

تمایز واحدهای سنگ‌شناسی در تصاویر ماهواره‌ای با استفاده از روش‌های یادگیری ماشین و یادگیری عمیق در منطقه هندودر استان مرکزی

مهرتاش منافی فرد^{۱*}، مصطفی یوسفی راد^۲

۱- استادیار گروه نقشه‌برداری، دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک

۲- دانشیار دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک

تاریخ دریافت مقاله: ۱۴۰۴/۰۸/۰۹ تاریخ پذیرش مقاله: ۱۴۰۵/۰۳/۲۰

چکیده

تصاویر سنجنش از دور در کاربردهای مختلف زمین‌شناسی نظیر شناسایی انواع سنگ‌ها مورد استفاده قرار می‌گیرند. در این پژوهش، از روش‌های هوش مصنوعی شامل جنگل تصادفی، یادگیری عمیق، *XGBoost* و *LightGBM* در تمایز چهار واحد زمین‌شناسی فیلیت، تراس‌های آبرفتی قدیمی، گرانیات تا گرانودیوریت و میگماتیت در منطقه هندودر استان مرکزی استفاده شده است. ورودی مدل‌های هوش مصنوعی شامل اطلاعات مستخرج از تصاویر ماهواره‌ای نظیر لندست، استر و سنتینل-۲، داده‌های توپوگرافی حاصل از مدل رقومی ارتفاع شامل ارتفاع، شیب، شاخص رطوبت توپوگرافی و جهت شیب، به‌همراه داده‌های مکانی و نمونه‌های صحرایی مربوط به واحدهای زمین‌شناسی منطقه است. به‌منظور آماده‌سازی داده‌های ورودی، پیش‌پردازش‌های لازم شامل تصحیحات رادیومتریک و اتمسفری، پردازش و طبقه‌بندی اولیه تصاویر ماهواره‌ای انجام شد. سپس، مجموعه‌ای از ویژگی‌ها براساس باندهای طیفی تصاویر ماهواره‌ای و نیز تصاویر حاصل از اعمال روش‌های تحلیل مؤلفه‌های اصلی و حداقل نویز کسری استخراج گردید. نتایج ارزیابی نشان داد که بهترین عملکرد مربوط به الگوریتم جنگل تصادفی است که با استفاده از داده‌های طیفی تصاویر استر، به‌همراه اطلاعات ارتفاعی و مکانی، به دست آمده است؛ به‌طوری‌که مقادیر ضریب کاپا (*Kappa*)، صحت کلی (*Overall Accuracy*) و امتیاز (*F-score*) به‌ترتیب برابر با ۰٫۷۴، ۰٫۸۲ و ۰٫۸۲ حاصل شدند.

کلیدواژه‌ها: زمین‌شناسی، سنگ‌شناسی، تصاویر ماهواره‌ای، یادگیری ماشین، یادگیری عمیق.

* نویسنده مکاتبه‌کننده: اراک، دانشگاه صنعتی اراک، دانشکده علوم زمین، گروه مهندسی نقشه‌برداری.

تلفن: ۰۸۶۳۳۴۰۰۷۶۶

۱- مقدمه

کاربرد سنجش از دور در زمین‌شناسی شامل تهیه نقشه شناسایی انواع سنگ‌ها، نقشه تغییرات و شناسایی ساختارها نظیر خطواره‌هاست. از زمان آغاز فن‌آوری سنجش از دور، زمین‌شناسان از این داده‌ها برای نقشه‌برداری منطقه‌ای، تفسیر ساختاری و کمک به اکتشاف معادن و هیدروکربن‌ها استفاده کرده‌اند. همچنین به‌منظور پایش فرآیندهای زمین‌شناسی، داده‌های سنجش از دور باید با مشاهدات میدانی ادغام شوند. رنگ نیز از ویژگی‌های مهم برای شناسایی سنگ‌ها در سنجش از دور است که منجر به منحنی-های طیفی مختلف برای انواع سنگ‌ها می‌شود.

تصاویر لندست^۱، استر^۲ و سنتینل^۳ از جمله تصاویر سنجش از دور متداول برای کاربردهای زمین‌شناسی هستند. در مقاله ون درمیر و همکاران [۱]، به مرور داده‌های سنجش از دور چندطیفی و ابرطیفی و کاربردهای آن‌ها در زمین‌شناسی پرداخته شده است. تصاویر سنجش از دور شامل تصاویر پهپاد یا تصاویر ماهواره‌ای، در کاربردهای مختلف نظیر نقشه‌برداری دیواره‌های معادن با تصاویر RGB دریافتی از پهپاد (یانگ و همکاران (۲۰۲۳) [۲] یا تمایز انواع سنگ‌ها با تصاویر ماهواره‌ای (کرکنل و همکاران (۲۰۱۴) [۳]) استفاده شده‌اند. در تحقیقات پیشین، به‌منظور تمایز واحدهای زمین‌شناسی، از روش‌های مختلف نظیر تحلیل مولفه اصلی (PCA) [۴-۱۲]، نسبت باندها [۹]، ترکیب باندها یا ترکیب رنگی کاذب [۴]، [۷]، [۹]، [۱۱]، [۱۲]، [۱۳] و [۱۴]، تحلیل مؤلفه‌های مستقل^۶ [۴] و [۵]، حداقل نویز کسری (MNF)^۷

[۴] و [۵] و طبقه‌بندی تصاویر [۹] و [۱۶] با روش‌هایی نظیر یادگیری ماشین (کرکنل و همکاران (۲۰۱۴) [۳])، یادگیری عمیق^۸ یا ترنسفورمر بینایی^۹ (آروای و همکاران (۲۰۲۵) [۱۷])، لی و همکاران (۲۰۲۶) [۱۸]) استفاده شده است. به‌عنوان مثال در مقاله محمدی‌زاد و همکاران (۲۰۱۷) [۱۹]، پس از پردازش اولیه و حذف نویز داده‌های سنجش از دور تصاویر استر، لندست و IRS-PAN با روش MNF، از روش‌های طبقه‌بندی مختلف نظیر طبقه‌بندی پیکسل‌ها با روش بیشینه شباهت^{۱۰}، روش‌های طبقه‌بندی طیفی و زیرپیکسلی نگاشتگر زاویه طیفی^{۱۱}، روش برازش ویژگی‌های طیفی^{۱۲} و روش تفکیک طیفی خطی^{۱۳} به‌منظور نقشه‌برداری زمین‌شناسی منطقه زفره استفاده شده است. در مقاله کرکنل و همکاران (۲۰۱۴) [۳] نیز مقایسه‌ای بین کارایی پنج الگوریتم یادگیری ماشین شامل جنگل تصادفی^{۱۴}، ماشین بردار پشتیبان^{۱۵}، k -نزدیکترین همسایه^{۱۶}، بیز ساده^{۱۷} و شبکه عصبی مصنوعی^{۱۸} برای طبقه‌بندی سنگ‌ها انجام شده است. براساس نتایج، الگوریتم جنگل تصادفی به دلیل کارایی بالا، پایداری و دقت بیشتر، انتخاب مناسبی برای طبقه‌بندی سنگ-شناسی با استفاده از داده‌های سنجش از دور است. در تحقیقی دیگر توسط سفربیرانوند و همکاران (۲۰۲۳) [۲۰]، از تصاویر ابرطیفی سنجنده هایپرین^{۱۹} و

⁸ Deep Learning⁹ Vision Transformer¹⁰ Maximum likelihood¹¹ Spectral and sub-pixel classification methods of spectral angle mapper (SAM)¹² Spectral Feature Fitting (SFF)¹³ Multi-Layer Perceptron (MLP)¹⁴ Random Forest¹⁵ Support Vector Machines (SVM)¹⁶ K-Nearest Neighbors (KNN)¹⁷ Naive Bayes¹⁸ Artificial Neural Networks¹⁹ Hyperion¹ Landsat² Aster³ Sentinel⁴ Principal Component Analysis (PCA)⁵ False-color composition (FCC)⁶ Independent component analysis⁷ Minimum Noise Fraction (MNF)

مرئی، نزدیک به فروسرخ و فروسرخ موج کوتاه از بین نه باند استر پردازش شدند. در نتیجه، نتایج حاصل از اعمال روش PCA، به بازنگری مرزهای سنگ‌شناسی نقشه‌های قبلی و شناسایی واحدهای سنگ‌شناسی جدید کمک کرده است.

روش‌های تصاویر ترکیبی رنگی کاذب و نسبت باندها نیز در موارد متعدد برای تمایز انواع سنگ‌ها در تصاویر استفاده شده‌اند. به عنوان مثال در تحقیق پنا و همکاران (۲۰۰۶) [۱۳]، از تصاویر ترکیبی رنگی RGB و نسبت باندها براساس داده‌های لندست و استر برای شناسایی واحدهای سنگ‌شناسی سطحی و از تصاویر رادارست^۶ برای ردیابی تشکیلات زمین‌شناسی دفن‌شده زیر شن‌ها استفاده شده است. در مقاله گیتنیا و همکاران (۲۰۲۱) [۱۴] نیز روش‌های ترکیب باندها، نسبت باندها و استخراج خطوط با هدف نقشه‌برداری از نواحی تغییر یافته هیدروترمالی با استفاده از تصاویر ماهواره‌ای لندست-۸ استفاده شده‌اند.

در بعضی مقالات نیز روش‌های مختلف نظیر PCA، MNF، نسبت باندها و تصاویر رنگی کاذب برای مناطق مورد نظر پیاده و نتایج مقایسه شده است. به عنوان مثال در مقاله محمد و همکاران (۲۰۲۱) [۲۳]، از PCA و ترکیب نسبت باندهای تصاویر ماهواره‌ای لندست-۸، برای شناسایی مناطق دگرسانی سنگ‌های متا-آتشفشانی و سیلیکا باریت^۷، شناسایی پتانسیل‌های طلا و تولید نقشه زمین‌شناسی با مقیاس ۱:۴۰۰۰۰۰ در شمال شرق سودان استفاده شده است. در مقاله زهیر و همکاران (۲۰۱۲) [۷] نیز از نسبت باندها، PCA، ترکیب رنگی کاذب و فیلترینگ فرکانسی^۸ داده‌های استر و ETM+ برای بهبود تفسیر تصویر و نقشه‌برداری منطقه جبل اگات^۹ در صحرای جنوب شرقی مصر استفاده شده است. در تحقیق الراج و

روش‌های طبقه‌بندی نقشه‌بردار زاویه طیفی^۱ و ماشین بردار پشتیبان به منظور تفکیک واحدهای زمین‌شناسی منطقه خرم‌آباد استفاده شده است و ماشین بردار پشتیبان به عنوان بهترین روش طبقه‌بندی معرفی شده است. همچنین، از تبدیل MNF برای کاهش داده‌ها و از الگوریتم شاخص خلوص پیکسلی برای استخراج پیکسل‌های خالص استفاده شده است. در مطالعه‌ای دیگر توسط آلبرت و همکاران (۲۰۲۱) [۲۱]، داده‌های ماهواره‌ای سنتینل-۲، روش طبقه‌بندی جنگل تصادفی و مدل‌سازی بر روی چهار متغیر سنگ‌شناسی، پارامترهای شاخص رطوبت توپوگرافی^۲، شاخص ناهمواری زمین^۴ و مدل رقومی ارتفاع (DEM)^۵، برای تولید نقشه‌های زمین‌شناسی منطقه‌ای در مرکز تونس استفاده شدند.

