



## Visual Modeling of Mineral Potential Exploration Using Support Vector Machine

Mandana Tahmooresi<sup>1\*</sup>, Behnam Babaei<sup>2</sup>, Saeed Dehghan<sup>3</sup>

1. PhD student in Mining Engineering-Mineral exploration, Mining department, Mahallat Branch, Islamic Azad University, Mahallat, Iran, Mandana\_tahmooresi@yahoo.com
2. Assistant Professor, Mining department, Mahallat Branch, Islamic Azad University, Mahallat, Iran, Dr.Behnam\_babaei@yahoo.com
3. Assistant Professor, Mining department, Mahallat Branch, Islamic Azad University, Mahallat, Iran, Dr.Saeed\_dehghan@yahoo.com

Received: 2022/07/15 - Accepted: 2022/11/08

### Abstract

With the advent of big data in geosciences, exploration studies have entered new dimensions. Big data means high-resolution image information. Since the data in geosciences have an enormous volume and variety, it is necessary to use big data analysis approaches in this field. This study investigates the application of support vector machines in machine vision in mineral potential exploration. In recent years, image classification has attracted much attention in machine vision, whose processes include pre-processing and segmentation, feature extraction, and related class identification. In this study, geological maps and remote sensing images are used to model the exploration of mineral potentials, Alexnet architecture is used to extract features automatically, and field information is used to learn the algorithm. In the next step, a support vector machine is used for modeling in order to identify structure factors in the occurrence probability of mineral potentials. Algorithms and evaluation indicators are programmed in MATLAB environment at each stage. The accuracy obtained using this method is 71% on the test data. According to the previous study conducted by the authors in identifying mineralization structures, the average accuracy of image data classification using convolutional neural network algorithms is 65%, the spectral angle mapper method in identifying alteration zones is 70%, and applying filters in identifying faults is 28%. As can be seen, the technique used in this research is highly accurate. Its advantages include reducing costs and speeding up the decision-making processes.

### Keywords

Visual modeling, Mineral potential exploration, Support vector machine, Gonabad, Iran.

---

\* Corresponding Author



## 1- Introduction

This research investigates the efficiency of support vector machines (SVM) in machine vision. Considering that in the previous study [7], convolutional neural network (CNN) was used to detect geological structures, and also its integration with the continuous genetic algorithm on image data in Gonabad region, in this research, SVM for visual modeling is used and then compared the accuracies of these two methods in the field of machine learning.

Feature extraction is an essential step in image processing that presents the raw image in smaller dimensions to facilitate decision-making, such as pattern recognition and object identification [2].

Pattern recognition leads to the discovery of classes in a data set. Features represent the distinctive information retrieved from the data that helps to identify different classes. Classification can be expressed by differentiating the data into other classes to which the data belongs [4].

In most cases, CNN is used to extract useful image features automatically, and due to the positive performance of deep learning in image processing, it is used to analyze unstructured data such as image classification [8].

The SVM algorithm has been developed in Cortes and Vapnik's (1995) statistical theory framework. It has been successfully used in many applications, including time series forecasting (Fernandez, 1999), face recognition (Tefas et al., 1999), and biological data processing for medical diagnosis (Veropoulos et al., 1999). Their theoretical foundations and experimental success require more research on the characteristics and applications of this method [3].

Chen et al. (2020) pointed out that big data and artificial intelligence (AI) have provided opportunities for many applications in geological sciences. Nevertheless, the methods and objectives are still in the initial stages, scattered, and lacking an integrated theoretical and application framework [1].

## 2- Methods

Considering the importance of the region structure in the modeling of mineral exploration, this study investigates the performance of intelligent algorithms in identifying structures. The basis of this research is visual modeling and includes two stages: feature extraction and classification. The network's input is the pixel vectors of the images, and the network's output is the pixel vectors' label.

The architecture used for feature extraction in this study is AlexNet. AlexNet is a deep convolutional neural network that identifies and classifies color images. After applying several layers of convolution and pooling, the input pixel vector is converted into a feature vector, and thus, spectral information is extracted in the input pixel vector.

A support vector machine is used to classify and model the features extracted in this research. In other words, the goal is to use SVM in machine vision. SVM is one of the most powerful machine learning algorithms [5] that creates a decision boundary between two classes and is characterized by a particular subset of training data called support vectors. The advantage of SVM compared to the perceptron neural network is that it creates a unique decision boundary with the maximum margin, and the version using kernel functions is very effective in learning speed [6].

Considering the importance of identifying the alteration zones and tectonics of the region in exploration modeling, in this research, structure identification is studied using a support vector machine. For this purpose, the relevant algorithms in the MATLAB environment are programmed. To identify the alteration zones and the fault orientation in the region, Aster and Landsat 8 (OLI) data are used, respectively. Neural network learning is done using data related to field studies. At first, the images are segmented into blocks with the same size in each classification, which is programmed in MATLAB to do it.

### 3- Findings and Argument

Remote sensing is critical in geological studies; this technology can provide valuable information, including identifying alteration zones and lineaments.

Alterations occur due to the interactions and effects of magmatic fluids and hydrothermal solutions with the surrounding rocks, which cause geochemical, mineralogical, and texture changes. Alteration zones can be related to economic mineralization, so identification of alteration zones is essential.

Field evidence and analysis results of mineralized samples in the Gonabad region show that the most critical alteration zones in the region are phyllic, propylitic, argillic, siliceous, and iron oxide alteration. The index minerals of the phyllic alteration zone are illite, muscovite and sericite, propylitic alteration, chlorite, epidote and calcite and argillic alteration, alunite, kaolinite and montmorillonite.

Another essential structure to be investigated is fault zones. The results of geochemical investigations in the region show that mineralization has occurred as a result of infiltration of magmatic fluids into fractures and along dykes.

This research uses a support vector machine to identify alteration zones on Aster data. Aster is a sensor system with a unique combination of comprehensive spectral coverage and high spatial resolution. ASTER provides high-resolution images in 14 spectral bands from the visible to the thermal infrared (TIR) regions of the electromagnetic spectrum. As mentioned above, the algorithm was trained using field study results. Finally, the accuracy of this method is compared with other traditional and neural network methods used to identify alteration zones in the region.

Also, due to the high spatial resolution in the panchromatic band, tectonic studies are performed using Landsat (8) images. This research uses the SVM on the Landsat (8) data to recognize fault orientations. The data from the field studies that led to the preparation of the geological maps with the scale of 1:250,000 and 1:100,000 Geological Survey and Mineral Exploration of Iran is used to learn the algorithm.

### 4- Conclusions

Traditional classification approaches are weakly focused on image classification due to the large dimensions of the feature space. This study shows that the support vector machine algorithm can be well generalized on image classification problems. The results of the studies show that the average accuracy of image data classification using convolutional neural networks and support vector machine algorithms is 65% and 71%, respectively.

In comparison, in machine learning algorithms in visual modeling, especially in cases where human error is possible, projects have time and cost limitations. On the other hand, the studied area is located in inaccessible areas. The field study is not possible, but it can have high accuracy for modeling mineral potential exploration.

### References

1. Chen, Lirong; Wang, Liang; Miao, Jinli; Gao, Huan; Zhang, Yue; Yao, Yao; Bai, Ming; Mei, Lisi; and He, Jing; (2020); "Review of the Application of Big Data and Artificial Intelligence in Geology." Journal of Physics: Conference Series. See also URL <https://doi.org/10.1088/1742-6596/1684/1/012007>.
2. Elnemr, Heba Ahmed; Zayed, Nourhan Mohamed; and Fakhreldein, Mahmoud Abdelmoneim; (2015); "Handbook of research on emerging perspectives in intelligent pattern recognition, analysis, and image processing, feature extraction techniques: Fundamental concepts and survey." See also URL <https://doi.org/10.4018/978-1-4666-8654-0>.
3. Evgeniou, Theodoros; and Pontil, Massimiliano; (2001); "Workshop on support vector

- 
- machines: Theory and applications. Center for Biological and Computational Learning, and Artificial Intelligence Laboratory*". See also URL [https://doi.org/ 10.1007/3-540-44673-7\\_12](https://doi.org/10.1007/3-540-44673-7_12).
4. Ladwani, Vandana M.; (2017); "*Support vector machines and applications.*" See also URL: [https://doi.org/ 10.4018/978-1-5225-2498-4.ch012](https://doi.org/10.4018/978-1-5225-2498-4.ch012).
  5. Osuna, Edgar; Freund, Robert; Girosi, Federico; (1997); "*Training support vector machines: an application to face detection.*" Computer society conference on computer vision and pattern recognition, See URL [http://dx.doi.org/10.1109/ CVPR.1997. 609310](http://dx.doi.org/10.1109/CVPR.1997.609310).
  6. Sahbi, Hichem; and Geman, Donald; (2006); "*A Hierarchy of Support Vector Machines for Pattern Detection.*" Journal of Machine Learning Research, 7 (2006): 2087-2123.
  7. Tahmooresi, Mandana; Babaei, Behnam; and Dehghan, Saeed; (2022); "Mineral exploration modeling by convolutional neural network and continuous genetic algorithm: a case study in Khorasan Razavi, Iran." Arabian Journal of Geosciences See URL [https:// doi .org /10.1007/s12517-022-10889-7](https://doi.org/10.1007/s12517-022-10889-7).
  8. You, Changhui; Zheng, Hong; Guo, Zhongyuan; Wang, Tianyu; and Wu, Xiongbing; (2021); "*Multiscale content-independent feature fusion network for source camera identification.*" Appl. Sci. 11(6752): 1-13.

مقاله پژوهشی

## مدل سازی تصویری اکتشاف پتانسیل های معدنی با استفاده از ماشین بردار پشتیبان

ماندانا طهمورثی<sup>۱\*</sup>، بهنام بابایی<sup>۲</sup>، سعید دهقان<sup>۳</sup>

۱. دانشجوی دکترای مهندسی معدن-اکتشاف مواد معدنی، گروه معدن، دانشگاه آزاد اسلامی واحد محلات، mandana\_tahmooresi@yahoo.com  
۲. استادیار، گروه معدن، دانشگاه آزاد اسلامی واحد محلات، dr.behnam\_babaei@yahoo.com  
۳. استادیار، گروه معدن، دانشگاه آزاد اسلامی واحد محلات، dr.saeed\_dehghan@yahoo.com

دریافت: ۱۴۰۱/۰۴/۲۴ - پذیرش: ۱۴۰۱/۱۰/۲۹

### چکیده

با ظهور داده های بزرگ در علوم زمین، مطالعات اکتشافی وارد ابعاد جدیدی شده است. منظور از داده های بزرگ اطلاعات تصویری با وضوح بالا است. از آنجا که این داده ها در علوم زمین حجم و تنوع بسیار زیادی دارند، استفاده از رویکردهای تجزیه و تحلیل داده های بزرگ در این حوزه ضروری است. در این مطالعه کاربرد ماشین بردار پشتیبان در بینایی ماشین در حوزه اکتشاف پتانسیل های معدنی مورد بررسی قرار می گیرد. در سال های اخیر طبقه بندی تصاویر توجه زیادی را در بینایی ماشین به خود معطوف کرده است که فرآیند آن شامل پیش پردازش و قطعه بندی، استخراج ویژگی و شناسایی کلاس مربوط است. در این مطالعه برای مدل سازی اکتشاف پتانسیل های معدنی از نقشه های زمین شناسی و تصاویر دورسنجی و از معماری الکسنت برای استخراج خودکار ویژگی ها استفاده شده و برای یادگیری الگوریتم، اطلاعات میدانی به کار گرفته می شود. در گام بعد برای مدل سازی به منظور شناسایی عوامل ساختاری در احتمال وقوع پتانسیل های معدنی، از ماشین بردار پشتیبان استفاده می شود. الگوریتم ها و شاخص های ارزیابی در هر مرحله در محیط متلب برنامه نویسی می شود. میزان دقت بدست آمده با استفاده از این روش، روی داده های آزمایشی ۷۱ است. با توجه به مطالعه قبلی انجام شده توسط نویسندگان در شناسایی ساختارهای کانی زایی، متوسط دقت طبقه بندی داده های تصویری با استفاده از الگوریتم های شبکه عصبی کانولوشن ۶۵ درصد، روش نقشه بردار زاویه طیفی در شناسایی زون های آلتراسیون ۷۰ درصد و اعمال فیلترها در شناسایی گسل ها ۲۸ درصد است. روش مورد استفاده در این تحقیق دقت بالایی دارد و از مزایای آن می توان به کاهش هزینه ها و افزایش سرعت در فرآیند تصمیم گیری اشاره کرد.

