

علمی - تخصصی

## مقایسه روش‌های مختلف سنجش از دور و مدل‌های شبکه عصبی کانولوشن، ماشین بردار پشتیبان و درخت تصمیم جهت تعیین مناطق مستعد و امیدبخش کانی‌سازی در منطقه سیاه چشمه و دیزج، استان آذربایجان غربی.

داود بیکی حسن<sup>۱\*</sup>، مسعود اسمعیل زاده<sup>۲</sup>

۱- دانشکده مهندسی معدن، دانشگاه صنعتی اصفهان، اصفهان ۲- دانشکده مهندسی معدن، دانشگاه ارومیه، ارومیه

(دریافت: ۱۴۰۱/۰۲/۱۷، پذیرش: ۱۴۰۱/۰۶/۱۹)

چکیده

امروزه روش‌های مختلف سنجش از دور یکی از کاربردی‌ترین روش‌ها در حوزه اکتشافات معدنی در مناطق کوهستانی، مرزی و فاقد نمونه‌های ژئوشیمی و رسوبات آبراهه معتبر در مرحله شناسایی محسوب می‌گردد. روش‌های طیفی نظیر فیلتر تنظیم پیکسل‌های مخلوط همسان (MTMF)، نقشه‌بردار زاویه طیفی (SAM) و نا آمیختگی طیفی خطی (LSU) بر اساس طیف هر پیکسل تصویر عارضه‌های مختلف را شناسایی می‌کنند. این مطالعه به منظور تعیین مناطق آلتراسیون، تفکیک سنگ‌ها و کانی‌های مختلف، طبقه‌بندی تصاویر و در نهایت تعیین مناطق مستعد و امیدبخش کانی‌سازی افیولیتی، سرپانتینیت‌ها، هاربورژیت‌های سرپانتینی شده، لیستونیت‌ها، کرومیت و منگنز در محدوده سیاه چشمه و دیزج صورت گرفته است. در مرحله پردازش از روش نوین ساعت شنی اتوماتیک (ASH) مبتنی بر روش‌های طیفی مذکور به منظور تعیین مناطق دگرسان شده و تفکیک کانی‌ها استفاده شده است. به منظور طبقه‌بندی تصاویر نیز از روش‌های شبکه عصبی کانولوشن عمیق (CNN)، ماشین بردار پشتیبان (SVM) و درخت تصمیم J48 (DT) استفاده شده است. در نهایت مدل‌های مختلف بر اساس معیارهای ارزیابی مختلف مقایسه و مدل CNN با دقت و صحت ۹۸٪ نسبت به دو مدل SVM و DT با دقت و صحت ۹۶٪ به‌عنوان بهترین مدل برای تهیه نقشه کلاسه‌بندی استفاده شده است.

کلیدواژه‌ها: دورسنجی، ساعت شنی اتوماتیک، شبکه عصبی کانولوشن، ماشین بردار پشتیبان، درخت تصمیم.

### ۱. مقدمه

برداشت‌های مستقیم ژئوشیمیایی و ژئوفیزیکی پرهزینه و زمان‌بر بوده که با استفاده از پردازش تصاویر ماهواره‌ای و تکنیک‌های دورسنجی می‌توان تا حدود زیادی در زمان و هزینه صرفه‌جویی کرد. استفاده از این تکنیک‌ها امکان شناسایی و پی‌جویی مواد معدنی در یک ناحیه وسیع را با دقت و سرعت بالا و هزینه کم میسر می‌سازد. سنجش از دور علم کسب، پردازش و تفسیر داده‌های ماهواره‌ای است که بدون تماس فیزیکی با آن پدیده و از فاصله دور اطلاعات ارزنده‌ای در اختیار ما قرار می‌دهد [۲]. این تصاویر و داده‌ها عکس‌العمل بین ماده و انرژی الکترومغناطیسی را ثبت می‌کنند. نمای کلی از مراحل مختلف دورسنجی و دریافت تصاویر ماهواره‌ای در شکل (۱) نشان داده شده است [۲].


فعالیت‌های اکتشافی به‌عنوان بخشی از یک استراتژی برای مشخص کردن یک ماده معدنی خاص در یک ایالت متالوژی به کار می‌رود. اکتشافات بزرگ اغلب به چند پروژه مستقل برای انجام فعالیت‌ها تقسیم می‌شوند و هر پروژه یک یا چند پی‌جویی را در برمی‌گیرد. این اکتشافات از مقیاس منطقه‌ای شروع شده و سرانجام به مقیاس محلی ختم می‌گردد. در هر یک از مراحل مختلف اکتشاف، فعالیت‌های متعددی (اعم از نمونه‌گیری صحرائی، برداشت‌های مختلف ژئوشیمیایی و ژئوفیزیکی، دورسنجی و حفاری) صورت گرفته و در آخر نقاط هدف مشخص می‌شود [۱].

پی‌جویی‌های زمینی و مستقیم در وسعت بالا برای

عمیق<sup>۲</sup> برای مشخص کردن مناطق دگرسان شده و مستعد کانی سازی در این پژوهش استفاده شده است. ضرورت انجام این پژوهش، وجود نشانه‌های معدنی و مناطق مستعد کانی سازی در محدوده سیاه چشمه و دیزج و نیاز اساسی برای مشخص کردن این مناطق خواهد بود. همچنین با توجه به وجود بستر مناسب برای حضور ماگما و نفوذ محلول‌های هیدروترمال در استان آذربایجان غربی و قرارگیری این استان در ایالت‌های متالوژی سندنجد-سیرجان و ارومیه-دختر و کنتاکت بین این دو زون و هم‌چنین زون افیولیتی موجود در منطقه، تمرکزهایی از کانی‌سازی طلا، جیوه به‌صورت رگه‌ای، منگنز، آهن و کانی‌های لیستونیت، فوشسیت، مگنیت، کوارتز، کرومیت و هارزبورژیت‌های سرپانتینی شده در سرپانتینیت‌ها در این استان شکل گرفته است. علاوه بر این، گسل‌های مرتبط با مناطق سرپانتینیزه شده، لیستونیت‌ها و کرومیت‌ها دلیل شایانی برای تعیین و تشخیص پدیده‌های مختلف زمین‌شناسی در این منطقه است [۴].

به همین جهت در این پژوهش سعی در استفاده از روش‌های کارآمد و استراتژیکی است که به بهترین شکل ممکن مناطق پرتازسیل کانی سازی را مشخص کند. این روش‌ها شامل روش پردازش ساعت شنی اتوماتیک<sup>۳</sup> و روش‌های کلاسه‌بندی نظیر شبکه عصبی کانولوشن عمیق<sup>۴</sup>، ماشین بردار پشتیبان<sup>۵</sup> و درخت تصمیم<sup>۶</sup> J48 می‌باشد.

به‌طور کلی در این پژوهش با استفاده از تصاویر ماهواره‌ای ASTER مربوط به منطقه مورد مطالعه واقع در نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ سیاه چشمه و دیزج و استفاده از تکنیک‌های مختلف سنجش‌ازدور، مناطق مستعد و امیدبخش کانی‌سازی تعیین شده است. در ابتدا با استفاده از نرم‌افزار ENVI پیش‌پردازش‌های لازم جهت اجرای پردازش‌های مختلف نظیر MTMF، SAM و LSU مبتنی بر ساعت شنی اتوماتیک روی تصویر ماهواره‌ای ASTER صورت گرفته است. همچنین به‌منظور استفاده از روش‌های یادگیری ماشین و عمیق، مدل‌های شبکه عصبی کانولوشن عمیق، ماشین بردار پشتیبان و درخت تصمیم J48 به‌منظور کلاسه‌بندی تصویر ماهواره‌ای ASTER در محیط MATLAB R2021b کد نویسی شده است. سپس نتایج حاصل از روش‌های پیشرفته سنجش‌ازدور با استفاده از معیارهای ارزیابی مختلف، مقایسه شده است. در نهایت نیز به‌منظور پس پردازش داده‌ها و تفسیر نتایج، مناطق مستعد و امیدبخش حاصل از متدهای معتبر به‌منظور مقایسه و اعتبار سنجی در محیط Arc Map به همراه گسل‌ها، نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ و



شکل (۱). نمای کلی فرآیند سنجش‌ازدور [۲]

روش‌های سنجش‌ازدور امروزه به‌عنوان روش‌های سریع با میدان دید گسترده در اکتشافات ذخایر معدنی به‌منظور تشخیص آلتراسیون‌ها، کانی‌ها و تفکیک لیتولوژی منطقه محسوب می‌شوند. روش‌های دورسنجی به‌عنوان بهترین و کارآمدترین روش اکتشافی در مناطق کوهستانی، مرزی و مناطقی که فاقد اطلاعات کافی زمین‌شناختی، ژئوشیمیایی و ژئوفیزیکی هستند، محسوب می‌گردد. بنابراین، بررسی و برنامه‌ریزی اصولی برای اکتشاف این مناطق با استفاده از روش‌های اکتشافی بهینه، امری ضروری خواهد بود. داده‌های سنجش‌ازدور پتانسیل بالایی برای شناسایی نواحی دگرسان شده مربوط به توده‌های کانسار و در نتیجه اکتشاف ذخایر معدنی در ناحیه مورد نظر رادارند. تصاویر ماهواره‌ای به دلیل قابلیت پوشش چند طیفی و زمانی در منطقه وسیع، می‌توانند برای تفکیک زون‌های دگرسانی، کلاسه‌بندی لیتولوژی‌های مختلف، تفکیک کانی‌ها، شناسایی ایالت‌ها، کمربندها، خطواره‌ها و مکان‌های کانی‌زایی استفاده شوند. همچنین تصاویر ماهواره‌ای متعددی از ماهواره‌های مختلف وجود دارد که بسته به توان تفکیک مکانی، رادیومتریکی و طیفی و در دسترس بودن این تصاویر، مورد استفاده قرار می‌گیرند [۳].

با توجه به قرارگیری منطقه در زون افیولیتی و ایالت متالوژی مطلوب جهت کانی‌سازی، عدم وجود اطلاعات کافی زمین‌شناسی، کانی‌شناسی، گسل‌ها، نمونه‌های ژئوشیمیایی و رسوبات آبراهه و هزینه مالی و زمانی زیاد جهت برداشت و آنالیز نمونه‌های ژئوشیمیایی در این منطقه، پردازش تصاویر ماهواره‌ای و استفاده از تکنیک‌های پیشرفته سنجش‌ازدور، بهترین راه برای شناسایی مناطق مستعد و امیدبخش کانی‌سازی در منطقه سیاه چشمه و دیزج محسوب می‌گردد. بنابراین می‌توان از روش‌های اکتشافی سریع و ارزان برای مشخص کردن زون‌های دگرسانی و کانی‌های مدنظر واقع در منطقه مورد مطالعه استفاده کرد. یکی از مهم‌ترین روش‌های اکتشافی کارآمد استفاده از روش‌های پیشرفته سنجش‌ازدور می‌باشد. لذا از روش‌های پیشرفته سنجش‌ازدور و روش‌های کلاسه‌بندی مبتنی بر یادگیری ماشین<sup>۱</sup> و یادگیری

<sup>۴</sup> Deep Convolutional Neural Network (DCNN)

<sup>۵</sup> Support Vector Machine (SVM)

<sup>۶</sup> Decision Tree (DT)

<sup>۱</sup> Machine Learning (ML)

<sup>۲</sup> Deep Learning (DL)

<sup>۳</sup> Automated Spectral Hourglass (ASH)

نمونه‌های آنالیز شده، نشان داده شده است.

## ۲. زمین‌شناسی منطقه

محدوده مورد مطالعه در این پژوهش، قسمت مشخصی از نقشه ۱:۱۰۰۰۰۰ سیاه چشمه و دیزج در شمال غرب ایران واقع در استان آذربایجان غربی در مرز دو کشور ایران و ترکیه می‌باشد (شکل ۲). این محدوده با وسعت ۷۸۱ کیلومتر مربع بر اساس تقسیمات واحدهای ساختمانی رسوبی ایران (اشتوکلین)، بخشی از کمربند دگرگونی و افیولیتی سنندج-سیرجان و بر اساس تقسیمات افتخارنژاد، بخشی از زون آمیزه رنگین و افیولیتی محسوب می‌گردد. مجموعه سنگ‌های افیولیتی شامل سنگ‌های اولترامافیک، بازالت‌های بالشی به همراه سنگ‌های آهکی، دایک‌های دیابازی و توده‌های نفوذی گابرو-دیوریتو میکروگابرو است. همچنین سیستم‌های مختلف گسله به صورت N70W، N35W و N30E می‌باشد. از لحاظ زمین‌شناسی اقتصادی، کانی کرومیت در حوالی روستای تودان در درون سنگ‌های الترامافیک به صورت عدسی‌های کم ضخامت دیده شده است. سنگ‌های دربرگیرنده از نوع هارزبورژیت‌ها و دونیت‌های سرپانتینیزه شده است. قرارگیری محدوده مورد مطالعه در زون افیولیتی شمال غرب ایران بر روی نقشه ساختاری ایران در شکل (۳) نشان داده شده است. واحدهای سنگی تشکیل‌دهنده منطقه مورد مطالعه، در نقشه‌های زمین‌شناسی ۱:۱۰۰۰۰۰ سیاه چشمه و دیزج در شکل (۴) نشان داده شده است.

