



## Application of Concentration-Area fractal modeling and artificial neural network to identify Cu, Zn±Pb geochemical anomalies in Hashtjin area, NW of Iran

Ali Imamalipour <sup>1</sup> , Hamed Ebrahimi <sup>2\*</sup> , Amir reza Abdollahpur <sup>3</sup>

<sup>1</sup> Associate Professor, Department of Mining Engineering, Faculty of Engineering, Urmia University, Urmia, Iran

<sup>2</sup> Ph.D. Student, Department of Mining Engineering, Faculty of Engineering, Urmia University, Urmia, Iran

<sup>3</sup> M.Sc. Student, Department of Geology, Faculty of Science, Tabriz University, Tabriz, Iran

### ARTICLE INFO

#### Article History

Received: 01 June 2024  
Revised: 01 October 2024  
Accepted: 01 October 2024

#### Keywords

Geochemical anomaly  
Machin learning  
Fractal modeling  
Mineral prospectivity mapping  
Hashtjin

#### \*Corresponding author

Hamed Ebrahimi  
✉ [hamed.ebrahimi@urmia.ac.ir](mailto:hamed.ebrahimi@urmia.ac.ir)

### ABSTRACT

Identification of geochemical anomalies plays an essential role in mineral exploration. Recent research investigations have shown that Machine Learning (ML) algorithms can identify geochemical anomalies associated with mineralization that represent targets for mineral exploration. Machine Learning algorithms are widely used in various fields due to their strong capability to extract and display high-level features of training samples. Autoencoder networks show a high ability to identify geochemical anomalies. In this study, the combined method of autoencoder network with the fractal concentration-area method was used to identify geochemical anomalies. First, using multivariate factor analysis, the elements barium, lead, zinc, copper, gold, iron, gold and arsenic were selected as indicators. Subsequently, the uni-element geochemical maps of these elements were prepared, and to standardize the maps in terms of minimum and maximum values, all maps were fuzzified and scaled. Using the fuzzy gamma operator, uni-element geochemical maps were combined. Then the resulting map applied the deep autoencoder method with eight layers of encoder and decoder were reconstructed. Finally, a mineral prospectively map was prepared for the potential area using the concentration-area fractal method. The mixed model proposed in this study introduces the region with high mineralization potential northeast of the studied area.

### How to cite this article

Imamalipour, A., Ebrahimi, H. and Abdollahpur, A.R., 2024. Application of Concentration-Area fractal modeling and artificial neural network to identify Cu, Zn±Pb geochemical anomalies in Hashtjin area, NW of Iran. *Journal of Economic Geology*, 16(3): 101–122. (in Persian with English abstract) <https://doi.org/10.22067/econg.2024.1117>



©2024 The author(s). This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers.

## EXTENDED ABSTRACT

### Introduction

Over the past few decades, the identification of geochemical anomalies has played an important role in mineral exploration (Coates et al., 2011; Lecun et al., 2015; Bergen et al., 2019). Various methods have been used to identify geochemical anomalies in the last few decades, including statistical analysis, geostatistical approaches (Nabavi, 1976), fractal modeling (Ziaii et al., 2009; Ziaii et al., 2012) and many other methods. Fractal/multifractal models are powerful tools that have been widely used to detect geochemical anomalies.

Recent developments in machine learning methods have led to significant advances in geoscience. ML-based approaches to mineral prospectivity mapping using geochemical data can more effectively identify statistical correlations between geochemical patterns than other non-ML methods. Recent research shows that machine-learning approaches enable the integration of geochemical data and the successful identification and separation of geochemical anomalies associated with mineralization that may be overlooked using non-machine learning methods (Tukey, 1977; Cheng, 2006; Cheng et al., 2010).

In this study, the combined method of autoencoder network with the fractal concentration-area method was applied to identify geochemical anomalies in the Hashtjin area (Ardabil province), NW Iran.

### Materials and methods

The combined method of the autoencoder network with the fractal concentration-area method was used to identify the geochemical anomalies. The flowchart of this study is as follows:

- 1- First single-element geochemical maps of Pb, Zn, Cu, Au, As, Fe, and Ba elements were prepared, and to incorporate the minimum and maximum values, all of them became fuzzy to be in the range of (0 and 1).
- 2- Geochemical maps were combined using the fuzzy gamma operator.
- 3- The deep autoencoder method was implemented on the resulting map, and the reconstructed output was obtained.
- 4- Using the fractal concentration-area method, the final map of mineral prospectivity maps was prepared.

### Discussion

An autoencoder is a type of artificial neural network used for learning efficient encoding of unlabeled data

(unsupervised learning). Autoencoder consists of two functions: an encoder function that encodes the input data into a lower-dimensional hidden layer and a decoder function that reconstructs the encoded input data.

The encoder part of an autoencoder network attempts to reduce the dimensionality of the input data while preserving the majority of the information, and it encodes the input data in a blinded space. The decoder part attempts to capture the encoded data and reconstruct the original data with minimal error. The deep autoencoder network is an autoencoder network in which the neural network is designed profoundly, and the number of layers in it is greater. Each layer looks at the data as a new perspective. This neural network automatically and through unsupervised learning identifies patterns, complex structures, and high-level features of the input data.

Considering the evidence of the fractal nature of element distribution, the use of these methods in geochemical exploration for separating anomalous populations from the background with high confidence levels is one of the most potent known methods. The concentration-area fractal method is based on the amount of area occupied by a particular concentration in the study area.

### Results

The study area exhibits complex geochemical features. In such a complex setting, it is essential to implement multiple methods in combination to separate anomalies from the background accurately. The combined method introduced in this study is a powerful tool for identifying geochemical anomalies in areas with complex geological history and diverse geochemical backgrounds. According to the results, all three methods used in this study represent a high favorability of ore mineralization in the northeast of the study area; Therefore, further investigations and investigation are recommended in the introduced area during later stages.

The results obtained from applying the fractal method to the output of the deep autoencoder method indicated a potentially favorable area for the mineralization with approximately 9,047,500 m<sup>2</sup>

In the predictive map obtained in the northeast of the studied area, an area with high mineralization potential is introduced, which is geologically represented by the Upper Jurassic (Lar Formation) and Cretaceous formation controlled by, fault boundaries and in the northeastern part of the Hashtjin.



## کاربرد مدل‌سازی فرکتالی عیار- مساحت و شبکه عصبی مصنوعی برای شناسایی ناهنجاری‌های زمین‌شیمیایی $Zn \pm Pb, Cu$ در منطقه هشتجین، شمال غرب ایران

علی امامعلی‌پور<sup>۱</sup>، حامد ابراهیمی<sup>۲\*</sup>، امیررضا عبدالله‌پور<sup>۳</sup>

<sup>۱</sup> دانشیار، گروه مهندسی معدن، دانشکده فنی مهندسی، دانشگاه ارومیه، ارومیه، ایران

<sup>۲</sup> دانشجوی دکتری، گروه مهندسی معدن، دانشکده فنی مهندسی، دانشگاه ارومیه، ارومیه، ایران

<sup>۳</sup> دانشجوی کارشناسی ارشد، گروه زمین‌شناسی، دانشکده علوم، دانشگاه تبریز، تبریز، ایران

### چکیده

### اطلاعات مقاله

شناسایی ناهنجاری‌های زمین‌شیمیایی نقش مهمی را در اکتشافات معدنی ایفا می‌کند. پژوهش‌های اخیر نشان‌دهنده است که الگوریتم یادگیری ماشین می‌تواند ناهنجاری‌های زمین‌شیمیایی مرتبط با کانی‌سازی را که اهدافی برای اکتشاف مواد معدنی هستند، شناسایی کند. الگوریتم‌های یادگیری ماشین به دلیل قابلیت قوی در استخراج و نمایش ویژگی‌های سطح بالای نمونه‌های آموزشی، به طور گسترده در زمینه‌های مختلف استفاده می‌شوند. شبکه‌های رمزگذار خودکار توانایی بالایی در شناسایی ناهنجاری‌های زمین‌شیمیایی نشان می‌دهند. در این پژوهش، از روش ترکیبی شبکه خودکار رمزگذار با روش فرکتالی عیار- مساحت برای شناسایی ناهنجاری‌های زمین‌شیمیایی استفاده شد. نخست، با استفاده از آنالیز چند متغیره فاکتوری عناصر باریم، سرب، روی، مس، طلا، آهن، طلا و آرسنیک به عنوان شاخص انتخاب شدند. سپس نقشه‌های زمین‌شیمیایی تک عنصری این عناصر تهیه شد و به منظور یکسان‌سازی نقشه‌های به دست آمده از لحاظ مقادیر کمینه و بیشینه، تمام نقشه‌ها به صورت فازی درآمدند. با استفاده از عملگر گامای فازی نقشه‌های زمین‌شیمیایی تک عنصری با هم تلفیق شدند. سپس نقشه حاصل از روش رمزگذار خودکار عمیق با هشت لایه رمزگذار و رمزگشا بازسازی شد. سرانجام، با استفاده از روش فرکتال عیار- مساحت نقشه پتانسیل معدنی برای این منطقه تهیه شد. مدل ترکیبی پیشنهادی در این پژوهش، منطقه‌ای با پتانسیل کانی‌زایی بالا در شمال شرق محدوده مورد بررسی را معرفی می‌کند.

تاریخ دریافت: ۱۴۰۳/۰۳/۱۲  
تاریخ بازنگری: ۱۴۰۳/۰۷/۱۰  
تاریخ پذیرش: ۱۴۰۳/۰۷/۱۰

### واژه‌های کلیدی

ناهنجاری زمین‌شیمیایی  
یادگیری ماشین  
مدل‌سازی فرکتالی  
نقشه پتانسیل معدنی  
هشتجین

### نویسنده مسئول

حامد ابراهیمی

hamed.ebrahimi@urmia.ac.ir ✉

### استناد به این مقاله

امامعلی‌پور، علی؛ ابراهیمی، حامد و عبدالله‌پور، امیررضا، ۱۴۰۳. کاربرد مدل‌سازی فرکتالی عیار- مساحت و شبکه عصبی مصنوعی برای شناسایی ناهنجاری‌های زمین‌شیمیایی  $Zn \pm Pb, Cu$  در منطقه هشتجین، شمال غرب ایران. زمین‌شناسی اقتصادی، ۱۶(۳): ۱۰۱-۱۲۲. <https://doi.org/10.22067/econg.2024.1117>

## مقدمه

روش‌های مختلفی برای شناسایی ناهنجاری‌های زمین‌شیمیایی در چند دهه اخیر استفاده شده است. از جمله تجزیه و تحلیل آماری (Tukey, 1977)، رویکردهای زمین‌آماري (Nabavi, 1976)، مدل‌سازی فرکتالی (Cheng, 2006; Cheng et al., 2010) و بسیاری روش‌های دیگر. مدل‌های فرکتال / مولتی فرکتال، ابزارهای قدرتمندی هستند که به طور گسترده برای تشخیص ناهنجاری‌های زمین‌شیمیایی استفاده شده‌اند. روش‌های آماری فضایی، مانند روش میانگین متحرک، تحلیل عاملی فضایی (Grunsky and Wackernagel, 1988) و زمین‌آمار چند متغیره (Agterberg, 2003; Zuo and Wang, 2016; Zuo, 2017) برای شناسایی ناهنجاری‌های زمین‌شیمیایی چند متغیره با در نظر گرفتن همبستگی‌های فضایی و تغییرات بین نمونه‌های همسایه علاوه بر توزیع فراوانی مقدار غلظت استفاده شده‌اند.