### کلمات کلیدی

مدل سازی تصویری، اکتشاف پتانسیل های معدنی، ماشین بردار پشتیبان، گناباد، ایران

## ۱- مقدمه

استخراج ویژگی فرآیندی است که تصویر خام را در ابعاد کمتر ارایه می‌کند تا اینکه در تصمیم‌گیری‌هایی همچون تشخیص الگو و شناسایی اشیا تسهیل شود. یافتن و استخراج ویژگی‌های قابل اعتماد و متمایزکننده همواره یک گام مهم برای انجام پردازش تصویر است [۱۲]. ویژگی‌ها به صورت تابعی از متغیرهای اصلی قابل اندازه‌گیری تعریف می‌شوند و تعیین‌کننده یک شی‌اند و برای طبقه‌بندی و یا تشخیص الگو مورد استفاده قرار می‌گیرند [۵]. روش‌های زیادی برای استخراج ویژگی‌ها استفاده می‌شود که مبتنی بر ویژگی‌های هندسی، آماری، بافت و رنگ است [۲۷]. برای استخراج ویژگی‌های هندسی نیاز به تصویری با قابلیت قطع‌بندی و اعمال فیلترهای مورفولوژیکی برای حذف نویزها است که بتواند به طور مستقل برچسب‌گذاری و پردازش شود [۶ و ۴۰]. در مورد استخراج ویژگی‌های آماری، ویژگی‌های مرتبه اول شاخص‌های آماری مربوط به یک پیکسل است. هیستوگرام شدت روشنایی در این مرتبه قرار دارد ولی در مرتبه دوم، پیکسل‌های همسایه نیز در نظر گرفته می‌شود [۱۹]. بافت، ویژگی است که برای تقسیم و طبقه‌بندی تصاویر استفاده می‌شود و اطلاعاتی را در مورد چیدمان فضایی رنگ‌ها یا شدت روشنایی در تصویر ارایه می‌دهد. بافت یک الگوی تکراری از تغییرات محلی در شدت روشنایی تصویر است. چنانچه بر اساس ویژگی‌های شدت پیکسل در تکسل باشد، تن و در صورتی که نشان‌دهنده ارتباط فضایی بین تکسل‌ها باشد، ساختار گویند [۲ و ۴۳]. رنگ متداول‌ترین ویژگی است و به دلیل شهودی بودن آن در مقایسه با سایر ویژگی‌ها و اطلاعات، مهم‌تر و استخراج آن به سهولت انجام می‌شود.

در بیشتر موارد برای استخراج ویژگی‌های مفید تصویر به صورت خودکار، شبکه عصبی کانولوشن<sup>۱</sup> مورد استفاده قرار می‌گیرد و به دلیل عملکرد مثبت یادگیری عمیق در پردازش تصویر، از آن برای تجزیه و تحلیل داده‌های بدون ساختار همچون طبقه‌بندی تصویر استفاده می‌شود [۴۴].

کنگ و لی<sup>۲</sup> بیان کردند تصاویر آموزش شبکه عصبی CNN تاثیر زیادی روی مدل‌سازی ذخیره معدنی می‌گذارد که مبین همبستگی فضایی و زمین‌آمار چندنقطه‌ای است، برخلاف واریوگرام در زمین‌آمار که به صورت ریاضی و دو نقطه‌ای

تعریف می‌شود [۲۱]. ژنگ و همکاران<sup>۳</sup> از شبکه عصبی CNN برای بالا بردن دقت عملکرد طبقه‌بندی تصاویر امواج لرزه استفاده کردند [۴۵]. چن و همکاران<sup>۴</sup> نشان دادند تفسیر خودکار ساختار سنگ دقت ارزیابی خطر زمین‌شناسی دهانه تونل را بهبود می‌بخشد همچنین علاوه بر ورود اطلاعات انواع مختلف واحدهای سنگی منطقه، شرایط مختلف برجا (مانند دما، رطوبت و مراحل تشکیل) نیز باید به مدل آموزش داده شود [۷].

تشخیص الگو منتج به کشف کلاس‌ها در یک مجموعه داده می‌شود. ویژگی‌ها، اطلاعات متمایز بازمی‌یابی شده از داده‌ها را نشان می‌دهند که به شناسایی کلاس‌های مختلف کمک می‌کند. طبقه‌بندی را می‌توان به تمایز داده‌ها به کلاس‌های مختلف که داده‌ها به آن‌ها تعلق دارد، بیان کرد [۲۴].

الگوریتم ماشین بردار پشتیبان<sup>۵</sup> در چارچوب تئوری آماری کورتکس و وپنیک<sup>۶</sup> توسعه پیدا کرده و با موفقیت در بسیاری از کاربردها، از جمله پیش‌بینی سری‌های زمانی (فرناندز<sup>۷</sup>)، شناسایی چهره (تفاس و همکاران<sup>۸</sup>) و پردازش داده‌های بیولوژیکی برای تشخیص پزشکی (وروپولوس و همکاران<sup>۹</sup>) مورد استفاده قرار گرفته است. مبانی نظری و موفقیت تجربی آن موجب شد، تحقیقات بیشتری در مورد ویژگی و همچنین کاربردهای این روش به عمل آید [۱۴].

در ادامه به برخی تحقیقات انجام شده در زمینه مدل‌سازی پتانسیل‌های معدنی به‌روش هوشمند اشاره می‌شود.

ان وایلا<sup>۱۰</sup> بیان کرد هوش مصنوعی به ویژه یادگیری ماشین فرصت‌های اقتصادی سودمندی را در زمینه علوم زمین و فرآوری مواد معدنی فراهم می‌کند که می‌توان به اکتشاف ذخایر معدنی با استفاده از شبکه عصبی CNN اشاره کرد که یکی از الگوریتم‌های یادگیری عمیق است و از تصاویر به عنوان ورودی استفاده می‌کند، وی از CNN برای مدل‌سازی معکوس داده‌های ژئوفیزیک با هدف شناسایی کانی‌سازی در مکان‌های مختلف، خواه در مقیاس محلی و یا منطقه‌ای، استفاده کرد [۳۰]. چن و همکاران<sup>۱۱</sup> به این موضوع اشاره کردند که هوش

<sup>3</sup> Zhang et al.

<sup>4</sup> Chen, Jiayao (2021)

<sup>5</sup> Support Vector Machine (SVM)

<sup>6</sup> Cortez and Vapnik

<sup>7</sup> Fernandez (1999)

<sup>8</sup> Tefas et al. (1999)

<sup>9</sup> Veropoulos et al. (1999)

<sup>10</sup> Nwaila

<sup>11</sup> Chen, Lirong (2020)

<sup>1</sup> Convolutional neural network (CNN)

<sup>2</sup> Kang and Lee

پیشرفت‌های اخیر در الگوریتم‌های یادگیری ماشین به محققان این امکان را داده است تا از ظرفیت روش‌های یادشده در برآورد ذخایر معدنی استفاده کنند. مدل‌های یادگیری ماشین می‌توانند چندین پارامتر زمین‌شناسی را در خود جای دهند و روابط غیرخطی پیچیده بین آن‌ها را تقریب بزنند و عملکرد برتری نسبت به روش‌های معمولی نشان دهند [۱۱]. ناتوانی و همکاران<sup>۳</sup> در زمینه اکتشاف ژئوشیمیایی و متالوژی کمان ماگمایی و شناسایی سازندهای ذخیره مس پورفیری با در نظر گرفتن مجموع داده‌های مربوط به سنگ‌های دربرگیرنده از روش‌های یادگیری ماشین استفاده کردند، آن‌ها هدف از این مطالعه را امکان استفاده از روش‌های یادشده برای تمایز نمونه‌های مرتبط با ذخایر مس پورفیری و نمونه‌هایی که با کانی‌سازی منطقه مرتبط نیستند، بیان کردند که در نهایت منجر به اکتشاف مس پورفیری با دقت بالا نسبت به روش‌های آمار دو متغیره شد [۲۸]. طهمورثی و همکاران از SVM و CNN و همکاران با الگوریتم ژنتیک پیوسته، زمین‌آمار (کریجینگ) برای مدل‌سازی عددی اکتشاف پتانسیل‌های معدنی استفاده کردند، همچنین برای مدل‌سازی زون‌ها و ساختارهای آنومالی روش CNN و تجمیع آن با الگوریتم ژنتیک پیوسته را به کار بردند. نتایج بدست آمده نشان می‌دهد روش‌های یادگیری ماشین دقت بالایی دارد [۳۶، ۳۷، ۳۸ و ۳۹].

در مورد نقاط قوت و ضعف روش‌های SVM و CNN می‌توان به موارد زیر اشاره کرد:

مزیت اصلی CNN این است که به طور خودکار فیلترها را روی سیگنال‌های ورودی اعمال و ویژگی‌های مهم را شناسایی می‌کند و ویژگی‌های متمایز هر کلاس را یاد می‌گیرد. از دیگر مزایای اصلی این روش توانایی جمع‌آوری و تولید داده از اطلاعات قبلی است [۳]. از این روش بیشتر در پردازش تصویر استفاده می‌شود. رویکردهای سنتی طبقه‌بندی تصویر بر اساس ویژگی‌های مهندسی و به‌طور دستی و فرآیند آن پیچیده، زمان‌بر و پرهزینه است. هر زمان که مساله یا مجموعه داده‌ها تغییر کند، فرآیند نیز تغییر می‌کند و به دانش متخصصان بستگی دارد و قابلیت تعمیم ندارد. ولی در CNN نیازی به مهندسی ویژگی نیست و ویژگی‌های مهم به‌طور خودکار از طریق فرآیند آموزش استخراج می‌شود [۲۰]. نقطه ضعف اصلی CNN بالا بودن زمان مورد نیاز برای یادگیری مجموعه داده‌های بزرگ است. از دیگر مزایای CNN استفاده از

مصنوعی راهکار بسیاری از مسایل در علوم زمین‌شناسی به ویژه در مورد داده‌های بزرگ است. با این وجود، روش‌ها و اهداف مبتنی بر هوش مصنوعی هنوز در مراحل ابتدایی و فاقد چارچوب نظری و کاربردی یکپارچه است [۸]. رحیمی و همکاران تعداد مکان‌های فاقد ذخیره را برای یادگیری ماشین یک موضوع چالش‌برانگیز بیان کردند که بر کارایی الگوریتم‌های نظارت شده در مدل‌سازی اکتشاف مواد معدنی تاثیر می‌گذارد. برای این منظور تاثیر تعداد مناطق دارای ذخیره و فاقد آن را بر اثربخشی مدل‌های اکتشافی مورد بررسی قرار دادند [۳۲]. شیرمارد و همکاران<sup>۱</sup> بیان کردند کاهش ذخایر معدنی جدید کشف شده و افزایش تقاضا برای مواد معدنی مختلف در سال‌های اخیر، زمین‌شناسان اکتشافی را بر آن داشته است تا به دنبال روش‌های کارآمدتر و نوآورانه‌تر برای پردازش انواع داده‌های مختلف در هر یک از مراحل اکتشاف پتانسیل‌های معدنی باشند. آن‌ها تاکید کردند که در هر تحقیق به عنوان گام اول، باید ویژگی‌های مختلف زمین‌شناسی منطقه مورد مطالعه از جمله واحدهای سنگی، زمین‌شناسی، انواع دگرسانی، ساختارها و کانی‌های شاخص، برای کمک به هدف‌گذاری و تصمیم‌گیری در مورد ذخایر معدنی جمع‌آوری شود. از جمله اطلاعات مورد استفاده داده‌های سنجش از دور است، افزایش سریع حجم داده‌ها از سکوه‌های مختلف، زمین‌شناسان را ملزم به توسعه روش‌های پیشرفته، نوآورانه و قوی پردازش داده‌ها کرده است. یکی از این روش‌ها، یادگیری ماشین است که می‌تواند به پردازش طیف گسترده‌ای از مجموعه داده‌های سنجش از دور کمک کند. با توجه به اینکه طیف مواد معدنی منحصر به فرد است، این امر منجر به ایجاد روش‌های مختلفی برای تطبیق طیف‌های پیکسل تصویر با طیف‌های کتابخانه‌ای و میدانی و تفکیک طیف‌های پیکسلی مخلوط به طیف‌های عضو نهایی خالص شده است. به عنوان مثال، وجود مواد معدنی همچون کانی‌های رسی (مانند کائولینیت و اپلیت)، کانی‌های سولفاتی (مانند آلونیت)، کانی‌های کربناته (مانند کلسیت و دولومیت)، اکسیدهای آهن (مانند هماتیت و گوتیت) و سیلیس (کوارتز) معرف رخساره‌های دگرسانی (پروپیلیتی، آرژیلیک و نظایر آن) بوده است و شاخص‌های کلیدی نهشته‌های اپی‌ترمال و پورفیری‌اند [۳۵]. داماکور دیوپی و آریا<sup>۲</sup> بیان کردند برآورد ذخایر معدنی شامل تعیین عیار و تناژ یک کناسار معدنی با استفاده از روش‌های مختلفی انجام می‌شود. روش‌های تخمین مرسوم شامل تکنیک‌های هندسی و زمین‌آماري‌اند. با این حال،

<sup>1</sup> Shirmard et al.

