



Kharazmi Journal of Earth Sciences

Journal homepage <https://gnf.khu.ac.ir>



Unsupervised LSTM-based deep learning for anomaly detection in the Kajan 1:100,000 map, Central Iran

Zohre Hoseinzade¹, Aref Daei², Zahra Alaminia^{3*}

1. Department of Mining Engineering, Hamedan University of Technology, Hamedan, Iran.

2. Department of Computer Science, Faculty of Mathematical Sciences, Ferdowsi University of Mashhad, Mashhad, Iran.

3. Department of Geology, Faculty of Science, Ferdowsi University of Mashhad, Mashhad, Iran.

Article info

Article type

Research Article

Article history

Received: 8 May 2026

Accepted: 21 June 2026

Keywords:

Cu-Au mineralization, Deep learning, Long Short-Term Memory (LSTM), Isfahan.

Abstract

Mineral potential modeling, as one of the key tools in exploration, faces challenges such as the complexity of nonlinear relationships, data heterogeneity, and limited labeled data. In this study, an unsupervised hybrid deep learning approach based on a Long Short-Term Memory network is proposed to identify mineralization-prone areas. This model is capable of extracting hidden structures, similarities, and anomalies from geological data without requiring labeled training data. In the first step, the extracted features were grouped using the BIRCH clustering algorithm. Subsequently, utilizing the prediction-area (P-A) plot, which evaluates the cumulative ratio of mineral occurrences to the predicted area, the zones with the highest mineral potential were delineated. To evaluate the model's performance, this approach was implemented in the 1:100,000 scale Kajan sheet in Isfahan Province, as an area with copper-gold mineralization potential. The input data consisted of alteration, geochemical, fault, and intrusive body layers, which were applied as inputs to the model after fuzzification. The results demonstrated that the proposed model, by assigning 72% of known mineral occurrences to less than 30% of the study area, exhibits a suitable capability in identifying complex patterns and delineating promising mineral zones, and the resulting maps show acceptable agreement with the geological evidence of the area. Compared to conventional supervised learning methods, the proposed approach, by eliminating the need for labeled data and enhancing the modeling power of nonlinear relationships, has the potential to reduce uncertainty and improve the accuracy of mineral potential modeling. These results indicate that the application of unsupervised deep learning models, particularly those based on LSTM, can serve as an effective tool in mineral deposit exploration and the optimization of exploration decisions.



Introduction

One of the fundamental steps in mineral exploration is the identification of geological features associated with target mineralization through the preparation and analysis of geological maps, which include lithological units, alteration types, structures, and mineral occurrences. Mineral Potential Modeling (MPM), as a GIS-based approach, provides a systematic framework for delineating high-potential mineralization zones using geoscience datasets (Carranza et al., 2008). Various MPM methods have been developed, broadly categorized into data-driven and knowledge-driven approaches, including weights of evidence, Analytical Hierarchy Process (Mokhtari et al., 2020), deep isolation forest, autoencoder networks, hybrid, and convolutional neural networks.

In recent decades, the application of machine learning in MPM has grown considerably, with supervised algorithms such as support vector machines and random forests, as well as unsupervised methods like K-means and iForest, being widely employed. However, these methods often rely on linear assumptions and face limitations in capturing the inherent complexities of geological data, including nonlinear correlations, high uncertainty, and data heterogeneity. To

address these challenges, advanced deep learning architectures, such as Convolutional Neural Networks (CNNs) for spatial feature extraction and Long Short-Term Memory (LSTM) networks for modeling sequential dependencies and hidden patterns (Hoseinzade et al., 2025), have demonstrated significant potential. This study employs a hybrid, unsupervised deep learning approach based on an LSTM architecture to identify hidden structures and anomalies without labeled data, applied to mineral potential modeling in the Kajan 1:100,000 sheet (Isfahan province, Iran) using alteration, geochemical, fault, and intrusive layers as inputs.

Materials and Methods

The research methodology employed in this study to identify mineral anomaly zones within the 1:100,000 geological map of the Kajan area utilizes an unsupervised deep learning approach based on a Long Short-Term Memory (LSTM) network architecture. The input data consist of four evidential layers: a geochemical layer derived from stream sediment analysis for copper, gold, molybdenum, and silver; an alteration layer extracted from ASTER satellite image processing to identify propylitic, argillic, and phyllic zones; a fault-related layer

DOI 10.22034/kjes.2026.11696

*Corresponding author: Zahra Alaminia; E-mail: alaminia@um.ac.ir

How to cite this article: Hoseinzade, Z., Daei, A., Alaminia, Z., 2026. Unsupervised LSTM-based deep learning for anomaly detection in the Kajan 1:100,000 map, Central Iran. Kharazmi Journal of Earth Sciences 12(1), 64- 81. <http://doi.org/10.22034/kjes.2026.11696>



representing the density and distance from major faults; and an intrusive body layer indicating distances from granitoid to dioritic intrusions. Following preparation and co-registration at a $100 \text{ m} \times 100 \text{ m}$ cell size, all layers were normalized to a range of zero to one using fuzzy membership functions and subsequently fed into the algorithm. The designed network operates in an unsupervised manner, learning latent features from the inputs and clustering the extracted features. Anomaly clusters are then separated from the background using a prediction-area (P-A) plot. The primary advantage of this algorithm over conventional methods such as random forests and support vector machines lies in its capability to model spatial dependencies and nonlinear hidden patterns among different exploration evidence layers without requiring labeled data (i.e., known mineralization points). Finally, the resultant anomaly map is validated using known mineral occurrences in the Kajan sheet, and the efficacy of the proposed method in delineating prospective areas for copper-gold exploration is assessed (Fig. 2).

Results and Discussion

The data utilized in this study comprise geochemical samples, fault layers, and geological units (Fig. 4). Geochemical data were derived from the analysis of 434 stream sediment samples. Structural controllers, particularly fractures, play a fundamental role in the formation and evolution of hydrothermal deposits by facilitating the movement of mineral-bearing fluids, a concept widely applied in mineral potential modeling. Accordingly, distance-to-fault layers were generated and subsequently fuzzified to ensure scale compatibility, enhance precision, and reduce uncertainty. Given the significant spatial and thermal relationships between intrusive bodies and porphyry copper to skarn deposits, and considering that fault-intersection zones can act as foci for hydrothermal fluids, a point-wise criterion was adopted. A distance-from-fault-intersection layer was created and fuzzified using a logistic function. Furthermore, intrusive rocks (ranging from granite-microgranite to granodiorite, diorite, quartz diorite, and quartz monzodiorite) are critically important for hydrothermal mineralization in the Kajan area. Therefore, a distance-from-intrusion layer was generated and fuzzified similarly. For geochemical investigations, pathfinder elements for Cu-Au mineralization (Au, Cu, Mo, As, Pb, Zn) were mapped, and anomalies were separated using the 97.5th percentile threshold, followed by fuzzification (Fig. 8). The Kajan area hosts significant hydrothermal mineralization with diverse alteration zones (phyllitic, argillic, advanced argillic, and propylitic), which were effectively identified using ASTER satellite data. Argillic and advanced argillic zones (kaolinite, montmorillonite, alunite, pyrite), propylitic zones (chlorite, epidote, calcite), iron oxides (hematite, goethite, limonite), and silicification were delineated and subsequently fuzzified using a logistic function (Fig. 9). Due to the complexity of the Kajan area, an unsupervised deep

learning algorithm based on LSTM was employed. To determine the importance of the resulting clusters, the natural logarithm of normal density was calculated, where normal density is derived from the prediction rate divided by the occupied area, following the prediction-area (P-A) plot method (Yousefi and Carranza, 2015). The proposed algorithm achieved an intersection point of 72% on the P-A plot (Fig. 10), indicating a high prediction rate with minimal occupied area. The results successfully discriminate known occurrences and show good spatial agreement with intrusive bodies (Fig. 11).

The results demonstrate that the unsupervised deep learning approach based on a Long Short-Term Memory (LSTM) architecture effectively extracts hidden patterns and complex relationships among multiple exploration evidence layers, which is particularly significant in geological data characterized by nonlinear behavior, spatial heterogeneity, and high uncertainty. Unlike conventional machine learning methods that often assume variable independence or simple linear relationships, the proposed model successfully captures intricate dependencies among alteration, geochemical, fault, and intrusive layers, leading to more accurate delineation of prospective mineral zones. Notably, the high-potential areas show good agreement with known geological evidence in the Kajan 1:100,000 sheet, where anomalies are concentrated near faults and intrusive bodies and coincide with alteration zones, confirming the model's capability to represent mineralization processes. Compared to classical methods such as random forest, support vector machine (SVM), and K-means, the proposed model offers several advantages: (1) it does not require labeled training data, which are often limited or unavailable in exploration areas; (2) its recurrent structure enables modeling of sequential dependencies and multi-layer interactions that are rarely addressed by traditional methods, which is especially valuable for spatial data with implicit continuity. However, limitations include sensitivity to hyperparameters, the need for sufficient data for effective training, high computational complexity, and limited interpretability, a common challenge in deep learning applications within geosciences. Despite these constraints, integrating unsupervised deep learning with multi-source geological data proves to be a powerful tool for mineral potential modeling. Future studies should combine this model with interpretable approaches and integrate geophysical or higher-resolution data to enhance accuracy and reliability.