پیشرفت‌های اخیر در روش‌های یادگیری ماشین به پیشرفت‌های قابل توجهی در علوم زمین منجر شده است. رویکردهای مبتنی بر ML برای مدل‌سازی آینده‌نگری مواد معدنی با استفاده از داده‌های زمین‌شیمیایی می‌توانند به طور مؤثرتری همبستگی‌های آماری بین الگوهای زمین‌شیمیایی را نسبت به سایر روش‌های غیر ML شناسایی کنند.

یادگیری ماشین زیرمجموعه‌ای از هوش مصنوعی است که با دریافت داده و با ایجاد الگوریتم‌هایی می‌تواند بدون دخالت انسان خود را تغییر دهد تا خروجی مدنظر را ارائه کند. یادگیری ماشین تلفیقی از علوم کامپیوتر و آمار است که در آن الگوریتم‌ها برای انجام دادن یک کار خاص بدون برنامه‌ریزی مستقیم استفاده می‌شوند. الگوریتم‌های ML معمولاً به دو دسته خلاصه می‌شوند:

یادگیری تحت نظارت و بدون نظارت. الگوریتم‌های یادگیری تحت نظارت، مانند رگرسیون لجستیک، ماشین‌های بردار پشتیبان (Vapnik, 1995)، شبکه‌های عصبی مصنوعی (Alavi, 1996)، شبکه‌های باور عمیق (Hinton et al., 2006) و شبکه عصبی

کانولوشنال (CNN) (Lecun et al., 1998)، بر توانمندسازی ماشین‌ها برای طبقه‌بندی اشیاء، مسائل یا موقعیت‌ها بر اساس داده‌های شناخته شده / برچسب‌گذاری شده، تمرکز می‌کنند. در مقابل، الگوریتم‌های یادگیری بدون نظارت که هدفشان شناسایی الگوهای پنهان یا بالقوه از مجموعه داده ورودی بدون نمونه‌های برچسب‌گذاری شده است، به طور گسترده در زمینه‌های خوشه‌بندی (Scott and Knott, 1974; Silverman, 1986)، کاهش ابعاد (Redlich, 1993)، و استخراج ویژگی (Coates et al., 2011) به کار گرفته شده‌اند. در مقایسه با روش‌های سنتی تجزیه و تحلیل داده‌ها، الگوریتم‌های ML توانایی قوی‌تری در (الف) اجرای پیش‌بینی‌های پیچیده، (ب) ایجاد نمایشی از رابطه بین ورودی‌ها و خروجی‌ها، (پ) نشان‌دادن الگوها، ساختارها و روابط جدید و پیش‌بینی نشده، دارند (Lecun et al., 2015; Bergen et al., 2019). الگوریتم‌های ML با موفقیت برای شناسایی الگوهای زمین‌شیمیایی پنهان و ناشناخته مرتبط با کانی‌سازی در یک محیط پیچیده زمین‌شناسی به کار گرفته شده‌اند (Ziaii et al., 2012; Ziaii et al., 2009). سامانه هوش مصنوعی نیازی به برنامه‌ریزی از قبل ندارد. به جای آن از الگوریتم‌هایی استفاده می‌کند که می‌توانند با هوش خود کار کنند. این الگوریتم‌ها شامل الگوریتم‌های یادگیری ماشین مانند الگوریتم‌های یادگیری تقویتی، شبکه‌های عصبی و یادگیری عمیق است.

یادگیری ماشین زیرمجموعه‌ای از هوش مصنوعی است که به ماشین اجازه می‌دهد به طور خودکار از داده‌های گذشته بدون برنامه‌نویسی صریح یاد بگیرد. هدف یادگیری ماشین این است که به ماشین‌ها اجازه دهد از داده‌ها یاد بگیرند تا بتوانند خروجی دقیقی ارائه دهند. ما در هوش مصنوعی سامانه‌های هوشمندی می‌سازیم تا مانند انسان هر کاری را انجام دهند. در یادگیری ماشین، ما به ماشین‌ها با داده‌ها آموزش می‌دهیم که یک کار خاص را انجام دهند و نتیجه دقیقی ارائه دهند.

فعالیت‌های آلی پوشیده شده است. زون البرز در امتداد نوار کوه‌زایی آلپ- هیمالیا قرار دارد و فازهای کوه‌زایی پرکامبرین موجب تحکیم پی سنگ آن و موجب بالازدگی آن، بدون چین خوردگی شده‌اند. فازهای کیمبرین پیشین و لارامید بیش از سایر فازها بر البرز تأثیرگذار بوده‌اند و البرز غربی در ائوسن بالایی از آب خارج شده و در معرض فرسایش قرار گرفته است. فازهای پیرنه، آستیرین و پاسادین موجب خروج کامل از آب شده‌اند.

محدوده مورد بررسی در ۲۰ کیلومتری جنوب خلخال بخش هشتمین واقع شده است. این محدوده در بین طول‌های جغرافیایی  $48^{\circ} 16' 22''$  و  $47^{\circ} 28' 18''$  شرقی و عرض جغرافیایی  $37^{\circ} 25' 24''$  و  $37^{\circ} 30' 00''$  شمالی در سامانه WGS 84 در نقشه توپوگرافی ۱:۲۵۰۰۰۰ اردبیل قرار دارد. همچنین از نظر تقسیم‌های کشوری، محدوده مورد بررسی در نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ هشتمین واقع شده است (Faridi et al., 2000). شکل ۱ موقعیت و نقشه زمین‌شناسی کل محدوده مورد پژوهش را نشان می‌دهد.

بزرگ‌ترین واحد رخنمون یافته با ترکیب سنگ‌های آتشفشانی بازیگ تفکیک نشده (به صورت واحدهای فرعی اغلب از گدازه‌های آندزیتی تا بازالتی متوسط لایه و گاه آگلومراهایی با همان ترکیب بازیگ)، واحدهای ولکانیکی آندزیت تا داسیت (متاولکانیک) به صورت طبقات ولکانیکی اسیدی تا حد واسط، همچنین واحد تراکی‌بازالت تا تراکی‌آندزیت قهوه‌ای بخش اعظم منطقه را تشکیل داده است. بر اساس بررسی‌های صحرایی انجام شده در گستره اکتشافی هشتمین، کانی‌سازی مشهودی به صورت ذخیره دیده نشده است؛ ولی آثار وسیع دگرسانی گرمابی در منطقه قابل تشخیص است. این گستره دگرسانی در مناطق تکنونیزه که انتقال سیالات گرمابی با سهولت بیشتری انجام شده، دارای وسعت بیشتری هستند و می‌توان از آنها به عنوان شاخص اکتشافی استفاده کرد.

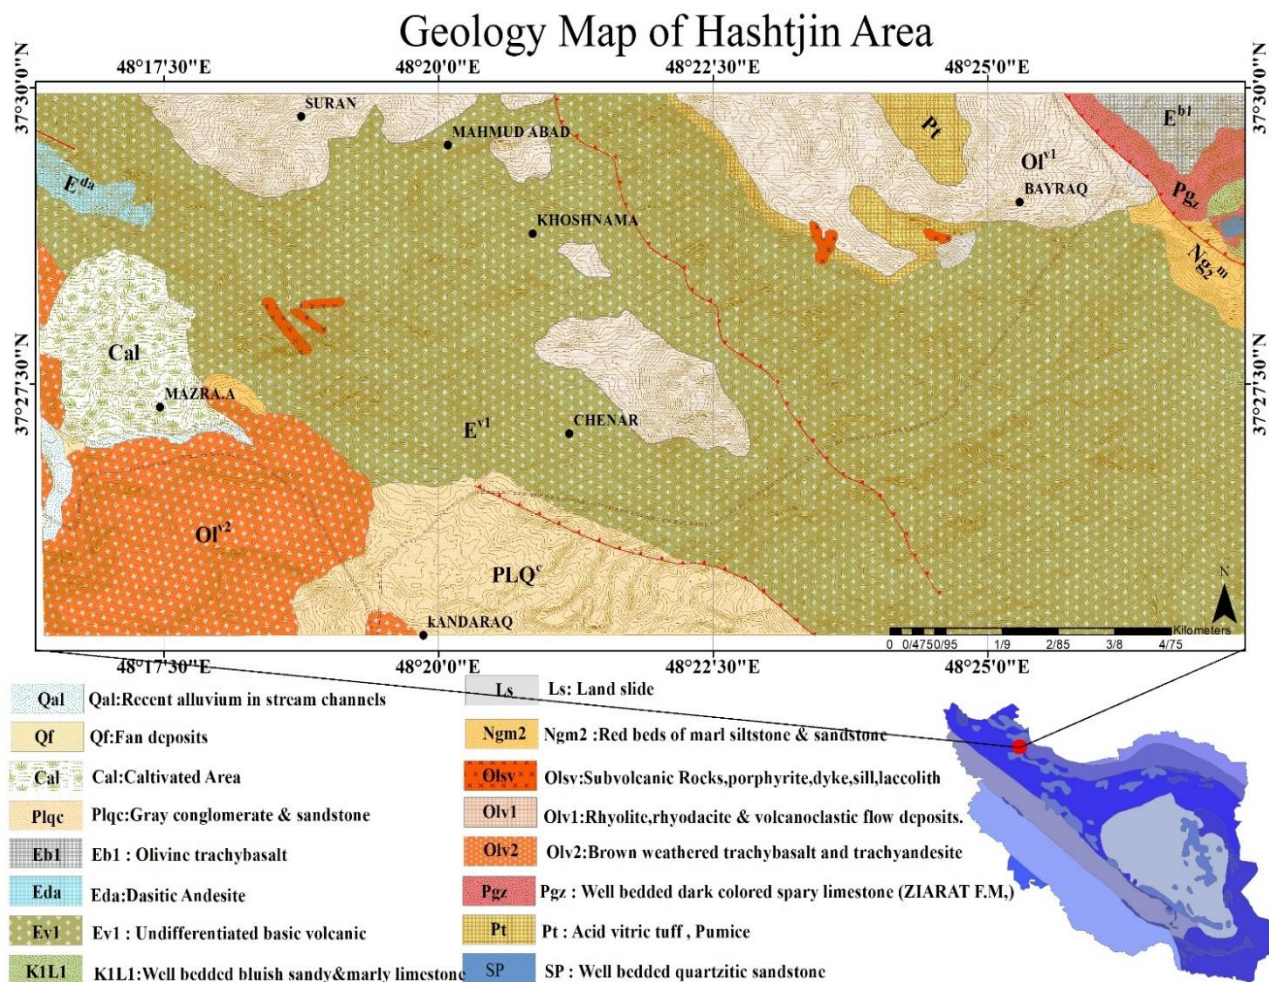
یادگیری ماشین و یادگیری عمیق دو زیرمجموعه اصلی هوش مصنوعی هستند. یادگیری عمیق زیرمجموعه اصلی یادگیری ماشین است. هوش مصنوعی یا AI دامنه بسیار گسترده‌ای دارد. یادگیری ماشین دامنه محدودی دارد. هوش مصنوعی در حال کار برای ایجاد یک سامانه هوشمند است که می‌تواند وظایف پیچیده مختلفی را انجام دهد. Autoencoder یک شبکه عصبی خودآموز بدون نظارت است که از دو بخش تشکیل شده است: رمزگذار و رمزگشا. رمزگذار برای تبدیل بردارهای ورودی به نمایش‌های سطح بالا از طریق خودآموزی با لایه‌های عصبی متعدد استفاده می‌شود و رمزگشا اطلاعات پنهان در فضای کم‌بعد را به بردارهای بازسازی شده در فضای ورودی نگاشت می‌کند. هدف آموزش به حداقل رساندن خطای بازسازی بین داده‌های ورودی اصلی و داده‌های بازسازی شده است. همچنین انتخاب روش‌های مورد استفاده برای ترسیم ناهنجاری‌های زمین‌شیمیایی به الگوی توزیع مجموعه داده‌ها بستگی دارد. روش‌های غیر ساختاری (مانند روش‌های آماری سنتی) این ویژگی را در نظر نمی‌گیرند؛ اما روش‌های ساختاری (مانند روش فرکتال) توجه ویژه‌ای به این مهم دارند. روش‌های یادگیری ماشین می‌توانند بسته به معماری شبکه خود ویژگی‌های پیچیده زمین‌شناسی و زمین‌شیمیایی منطقه را شناسایی و استخراج کنند (Zuo et al., 2019). این پژوهش روشی ترکیبی از کاربرد روش فرکتالی عیار- مساحت و روش خودرمزگذار خودکار عمیق را پیشنهاد می‌کند که توانایی بالایی در جداسازی ناهنجاری‌های زمین‌شیمیایی از زمینه دارد و مناطق امیدبخشی را در منطقه مورد بررسی معرفی می‌کند.

