها در لایه مخفی	الگوریتم آموزش	آموزش			تست			اعتبارسنجی		
			R ²	SSE	RMSE	R ²	SSE	RMSE	R ²	SSE	RMSE
۱	۲	SCG	۰/۶۱	۱/۷۱	۰/۶۶	۰/۶۳	۱/۸	۰/۵۳	۰/۶۳	۱/۸۲	۰/۵۷
۲	۳	SCG	۰/۵۵	۱/۶۸	۰/۶۸	۰/۶۱	۱/۷۴	۰/۵۹	۰/۶	۱/۷۲	۰/۵۸
۳	۴	LM	۰/۵۱	۱/۶۲	۰/۷۲	۰/۵۴	۱/۷۳	۰/۶۴	۰/۵۷	۱/۶۱	۰/۷۳
۴	۵	LM	۰/۴۹	۱/۵۹	۰/۷۹	۰/۵۸	۱/۶۲	۰/۷۲	۰/۵۸	۱/۶۶	۰/۶۴
۵	۶	LM	۰/۴۴	۱/۵۴	۰/۸۱	۰/۵۶	۱/۶۳	۰/۷۳	۰/۵۴	۱/۵۵	۰/۷۸
۶	۷	LM	۰/۴۳	۱/۴۱	۰/۸۷	۰/۵	۱/۵۹	۰/۷۸	۱/۵۴	۱/۵۵	۰/۷۳
۷	۸	LM	۰/۳۹	۱/۳۷	۰/۸۹	۰/۴۸	۱/۴۹	۰/۸۱	۰/۵۹	۱/۵۹	۰/۸۴
۸	۹	LM	۰/۳۷	۱/۲۴	۰/۹۳	۰/۳۵	۱/۱۴	۰/۸۸	۰/۵۴	۱/۵۶	۰/۸۹
۹	۱۰	SCG	۰/۶۳	۱/۴۶	۰/۹۰	۰/۴۴	۱/۵۹	۰/۸۴	۰/۵۴	۱/۵۶	۰/۸۵
۱۰	۱۱	SCG	۰/۷۲	۱/۵۱	۰/۸۷	۰/۵۴	۱/۶۲	۰/۸۱	۰/۶۸	۱/۷۶	۰/۷۹



شکل ۱۲: بلوک‌های تخمین خورده آهن در زون کانی‌زایی کانسار آهن لکه‌سیاه به همراه حفاریات اکتشافی به روش شبکه عصبی مصنوعی (دید انتخابی)


۴-۷- منحنی عیار- تناژ

رسم منحنی عیار-تناژ نیازمند محاسبه تناژ متناظر برای عیارهای مختلف است. در پژوهش حاضر مقدار جرم مخصوص متوسط ماده معدنی بر اساس گزارش تست تکنولوژی معادل ۴/۳ گرم بر سانتی‌متر مکعب (تن بر مترمکعب) در نظر گرفته شده که با توجه به ابعاد بلوک‌های تخمینی، مقدار تناژ متناظر هر بلوک معادل ۳۴/۴ تن به دست خواهد آمد. در این پژوهش،


تخمین ذخیره با دو روش زمین‌آماري و شبکه عصبی مصنوعی انجام می‌شود. حال با توجه به عیار تخمینی بلوک‌ها و جرم مخصوص آن‌ها می‌توان به محاسبه مقدار ذخیره به ازای عیار حدهای مختلف پرداخت. در شکل‌های ۱۳، ۱۴ و ۱۵، منحنی عیار- تناژ و در جدول‌های ۸، ۹ و ۱۰، مقادیر عیار- تناژ محاسبه شده برای متغیر آهن در کانسار لکه‌سیاه ارایه شده است. نتایج حاکی از آن است که شبکه عصبی مقدار تناژ و

این موضوع حاکی از هموارشدگی عیار در روش شبکه عصبی است که باعث شده است عیارهای پایین به سمت مقادیر بالا کشیده شوند و در نتیجه مقدار عیار متوسط و همچنین تناژ از مقادیر واقعی خود بالاتر به دست آیند. برای مقایسه، نتایج نمودارهای عیار- تناژ و میزان همبستگی نتایج به وسیله روش های تخمین مختلف مورد استفاده، آورده شده است.


