

Application of Machine Learning to Improve the Efficiency of Mineral Exploration: A Case Study of Geochemical Anomaly Separation in the Maraki Area, Hormozgan Province, Iran

 <https://doi.org/10.22034/bs.2026.2089400.3242>

Mahdis Satari, M.Sc. Student in Mining Engineering (Mineral Exploration), School of Mining Engineering, College of Engineering, University of Tehran, Tehran, Iran. 

Golnaz Jozanikohan*, Assistant Professor, Ph.D. in Mining Engineering (Mineral Exploration), School of Mining Engineering, College of Engineering, University of Tehran, Tehran, Iran. 

Accepted: 2 June 2026

Received: 23 May 2026

Revised: 30 May 2026

Machine Learning/ Random Forest/ Geochemical Anomaly/ Mineral Exploration/ Exploration Efficiency/ Maraki; Hormozgan

The increasing costs and uncertainties associated with the early stages of mineral exploration highlight the need for advanced analytical approaches to improve the efficiency of exploration processes. This study investigates the application of machine learning algorithms to enhance mineral exploration efficiency through the separation of geochemical anomalies. The Maraki area in Hormozgan Province, Iran, was selected as the case study, and regional geochemical data were analyzed using a combination of statistical methods and machine learning models. Initially, descriptive statistical and correlation analyses were conducted to examine the characteristics of the dataset and identify relationships among geochemical elements. Subsequently, classical statistical approaches, including the standard deviation method and the Median Absolute Deviation (MAD) method, were applied to distinguish background values from anomalous concentrations. In the next stage, the Random Forest algorithm was employed as an effective machine learning technique to identify complex patterns and nonlinear relationships among geochemical elements. The results indicate that the Random Forest model outperforms traditional statistical methods in identifying areas with high mineralization potential. The probability maps generated by the model also demonstrate strong spatial correspondence with the geological and structural features of the study area. Overall, the findings suggest that integrating machine learning techniques with conventional geological and geochemical analyses can significantly improve the accuracy of exploration data interpretation, reduce uncertainty during the early stages of exploration, and enhance the economic efficiency of mineral exploration activities. These results highlight the potential of data-driven approaches to improve decision-making and planning in mineral exploration.

Data Availability

The data used or generated in this research are presented in the text of the article.

Conflicts of Interest

The authors of this paper declare no conflict of interest regarding the authorship or publication of this article.

* Corresponding Author: gjkohan@ut.ac.ir

doi <https://doi.org/10.22034/bs.2026.2089400.3242>

مقاله پژوهشی

کاربرد یادگیری ماشین در ارتقای بهره‌وری اکتشافات معدنی: مطالعه موردی جدایش ناهنجاری‌های ژئوشیمیایی در محدوده مراکی هرمزگان

دریافت: ۱۴۰۵ / ۰۳ / ۰۲ بازنگری: ۱۴۰۵ / ۰۳ / ۰۹ پذیرش: ۱۴۰۵ / ۰۳ / ۱۲

مهدیس ستاری^۱ 
گلناز جوزانی کهن^۲ (نویسنده مسئول) 

چکیده

افزایش هزینه‌ها و عدم قطعیت در مراحل اولیه اکتشاف معدنی، ضرورت استفاده از روش‌های تحلیلی پیشرفته برای بهبود کارایی فرآیندهای اکتشافی را برجسته کرده است. در این پژوهش، کاربرد الگوریتم‌های یادگیری ماشین در ارتقای بهره‌وری اکتشافات معدنی از طریق جدایش ناهنجاری‌های ژئوشیمیایی مورد بررسی قرار گرفته است. محدوده مراکی در استان هرمزگان به عنوان مطالعه موردی انتخاب شد و داده‌های ژئوشیمیایی منطقه با بهره‌گیری از ترکیبی از روش‌های آماری و مدل یادگیری ماشین تحلیل گردید. در مرحله نخست، تحلیل‌های آماری توصیفی و همبستگی برای بررسی ویژگی‌های داده‌ها و شناسایی روابط میان عناصر ژئوشیمیایی انجام شد. سپس به منظور تفکیک مقادیر زمینه و ناهنجاری، از روش‌های آماری کلاسیک شامل انحراف معیار و انحراف از میانه استفاده شد. در ادامه، الگوریتم جنگل تصادفی

به عنوان یکی از روش‌های کارآمد یادگیری ماشین برای شناسایی الگوهای پیچیده و روابط غیرخطی میان عناصر ژئوشیمیایی به کار گرفته شد. نتایج نشان داد که مدل جنگل تصادفی در مقایسه با روش‌های آماری سنتی توانایی بالاتری در شناسایی نواحی مستعد کانی‌سازی دارد و نقشه‌های حاصل از این مدل هم‌خوانی مناسبی با روندهای زمین‌شناسی و ساختاری منطقه نشان می‌دهند. یافته‌های پژوهش بیانگر آن است که استفاده از رویکردهای مبتنی بر یادگیری ماشین می‌تواند به بهبود دقت تحلیل داده‌های اکتشافی، کاهش عدم قطعیت در مراحل اولیه اکتشاف و ارتقای بهره‌وری اقتصادی فعالیت‌های معدنی کمک کند. این نتایج می‌تواند در طراحی راهبردهای نوین اکتشاف معدنی و توسعه رویکردهای داده‌محور در بخش معدن مورد استفاده قرار گیرد.

طبقه‌بندی JEL: Q3، Q32، C45

کلمات کلیدی: یادگیری ماشین / جنگل تصادفی / ناهنجاری ژئوشیمیایی / اکتشاف معدنی / بهره‌وری اکتشاف

۱. کارشناسی ارشد رشته مهندسی معدن گرایش اکتشاف مواد معدنی، دانشکده مهندسی معدن، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران
۲. استادیار، دکتری مهندسی معدن گرایش اکتشاف معدن، دانشکده مهندسی معدن، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران
gjkohan@ut.ac.ir

۱. مقدمه و طرح مسئله

بخش معدن به عنوان یکی از منابع اصلی تأمین مواد اولیه برای فعالیت‌های تولیدی، نقش مهمی در توسعه اقتصادی و صنعتی کشورها ایفا می‌کند. مطالعات نشان می‌دهد که توسعه فعالیت‌های معدنی و نحوه بهره‌برداری از منابع معدنی می‌تواند بر سرمایه‌گذاری‌های مرتبط با مدیریت محیط‌زیست و حکمرانی در بخش معدن تأثیرگذار باشد و بهبود کیفیت حکمرانی و مقررات می‌تواند نقش مهمی در هدایت فعالیت‌های معدنی به سمت توسعه پایدار ایفا کند (رجبی و عادل‌نیک، ۱۴۰۲). همچنین پژوهش‌های مختلف در حوزه اقتصاد معدن نشان می‌دهند که توسعه فعالیت‌های معدنی می‌تواند آثار قابل توجهی بر رشد اقتصادی، توسعه منطقه‌ای و شکل‌گیری ساختارهای اقتصادی در مناطق معدنی داشته باشد و از این رو بررسی کارایی و بهره‌وری در فرآیندهای اکتشاف و بهره‌برداری معدنی از اهمیت زیادی برخوردار است (عادل‌نیک و رجبی، ۱۴۰۱).

