Shahid Chamran University of Ahvaz
OPEN ACCESS Adv. Appl. Geol. Summer 2025, Vol. 15(2): 164 - 191

Research Article

Reconnaissance of prospective zones using a semi-supervised support vector machine algorithm in Sonajil porphyry copper-gold deposit

Majid Mahboubiaghdam[1*], Moharram Jahangiri[2], Aynur Nasseri [3]

1- Ph.D. Mining Engineering, Faculty of Mining Engineering, Sahand University of Technology, Tabriz, Iran.
2- PhD Mining Engineering, Shahrood University of Technology, Shahrood, Iran
3- Assistan Professor, Department of Mining Engineering, Ahar Branch, Islamic Azad University, Ahar, Iran.

Keywords: *potential map, support vector machine, Gustafson Kessel, semi-supervised algorithm, Sonajil, East Azerbaijan.*

1-Introduction

Recognition of mineral resources, aimed at determining prospective zones, requires simultaneous consideration of various reconnaissance layers, including lithology, geochemistry, geophysics, faults, alteration, and remote sensing datasets (Ghezelbash et al., 2019; Sun et al., 2022). Combining this dataset as a basis for creating an appropriate mineral potential map is optimal for reconnaissance programs (Cheng et al., 2023; Liu et al., 2019; Zekri et al., 2019; Zuo et al., 2021). There are two distinct methods for providing mineral potential models: data-oriented and knowledge-oriented methods. Each method has some advantages and disadvantages. This study demonstrates that shortcomings can be overcome by developing a powerful method utilizing the semi-supervised support vector machine algorithm. It is where complex lithological evolution and multiple stages of mineralization take place. The semi-supervised method is a model that includes both supervised and unsupervised procedures. In this study, a semi-supervised Support Vector Machine (SVM) algorithm was used to create a mineral potential map for the Sounajil region in northwestern Iran. More specifically, Gustafson-Kessel clustering was employed to cluster the training data, followed by the application of the SVM method for supervised training classification, which can enhance the performance of the mineral potential map.

2-Materials and data processing

Since the evolution condition of porphyry copper deposit formation is complex, selecting zones with high potential is a challenging task. To solve the problem, the new machine learning methods (a combination of supervised and unsupervised methods) were used to produce the mineral potential in the Sounajil zone. A set of reconnaissance traits (information layers) was provided for this purpose. The final mineral potential map was created using these raster layers, which have 83,408 data points (pixels) with a resolution of 15 x 15 meters. Figure 1 and 2 shows reconnaissance layers, containing 10 information layers.

* Corresponding author: m65.mahboubiaghdam@gmail.com
DOI: 10.22055/aag.2025.50114.2524
Received: 2025-07-09
Accepted: 2025-08-29

ISSN: 2717-0764

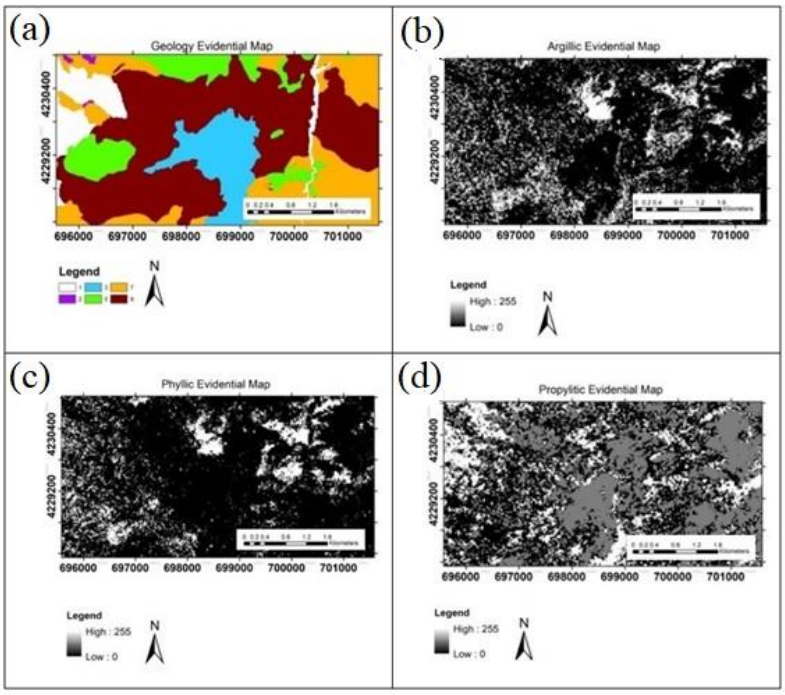


Fig.1. Continuous evidence maps: (a) Geological, (b) Argillic alteration, (c) Phyllic alteration, (d) Propylitic alteration.

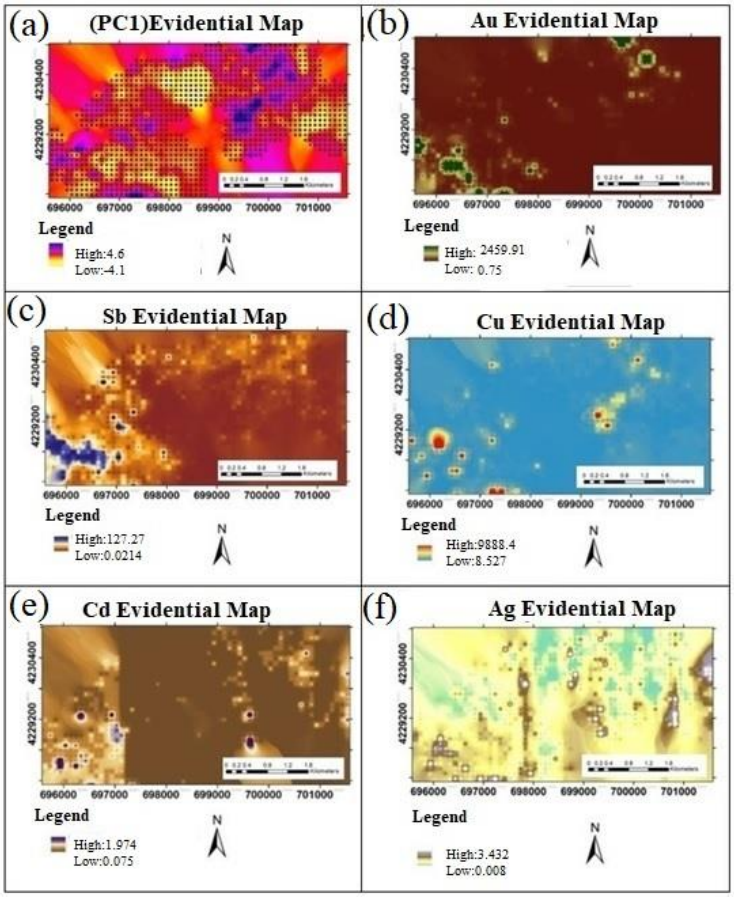


Fig.2. Continuous evidence maps: (a) Geochemistry, (b) Au raster map, (c) Sb raster map, (d) Cu raster map, (e) Cd raster map, (f) Ag raster map.

ISSN: 2717-0764
CC BY

3-Results and discussions

A combination of clustering and support vector machine was used to produce a powerful prediction method for the reconnaissance of porphyry copper in the region. Thus, information layers, containing 10 reconnaissance traits, were obtained. The pixel size was 15x15 when providing reconnaissance traits. Therefore, the total number of pixels used for constructing the decision-making matrix and the process continuation was 83,408. The Gustafson-Kessel approach was employed to cluster the training data, and the results were compared with those obtained from using the full dataset to enhance the performance of the Support Vector Machine (SVM) classifier. It is anticipated that the clustering technique will produce more accurate results than using the entire dataset because it can separate the data into more internally correlated clusters. The classification results were evaluated under various clustering scenarios. Clusters 2, 3, 4, and 5 were used to assess the outcomes in the first scenario after Cluster 1 was eliminated. Clusters 1, 3, 4, and 5 were utilized in the second scenario after Cluster 2 was eliminated. Clusters 1, 2, 4, and 5 were considered in the third scenario, whereas Cluster 3 was disregarded. Lastly, Cluster 4 was excluded from the fourth scenario, and Clusters 1, 2, 3, and 5 were used to assess the outcomes. The confusion matrix revealed the lowest error rate (3.2%) in the scenario where Cluster 4 was eliminated, indicating that almost 97% of all samples were properly classified into their respective classes. The overall results of clustering showed that this model achieved higher accuracy and better performance in determining promising mineralization zones compared to the strategy using the complete dataset (Figure 3-7).

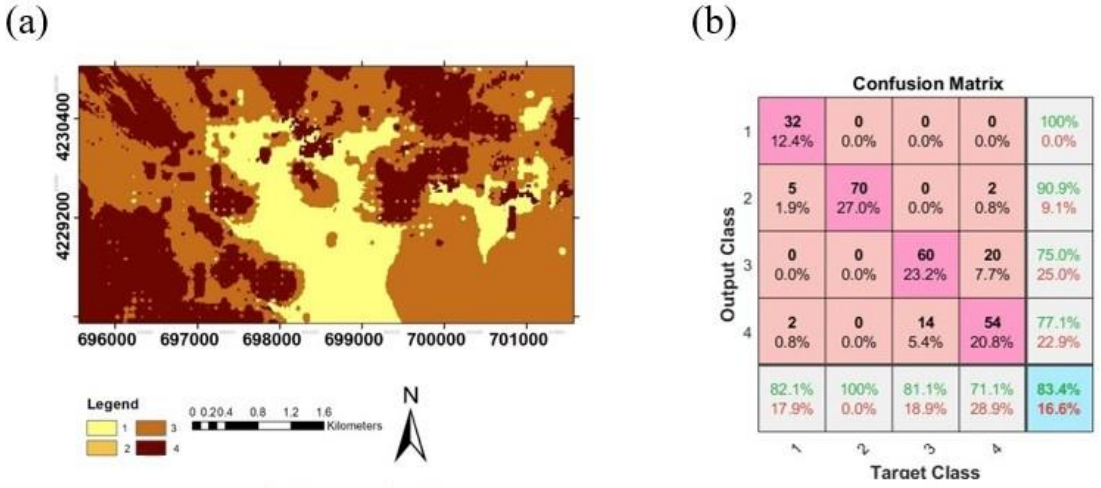


Fig.3. (a) Potential map using unclustered data (b) Confusion matrix with 83% accuracy

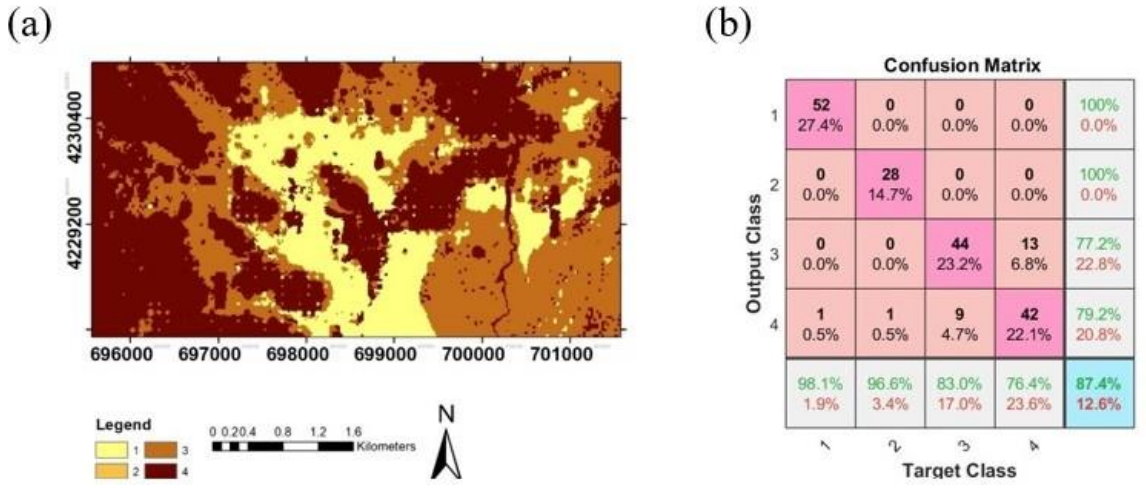


Fig. 4. (a) Potential map when the first cluster is removed, (b) Confusion matrix with 87% accuracy

ISSN: 2717-0764
CC BY

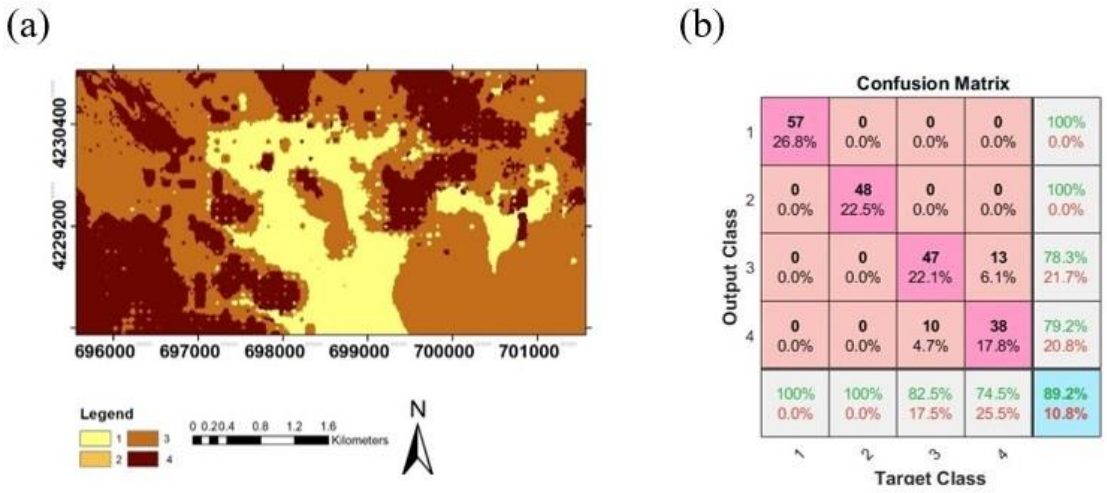


Fig. 5. (a) Potential map when the second cluster is removed, (b) Confusion matrix with 89% accuracy

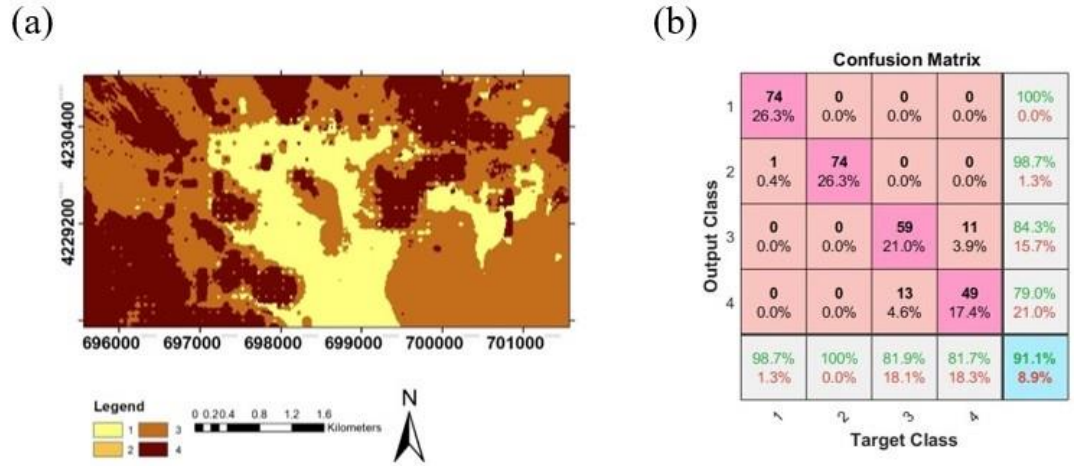


Fig. 6. (a) Potential map when the third cluster is removed, (b) Confusion matrix with 91% accuracy

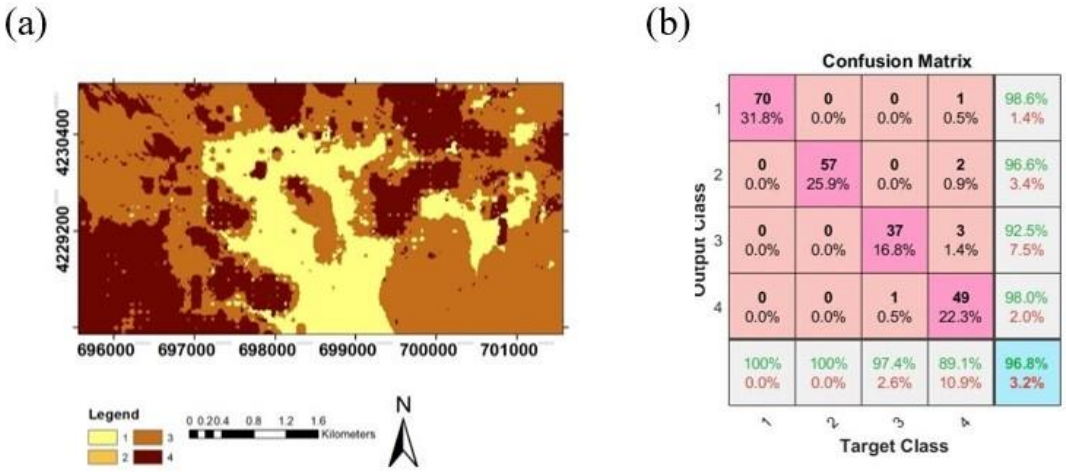


Fig. 7. (a) Potential map when the fourth cluster is removed, (b) Confusion matrix with 96% accuracy

ISSN: 2717-0764
CC BY

4-Conclusion

This study employed a hybrid strategy of supervised and unsupervised SVM-GK machine learning methods to assess the capability of these methods in generating a mineral potential map for the Sounajil zone. The results show that using clustered data for classifier design improves the average accuracy by approximately 10% compared to using the complete dataset. Comparative results between all data and clustered data show that the clustering-based approach is more efficient in developing the mineral potential map, owing to its capacity to discover hidden data structures.