به منظور تهیه بانک اطلاعاتی مورد نیاز و کلیدهای اکتشافی برای انجام مطالعات دور سنجی، بررسی مطالعات پیشین صورت گرفته در این منطقه و مناطق مشابه با این منطقه امری اساسی خواهد بود. لیستونیت‌های موجود در منطقه خوی سه دسته می‌باشند [۵]:




(۱) لیستونیت‌های سیلیسی که عمدتاً از کانی‌های کوارتز،

کلسدون، اوپال و هیدروکسیدهای ثانویه آهن به عنوان کانی‌های اصلی و منیزیت، دولومیت، کلسیت و کانی‌های رسی به عنوان کانی‌های فرعی تشکیل شده‌اند. لیستونیت‌های سیلیسی منبع اصلی برای حضور طلا و جیوه می‌باشند.

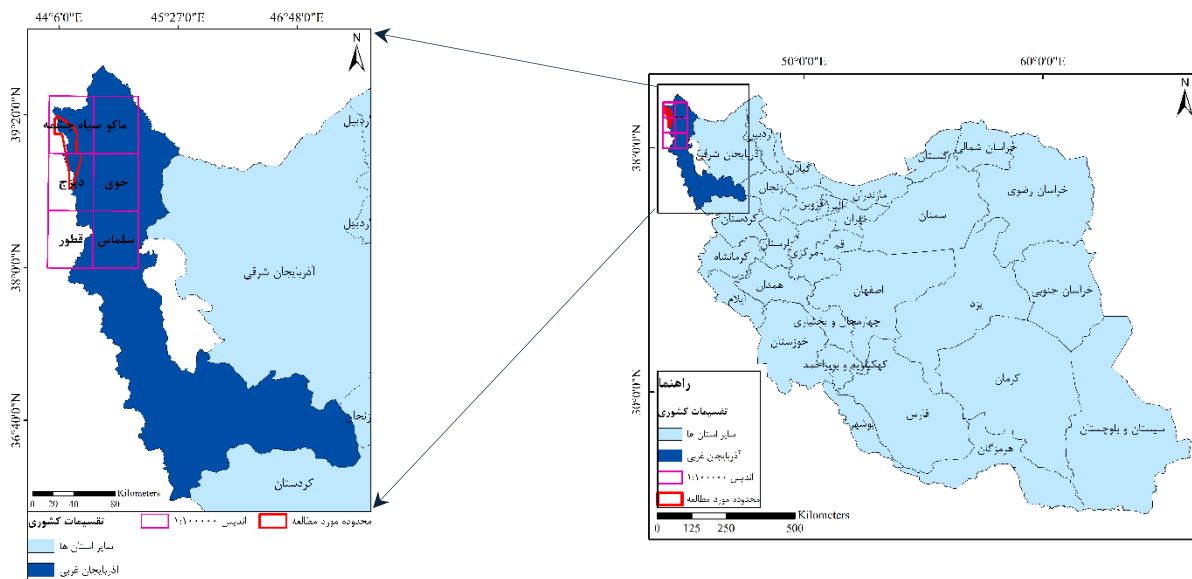
(۲) لیستونیت‌های سیلیسی-کربناته که از مقدار کانی‌های سیلیسی کاسته و به مقدار کانی‌های کربناته افزوده می‌شود. در این لیستونیت‌ها، کلسیم، منیزیم و سیلیکات‌های منگنز جانشین سنگ‌های الترامافیک می‌شوند.

(۳) لیستونیت‌های کربناته که فاقد کانی‌های سیلیسی بوده و در آن‌ها مقادیر استرانسیم و دولومیت زیاد است.

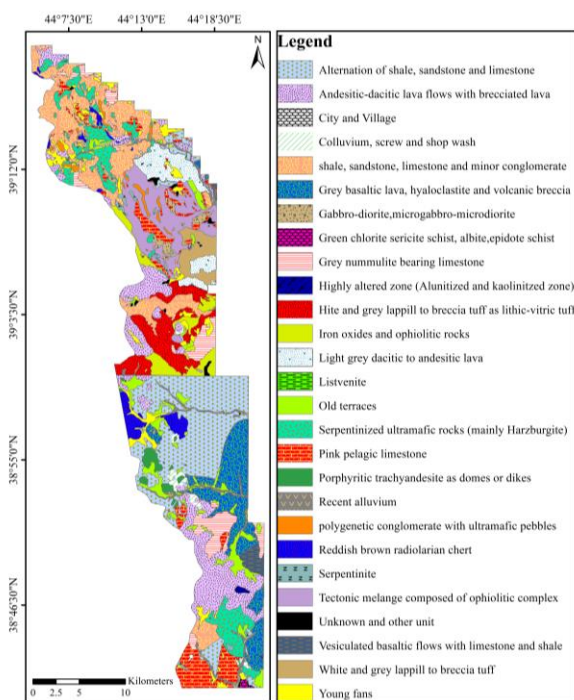
لیستونیت‌ها عموماً به صورت سنگ‌های فوشسیت (مسکوویت کروم‌دار) و کوارتز و همچنین کربنات‌های مشتق شده از سنگ‌های اولترامافیک به وسیله متاسوماتیسم کربناته ایجاد می‌گردد. لیستونیت‌ها به طور معمول مرتبط با گسل‌های اصلی و شیئرزون‌ها می‌باشند. لیستونیت‌ها عموماً در تراست‌های بازالتی و در طول گسل‌های موجود در ساختارهای افیولیتی شکل می‌گیرند و همراه با فوشسیت، کوارتز و کروم-اسپینل می‌باشند. ترکیب سنگی لیستونیت‌ها عموماً سنگ‌های برشی می‌باشند. این لیستونیت‌ها در دمای حداقل ۱۰۰-۸۰ درجه و حداکثر ۳۵۰-۲۰۰ درجه تشکیل می‌گردند. یک فرم کلی از تشکیل لیستونیت‌ها به صورت معادله‌های (۱-۳) می‌باشد [۶]:



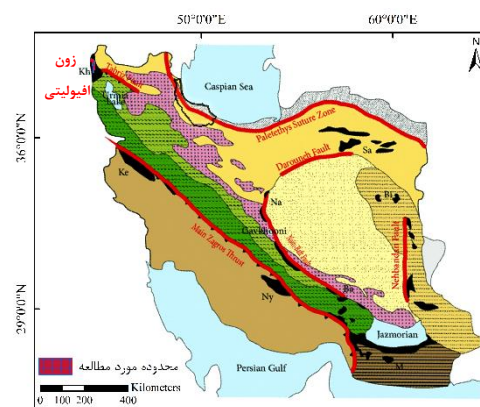
**Listvenites**



شکل (۲). موقعیت جغرافیایی منطقه مورد مطالعه در محدوده سیاه چشمه و دیزج



شکل (۴). نقشه زمین شناسی محدوده مورد مطالعه



شکل (۳). قرارگیری محدوده مورد مطالعه در زون افیولیتی شمال غرب ایران

### ۳. روش تحقیق

#### • حذف اثر پوشش‌های گیاهی

شاخص پوشش گیاهی شاخصی است که به منظور توصیف پوشش گیاهی توسعه یافته و با استفاده از تفاوت بین مادون قرمز نزدیک (که توسط گیاهان بازتابش می‌شود) و نور قرمز (که توسط گیاهان جذب می‌شود) می‌تواند نقاط دارای پوشش گیاهی را نمایان سازد. در مباحث اکتشاف کانی‌ها و آلتراسیون‌ها هدف اصلی مشخص کردن این شاخص و حذف پوشش‌های گیاهی می‌باشد. شاخص NDVI از طریق رابطه (۴) محاسبه می‌گردد [۹].

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (4)$$

#### ۳-۲. پردازش‌های پیشرفته

یک مشکل اساسی در استفاده از تصاویر ماهواره‌ای مختلف، حضور پیکسل‌های مخلوط می‌باشد. به طوری که طیف یک پیکسل ترکیب طیف‌های پوشش‌دهنده سطحی آن بوده که شناسایی این اعضای انتهایی<sup>۱</sup> یکی از موارد اساسی در صحت تجزیه طیفی در دور سنجی می‌باشد. استخراج مناسب خوشه‌های اعضای انتهایی بر میزان عدم قطعیت فرآیند طبقه‌بندی تصاویر ماهواره‌ای و استفاده از روش‌های طیف-مینا تأثیرگذار است. به این دلیل روش‌های گوناگونی نظیر ترتیب استفاده از فرآیندهای MNF، PPI و N-Dimensional برای مشخص کردن پیکسل‌های خالص وجود در نظر گرفته شده است. در ادامه نیز با توجه به مقادیر بالاتر Score و SFF به دست آمده برای هر کانی، هر خوشه به کانی مورد نظر نسبت داده می‌شود [۱۰]. به منظور تعیین پیکسل‌های خالص طبقه‌بندی شده جهت استفاده در روش‌های پردازش طیفی می‌توان از روش کاملاً خودکار ساعت شنی طیفی اتوماتیک استفاده کرد.

#### • ساعت شنی اتوماتیک

متد ساعت شنی اتوماتیک یک روش نوین برای پردازش داده‌های سنجش‌ازدور می‌باشد. در این روش فرآیندهای مختلف روی داده‌های پیش پردازش شده به صورت خودکار انجام می‌گردد. روش ساعت شنی طیفی اتوماتیک با استفاده از داده‌های طیفی فرا تعیین شده برای پیدا کردن خالص‌ترین اعضای انتهایی به منظور مشخص کردن موقعیت و تخمین فراوانی آن‌ها استفاده می‌گردد. این فرآیندها شامل سه مرحله زیر خواهد بود [۱۱]:

(۱) تبدیل کسر کمترین نویز (MNF).

(۲) اندیس پیکسل‌های خالص (PPI).

#### ۳-۱. پیش پردازش داده‌ها

اولین مرحله پردازش داده‌ها مرحله پیش پردازش است که در آن خطاها، نویزها و اعوجاج‌های موجود در تصاویر شناسایی و تصحیح می‌شوند. سپس داده‌های تصحیح شده در مرحله پردازش مورد استفاده قرار می‌گیرند.

#### • تصحیحات رادیومتریک و اتمسفریک

یکی از مهم‌ترین پیش پردازش‌های تصاویر ماهواره‌ای، تصحیحات رادیومتریک به منظور برطرف سازی خطاهای رادیومتریک موجود در آن‌ها است. هر عاملی که بر روی انرژی رسیده به سنجنده به گونه‌ای اثر بگذارد که انرژی رسیده به سنجنده با انرژی منتشر شده از سطح زمین یکسان نباشد، به عنوان یک خطای رادیومتریک شناخته خواهد شد. در تصحیحات رادیومتریک هدف محاسبه پارامترهایی چون تابندگی و بازتابش ناشی از لایه‌های بالایی اتمسفر و تعدیل این خطاها بر اساس پارامتر رادیانس می‌باشد. تصحیح اتمسفری در راستای تصحیح رادیومتریک است. در تصحیح اتمسفری می‌توان اثر پخش و جذب امواج الکترومغناطیسی از روی باندهای بازتابی را حذف کرد تا از این طریق بازتاب‌های طیفی به درستی تصحیح شده و امکان انجام پردازش‌های طیفی نیز در گام‌های بعدی فراهم شود [۷]. در این مطالعه از روش Radiometric Calibration برای انجام تصحیحات رادیومتریک (تعیین تابندگی داده‌ها) و از روش FLAASH برای انجام تصحیحات اتمسفریک استفاده شده است.

#### • تصحیحات هندسی

یکی دیگر از تصحیحات مهم در مرحله پیش پردازش، تصحیحات هندسی می‌باشد. منظور از تصحیح هندسی شامل حذف و نرمال سازی عواملی نظیر ارتفاع پدیده‌های سطح زمین، زاویه دید ماهواره و شکل زمین است که هندسه تصاویر را دچار اعوجاج می‌کند. بیشتر تصاویر ماهواره‌ای مورد استفاده در دورسنجی دارای مقادیر مکانی مشخصی می‌باشند. به این معنی که دارای مقادیر طول و عرض جغرافیایی بوده و در اصطلاح فرآیند رجیستری روی آن‌ها صورت گرفته است ولی به طرز دقیق زمین مرجع نشده‌اند و ممکن است عارضه‌های مختلف با مکان اصلی خود شیفت داشته باشد [۸]. در این مطالعه از روش Image to Image با استفاده از تصویر هوایی منطقه مطالعه حاصل از نرم افزار SAS Planet استفاده شده است.

۳) تعیین اعضای انتهایی به صورت خودکار به کمک فضای  $n$ -بعدی.