اکتشاف مواد معدنی یکی از حلقه‌های اساسی زنجیره ارزش بخش معدن محسوب می‌شود و نقش تعیین‌کننده‌ای در تأمین مواد اولیه صنایع و توسعه اقتصادی کشورها ایفا می‌کند (Doherty et al., 2023). با گسترش صنایع مبتنی بر فلزات و افزایش تقاضای جهانی برای مواد معدنی، شناسایی منابع جدید معدنی به یکی از اولویت‌های راهبردی در سیاست‌های توسعه صنعتی تبدیل شده است (Zheng et al., 2023). در این میان، ارتقای بهره‌وری در فرآیندهای اکتشافی و کاهش عدم قطعیت در شناسایی ذخایر معدنی از اهمیت ویژه‌ای برخوردار است؛ زیرا فرآیند اکتشاف ذاتاً با ریسک بالا، هزینه‌های قابل توجه و عدم قطعیت‌های زمین‌شناسی همراه است (Meloni et al., 2026).

اکتشافات ژئوشیمیایی یکی از مؤثرترین ابزارها برای شناسایی مناطق امیدبخش معدنی به شمار می‌روند. این روش بر پایه نمونه‌برداری سیستماتیک از محیط‌های زمین‌شناسی نظیر سنگ، خاک یا رسوبات آبراهه‌ای و تحلیل

غلظت عناصر مختلف استوار است. هدف اصلی در این رویکرد، شناسایی ناهنجاری‌های ژئوشیمیایی است؛ به بیان دیگر، الگوهای غیرعادی در توزیع غلظت عناصر که می‌توانند نشان‌دهنده حضور کانی‌سازی در اعماق زمین باشند (Jozanikohan et al., 2021). با این حال، یکی از چالش‌های اساسی در تحلیل داده‌های ژئوشیمیایی، تفکیک دقیق ناهنجاری‌های واقعی از مقادیر طبیعی زمینه است. این مسئله به‌ویژه در مراحل اولیه اکتشاف اهمیت دارد، زیرا ناهنجاری‌های مرتبط با کانی‌سازی اغلب ضعیف، چندمتغیره و دارای همپوشانی آماری با مقادیر زمینه هستند (Zhong et al., 2021; Doherty et al., 2023).

روش‌های آماری کلاسیک که به طور سنتی برای جدایش ناهنجاری‌های ژئوشیمیایی مورد استفاده قرار گرفته‌اند، عمدتاً بر تحلیل توزیع آماری داده‌ها و تعیین آستانه‌های تفکیک متکی هستند. اگرچه این روش‌ها در بسیاری از مطالعات اکتشافی کاربرد داشته‌اند، اما محدودیت‌های مهمی دارند (حسنی‌پاک، ۱۳۹۴). نخست آنکه تعیین آستانه^۳ تفکیک در بسیاری از موارد به قضاوت کارشناس وابسته است و می‌تواند موجب بروز عدم قطعیت در نتایج شود. دوم آنکه بسیاری از این روش‌ها قادر به مدل‌سازی روابط پیچیده و غیرخطی میان عناصر ژئوشیمیایی نیستند (Zuo et al., 2019; Zhang Zhou et al., 2024).

افزون بر این، داده‌های ژئوشیمیایی اغلب با مشکلاتی نظیر وجود داده‌های پرت، مقادیر زیر حد تشخیص و توزیع‌های غیرنرمال مواجه هستند که می‌تواند موجب خطا در تحلیل‌های آماری و روش‌های درونیابی شود؛ از این رو استفاده از روش‌های تخمین غیرپارامتری که وابستگی کمتری به تابع توزیع داده‌ها دارند می‌تواند راهکار مناسبی برای تفسیر داده‌های ژئوشیمیایی باشد (Mohammadpour et al., 2019).


1. Background
2. Separation
3. Thresholding

ناهنجاری های ژئوشیمیایی عنصر مس در محدوده اکتشافی مراکی در شرق پهنه بشاگرد انجام شده است. در این پژوهش تلاش شده است با بهره گیری از داده های لیتوژئوشیمیایی منطقه و مقایسه عملکرد الگوریتم جنگل تصادفی با برخی روش های آماری، کارایی این رویکرد در بهبود دقت شناسایی اهداف اکتشافی مورد ارزیابی قرار گیرد. نتایج این مطالعه می تواند به توسعه رویکردهای داده محور در اکتشافات معدنی و ارتقای کارایی فرآیند تصمیم گیری در مراحل اولیه اکتشاف کمک کند.

۲. منطقه مورد مطالعه

۲-۱. موقعیت جغرافیایی و راه های دسترسی

محدوده مورد مطالعه در پهنه بشاگرد، در شرق استان هرمزگان و در مجاورت مرز استان سیستان و بلوچستان واقع شده است. این محدوده با وسعتی حدود ۷۱ کیلومتر مربع در محدوده شهرستان های بشاگرد و جاسک قرار داشته و در نقشه زمین شناسی ۱:۱۰۰۰۰۰ مراکی مشخص شده است. نمودار (۱) موقعیت محدوده مراکی در ایران را نشان می دهد.



نمودار ۱. موقعیت محدوده مراکی و نقشه برگ های زمین شناسی مورد استفاده در تحلیل های اکتشافی

منطقه در فاصله حدود ۱۴۰ کیلومتری غرب شهر نیک شهر و حدود ۷۰ کیلومتری جنوب غرب شهر بنت قرار دارد و روستاهای توتان و سونته سر در مجاورت شمالی و شرقی آن واقع شده اند. مختصات جغرافیایی محدوده بین

در سال های اخیر، پیشرفت های قابل توجه در حوزه داده کاوی و یادگیری ماشین^۱، فرصت های جدیدی برای تحلیل داده های زمین شناسی و ژئوشیمیایی فراهم کرده است (Rodriguez-Galiano et al., 2015). الگوریتم های یادگیری ماشین به دلیل توانایی بالا در تحلیل داده های چندمتغیره و شناسایی الگوهای پیچیده و غیرخطی، به تدریج در مطالعات اکتشافی مورد توجه قرار گرفته اند (McKay & Harris, 2016). این الگوریتم ها می توانند با استفاده از ساختارهای محاسباتی پیشرفته، روابط پنهان میان متغیرها را استخراج کرده و فرآیند طبقه بندی^۲ یا پیش بینی را با دقت بالاتری انجام دهند (Lachaud et al., 2023).