<sup>2</sup> Dumakor-Dupey and Arya

<sup>3</sup> Nathwani et al.

## ۲- مواد و روش‌ها

### ۲-۱- موقعیت جغرافیایی و زمین‌شناسی منطقه مورد مطالعه

با توجه به امکان گردآوری داده‌های زمین‌شناسی و دورسنجی در منطقه گناباد واقع در استان خراسان رضوی، الگوریتم مدل‌سازی تصویری اکتشاف پتانسیل‌های معدنی با استفاده از ماشین‌بردار پشتیبان در این منطقه مورد بررسی قرار می‌گیرد. این منطقه شامل دو زون به نام‌های هلالی با مساحت ۵۰۴ کیلومتر مربع در شمال غرب و آهنی با مساحت ۴۹۱ کیلومتر مربع در جنوب شرق (شکل ۱) است. منطقه مورد بررسی دارای واحدهای سنگی با سن پالئوزوئیک، مزوزوئیک و سنوزوئیک است، واحدهای آذرین درونی و بیرونی که عمدتاً در دوران سنوزوئیک تشکیل شده است حاصل از فوران ماگمایی با ترکیب مافیک، حدواسط و یا اسیدی است که منجر به ایجاد زون‌های دگرسانی در منطقه شده است. دگرسانی‌های فیلیک، پروپیلیتیک، آرژیلیک، سیلیسی و آهنی آلتراسیون‌های غالب در منطقه‌اند. با توجه به ارتباط زون‌های دگرسانی و کانی‌زایی، شناسایی زون‌های دگرسانی همواره نظر زمین‌شناسان را به خود جلب کرده است. سازند شمشک (ژوراسیک پیشین) در زون آهنی، بیشترین گسترش را در منطقه دارد. سازند شمشک در منطقه از سه عضو آتشفشانی، توده‌های شیلی، ماسه‌سنگ، سنگ‌آهک و شیل سیاه و سنگ‌های دگرگونی شامل کوارتزیت، اسلیت و فیلیت تشکیل شده است. طبق مستندات موجود واحدهای رسوبی سازند شمشک در محیط کم ژرفای دریایی نهشته شده است، علت وجود سنگ‌های دگرگونی را می‌توان به دلیل وجود دایک‌ها و گسل‌های متعدد در منطقه و نفوذ سیالات ماگمایی به داخل شکستگی‌ها بیان کرد که در برخی محل‌ها باعث ایجاد دگرسانی و کانی‌سازی شده است.

### ۲-۲- معرفی روش

با توجه به اهمیت ساختار منطقه در مدل‌سازی اکتشاف پتانسیل‌های معدنی در این مطالعه عملکرد الگوریتم‌های هوشمند در شناسایی ساختارها مورد بررسی قرار می‌گیرد. مبنای این تحقیق مدل‌سازی تصویری و شامل دو مرحله استخراج ویژگی و طبقه‌بندی است. ورودی شبکه بردارهای پیکسلی تصاویر و خروجی سیستم برچسب بردارهای پیکسلی است.

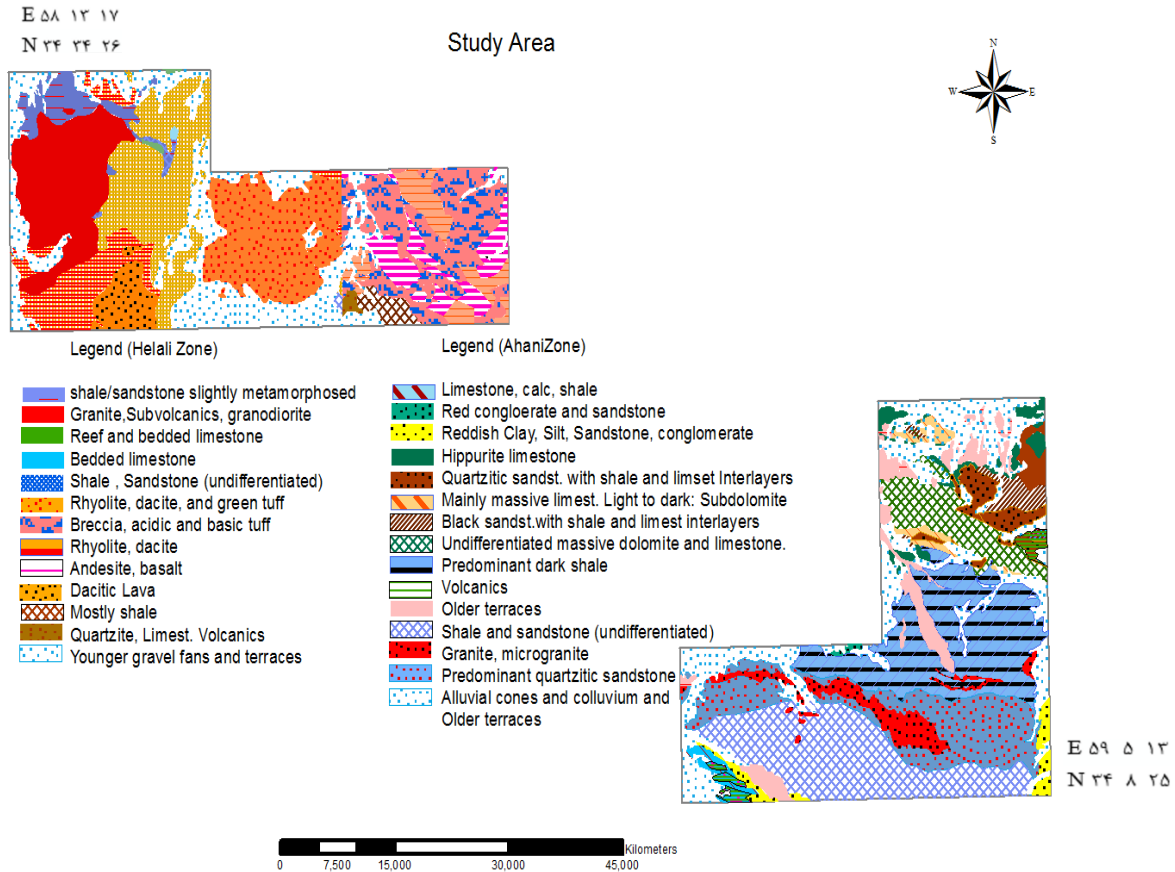
روش‌های افزایش داده‌ها است ولی برچسب‌گذاری مناسب داده‌ها باید توسط متخصصان انجام شود. در بسیاری از کارهای تحقیقاتی با معماری CNN، یادگیری انتقالی به کار گرفته می‌شود به طوری که از دانش موجود مدل‌های از پیش آموزش دیده شده برای بالابردن کارایی یادگیری استفاده می‌شود. هنگامی که به دلیل داشتن مجموعه داده‌های آموزشی کوچک یا پیچیده امکان آموزش شبکه از ابتدا وجود نداشته باشد با استفاده از وزن‌های مدل از پیش آموزش داده شده، مقداردهی اولیه انجام می‌شود. شبکه‌های عصبی کانولوشن از پیش آموزش دیده شده، مدلهایی‌اند که قبلاً بر روی مجموعه داده‌ها با تعداد کلاس‌های متفاوت آموزش دیده‌اند. سپس این مدل‌ها بر مجموعه داده‌های مورد مطالعه تطبیق داده می‌شوند [۲۰].

عدم توانایی در ایجاد زاوایی دید متفاوت از تصاویر از نقاط ضعف طبقه‌بندی‌کننده‌های SVM است. با این حال اجرای لایه اتصال کامل با چندین لایه پنهان می‌تواند بر این امر غلبه کند [۱۸]. از مزایای SVM می‌توان به عملکرد خوب آن در صورت نداشتن اطلاع در مورد داده‌ها، اشاره کرد. حتی در مورد داده‌های بدون ساختار و نیمه‌ساختار یافته مانند متن و تصاویر این روش به خوبی عمل می‌کنند. توابع کرنلی قدرت واقعی را به SVM می‌دهد. با یک تابع کرنل مناسب، می‌توان مسایل پیچیده را حل کرد. این روش روی داده‌هایی با ابعاد بالا نیز عملکرد خوبی دارد. مدل‌های SVM در عمل تعمیم خوبی دارند و مشکل بیش‌برازش در آن کمتر رخ می‌دهد. SVM در مقایسه با شبکه‌های عصبی ساده (ANN)، نتایج بهتری ارائه می‌دهند. از معایب SVM این است که انتخاب یک تابع کرنل مناسب، آسان نیست. زمان آموزش برای مجموعه داده‌های بزرگ طولانی و تنظیم دقیق فرآیندهای SVM<sup>۱</sup> نیز چندان آسان نیست [۱].

در این تحقیق هدف بررسی کارایی ماشین‌بردار پشتیبان در بینایی ماشین است. با توجه به اینکه در تحقیق قبلی [۳۹]، برای تشخیص ساختارهای زمین‌شناسی از شبکه عصبی کانولوشن و نیز تجمیع آن با الگوریتم ژنتیک پیوسته بر روی داده‌های تصویری در منطقه گناباد استفاده شده است، در این تحقیق ماشین‌بردار پشتیبان برای مدل‌سازی تصویری اکتشافی به کار گرفته می‌شود تا دقت این دو روش در حوزه یادگیری ماشین مورد مقایسه قرار گیرد.

<sup>۱</sup> Hyperparameters





شکل ۱- نقشه زمین شناسی منطقه مورد مطالعه

فرآیند CNN شامل لایه های کانولوشن و ادغام<sup>۳</sup> است و با انباشت چندین لایه کانولوشن و ادغام، معماری عمیق ساخته می شود. ابتدا لایه کانولوشن معرفی می شود. مقدار نرون  $v_{ij}^x$  در موقعیت  $x$  از نقشه ویژگی  $j$ th در لایه  $i$ th طبق رابطه ۱ و ۲ است:

$$v_{ij}^x = g(b_{ij} + \sum_m \sum_{p=0}^{P_{i-1}} w_{ijm}^p v_{(i-1)m}^{x+p}) \quad (1)$$

$$g(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

که در آن:

$m$ : نقشه ویژگی در لایه قبلی  $(i-1)$ th را متصل شده به نقشه ویژگی جاری نشان می دهد.

$w_{ijm}^p$ : وزن موقعیت  $p$  در نقشه ویژگی  $m$ th

$p_i$ : عرض کرنل

$b_{ij}$ : بایاس نقشه ویژگی  $j$ th در لایه  $i$ th

هر لایه ادغام به لایه کانولوشن قبل مربوط می شود. نرون در لایه ادغام بخشی از لایه کانولوشن را ترکیب می کند. متداول ترین عملیات، ادغام بیشینه است که به صورت رابطه ۳ تعریف می شود:

معماری مورد استفاده برای استخراج ویژگی در این مطالعه الکسنت است. الکسنت یک شبکه عصبی کانولوشن عمیق است که برای شناسایی و طبقه بندی تصاویر رنگی طراحی شده است. بردار پیکسل ورودی بعد از اعمال چندین لایه کانولوشن و ادغام به بردار ویژگی تبدیل و بدین ترتیب اطلاعات طیفی در بردار پیکسل ورودی استخراج می شود. اصول کلی این معماری به شرح زیر است [۹]:


الکس کریژوسکی و همکاران<sup>۱</sup> مدل CNN عمیق تر و وسیع تری را در مقایسه با لی نت پیشنهاد دادند که معماری پیچیده تری داشت. از معماری الکسنت با توجه به استفاده از GPU، تابع فعال سازی<sup>۲</sup> ReLU، روش منظم سازی به نام حذف نرونی و افزایش داده ها، نتایج موفقیت آمیزی بدست آمد. قدرت CNN بستگی به وزن های مناسب شبکه دارد که به وسیله الگوریتم پس انتشار خطا یادگیری می شوند. مدل های از پیش آموزش دیده شده همچون لی نت و الکسنت قبلا روی مجموعه داده های (عظیم) آموزش دیده اند و وزن ها و بایاس های اولیه خود را به همراه دارند.