5-References

Cheng, H., Zheng, Y., Wu, S., Lin, Y., Gao, F., Lin, D., 2023. GIS-based mineral prospectivity mapping using machine learning methods: a case study from Zhuonuo ore district, Tibet. Ore Geology Reviews 161, 105627. https://doi.org/10.1016/j.oregeorev.2023.105627.

Ghezelbash, R., Maghsoudi, A., Bigdeli, A., Carranza, E.J.M.J.N.R.R., 2021. Regional-scale mineral prospectivity mapping: Support vector machines and an improved data-driven multi-criteria decision-making technique. Natural Resources Research 30, 1977-2005 .http://dx.doi.org/10.1007/s11053-021-09842-4.

Liu, Y., Cheng, Q., Zhou, K.J.N.R.R., 2019. New insights into element distribution patterns in geochemistry: A perspective from fractal density. Natural Resources Research 28, 5-29 . http://dx.doi.org/10.1007/s11053-018-9374-7.

Sun, G., Zeng, Q., Zhou, J.-X.J.O.G.R., 2022. Machine learning coupled with mineral geochemistry reveals the origin of ore deposits. Ore Geology Reviews 142, 104753 . http://dx.doi.org/10.1016/j.oregeorev.2022.104753.

Zekri, H., Cohen, D.R., Mokhtari, A.R., Esmaeili, A.J.N.R.R., 2019. Geochemical prospectivity mapping through a feature extraction–selection classification scheme. Natural Resources Research 28, 849-865 . https://doi.org/10.1007/s11053-018-9422-3

Zuo, R., Kreuzer, O.P., Wang, J., Xiong, Y., Zhang, Z., Wang, Z.J.N.R.R., 2021. Uncertainties in GIS-based mineral prospectivity mapping: Key types, potential impacts and possible solutions. Natural Resources Research 30, 3059-3079 .http://dx.doi.org/10.1007/s11053-021-09871-z.

HOW TO CITE THIS ARTICLE:
Mahboubiaghdam, M., Jahangiri, M., Nasseri, A,. 2025. Reconnaissance of prospective zones using a semi-supervised support vector machine algorithm in Sonajil porphyry copper-gold deposit. Adv. Appl. Geol. 15 (2), 164-191.
DOI: 10.22055/aag.2025.50114.2524
https://aag.scu.ac.ir/article_20218.html

©2025 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

ISSN: 2717-0764

مقاله پژوهشی

شناسایی مناطق پتانسیل‌دار با استفاده از الگوریتم نیمه نظارتی ماشین بردار پشتیبان در کانسار پورفیری مس – طلای سوناجیل

مجید محبوبی اقدم

دانش آموخته دکتری دانشکده مهندسی معدن، دانشگاه صنعتی سهند، تبریز، ایران

محرم جهانگیری

دانش آموخته دکتری مهندسی معدن،دانشگاه صنعتی شاهرود

آینور ناصری

استادیار،دانشگاه آزاد اسلامی،اهر، ایران

m65.mahboubiaghdam@gmail.com

تاریخ دریافت: ۱۴۰۴/۰۴/۱۸ تاریخ پذیرش: ۱۴۰۴/۰۶/۰۷

چکیده

در تهیه نقشه‌های پیش‌بینی پتانسیل معدنی، استفاده از الگوریتم‌های هیبریدی یادگیری ماشین به همراه داده‌های همگن منجر به دستیابی به نتایج قابل‌اعتماد می‌شود. برای همگن‌سازی و کشف ساختارهای پنهان داده‌ها، روش‌های خوشه‌بندی بدون نظارت بسیار کارآمد هستند. ازاین‌رو در این مقاله با ترکیبی از روش‌های تحت نظارت و بدون نظارت با استفاده از داده‌های آموزشی و آزمایشی، نقشهٔ پتانسیل بادقت بالا تهیه شد. در اینجا الگوریتم ماشین بردار پشتیبان نیمه نظارت شده برای تهیه نقشه پتانسیل معدنی استفاده شد. ابتدا لایه‌های رستری از ۱۰ ویژگی اکتشافی تهیه شد. سپس ۲۷ گمانه اکتشافی حفر شده بر اساس غلظت مس به ۴ کلاس C1 تا C4 تقسیم شدند و از هر کلاس دو گمانه انتخاب و ۱۰۰ متر بافرزنی در اطراف این گمانه‌ها انجام شد تا ۱۱۱۳ داده آموزشی استخراج شود. سپس داده‌های موجود با روش گوستافسون خوشه‌بندی شدند و کل داده‌ها و داده‌های خوشه‌بندی وارد الگوریتم ماشین بردار پشتیبان شدند تا دقت روش طبقه‌بندی‌کننده ماشین بردار پشتیبان در ۴ خوشه مختلف ارزیابی شود. نتایج نشان‌دهنده افزایش دقت در هنگام استفاده از داده‌های خوشه‌بندی‌شده به‌جای کل داده‌ها است. همچنین در صورت عدم استفاده از داده‌های خوشه ۴ دارای بالاترین دقت ۹۷ درصد است. برای اعتبارسنجی، گمانه‌هایی که در آموزش داده‌ها مورد استفاده قرار نگرفتند، مورد ارزیابی قرار گرفتند. نتایج کلی بر اساس طبقه‌بندی گمانه‌ها و نقشه پتانسیل تهیه‌شده نشان‌دهنده دقت روش نیمه نظارتی ماشین بردار پشتیبان به‌عنوان یک نتیجه بهینه برای اکتشاف بیشتر و تعیین اهداف کانی‌سازی است.

واژه‌های کلیدی: *نقشه پتانسیل، ماشین بردار پشتیبان، خوشه‌بندی گوستافسون، الگوریتم نیمه نظارتی، سوناجیل، آذربایجان شرقی*

۱-مقدمه

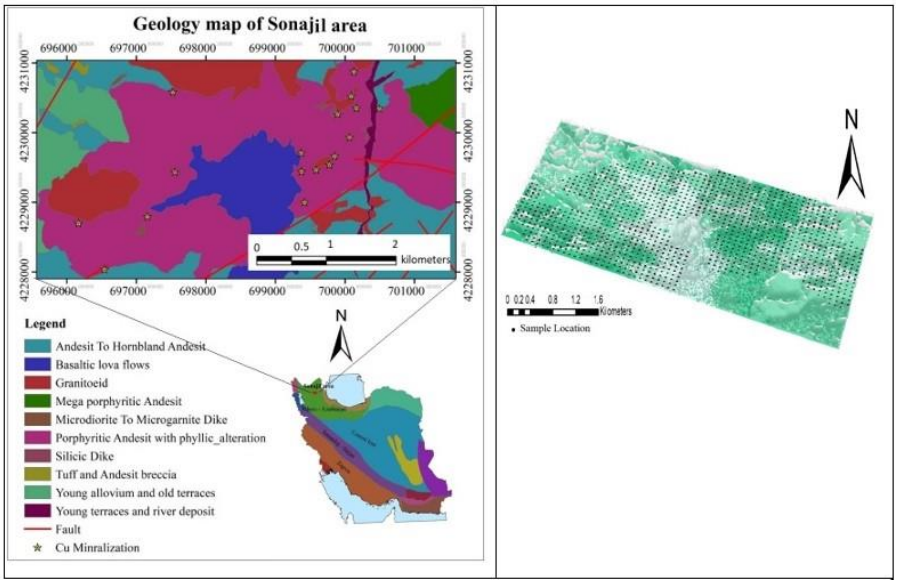
اکتشاف ذخایر معدنی باهدف تعیین مناطق پتانسیل‌دار مستلزم درنظرگرفتن هم‌زمان لایه‌های اکتشافی مختلف مانند لیتولوژی، ژئوشیمی، ژئوفیزیک، گسل، دگرسانی و مجموعه داده‌های سنجش‌ازدور است (Ghezelbash et al., 2019; Sun et al., 2022). ترکیب این مجموعه داده‌ها به‌عنوان مبنایی برای ایجاد یک نقشه پتانسیل معدنی مناسب، کار بهینه برای برنامه‌های اکتشافی است (Cheng et al., 2023; Liu et al., 2019; Zekri et al., 2019; Zuo et al., 2021). در این میان وجود حجم بالای داده‌ها در بررسی‌های اکتشافی و ارتباط پیچیده بین لایه‌های اکتشافی موجود و شواهد کانی‌سازی، باعث ایجاد عدم قطعیت بالایی در خروجی مدل اکتشافی پتانسیل معدنی شده است. ازاین‌رو، به‌کارگیری روش‌های مبتنی بر یادگیری ماشین که توانایی تحلیل و کشف ارتباط پیچیده فضایی را دربین داده‌های اکتشافی اولیه دارا باشند، توسعه یافته است (Seyedrahimi-Niaraq and Hekmatnejad, 2021; Keykhay-Hosseinpoor., 2021). برای تهیه مدل پتانسیل معدنی دو رویکرد متفاوت داده‌محور و دانش‌محور وجود دارد. روش داده‌محور در منطقه‌ای به کار می‌رود که در آن اکتشاف گسترده با مجموعه داده‌های کافی در دسترس است که همبستگی بین نهشته‌های شناخته شده و ویژگی‌های زمین‌شناسی و ژئوشیمیایی و دورسنجی را تسهیل می‌کند، درحالی‌که روش دانش‌محور بیشتر در مناطقی کاربرد دارد که

کارهای اکتشافی کمتری صورت‌گرفته است و تخصیص امتیاز به لایه‌های شاهد اکتشافی باتوجه‌به تکامل ژنتیکی منطقه و روند توسعه کانی‌سازی توسط متخصصین انجام می‌شود (Carranza, 2017; Porwal and Carranza, 2015). هیچ قانون یا معیار ثابتی برای انتخاب مدل وجود ندارد، اما مدل بر اساس عوامل ذکر شده و شرایط منطقه انتخاب خواهد شد. روش‌های متداول تهیه نقشه پتانسیل معدنی که متعلق به مدل‌های مبتنی بر داده است شامل وزن شواهد (Nykänen et al., 2008)، وزن‌های فازی شواهد (Zhang et al., 2016)، وزن‌های تقویت‌شده شواهد (Zhang et al., 2016)، ماشین بردار پشتیبانی (Ghezelbash et al., 2021; Tao et al., 2022)، جنگل تصادفی (Gao et al., 2016; McKay and Harris, 2016) رگرسیون لجستیک (Zhang et al., 2018)، شبکه‌های عصبی (Li et al., 2021; Mohammadzadeh and Nasseri, 2018)، شبکه‌های بیزی (Porwal et al., 2006)، توابع باور شواهد (Liu et al., 2015)، می‌باشد. در سال‌های اخیر، مدل‌های یادگیری بدون نظارت برای تهیه نقشه مناطق معدنی بالقوه و مقابله با موقعیت‌هایی که اطلاعات اکتشافی پراکنده وجود دارد، مورد استفاده قرار گرفته‌اند. هدف این مدل‌ها (به‌عنوان‌مثال C-means) شناسایی توزیع اساسی متغیرهای پیش‌بینی‌کننده و استفاده بیشتر از آنها برای تهیه نقشه پتانسیل معدنی است (Sadeghi et al.,2024; Jahangiri et al., 2018; Wang et al., 2020a). تکنیک‌های اصلی رویکرد روش دانش‌محور شامل منطق بولین (Wang et al., 2020a)، همپوشانی شاخص (Aryafar and Roshanravan, 2020)، منطق فازی (Abedi et al., 2013)، تحلیل پوششی داده‌ها (Hosseini et al., 2015)، نقشه خودسازمانده (SOM) و خوشه‌بندی K-means (Zuo, 2017) می‌باشد. هر یک از روش‌های ذکر شده مزایا و معایب خود را دارند. این مطالعه نشان می‌دهد که می‌توان با ایجاد روشی قوی با استفاده از الگوریتم نیمه نظارت ماشین بردار پشتیبان، کاستی‌ها را برطرف کرد. روش‌های یادگیری نیمه نظارتی برای پوشش محدودیت‌های دو رویکرد یادگیری اشاره شده، تو سعه یافته‌اند. در مدل‌سازی پتانسیل معدنی با رویکرد یادگیری نیمه نظارت شده، مناطق تأیید شده کانی‌سازی و یا نقاط عقیم در منطقه مورد بررسی هستند که در فاز یادگیری مدل از آنها استفاده می‌شود و نتیجه خروجی مدل تولیدشده، شناسایی مناطق دارای پتانسیل کانی‌سازی است که نیاز به بررسی‌های زمین‌شناسی دارد. (Rodriguez-Galiano et al., 2015; Wang et al., 2022). این روش با موفقیت توسط (Fatehi and Asadi, 2017) برای خوشه‌بندی داده‌های ژئوشیمیایی و جداسازی آنومالی‌های ژئوشیمیایی از زمینه برای حفاری بیشتر و توسط (Li et al.,2025; Wang et al., 2020a; Keykhay-Hosseinpoor., 2021) برای نقشه پتانسیل معدنی، با استفاده از جنگل تصادفی و ماشین بردار پشتیبان نیمه نظارت شده استفاده شده است. اما در استفاده از الگوریتم‌های طبقه‌بندی، شرط استفاده بهینه از داده‌های آموزشی مطرح می‌شود. به این معنی که اگر از داده‌های آموزشی به‌صورت کلی و بدون خوشه‌بندی استفاده شود، با مشکل نویز داده‌های ناشی از نمونه‌برداری یا تحلیل و یا خطای انسانی در یادگیری شبکه مواجه خواهیم شد. برای این منظور از الگوریتم‌های خوشه‌بندی برای شکستن فضای کل مجموعه داده‌ها به چندین زیرفضای همگن استفاده خواهد شد تا دقت طبقه‌بندی کننده در آموزش داده‌ها افزایش یابد. در واقع، اطلاعات استخراج شده به این روش بدون نظارت می‌تواند در طبقه‌بندی نمونه‌ها به مناطق پتانسیل‌دار و عقیم کمک کند. در این مقاله از یک الگوریتم ماشین بردار نیمه نظارت شده برای ارائه نقشه پتانسیل معدنی برای منطقه سوناجیل در شمال غربی ایران استفاده کردیم. به طور دقیق‌تر، از اطلاعات روش خوشه‌بندی گوستافسون برای خوشه‌بندی داده‌های آموزشی و سپس الگوریتم ماشین بردار پشتیبان برای طبقه‌بندی یادگیری نظارت شده استفاده شد که می‌تواند به بهبود عملکرد نقشه پتانسیل معدنی کمک کند.