در میان الگوریتم های مختلف یادگیری ماشین، الگوریتم جنگل تصادفی^۳ به عنوان یکی از روش های یادگیری گروهی^۴ مبتنی بر درخت تصمیم^۵، قابلیت قابل توجهی در مسائل طبقه بندی و تحلیل داده های پیچیده نشان داده است. این الگوریتم با ترکیب مجموعه ای از درختان تصمیم و استفاده از مکانیزم رأی گیری جمعی، قادر است مرزهای تصمیم گیری غیرخطی را به خوبی مدل سازی کرده و در برابر نویز و داده های پرت مقاومت بالایی از خود نشان دهد (Trott et al., 2022). علاوه بر این، یکی از مزایای مهم جنگل تصادفی، امکان تحلیل اهمیت متغیرها است که می تواند در تفسیر زمین شناسی داده های ژئوشیمیایی و شناسایی عناصر راهنما در فرآیند اکتشاف مفید واقع شود (Zhou et al., 2025). با وجود گسترش استفاده از روش های یادگیری ماشین در علوم زمین، هنوز نیاز به مطالعات کاربردی که کارایی این الگوریتم ها را در شرایط واقعی داده های اکتشافی ارزیابی کنند، احساس می شود. از این رو، پژوهش حاضر با هدف بررسی کاربرد الگوریتم جنگل تصادفی در جدایش

1. Machine Learning
2. Classification
3. Random Forest
4. Ensemble Learning
5. Decision Tree

۲-۳. ویژگی‌های زمین‌شناسی و ساختاری

از نظر زمین‌شناسی، محدوده مورد مطالعه بخشی از پهنه ساختاری بشاگرد محسوب می‌شود که تحت تأثیر فعالیت‌های تکتونیکی شدید قرار گرفته است. شبکه‌ای متراکم از گسل‌ها و شکستگی‌ها منطقه را قطع کرده و راستای غالب این ساختارها شمال‌شرق-جنوب‌غرب است. بیشترین تراکم شکستگی‌ها در بخش‌های مرکزی و شمالی منطقه، به‌ویژه در مرز میان واحدهای آذرین و رسوبی مشاهده می‌شود. بسیاری از آبراهه‌ها و دره‌های منطقه نیز تبعیت مستقیمی از این ساختارهای گسلی دارند (سازمان زمین‌شناسی و اکتشافات معدنی کشور، ۱۳۹۸). واحدهای سنگی منطقه شامل مجموعه‌ای از سنگ‌های رسوبی، آذرین و آذرآواری با سن‌های مختلف است. رسوبات میوسن شامل شیل‌ها و ماسه‌سنگ‌های تپه‌ماهوری عمدتاً در بخش‌های شمالی و جنوبی گسترش دارند. در بخش‌های مرکزی، واحدهای آذرین شامل گدازه‌های بازالتی و آندزیتی همراه با واحدهای آهکی پلاژیک مشاهده می‌شوند. علاوه بر این، واحدهای اولترامافیک سرپانتینی‌شده، توده‌های نفوذی دیوریتی تا گابرو دیوریتی و دایک‌های دیابازی نیز در منطقه رخنمون دارند. حضور دگرسانی‌هایی نظیر کلریتی، اپیدوتی و سرپانتینی در برخی از واحدهای سنگی نشان‌دهنده پتانسیل کانی‌سازی در این محدوده است (سازمان زمین‌شناسی و اکتشافات معدنی کشور، ۱۳۹۸). در نمودار (۲) نقشه زمین‌شناسی فنوج قابل مشاهده است.



نمودار ۲. نقشه زمین‌شناسی فنوج (سازمان زمین‌شناسی و اکتشافات معدنی کشور، ۱۳۹۸).

عرض‌های شمالی ۲۶°۱۲ تا ۲۶°۱۴ و طول‌های شرقی ۵۸°۵۷ تا ۵۸°۵۹ قرار دارد (سازمان توسعه و نوسازی معادن و صنایع معدنی ایران، ۱۳۹۸). دسترسی به منطقه عمدتاً از طریق محور چابهار- نیک‌شهر و سپس شهر بنت امکان‌پذیر است و در ادامه از مسیر روستای توتان به سمت روستای سونته‌سر می‌توان به محدوده مورد مطالعه رسید. شبکه راه‌های ارتباطی در این منطقه محدود بوده و بخش قابل توجهی از مسیرهای دسترسی شامل راه‌های فرعی و محلی است.

۲-۲. شرایط اقلیمی، پوشش گیاهی و توپوگرافی

منطقه دارای اقلیم گرم و نسبتاً مرطوب با تابستان‌های بسیار گرم و دمای تا حدود ۴۵ درجه سانتی‌گراد و زمستان‌های معتدل با میانگین دمای ۱۰ تا ۲۰ درجه سانتی‌گراد است. میانگین بارندگی سالانه حدود ۱۲۰ تا ۱۴۰ میلی‌متر بوده و عمدتاً به صورت رگبارهای کوتاه‌مدت در فصول زمستان و بهار رخ می‌دهد. به دلیل بارندگی محدود و تبخیر بالا، منابع آب سطحی و زیرزمینی در منطقه فقیر بوده و آبراهه‌ها عمدتاً فصلی هستند (سازمان توسعه و نوسازی معادن و صنایع معدنی ایران، ۱۳۹۸).

پوشش گیاهی منطقه به دلیل شرایط اقلیمی خشک، پراکنده و تنک است و بیشتر در امتداد آبراهه‌ها توسعه یافته است. از مهم‌ترین گونه‌های گیاهی منطقه می‌توان به نخل وحشی (داز) و برخی گیاهان صمغی نظیر آنغوزه و کتیرا اشاره کرد. خاک منطقه غالباً شنی تا ماسه‌ای بوده و از نظر مواد آلی فقیر است. از نظر توپوگرافی، منطقه دارای ناهمواری قابل توجهی بوده و ارتفاع آن بین حدود ۶۰۰ تا ۱۲۰۰ متر از سطح دریا متغیر است. بیشترین ارتفاعات در بخش‌های مرکزی و شمال‌غربی محدوده و عمدتاً بر روی واحدهای آذرین مقاوم قرار دارند (سازمان توسعه و نوسازی معادن و صنایع معدنی ایران، ۱۳۹۸).

