

شناسایی کانی‌های موجود در مقاطع نازک سنگ با استفاده از پردازش تصاویر رنگی

شکوفه ساعدی^۱ و عبدالله چاله‌چاله^۲

چکیده

در روش سنتی برای مطالعه کانی‌های موجود در مقاطع نازک، مرز کانی‌ها به صورت دستی جدا شده و هر بخش برچسب‌گذاری می‌شود. این روش هزینه‌بر و نیازمند دانش، تخصص و تجربه بالایی است. بنابراین وجود یک سامانه شناسایی خودکار در این حوزه ضروری است. چنین سامانه‌ای می‌تواند باعث افزایش دقت و کاهش خطاهای انسانی، هزینه و زمان تشخیص کانی‌ها شود. هدف این پژوهش، پیشنهاد یک سامانه تشخیص خودکار است که با استفاده از پردازش تصویر، کانی‌های موجود را شناسایی و طبقه‌بندی کند. مراحل اصلی روش ارائه شده شامل جمع‌آوری تصاویر از مقاطع نازک، قطعه‌بندی، استخراج ویژگی و طبقه‌بندی است. پس از ایجاد پایگاه تصاویر، الگوریتم JSEG برای قطعه‌بندی انتخاب و اعمال شده است. سپس ویژگی‌های رنگ و بافت در دو فضای رنگی RGB و HSI از هر ناحیه استخراج شده‌اند. این ویژگی‌ها، برای طبقه‌بندی به طبقه‌بند فرستاده شده و طبقه‌بند هر ناحیه را به عنوان یک کانی برچسب‌گذاری کرده است. به علاوه، در این پژوهش کارایی شش طبقه‌بند مختلف نیز برای این منظور مورد ارزیابی قرار گرفته است. براساس نتایج، طبقه‌بند Bagged Tree دارای بالاترین دقت به میزان ۹۵/۵۲٪ و کمترین میزان میانگین خطای مطلق برابر با ۰/۰۴ می‌باشد. همچنین همه طبقه‌بندها دارای دقت بالای ۹۳٪ هستند که نشان می‌دهد روش استخراج ویژگی پیشنهادی دارای قابلیت مناسبی است.

کلیدواژه‌ها

پردازش تصویر، شناسایی خودکار، مقاطع نازک، کانی، قطعه‌بندی، طبقه‌بندی

۱ مقدمه

دارد. یک روش کم هزینه و رایج برای شناسایی مواد معدنی و هم-چنین طبقه‌بندی معمولی سنگ‌ها، استفاده از میکروسکوپ پلاریزان است. این کار که معمولاً به صورت دستی و توسط یک متخصص در آزمایشگاه کانی‌شناسی انجام می‌شود، مرز بین کانی‌ها به صورت دستی جدا شده، هر بخش برچسب‌گذاری و درصد هر کانی محاسبه می‌شود. همان‌گونه که قابل انتظار است، شناسایی مواد معدنی از این طریق وقت‌گیر و پرهزینه بوده، مستلزم حضور یک متخصص کانی‌شناسی است و در نهایت احتمال وجود خطا در این روش وجود دارد.

امروزه روش‌های تشخیص کانی ارائه شده مبتنی بر پردازش تصویر کارایی مناسبی داشته و به دلیل انجام کار به صورت خودکار از دقت و سرعت بالایی برخوردارند. این پژوهش‌ها عمدتاً مبتنی بر پردازش تصاویر مقاطع نازک سنگ هستند که این

طبقه‌بندی سنگ‌ها یک بخش جدایی‌ناپذیر از زمین‌شناسی مدرن است [۱] که براساس شناسایی مواد معدنی انجام می‌شود. طبقه‌بندی سنگ نقش مهمی در مهندسی معدن، مکانیک سنگ، پترولوژی، پتروگرافی و بسیاری از شاخه‌های دیگر علوم زمین

این مقاله در شهریورماه سال ۱۳۹۹ دریافت، در فروردین‌ماه سال ۱۴۰۰ بازنگری و در اردیبهشت‌ماه همان سال پذیرفته شد.