عیار متوسط را کمی بالاتر از حد تخمین خورده شده به وسیله کریجینگ تخمین زده است. علت این امر ممکن است زیادی الگوهای کانسنگ در سری آموزشی نسبت به الگوی باطله باشد که باعث می شود شبکه الگویی را که تعداد بیشتری از آن مثال در دست دارد بهتر و بیشتر یاد بگیرد و باعث شود که مقدار عیارهای پایین، کمتر از حد واقعی تخمین زده شود. به عبارتی



شکل ۱۱: بلوک های تخمین خورده آهن در زون کانی زایی کانسار آهن لکه سیاه به همراه حفريات اکتشافی به روش شبیه سازی گاوسی (تحقق E-type) (دید انتخابی)



شکل ۱۱: بلوک های تخمین خورده آهن در زون کانی زایی کانسار آهن لکه سیاه به همراه حفريات اکتشافی به روش شبیه سازی گاوسی (تحقق E-type) (دید انتخابی)



شکل ۱۱: بلوک‌های تخمین خورده آهن در زون کانی‌زایی کانسار آهن لکه‌سیاه به همراه حفاریات اکتشافی به روش شبیه‌سازی گاوسی (تحقق E-type) (دید انتخابی)

جدول ۸: جدول عیار-تناژ آهن کانسار لکه‌سیاه به روش کریجینگ معمولی

عیار حد (%)	میانگین (%)	تناژ (میلیون تن)
۲۰	۴۱/۴۷	۴۳۹/۲۵
۳۰	۴۴/۹۶	۳۹۰/۶۱
۴۰	۴۹/۴۵	۲۹۳/۵۳

جدول ۹: جدول عیار-تناژ آهن کانسار آهن لکه‌سیاه به روش شبیه‌سازی گاوسی

عیار حد (%)	میانگین (%)	تناژ (میلیون تن)
۲۰	۴۲/۶۷	۴۵۴/۳۹
۳۰	۴۵/۸۶	۴۱۱/۸۴
۴۰	۴۹/۹۰	۳۲۳/۰۸

جدول ۱۰: جدول عیار-تناژ آهن کانسار لکه‌سیاه به روش شبکه عصبی مصنوعی

عیار حد (%)	میانگین (%)	تناژ (میلیون تن)
۲۰	۴۲/۹۸	۴۵۰/۱۶۱۸
۳۰	۴۶/۴۳	۴۰۶/۷۰۳۳
۴۰	۵۰/۷۴	۳۲۰/۸۳۴۱

ذخیره انجام شد، سپس با استفاده از روش شبیه سازی متوالی گاوسی به عنوان روشی ساده و سودمند در زمین آمار برای شبیه سازی، تعداد ۱۰ شبیه سازی زمین آماری انجام شد و برای هر شبیه سازی تخمین ذخیره صورت گرفت. نتایج مدل سازی با روش شبکه عصبی مصنوعی نشان داد که شبکه عصبی با ۸ نرون در لایه مخفی و الگوریتم آموزش لونیگ مارکوات بهترین عملکرد را دارد.

