

Original Research Paper

Enhancing lithological mapping using pixel- and object-based machine learning on Sentinel-2 and PRISMA Data: A case study from the Remeshk-Mokhtarabad ophiolite complex

Fatemeh Hajimohammadi^{1,2}, Mohsen Arvin^{*1}, and Sara Dargahi¹¹ Department of Geology, College of Sciences, Shahid Bahonar University of Kerman, Kerman, Iran² Geological Survey of Iran, Tehran, Iran

ARTICLE INFO

Article history:

Received: 2025 October 07

Accepted: 2025 December 28

Available online: 2026 March 21

Keywords:

Lithological mapping

Machine learning

Object-based and Pixel-based analysis

PRISMA

Sentinel-2

Remeshk-Mokhtarabad ophiolitic complex

Makran

ABSTRACT

Machine learning algorithms and lithological interpretation based on remote sensing play a crucial role in regional geological studies; however, expert interpretation by experienced geologists remains irreplaceable. This study employs multispectral Sentinel-2 and hyperspectral PRISMA satellite data to evaluate lithological mapping of the Remeshk–Mokhtarabad ophiolitic complex located in the northern Makran, southeastern Iran. The research focuses on integrating remote sensing technologies with machine learning algorithms to enhance geological mapping accuracy and to support field-based investigations. Selection of optimal input features for classifiers is considered a key objective of this study. To this end, various image enhancement techniques, including spectral analysis, band combinations and ratios, principal component analysis, color ratio composites, and minimum noise fraction transformation, were applied. Subsequently, machine learning algorithms, specifically neural networks, support vector machines, and k-nearest neighbors were applied for classification. Accuracy assessment based on overall accuracy and the kappa coefficient indicates that the object-based approach applied to multispectral Sentinel-2 imagery produces more homogeneous maps with higher accuracy, whereas the pixel-based approach yields better performance for hyperspectral PRISMA data. The results demonstrate that the combined use of Sentinel-2 and PRISMA data provides a powerful tool for lithological mapping in ophiolitic complexes.

1. Introduction

Geological maps at various scales provide a two-dimensional representation of the distribution of different lithological units and their structural components within a defined geographic area. In recent decades, advances in the acquisition and processing of hyperspectral and multispectral satellite data have significantly improved the ability to accurately identify geological features and


mineral compositions. Machine learning algorithms, employed for pattern recognition and classification of data into lithological units, offer improved speed and accuracy compared to traditional methods (Gad and Kusky, 2007; Ge et al., 2018b; Rajan Girija and Mayappan, 2019; Shayeganpour et al., 2021; El-Omairi and El Garouani, 2023; Ghoneim et al., 2024). Techniques such as spectral

* Corresponding author: Mohsen Arvin; E-mail: arvin@uk.ac.ir

Citation:

Hajimohammadi, F., Arvin, M., and Dargahi, S., 2026. Enhancing lithological mapping using pixel- and object-based machine learning on Sentinel-2 and PRISMA Data: A case study from the Remeshk-Mokhtarabad ophiolite complex. *Scientific Quarterly Journal of Geosciences*, 36(1), 139, 79-96. <https://doi.org/10.22071/gsj.2025.551653.2227>.

E-ISSN: 2645-4963; Copyright©2021 G.S. Journal & the authors. All rights reserved.

 doi: 10.22071/gsj.2025.551653.2227 dor: 20.1001.1.10237429.1405.36.1.5.3This is an open access article under the by-nc/4.0/ License (<https://creativecommons.org/licenses/by-nc/4.0/>)

analysis, band ratio, and principal component analysis are applied to extract spectral features and reduce data dimensionality. PRISMA satellite data, with their broader spectral coverage and higher signal-to-noise ratio, are more effective for precise lithological mapping than Sentinel-2 data (Chen et al., 2007; Harris et al., 2010; Leverington, 2010; Li et al., 2014; Shebl et al., 2023). Therefore, a primary objective of this study is to evaluate the potential of PRISMA satellite data for mapping ophiolitic lithologies.

In recent years, object-based classification has gained prominence, providing more accurate results with high-resolution satellite imagery (Shayeganpour et al., 2021; Ouchra et al., 2022). This approach is well-suited for medium- to high-resolution satellite data and serves as an effective alternative to pixel-based methods (Baatz, 2000; Benz et al., 2004). In this study, we evaluate pixel-based and object-based classification methods, integrated with machine learning algorithms (neural networks (NN), support vector machines (SVM), and k-nearest neighbors (kNN), for mapping the Remeshk-Mokhtarabad ophiolitic complex in northern Makran, southeastern Iran.

It is evident that artificial intelligence models serve as powerful tools for geologists; however, expert interpretation by experienced geologists remains irreplaceable. Within this framework, validation of the results should be conducted in two stages, including model-based evaluation using artificial intelligence methods and subsequent review by a geologist. This step is of critical importance, as the inherent complexity of geological phenomena may lead to errors or ambiguities in the interpretation of complex structures by the models. Ultimately, the integration of the computational capabilities of artificial intelligence models with the domain expertise of geologists facilitates the production of more accurate and reliable lithological maps.

The Remeshk–Mokhtarabad ophiolitic complex in the northern Makran, SE Iran, comprises the plutonic Remeshk Complex overlain by volcanic–sedimentary units of the Mokhtarabad Complex. The ophiolitic succession includes ultramafic rocks, gabbro, plagiogranite, a sheeted dyke complex, pillow lavas, pelagic limestone, radiolarian chert, and the Deyader metamorphic complex (McCall, 1985; Hunziker, 2014; Moslempour et al., 2015), (Fig. 1). Regionally, the northern Makran is separated from the inner Makran by the Bashakerd thrust (Burg et al., 2012). The Makran Basin consists of two major geological domains: (1) pre–middle Paleocene to Paleogene units, restricted to the northern side of the Bashakerd fault, and (2) Neogene–Quaternary deposits (McCall, 1985, 2003).

2. Research methodology

In this study, multispectral datasets from Sentinel-2 and hyperspectral datasets from PRISMA satellites were utilized. Image preprocessing and processing were conducted using ENVI 5.6, ArcGIS 10.8.2, Geomatica 2020, and eCognition 9.01 software packages. The workflow diagram (Fig. 2) illustrates the comprehensive methodological framework employed in this research. Detailed descriptions of each step, including the datasets used, methodologies, preprocessing procedures, algorithms, and software, are presented separately and comprehensively in the following sections of the article.

2.1. Data and data preprocessing

The Sentinel-2 Level-2A and PRISMA Level-2D datasets were

preprocessed using ENVI 5.6. Preprocessing steps included geometric co-registration and radiometric normalization. In the next step, to spatially harmonize the Sentinel-2 data, the 20-m bands were resampled to 10-m resolution using the nearest-neighbor method. This approach minimizes changes in reflectance values by avoiding any spatial averaging or spectral interpolation. Consequently, the spectral analysis for mineral mapping remains based on the original spectral information, without applying any spectral normalization that could modify diagnostic absorption features. The resampling was performed solely during the data-preparation stage for machine-learning algorithms, ensuring consistent spatial dimensions among model inputs for lithological classification. Spectral regions affected by atmospheric water absorption and sensor-induced striping in PRISMA data were excluded. The MNF transformation was applied to reduce noise and correct smile effects.

3. Results

3.1. Data processing and feature extraction

Accurate extraction of input features is essential for reliable classification (Pal and Foody, 2010). This study emphasized the selection of representative training and testing datasets and optimizing input variables for the chosen classification algorithms. To achieve this, a suite of image processing techniques was applied to Sentinel-2 and PRISMA datasets to enhance lithological discrimination and provide robust inputs for classification. The primary objective was to delineate the search area, thereby reducing the cost and time required for field surveys (Rajan Girija and Mayappan, 2019).

A comprehensive set of methods, including spectral analysis of rocks and minerals, Decorrelation Stretch (DS), Principal Component Analysis (PCA), Minimum Noise Fraction (MNF) Transform, Band Combinations (BC), Color Ratio Composites (CRC), and Band Ratios (BR), was implemented. The outputs were utilized both visually, through RGB composites, and quantitatively as inputs for classification algorithms (Figs. 4–6). For spectral analysis, electromagnetic signatures of lithological units and rock-forming minerals in the study area were extracted from calibrated Sentinel-2 and PRISMA data and cross-referenced with established spectral libraries (e.g., JHU) (Fig. 3). These absorption and reflectance spectral features were then incorporated into the classification framework. The DS technique was applied to selected Sentinel-2 bands (RGB: 12, 3, 2) to enhance contrast and minimize inter-band correlation, thereby improving visual discrimination (Fig. 4). PCA was employed to reduce dimensionality and mitigate radiometric redundancy. For Sentinel-2 data, the first three principal components (PC1, PC2, and PC3) accounted for over 95% of the variance, while for PRISMA data, they explained more than 90% of the variance (Fig. 6). These components provided superior lithological discrimination compared to the original bands. False Color Composites (FCC) derived from both datasets effectively delineated lithological boundaries (Figs. 4 and 5). The BR and CRC techniques were particularly effective in enhancing spectral contrasts among basalt, gabbro, and meta-basalt by minimizing topographic and illumination effects. Additionally, the MNF transform was applied to both Sentinel-2 and PRISMA datasets to reduce noise and correct for the smile effect, thereby enhancing spectral information relevant to geological mapping (Boardman et al., 1995).

3.2. Training and testing data selection

Geological maps at 1:100,000 and 1:250,000 scales were used as reference sources for selecting the training and testing datasets. Due to the lithological complexity of the ophiolitic assemblage, representative samples were selected using the remote-sensing techniques described in Section 4, together with geological maps, previous studies (Hunziker, 2014; Hunziker et al., 2015; Saccani et al., 2022, 2023; Hajimohammadi et al., 2025), and field observations of key units. Sentinel-2 and PRISMA datasets, with their differing spatial resolutions and spectral coverage, provided complementary data for analysis. Endmember spectra were extracted to validate regions of interest (ROI). The dataset was divided into 80% training and 20% testing subsets, which served as inputs for SVM, NN, and kNN classification algorithms.

3.3. Classification results

This study evaluates the performance of SVM, NN, and kNN for lithological mapping of the Remeshk-Mokhtarabad ophiolite complex using Sentinel-2 and PRISMA imagery. Both pixel-based image analysis (PBIA) and object-based image analysis (OBIA) approaches were implemented using ENVI 5.6 and eCognition 9.01. Classification accuracy depends significantly on data quality, quantity, and algorithm suitability.

In PBIA, individual pixels were classified based on their spectral similarity to reference lithological units. NN and SVM were applied with optimized parameters, using representative training samples and spectral features. In OBIA, images were segmented into homogeneous objects based on spectral, spatial, and textural features, followed by classification using SVM and kNN ($k=5$). This approach enhanced the contextual recognition of subtle lithological variations.

The NN algorithm employs input, hidden, and output layers, with node weights iteratively adjusted to optimize performance. SVM separates classes by constructing a hyperplane that maximizes the margin between classes, effectively handling complex and noisy multispectral and hyperspectral data. kNN assigns class labels based on the proximity of test samples to training samples in feature space. The integrated PBIA and OBIA framework, utilizing NN, SVM, and kNN, demonstrated robust lithological discrimination. These findings highlight the critical role of algorithm selection, parameter optimization, and the combined use of pixel- and object-based approaches in achieving accurate lithological mapping in complex ophiolite terrains. The results of applying machine-learning algorithms reveal a clear difference in their ability to discriminate lithological units within the ophiolitic complex (Fig. 7).

4. Discussion

Three machine learning algorithms SVM, NN, and kNN were implemented using PBIA and OBIA to identify major lithological units, including basalt, meta-basalt, blueschist, gabbro, peridotite, and sedimentary rocks. The classified images of the Remeshk-Mokhtarabad ophiolitic complex were evaluated to ensure the reliability of the results. Random sampling of testing data was first performed across different lithological units, and the outcomes were compared with geological maps and field observations. Accuracy assessment, including overall accuracy, the Kappa coefficient, and

the F1-score, was conducted for both classification approaches using confusion matrices ((Congalton, 1991); see Tables 1–3, Figs. 9 and 10). Additionally, the agreement between PBIA and OBIA classification results was analyzed to evaluate the lithological validity of each classifier output.

OBIA outperformed PBIA, yielding clearer lithological boundaries and higher accuracy due to its integration of spectral, textural, and spatial features. SVM with OBIA achieved the highest performance (overall accuracy: 90.99%, kappa: 0.90), followed by kNN (overall accuracy: 89.47%, kappa: 0.8863). PBIA with SVM on PRISMA data also produced robust results (overall accuracy: 87.83%, kappa: 0.8682), whereas NN on Sentinel-2 performed poorly (overall accuracy: ~47%, kappa: 0.43), likely due to its simplistic architecture. The F1-score, which balances precision and recall, indicated consistent performance in OBIA models but variable performance in PBIA models, particularly with imbalanced datasets.

Producer's accuracy (equivalent to recall) demonstrated that OBIA models (SVM and kNN) excelled in identifying lithological units such as limestone, plagiogranite, and Quaternary sediments (approaching 100%), while PBIA struggled with complex units like layered gabbro and meta-basalt. Spectral similarities and differences in data resolution, particularly between PRISMA and Sentinel-2, contributed to classification errors. OBIA's incorporation of textural and geometric features proved superior for distinguishing spectrally similar lithological units, highlighting the importance of careful parameter tuning and training data selection in PBIA models.

The integration of Sentinel-2 multispectral and PRISMA hyperspectral data, in combination with band ratios (BR) and principal component analysis (PCA), enabled effective mapping of ophiolitic lithologies and vegetation. While Sentinel-2 provided superior spatial resolution and facilitated vegetation delineation, it struggled to discriminate spectrally similar rock units. In contrast, the high spectral resolution of PRISMA improved mineral differentiation. Object-based image analysis (OBIA), through the incorporation of spatial and textural information, further enhanced classification accuracy, outperforming traditional pixel-based approaches.