۲- زمین‌شناسی و متالوژنی منطقه

نهشته پورفیری سوناجیل در زون ساختاری البرز - آذربایجان و پهنه کانی‌زایی ارسباران در حدود ۱۰۰ کیلومتری شمال شرقی شهر تبریز در شمال غربی ایران واقع شده است.کانسارهای پورفیری، اسکارن و اپی‌ترمال شاخص‌ترین انواع کانی‌زایی این پهنه و در ارتباط با توده های نفوذی سنوزوئیک هستند. در پهنه ارسباران چینش کانسارهای پورفیری، روند شمال باختر- جنوب خاور نشان می‌دهد که به طول نزدیک به ۲۵۰ کیلومتر کشیده شده و قابل مقایسه با کمربند فلززایی پورفیری نوع آند در آمریکای جنوبی است. توزیع نهشته‌های کانی‌زایی نشان می‌دهد که هر دو نوع کانی‌زایی پورفیری یعنی مس - مولیبدن

پورفیری و مس - طلای پورفیری در پهنه ارسباران وجود دارد. مهم‌ترین کانسارهای مس - مولیبدن پورفیری در بخش شمالی این پهنه تشکیل شده است که از جمله این کانسارها می توان کانسار سونگون و بالوجه در ایران و کانسارهای آگاراک و پاراغاچای در ارمنستان را نام برد . در بخش جنوبی، کانسارهای پورفیری از نوع غنی از طلا هستند که جمله این کانسارها می‌توان به مسجد داغی و شاللو اشاره کرد. از دید موقعیت زمین‌شناسی ، محدوده سوناجیل در بخش مرکزی نقشه زمین شناسی ۱:۱۰۰,۰۰۰ اهر جای گرفته که به طور چیره از سنگ‌های آتشفشانی و نیمه ژرف ائوسن- الیگوسن پوشیده شده است. از دید ساختاری نیز گسل‌های بزرگ با طول‌های چندین کیلومتر در منطقه دیده نشده ولی در محدوده معدنی سوناجیل، به طور چیره گسل‌های کانه‌دار در پیرامون توده نفوذی سوناجیل روند شمال باختر- جنوب خاور دارند. بر پایه بررسی‌های صحرایی و نقشه زمین‌شناسی ، رخنمون‌های سنگی موجود در محدوده عمدتاً شامل نهشته‌های آتشفشانی رسوبی ائوسن، توده‌های نفوذی الیگو میوسن، نهشته‌های رسوبی میوسن و همچنین بازالت‌های کواترنری می‌باشند. نهشته‌های ائوسن شامل توالی ضخیمی از سنگ‌های آندزیتی، بازالتی، آذرآواری و رسوبی هستند که عمدتاً در بخش‌های جنوبی محدوده گسترش دارند. این نهشته‌ها در کنار توده های نفوذی کمی دگرگون و در حاشیه توده نفوذی سوناجیل پورفیری فرایندهای دگرسانی مختلف را تحمل کرده‌اند. توده نفوذی در منطقه را توده‌های مونزوسینیت تا میکرومونزوسینیت پورفیری تشکیل می‌دهند که در مرکز محدوده اکتشافی رخنمون دارند. نفوذ توده سوناجیل پورفیری در داخل آن‌ها و به خصوص توده میکرومونزوسینیت پورفیری که قدیمی‌ترین پالس نفوذ در منطقه است سبب گسترش انواع دگرسانی‌های سیستم پورفیری و تغییر مشخصات تکتونیکی لایه ها و همچنین بخشی از کانی‌زایی پورفیری در داخل این توده‌ها شده است. این توده که در بخش‌های مختلف منطقه رخنمون دارد عامل ایجاد کانی‌زایی پورفیری در منطقه است و ترکیب کوارتز مونزودیوریت تا گرانودیوریتی دارد. همچنین این منطقه بعداً در معرض توده نفوذ دیگری به نام (اینچه) با ترکیب دیوریت تا کوارتز- مونزودیوریت قرار گرفته که در قسمت شمالی منطقه بدون دگرسانی و کانی‌زایی قابل توجهی در معرض دید قرار گرفته است. دایک‌های زیادی از این توده منشعب شده و در جهات مختلفی به درون توده پورفیری سوناجیل و سنگ‌های ولکانیک ائوسن تزریق شده‌اند (Moshefi et al., 2018; Hosseinzadeh et al., 2017). جهت انجام این مطالعه از داده‌های لیتوژئوشیمیایی به تعداد ۱۲۴۸ نمونه در یک شبکه منظم (فاصله نمونه‌ها ۱۰متر) که توسط شرکت ملی مس انجام شده بود استفاده شد. این نمونه ها به روش ICP(MS) برای ۴۴ عنصر آنالیز شدند. شکل ۱ نقشه زمین‌شناسی محدوده سوناجیل را به همراه نقاط نمونه‌برداری نشان می‌دهد.



شکل ۱- نقشه زمین شناسی منطقه سوناجیل به همراه نقاط نمونه برداری لیتوژئوشیمیایی (Hosseinzadeh et al., 2017)

Fig. 1. Geological map of the Sonajil area along with the Lithogeochemical sampling points (Hosseinzadeh et al., 2017)

۳-روش، الگوریتم‌های گوستافسون کسل و ماشین بردار پشتیبان و شاخص‌های اعتبارسنجی الگوریتم‌های خوشه‌بندی

۳-۱- گوستافسون کسل

الگوریتم گوستافسون‌کسل به‌عنوان یکی از روش‌های خوشه‌بندی نرم، برخلاف روش‌های همچون میانگین C که صرفاً توانایی تشخیص خوشه‌های کروی را دارند، می‌تواند خوشه‌های خطی و بیضوی را شناسایی کند. در الگوریتم گوستافسون‌کسل هر خوشه بر اساس یک نقطه و یک ماتریس ایجاد می‌شود که در آن، نقطه بیانگر مرکز خوشه و ماتریس بیانگر کوواریانس آن است. بر این اساس الگوریتم گوستافسون‌کسل قابلیت تفکیک خوشه‌های بیضوی را نیز دارد و برخلاف اغلب روش‌های خوشه‌بندی محدودیتی در قبال ایجاد خوشه‌های دایره‌ای ندارد (Lesot and Kruse, 2008)

بسیاری از الگوریتم‌های خوشه‌بندی فازی مبتنی بر نمونه، مانند FCM، مبتنی بر بهینه‌سازی یک طرح هستند و می‌خواهند تابع مناسبی مانند J را که نشان‌دهنده خطای اتصالات خوشه‌ای داده‌ها می‌باشد را به حداقل برسانند.

$$J(V,U) = \sum_{i=1}^{c} 1 \sum_{k=1}^{N} (u_{ik})^{\beta} d_{ik}^2 \qquad \text{(رابطه ۱)}$$

که در آن: uik درجه عضویت داده نقطه‌ای xk به مدل الگوی iام (مرکز خوشه)، U=[uij] ماتریس تقسیم‌بندی با ابعاد C × N، V=[vi] ماتریس C × q نمونه‌های اولیه و dik فاصله بین داده نقطه‌ای kام و نمونه iام است. پارامتر $\beta > 1$ وزن نمایی است که فازی شدن تقسیم‌بندی را کنترل می‌کند (تعیین‌کننده این است که خوشه‌ها چه مقدار باهم تداخل دارند). درحالی‌که الگوریتم FCM تنها قادر به تشخیص خوشه‌های کروی است، الگوریتم گوستافسون-کسل می‌تواند خوشه‌های بیضوی را نیز شناسایی کند. الگوریتم گوستافسون‌کسل، گسترش‌یافته الگوریتم استاندارد FCM با استفاده از نورم فاصله تطبیقی به‌منظور تشخیص خوشه‌ها از اشکال مختلف هندسی در مجموعه داده می‌باشد. فاصله تطبیقی برای هر خوشه مجزا مطابق رابطه (رابطه۲ به دست می‌آید و Si=1…C (ماتریس نورم القایی هر خوشه) از رابطه (رابطه۳ قابل‌محاسبه است.

$$d_{ik}^2 = \|x_k - v_i\|_{s_i}^2 = (x_k - v_i)^T S_i (x_k - v_i). \qquad \text{(رابطه۲)}$$

$$S_i = [\rho_i \, det(F_i)]^{1/q} F_i^{-1} \qquad \text{(رابطه۳)}$$

که در آن q تعداد ویژگی داده‌های اولیه، ρi حجم خوشه i ام است و Fi ماتریس کوواریانس فازی محاسبه‌شده مطابق رابطه (رابطه۴ است:

$$F_i = \frac{\sum_{k=1}^{N} (u_{ik})^{\beta} (x_k - v_i)(x_k - v_i)^T}{\sum_{k}^{N} (u_{ik})^{\beta}} \qquad \text{(رابطه۴)}$$

به حداقل رساندن تابع هدف J (V, U) تحت محدودیت $\sum_{i=1}^{c} \boldsymbol{u_{ik}} = \mathbf{1}$ با استفاده از یک الگوریتم تکرارشونده که مراکز خوشه و درجه عضویت را بهینه‌سازی می‌کند، طبق روابط (رابطه۵ و (رابطه۶ انجام می‌شود (Serir et al., 2012):

$$v_i = \frac{\sum_{k=1}^{N} (u_{ik})^{\beta} x_k}{\sum_{k}^{N} (u_{ik})^{\beta}}, i = 1 \dots c, k = 1 \dots N \qquad \text{(رابطه۵)}$$

و

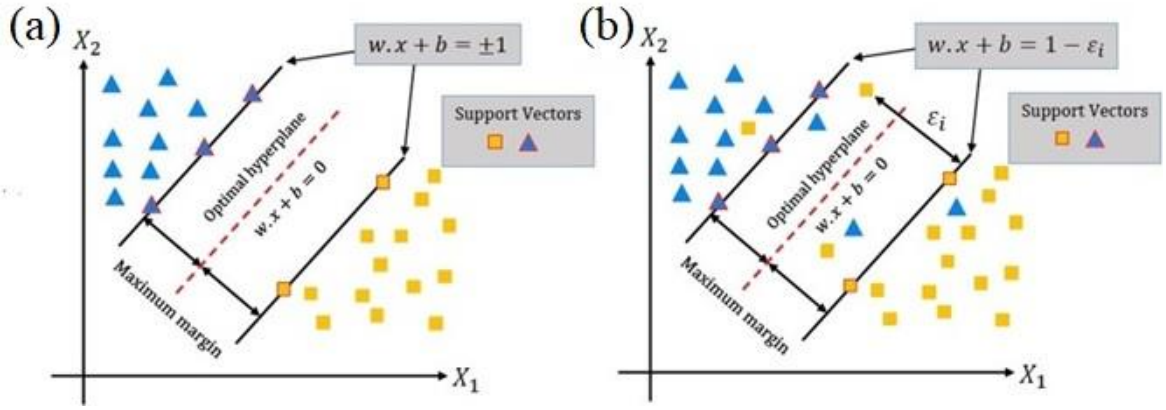
$$u_{ik} = \frac{1}{\sum_{j=1}^{c} \left(d_{ik}/d_{jk}\right)^{2/\beta - 1}}, i = 1 \dots c, k = 1 \dots N \qquad \text{(رابطه۶)}$$

۳-۲- ماشین بردار پشتیبان

استفاده از ماشین‌های بردار پشتیبان (SVM) که توسط Vapnik ارائه شد، به‌عنوان یکی از راه‌حل‌های جذاب در یادگیری ماشین و تشخیص الگو گسترش یافته است. SVMپیشگویی های خود را با استفاده از ترکیبی خطی از تابع Kernel که بر روی مجموعه‌ای از داده‌های آموزشی با نام بردارهای پشتیبان عمل می‌کند ، انجام می‌دهد. پس از اینکه بردارهای ورودی توسط توابع کرنل به یک فضای چند بعدی(با بعد بزرگتر از بعد اولیه) نگاشت شدند، یک ابرصفحه ساخته می شود که با حداکثر فاصله ممکن، بردارهای ورودی را از هم جدا می‌کند. به این ابرصفحه، ابرصفحه با حداکثر مرز جداکننده گفته می‌شود. در دو طرف این ابرصفحه، دو ابرصفحه موازی آن قرار دارد که هیچ داده‌ای در مرز بین این دو ابر سطح قرار نمی‌گیرد (شکل۲). هرچه فاصله بین این دو ابرسطح موازی بیشتر باشد، خطای کلاس بندی هم کمتر خواهد بود.

برای توضیح بیشتر، ابتدا یک مجموعه دو کلاسه را در نظر می‌گیریم. مجموعه‌ای از داده‌های آموزشی متشکل از l بردار

ویژگی $\boldsymbol{x_i} \in \boldsymbol{R^n}$، به شرطی که $\boldsymbol{i}(=\boldsymbol{1,2,3,\dots,n})$ تعداد نمونه‌ها باشد را در نظر بگیرید. داده‌ها در $\boldsymbol{y_i}$ طبقه‌بندی می‌شوند به‌طوری‌که یک کلاس برابر ۱ و کلاس دیگر برابر ۱- باشد ($\boldsymbol{y_i} \in \{-\boldsymbol{1},\boldsymbol{1}\}$). اگر دو کلاس به‌صورت خطی از هم جدا شوند، آنگاه باید یک آبَر صفحه(Hyperplanes) طراحی شود که در ادامه معادلات آن ارائه می‌شود(Kavzoglu et al., 2009) (شکل۲-a):



شکل۲- شکل کلی طبقه‌بندی داده‌ها با استفاده از SVM در دو حالت (a) تفکیک‌پذیر، (b) جدانشدنی (Kavzoglu et al., 2009).