از روش‌های متداول دیگر در شناسایی انواع سنگ‌ها، PCA و MNF هستند. به عنوان مثال در تحقیق پور و همکاران (۲۰۱۳) [۶]، روش PCA و داده‌های لندست، هایپریون و PALSAIR برای شناسایی مناطق دگرسانی هیدروترمال و عناصر ساختاری مرتبط با کانی‌سازی طلا در منطقه معدنی در مالزی شرقی به کار برده شده است. در تحقیق کومار و همکاران (۲۰۱۵) [۲۲]، از روش PCA، MNF و روش تحلیل مؤلفه‌های مستقل بر روی داده‌های سنجنده استر استفاده شده است و ترکیب باندهای PCA (R: PC2, G: PC1, B: PC3) و ICA (R: MNF2, G: MNF1, B: MNF3) و IC2, G: IC3, B: IC1 برای نقشه‌برداری سنگ‌شناسی مؤثر واقع شده است. همچنین، کارایی ترکیب باندهای حاصل از روش تحلیل مؤلفه مستقل نسبت به روش PCA و MNF بیشتر بوده است. در مقاله گومز و همکاران (۲۰۰۵) [۸] نیز داده‌های بازتابش در باندهای

²⁰ Spectral Angle Mapper (SAM)

² Pixel Purity Index (PPI)

³ Topographic Wetness Index (TWI)

⁴ Terrain Ruggedness Index (TRI)

⁵ Digital Elevation Model (DEM)

⁶ RADARSAT

⁷ Meta-volcanic and silica barite rocks

⁸ Frequency filtering (FFT-RWT)

⁹ Gebel Egat

انواع سنگ‌ها مورد آزمون قرار گرفتند و تصاویر حاصل از اعمال روش‌های *MNF*, *PCA*، ترکیبات مختلف باندها، اطلاعات حاصل از مدل ارتفاعی منطقه نظیر ارتفاع، شیب، جهت شیب، اطلاعات مکانی و داده‌های زمینی جمع‌آوری شده توسط نویسندگان مقاله، به-عنوان ورودی روش‌های طبقه‌بندی استفاده شدند. همچنین، روش‌های انتخاب ویژگی مختلف به‌منظور انتخاب ویژگی‌های برتر از بین تعداد زیاد ویژگی استفاده گردید و متوازن‌سازی داده‌ها با روش‌های مختلف مورد ارزیابی قرار گرفت. نتایج حاصل از اعمال روش طبقه‌بندی نیز روی داده‌های سه ماهواره مختلف استر، لندست و سنتینل-۲ مقایسه شدند.

این مقاله در هشت بخش ارائه شده است. بخش دوم شامل تشریح روش پیشنهادی است. در بخش سوم و چهارم، منطقه مورد مطالعه و داده‌های ورودی (نظیر تصاویر ماهواره‌ای و نقاط زمینی برداشت شده) شرح داده شده‌اند. در بخش پنجم، پیش‌پردازش‌های لازم شامل تصحیحات تصاویر ماهواره‌ای و طبقه‌بندی تصاویر بیان شده است. در بخش ششم، مروری به روش‌های تمایز واحدهای زمین‌شناسی شامل روش جنگل تصادفی، *LightGBM*، *XGBoost* و یادگیری عمیق انجام شده است. ارزیابی نتایج و نتیجه‌گیری نیز در بخش هفتم و هشتم انجام شده‌اند.

۲- روش پیشنهادی

هدف اصلی این تحقیق، تمایز چهار واحد زمین‌شناسی فیلیت^۳، تراس‌های آبرفتی قدیمی^۴، گرانیت تا گرانودیوریت^۵ و میگماتیت^۶ از یکدیگر در منطقه هندودر استان مرکزی است. مراحل روش پیشنهادی در شکل (۱) نشان داده شده است. برای این منظور، تصاویر ماهواره‌ای مختلف (استر، سنتینل-۲ و لندست) جهت استخراج ویژگی‌های طیفی بررسی و پیش-

همکاران (۲۰۲۲) [۹]، به منظور نقشه‌برداری واحدهای زمین‌شناسی منطقه‌ای واقع در شمال شرقی مراکش، روش‌های مختلف از جمله ترکیب رنگی، نسبت‌باند، *MNF*، *PCA* و طبقه‌بندی زاویه طیفی براساس تصاویر لندست-۸ و استر استفاده شده‌اند. به‌منظور نقشه‌برداری زمین‌شناسی و معدنی منطقه‌ای در روسیه در مقاله نفیگین و همکاران (۲۰۲۲) [۴] نیز از روش‌های *MNF*، *PCA* و روش تحلیل مؤلفه‌های مستقل براساس داده‌های سنجش از دور لندست-۸ استفاده شده است. همچنین، ترکیب‌های رنگی *RGB* شبه‌رنگی^۱ برای نمایش توزیع و تجمع کلاس‌های مواد زمین‌شناسی تولید و تفسیر شدند و ادغام لایه‌های موضوعی اطلاعاتی با استفاده از مدل منطق فازی انجام شده است. در تحقیقی دیگر براساس تصاویر سنتینل-۲ (ال نحمی و همکاران (۲۰۱۷) [۱۵]) از روش‌های ضریب شاخص بهینه^۲ برای انتخاب بهترین ترکیب باندهای تصویری و از روش تحلیل مؤلفه‌های مستقل و *MNF* برای استخراج اطلاعات پنهان و کاهش نویز استفاده شده است.

از طرف دیگر، شاخص‌های جدید برای شناسایی انواع خاص از سنگ‌ها و جداسازی آنها از باقی سنگ‌ها، توسط بعضی محققین معرفی شدند. به‌عنوان مثال، چندین شاخص نسبت باند طیفی براساس داده‌های ماهواره‌ای لندست-۸ و استر برای محیط‌های قطب جنوب در مقاله پور و همکاران (۲۰۱۸) [۲۴] توسعه داده شد تا کانی‌های آهن، کانی‌های حاوی *Al-OH* و *Fe*، *Mg-O-H* و *CO3* نقشه‌برداری شوند.

در این مقاله برخلاف مقالات پیشین، نتایج رضایت بخشی از به‌کارگیری مستقیم روش‌های *PCA*، نسبت باندها، ترکیب رنگی کاذب و *MNF*، برای تمایز واحدهای زمین‌شناسی حاصل نشد. به منظور حل مشکل، روش‌های طبقه‌بندی مختلف به‌منظور شناسایی

³ Phyllite

⁴ Old Alluvial Terraces

⁵ Granite to Granodiorite


⁶ Migmatite

¹ Pseudo-colored RGB composites

² Optimum Index Factor (OIF)

آموزش و ارزیابی روش، نمونه‌های مختلف از واحدهای سنگ‌شناسی مختلف از منطقه هندودر واقع در استان مرکزی برداشت و موقعیت آنها با سیستم تعیین موقعیت جهانی ثبت شده است. از آنجا که نقشه‌های زمین‌شناسی منطقه نسبت به واقعیت موجود دارای خطا بودند، داده‌های برداشت شده در مرحله کار صحرایی برای آموزش و ارزیابی روش استفاده شدند.

پردازش شدند. سپس، ویژگی‌های مختلف براساس ترکیبات باندها و روش‌های *PCA* و *MNF* ایجاد و به-عنوان ورودی روش‌های جنگل تصادفی، *XGBoost*، *LightGBM* و یادگیری عمیق استفاده شدند. همچنین، از مدل رقومی ارتفاع برای محاسبه داده‌های توپوگرافی نظیر ارتفاع، شیب، شاخص رطوبت توپوگرافی و جهت شیب استفاده شده است. به‌منظور




شکل ۱: مراحل کلی روش پیشنهادی

۳- منطقه مورد مطالعه

هندودر شهری در قسمت جنوبی استان مرکزی و مرکز بخش سرپند است. این منطقه در عرض جغرافیایی ۳۳ درجه، ۴۶ دقیقه و ۳۷/۸۲۰ ثانیه شمالی و طول

جغرافیایی ۴۹ درجه، ۱۳ دقیقه و ۵۶/۷۴۲ ثانیه شرقی واقع است. میانگین دمای سالانه ۱۷ درجه و ارتفاع متوسط منطقه ۲۰۳۷ متر است. در شکل (۲)، محدوده منطقه مورد مطالعه نشان داده شده است.



شکل ۲: منطقه مورد مطالعه (هندودر (ناحیه قرمز) واقع در شازند استان مرکزی)

۴- ورودی‌ها

ورودی‌های روش شامل نمونه‌های برداشت شده از منطقه هندودر و تصاویر ماهواره‌ای هستند. در ادامه، جزئیات بیشتر شرح داده می‌شوند.

۴-۱- داده‌های زمینی حاصل از عملیات صحرایی

جمع‌آوری نمونه‌های زمینی به منظور آموزش و ارزیابی روش امری ضروری است. برای این منظور، نمونه‌های زمینی واحدهای زمین‌شناسی فیلیت، تراس‌های آبرفتی قدیمی، گرانیت تا گرانودیوریت و میگماتیت از بخش-

های مختلف منطقه هندودر با پراکندگی نسبتاً یکنواخت در بازه زمانی ۱۴۰۱-۱۴۰۲ با عملیات صحرایی جمع‌آوری شدند. موقعیت‌های نقاط نمونه-برداری شده نیز با سیستم تعیین موقعیت جهانی ثبت شدند. در نتیجه، تعداد نمونه‌های جمع‌آوری شده از واحدهای سنگ‌شناسی فیلیت، تراس‌های آبرفتی قدیمی، گرانیت تا گرانودیوریت و میگماتیت به‌ترتیب ۱۴۵، ۹۰، ۵۹ و ۴۷ هستند (جدول (۱)).