۴-۲. نمونه برداری و آنالیزهای ژئوشیمیایی

با توجه به شواهد زمین شناسی و احتمال وجود کانی سازی مس از نوع سولفید توده ای، نمونه برداری لیتوژئوشیمیایی به صورت سیستماتیک در منطقه انجام شد. شبکه نمونه برداری با فواصل ۱۰۰×۱۰۰ متر در مناطق زمینه و ۵۰×۵۰ متر در مناطق مستعد طراحی گردید. در مجموع ۲۱۱ نمونه سنگی از واحدهای مختلف سنگی منطقه برداشت شد. نمونه ها پس از آماده سازی در آزمایشگاه زراژما پرشیا در بندرعباس با استفاده از روش های Fire Assay و ICPOES برای ۳۴ عنصر شیمیایی آنالیز شدند. به منظور کنترل کیفیت داده ها، تعدادی نمونه تکراری و استاندارد نیز در فرآیند آنالیز مورد استفاده قرار گرفت.

۳. روش شناسی پژوهش

۳-۱. پیش پردازش و تحلیل تک متغیره داده ها

در این پژوهش، مجموعه داده ای شامل ۲۱۱ نمونه سنگی برداشت شده از واحدهای مختلف سنگی منطقه مورد مطالعه مورد استفاده قرار گرفت. غلظت ۳۴ عنصر

ژئوشیمیایی شامل Ag, Al, As, Ba, Be, Ca, Cd, Ce, Co, Cr, Cu, Fe, K, La, Li, Mg, Mn, Mo, Na, Ni, P, Pb, S, Sb, Sc, Sr, Th, Ti, U, V, Y, Yb, Zn اندازه گیری شد. انتخاب این مجموعه از عناصر با توجه به ماهیت کانی زایی احتمالی از نوع سولفید توده ای صورت گرفت؛ در این نوع کانسارها عناصر پایه (Cu, Pb, Zn) به همراه عناصر ردیاب نظیر Ag, As, Sb, Ba, Co, Ni, Cr و عناصر مرتبط با دگرسانی (K, Na, Mg, Ca) نقش کلیدی در شناسایی الگوهای ژئوشیمیایی دارند و از این رو گنجاندن آن ها برای مدل سازی ضروری است.

در مرحله نخست، کیفیت داده ها و میزان مقادیر زیر حد تشخیص بررسی شد. عناصری که درصد قابل توجهی از مقادیر آن ها کمتر از حد تشخیص آزمایشگاهی بود از مجموعه داده حذف شدند. بر این اساس عناصر Ag, Mo, Th و U به دلیل داشتن بیش از ۴۰ درصد داده های سانسور شده از تحلیل های بعدی کنار گذاشته شدند. نتایج این تحلیل ها در جدول قابل مشاهده است.

جدول ۱. فهرست عناصر حذف شده از پژوهش به دلیل درصد بالای داده های زیر حد تشخیص


وضعیت	درصد داده های زیر حد تشخیص	حد تشخیص (ppm)	عنصر
حذف شده	۸۵٫۸	۰٫۵۰	Ag
حذف نشده	۱٫۴	۱۰۰	Al
حذف نشده	۱۸٫۵	۱۰۰	Ca
حذف نشده	۳۷٫۰	۱۰۰	Mg
حذف شده	۹۵٫۰	۰٫۵۰	Mo
حذف شده	۱۰۰	۵٫۰	Th
حذف شده	۱۰۰	۵٫۰	U

برای داده های با چولگی کم تا متوسط توصیه شده است واز کاهش مصنوعی واریانس داده ها جلوگیری می کند. در گام بعدی، داده های پرت^۲ با استفاده از روش دامنه بین چارکی


برای سایر عناصر، مقادیر زیر حد تشخیص با نصف مقدار حد تشخیص ($DL/2$) جایگزین شدند؛ این روش در مطالعات ژئوشیمیایی به عنوان راه کاری ساده و غیراریب

(IQR) شناسایی و مدیریت شدند. پس از پالایش داده‌ها، توزیع آماری عناصر با استفاده از هیستوگرام‌ها، نمودارهای احتمال و آزمون اندرسون-دارلینگ مورد بررسی قرار گرفت.

نمودار (۳) الف و ب نمودار احتمال نرمال^۱ و هیستوگرام عنصر مس را نشان می‌دهد.



(ب)



(الف)

نمودار ۳. الف) نمودار احتمال نرمال (با فاصله اطمینان ۹۵٪) برای داده‌های عنصر مس (ب) توزیع فراوانی داده‌های عنصر مس

همان‌طور که در هیستوگرام دیده می‌شود، توزیع دارای چولگی مثبت است. به منظور کاهش اثر چولگی و آماده‌سازی داده‌ها برای تحلیل‌های چندمتغیره، تبدیل لگاریتمی بر روی داده‌ها اعمال شد. در ادامه شاخص‌های آماری توصیفی شامل

میانگین، میانه، انحراف معیار، ضریب تغییرات، چولگی و کشیدگی برای عناصر محاسبه شد. جدول (۱) شاخص‌های آماری توصیفی غلظت مس را نشان می‌دهد.

جدول ۲. شاخص‌های آماری توصیفی غلظت عناصر در نمونه‌های مورد مطالعه (بر حسب ppm)

Element	Mean	StDev	Variance	Cvariation	Median	Minimum	Maximum	Skewness	Kurtosis
Cu 65.4882		38.306	1467.33	58.4926	53	13	141.5	1.00319	-0.19624

همچنین برای بررسی روابط بین عناصر، ماتریس همبستگی پیرسون محاسبه گردید. این تحلیل امکان شناسایی انجمن‌های ژئوشیمیایی و عناصر راهنما در سیستم‌های کانی‌سازی را فراهم می‌کند. مجموع این مراحل پیش‌پردازش، داده‌های ژئوشیمیایی را برای انجام تحلیل‌های پیشرفته‌تر شامل روش‌های آماری جدایش ناهنجاری و الگوریتم‌های یادگیری ماشین آماده ساخت. نتایج محاسبه ماتریس همبستگی پیرسون در جدول (۲) نشان داده می‌شود. گروه عناصر لیتوفیل اصلی همبستگی بسیار قوی با سیلیکات‌ها و اکسیدها نشان می‌دهند، به‌ویژه Al-Sc در کانی‌های