Field Validation

To validate the LSTM-based unsupervised deep learning model, a targeted field validation program was conducted in two prospect zones introduced by the model within the Kajan 1:100,000 sheet: Hashemabad and Kooh-e-Lakht. In the Hashemabad area (southeastern Kajan), field observations confirmed a skarn system with significant Cu-Fe mineralization as malachite and magnetite (Fig. 12. b, c), occurring as massive

and vein-veinlet styles at the contact between a granitoid intrusion and Cretaceous carbonate rocks, with clear propylitic alteration. This fully aligns with the model's prediction regarding the combined influence of intrusion, faults, and alteration. In the Kooh-e-Lakht area (southwestern Kajan), field validation revealed a hydrothermal system with significant gold mineralization. The lithology consists of volcanic rocks (andesite, dacite, rhyodacite, rhyolite, diabase) and intrusive rocks (granodiorite, diorite, micro-monzodiorite), extensively affected by hydrothermal fluids over an area of 2.5 km², producing phyllic, argillic, advanced argillic, propylitic, and silicic alterations (Fig. 12. c-e). Gold mineralization is primarily associated with silica-breccia veins containing malachite, barite, alunite, and iron oxides, with no direct link to a distinct intrusive body, an observation that strongly supports the LSTM model's prediction emphasizing the role of fault structures in focusing anomalies in this region.

Conclusions

This study demonstrated that an unsupervised deep learning approach based on a Long Short-Term Memory (LSTM) architecture can be effectively applied to mineral potential modeling and the delineation of prospective mineralization zones. By leveraging its capability to learn nonlinear relationships and extract hidden patterns from multi-source geological data, the proposed model successfully identified meaningful structures and mineralization-related anomalies without requiring labeled training data, a key advantage, particularly in exploration settings where training data are limited or unreliable. The integration of alteration, geochemical, fault, and intrusive layers within a deep learning framework produced prospectivity maps that are geologically consistent with known mineralization patterns, indicating the model's capacity to represent complex geological processes and deliver

reliable results for exploration decision-making. Compared to conventional machine learning methods, the proposed model eliminates the need for data labeling and enhances the modeling of complex relationships, thereby representing an effective step toward reducing uncertainty in mineral potential modeling. Nevertheless, computational complexity, parameter sensitivity, and limited interpretability remain challenges that must be addressed in practical applications. Future studies should therefore focus on incorporating model interpretability techniques and integrating higher-resolution, multi-scale data. Overall, the findings indicate that hybrid approaches based on deep learning, particularly unsupervised models, can serve as efficient and modern tools in mineral exploration, playing a significant role in improving accuracy, reducing risk, and optimizing decision-making processes.

References

- Carranza, E.J.M., Van Ruitenbeek, F.J.A., Hecker, C., van der Meijde, M., van der Meer, F.D., 2008. Knowledge-guided data-driven evidential belief modeling of mineral prospectivity in Cabo de Gata, SE Spain. *International Journal of Applied Earth Observation and Geoinformation* 10(3), 374–387.
- Hoseinzade, Z., Shojaei, M., Khademi, F., Mokhtari, A.R., Saremi, M., 2025. Integration of deep learning models for mineral prospectivity mapping: a novel Bayesian index approach to reducing uncertainty in exploration. *Modeling Earth Systems and Environment* 11(3), 161.
- Mokhtari, M., Hoseinzade, Z., Shirani, K., 2020. A comparison study on landslide prediction through FAHP and Dempster–Shafer methods and their evaluation by P–A plots. *Environmental Earth Sciences* 79(3), 76. doi: 10.1007/s12665-019-8804-0.
- Yousefi, M., Carranza, E.J.M., 2015. Prediction–area (P–A) plot and C–A fractal analysis to classify and evaluate evidential maps for mineral prospectivity modeling. *Computers & Geosciences* 79, 69–81.

CRediT authorship contribution statement

	Conceptualization, Methodology, Software, Formal analysis, Investigation, Resources, Data Curation, Writing - Original Draft, Supervision
	Writing - Original Draft, Conceptualization, Software, Investigation, Formal analysis, Review & Editing
	Validation, Formal analysis, Investigation, Writing - Review & Editing, Supervision



دسترسی آزاد

نشریه علوم زمین خوارزمی

Journal homepage <https://gnf.khu.ac.ir>

یادگیری عمیق بدون نظارت مبتنی بر LSTM برای شناسایی ناهنجاری در نقشه 1:100,000 کجان، مرکز ایران

زهره حسین زاده^۱، عارف داعی^۲، زهرا اعلمی نیا^{۳*}

۱. گروه مهندسی معدن، دانشکده مهندسی معدن و مواد، دانشگاه صنعتی همدان، همدان، ایران.

۲. گروه علوم کامپیوتر، دانشکده علوم ریاضی، دانشگاه فردوسی مشهد، مشهد، ایران.

۳. گروه زمین شناسی، دانشکده علوم، دانشگاه فردوسی مشهد، مشهد، ایران.

چکیده

اطلاعات مقاله

نوع مقاله

مقاله پژوهشی

تاریخچه مقاله

دریافت: ۱۴۰۵/۰۲/۱۸

پذیرش: ۱۴۰۵/۰۳/۳۱

واژه‌های کلیدی:

کانه‌زایی مس-طلا، یادگیری

عمیق، شبکه LSTM،

اصفهان.



مدل‌سازی پتانسیل معدنی به‌عنوان یکی از ابزارهای کلیدی در اکتشاف، با چالش‌هایی نظیر پیچیدگی روابط غیرخطی، ناهمگونی داده‌ها و محدودیت داده‌های برچسب‌خورده مواجه است. در این پژوهش، یک رویکرد یادگیری عمیق بدون نظارت و هیبریدی مبتنی بر شبکه حافظه طولانی کوتاه مدت به‌منظور شناسایی نواحی مستعد کانه‌زایی ارائه شده است. این مدل قادر است بدون نیاز به داده‌های آموزشی برچسب‌خورده، ساختارهای پنهان، شباهت‌ها و ناهنجاری‌ها را در داده‌های زمین‌شناسی استخراج نماید. در گام نخست، ویژگی‌های استخراج‌شده توسط الگوریتم خوشه‌بندی BIRCH گروه‌بندی شدند و سپس با بهره‌گیری از شاخص پیش‌بینی-مساحت (P-A)، که نسبت تجمعی نقاط معدنی به مساحت پیش‌بینی‌شده را ارزیابی می‌کند، نواحی با بیشترین پتانسیل معدنی تفکیک گردیدند. به‌منظور ارزیابی کارایی مدل، این رویکرد در برگه یکصد هزار کجان در استان اصفهان، به‌عنوان منطقه‌ای با پتانسیل کانه‌زایی مس-طلا، پیاده‌سازی شد. داده‌های ورودی شامل لایه‌های دگرسانی، ژئوشیمی، گسل‌ها و توده‌های نفوذی بوده که پس از فازی‌سازی، به‌عنوان ورودی به مدل اعمال شدند. نتایج نشان داد که مدل پیشنهادی با تخصیص ۷۲ درصد از نقاط معدنی شناخته‌شده به کمتر از ۳۰ درصد از مساحت منطقه، توانایی مناسبی در شناسایی الگوهای پیچیده و تفکیک نواحی امیدبخش معدنی دارد و نقشه‌های حاصل از آن با شواهد زمین‌شناسی منطقه همخوانی قابل قبولی دارند. در مقایسه با روش‌های متداول یادگیری نظارت‌شده، رویکرد پیشنهادی با حذف نیاز به داده‌های برچسب‌خورده و افزایش قدرت مدل‌سازی روابط غیرخطی، پتانسیل کاهش عدم قطعیت و بهبود دقت مدل‌سازی پتانسیل معدنی را دارد. این نتایج نشان می‌دهد که استفاده از مدل‌های یادگیری عمیق بدون نظارت، به‌ویژه مبتنی بر LSTM، می‌تواند به‌عنوان ابزاری مؤثر در اکتشاف ذخایر معدنی و بهینه‌سازی تصمیم‌گیری‌های اکتشافی مورد استفاده قرار گیرد.