جدول ۱: واحدهای زمین‌شناسی مورد ارزیابی

نوع سنگ	مخفف	تعداد نمونه‌ها
فیلیت	<i>Jph</i>	۱۴۵
تراس‌های آبرفتی قدیمی	<i>Qt1</i>	۹۰
گرانیت تا گرانودیوریت	<i>gr1</i>	۵۹
میگماتیت	<i>gr.at</i>	۴۷

تعدادی از نمونه‌ها به دلایلی نظیر پوشیده بودن توسط گیاه و یخ و غیره در تصاویر ماهواره‌ای، براساس نتایج طبقه‌بندی تصویر (بخش ۵) حذف شدند. سپس، ۸۰

درصد نمونه‌ها برای آموزش و ۲۰ درصد نمونه‌ها برای ارزیابی روش پیشنهادی استفاده شدند. در ادامه، مشخصات واحدهای سنگی مذکور شرح داده شده‌اند.

شهر هندودر با روندی شمال‌غربی گسترش یافته و تا نواحی روستای اسکندرلو و برج عیوض امتداد می‌یابد. این واحد شامل فیلیت‌های تیره‌رنگ است که به‌عنوان ادامه‌ای از فیلیت‌ها و اسلیت‌های^{۱۵} تیره‌رنگ مناطق شازند و همدان در نظر گرفته می‌شود. این سنگ‌ها همراه با ماسه‌سنگ‌های ریزدانه با رنگ خاکستری مایل به تیره مشاهده می‌شوند و اغلب دارای بافت لکه‌ای و خرد شده و کلریتی شده هستند (شکل (۴)).

– **واحد میگماتیتی:** این واحد به‌صورت پیوسته در ارتباط با توده آذرین *gr1* بوده و در امتداد جاده هندودر-مالمیر قابل مشاهده است. این سنگ‌ها دارای بلورهای درشت و کشیده کوارتز، فلدسپار^{۱۶}، انواع میکا^{۱۷} و تورمالین^{۱۸} هستند. همچنین، فراوانی بالای بیوتیت و حضور آندالوزیت^{۱۹} به‌صورت بلورهای درشت و پراکنده از ویژگی‌های شاخص این واحد است (شکل (۵)) و بر اساس شواهد صحرایی، این واحد دارای منشأ گرانیتوئیدی است. از نظر کانی‌شناسی، این سنگ‌ها مشابه پگماتیت‌های غنی از سیلیکات آلومینیوم^{۲۰} بوده و شامل کانی‌هایی نظیر کوارتز، پلاژیوکلاز، فلدسپار پتاسیم، آندالوزیت، سیلیمانیت^{۲۱}، بیوتیت، اسپینل^{۲۲} و کروندم^{۲۳} هستند. در بخش مزوسوم، هم‌رشدی اسپینل و کروندم در حاشیه آندالوزیت مشاهده می‌شود و در برخی موارد، آندالوزیت به سیلیمانیت تبدیل شده است.

– **واحد سنگی گرانیت تا گرانودیوریت:** این واحد آذرین (شکل (۳)) به‌طور گسترده در بخش‌های جنوبی منطقه مورد مطالعه، از جنوب تا غرب شهر هندودر و نیز در نواحی جنوبی و غربی روستاهای خنادره سفلی و علیا رخنمون دارد. این توده عمدتاً دارای رنگ روشن بوده و بافت درشت‌بلور آن، همراه با حضور آنکلاوهای مافیک^۱، از ویژگی‌های شاخص سنگ‌شناسی آن محسوب می‌شود. پوشش گیاهی نسبتاً متراکم در برخی بخش‌های منطقه، مشاهده پیوسته این واحد را محدود کرده است. با این حال، حضور زینولیت‌هایی^۲ از سنگ‌های مختلف با اندازه‌های متنوع، از دیگر ویژگی‌های قابل توجه این توده به شمار می‌رود. این واحد با سن ژوراسیک میانی، در زون ساختاری زمین‌شناسی سنج-سیرجان قرار گرفته و ترکیب سنگ‌شناسی آن عمدتاً شامل گرانیت^۳ و گرانودیوریت^۴ است. آنکلاوهای میکروگرانولار مافیک^۵ با ترکیب کوارتز مونزودیوریت^۶ و کوارتز دیوریت^۷، به‌ویژه در بخش‌های حاشیه‌ای توده، به‌وفور مشاهده می‌شوند. از دیدگاه کانی‌شناسی، این سنگ‌ها دارای ترکیبی نسبتاً همگن از کانی‌های کوارتز^۸، پلاژیوکلاز^۹، بیوتیت^{۱۰}، آلکالی فلدسپار^{۱۱} و آمفیبول‌ها^{۱۲} از نوع کلسیک^{۱۳} و ترمولیت-اکتینولیت^{۱۴} هستند.

– **واحد فیلیت و سیلت استون‌های فیلیتی:** این واحد در محدوده مورد نظر از جنوب و جنوب غرب

¹ Mafic incusions

² Xenoliths

³ Granite

⁴ Granodiorite

⁵ Mafic Microgranular Enclaves

⁶ Quartz Monzodiorite

⁷ Quartz Diorite

⁸ Quartz

⁹ Plagioclase

¹⁰ Biotite

¹¹ Alkali Feldspar

¹² Amphiboles

¹³ Calcic

¹⁴ Tremolite-Actinolite

¹⁵ Slate

¹⁶ Feldspar

¹⁷ Mica

¹⁸ Tourmaline

¹⁹ Andalusite

²⁰ Aluminosilicate-rich Pegmatites

²¹ Sillimanite

²² Spinel

²³ Corundum



شکل ۱: نمایی از توده گرانیتی-گرانودیوریتی



شکل ۲: فیلیت‌های منطقه مورد مطالعه



شکل ۳: نمایی از واحد میگماتیتی در منطقه مورد مطالعه

ارتفاعات اشاره کرد. ترکیب دانه‌های تشکیل‌دهنده این تراس‌ها عمدتاً شامل قطعاتی از توده‌های نفوذی آستانه^۱، واحدهای سنگی دگرگونی و همچنین مقادیری از شیل‌ها^۲ و ماسه‌سنگ‌های رسوبی است.

^۱ Intrusive Bodies

^۲ Shale

- واحد تراس‌های آبرفتی: این واحد در محدوده ارتفاعات و تپه‌های منطقه مورد مطالعه گسترش یافته است. تأثیر عوامل توپوگرافی و فرایندهای هوازدگی بر سنگ مادر موجب شده است که این واحد عمدتاً از رسوبات ریزدانه رسی و سیلتی تشکیل شود. از ویژگی‌های شاخص واحد تراس آبرفتی می‌توان به شیب نسبتاً تند و یا هم‌راستایی آن با شیب دامنه‌های

۴-۲- تصاویر ماهواره‌ای

تصاویر ماهواره‌ای مورد استفاده در این تحقیق استر، لندست-۹، سنتینل-۲ و مدل رقومی ارتفاع استر هستند (جدول (۲)). همچنین، به منظور دستیابی به دقت مکانی خوب، از تصاویر تصحیح هندسی شده استفاده شده است و تصحیحات رادیومتریکی و اتمسفری با روش فلش^۱ در صورت نیاز بر روی تصاویر اعمال شدند. تصحیحات رادیومتریکی برای تبدیل مقادیر پیکسل‌های تصویر به رادیانس و تصحیحات اتمسفری برای کاهش تأثیرات جوی بر روی تصاویر انجام شده‌اند. تصحیحات اتمسفری شامل حذف اثرات بخار آب، غبار و سایر عوامل جوی است که می‌توانند تأثیرات نامطلوبی بر روی کیفیت تصویر داشته باشند.

در این مقاله، از تصویر ماهواره سنتینل-۲ اخذ شده در تاریخ ۱۱ نوامبر ۲۰۲۳ و زمان ۰۷:۳۱:۳۱ به وقت گرینویچ استفاده شده است که توسط سازمان فضایی اروپا مدیریت می‌شود. این تصویر شامل داده‌های سطح A2 است و از تصحیحات مکانی برخوردار است. تصاویر سنتینل-۲ در سه دقت مکانی ۱۰، ۲۰ و ۶۰ متر ارائه می‌شوند و دارای ۱۳ باند طیفی هستند که از طیف مرئی تا مادون قرمز نزدیک^۲ و مادون قرمز طول موج کوتاه^۳ را پوشش می‌دهند. در این تحقیق، از باندهای ۲، ۳، ۴ و ۸ با قدرت تفکیک مکانی ۱۰ متر و باندهای ۵، ۶، ۷، ۸a، ۱۱ و ۱۲ با قدرت تفکیک مکانی ۲۰ متر استفاده شده است.

تصویر استر در تاریخ ۲۰۰۴/۰۷/۳۱ اخذ شده است و از تصویر مرحله T1 استفاده شده است که شامل تصحیحات هندسی است. در این تحقیق، از سه باند مرئی و مادون قرمز نزدیک^۴ با قدرت تفکیک مکانی ۱۵ متر، شش باند مادون قرمز طول موج کوتاه با قدرت

تفکیک مکانی ۳۰ متر و پنج باند مادون قرمز حرارتی^۵ با قدرت تفکیک مکانی ۹۰ متر استفاده شده است. ماهواره لندست-۹ جدیدترین ماهواره در برنامه لندست است که توسط سازمان فضایی و زمین‌شناسی آمریکا مدیریت می‌شود. تصویر لندست-۹ در تاریخ ۳۰ نوامبر ۲۰۲۳ اخذ شده است و شامل دو باند مادون قرمز حرارتی با قدرت تفکیک مکانی ۱۰۰ متر و باندهای ۱ تا ۷ (شامل باندهای مرئی، مادون قرمز نزدیک و دو باند مادون قرمز طول موج کوتاه با قدرت تفکیک مکانی ۳۰ متر) است. از باند پانکروماتیک با قدرت تفکیک مکانی ۱۵ متر نیز برای افزایش قدرت تفکیک مکانی باندهای دیگر با روش پن شارپنینگ^۶ استفاده شده است. سطح پردازش تصویر، پردازش سطح اول (L1TP) با تصحیح دقیق توپوگرافی^۷ است که شامل تصحیحات هندسی و رادیومتریکی است. برای پردازش تصویر در سطح L1TP، تصحیح اتمسفری به صورت خودکار انجام نمی‌شود و از روش فلش برای اعمال تصحیح اتمسفری و تبدیل تصویر به مقادیر بازتاب سطحی استفاده شده است. زمان اخذ تصاویر طوری انتخاب شده است که پوشش زمین توسط ابر، گیاه و برف حداقل باشد تا در تمایز سنگ‌ها مشکلی ایجاد نشود.

از طرف دیگر، به منظور استخراج اطلاعات توپوگرافی، تصویر مدل رقومی ارتفاع استر استفاده شده است. مدل رقومی ارتفاع شامل مقادیر ارتفاع نقاط مختلف زمین است که به صورت آرایه‌ای از اعداد نمایش داده می‌شود. تصویر مورد استفاده دارای دقت مکانی حدود ۳۰ متر در هر پیکسل است و داده‌های ارتفاعی منطقه با عرض جغرافیایی ۳۳ درجه شمالی و طول جغرافیایی ۴۹ درجه شرقی را پوشش می‌دهد.