Fig. 2. The general form of data classification using SVM in two cases (a) separable, (b) non- separable (Kavzoglu et al., 2009).

$$w.x_i + b \le -1 \quad for y_i = -1 \qquad \text{(رابطه ۷)}$$

$$w.x_i + b \ge +1 \quad for y_i = +1 \qquad \text{(رابطه۸)}$$

W: بردار نرمال است که به ابرصفحه عمود است. x_i: یک بردار حقیقی p بعدی. b: عرض از مبدأ که معادله ۷ و ۸ به‌صورت معادله ۹ نیز بیان می‌شود:

$$y_i(wx_i + b) \ge 1, \quad i = 1,2,\dots,n \qquad \text{(رابطه۹)}$$

y_i: به عبارتی قید یا برچسب کلاس‌های می‌باشد. پس از این می‌توان ابر صفحه جداکننده را به‌عنوان یک تابع تصمیم به رسمیت شناخت،

$$f(x) = sign(wx + b) \qquad \text{(رابطه۱۰)}$$

که در آن SIGN یک تابع نشانه‌ای است که به‌صورت زیر تعریف شده است:

$$sign(x) = \begin{cases} 1 & if \quad x > 0 \\ 0 & if \quad x = 0 \\ -1 & if \quad x < 0 \end{cases} \qquad \text{(رابطه۱۱)}$$

پارامترهای ابرصفحه جداکننده (b,w) به‌عنوان یک تابع تصمیم را می‌توان با حل تابع بهینه‌سازی زیر به دست آورد:

$$\text{minimize}\tau(x) = \frac{1}{2}||w||^2 \qquad \text{(رابطه۱۲)}$$

منوط به

$$y_i((wx_i + b) \ge 1, \quad i = 1,\dots,l \qquad \text{(رابطه۱۳)}$$

راه‌حل این مشکل بهینه‌سازی:

$$L(w,b,\alpha) = \frac{1}{2}||w||^2 - \sum_{i=1}^{l} \alpha_i(y_i((x_i w) + b) - 1) \qquad \text{(رابطه۱۴)}$$

$$\frac{\partial}{\partial w}L(w,b,\alpha)=0 \quad \text{(رابطه۱۵)}$$

$$\frac{\partial}{\partial b}L(w,b,\alpha)=0 \quad \text{(رابطه۱۶)}$$

$$\frac{\partial}{\partial \alpha}L(w,b,\alpha)=0 \quad \text{(رابطه۱۷)}$$

که در آن α_i ضرایب لاگرانژ است. تابع لاگرانژ باتوجه‌به w و b معادله را به حداقل و با توجه به $\alpha_i > \mathbf{0}$ حداکثر می‌رساند. ضرایب لاگرانژ α_i توسط تابع بهینه‌سازی زیر تعیین می‌شوند:

$$\text{maximize}\sum_{i=1}^{l}\alpha_i-\frac{1}{2}\sum_{ij=1}^{l}\alpha_i\alpha_j y_i y_j\,(x_i.x_j) \quad \text{(رابطه۱۸)}$$

$$\alpha_i \geq 0, i=1,\ldots,l \;\; and \;\; \sum_{i=1}^{1}\alpha_i y_i=0 \quad \text{(رابطه۱۹)}$$

روش جداسازی بر اساس ابر صفحه بهینه به‌وسیله تابع هزینه زیر خواهد بود(Zuo and Carranza, 2011) :

$$f(x)=s\,i\,gn(\sum_{i=1}^{l}y_i\alpha_i\,(xx_i)+b) \quad \text{(رابطه۲۰)}$$

راه‌حل فوق را می‌توان به مسائلی که در فضای ویژگی از هم قابل تفکیک هستند اعمال کرد. به‌منظور بهبود طبقه‌بندی، مقدار جریمه‌ی(Penalty)C برای خطاهای طبقه‌بندی نادرست و متغیرهای جاافتاده(Slack) مثبت $\boldsymbol{\varepsilon_i}$ مورداستفاده قرار گرفتند (شکل۲ − b). این متغیرها در قیدهای

$$w.x_i+b\leq =-1-1 \quad for\,y_i \quad \text{(رابطه ۷)}$$

، (رابطه۸ به شرح زیر گنجانده شده‌اند.

$$\begin{matrix} wx_i+b \\ \geq 1-\varepsilon_i \quad for \quad y_i \\ =+1 \end{matrix}$$

$$\begin{matrix} wx_i+b \\ \leq 1+\varepsilon_i \quad for \quad y_i \\ =-1 \end{matrix} \quad \text{(رابطه۲۱)}$$

$$\begin{matrix} \varepsilon_i \geq 0, \\ i=1,2,\ldots,n \end{matrix}$$

درنهایت، تابع زیر باید بهینه‌سازی شود:

$$\begin{matrix} \text{minimize}\tau(x) \\ =\frac{1}{2}||w||^2 \\ +C\left(\sum_{i=1}^{l}\varepsilon i\right)^k \end{matrix} \quad \text{(رابطه۲۲)}$$

منوط به:

$$\begin{matrix} y_i\big((wx \\ +b\big) \\ \geq 1 \\ -\varepsilon_i \;\; i \\ =1,\ldots \end{matrix} \quad \text{(رابطه۲۳)}$$

در مواردی که داده‌ها به‌صورت خطی از هم جدا نشوند، یک تابع طراحی $\emptyset(\boldsymbol{x})$ جهت به نقشه درآوردن داده‌ها از فضای اصلی x به فضای هیلبرت(Hilbert) X استفاده می‌شود. در تابع بهینه‌سازی SVM، اطلاعات ویژگی‌ها در داده‌های آموزشی به‌صورت ضرب نقطه‌ای به نظر می‌رسند (xixj) (توابع (رابطه۱۸ و (رابطه۱۹) (Yang et al., 2008). بنابراین، تابع کرنل(kernel function) K به‌صورت زیر است:

$$\begin{matrix} K(x_i,x_j)= \\ <\varphi(x_i)\times\varphi(x_j) \end{matrix} \quad \text{(رابطه۲۴)}$$

بنابراین ما فقط نیاز داریم که از K در برنامه آموزشی خود استفاده کنیم، بدون دانستن فرم صحیح و روشن از $\emptyset(\mathbf{x})$. همین رویکرد را می‌توان با یک تابع تصمیم استفاده کرد؛ بنابراین، فرمول دوگانه این مشکل به شرح زیر است:

$$\text{maximize} \sum_{i=1}^{l} \alpha_i - \frac{1}{2} \sum_{ij=1}^{l} \alpha_i \alpha_j y_i y_j \, K(x_i . x_j) \quad \text{(رابطه۲۵)}$$

منوط به:

$$\alpha_i \geq 0, 1, \ldots, l \quad and \quad \sum_{i=1}^{1} \alpha_i y_i = 0 \quad \text{(رابطه۲۶)}$$

در اغلب مسائل معدنی طبقه بندی مربوط به چندین کلاس می باشد. در این پژوهش نیز کد نویسی الگوریتم SVM در محیط نرم‌افزار MATLAB برای حالت چند کلاسه و با استفاده از کرنل RBF نوشته شد. برای بدست اوردن نتایج مناسب کلاسه بندی در روش ماشین بردار پشتیبان دو پارامتر اساسی C و سیگما را باید مورد توجه قرار داد. برای بدست اوردن مقادیر بهینه برای پارامتر C و سیگما از الگوریتم خفاش استفاده شد.

۳-۳- شاخص‌های اعتبارسنجی الگوریتم‌های خوشه‌بندی فازی

تعیین تعداد خوشه بهینه باید تا حد ممکن قابل تفسیر باشد. به‌منظور بررسی نتایج خوشه‌بندی از شاخص‌های اعتبارسنجی استفاده می‌شود که تعیین‌کننده فشردگی یا تراکم (اعضای هر خوشه باید تا جایی که ممکن است نزدیک به هم قرار بگیرند) و جدایش (خود خوشه‌ها باید به‌صورت گسترده از هم جدا باشند) نتایج خوشه‌بندی باشند. گروه اول(فشردگی) فقط از عضویت‌های خوشه‌بندی استفاده می‌کند درحالی‌که گروه دوم (جدایش) از عضویت‌های در ارتباط با خود داده‌ها استفاده می‌کند. در گروه اول، اغلب از ضریب تقسیم‌بندی (Partition co-efficient)(Bezdek and Bezdek, 1981) و آنتروپی طبقه‌بندی(Classification entropy) استفاده می‌شود. در گروه دوم، اغلب اعتبارسنجی شاخص زی - بنی(Xie-Beni) (Xie and Beni, 1991)، شاخص تقسیم‌بندی(Partition index) (Bensaid et al., 1996) و شاخص جدایی (Separation index) (Bensaid et al., 1996) به کار بسته می‌شوند. در ادامه این پارامترها معرفی می‌شوند:

۳-۳-۱- شاخص PC

شاخص PC، "هم‌پوشانی" بین خوشه‌ها را اندازه‌گیری می‌کند که مطابق معادله ۲۷ تعریف شده است:

$$PC = \frac{1}{N} \sum_{i=1}^{m} 1 \sum_{k=1}^{N} \mu_{ik}^2 \quad \text{(رابطه۲۷)}$$

که در آن N تعداد داده‌ها و μik مقدار عضویت داده نقطه‌ای K در خوشه iام می‌باشد.

۳-۳-۲- شاخص CE

شاخص CE مقدار فازی بودن تقسیم‌بندی خوشه را اندازه‌گیری می‌کند که مطابق معادله ۲۸ تعریف می‌شود:

$$CE = \frac{1}{N} \sum_{i=1}^{m} 1 \sum_{k=1}^{N} \mu_{ik} \, log_a \, \mu_{ik} \quad \text{(رابطه۲۸)}$$

هنگامی‌که خوشه‌های مختلف ارزیابی می‌شوند، نزدیک‌تر شدن شاخص PC به یک و شاخص CE به صفر، به‌عنوان بهترین خوشه در نظر گرفته می‌شوند. شاخص‌های PC و CE حساس به پارامتر β می‌باشند. با نزدیک شدن شاخص PC به مقدار β /1، نتایج به‌دست‌آمده مبهم‌تر می‌شود. شاخص PC نقطه‌ضعفی دارد و آن این است که مقدار آن با توجه به β کاهش می‌یابد و هیچ ارتباط مستقیمی با داده‌ها ندارد. بااین‌حال، شاخص PC نمایش می‌دهد که خوشه‌ها تا چه مقدار باهم همپوشانی دارند. شاخص CE هم دارای معایب مشابه است. همان‌طور که تعداد خوشه افزایش می‌یابد، مقدار شاخص PC کاهش می‌یابد، درحالی‌که ارزش شاخصCE افزایش می‌یابد. به‌طور خلاصه، هر دو شاخص تخمین PC وCE تا حدودی مشخص می‌کنند که تا چه حد خوشه‌ها باهم همپوشانی دارند.

۳-۳-۳- شاخص زی - بنی XB

شاخص زی - بنی با هدف تعیین نسبت مقدار کل تغییرات درون خوشه‌ای و جدایی خوشه‌ها، بر اساس معادله ۲۹ تعریف می‌شود:

$$XB = \frac{\sum_{i=1}^{m} 1 \sum_{k=1}^{N} \mu_{ik}^{\beta} \|x_k - u_i\|^2}{N . min_{i.k} \|x_k - u_i\|^2} \quad \text{(رابطه ۲۹)}$$

xk معرف نمونه مورد بررسی و ui معرف مرکز خوشه است. شاخص زی - بنی در خواص تراکم و جدایش متمرکز است. هرچه خوشه‌ها بیشتر از همدیگر تفکیک شوند، مقدار شاخص زی و بنی مقدار کمتری خواهد شد.

۳-۳-۴- شاخص SC

شاخص SC نسبت مجموع تراکم به جدایش خوشه‌ها از یکدیگر است و مطابق معادله ۳۰ تعریف می‌شود:

$$SC = \sum_{i=1}^{m} 1 \frac{\sum_{j=1}^{N} \mu_{ij}^{\beta} \|x_j - u_i\|^2}{N_i . \sum_{k=1}^{m} \|u_k - u_i\|^2} \quad \text{(رابطه ۳۰)}$$

هر چه مقدار شاخص SC کاهش یابد، بهترین خروجی خوشه‌بندی را خواهیم داشت. این مقدار به‌عنوان اعتبارسنجی زمانی مفید خواهد بود که خوشه‌بندی‌های مختلف که دارای تعداد خوشه‌های یکسانی هستند باهم مقایسه شوند.

۳-۳-۵- شاخص جدایش S

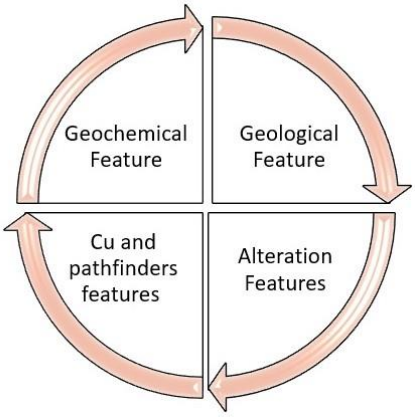
شاخص جدایش S که در معادله ۳۱ تعریف شده است، از یک مقدار فاصله جدایش کمینه برای اعتبار تقسیم‌بندی استفاده می‌کند.

$$S = \frac{\sum_{i=1}^{m} 1 \sum_{k=1}^{N} \mu_{ik}^{2} \|x_k - u_i\|^2}{N . min_{i.k} \|u_i - u_k\|^2} \quad \text{(رابطه ۳۱)}$$

شاخص جدایش S، نشان‌دهنده یک تقسیم‌بندی بهینه معتبر است؛ بنابراین، شاخص‌های اعتبارسنجی، زمانی که پیش‌بینی تعداد خوشه‌ها ناشناخته است، مفید خواهند بود. مقادیر بیشتر شاخص S نشان‌دهنده جدایش بهتر خوشه‌ها از یکدیگر می‌باشد.

۴- مواد و پردازش داده‌ها (ایجاد نقشه‌های شاهد پیوسته)

ازآنجایی‌که شرایط تکاملی تشکیل کانسار مس پورفیری پیچیده است، انتخاب مناطق با پتانسیل بالا دشوار است. برای غلبه بر مشکل تا حدودی از روش‌های جدید یادگیری ماشین (ترکیب روش‌های نظارت شده و بدون نظارت) برای تولید نقشه پتانسیل معدنی در محدوده سوناجیل استفاده کردیم. برای این منظور مجموعه‌ای از ویژگی‌های اکتشافی (لایه‌های اطلاعاتی) تهیه شد. این لایه‌های رستری در ابعاد ۱۵×۱۵ متر، حاوی ۸۳۴۰۸ داده (پیکسل) است که در تهیه نقشه پتانسیل نهایی استفاده شده است. شکل ۳ لایه‌های اکتشافی را نشان می‌دهد که شامل ۱۰ لایه اطلاعات است.



شکل ۳- لایه های اکتشافی در منطقه سوناجیل برای تهیه نقشه پتانسیل معدنی
Fig. 3. Exploration features in the Sonajil area for providing potential map

۴-۱- لایه های ژئوشیمیایی چند عنصری

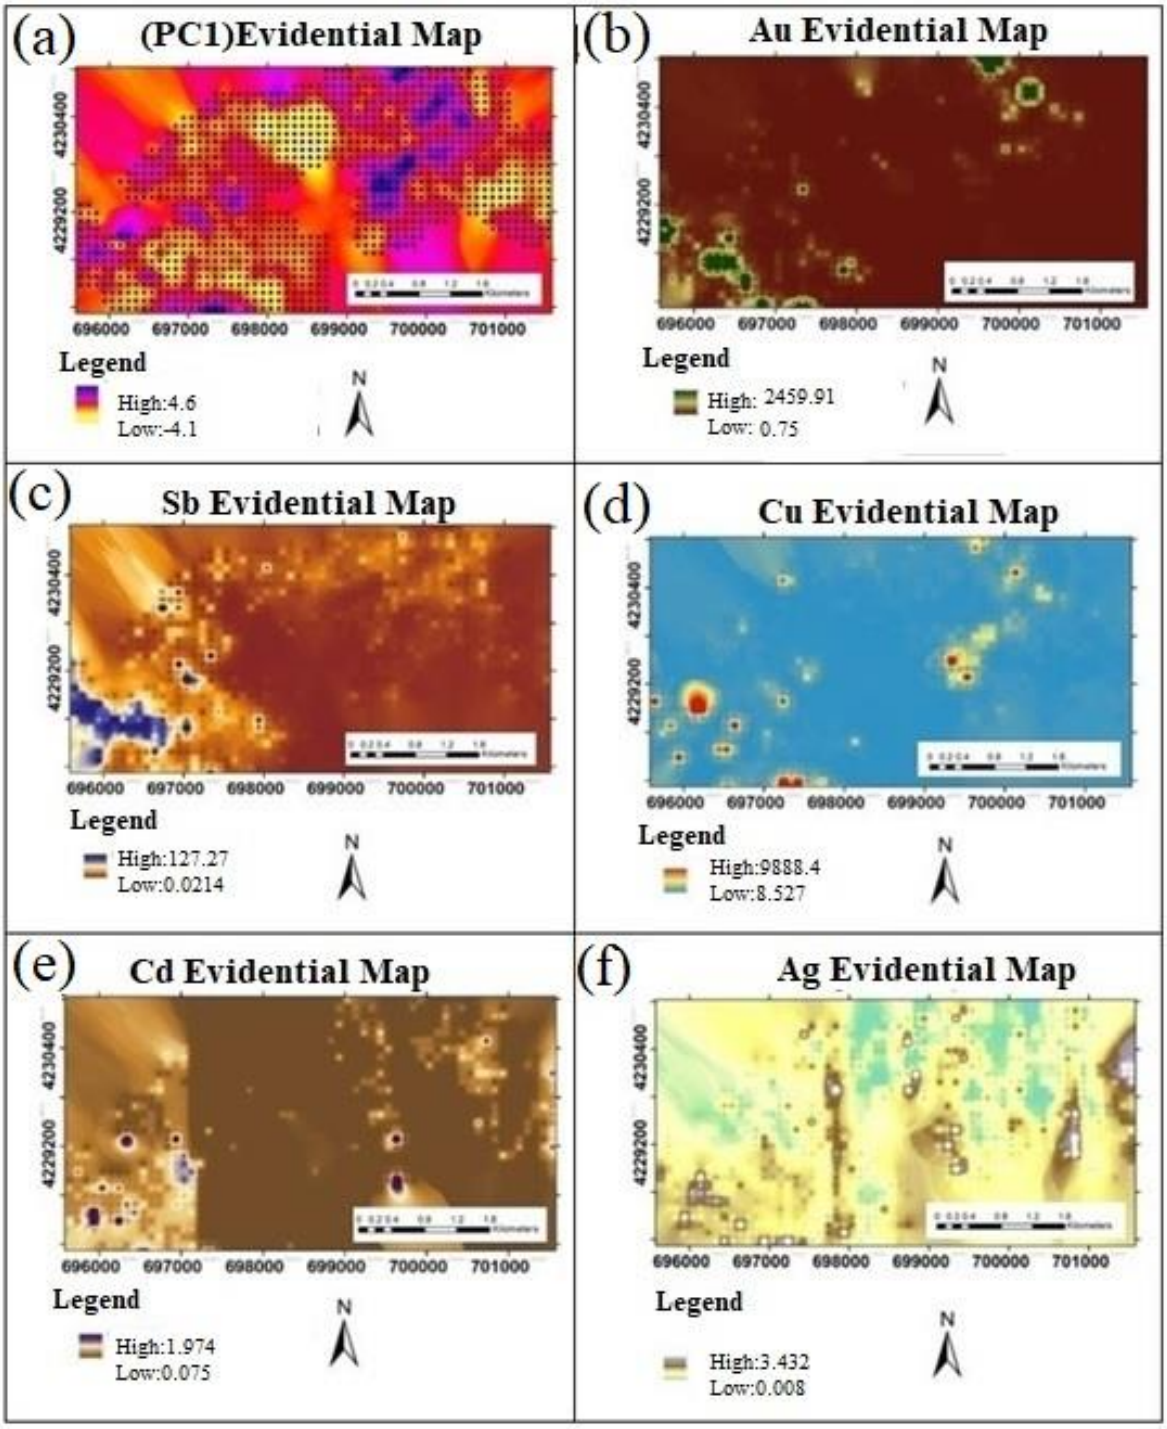
برای تهیه نقشه ژئوشیمیایی چند عنصری، از ۱۲۴۸ نمونه لیتوژئوشیمیایی که در یک شبکه منظم نمونه برداری، برداشت و با روش ICP(MS) آنالیز شده بودند، استفاده شد. به همین منظور روش تحلیل مؤلفه های اصلی برای رسیدن به نتیجه دقیق انتخاب شد.PCA یک ابزار مناسب برای تبدیل مقادیر عیار چند عنصر مختلف به یک مؤلفه اصلی منفرد و کاهش ابعاد داده‌ها به مؤلفه‌های اصلی غیر وابسته بر اساس ماتریس همبستگی متغیرهاست(Mohammadzadeh and Nasseri, 2018). به این ترتیب مؤلفه‌هایی از مجموعه داده را که بیشترین تأثیر در واریانس را دارند حفظ می‌کند و روابط بین عنصری پنهان در مجموعه داده‌های اکتشافی را مشخص می کند.در واقع