در این متد، فرآیند حذف پیوسته اعضای انتهایی استخراج شده برای جدایش ویژگی‌های طیفی آن‌ها و فرار دادن آن‌ها در یک شرایط برابر اعمال شده تا اعضای انتهایی استخراج شده با یکدیگر مقایسه شوند. حذف مداوم و مقایسه ویژگی، کلید شناسایی طیفی موفقیت‌آمیز می‌باشد. به منظور تنظیم پارامترهای این روش برای استخراج پیکسل‌های خالص تعداد باندهای MNF، تعداد تکرارهای PPI، مقدار حدآستانه PPI و حداکثر تعداد پیکسل‌های PPI اعمال شده برای انتخاب اعضای انتهایی به عنوان ورودی در نظر گرفته می‌شود [۱۱].

در این روش کاربر می‌تواند به صورت گام به گام و خودکار اقدام به پردازش داده‌های موجود با استفاده از اعضای انتهایی به دست آمده نماید. به طوری که پس از وارد کردن داده‌ها و اعضای انتهایی به دست آمده (به صورت فایل ASCII، فایل کتابخانه مرجع و فایل ROI/EVF)، روش یا روش‌های موردنظر جهت پردازش تعیین می‌گردد. این روش‌ها شامل روش‌های فیلتر تنظیم پیکسل‌های مخلوط همسان<sup>۱</sup>، نقشه بردار زاویه طیفی<sup>۲</sup> و نا آمیختگی طیفی خطی<sup>۳</sup> می‌باشد. متد پردازش ساعت شنی از ماهیت بسیار دقیق داده‌های ابرطیفی پرده برداری کرده و برای یافتن خالص ترین طیف یا منحصربه‌فردترین طیف پیکسل (اعضای انتهایی) در مجموعه داده استفاده می‌کند. این جریان پردازش با داده‌های ورودی بازتاب شروع می‌شود. روش ساعت شنی اتوماتیک یک روش دقیق و قوی در پردازش داده‌ها بوده و صحت نتایج خروجی به دست آمده نسبت به روش‌های بصری بالاتر می‌باشد. به همین جهت نتایج خروجی به دست آمده از روش‌های MTMF، SAM و LSU در متد ساعت شنی اتوماتیک دقت و صحت بالاتری نسبت به پیاده‌سازی رایج این روش‌ها خواهد داشت [۱۲].

#### • فیلتر تطبیق پیکسل‌های مخلوط همسان

روش MTMF نخستین بار توسط بوردمن<sup>۴</sup> مطرح شد و بر اساس آن، این روش یک آنالیز برای پیکسل‌های ترکیبی مبتنی بر طیف اعضای انتهایی به دست آمده با استفاده از روش PPI می‌باشد. در واقع روش MTMF یک روش ترکیبی بر اساس روش‌های پردازش سیگنال و نظریه ترکیبی خطی است. این روش ترکیبی از روش فیلترینگ تطبیقی<sup>۵</sup> و محدودیت‌های اعمال شده بر اساس ترکیب خطی مؤلفه‌های فردی هر پیکسل می‌باشد. این روش شامل

دو مرحله است [۱۲]:

۱) مرحله فیلتر همسان شده (MF): این مرحله برای پیدا کردن فراوانی اعضای تعریف شده با استفاده از یک جزء خالص می‌باشد. این روش فقط تا حدودی روی پیکسل‌های خالص به منظور شناسایی ویژگی‌های طیفی به کار گرفته می‌شود. در واقع این روش پیکسل‌های هدف را برجسته و پس‌زمینه را محو می‌کند.

۲) مرحله تنظیم مخلوط (MT): این مرحله به منظور مشخص کردن پیکسل‌های مثبت کاذب برای از بین بردن نویزها از پس‌زمینه می‌باشد.

در واقع روش MTMF توسعه یافته روش MF می‌باشد که تصاویر عدم امکان<sup>۶</sup> به آن اضافه شده و ورودی آن، پیکسل‌های خالص می‌باشد. این روش اثر اعضای انتهایی را با ماکزیمم کردن مقدار سیگنال به نویز (SNR) بیشینه و اثر نامطلوب پس‌زمینه مخلوط را کمینه می‌کند. این روش یک روش سریع و کاربردی جهت شناسایی مناطق هدف (آلتراسیون یا کانی‌های مربوط به اعضای انتهایی) از طریق انطباق طیف اعضای انتهایی می‌باشد. تصاویر عدم امکان برای کمینه کردن تعداد پاسخ‌های کاذبی است که در مرحله اول (MF) مشخص شده است [۱۳].

#### • نقشه بردار زاویه طیفی

روش SAM برای اولین بار توسط کروی<sup>۷</sup> و همکاران در سال ۱۹۹۳ مطرح شد. این روش یک روش طبقه‌بندی نظارت شده زیر پیکسلی برای طبقه‌بندی پیکسل‌ها بر اساس خصوصیات طیفی آن‌ها می‌باشد. بر این اساس طیف‌های مربوط به پیکسل‌های خالص منطقه مورد مطالعه به عنوان ورودی دستور در نظر گرفته شده و بر اساس شباهت موجود بین طیف این پیکسل‌ها و سایر پیکسل‌های موجود در تصویر، فرآیند طبقه‌بندی صورت می‌گیرد [۱۴].

بنابراین روش SAM با استفاده از تشابه طیفی پیکسل‌های خالص وارد شده و طیف بازتابی تصویر، فرآیند طبقه‌بندی را انجام می‌دهد. این روش، زاویه طیفی (فاصله بین طول موج‌های دو باند مجاور) بین طیف هر پیکسل و طیف پدیده موردنظر (داده‌های آموزشی) را محاسبه می‌کند و بر اساس مقدار این زاویه فرآیند طبقه‌بندی صورت می‌گیرد. مقادیر پایین این زاویه طیفی بیانگر تشابه بیشتر و مقادیر بالای آن بیانگر تشابه کمتر آن پیکسل با پدیده موردنظر خواهد بود. بدین معنی که هر چه این زاویه کمتر

<sup>۵</sup> Matched Filtering

<sup>۶</sup> Infeasibility

<sup>۷</sup> F. A. Kruse

<sup>۱</sup> Mixture Tuned Matched Filtering (MTMF)

<sup>۲</sup> Spectral Angle Mapper (SAM)

<sup>۳</sup> Linear Spectral Unmixing (LSU)

<sup>۴</sup> Boardman

طرح اصلی یادگیری عمیق و اجرای آن در علوم مختلف توسط پروفیسور هینتون در سال ۲۰۰۶ مطرح شد [۱۶]. در شبکه‌های عصبی کانولوشن از یک واحد خطی اصلاح شده<sup>۲</sup> برای حذف مقادیر منفی از تابع فعال‌سازی و جلوگیری از مشکلات Over fitting استفاده می‌گردد. این فرآیند همواره به دنبال لایه کانولوشن می‌باشد. عملیات حداکثر پولینگ<sup>۳</sup> برای ساده‌سازی خروجی با انجام نمونه‌گیری غیرخطی و کاهش تعداد پارامترهایی که شبکه برای یادگیری نیاز دارد، استفاده می‌گردد. پس از آن لایه کاملاً متصل<sup>۴</sup> برداری با ابعاد  $k$  (تعداد کلاس‌هایی که شبکه قادر به کلاسه‌بندی آن‌ها می‌باشد) را استخراج می‌کند. هر نرون از سطح ویژگی استخراج شده در لایه کانولوشن به صورت محلی به ورودی آن متصل می‌باشد و مجموع وزنی با وزن اتصال موجود و مقدار جبرانی به ورودی محلی اضافه می‌گردد. در فرآیند آموزش، الگوریتم گرادیان نزولی عموماً به‌عنوان تابع زیان انتخاب می‌شود. مقدار باقیمانده به‌وسیله گرادیان نزولی برای آپدیت مقادیر آموزشی وزن‌ها ( $w$ ) و بایاس ( $b$ ) در هر لایه CNN به صورت لایه به لایه پس‌انتشار می‌یابد. شبکه عصبی کانولوشن به مقدار زیادی داده اولیه جهت آموزش نیاز ندارد و آموزش چنین مجموعه داده‌هایی در مقیاس بزرگ بسیار زمان‌بر خواهد بود. با این وجود مجموعه داده‌های سنجش‌ازدور برای آموزش شبکه اعم از زمان‌بر بودن آن، بسیار مناسب می‌باشد. همچنین بهینه‌سازی ساختار شبکه اهمیت بسیار ویژه در آموزش شبکه خواهد داشت. [۱۷].

نمای کلی از مدل CNN رایج در پردازش تصویر در شکل (۵) نشان داده شده است [۱۸]. در هر شبکه عصبی کانولوشن تصویر ورودی وارد شبکه شده و پس از ضرب نقطه‌ای بین ورودی نرون‌ها و پارامترهای هر نرون، خروجی شبکه محاسبه می‌گردد. به‌منظور تنظیم پارامترهای شبکه (آموزش شبکه) نیز پس از محاسبه خطای شبکه از نتیجه خروجی، مرحله بعد آغاز می‌شود. در این مرحله بر اساس روش مورد استفاده در تنظیم پارامترهای شبکه، تمامی پارامترها با توجه به تأثیر جزئی آن پارامتر در ایجاد خطای شبکه، تغییر پیدا کرده و بعد از آپدیت پارامترهای موردنظر، مرحله اول دوباره شروع به کار می‌کند [۱۹].

باشد شکل طیفی یک پدیده با پدیده دیگر بارزتر شده و مقایسه طیفی بین پیکسل مرجع و پیکسل تصویر با دقت بالاتری انجام می‌شود [۱۴].

#### • نا آمیختگی طیفی خطی

روش LSU یک روش پردازش زیر پیکسل می‌باشد که برای تعیین نسبت مواد تشکیل‌دهنده در یک پیکسل بر اساس مشخصات طیفی مواد به کار می‌رود. در محیط‌های زمین‌شناسی بیشتر پیکسل‌های یک تصویر خالص نیستند و ارزش هر پیکسل اغلب مخلوطی از انرژی‌های بازتابی یا گسیل‌شده از مواد مختلف در میدان دید لحظه‌ای است. بنابراین خروجی این پردازش یک مجموعه از تصاویر است که برای هر عضو انتهایی انتخابی فراوانی آن رده را در پیکسل به تصویر می‌کشد. انعکاس طیفی مخلوط در این روش از طریق رابطه (۵) محاسبه می‌گردد [15]:

$$R_i = \sum_{j=1}^n f_j r_{ij} + \varepsilon_i, \quad \sum f_i = 1; \quad (5)$$

$$i = 1, \dots, L$$

$$0 \leq f_j \leq 1$$

در این رابطه  $i$  باند طیفی سنجنده مورد استفاده،  $L$  تعداد باندهای سنجنده،  $j$  شماره عضو انتهایی موردنظر،  $n$  تعداد اعضای انتهایی،  $R_i$  انعکاس طیفی مخلوط در پیکسل مربوط به باند  $i$ ،  $f_j$  فراوانی عضو انتهایی  $j$ ام در آن پیکسل،  $r_{ij}$  انعکاس حاصل از عضو انتهایی  $j$ ام در باند  $i$  و  $\varepsilon_i$  خطای باقیمانده در باند  $i$  می‌باشد.

نتایج خالص طیفی یک سری تصاویر خاکستری برای هر عضو انتهایی و تصویر خطای جذر میانگین مربعات<sup>۱</sup> است. در تصاویر خاکستری فراوانی‌های بالاتر و در تصویر RMS خطای بالاتر با پیکسل‌های روشن نشان داده می‌شوند. نتایج خالص طیفی به مقدار زیادی به طیف عضو انتهایی بستگی داشته و تغییر در عضو انتهایی نتایج را تغییر خواهد داد. مشاهده تصاویر RMS به تعیین عضو انتهایی اشتباه و گم‌شده کمک شایانی خواهد کرد [۱۵].

### ۳-۳. پردازش‌های مبتنی بر یادگیری ماشین و یادگیری

#### عمیق

#### • شبکه عصبی کانولوشن عمیق (CNN)

<sup>۲</sup> Max Pooling Oprtation

<sup>۴</sup> Fully Connected Layer

<sup>۱</sup> Root Mean Square Error (RMSE)


<sup>۲</sup> Rectified Linear Unit (ReLU)

جدول (۱). توابع کرنل محبوب در روش ماشین بردار پشتیبان غیرخطی جدانشدنی [۲۲]

نوع تابع کرنل	رابطه
Linear kernel	$K(x, u) = x^T \cdot u$
Polynomial Function	$K(x, u) = (ax^T u + c)^q, q > 0$
Hyperbolic Tangent (Sigmoid)	$K(x, u) = \tanh(\beta x^T u + \gamma)$
Gaussian radial basis function (RBF)	$K(x, u) = \exp\left(-\frac{\ x - u\ ^2}{\sigma^2}\right)$
Laplacian radial basis function	$K(x, u) = \exp\left(-\frac{\ x - u\ }{\sigma}\right)$


• درخت تصمیم (DT)

درخت تصمیم یک ساختار درختی شبیه به فلوجارت است که به طور گسترده برای نشان دادن مدل های طبقه بندی مورد استفاده قرار می گیرد که در آن هر گره درونی (گره غیر برگ) دلالت بر یک آزمون روی یک صفت دارد. هر شاخه بیانگر نتیجه آزمون بوده و هر گره برگ (گره ترمینال) یک برچسب کلاس را نگهداری می کند. بالاترین گره در درخت، گره ریشه است [۲۳]. در شکل (۷)، نمونه ای از درخت تصمیم کلی برای طبقه بندی ارائه شده است. [۲۴].