مقدمه

تاکنون روش‌های گوناگونی برای مدل‌سازی پتانسیل معدنی توسعه یافته‌اند که به طور کلی در دو دسته داده‌محور و دانش‌محور قرار می‌گیرند. از جمله این روش‌ها می‌توان به وزن شواهد (Wang et al., 2002)، فرایند تحلیل سلسله‌مراتبی یا AHP (Mokhtari et al., 2020; Saremi et al., 2024a)، الگوریتم جنگل ایزوله عمیق (Saremi et al., 2024b)، شبکه خودمرزگذار (Mirzabozorg and Abedi, 2023)، روش‌های ترکیبی (Hajhosseini et al., 2024) و شبکه‌های عصبی پیچشی (CNN: Convolutional Neural Network) (Li et al., 2023) اشاره کرد.

در دهه‌های اخیر، به‌کارگیری روش‌های یادگیری ماشین در مدل‌سازی پتانسیل معدنی رشد چشمگیری داشته است. الگوریتم‌های تحت‌نظارت مانند ماشین‌های بردار پشتیبان (Abedi et al., 2012) و جنگل‌های تصادفی (Ghasemzadeh et al., 2023) و همچنین روش‌های بدون نظارت مانند K-

یکی از مراحل اصلی در اکتشافات معدنی، شناسایی عوارض زمین‌شناسی مرتبط با کانی‌زایی هدف، از طریق تهیه و بررسی نقشه‌های زمین‌شناسی است. این نقشه‌ها شامل عوارض مختلفی مانند واحدهای سنگ‌شناسی، انواع دگرسانی، ساختارها و نشانه‌های معدنی می‌باشند (Rowan et al., 2006). مدل‌سازی پتانسیل معدنی (MPM: Mineral Prospectivity Mapping) به عنوان رویکردی مبتنی بر سامانه اطلاعات جغرافیایی (GIS)، ابزاری نظام‌مند برای شناسایی نواحی با پتانسیل بالای کانه‌زایی محسوب می‌شود که با استفاده از مجموعه داده‌ها و عوارض علوم زمین انجام می‌گیرد (Carranza et al., 2008). این مدل‌ها با فراهم‌سازی اطلاعات جامع و دقیق درباره مناطق امیدبخش، زمینه تصمیم‌گیری آگاهانه و طراحی هدفمند برنامه‌های اکتشافی را برای زمین‌شناسان فراهم می‌کنند (Zhang et al., 2021). در این راستا،

DOI 10.22034/kjes.2026.11696

*نویسنده مسئول: زهرا اعلمی نیا alaminia@um.ac.ir

استناد به این مقاله: حسین زاده، ز.، داعی، ع.، اعلمی نیا، ز. (۱۴۰۵). یادگیری عمیق LSTM نظارت نشده برای شناسایی ناهنجاری در نقشه ۱:۱۰۰۰۰۰ کجان، مرکز ایران. مجله علوم زمین خوارزمی. جلد ۱۲، شماره ۱، صفحه ۶۴ تا ۸۱. <http://doi.org/10.22034/kjes.2026.11696>



شناسایی کند. بدین منظور، پس از گروه‌بندی خودکار نمونه‌ها بر اساس معیارهای آماری و الگوریتمی، با استفاده از شاخص اطمینان، هدف‌هایی با بیشترین پتانسیل معدنی تفکیک شده‌اند. الگوریتم پیاده‌شده در این مقاله مبتنی بر معماری شبکه حافظه کوتاه مدت است. هدف اصلی ارزیابی توانایی شبکه مذکور در استخراج الگوهای پیچیده و بهبود دقت تفکیک نواحی امیدبخش معدنی در مقایسه با روش‌های متداول یادگیری ماشین است. بدین منظور، از مدل هیبریدی مبتنی بر شبکه حافظه کوتاه مدت برای مدل‌سازی پتانسیل معدنی در برگه یکصد هزار کجان واقع در استان اصفهان که از نظر کانه‌زایی مس-طلا از پتانسیل مناسبی برخوردار است، استفاده شد. لایه‌های به‌کار رفته شامل لایه دگرسانی، لایه ژئوشیمی، لایه گسل و لایه توده نفوذی هستند که پس از فاز‌سازی به‌عنوان ورودی به مدل یادگیری عمیق داده شدند تا شبکه با ساز و کار درونی خود نواحی مستعد کانه‌زایی را شناسایی کند.

زمین‌شناسی ناحیه‌ای


محدوده مورد مطالعه در استان اصفهان و در بخش میانی کمان ماگمایی ارومیه-دختر قرار دارد. به استناد برگه زمین‌شناسی ۱:۱۰۰۰۰۰ کجان، قدیمی‌ترین واحد رخنمون‌یافته در ناحیه، واحدهای هارزبورژیت سرپانتینیته شده در گوشه شمال‌خاوری نقشه کجان است (شکل ۱). این واحدها بروزند کمی داشته و با دگرسانی‌های شدید همراهند و در بخش زیرین توالی دگرگونی قرار گرفته‌اند. این توالی دگرگونی شامل اپیدوت شیست، متاندزیت، متابازالت و واحدهای کربناتی شامل مرمر و سنگ آهک بلورین است. واحدهای متعلق به دوره کرتاسه عمدتاً شامل سنگ آهک‌های کرم خاکستری حاوی اوریتولین و همچنین اسپیلیت بازالتی تا آندزیتی با دگرسانی جزئی می‌باشند. نهشته‌های سنوزوئیک با توالی پیچیده‌ای آغاز می‌شوند که شامل کنگلومرای قرمز ائوسن، توف‌های اسیدی، ایگنیمبریت، گدازه‌های تراکی‌آندزیت تا داسیت، و لیتیک توف‌های همراه با سیلتستون و ماسه‌سنگ توفی است. این توالی با جریان‌های ریولیتی صورتی ادامه یافته و در ائوسن بالایی، مجموعه تراکی‌آندزیت، آندزیت، داسیت، ایگنیمبریت‌های تنابویی، ماسه‌سنگ‌های توفی، توف‌های خاکستری، کنگلومرا، سیلتستون و جریان‌های گدازه پیروکسن آندزیت تا بازالت پیروکسن به رنگ سبز خاکستری دیده می‌شود. نهشته‌های میوسن با توالی کنگلومرای مایل به قرمز خاکستری شروع شده و به توالی مارن همراه با میکروکنگلومرا، بین لایه‌های مارن و گچ ختم می‌شود. جریان‌های گدازه و اسکوری با ترکیب بازالتی تا آندزیتی در این نهشته‌ها مشاهده می‌گردد. نهشته‌های پلیوسن با حضور جریان‌های لاهار همراه با تفرهای با ترکیب اسیدی به رنگ خاکستری روشن آغاز شده و با آگلومرا، توف‌های برشی، جریان‌های گدازه داسیتی تا آندزیتی به رنگ قرمز خاکستری و سپس هیالوداسیت همراه با ایگنیمبریت در قاعده، به پایان می‌رسد. توده‌های نفوذی از جنس دیوریت، مونزودیریت و