5. Conclusion

Lithological mapping of the Remeshk-Mokhtarabad ophiolite complex using Sentinel-2 and PRISMA datasets with SVM, NN, and kNN algorithms demonstrated distinct performance outcomes. PBIA with SVM, excelled with PRISMA hyperspectral data, while OBIA with SVM and kNN, outperformed in distinguishing complex lithological units using Sentinel-2 multispectral data. The CRC technique enhanced the differentiation of intricate rock units. Sentinel-2 and PRISMA datasets complemented each other, with PRISMA providing superior spectral resolution for mineral discrimination and Sentinel-2 offering enhanced spatial resolution for detailed mapping of ophiolitic rocks and vegetation. Challenges such as atmospheric noise and vegetation cover may affect classification accuracy, and field spectroscopy is recommended for further validation. Field spectrometry can provide accurate spectral signatures of lithological units and serve as reference data to enhance the training of machine-learning classification algorithms.

بهبود نقشه برداری سنگ شناسی با به کارگیری الگوریتم‌های یادگیری ماشین بر پایه پیکسل و شیء بر اساس داده‌های Sentinel-2 و PRISMA: مطالعه موردی هماتیت افیولیتی رمشک-مختار آباد

فاطمه حاجی محمدی^{۱*}، محسن آروین^{۱*} و سارا درگاهی^۱^۱ گروه زمین شناسی، دانشکده علوم، دانشگاه شهید باهنر کرمان، کرمان، ایران^۲ سازمان زمین شناسی و اکتشافات معدنی کشور، تهران، ایران

چکیده

الگوریتم‌های یادگیری ماشین و تفسیر سنگ‌شناسی بر پایه سنجش از دور نقش مهمی در مطالعات زمین شناسی ناحیه‌ای بازی می‌کنند، با این حال نقش تفسیر تخصصی زمین شناس با تجربه همچنان غیر قابل جایگزین است. این پژوهش، از داده‌های چند طیفی ماهواره سنتینل-۲ و داده‌های فراطیفی ماهواره پریسما برای آزمون نقشه برداری سنگ‌شناسی هماتیت افیولیتی رمشک-مختار آباد واقع در مکران شمالی، جنوب‌خاور ایران، استفاده می‌کند و بر ترکیب فناوری‌های سنجش از دور با الگوریتم‌های یادگیری ماشین برای بهبود نقشه برداری زمین شناسی و تقویت مطالعات میدانی تمرکز دارد. انتخاب ورودی‌های بهینه برای طبقه‌بندی کننده‌ها از اهداف کلیدی این پژوهش به‌شمار می‌رود و بدین منظور از فناوری‌های بهبود تصویر شامل تحلیل طیفی، ترکیب و نسبت بانندی، تحلیل مولفه‌های اصلی، ترکیب نسبت رنگی و تبدیل حداقل کسر نوفه استفاده شد. در ادامه، الگوریتم‌های شبکه عصبی، ماشین بردار پشتیبان و نزدیک‌ترین همسایگی برای طبقه‌بندی داده‌ها به کار گرفته شدند. نتایج ارزیابی صحت کلی و ضریب کاپا نشان داد که رویکرد بر پایه شیء در تصاویر چندطیفی سنتینل-۲ نقشه‌هایی همگن‌تر و با دقت بالاتر تولید می‌کند، در حالی که رویکرد بر پایه پیکسل برای داده‌های فراطیفی پریسما عملکرد مناسب‌تری دارد. نتایج نشان می‌دهد استفاده از داده‌های سنتینل-۲ و پریسما ابزاری توانمند برای نقشه برداری سنگ‌شناسی در بهینه‌های افیولیتی فراهم می‌کند.

اطلاعات مقاله

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۴/۰۷/۱۵

تاریخ پذیرش: ۱۴۰۴/۱۰/۰۷

تاریخ انتشار: ۱۴۰۵/۰۱/۰۱

کلیدواژه‌ها:

نقشه برداری سنگ‌شناسی

یادگیری ماشین

تحلیل بر پایه شیء و بر پایه پیکسل

پریسما

سنتینل-۲

هماتیت افیولیتی رمشک-مختار آباد

مکران

۱- پیش نوشتار

Shayeganpour et al., 2021; El-Omairi and El Garouani, 2023; Ghoneim et al., 2024). از سوی دیگر، فناوری‌های سنجش از دور می‌توانند در زمانی کوتاه مقادیر زیادی از داده‌های تصاویر ماهواره‌ای چندطیفی و فراطیفی را پردازش کنند. این ویژگی ترکیب منابع داده مختلف را آسان می‌کند و در نتیجه دقت نقشه برداری سنگ‌شناسی را افزایش می‌دهد (Sun et al., 2019). تصاویر فراطیفی پریسما (PRISMA- Precursore IperSpettrale della Missione Applicativa) با رزولوشن طیفی بالا و تصاویر چند طیفی سنتینل-۲ (Sentinel 2) با رزولوشن مکانی مناسب، ابزارهای قدرتمندی برای نقشه برداری سنگ شناسی ارائه می‌دهند. ترکیب این داده‌ها

نقشه‌های زمین شناسی در مقیاس‌های گوناگون، نمایش دو بعدی از پراکنندگی‌های واحدهای سنگ شناسی مختلف و اجزای ساختاری آن‌ها را در یک منطقه جغرافیایی مشخص ارائه می‌دهند. در دهه‌های اخیر، پیشرفت در برداشت و پردازش داده‌های ماهواره‌ای فراطیفی و چندطیفی، امکان شناسایی دقیق‌تر ویژگی‌های زمین شناسی و مواد معدنی را فراهم کرده است. الگوریتم‌های یادگیری ماشین می‌توانند برای تشخیص الگوها و ویژگی‌ها در داده‌ها و طبقه‌بندی آن‌ها به واحدهای سنگ شناسی مختلف، آموزش ببینند. این روش‌ها در مقایسه با رویکردهای سنتی، سریع‌تر، کارآمدتر و دقیق‌تر هستند (Gad and Kusky, 2007; Rajan Giriya and Mayappan, 2019).

* نویسنده مسئول: محسن آروین؛ E-mail: arvin@uk.ac.ir

ماخذ نگاری:

حاجی محمدی، ف.، آروین، م. و درگاهی، س.، ۱۴۰۵، بهبود نقشه برداری سنگ‌شناسی با به کارگیری الگوریتم‌های یادگیری ماشین بر پایه پیکسل و شیء بر اساس داده‌های Sentinel-2 و PRISMA: مطالعه موردی هماتیت افیولیتی رمشک-مختار آباد. فصلنامه علمی علوم زمین، ۳۶(۱)، ۷۹-۹۶. <https://doi.org/10.22071/gsj.2025.551653.2227>

doi: 10.22071/gsj.2025.551653.2227



doi: 20.1001.1.10237429.1405.36.1.5.3

حقوق معنوی مقاله برای فصلنامه علوم زمین و نویسندگان مقاله محفوظ است.

This is an open access article under the by-nc/4.0/ License (<https://creativecommons.org/licenses/by-nc/4.0/>)

از داده‌های تصاویر سنتینل-۲ و پریسما در تفکیک سنگ شناسی افیولیتی و پوشش گیاهی برای نقشه برداری سنگ شناسی همتافت افیولیتی رمشک-مختارآباد واقع در مکران شمالی، ارزیابی و مقایسه و در نهایت پتانسیل این روش برای تهیه پیش‌نقشه زمین شناسی بررسی خواهد شد.

بدیهی است که مدل‌های هوش مصنوعی به عنوان ابزاری توانمند در اختیار زمین شناسان قرار می‌گیرند، با این حال نقش تفسیر تخصصی زمین شناس با تجربه هم‌چنان غیر قابل جایگزین است. در این چارچوب، اعتبارسنجی نتایج می‌بایست در دو مرحله، شامل ارزیابی مبتنی بر مدل‌های هوش مصنوعی و بازبینی توسط زمین شناس، انجام پذیرد. این مرحله از اهمیت بالایی برخوردار است، زیرا با توجه به پیچیدگی‌های ذاتی پدیده‌های زمین‌شناسی، امکان بروز خطا یا ابهام در تفسیر ساختارهای پیچیده توسط مدل وجود دارد. در نهایت، تلفیق توان پردازشی مدل‌ها با دانش تخصصی زمین شناس، زمینه دستیابی به نقشه‌های سنگ‌شناسی دقیق‌تر و قابل اعتمادتر را فراهم می‌سازد.

همتافت افیولیتی رمشک-مختارآباد، واقع در مکران شمالی در جنوب‌خاور ایران، از مجموعه رمشک به‌عنوان یک واحد پلوتونیک تشکیل شده است که توسط واحدهای آتشفشانی و رسوبی موسوم به مجموعه مختارآباد پوشیده می‌شود. این توالی افیولیتی شامل توده‌های اولترامافیک، گابرو، پلاژیوگرنایت، مجموعه دایک‌های ورقه‌ای، گدازه‌های بالشی، سنگ‌آهک پلاژیک و چرت رادیولاریتی، همراه با مجموعه دگرگونی دیاپر می‌باشد که در ناحیه‌ای با پوشش گیاهی پراکنده و محدود رخنمون دارد (McCall, 1985; Hunziker et al., 2015; Moslempour et al., 2015). انتخاب این منطقه به دلیل تنوع زمین‌شناسی و وجود داده‌های صحرائی برخی واحدهای سنگی برای اعتبارسنجی انجام شده است (شکل ۱). زمین‌شناسی حوضه مکران به دو بخش اصلی تقسیم می‌شود: (۱) واحدهای پیش از پالئوسن میانی تا پالئوژن و (۲) رسوبات نئوژن تا کواترنری (McCall, 1985, 2003). توالی پیش از پالئوسن میانی به بخش‌های شمالی گسل بشارگرد محدود می‌شود و شامل مکران شمالی و منطقه مورد مطالعه است. فرورفتگی جازموریان بخش شمالی حوضه مکران را تشکیل می‌دهد و مکران شمالی به‌وسیله راندگی بشارگرد از مکران داخلی جدا می‌شود (Burg et al., 2012).

۲- روش پژوهش

در پژوهش حاضر از داده‌های ماهواره‌ای سنتینل-۲ و پریسما استفاده شده است. برای پیش پردازش و پردازش تصاویر ماهواره‌ای از نرم‌افزارهای، ENVI 5.6، Geomatica 2020، ArcGIS 10.8.2 و eCognition 9.01 استفاده شده است. نمودار جریان‌ی شکل ۲ رویکرد دقیقی از روش‌های اتخاذ شده در این پژوهش را نشان می‌دهد. توضیحات تفصیلی مربوط به هر مرحله، داده‌های مورد استفاده، روش‌ها، پیش‌پردازش، الگوریتم‌ها، و نرم‌افزارهای به کار رفته، در بخش‌های بعدی مقاله به صورت جداگانه و کامل ارائه شده‌اند.