## زمین‌شناسی و چینه‌شناسی منطقه هشتمین در زون البرز غربی - آذربایجان

رشته کوه البرز یک سامانه چند کوه‌زایی پیچیده است که از شمال و شمال شرق به خط برخوردی پالئوتتیس محدود شده است (Alavi, 1996) که بعد توسط ورقه‌های رانده مربوط به

بخش های کم ارتفاع اثر گذاشته است. کانه زایی به صورت پهنه سیلیسی شده حاوی رگه- رگچه های کوارتزی کانه دار است که کالکوپیریت، پیریت، گالن، اسفالریت، هماتیت به عنوان کانی های اصلی و مالاکیت، کالکوسیت، گوتیت در اثر فرایندهای برون زاد تشکیل شده اند. بافت مواد معدنی و باطله از نوع پراکنده، رگه- رگچه ای، برشی و پرکننده فضاهای خالی است. ویژگی های زمین شناسی، کانی شناسی ماده معدنی در رخدادهای منطقه مورد بررسی شباهت زیادی به کانسارهای اپی ترمال فلزهای پایه (نوع سولفیداسیون متوسط) دارد.

این دگرسانی ها به صورت نواری از شمال غرب تا جنوب شرق کشیده شده و مهم ترین آنها عبارتند از دگرسانی سریسیتی، آرژیلیک، سیلیسی شدگی، کلریتی و همچنین زون های آغشته به اکسیدهای آهن (Afzal et al., 2015). نیروها و فرایندهای زمین ساختی که به طور قابل توجهی بر منطقه اثر داشته، باعث ایجاد گسل هایی با سازوکار متعدد از جمله راستالغز، عادی و معکوس با روند شمال غرب- جنوب شرق شده است. پهنه های دگرسانی گسترده که به نظر می رسد اغلب با گسل ها و شکستگی های منطقه در ارتباط هستند، بر بیشتر نهشته های



شکل ۱. موقعیت و نقشه زمین شناسی منطقه هشتجین در مقیاس ۱:۱۰۰۰۰۰ (Faridi et al., 2000)

Fig. 1. Location and geological map (1:100000) of the Hashtjin area (Faridi et al., 2000)

منتهی می شود نیز آثار دگرسانی در میان واحدهای موجود که اغلب کائولینیتی تا بنتونیتی شده اند و کانی های کوارتز و پیریت دیده می شود (شکل ۳-۳A).

### مواد و روش ها


#### آماده سازی داده ها

در این پژوهش از داده های مربوط به اکتشافات زمین شیمیایی انجام شده به روش رسوبات آبراهه ای به تعداد ۲۱۱ نمونه در مقیاس ۱:۱۰۰۰۰۰ استفاده شده است (داده ها مربوط به سازمان زمین شناسی اردبیل). نمونه های زمین شیمیایی به روش رسوب های آبراهه ای با تراکم ۲ نمونه در کیلومتر مربع برداشت شده است (شکل ۴). نمونه ها برداشت شده پس از آماده سازی به روش تجزیه شیمیایی ICP-MS ۴۴ عنصری و ۱۲ اکسید به روش XRF در آزمایشگاه سازمان زمین شناسی مرکز اردبیل مورد ارزیابی قرار گرفت و نتایج به دست آمده از آنالیز نمونه ها نیز توسط نرم افزارهای GIS10، SPSS و EXCEL مورد تحلیل قرار گرفته است.


**کانی سازی و دگرسانی های محدوده مورد بررسی**  
محدوده دگرسانی غرب چنار: سنگ میزبان دگرسانی جزو واحد ولکانیک تفکیک نشده است که اغلب از تراکی آندزیت تا الوین تراکی بازالت بر اساس مشاهدات صحرایی گسترش این دگرسانی دارای یک روند شمال غرب- جنوب شرق است و در بررسی های آزمایشگاهی در حد آرژیلیک پیشرفته با کانی های کوارتز، کائولن، همتایت ارزیابی شده است (شکل ۲). بخش هایی از واحد سنگی دگرسانی به دلیل وجود همتایت به رنگ قهوه ای تا قرمز اخرای دیده می شود بخش های روشن تر اغلب از کانی های کائولن تشکیل شده است.

**محدوده دگرسانی خوشنامه:** این محدوده چون در امتداد یک گسل تراسی تشکیل شده است، علاوه بر محدوده اصلی در چندین محل دیگر در مجاورت گسله یاد شده دیده می شود. سنگ میزبان همان واحد سنگ های آتشفشانی تفکیک نشده است که اغلب از گدازه های تراکی آندزیت و آگلومرا تشکیل شده است (شکل ۳-۳B).

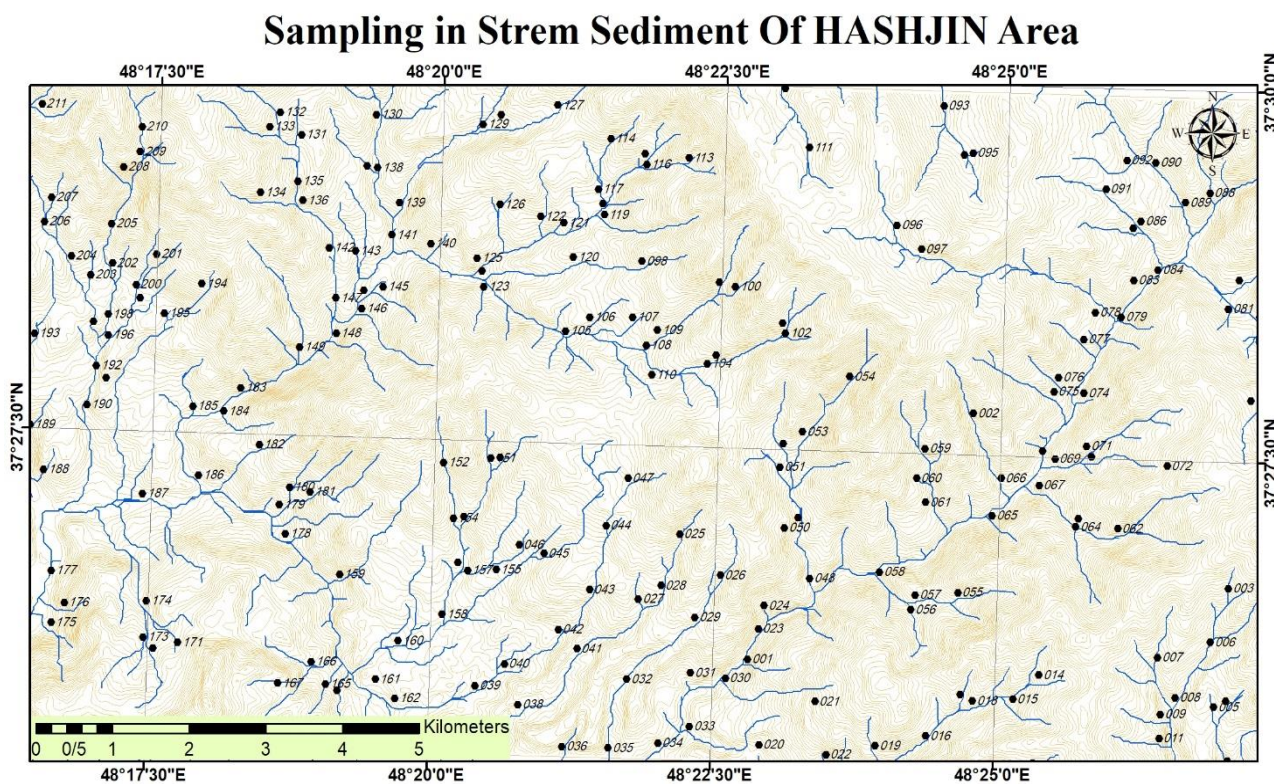
وسعت این دگرسانی در محل حدود ۵۰ تا ۱۵۰ متر است. البته در مسیر آبراهه اصلی که به محدوده دگرسانی شرق خوشنامه



شکل ۲. نمای کلی از محدوده دگرسانی غرب چنار و دگرسانی آرژیلیک به همراه اکسید آهن در منطقه هشتجین  
Fig. 2. An overview of the alteration zone west of Chanar, argillic alteration with iron oxide in the Hashtjin area



شکل ۳. A: نمایی از محدوده دگرسانی خوشنامه و B: رخنمون سنگ های آتشفشانی بازیک در منطقه هشتجین  
 Fig. 3. A. view of Khoshnameh alteration zone, and B. outcrop of the basic volcanic rocks in the Hashtjin area



شکل ۴. نقشه محل نمونه برداری رسوب آبراه ها در منطقه هشتجین  
 Fig. 4. The location map of the stream sediments samples in the Hashtjin area



## روش جداسازی آنومالی‌های زمین‌شیمیایی

این پژوهش در محدوده شمال غرب هشتجین (استان اردبیل) انجام شد. در فاز نخست، ابتدا پیش پردازش‌های آماری لازم (جایگزینی مقادیر سنسورد و مقادیر خارج از ردیف و عادی‌سازی) بر روی داده‌ها انجام شد. برای ترسیم نقشه ناهنجاری‌های چند فلزی از طریق شناسایی ناهنجاری‌های زمین‌شیمیایی با کمک آنالیز چند متغیره فاکتوری، عناصر سرب، روی، مس، طلا، آرسنیک، آهن و باریوم به عنوان شاخص انتخاب شدند. سپس نقشه‌های زمین‌شیمیایی تک عنصری این عناصر تهیه شد و به منظور یکسان‌سازی نقشه‌های حاصل از لحاظ مقادیر کمترین و بیشترین، تمام نقشه‌ها به صورت فازی درآمدند و در دامنه (۰ و ۱) قرار گرفتند (شکل ۵-A تا G). به منظور انجام ادامه بررسی‌ها با استفاده از عملگر گامای فازی، نقشه‌های زمین‌شیمیایی تک عنصری با هم تلفیق شدند (شکل ۱۲-A). در این پژوهش پیش پردازش‌های آماری بر روی داده‌ها در نرم‌افزار اکسل انجام شد. انجام آنالیزهای آماری تک متغیره و چندمتغیره به منظور تشخیص عناصر شاخص و مرتبط با کانی‌سازی، با نرم‌افزار SPSS مورد جستجو قرار گرفت. نقشه‌های رستری زمین‌شیمیایی با اندازه پیکسل ۵۰ \* ۵۰ با کمک نرم‌افزار ARCGIS 10.8 تهیه شدند. کدنویسی‌های لازم برای اجرای الگوریتم خودرمزگذار عمیق در محیط اسپایدر (SPYDER=5.4.3) در آن‌اکنوندا ۳ انجام شد. نمودار لگاریتمی عیار- مساحت در محیط اکسل و نقشه‌ی پیشگوی نهایی در ARCGIS ترسیم شد.