مقایسه نتایج تخمین عیار میانگین، میزان ذخیره و ترسیم نمودارهای عیار- تناژ به ازای عیار حدهای مختلف با روش های تخمین مورد استفاده نشان می دهد که روش شبیه سازی به دلیل نزدیک بودن نتایج تخمین عیار و میزان ذخیره کانسار دقیق تر است. هرچند اعتبارسنجی نتایج به دست آمده از روش شبکه عصبی مصنوعی نشان داد که این تخمین اعتبار بسیار خوبی داشته و به علت سادگی استفاده و عدم نیاز به محاسبات سنگین واریوگرافی ممکن است جایگزین مناسبی برای روش های زمین آماری کریجینگ و شبیه سازی متوالی گاوسی باشد. روش های کریجینگ و شبیه سازی زمین آماری به دلیل در نظر گرفتن ساختار فضایی داده ها، خطای کمتری دارند که شبیه سازی زمین آماری به دلیل حذف اثر هموارسازی روش کریجینگ و محاسبه میزان تناژ ذخیره در سطح اعتماد ۹۵٪ دارای دقت بالاتری است، بنابراین در مورد کانسارهایی که پراکندگی داده های عیارسنجی آنها از توزیع نرمال پیروی نمی کنند، استفاده از روش های تخمین زمین آماری غیرخطی همانند شبیه سازی متوالی گاوسی گریزناپذیر است. اگرچه روش های تخمین زمین آماری غیرخطی پیچیدگی های خاص خود را دارند، به هر جهت در صورت درک درست مفاهیم نظری این روش ها و انتخاب درست پارامترهای آنها به هنگام تخمین، نتایج بسیار دقیق، سودمند و مطلوب خواهند بود. مقایسه تخمین عیار آهن به دست آمده به وسیله مدل های کریجینگ، شبیه سازی و شبکه عصبی مصنوعی کم و بیش الگوهای توزیع مشابهی را که نزدیک به داده های نمونه هستند، حفظ می کند، بنابراین پیشنهاد می شود برای به دست آوردن سناریوهای

روش های شبکه عصبی، شبیه سازی متوالی گاوسی، کریجینگ معمولی، به ترتیب بیشترین میزان عیار متوسط را تخمین زده اند. مطابق نمودارها، در مجموع اختلاف میزان ذخیره محاسبه شده با روش های مختلف مورد استفاده در این پژوهش، چندان زیاد نیست که البته مهم ترین دلیل این امر آن است که از دقیق ترین روش های تخمین زمین آماری استفاده شده، ولی نتایج روش شبیه سازی متوالی گاوسی از روش های دیگر دقیق تر است و درجه اعتماد بیشتری دارد. در جدول ۱۱، نیز ماتریس همبستگی مقادیر تخمینی عیار آهن کانسار لکه سیاه با روش های مختلف تخمین آورده شده است. داده های این جدول نشان می دهند که بیشترین میزان همبستگی بین نتایج تخمین دو روش شبکه عصبی مصنوعی و شبیه سازی متوالی گاوسی (در حدود ۰/۸۴) و کمترین میزان همبستگی بین نتایج تخمین دو روش شبکه عصبی مصنوعی و کریجینگ معمولی (در حدود ۰/۶۱) است. این امر نیز نشان از دقت بالای روش شبیه سازی متوالی گاوسی و شبکه عصبی مصنوعی است.

۵- نتیجه گیری

برآورد توزیع عیار با استفاده از مدل های مبتنی بر زمین آمار و شبکه عصبی مصنوعی برای یک کانسار آهن در ایران مرکزی انجام شده است. روش های زمین آماری بر روی مدل های مبتنی بر همبستگی مکانی پارامترهای کانسارها کار می کنند، در صورتی که شبکه عصبی مصنوعی توزیع غیرخطی را مدل می کند. در ابتدا بر روی اطلاعات داده های اکتشافی موجود، تحلیل های آماری کلاسیک انجام شد و وجود یا عدم وجود روند در داده ها بررسی و سپس مدل هندسی کانسار تهیه شد. در مرحله بعد از مدل بلوکی ماده معدنی استفاده شد تا به روش زمین آماری کریجینگ تخمین عیار انجام گیرد. به این منظور پس از ترسیم هیستوگرام داده ها و نرمال کردن آنها، در جهات مختلف واریوگرام رسم شد تا بزرگترین شعاع تاثیر مشخص شود. پس از برازش مدل به واریوگرام، تخمین عیار به روش کریجینگ صورت گرفت و با استفاده از آن تخمین

جدول ۱۱: ماتریس همبستگی مقادیر تخمینی عیار آهن کانسار لکه سیاه با روش های زمین آماری و کلاسیک

روش تخمین	روش شبکه عصبی مصنوعی	روش کریجینگ معمولی	روش شبیه سازی گاوسی
روش شبکه عصبی مصنوعی	۱	۰/۶۱	۰/۸۴
روش کریجینگ معمولی	۰/۶۱	۱	۰/۶۹
روش شبیه سازی گاوسی	۰/۸۴	۰/۶۹	۱