^۱ کارشناس ارشد مهندسی فناوری اطلاعات.

رایانامه: shokoofeh.saedi@yahoo.com

^۲ گروه مهندسی کامپیوتر، دانشکده فنی مهندسی، دانشگاه رازی، کرمانشاه، ایران.

رایانامه: chalechale@razi.ac.ir

ایزدی و همکاران [۶] از نرمال‌سازی و فیلتر میانگین در مرحله پیش پردازش استفاده کرده‌اند. در این پژوهش برای هر پیکسل یک بردار دوازده‌تایی شامل ویژگی‌های RGB و HIS در دو نور معمولی و قطبی استخراج شده و به صورت ترکیب‌های مختلف برای جداسازی کانی‌ها استفاده شده است. مبنای جداسازی کانی‌ها، انجام خوشه بندی مبتنی بر خواص رنگی است. بنابراین، در ابتدا، پیکسل‌های با درجه تشابه بزرگ تر از δ در یک خوشه قرار گرفته، و پس از آن، خوشه‌های حاوی کانی‌های شاخص شناسایی شده است.

در [۷] یک سامانه هوشمند برای شناسایی مواد معدنی در مقاطع نازک براساس یک روش آبخاری ارائه می‌شود. پایگاه داده به صورت دستی به دو گروه تقسیم شده است. گروه ۱۵ شامل مواد معدنی است که در نور معمولی و نور قطبی، رنگ‌های مختلفی را نشان می‌دهند. بنابراین، اجزای رنگ یک پارامتر کامل برای شناسایی این مواد معدنی هستند. گروه ۲ شامل آن دسته از مواد معدنی است که تقریباً همان رنگ نور معمولی را در نور قطبی نشان می‌دهند و بنابراین ویژگی‌های بافتی نیز برای شناسایی درست لازم است.

در مرحله استخراج ویژگی، یک بردار ۱۲ تایی برای هر پیکسل در فضای RGB و HSI استخراج می‌شود. سطح اول آبخار، شامل شناسایی خوشه‌های معدنی بر اساس رنگ است. اگر این خوشه‌ها به عنوان گروه ۱ شناسایی شوند، به عنوان خروجی گزارش می‌شوند. اگر خوشه‌ها به عنوان گروه ۲ شناسایی شوند، به سطح دوم آبخار منتقل می‌شوند. در سطح دوم آبخار، دو بردار ویژگی مبتنی بر بافت با ابعاد 2×120 در تصاویر مقاطع نازک در نور معمولی و نور قطبی، از هر خوشه استخراج می‌شود. طبقه بندی در سطح دوم آبخار براساس بردار ویژگی‌های بافتی انجام می‌شود. زندی فر و همکاران از روش تهیه مقاطع متوالی برای مدل‌سازی استفاده کرده‌اند [۸]. در ابتدا تمام نمونه‌های مورد نظر در ابعاد چند سانتی متری برش داده شده و تصویر مقاطع نازک میکروسکوپی از آن تهیه می‌شود. سپس لایه نازک ۱ سانتی متری از سطح سنگ برداشته شده و این فرایند مجدداً تکرار شده است. این فرآیند برای هر نمونه ۹ بار تکرار شده است.

ماتریس‌های مربوط به عکس‌های متوالی به صورت ستونی مرتب شده و ارزشهای z مربوط به شماره عکس در مقاطع متوالی و ارزش چهارم مربوط به مقدار عددی رنگ به آن اضافه شده است. ماتریس نهایی در فایل اسکی استاندارد ذخیره و مدل سازی شده است. در این روش هر نقطه مجهول، ارزش مربوط به نزدیکترین نقطه معلوم را خواهد داشت. نهایتاً ۱۱ مدل برای ۱۱ نمونه سنگی تهیه شده است. مدل‌های به دست آمده توزیع کامل ارزش باند رنگی برای هر کانی را با مقیاس رنگی مربوطه نشان داده‌اند. بعد از محاسبه پارامترهای آماری برای ۵ کانی مورد نظر در تمام مدل‌ها، با فیلترگذاری، مقدار هر کانی مشخص شده است.