<sup>1</sup> Alexnet Krizhevsky

<sup>2</sup> Rectified linear units


<sup>3</sup> Pooling

فعال ساز غیرخطی تانژانت هیپربولیک یک روش معمول برای یادگیری شبکه عصبی است ولی الکسنت نشان داد که استفاده از تابع غیرخطی رلو (منحنی پیوسته شکل ۲) موجب آموزش سریع تر CNN می شود. الکسنت می تواند کاهش نرخ خطای ۲۵ درصد را شش مرتبه سریعتر از یک شبکه با استفاده از تانژانت هیپربولیک (منحنی نقطه ای شکل ۲) تجربه کند [۲۲].




شکل ۲- نمودار کاهش نرخ خطای یادگیری با استفاده از توابع رلو (منحنی پیوسته) و تانژانت هیپربولیک (منحنی نقطه ای) [۲۲]

شکل ۳ نشان می دهد در مقادیر خیلی بالا یا خیلی پایین  $Z$  تابع تانژانت هیپربولیک اشباع و شیب تابع نزدیک به صفر می شود. در حالی که شیب تابع رلو در مقادیر بالا و مثبت  $Z$  نزدیک به صفر نیست (شکل ۴) که این امر به همگرایی سریعتر شبکه کمک می کند. برای مقادیر منفی  $Z$  شیب صفر است اما اکثر نورون های یک شبکه عصبی معمولاً مقادیر مثبت دارند. به همین دلیل عملکرد تابع رلو بر تابع تانژانت هیپربولیک غالب می شود [۲۹].



شکل ۳- تابع فعال ساز تانژانت هیپربولیک [۲۹]



شکل ۴- تابع فعال ساز غیرخطی رلو [۲۹].

اگر عملکرد شبکه عصبی بر روی داده های آموزشی خوب و

$$a_j = \max_{N \times 1} (a_i^{n \times 1} u(n, 1)) \quad (3)$$

که در آن  $u(n, 1)$  یک تابع پنجره ای به بخشی از یک لایه کانولوشن و  $a_j$  مقدار بیشینه در این همسایگی است. تمام لایه ها شامل لایه های کانولوشن و ادغام با استفاده از الگوریتم پس انتشار خطا آموزش داده می شوند.

شبکه عصبی CNN دو بعدی با تعمیم رابطه ۱ بدست می آید، مقدار نرون  $v_{ij}^{xy}$  در موقعیت  $(x, y)$  نقشه ویژگی  $z$  ام در لایه  $i$  ام به صورت رابطه ۴ است:

$$v_{ij}^{xy} = g(b_{ij} + \sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} w_{ijm}^{pq} v_{(i-1)m}^{(x+p)(y+q)}) \quad (4)$$

که در آن:

$m$ : نقشه ویژگی در لایه  $(i-1)$  ام متصل شده به نقشه ویژگی جاری  $z$  ام

$w_{ijm}^{pq}$ : وزن موقعیت  $(p, q)$  متصل شده به ویژگی  $z$  ام

$P_i$  و  $Q_i$ : ارتفاع و عرض کرنل کانولوشن مکانی

$b_{ij}$ : بایاس نقشه ویژگی  $z$  ام در لایه  $i$  ام

ادغام به طریق مشابه قبل انجام می شود [۹]. الکسنت روی یک میلیون تصویر رنگی با ۱۰۰۰ طبقه آموزش داده شده و از ۵ لایه کانولوشن و ۳ لایه اتصال کامل تشکیل شده است. در یک لایه کانولوشن چندین کرنل کانولوشن (فیلترها) هم اندازه وجود دارد که ویژگی های خوب را در یک تصویر استخراج می کند. برای مثال اولین لایه کانولوشن الکسنت تصویری با اندازه  $227 \times 227 \times 3$  را به عنوان ورودی دریافت می کند سپس با استفاده از ۹۶ کرنل  $11 \times 11$  با مقدار گام ۴ و مقدار لایه گذاری برابر ۲ عملیات کانولوشن را روی عکس ورودی انجام می دهد. خروجی این لایه ۹۶ نقشه ویژگی به اندازه  $55 \times 55$  است که به یک تابع فعال ساز واحد یکسو شده خطی (رلو) وارد و به لایه بعدی منتقل می شود. این لایه  $34944$  پارامتر یادگیری را دربردارد. عرض و ارتفاع کرنل ها همواره یکسان و عمق همان تعداد کانال ها است. دو لایه اول کانولوشن با لایه های ادغام بیشینه دنبال می شود و لایه های سوم، چهارم و پنجم کانولوشن به طور مستقیم به هم متصل می شوند که به ترتیب  $384$ ،  $384$  و  $256$  نقشه ویژگی دارند. پنجمین لایه کانولوشن به یک لایه ادغام بیشینه متصل و خروجی آن به دو لایه اتصال کامل وارد می شود. لایه دوم اتصال کامل به یک لایه طبقه بندی سافت مکس با ۱۰۰۰ برجسب متصل می شود. تابع غیرخطی رلو پس از کلیه لایه های کانولوشن و اتصال کامل مورد استفاده قرار می گیرد [۲۳].

ویژگی مهم الکسنت استفاده از تابع رلو است [۴]. تابع

$$\text{Min } \tau(w) = \frac{1}{2} \|w^2\| \quad y_i(wx_i + b) - 1 \geq 0 \quad (10)$$

برای حل این مساله ساده‌تر آن است که مساله به صورت دوگان مطرح و حل شود. برای بدست آوردن شکل دوگان مساله ضریب لاگرانژ مثبت  $\alpha_i \geq 0$  در قیود ضرب شده و از تابع هدف کسر می‌شود، به رابطه ۱۱ مساله اولیه گفته می‌شود:

(۱۱)

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

برای داشتن پاسخ بهینه باید مشتق تابع نسبت به متغیرهای  $w$  و  $b$  برابر صفر قرار داده می‌شود (روابط ۱۲ و ۱۳):

$$\frac{\partial}{\partial b} L(w, b, \alpha) = 0 \quad (12)$$

$$\frac{\partial}{\partial w} L(w, b, \alpha) = 0 \quad (13)$$

با جایگذاری در رابطه ۱۱، رابطه دوگان مساله بهینه‌سازی به شرح رابطه‌های ۱۴ و ۱۵ تعریف می‌شود:

$$\text{Max } \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (14)$$

$$\alpha_i \geq 0 \quad i=1, \dots, l \quad \& \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (15)$$

ابرفضه بهینه طبق رابطه ۱۶ است:

$$f(x) = \text{sgn}(\sum_{i=1}^l y_i \alpha_i (x x_i) + b) \quad (16)$$

دوگان مساله بهینه‌سازی در حالت حاشیه نرم به صورت روابط ۱۷ و ۱۸ تعریف می‌شود:

$$\text{Max } \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (17)$$

$$0 \leq \alpha_i \leq C \quad \& \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (18)$$

$C$  پارامتر جریمه یا هزینه است. متغیرهای دوگانه با حل مجموعه داده‌های آموزشی بدست آورده می‌شوند، بعد از آن SVM برای طبقه‌بندی داده‌های آزمایشی مورد استفاده قرار می‌گیرد. یک فرض مهم این است که داده‌ها دارای قابلیت جداسازی خطی باشند و اگر داده‌ها به صورت خطی قابل تفکیک نباشند، می‌توان مساله را با استفاده از توابع کرنل مختلف حل کرد. توابع کرنل برای تبدیل داده‌های ورودی به فضای ویژگی با ابعاد بالاتر استفاده می‌شود. در این حالت به جای  $x_i, x_j$  تابع کرنل  $K(x_i, x_j)$  به کار برده می‌شود (رابطه ۱۹):

$$f(x) = \text{sgn}(\sum_{i=1}^l y_i \alpha_i K(x_i, x) + b) \quad (19)$$

توابع کرنل متداول، خطی، چندجمله‌ای، تابع پایه شعاعی

بر روی داده‌های جدید (آزمایشی) مناسب نباشد، به آن بیش‌برازش گویند. در شبکه عصبی الکسنت برای کاهش بیش‌برازش از روش‌های افزایش داده مانند قرینه‌سازی، انتقال تصویر اصلی در جهت‌های افقی و عمودی و بیرون‌اندازی نرون معرفی شده توسط هینتون<sup>۱</sup> (۲۰۱۲)، استفاده شده است. در بیرون‌اندازی، یک نرون از شبکه خارج و بدین ترتیب وارد فرآیند پس‌انتشار خطا نمی‌شود. بنابراین هر ورودی با معماری متفاوتی از شبکه عبور می‌کند که در نتیجه، پارامترهای وزنی بدست آمده اطمینان بیشتری دارند.

برای طبقه‌بندی و مدل‌سازی ویژگی‌های استخراج‌شده در این تحقیق از ماشین بردار پشتیبان استفاده می‌شود. به عبارتی هدف کاربرد SVM در بینایی ماشین است. SVM یکی از قدرتمندترین الگوریتم‌های یادگیری ماشین است [۳۱] که مرز تصمیم‌گیری بین دو کلاس را ایجاد می‌کند و با زیر مجموعه خاصی از داده‌های آموزشی به نام بردارهای پشتیبان مشخص می‌شود. مزیت ماشین بردار پشتیبان نسبت به شبکه عصبی پرسپترون در این است که یک مرز تصمیم منحصر به فرد با حداکثر حاشیه ایجاد می‌کند و نسخه استفاده از توابع کرنل در سرعت یادگیری بسیار موثر است [۳۴]. رابطه جداکننده خطی را می‌توان با تابع  $\text{sgn}(x)$  به صورت رابطه ۵ نوشت [۲۶]:

$$f(x) = \text{sgn}(wx_i + b) \quad (5)$$

که در آن:

$w$ : بردار نرمال ابرصفحه تصمیم‌گیری

$x_i$ : داده‌های نقطه‌ای

فرض می‌شود همه داده‌ها حداقل فاصله ۱ را از ابرصفحه دارند، بدین ترتیب دو رابطه حدی برای مجموعه داده‌های آموزشی  $\{(x_i, y_i)\}$  تعریف می‌شود که در اینجا  $y_i$  کلاس داده نام به صورت رابطه‌های ۶ تا ۸ است:

$$y_i \in \{-1, +1\} \quad (6)$$

$$wx_i + b \geq +1 \quad (7)$$

$$wx_i + b \leq -1 \quad (8)$$

که معادل است با رابطه ۹ است:

$$y_i(wx_i + b) \geq 1 \quad i=1, 2, \dots, n \quad (9)$$

برای حداکثر شدن حاشیه، رابطه بهینه‌سازی مقید تعریف می‌شود (رابطه ۱۰):

<sup>1</sup> Geoffrey Hinton

نسبت پاسخ‌های مثبت صحیح به مجموع پاسخ‌های مثبت صحیح و منفی غلط انجام می‌شود. این معیار همچنین به نام نرخ پاسخ مثبت صحیح مدل نیز شناخته می‌شود. به عبارت دیگر این معیار، حساسیت عملکرد مدل‌ها را در مواقعی که باید پاسخ مثبت داشته باشند، ارزیابی می‌کند (رابطه ۲۲).

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (22)$$

معیار ویژگی<sup>۴</sup> میزان توانایی مدل‌ها را در ایجاد تمایز بین دسته‌ها با تعیین نسبت پاسخ‌های منفی صحیح به مجموع پاسخ‌های مثبت غلط و منفی صحیح مشخص می‌کند. این معیار مفهومی مشابه معیار حساسیت را برای پاسخ‌های منفی ارائه می‌کند و به نام نرخ پاسخ‌های منفی صحیح نیز شناخته می‌شود.

$$\text{Specificity} = \frac{TN}{FP+TN} \quad (23)$$

معیار صحت<sup>۵</sup> این معیار میزان دقت و اعتمادپذیری پاسخ‌های مثبت مدل را مشخص می‌کند یا به عبارت دیگر احتمال صحیح بودن پاسخ‌های مثبت مدل را تعیین می‌کند. این معیار با نام ارزش پیش‌بینی مثبت نیز شناخته می‌شود.

$$\text{Precision} = \frac{TP}{TP+FP} \quad (24)$$

معیار  $F_1$ -score یکی از جامع‌ترین معیارهای ارزیابی دقت و عملکرد مدل‌های دسته‌بندی و پیش‌بینی است که طبق رابطه ۲۵ تعیین می‌شود [۴۱]:

$$F_1 - \text{score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (25)$$

منحنی مشخصه عملکرد سیستم یا منحنی عملیاتی گیرنده<sup>۶</sup> نمودار گرافیکی است که توانایی تشخیص یک سیستم طبقه‌بندی را نشان می‌دهد. این منحنی برای بیان نرخ مثبت صحیح (TPR) در برابر نرخ مثبت غلط (FNR) به کار می‌رود. محور عمودی این منحنی معیار حساسیت و محور افقی آن معیار (ویژگی ۱) است. یک خط نیم‌ساز نیز در این منحنی دیده می‌شود. بالای خط نیم‌ساز، نقاطی قرار گرفته‌اند که مقدار حساسیت یا نرخ مثبت صحیح (TPR) آن‌ها نسبت به نرخ مثبت کاذب (FPR) بیشتر است. هر چه منحنی بالاتر از خط نیم‌ساز قرار گیرد، روش عملکرد مناسب‌تری دارد و نتایج این روش برای استفاده قابل اطمینان‌تر خواهد بود (شکل‌های ۵-الف و ۵-ب). روی خط نیم‌ساز، مقدار عددی نرخ مثبت صحیح (TPR) و نرخ مثبت کاذب (FPR) با یکدیگر برابر است. وقتی منحنی روی خط نیم‌ساز قرار گیرد، روش از عملکرد مناسبی برخوردار نیست و نتایج آن قابل اطمینان

(RBF<sup>۱</sup>) اند [۱۷] که در این مطالعه از RBF استفاده شده است:

$$k(x_i, x_j) = \exp\{-\gamma \|x_i - x_j\|^2\}, \quad \lambda > 0 \quad (20)$$

$\gamma$ : ضریب کرنل است.