## روش درون‌یابی توزیع عناصر و دسته‌بندی آنومالی‌ها

یکی از مباحث بسیار کاربردی در بسیاری از علوم درون‌یابی است. با کمک درون‌یابی می‌توانید برای نقاطی که ارزش یا داده‌ای وجود ندارد، بر اساس نقاطی که ارزش آنها برداشت شده است، مقادیر آنها را تخمین زد. شرط اصلی استفاده از روش درون‌یابی پیوسته بودن متغیر است. اگر متغیر پیوسته

نباشد، نمی‌توان از درون‌یابی استفاده کرد. پیوسته بودن یعنی ارزش یک نقطه وابسته به نقاط یا تحت تأثیر نقاط اطراف است. به صورت کلی، دو روش برای درون‌یابی استفاده خواهد شد. روش اول، روش‌های زمین‌آمار و روش دوم، روش‌های قطعی است.

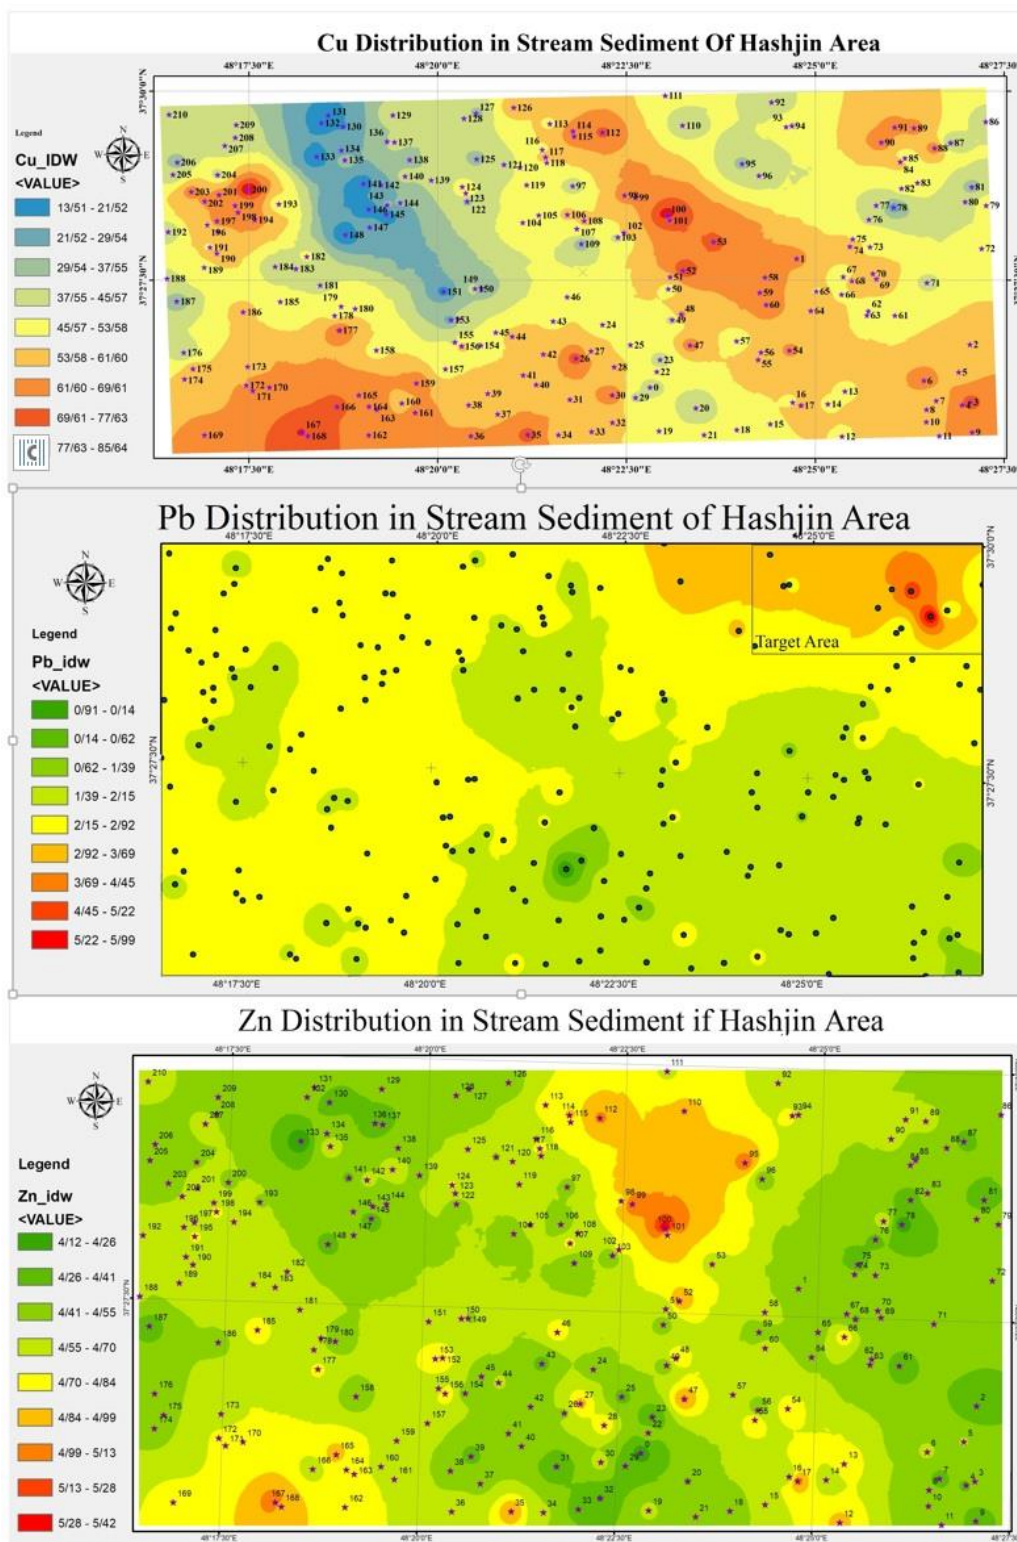
در روش‌های قطعی از الگوریتم‌های ریاضی برای تخمین مقادیر بر اساس نزدیکی نقاط نمونه استفاده می‌شود. روش‌هایی مانند وزن‌دهی معکوس فاصله و درون‌یابی اسپلاین، دو نوع معروف از این نوع درون‌یابی هستند. در روش زمین‌آمار برای تولید سطوح درون‌یابی دقیق‌تر، خودهمبستگی مکانی را در نظر می‌گیرند. معروف‌ترین روش کریجینگ است که از وابستگی فضایی متغیر را مدل‌سازی می‌کنند. البته هر کدام از این روش‌ها متغیرهای خود را داراست و باید با دقت بالا آنها را پیاده‌سازی کرد.

روش استفاده در این پژوهش، روش درون‌یابی فاصله معکوس است یکی از معروف‌ترین روش‌های درون‌یابی در دنیاست. از این روش برای تخمین مقدار یک سطح پیوسته در مکان‌های نمونه‌برداری نشده بر اساس مقادیر نقاط نمونه اطراف استفاده می‌شود (شکل ۶). این روش بر اساس فاصله است (Farhadi et al., 2022)؛ به این معنی که نمونه‌هایی که فاصله نزدیک‌تر دارند، باید ارزش و تأثیر بیشتری داشته باشند. درون‌یابی فاصله معکوس با تخصیص وزن به هر نقطه نمونه بر اساس فاصله آن تا محل مورد نظر کار می‌کند و وزن نهایی بر اساس فاصله نقاط اطراف و مقدار وزن نیز بر اساس فاصله خواهد بود. اساس درون‌یابی فاصله معکوس این است که در مواردی که نقاط نمونه پراکنده هستند یا توزیع نقاط نمونه نشان‌دهنده الگوی اساسی نیست؛ نمونه نزدیک‌تر تأثیر بیشتری بر تخمین نسبت به نقاط نمونه دورتر خواهد داشت و وزن تخصیص داده شده به هر نقطه نمونه متناسب با فاصله معکوس بین نقطه نمونه و محل هدف است.



شکل ۵. نقشه‌های زمین‌شیمیایی تک متغیره: A: آرسنیک، B: طلا، C: باریم، D: مس، E: آهن، F: سرب و G: روی در منطقه هشتجین

**Fig. 5.** Univariate geochemical maps: A: Arsenic, B: Gold, C: Barium, D: Copper, E: Iron, F: Lead, and G: Zinc in the Hashtjin area



شکل ۶. نقشه های زمین شیمیایی تک عنصری مس، سرب، روی به روش درون یابی فاصله معکوس در منطقه هشتجین

Fig. 6. Single-element geochemical maps of Cu, Pb, Zn elements using IDW Method in the Hashtjin area