means (Mirzabozorg et al., 2024; Ghezelbash et al., 2020) و IForest (Zhang et al., 2022) به‌طور گسترده در این زمینه به‌کار رفته‌اند. اگرچه این روش‌ها در شرایط ساده عملکرد مناسبی داشته‌اند، اما اغلب بر روابط خطی و فرضیات اولیه ساده‌کننده استوارند و در مواجهه با پیچیدگی‌های ذاتی داده‌های زمین‌شناسی (نظیر همبستگی‌های غیرخطی، عدم قطعیت بالا و ناهمگونی داده‌ها) با محدودیت‌هایی روبه‌رو هستند (Mirzabozorg and Abedi, 2023; Saremi et al., 2024c). شبکه یادگیری عمیق از چند مرحله تشکیل می‌شود که شامل لایه ورودی، لایه‌های پنهان و لایه خروجی است. این شبکه داده‌های خام را دریافت می‌کند و بدون نیاز به دخالت کاربر، ویژگی‌های نماینده مورد نیاز برای طبقه‌بندی را فرا می‌گیرد. آموزش شبکه با الگوریتم پس‌انتشار خطا انجام می‌شود (Li et al., 2020a). با گسترش رویکردهای یادگیری ماشین، روش‌هایی مانند جنگل تصادفی، ماشین بردار پشتیبان و شبکه‌های عصبی مصنوعی در جهت رفع برخی از این محدودیت‌ها مورد استفاده قرار گرفتند. با این حال، اکثر این مدل‌ها فرض استقلال میان متغیرهای ورودی را پذیرفته و قابلیت مدل‌سازی روابط دنباله‌دار یا وابستگی‌های فضایی-زمانی را ندارند. در سال‌های اخیر، توسعه معماری‌های پیشرفته‌تر یادگیری عمیق موجب ورود الگوریتم‌هایی مانند شبکه‌های عصبی مصنوعی (Li et al., 2020b; Li et al., 2021) به حوزه مدل‌سازی پتانسیل معدنی شده است. این شبکه‌ها با استفاده از لایه‌های پیچشی و ادغام، قادر به استخراج ویژگی‌های مکانی از داده‌های جغرافیایی و شناسایی الگوهای فضایی در داده‌های شواهد اکتشافی هستند (Mirzabozorg et al., 2024). توانایی شبکه‌های عصبی پیچشی در شناسایی خودکار الگوهای پیچیده (مانند پهنه‌بندی ناهنجاری‌های ژئوشیمیایی مرتبط با کانه‌زایی) محققان را به استفاده گسترده از آن‌ها در مدل‌سازی پتانسیل معدنی ترغیب کرده است (Li et al., 2020b). علاوه بر شبکه‌های عصبی پیچشی، شبکه‌های حافظه کوتاه‌مدت (LSTM: Long Short-Term Memory) نیز به دلیل قابلیت درک وابستگی‌های طولانی‌مدت و الگوهای پنهان در داده‌های ترتیبی، توجه بسیاری از پژوهشگران را جلب کرده‌اند (Hoseinzade et al., 2025). شبکه حافظه کوتاه مدت نوعی شبکه عصبی بازگشتی (RNN: Recurrent Neural Network) است که عمدتاً برای تحلیل داده‌های ترتیبی و سری‌های زمانی به کار می‌رود (Hochreiter and Schmidhuber, 1997). ساختار دروازه‌ای این شبکه‌ها امکان مدل‌سازی پویا و مؤثر روابط پیچیده و غیرخطی بین لایه‌های مختلف اکتشافی را فراهم می‌سازد. کاربردهای موفق آن‌ها در زمینه‌هایی همچون پیش‌بینی عیار، تحلیل داده‌های حفاری و مدل‌سازی پتانسیل معدنی، کارایی این روش‌ها را اثبات کرده است.

در این پژوهش، از یک رویکرد یادگیری عمیق بدون نظارت و هیبریدی بهره گرفته شده است که قادر است بدون نیاز به داده‌های برچسب‌خورده، ساختارهای پنهان، شباهت‌ها و ناهنجاری‌ها را در داده‌های زمین‌شناسی

آبرفتی، پادگانه‌ها، تراس‌های رودخانه‌ای و دامنه‌های هوازده را تشکیل داده و واحدهای زمین‌شناسی زیرین را می‌پوشانند. در برخی مناطق، این نهشته‌ها منجر به تشکیل شوره‌زارها شده‌اند.

گرانودیوریت تا گرانیت با سن الیگوسن و جوان‌تر هستند که بیشتر در بخش باختری کوه‌های کلاغ و کجستان، جنوب هاشم آباد و کوه‌لخت رخنمون یافته- (شکل ۱). رسوبات کواترنری به صورت قله‌سنگ و پاره‌سنگ دیده می‌شوند که هنوز به طور کامل سفت نشده و هوازده شده‌اند. این رسوبات بادبزنی‌های



شکل ۱- نقشه زمین‌شناسی ساده شده براساس نقشه یکصد هزار کجان (برگرفته از Amini and Amini Chehragh, 2003)

Fig. 1. Simplified geologic map based on the 1:100000 Kajan map (after Amini and Amini Chehragh, 2003)


پروپلیتیک، آرژیلیک و فیلیک)، لایه گسلی (تراکم و فواصل از گسل‌های اصلی) و لایه توده نفوذی (فواصل از توده‌های گرانیتوئیدی تا دیوریتی) می‌باشند. تمامی لایه‌ها پس از آماده‌سازی و هم‌مکان‌سازی با ابعاد سلول 100×100 متر، با استفاده از توابع عضویت فازی به بازه صفر تا یک نرمالایز شده و سپس به عنوان ورودی به الگوریتم ارائه شدند. شبکه طراحی شده از نوع بدون نظارت بوده و وظیفه یادگیری ویژگی‌های پنهان در ورودی‌ها را داشت. سپس ویژگی‌های استخراج شده را خوشه‌بندی می‌نماید. در نهایت با استفاده از نمودار نرخ پیش‌بینی-مساحت (P-A: Prediction-Area plot)، خوشه آنومالی از زمینه

روش پژوهش

در این پژوهش، به منظور شناسایی نواحی دارای ناهنجاری معدنی در برگه ۱:۱۰۰۰۰۰ زمین‌شناسی کجان، از یک رویکرد یادگیری عمیق نظارت نشده مبتنی بر معماری شبکه حافظه کوتاه مدت استفاده شده است. داده‌های ورودی مدل شامل چهار لایه شواهد اکتشافی شامل لایه ژئوشیمیایی (بر پایه تجزیه رسوبات آبراهه‌ای برای عناصر مس، طلا، مولیبدن و نقره)، لایه دگرسانی (مستخرج از پردازش تصاویر ماهواره‌ای استر برای شناسایی پهنه‌های

کجان اعتبارسنجی شده و قابلیت روش پیشنهادی در تفکیک مناطق امیدبخش برای اکتشافات مس-طلا مورد ارزیابی قرار می گیرد (شکل ۲). تمام مراحل ذکر شده در پاپتون ۳، کدنویسی شده است.

تفکیک می شود. مزیت اصلی الگوریتم مذکور نسبت به روش های متداول مانند جنگل تصادفی و ماشین بردار پشتیبان، توانایی آن در مدل سازی وابستگی های مکانی و الگوهای پنهان غیرخطی بین لایه های مختلف شواهد اکتشافی بدون نیاز به داده های برچسب خورده (نقاط کانده زایی شناخته شده) است. در نهایت، نقشه نهایی نواحی ناهنجار با نشانه های معدنی شناخته شده در برگه یکصد هزار




شکل ۲- نمودار جریان مراحل مختلف اکتشاف و شناسایی پتانسیل یابی معدنی

Fig. 2. Flowchart of the various stages of exploration and mineral prospectivity mapping

به عنوان خروجی ارسال شود. این سازوکار به شبکه حافظه کوتاه مدت این امکان را می دهد که به طور انتخابی اطلاعات را در طول دنباله حفظ یا فراموش کند و بنابراین بهتر می تواند وابستگی های بلندمدت را مدل سازی کند (Sherstinsky, 2020). در مطالعات بسیاری (مانند Jyostna et al., 2025) از شبکه مذکور استفاده شده است اما در این مطالعه، از این شبکه با ساختار تعبیه شده برای یادگیری الگوهای پنهان در داده ها و استخراج ویژگی های مهم استفاده شده است. سپس این ویژگی های استخراج شده به یک الگوریتم خوشه بندی داده می شود تا داده ها به دسته های مختلف تقسیم شوند. این ترکیب از شبکه حافظه کوتاه مدت و خوشه بندی، رویکردی قدرتمند برای تحلیل و درک داده ها ارائه می دهد که می تواند به استخراج ویژگی های دقیق تر، خوشه بندی بهتر و کشف الگوهای پنهان در داده ها کمک کند. تصویر شماتیک از معماری تلفیقی پیشنهادی در شکل ۳ ارائه شده است.

الگوریتم مبتنی بر LSTM

شبکه LSTM نوعی شبکه عصبی بازگشتی است که برای رفع محدودیت شبکه های بازگشتی سنتی در به خاطر سپردن وابستگی های بلندمدت در داده های دنباله ای طراحی شده است. مشکل اصلی شبکه های بازگشتی معمولی این است که در حفظ اطلاعات طولانی مدت دچار مشکل می شوند که این مسئله به محو شدن گرادیان معروف است. شبکه حافظه کوتاه مدت با معرفی یک سازوکار به نام سلول حافظه این مشکل را حل می کند. سلول حافظه در شبکه حافظه کوتاه مدت مانند یک نوار نقاله اطلاعات را در طول دنباله منتقل می کند. این سلول دارای سه دروازه اصلی است: دروازه فراموشی، دروازه ورودی، و دروازه خروجی. دروازه فراموشی تعیین می کند که چه اطلاعاتی باید از سلول حذف شود، دروازه ورودی مشخص می کند که چه اطلاعات جدیدی باید به سلول اضافه شود، و دروازه خروجی تصمیم می گیرد که چه اطلاعاتی از سلول




شکل ۳- نقشه راه الگوریتم یادگیری عمیق مبتنی بر شبکه حافظه کوتاه مدت (LSTM)

Fig. 3. Roadmap of the Long Short-Term Memory (LSTM)-based deep learning algorithm

شیمیایی ۴۳۴ نمونه رسوب آبراهه‌ای در برگه یکصد هزار کجان بدست آمده است.