تصاویر در نور معمولی و نور قطبی گرفته می‌شوند. معمولاً در این روش‌ها، پس از انجام پیش‌پردازش بر روی تصاویر، مرز بین کانی‌ها با استفاده از روش‌های مختلف مشخص شده و سپس کانی‌های موجود در سنگ شناسایی و برجسب گذاری می‌شوند.

در پژوهش [۲]، تصاویر میکروسکوپی رقمی شده مقاطع نازک سنگ‌های گرانیت، دیوریت، آندزیت و آنکلاوهای میکرودیوریتی مورد پردازش قرار گرفتند. در این پژوهش، با اعمال روش‌های آشکارسازی لبه و فیلترهای مختلف بر روی مقاطع میکروسکوپی، پدیده‌هایی مثل تبلور مجدد، انحلال، رشد ناقص بلور، شکستگی‌های ریز و خوردگی خلیج مانند در تصاویر مقاطع نازک سنگ‌ها آشکارسازی شدند. همچنین پدیده‌هایی مانند تخلخل موجود در سنگ، سیالات درگیر و بسیاری از پدیده‌های پتروگرافی شناسایی شدند.

نوردان و همکاران از فیلتر میانه 3×3 برای کاهش نویز استفاده کرده‌اند [۳]. سپس از شبکه عصبی MLP با الگوریتم آموزشی بازگشتی استفاده شده است. سه پارامتر رنگ برای هر مقطع نازک در دو نور پلاریزه شده عمودی و افقی و در دو فرمت RGB و HSV استخراج شده است. شبکه با شش پارامتر ورودی با استفاده از مقادیر RGB و HSV به صورت جداگانه و به صورت همزمان با طول دوازده آموزش داده شده است.

ماریوس و همکاران تصمیم گرفتند که از تبدیل مورفولوژیکی در ترکیب با مقادیر استاندارد ریاضی و مقادیر آماری کانال‌های رنگی به عنوان ویژگی‌های مورد استفاده در تشخیص کانی‌ها استفاده کنند [۱]. آن‌ها یک فضای ویژگی ۱۳ تایی تعریف کرده‌اند. فضاهای رنگی RGB، CIELab، YIQ و HSV برای اهداف این پژوهش مورد استفاده قرار گرفته است. در نتیجه، چهار مجموعه جداگانه از ۱۳ پارامتر برای هر فضای رنگی بدست آمده است. پس از نرمال‌سازی داده‌ها، چهار روش مختلف شناسایی الگو در طبقه بندی نمونه‌های سنگ، شامل روش‌های نزدیک‌ترین همسایه، K-نزدیک‌ترین همسایه، نزدیک‌ترین حالت و محدوده کروی مطلوب، مورد استفاده قرار گرفته است.

در پژوهش ارائه شده در [۴] چندین تصویر برای به دست آوردن یک تصویر مینیمم گرفته شده است. یک تصویر مینیمم با استفاده از کمترین مقدار شدت هر پیکسل در بین تمام تصاویر، انتخاب شده است. پس از عملیات پیش‌پردازش، تصویر مینیمم به منظور تشخیص مواد معدنی مختلف، توسط الگوریتم JSEG قطعه بندی شده است. الگوریتم JSEG یک الگوریتم قطعه بندی بدون نظارت مبتنی بر رنگ و بافت است [۵]. این الگوریتم هر دو ویژگی بافت و رنگ را برای قطعه بندی در نظر می‌گیرد. بنابراین، یک منطقه معدنی دارای یک بافت با چندین رنگ به عنوان یک ناحیه واحد شناخته می‌شود. در نهایت پس از اصلاح ناحیه‌ها از طریق رابط GUI و برجسب گذاری هر ناحیه توسط کاربر، درصد هر ماده معدنی به طور خودکار توسط نرم افزار محاسبه می‌شود.