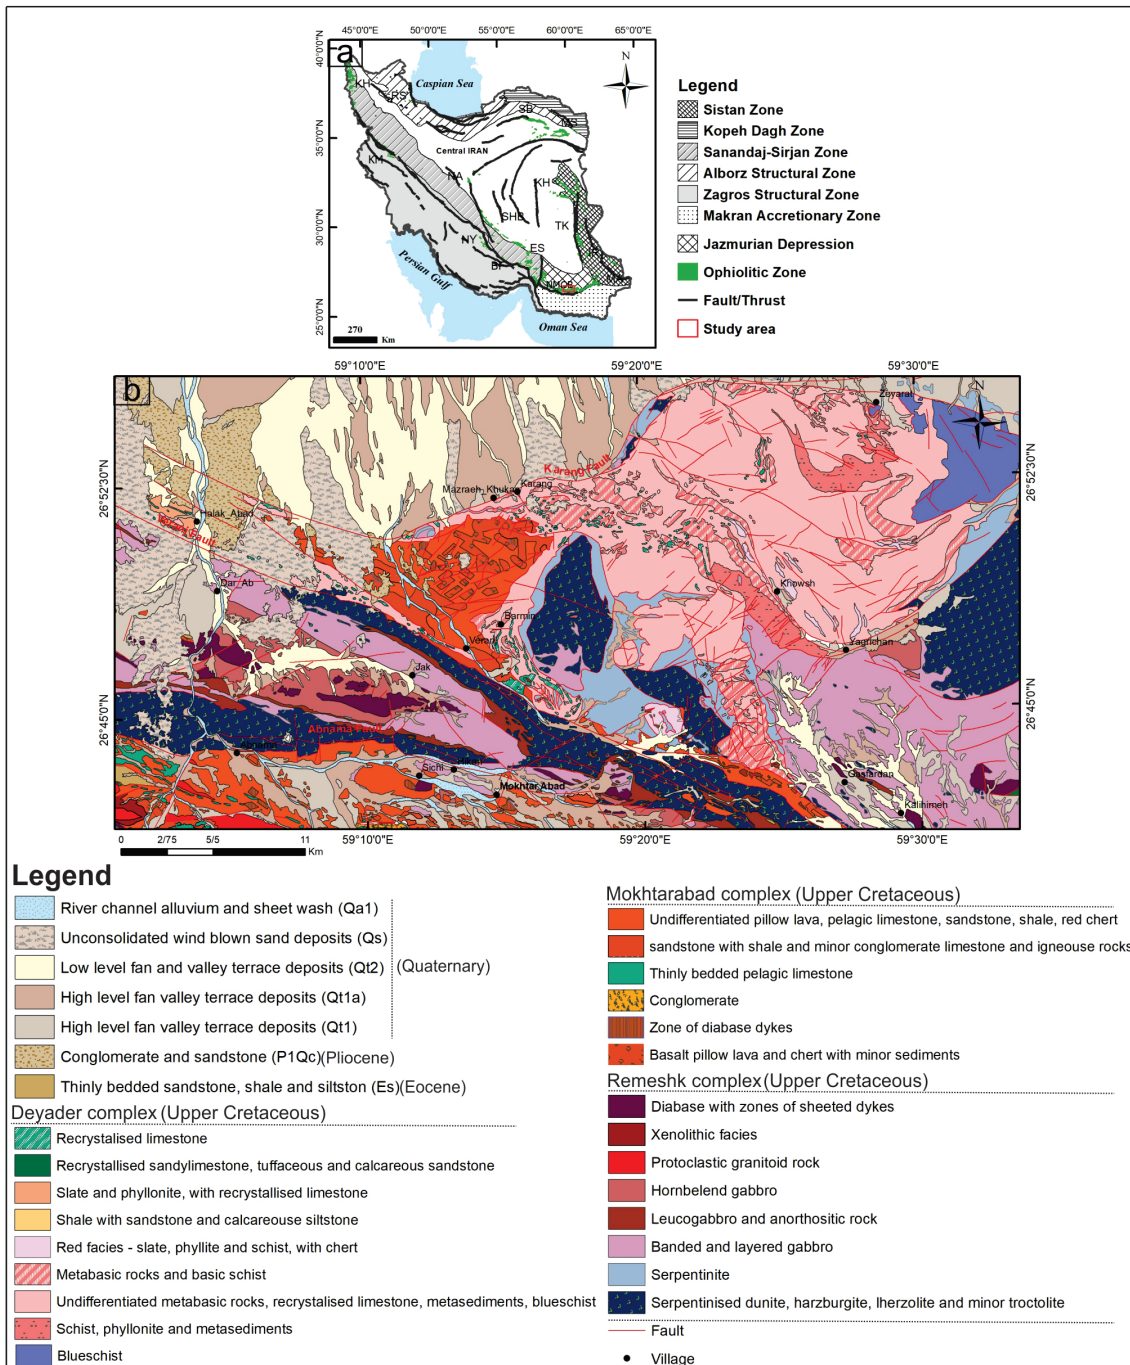
۲-۱- داده‌ها و پیش‌پردازش

در این پژوهش داده‌های ماهواره‌ای سنتینل-۲ و پریسما مربوط به منطقه رمشک-مختارآباد در تاریخ‌های مناسب دریافت و برای پردازش آماده شدند. داده‌های سطح L2A (تصحیح‌شده اتمسفری) از ماهواره سنتینل-۲ مربوط به تاریخ ۲۰۱۷ از سامانه Copernicus Open Access Hub، دریافت شد. سنتینل-۲ دارای ۱۳ باند طیفی است که از محدوده مرئی (VNIR) تا فرورسرخ موج کوتاه (SWIR) را پوشش می‌دهد (۴۴۳ تا ۲۱۹۰ نانومتر). باندهای کلیدی برای این کار باندهای بازولوشن ۱۰ متر (۲، ۳، ۴، ۸) و ۲۰ متر (۱۱، ۱۲) هستند (Drusch et al., 2012). باندهای مورد استفاده شامل باندهای مرئی (۲، ۳، ۴)، فرورسرخ نزدیک (۸) و فرورسرخ موج کوتاه (۱۱، ۱۲) بازولوشن ۱۰ و ۲۰ متر بودند.

می‌تواند دقت شناسایی واحدهای سنگی را در مقیاس ناحیه‌ای بهبود بخشد. هم‌چنین، استفاده از فناوری‌هایی از جمله تحلیل طیفی (Multispectral and Hyperspectral Analysis)، ترکیب بانندی (Band Composite-BC)، نسبت بانندی (Band Ratios-BC)، تحلیل مولفه‌های اصلی (Principal Component Analysis-PCA)، ترکیب نسبت رنگی (Color Ratio Composite-CRC) و تبدیل کمینه کسر نوفه (BR Minimum Noise Fraction-MNF)، به عنوان روش‌های موثر برای استخراج ویژگی‌های طیفی و کاهش ابعاد داده‌ها شناخته شده‌اند. در نقشه برداری سنگ‌شناسی شناسایی واحدهای سنگی از طریق تطبیق ویژگی‌های جذب طیفی مرجع یک یا چند کانی اصلی سازنده سنگ، یا با مقایسه پاسخ طیفی کامل سنگ، با طیف هدف ناشناخته و با استفاده از کتابخانه‌های طیفی و تطبیق طیفی صورت می‌پذیرد (Clark et al., 2003).

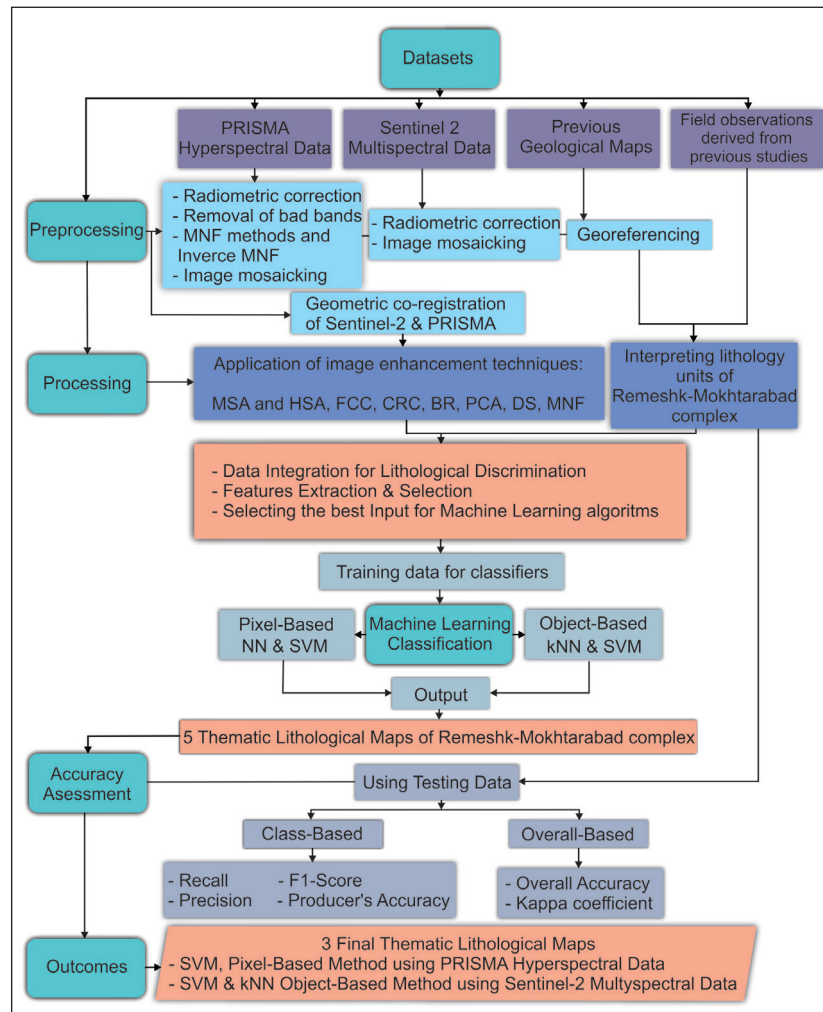
تاکنون از به کارگیری داده‌های چند طیفی سنتینل-۲ در نقشه برداری سنگ‌شناسی، نتایج معقولی حاصل شده است. با این حال، این حسگرهای چند طیفی به دلیل تعداد محدود باند، به ویژه در محدوده فرورسرخ موج کوتاه (Short-Wave Infrared-SWIR)، به طور مشخص قادر به نشان دادن تغییرات گسترده در ترکیبات کانی‌شناسی نیستند. سنسجش از دور فراطیفی با پوشش طیفی پیوسته خود در محدوده طول موج ۰/۴ تا ۲/۵ میکرومتر، به عنوان ابزاری کارآمد برای تهیه نقشه‌های دقیق کانی‌شناسی و سنگ شناسی در نظر گرفته می‌شود (Chen et al., 2007; Harris et al., 2023). منطقی به نظر می‌رسد که داده‌های پریسما با فراوانی باندها و بهبود رادیانس (Acquire radiance within VNIR and SWIR spectrum ranges besides Short-Wave Infrared-SWIR) و همچنین داشتن میزان سیگنال به نوفه (Signal-to-Noise Ratio-SNR) بالا بتوانند برای نقشه برداری دقیق سنگ‌شناسی، مناسب‌تر از داده‌های چند طیفی سنتینل-۲ عمل کنند. در نتیجه، یکی از اهداف پژوهش حاضر بررسی پتانسیل داده ماهواره‌ای پریسما برای نقشه برداری سنگ‌شناسی افیولیتی است.

در مطالعات سنسجش از دور برای تفکیک پدیده‌های موضوعی و استخراج دقیق‌تر اطلاعات از تصاویر ماهواره‌ای روش‌های طبقه‌بندی متفاوتی وجود دارد که با توجه به نوع روش مورد استفاده، نتایج متفاوتی حاصل می‌شود (Mather and Tso, 2016). روش بر پایه پیکسل (Pixel-Based Image Analysis PBIA)، که بر اساس پیکسل‌ها طبقه‌بندی می‌شود، به دلیل سهولت اجرا، متداول‌ترین روش برای تهیه نقشه‌های زمین‌شناسی است (Whiteside et al., 2011). در مقابل، روش‌های طبقه‌بندی بر پایه شیء (Object-Based Image Analysis-OBIA) که مجموعه‌ای از پیکسل‌های همگن را در نظر می‌گیرند، با وجود پتانسیل شایان توجهی که برای نقشه برداری زمین‌شناسی دارند، کمتر مورد استفاده قرار می‌گیرند. در سال‌های اخیر، طبقه‌بندی با استفاده از رویکرد بر پایه شیء محبوبیت ویژه‌ای یافته است و طبقه‌بندی دقیق‌تری را می‌توان با استفاده از داده‌های ماهواره‌ای با وضوح بالاتر تولید نمود (Shayeganpour et al., 2021; Ouchra et al., 2022). روش بر پایه شیء نه تنها برای تصاویر ماهواره‌ای با وضوح متوسط تا بالا مناسب است؛ بلکه به عنوان جایگزینی برای فناوری بر پایه پیکسل نیز تکامل یافته است (Baatz, 2000; Benz et al., 2004). نرم‌افزار eCognition با قابلیت پیاده‌سازی بر پایه شیء و نرم‌افزار ENVI با ابزارهای طبقه‌بندی بر پایه پیکسل، امکان ترکیب و مقایسه این روش‌ها را فراهم می‌کنند. این پژوهش تلاش دارد تا با ترکیب فناوری‌های سنسجش از دور و الگوریتم‌های معروف یادگیری ماشین (Machine Learning)، از جمله، شبکه عصبی (Neural Network-NN)، ماشین بردار پشتیبان (Support Vector Machine-SVM) و نزدیک‌ترین همسایگی (K-Nearest Neighbor-kNN)، بهره‌گیری از ویژگی‌های مکمل داده‌های فراطیفی و چندطیفی و روش‌های پیشرفته پردازش تصویر، یک نقشه تا حد ممکن دقیق از واحدهای سنگ شناسی منطقه ارائه دهد. افزون بر این عملکرد طبقه‌بندی تصاویر ماهواره‌ای، بر پایه پیکسل و بر پایه شیء و نتایج حاصل



شکل ۱- موقعیت جغرافیایی و زمین‌شناسی همناخت افیولیتی رمشک-مختارآباد، مکران شمالی، جنوب خاوری ایران. (a) پهنه‌های ساختاری ایران با کمرندهای اصلی افیولیتی (سبز رنگ): کمرندهای افیولیتی شمال مکران (NMOC)، کرمانشاه (KM)، ناین (NA)، نیریز (NY)، سبزواری (SB)، شهر بابک (SHB)، چهل کوره (TH)، خوی (KH)، بافت (BF)، ایرانشهر (IR)، اسپندقه (ES)، مشهد (MS)؛ کادر قرمز موقعیت منطقه مورد مطالعه را نشان می‌دهد. (b) نقشه زمین‌شناسی-ساختاری ساده شده منطقه مورد مطالعه که واحدهای سنگی مختلف را نشان می‌دهد، برگرفته از نقشه‌های زمین‌شناسی: نقشه‌های زمین‌شناسی رامک و فوج با مقیاس ۱:۱۰۰,۰۰۰ (افتخارزاد و همکاران (Eftekhar-Nezhad et al., 1979))؛ صمیمی نمین و حاجی زاد کبیر (Samimi Namin and Hajizadeh Kabir, 1982) و نقشه زمین‌شناسی فوج با مقیاس ۱:۲۵۰,۰۰۰ (Eftekhar-Nezhad et al., 1979))، منتشر شده از سوی سازمان زمین‌شناسی ایران.

Figure 1. Geological and geographical location of the Remeshk-Mokhtarabad ophiolite complex, Northern Makran, SE Iran, a) The major structural zones of Iran and distribution of the principal ophiolitic belts (shown in green): North Makran Ophiolitic Belt (NMOC), Kermanshah (KM), Nain (NA), Neyriz (NY), Sabzevar (SB), Shahre-Babak (SHB), Tchhel Kureh (TH), Khoy (KH), Baft (BF), Iranshahr (IR), Esphandagheh (ES), Mashhad (MS). The red box indicates the location of the study area, b) Simplified geological-structural map of the study area (red box), illustrating the main lithological units. The map is compiled from the 1:100,000 geological maps of Ramak and Fannuj (Eftekhar-Nezhad et al., 1979; Samimi Namin and Hajizadeh Kabir, 1982), and the 1:250,000 Fannuj geological map (Eftekhar-Nezhad et al., 1979), published by the Geological Survey of Iran.



شکل ۲- نمودار جریان میبش روش پژوهش حاضر.

Figure 2. Workflow diagram summarizing the methodology of this study.

از باندها مشخص گردید. باندهای دیگر (مثل باند ۱ یا ۹) به دلیل رزولوشن پایین یا کاربرد خاص (مانند تشخیص ابر) حذف می شوند. در گام بعدی، به منظور یکپارچه سازی رزولوشن مکانی داده های سنتینل-۲، باندهای ۲۰ متری با استفاده از روش نزدیک ترین همسایگی به مقیاس ۱۰ متر تبدیل شدند. این روش، بدون انجام هرگونه میانگین گیری مکانی یا درون یابی طیفی، کمترین میزان تغییر در مقدار بازتاب (Reflectance) را ایجاد می کند. بدین ترتیب، تحلیل طیفی هم چنان بر پایه مقادیر طیفی اصلی است و از هرگونه همسان سازی طیفی (Spectral Normalization) که سبب تغییر امضاهای طیفی شود، پرهیز گردید. باز نمونه برداری (Upsampling) فقط در مرحله آماده سازی داده ها برای الگوریتم های یادگیری ماشین جهت تفکیک واحدهای سنگی و به منظور یکپارچه سازی ابعاد مکانی ورودی های مدل مورد استفاده قرار گرفت.