از فرآیندهای الگوریتم SVM، می‌توان به C (محدودیت جعبه‌ای یا پارامتر هزینه) و  $\gamma$  (گاما یا ضریب کرنل) اشاره کرد که قبل از یادگیری، مقاردهی اولیه می‌شوند، مقدار بالای محدودیت جعبه‌ای مدل انعطاف‌پذیرتری را با حاشیه کم ایجاد می‌کند. همچنین هرچه مقدار گاما کمتر باشد، انحنای مرز تصمیم پایین و منطقه تصمیم بسیار گسترده خواهد بود [۳۳].

برای ارزیابی عملکرد مدل‌سازی شاخص‌های زیر استفاده و در محیط متلب برنامه‌نویسی انجام می‌شود.

تشکیل ماتریس درهم ریختگی یکی از بهترین روش‌های ارزیابی دقت مدل‌های ایجاد شده برای انجام پیش‌بینی و دسته‌بندی به ویژه در مسایلی با بیش از دو دسته است. این ماتریس با مقایسه نتایج حاصل از مدل با واقعیت، پاسخ‌های به دست آمده از مدل‌ها را بررسی می‌کند. جدول ۱ ماتریس درهم ریختگی<sup>۱</sup> را با دو کلاس نشان می‌دهد:

جدول ۱- ماتریس درهم ریختگی [۱۵]

		برچسب پیش‌بینی شده	
		مثبت	منفی
برچسب شناخته شده	مثبت	TP	FN
	منفی	FP	TN

TP پاسخ مثبت صحیح، TN پاسخ منفی صحیح، FP پاسخ مثبت غلط و FN پاسخ منفی غلط است. پس از تعیین اجزای ماتریس درهم ریختگی می‌توان کارایی و عملکرد مدل را با استفاده از معیارهای اساسی زیر ارزیابی کرد.

معیار دقت<sup>۲</sup> از رایج‌ترین معیارهای ارزیابی مدل‌ها به شمار می‌رود که میزان دقت مدل را با محاسبه نسبت مجموع پاسخ‌های صحیح (TP و TN) را به کل پاسخ‌ها نشان می‌دهد (رابطه ۲۱).

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (21)$$

معیار حساسیت<sup>۳</sup> میزان توانایی و حساسیت مدل‌ها را در انجام دسته‌بندی صحیح مشخص می‌کند. این امر با محاسبه

<sup>4</sup> Specificity

<sup>5</sup> Precision

<sup>6</sup> Receiver operating characteristic (ROC)

<sup>1</sup> Confusion matrix

<sup>2</sup> Accuracy

<sup>3</sup> Sensitivity-Recall

## ۲-۳- پیاده‌سازی روش

با توجه به اهمیت شناسایی زون‌های آلتراسیون و تکتونیک منطقه در مدل‌سازی اکتشافی، در این تحقیق شناسایی ساختار با استفاده از ماشین بردار پشتیبان مورد مطالعه قرار می‌گیرد که به همین منظور الگوریتم‌های مربوط در محیط متلب برنامه‌نویسی و برای شناسایی زون‌های آلتراسیون از داده‌های استر و برای تعیین جهت گسل‌ها در منطقه از داده‌های (OLI) لندست (۸) استفاده می‌شود. یادگیری شبکه عصبی با استفاده از داده‌های مربوط به مطالعات میدانی انجام می‌گیرد. در ابتدا تصاویر به قطعات یکسان برش داده می‌شوند که این امر با استفاده از برنامه‌نویسی در متلب انجام می‌شود. اندازه تصاویر ورودی برای شناسایی زون‌های آلتراسیون  $30 \times 30$  پیکسل و برای گسل‌ها  $100 \times 100$  پیکسل انتخاب می‌شود.

به همین دلیل دو مجموعه داده تعریف و سپس به تعداد کلاس‌ها (وجود یا نبود آلتراسیون در بحث اول و جهت‌های غالب و یا نبود گسل مربوط به موضوع دوم)، پوشه‌های حاوی تصاویر مربوط در آن قرار داده می‌شود. نمونه‌هایی از برش‌های تصاویر در شکل ۶ آورده شده است.

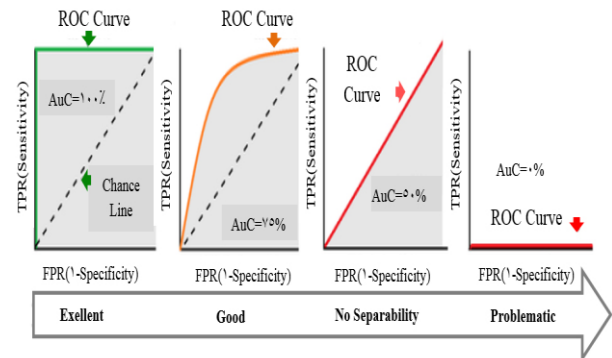
قالب ذخیره کلیه فایل‌های تصویری jpg و به صورت RGB است و ۷۰ درصد داده‌ها به عنوان داده‌های آموزشی و ۳۰ درصد بقیه داده‌های آزمایشی است. داده‌های آموزشی و آزمایشی با استفاده از تابع randperm به صورت تصادفی انتخاب می‌شوند.

در این مطالعه از معماری الکسنت برای استخراج ویژگی استفاده می‌شود. برای این منظور از تابع activations روی لایه اتصال کامل استفاده شده است.

همچنین برای طبقه‌بندی تابع TemplateSVM، تابع کرنل پایه شعاعی (RBF)، محدودیت جعبه‌ای برابر ۱۰ و مقیاس کرنلی پیش‌فرض مورد استفاده می‌گیرد. برای برآزش مدل‌های چندکلاس برای طبقه‌بندی داده‌ها نیز تابع fitcecoc استفاده می‌شود.

جدول‌های ۲ و ۳ ماتریس درهم ریختگی بدست آمده از مدل‌سازی تصویری SVM برای شناسایی زون‌های آلتراسیون و گسل‌ها را نشان می‌دهد. همانطور که در جدول ۲ ملاحظه می‌شود، از ۴۳۳ نمونه تصویری آزمایشی مربوط به زون‌های آلتراسیون، الگوریتم ۲۷۶ نمونه را به درستی در کلاس مربوطه شناسایی کرده است. کلاس ۱ مربوط به نبود زون آلتراسیون با ۲۱۱ نمونه آزمایشی و کلاس ۲ مربوط به وجود زون آتره شده با ۲۲۲ نمونه آزمایشی است که از این تعداد ۷۷ نمونه مربوط به کلاس ۱ و ۱۹۹ نمونه مربوط به کلاس ۲ به درستی شناسایی شده است.

نخواهد بود (شکل ۵-ج). پایین خط نیم‌ساز، نقاطی قرار گرفته‌اند که مقدار حساسیت یا نرخ مثبت صحیح (TPR) آن‌ها نسبت به نرخ مثبت کاذب (FPR) کمتر است، وقتی منحنی زیر خط نیم‌ساز قرار گیرد، روش عملکرد بسیار نامناسبی دارد (شکل ۵-د). به سطح زیر منحنی مشخصه عملکرد سیستم، (Area Under Curve) گفته می‌شود [۱۶].



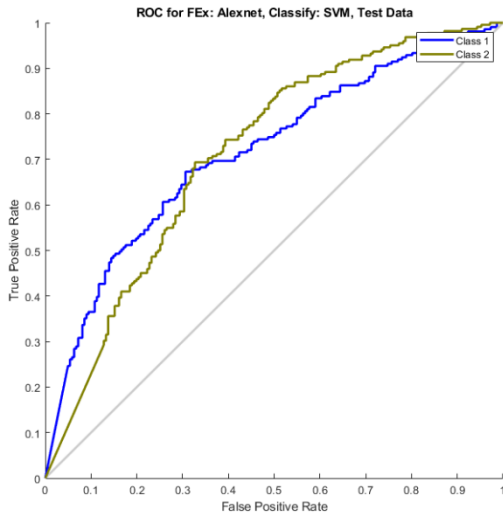
شکل ۵- منحنی مشخصه عملکرد در معرفی توانایی مدل [۱۶]

Alteration zones				
Occurrence of alteration				
Lack of alteration				
Faults orientations				
east-west				
north-south				
northeast-southwest				
northwest-Southeast				
absence of faults				


شکل ۶- تصاویر طبقه‌بندی آموزش شبکه عصبی کانولوشن [۳۶]

الگوریتم به درستی شناسایی شده است.

شکل های ۷ و ۸ منحنی ROC بدست آمده از مدل سازی تصویر SVM برای شناسایی زون های آلتراسیون و گسله را روی داده های آزمایشی نشان می دهد، منحنی در بالای خط نیم سازه قرار گرفته است و متوسط AUC مربوط به شناسایی زون های آلتراسیون ۷۱ و زون های گسله ۹۴ درصد است که عملکرد مناسب الگوریتم مدل سازی را نشان می دهد.



شکل ۷- منحنی مشخصه عملکرد مدل سازی تصویر SVM برای شناسایی زون های آلتراسیون روی داده های آزمایشی



شکل ۸- منحنی مشخصه عملکرد مدل سازی تصویر SVM برای شناسایی گسل ها روی داده های آزمایشی

شاخص های ارزیابی حاصل از اجرای الگوریتم مدل سازی موضوع این تحقیق روی داده های آزمایشی در شناسایی زون های

جدول ۲- ماتریس درهم ریختگی حاصل از مدل سازی تصویر SVM برای شناسایی زون های آلتراسیون

Output Class	Target Class 1	Target Class 2	Accuracy
1	77 (17.8%)	23 (5.3%)	77.0% (23.0%)
2	134 (30.9%)	199 (46.0%)	59.8% (40.2%)
	36.5% (63.5%)	89.6% (10.4%)	63.7% (36.3%)

جدول ۳- ماتریس درهم ریختگی حاصل از مدل سازی تصویر SVM برای شناسایی زون های گسله

Output Class	Target Class 1	Target Class 2	Target Class 3	Target Class 4	Target Class 5	Accuracy
1	43 (10.6%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	100% (0.0%)
2	0 (0.0%)	47 (11.6%)	1 (0.2%)	0 (0.0%)	1 (0.2%)	95.9% (4.1%)
3	0 (0.0%)	1 (0.2%)	45 (11.1%)	1 (0.2%)	13 (3.2%)	75.0% (25.0%)
4	0 (0.0%)	9 (2.2%)	5 (1.2%)	53 (13.1%)	4 (1.0%)	74.6% (25.4%)
5	2 (0.5%)	6 (1.5%)	25 (6.2%)	19 (4.7%)	131 (32.3%)	71.6% (28.4%)
	95.6% (4.4%)	74.6% (25.4%)	59.2% (40.8%)	72.6% (27.4%)	87.9% (12.1%)	78.6% (21.4%)

در مورد عملکرد الگوریتم SVM در مدل سازی زون های گسله مطابق جدول ۳، از ۴۰۶ نمونه تصویری آزمایشی مربوط به زون های گسله، الگوریتم ۳۱۹ نمونه را به درستی در کلاس مربوط شناسایی کرده است. کلاس ۱ مربوط به زون های گسله با جهت شرقی - غربی با ۴۵ نمونه آزمایشی، کلاس ۲، شمالی - جنوبی با ۶۳ نمونه آزمایشی، کلاس ۳، شمال شرقی - جنوب غربی با ۷۶ نمونه آزمایشی، کلاس ۴، نبود زون گسلی با ۷۳ نمونه آزمایشی و کلاس ۵ گسل هایی با جهت شمال غربی - جنوب شرقی با ۱۴۹ نمونه آزمایشی است که از این تعداد به ترتیب ۴۳ نمونه مربوط به کلاس ۱، ۴۷ نمونه متعلق به کلاس ۲، ۴۵ نمونه از کلاس ۳، ۵۳ نمونه از کلاس ۴ و ۱۳۱ نمونه مربوط به کلاس ۵ به وسیله

داغ شستشو می شوند. مجموعه کانی های بدست آمده شامل کائولینیت، پیروفیلیت، دیکیت و آلونیت با مقداری کوارتز، توپاز و تورمالین است. آلتراسیون آرژیلیک پیشرفته به طور متداول مرتبط با ذخایر اپی ترمال سطحی است.