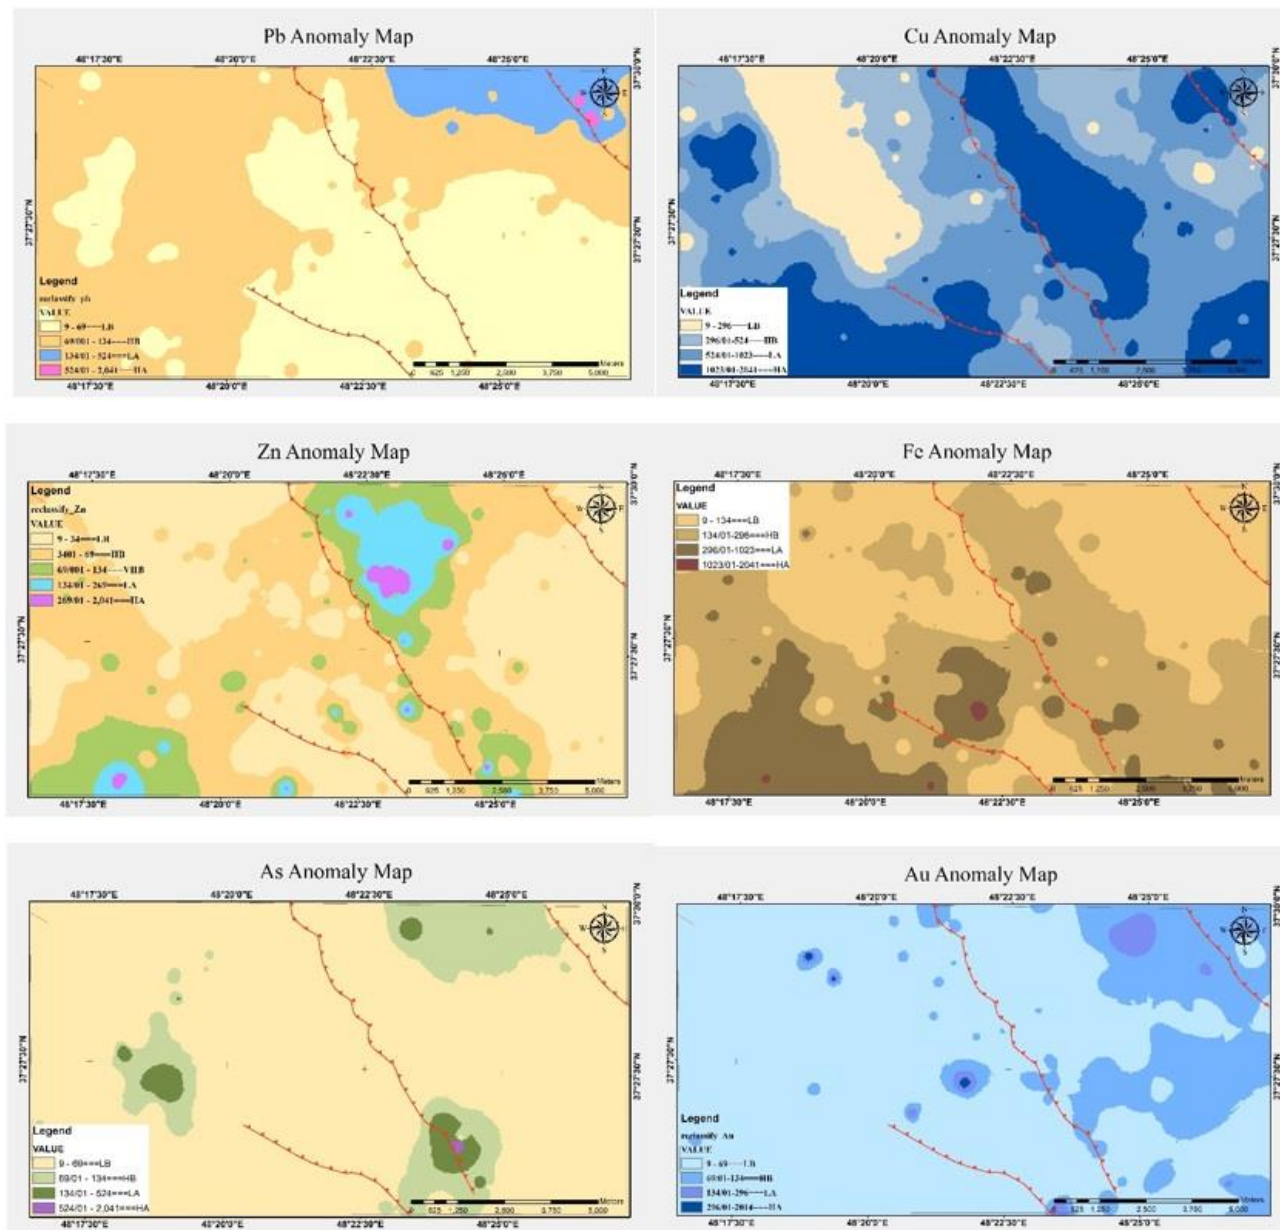
این جدول شامل اطلاعاتی مانند نام هر رده، بازه مقداری ارزش های پیکسل های متعلق به هر رده و همچنین رنگ مربوط به هر رده برای نمایش بهتر در نقشه است. از جمله الگوریتم های طبقه بندی شده مورد استفاده می توان به روش های تقسیم مقادیر، برش طبیعی، کوانتیل، روش های کاستی تحمیلی و روش های مبتنی بر مقایسه ارزش های پیکسل ها با معیارهای ثابت مانند میانگین، مد و انحراف معیار اشاره کرد. روش استفاده در این پژوهش، الگوریتم برش طبیعی است (شکل ۷).

روش دسته بندی آنومالی ها به معنای تبدیل مقادیر پیکسل های یک لایه رستری به دسته های مختلف با استفاده از یک الگوریتم طبقه بندی شده مشخص است. با اعمال این الگوریتم بر روی لایه رستری، هر پیکسل به یک دسته خاص از دسته های تعریف شده نسبت داده می شود. این دسته بندی می تواند برای اهداف مختلف مانند تحلیل ویژگی های زمین شناسی، تحلیل تغییرات زمین شناسی در زمان و ... استفاده شود. بعد از اعمال الگوریتم بر روی لایه رستری، یک جدول ایجاد می شود که شامل اطلاعات دسته بندی شده برای هر رده است (جدول ۱).

جدول ۱. مقادیر غلظت ها و مساحت های مربوط به هر عنصر در منطقه هشتجین

Table 1. Concentration and area values of each element in the Hashtjīn area

Pb			Zn			Cu		
VALUE	area	cumarea	VALUE	area	cumarea	VALUE	area	cumarea
2041	95000	95000	2041	45000	45000	2041	5250000	5250000
1023	380000	475000	1023	195000	240000	1023	85145000	90395000
524	2027500	2502500	524	1920000	2160000	524	114112500	204507500
269	17955000	20457500	269	15115000	17275000	296	61142500	265650000
134	148342500	168800000	134	36802500	54077500	134	13020000	278670000
69	123930000	292730000	69	110035000	164112500	69	8862500	287532500
34	5157500	297887500	34	118435000	282547500	34	7455000	294987500
18	617500	298505000	18	15455000	298002500	18	3245000	298232500
9	185000	298,690,000	9	687500	298690000	9	457500	298690000
As			Au			Fe		
VALUE	area	cumarea	VALUE	area	cumarea	VALUE	area	cumarea
2041	55000	55000	2041	35000	35000	2041	127500	127500
1023	145000	200000	1023	192500	227500	1023	475000	602500
524	957500	1157500	524	1137500	1365000	524	4847500	5450000
296	5332500	6490000	296	2895000	4260000	296	38540000	43990000
134	34902500	41392500	134	9127500	13387500	134	131525000	175515000
69	74112500	115505000	69	51865000	65252500	69	79467500	254982500
34	126802500	242307500	34	59895000	125147500	34	37065000	292047500
18	53430000	295737500	18	57075000	182222500	18	6217500	298265000
9	2952500	298690000	9	116467500	298690000	9	425000	298690000



شکل ۷. نقشه‌های داده‌های زمین‌شیمیایی برای عناصر مس، سرب، روی، آهن، طلا و آرسنیک در منطقه هشتجین

Fig. 7. The generated maps geochemical data for Cu, Pb, Zn, Fe, Au, and As elements in the Hashtjin area

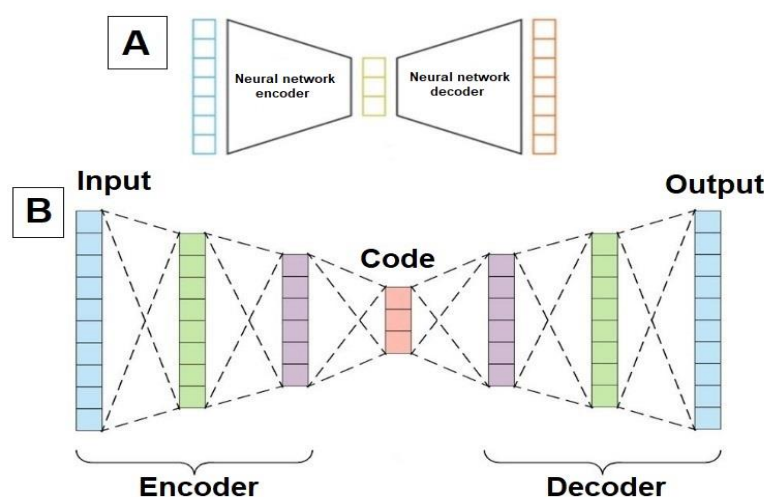
یاد می‌گیرد: یک تابع رمزگذاری که داده‌های ورودی را در یک لایه پنهان با ابعاد کمتر از لایه ورودی کدگذاری می‌کند و یک تابع رمزگشایی که داده‌های ورودی رمزگذاری شده را بازسازی می‌کند. رمزگذار خودکار یک نمایش (رمزگذاری) کارآمد را

### شبکه خودرمزگذار خودکار

خودرمزگذار خودکار نوعی شبکه عصبی مصنوعی است که برای یادگیری کدگذاری کارآمد داده‌های بدون برچسب (یادگیری بدون نظارت) استفاده می‌شود. رمزگذار خودکار دو عملکرد را

الگوریتم به صورت خودکار الگوها و ساختار داده‌ای را شناسایی کند. (شکل ۸-۸). ساختار کلی شبکه خودرمزگذار خودکار را نشان می‌دهد. شبکه خودرمزگذار عمیق یک شبکه خودرمزگذار است که در آن شبکه عصبی به صورت عمق‌دار طراحی شده است و تعداد لایه‌ها در آن بیشتر است. هر لایه به عنوان چشم‌انداز جدید به داده نگاه می‌کند. این شبکه عصبی به صورت خودکار و به صورت یادگیری بدون نظارت، الگوها، ساختار پیچیده و ویژگی‌های سطح بالای داده‌های ورودی را شناسایی می‌کند (شکل ۸-۸).

برای مجموعه‌ای از داده‌ها، معمولاً برای کاهش ابعاد به کار می‌برد. ابعاد لایه ورودی و لایه خروجی با هم برابر است. بخش رمزگذار شبکه خودرمزگذار خودکار سعی می‌کند با حفظ بخش عمده اطلاعات داده‌های ورودی، ابعاد داده‌ها را کاهش دهد و داده‌های ورودی را در فضای پنهان کدگذاری کند و بخش رمزگشا تلاش می‌کند تا داده‌های رمزگذاری شده را بگیرد و با کمترین خطا داده‌های اولیه را بازسازی کند (Reichstein et al., 2019; Sun et al., 2019). بر خلاف یادگیری با نظارت، در یادگیری بدون نظارت، داده‌ها بدون برچسب هستند و هدف این است که



شکل ۸. ساختار A: شبکه خودرمزگذار خودکار ساده و B: شبکه خودرمزگذار عمیق با سه لایه رمزگذار و سه لایه رمزگشا در منطقه هشتجین

**Fig. 8.** Structure of A: simple autoencoder network, and B: deep autoencoder network with 5 encoder layers and 5 decoder layers in the Hashtjini area

فضایی نمونه در تعیین مناطق آنومال تأثیر دارد، نسبت به روش‌های غیرساختاری برتری دارند. با توجه به اثبات وجود ماهیت فرکتالی در توزیع عناصر، می‌توان در اکتشافات زمین‌شیمیایی برای جدایش جوامع ناهنجاری از زمینه از این روش به عنوان یکی از قوی‌ترین روش‌های شناخته‌شده برای تعیین حد آستانه با ضریب اطمینان بالا، استفاده کرد. (Farhadi et al., 2024; Pourgholam et al., 2024). روش فرکتال عیار- مساحت مبتنی بر میزان مساحتی است که هر عیار خاص در

## تحلیل فرکتال

امروزه جدایش ناهنجاری از زمینه و جداسازی ناهنجاری‌های با درجه‌های شدت گوناگون، مهم‌ترین کار در بررسی‌های زمین‌شیمیایی است. برای جداسازی ناهنجاری در اکتشاف زمین‌شیمیایی از روش‌های آماری گوناگون مانند روش‌های آنالیز تک متغیره و چند متغیره استفاده شده است. روش‌های فرکتالی عیار- مساحت، عیار- تعداد جزو روش‌های ساختاری جداسازی ناهنجاری از زمینه هستند و با توجه به اینکه در آنها موقعیت

از  $V$  و مساحت‌های محصور با هر خط  $[A(\geq V)]$  رابطه زیر برقرار است:

$$[A(\geq v) \propto v^{-\alpha}] \quad (1)$$

توان  $\alpha$  در رابطه نشان‌دهنده شیب خط مستقیم رسم شده توسط کمترین مربع‌ها در نمودار  $\log$ - $\log$  است.