¹ Flaash

² Near Infrared (NIR)

³ Short-Wave Infrared (SWIR)

⁴ Visible Near Infrared (VNIR)

⁵ Thermal InfraRed (TIR)

⁶ Pan-sharpening

⁷ Level 1 Terrain Precision (L1TP)

جدول ۲: داده‌های ماهواره‌ای

تاریخ	قدرت تفکیک مکانی (متر)	باند‌ها	نام تصویر	تصویر ماهواره‌ای
۲۰۰۴/۰۷/۳۱	۱۵ ۳۰ ۹۰	سه باند مرئی و مادون قرمز نزدیک (VNIR) شش باند مادون قرمز طول موج کوتاه (SWIR) پنج باند مادون قرمز حرارتی (TIR)	AST_LT_۰۳۱۱۰۰۸۲۰۰۴۰۷۳۱۳۳_ ۲۰۲۴۰۲۲۳۰۸۱۲۵۹_۱۱۷۲۷	استر
۲۰۲۳/۱۱/۱۱	۱۰ ۲۰	باند‌های ۰.۲، ۰.۳، ۰.۴ و ۰.۸ (B, G, R, NIR) باند‌های ۰.۵، ۰.۶، ۰.۷، ۰.۸a و ۱.۱ (NIR,) (SWIR)	SrA_MSIL2A_۲۰۲۳۱۱۱۱T۰۷۳۱۳۱_ N۰۵۰۹_R۰۴۹_T۳۹SUT_۲۰۲۳۱۱۱۱T ۱۰۲۸۵۲.SAFE	سنتینل-۲
۲۰۲۳/۱۱/۳۰	۳۰ ۱۰۰	باند‌های ۱ تا ۷ (Coastal, B, G, R, NIR,) (SWIR1, SWIR2) دو باند مادون قرمز حرارتی	LC۰۹_LTTP_۱۶۵۰۳۷_۲۰۲۳۱۱۳۰_ ۲۰۲۳۱۱۳۰_۰۲_T۱	لندست-۹
-	۳۰	۱ باند	ASTGMTV۰۰۳_N۳۳E۰۴۹_dem	مدل رقومی ارتفاع استر

۵- پیش‌پردازش

پس از دانلود تصاویر ماهواره‌ای، تصحیحات رادیومتریک، اتمسفری (فلش) و یکسان‌سازی داده‌ها^۱ انجام شدند تا مقادیر باندها در بازه صفر تا یک قرار گیرند. سپس، طبقه‌بندی با روش بیشینه احتمال انجام شد تا طبقه خاک و سنگ از گیاه، سایه، ساختمان و آب جدا شوند و پردازش‌های بعدی روی کلاس خاک و سنگ انجام شدند (شکل (۶)). دلیل طبقه‌بندی تصاویر، استفاده از تصاویر قدیمی استر و امکان ساخت و ساز یا وجود پوشش گیاهی در زمان اخذ تصویر نسبت به زمان برداشت نمونه‌ها بود. بنابراین، اگر نمونه در منطقه‌ای با کلاس غیر از خاک و سنگ واقع شده بود، از پردازش‌های بعدی حذف شده است.

اگر در طبقه‌بندی تعداد داده‌های یک کلاس نسبت به سایر کلاس‌ها بسیار بیشتر باشد، مدل به کلاس غالب متمایل می‌شود. از آنجا که در مرحله عملیات زمینی، تعداد نمونه‌های برداشت شده در بعضی کلاس‌ها بیشتر و در بعضی کلاس‌ها کمتر است، متوازن‌سازی داده‌ها با

روش‌های مختلف نظیر SMOT^۲، نمونه‌برداری افزایشی تصادفی^۳ و نمونه‌برداری کاهشی تصادفی^۴ انجام شد. روش نمونه‌برداری کاهشی تصادفی از گروه نمونه‌برداری کاهشی است که تعداد نمونه‌های کلاس غالب را کم می‌کند تا تعداد نمونه‌های آنها با تعداد نمونه‌های کلاس کم‌تعداد برابر شود. برای این منظور، برخی از نمونه‌های کلاس غالب به صورت تصادفی حذف می‌شوند. از طرف دیگر، روش نمونه‌برداری افزایشی تصادفی از جمله روش‌های نمونه‌برداری افزایشی است که داده‌های کلاس‌های کم‌تعداد به صورت تصادفی تکرار می‌شوند تا تعداد نمونه‌های آنها با تعداد نمونه‌های کلاس‌های پر تعداد برابر شود. روش SMOT، روشی پیشرفته‌تر برای نمونه‌برداری افزایشی است که در آن نمونه‌های جدید به صورت مصنوعی ایجاد می‌شوند. در این روش، همسایه‌های نزدیک برای هر نمونه از کلاس کم‌تعداد تعیین می‌شوند و نمونه‌های جدید بین این نقاط

^۲ Synthetic Minority Over-sampling Technique (SMOT)


^۳ RandomOverSampler

^۴ RandomUnderSampler

^۱ Normalize

بین روش‌های بالا، بهترین نتیجه با روش *SMOT* حاصل شده است که تعداد داده‌ها بعد از اعمال این روش ۱۱۴ است.

به صورت خطی ساخته می‌شوند. برخلاف روش‌های تکراری، داده‌های مصنوعی جدید در این روش ایجاد می‌شوند که می‌تواند باعث افزایش تنوع در داده‌ها شود. از



(ب)



(الف)

شکل ۴: (الف) تصویر اولیه استر برای منطقه شازند، (ب) تصویر طبقه‌بندی شده استر (نواحی زرد مربوط به کلاس خاک و سنگ هستند)

ماهواره‌ای مختلف، ترکیبات مختلف باندی (نظیر نسبت باندها) محاسبه شدند.

- **انتقال *PCA* و *MNF*:** انتقال *PCA* و *MNF* روی باندهای ۱ تا ۷ لندست-۹، ۱۰ باند از سنتینل ۲ و ۹ باند از استر (شامل باندهای مرئی، مادون قرمز نزدیک و طول موج کوتاه) اعمال و پنج مولفه اول انتقال *PCA* و پنج مولفه اول روش *MNF* به عنوان ورودی روش طبقه‌بندی استفاده شدند.
- **ترکیبات مختلف از انتقال *PCA* و *MNF*:** ترکیبات مختلف حاصل از اعمال انتقال *PCA* و *MNF* روی باندهای تصویری به ترکیبات مرحله قبل اضافه شدند. تعدادی از ترکیبات مختلف باندی تصویر استر در جدول (۳) نشان داده شده است.

۶- تمایز واحدهای زمین‌شناسی

در این بخش، آماده‌سازی داده‌های پیش‌پردازش شده و روش‌های یادگیری ماشین و یادگیری عمیق برای تمایز واحدهای سنگی شرح داده می‌شوند.

۶-۱- آماده‌سازی داده‌ها

در این مرحله، ویژگی‌های مختلف از تصاویر ماهواره‌ای مختلف استخراج و به عنوان ورودی روش‌های یادگیری ماشین و یادگیری عمیق استفاده شدند. این ویژگی‌ها به صورت زیر هستند:

- **استخراج اطلاعات باندهای مختلف از تصاویر ماهواره‌ای:** اطلاعات اولیه باندها بعد از پیش‌پردازش‌های لازم استخراج شدند.
- **ترکیبات مختلف باندی (نظیر نسبت باندها):** بعد از استخراج باندهای مورد نظر از تصاویر

جدول ۳: تعدادی از ترکیبات مختلف باندی ایجاد شده براساس تصویر استر

$\frac{TIR_4}{TIR_5} \frac{TIR_2}{TIR_1} \frac{TIR_2}{TIR_3} \frac{TIR_4}{TIR_3} \frac{TIR_3}{TIR_5} \frac{SWIR_1}{VNIR_1} \frac{SWIR_2}{VNIR_1} \frac{SWIR_1}{SWIR_4} \frac{SWIR_2}{SWIR_1} \frac{VNIR_2 + VNIR_1}{VNIR_2}$
$\frac{TIR_2 \times TIR_2}{TIR_1 \times TIR_3} \frac{3 \times TIR_4}{TIR_1 + TIR_2 + TIR_3} \frac{TIR_1 \times TIR_2}{TIR_2 \times TIR_2} \left(\frac{TIR_2}{TIR_1 + TIR_3} \right) \times \frac{TIR_4}{TIR_3} \frac{TIR_3/TIR_4}{(TIR_4/TIR_3)^2} TIR_3 + \left(\frac{TIR_5}{TIR_4} \right)^2$
$\frac{TIR_2/TIR_4}{(TIR_4/TIR_3)^2} \frac{VNIR_1 + VNIR_2}{VNIR_2} \frac{VNIR_3 + SWIR_2}{SWIR_1} \frac{SWIR_2 + SWIR_4}{SWIR_3} \frac{SWIR_2 \times VNIR_1}{VNIR_3 \times VNIR_2} SWIR_4 + \frac{SWIR_6}{SWIR_5} \frac{VNIR_3}{VNIR_1} \frac{VNIR_2}{VNIR_1}$
$TIR_1 + TIR_2 + TIR_3 + TIR_4 + TIR_5, VNIR_1 + VNIR_2 + VNIR_3, TIR_4 - TIR_5, SWIR_6 - SWIR_5$
$VNIR_3 - VNIR_1 \frac{TIR_1 - TIR_2}{TIR_1 + TIR_2} \frac{SWIR_2 - SWIR_3}{SWIR_2 + SWIR_3} \frac{TIR_3 \times TIR_4}{TIR_2 \times TIR_5} \frac{VNIR_1 \times SWIR_2}{SWIR_3 \times VNIR_2} TIR_2^2 - TIR_3^2$
$SWIR_2^2 + VNIR_3^2, \sqrt{TIR_1 \times TIR_4}, \sqrt{VNIR_2 \times SWIR_2} \frac{TIR_4 \times TIR_5}{VNIR_1 \times VNIR_2} \frac{SWIR_4 \times TIR_2}{SWIR_1 + SWIR_2}$
$\frac{TIR_2 \times VNIR_3}{TIR_3 \times VNIR_1} \frac{SWIR_1 \times TIR_4}{SWIR_3 \times TIR_2} \frac{TIR_3}{TIR_1 + TIR_2 + TIR_4} \frac{VNIR_1}{VNIR_2 + VNIR_3 + SWIR_2}$
$PCA_1 + PCA_2 + PCA_3 + PCA_4 + PCA_5, MNF_1 + MNF_2 + MNF_3 + MNF_4 + MNF_5, PCA_1 - PCA_2$
$MNF_1 - MNF_2, PCA_4 - PCA_5, MNF_4 - MNF_5, \frac{PCA_1}{PCA_2} \frac{MNF_1}{MNF_2} \frac{PCA_3}{PCA_4}$
$\frac{MNF_3}{MNF_4} PCA_1 \times PCA_2, MNF_1 \times MNF_2, PCA_4 \times PCA_5, MNF_4 \times MNF_5, \frac{PCA_1}{MNF_1} \frac{PCA_2}{MNF_2}$
$\frac{PCA_2}{MNF_2} \frac{PCA_3}{MNF_3} \frac{PCA_1 + MNF_1}{PCA_2 + MNF_2} \frac{PCA_3 + MNF_3}{PCA_4 + MNF_4} \frac{PCA_1 \times MNF_2}{PCA_3 \times MNF_4} \frac{PCA_2 \times PCA_4}{MNF_1 \times MNF_3} PCA_1^2 - PCA_2^2$
$MNF_1^2 - MNF_2^2, PCA_3^2 + MNF_3^2, \sqrt{PCA_1 \times PCA_2}, \sqrt{MNF_1 \times MNF_2}, \sqrt{PCA_4 \times MNF_4}$