رسی^۱ و Fe-V در اکسیدهای آهن. در گروه کالکوفیل، قوی‌ترین همبستگی مربوط به Cr-Ni با منشأ اولترامافیک است، در حالی که Cu-Li مرتبط با فرایندهای هیدروترمال و Pb-S نشان‌دهنده سولفید سرب احتمالی می‌باشد. عناصر نادر خاکی مانند Ce-La دومین همبستگی قوی را داشته و ارتباط بسیار قوی Ce-P و La-P نقش فسفات را در تمرکز REE تأیید می‌کند. در گروه آلکالی و آلکالی خاکی، Na-Fe همبستگی قوی (جایگزینی در فلدسپات‌ها)، K-Co متوسط، و همبستگی‌های منفی مانند Fe-Cr، Al-Cr و

1. Probability Plots

همبستگی مثبت و با La-Ce منفی دارد؛ نیکل و کروم با Cr-Ni بسیار قوی و Ca مثبت، ولی با Al, Fe, Na منفی همراهند؛

Na-Ni نشان‌دهنده تفاوت ژئوشیمیایی بین محیط‌های فلسیک و مافیک هستند. از نظر اکتشافی، مس با Li و Co

جدول ۳. ماتریس همبستگی پیرسون برای عناصر منتخب

	Al	As	Ba	Be	Ca	Cd	Ce	Co	Cr	Cu	Fe	K	La	Li	Mg	Mn	Na	Ni	P	Pb	S	Sb	Sc	Sr	Ti	V
Al	1																									
As	0.217	1																								
Ba	-0.26	-0.015	1																							
Be	0.673	0.2	-0.102	1																						
Ca	-0.2	0.021	0.2115	-0.04	1																					
Cd	-0.29	0.121	0.0303	-0.25	0.239	1																				
Ce	0.037	0.187	0.0914	-0.19	-0.03	-0.099	1																			
Co	0.23	-0.029	-0.331	0.325	0.016	8E-04	-0.31	1																		
Cr	-0.32	-0.18	0.1089	-0.16	0.252	0.069	-0.39	0.45	1																	
Cu	0.258	0.075	-0.153	0.243	-0.04	0.008	-0.39	0.33	0.166	1																
Fe	0.547	0.248	-0.093	0.565	-0.17	-0.242	0.476	0.07	-0.46	-0.133	1															
K	0.13	0.108	-0.28	0.174	0.24	0.178	-0.31	0.43	0.196	0.214	-0.007	1														
La	-0.18	0.141	0.1504	-0.34	0.107	-0.006	0.939	-0.31	-0.25	-0.4	0.314	-0.24	1													
Li	0.499	-0.095	-0.188	0.305	-0.41	-0.202	-0.45	0.27	0.029	0.449	-0.08	-0.06	-0.57	1												
Mg	0.303	-0.047	-0.167	0.362	0.021	-0.056	-0.26	0.37	0.095	0.156	0.145	0.186	-0.31	0.28	1											
Mn	0.215	-0.067	-0.095	0.082	-0.33	-0.193	0.27	0.02	-0.34	0.03	0.305	-0.18	0.175	0.28	0.112	1										
Na	0.501	0.258	-0.001	0.288	-0.41	-0.35	0.592	-0.19	-0.48	-0.127	0.6	-0.46	0.357	0.12	-0.09	0.27	1									
Ni	-0.38	-0.175	0.049	-0.2	0.29	0.08	-0.33	0.42	0.924	0.118	-0.475	0.26	-0.17	-0.1	0.019	-0.31	-0.53	1								
P	0.047	0.286	-0.081	-0.14	-0.13	-0.058	0.87	-0.2	-0.45	-0.392	0.577	-0.18	0.812	-0.4	-0.21	0.27	0.58	-0.37	1							
Pb	-0.17	-0.012	0.1575	-0.14	0.162	0.121	0.24	0.13	0.085	-0.016	0.151	0.058	0.351	-0.2	0.011	0.19	-0.19	0.111	0.2	1						
S	-0.25	0.126	0.4296	-0.25	0.221	0.224	0.405	-0.15	-0.07	-0.28	0.111	-0.21	0.454	-0.4	-0.18	0.01	0.057	-0.07	0.34	0.35	1					
Sb	-0.03	0.046	0.0668	-0.05	0.06	0.032	0.123	0.03	-0.06	-0.078	0.022	0.012	0.159	-0.1	0.004	0.04	-0.01	-0.07	0.07	0.09	0.16	1				
Sc	0.705	0.079	-0.302	0.757	-0.15	-0.252	-0.19	0.58	0.023	0.339	0.481	0.291	-0.35	0.4	0.363	0	0.303	-0.05	-0.1	-0.2	-0.4	-0.07	1			
Sr	0.495	0.195	0.0143	0.291	-0.15	-0.06	-0.3	-0.04	-0.08	0.28	-0.061	-0.03	-0.39	0.59	0.148	0.12	0.103	-0.16	-0.33	-0.3	-0.2	-0.11	0.19	1		
Ti	0.495	0.195	0.0143	0.291	-0.15	-0.06	-0.3	-0.04	-0.08	0.28	-0.061	-0.03	-0.39	0.59	0.148	0.12	0.103	-0.16	-0.33	-0.3	-0.2	-0.11	0.19	0.05	1	
V	0.661	0.186	-0.13	0.988	-0.04	-0.211	-0.26	0.4	-0.12	0.276	0.521	0.205	-0.41	0.33	0.373	0.06	0.245	-0.16	-0.2	-0.2	-0.3	-0.04	0.79	0.3	0.303	1

و مشاهدات صحرایی، شاخص غنی‌شدگی خنثی برای هر نمونه محاسبه شد. برای هر عنصر، میانه غلظت در هر واحد سنگی به عنوان زمینه محلی در نظر گرفته شد و مقدار ناهنجاری هر نمونه از رابطه (۱) به دست آمد:

$$\text{Enrichment Index} = \frac{\text{Concentration}_{\text{sample}}}{\text{Median}_{\text{rock unit}}} \quad (1)$$

این شاخص، اختلاف غلظت هر نمونه را نسبت به پس‌زمینه سنگ‌شناسی خود نشان می‌دهد و اثر ترکیب سنگ را حذف

و REEها با فسفر شاخص مناسبی برای کانی‌های فسفات محسوب می‌شوند. این الگوها تأثیرپذیری از سنگ‌میزبان را نشان داده و می‌توانند مبنای طراحی مدل‌های اکتشافی و اولویت‌بندی نمونه‌برداری قرار گیرند.