- estimation through ordinary kriging*". Australian Journal of Basic and Applied Sciences, 3(1): 330-341.
- [10] Marzeihe, S. K., Hassan, M., Hossein, H., and Parviz, M. (2013). "Determining the best search neighbourhood in reserve estimation, using geostatistical method: a case study anomaly no. 12a iron deposit in central Iran". Journal of the Geological Society of India, 81: 581-585.
- [11] Silva, D., and Almeida, J. (2017). "Geostatistical Methodology to Characterize Volcanogenic Massive and Stockwork Ore Deposits". Minerals, 7(12): 238. DOI: 10.3390/min7120238.
- [12] Abdessattar, L., Dimitriy, N., and Messaoud, M. (2019). "Geostatistical Modeling by the Ordinary Kriging in the Estimation of Mineral Resources on the Kieselguhr Mine, Algeria". In: IOP Conference Series: Earth and Environmental Science. IOP Publishing, 362(1): 012051. DOI: 10.1088/1755-1315/362/1/012051.
- [13] Al-Alawi, S. M., and Tawo, E. E. (1999). "A comparison between artificial neural network and a geostatistical technique in the estimation of regionalized variables". Engineering Journal of University of Qatar, 12: 125-149. DOI: <https://doi.org/10.1016/j.jhydrol.2016.08.045>.
- [14] Sarkar, B. C. (2014). "Geostatistics: concepts and applications in mineral deposit modeling for exploration and mining". Journal Indian Geological Congress, 6(1): 3-26.
- [15] Sarkar, B. C., and Gandhi, S. M. (2016). "Essential of mineral exploration and evaluation". Elsevier Inc.
- [16] Goswami, A. D., Mishra, M. K., and Patra, D. (2017). "Investigation of general regression neural network architecture for grade estimation of an Indian iron ore deposit". Arabian Journal of Geosciences, 10: 80. DOI: <https://doi.org/10.1007/s12517-017-2868-5>.
- [17] Jafrasteh, B., Fathianpour, N., and Suárez, A. (2016). "Advanced machine learning methods for copper ore grade estimation". In: Near Surface Geoscience 2016-22nd European Meeting of Environmental and Engineering Geophysics.
- [18] Jafrasteh, B., Fathianpour, N., and Suarez, A. (2018). "Comparison of machine learning methods for copper ore grade estimation". Computers & Geosciences, 22: 1371-1388.
- [19] Isaaks, E. (1990). "The application of Monte Carlo methods to the analysis of spatially correlated data". PhD Thesis, Stanford University, pp. 213.
- [20] Journel, A. G., and Isaaks, E. H. (1984). "Conditional Indicator Simulation: Application to a Saskatchewan uranium deposit". Journal of the International Association for Mathematical Geology, 16(7): 685-718.
- جایگزین برای برنامه‌ریزی معدن و پارامترهای طراحی شده، مدل‌سازی عیار با استفاده از این سه روش انجام شود. این روش‌ها زمینه‌ای برای مدل‌سازی عیار منسجم فراهم می‌کنند که به بهبود روش‌های تخمین ذخیره آهن منجر می‌شود. نتایج این پژوهش برای کلیه متخصصان مهندسی اکتشاف معدن که همواره با موضوع تخمین دقیق ذخایر معدنی سروکار دارند، قابل استفاده است.