اگرچه داده های سطح L2D تصاویر پریسما در محدوده VNIR (۴۰۰-۱۰۱۰ نانومتر) و SWIR (۹۴۰-۲۵۰۵ نانومتر) در زمان بارگذاری شامل تصحیحات اتمسفری و ژئورفرنسینگ هستند، با این حال، برخی خطاها به دلیل اثرات جذب آب در محدوده های طیفی خاص (۱۳۴۹-۱۵۰۱ نانومتر و ۱۷۹۳-۱۹۹۳ نانومتر) وجود دارد که به ترتیب مربوط به باندهای ۱۰۲-۱۱۶ و ۱۴۵-۱۶۷ می باشد. این محدوده ها به دلیل جذب OH و جذب آب آزاد برای تجزیه و تحلیل های مطالعات معدنی یا کاربردهایی که نیاز به بازتاب دقیق سطح دارند، مناسب نیستند و باید حذف شوند. افزون بر این، برخی باندها به دلیل وجود خطوط راه راه

ماهواره پریسما اولین ماموریت اپتیکی فراتطیفی آژانس فضایی ایتالیا (ASI: Italian Space Agency) است. یک حسگر نوع جارویی در امتداد مسیر (Push-broom) با وضوح مکانی ۳۰ متر برای باندهای فراتطیفی و ۵ متر برای باندهای پانکروماتیک و دارای یک واحد کالیبراسیون داخلی برای نتایج طیفی بهتر است. این ماهواره تصاویر فراتطیفی منطقه ای به مساحت ۳۰×۳۰ کیلومتر مربع با رزولوشن طیفی بین ۹ تا ۱۵ نانومتر را ثبت می کند (Pignatti et al., 2015; Loizzo et al., 2019; Cogliati et al., 2021). داده ها شامل ۶ صحنه اطلاعاتی، سطح L2D با پوشش ابری کمتر از ۵% (تصحیح شده اتمسفری و ژئومتریکی) در قالب ۵.۵، مربوط به تاریخ های ۲۰۲۰ و ۲۰۲۱، از آژانس فضایی ایتالیا تهیه شد. این داده ها شامل ۲۳۹ باند طیفی در محدوده ۴۰۰-۲۵۰۰ نانومتر با رزولوشن فضایی ۳۰ متر بودند.

در این پژوهش داده های زمینی شامل نقشه های زمین شناسی با مقیاس های ۱:۲۵۰،۰۰۰ و ۱:۱۰۰،۰۰۰، منتشر شده توسط سازمان زمین شناسی و اکتشافات معدنی ایران برای اعتبارسنجی استفاده شد (برای جزئیات نقشه به زیرنویس شکل ۱ مراجعه شود).

داده های سنتینل-۲ در زمان بارگذاری، تصحیح هندسی و ژئورفرنس شده هستند. اما این اطلاعات بر روی آن ها ذخیره نشده است، از این رو، باندهای با قدرت تفکیک مکانی ۱۰ متر شامل باندهای ۲، ۳، ۴ و ۸ و باندهای ۱۱ و ۱۲ با قدرت تفکیک ۲۰ متر در نرم افزار ENVI نسخه 5.6 فراخوانی و اطلاعات هندسی و سیستم مختصات جدید و محدوده های مختلف طیف الکترومغناطیس برای هر یک

است (Rajan Girija and Mayappan, 2019). روش ها و فناوری های پردازش تصویر شامل تحلیل طیفی کانی و سنگ، فناوری بهبود طیفی کشتش ناهمبستگی (Decorrelation stretch-DS)، تحلیل مولفه های اصلی (PCA)، تبدیل کمینه کسر نوفه (MNF)، ترکیب باندی (BC)، ترکیب نسبت رنگی (CRC) و نسبت های باندی (BR)، بر روی داده های ماهواره های پرپسما و سنتینل-۲ برای نقشه برداری دقیق زمین شناسی از واحدهای سنگی رخنمون یافته در هم تافت افیولیتی رمشک-مختار آباد اعمال شدند. فناوری های PCA، DS، BR و BR را به صورت تصویری محاسبه کرده و با ترکیب آن ها به صورت ترکیب رنگی (Red, Green, Blue- RGB)، تفکیک چشمی را هم می توان بهبود بخشید (شکل های ۴ و ۵). در این پژوهش از این فناوری های بهبود تصویر به منظور بهبود تفکیک سنگ شناسی و افزایش ارزیابی دقت نقشه های طبقه بندی شده استفاده خواهد شد.

فناوری های متعددی برای انتخاب طیف های مرجع کانی و سنگ جهت تجزیه و تحلیل طیفی برای تشخیص واحدهای سنگی وجود دارد (Vangi et al., 2021). در این پژوهش، ویژگی های طیف الکترومغناطیسی واحدهای اصلی سنگی در منطقه مورد مطالعه، در تصاویر کالیبره شده پرپسما و سنتینل-۲ با کتابخانه های طیفی استاندارد منتشر شده از طیف واحدهای سنگی، کتابخانه طیفی دانشگاه جان هاپکینز (JHU) در نرم افزار ENVI، بازنویسی (Resample) شدند. ویژگی های طیفی و جذب و بازتاب طیف هر واحد سنگی مشخص و برای تجزیه و تحلیل بیشتر به الگوریتم های طبقه بندی وارد شدند (شکل های ۳-۱، ۳-۲، ۳-۳).

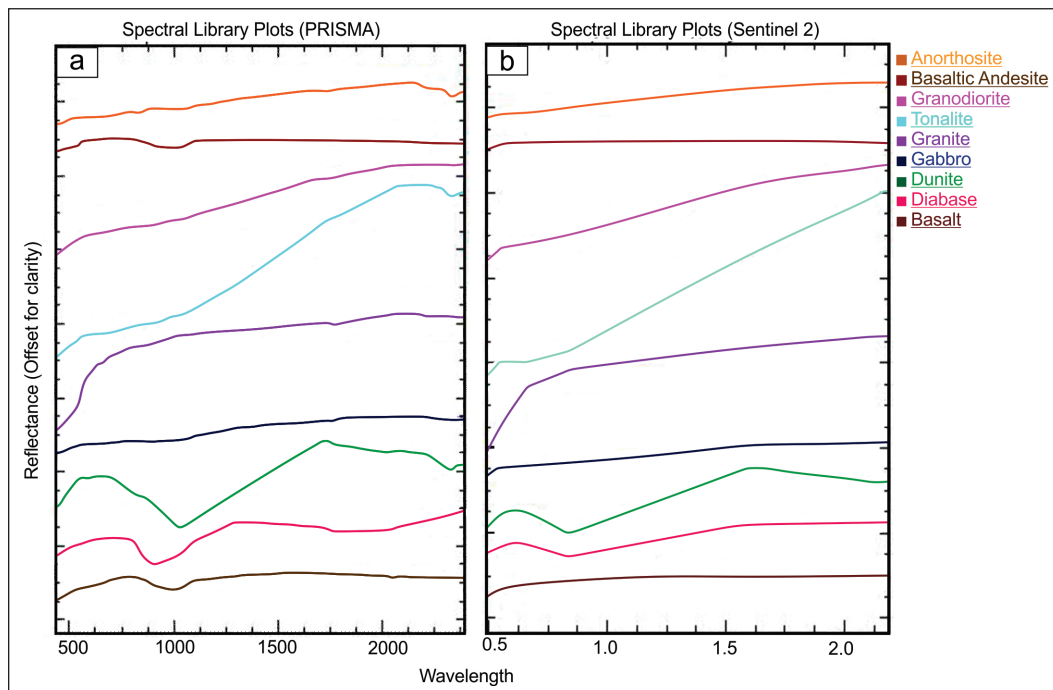
فناوری بهبود طیفی کشتش ناهمبستگی (DS)، بر روی باندهای (۲، ۳، ۱۲: RGB) داده سنتینل-۲ اعمال شد (شکل ۴). این روش اجزای اصلی یک تصویر را برای دستیابی به افزایش کنتراست از طریق کشتش تصویر و به کمترین مقدار رساندن همبستگی باندهای ویژه، بهبود می بخشد.

(Striped lines) که به احتمال ناشی از نوفه حسگر یا مشکلات کالیبراسیون هستند، حذف شده اند. به منظور حذف اثر لبخند (Smile effect) و کاهش نوفه تصویر، روش تبدیل کسر حداقل نوفه (Inverse MNF Transform-MNF)، بر روی داده ها اعمال شد و اطلاعات باقیمانده با استفاده از الگوریتم تبدیل معکوس MNF به فضای اولیه بازگردانده شدند. پس از حذف باندهای بدون داده و نوفه، ۱۱۰ باند انتخاب و برای بررسی های بعدی شماره گذاری شدند. صحنه های تصاویر در نرم افزار ENVI مرجع سازی و ترکیب شده اند و سپس اندازه آن به مرزهای منطقه مورد مطالعه برای استخراج ویژگی محدود شد. هم چنین به منظور مقایسه طیفی و مکانی بین داده های تصاویر سنتینل-۲ و پرپسما با استفاده از نقاط کنترل زمینی (Ground Control Points-GCPs)، فرایند هم ترازی هندسی (Geometric Co-registration)، در نرم افزار ENVI انجام شد.

۳- داده ها و اطلاعات


۳-۱- پردازش و استخراج ویژگی ها

استخراج دقیق ویژگی ها و داده های ورودی، یک نکته مهم در طبقه بندی قابل اعتماد است (Pal and Foody, 2010). این پژوهش به انتخاب شایسته داده های آموزشی و آزمایشی نماینده (Training and Testing data) و تعیین بهترین ورودی برای الگوریتم های طبقه بندی اتخاذ شده توجه ویژه ای دارد. در این راستا، چندین فناوری پردازش تصویر به داده های سنتینل-۲ و پرپسما برای تنظیم سطح بالاتری از تمایز واحدهای سنگ در معرض و تعیین ورودی های اطلاعاتی برای الگوریتم های طبقه بندی اعمال شد. انتخاب محصولات و فناوری های سنجش از دور به طور کامل به واحدهای سنگی مورد نظر و ماهیت منطقه مورد مطالعه بستگی دارد. هدف اصلی این فناوری ها محدود کردن منطقه جستجو و سپس کاهش هزینه و زمان کار میدانی




شکل ۳- طیف های استاندارد کتابخانه طیفی JHU باز نمونه برداری شده (resampled) با (a) داده های فراطیفی پرپسما (برحسب نانومتر) و (b) داده های چندطیفی سنتینل-۲ (برحسب میکرومتر) برای واحدهای سنگی اصلی هم تافت افیولیتی رمشک-مختار آباد.

Figure 3. JHU spectral library reference spectra resampled to a) PRISMA hyperspectral data (nanometers) and b) Sentinel-2 multispectral data (micrometers), for the principal lithological units of the Remeshk-Mokhtarabad ophiolitic complex.



شکل ۴- نتایج پردازش تصاویر سنتینل-۲، a و b تصاویر ترکیب باندی (BC)، c و d ترکیب نسبت رنگی (CRC)، e نسبت باندی (BR)، f بهبود طیفی کشتش ناهمبستگی (DS).

Figure 4. Sentinel-2 image processing results; a and b) Band combination (BC), c and d) Color ratio composite (CRC), e) Band ratio (BR), f) Decorrelation stretch (DS).




شکل ۵- نتایج پردازش تصاویر پریسما، a و b تصاویر ترکیب باندی (BC)، c ترکیب نسبت رنگی (CRC)، d نسبت باندی (BR).

Figure 5. PRISMA image processing results; a-b) Band combination (BC), c) Color ratio composite (CRC), d) Band ratio (BR).

بیشترین تغییرات سنگ شناسی را می توان داشت. در تصاویر سنتینل-۲، PCA بر روی ۶ باند منتخب (۲،۳،۴،۸،۱۱،۱۲) اعمال شد و سه مولفه اول (PC1، PC2، PC3) که بیش از ۹۵٪ واریانس را توضیح می دادند، انتخاب شدند. PC1، دارای ضرایب منفی می باشد و نشان دهنده روشنایی کلی (Albedo) است، آن چه که شدت بازتاب کل تصویر را بازتاب می دهد. تفاوت های سنگ شناسی و پوشش گیاهی بیشتر در مولفه های بعدی (PC2 و PC3) آشکار می شوند. PC2، تمایز بین واحدهای سنگی مانند بازالت و متابازالت را بر اساس ویژگی های SWIR برجسته می کند و PC3، جزئیات ظریف تر مانند تفاوت بازالت و گابرو را نشان می دهد. در تصاویر پریسما، PCA بر روی باندهای SWIR (۱۳۰۰-۲۵۰۰ نانومتر) و باندهای VNIR (۴۰۰-۱۰۰۰ نانومتر) برای تفکیک واحدهای سنگی و پوشش گیاهی اعمال شد. ترکیب رنگی (PC3، PC2، PC1) به صورت RGB برای جداسازی واحدهای سنگی نتایج خیلی خوبی می دهد (شکل ۶).

تحلیل مولفه اصلی (PCA)، یک فناوری آماری قدرتمند بهبود تصویر است و با کاهش اثرات تابشی (Radiometric effect suppression) که در همه باندها چیره هستند، اجزای نوفه را تفکیک و داده های تصویر اصلی با همبستگی بالا را به مجموعه ای از متغیرهای غیرهمبسته به نام مولفه های اصلی یا باندهای PC تبدیل می کند و از این طریق ابعاد داده ها را کاهش می دهد (Singh and Harrison, 1985). این فناوری بیشتر واریانس موجود در باندهای اصلی را در باندهای PC مرتبه بالاتر جمع می کند و نوفه را در آخرین باندها تفکیک می کند (Sabins and Lulla, 1987; Sabins, 1997). استفاده از تصاویر مولفه اصلی داده های سنتینل-۲ نتایج بهتری در نقشه برداری از سنگ شناسی مجموعه های آفیولیتی ارائه می دهد (Ge et al., 2018a). هم چنین این فناوری یکی از پرکاربردترین فناوری های کاهش ابعاد داده ها برای مجموعه داده های فراطیفی مانند پریسما می باشد (Tripathi and Garg, 2021). تصاویر مولفه های اصلی اول، دوم و سوم دارای بیشترین اطلاعات هستند که با ترکیب رنگی این سه باند



شکل ۶- تصاویر ترکیب رنگی کاذب (FCC) باندهای PC حاصل از تحلیل مولفه اصلی (PCA)، پردازش شده (b و a تصاویر سنتینل-۲، c و d تصاویر پریسما).