آماده‌سازی لایه‌های اطلاعاتی

داده‌های مورد استفاده در این مطالعه شامل داده‌های ژئوشیمیایی، لایه گسل و لایه زمین‌شناسی می‌باشد (شکل ۴). داده‌های ژئوشیمی از نتایج تجزیه



شکل ۴- موقعیت نمونه‌های رسوب آبراهه‌ای برداشت شده در نقشه یکصد هزار کجان

Fig. 4. The location of the collected stream sediment samples within the 1:100000 scale map of Kajan

مدل مفهومی کانسار به مجموعه‌ای از فرضیات و داده‌های زمین‌شناسی گفته می‌شود که برای توضیح و توصیف نحوه شکل‌گیری، ساختار، و توزیع مواد


مدل مفهومی

از مهم‌ترین آنها شکستگی‌هایی است که نقش بسیار مهمی در تشکیل و توسعه ذخایر گرمایی ایفا می‌کنند. این ساختارهای زمین‌شناسی مسیری برای حرکت سیالات گرمایی فراهم می‌کنند که حاوی مواد معدنی مختلف، از جمله فلزات ارزشمندی مانند طلا، مس، نقره و سایر فلزات، هستند. در مطالعات بسیاری از کنترل‌کننده‌های ساختاری به منظور پتانسیل‌یابی استفاده شده است (Yousefi and Hronsky, 2023). در این مطالعه با توجه به اهمیت گسل‌ها در منطقه مورد مطالعه لایه‌های فاصله از گسل بکار برده شد. سپس مقادیر این لایه‌ها به منظور اطمینان از سازگاری مقیاس اندازه‌گیری، افزایش دقت و کاهش عدم قطعیت مدل‌سازی پتانسیل معدنی فازی شدند. نقشه مقادیر فازی شده هر دو لایه در شکل ۵ نمایش داده شده است.

معدنی در یک ناحیه مشخص به کار می‌رود. این مدل‌ها بر اساس اطلاعات حاصل از مطالعات زمین‌شناسی، ژئوفیزیکی، ژئوشیمیایی و حفاری‌ها ساخته می‌شوند و به درک بهتر از نحوه تشکیل و جای‌گذاری مواد معدنی مانند فلزات و سنگ‌های ارزشمند در زمین کمک می‌کنند. با توجه به منطقه مورد مطالعه و ویژگی‌های آن، هدف پتانسیل‌یابی ذخایر مس-طلا از نوع پورفیری، اسکارن و گرمایی است. بر اساس مدل مفهومی کانسار مورد جستجو از معیارهای مختلفی برای تولید نقشه‌های شاهد اکتشافی در این مطالعه استفاده شد که در ادامه شرح داده می‌شود.

کنترل‌کننده‌های ساختاری

کنترل‌کننده‌های ساختاری به ویژگی‌ها و ساختارهای زمین‌شناسی گفته می‌شود که بر توزیع و تمرکز کانی‌زایی یا ذخایر معدنی تأثیر می‌گذارند. یکی



شکل ۵- کنترل‌کننده‌های ساختاری، لایه اطلاعاتی فاصله از گسل‌های فازی شده


Fig. 5. Structural controllers, the information layer of fuzzified distance from the faults

مرتبط با کانی‌سازی باشد. یوسفی و هرونسکی (Yousefi and Hronsky, 2023) در این زمینه، یک معیار نقطه‌ای جدید را برای شناسایی کانسارهای پورفیری و گرمایی پیشنهاد کردند. این ویژگی تقاطع گسل‌ها و توده نفوذی است که در آن فرایندهای فیزیکی و شیمیایی لازم برای تشکیل کانسنگ به طور همزمان عمل می‌کنند. این ویژگی می‌تواند به عنوان یک معیار اکتشافی مناسب برای کانسارهای مس-طلا پورفیری استفاده شود. نواحی با

فاصله از تقاطع گسل و توده نفوذی

روابط فضایی و حرارتی قابل توجهی بین توده‌های نفوذی و بسیاری از کانسارهای معدنی از جمله مس-طلا پورفیری و اسکارن وجود دارد. علاوه بر این، در کانسارهای گرمایی، گسل‌ها عبور ماگماها و جریان سیالات گرمایی را تسهیل می‌کنند. تقاطع گسل و توده نفوذی می‌تواند محل تمرکز سیالات

نفوذپذیری بالا در اطراف این نقاط وجود دارند. ابتدا لایه فاصله حاصل از تقاطع گسل و توده نفوذی ایجاد و سپس با استفاده از تابع لجستیک یوسفی و نیکانن (Yousefi and Nykänen, 2016)، فازی شدند (شکل ۶).




شکل ۶- لایه فاصله از تقاطع گسل و توده نفوذی فازی شده

Fig. 6. Fuzzified distance to fault-intrusion intersection layer

تفسیرپذیری و کاهش عدم قطعیت در تحلیل مدل‌سازی پتانسیل معدنی افزایش یابد. شکل ۷ لایه شاهد ساخته شده را نشان می‌دهد.

فاصله از سنگ‌های نفوذی

سنگ‌های نفوذی نقش حیاتی در تشکیل ذخایر معدنی داشته و اطراف آنها به طور قابل توجهی احتمال کشف ذخایر ماگمایی و گرمابی افزایش می‌یابد. با توجه به گزارش‌های زمین‌شناسی و مطالعات انجام شده (Amini and Amini Chehragh, 2003) در برکه کجان، توده‌های نفوذی با ترکیب گرانیت میکروگرانیت، گرانودیوریت تا دیوریت، کوارتز دیوریت و کوارتز مونزودیوریت نقش مهمی در ایجاد کانه‌زایی گرمابی دارند. بر همین اساس استفاده از لایه فاصله از توده نفوذی می‌تواند یک راهنمای اکتشافی مهم به منظور شناسایی تارگت‌های اکتشافی باشد. از این‌رو توده‌های نفوذی استخراج و فاصله از آنها محاسبه شد. در نهایت مقادیر این لایه با استفاده از یک تابع لجستیکی (Yousefi and Nykänen, 2016) به یک فضای فازی تبدیل شدند تا دقت،




شکل ۷- لایه فاصله از توده‌های نفوذی

Fig. 7. The Layer of distance from the intrusive bodies

در تلفیق لایه‌های اطلاعاتی فازی شدند. ناهنجاری عناصر مذکور در شکل ۸ ارائه شده است.

لایه‌های شواهد ژئوشیمیایی

مطالعات ژئوشیمیایی، نقش مهمی در مدل‌سازی پتانسیل معدنی، به ویژه در مقیاس منطقه‌ای ایفا می‌کنند. بررسی‌های ژئوشیمیایی برای درک توزیع و رفتار عناصر مرتبط با کانی‌سازی حیاتی هستند. تکنیک‌های مختلفی برای تعیین ناهنجاری‌های ژئوشیمیایی و ایجاد لایه‌های شواهد برای مدل‌سازی پتانسیل معدنی در مقیاس منطقه‌ای توسعه یافته‌اند (Meigoony et al., 2014; Rezaei Alishahdani et al., 2025). این روش‌ها بیشتر بر بررسی رفتار و اطلاعات ژئوشیمیایی عناصری که ارتباط مثبتی با کانی‌سازی نشان می‌دهند، تمرکز می‌کنند. با توجه به اینکه کانی‌زایی هدف در این مطالعه، مس و طلا بود، از عناصر ردیاب آن استفاده شد. بر همین اساس نقشه‌های عناصر مس، طلا، مولیبدن، آرسنیک، سرب و روی ترسیم و تجزیه‌های آنها با استفاده از روش پرسنتایل (بیشتر از ۹۷/۵٪) تفکیک شد. در نهایت به منظور شرکت



شکل ۸- لایه شاهد ژئوشیمی. ناهنجاری‌های ژئوشیمیایی استخراج شده عناصر مرتبط با مس و طلا روی نقشه نشان داده شده است
 Fig. 8. The geochemical proxy layer. Geochemical anomalies of elements associated with Cu and Au are shown on the map


و بارزسازی این زون‌ها به شمار می‌روند (Pour and Hashim, 2012; Hajaj et al., 2024; Ghoraeian et al., 2024).