### نتایج و بحث

برای دست‌یافتن به نقشه مناطق پتانسیل دار کانی سازی چندفازی در منطقه مورد پژوهش، نقشه‌های تک عنصری عناصر شاخص شامل سرب، روی، باریم، آهن، مس، طلا و آرسنیک با به کارگیری عملگر گامای فازی ( $\text{Gamma} = 0.9$ ) با هم تلفیق شدند (شکل ۱۲- $A$ ). سپس از الگوریتم یادگیری عمیق خودرمزگذار خودکار برای بازسازی نقشه به دست آمده، استفاده شد. ساختار شبکه خودرمزگذار استفاده شده در این پژوهش با هشت لایه پنهان، شامل چهار لایه رمزگذار و چهار لایه رمزگشا به صورت ۵۰۰۰ و ۵۰۰۰ و ۱۰۰۰ و ۵۰۰ و ۱۰۰۰ و ۵۰۰۰۰ با ابعاد ورودی و خروجی ۵۰۰۰۰۰ و با تعداد دوره ۴۰۰ ( $\text{epochs} = 400$ ) طراحی شد (جدول ۲).

منطقه مورد بررسی اشغال کرده است. هر چه عیار عنصر افزایش یابد، میزان مساحت اشغالی توسط آن کاهش می‌یابد. در این روش، نمودار لگاریتمی عیار در برابر مساحت تجمعی رسم می‌شود (Aramesh Asl et al., 2015). این نمودار در نقاطی می‌شکند یا به عبارتی تغییر شیب تند می‌دهد که این نقاط نشان‌دهنده تغییر از زمینه به ناهنجاری‌های درجه‌های مختلف و به دنبال آن تغییرات در شرایط زمین‌شناسی به خصوص کانی‌سازی است. به طور کلی داده‌های زمین‌شیمیایی رفتار چند فرکتال دارند که این نشان‌دهنده میزان تغییرات در شرایط زمین‌شناسی، زمین‌شیمیایی، دگرسانی، هوازدگی سطحی، کانی‌سازی و به دنبال آن مراحل غنی‌شدگی یک عنصر است (Qaderi, 2014; Daneshvar Saein et al., 2020).

روش عیار- مساحت برای نشان‌دادن رابطه بین نتایج به دست آمده و اطلاعات زمین‌شناسی، زمین‌شیمیایی و کانی‌شناسی عمل می‌کند. کاربردی‌ترین ویژگی آن پیاده‌سازی آسان و توانایی محاسبه آستانه‌های غیرعادی کمی است (Zuo et al., 2009). برای مجموعه‌ای از خطوط غلظت‌های تک عنصری، خطوط غلظت  $V$  و مساحت غلظت‌های تک عنصری مساوی یا بزرگ‌تر


جدول ۲. مشخصات لایه‌های رمزگذار و رمزگشای تعریف شده برای اجرای الگوریتم خودرمزگذار خودکار عمیق محدوده هشتجین

**Table 2.** Specifications of the encoder and decoder layers defined for the implementation of the deep autoencoder algorithm Hashtjin Area

Layers name	Unites	Activation	Input
Encoded1	50000	Relu	Input image
Encoded2	5000	Relu	Encoded1
Encoded3	1000	Relu	Encoded2
Encoded4	500	Relu	Encoded3
Decoded1	1000	Relu	Encoded4
Decoded2	5000	Relu	Decoded1
Decoded3	50000	Relu	Decoded2
Decoded4	500000	Sigmoid	Decoded3

بالای کانی سازی چندفلزی را در بخش شمال شرقی منطقه مورد بررسی نشان می دهد (شکل ۱۲- B). شبکه تعریف شده در این بررسی با ورودی نقشه حاصل از انجام تلفیق فازی نقشه های زمین شیمیایی تک عنصری و خروجی بازسازی شده و تابع بهینه ساز آدام تشکیل شد.

نمودار خطا برحسب تعداد، دوره های آموزش را نشان می دهد که در epoch=75 به طور تقریبی به مقدار ۰/۰۰۴۱ رسیده است و از دوره ۷۵ تا ۴۰۰ میزان خطا تقریباً ثابت مانده است (شکل ۹). خروجی بازسازی شده حاصل از اجرای روش خودرمزگذار خودکار عمیق را بر روی نقشه به دست آمده از تلفیق فازی نقشه های تک عنصری عناصر شاخص نشان می دهد که احتمال



شکل ۹. نمودار خطا برحسب تعداد دوره های آموزش در آموزش روش خودرمزگذار عمیق در منطقه هشتجین

Fig. 9. Error graph according to the number of training courses in training the deep autoencoder method in the Hashtjin area

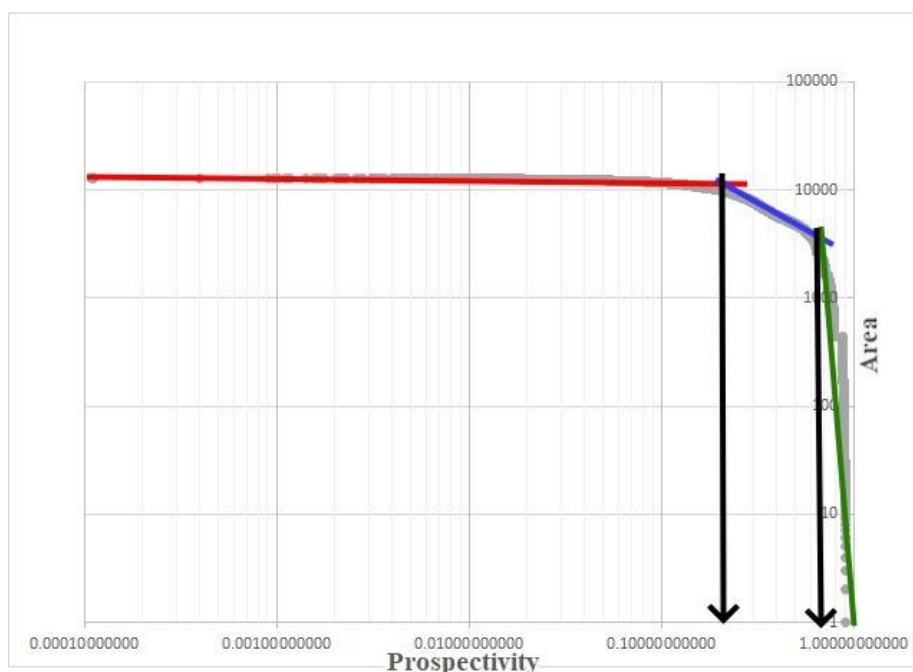
۱) تبدیل نقشه به دست آمده از الگوریتم خودرمزگذار عمیق به شیپ فایل (قالب عمومی داده های برداری در نرم افزارهای سامانه اطلاعات جغرافیایی است).  
 ۲) به دست آوردن فراوانی مربوط به هر نقطه (هر نقطه در واقع نماینده سلولی با ابعاد ۵۰\*۵۰ است)؛  
 ۳) مرتب سازی مقادیر احتمال در حالت نزولی و سپس محاسبه مساحت و مساحت تجمعی هر سطح در نرم افزار اکسل؛  
 ۴) ترسیم نمودارهای log-log احتمال در مقابل مساحت و برازش خطوط مستقیم روی نقاط؛

این روش برای تجزیه و تحلیل انواع مختلف داده های زمین شیمیایی از جمله نمونه های رسوب آبراهه ای (Cheng et al., 1996)، نمونه های سنگ (Cheng et al., 1994) و هوموس (Sim et al., 1999) استفاده شده است. در این پژوهش، روش عیار- مساحت پیشنهاد شده توسط چنگ و همکاران (Cheng et al., 1994) برای جداسازی سطوح مختلف، احتمال مربوط به کانی سازی در نقشه حاصل از الگوریتم خودرمزگذار خودکار استفاده شد. مراحل تفکیک جوامع با احتمال متفاوت با این روش را می توان به صورت زیر خلاصه کرد:



پیشنهادی خودرمزگذار خودکار عمیق- فرکتالی (عیار- مساحت) نشان می دهد. در نقشه پیشگوی به دست آمده در شمال شرق منطقه مورد پژوهش، محدوده ای با پتانسیل بالای کانی سازی معرفی می شود که از نظر زمین شناسی با نهشته های ژوراسیک بالایی (سازند لار) و کرتاسه که اغلب با مرز گسله و به صورت ورقه های رانده و نابرجا رخنمون دارند و روی آن سازند آهکی کرتاسه زیرین (سازند تیز کوه) در آغ داغ مشاهده می شود، انطباق دارند. در هر سه نقشه پیشگوی حاصل از روش های تلفیق فازی (شکل ۱۲-A)، نقشه بازسازی شده با الگوریتم یادگیری عمیق خودرمزگذار خودکار (شکل ۱۲-B) و نقشه حاصل از اجرای روش ترکیبی پیشنهادی (شکل ۱۲-C) منطقه امیدبخش با احتمال بالای کانی سازی چند فلزی در بخش شمال شرقی منطقه معرفی شده است.