شکل (۷). نمونه درخت تصمیم معمولی برای طبقه بندی [۲۴].


مدل طبقه بندی J48 یک درخت تصمیم C4.5 ساده برای کلاسه بندی می باشد که یک درخت دودویی را ایجاد می کند. J48 در حال ساخت درخت، مقادیر ازدست رفته را نادیده می گیرد و مقدار آن مورد را بر مبنای آنچه برای مقادیر دیگر رکوردها وجود دارد، پیش بینی می کند. این روش از الگوریتم Information Gain Ratio (IGR) به جای Information Gain (IG) در روش



شکل (۵). مراحل مختلف شبکه عصبی کانولوشن [۱۹].

• ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یکی از رایج ترین طبقه بندی کننده ها در حوزه یادگیری ماشین است که داده ها را با استفاده از یک هایپرپلان جداکننده بهینه، طبقه بندی می کند. یکی از مزایای کلیدی SVM برای برنامه های سنجش از دور، توانایی آن در مدیریت داده های با ابعاد بالا با استفاده از تعداد کمی نمونه آموزشی می باشد. این طبقه بندی کننده دارای دو پارامتر آزاد است که هدف کلی تنظیم این دو پارامتر می باشد. پارامتر C (پنالتی در بخش خطا) و  $\delta$  (حاشیه تحمل) دو پارامتر اساسی SVM، معمولاً با اعتبار متقابل نمونه های آموزشی و جستجوی شبکه انتخاب می شوند [۲۰]. در شکل (۶) نمای کلی از ماشین بردار پشتیبان و نحوه عملکرد آن نشان داده شده است [۲۱].



شکل (۶). نمای کلی طبقه بندی کننده SVM و نحوه عملکرد آن

[۲۱]

زمانی که داده ها به صورت خطی در فضای ورودی قابل جدا شدن نمی باشند، روش ماشین بردار پشتیبان حاشیه نرم و حاشیه سخت قادر به پیدا کردن هایپرپلان بهینه جداسازی نخواهد بود. برای جداسازی خطی داده ها می توان از کرنل ها برای تبدیل داده ها به ابعاد بالاتر استفاده کرد. بنابراین در فضای کرنل یک هایپرپلان خطی می تواند برای جدایش کلاس های مختلف استفاده شود. توابع کرنل محبوب در جدول (۱) نشان داده شده است [۲۲].



ID3 استفاده می‌کند [۲۵].

#### • مروری بر روش‌های پیشین

در یک مطالعه برای مشخص کردن دگرسانی‌های هیدروترمال و ساختارهای خطی مرتبط با کانی‌سازی طلا در ناحیه سقز در استان کردستان واقع در زون سنندج-سیرجان با استفاده از داده‌های تصاویر ASTER و روش‌های آنالیز مؤلفه‌های اصلی، زاویه طیفی و دیورژانس اطلاعات طیفی استفاده کرده‌اند. بنابر نتایج به‌دست‌آمده، روش‌های مذکور موجب افزایش سرعت و کارایی پی‌جویی‌های اولیه برای انجام مطالعات ژئوشیمیایی در مراحل بعدی می‌گردد [۲۸]

در یک تحقیق برای شناسایی مناطق مستعد کانی‌سازی فلزات پایه از طریق دگرسانی‌های فیلیک، اکسید آهن، آرژیلیک، پروپیلیتیک و سیلیسی‌شدگی در منطقه تروند سمنان واقع در کمربند ماگمایی تروند-چاه شیرین از متدهای آنالیز مؤلفه‌های اصلی، تبدیل کسر کمترین نویز، برازش کمترین مربعات<sup>۱</sup>، زاویه طیفی و برازش خصوصیات طیفی<sup>۲</sup> بهره برده‌اند. بر اساس این نتایج روش‌های برازش کمترین مربعات و برازش خصوصیات طیفی عملکرد بهتری برای آشکارسازی آلتراسیون‌های هیدروترمال نسبت به سایر روش‌ها داشته‌اند [۲۹]

در گزارش دیگر از روش‌های نسبت باندی، عمق باند نسبی، آنالیز مؤلفه‌های اصلی و فیلتر تنظیم پیکسل‌های مخلوط همسان در تصاویر ASTER برای مشخص کردن آلتراسیون‌های هیدروترمال با استفاده از باندهای مادون قرمز طول موج کوتاه، سیلیسی‌شدگی با استفاده از باندهای حرارتی و اکسیدهای آهن با استفاده از باندهای مادون قرمز نزدیک در قسمت غربی یزد استفاده کرده‌اند. بر این اساس روش فیلتر تنظیم پیکسل‌های مخلوط همسان عملکرد بهتری برای شناسایی آلتراسیون‌ها نسبت به روش‌های دیگر داشته است [۳۰]

در یک مطالعه با استفاده از داده‌های تصاویر ASTER، زون‌های دگرسانی هیدروترمال مرتبط با سیستم‌های پورفیری منطقه جبال بارز واقع در جنوب شرقی ایران را مشخص کرده‌اند. در این مطالعه پس از پیش‌پردازش تصاویر از روش‌های نسبت باندی، ترکیب رنگی کاذب و زاویه طیفی برای جداسازی دگرسانی‌ها استفاده شده است. بر اساس نتایج، زون‌های دگرسانی فیلیک و آرژیلیک گسترده‌ای مشاهده شده است، به گونه‌ای که آلتراسیون آرژیلیک توسط آلتراسیون پروپیلیتیک محاصره شده است. هم‌چنین نفوذهای گرانیته‌توئیدی بیشترین آلتراسیون را به خود اختصاص داده‌اند [۳۰]

همچنین با استفاده از تصاویر ماهواره‌های ASTER و

$$IGR_A(D) = \frac{IG(A)}{Entropy_A(D)} \quad (۶)$$

$$IG(A) = Entropy(D) - Entropy_A(D) \quad (۷)$$

$$E(D) = - \sum_{i=1}^c P_i \times \log_2(P_i) \quad (۸)$$

$$E_A(D) = - \sum_{j=1}^v \frac{|D_j|}{|D|} \times Entropy(D_j) \quad (۹)$$

که در آن در  $P_i$  احتمال اینکه نمونه‌ای از داده‌ها مربوط به کلاس  $i$ ام باشد،  $C$  تعداد برجسب کلاس‌های موجود در داده‌های آموزشی،  $v$  تعداد اعضای دامنه‌ی صفت خاصه‌ی  $A$ ،  $D_j$  قسمتی از داده‌های اولیه که مقدار صفت خاصه‌ی آن‌ها  $V_j$  است،  $E(D)$  پارامتر آنتروپی و  $|D|$  اندازه‌ی داده‌های  $D$  می‌باشد [۲۵]. الگوریتم J48 می‌تواند ویژگی‌های عددی را اداره کرده و با استفاده از معیارهای نسبی تأثیر به‌سزایی در القای مقادیر گم‌شده داشته باشد. تمام تقسیمات معقول دوتایی که از داده‌های آموزشی استخراج می‌شود، مورد بررسی قرار گرفته و یکی از آن‌ها با بهترین رتبه (در اینجا بزرگ‌ترین مقدار برای Information Gain Ratio) انتخاب می‌شود. نحوه اجرای الگوریتم J48 در جدول (۲) نشان داده شده است [۲۶، ۲۷].

جدول (۲). نحوه اجرای الگوریتم J48 [۲۷]

الگوریتم J48	
۱:	بارگذاری داده‌ها و راه‌اندازی اولیه
۲:	حلقه for: برای هر ویژگی $A$ انجام دهید
۳:	محاسبه مقدار نرمال شده $IGR(A)$
۴:	پیدا کردن ویژگی با مقدار ماکزیمم $IGR$
۵:	تولید یک گره تصمیم با تقسیم آن ویژگی
۶:	تکرار در سرتاسر ویژگی‌های تقسیم‌ناپذیر
۷:	پایان حلقه for
* $A$ : مقادیر ویژگی	
* $IGR(A)$ : مقدار Information Gain Ratio برای ویژگی $A$	

<sup>۱</sup> Spectral Feature Fitting (SFF)

<sup>۲</sup> Least Squares Fitting (LS-Fit)

#### ۱-۱-۴. موزائیک کردن دو فریم ASTER و برش تصویر بر

##### اساس منطقه مورد مطالعه

به منظور سهولت انجام مباحث دورسنجی و قرارگیری محدوده مورد مطالعه در دو فریم تصاویر ASTER، از فرآیند موزائیک کردن استفاده می‌گردد. این فرآیند به صورت جداگانه روی محدوده‌های مختلف VNIR، SWIR و TIR صورت می‌گیرد. همچنین به منظور یکسان کردن اندازه پیکسل‌های مربوط به باندهای VNIR (با قدرت تفکیک مکانی ۱۵ متر) و باندهای SWIR (با قدرت تفکیک مکانی ۳۰ متر) از فرآیند باز نمونه برداری<sup>۱</sup> در قدرت تفکیک مکانی با اندازه ۳۰ متر استفاده شده است. بنابراین قدرت تفکیک مکانی تمامی باندها برابر ۳۰ متر در نظر گرفته شده است.

#### ۲-۱-۴. تصحیحات رادیومتریک و اتمسفریک

با استفاده از این تصحیح داده‌های موجود از حیث خطاهای رادیومتریکی اصلاح شده‌اند. بدین منظور رادیانس مربوط به محدوده‌های طیفی VNIR و SWIR با استفاده از دستور Calibration Radiometric محاسبه و پس از استک کردن این دو محدوده طیفی تصحیح اتمسفریک با استفاده از روش FLAASH صورت گرفته است. قبل از انجام این تصحیحات طیف مربوط به یک پیکسل طیف نادرستی از خود نشان می‌داد و بعد از انجام این تصحیحات هر پیکسل طیف درستی را به خود گرفت.

#### ۳-۱-۴. تصحیحات بعد از FLAASH

بعد از فرآیند FLAASH مقادیر پیکسل‌ها اعداد منفی و اعداد بسیار بزرگ به خود می‌گیرد که با این مقادیر نمی‌توان شاخص‌های مختلف طیفی<sup>۲</sup> را محاسبه کرد. بدین معنی که مقادیر بازتاب سطحی<sup>۳</sup> بعد از تصحیح اتمسفریک FLAASH در محدوده نرمال قرار نخواهند گرفت. بدین منظور برای نرمال‌سازی داده‌ها و قرارگیری مقادیر هر پیکسل بین اعداد صفر و یک، از فرآیند Rescaling طبق رابطه (۱۰) استفاده شده است.

$$\text{Float}((b1 \leq 0) * 0 + (b1 \geq 10000) * 1 + (b1 > 0 \text{ and } b1 < 10000) * \text{float}(b1/10000.0)) \quad (10)$$

#### ۴-۱-۴. حذف اثر پوشش‌های گیاهی

به دلیل تأثیر پوشش‌های گیاهی سبز در روش‌های مختلف پردازش تصاویر، با استفاده از شاخص NDVI، این پیکسل‌ها را مشخص کرده و به عنوان ماسک با مقدار DN Value=0 روی تصویر اصلی اعمال می‌کنیم. بازه در نظر گرفته شده NDVI [۰/۳ و ۰/۳-] جهت حذف پوشش‌های گیاهی سبز می‌باشد.

Landsat-8 زون‌های آلتراسیون هیدروترمال مرتبط با کانی‌سازی طلا را در ناحیه‌ای در شرق کامرون مشخص کرده‌اند. این ناحیه چندین رگه کوارتز طلا دار مرتبط با پیریتی‌شدگی، اکسیدهای آهن، سیلیسی‌شدگی، سریزیت و مسکوویت را در برمی‌گیرد. در این مطالعه از روش‌های آنالیز مؤلفه‌های اصلی، آنالیز مؤلفه‌های مستقل و نسبت‌های باندی برای استخراج اطلاعات طیفی مرتبط با اکسیدهای آهن، گروه کانی‌های کربناتی و سیلیسی‌شدگی برای تصاویر Landsat-8 در مقیاس ناحیه‌ای استفاده شده است. همچنین از روش زیر پیکسل با استفاده از الگوریتم تجزیه طیفی خطی برای تفکیک جزئی کانی‌های ه‌ماتیت، جاروسیت، کائولینیت، مسکوویت، کلریت و اپیدوت برای تصاویر داده‌های ASTER در مقیاس محلی استفاده شده است. با این وجود نیز، از تکنیک ساعت شنی اتوماتیک برای استخراج طیف‌های مرجع از باندهای ASTER به طور مستقیم برای ایجاد تصاویر جزئی از اعضای انتهایی با استفاده از الگوریتم تجزیه طیفی خطی استفاده شده است. در نهایت نیز دگرسانی‌های مرتبط با گسل‌ها بهترین مناطق برای پی‌جویی کانی‌سازی طلا می‌باشند. بنابراین استفاده از روش‌های دورسنجی به کاربر اجازه می‌دهد که فاکتورهای مزاحم (پوشش‌های گیاهی و لاتریتی‌شدگی) را جداسازی و خطای مربوط به آن‌ها را کمینه کند.