۳-۲. خنثی‌سازی اثر سنگ‌شناسی با شاخص غنی‌شدگی برای جلوگیری از یادگیری مدل براساس تفاوت‌های زمینه سنگ‌شناسی و اطمینان از اینکه الگوریتم ناهنجاری‌های واقعی کانی‌سازی را تشخیص می‌دهد، لازم است اثر سنگ‌میزبان خنثی شود. به این منظور، پس از شناسایی واحدهای اصلی سنگی با استفاده از نقشه زمین‌شناسی

می‌کند. به این ترتیب، مقادیر مثبت شاخص بیانگر غنی‌شدگی احتمالی ناشی از فرایندهای کانی‌سازی مستقل از جنس سنگ هستند. داده‌های ورودی به مدل‌های آماری و یادگیری ماشین براساس این شاخص‌های غنی‌شدگی تنظیم شدند.

۳-۳. روش‌های آماری کلاسیک جدایش ناهنجاری


برای شناسایی اولیه ناهنجاری‌های ژئوشیمیایی و تفکیک آن‌ها از مقادیر زمینه، از دو روش کلاسیک استفاده شد: روش انحراف معیار و روش انحراف مطلق میانه (MAD). در روش انحراف معیار، مقادیر بزرگ‌تر از میانگین به علاوه دو برابر انحراف معیار به عنوان ناهنجاری در نظر گرفته شد.

روش MAD نیز با استفاده از رابطه (۲)


$$\begin{aligned} \text{Threshold} &= \text{Median} + 2 \times \text{MAD} \\ \text{MADThreshold} &= \text{Median} + 2 \times \text{MAD} \end{aligned} \quad (2)$$

آستانه‌گذاری شد. این دو روش به عنوان مبنا برای مقایسه با خروجی مدل یادگیری ماشین به کار رفتند. نقشه‌های ناهنجاری حاصل از این دو روش در نمودار (۴) نشان داده شده است.

۳-۴. مدل‌سازی با جنگل تصادفی و برچسب‌گذاری داده‌ها برای به کارگیری الگوریتم یادگیری نظارت‌شده، برچسب‌گذاری



(ب)



(الف)

نمودار ۴. نقشه ناهنجاری ژئوشیمیایی عنصر مس بر پایه روش: الف) انحراف معیار و ب) انحراف از میانه

بالا به عنوان کلاس «ناهنجاری» (کد ۱) و مابقی به عنوان کلاس «زمینه» (کد ۰) برچسب‌گذاری شدند. توزیع نهایی کلاس‌ها به این ترتیب بود: ۱۴۲ نمونه زمینه (۶۷.۳ درصد) و ۶۹ نمونه ناهنجاری (۳۲.۷ درصد).

نمونه‌ها به عنوان «زمینه» یا «ناهنجاری» ضروری است. در این پژوهش، برای اجتناب از برچسب‌زنی دایره‌ای با همان روش‌های آماری کلاسیک، از روش فرکتالی عیار-مساحت بر روی غلظت عنصر مس استفاده شد. این روش با بهره‌گیری از رابطه توانی میان عیار و مساحت در نمودار لگاریتمی، جوامع ژئوشیمیایی مختلف را تفکیک می‌کند. نمونه‌های متعلق به جوامع با عیار

۳-۵. ارزیابی عملکرد مدل

$$F1-Score = 2 \times (Precision \times Recall) / (Precision + Recall) \quad (۶)$$

این شاخص‌ها امکان ارزیابی توانایی مدل در تشخیص صحیح ناهنجاری‌های ژئوشیمیایی را فراهم می‌کنند و مبنایی برای مقایسه نتایج حاصل از روش‌های مختلف محسوب می‌شوند. در جدول (۴) مقادیر شاخصه‌های ارزیابی جنگل تصادفی قابل مشاهده است.

برای ارزیابی عملکرد مدل جنگل تصادفی از شاخص‌های متداول یادگیری ماشین شامل دقت، بازخوانی، امتیاز F1 و سطح زیر منحنی استفاده شد. این شاخص‌ها از روابط زیر محاسبه می‌شود.

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (۳)$$

$$Precision = TP / (TP + FP) \quad (۴)$$

$$Recall (Sensitivity) = TP / (TP + FN) \quad (۵)$$

جدول ۴. مقادیر شاخصه‌های ارزیابی جنگل تصادفی

مقدار نهایی	شاخصه‌های ارزیابی جنگل تصادفی
۰٫۸۹۱	Accuracy
۰٫۹۷۶	(ROC (AUC-ROC
۰٫۸۱۸	Precision
۰٫۸۵۷	Recall
۰٫۸۳۷	F1

۴. یافته‌ها

۴-۱. نتایج تحلیل آماری داده‌ها

بررسی شاخص‌های آماری توصیفی نشان داد که بسیاری از عناصر مورد مطالعه دارای توزیع نامتقارن و چولگی مثبت هستند. عنصر مس دارای ضریب تغییرات بالا بوده که بیانگر پراکندگی قابل توجه داده‌ها و احتمال وجود ناهنجاری‌های موضعی است. عناصر کروم و نیکل نیز رفتار مشابهی نشان دادند که می‌تواند با حضور واحدهای اولترامافیک در منطقه مرتبط باشد.

نتایج ماتریس همبستگی پیرسون بیانگر وجود چند انجمن ژئوشیمیایی شاخص در منطقه است. همبستگی قوی بین کروم و نیکل نشان‌دهنده منشأ سنگی مشترک و ارتباط با واحدهای مافیک-اولترامافیک است. عنصر مس همبستگی معنی‌داری با کبالت و پتاسیم داشت که می‌تواند در تفسیر سامانه‌های کانی‌سازی نقش راهنما داشته باشد.


۴-۲. نتایج روش‌های آماری کلاسیک

نقشه‌های حاصل از روش انحراف معیار و انحراف از میانه محدوده‌هایی را به عنوان ناهنجاری معرفی کردند که عمدتاً در بخش‌های مرکزی و جنوب غربی منطقه تمرکز داشتند. روش انحراف از میانه نسبت به روش انحراف معیار محدوده‌های محدودتر و متمرکزتری را به عنوان ناهنجاری مشخص کرد که بیانگر مقاومت بیشتر این روش در برابر داده‌های پرت است.

مقایسه نتایج دو روش نشان داد که اگرچه الگوی کلی توزیع ناهنجاری‌ها مشابه است، اما شدت و گستره آن‌ها در روش انحراف معیار بیشتر برآورد شده است.