برای نمایش تأثیر توپوگرافی بر رطوبت خاک به کار می‌رود. شاخص رطوبت توپوگرافی به صورت رابطه (۱) تعریف می‌شود:

رابطه (۱)

$$TWI = \ln \left(\frac{a}{\tan(\beta)} \right)$$

در رابطه (۱)، β و a به ترتیب شیب محلی زمین و مساحت تجمع آب (مسطحی که آب به سمت یک نقطه جمع می‌شود) هستند. a به طور معمول به عنوان مساحت تجمع جریانی یا تخلیه تجمع در واحد طول تعریف می‌شود.

• اطلاعات توپوگرافی و مکانی: علاوه بر اطلاعات

بالا، داده‌های ارتفاعی از مدل رقومی ارتفاع استخراج شدند. همچنین، از اطلاعات موقعیت نقاط (Coord) به عنوان ویژگی مکانی استفاده شد. در این مرحله، ارتفاع، شیب، جهت شیب و شاخص رطوبت توپوگرافی به عنوان اطلاعات توپوگرافی (Topo) از مدل رقومی ارتفاع محاسبه شدند. شاخص رطوبت توپوگرافی، یک شاخص جغرافیایی است که برای برآورد توزیع مکانی رطوبت خاک و پتانسیل جریان سطحی استفاده می‌شود و به عنوان یک مدل ساده

بالا و توانایی کار با داده‌های پیچیده یکی از روش‌های پرکاربرد در یادگیری ماشین است. در این تحقیق، ۱۰۰۰ درخت تصمیم‌گیری ایجاد شدند. هرچند افزایش تعداد درختان می‌تواند دقت مدل را افزایش دهد، زمان آموزش و پیش‌بینی افزایش می‌یابد. همچنین، حداقل تعداد نمونه‌ها که باید در یک گره وجود داشته باشد تا آن گره تقسیم شود، برابر با دو در نظر گرفته شد. بنابراین، هر گره می‌تواند به دو گره فرعی تقسیم شود، مگر اینکه تعداد نمونه‌ها کمتر از دو باشد. در هر تقسیم درخت، تعداد ویژگی‌هایی که باید به‌طور تصادفی انتخاب شوند نیز برابر با ریشه دوم تعداد کل ویژگی‌ها انتخاب شد.

۶-۳-۲- روش یادگیری عمیق

اساس روش‌های یادگیری عمیق، استفاده از شبکه‌های عصبی مصنوعی چند لایه برای یادگیری و استخراج ویژگی‌های پیچیده از داده‌هاست. شبکه‌های عصبی یادگیری عمیق شامل لایه‌های ورودی، پنهان و خروجی هستند که ویژگی‌های پیچیده و غیرخطی توسط لایه‌های پنهان به‌صورت خودکار از داده‌های ورودی استخراج می‌شوند. هر لایه شبکه عصبی متشکل از چند نورون است که به هم متصل هستند و توسط وزن‌ها و بایاس‌ها اطلاعات عددی از یک لایه به لایه بعد منتقل می‌شوند. در یادگیری نظارت‌شده، شبکه عصبی با استفاده از داده‌های برچسب‌دار (نوع سنگ برای هر نمونه) آموزش می‌بیند تا ارتباط بین ورودی‌ها (اطلاعات طیفی، توپوگرافی و مکانی) و خروجی‌ها (نوع سنگ) برقرار شود. مزیت اصلی یادگیری عمیق کاهش نیاز به استخراج دستی ویژگی‌هاست و ویژگی‌ها به‌طور خودکار از داده‌های پیچیده استخراج می‌شوند.

در این تحقیق، یک شبکه عصبی عمیق شامل پنج لایه پیاده‌سازی شد که هدف آن آموزش مدل برای حل مسئله طبقه‌بندی است. لایه‌های فشرده به‌عنوان

۶-۲- انتخاب ویژگی

از آنجا که تعداد ویژگی‌های ایجاد شده زیاد بود، انتخاب ویژگی‌های برتر با روش‌های مختلف انتخاب ویژگی نظیر جنگل تصادفی، حذف ویژگی‌ها به صورت بازگشتی^۱، لاسو^۲، باروت^۳ و ضریب همبستگی پیرسون^۴ انجام شد. در این تحقیق، بهترین نتیجه با روش لاسو حاصل شد.

۶-۳- الگوریتم

در این بخش، روش‌های مختلف طبقه‌بندی به‌منظور تمایز واحدهای زمین‌شناسی شرح داده می‌شوند.

۶-۳-۱- روش جنگل تصادفی

روش جنگل تصادفی یک الگوریتم یادگیری ماشین نظارت‌شده است که برای حل مسائل طبقه‌بندی استفاده می‌شود. اساس این روش، ترکیب چند درخت تصمیم‌گیری^۵ برای بهبود دقت پیش‌بینی و کاهش مشکل بیش‌برازش است. برای این منظور، هر درخت به‌طور مستقل از سایر درختان آموزش داده می‌شود و برای ساخت هر درخت از نمونه‌گیری تصادفی و انتخاب ویژگی‌های تصادفی استفاده می‌شود. در مرحله نمونه‌گیری تصادفی، چندین نمونه تصادفی (با جایگزینی) از داده‌های آموزشی انتخاب می‌شوند. در مرحله انتخاب ویژگی‌های تصادفی نیز تعدادی از ویژگی‌ها به‌صورت تصادفی در هر گره درخت انتخاب می‌شوند تا بهترین تقسیم‌بندی بر این اساس انجام شود. با این روش از هم‌بستگی بین درخت‌ها جلوگیری می‌شود و به ایجاد تنوع درختان کمک می‌شود. پس از آموزش همه درخت‌ها، رأی‌گیری اکثریت بین پیش‌بینی‌های درختان مختلف برای طبقه‌بندی انجام می‌شود و ترکیب درختان متعدد باعث افزایش دقت می‌شود. در کل، روش جنگل تصادفی به دلیل عملکرد

¹ Recursive Feature Elimination (RFE)

² Lasso

³ Boruta

⁴ Pearson's Correlation Coefficient

⁵ Decision Trees (DT)

یادگیری آن ۰/۰۰۱ تنظیم شد. مدل با استفاده از داده‌های آموزشی و برای ۱۰۰۰ تکرار^{۱۰} آموزش دید و ۲۰ درصد از داده‌ها برای اعتبارسنجی استفاده شدند. همچنین، اندازه دسته^{۱۱} برابر با ۲۰۰ در نظر گرفته شد تا مدل هر بار ۲۰۰ نمونه را پردازش کند.

۶-۳-۳- روش *XGBoost*

روش *XGBoost* (چن و همکاران (۲۰۱۶) [۲۵]) یک روش یادگیری ماشین نظارت شده است که برای مسائل طبقه‌بندی طراحی شده است. این روش بر اساس الگوریتم تقویت گرادیانی^{۱۲} عمل می‌کند و با ترکیب چند مدل ضعیف (نظیر درختان تصمیم‌گیری ضعیف) یک مدل قوی ایجاد می‌شود که قادر به پیش‌بینی خروجی‌هاست. در الگوریتم تقویت گرادیانی، مدل‌های جدید با هدف کاهش خطای مدل‌های قبلی به‌طور ترتیبی اضافه می‌شوند تا مدل نهایی به‌صورت تدریجی بهبود داده شود. یکی از مزایای این روش، توانایی آن در ارائه ویژگی‌های موثر^{۱۳} است که نشان می‌دهد کدام ویژگی‌ها بیشترین تاثیر را در پیش‌بینی‌ها دارند.

در این تحقیق، تعداد درخت‌ها برابر با ۱۰۰۰ در نظر گرفته شد تا مدل قادر به یادگیری الگوهای پیچیده باشد و به‌منظور کنترل بیش‌برازش، نرخ یادگیری مقدار کوچکی برابر با ۰/۰۵ انتخاب شد. با توجه به ماهیت چندکلاسه مسئله، از تابع هدف *softmax* چند کلاسه استفاده گردید و تعداد کلاس‌ها براساس تعداد برچسب‌های متمایز در داده‌های آموزشی تنظیم شد.

۶-۳-۴- روش *LightGBM*

روش *LightGBM* (گولین و همکاران (۲۰۱۷) [۲۶]) یک روش یادگیری ماشین کارآمد است که براساس الگوریتم تقویت گرادیانی عمل می‌کند. برخلاف بسیاری از الگوریتم‌های تقویت گرادیانی که درختان را به‌صورت

لایه‌های کاملاً متصل^۱ شناخته می‌شوند که در آن هر نورون به تمام نورون‌های لایه قبلی و بعدی متصل است. مدل شامل چهار لایه فشرده با تعداد نورون‌های ۱۲۸، ۶۴، ۳۲ و ۱۶ است. لایه اول شامل ۱۲۸ نورون، تابع فعال‌سازی رلو^۲ و ورودی به ابعاد تعداد ویژگی‌های داده آموزشی است. لایه‌های دوم تا چهارم به ترتیب شامل ۶۴، ۳۲ و ۱۶ نورون با تابع فعال‌سازی رلو هستند. لایه خروجی آخرین لایه فشرده با تعداد نورون برابر با تعداد کلاس‌ها و تابع فعال‌سازی سافت مکس^۳ است که خروجی آن توزیع احتمال کلاس‌های مختلف را برای هر نمونه تولید می‌کند. در هر لایه فشرده از منظم‌سازی^۴ *L2* استفاده شد که به جلوگیری از بیش‌برازش کمک می‌کند. این روش باعث می‌شود وزن‌های شبکه به مقدار بزرگی نرسند و مدل ساده‌تر شود. لایه‌های میانی شامل نرمال‌سازی دسته‌ای^۵ و حذف تصادفی^۶ برای بهبود یادگیری و جلوگیری از بیش‌برازش هستند. نرمال‌سازی باعث می‌شود سرعت همگرایی افزایش یابد و آموزش شبکه پایدارتر شود. همچنین در هر لایه، از حذف تصادفی با مقدار ۰/۳ استفاده شد. حذف تصادفی روشی است که به‌صورت تصادفی برخی از نورون‌ها را در طول هر دوره آموزشی غیرفعال می‌کند و به جلوگیری از وابستگی زیاد مدل به برخی نورون‌ها کمک می‌کند. همچنین برای آموزش مدل، از تابع زیان^۷ آنتروپی متقاطع دسته‌بندی^۸ و بهینه‌ساز آدام^۹ استفاده شد. تابع آنتروپی متقاطع دسته‌بندی برای مسائل طبقه‌بندی چندکلاسه استفاده می‌شود و آدام یک بهینه‌ساز پرکاربرد است که نرخ