بر اساس یک مقاله، اخیراً فناوری‌های هوش مصنوعی به دلیل کاربردهای عملی در زمینه‌های مختلف مورد توجه بسیاری قرار گرفته‌اند. عامل اصلی این موفقیت، یادگیری ماشین است که از پردازش اطلاعات در مغزهای بیولوژیکی الهام گرفته است. در این مطالعه، یکی از تکنیک‌های یادگیری بانام شبکه‌های عصبی کانولوشن (CNNs) برای پیش‌بینی نوسان شاخص سهام استفاده شده است. علاوه بر این، توپولوژی شبکه CNN برای بهبود عملکرد مدل، بهینه گشته است. CNN پارامترهای زیادی دارد که برای ساختن یک مدل بهینه که می‌تواند الگوهای داده را به صورت کارآمد یاد بگیرد، باید تنظیم شود. این مطالعه روشی را برای بهینه‌سازی سیستماتیک پارامترهای مدل CNN با استفاده از الگوریتم ژنتیک (GA) ارائه می‌دهد. برای تأیید اثربخشی مدل، نتیجه پیش‌بینی با شبکه‌های عصبی مصنوعی استاندارد (ANNs) و مدل‌های CNN مقایسه شده است. [۳۱]

#### ۴. نتایج و بحث

#### ۱-۴. پیش‌پردازش داده‌ها

<sup>۲</sup> Surface Reflectance

<sup>۱</sup> Resampling

<sup>۲</sup> Spectral Indices

۴-۲. پردازش داده‌ها

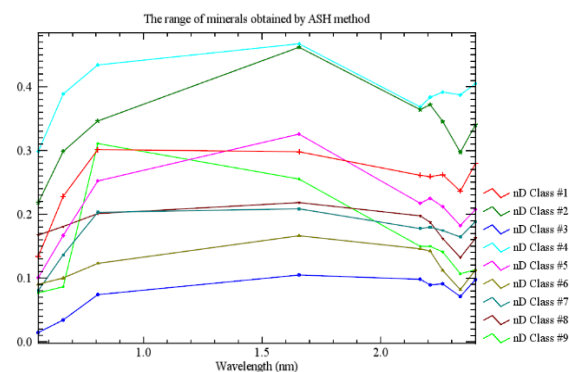
۴-۲-۱. ساعت شنی اتوماتیک

به‌منظور تنظیم پارامترها برای استخراج پیکسل‌های خالص، تعداد باندهای MNF برابر ۹، تعداد تکرارهای PPI برابر ۱۰۰۰۰، مقدار حد آستانه PPI برابر ۲/۵ و حداکثر تعداد پیکسل‌های PPI اعمال‌شده برای انتخاب اعضای انتهایی برابر ۱۰۰۰۰ به‌عنوان ورودی روش ساعت شنی اتوماتیک در نظر گرفته‌شده است.

با توجه به کلاس‌های به‌دست‌آمده از ۹ باند MNF و استفاده از نمایشگر n-بعدی به‌صورت خودکار و آنالیز طیفی با استفاده از پارامتر میانگین طیفی (Mean) در طیف‌های به‌دست‌آمده، می‌توان بر اساس پارامترهای SFF و Score شباهت هر طیف حاصله و طیف کانی‌های موجود در کتابخانه مرجع USGS را مورد بررسی قرار داد.

این فرآیند از طریق آنالیز طیفی و کتابخانه طیفی مرجع Nikolet و Beckman حاصل شده است. بر اساس این نتایج طیف کانی‌هایی که مقدار SFF و Score نزدیک به یک دارند، شباهت بیشتری به طیف‌های حاصله از پیکسل‌های خالص در روش ساعت شنی اتوماتیک خواهند داشت.

نمودارهای طیفی به‌دست‌آمده در شکل (۸) و نتایج حاصل از آنالیز طیفی برای هر کلاس در جدول (۳) نشان داده‌شده است.



شکل (۸). طیف پیکسل‌های خالص به‌دست‌آمده در خوشه‌های مختلف در روش ساعت شنی اتوماتیک

جدول (۳). نتایج حاصل از آنالیز طیفی برای هر کلاس در روش ساعت شنی اتوماتیک

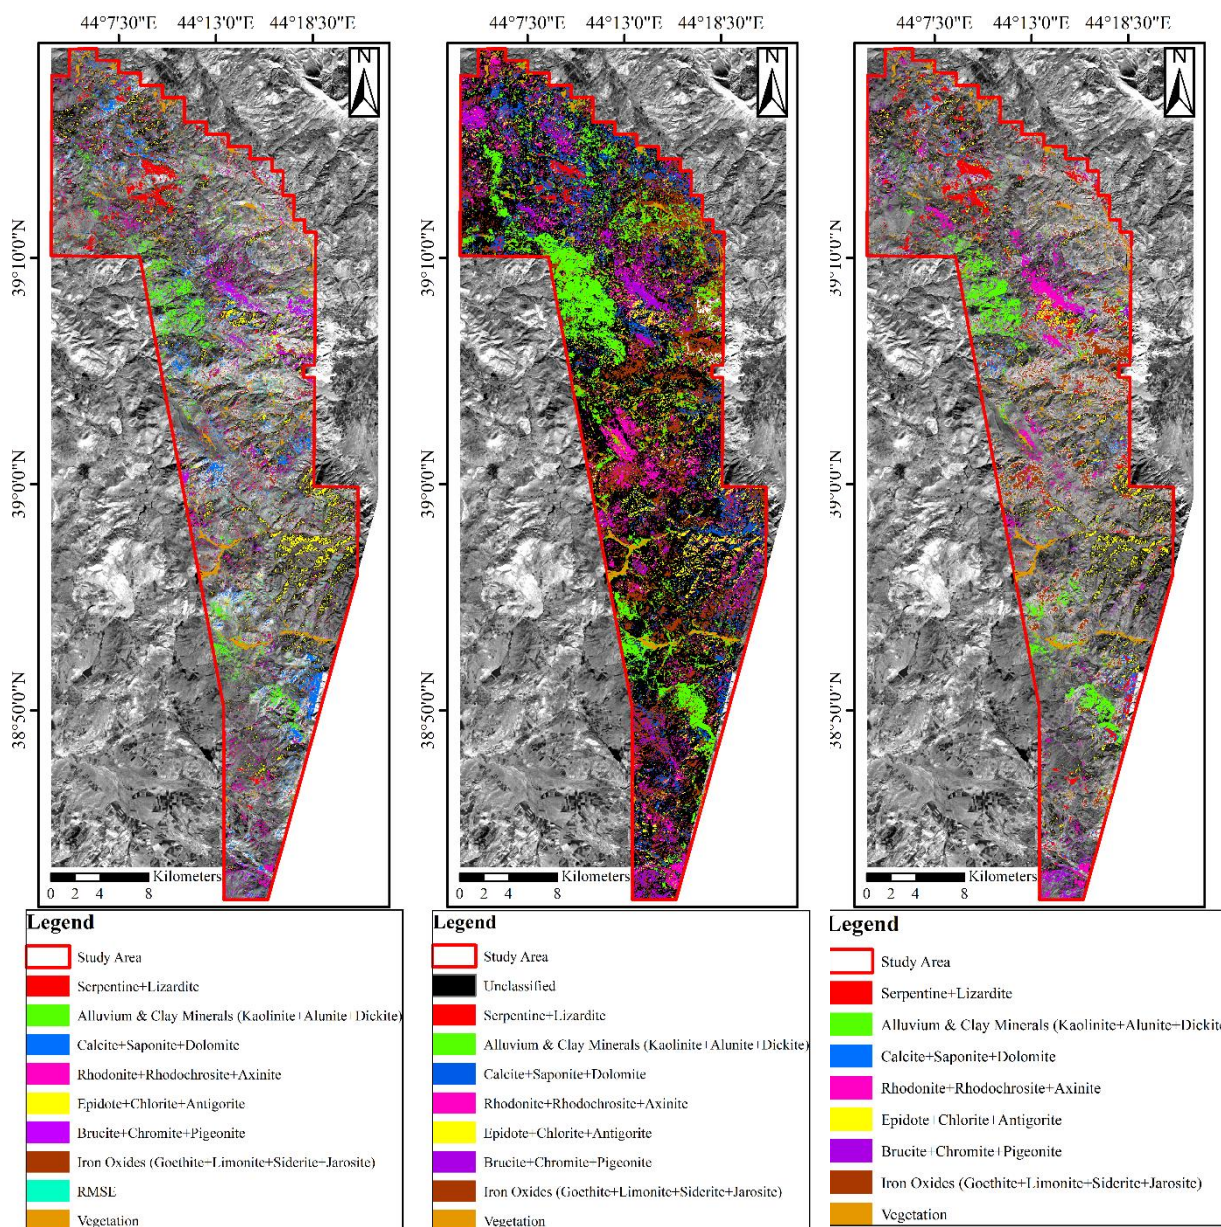
nD class number	نام کانی	SFF Score
nD class #1	بروسیت	۰/۹۲۵

۰/۹۱۴	کرومیت	nD class #2
۰/۹۰۱	پیگونیت	
۰/۹۲۹	کلسیت	
۰/۸۲۹	ساپونیت	
۰/۸۴۸	دولومیت	nD class #3
۰/۹۵۷	اپیدوت	
۰/۸۵۳	کلریت	
۰/۷۳۲	آنتی‌گوریت	nD class #4
۰/۸۹۵	پیگونیت	
۰/۸۲۳	اوژیت	nD class #5
۰/۹۵۳	کانولینیت	
۰/۸۷۴	آلونیت	
۰/۷۸۶	دیکیت	
۰/۹۴۰	سرپانتین	nD class #6
۰/۹۲۷	لیزاردیت	
۰/۸۰۳	رودنیت	nD class #7
۰/۷۱۴	رودوکروزیت	
۰/۶۸۴	آکسینیت	
۰/۹۲۹	گوتیت	nD class #8
۰/۸۹۴	لیمونیت	
۰/۸۴۱	سیدریت	
۰/۸۲۱	جاروسیت	
نزدیک به صفر	پوشش گیاهی	
		nD class #9

با استفاده از پیکسل‌های خالص به‌دست‌آمده از روش PPI به‌صورت خودکار و استفاده از آنالیز طیفی به‌منظور شناخت و خوشه‌بندی هر یک از پیکسل‌های خالص، نتایج حاصل از این

مقادیر MF و Infeasibility. خروجی تصویر SAM تصویر کلاسه‌بندی شده و خروجی LSU نیز مقادیر تک‌کلاسه هر طیف مرجع و مقادیر RMSE می‌باشد که به ترتیب در اشکال (۹ تا ۱۱) نشان داده شده است.