در PCA، اجزای اصلی (یاPCها) بدون هیچ گونه فرضیات آماری برای محاسبه ماکسیمم واریانس کل متغییرهای ورودی تعیین می شوند(Mahdiyanfar and Seyedrahimi-Niaraq, 2023).در تحقیق حاضر،پس از مطالعات آماری، ۱۲ عنصر مرتبط با کانی‌زایی انتخاب و پس از نرمال سازی، روش تحلیل مؤلفه‌های اصلی معمولی بر روی داده‌ها اعمال شده است (جدول ۱). بر اساس مقادیر به دست آمده از ماتریس همبستگی چرخشی ۱۲ عنصر انتخابی شامل Au، As، Sb، Ag، Bi، Cu، Mo، Pb، S، Zn، Hg و Cd استخراج شدند. طبق جدول ۱، در PC1 عناصر Au،Ag، Sb، Cu، دارای مقادیر همبستگی بالاتر از ۰/۵ هستند که نشان دهنده ارتباط فضایی مثبت۴ عنصر مذکور در کانی‌زایی مس پورفیری در محدوده مورد مطالعه است. همچنین، مقدار واریانس محاسبه شده برای ۳ مؤلفه اصلی PC1 و PC2 و PC3 به ترتیب ۲۳/۶ و ۱۶/۱و ۱۲/۸ از مجموع واریانس‌های محاسبه شده برای داده‌های چند متغیره است. با توجه به کانی‌سازی مس و پاراژنزهای مس در نهایت PC1 به‌عنوان مؤثرترین مؤلفه انتخاب شده و نقشه نهایی چند عنصری ژئوشیمیایی مربوط به آن، به‌عنوان لایه ژئوشیمیایی نهایی مورد استفاده قرار گرفته است (شکل ۴). به منظور انتخاب لایه های شاهد اکتشافی تک عنصری که ارتباط خوبی با عنصر کانی‌ساز دارند ، علاوه بر اطلاعات روش PCA از روش تحلیل خوشه ای و دندوگرام به‌عنوان مکمل استفاده شد. بنابراین با توجه به نمودار خوشه‌بندی، عنصر مس(Cu) و عناصر پاراژنز مس (Au-Ag-Sb-Cd) نیز بصورت جداگانه به‌عنوان لایه اکتشافی به منظور بهبود نتایج نقشه پتانسیل معدنی انتخاب شدند. در شکل ۴ لایه‌های رستری تهیه شده از تک تک عناصر ذکر شده آورده شده است.

جدول ۱. مقادیر PC و Eigen values به همراه واریانس و واریانس تجمعی مربوط به هر یک از PCها.

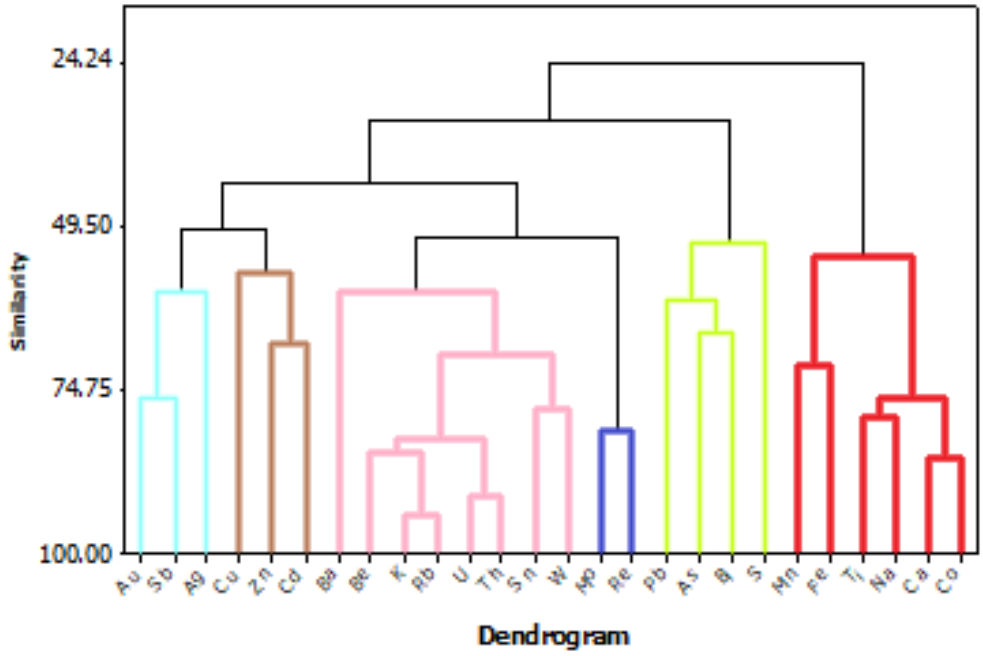
Table 1. PC and eigenvalues , along with variance and cumulative variance for each of the PCs.

Elements	PC1	PC2	PC3	PC4
As	0.31	0.59	-0.44	-0.07
Sb	0.82	0.17	-0.05	-0.05
Au	0.81	-0.1	-0.09	0.05
Ag	0.51	-0.14	0.06	0.66
Bi	0.02	0.51	-0.28	-0.13
Cu	0.65	0.05	0.14	0.05
Mo	0.05	0.75	0.07	0.13
Pb	0.03	0.77	0.12	0.01
S	-0.03	0.19	-0.62	0.02
Zn	0.07	0.09	0.78	-0.02
Hg	-0.12	0.12	-0.06	0.85
Cd	0.52	0.42	0.46	0.17
Eigen value	2.38	1.93	1.53	1.24
Variance	23.6	16.1	12.8	10.5
Cum.Var	23.6	39.7	52.5	63



شکل ۴- نقشه های شاهد پیوسته: (a) ژئوشیمی، (b) نقشه رستری Au، (c) نقشه رستری Sb، (d) نقشه رستری Cu، (e) نقشه رستری Cd و (f) نقشه رستری Ag .

Fig.4. Continuous evidence maps: (a) Geochemistry, (b) Au raster map, (c) Sb raster map, (d) Cu raster map, (e) Cd raster map and (f) Ag raster map.



شکل ۵- نمودار خوشه‌بندی داده های لیتوژئوشیمیایی
Fig. 5. Clustering diagram of lithogeochemical data

۴-۲- لایه دگرسانی های گرمابی

دگرسانی‌های گرمابی در انواع کانی‌زایی‌های مختلف نقش کلیدی ایفا می‌کنند و به‌عنوان مهم‌ترین کلید اکتشافی در عملیات صحرایی، شامل تغییرات کانی‌شناسی و شیمیایی است که تحت تأثیر آب‌های ماگمایی و یا گرمابی در سنگ‌ها ایجاد می شود(Beane, 1995; Lagat, 2009). کانسار سوناجیل در منطقه از نوع مس پورفیری است که این نوع ذخایر، الگوی تقریبا متحدالمرکزی از زون های دگرسانی گرمابی نشان می‌دهند که دلالت بر تغییرات سنگ‌شناسی ، کانی‌شناسی و ساختاری در محیط قبل از تشکیل کانسار دارد بنابراین شناسایی زون‌های دگرسانی برای اکتشاف این نوع کانسارها بسیار اهمیت دارد.این مقاله جنبه‌های کلی فرآیندهای دگرسانی گرمابی و تشخیص آن‌ها در کانسار پورفیری سوناجیل را با استفاده از اهداف روش سنجش از دور بررسی می‌کند زیرا حاوی غلظت بالایی از فلزات پایه هستند. این روش برای شناسایی کانال‌های گرمابی مفید است که به نوبه خود ممکن است منجر به شناسایی زون‌های معدنی مشابه در ادامه همان مسیر شود(Salehi et al., 2020; Zhao et al., 2021). در این راستا، تصاویر Aster به‌عنوان داده های موفق در تشخیص دگرسانی گرمابی استفاده شد. بر این اساس، مجموعه ای از داده های Aster در محیط نرم افزار ENVI برای تهیه نقشه های تناوب فیلیک، آرژیلیک و پروپیلیتیک بر اساس روش نسبت باندی استفاده شد. بنابراین در ابتدا تصحیحات هندسی و رادیومتری انجام و پوشش گیاهی منطقه حذف شد. با استفاده از طیف بازتاب استاندارد، کانی‌های شاخص سه دگرسانی با نسبت باندی ۵/۷ (Wang et al., 2020b) برای آرژیلیک، ۶/(۷+۵) (Wang et al., 2020b) برای دگرسانی فیلیک و ۹ / (۷ + ۸) برای دگرسانی پروپیلیتیک استفاده شد. در نهایت، سه نقشه رستری مرتبط از دگرسانی‌های آرژیلیک، فیلیک و پروپیلیتیک تهیه شد (شکل ۶-b، c و d).

۴-۳- لایه زمین شناسی

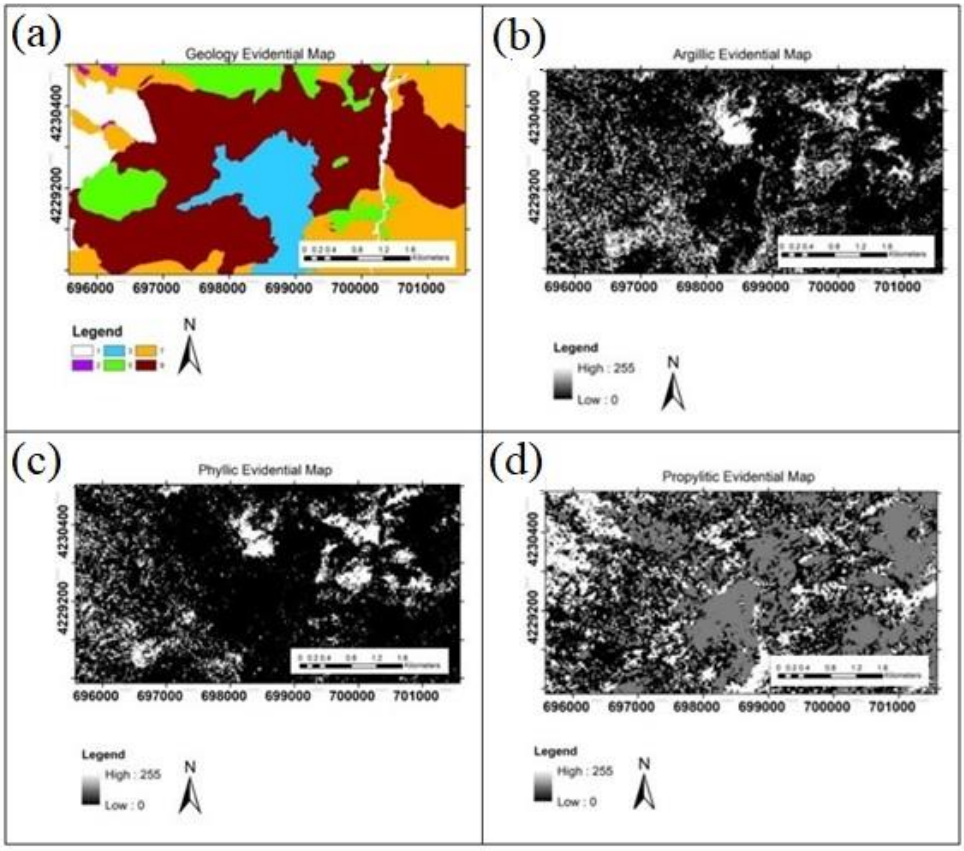
بسیاری از کانسارهای مس پورفیری در منطقهٔ شمال غرب ایران از نظر ژنتیکی با کالک آلکالن تا فلسیک در بالای زون فرورانش جزایر قوس آتشفشانی مرتبط هستند. واحدهای لیتولوژی آنها شامل آندزیت پورفیری، آندزیت مگا پورفیری، گرانیتوئید، آندزیت تا آندزیت هورنبلند است(Aghazadeh et al., 2015). لیتولوژی‌های مشابهی در سوناجیل وجود دارد که در آن آندزیت پورفیری با دگرسانی فیلیک تلفظ می‌شود. در این تحقیق با استفاده از نقشه زمین‌شناسی منطقه، ادغام برخی لیتولوژی‌ها انجام شد و اهمیت هر لیتولوژی باتوجه‌به روند توسعه

کانی‌سازی مس و همچنین نظرات کارشناسی در مورد واحدهای زمین‌شناسی منطقه تعیین و امتیازدهی شد. در نتیجه، ۶ کلاس برای لایه‌های زمین‌شناسی تعریف شد(جدول ۲). شکل ۶-aنقشه رستری لایه زمین‌شناسی را نشان می‌دهد.

جدول ۲. لیتولوژی های نهشته سوناجیل و امتیازات آنها برای ادغام

Table 2. Lithologies of the Sonajil deposit and their advantages for integration

Lithology	Score	Lithology	Score
Eocene (lower-middle) andesite	7	Sonajil porphyritic micro-diorite	9
Mega-porphyritic andesite	7	Slicic Dyke	5
Granitoid (Incheh)	5	Basaltic lava flows (Okuzdaghi)	3
Tuff & breccias	2	Young alluvium & old terraces	1
Young terraces & river deposits	1		



شکل ۶- نقشه های شاهد پیوسته: (a) زمین شناسی، (b) دگرسانی آرژیلیک، (c) دگرسانی فیلیک و (d) دگرسانی پروپیلیتیک

Fig.6. Continuous evidence maps: (a) Geological, (b) Argillic alteration, (c) Phyllic alteration, and (d) Propylitic alteration.