۶- مراجع

- [1] Dimitrakopoulos, R. (2010). "Advances in orebody modelling and strategic mine planning". Spectroscopy Series, 17: 345. <https://www.springer.com/gp/book/9783319693194>.
- [2] Tutmez, B. (2007). "An uncertainty oriented fuzzy methodology for grade estimation". Computers and Geosciences, 33: 280-288.
- [3] Dominy, S. C., Noppe, M. A., and Annels, A. E. (2002). "Errors and uncertainty in mineral resource and ore reserve estimation: the importance of getting it right". Exploration and Mining Geology, 11(1-4): 77-98.
- [4] Battalgazy, N., and Madani, N. (2019). "Categorization of mineral resources based on different geostatistical simulation algorithms: a case study from an iron ore deposit". Natural Resources Research, 28(4): 1329-1351.
- [5] Afeni, T. B., Akeju, V. O., and Aladejare, A. E. (2020). "A comparative study of geometric and geostatistical methods for qualitative reserve estimation of limestone deposit". Geoscience Frontiers, 12(1): 243-253. DOI: <https://doi.org/10.1016/j.gsf.2020.02.019>.
- [6] Jafrasteh, B., Fathianpour, N., and Suarez, A. (2018). "Comparison of machine learning methods for copper ore grade estimation". Computers & Geosciences, 22: 1371-1388.
- [7] Sarkar, B. C., and Roy, I. (2005). "A geostatistical approach to resource evaluation of kala iron ore deposit, Sundergarh dist., Orissa". Journal of the Geological Society of India, 65(5): 553-561.
- [8] Asghari, O., and Hezarkhani, A. (2006). "Geostatistical modeling and reserve estimation of Choghart iron ore deposit through ordinary kriging method". In Proceedings of the 5th International Scientific Conference – SGEM, 631-642.
- [9] Asghari, O., Fatemeh, S., and Hassan, B. A. (2009). "The comparison between sequential Gaussian simulation (SGS) of choghart ore deposit and geostatistical

introduction with applications". Springer, Berlin.

DOI: 10.1007/BF01033030.

- [29] Dubrule, O. (2003). "Geostatistics for seismic data integration in earth models". EAGE: European Association of Geoscientists and Engineers, printed in US.
- [30] Barbosa Queiroz, J. C., Sturaro, J. R., and Riedel, P. S. (2001). "Geostatistic Mapping of Arsenic, Manganese and Iron Contamination Risk in the Port of Santana, Apama, Brazil". Universidate Estadual Palista, Brazil.
- [31] Vann, J., Bertoli O., and Jackson, S. (2002). "Geostatistical Simulation for Quantifying Risk". Geostatistical Association of Australian Symposium.
- [32] Rezaei, A., Hassani, H., Moarefvand, P., and Golmohammadi, A. (2019). "Grade 3D Block Modeling and Reserve Estimation of the C-North Iron Skarn Ore Deposit, Sangan, NE Iran". Global Journal of Earth Science and Engineering, 6: 23-37.
- [33] Jami, M., Dunlop, C., and Cohen, R. (2007). "Fluid inclusion and Stable Isotope Study of the Esfordi Apatite- Magnetite Deposit, Central Iran". Economic Geology, 102: 1111-1128.
- [34] NISCO, (1980). "Result of search and valuation works at magnetic anomalies of the Bafq iron ore region during 1976-1979". National Iranian Steel Corporation, Iran, Unpublished Report, pp. 260.
- [35] Ramezani, J., and Tucker, R. D. (2003). "The Saghand region, central Iran: U-Pb geochronology, petrogenesis and implications for Gondwana tectonics". American Journal of Science, 303(7): 622-665.
- [21] Chilès, J. (1999). "Geostatistics, Modeling spatial uncertainty". Wiley Series in Probability and Mathematical Statistics, New-York.
- [22] Rendu, J. M. (2014). "An Introduction to Cut-Off Grade Estimation". Second Edition, Society for Mining, Metallurgy, and Exploration.
- [23] Dutta, S., Bandopadhyay, S., Ganguli, R., and Misra, D. (2010). "Machine learning algorithms and their application to ore reserve estimation of sparse and imprecise data". Journal of Intelligent Learning Systems and Applications, 2(2): 86-96.
- [24] Tadeusiewicz, R. (2015). "Neural networks in mining sciences-general overview and some representative examples". Archives of Mining Sciences, 60(4): 971-984.
- [25] Jalloh, A., Sasaki, K., Jalloh, Y., and Barrie, A. K. (2016). "The integration artificial neural networks and geostatistical 3D geological block modeling: a case study on a mineral sand deposit". Proceedings of the 24th International Mining Congress of Turkey, IMCET, 257-263.
- [26] Journel, A. G., and Huijbregts, C. (1978). "Mining geostatistics". Academic Press, London.
- [27] Badel, M., Angorani, S., and Panah, M. S. (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.
- [28] Wackernagel, H. (1995). "Multivariate geostatistics-an