۵) تعیین نقاط شکست نمودار و  
 ۶) تهیه نقشه ناهنجاری بر اساس مرز احتمالات به دست آمده از نقاط شکست در نمودار لگاریتمی احتمال- مساحت.  
 نمودار احتمال- مساحت حاصل وجود سه جامعه با رفتار متفاوت را نشان داد. نقاط شکست مشخص شده مرز جدایش جوامع با احتمال کانی سازی متفاوت هستند. این نمودار در دو نقطه شکسته یا تغییر شیب تند می دهد (شکل ۱۰) که در جدول ۳، مقادیر نقاط شکست و در نمودار لگاریتمی (شکل ۱۱)، احتمال کانی سازی بر حسب مساحت آورده شده است. نتایج حاصل از انجام روش فرکتال بر روی خروجی به دست آمده از روش خودرمزگذار خودکار عمیق نشان می دهد که مساحتی حدود ۹۰۴۷۵۰۰ مترمربع از منطقه مورد پژوهش به عنوان منطقه احتمال کانی سازی معرفی می شود (شکل ۱۲-C). نقشه پیشگوی مناطق مستعد کانی سازی چندفلزی سرب، روی و مس را بر اساس مدل ترکیبی



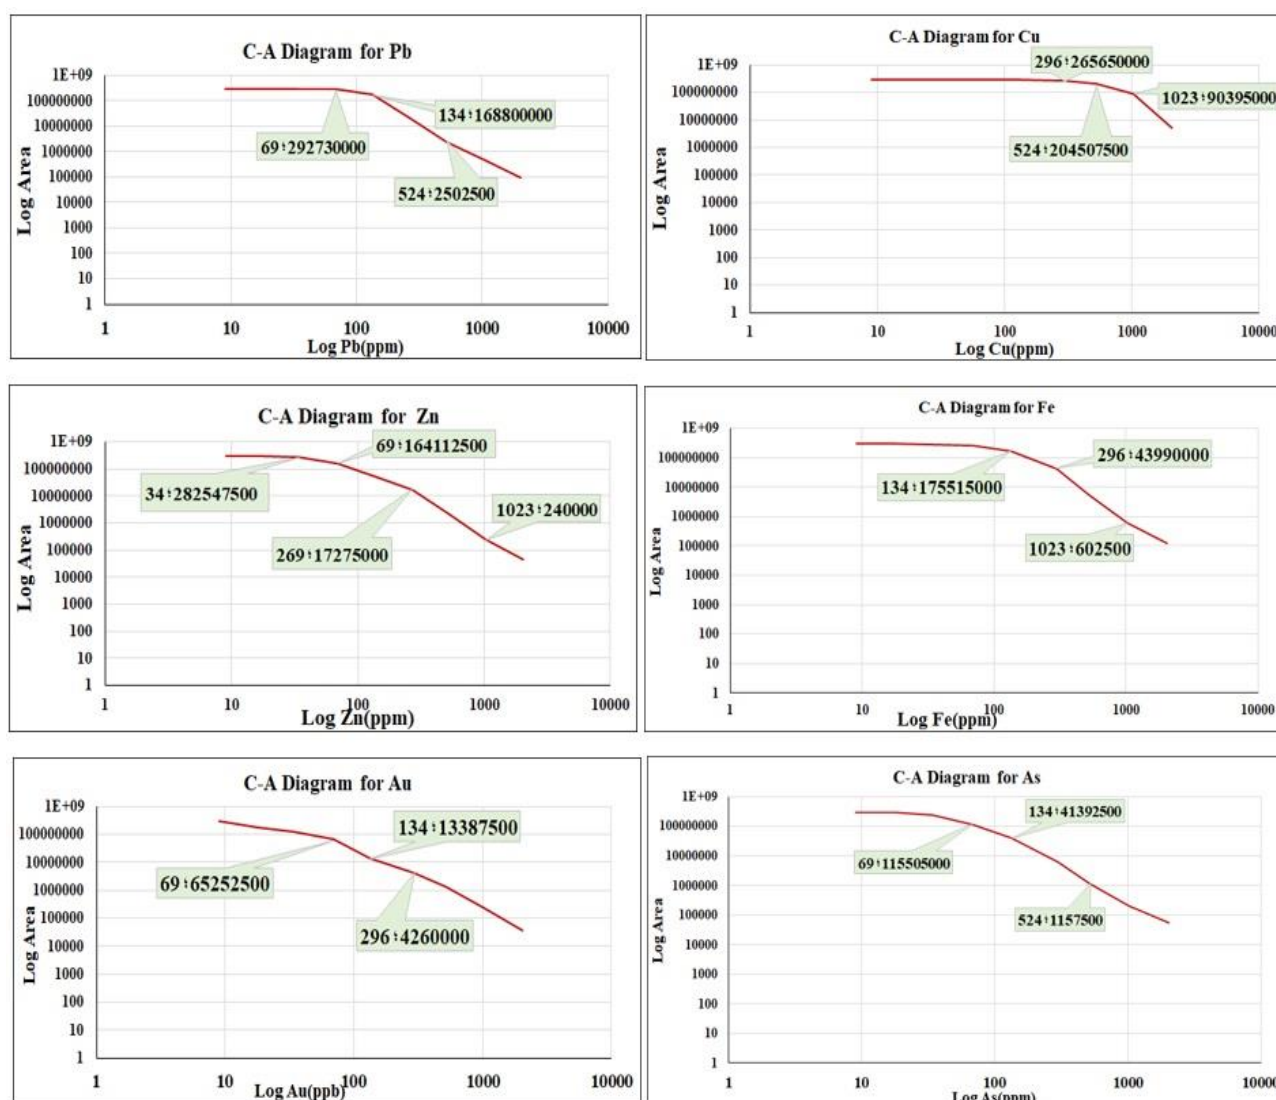
شکل ۱۰. نمودار احتمال کانی سازی بر حسب مساحت برای کانی سازی چندفلزی سرب و روی و مس در منطقه هشتجین

Fig. 10. Mineralization probability diagram by area for lead, zinc, and copper polymetallic mineralization in the Hashtjin area

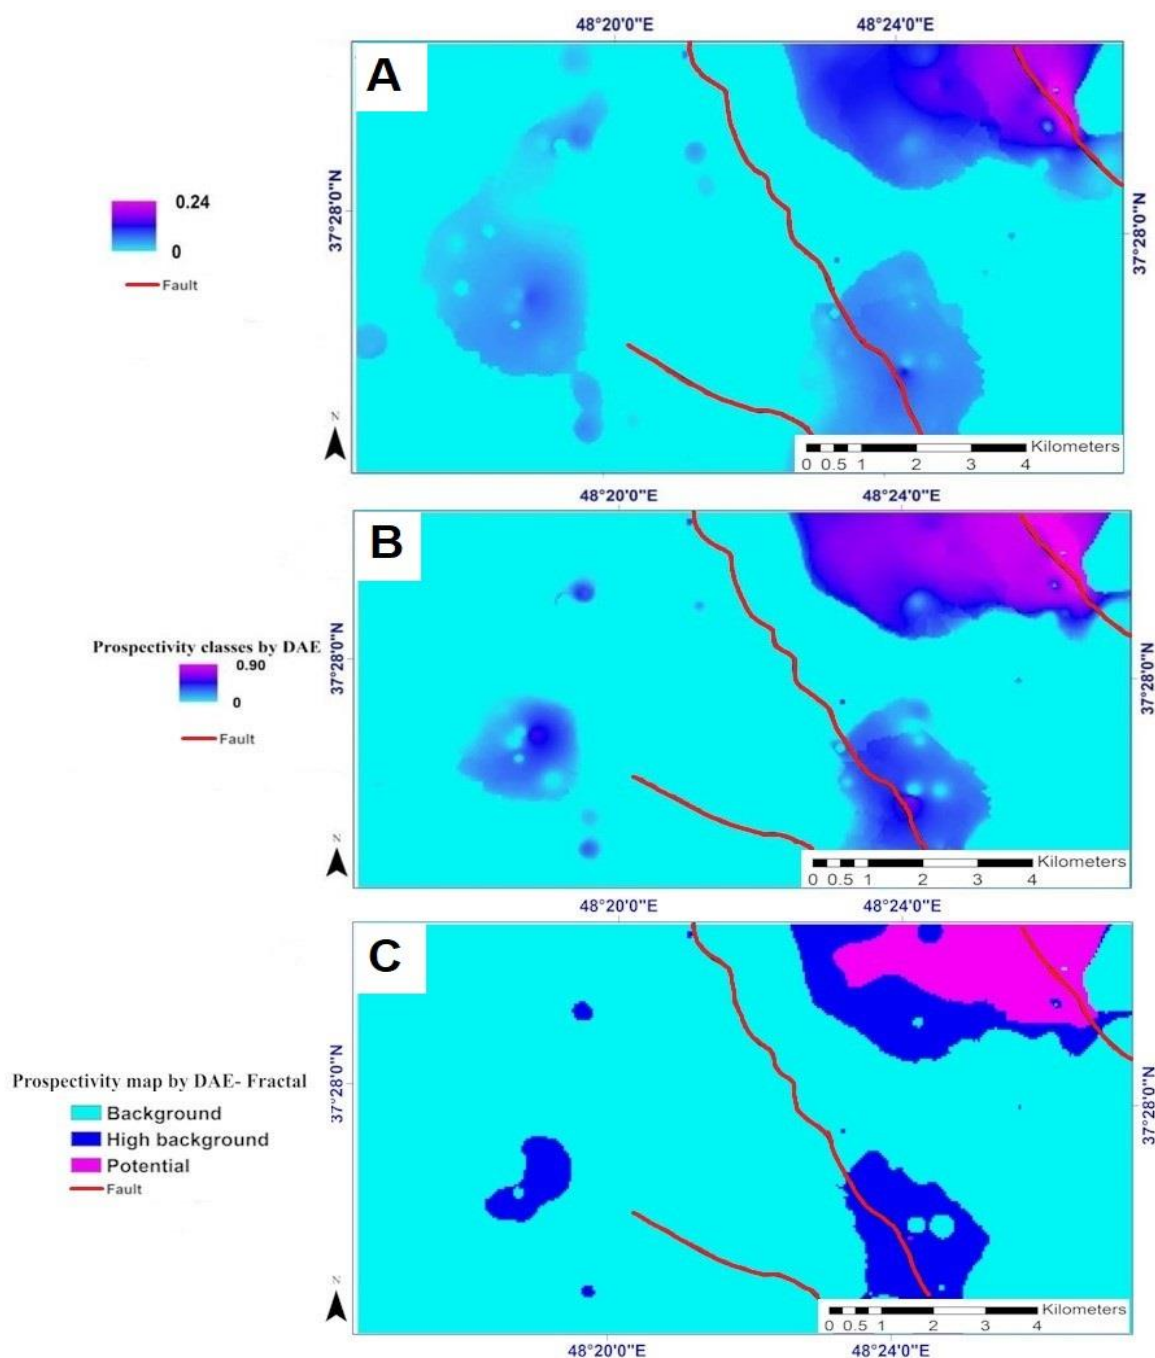
جدول ۳. مقادیر نقاط شکست در نمودار احتمال- مساحت در منطقه هشتجین

Table 3. Breakpoints values in the probability-area diagram in the Hashtjin area

Breakpoints	Breaking point 1	Breaking point 2
probability	0/22	0/61
Number of cells	9672	3619
Area (square meter) = number of cells 50*50	24180000	9047500



شکل ۱۱. نمودار لگاریتمی مدل چند فرکتالی عیار- مساحت و مقادیر شکست برای عناصر سرب، مس، روی، آهن، طلا و آرسنیک در منطقه هشتجین  
 Fig. 11. The logarithmic diagram of the C-N multifractal model and breakdown values for Pb, Cu, An, Fe, Au and As elements in the Hashtjin area



شکل ۱۲. نقشه های پتانسیل یابی معدنی به دست آمده بر اساس A: تلفیق فازی نقشه های زمین شیمیایی تک عنصری با عملگر گامای فازی (Gamma=0.9)، B: بازسازی نقشه به دست آمده از تلفیق فازی با روش خودرمزگذار عمیق در منطقه هشتجین روی نقشه بازسازی شده توسط خودرمزگذار عمیق در منطقه هشتجین

**Fig. 12.** Mineral prospectivity maps generated by A: Fuzzy integration of univariate geochemical maps with fuzzy gamma operator (Gamma=0.9), B: Reconstruction of the map resulting from fuzzy integration with the deep autoencoder method, and C: Implementation of fractal concentration-area method on the reconstructed map by deep autoencoder in the Hashtjin area

## نتیجه گیری

منطقه مورد پژوهش دارای ویژگی های پیچیده زمین شیمیایی است. در چنین منطقه پیچیده ای، باید چندین روش را با هم پیاده سازی کنیم که در آنها بتوانیم به طور دقیق ناهنجاری را از زمینه جدا کنیم. بر اساس نقشه های به دست آمده، روش ترکیبی پیشنهاد شده منطقه ای با مساحت ۹۰۴۷۵۰۰ متر مربع را در شمال شرق منطقه مورد بررسی به عنوان هدف اکتشافی با احتمال بالای کانی سازی معرفی می کند که معرفی آن با شرایط زمین شناسی منطقه همخوانی دارد. در این پژوهش، روش ترکیبی خودرمزگذار خودکار عمیق- فرکتال بهتر از روش های کلاسیک و خودرمزگذار خودکار (در بازسازی نقشه حاصل از انجام تلفیق فازی بر روی نقشه های زمین شیمیایی تک عنصری) توانسته است اهداف اکتشافی را معرفی کند. روش ترکیبی معرفی شده در این پژوهش ابزاری قدرتمند برای شناسایی ناهنجاری های زمین شیمیایی در مناطقی است که محیط پیچیده زمین شناسی و زمینه زمین شیمیایی متنوع

دارند. با توجه به نتایج، هر سه روش به کار برده شده در این پژوهش احتمال بالای کانی سازی چندفیزی در شمال شرق منطقه مورد بررسی را نشان می دهند. از این رو، انجام بررسی ها و مطالعات بیشتر در منطقه معرفی شده در پژوهش های بعدی توصیه می شود.