^۱ Fully Connected

^۲ ReLU

^۳ Softmax

^۴ Regularization

^۵ Batch normalization

^۶ Dropout

^۷ Loss

^۸ Categorical crossentropy

^۹ Adam

^{۱۰} Epochs

^{۱۱} Batch size

^{۱۲} Gradient Boosting

^{۱۳} Feature Importance

$$Accuracy = \frac{TP + TN}{FP + FN + TP + TN}$$

رابطه (۳)

$$Precision = \frac{TP}{FP + TP}$$

رابطه (۴)

$$Recall = \frac{TP}{FN + TP}$$

رابطه (۵)

$$F - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

در روابط ذکر شده، TP ، TN ، FP و FN به ترتیب تعداد نمونه‌های صحیح که به درستی مثبت شناسایی شدند، تعداد نمونه‌های صحیح که به درستی منفی شناسایی شدند، تعداد نمونه‌های منفی که به اشتباه مثبت شناسایی شدند و تعداد نمونه‌های مثبت که به اشتباه منفی شناسایی شدند، هستند. در نتیجه، صحت نسبت پیش‌بینی‌های صحیح به کل پیش‌بینی‌هاست. دقت نشان می‌دهد که چه نسبتی از کل پیش‌بینی‌های مثبت صحیح است و یادآوری نشان می‌دهد از کل نمونه‌های مثبت واقعی، چه نسبتی به درستی تشخیص داده شده‌اند. امتیاز ($F-Score$) نیز میانگینی از دقت و یادآوری است. همچنین، آرایه ابهام^۳ به صورت جدولی است که تعداد نمونه‌های واقعی و پیش‌بینی شده برای هر کلاس را نشان می‌دهد و ابزاری برای مشاهده عملکرد مدل است. ضریب کاپا نیز یک معیار آماری است که میزان توافق بین برچسب‌های پیش‌بینی شده و مقادیر واقعی را با در نظر گرفتن توافق تصادفی اندازه‌گیری می‌کند، به طوری که مقادیر نزدیک به ۱ نشان‌دهنده توافق بالا و مقادیر نزدیک به صفر بیانگر توافق در سطح تصادفی هستند.

۷- ارزیابی نتایج

سطح به سطح رشد می‌دهند، این روش از رویکرد رشد براساس داده‌های برگ استفاده می‌کند که به کاهش خطا و ایجاد مدل دقیق‌تر کمک می‌کند. روش $LightGBM$ با استفاده از روش‌های بهینه‌سازی مانند تقسیم داده بر اساس گرادیان^۱ و نمونه‌برداری^۲، سرعت آموزش بالا دارد. این روش به دلیل سرعت بالا، دقت زیاد و قابلیت کار با مجموعه داده‌های بزرگ، در بسیاری از حوزه‌ها کاربرد دارد.

در تنظیم پارامترهای مدل، نرخ یادگیری برابر با ۰٫۲ در نظر گرفته شد تا فرآیند همگرایی با سرعت بیشتری انجام شود. همچنین، از الگوریتم تقویت گرادیانی از نوع $DART$ استفاده شد که با بهره‌گیری از روش حذف تصادفی درخت‌ها، نقش مؤثری در کاهش بیش‌برازش ایفا می‌کند. به منظور کنترل پیچیدگی مدل و جلوگیری از بیش‌برازش نیز تعداد برگ‌ها برابر با ۱۰۰ و حداکثر عمق درخت برابر با ۱۰ تنظیم شد. با توجه به ماهیت چندکلاسه مسئله، از تابع هدف چندکلاسه استفاده شد و ارزیابی عملکرد مدل براساس معیارهای $multi_logloss$ و $multi_error$ صورت پذیرفت. به این ترتیب، مدل نهایی با ۵۰۰ تکرار آموزش داده شد و خروجی آن به صورت توزیع احتمال تعلق هر نمونه به کلاس‌های مختلف محاسبه گردید. در نهایت، برچسب هر نمونه بر اساس بیشینه مقدار احتمال تخصیص داده شد.

۶-۴- معیارهای ارزیابی نتایج

نتایج حاصل در این مقاله با معیارهای صحت ($Accuracy$)، دقت ($Precision$)، یادآوری ($Recall$) و امتیاز ($F-Score$) ارزیابی شدند. همچنین، آرایه ابهام و معیارهای ذکر شده برای بهترین روش گزارش شده است. معیارهای صحت، دقت، یادآوری و امتیاز به صورت روابط (۲) تا (۵) تعریف می‌شوند:

رابطه (۲)

^۱ Histogram-based decision tree learning

^۲ Gradient-based one-side sampling

^۳ Confusion matrix

در این بخش، نتایج طبقه‌بندی واحدهای سنگ‌شناسی با تغییر پارامترها و اعمال روش‌های مختلف ارزیابی شده است. برای این منظور، داده‌ها ۲۰ بار به صورت تصادفی به دو دسته آموزشی و آزمایشی دسته‌بندی و ذخیره شدند و در هر تکرار، ۸۰٪ داده‌ها به عنوان داده آموزشی و ۲۰٪ داده‌ها به عنوان داده آزمایشی در نظر گرفته شدند. سپس، میانگین نتایج حاصل از ۲۰ بار تکرار روی داده‌های ذخیره شده محاسبه گردید. همچنین، پارامترهای *Coord* و *Topo* به ترتیب نشان دهنده در نظر گرفتن (یک) یا صرف نظر کردن (صفر) از ویژگی‌های مکانی و توپوگرافی هستند.

جدول ۴: نتایج حاصل از طبقه‌بندی با روش‌های انتخاب ویژگی مختلف ($Topo=1, Coord=0$), روش متوازن سازی داده‌ها: افزایش مصنوعی نمونه‌های اقلیت، روش طبقه‌بندی: جنگل تصادفی

روش انتخاب ویژگی	امتیاز	یادآوری	دقت	صحت
Lasso	۰.۶۷	۰.۶۸	۰.۶۷	۰.۷۰
Pearson's Correlation Coefficient	۰.۶	۰.۶۲	۰.۶۱	۰.۶۴
RF	۰.۶۳	۰.۶۴	۰.۶۳	۰.۶۶
RFE	۰.۶۳	۰.۶۵	۰.۶۴	۰.۶۶
Boruta	۰.۶۲	۰.۶۴	۰.۶۳	۰.۶۶
—	۰.۶۲	۰.۶۴	۰.۶۳	۰.۶۶

۷-۲- تاثیر توازن نمونه‌ها در طبقه‌بندی انواع سنگ‌ها در این بخش، دقت حاصل از ایجاد توازن در تعداد نمونه‌های کلاس‌های مختلف با روش‌های مختلف افزایش مصنوعی نمونه‌های اقلیت، نمونه‌برداری افزایشی تصادفی و نمونه‌برداری کاهش تصادفی ارزیابی

و مقایسه شده است. همانطور که در جدول (۵) مشاهده می‌شود، بهترین نتایج با روش افزایش مصنوعی نمونه‌های اقلیت و روش نمونه‌برداری افزایشی تصادفی حاصل شده است و ایجاد توازن در نمونه‌ها با کاهش تعداد نمونه‌ها باعث کاهش دقت روش می‌شود.

جدول ۵: نتایج حاصل از طبقه‌بندی با روش‌های مختلف توازن نمونه‌ها ($Topo=1, Coord=0$), روش انتخاب ویژگی: لاسو، روش طبقه‌بندی: جنگل تصادفی

روش متوازن سازی داده‌ها	امتیاز	یادآوری	دقت	صحت
افزایش مصنوعی نمونه‌های اقلیت	۰.۶۷	۰.۶۸	۰.۶۷	۰.۷۰
نمونه‌برداری افزایشی تصادفی	۰.۶۶	۰.۶۷	۰.۶۷	۰.۷۰
نمونه‌برداری کاهش تصادفی	۰.۶۲	۰.۶۴	۰.۶۲	۰.۶۵

همانطور که مشاهده می‌شود، بهترین نتایج با تصاویر استر به دلیل وجود باندهای متنوع *TIR* و *SWIR* حاصل شده است و نتایج طبقه‌بندی با روش‌های لندست و سنتینل-۲ نسبتاً مشابه است.

۷-۳- تاثیر داده ماهواره‌ای در طبقه‌بندی انواع سنگها
به‌منظور طبقه‌بندی انواع سنگ‌ها از چند روش طبقه‌بندی استفاده شده است و نتایج آنها در جدول (۶) نشان داده شده‌اند.

جدول ۶: نتایج حاصل از طبقه‌بندی با داده‌های ماهواره‌ای مختلف ($Topo=1$, $Coord=0$), روش انتخاب ویژگی: لاسو، روش متوازن-سازي داده‌ها: افزايش مصنوعی نمونه‌های اقلیت، روش طبقه‌بندی: جنگل تصادفی)

داده ورودی	امتیاز	یادآوری	دقت	صحت
سنتینل-۲	۰.۶۲	۰.۶۴	۰.۶۲	۰.۶۶
لندست	۰.۶۳	۰.۶۴	۰.۶۵	۰.۶۶
استر	۰.۶۷	۰.۶۸	۰.۶۷	۰.۷۰

یادگیری عمیق و ماشین بردار پشتیبان حاصل شده است. نتایج روش‌های *LightGBM* و *XGBoost* به‌طور تقریبی مشابه هستند و ضعیف‌ترین نتایج با ماشین بردار پشتیبان حاصل شده است.