شکل ۸ توزیع پهنه‌های دگرسانی در منطقه را نشان می‌دهد. دگرسانی‌های آرژلیک و آرژلیک پیشرفته عمدتاً در بالای زون فیلیک سامانه‌های ماگمایی-گرمایی توسعه یافته‌اند و شامل کانی‌هایی نظیر کائولینیت، مونتموریلونیت، آلونیت و پیریت هستند که به‌عنوان شاخص‌های مهم اکتشاف کانسارهای پورفیری و گرمایی سولفید زیاد شناخته می‌شوند. افزایش شدت دگرسانی منجر به تبدیل آرژلیک به آرژلیک پیشرفته با حضور کانی‌هایی مانند دیاسپور، پیروفلیت و کوارتز می‌شود. برای بارزسازی اکسیدهای آهن، از ویژگی‌های طیفی کانی‌هایی مانند هماتیت، گوتیت و لیمونیت استفاده شده است. زون پروپلیتیک به‌عنوان گسترده‌ترین زون حاشیه‌ای، با کانی‌هایی نظیر کلریت، اپیدوت و کلسیت مشخص می‌شود. همچنین، دگرسانی سیلیسی در بخش‌های

لایه‌های سنجش از دور

برگه زمین‌شناسی یکصد هزار کجان از دیدگاه زمین‌شناسی اقتصادی، دارای کانه‌زایی‌های گرمایی قابل توجهی بوده و به دلیل گسترش دگرسانی‌های متنوع، پتانسیل مناسبی برای تمرکز فلزاتی نظیر مس و طلا دارد (Amini and Amini Chehragh, 2003). با توجه به ارتباط نزدیک زون‌های دگرسانی با کانه‌زایی فلزی، شناسایی و پهنه‌بندی این زون‌ها نقش کلیدی در اکتشاف دارد. از مهم‌ترین دگرسانی‌های موجود در این پنجره می‌توان به فیلیک، آرژلیک، آرژلیک پیشرفته و پروپلیتیک اشاره کرد که معمولاً بر اساس کانی‌های شاخص تفکیک می‌شوند. در این راستا، داده‌های سنجنده استر به دلیل توانایی در تفکیک ویژگی‌های طیفی کانی‌ها، ابزار مؤثری برای شناسایی

مرکزی تا شمال غرب منطقه مشاهده شده که به عنوان یکی از مراحل نهایی فعالیت‌های گرمایی مرتبط با توده‌های نفوذی تفسیر می‌شود. در نهایت، تمامی لایه‌های دگرسانی با استفاده از تابع لجستیک، فازی‌سازی شدند (شکل ۹).




شکل ۹- دگرسانی‌های استخراج شده از تصاویر ماهواره‌ای استر

Fig. 9. Alterations extracted from ASTER satellite images

درصد رخدادهای معدنی شناخته شده و مساحت به تفکیک هر روش نشان داده شده است. نمودار مذکور شامل دو منحنی است که یکی از آنها مربوط به نرخ پیش‌بینی رخدادهای معدنی شناخته شده به وسیله هر کلاسه و دیگری درصد ناحیه اشغال شده بوسیله هر کلاسه می‌باشد. در واقع این منحنی‌ها به عنوان معیاری برای ارزیابی یک مدل پتانسیل معدنی است. به منظور ارزیابی مدل، هرچه نقطه تلاقی در نمودار، مقدار بالاتری را نشان دهد (یعنی نرخ پیش‌بینی بالاتر)، بدین معناست که کمترین مقدار درصد مساحت در برگیرنده را دارد. بر همین اساس الگوریتم طراحی شده دارای نقطه تلاقی ۷۲٪ است. نتایج حاصل از این روش نیز به خوبی رخدادها را تفکیک نموده و همخوانی با توده نفوذی نیز در این شکل دیده می‌شود (شکل ۱۱).


ارزیابی عملکرد مدل

با توجه به پیچیدگی‌های برگه یکصد هزار کجان، استفاده از یک الگوریتم مناسب به منظور شناسایی نقاط امیدبخش اکتشافی ضروری است. الگوریتم‌های متعددی بدین منظور وجود دارد که در این مطالعه از الگوریتم یادگیری عمیق مبتنی بر LSTM استفاده شد. پس از پیاده‌سازی الگوریتم‌ها، اهمیت خوشه‌ها باید تعیین گردد که از لگاریتم طبیعی چگالی نرمال بدین منظور استفاده شد. چگالی نرمال از تقسیم نرخ پیش‌بینی بر مساحت اشغال شده بدست می‌آید. دو معیار مذکور نتیجه نمودار منطقه پیشگویی است که توسط (Yousefi and Carranza, 2015) معرفی شد. شکل ۱۰ نمودار مربوط به



شکل ۱۰- نمودار نرخ پیش‌بینی-مساحت مربوط به مدل LSTM

Fig. 10. Prediction-area plot for the LSTM model



شکل ۱۱- مدل تولید شده با استفاده از الگوریتم‌های یادگیری عمیق بر مبنای LSTM

Fig. 11. Model generated using deep learning algorithms based on LSTM

استخراج نماید. این موضوع به‌ویژه در داده‌های زمین‌شناسی که ذاتاً دارای رفتار غیرخطی، ناهمگونی فضایی و عدم قطعیت بالا هستند، از اهمیت ویژه‌ای برخوردار است. برخلاف روش‌های متداول یادگیری ماشین که عمدتاً بر فرض استقلال متغیرها یا روابط ساده استوارند، مدل پیشنهادی توانسته است وابستگی‌های پیچیده میان لایه‌هایی مانند دگرسانی، ژئوشیمی، ساختارهای

بحث

نتایج حاصل از این پژوهش نشان می‌دهد که به‌کارگیری رویکرد یادگیری عمیق بدون نظارت مبتنی بر شبکه حافظه کوتاه مدت توانسته است الگوهای پنهان و روابط پیچیده میان لایه‌های مختلف اکتشافی را با دقت قابل قبولی


به منظور راستی آزمایی نتایج حاصل از مدل یادگیری عمیق بدون نظارت مبتنی بر شبکه حافظه کوتاه مدت، یک برنامه اعتبارسنجی میدانی هدفمند در دو ناحیه امیدبخش معرفی شده توسط مدل واقع در برگه یکصد هزار کجان، شامل مناطق هاشم آباد و کوه لخت اجرا گردید. انتخاب این نواحی بر اساس امتیاز پتانسیل یابی بالای مدل و همخوانی آن‌ها با الگوهای پیش‌بینی شده از همجواری گسل‌ها، توده‌های نفوذی و پهنه‌های دگرسانی صورت پذیرفت.

بازدید صحرایی از منطقه هاشم آباد (جنوب‌خاوری برگه یکصد هزار کجان) وجود یک سامانه اسکارن را تایید نمود. برونزدهای مشاهده شده شامل اسکارن همراه با کانه‌زایی قابل توجه مس و آهن به شکل مالاکیت و مگنتیت است (شکل ۱۲- b و c). کانه‌زایی به صورت توده‌ای و رگه-رگچه‌ای در محل تماس توده نفوذی گرانیتوئیدی با سنگ‌های کربناته با سن کرتاسه رخ داده است. دگرسانی گرمابی پروپلیتیک به وضوح قابل مشاهده است. این الگو با پیش‌بینی مدل مبنی بر تأثیر همزمان توده نفوذی، ساختارهای گسلی و پهنه دگرسانی در تمرکز ناهنجاری‌ها، انطباق کامل دارد.

در ناحیه کوه لخت (جنوب‌باختری)، اعتبارسنجی میدانی وجود یک سامانه گرمابی با کانه‌زایی شاخص طلا را آشکار ساخت (Hafezi et al., 2024). از دیدگاه زمین‌شناسی، سنگ‌های منطقه شامل دو دسته اصلی هستند: دسته آتشفشانی متشکل از آندزیت پورفیری، داسیت پورفیری، ریوداسیت، رپولیت و دیاباز، و دسته نفوذی شامل گرانودیوریت، دیوریت و میکرومونزودیوریت. این سنگ‌ها بیشتر تحت تأثیر سیالات گرمابی گسترده قرار گرفته‌اند. سیالات گرمابی پهنه‌ای به وسعت ۲٫۵ کیلومتر مربع را تحت تأثیر قرار داده و دگرسانی‌های فیلیک، آرژیلیک، آرژیلیک پیشرفته، پروپلیتیک و سیلیسی با شدت‌های متفاوت ایجاد کرده‌اند. دگرسانی سیلیسی به شکل رگه‌های سیلیسی-برشی، زون‌های برشی و توده‌های سیلیسی ظاهر شده است. دگرسانی‌های گسترده در امتداد پهنه‌های گسلی با راستای شمال‌باختر-جنوب‌خاور توسعه یافته که نقش اصلی این ساختارها را به عنوان مجرای عبور سیالات گرمابی تایید می‌کند. از نظر کانه‌زایی، ساختارهای رگه-رگچه‌ای حاوی کوارتز و سولفید در یک زمینه سیلیسی مشاهده شده است. رگه‌های سیلیسی-برشی به دو گروه تقسیم می‌شوند (Hafezi et al., 2024): گروه اول همراه با مالاکیت، باریت، آلونیت و اکسیدهای آهن و گروه دوم مشخص شده با اکسیدهای آهن و آلونیت. کانه‌زایی طلا عمدتاً با گروه اول این رگه‌ها مرتبط است و این کانه‌زایی بدون ارتباط مستقیم با توده نفوذی آشکار، با پیش‌بینی مدل LSTM در مورد اهمیت لایه ساختارهای گسلی در تمرکز ناهنجاری در این منطقه، همخوانی بسیار خوبی نشان می‌دهد (شکل ۱۲- c، d و e).