## تعارض منافع

هیچ گونه تعارض منافی توسط نویسندگان بیان نشده است.

## قدردانی

نویسندگان این مقاله از حمایت های سازمان زمین شناسی شمال غرب کشور، سازمان صنعت، معدن و تجارت استان اردبیل، همچنین از آقای مهندس داریوش گلابی و از ارائه نظرها و پیشنهادهای ارزنده و سازنده داوران محترم نشریه زمین شناسی اقتصادی تشکر و قدردانی می نمایند.

1. Machin Learning
2. Deep autoencode
3. unsupervised learning
4. Interpolation
5. Geostatistical
6. Deterministic
7. (IDW) Inverse Distance Weighting
8. Classified
9. Equal Interval
10. Natural Breaks
11. Quantile
12. Geometrical Interval
13. Input image
14. Decoded
15. Adam
16. Shapefile
17. GIS

## References

- Afzal, P., Aramesh Asl, R., Adib, A. and Yasrebi, A.B., 2015. Application of fractal modelling for Cu mineralisation reconnaissance by ASTER multispectral and stream sediment data in Khoshname area, NW Iran. *Journal of the Indian Society of Remote Sensing*, 43: 0255–660. <https://doi.org/10.1007/s12524-014-0384-6>
- Alavi, M., 1996. Tectonostratigraphic synthesis and structural style of the Alborz Mountains system northern Iran. *Journal of Geodynamic*, 21(1): 1–33. [https://doi.org/10.1016/0264-3707\(95\)00009-7](https://doi.org/10.1016/0264-3707(95)00009-7)
- Aramesh, Asl,R., Afzal, P., Adib, A. and Yasrebi, A.B., 2015. Application of multifractal modeling for the identification of alteration zones and major faults based on ETM+ multispectral data. *Arabian Journal of Geosciences*, 8: 2997–3006. <https://doi.org/10.1007/s12517-014-1366-2>
- Bergen, K.J., Johnson, P.A., De Hoop, M.V. and Beroza, G.C., 2019. Machine learning for data-driven discovery in solid earth geoscience, *Science*, 363(6433). <https://doi.org/10.1126/science.aau0323>
- Cheng, Q., 2006. Mapping singularities with stream sediment geochemical data for prediction of undiscovered mineral deposits in Gejiu, Yunnan Province, China. *Ore Geology Reviews*. 32(1–2): 314–324. <https://doi.org/10.1016/j.oregeorev.2006.10.002>
- Cheng, Q., Agterberg, F.P. and Ballantyne, S.B., 1994. The separation of geochemical anomalies from background by fractal methods. *Journal of Geochemical Exploration*. 51(2): 109–130. [https://doi.org/10.1016/0375-6742\(94\)90013-2](https://doi.org/10.1016/0375-6742(94)90013-2)
- Cheng, Q., Agterberg, F.P. and Bonham Carter, G.F., 1996. A spatial analysis method for geochemical anomaly separation. *Journal of Geochemical Exploration*.56(3): 183–195. [https://doi.org/10.1016/S0375-6742\(96\)00035-0](https://doi.org/10.1016/S0375-6742(96)00035-0)
- Cheng, Q., Xia, Q., Li, W., Zhang, S., Chen, Z., Zuo, R. and Wang, W., 2010. Density/area power-law models for separating multi-scale anomalies of ore and toxic elements in stream sediments in Gejiu mineral district, Yunnan Province, China. *Biogeosciences*.7(10): 3019–3025. <https://doi.org/10.5194/bg-7-3019-2010>
- Coates, A., Lee, H., and Ng, A. Y., 2011. An analysis of singlelayer networks in unsupervised feature learning. 14th International Conference on Artificial Intelligence and Statistics (AISTATS) 2011, Fort Lauderdale, FL, USA
- Daneshvar Saein, L., Afzal, P., Shahbazi, S. and Sadeghi, B., 2020. Application of an improved zonality index model integrated with multivariate fractal analysis: epithermal gold deposits. *Geopersia*,12(2): 379–394. <https://doi.org/10.22059/GEOPE.2022.339864.648652>
- Farhadi, S., Afzal, P., Boveiri Konari, M., Daneshvar Saeini, L. and Sadeghi, B., 2022. Combination of machine learning algorithms with concentration-area fractal method for soil geochemical anomaly detection in sediment-hosted Irankuh Pb-Zn deposit, Central Iran. *Minerals*, 12(6): 689. <https://doi.org/10.3390/min12060689>
- Farhadi, S., Tatullo, S., Konari, MB. and Afzal, P., 2024. Evaluating Stacking C and ensemble models for enhanced lithological classification in geological mapping. *Journal of Geochemical Exploration* 260: 107–441. <https://doi.org/10.1016/j.gexplo.2024.107441>
- Faridi, M., Anvari, A. and Ghassemi, M.R., 2000. Geological map of Hashtchin, scale 1:100000, Geological Organization of the country. Sheet Index 5664.
- Grunsky, E.C. and Agterberg, F.P., 1988. Spatial and multivariate analysis of geochemical data from metavolcanic rocks in the Ben Nevis area, Ontario. *Mathematical Geology*, 20(7): 825–861. <https://doi.org/10.1007/BF00890195>
- Hinton, G.E., Osindero, S. and Teh, Y.W., 2006. A fast-learning algorithm for deep belief nets. *Neural Computation* 18(7): 1527–54. <https://doi.org/10.1162/neco.2006.18.7.1527>
- LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *Nature*, 521: 436–444. <https://doi.org/10.1038/nature14539>
- Lecun, Y., Bottou, L., Bengio, Y. and Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11). <https://doi.org/10.1109/5.726791>
- Nabavi, M., 1976. An introduction to the geology of Iran. *Geological Survey of Iran*, 109: 104–109. (in Persian)
- Pourgholam, M.M., Afzal, P., Adib, A., Rahbar, K. and Gholinejad, M., 2024. Recognition of REEs anomalies using an image Fusion fractal-wavelet model in Tarom metallogenic zone, NW Iran. *Geochemistry*, 84(2): 126093.

- <https://doi.org/10.1016/j.chemer.2024.126093>
- Qaderi, S., 2014. Survey of Remote sensing and geochemical exploration of a region in Kermanshah 1:100000 sheet. Master thesis, Urmia University, Urmia, Iran. Retrieved September 26, 2024 from <https://elmnet.ir/doc/10927102-41181>
- Redlich, A.N., 1993. Redundancy reduction as a strategy for unsupervised learning. *Neural Computation*, 5(2): 289–304. <https://doi.org/10.1162/neco.1993.5.2.289>
- Reichstein, M., Camps Valls, G., Stevens, B., Jung, M., Denzler, J. and Carvalhais, N., 2019. Deep learning and process understanding for data-driven earth system science. *Nature*, 77(43): 195–204. <https://doi.org/10.1038/s41586-019-0912-1>
- Scott, A.J. and Knott, M., 1974. A cluster analysis method for grouping means in the analysis of variance. *Biometrics*, 30(30): 507–512. <https://doi.org/10.2307/2529204>
- Silverman, B.W., 1986. *Density Estimation for Statistics and Data Analysis*. Chapman & Hall, London – New York, 175 pp. <https://doi.org/10.1002/bimj.4710300745>
- Sim, B.L., Agterberg, F.P. and Beaudry, C., 1999. Determining the cutoff between background and relative base metal smelter contamination levels using multifractal methods. *Computers & Geosciences*, 25(9): 1023–1041. [https://doi.org/10.1016/S0098-3004\(99\)00064-3](https://doi.org/10.1016/S0098-3004(99)00064-3)
- Sun, T., Chen, F., Zhong, L., Liu, W. and Wang, Y., 2019. GIS-based mineral prospectivity mapping using machine learning methods: a case study from Tongling ore district, eastern China. *Ore Geology Reviews*, 109: 26–49. <https://doi.org/10.1016/j.oregeorev.2019.04.003>
- Tukey, J.W., 1977. Some thoughts on clinical trials, especially problems of multiplicity. *Science*. 198(4318): 679–684. <https://doi.org/10.1126/science.333584>
- Vapnik, V., 1995. *The Nature of Statistical Learning Theory*. Springer-Verlag, New York. 188 pp. <http://doi.org/10.1007/978-1-4757-2440-0>
- Wackernagel, H., 2003. *Multivariate geostatistics: An introduction with applications*. Springer Science & Business Media, Mathematical Geology, 388 pp. <http://doi.org/10.1007/978-3-662-05294-5>
- Ziaii, M., Ardejani, F.D., Ziaei, M. and Soleymani, A.A., 2012. Neuro-fuzzy modeling based genetic algorithms for identification of geochemical anomalies in mining geochemistry. *Applied Geochemistry*, 27(3): 663–676. <https://doi.org/10.1016/j.apgeochem.2011.12.020>
- Ziaii, M., Pouyan, A.A. and Ziaei M., 2009. Neuro-fuzzy modelling in mining geochemistry: Identification of geochemical anomalies. *Journal of Geochemical Exploration*.100(1): 25–36. <https://doi.org/10.1016/j.gexplo.2008.03.004>
- Zuo, R., 2017. Machine learning of mineralization-related geochemical anomalies: a review of potential methods. *Natural Resources Research*, 26: 457–464. <https://doi.org/10.1007/s11053-017-9345-4>
- Zuo, R., Cheng, Q., Agterberg, F.P. and Xia, Q., 2009. Application of singularity mapping technique to identify local anomalies using stream sediment geochemical data, a case study from Gangdese, Tibet, western China. *Journal of Geochemical Exploration*,101(3): 225–235. <https://doi.org/10.1016/j.gexplo.2008.08.003>
- Zuo, R. and Wang, J., 2016. Fractal/multifractal modeling of geochemical data. *Journal of Geochemical Exploration*. 164: 33–41. <https://doi.org/10.1016/j.gexplo.2015.04.010>
- Zuo, R., Xiong, Y., Wang, J. and Carranza, E., 2019. Deep learning and its application in geochemical mapping. *Earth- Science Reviews*, 192: 1–14. <https://doi.org/10.1016/j.earscirev.2019.02.023>