فرآیند به‌عنوان ورودی به‌صورت فایل ROI برای روش‌های SAM، MTMF و LSU به‌صورت خودکار در نظر گرفته می‌شود. درنهایت نیز پس از اتمام فرآیند ساعت شنی اتوماتیک، نتایج حاصل از هر روش نشان داده می‌شود. خروجی تصویر MTMF



شکل (۱۱). آلتراسیون ها و کانی‌های به‌دست‌آمده از روش LSU

شکل (۱۰). آلتراسیون ها و کانی‌های به‌دست‌آمده از روش SAM

شکل (۹). آلتراسیون ها و کانی‌های به‌دست‌آمده از روش MTMF

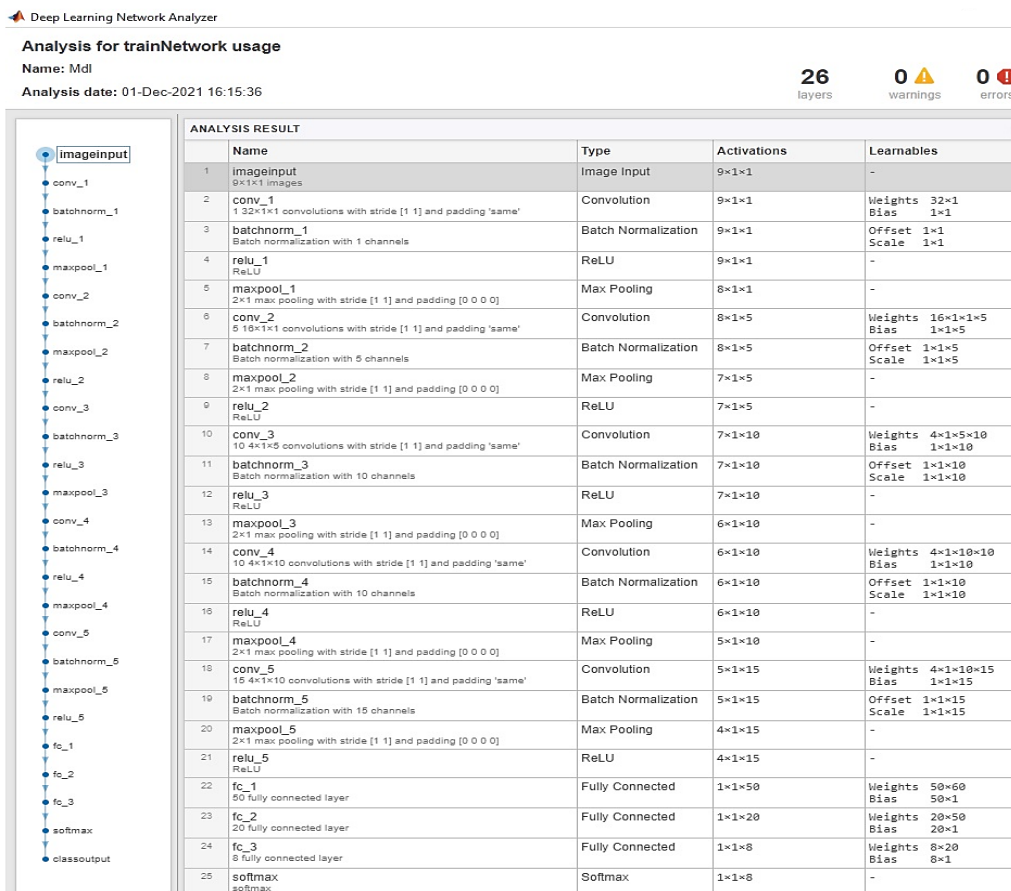
به داخل شبکه در نظر گرفته شده است. فایل حاوی داده‌های دارای برجستگی کلاس مشخص نیز، به‌عنوان ورودی بر نامه تعریف شده و به‌صورت تصادفی با استفاده از قاعده ۷۰ به ۳۰، ۷۰٪ آن‌ها به‌عنوان مجموعه داده آموزشی و ۳۰٪ مابقی به‌عنوان مجموعه داده آزمون در نظر گرفته شده است. تعداد کل داده‌های

۲-۲-۴. شبکه عصبی کانولوشن (CNN) در این بخش از برنامه کد نویسی شده شبکه عصبی کانولوشن عمیق در محیط متلب برای طبقه‌بندی تصویر ماهواره‌ای ASTER استفاده شده است. داده‌های ورودی تصویر ASTER شامل ۹ باند VNIR+SWIR به‌عنوان کانال‌های ورودی تصویر

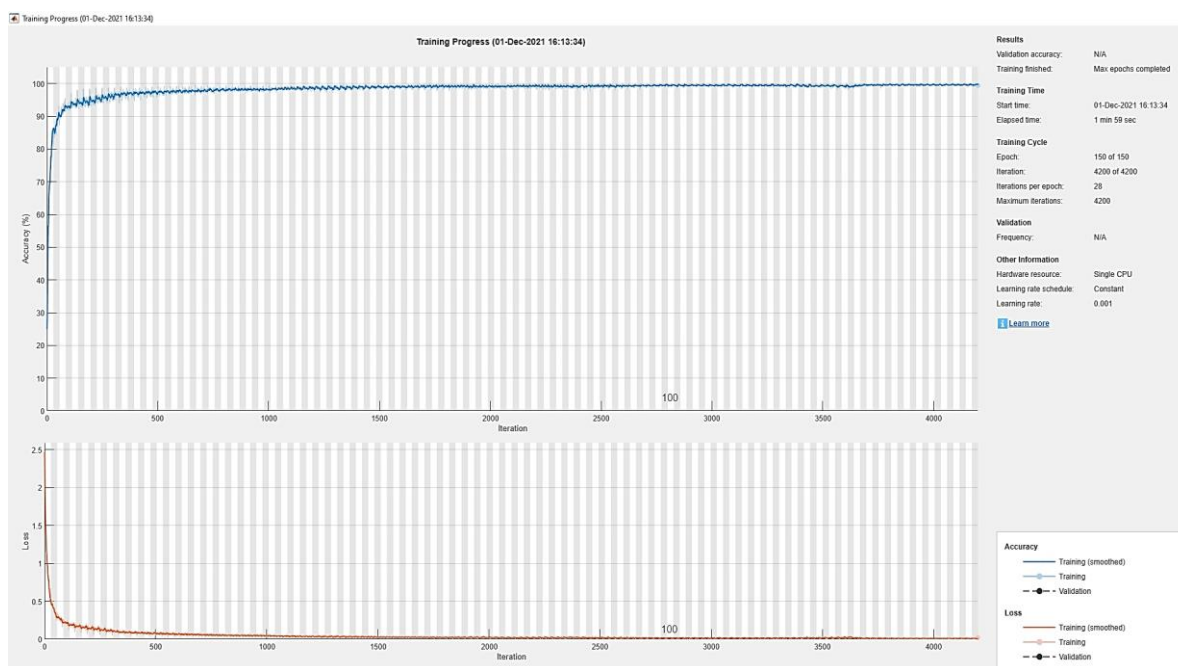
بهترین قواعد ReLU استخراج خواهد شد. سپس کانال‌های برگزیده تصویر وارد لایه‌های کاملاً متصل شده و در نهایت نیز تصویر خروجی حاصل می‌شود.

فرآیند آموزش از وزن‌های اولیه تصادفی استفاده می‌کند. پس از کامل شدن هر Batch از آموزش، نرخ یادگیری تغییر کرده و وزن‌ها به طور مداوم برای یافتن مقدار بهینه تنظیم می‌شوند که باعث کاهش مقدار تابع هزینه و افزایش تابع هدف در فرآیند آموزش می‌گردد. پس از هر دوره، پارامترهای آموزش‌دیده در فایل‌ها ذخیره‌شده و برای ارزیابی مجموعه داده آزمون و تعیین دقت در هر دوره استفاده می‌شوند. پس از گذراندن ۱۵۰ دوره، تابع هزینه در فرآیند آموزش به تدریج به حداقل رسید. تعداد کلی تکرارها برابر ۴۲۰۰، تعداد تکرارها در هر دوره برابر ۲۸ و مقدار نرخ یادگیری برابر ۰/۰۰۱ در نظر گرفته شده است. طرح کلی معماری مدل شبکه عصبی CNN و نمودار همگرا شدن به ترتیب در شکل‌های (۱۲) و (۱۳) نشان داده شده است.

دارای برچسب کلاس مشخص ۲۰۸۸۱ بوده که ۱۴۶۱۶ داده به‌عنوان مجموعه داده آموزشی و ۶۲۶۵ داده به‌عنوان مجموعه داده آزمون در نظر گرفته شده است. با استفاده از کانال‌های ورودی داده‌های آموزشی، فرآیند آموزش آغاز می‌گردد. کانال‌های تصویر به دنبال اولین لایه کانولوشن گشته و مهم‌ترین ویژگی‌های کانال‌های تصویر استخراج می‌گردد. اندازه کرنل کانولوشن در این مطالعه خاص برابر ۳۲ و گام کرنل برابر ۵ در نظر گرفته شده است. با توجه به حساسیت این روش، اگر مقدار این اعداد از مقادیر در نظر گرفته شده بیشتر شود، امکان رسیدن به دقت بالاتر افزایش یافته ولی از طرف دیگر محاسبات شبکه پیچیده شده و تعداد پارامترها افزایش یافته و ممکن است با مشکل Over fitting داده‌ها مواجه شویم. در مرحله بعدی Batch Normalization با استفاده از کانال‌های ورودی صورت گرفته و قاعده ReLU استخراج می‌شود. در مرحله پولینگ نیز از روش Max pooling برای نگهداری ویژگی‌ها و حفظ اطلاعات تصویر و جبران خطای پارامترها در لایه کانولوشن استفاده شده است. بدین ترتیب این مراحل با توجه به اندازه و گام کرنل تکرار می‌شود و



شکل (۱۲). طرح کلی معماری شبکه عصبی CNN در محیط متلب



شکل (۱۳). نمودار همگرا شدن مدل شبکه عصبی CNN در محیط متلب

۴) و نتایج مقادیر تخمین زده شده، معیارهای ارزیابی مختلف طبق جدول (۵) محاسبه شده است. با توجه به این جدول، مدل CNN با دقت و صحت مناسب (بیش از ۹۸٪) عملیات کلاسه‌بندی را انجام داده است. نتایج این مدل کلاسه‌بندی در شکل (۱۴) نشان داده شده است.

برای پیاده‌سازی این مدل روی داده‌های اصلی تصویر ماهواره‌ای، مدل موردنظر اعتبارسنجی شده و میزان دقت و صحت و پارامترهای دیگر ارزیابی شده است. بدین منظور از مدل CNN آموزش‌دیده برای تعیین برچسب کلاس ۳۰٪ داده‌های دارای برچسب کلاس مشخص استفاده شده است. به منظور بررسی و ارزیابی دقت و صحت مدل CNN بر اساس ماتریس ابهام (جدول

جدول (۴). ماتریس ابهام مربوط به مدل CNN برای کلاس‌های مختلف نمونه مربوط به الگوریتم (پیش‌بینی شده)

پوشش گیاهی	اکسیدهای آهن	بروسیت/کرومیت	اپیدوت/کلریت	رودونیت/رودوکرو	کلسیت/دولومیت	آبرفت /کانی‌های	لیزاردیت/سریپانتی	کلاس‌ها	نمونه مربوط به کلاس واقعی
۰	۰	۰	۶	۰	۰	۱	۷۰۶	لیزاردیت/سریپانتین	
۱۲	۱	۰	۰	۰	۰	۱۰۳۶	۰	آبرفت /کانی‌های رسی	
۰	۰	۰	۰	۰	۲۸۱	۰	۰	کلسیت/دولومیت	
۱	۰	۲	۱	۴۹۶	۰	۰	۰	رودونیت/رودوکروزیت	
۳	۰	۰	۱۳۸۳	۱	۰	۰	۳	اپیدوت/کلریت	
۰	۱	۳۰۸	۰	۵	۰	۲	۰	بروسیت/کرومیت	
۱	۱۶۷	۱	۰	۰	۳	۲	۰	اکسیدهای آهن	
۱۸۲۰	۴	۰	۵	۰	۰	۱۲	۰	پوشش گیاهی	

جدول (۵). معیارهای ارزیابی دقت به‌دست‌آمده در مدل CNN

نام معیار	ضریب کاپا	دقت کلی	خطای مطلق (MAPE)	میانگین درصد	صحت	حساسیت (یادآوری)	تشخیص‌پذیری	معیار F-score
مقدار	۰/۹۸۶۸	۰/۹۸۹۳	۰/۰۱۴	۰/۹۸۶۰	۰/۹۸۶۰	۰/۹۸۶۸	۰/۹۹۸۳	۰/۹۸۶۴

بدین معنی که مدل SVM برای مجموعه داده‌های آموزش شی که دارای برچسب کلاس مشخص هستند، در سه حالت مختلف ایجاد شده و روی داده‌های آزمون پیاده‌سازی شده است. بر اساس معیارهای ارزیابی به‌دست‌آمده با کرنل‌های متفاوت، مدل SVM با کرنل Polynomial بیشترین دقت و صحت را داشته است. برای ارزیابی کارایی، دقت و صحت مدل SVM با کرنل‌های Linear, Gaussian و Polynomial بر اساس ماتریس ابهام و نتایج مقادیر تخمین زده شده، معیارهای ارزیابی مختلف بررسی شده است. با توجه به جدول (۶) مدل SVM با کرنل Polynomial با دقت و صحت مناسب (بیش از ۹۶٪) فرآیند کلاسه‌بندی را انجام داده است. مزیت اصلی این روش نسبت به سایر روش‌های کلاسه‌بندی، سرعت بالای پردازش‌ها و در نتیجه‌ی آن کاهش زمان محاسبات خواهد بود. نقشه کلاسه‌بندی شده با استفاده از مدل SVM در شکل (۱۵) نشان داده شده است.