گسلی و توده‌های نفوذی را به صورت همزمان مدل‌سازی کند. این قابلیت منجر به تفکیک دقیق‌تر نواحی امیدبخش معدنی شده است. یکی از نکات قابل توجه در نتایج، همخوانی مناسب نواحی با پتانسیل بالا با شواهد زمین‌شناسی شناخته شده در برگه یکصد هزار کجان است. تمرکز ناهنجاری‌ها در مجاورت گسل‌ها و توده‌های نفوذی، و همچنین انطباق آن‌ها با پهنه‌های دگرسانی، نشان‌دهنده عملکرد مناسب مدل در بازنمایی فرآیندهای کانه‌زایی است. این موضوع بیانگر آن است که مدل شبکه حافظه کوتاه مدت نه تنها یک ابزار آماری، بلکه یک چارچوب تحلیلی مؤثر برای درک روابط زمین‌شناسی نیز محسوب می‌شود. چنین نتایجی با مطالعات پیشین که نقش ساختارها و دگرسانی‌ها را در کنترل کانه‌زایی تأیید کرده‌اند، همخوانی دارد. در مقایسه با روش‌های کلاسیک مانند جنگل تصادفی، SVM و K-mean، مدل پیشنهادی از چند جهت برتری نشان می‌دهد. اولاً، عدم نیاز به داده‌های برچسب‌خورده یکی از مزیت‌های کلیدی این روش است، زیرا در بسیاری از مناطق اکتشافی، داده‌های آموزشی معتبر محدود یا در دسترس نیستند. ثانیاً، ساختار بازگشتی LSTM امکان مدل‌سازی وابستگی‌های دنباله‌دار و تعاملات چندلایه‌ای را فراهم می‌سازد که در روش‌های سنتی کمتر مورد توجه قرار گرفته است. این ویژگی به‌ویژه در داده‌های مکانی که دارای نوعی پیوستگی ضمنی هستند، اهمیت پیدا می‌کند. با این حال، باید توجه داشت که استفاده از LSTM برای داده‌های فضایی، مستلزم تعریف مناسب ساختار ورودی و ترتیب‌دهی داده‌ها است، که می‌تواند بر نتایج نهایی تأثیرگذار باشد. با وجود مزایای قابل توجه، مدل پیشنهادی دارای محدودیت‌هایی نیز هست. از جمله این محدودیت‌ها می‌توان به حساسیت مدل به پارامترهای تنظیمی، نیاز به حجم مناسب داده برای آموزش مؤثر، و پیچیدگی محاسباتی بالا اشاره کرد. علاوه بر این، تفسیرپذیری مدل‌های یادگیری عمیق همچنان یکی از چالش‌های اساسی در کاربردهای علوم زمین است، زیرا تعیین دقیق نقش هر یک از لایه‌های ورودی در خروجی نهایی به‌سادگی امکان‌پذیر نیست. این موضوع می‌تواند در فرآیند تصمیم‌گیری اکتشافی، به‌ویژه برای کارشناسانی که به دنبال شفافیت مدل هستند، محدودیت ایجاد کند. در نهایت، نتایج این پژوهش نشان می‌دهد که ترکیب رویکردهای یادگیری عمیق بدون نظارت با داده‌های چندمنبعی زمین‌شناسی می‌تواند به‌عنوان یک ابزار قدرتمند در مدل‌سازی پتانسیل معدنی مورد استفاده قرار گیرد. پیشنهاد می‌شود در مطالعات آینده، از ترکیب این مدل با روش‌های تفسیرپذیر و همچنین ادغام داده‌های ژئوفیزیکی و داده‌های با قدرت تفکیک بالاتر استفاده شود تا دقت و قابلیت اعتماد مدل افزایش یابد.

اعتبارسنجی میدانی



شکل ۱۲- تصاویر صحرایی از مناطق هاشم‌آباد و کوه‌لخت، (a) کانه‌زایی مس-آهن، در مرز بین توده گرانودیوریت و سنگ‌های کربناته، همراه با تشکیل اسکارن. (b) حضور مگنتیت و هماتیت همراه با کلریت در درون سنگ‌های کربناته کرتاسه، (c) تزریق توده گرانودیوریت در میان سنگ‌های آتشفشانی در منطقه کوه‌لخت، (d) برش‌های سیلیسی در سنگ‌های آتشفشانی در کوه لخت و (e) آغشتگی اکسید آهن (گوئیت و لیمونیت) به همراه مالاکیت و ژپس در پهنه گوسان در منطقه کوه‌لخت

Fig. 12. Field photographs from the Hashemabad and Kuh-e Lakht areas. a) Cu-Fe mineralization at the contact between the granodiorite intrusion and carbonate rocks, associated with skarn formation. b) Occurrence of magnetite and hematite along with chlorite within Cretaceous carbonate rocks. c) Injection of granodiorite intrusion into volcanic rocks in the Kuh-e Lakht area. d) Silica breccia within volcanic in Kuh-e Lakht. e) Iron oxide impregnation (goethite, limonite) accompanied by malachite and gypsum in the gossan (iron cap) zone, Kuh-e Lakht area

این پژوهش نشان داد که به‌کارگیری یک رویکرد یادگیری عمیق بدون نظارت مبتنی بر LSTM می‌تواند به‌طور مؤثری در مدل‌سازی پتانسیل معدنی و شناسایی نواحی امیدبخش کانه‌زایی مورد استفاده قرار گیرد. مدل پیشنهادی با بهره‌گیری از قابلیت یادگیری روابط غیرخطی و استخراج الگوهای پنهان از داده‌های چندمنبعی زمین‌شناسی، توانست بدون نیاز به داده‌های برجسب‌خورده، ساختارهای معنادار و ناهنجاری‌های مرتبط با کانه‌زایی را شناسایی کند. این ویژگی، به‌ویژه در شرایطی که داده‌های آموزشی محدود یا نامطمئن هستند، یک مزیت کلیدی محسوب می‌شود. ادغام لایه‌های دگرسانی، ژئوشیمی، گسل‌ها و توده‌های نفوذی در قالب یک چارچوب یادگیری عمیق، منجر به تولید نقشه‌هایی شد که از نظر زمین‌شناسی با الگوهای شناخته‌شده کانه‌زایی سازگار هستند. این همخوانی نشان‌دهنده توانایی مدل در بازنمایی

نتایج اعتبارسنجی میدانی نشان می‌دهد که تفکیک دو نوع کانه‌زایی متفاوت اسکارن (هاشم‌آباد) و گرمابی (کوه لخت) توسط مدل پیشنهادی، با خطای موقعیت مکانی کمتر از ۳۰۰ متر نسبت به نقاط اکتشافی پیشین، انجام شده است. این امر گویای آن است که مبتنی بر شبکه حافظه کوتاه مدت توانسته است الگوهای متمایز امضای کانه‌زایی (مانند همراهی با توده نفوذی در اسکارن در مقابل کنترل گسلی محض در گرمابی) را از روی روابط پیچیده میان لایه‌های ورودی، بدون آموزش نظارت شده، بازشناسی نماید. شناسایی این دو نوع کانه‌زایی، موفقیت رویکرد یادگیری عمیق بدون نظارت را در شناسایی پهنه‌های امیدبخش جدید و متنوع تایید می‌کند.

نتیجه‌گیری

نتایج این تحقیق نشان می‌دهد که رویکردهای هیبریدی مبتنی بر یادگیری عمیق، به‌ویژه در قالب مدل‌های بدون نظارت، می‌توانند به‌عنوان ابزارهایی کارآمد و نوین در اکتشافات معدنی مطرح شوند و نقش مهمی در بهبود دقت، کاهش ریسک و بهینه‌سازی فرآیند تصمیم‌گیری ایفا نمایند.

قدردانی

نویسندگان مراتب سپاس و قدردانی خود را از همراهی آقای دکتر علی قاسمی در بازدیدهای میدانی جهت بررسی مناطق دارای ناهنجاری حاصل از مدل‌سازی الگوریتمی ابراز می‌دارند.