Figure 6. False-color composites, (FCC) of principal component (PC) bands derived from principal component analysis (PCA): a-b) processed Sentinel-2 images, c-d) processed PRISMA images.

مختلف تصویر و اختصاص این نسبت ها به کانال های رنگی RGB یک تصویر رنگی است (شکل های ۴ و ۵). این فناوری به دلیل حذف اثرات توپوگرافی و تفاوت های روشنایی، برای تمایز انواع سنگ ها بسیار موثر است و هم چنین اثر سایه را نیز از طریق اعمال نسبت ها خنثی می کند. تبدیل کمینه کسر نوفه (MNF) یک فناوری شناخته شده برای کاهش نوفه و استخراج ویژگی های طیفی مفید از داده های چندباندی مانند تصاویر سنتینل-۲ و پریسما می باشد. این فناوری با تعیین داده های تصویری مفید و جداسازی نوفه از اطلاعات مفید، داده ها را به اجزای اصلی با نوفه کمتر تبدیل می کند و اطلاعات طیفی مرتبط با ویژگی های زمین شناسی را برجسته می سازد (Boardman et al., 1995).

۳-۲- انتخاب داده های آموزشی و آزمایشی

نقشه های زمین شناسی در مقیاس های ۱:۱۰۰۰۰۰ و ۱:۲۵۰۰۰۰ به عنوان مرجع

تصاویر ترکیب باندهای (BC)، تولید شده از تصاویر پریسما و سنتینل-۲، نشان داد که برخی از ترکیب های رنگی کاذب (False Color Composite-FCC) می توانند تفکیک سنگ شناختی قابل قبولی را فراهم کنند (شکل های ۴، ۵ و ۶). نسبت باندهای (BR)، یک فناوری ساده است که برای افزایش تفاوت های جزئی در بازتاب طیفی سنگ ها و خاک ها با کاهش اثر توپوگرافی استفاده می شود و اگر باندهای مورد استفاده با موقعیت قله های بازتاب، فرورفتگی های جذب و تغییرات در منحنی شیب مطابقت داشته باشند، استفاده از نسبت های باندهای، کنتراست های طیفی و جذبی را به بیشترین مقدار می رساند (Langford, 2015; Ge et al., 2018a). در این پژوهش، ویژگی های طیفی استخراج شده از تصاویر پریسما و سنتینل-۲، (شکل های ۳-۲ و ۳-۱) با استفاده از ترکیبات مختلف بر روی باندهای VNIR و SWIR اعمال شد و نتایج مرزبندی واحدهای سنگی مورد نظر را نشان داد (شکل های ۴ و ۵). ترکیب نسبت رنگی (CRC)، روشی شامل محاسبه نسبت های بین باندهای طیفی

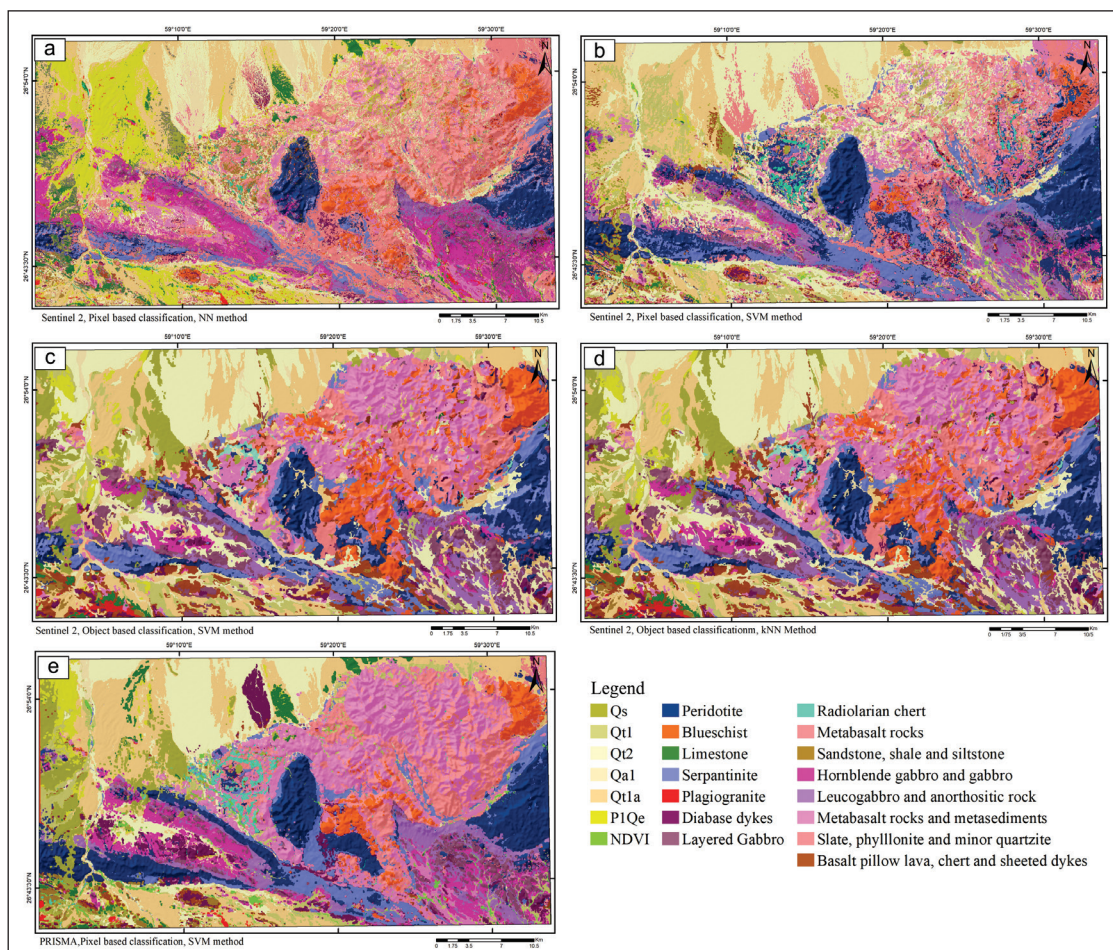
کیفیت و کمیت داده‌های ورودی و انتخاب مناسب الگوریتم برای یک مسئله خاص بستگی دارد (Fenza et al., 2021). برای یافتن طبقه‌بندی کننده بهینه برای طبقه‌بندی سنگ شناسی هماتیت افیولیتی رمشک-مختارآباد با استفاده از داده‌های سنتینل-۲ و پریسما، سه الگوریتم معمول یادگیری ماشین، kNN، NN و SVM با رویکردهای بر پایه پیکسل (PBIA) و بر پایه شیء (OBIA)، برای نقشه برداری سنگ‌شناسی به کار گرفته شدند (شکل ۷).

رویکرد بر پایه پیکسل با در نظر گرفتن تطابق تقریبی بین ویژگی‌های طیفی پیکسل تصویر و طیف مرجع یک واحد سنگی شناخته شده، هر پیکسل را به کلاس سنگی خود بدون در نظر گرفتن ویژگی‌های زمینه‌ای طبقه‌بندی می‌کند (Van der Meer et al., 2012). در این رویکرد هر پیکسل به صورت مستقل و بدون در نظر گرفتن پیکسل‌های اطرافش طبقه‌بندی می‌شود، به این ترتیب، پیکسل‌هایی که ارزش طیفی آن‌ها از نظر آماری، اختلاف معناداری ندارند، در یک کلاس طیفی قرار می‌گیرند. الگوریتم‌های یادگیری ماشینی که در این پژوهش برای نقشه برداری سنگ شناسی در سطح پیکسل استفاده شده‌اند شامل شبکه عصبی (NN) و ماشین بردار پشتیبان (SVM) هستند (شکل ۷). برای هر دو این الگوریتم‌ها، از یک روش یکسان برای انتخاب داده‌های آموزشی و ویژگی‌های طبقه‌بندی استفاده شد. با این حال، تنظیم بهینه پارامترهای تنظیم برای هر طبقه‌بندی کننده به طور جداگانه تعیین شده‌اند.

برای انتخاب داده‌های آموزشی و آزمایشی استفاده شدند. به دلیل پیچیدگی سنگ‌شناسی هماتیت افیولیتی، داده‌های نماینده با کمک فناوری‌های سنسور از دور یاد شده در بخش ۴، نقشه‌های زمین‌شناسی، مطالعات پیشین (Hunziker, 2014; Hunziker et al., 2015; Sacconi et al., 2022, 2023; Hajimohammadi et al., 2025) و مشاهدات میدانی برخی واحدها انتخاب شدند. داده‌های سنتینل-۲ و پریسما با توجه به تفاوت در رزولوشن مکانی و پوشش طیفی، نمونه‌های متفاوتی را شامل شدند که در انتخاب داده‌ها در نظر گرفته شدند. تفسیر چشمی با روش‌های یاد شده، استخراج داده‌های آموزشی و آزمایشی واحدهای سنگی را امکان پذیر کرد. طیف‌های خالص (Endmember spectra) هر واحد سنگی برای تأیید مناطق مورد نظر (Region of Interest-ROI) و پارامترهای آموزشی استخراج شدند. داده‌ها به ۸۰٪ آموزش و ۲۰٪ آزمایش تقسیم شده و به عنوان ورودی الگوریتم‌های طبقه‌بندی شامل شبکه عصبی (NN)، ماشین بردار پشتیبان (SVM) و نزدیک‌ترین همسایگی (kNN) استفاده شدند.

۳-۳- نتایج طبقه‌بندی

در نقشه برداری سنگ‌شناسی، الگوریتم‌های متنوع یادگیری ماشین متناسب با الزامات تحلیلی و ویژگی‌های ذاتی داده‌های زمین‌شناسی، از جمله پیچیدگی طیفی و ناهمگنی مکانی، مورد استفاده قرار می‌گیرند. با این حال، دقت نتایج به شدت به



شکل ۷- نتایج طبقه‌بندی الگوریتم‌های یادگیری ماشین: رویکرد بر پایه پیکسل، (a) الگوریتم NN، (b) الگوریتم SVM در تصاویر سنتینل-۲ و (c) الگوریتم SVM در تصاویر پریسما؛ رویکرد بر پایه شیء، (c) الگوریتم SVM، (d) الگوریتم kNN در تصاویر سنتینل-۲.

Figure 7. Results of machine learning classification; Pixel-based approach, a) NN algorithm, b) SVM algorithm applied to Sentinel-2 images, and e) SVM algorithm applied to PRISMA images; Object-based approach, c) SVM, d) kNN algorithms applied to Sentinel-2 images.

۳-۶- نزدیک ترین همسایه

نزدیک ترین همسایه (kNN)، به دلیل سادگی پیاده سازی، وضوح تئوری و عملکرد عالی طبقه بندی، در بسیاری از زمینه ها به طور گسترده مورد استفاده قرار گرفته است. رویکرد kNN یک روش نظارت شده است که اشیاء را بر اساس فاصله آن ها در فضای ویژگی به کلاس های تعریف شده (داده های آموزشی) تخصیص می دهد (Cover and Hart, 1967). این الگوریتم از یک رویکرد یادگیری بر پایه نمونه یا «یادگیری تنبل» (Lazy learning) استفاده می کند و بر اساس روش نزدیک ترین همسایه ها، یک شیء X با ویژگی های کلاس K نزدیکترین همسایه اش طبقه بندی می شود. بنابراین، K پارامتر تنظیم کلیدی در این طبقه بندی کننده است که تا حد زیادی عملکرد طبقه بندی کننده kNN را تعیین می کند (Qian et al., 2014). در این پژوهش، مقدار بهینه k برابر با ۵ در نظر گرفته شده است. گفتنی است در واحدهای سنگی افیولیتی، که می توانند دارای تنوع های پیچیده بافتی و طیفی باشند، همان گونه که در مطالعه حاضر و گه و همکاران (Ge et al., 2018b) مشاهده شده است، انتخاب مقدار بهینه k برابر با ۵ به مدل امکان می دهد تا الگوهای محلی را به خوبی شناسایی کند و هم زمان از بیش برآش (Overfitting) جلوگیری نماید (شکل ۷-d).

۴- بحث

۴-۱- ارزیابی دقت نتایج طبقه بندی کننده ها

تصاویر طبقه بندی شده از هم تافت افیولیتی رمشک-مختار آباد باید ارزیابی شوند تا از صحت نتایج اطمینان حاصل شود. از این رو، ابتدا نمونه برداری تصادفی برای داده آزمایشی از انواع واحدهای سنگی انجام و نتایج با نقشه زمین شناسی و مشاهدات میدانی مقایسه شدند. سپس ارزیابی دقت هر دو رویکرد طبقه بندی با استفاده از ماتریس درهم ریختگی (confusion matrices) (Congalton, 1991)، انجام و میزان تطابق بین نتایج طبقه بندی PBIA و OBIA برای ارزیابی اعتبار سنگ شناسی هر خروجی طبقه بندی کننده ارزیابی شد. سه الگوریتم یادگیری ماشین، kNN، NN و SVM با رویکردهای بر پایه پیکسل و بر پایه شیء، توانستند واحدهای اصلی سنگ شناسی شامل بازالت، متابازالت، شیست آبی، گابرو، پریدوتیت و سنگ های رسوبی را شناسایی کنند (شکل ۷). با این حال، نقشه خروجی رویکرد بر پایه شیء، امتدادها و مرزهای سنگ شناسی را واضح تر و شفاف تر از خروجی رویکرد بر پایه پیکسل نشان داد و کل منطقه با موفقیت به طبقات سنگ شناسی اختصاص داده شده تقسیم شد. روش بر پایه شیء با در نظر گرفتن ویژگی های جذب و انعکاس طیفی خاص اشیاء مورد نظر و بافت ها و روابط مکانی آن ها، قادر به دستیابی به نتایج قابل اعتمادی بود. انواع مختلف سنگ شناسی و رسوبات کواترنری نیز از طریق فرایند طبقه بندی انجام شده و بر اساس مناطق آموزشی مناسب، حتی در تعداد کم، با موفقیت تفکیک شدند. افزون بر این، مقایسه نتایج با مشاهدات میدانی انجام شده، نشان داد که واحدهای سنگ شناسی استخراج شده، دقیق تر از نتایج به دست آمده از رویکرد بر پایه پیکسل هستند. در ادامه، نتایج طبقه بندی ها با استفاده از درهم ریختگی، معیارهای صحت کلی (Overall Accuracy) و ضریب کاپا (Kappa Coefficient) و هم چنین، بر اساس کلاس ها ارزیابی و مقایسه شدند (جدول های ۱ تا ۳). این نمودارها دیدی جامع و قابل فهم از عملکرد هر مدل برای هر کلاس ارائه می دهند و نقاط قوت و ضعف هر مدل و رویکرد را آشکارا مشخص می کنند.