#### ۴-۲-۳. ماشین بردار پشتیبان (SVM)

در این بخش نیز همانند بخش قبل از برنامه کد نویسی شده ماشین بردار پشتیبان جهت طبقه‌بندی تصویر ماهواره‌ای ASTER در محیط متلب استفاده شده است. با استفاده از کانال‌های ورودی (باند‌های تصویر) داده‌های آموزشی، فرآیند آموزش شروع شده و با استفاده از این داده‌ها و الگوریتم SVM در فرآیند یادگیری، مدل SVM ایجاد می‌گردد. به‌منظور استفاده از این مدل هاپیر پارامتر در حالت چندکلاسه از تابع fitcecoc به ازای  $n$  کلاس خروجی از  $\frac{n(n-1)}{2}$  استفاده خواهد شد. بر اساس مقادیر پیش‌فرض مدل SVM در نرم‌افزار متلب و تغییر تابع کرنل در سه حالت Linear, Gaussian و Polynomial، سه مدل متفاوت حاصل شده است

جدول (۶). معیارهای ارزیابی دقت به‌دست‌آمده در مدل SVM با کرنل‌های مختلف

نام معیار	ضریب کاپا	دقت کلی	خطای مطلق (MAPE)	میانگین درصد	صحت	حساسیت (یادآوری)	تشخیص‌پذیری	معیار F-score	خطای
مقدار در کرنل Linear	۰/۹۳۴۶	۰/۹۴۷۰	۰/۰۹۹	۰/۹۴۲۶	۰/۹۵۰۵	۰/۹۹۱۶	۰/۹۴۶۵	۰/۰۵۲۳	خطای طبقه‌بندی درون نمونه‌ای
مقدار در کرنل Gaussian	۰/۹۴۵۴	۰/۹۵۵۸	۰/۰۸۹	۰/۹۵۷۲	۰/۹۶۳۲	۰/۹۹۳۰	۰/۹۶۰۲	۰/۰۴۲۸	
مقدار در کرنل Polynomial	۰/۹۵۵۵	۰/۹۶۳۹	۰/۰۷۶	۰/۹۶۴۳	۰/۹۷۱۱	۰/۹۹۴۴	۰/۹۶۷۷	۰/۰۳۳۰	

انجام داده است. مزیت اصلی این روش نسبت به سایر روش‌های کلاسه‌بندی در حوزه یادگیری ماشین، سرعت بسیار بالای پردازش‌ها و ساختار درختی قابل فهم خواهد بود. نقشه کلاسه‌بندی شده این مدل در شکل (۱۶) نشان داده شده است.

#### ۴-۲-۴. درخت تصمیم J48

برای ساخت این مدل از دستور fitctree در محیط متلب استفاده شده است. این مدل با دقت بالا و سرشکن کردن خطاها در تمامی کلاس‌ها عملکرد خوبی را نشان داده است. برای ارزیابی کارایی، دقت و صحت مدل DT با استفاده از الگوریتم J48 بر اساس ماتریس ابهام و نتایج مقادیر تخمین زده شده، معیارهای ارزیابی مختلف بررسی شده است. با توجه به جدول (۷) این مدل با دقت و صحت مناسبی (بیش از ۹۶٪) فرآیند کلاسه‌بندی را

جدول (۷). معیارهای ارزیابی دقت به‌دست‌آمده در مدل DT

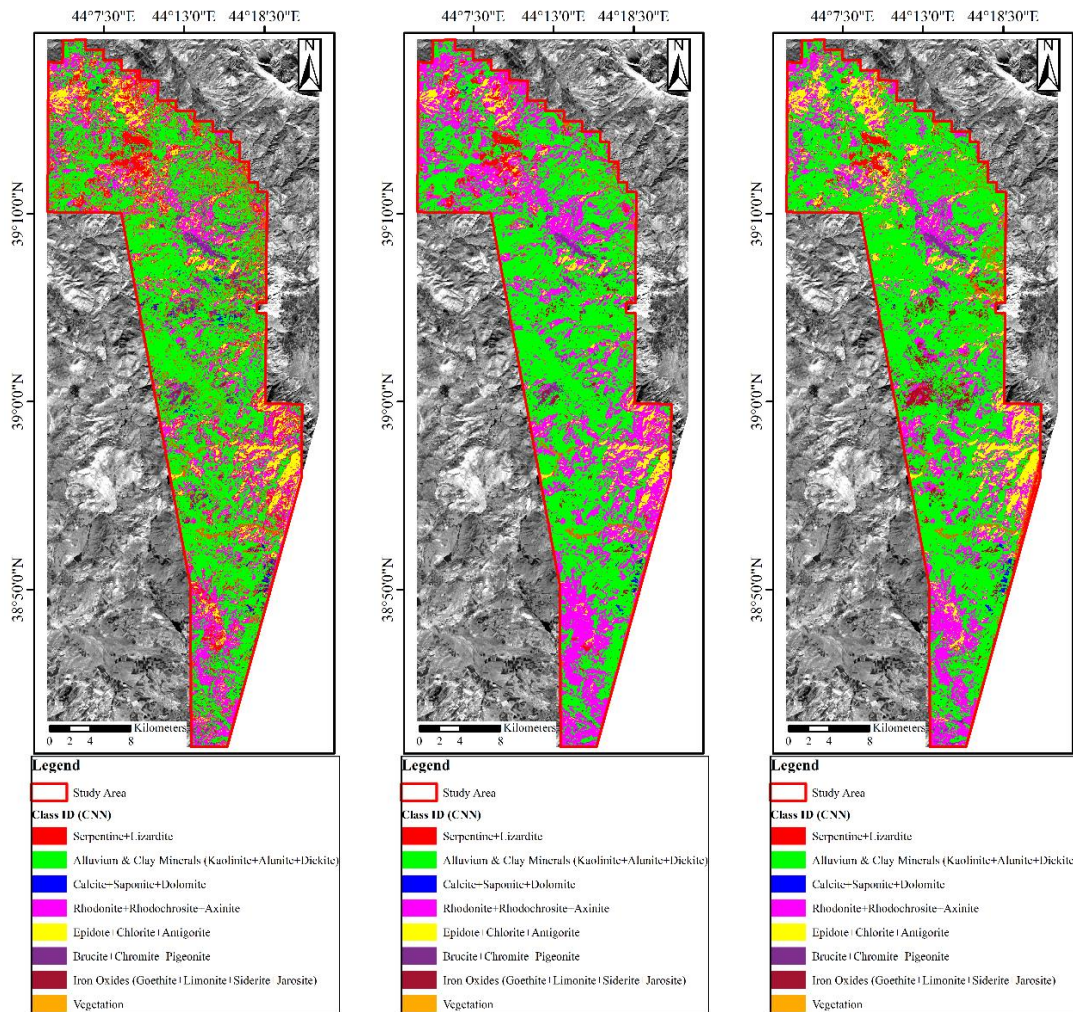
نام معیار	ضریب کاپا	دقت کلی	(MAPE)	صحت	حساسیت (یادآوری)	تشخیص‌پذیری	معیار F-score
مقدار	۰/۹۶۰۶	۰/۹۶۸۱	۰/۰۵	۰/۹۶۳۱	۰/۹۶۷۱	۰/۹۹۵۰	۰/۹۶۵۱

معیارهای ارزیابی مختلف در شکل (۱۷) بررسی شده است.

طبق این نمودار معیار F (F-Score)، ضریب کاپا (Kappa Coefficient) و میانگین درصد خطای مطلق (MAPE) روی محور افقی و مقادیر آن‌ها روی محور عمودی مشخص شده است. مقدار هر معیار برای مدل‌های CNN، SVM و DT به‌صورت نمودار میله‌ای نشان داده شده است.

۳-۴. ارزیابی عملکرد مدل‌های یادگیری ماشین و عمیق

بر اساس نتایج به‌دست‌آمده، سه مدل CNN، SVM و DT با دقت، صحت و کارایی تقریباً برابر توانسته‌اند فرآیند طبقه‌بندی را انجام داده و یک مدل بهینه جهت تهیه نقشه کلاسه‌بندی منطقه ایجاد کنند. باین حال با توجه به نتایج به‌دست‌آمده از معیارهای ارزیابی برای هر مدل، مدل CNN نسبت به مدل‌های SVM و DT عملکرد بهتری در تشخیص درست کلاس‌کانی‌ها و آلتراسیون‌های مختلف داشته است. برای مقایسه عملکرد مدل‌ها،



شکل (۱۶). نقشه کلاسه‌بندی منطقه با

استفاده از روش DT

شکل (۱۵). نقشه کلاسه‌بندی منطقه با

استفاده از روش SVM

شکل (۱۴). نقشه کلاسه‌بندی منطقه با

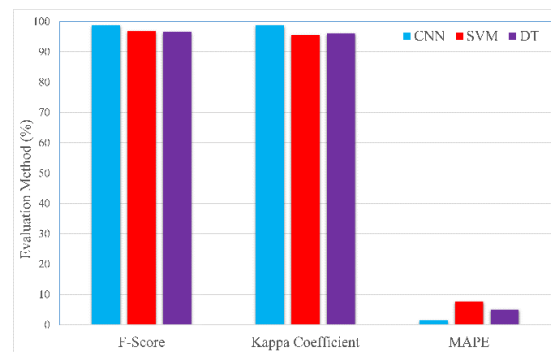
استفاده از روش CNN



مرکزی، زون افیولیتی حاوی کانی‌های پروسیت و کرومیت به صورت متمرکز (لایه نواری شکل) و پراکنده پیرامون اکسیدهای آهن و کانی‌های منگن‌دار قابل مشاهده است. تقاطع گسل‌های اصلی، فرعی و انگاشته شده در این بخش احتمال حضور کانی کرومیت را تا حد بسیاری افزایش خواهد داد.

با توجه به شکل (۱۶) اکثر گسل‌ها در بخش شمال‌غربی و مرکزی منطقه وجود داشته و مرتبط با کلاس کانی‌های به دست آمده در مناطق پرتانسیل و مستعد کانی سازی از طریق مدل‌های یادگیری ماشین و عمیق می‌باشد. همچنین نشانه‌های معدنی شناخته شده در این محدوده به صورت توصیفات زمین‌شناسی در راهنمای نقشه ذکر شده است. بر اساس این توصیفات، هارزبورژیت‌های سرپانتینی شده به صورت متعدد در بخش شمال‌غربی محدوده مشاهده شده است. بر اساس این شکل، ۷ نقطه کنترل صحرایی در منطقه سیاه چشمه و دیزج برداشت و مورد آنالیز شیمیایی قرار گرفته است. سه نقطه کنترلی آنالیز شده در بخش شمال‌غربی واقع در زون دگرسانی سرپانتینی شده قرار گرفته است. نمونه‌های برداشت شده در این بخش منطبق با نتایج حاصل از روش‌های پردازش و کلاسه‌بندی در تعیین کانی‌های لیزاردیت و سرپانتین می‌باشد. طبق نتایج آنالیز به دست آمده از سه نمونه برداشت شده، مقدار طلا ۴۲ppb، ۴۵ppb، ۷۴ppb بوده است. بر اساس آنومالی پی‌شهاد شده در این محدوده، واحدهای سنگی دربرگیرنده این آنومالی شامل سکانس‌های افیولیتی (الترامافیک) گابرو، گابرودیوریت، دیاباز، سنگ‌آهک و سیلیس می‌باشد. دگرسانی‌های موجود نیز از نوع سیلیسی، سرپانتینی و اکسیدهای آهن (به صورت هماتیت و لیمونیت) بوده است. همچنین در آبراه‌های این منطقه شواهد مناسبتی از آلتراسیون و کانی‌سازی پیریت، کالکوپیریت و منگنز در سنگ‌های افیولیتی با ابعاد ۱۰ × ۱۰ متر مشاهده شده است. سه نمونه دیگر نیز در بخش شمالی دیزج برداشت و آنالیز شده است. اساس زمین‌شناسی این محدوده شامل بازالت‌های سبزرنگ، ریولیت و داسیت می‌باشد. مقدار طلا در دو نمونه از این سه نمونه قابل قبول (۱۱ppb و ۲۲ppb) بوده و نیازمند بررسی‌های بیشتر خواهد بود.

یکی از مباحث مهم در تولید نتایج این مدل‌ها در محیط متلب، زمان اجرای این پردازش‌ها می‌باشد. به طوری که زمان اجرای پردازش‌ها برای مدل CNN ۳ دقیقه و ۲۱ ثانیه، مدل SVM ۵۳ ثانیه و مدل DT ۲۸ ثانیه بوده است.