References

- Abedi, M., Norouzi, G.H., Bahroudi, A., 2012. Support vector machine for multi-classification of mineral prospectivity areas. *Computers & Geosciences* 46, 272–283.
- Amini, B., Amini Chehragh, M., 2003. Geological quadrangle map of Kajan 1:100000, Geological Survey of Iran.
- Carranza, E.J.M., Van Ruitenbeek, F.J.A., Hecker, C., van der Meijde, M., van der Meer, F.D., 2008. Knowledge-guided data-driven evidential belief modeling of mineral prospectivity in Cabo de Gata, SE Spain. *International Journal of Applied Earth Observation and Geoinformation* 10(3), 374–387.
- Ghasemzadeh, S., Maghsoudi, A., Yousefi, M., Kreuzer, O.P., 2023. Spatially weighted singularity mapping in conjunction with random forest algorithm for mineral prospectivity modeling. *International Journal of Mining and Geo-Engineering* 57, 455–462.
- Ghezelbash, R., Maghsoudi, A., Carranza, E.J.M., 2020. Optimization of geochemical anomaly detection using a novel genetic K-means clustering (GKMC) algorithm. *Computers & Geosciences* 134, 104335.
- Ghoraeian, F., Nozaem, R., Rezaei, S., Rajabi, A., Taghavi, A., 2024. Evaluation of spatial correlation of alteration with fault zones using remote sensing methods, case study of Indes-Tafarsh and Talkhab fault zones in Markazi Province. *Kharazmi Journal of Earth Sciences*, 10(2), 557–587. doi: 10.22034/KJES.2024.10.2.102102 (in Persian)
- Hafezi, A., Haroni, H.A., Tabatabaei, S.H., Esmaeiloghli, S., 2024. Adopting a cell-based method to identify mineralized geological structures in support of mineral prospectivity mapping at the Kuh-Lakht epithermal gold deposit, Central Iran. *Ore Geology Reviews* 171, 106175.
- Hajaj, S., El Harti, A., Jellouli, A., Pour, A.B., Himyari, S.M., Hamzaoui, A., Hashim, M., 2024. ASTER data processing and fusion for alteration minerals and silicification detection: Implications for cupriferous mineralization exploration in the western Anti-Atlas, Morocco. *Artificial Intelligence in Geosciences* 5, p.100077.
- Hajihosseinalou, M., Maghsoudi, A., Ghezelbash, R., 2024. Stacking: A novel data-driven ensemble machine learning strategy for prediction and mapping of Pb–Zn prospectivity in Varcheh district, west Iran. *Expert systems with applications* 237, 121668. doi: 10.1016/J.ESWA.2023.121668.
- Hochreiter, S., Schmidhuber, J., 1997. Long Short-Term Memory. *Neural Computation* 9(8), 1735–1780.
- Hoseinzade, Z., Shojaei, M., Khademi, F., Mokhtari, A.R., Saremi, M., 2025. Integration of deep learning models for mineral prospectivity mapping: a novel Bayesian index approach to reducing uncertainty in exploration. *Modeling Earth Systems and Environment* 11(3), 161.
- Jyostna, B., Meena, A., Rathod, S., Tuti, M.D., Choudhary, K., Lama, A., Kumar, A.T., Reddy, B.N.K., Bhanusree, D., Rakesh, J., Swarnaraj, A.K., 2025. Multiscale rainfall forecasting using a hybrid ensemble empirical mode decomposition and LSTM model. *Modeling Earth Systems and Environment* 11(2), 119.
- Li, H., Li, X., Yuan, F., Jowitt, S.M., Zhang, M., Zhou, J., Zhou, T., Li, X., Ge, C., Wu, B., 2020b. Convolutional neural network and transfer learning based mineral prospectivity modeling for geochemical exploration of Au mineralization within the Guandian–Zhangbaling area, Anhui Province, China. *Applied Geochemistry* 122, 104747.
- Li, Q., Chen, G., Luo, L., 2023. Mineral prospectivity mapping using attention-based convolutional neural network, *Ore Geology Reviews* 156, 105381. doi: 10.1016/J.OREGEORE.2023.105381.
- Li, S., Chen, J., Xiang, J., 2020a. Applications of deep convolutional neural networks in prospecting prediction based on two-dimensional geological big data. *Neural computing and applications* 32(7), 2037–2053.
- Li, T., Zuo, R., Xiong, Y., Peng, Y., 2021. Random-drop data augmentation of deep convolutional neural network for mineral prospectivity mapping. *Natural resources research* 30(1), 27–38.
- Meigoony, M.S., Afzal, P., Gholinejad, M., Yasrebi, A.B., Sadeghi, B., 2014. Delineation of geochemical anomalies using factor analysis and multifractal modeling based on stream sediments data in Sarajeh 1: 100,000 sheet, Central Iran. *Arabian Journal of Geosciences* 7(12), 5333–5343.
- Mirzabozorg, S.A.A.S., Abedi, M., 2023. Recognition of mineralization-related anomaly patterns through an autoencoder neural network for mineral exploration targeting. *Applied Geochemistry* 158, 105807. doi: 10.1016/j.apgeochem.2023.105807.
- Mirzabozorg, S.A.A.S., Abedi, M., Yousefi, M., 2024. Enhancing training performance of convolutional neural network algorithm through an autoencoder-based unsupervised labeling framework for mineral exploration targeting. *Geochemistry* 84(4), 126197.

- Mokhtari, M., Hoseinzade, Z., Shirani, K., 2020. A comparison study on landslide prediction through FAHP and Dempster-Shafer methods and their evaluation by P-A plots. *Environmental Earth Sciences* 79(3), Article 76. doi: 10.1007/s12665-019-8804-0.
- Pour, A.B., Hashim, M., 2012. The application of ASTER remote sensing data to porphyry copper and epithermal gold deposits. *Ore Geology Reviews* 44, 1–9.
- Rezaei Alishahdani, A., Jafari Rad, A., Alaminia, Z., Arian, M., Jamali, H., 2025. Whole-rock geochemistry of hydrothermal alterations and its relationship with gold mineralization in the Shourab prospect, Isfahan. *Kharazmi Journal of Earth Sciences*, 11(2), 289–316. doi: 10.22034/KJES.2025.11.2.103844 (in Persian)
- Rowan, L.C., Schmidt, R.G., Mars, J.C., 2006. Distribution of hydrothermally altered rocks in the Reko Diq, Pakistan mineralized area based on spectral analysis of ASTER data. *Remote Sensing of Environment* 104(1), 74–87.
- Saremi, M., Bagheri, M., Agha Seyyed Mirzabozorg, S.A., Hassan, N.E., Hoseinzade, Z., Maghsoudi, A., Rezaia, S., Ranjbar, H., Zoheir, B., Beiranvand Pour, A., 2024b. Evaluation of deep isolation forest (DIF) algorithm for mineral prospectivity mapping of polymetallic deposits. *Minerals* 14(10), 1015.
- Saremi, M., Hoseinzade, Z., Mirzabozorg, S.A.A.S., Pour, A.B., Zoheir, B., Almasi, A., 2024a. Integrated remote sensing and geochemical studies for enhanced prospectivity mapping of porphyry copper deposits: A case study from the Pariz district, Urmia–Dokhtar metallogenic belt, southern Iran. *Remote Sensing Applications: Society and Environment* 36, 101343.
- Saremi, M., Maghsoudi, A., Hoseinzade, Z., Mokhtari, A.R., 2024c. Data-driven AHP: a novel method for porphyry copper prospectivity mapping in the Varzaghan District, NW Iran. *Earth Science Informatics* 17(6), 5063–5078.
- Sherstinsky, A., 2020. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica d: Nonlinear phenomena* 404, 132306.
- Wang, H., Cai, G., Cheng, Q., 2002. Data integration using weights of evidence model: applications in mapping mineral resource potentials. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 34(4), 48–53.
- Yousefi, M., Carranza, E.J.M., 2015. Prediction–area (P–A) plot and C–A fractal analysis to classify and evaluate evidential maps for mineral prospectivity modeling. *Computers & Geosciences* 79, 69–81.
- Yousefi, M., Hronsky, J.M., 2023. Translation of the function of hydrothermal mineralization–related focused fluid flux into a mappable exploration criterion for mineral exploration targeting. *Applied Geochemistry* 149, 105561.
- Yousefi, M., Nykänen, V., 2016. Data-driven logistic-based weighting of geochemical and geological evidence layers in mineral prospectivity mapping. *Journal of Geochemical Exploration* 164, 94–106.
- Zhang, S., Carranza, E.J.M., Xiao, K., Chen, Z., Li, N., Wei, H., Xiang, J., Sun, L., Xu, Y., 2021. Geochemically Constrained Prospectivity Mapping Aided by Unsupervised Cluster Analysis: Natural Resources Research 30(3), 1955–1975.
- Zhang, S., Carranza, E.J.M., Xiao, K., Wei, H., Yang, F., Chen, Z., Li, N., Xiang, J., 2022. Mineral prospectivity mapping based on isolation forest and random forest: Implication for the existence of spatial signature of mineralization in outliers. *Natural Resources Research* 31(4), 1981–1999.