۴-۳. نتایج مدل جنگل تصادفی

مدل جنگل تصادفی توانست با دقت بالایی نسبت به روش‌های کلاسیک، نواحی مستعد کانی‌سازی را شناسایی




نمودار ۶. نمودار اهمیت متغیرها در مدل جنگل تصادفی

۵. نتیجه‌گیری و توصیه‌های سیاستی

عملکرد برتر مدل جنگل تصادفی در این مطالعه را می‌توان در چارچوب مزایای کلی روش‌های یادگیری ماشین در تحلیل داده‌های ژئوشیمیایی ارزیابی کرد. داده‌های اکتشافی ژئوشیمیایی اغلب دارای توزیع‌های ناهمگن، روابط غیرخطی و اندرکنش‌های چندمتغیره پیچیده هستند. در چنین شرایطی، روش‌های آماری کلاسیک که برپیش‌فرض‌های خطی یا تک‌متغیره استوارند، معمولاً در بازنمایی کامل ساختار واقعی داده‌ها ناتوان‌اند. در مقابل، الگوریتم‌های یادگیری ماشین با قابلیت یادگیری الگوهای پنهان و مدل‌سازی همزمان متغیرهای متعدد، توانایی بیشتری در آشکارسازی روابط ژئوشیمیایی پیچیده دارند.

در این میان، عملکرد مناسب جنگل تصادفی ناشی از توانایی این الگوریتم در شناسایی امضاهای ژئوشیمیایی ترکیبی است؛ به گونه‌ای که به جای تمرکز بر یک عنصر منفرد، الگوهای چندعنصری مرتبط با فرآیندهای کانی‌سازی را تشخیص می‌دهد. این ویژگی به ویژه در محیط‌های زمین‌شناسی پیچیده - که کانی‌سازی حاصل برهمکنش مجموعه‌ای از عوامل سنگ‌شناسی، ساختاری و ژئوشیمیایی است - حائز اهمیت است. به عبارت دیگر، یادگیری ماشین می‌تواند روابطی را استخراج کند

کند. نقشه احتمال خروجی مدل، محدوده‌های اولویت‌دار را با تمرکز مشخص‌تری نسبت به روش‌های آماری کلاسیک نشان داد. محدوده‌های با احتمال بالای کانی‌سازی عمدتاً در امتداد روند ساختاری غالب منطقه شمال شرقی - جنوب غربی (NE-SW) قرار دارند. نقشه ناهنجاری عنصر مس در مدل جنگل تصادفی در نمودار (۵) نشان داده می‌شود. در این شکل، ۵ منطقه اصلی با پتانسیل بسیار بالا برای کانی‌سازی مس شناسایی شدند. این زون‌ها دارای بالاترین نمره احتمال خروجی از مدل جنگل تصادفی بوده و از نظر فضایی با الگوهای ژئوشیمیایی غالب بر محدوده در ارتباط هستند.



نمودار ۵. نقشه نهایی پتانسیل سنجی مس براساس خروجی مدل جنگل تصادفی

۵-۴. تحلیل اهمیت متغیرها

نمودار اهمیت متغیرها نمودار (۶) نشان داد که عناصر کروم، نیکل، کبالت و پتاسیم بیشترین سهم را در پیش‌بینی ناهنجاری‌های مرتبط با مس داشته‌اند. این موضوع بیانگر نقش کنترل لیتولوژیکی (واحدهای مافیک-اولترامافیک) و دگرسانی پتاسیک در تمرکز کانی‌سازی در منطقه است.

که بازتاب دهنده پاراژنز ژئوشیمیایی و شرایط زمین ساختی منطقه باشند.

تحلیل اهمیت متغیرها در مدل جنگل تصادفی نشان داد که علاوه بر عنصر مس، عناصر شاخص کلیدی کبالت، نیکل و پتاسیم نیز از مهم ترین متغیرهای تأثیرگذار هستند. از نظر ژئوشیمیایی، این مجموعه عناصر مؤید یک پاراژنز سولفیدی قوی و حضور دگرسانی های مرتبط با کانی سازی مس می باشد. براساس مدل نهایی، تعداد ۵ منطقه با اولویت اکتشافی بالا برای مس شناسایی شد. موقعیت فضایی این زون ها با مدل کانی سازی نوع سولفید توده ای آتشفشان زاد و کنترل های ساختاری منطقه کاملاً همخوانی داشته و نشان دهنده پتانسیل بالای منطقه برای اکتشافات آتی است.

از منظر اکتشاف معدنی، چنین قابلیت به معنای گذار از تحلیل های توصیفی صرف به رویکردهای داده محور و پیش بینی محور است. کاربرد مدل های یادگیری ماشین، تلفیق حجم بالایی از داده های ژئوشیمیایی و زمین شناسی را ممکن ساخته و به شناسایی هدفمندتر نواحی امیدبخش منجر می شود. در نتیجه، این روش ها نه تنها دقت تفسیر داده ها را افزایش می دهند، بلکه می توانند عدم قطعیت را در مراحل اولیه اکتشاف کاهش دهند.

با توجه به این ظرفیت ها، بهره گیری نظام مند از یادگیری ماشین در مطالعات اکتشافی می تواند پیامدهای مهمی برای مدیریت و سیاست گذاری در بخش معدن داشته باشد. توسعه زیرساخت های داده ای، گسترش کاربرد روش های تحلیل پیشرفته و حرکت به سوی تصمیم گیری مبتنی بر داده، از جمله اقداماتی هستند که کارایی و اثربخشی فرآیندهای اکتشاف معدنی را بهبود می بخشد. از این رو، نتایج پژوهش حاضر را می توان نمونه ای عملی از کاربرد رویکردهای هوشمند در اکتشاف معدنی تلقی کرد و مبنایی برای تدوین توصیه های سیاستی و مدیریتی در این حوزه قرار داد.

دسترسی به داده ها

در صورت نیاز به اطلاعات بیشتر در خصوص نحوه تجزیه و تحلیل داده ها در این مقاله، با نویسنده مسئول مکاتبه فرمایید.

تعارض منافع

نویسنده اعلام می کند که هیچ تضاد منافع در مورد انتشار تحقیق ثبت شده وجود ندارد. علاوه بر این، موارد اخلاقی از جمله سرقت ادبی، رضایت آگاهانه، رفتار نادرست، جعل و/ یا جعل داده ها، انتشار مضاعف و یا سوء رفتار به طور کامل توسط نویسندگان رعایت شده است.

۶. منابع

حسینی پاک، علی اصغر. (۱۳۹۴). اصول اکتشافات ژئوشیمیایی. تهران: انتشارات دانشگاه تهران.

رجبی، عادل نیک. (۲۰۲۴). تأثیر رویکرد سیاست گذاری های معدنی دولت در جبران پیامدهای زیست محیطی در ایران. پژوهشنامه بازرگانی، ۲۸(۱۰۹)، ۱-۳۳.