برای این کار بخش‌های دیگر غیر از کانی مورد نظر از مدل حذف شده است.

حسن پور و همکاران عکس‌های مورد استفاده را به روش پویا تهیه کرده‌اند [۹]. در روش پویا از یک سری عکس‌های پی در پی سطح خاکستری، که با تغییر بک‌نواخت زاویه مقطع میکروسکوپی نسبت به راستای نور قطبی شده تهیه شده‌اند، برای قطعه‌بندی استفاده می‌شود [۱۰]. قطعه‌بندی براساس تشخیص لبه صورت گرفته است. ابتدا در ArcGIS کیفیت هر عکس به طور جداگانه افزایش می‌یابد، سپس مرزبندی اولیه صورت می‌گیرد. سپس مرزهای ناخواسته و غیرواقعی حذف می‌شوند. در نهایت مرزهای به دست آمده رقمی شده تا در محیط نرم افزار ArcGIS قابل بررسی باشد. برای کاهش دخالت کاربر در مراحل یاد شده و عملیات مرزبندی به صورت خودکار، مدلی با استفاده از ArcGIS ModelBuilder طراحی شد. بیشتر توابع و فرآیندهای به کار رفته در این پژوهش، هر کدام در نرم افزارهای تحلیل عکس به صورت جداگانه وجود دارند. اما با اجتماع تمام این توابع در محیط نرم افزاری ArcGIS کاربر می‌تواند بدون مراجعه به چندین نرم افزار مرزبندی را با سرعت بیشتری انجام دهد. با انجام تمامی مراحل مرزبندی در یک نرم افزار به طور غیر مستقیم بر دقت نتایج نیز افزوده می‌شود.

باکلانوا و همکاران از الگوریتم تجزیه و تحلیل خوشه‌ای برای شناخت سنگ معدنی استفاده کرده‌اند [۱۱]. یک الگوریتم تصاویر رنگی سنگ‌ها را با استفاده از روش‌های تحلیل خوشه‌ای به صورت خودکار تقسیم‌بندی کرده است. در این پژوهش مشخص شد که فضای رنگی با استفاده از روش تجزیه و تحلیل خوشه‌ای، برای تقسیم سنگ‌ها دارای کارایی مناسب است. تصاویر در فضای رنگ HSV بررسی شده‌اند. رویکرد اصلی روش پیشنهادی شامل شناسایی خودکار کانی‌های مورد نظر در کل تصویر و همچنین تنظیم خودکار پارامترهای مورد نیاز بوده است.

بودنی و همکاران یک رویکرد شامل توصیف ساختاری مقاطع نازک و طبقه‌بندی سنگ‌ها براساس تصاویر بدست آمده از میکروسکوپ نوری قطبی ارائه کرده‌اند [۱۲]. ابتدا تصاویر مقاطع نازک با استفاده از روش آب‌پخشان با کاهش نویز قطعه‌بندی شده و مرزهای کانی‌ها به دست آمده است. طبقه‌بندی برای تعیین نوع سنگ با روش درخت تصمیم‌گیری و طبقه‌بندی ترکیبات معدنی ماسه سنگ‌ها با روش جنگل تصادفی آموزش داده شده است.

در [۱۳] یک روش برای به حداکثر رساندن میزان اطلاعاتی که می‌توان با ترکیب دستگاه‌های نوری و الگوریتم‌های پردازش تصویر، از مقاطع نازک استخراج کرد، شرح داده شده است. تاکید اصلی بر استفاده از الگوریتم رشد ناحیه است که حساسیت کمی به نویز دارد. همچنین مقایسه‌ای بین شناسایی خودکار کانی‌ها با روش دستی ارائه داده که نشان دهنده کاهش زمان و افزایش دقت است. علاوه بر این، از طریق رابط کاربری گرافیکی امکان تعامل مستقیم بین زمین‌شناس و نرم افزار را فراهم کرده است.