۴-۴- انتخاب داده های آموزشی

پس از به‌دست‌آوردن داده‌های کلی از ۱۰ فیچر (لایه اکتشافی)، از اطلاعات گمانه‌های حفر شده در منطقه (شکل۷) برای انتخاب داده های آموزشی استفاده شد. تعداد گمانه‌های حفر شده در منطقه در مجموع ۲۷ گمانه است که در سه مرحله حفر شده اند که در جدول شماره ۳ تعداد گمانه‌ها به همراه نام اختصاری آنها آورده شده است. به منظور انتخاب داده‌های آموزشی برای کلاسیفایر ماشین بردار پشتیبان، گمانه ها ابتدا به دو دسته عقیم و غیرعقیم تقسیم شدند (جدول ۴). پس از کلاس بندی گمانه‌ها به ۴ کلاس C1 تا C4 ، از هر کلاس دو گمانه (۸

گمانه) انتخاب و ۱۰۰ متر بافر در اطراف آنها برای تعیین داده‌های آموزشی انجام شد. شکل۸ نمودار غلظت گمانه‌های انتخاب شده از کلاس C1 تا C4 را نشان می‌دهد و شکل ۹ موقعیت این گمانه‌ها را بر روی نقشه زمین‌شناسی نشان می‌دهد.

جدول ۳. تعداد گمانه‌های حفر شده در منطقه سوناجیل

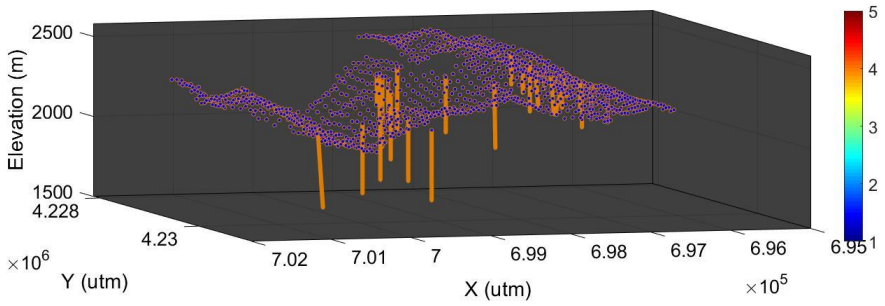
Table 3. Number of boreholes drilled in the Sonajil area

Number	*Boreholes*
11	Old boreholes (SOL)
13	Porphyry-oxide boreholes (PH-OX)
3	Epithermal boreholes (EP)

جدول ۴. طبقه بندی گمانه‌ها بر اساس تغییرات نمودار غلظت مس برای تعیین داده‌های آموزشی

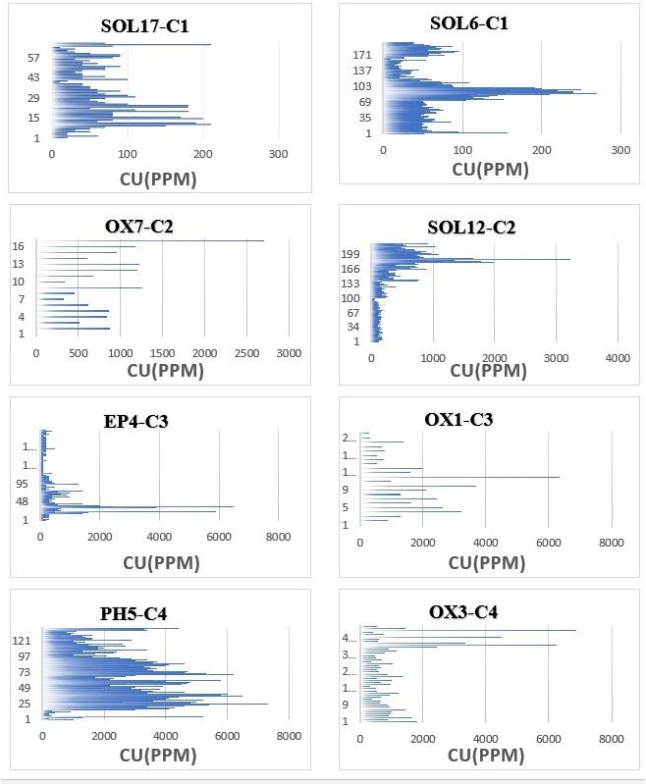
Table 4. Classification of boreholes based on changes in copper concentration diagram for determining training data

Abbreviation of boreholes for each class	*Number of boreholes*	*assay (ppm)*	*Classify boreholes*
SOL6 -SOL9-SOL10 -SOL15-SOL16-SOL17	6	C<1000	C1
SOL12 -OX6-OX7-SOL8-OX5	5	1000<C<2000	C2
SOL7-SOL14-OX1-OX8-Ph2-EP1-EP4-OX4-Ph1	9	2000<C<5000	C3
OX3 -Ph5-Ph6-SOL11-EP5-OX2-Ph3	7	5000<C	C4



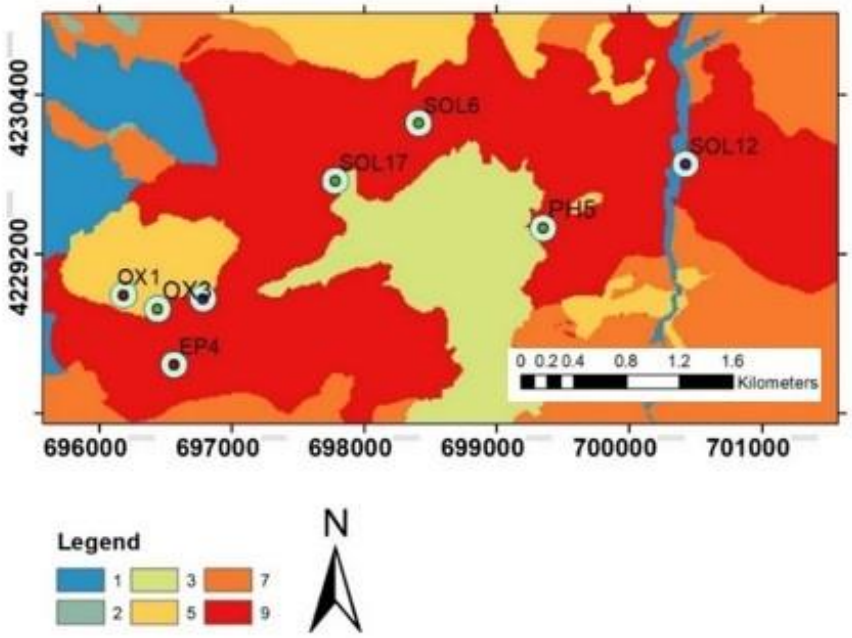
شکل ۷- موقعیت گمانه‌های مورد استفاده در نمای سه بعدی به همراه داده‌های لیتوژئوشیمیایی

Fig. 7. Location of boreholes used in the 3D view along with lithogeochemical data



شکل ۸- نمودار های غلظت عنصر مس در گمانه های آموزشی (کلاس‌های C1 تا C4)

Fig. 8. Copper element concentration diagrams in training boreholes (Classes C1 to C4)



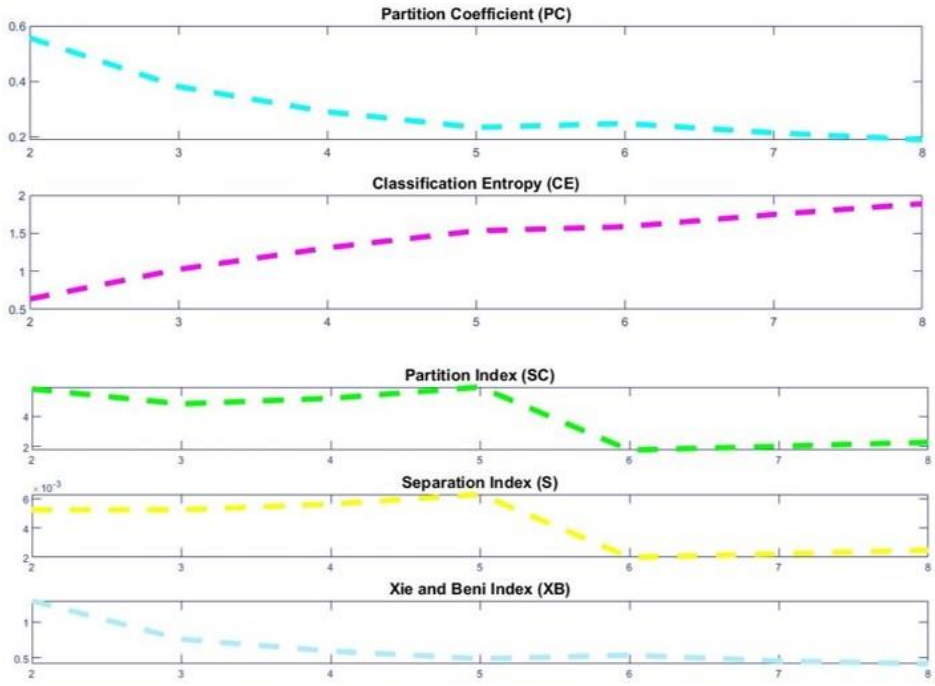
شکل ۹- موقعیت گمانه های آموزشی از کلاس‌های طبقه بندی شده C1 تا C4 (مطابق با جدول شماره۴) - بافرزنی به شعاع ۱۰۰ متر می باشد.

Fig. 9. Location of training boreholes from classified classes C1 to C4 (according to Table 4) - Buffering is within a radius of 100 meters.

۵- نتایج و بحث

۵-۱- طراحی مدل

در کانسارهای مس پورفیری، به دلیل ماهیت سیال گرمابی و شرایط فیزیکوشیمیایی حاکم بر منطقه، مناطق مختلفی با غلظت‌های متفاوت ایجاد می‌شود که هر زون به بخش خاصی از کانسار مربوط است. با خوشه‌بندی نمونه‌ها، داده‌هایی که دارای ویژگی‌های مشترک هستند در یک خوشه قرار می‌گیرند. این کار منجر به تفسیر بهتر و مدل‌سازی دقیق‌تر نقشه پتانسیل می‌شود. در مجموعه داده‌های اکتشافی، معمولاً یک سری داده پرت وجود دارد که عملکرد کل مجموعه را در تحلیل‌های اکتشافی دچار اشتباه می‌کند. با استفاده از الگوریتم‌های خوشه‌بندی می‌توان بهترین خوشه‌ها را شناسایی کرد و در تجزیه‌وتحلیل داده‌ها مورد استفاده قرار داد. برای انجام خوشه‌بندی استاندارد ابتدا باید تعداد خوشه‌های بهینه شناسایی شود که این کار با استفاده از شاخص‌های اعتبارسنجی انجام گردید، سپس الگوریتم خوشه‌بندی گوستافسون کسل بر روی داده‌ها اعمال شد و اعضای هر خوشه مشخص شد. سپس داده‌های هر خوشه به ۷۰ درصد آموزش و ۳۰ درصد تست تقسیم شد و سپس الگوریتم طبقه‌بندی‌کننده ماشین بردار پشتیبان برای تهیه نقشه پتانسیل بر اساس دقت و خطا طراحی گردید. شکل ۱۰ شاخص‌های اعتبارسنجی شامل ۱۱۱۳ داده آموزشی را نشان می‌دهد که در جدول ۵ به همراه داده‌های هر خوشه نشان داده شده است. باتوجه‌به شاخص‌های تعیین‌کننده تعداد خوشه‌های بهینه، تقریباً در تمام شاخص بعد از چهارمین پیک، مقادیر شاخص‌ها نسبتاً ثابت هستند؛ بنابراین تعداد خوشه‌های بهینه برای الگوریتم گوستافسون کسل ۴ خوشه در نظر گرفته شد. در این مرحله ابتدا کلیه داده‌های آموزشی و سپس داده‌های خوشه‌بندی‌شده به‌عنوان ورودی الگوریتم ماشین بردار پشتیبان برای تهیه نقشه پتانسیل در نظر گرفته شده است. شکل ۱۱ عملکرد گام‌به‌گام طبقه‌بندی‌کننده هیبریدی GK-SVM را برای تهیه یک نقشه پتانسیل بهینه با استفاده از تمام لایه‌های شاهد اکتشافی را نشان می‌دهد.

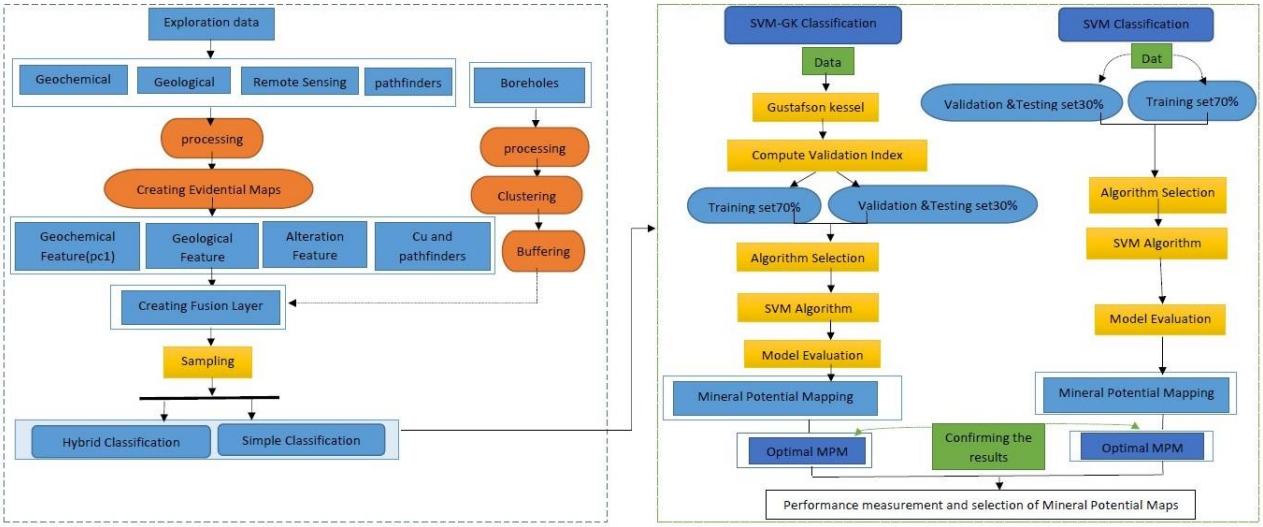


شکل ۱۰- شاخص های اعتبار سنجی با روش های مختلف
Fig. 10. Validation indicators with different methods

جدول ۵. نتایج خوشه بندی داده ها با استفاده از الگوریتم خوشه بندی GK در منطقه سوناجیل

Table 5. Data clustering results using the GK clustering algorithm in the Sonajil region

Number of data in the fourth cluster	Number of data in the third cluster	Number of data in the second cluster	Number of data in the first cluster	Total data	Clustering algorithm
277	**138**	**302**	**396**	**1113**	Gustafson



شکل ۱۱- فلوچارت مدل پتانسیل معدنی بهینه بر اساس الگوریتم GK-SVM در منطقه سوناجیل.

Fig. 11. Flowchart of the optimal mineral potential model based on the GK-SVM algorithm in the Sonajil region.