<https://doi.org/10.22034/ijts.2024.2005685.3869>
سازمان توسعه و نوسازی معادن و صنایع معدنی ایران، (۱۳۹۸) "گزارش نهایی اکتشاف منابع معدنی پلی متال در پهنه بشاگرد، استان هرمزگان،" شرکت مهندسین مشاور زمین آب پی، مهرماه.

عادل نیک، رجبی. (۲۰۲۳). تأثیر بهره برداری از معادن بر سطح استاندارد زندگی مردم ساکن مناطق میزبان معدن، مطالعه موردی ایران. پژوهشنامه بازرگانی، ۲۷(۱۰۶)، ۳۵-۶۶.

10.22034/ijts.2023.1982683.3760

نقشه ۱/۲۵۰۰۰ فوج، سازمان زمین شناسی و اکتشافات معدنی کشور، تهران، ایران.

Adeli Nik, R., & Rajabi, R. (2023). Tāsire bahrebardāri az ma'āden bar satahe standarde zendegiye mardome s ā kene manāteqe mizbāne ma'dan: Motāle'eye m o rediye Irān. Pajouheshnamehye Bazargani, 27 (106), 35-66. 10.22034/ijts.2023.1982683.3760 [In Persian]

Doherty, M. E., Arndt, K., Chang, Z., Kelley, K., & La vin, O. (2023). Stream sediment geochemistry in mineral exploration: a review of fine-fraction, clay-fraction, bulk leach gold, heavy mineral concentrate and indicator mineral chemistry. Geochemistry: Exploration, Environment, Analysis,

- Reimann, C., Filzmoser, P., Garrett, R., & Dutter, R. (2011). Statistical data analysis explained: applied environmental statistics with R. John Wiley & Sons.
- Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmo, M., & Chica-Rivas, M. J. O. G. R. (2015). Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines. *Ore geology reviews*, 71, 804-818. <https://doi.org/10.1016/j.oregeorev.2015.01.001>
- Schnitzler, N., Ross, P. S., & Gloaguen, E. (2019). Using machine learning to estimate a key missing geochemical variable in mining exploration: Application of the Random Forest algorithm to multi-sensor core logging data. *Journal of Geochemical Exploration*, 205, 106344. <https://doi.org/10.1016/j.gexplo.2019.106344>
- Trott, M., Leybourne, M., Hall, L., & Layton-Matthews, D. (2022). Random forest rock type classification with integration of geochemical and photographic data. *Applied Computing and Geosciences*, 15, 100090. <https://doi.org/10.1016/j.acags.2022.100090>
- ZhangZhou, J., He, C., Sun, J., Zhao, J., Lyu, Y., Wang, S., ... & Agarwal, A. (2024). Geochemistry π : automated machine learning python framework for tabular data. *Geochemistry, Geophysics, Geo systems*, 25(1), e2023GC011324. <https://doi.org/10.1029/2023GC011324>
- Zheng, C., Yuan, F., Luo, X., Li, X., Liu, P., Wen, M., ... & Albanese, S. (2023). Mineral prospectivity mapping based on Support vector machine and Random Forest algorithm-A case study from Ashele copper-zinc deposit, Xinjiang, NW China. *Ore Geology Reviews*, 159, 105567. <https://doi.org/10.1016/j.oregeorev.2023.105567>
- Zhong, R., Deng, Y., Li, W., Danyushevsky, L. V., Cracknell, M. J., Belousov, I., ... & Li, L. (2021). Revealing the multi-stage ore-forming history of a mineral deposit using pyrite geochemistry and machine learning-based data interpretation. *Ore Geology Reviews*, 133, 104079. <https://doi.org/10.1016/j.oregeorev.2021.104079>
- Zhou, S., Cheng, Z., Wang, J., Li, N., & Jiang, G. (2025). Uncover implicit associations among geochemical elements using machine learning. *Ore Geology Reviews*, 179, 106506. <https://doi.org/10.1016/j.oregeorev.2025.106506>
- 23 (4), *geochem*2022-039. <https://doi.org/10.1144/geochem2022-039>
- Geological Survey of Iran. (n.d.). Fanouj 1:250000 geological map. Tehran, Iran. [In Persian]
- HasaniPak, A.A. (2015). Osulekteshefate geochemiyayi [Principles of geochemical exploration]. Tehran: University of Tehran Press. [In Persian]
- Iranian Mines and Mining Industries Development and Renovation Organization (IMIDRO). (2019). Final exploration report of polymetal mineral resources in the Bashagard zone, Hormozgan Province. Zamin Ab Pey Consulting Engineers. [In Persian]
- Jozanikohan, G., Nosrati Abarghoeei, M., & Sedighi, H. (2021). Geochemical study of rare earth elements content in Tabas Coal Ash, Parvadeh Coal Mine. *Journal of Mining and Environment*, 12(4), 1143-1153.
- Lac haud, A., Adam, M., & Mišković, I. (2023). Comparative study of random forest and support vector machine algorithms in mineral prospectivity mapping with limited training data. *Minerals*, 13(8), 1073. <https://doi.org/10.3390/min13081073>
- McKay, G., & Harris, J. R. (2016). Comparison of the data-driven random forests model and a knowledge-driven method for mineral prospectivity mapping: A case study for gold deposits around the Huritz Group and Nueltin Suite, Nunavut, Canada. *Natural Resources Research*, 25(2), 125-143. <https://doi.org/10.1007/s11053-015-9274-z>
- Meloni, F., Gozzi, C., Cabassi, J., Nisi, B., Rappuoli, D., & Vaselli, O. (2026). Integrating Compositional Data Analysis (CoDA) and Random Forest for lithology-specific geochemical baseline determination. *Science of the Total Environment*, 1011, 181169. <https://doi.org/10.1016/j.scitotenv.2025.181169>
- Mohammadpour, M., Bahroudi, A., Abedi, M., Rahimpour, G., Jozanikohan, G., & Khalifani, F. M. (2019). Geochemical distribution mapping by combining number-size multifractal model and multiple indicator kriging. *Journal of Geochemical Exploration*, 200, 13-26. <https://doi.org/10.1016/j.gexplo.2019.01.018>
- Rajabi, R., & Adeli Nik, R. (2024). Tāsire roykardhāye sī ā satgozāriye ma'daniye dowlāt dar jobrāne payāmadhāye zistmohiti dar Irān. *Pajouheshnamehye Bazargani*, 28(109), 1-33. <https://doi.org/10.22034/ijts.2024.2005685.3869> [In Persian]

Zuo, R., Xiong, Y., Wang, J., & Carranza, E. J. M. (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>