۷-۴- تاثیر روش طبقه‌بندی در طبقه‌بندی انواع سنگها
در این بخش، کارایی روش‌های مختلف طبقه‌بندی در تمایز سنگ‌ها بررسی شده است. همانطور که در جدول (۷) مشاهده می‌شود، بهترین نتایج به‌ترتیب با روش‌های جنگل تصادفی، *LightGBM*، *XGBoost*

جدول ۷: نتایج حاصل از طبقه‌بندی با روش‌های طبقه‌بندی مختلف ($Topo=1$, $Coord=0$), روش انتخاب ویژگی: لاسو، روش متوازن-سازي داده‌ها: افزايش مصنوعی نمونه‌های اقلیت، داده ورودی: استر)

روش طبقه‌بندی	امتیاز	یادآوری	دقت	صحت
جنگل تصادفی	۰.۶۷	۰.۶۸	۰.۶۷	۰.۷۰
<i>LightGBM</i>	۰.۶۴	۰.۶۵	۰.۶۴	۰.۶۸
<i>XGBoost</i>	۰.۶۳	۰.۶۵	۰.۶۴	۰.۶۷
یادگیری عمیق	۰.۵۸	۰.۵۹	۰.۵۹	۰.۶۳
SVC	۰.۵۴	۰.۵۷	۰.۵۴	۰.۵۶

استفاده از اطلاعات توپوگرافی باعث افزایش دقت روش می‌شود. همچنین، اطلاعات مکانی در مواردی که اطلاعات طیفی قادر به تمایز واحدهای سنگی از هم نیستند، به جداسازی آنها از هم کمک می‌کند و باعث افزایش دقت می‌شوند.


۷-۵- تاثیر ویژگی‌های توپوگرافی و اطلاعات مکانی در طبقه‌بندی انواع سنگها
در این مرحله، تاثیر اطلاعات توپوگرافی با حذف ویژگی‌های مربوط به اطلاعات توپوگرافی (ارتفاع، شیب، شاخص رطوبت توپوگرافی و جهت شیب) بررسی شده است. همانطور که در جدول (۸) مشاهده می‌شود،

جدول ۸: نتایج حاصل از طبقه‌بندی با وجود ویژگی‌های توپوگرافی ($Top=1$) و مکانی ($Coord=1$) و بدون ویژگی‌های توپوگرافی ($Top=0$) و مکانی ($Coord=0$) (روش انتخاب ویژگی: لاسو، روش متوازن‌سازی داده‌ها: افزایش مصنوعی نمونه‌های اقلیت، داده ورودی: استر، روش طبقه‌بندی: جنگل تصادفی)

صحت	دقت	یادآوری	امتیاز	Coord	Topo
۰٫۶۲	۰٫۵۹	۰٫۶۰	۰٫۵۸	۰	۰
۰٫۷۰	۰٫۶۷	۰٫۶۸	۰٫۶۷	۰	۱
۰٫۷۸	۰٫۷۸	۰٫۷۹	۰٫۷۸	۱	۰
۰٫۸۲	۰٫۸۲	۰٫۸۳	۰٫۸۲	۱	۱

ارزیابی، جداگانه برای هر کلاس محاسبه شده‌اند و نتایج حاصل از میانگین ۲۰ تکرار در شکل (۷) نشان داده شده‌اند.

براساس نتایج حاصل، بهترین دقت با روش جنگل تصادفی و با در نظر گرفتن اطلاعات توپوگرافی و مکانی به همراه اطلاعات طیفی حاصل شده است. به‌منظور ارزیابی عملکرد روش برای هر کلاس، معیارهای



شکل ۷: نتایج حاصل از طبقه‌بندی برای هر کلاس (روش انتخاب ویژگی: لاسو، روش متوازن‌سازی داده‌ها: افزایش مصنوعی نمونه‌های اقلیت، داده ورودی: استر، روش طبقه‌بندی: جنگل تصادفی، کلاس ۱: Jph ، کلاس ۲: Qtl ، کلاس ۳: $gr.at$ ، کلاس ۴: $gr1$)

اصلی افزایش یافته و از میزان خطاهای بین‌کلاسی کاسته شده است.

در حالتی که تنها از داده‌های مکانی استفاده شده است، بهبود قابل توجهی در برخی از کلاس‌ها مشاهده شده است. با این حال، همچنان میزان قابل‌ملاحظه‌ای از اختلاط بین کلاس‌ها وجود دارد. بهترین عملکرد با ضریب کاپا برابر با ۰/۷۴ مربوط به حالتی است که هر دو نوع داده مکانی و توپوگرافی به‌صورت هم‌زمان مورد استفاده قرار گرفته‌اند. در این حالت، مقادیر واقع بر قطر اصلی افزایش یافته و پراکندگی خطاها به حداقل رسیده است که بیان‌گر کاهش عدم قطعیت و افزایش قابلیت تفکیک مدل است. به‌طور کلی، نتایج نشان می‌دهد که ترکیب داده‌های چندمنبعی نقش مؤثری در کاهش عدم قطعیت و بهبود دقت طبقه‌بندی دارد و استفاده هم‌زمان از داده‌های مکانی و توپوگرافی منجر به پایدارترین و قابل‌اعتمادترین نتایج شده است.

به‌منظور سنجش دقت و قابلیت اعتماد نتایج طبقه‌بندی، برای هر حالت آرایه ابهام تشکیل شد تا عملکرد مدل در سطح هر یک از کلاس‌های زمین‌شناسی به‌طور جداگانه ارزیابی شود. بر اساس این آرایه، شاخص‌های ارزیابی شامل صحت کلی، دقت، یادآوری و امتیاز محاسبه شدند. این شاخص‌ها امکان بررسی عملکرد مدل‌ها را هم در سطح کلی و هم در سطح هر کلاس فراهم می‌کنند.

به‌منظور ارزیابی دقیق‌تر عملکرد مدل و بررسی میزان عدم قطعیت در نتایج، آرایه‌های ابهام برای چهار حالت مختلف شامل استفاده و عدم استفاده از داده‌های مکانی و توپوگرافی مورد تحلیل قرار گرفتند. نتایج نشان داد که در حالت پایه (بدون استفاده از داده‌های مکانی و توپوگرافی)، پراکندگی مقادیر خارج از قطر اصلی بیشتر است که بیان‌گر خطای بالاتر در طبقه‌بندی است. با افزودن داده‌های توپوگرافی، تمرکز مقادیر بر روی قطر

جدول ۹: آرایه ابهام حاصل از طبقه‌بندی برای هر کلاس (روش انتخاب ویژگی: لاسو، روش متوازن‌سازی داده‌ها: افزایش مصنوعی نمونه‌های اقلیت، داده ورودی: استر، روش طبقه‌بندی: جنگل تصادفی، کلاس ۱: Jph کلاس ۲: $Qt1$ ، کلاس ۳: $gr.at$ ، کلاس ۴: $gr1$)

پارامترها	آرایه ابهام
$Coord=.$ $Topo=1$	$\begin{bmatrix} 23.8 & 5 & 0.5 & 0.5 \\ 4.3 & 10.8 & 1.65 & 1.25 \\ 0.2 & 1.6 & 5.7 & 1.95 \\ 0.5 & 0.7 & 2.5 & 8.5 \end{bmatrix}$
$Coord=1$ $Topo=1$	$\begin{bmatrix} 25.4 & 4.4 & 0 & 0 \\ 3.55 & 13.3 & 1.5 & 0.1 \\ 0.2 & 0.35 & 7.85 & 1.5 \\ 0.45 & 0.5 & 1 & 10.25 \end{bmatrix}$
$Coord=.$ $Topo=.$	$\begin{bmatrix} 20.85 & 5.95 & 1.7 & 1.3 \\ 4.75 & 9.3 & 2.55 & 1.4 \\ 0.6 & 1.45 & 5.3 & 2.1 \\ 0.85 & 0.6 & 3.15 & 7.15 \end{bmatrix}$
$Coord=1$ $Topo=.$	$\begin{bmatrix} 23.8 & 5.75 & 0.2 & 0.5 \\ 4.15 & 13.3 & 1.35 & 0.2 \\ 0.5 & 0.2 & 7.5 & 1.35 \\ 0.3 & 0 & 1.15 & 10.3 \end{bmatrix}$

۷-۶- بحث

طبقه‌بندی تأثیر قابل توجهی بر عملکرد نهایی مدل در طبقه‌بندی انواع سنگ‌ها دارند. در میان روش‌های انتخاب ویژگی، روش لاسو عملکرد بهتری نسبت به

نتایج حاصل از این پژوهش نشان می‌دهد که انتخاب ویژگی، توازن داده‌ها، نوع داده ورودی و الگوریتم

نتایج همچنین نشان داد که افزودن ویژگی‌های توپوگرافی و اطلاعات مکانی تأثیر قابل توجهی در بهبود دقت مدل دارد. به‌ویژه، ترکیب همزمان اطلاعات طیفی، توپوگرافی و مکانی منجر به بیشترین دقت شد. این امر نشان می‌دهد که اطلاعات مکانی و توپوگرافی می‌توانند مکمل اطلاعات طیفی باشند، به‌ویژه در شرایطی که شباهت طیفی بین واحدهای سنگی وجود دارد. به‌طور کلی، نتایج این پژوهش بیانگر آن است که استفاده همزمان از انتخاب ویژگی مناسب، توازن داده‌ها، داده‌های ماهواره‌ای با قدرت تفکیک طیفی بالا و الگوریتم‌های پیشرفته یادگیری ماشین می‌تواند به‌طور قابل توجهی دقت طبقه‌بندی انواع سنگ‌ها را بهبود بخشد.

۸- نتیجه‌گیری:

شناسایی و تمایز واحدهای زمین‌شناسی با استفاده از داده‌های سنجنش از دور، به‌منظور تهیه نقشه‌های سنگ‌شناسی در مقیاس وسیع، از اهمیت بالایی برخوردار است. در این پژوهش، توانایی داده‌های سنجنش از دور مبتنی بر تصاویر ماهواره‌ای استر، لندست و سنتینل-۲، به‌همراه نمونه‌های استخراج‌شده از واحدهای سنگ‌شناسی منطقه هندودر، در تفکیک واحدهای زمین‌شناسی مورد ارزیابی قرار گرفت. نتایج نشان داد که تصاویر ماهواره‌ای، در صورت به‌کارگیری روش‌های یادگیری ماشین و یادگیری عمیق و نیز استخراج ویژگی‌های مناسب، قادر به تمایز مؤثر واحدهای سنگ‌شناسی هستند. همچنین، اطلاعات توپوگرافی، ویژگی‌های حاصل از تبدیل‌های *MNF* و *PCA*، و باندهای حرارتی استر از جمله عوامل مؤثر در بهبود تفکیک واحدهای زمین‌شناسی محسوب می‌شوند. در نهایت، به‌کارگیری روش جنگل تصادفی، در ترکیب با تصاویر استر و اطلاعات توپوگرافی و مکانی، منجر به بهبود قابل توجه عملکرد مدل در طبقه‌بندی واحدهای سنگ‌شناسی شده است.