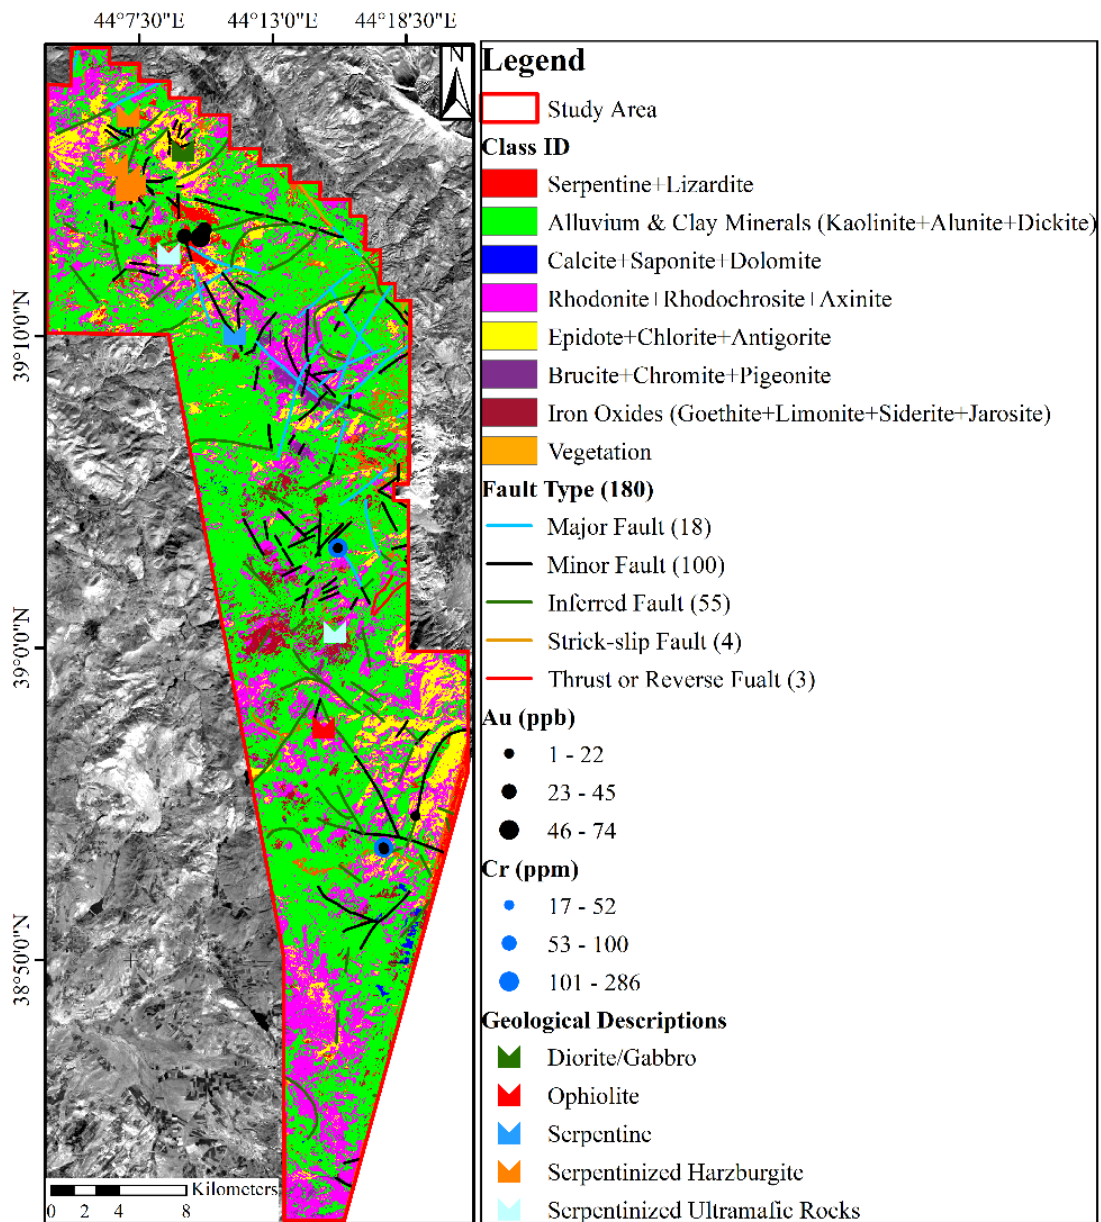
شکل (۱۷). نمودار میله‌ای مقایسه مدل‌های CNN، SVM و DT بر اساس معیارهای ارزیابی مختلف

## ۵. نتیجه‌گیری

بر اساس نتایج به دست آمده از مدل شبکه عصبی کانولوشن عمیق (CNN) در محدوده مورد مطالعه واقع در محدوده سیاه چشمه و دیزج در شکل (۱۸)، نتایج حاصله بیانگر پتانسیل بالایی از حضور کانی‌های مافیک و الترامافیک دگرسان شده در زون افیولیتی شمال‌غربی محدوده است. تمامی نتایج بیانگر زون متمرکز دگرسان شده همراه با هاله‌هایی از کلسیت، اپیدوت، کلریت و کانی‌های منگن‌دار در این بخش می‌باشد. تشکیل این تیپ کانی‌سازی در بخش افیولیتی و سنگ‌های مافیک و الترامافیک دگرسان شده حاکی از تشکیل لیستونیت در منطقه مورد مطالعه خواهد بود. به طوری که در مرکز زون افیولیتی دگرسان شده مقدار سیلیس بیشتر و هرچه به سمت خارج زون دگرسانی پیش برویم، از مقدار سیلیس کاسته و به مقدار کانی‌های کربناته افزوده می‌گردد. افزایش کانی‌های کربناته در زون خارجی دگرسان شده نیز بیانگر تشکیل سنگ میزبان کانی‌های منگن‌دار خواهد بود. به طوری که طبق شرایط به دست آمده در مرزی‌ترین بخش شمال‌غربی محدوده، پتانسیل بالایی از حضور کانی‌های منگن‌دار قابل مشاهده است. بنابراین شمال‌غربی محدوده منطقه مستعد کانی‌سازی طلا (در بخش لیستونیت‌های سیلیسی) و منگنز (در بخش خارجی زون افیولیتی و لیستونیت‌های کربناته) در محدوده سیاه چشمه می‌باشد.

بخش جنوبی منطقه مستعد کانی‌سازی منگنز بوده و بخش کوچکی را ایجاد کرده است. همچنین عدم وجود گسل‌های خاص در بخش جنوبی دیزج باعث فقر این بخش از سیلیس و عدم تشکیل لیستونیت‌های سیلیسی شده است.

بخش مرکزی منطقه نیز پتانسیل بالایی از حضور کانی کرومیت به عنوان یکی از مهم‌ترین کانی‌های موجود در سری‌های افیولیتی نشان داده است. بر اساس نتایج به دست آمده در بخش



شکل (۱۸). انطباق نتایج حاصل از نقشه کلاسه‌بندی با رخنمون‌ها، نمونه‌های آنالیز شده و گسل‌ها در منطقه سیاه چشمه و دیزج

in the Antarctic Environment Using ASTER Satellite Data: Case Study from the Mesa Range, Campbell and Priestley Glaciers, Northern Victoria Land,” *Remote Sensing*, vol. 13, 2020.

[12] J. Didero Takodjou Wambo, A. B. Pour, S. Ganno, P. D. Asimow, and et al., “Identifying high potential zones of gold mineralization in a sub-tropical region using Landsat-8 and ASTER remote sensing data: a case study of the Ngoura-Colomines goldfield, Eastern Cameroon,” *Ore Geology Reviews*, vol. 122 pp. 103530, 2020.

[13] J. T. Mundt, D. R. Streutker, and N. F. Glenn, “Partial unmixing of hyperspectral imagery: theory and methods,” *Proceedings of the American Society of photogrammetry and remote sensing*, vol. 2007, 2007.

[14] H. Aboelkhair, A. Abdelhalim, Z. Hamimi, and M. Al-Gabali, “Reliability of using ASTER data in lithologic mapping and alteration mineral detection of the basement complex of West Berenice, Southeastern Desert, Egypt,” *Arabian Journal of Geosciences*, vol. 13 pp. 287, 2020.

[15] K. D. Singh, and D. Ramakrishnan, “A comparative study of signal transformation techniques in automated spectral unmixing of infrared spectra for remote sensing applications,” *International Journal of Remote Sensing*, vol. 38 pp. 1235-1257, 2017.

[16] S. Gong, C. Liu, Y. Ji, B. Zhong, and et al., “Advanced image and video processing using MATLAB,” *Springer*, vol. 12, 2018.

[17] X. Liu, F. Han, K. H. Ghazali, I. I. Mohamed, and et al., “A review of Convolutional Neural Networks in Remote Sensing Image,” in *Proceedings of the 2019 8th International Conference on Software and Computer Applications*, Association for Computing Machinery: Penang, Malaysia, pp. 263–267, 2019.

[18] F. Sultana, A. Sufian, and P. Dutta, “Advancements in Image Classification using Convolutional Neural Network,” in *2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)*, IEEE, pp. 122-129, 2018.

[19] R. Tombe, and S. Viriri, “Effective Processing of Convolutional Neural Networks for Computer Vision: A Tutorial and Survey,” *IETE Technical Review*, pp. 1-14, 2020.

## ۶. مراجع

[1] F. F. Sabins, “Remote sensing for mineral exploration,” *Ore Geology Reviews*, vol. 14 pp. 157-183, 1999.

[2] J. R. Jensen, “Introductory digital image processing: a remote sensing perspective,” *Pearson Series in Geographic Information Scienc*, 2016.

[3] M. H. Karimpur, A. Malekzadeh, and M. R. Heydarian, “Exploration of mineral resources, geological, geochemical, satellite and geophysical models,” *Univ. of Mashhad, Ferdosi*, pp. 1-632, 1391. (In Persian)

[4] M. Ghorbani, “Economic geology of Iran,” *Mineral deposits and natural resources*, Springer, pp. 1-450, 2013.

[5] A. Emamalipour, M. Yousefi, and M. Karimlou, “Geochemistry and mineralogy of Listwaenite hosting Mercury mineralization and its comparison with the Barren types in Tavreh area, West of Khoy city,” *Economic Geology*, vol. 5 pp. 307-324, 1392. (In Persian)

[6] M. D. Menzel, C. J. Garrido, V. L. Sánchez-Vizcaíno, C. Marchesi, and et al., “Carbonation of mantle peridotite by CO<sub>2</sub>-rich fluids: the formation of listvenites in the Advocate ophiolite complex (Newfoundland, Canada),” *Lithos*, vol. 323 pp. 238-261, 2018

[7] J. R. Jensen, “Introductory digital image processing: a remote sensing perspective,” *Prentice-Hall, Inc., Upple Saddle River*, 1996

[8] J. Tang, and Z. Nie, “Geometric correction of remote sensing image,” *Geomatics & Spatial Information Technology*, vol. 30 pp. 100-106, 2007.

[9] A. R. Huete, G. Hua, J. Qi, A. Chehbouni, and et al., “Normalization of multidirectional red and NIR reflectances with the SAVI,” *Remote Sensing of Environment*, vol. 41 pp. 143-154, 1992.

[10] A. Taghavi, M. Maanijou, D. Lentz, and A. A. Sepahi, “Partial sub-pixel and pixel-based alteration mapping of porphyry system using ASTER data: regional case study in western Yazd, Iran,” *International Journal of Image and Data Fusion*, vol. 10 pp. 300-326, 2019.

[11] A. B. Pour, M. Sekandari, O. Rahmani, L. Crispini, and et al., “Identification of Phyllosilicates

- [30] S. Fakhari, A. Jafariad, P. Afzal, and et al., "Delineation of hydrothermal alteration zones for porphyry systems utilizing ASTER data in Jebal-Barez area, SE Iran," *Iranian Journal of Earth Sciences*, vol. 11, pp. 80-92, 2019.
- [31] H. Chung, K. Shin, "Genetic algorithm-optimized multi-channel convolutional neural network for stock market prediction," *Neural Computing and Applications*, vol. 32, pp. 8797-7914, 202
- [20] S. E. Jozdani, B.A. Johnson, and D. Chen, "Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification," *Remote Sensing*, vol. 11 pp. 1713, 2019.
- [21] P. R. Kadavi, and C. W. Lee, "Land cover classification analysis of volcanic island in Aleutian Arc using an artificial neural network (ANN) and a support vector machine (SVM) from Landsat imagery," *Geosciences Journal*, vol. 22 pp. 653-665, 2018.
- [22] M. Awad, and R. Khanna, "Efficient learning machines: theories, concepts, and applications for engineers and system designers," Springer Nature, Apress, p. 268, 2015.
- [23] N. Bhargava, and G. Sharma, "RBMM Decision Tree Analysis on J48 Algorithm for Data Mining," *International Journal of Advanced Research in Decision Tree Analysis on J48 Algorithm for Data Mining*, vol. 3 pp. 1114-1119, 2013.
- [24] R. C. Barros, A. C. De Carvalho, and A. A. Freitas, "Automatic design of decision-tree induction algorithms," Springer International Publishing in AG Switzerland, Springer Science, 2015.
- [25] T. R. Patil, and S. Sherekar, "Performance Analysis of Naive Bayes and J48 Classification Algorithm for Data Classification," *International Journal Of Computer Science And Applications*, vol. 6 pp. 256-261, 2013.
- [26] O. Z. Maimon, and L. Rokach, "Data mining with decision trees: theory and applications," World scientific, Co. Ptc. Ltd, vol. 81. 2014.
- [27] X. S. Yang, "Introduction to algorithms for data mining and machine learning," Academic press, 2019.
- [28] A. Sheikhrhimi, A. B. Pour, B. Pardhan, and et al., "Mapping hydrothermal alteration zones and lineaments associated with orogenic gold mineralization using ASTER data: A case study from the Sanandaj-Sirjan Zone, Iran," *Advances in Space Research*, vol. 63. pp. 3315-3332, 2019.
- [29] M. Zamyad, P. Afzal, M. Pourkermani, and et al., "Determination of Hydrothermal Alteration Zones Using Remote Sensing Methods in Tirka Area, Toroud, NE Iran," *Journal of the Indian Society of Remote Sensing*, vol. 47, pp. 1817-1830, 2019.