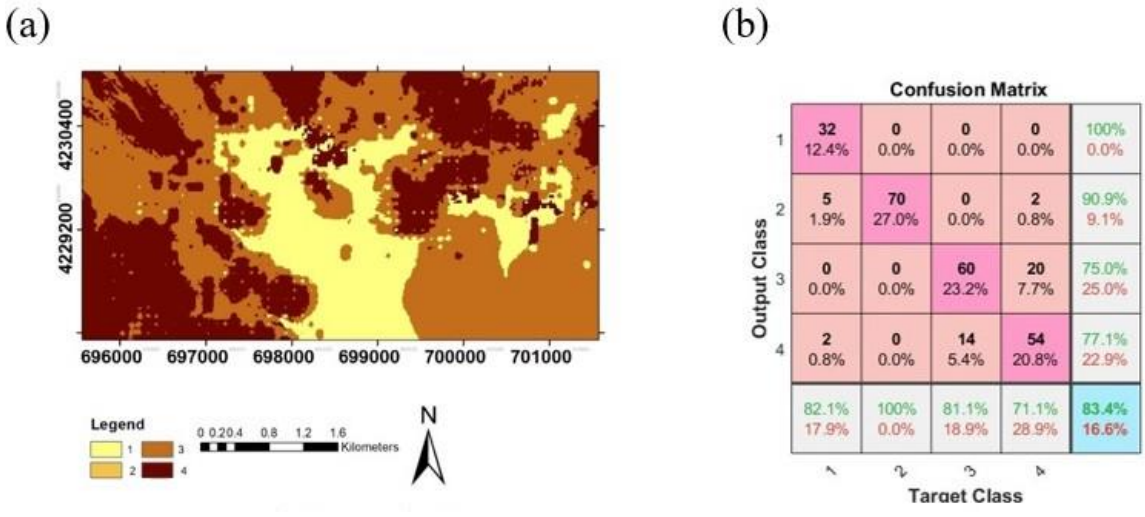
۵-۲- پردازش

به‌منظور تولید یک روش پیش‌بینی قوی برای اکتشاف مس پورفیری در منطقه، از ترکیبی از روش‌های خوشه‌بندی و ماشین بردار پشتیبان استفاده کردیم. با انجام مطالعات اولیه و بررسی‌های آماری انجام شده مجموعه لایه‌های اطلاعاتی دارای ۱۰ ویژگی اکتشافی به دست آمد. در تهیه لایه های اطلاعاتی، اندازه پیکسل ۱۵ × ۱۵ متر (بر اساس اندازه پیکسل تصاویر استر) در نظر گرفته شد، بنابراین. تعداد پیکسل ها برای تهیه ماتریس تصمیم گیری و ادامه کار ۸۳۴۰۸ پیکسل به دست آمد. برای بهبود عملکرد الگوریتم طبقه‌بندی‌کننده ماشین بردار پشتیبان، داده‌های آموزشی با استفاده از الکوریتم گوستافسون کسل خوشه‌بندی گردید و نتایج به دست آمده با حالت استفاده از کل داده‌ها مقایسه شد. از آنجایی که الگوریتم خوشه‌بندی می‌تواند داده‌ها را به خوشه‌های دارای همبستگی داخلی بیشتر تقسیم کند، بنابراین انتظار می‌رود نتایج با افزایش دقت و کاهش خطا همراه باشد. نتایج الگوریتم طبقه‌بندی کننده در حالت‌های مختلف استفاده از داده های خوشه‌بندی شده مورد ارزیابی قرار گرفت، در حالت اول (شکل۱۳a-b) خوشه ۱ حذف شد و نتایج با چهار خوشه ۲، ۳، ۴ و ۵ مورد ارزیابی قرار گرفت و بررسی ها نشان از افزایش دقت به ۸۷ درصد کاهش خطا ۱۳ درصد است. در حالت دوم (شکل ۱۳c-d)، خوشه ۲ حذف شد و نتایج با چهار خوشه ۱، ۳، ۴ و ۵ ارزیابی شد که نسبت به حالت اول افزایش ۲ درصدی دقت را نشان میدهد. در حالت سوم (شکل۱۴a-b)، خوشه ۳ حذف شد و نتایج با چهار خوشه ۱، ۲، ۴ و ۵ ارزیابی شد که در این حالت دقت نسبت به دو حالت قبل افزایش داشته است. در نهایت در حالت چهارم (شکل۱۴c-d)، خوشه ۴ کنار گذاشته شد و نتایج با ۴ خوشه

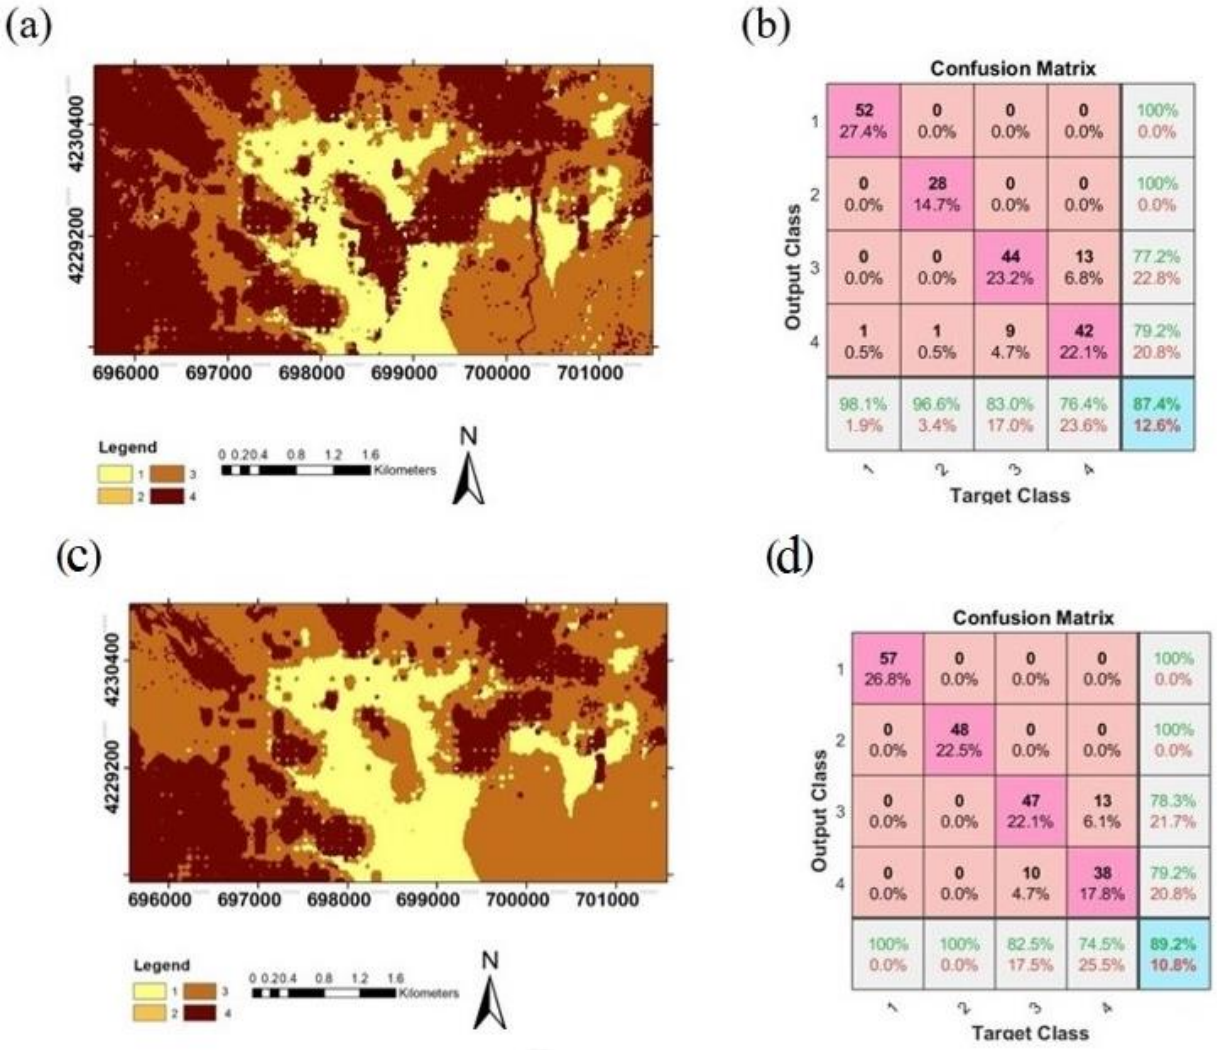
۱، ۲، ۳ و۵ ارزیابی شد. کمترین خطای مشاهده شده در بررسی ماتریس کانفیوژن با ۳ درصد در این حالت اتفاق افتاده است. در واقع حدود ۹۷ درصد از کل نمونه ها به درستی شناسایی و در کلاس‌ها طبقه بندی شده اند. نتایج استفاده از داده های خوشه‌بندی شده با دقت ۹۷ درصد نشان‌دهنده عملکرد دقیق و بهتر این مدل در تعیین پهنه‌های امیدوارکننده کانی‌سازی نسبت به حالت استفاده از کل داده‌ها (شکل ۱۲) با دقت ۸۳ درصد است.

۵-۳- اعتبارسنجی

شکل‌های ۱۲ تا ۱۴ نقشه پتانسیل منطقه سوناجیل را در حالت‌های مختلف به همراه ماتریس کانفیوژن نشان می‌دهند. با بررسی نتایج به دست آمده مشاهده می شود که کمترین دقت مربوط به حالت استفاده از کل داده‌ها (شکل ۱۲) با دقت طبقه بندی ۸۳ درصد و خطای ۱۷ درصد است و این به این معنی است که به دلیل وجود داده‌های ناهمگن در داخل داده‌ها ، عملکرد الگوریتم طبقه بندی تحت تاثیر قرار گرفته و با خطای بیشتری همراه بوده است. با انجام خوشه‌بندی انتظار افزایش دقت و کاهش خطا را داشتیم که بررسی نتایج بدست آمده در هنگام استفاده از داده‌های خوشه‌بندی شده در حالت های مختلف نشان از افزایش دقت و کاهش خطا در تمامی حالات نسبت به حالت استفاده از کل داده‌ها را می‌دهد به قسمی که در حالت چهارم (شکل c-d۱۴) با افزایش ۱۴ درصدی، دقت به ۹۷ درصد افزایش یافته است و تاثیر مثبت عملکرد الگوریتم خوشه‌بندی بر افزایش دقت الگوریتم طبقه بندی را نشان می‌دهد. این مقاله یک ایده امیدوارکننده برای تهیه نقشه پتانسیل در مناطق ناشناخته و دارای اطلاعات اکتشافی ناقص با پرداختن به موضوع رویکرد الگوریتم نیمه نظارتی ارائه می‌کند. در مطالعات پتانسیل یابی معمولا نتایج بدست آمده مورد اعتبارسنجی قرار میگیرند و برای اینکار باید از اطلاعاتی استفاده شود که هیچ نقشی در روند آموزش شبکه نداشته باشند. در این مطالعه نتیجه نهایی و نقشه پتانسیل نهایی در (شکل ۱۵) نشان داده شده است و شدت مناطق پتانسیل‌دار از کلاس ۴ به کلاس ۱ کمتر می‌شود. با جانمایی گمانه های حفاری شده بر روی نقشه پتانسیل مشاهده می‌شود که تقریبا ۸۰ درصد گمانه ها در منطقه با شدت کانی‌سازی بیشتر قرار گرفته است که این نتایج با نتایج واقعی گمانه ها همخوانی دارد و نشان می‌دهد که نقشه پتانسیل تهیه شده از دقت بالایی برخوردار است و می‌تواند به‌عنوان مبنای عملیات اکتشافی آتی در نظر گرفته شود. طبقه بندی گمانه ها در جدول ۳ مشخص شده است.

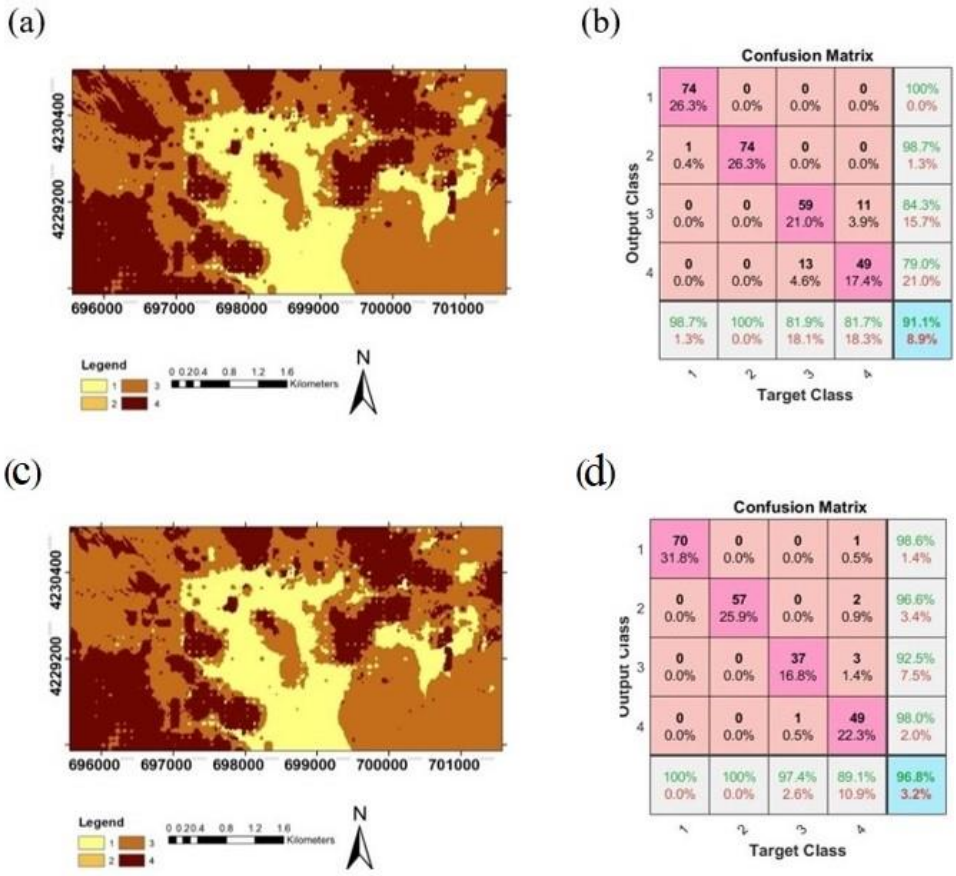


شکل ۱۲- (a) نقشه پتانسیل در حالت استفاده از داده‌های بدون خوشه‌بندی، (b) confusion matrix دارای دقت ۸۳ درصد
Fig.12. (a) Potential map using unclustered data, (b) Confusion matrix with 83% accuracy



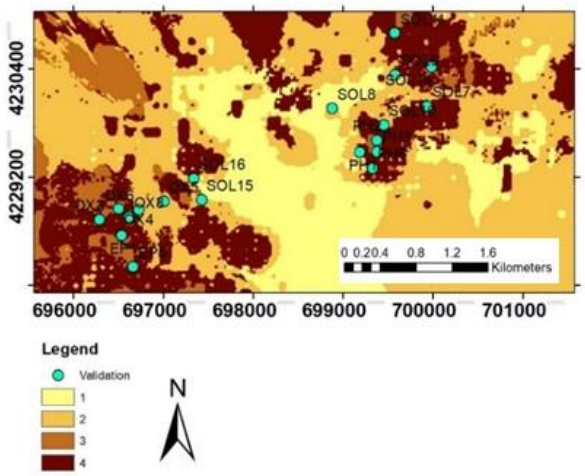
شکل ۱۳- (a) نقشه پتانسیل در حالت حذف خوشه اول، (b) confusion matrix دارای دقت ۸۷ درصد، (c) نقشه پتانسیل در حالت حذف خوشه دوم و (d) confusion matrix دارای دقت ۸۹ درصد

Fig. 13. (a) Potential map when the first cluster is removed, (b) Confusion matrix with 87% accuracy, (c) Potential map when the second cluster is removed and (d) Confusion matrix with 89% accuracy



شکل ۱۴- (a) نقشه پتانسیل در حالت حذف خوشه سوم، (b) confusion matrix دارای دقت ۹۱درصد، (c) نقشه پتانسیل در حالت حذف خوشه چهارم و (d) confusion matrix دارای دقت ۹۶درصد

Fig. 15. (a) Potential map when the third cluster is removed, (b) Confusion matrix with 91% accuracy, (c) Potential map when the fourth cluster is removed and (d) Confusion matrix with 96% accuracy



شکل ۱۵- اعتبارسنجی نقشه پتانسیل تهیه شده بر اساس گمانه های تست

Fig. 17. Validation of the potential map prepared based on test boreholes

۶- نتیجه‌گیری

در این مطالعه، استراتژی ترکیبی روش‌های نظارت شده و بدون نظارت یادگیری ماشینی SVM-GK به‌منظور آگاهی از توانایی این روش‌ها برای تهیه نقشه پتانسیل معدنی منطقه سوناجیل استفاده شد. نتایج حاکی از آن است که طراحی کلاسیفایر در حالت استفاده از داده‌های خوشه‌بندی نسبت به حالت استفاده از کل داده‌ها افزایش میانگین دقت ۱۰ درصدی را دارد. نتایج مقایسه‌ای در مورد استفاده از کل داده‌ها و در مورد استفاده از داده‌های خوشه‌ای نشان می‌دهد که روش خوشه‌بندی در تهیه نقشه پتانسیل به دلیل کشف ساختارهای پنهان داده‌ها کارآمدتر است. همچنین مقایسه بین حالت‌های مختلف خوشه‌بندی نشان داد که ماتریس کانفیوژن در صورت حذف خوشه ۴ کمترین خطا را دارد و در نتیجه کلاسیفایر ماشین بردار پشتیبان بالاترین دقت را در این حالت نشان داد. این مطالعه نشان می‌دهد که استفاده از روش نیمه نظارت ماشین بردار پشتیبان با سادگی در پردازش داده‌ها و دقت در پردازش، نتیجه مطلوبی در تهیه نقشه پتانسیل در منطقه دارد. همچنین نشان می‌دهد که استفاده داده‌های آموزشی که از ارتباط داده‌های سطحی و گمانه‌ها به دست آمد، روشی دقیق در تهیه نقشه پتانسیل و شناسایی الگوی حاکم بر منطقه و نهایتاً تشخیص کانسار پنهان در مناطق فاقد گمانه‌های اکتشافی هست.