رویکرد بر پایه شیء برای داده پریماسا نتیجه قابل قبولی در بر نداشت. در نتیجه، طبقه بندی بر روی این داده فراطیفی با رویکرد بر پایه پیکسل و مدل SVM انجام شد که با صحت کلی نزدیک به (۸۷/۸۳٪) و ضریب کاپا (۰/۸۶۸۲) عملکرد بسیار خوبی در تمایز واحدهای سنگ شناسی ارائه کرد. مدل شبکه عصبی (NN) با رویکرد بر پایه پیکسل، برای داده سنتینل-۲ با صحت کلی پایین (حدود ۴۷٪) و ضریب کاپا متوسط (۰/۴۳)، توانست کلاس ها را به خوبی از هم تفکیک کند. این مسئله ممکن است به دلیل معماری ساده این مدل برای یادگیری باشد. مدل

رویکرد بر پایه شیء فناوری موثر برای تفکیک چندین شیء تصویری است که بر اساس شباهت های نسبی پیکسل های مشابه و مجاور در ویژگی های طیفی، مکانی و بافتی، به صورت یکپارچه سازماندهی شده اند (Blaschke et al., 2014). بنابراین، هر شیء تصویری در بر دارنده ویژگی های طیفی و مکانی بیشتری نسبت به پیکسل های منفرد است. این رویکرد یک چارچوب فرایندی ارائه می دهد که شامل دو مرحله اصلی طبقه بندی (Segmentation) و انتخاب داده های آموزشی است (Benz et al., 2004). طبقه بندی تصویر به چند ضلعی های غیر هم پوشان (Automated Segmentation)، به عنوان اولین و مهم ترین گام در رویکرد OBIA شناخته می شود (Baatz, 2000). این مرحله شامل تقسیم تصویر به پیکسل های مجاور با ویژگی های مشابه است که بر اساس اطلاعات مکانی، بافتی و ارتباطی تعریف شده اند و همگنی شیء حاصل را مشخص می کنند (Willhauck et al., 2000). این الگوریتم با هر ناحیه پیکسلی آغاز می شود و سپس آن ها را بر اساس معیار همگنی، به صورت پیوسته در گروه های معنادار سازماندهی می کند (Baatz, 2000). پارامتر مقیاس، رنگ، شکل، همواری و فشردگی، پارامترهای اصلی در این مرحله هستند که باید تا حد امکان دقیق تعیین شوند تا با واقعیت مطابقت داشته باشند. ویژگی های پر کاربرد در رویکرد OBIA شامل معیارهای طیفی مانند میانگین روشنایی (Average brightness) یا انحراف استاندارد (Standard deviation) باندهای طیفی، شکل مانند مساحت، گردی یا فشردگی و بافت مانند یکنواختی یا آنتروپی هستند. این ویژگی ها برای شناسایی و تفکیک کلاس های مختلف واحدهای سنگی، به ویژه هم تافت افیولیتی که ممکن است با وجود تفاوت های طیفی اندک، از نظر شکل یا بافت متمایز باشند، بسیار مفیدند. در گام بعدی، طبقه بندی تصویر توسط الگوریتم های استاندارد یادگیری ماشین SVM و kNN در نرم افزار eCognition، نسخه 9.01 (Trimble, 2015)، انجام شد (شکل ۷).

نتایج حاصل از به کارگیری الگوریتم های یادگیری ماشین، تفاوت آشکاری را در توانایی آن ها برای تفکیک واحدهای سنگی هم تافت افیولیتی نشان می دهد.

۳-۴- شبکه عصبی

طبقه بندی کننده شبکه عصبی (NN)، به طور گسترده در تشخیص الگو و طبقه بندی داده های تصویر به کار می رود. در این الگوریتم سه لایه وجود دارد، یک لایه ورودی، یک لایه میانی (یعنی لایه پنهان) و یک لایه خروجی، هر لایه از یک یا چند گره تشکیل شده است که از طریق آزمایش تکراری تنظیم می شوند تا منطقی ترین خروجی به دست آید (Hepner et al., 1990; Haykin and Network, 2004). بخش عمده خطاهای طبقه بندی در مرزهای انتقالی واحدها مشاهده شد، مناطقی که هم پوشانی طیفی ماهیت طبیعی واحدهای سنگی است (شکل ۷-a).

۳-۵- ماشین بردار پشتیبان

ماشین بردار پشتیبان (SVM)، یک فناوری طبقه بندی نظارت شده است که از یک رویکرد یادگیری آماری توسعه یافته است و به طور عمده برای حل توزیع های کلاس پیچیده با مجموعه داده های چندطیفی و فراطیفی که نوفه ای و پیچیده هستند، استفاده می شود (Roli and Fumera, 2001; Li et al., 2014). این الگوریتم پس از آموزش و یادگیری، به داده های ناشناخته برچسبی اختصاص می دهد و با ایجاد یک ابرصفحه (Hyperplane)، کلاس ها را جدا و فضای بین آن ها را افزایش می دهد (Noble, 2006). افزون بر این، SVM از یک تابع هسته (Kernel function) استفاده می کند تا جداسازی داده های غیر قابل جداسازی را افزایش دهد. این اغلب با افزایش ابعاد داده ها به دست می آید. عملکرد SVM روی هر دو داده سنتینل-۲ و پریماسا نشان داد که در نواحی ناهمگن این الگوریتم با پیچیدگی طیفی افیولیت ها سازگاری دارد (شکل های ۷-b, c, e).

پریسما، یک استثنا است و عملکردی بسیار نزدیک به مدل های بر پایه شیء دارد. صحت کلی و ضریب کاپای بالای آن نشان می دهد که با وجود استفاده از روش پیکسل محور، این مدل در تصاویر فراطیفی پریسما توانسته است به نتایج قابل قبولی دست یابد.

SVM با رویکرد بر پایه پیکسل، در تصویر سنتینل-۲ با صحت کلی نزدیک به ۴۷/۲۷٪ و ضریب کاپا (۰/۴۲۹۹) مشابه مدل NN عملکرد آن چنان خوبی نداشت و این مسئله بیانگر آن است که داده های پیکسلی به تنهایی اطلاعات مکانی یا بافتی کافی را ارائه نمی دهند. مدل SVM با رویکرد بر پایه پیکسل، در تصویر

جدول ۱- نتایج ارزیابی صحت و ضریب کاپا در روش های طبقه بندی بر پایه پیکسل و بر پایه شیء.

Table 1. Accuracy assessment results and Kappa coefficients for pixel-based and object-based classification methods.

Satellite Data	Classification Method and Algorithm	Overall Accuracy	Kappa Coefficient
Sentinel 2	NN (Pixel-Based)	46/96%	0/4339
	SVM (Pixel-Based)	47/27%	0/4299
	SVM (Object-Based)	90/99%	0/9016
	kNN (Object-Based)	89/47%	0/8863
PRISMA	SVM (Pixel-Based)	87/82%	0/8682

جدول ۲- تحلیل برآوردی معیارهای کلاس به کلاس و مقایسه برآوردی مدل های طبقه بندی.

Table 2. Estimated analysis of class-wise metrics and comparative assessment of classification models.

Overall Metric	Sentinel 2				PRISMA
	NN (Pixel-Based)	SVM (Pixel-Based)	SVM (Object-Based)	kNN (Object-Based)	SVM (Pixel-Based)
Class-wise Accuracy	Many to Medium	Low	High to Complete	High to Complete	High to Complete
Number of Problematic Classes	Many	Many	Few	Few	Few
Error-free Classes	Few	Very Few	Many	Many	Many
Approx. Mean F1-score	0.55-0.45	0.55-0.40	0.95-0.85	0.93-0.85	0.9-0.85

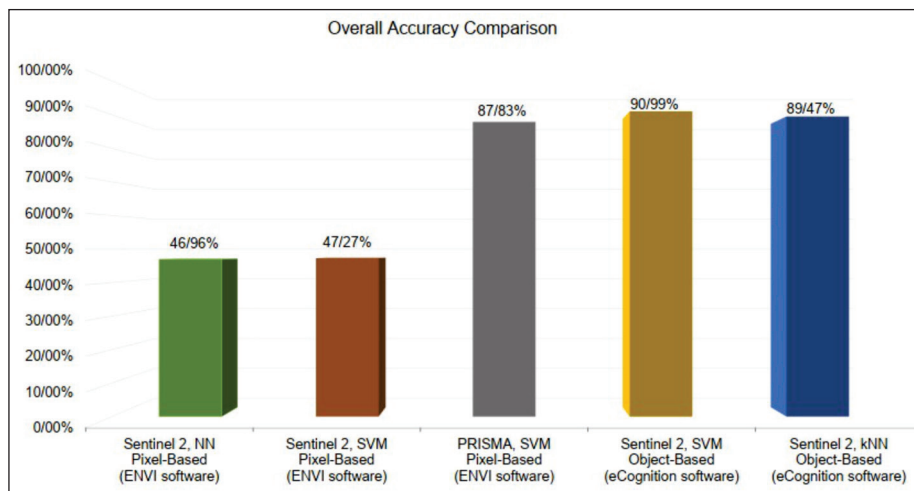
جدول ۳- جدول درصد دقت تولیدکننده برای هر واحد سنگی در هر چهار مدل طبقه بندی.

Table 3. Producer's accuracy (%) for each lithological unit across the four classification models.

Class	Producer's Accuracy (%)				
	Sentinel 2				PRISMA
	kNN (Object-Based)	SVM (Object-Based)	NN (Pixel-Based)	SVM (Pixel-Based)	SVM (Pixel-Based)
Q ^s	100	100	100	57.77	95.53
Q ^{t1}	94.78	94.78	-	52.02	42.06
Q ^{t2}	100	100	-	-	95.42
p ^{1Qe}	53.77	53.77	-	-	78.29
Q ^{a1}	58.49	58.49	-	50.31	95.21
Peridotite	86.13	97.47	50.83	92.58	94.07
Blueschist	71.79	71.79	72.36	41.31	87.75
Limestone	100	99.79	97.71	67.71	97.62
Serpentinite	77.56	100	77.56	77.56	-
Plagiogranite	100	100	69.67	-	98.02
Diabase dykes	100	100	0.89	12.06	94.01
Layered gabbro	68.85	68.85	15.13	26.58	-
Metabasalt rocks	73.02	73.02	74.01	66.24	76.84
Radiolarian chert	73.99	69.66	17.24	61.12	-
Sandstone, shale and siltstone (E ^s)	100	100	4.65	28.68	89.28
Hornblende gabbro and gabbro	100	100	24.48	4.88	73.19
Leucogabbro and anorthositic rock	62.29	100	62.29	94.89	87.82
Metabasalt rocks and metasediments	94.03	94.03	17.86	22.45	83.16
Slate, phyllonite and minor quartzite (dy5)	35.95	35.95	26.25	35.95	-
Basalt pillow lava, chert and sheeted dykes	94.7	93.36	46.4	62.75	-

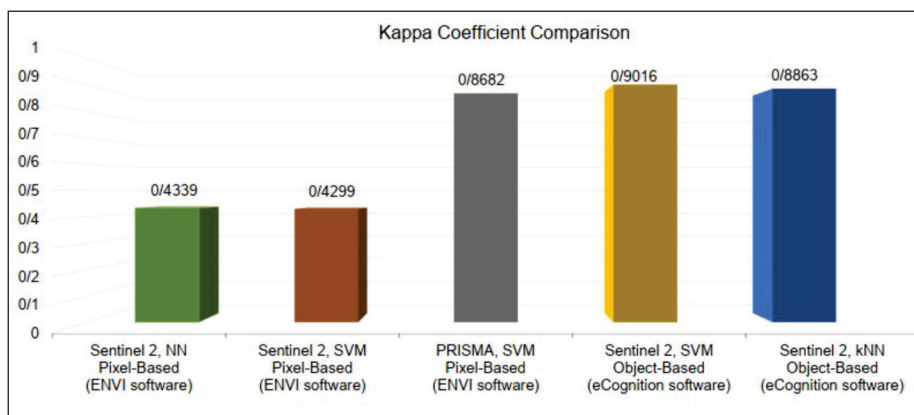
است. مدل kNN با رویکرد بر پایه شیء، صحت کلی بسیار بالا (۸۹/۴۷٪) و ضریب کاپا قوی (۰/۸۸۶۳)، عملکرد شایان توجهی دارد. این مدل ساده، وقتی با رویکرد بر پایه شیء ترکیب می شود، توان طبقه بندی بالایی دارد (جدول ۱، شکل های ۸ و ۹).

مدل SVM با رویکرد بر پایه شیء، دقت بسیار بالا (۹۰/۹۹٪) و ضریب کاپا فوق العاده (۰/۹۰)، بهترین عملکرد را در بین تمام مدل ها دارد که نشان دهنده توانایی بهتر این روش در تمایز واحدهای سنگ شناسی با ویژگی های مکانی پیچیده است. ترکیب داده های بر پایه شیء و مدل SVM سبب طبقه بندی بسیار دقیق شده



شکل ۸- ارزیابی دقت طبقه بندی ها با استفاده از ماتریس درهم ریختگی و مقایسه معیارهای صحت کلی آن ها.

Figure 8. Evaluation of classification accuracy using confusion matrices and comparison of overall accuracy metrics.



شکل ۹- ارزیابی دقت طبقه بندی ها با استفاده از ماتریس درهم ریختگی و مقایسه ضریب کاپا آن ها.