آلتراسیون فیلیک معمولا در ذخایر مس پورفیری در سنگ های کالکوالکالان دیده می شود و معمولا با گروهی از کانی های کوارتز، سریسیت و پیریت همراه است و در دماهای بالا و شرایط اسیدیته متوسط (PH پایین) دیده می شود. این نوع دگرسانی اغلب ارتباط نزدیکی با دگرسانی آرژیلیک دارد و در دماهای پایین تر رخ می دهد و اغلب بر پلاژیوکلازها تاثیر می گذارد. دگرسانی فیلیک معمولا در زون فلزات پایه پورفیری تشکیل می شود.

آلتراسیون پروپیلیتیک نوعی دگرسانی شیمیایی سنگ است که در اثر فعل و انفعالات سیالات هیدروترمال حاوی آهن و منیزیم ایجاد می شود. این نوع آلتراسیون یکی از گسترده ترین شکل های دگرسانی ها است. فرم ملایم آلتراسیون در دماهای پایین به وجود می آید و عمدتا شامل کلریت، اپیدوت، کلینوزوئیت، کلسیت، زویسیت و آل بیت است و در حواشی ذخایر مس پورفیری و ذخایر فلزی گران بهای اپی ترمال یافت می شود.

در دگرسانی سیلیسی، کانی های کربناته به کانی های سیلیکات تبدیل می شود که یک مرحله ضروری در تشکیل ذخایر اسکارن است. ماگمای اسیدی سنگ کربناته را به آسانی حل می کند. طی مرحله سیلیسی شدن، کانی های جدید کوارتز یا سیلیس آمورف جدید تشکیل می شود که می تواند به صورت هاله ای در اطراف انواع ذخایر معدنی دیده شود.

آلتراسیون هماتیته حاصل سیالات اکسیدکننده است که منجر به تشکیل هماتیت به همراه فلدسپات پتاسیم، سریسیت، کلریت و اپیدوت می شود. هماتیته شدن در محیط های ماگمایی-هیدروترمال رخ می دهد و همراه با ذخایر چینه ای شکل مس و کبالت رسوبی است [۴۲].

سنجش از دور امروزه در مطالعات زمین شناسی اهمیت ویژه ای دارد، به طوری که این فناوری می تواند اطلاعات ارزشمندی از جمله شناسایی زون های آلتراسیون و خطواره ها در اختیار قرار دهد.

سنجنده استر از لحاظ توان تفکیک مکانی دارای دقت ۱۵، ۳۰ و ۹۰ متری به ترتیب در باندهای مرئی- مادون قرمز نزدیک (۳ باند با طول موجی بین ۰٫۵۲ تا ۰٫۸۶ میکرومتر)،

آلتراسیون و زون های گسلی (مطابق جداول ۴ و ۵) نشان می دهد، دقت الگوریتم یاد شده، به ترتیب ۶۳٫۷ و ۷۸٫۶ درصد است.

جدول ۴- نتایج شاخص های ارزیابی اجرای الگوریتم مدل سازی تصویری SVM روی داده های آزمایشی در شناسایی زون های آلتراسیون.

Accuracy: ۶۳٫۷۴۱۳
Precision: [۷۷ ۵۹٫۷۵۹۸]
Recall: [۳۶٫۴۹۲۹ ۸۹٫۶۳۹۶]
F1_Score: [۴۹٫۵۱۷۷ ۷۱٫۷۱۱۷]
AUC: [۰٫۷۱۶۱ ۰٫۷۱۳۲]

جدول ۵- نتایج شاخص های ارزیابی اجرای الگوریتم مدل سازی تصویری SVM روی داده های آزمایشی در شناسایی زون های گسلی.

Accuracy: ۷۸٫۵۷۱۴
Precision: [۱۰۰ ۹۵٫۹۱۸۴ ۷۵ ۷۴٫۶۴۷۹ ۷۱٫۵۸۴۷]
Recall: [۹۵٫۵۵۵۶ ۷۴٫۶۰۳۲ ۵۹٫۲۱۰۵ ۷۲٫۶۰۲۷ ۸۷٫۹۱۹۵]
F1_Score: [۹۷٫۷۲۷۳ ۸۳٫۹۲۸۶ ۶۶٫۱۷۶۵ ۷۳٫۶۱۱۱ ۷۸٫۹۱۵۷]
AUC: [۱ ۰٫۹۷۳۹ ۰٫۸۷۸۶ ۰٫۹۳۸۴ ۰٫۹۰۲۲]

### ۳- نتایج و بحث

آلتراسیون ها به واسطه فعل و انفعالات و تاثیر سیالات ماگمایی و محلول های هیدروترمال با سنگ های دربرگیرنده به وجود می آیند که موجب ایجاد تغییرات ژئوشیمیایی، کانی شناسی و بافت سنگ های دربرگیرنده می شوند. زون های آلتراسیون می تواند در ارتباط با کانی زایی اقتصادی باشد به همین دلیل شناسایی زون های آلتراسیون اهمیت زیادی دارد.

شواهد صحرایی و نتایج آنالیز نمونه های مینرالیزه در منطقه گناباد نشان می دهد که مهم ترین زون های آلتراسیون در منطقه، آلتراسیون فیلیک، پروپیلیتیک، آرژیلیک، سیلیسی و اکسید آهن است. کانی های شاخص زون دگرسانی فیلیک، ایلیت، موسکوویت و سریسیت، دگرسانی پروپیلیتیک، کلریت، اپیدوت و کلسیت و دگرسانی آرژیلیک، آلونیت، کائولینیت و مونت مورونیت است.

آلتراسیون آرژیلیک معمولا در دمای پایین و گاه در شرایط اتمسفری به وجود می آید و به دو صورت پیشرفته و متوسط تعریف می شود. آلتراسیون آرژیلیک متوسط در دمای پایین به وجود می آید و طی آن فلدسپات های پلاژیوکلاز با کانی های رسی، کائولینیت و مونت مورونیت جایگزین می شود که در لبه های سیستم های پورفیری به وجود می آید. طی آلتراسیون آرژیلیک پیشرفته، سنگ ها تحت تاثیر تحت سیالات اسیدی

استفاده از نتایج مطالعات میدانی بوده است که در نهایت، دقت این روش با سایر روش‌های سنتی و هوشمند مورد استفاده برای شناسایی زون‌های آلتراسیون در منطقه، مقایسه می‌شود. فرض می‌شود، دقت داده‌های مطالعات میدانی صددرصد است. جدول ۶ مقایسه دقت روش‌های نقشه‌برداری زاویه طیفی و مدل‌سازی هوشمند شبکه عصبی کانولوشن را در شناسایی زون‌های آلتراسیون در منطقه، نشان می‌دهد [۳۹]. علاوه بر آن برای تعیین سیستماتیک فرآیندهای شبکه عصبی کانولوشن از الگوریتم ژنتیک پیوسته نیز استفاده شده است [۳۹] که دقت این روش نیز در جدول ۶ آورده شد.

جدول ۶- مقایسه دقت الگوریتم‌های مختلف در شناسایی زون‌های آلتراسیون

مطالعات میدانی	نقشه‌برداری زاویه طیفی	شبکه عصبی کانولوشن	تجمیع شبکه عصبی کانولوشن با الگوریتم ژنتیک پیوسته	ماشین‌بردار پشتیبان
۱۰۰ درصد	به‌طور متوسط ۷۰ درصد	٪۷۵٫۷۵	٪۷۲٫۳۲	٪۶۳٫۷۴

جدول ۷- مقایسه دقت الگوریتم‌های مختلف در شناسایی گسل‌ها

مطالعات میدانی	اعمال فیلترها روی تصویر اولین مولفه اصلی ماهواره لندست ۸	شبکه عصبی کانولوشن	تجمیع شبکه عصبی کانولوشن با الگوریتم ژنتیک پیوسته	ماشین‌بردار پشتیبان
۱۰۰ درصد	به‌طور متوسط ۲۸ درصد	٪۵۶٫۸۹	٪۵۴٫۸۱	٪۷۸٫۵۷

نقشه زمین‌شناسی ۱/۲۵۰۰۰۰ و ۱/۱۰۰۰۰۰۰ سازمان زمین‌شناسی و اکتشافات معدنی کشور و برای یادگیری الگوریتم استفاده می‌شود، صددرصد است. در گام بعدی دقت این روش با دقت حاصل از روش‌های دستی (اعمال فیلترهای مختلف در استخراج خطواره‌ها)، شبکه عصبی کانولوشن و روش تجمیع شبکه عصبی کانولوشن با الگوریتم ژنتیک پیوسته [۳۹] مقایسه می‌شود (جدول ۷).

#### ۴- نتیجه‌گیری

رویکردهای طبقه‌بندی سنتی، به طور ضعیفی بر روی طبقه‌بندی تصویر متمرکز می‌شوند که علت آن ابعاد زیاد فضای ویژگی است. این مطالعه نشان می‌دهد که الگوریتم ماشین‌بردار پشتیبان می‌تواند به خوبی بر روی مسایل طبقه‌بندی تصویر تعمیم داده شود. نتایج مطالعات انجام شده، متوسط دقت طبقه‌بندی داده‌های تصویری با استفاده از الگوریتم‌های شبکه عصبی کانولوشن و ماشین‌بردار پشتیبان را به ترتیب ۶۵ و ۷۱ درصد نشان می‌دهد.

در مقام مقایسه، الگوریتم‌های یادگیری ماشین در مدل‌سازی تصویری به ویژه در مواردی که امکان خطای نیروی

مادون قرمز طول موج کوتاه (۶ باند با طول موجی بین ۱/۶ تا ۲/۴۳ میکرومتر) و مادون قرمز حرارتی (۵ باند با طول موجی بین ۸/۱۲۵ تا ۱۱/۶۵ میکرومتر) است. وجود قدرت تفکیک مکانی کافی در محدوده طیفی مادون قرمز طول موج کوتاه موجب شده این سنجنده به طور وسیع و موفق در تهیه نقشه‌های زمین‌شناسی و اکتشاف مواد معدنی مورد استفاده قرار گیرد (اطلاعات تکمیلی طیفی و مکانی سنجنده استر در پیوست ۱ آورده شده است) [۱۰ و ۱۳]. در این تحقیق از ماشین‌بردار پشتیبان برای شناسایی زون‌های آلتراسیون روی داده‌های استر استفاده می‌شود. آموزش الگوریتم یاد شده با

یکی دیگر از ساختارهای مهم مورد بررسی در این تحقیق، وضعیت گسل‌ها است. نتایج بررسی‌های ژئوشیمیایی در منطقه نشان می‌دهد کانی‌زایی در نتیجه نفوذ سیالات ماگمایی به داخل شکستگی‌ها و در امتداد دایک‌ها رخ داده است [۳۷ و ۳۸]، با توجه به اینکه تصاویر ماهواره لندست ۸ با دارا بودن ۱۱ باند، در باند ۸ (باند پانکروماتیک) قدرت تفکیک مکانی ۱۵ متر را دارد و باندهای ۱۰ و ۱۱ (مادون قرمز حرارتی)، دارای قدرت تفکیک مکانی ۱۰۰ متر و مابقی باندها دارای قدرت تفکیک مکانی ۳۰ متر است که به جز باندهای سیروس و آئروسل ساحلی، در محدوده نور مرئی و مادون قرمز نزدیک و طول موج کوتاه قرار می‌گیرد (اطلاعات تکمیلی طیفی و مکانی ماهواره لندست ۸ در پیوست ۲ آورده شده است) [۲۵]، بنابراین به دلیل قدرت تفکیک مکانی بالا در باند پانکروماتیک<sup>۱</sup>، مطالعات تکتونیک با استفاده از تصاویر ماهواره لندست ۸ انجام می‌شود.