مراجع

Abedi, M., Norouzi, G.H., Fathianpour, N.J.I.J.o.A.E.O., 2013. Fuzzy outranking approach: a knowledge-driven method for mineral prospectivity mapping. International Journal of Applied Earth Observation and Geoinformation 21, 556-567. http://dx.doi.org/10.1016/j.jag.2012.07.012.

Aghazadeh, M., Hou, Z., Badrzadeh, Z., Zhou, L.J.O.g.r., 2015. Temporal–spatial distribution and tectonic setting of porphyry copper deposits in Iran: constraints from zircon U–Pb and molybdenite Re–Os geochronology. Ore Geology Reviews 70, 385-406. http://dx.doi.org/10.1016/j.oregeorev.2015.03.003.

Aryafar, A., Roshanravan, B.J.E.S.I., 2020. Improved index overlay mineral potential modeling in brown-and green-fields exploration using geochemical, geological, and remote sensing data. Earth Science Informatics 13, 1275-1291. https://doi.org/10.1007/s12145-020-00509-x.

BEANE, R.E.J.P.c.d.o.t.A.C., 1995. Hydrothermal fluids and hydrothermal alteration in porphyry copper deposits. Porphyry copper deposits of the American Cordillera 83-93. https://cir.nii.ac.jp/crid/1571698600835102592.

Bensaid, A.M., Hall, L.O., Bezdek, J.C., Clarke, L.P., Silbiger, M.L., Arrington, J.A., Murtagh, R.F.J.I.T.o.f.s., 1996. Validity-guided (re) clustering with applications to image segmentation. IEEE Transactions on Fuzzy Systems 4, 112-123. http://dx.doi.org/10.1109/91.493905.

Bezdek, J.C., Bezdek, J.C.J.P.r.w.f.o.f.a., 1981. Objective function clustering. Pattern recognition with fuzzy objective function algorithms 43-93. http://dx.doi.org/10.1007/978-1-4757-0450-1.

Carranza, E.J.M.J.N.R.R., 2017. Natural resources research publications on geochemical anomaly and mineral potential mapping, and introduction to the special issue of papers in these fields. Natural Resources Research 26, 379-410. http://dx.doi.org/10.1007/s11053-017-9348-1.

Cheng, H., Zheng, Y., Wu, S., Lin, Y., Gao, F., Lin, D., 2023. GIS-based mineral prospectivity mapping using machine learning methods: a case study from Zhuonuo ore district, Tibet. Ore Geology Reviews 161, 105627. https://doi.org/10.1016/j.oregeorev.2023.105627.

Fatehi, M., Asadi, H.H.J.O.G.R., 2017. Application of semi-supervised fuzzy c-means method in clustering multivariate geochemical data, a case study from the Dalli Cu-Au porphyry deposit in central Iran. Ore Geology Reviews 81, 245-255. https://doi.org/10.1016/j.oregeorev.2016.10.002.

Gao, Y., Zhang, Z., Xiong, Y., Zuo, R.J.O.G.R., 2016. Mapping mineral prospectivity for Cu polymetallic mineralization in southwest Fujian Province, China. Ore Geology Reviews 75, 16-28. http://dx.doi.org/10.1016/j.oregeorev.2015.12.005.

Ghezelbash, R., Maghsoudi, A., Bigdeli, A., Carranza, E.J.M.J.N.R.R., 2021. Regional-scale mineral prospectivity mapping: Support vector machines and an improved data-driven multi-criteria decision-making technique. Natural Resources Research 30, 1977-2005. http://dx.doi.org/10.1007/s11053-021-09842-4.

Ghezelbash, R., Maghsoudi, A., Carranza, E.J.M.J.N.R.R., 2019. An improved data-driven multiple criteria decision-making procedure for spatial modeling of mineral prospectivity: adaptation of prediction–area plot and logistic functions. Natural Resources Research 28, 1299-1316. https://doi.org/10.1007/s11053-018-9448-6.

Hosseini, S.A., Abedi, M.J.C., 2015. Data envelopment analysis: a knowledge-driven method for mineral prospectivity mapping. Computers & Geosciences 82, 111-119. http://dx.doi.org/10.1016/j.cageo.2015.06.006.

Hosseinzadeh, M.R., Maghfouri, S., Ghorbani, M., Moayyed, M., 2017. Different types of vein- veinlets related to mineralization and fluid inclusion studies in the Sonajil porphyry Cu- Mo deposit, Arasbaran magmatic zone. Scientific Quarterly Journal of Geosciences 101, 2219-230 (in Persian with extended English abstract). https://doi.org/10.22071/gsj.2016.41069.

Jahangiri, M., Ghavami Riabi, S.R., Tokhmechi, B.J.J.o.M., 2018. Estimation of geochemical elements using a hybrid neural network-Gustafson-Kessel algorithm. Journal of Mining and Environment 9, 499-511. https://doi.org/10.22044/jme.2017.5513.1363.

Keykhay-Hosseinpoor, M., Kouhsari, A., Morshedy, A.H., Porwal, A., 2021. Porphyry Cu-Au prospectivity modelling using semi-supervised learning algorithm in Dehsalm district, eastern Iran. Journal of Economic Geology 13(1), 193-21378 (in Persian with extended English abstract). https://doi.org/10.22067/econg.v13i1.81382.

Kavzoglu, T., Colkesen, I.J.I.J.o.A.E.O., 2009. A kernel function analysis for support vector machines for land cover classification. International Journal of Applied Earth Observation and Geoinformation 11, 352-359. http://dx.doi.org/10.1016/j.jag.2009.06.002.

Lagat, J.J.D.d.s.c.I.o.e.f.g.r., 2009. Hydrothermal alteration mineralogy in geothermal fields with case examples from Olkaria domes geothermal field, Kenya. Dipresentasikan dalam short course IV on exploration for geothermal resources. 1-22. https://docslib.org/doc/11476342.

Lesot, M.J., Kruse, R., 2008. Gustafson-Kessel-like clustering algorithm based on typicality degrees, In: Uncertainty and Intelligent Information Systems. World Scientific. In Uncertainty and Intelligent Information Systems. 117-130. http://dx.doi.org/10.1142/9789812792358_0009.

Li, S., Chen, J., Liu, C., Wang, Y.J.J.o.E.S., 2021. Mineral prospectivity prediction via convolutional neural networks based on geological big data. Journal of Earth Science 32, 327-347 http://dx.doi.org/10.1007/s12583-020-1365-z.

Li, Q., Chen, G., Wang, D., 2025. Mineral Prospectivity Mapping Using Semi-supervised Machine Learning. Mathematical Geosciences 57(2), 275-305. http://dx.doi.org/10.1007/s11004-024-10161-6.

Liu, Y., Cheng, Q., Xia, Q., Wang, X.J.F.o.E.S., 2015. The use of evidential belief functions for mineral potential mapping in the Nanling belt, South China. Frontiers of Earth Science 9, 342-354. http://dx.doi.org/10.1007/s11707-014-0465-4.

Liu, Y., Cheng, Q., Zhou, K.J.N.R.R., 2019. New insights into element distribution patterns in geochemistry: A perspective from fractal density. Natural Resources Research 28, 5-29. http://dx.doi.org/10.1007/s11053-018-9374-7.

McKay, G., Harris, J.J.N.R.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, 125-143. http://dx.doi.org/10.1007/s11053-015-9274-z.

Mahdiyanfar, H., Seyedrahimi-Niaraq, M., 2023. Integration of Fractal and Multivariate Principal Component Models for Separating Pb-Zn Mineral Contaminated Areas. Journal of Mining and Environment, 14(3), 1019-1035. https://doi.org/10.22044/jme.2023.13227.2424.

Mohammadzadeh, M., Nasseri, A.J.J.o.A.E.S., 2018. Geochemical modeling of orogenic gold deposit using PCANN hybrid method in the Alut, Kurdistan province, Iran. Journal of African Earth Sciences 139, 173-183. http://dx.doi.org/10.1016/j.jafrearsci.2017.11.038.

Moshefi, P., Hosseinzadeh, M.R., Moayyed, M., Lentz, D.R.J.O.G.R., 2018. Comparative study of mineral chemistry of four biotite types as geochemical indicators of mineralized and barren intrusions in the Sungun Porphyry Cu-Mo deposit, northwestern Iran. Ore Geology Reviews 97, 1-20. http://dx.doi.org/10.1016/j.oregeorev.2018.05.003.

Nykänen, V., Groves, D., Ojala, V., Gardoll, S.J.A.J.o.E.S., 2008. Combined conceptual/empirical prospectivity mapping for orogenic gold in the northern Fennoscandian Shield, Finland. Australian Journal of Earth Sciences 55, 39-59 http://dx.doi.org/10.1080/08120090701581380.

Porwal, A., Carranza, E.J.M., Hale, M.J.C., Geosciences, 2006. Bayesian network classifiers for mineral potential mapping. Computers & Geosciences 32, 1-16 http://dx.doi.org/10.1016/j.cageo.2005.03.018.

Porwal, A., Carranza, E.J.M.J.O.g.r. 2015. Introduction to the Special Issue: GIS-based mineral potential modelling and geological data analyses for mineral exploration. Ore Geology Reviews 71, 477-483. http://dx.doi.org/10.1016/j.oregeorev.2015.04.017.

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.

Sadeghi, M., Casey, P., Carranza, E. J. M., Lynch, E. P., 2024. Principal components analysis and K-means clustering of till geochemical data: Mapping and targeting of prospective areas for lithium exploration in Västernorrland Region, Sweden. Ore Geology Reviews 167, 106002. https://doi.org/10.1016/j.oregeorev.2024.106002.

Salehi, T., Tangestani, M.H.J.R.S.A.S., Environment, 2020. Per-pixel analysis of ASTER data for porphyry copper hydrothermal alteration mapping: a case study of NE Isfahan, Iran. Remote Sensing Applications: Society and Environment 20, 100377. http://dx.doi.org/10.1016/j.rsase.2020.100377.

Serir, L., Ramasso, E., Zerhouni, N.J.I.j.o.a.r., 2012. Evidential evolving Gustafson–Kessel algorithm for online data streams partitioning using belief function theory. International journal of approximate reasoning 53, 747-768. https://dx.doi.org/10.1016/j.ijar.2012.01.009.

Seyedrahimi-Niaraq, M., Hekmatnejad, A., 2021. The efficiency and accuracy of probability diagram, spatial statistic and fractal methods in the identification of shear zone gold mineralization: a case study of the Saqqez gold ore district, NW Iran. Acta Geochimica 40(1), 78-88. https://doi.org/10.1007/s11631-020-00413-7.

Sun, G., Zeng, Q., Zhou, J.-X.J.O.G.R., 2022. Machine learning coupled with mineral geochemistry reveals the origin of ore deposits. Ore Geology Reviews 142, 104753. http://dx.doi.org/10.1016/j.oregeorev.2022.104753.

Tao, J., Zhang, N., Chang, J., Chen, L., Zhang, H., Chi, Y.J.N.R.R., 2022. Unlabeled sample selection for mineral prospectivity mapping by semi-supervised support vector machine. Natural Resources Research 31, 2247-2269. https://doi.org/10.1007/s11053-022-10093-0.

Wang, J., Zuo, R., Xiong, Y.J.N.R.R., 2020a. Mapping mineral prospectivity via semi-supervised random forest. Natural Resources Research 29, 189-202. http://dx.doi.org/10.1007/s11053-019-09510-8.

Wang, Z., Zhou, C., Qin, H.J.A.i.S.R., 2020b. Detection of hydrothermal alteration zones using ASTER data in Nimu porphyry copper deposit, south Tibet, China. Advances in Space Research 65, 1818-1830. http://dx.doi.org/10.1016/j.asr.2020.01.008.

Wang, Z., Zuo, R.J.C., Geosciences, 2022. Mineral prospectivity mapping using a joint singularity-based weighting method and long short-term memory network. Computers & geosciences 158, 104974 http://dx.doi.org/10.1016/j.cageo.2021.104974.

Xie, X., Beni, G., 1991. A new fuzzy clustering validity criterion and its application to color image segmentation. In: Proceedings of the 1991 IEEE International Symposium on Intelligent Control. https://doi.org/10.1109/ISIC.1991.187401.pp. 463-468.

Yang, Q., Li, X., Shi, X.J.C., geosciences, 2008. Cellular automata for simulating land use changes based on support vector machines. Computers & Geosciences 34, 592-602. http://dx.doi.org/10.1016/j.cageo.2007.08.003.

Zekri, H., Cohen, D.R., Mokhtari, A.R., Esmaeili, A.J.N.R.R., 2019. Geochemical prospectivity mapping through a feature extraction–selection classification scheme. Natural Resources Research 28, 849-865. https://doi.org/10.1007/s11053-018-9422-3

Zhang, D., Ren, N., Hou, X.J.G.M.D., 2018. An improved logistic regression model based on a spatially weighted technique (ILRBSWT v1.0) and its application to mineral prospectivity mapping. Geoscientific Model Development 11, 2525-2539. https://doi.org/10.5194/gmd-11-2525-2018.

Zhang, Z., Zuo, R., Xiong, Y.J.S.C.E.S., 2016. A comparative study of fuzzy weights of evidence and random forests for mapping mineral prospectivity for skarn-type Fe deposits in the southwestern Fujian metallogenic belt, China. Science China Earth Sciences 59, 556-572. http://dx.doi.org/10.1007/s11430-015-5178-3.

Zhao, Z.-F., Zhou, J.-X., Lu, Y.-X., Chen, Q., Cao, X.-M., He, X.-H., Fu, X.-H., Zeng, S.-H., Feng, W.-j.J.O.G.R., 2021. Mapping alteration minerals in the Pulang porphyry copper ore district, SW China, using ASTER and WorldView-3 data: Implications for exploration targeting. Ore Geology Reviews 134, 104171. http://dx.doi.org/10.1016/j.oregeorev.2021.104171.

Zuo, R., Carranza, E.J.M.J.C., Geosciences, 2011. Support vector machine: A tool for mapping mineral prospectivity. Computers & Geosciences 37, 1967-1975. http://dx.doi.org/10.1016/j.cageo.2010.09.014.

Zuo, R., Kreuzer, O.P., Wang, J., Xiong, Y., Zhang, Z., Wang, Z.J.N.R.R., 2021. Uncertainties in GIS-based mineral prospectivity mapping: Key types, potential impacts, and possible solutions. Natural Resources Research 30, 3059-3079. http://dx.doi.org/10.1007/s11053-021-09871-z.

Zuo, R.J.N.R.R., 2017. Machine learning of mineralization-related geochemical anomalies: A review of potential methods. Natural Resources Research 26, 457-464. https://doi.org/10.1016/j.cageo.2015.06.006.