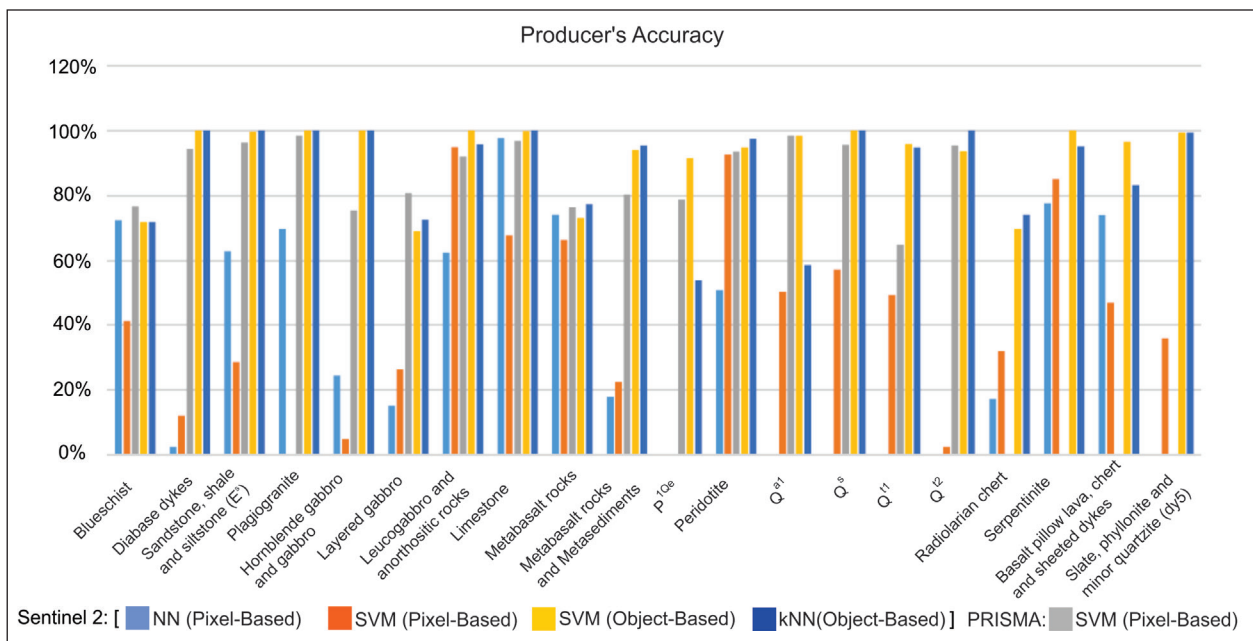
Figure 9. Evaluation of classification accuracy using confusion matrices and comparison of Kappa coefficients.

F1-score و صحت کلی مقادیر بسیار نزدیکی دارند. این همبستگی قوی نشان دهنده این است که مدل ها به طور یکنواخت و قوی در تمام کلاس ها عمل کرده اند. در مدل های ضعیف تر بر پایه پیکسل، میانگین F1-score ممکن است کمی بالاتر یا پایین تر از صحت کلی باشد که این موضوع نشان دهنده عملکرد نامتوازن مدل در کلاس های مختلف است. ممکن است مدل در شناسایی یک کلاس خاص عملکرد خوبی داشته باشد، اما در سایر کلاس ها به شدت ضعیف عمل کند و میانگین کلی را تحت تأثیر قرار دهد. F1-score، به دلیل در نظر گرفتن فراخوانی و دقت به صورت هم زمان، معیار دقیق تری برای ارزیابی عملکرد مدل در چنین شرایطی است. دقت تولید کننده (Producer's Accuracy)، به طور معمول در ارزیابی داده های مکانی، مانند این پژوهش، کاربرد دارد و معادل یادآوری است. این معیار در

معیار F1-Score، برای ارزیابی عملکرد مدل های طبقه بندی است که تعادلی بین دقت (Precision) و یادآوری (Recall) برقرار می کند. محدوده ای بین صفر و یک که یک نشان دهنده بهترین و صفر بدترین عملکرد می باشد (جدول ۲). این معیار به ویژه زمانی مفید است که داده ها نامتوازن باشند، به عنوان مثال، تعداد نمونه های یک کلاس خیلی بیشتر از کلاس دیگر باشد. معیار F1-Score، میانگین هارمونیک دقت و یادآوری است $(F1 = 2 \times (Precision \times Recall / (Precision + Recall)))$. دقت، نسبت نمونه های درست طبقه بندی شده برای یک کلاس خاص به کل نمونه هایی که به آن کلاس نسبت داده شده اند، می باشد (درست + نادرست). یادآوری، نسبت نمونه های درست طبقه بندی شده برای یک کلاس خاص به کل نمونه های واقعی آن کلاس می باشد. در مدل های قوی تر بر پایه شیء، میانگین

(Hornblende Gabbro) و رسوبات کواترنری (Q^2 و Q^3) معمولاً دقت تولیدکننده بسیار بالایی (نزدیک به ۱۰۰٪) در مدل‌های بر پایه شیء kNN و SVM دارند، که نشان‌دهنده شناسایی عالی این کلاس‌ها توسط این مدل‌ها است. برخی کلاس‌ها مانند گابرو لایه‌ای (Layered Gabbro)، چرت رادیولاریتی (Radiolarian chert)، متابازالت و متاسدیمنت‌ها (Metabasalt rocks and metasediments) و به ویژه رسوبات کواترنری (Q^{10c} و Q^{11}) در مدل‌های بر پایه پیکسل NN و SVM، دقت تولیدکننده بسیار پایینی دارند، که نشان‌دهنده دشواری در شناسایی این واحدها توسط مدل‌ها یا وجود هم‌پوشانی زیاد با سایر کلاس‌ها می‌باشد.

چهارچوب ماتریس درهم‌ریختگی، نشان می‌دهد که یک طبقه‌بندی‌کننده با چه دقتی ویژگی‌های دنیای واقعی را به کلاس‌های مربوطه در یک نقشه طبقه‌بندی نگاشت می‌کند. برای هر کلاس، دقت تولیدکننده با تقسیم تعداد نمونه‌های درست طبقه‌بندی‌شده از آن کلاس بر تعداد کل نمونه‌هایی که واقعا به آن کلاس در داده‌های واقعی تعلق دارند، محاسبه می‌شود (جدول ۳ و شکل ۱۰). کلاس‌های با دقت بالا و کلاس‌های چالش برانگیز واحدهای سنگی، نکات برجسته‌ای است که از این جدول می‌توان استنباط کرد. کلاس‌هایی مانند سنگ آهک (Limestone)، پلاژیوگرانیت (Plagiogranite)، ماسه سنگ، شیل و سیلتستون (Es)، هورنبلند گابرو



شکل ۱۰- ارزیابی و مقایسه دقت تولیدکننده برای هر واحد سنگی در مدل‌های طبقه‌بندی.

Figure 10. Assessment and comparison of producer's accuracy for each lithological unit across the classification models.

زمین‌شناسی به هم نزدیک هستند و احتمالاً ویژگی‌های طیفی مشابهی دارند، که سبب خطاهای مثبت کاذب (Commission) و منفی کاذب (Omission) بین آن‌ها در ماتریس درهم‌ریختگی شده است. کلاس‌های متابازالت و دایک‌های دیابازی در طبقه‌بندی پریسما با دقت بسیار بالا و نزدیک به ۱۰۰٪ طبقه‌بندی شده‌اند؛ در حالی که همین کلاس‌ها در داده‌های سنتینل-۲ با رویکرد بر پایه پیکسل دقت بسیار پایینی یا حتی نامشخص دارند. این موضوع نشان‌دهنده تاثیر تفاوت‌های رزولوشن و پوشش طیفی بین دو داده ماهواره‌ای است. پدیدتیت و سرپانتینیت، این دو کلاس نیز عملکرد خوبی در تصاویر پریسما دارند، با این حال، تمایز آن‌ها در تصاویر سنتینل-۲ با چالش‌هایی مواجه می‌شود. نماد نامشخص، در دقت تولیدکننده، نشان‌دهنده عدم امکان محاسبه دقت برای آن کلاس و روش است. این امر به ویژه در برخی کلاس‌ها و روش‌های بر پایه پیکسل دیده می‌شود که بیانگر پراکندگی نامناسب یا کمبود داده‌های آموزشی و آزمایشی و یا پیچیدگی طبقه‌بندی آن‌ها باشد.

۴-۲- ارزیابی کارایی داده سنتینل-۲ و داده پریسما

این پژوهش نشان می‌دهد که کاربرد داده‌های چندطیفی سنتینل-۲ و فراطیفی پریسما با استفاده از فناوری‌های سنجنش از دور، واحدهای سنگی افیولیتی و پوشش گیاهی را به خوبی تفکیک می‌کند. داده‌های سنتینل-۲ با رزولوشن مکانی ۱۰ متر و ۱۳ باندها، ویژگی‌های

در تفاوت بین مدل‌های بر پایه شیء و بر پایه پیکسل، آشکارا مشاهده می‌شود که مدل‌های SVM و kNN که رویکرد بر پایه شیء دارند برای بسیاری از کلاس‌ها دقت تولیدکننده به مراتب بالاتری نسبت به مدل‌های NN و SVM که رویکرد بر پایه پیکسل دارند، ارائه می‌دهند. این می‌تواند به دلیل توانایی رویکرد بر پایه شیء در استفاده از اطلاعات بافتی و هندسی اشیاء، افزون بر اطلاعات طیفی پیکسل‌ها باشد. مدل‌های بر پایه پیکسل SVM و NN، در شناسایی بسیاری از کلاس‌ها عملکرد بسیار ضعیفی از خود نشان داده‌اند؛ به گونه‌ای که برای برخی کلاس‌ها (مانند پلاژیوگرانیت در مدل SVM یا رسوبات کواترنری Q^{10c} و Q^{12} در مدل NN) دقت تولیدکننده نامشخص است. این امر بر ضرورت بررسی دقیق‌تر پارامترها، داده‌های آموزشی، و ساختار این مدل‌ها تأکید می‌کند. در میان مدل‌های بر پایه پیکسل، مدل SVM روی تصاویر پریسما عملکرد بسیار بهتری را نشان می‌دهد. این مدل در بیشتر کلاس‌ها تمایز بالایی دارد که نشان‌دهنده توانایی بالای تصاویر فراطیفی در استخراج اطلاعات طیفی متمایز است.

از دیدگاه زمین‌شناسی با توجه به این که کلاس‌ها به انواع سنگ‌ها و واحدهای زمین‌شناسی اشاره دارند، خطاها ممکن است به دلیل شباهت‌های طیفی یا بافتی در داده‌های ورودی، مانند تصاویر ماهواره‌ای یا داده‌های پردازش شده، باشد. کلاس‌هایی مانند گابروها (Layered Gabbro, Hornblende Gabbro, Leuco Gabbro)، از نظر

واحدهای سنگی داشته و انتخاب مناسب داده های آموزشی ورودی به الگوریتم های طبقه بندی به عنوان یکی از الزامات اساسی این فرایند مطرح است. در میان روش های بهبود تصویر مورد استفاده، ترکیب نسبت های رنگی (CRC) کارآیی بالاتری در تفکیک واحدهای سنگی پیچیده نشان داد. در مجموع، با وجود این که رویکرد بر پایه پیکسل الگوریتم طبقه بندی SVM، با تصاویر فرایفی پریسما، امکان تفکیک واحدهای سنگی نمایان در منطقه مورد مطالعه را نسبت به همین الگوریتم در تصاویر چند طیفی به طور موثرتری فراهم کرد، به هر حال، رویکرد بر پایه شیء الگوریتم های SVM و kNN در تفکیک واحدهای سنگی با میان لایه های جزئی به دست آمده برای برخی از طبقات واحدهای سنگی، بسیار موثرتر عمل کرده است. هم چنین این پژوهش نشان داد که سنتینل-۲ و پریسما مکمل یکدیگر هستند و استفاده هم زمان آن ها از برای قدرتمند برای نقشه برداری واحدهای سنگی پهنه های افیولیتی فراهم می کند. پریسما برای شناسایی طیفی دقیق تر و سنتینل-۲ برای جزئیات فضایی مناسب تر هستند، بنابراین، استفاده از این دو در کنار هم می تواند به درک بهتری از ساختارهای زمین شناسی پیچیده بیانجامد. با وجود دقت بالای نتایج، پیشنهاد می شود برای اعتبارسنجی دقیق تر، داده های میدانی مانند طیف سنجی زمینی جمع آوری شود. طیف سنجی میدانی می تواند ویژگی های طیفی دقیق واحدهای سنگی را فراهم کند و به عنوان داده مرجع برای بهبود آموزش الگوریتم های طبقه بندی یادگیری ماشین استفاده شود.

سپاسگزاری

در اینجا لازم است از حمایت های دانشگاه شهید باهنر کرمان و سازمان زمین شناسی و اکتشافات معدنی کشور (مدیریت ژئومتیکس و گروه سنجش از دور) برای انجام این پژوهش، تشکر و قدردانی گردد. نگارندگان از داوران گرامی مقاله به جهت ارائه نظرات ارزنده و از سردبیر و هیئت تحریریه محترم فصلنامه علوم زمین قدردانی می نمایند.

References

- Baatz, M., 2000, Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation: *Angewandte geographische informationsverarbeitung*, p. 12–23.
- Benz, U. C., Hofmann, P., Willhauck, G., Lingensfelder, I., and Heynen, M., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information: *ISPRS Journal of photogrammetry and remote sensing*, v. 58, no. 3-4, p. 239–258.
- Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Feitosa, R. Q., Van der Meer, F., Van der Werff, H., and Van Coillie, F., 2014. Geographic object-based image analysis—towards a new paradigm: *ISPRS journal of photogrammetry and remote sensing*, v. 87, p. 180–191.
- Boardman, J. W., Kruse, F. A., and Green, R. O., 1995. Mapping target signatures via partial unmixing of AVIRIS data, in *Proceedings Summaries of the fifth annual JPL airborne earth science workshop. Volume 1: AVIRIS workshop1995*.
- Burg, J.-P., Dolati, A., Bernoulli, D., and Smit, J., 2012. Structural style of the Makran Tertiary accretionary complex in SE-Iran, in *Proceedings Lithosphere dynamics and sedimentary basins: The Arabian Plate and analogues*, Springer, p. 239–259.
- Chen, X., Warner, T. A., and Campagna, D. J., 2007. Integrating visible, near-infrared and short-wave infrared hyperspectral and multispectral thermal imagery for geological mapping at Cuprite, Nevada: *Remote Sensing of Environment*, v. 110, no. 3, p. 344–356.
- Clark, R. N., Swayze, G. A., Livo, K. E., Kokaly, R. F., Sutley, S. J., Dalton, J. B., McDougal, R. R., and Gent, C. A., 2003. Imaging spectroscopy: Earth and planetary remote sensing with the USGS Tetracorder and expert systems: *Journal of Geophysical Research: Planets*, v. 108, no. E12.
- Cogliati, S., Sarti, F., Chiarantini, L., Cosi, M., Lorusso, R., Lopinto, E., Miglietta, F., Genesisio, L., Guanter, L., and Damm, A., 2021. The PRISMA imaging spectroscopy mission: overview and first performance analysis: *Remote sensing of environment*, v. 262, p. 112499.
- Congalton, R. G., 1991. A review of assessing the accuracy of classifications of remotely sensed data: *Remote sensing of environment*, v. 37, no. 1, p. 35–46.
- Cover, T., and Hart, P., 1967. Nearest neighbor pattern classification: *IEEE transactions on information theory*, v. 13, no. 1, p. 21–27.