در این تحقیق از ماشین‌بردار پشتیبان روی داده‌های لندست ۸ برای شناسایی وضعیت گسل‌ها استفاده می‌شود. فرض شده، دقت داده‌های مطالعات میدانی که منجر به تهیه

<sup>1</sup> Panchromatic




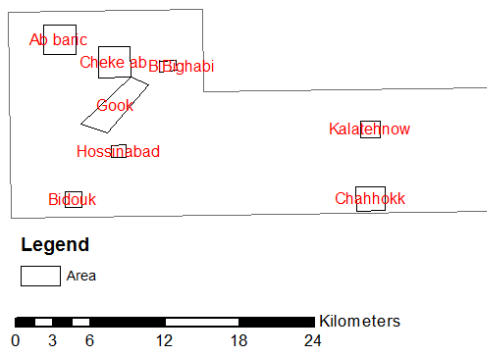
نشان می‌دهد که در منطقه مورد مطالعه معدن فلزی وجود ندارد ولی به نظر می‌رسد لازم است برای جلوگیری از تضييع ذخایر معدنی، بهره‌برداران با افزایش عمق بهره‌برداری، اقدام به نمونه‌برداری‌های دوره‌ای کنند.

در پایان پیشنهاد می‌شود این روش در چندین محدوده معدنی دیگر نیز پیاده‌سازی شود و نتایج بدست آمده با یافته‌های این تحقیق مقایسه و مورد ارزیابی قرار گیرد.

انسانی وجود دارد، پروژه‌ها دارای محدودیت زمانی و هزینه‌ای است و از سوی دیگر منطقه مورد مطالعه در مناطق صعب العبور قرار دارد که امکان مطالعه میدانی میسر نیست، می‌تواند دقت بالایی برای مدل‌سازی اکتشاف پتانسیل‌های معدنی داشته باشد.

با توجه به نتایج مطالعات ژئوشیمیایی و ساختاری، مناطق امیدبخش در منطقه در شکل ۹ نشان داده شده است. به لحاظ پراکندگی ماده معدنی باید گفت که بررسی‌های به عمل آمده

Map of Targets



شکل ۹- نقشه محدوده‌های امیدبخش

On Information Technology And Data Related Research Data Science & Digital Broadcasting Systems. See also URL <https://doi.org/10.15308/Sinteza-2019-445-451>.

- Boas, Franz; (۱۹۲۲); "The measurement of differences between variable quantities". Journal Of the American Statistical Association, XVIII(۱۴۰): 425-445.
- Boato, Giulia; Dang-Nguyen; Duc-Tien; and De Natale, Francesco G.B; (2019); "Morphological Filter Detector for Image Forensics Applications". IEEEExplore, 8:13549-13560.
- Chen, Jiayao; Yang, Tongjun; Zhang, Dongming; Huang, Hongwei; and Tian, Yu; (2021); "Deep learning based classification of rock structure of tunnel face". Geoscience Frontiers,12( 1): 395-404.
- Chen, Lirong; Wang, Liang; Miao, Jinli; Gao, Huan; Zhang, Yue; Yao, Yao; Bai, Ming; Mei, Lisi; and He, Jing; (2020); "Review of the Application of Big Data and Artificial Intelligence

## منابع

- (2020); "Advantages, disadvantages and application of SVM". See also URL <https://statinfer.com/204-6-7-soft-margin-classification-noisy-data>.
- Aggarwal, Namita; and Agrawal, R. K.; (2012); "First and second order statistics features for classification of magnetic resonance brain images". Journal of Signal and Information Processing, 3: 146-153.
- Alzubaidi, Laith; Zhang, Jinglan; Humaidi, Amjad J.; Al-Dujaili, Ayad; Duan, Ye; Al-Shamma, Omran; Santamaria, J. Fadhel; Mohammed A.; Al-Amidie, Muthana; and Farhan, Laith; (2021); "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions". Journal of Big Data. See also URL <https://doi.org/10.1186/s40537-021-00444-8>.
- Bezdan, Timea; and Bačanin Džakula, Nebojsa; (2019); "Convolutional neural network layers and architectures". International Scientific Conference

- 2319-2323. See also URL <https://doi.org/10.1109/RTEICT42901.2018.9012507>.
19. K. Anuradhav Sankaranarayanan. Kv (2013); “*Statistical feature exploration to classify oral cancers*”. Journal of Global Research in Computer Science, 4(2): 8-12.
  20. Kamilaris, A.; and Prenafeta-Boldú, F. X. ; (2018); “*A review of the use of convolutional neural networks in agriculture*”. The Journal of Agricultural Science, See also URL <https://doi.org/10.1017/S0021859618000436> 1–11.
  21. Kang, Byeongcheol; and Lee, Kyungbook; (2020); “*Managing uncertainty in geological scenarios using machine learning-based classification model on production data*”. Hindawi, 8892556: 1-16.
  22. Krizhevsky, Alex; Ilya, Sutskever; and Hinton, Geoffrey E. ; (2012); “*Magenet classification with deep convolutional neural networks*”. See also URL <https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>.
  23. Kurama, Vihar; (2022); “*A Review of Popular Deep Learning Architectures: AlexNet, VGG16, and GoogleNet*”. <https://blog.paperspace.com/popular-deep-learning-architectures-alexnet-vgg-googlenet/>.
  24. Ladwani, Vandana M.; (2017); “*Support vector machines and applications*”. See also URL <https://doi.org/10.4018/978-1-5225-2498-4.ch012>.
  25. Mahboob, M.A. ; Genc, B. ; Celik, T. v Ali, S. ; and Atif, I.; (2019); “*Mapping hydrothermal minerals using remotely sensed reflectance spectroscopy data from Landsat*”. The Journal of the Southern African Institute of Mining and Metallurgy. 119:279-289.
  26. Mohammadi, N. Mahvash; and Hezarkhani, A.; (2020); “*Comparative study of SVM and RF methods for classification of alteration zones using remotely sensed data*”. Journal of Mining and Environment (JME), 11(1): 49-61. See also URL <https://10.22044/jme.2019.7956>. 1664.
  27. Mutlag, Wamidh K. ; Ali, Shaker K., Aydam; Zahoor M. ; and Taher, Bahaa H.; (۲۰۲۰); “*Feature extraction methods: A review*”. Journal of Physics: Conference Series, ۱۵۹۱ :۱-۱۱. See also URL <https://doi.org/10.1088/1742-6596/1591/1/012028>.
  28. Nathwani, Chetan L. ; Wilkinson, Jamie J. Fry; George, Armstrong; Robin N., Smith, Daniel J. ; and Ihlenfeld, Christian.; (2022); “*Machine learning for geochemical exploration: classifying metallogenic fertility in arc magmas and insights into porphyry copper deposit formation*”. Mineralium Deposita, See also URL <https://doi.org/10.1007/s00126-021-01086-9>.
  9. Chen, Yushi; Jiang, Hanlu; Li, Chunyang; Jia, Xiuping; and Ghamisi, Pedram; (2016); “*Deep feature extraction and classification of hyperspectral images based on convolutional neural networks*”. IEEE Transactions on Geoscience and Remote Sensing, 54(10): 6232–6251. See also URL <https://doi.org/10.1109/TGRS.2016.2584107>.
  10. Di Tommaso, Inés; and Rubinstein, Nora; (2007); “*Hydrothermal alteration mapping using ASTER data in the Infiernillo porphyry deposit, Argentina*”. Ore Geology Reviews, 32: 275–290. See also URL <https://doi.org/10.1016/j.oregeorev.2006.05.004>.
  11. Dumakor-Dupey, Nelson K. ; and Arya, Sampurna. (2021). “*Machine Learning—A Review of Applications in Mineral Resource Estimation*”. Energies, 14:1-29. See also URL <https://doi.org/10.3390/en14144079>.
  12. Elnemr, Heba Ahmed; Zayed, Nourhan Mohamed; and Fakhreldein, Mahmoud Abdelmoneim; (۲۰۱۵); “*Handbook of research on emerging perspectives in intelligent pattern recognition, analysis, and image processing, feature extraction techniques: Fundamental concepts and survey*”. See also URL <https://doi.org/10.4018/978-1-4666-8654-0>.
  13. Elsaid, Mahmoud; Aboelkhair, Hatem; Dardier, Ahmed; Hermas, Elsayed ;and Minoru, Urai; (2014); “*Processing of multispectral ASTER data for mapping alteration minerals zones: As an aid for Uranium exploration in Elmissikat-Eleridiya Granites, Central Eastern Desert, Egypt*”. The Open Geology Journal, 8:69-83.
  14. Evgeniou, Theodoros; and Pontil, Massimiliano; (2001) ; “*Workshop on support vector machines: Theory and applications. Center for Biological and Computational Learning, and Artificial Intelligence Laboratory*”. See also URL [https://doi.org/10.1007/3-540-44673-7\\_12](https://doi.org/10.1007/3-540-44673-7_12).
  15. <https://blog.faradars.org/confusion-matrix-from-zero-to-hero/>
  16. [https://dastmardi.ir/1399/01/13/receiver\\_operating\\_characteristic/](https://dastmardi.ir/1399/01/13/receiver_operating_characteristic/)
  17. <https://www.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html>
  18. Jogin, Manjunath; Mohana, M S; Madhulika, G Dv Divya, R K, Meghana; and S, Apoorvav (2018) ; “*Feature extraction using convolution neural networks (CNN) and deep learning*”. 2018 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT-2018), MAY 18th & 19<sup>th</sup>. 1:

- vector machine and integration it with continuous genetic algorithm in Gonabad region, Khorasan Razavi, Iran*". Arabian Journal of Geosciences See also URL <https://doi.org/10.1007/s12517-021-07306-w>.
38. Tahmooresi, Mandana; Babaei, Behnam; and Dehghan, Saeed; (2022); "Geochemical exploration numerical modeling using convolutional neural network (Case study: Gonabad region)". Journal of Aalytical and Numerical Methods in Mining Engineering (Yazd University) See also URL doi 10.29252/ANM.2022.17958.1534.
  39. Tahmooresi, Mandana; Babaei, Behnam; and Dehghan, Saeed; (2022); "Mineral exploration modeling by convolutional neural network and continuous genetic algorithm: a case study in Khorasan Razavi, Iran". Arabian Journal of Geosciences See also URL <https://doi.org/10.1007/s12517-022-10889-7>
  40. Tao, Jin; (2020); "Statistical object features". See also URL <https://slidetodoc.com/statistical-object-features-jin-tao-introduction>.
  41. Vakili, Meysam; Ghamsari, Mohammad ;and Rezaei, Masoumeh; (2020); "Performance analysis and comparison of machine and deep learning algorithms for IoT data classification". See also URL <https://arxiv.org/abs/2001.09636>.
  42. Williams, Kylie; (2021); "What the -ic? An Introduction to Alteration". <https://www.geologyforinvestors.com/ic-introduction-alteration/>.
  43. Wirth, Michael A. ; (2004); "Texture Analysis". See also URL <http://www.cyto.purdue.edu/education/wirth06>.
  44. You, Changhui; Zheng, Hong; Guo, Zhongyuan Wang, Tianyu; and Wu, Xiongbin; (2021); "Multiscale content-independent feature fusion network for source camera identification". Appl. Sci. 11(6752): 1-13.
  45. Zhang, Chun-Xia; Wei, Xiao-Li ;and Kim, Sang-Woon; (2021); "Empirical evaluation on utilizing CNN-features for seismic patch classification". In Proceedings of the 10<sup>th</sup> International Conference on Pattern Recognition Applications and Methods (ICPRAM 2021), 1: 166-173.
  29. Nayak, Sunita; (2018); "Understanding AlexNet-LearnOpenCV". See also URL <https://learnopencv.com/understanding-alexnet>.
  30. Nwaila, Glen; (2019); "Convolutional Neural Networks in Exploration of Mineral Deposits". See also URL <https://www.linkedin.com/pulse/convolutional-neural-networks-exploration-mineral-deposits-nwaila>.
  31. Osuna, Edgar; Freund, Robert; Girosi, Federico; (1997); "Training support vector machines: an application to face detection". Computer society conference on computer vision and pattern recognition, See also URL <http://dx.doi.org/10.1109/CVPR.1997.609310>.
  32. Rahimi, Hossain; Abedi, Maysam; Yousefi, Mahyar; Bahroudi, Abbas; and Elyas, Gholam-Reza; (2021); "Supervised mineral exploration targeting and the challenges with the selection of deposit and non-deposit sites thereof". Applied Geochemistry, See also URL <https://doi.org/10.1016/j.apgeochem.2021.104940>.
  33. "RBF SVM parameters". See also URL [https://scikit-learn.org/stable/\\_downloads/ea8b449d4699d078ef9cc5cded54cc67/plot\\_rbf\\_parameters.py](https://scikit-learn.org/stable/_downloads/ea8b449d4699d078ef9cc5cded54cc67/plot_rbf_parameters.py).
  34. Sahbi, Hichem; and Geman, Donald; (2006); "A Hierarchy of Support Vector Machines for Pattern Detection". Journal of Machine Learning Research, 7 (2006): 2087-2123.
  35. Shirmard, Hojat; Farahbakhsh, Ehsan; Dietmar Muller, R. ; and Chandra, Rohitash; (2021); "A review of machine learning in processing remote sensing data for mineral exploration". See also URL arXiv:2103.07678 v2 [cs.LG] 4 Dec 2021.
  36. Tahmooresi, Mandana; (2021); "Data mining and intelligent optimization of support vector machine and convolutional neural network using genetic algorithm in order to modeling for mineral potential exploration (Case study: Gonabad arena) ", Ph.D. Dissertation, Mahallat Branch, Islamic Azad University, Mahallat, IRAN. [In Persian].
  37. Tahmooresi, Mandana; Babaei, Behnam; and Dehghan, Saeed; (2021); "Intelligent geochemical exploration modeling using multiclass support