سایر روش‌ها نشان داد. این امر را می‌توان به قابلیت این روش در اعمال منظم‌سازی و حذف ویژگی‌های غیرمؤثر نسبت داد که منجر به کاهش پیچیدگی مدل و بهبود تعمیم‌پذیری آن می‌شود. در مقابل، سایر روش‌ها مانند جنگل تصادفی، حذف ویژگی‌ها به صورت بازگشتی و باروتا عملکرد نسبتاً مشابهی داشتند که نشان‌دهنده همپوشانی اطلاعاتی بین ویژگی‌ها است.

در زمینه توازن داده‌ها، نتایج نشان داد که روش‌های افزایش تعداد نمونه‌ها، به‌ویژه افزایش مصنوعی نمونه‌های اقلیت، تأثیر مثبتی بر عملکرد مدل دارند. این موضوع بیانگر آن است که عدم توازن داده‌ها می‌تواند باعث سوگیری مدل به سمت کلاس‌های غالب شود و استفاده از روش‌های نمونه‌برداری افزایشی به بهبود یادگیری کلاس‌های کم‌تعداد کمک می‌کند. در مقابل، کاهش تعداد نمونه‌ها در نمونه‌برداری کاهش منجر به از دست رفتن اطلاعات و کاهش دقت مدل شده است.

بررسی تأثیر داده‌های ماهواره‌ای مختلف نشان داد که تصاویر استر عملکرد بهتری نسبت به سنتینل-۲ و لندست دارند. این موضوع احتمالاً به دلیل وجود باندهای طیفی متنوع‌تر، به‌ویژه در محدوده‌های فروسرخ موج کوتاه و فروسرخ حرارتی است که توانایی بیشتری در تفکیک واحدهای سنگی فراهم می‌کنند.

در مقایسه الگوریتم‌های طبقه‌بندی، روش جنگل تصادفی بهترین عملکرد را ارائه داد. این موضوع می‌تواند به توانایی این الگوریتم در مدل‌سازی روابط غیرخطی و مقاومت آن در برابر نویز و بیش‌برازش نسبت داده شود. همچنین، روش‌های *LightGBM* و *XGBoost* عملکردی نزدیک به جنگل تصادفی داشتند که نشان‌دهنده کارایی بالای روش‌های مبتنی بر تقویت گرادیانی در این مسئله است. در مقابل، عملکرد ضعیف‌تر ماشین بردار پشتیبان می‌تواند ناشی از حساسیت این روش به انتخاب پارامترها و ساختار پیچیده داده‌ها باشد.

مراجع

- [1] F. D. van der Meer, H. M. A. van der Werff, F. J. A. van Ruitenbeek et al., "Multi- and hyperspectral geologic remote sensing: A review," *International Journal of Applied Earth Observation and Geoinformation*, vol. 14, no. 1, pp. 112-128, 2012.
- [2] P. Yang, K. Esmaeili, S. Goodfellow et al., "Mine pit wall geological mapping using UAV-based RGB imaging and unsupervised learning," *Remote Sensing*, vol. 15, no. 6, pp. 1641, 2023.
- [3] M. J. Cracknell, and A. M. Reading, "Geological mapping using remote sensing data: A comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information," *Comput. Geosci.*, vol. 63, pp. 22-33, 2014.
- [4] I. O. Nafigin, V. T. Ishmukhametova, S. A. Ustinov et al., "Geological and mineralogical mapping based on statistical methods of remote sensing data processing of Landsat-8: a case study in the southeastern Transbaikalia, Russia," *Sustainability*, vol. 14, no. 15, pp. 9242, 2022.
- [5] A. Shebl, and A. Csamer, "Stacked vector multi-source lithologic classification utilizing Machine Learning Algorithms: Data potentiality and dimensionality monitoring," *Remote Sensing Applications: Society and Environment*, vol. 24, pp. 100643, 2021.
- [6] A. B. Pour, M. Hashim, and J. van Genderen, "Detection of hydrothermal alteration zones in a tropical region using satellite remote sensing data: Bau goldfield, Sarawak, Malaysia," *Ore Geology Reviews*, vol. 54, pp. 181-196, 2013.
- [7] B. Zoheir, and A. Emamb, "Integrating geologic and satellite imagery data for high-resolution mapping and gold exploration targets in the South Eastern Desert, Egypt," *Journal of African Earth Sciences*, vol. 66-67 pp. 22-34, 2012.
- [8] C. c. Gomez, C. Delacourt, P. Allemand et al., "Using ASTER remote sensing data set for geological mapping, in Namibia," *Physics and Chemistry of the Earth* vol. 30, pp. 97-108, 2005.
- [9] A. Elaaraj, A. Lhachmi, H. Tabyaoui et al., "Remote sensing data for geological mapping in the Saka region in northeast Morocco: an integrated approach," *Sustainability*, vol. 14, no. 22, pp. 15349, 2022.
- [10] E. P. Binam Mandeng, L. M. Bondjè Bidjeck, J. D. Takodjou Wambo et al., "Lithologic and structural mapping of the Abiete-Toko gold district in southern Cameroon, using Landsat 7 ETM+/SRTM," *Comptes Rendus Geoscience*, vol. 350, pp. 130-140, March 01, 2018, 2018.
- [11] J. Aadaj, A. Tabit, A. Algouti et al., "Integrated optical and radar remote sensing for litho-structural mapping of the Kerdous and Ait Abdellah inliers, western Anti-Atlas, Morocco," *Scientific Reports*, vol. 16, no. 1, pp. 170, 2025.
- [12] M. A. Elfadly, M. Abdelrady, A. Decarlis et al., "Multidisciplinary approaches to lithological discrimination and structural mapping for mineral resource assessment," *Scientific Reports*, vol. 16, no. 1, pp. 9079, 2026.
- [13] S. A. Peña, and M. G. Abdelsalam, "Orbital remote sensing for geological mapping in southern Tunisia: Implication for oil and gas exploration," *Journal of African Earth Sciences*, vol. 44, pp. 203-219, 2006.
- [14] L. Githenya, E. Mathu, P. Kariuki et al., "Integration of remote sensing and geological mapping for economic mineralization mapping in Mwitika-Makongo area, Kitui county," *Journal of Remote Sensing & GIS*, vol. 10, no. 281, pp. 1-5, 2021.

- [15] F. Al-Nahmi, O. Saddiqi, A. Hilali et al., "Application of remote sensing in geological mapping, case study al Maghrabah area - Hajjah region, Yemen," *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 44W4, pp. 63-71, 2017.
- [16] I. Serbouti, M. Raji, M. Hakdaoui et al., "Improved lithological map of large complex semi-arid regions using spectral and textural datasets within google earth engine and fused machine learning multi-classifiers," *Remote Sensing*, vol. 14, no. 21, pp. 5498, 2022.
- [17] V. Árvai, and G. Albert, "Lightweight deep learning approaches for lithological mapping in vegetated terrains of the Vălioara valley, Romania," *ISPRS International Journal of Geo-Information*, vol. 14, no. 9, pp. 350, 2025.
- [18] X. Li, P. Feng, B. Yu et al., "Geologically constrained multi-scale transformer for lithology identification under extreme class imbalance," *Eng.*, vol. 7, no. 1, pp. 8, 2026.
- [19] R. Mohammadizad, and R. Arfania, "Advanced Investigation of Remote Sensing to Geological Mapping of Zefreh Region in Central Iran," *Open Journal of Geology*, vol. 7, pp. 1509-1529, 2017.
- [20] P. Safarbeyranvand, P. Z. Firouzabadi, A. Hosingholizade et al., "Using EO1 hyperspectral images for rock units mapping," *6th Intercontinental Geoinformation Days (IGD)*, Baku, Azerbaijan, vol. 6, pp. 191-194, 2023
- [21] G. Albert, and S. Ammar, "Application of random forest classification and remotely sensed data in geological mapping on the Jebel Meloussi area (Tunisia)," *Arabian Journal of Geosciences*, vol. 14, no. 21, pp. 2240, 2021.
- [22] C. Kumar, A. Shetty, S. Raval et al., "Lithological discrimination and mapping using ASTER SWIR data in the Udaipur area of Rajasthan, India," *Procedia Earth and Planetary Science*, vol. 11, pp. 180-188, 2015.
- [23] M. T. A. Mohamed, L. S. Al-Naimi, T. I. Mgbeojedo et al., "Geological mapping and mineral prospectivity using remote sensing and GIS in parts of Hamissana, Northeast Sudan," *Journal of Petroleum Exploration and Production*, vol. 11, no. 3, pp. 1123-1138, 2021.
- [24] A. B. Pour, Y. Park, M. Hashim et al., "Regional geological mapping in Northern Victoria Land, Antarctica using multispectral remote sensing satellite data," *IOP Conf. Series: Earth and Environmental Science*, vol. 169, no. 012081, pp. 1-9, 2018.
- [25] T. Chen, and C. Guestrin, "XGBoost: a scalable tree boosting system," *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* pp. 785 - 794, 2016.
- [26] Guolin Ke., Qi Meng., Thomas Finley. et al., "LightGBM: a highly efficient gradient boosting decision tree," *NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems*, pp. 3149 - 3157, 2017.



Distinguishing Lithological Units Based on Satellite Imagery Using Machine Learning and Deep Learning Methods in the Hendudar Region, Markazi Province

Mehrtash Manafifard ^{*1}, Mostafa Yousefird ²

1- Assistant Professor in Department of Earth Science, Arak University of Technology, Arak, Iran

2- Associate Professor in Department of Earth Science, Arak University of Technology, Arak, Iran

Abstract

Remote sensing imagery is widely used in various geological applications, including the identification and discrimination of different rock types. In this study, artificial intelligence methods, including Random Forest, Deep Learning, XGBoost, and LightGBM, were employed to distinguish four geological units, Phyllite, Ancient Alluvial Terraces, Granite to Granodiorite, and Migmatite, in the Hendudar area, Markazi Province, Iran.

The input data for the AI models consisted of the features extracted from the satellite imagery such as Landsat, ASTER, and Sentinel-2, along with topographic data derived from a Digital Elevation Model (DEM), including elevation, slope, Topographic Wetness Index (TWI), and aspect. In addition, the spatial data and field samples of the geological units were incorporated into the analysis.

To prepare the input datasets, the necessary preprocessing steps, including radiometric and atmospheric corrections, as well as the initial image processing and classification, were performed. Subsequently, a set of features was generated based on the spectral bands of the satellite imagery, as well as the transformed datasets derived from Principal Component Analysis (PCA) and Minimum Noise Fraction (MNF) techniques.

The evaluation results indicated that the Random Forest algorithm achieved the best performance. Using spectral information from ASTER imagery combined with topographic and spatial data, the model attained Kappa, Overall Accuracy, and F-score values of 0.74, 0.82, and 0.82, respectively.

Key words: Geology, Lithological mapping, Satellite imagery, Machine learning, Deep learning.