فضایی و پوشش گیاهی (Normalized Difference Vegetation Index-NDVI) را به خوبی شناسایی کردند، اما به دلیل رزولوشن طیفی پایین، تفکیک سنگ شناسی های مشابه مانند پریدوتیت و سربانتینیت، متابازالت و دایک های دیابازی چالش برانگیز بود. در مقابل، پریسما با ۲۳۹ باند فرایفی و رزولوشن طیفی بالا، جذب های خاص کانی ها را دقیق تر شناسایی کرد. نتایج این پژوهش تأیید می کند که داده های فرایفی با رویکرد بر پایه پیکسل به دلیل توانایی در ثبت جزئیات طیفی، برای تمایز کانی شناسی و سنگ شناسی های پیچیده مناسب تر هستند. همچنین الگوریتم SVM انتخاب مناسبی برای طبقه بندی داده های PRISMA است (Shebl et al., 2023). این یافته ها با مطالعات پیشین که بر توانایی داده های فرایفی در شناسایی کانی ها تأکید کرده اند، هم راستا است (Chen et al., 2007; Harris et al., 2010; Leverington, 2010; Li) (et al., 2014; Shebl et al., 2023). با این حال، چالش هایی مانند رزولوشن مکانی ۳۰ متر و نوفه اتمسفری در باندهای SWIR می تواند محدودیت هایی ایجاد کند. در نتیجه، انتخاب رویکرد بر پایه شیء در تصاویر چند طیفی، به دلیل در نظر گرفتن اطلاعات فضایی و بافتی افزون بر اطلاعات طیفی، تأثیر شایان توجهی بر عملکرد نهایی و دقت شناسایی کلاس های مختلف دارد.

۵- نتیجه گیری

این پژوهش با هدف نقشه برداری سنگ شناسی هم تافت افیولیتی رمشک-مختارآباد، با بهره گیری از داده های ماهواره ای سنتینل-۲ و پریسما و به کارگیری الگوریتم های یادگیری ماشین شامل شبکه عصبی (NN)، ماشین بردار پشتیبان (SVM) و نزدیک ترین همسایگی (kNN) انجام شد. نتایج این پژوهش نشان داد که رویکرد مبتنی بر پیکسل برای داده های فرایفی پریسما و رویکرد مبتنی بر شیء برای تصاویر چند طیفی سنتینل-۲، بالاترین عملکرد را در نقشه برداری سنگ شناسی ارائه می دهند. همچنین، فناوری های سنجش از دور به کار گرفته شده نقش موثری در افزایش دقت تمایز

- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., and Martimort, P., 2012. Sentinel-2: ESA's optical high-resolution mission for GMES operational services: Remote sensing of Environment, v. 120, p. 25–36.
- Eftekhar-Nezhad, J., Arshadi, S., Mahdavi, M., Morgan, K., McCall, G., and Huber, H., 1979. Fannuj Quadrangle Map 1: 250000: Geological Survey of Iran, Tehran.
- Eftekhar-Nezhad, J., Arshadi, S., Mahdavi, M., 1979, Fannuj Map, scale 1: 100,000: Geological Survey of Iran, Tehran.
- El-Omairi, M. A., and El Garouani, A., 2023. A review on advancements in lithological mapping utilizing machine learning algorithms and remote sensing data: Heliyon, v. 9, no. 9.
- Fenza, G., Gallo, M., Loia, V., Orciuoli, F., and Herrera-Viedma, E., 2021. Data set quality in machine learning: consistency measure based on group decision making: Applied Soft Computing, v. 106, p. 107366.
- Gad, S., and Kusky, T., 2007. ASTER spectral ratioing for lithological mapping in the Arabian–Nubian shield, the Neoproterozoic Wadi Kid area, Sinai, Egypt: Gondwana research, v. 11, no. 3, p. 326–335.
- Ge, W., Cheng, Q., Jing, L., Armenakis, C., and Ding, H., 2018a. Lithological discrimination using ASTER and Sentinel-2A in the Shibanjing ophiolite complex of Beishan orogenic in Inner Mongolia, China: Advances in Space Research, v. 62, no. 7, p. 1702–1716.
- Ge, W., Cheng, Q., Tang, Y., Jing, L., and Gao, C., 2018b. Lithological classification using Sentinel-2A data in the Shibanjing ophiolite complex in Inner Mongolia, China: Remote Sensing, v. 10, no. 4, p. 638.
- Ghoneim, S. M., Hamimi, Z., Abdelrahman, K., Khalifa, M. A., Shabban, M., and Abdelmaksoud, A. S., 2024. Machine learning and remote sensing-based lithological mapping of the Duwi Shear-Belt area, Central Eastern Desert, Egypt: Scientific Reports, v. 14, no. 1, p. 17010.
- Hajimohammadi, F., Arvin, M., Dargahi, S., Jafari, M. K., and Pan, Y., 2025. Volcanic stratigraphy and vesicle analysis of pillow lavas in the North Makran complexes, southeastern Iran: Implications for emplacement depth of extrusive sequences: Journal of Asian Earth Sciences, p. 106649.
- Harris, J., McGregor, R., and Budkewitsch, P., 2010. Geological analysis of hyperspectral data over southwest Baffin Island: Methods for producing spectral maps that relate to variations in surface lithologies: Canadian Journal of Remote Sensing, v. 36, no. 4, p. 412–435.
- Haykin, S., and Network, N., 2004. A comprehensive foundation: Neural networks, v. 2, no. 2004, p. 41.
- Hepner, G., Logan, T., Ritter, N., and Bryant, N., 1990. Artificial neural network classification using a minimal training set- Comparison to conventional supervised classification: Photogrammetric Engineering and Remote Sensing, v. 56, no. 4, p. 469–473.
- Hunziker, D., 2014. Magmatic and metamorphic history of the North Makran ophiolites and blueschists (SE Iran): Influence of Fe³⁺/Fe²⁺ ratios in blueschist facies minerals on geothermobarometric calculations: ETH Zurich.
- Hunziker, D., Burg, J. P., Bouilhol, P., and von Quadt, A., 2015. Jurassic rifting at the Eurasian Tethys margin: Geochemical and geochronological constraints from granitoids of North Makran, southeastern Iran: Tectonics, v. 34, no. 3, p. 571–593.
- Langford, R. L., 2015. Temporal merging of remote sensing data to enhance spectral regolith, lithological and alteration patterns for regional mineral exploration: Ore Geology Reviews, v. 68, p. 14–29.
- Leverington, D. W., 2010. Discrimination of sedimentary lithologies using Hyperion and Landsat Thematic Mapper data: a case study at Melville Island, Canadian High Arctic: International Journal of Remote Sensing, v. 31, no. 1, p. 233–260.
- Li, M., Zang, S., Zhang, B., Li, S., and Wu, C., 2014. A review of remote sensing image classification techniques: The role of spatio-contextual information: European Journal of Remote Sensing, v. 47, no. 1, p. 389–411.
- Loizzo, R., Daraio, M., Guarini, R., Longo, F., Lorusso, R., Dini, L., and Lopinto, E., 2019. Prisma mission status and perspective, in Proceedings IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium20, 19 IEEE, p. 4503–4506.
- Mather, P., and Tso, B., 2016. Classification methods for remotely sensed data, CRC press.
- McCall, G., 1985. Explanatory Text of the Minab Quadrangle Map, scale 1: 250,000: Geological Survey of Iran, Tehran.
- McCall, G.A., 2003. critique of the analogy between Archaean and Phanerozoic tectonics based on regional mapping of the Mesozoic-Cenozoic plate convergent zone in the Makran, Iran: Precambrian research, v. 127, no. 1-3, p. 5–17.
- Moslempour, M. E., Khalatbari-Jafari, M., Ghaderi, M., Yousefi, H., and Shahdadi, S., 2015. Petrology, geochemistry and tectonics of the extrusive sequence of Fannuj-Maskutan ophiolite, Southeastern Iran: Journal of the Geological Society of India, v. 85, no. 5, p. 604–618.
- Noble, W. S., 2006. What is a support vector machine?: Nature biotechnology, v. 24, no. 12, p. 1565–1567.
- Ouchra, H., Belangour, A., and Erraissi, A., 2022. A comparative study on pixel-based classification and object-oriented classification of satellite image: International Journal of Engineering Trends and Technology, v. 70, no. 8, p. 206–215.
- Pal, M., and Foody, G. M., 2010. Feature selection for classification of hyperspectral data by SVM: IEEE Transactions on Geoscience and Remote Sensing, v. 48, no. 5, p. 2297–2307.
- Pignatti, S., Acito, N., Amato, U., Casa, R., Castaldi, F., Coluzzi, R., De Bonis, R., Diani, M., Imbrenda, V., and Laneve, G., 2015. Environmental products overview of the Italian hyperspectral prisma mission: The SAP4PRISMA project, in Proceedings 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)2015, IEEE, p. 3997–4000.

- Qian, Y., Zhou, W., Yan, J., Li, W., and Han, L., 2014. Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery: *Remote sensing*, v. 7, no. 1, p. 153–168.
- Rajan Girija, R., and Mayappan, S., 2019. Mapping of mineral resources and lithological units: A review of remote sensing techniques: *International Journal of Image and Data Fusion*, v. 10, no. 2, p. 79–106.
- Roli, F., and Fumera, G., 2001. Support vector machines for remote sensing image classification, in *Proceedings Image and signal processing for remote sensing VI2001*, Volume 4170, SPIE, p. 160–166.
- Sabins, F. F., 1997. *Remote sensing laboratory manual*, Kendall/Hunt Publishing Company.
- Sabins, J., and Lulla, K., 1987. *Remote sensing: principles and interpretation*.
- Saccani, E., Delavari, M., Dolati, A., Pandolfi, L., Barbero, E., Brombin, V., and Marroni, M., 2023. Geochemistry of volcanic rocks and dykes from the Remeshk-Mokhtarabad and Fannuj-Maskutan Ophiolites (Makran Accretionary Prism, SE Iran): new constraints for magma generation in the Middle East Neo-Tethys: *Geosystems and Geoenvironment*, v. 2, no. 3, p. 100140.
- Saccani, E., Delavari, M., Dolati, A., Pandolfi, L., Barbero, E., Tassinari, R., and Marroni, M., 2022. Geochemistry of basaltic blueschists from the Deyader Metamorphic Complex (Makran Accretionary Prism, SE Iran): new constraints for magma generation in the Makran sector of the Neo-Tethys: *Journal of Asian Earth Sciences*, v. 228, p. 105141.
- Samimi Nadim, M., and Hajizad Kabir, Y., 1982, Ramak Map, scale 1: 100,000: Geological Survey of Iran, Tehran.
- Shayeganpour, S., Tangestani, M. H., and Gorsevski, P. V., 2021. Machine learning and multi-sensor data fusion for mapping lithology: A case study of Kowli-kosh area, SW Iran: *Advances in Space Research*, v. 68, no. 10, p. 3992–4015.
- Shebl, A., Abriha, D., Fahil, A. S., El-Dokouny, H. A., Elrasheed, A. A., and Csámer, Á., 2023. PRISMA hyperspectral data for lithological mapping in the Egyptian Eastern Desert: Evaluating the support vector machine, random forest, and XG boost machine learning algorithms: *Ore Geology Reviews*, v. 161, p. 105652.
- Singh, A., and Harrison, A., 1985. Standardized principal components: *International journal of remote sensing*, v. 6, no. 6, p. 883–896.
- Sun, T., Chen, F., Zhong, L., Liu, W., and Wang, Y., 2019. GIS-based mineral prospectivity mapping using machine learning methods: A case study from Tongling ore district, eastern China: *Ore Geology Reviews*, v. 109, p. 26–49.
- Tripathi, P., and Garg, R. D., 2021. Feature extraction of DESIS and PRISMA hyperspectral remote sensing datasets for geological applications: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 44, p. 169–173.
- Van der Meer, F. D., Van der Werff, H. M., Van Ruitenbeek, F. J., Hecker, C. A., Bakker, W. H., Noomen, M. F., Van Der Meijde, M., Carranza, E. J. M., De Smeth, J. B., and Woldai, T., 2012. Multi-and hyperspectral geologic remote sensing: A review: *International journal of applied Earth observation and geoinformation*, v. 14, no.1, p. 112–128.
- Vangi, E., D'Amico, G., Francini, S., Giannetti, F., Lasserre, B., Marchetti, M., and Chirici, G., 2021. The new hyperspectral satellite PRISMA: Imagery for forest types discrimination: *Sensors*, v. 21, no. 4, p. 1182.
- Whiteside, T. G., Boggs, G. S., and Maier, S. W., 2011. Comparing object-based and pixel-based classifications for mapping savannas: *International Journal of Applied Earth Observation and Geoinformation*, v. 13, no. 6, p. 884–893.
- Willhauck, G., Schneider, T., De Kok, R., and Ammer, U., 2000. Comparison of object oriented classification techniques and standard image analysis for the use of change detection between SPOT multispectral satellite images and aerial photos, in *Proceedings Proceedings of XIX ISPRS congress2000*, Volume 33, Amsterdam: IAPRS, p. 35–42.