## پیوست ۱: اطلاعات طیفی و مکانی سنجنده استر

شماره باند طیفی	نام باند طیفی	طول موج (میکرومتر)	قدرت تفکیک مکانی (متر)
۱	سبز	۰٫۵۲-۰٫۶	۱۵
۲	قرمز	۰٫۶۳-۰٫۶۹	۱۵
N۳	مادون قرمز نزدیک- مریبی (VNIR)	۰٫۷۸-۰٫۸۶	۱۵
B۳	مادون قرمز نزدیک- مریبی (VNIR)	۰٫۷۸-۰٫۸۶	۱۵
۴	مادون قرمز طول موج کوتاه (SWIR)	۱٫۶-۱٫۷	۳۰
۵	مادون قرمز طول موج کوتاه (SWIR)	۲٫۱۴۵-۲٫۱۸۵	۳۰
۶	مادون قرمز طول موج کوتاه (SWIR)	۲٫۱۸۵-۲٫۲۲۵	۳۰
۷	مادون قرمز طول موج کوتاه (SWIR)	۲٫۲۳۵-۲٫۲۸۵	۳۰
۸	مادون قرمز طول موج کوتاه (SWIR)	۲٫۲۹۵-۲٫۳۶۵	۳۰
۹	مادون قرمز طول موج کوتاه (SWIR)	۲٫۳۶-۲٫۴۳	۳۰
۱۰	مادون قرمز حرارتی (TIRS)	۸٫۱۲۵-۸٫۴۷۵	۹۰
۱۱	مادون قرمز حرارتی (TIRS)	۸٫۴۷۵-۸٫۸۲۵	۹۰
۱۲	مادون قرمز حرارتی (TIRS)	۸٫۹۲۵-۹٫۲۷۵	۹۰
۱۳	مادون قرمز حرارتی (TIRS)	۱۰٫۲۵-۱۰٫۹۵	۹۰
۱۴	مادون قرمز حرارتی (TIRS)	۱۰٫۹۵-۱۱٫۶۵	۹۰

## پیوست ۲: اطلاعات طیفی و مکانی ماهواره لندست ۸

شماره باند طیفی	نام باند طیفی	طول موج (میکرومتر)	قدرت تفکیک مکانی (متر)
۱	آژوسل ساحلی	۰٫۴۳-۰٫۴۵	۳۰
۲	آبی	۰٫۴۵-۰٫۵۱	۳۰
۳	سبز	۰٫۵۳-۰٫۵۹	۳۰
۴	قرمز	۰٫۶۴-۰٫۶۷	۳۰
۵	مادون قرمز نزدیک (NIR)	۰٫۸۵-۰٫۸۸	۳۰
۶	مادون قرمز طول موج کوتاه (SWIR)	۱٫۵۷-۱٫۶۵	۳۰
۷	مادون قرمز طول موج کوتاه (SWIR)	۲٫۱۱-۲٫۲۹	۳۰
۸	پانکروماتیک	۰٫۵-۰٫۶۸	۱۵
۹	سیروس	۱٫۳۶-۱٫۳۸	۳۰
۱۰	مادون قرمز حرارتی	۱۰٫۶-۱۱٫۱۹	۱۰۰
۱۱	مادون قرمز حرارتی	۱۱٫۵-۱۲٫۵۱	۱۰۰

## پیوست ۳: کد الگوریتم یادگیری ماشین برای مدل سازی اکتشافی در محیط متلب

```

clc;
clear;
close all;
%% Load and Divide Data
ListFolder = {'ProjectData'};
NameDataSet = ListFolder{1};
[imdsTrain,imdsTest] = LoadDivideData(NameDataSet);

%% Select Type of Networks
ListNet = {'Alexnet'};

```

```

NameNetwork = ListNet{1};
%% Read Network and Set Pere-P
[net, augimdsTrain, augimdsTest] = ReadNet_SetData(...
    NameNetwork, imdsTrain, imdsTest);
%% Features Extraction using CNN
[FeaturesTrain, FeaturesTest] = FeatureExtractionUsinCNN(net, ...
    augimdsTrain, augimdsTest);

%% Train Using Classification
ListClassify = {'SVM'};
NameClassify = ListClassify{1};
Kfold = 'on'; % 'on', 'off'
TrainModel = Classification(NameClassify, ...
    FeaturesTrain, imdsTrain.Labels, Kfold);
%% Prediction and Evaluation
% Test Data
LabelsTest = imdsTest.Labels;
ResultsTest = EvaluatePlot(TrainModel, ...
    FeaturesTest, LabelsTest, ['FEx: ', NameNetwork, ', Classify: ', NameClassify, ',
Test']);

% Train Data
LabelsTrain = imdsTrain.Labels;
ResultsTrain = EvaluatePlot(TrainModel, ...
    FeaturesTrain, LabelsTrain, ['FEx: ', NameNetwork, ', Classify:
', NameClassify, ', Train']);

function [imdsTrain, imdsTest] = LoadDivideData(name)
if strcmp(' ProjectData ', name)
    nameTrain = ['DataSets/', name, '/TrainCifar'];
    nameTest = ['DataSets/', name, '/TestCifar'];
    imdsTrain = imageDatastore(nameTrain, ...
        'IncludeSubfolders', true, ...
        'LabelSource', 'foldernames');
    imdsTest = imageDatastore(nameTest, ...
        'IncludeSubfolders', true, ...
        'LabelSource', 'foldernames');
%     load([name, 'Divide.mat'])

else
    name = ['DataSets/', name];
    imds = imageDatastore(name, ...
        'IncludeSubfolders', true, ...
        'LabelSource', 'foldernames');
    [imdsTrain, imdsTest] = splitEachLabel(imds, 0.7, 'randomized');
%     load([name, 'Divide.mat'])

end
end

function TrainModel = Classification(NameClassify, ...
    FeaturesTrain, TragetsTrain, Kfold)

%% Classification
TrainData.Kfold = Kfold;
TrainData.Inputs = FeaturesTrain;
TrainData.Targets = TragetsTrain;

switch NameClassify
    case 'SVM'
        temp = templateSVM('KernelFunction', 'rbf', 'BoxConstraint', 10, ...
            'KernelScale', 'auto', 'CacheSize', 1000);
    otherwise

```

```

        temp = templateSVM('KernelFunction','rbf','BoxConstraint',10,...
            'KernelScale','auto','CacheSize',1000);
    end
    TrainModel = Classifier(TrainData,temp);
end

function Classify = Classifier(TrainData,temp)
TrainFeatur = TrainData.Inputs;
TrainTargets = TrainData.Targets;
%% Train Algorithm
if strcmp('on',TrainData.Kfold)
    %% Apply k-Fold Cross Validation
    N = numel(TrainData.Targets);
    K = 4; % k-Fold
    CVI = CrossValInd(N,K);
    Accuracy = zeros(1,K);

    for i = 1:K
        training = TrainFeatur(CVI~=i,:);
        group = TrainTargets(CVI~=i);
        valid = TrainFeatur(CVI==i,:);
        label = TrainTargets(CVI==i);
        Classify = fitcecoc(training,group,'Learners',temp);
        Class = predict(Classify,valid);
        B = confusionmat(label,Class);
        Accuracy(i) = sum(diag(B))/sum(B(:));
    end
else
    Classify = fitcecoc(TrainFeatur,TrainTargets,'Learners',temp);
End

function Iout = CreateImege3D(filename)
% Resize the flowers images to the size required by the network.
Iout = imread(filename);
% Some images may be grayscale. Replicate the image 3 times to
% create an RGB image.
if ismatrix(Iout)
    Iout = cat(3,Iout,Iout,Iout);
end
% Resize the image as required for the CNN.
Iout = imresize(Iout, [224 224]);
function Results = EvaluatePlot(TrainModel,data,Labels,Name)
% Prediction
[YPred,scores] = predict(TrainModel,data);

Lau = unique(Labels);
groups = zeros(size(YPred));
groupshat = zeros(size(YPred));
for i = 1:numel(Lau)
    ID = ismember(YPred,Lau(i));
    groupshat(ID) = i;

    ID = ismember(Labels,Lau(i));
    groups(ID) = i;
end

confmat = confusionmat(groups,groupshat);
Results = PrecisionRecall(confmat);
[Targets,Groups] = H_MultiClassCMROC(groups',groupshat');
figure,plotconfusion(Targets,Groups)
title(['CM for ',Name,' Data'])
for i = 1:size(confmat,1)
[~,~,~,AUC(i)] = perfcurve(Targets(i,:),scores(:,i)',1);

```

```

end
Results.AUC = AUC;
disp(['Results For ',Name,' Data'])
disp(Results)
disp(' *****')
figure,plotroc(Targets,scores')
title(['ROC for ',Name,' Data'])
end

function [FeaturesTrain,FeaturesTest] =
FeatureExtractionUsinCNN(net,augimdsTrain,augimdsTest)

Layers = net.Layers;
name = Layers(end-2).Name;
layer = name;
FeaturesTrain = activations(net,augimdsTrain,layer,'OutputAs','rows');
FeaturesTest = activations(net,augimdsTest,layer,'OutputAs','rows');
end

function [Targets,Groups] = H_MultiClassCMROC(Targets,Groups)
Tu = unique(Targets);
Temp1 = zeros(size(Targets));
Temp2 = Temp1;
for i = 1:numel(Tu)
    Ind1 = find(Targets==Tu(i));
    Temp1(Ind1) = i; %#ok
    Ind2 = find(Groups==Tu(i));
    Temp2(Ind2) = i; %#ok
end
Targets = full(ind2vec(Temp1));
Groups = full(ind2vec(Temp2));

function Results = PrecisionRecall(confmat)
nC = size(confmat,1);
for i = 1:nC
Precision(i) = confmat(i,i)/sum(confmat(:,i))*100;
Recall(i) = confmat(i,i)/sum(confmat(i,:))*100;
F1_Score(i) = 2*Precision(i)*Recall(i)/(Precision(i)+Recall(i));
end

Accuracy = sum(diag(confmat))/sum(confmat(:));
Results.Accuracy = 100*Accuracy;
Results.Precision = Precision;
Results.Recall = Recall;
Results.F1_Score = F1_Score;
% disp(Results)
end

function [net,augimdsTrain,augimdsTest] = ReadNet_SetData(...
    NameNet,imdsTrain,imdsTest)
I = readimage(imdsTrain,1);
if numel(size(I))<3
    imdsTrain.ReadFcn = @CreateImege3D;
    imdsTest.ReadFcn = @CreateImege3D;
end
NameNet = lower(NameNet);
net = eval(NameNet);
inputSize = net.Layers(1).InputSize;
pixelRange = [-30 30];
imageAugmenter = imageDataAugmenter( ...
    'RandXReflection',true, ...
    'RandXTranslation',pixelRange, ...
    'RandYTranslation',pixelRange);

```

```
augimdsTrain = augmentedImageDatastore(inputSize,imdsTrain, ...
    'DataAugmentation',imageAugmenter);
augimdsTest = augmentedImageDatastore(inputSize,imdsTest, ...
    'DataAugmentation',imageAugmenter);

function options = SetTrainOptions(augimdsValidation)
options = trainingOptions('sgdm', ...
    'MiniBatchSize',120, ...
    'MaxEpochs',20, ...
    'InitialLearnRate',1e-4, ...
    'ValidationData',augimdsValidation, ...
    'ValidationFrequency',3, ...
    'ValidationPatience',Inf, ...
    'Verbose',1, ...
    'Plots','training-progress',...
    'ExecutionEnvironment','gpu');%'none','training-progress'
end
```