در [۱۴]، برای بدست آوردن تصویر لبه، از فیلتر لبه برای تصویر مقیاس خاکستری استفاده شده است. در این پژوهش از عملگر تشخیص لبه Canny استفاده شده است. سپس تصویر خاکستری و تصویر RGB به تعداد محدودی از سلول‌ها که یک ساختار شبکه تشکیل را می‌دهند، تقسیم شده‌اند. سلول‌ها به صورت جداگانه طبقه‌بندی شده و طبقه‌بندی کلی با استفاده از یک طرح رأی‌گیری اکثریت انجام شده است.

چنگ و همکاران ابتدا ویژگی‌های رنگی را در کانال رنگی RGB و HSV در تصویر مقاطع نازک سنگ استخراج کرده‌اند [۱۵]. برای استخراج ویژگی‌های بافت از ماتریس هم‌رخداد در سطح خاکستری استفاده شده است. برای طبقه‌بندی از الگوریتم خوشه‌بندی FCM استفاده شده است. این الگوریتم بر روی ویژگی‌های رنگی و ویژگی‌های بافت به صورت جدا مورد استفاده قرار گرفته است و در پایان، با ترکیب ویژگی‌های رنگی و بافت استخراج شده در فضای رنگی HSV، الگوریتم خوشه‌بندی FCM براساس ویژگی‌های بافت-رنگ وزن‌دار ارائه شده است.

در [۱۶]، یک الگوریتم خوشه بندی افزایشی-پویا برای تقسیم بندی مواد معدنی در بخشهای نازک حاوی مواد معدنی، توسعه یافته است. در الگوریتم خوشه بندی، نیازی به تعیین تعداد خوشه های موجود در تصاویر مقاطع نازک نیست و همچنین قادر به مقابله با تغییر رنگ و مرزهای نامشخص مواد معدنی است. علاوه بر این، در این تحقیق یک پایگاه داده باز (پایگاه داده های معدنی البرز) ایجاد و مورد استفاده قرار گرفته است.

با وجود این که یک سامانه تشخیص خودکار کانی می‌تواند کارایی بالایی در این حوزه داشته باشد و به طور چشم‌گیری باعث کاهش هزینه، افزایش دقت و کاهش زمان شناسایی شود، اما متأسفانه از سوی پژوهش‌گران، چندان مورد توجه قرار نگرفته و کارهای ارائه شده در این زمینه اندک است. وجود یک سامانه تشخیص کانی به صورت کاملاً خودکار می‌تواند به افرادی که در این زمینه فعالیت می‌کنند، کمک شایانی کند. چراکه تشخیص کانی‌ها به صورت چشمی توسط افراد متخصص انجام می‌شود که این کار نیازمند دانش، دقت و تجربه بالایی است و احتمال خطای انسانی در آن بالاست.

از سوی دیگر، با وجود این که در تمامی این روش‌ها از تصاویر مقاطع نازک سنگ برای تشخیص کانی‌ها استفاده می‌شود، تنها پایگاه داده ای در این حوزه که برای عموم قابل دسترس باشد؛ در دامنه اطلاعات نویسنده‌گان؛ پایگاه داده معرفی شده در [۱۶] است. بنابراین هر پژوهشی از پایگاه داده متفاوتی استفاده می‌کند که این امر کار مقایسه بین روش‌های مختلف را دشوار می‌کند. واضح است که وجود یک یا چند پایگاه داده استاندارد، انجام پژوهش‌های بیشتر را برای افراد علاقه‌مند به این حوزه که تخصص کافی در زمینه کانی‌شناسی ندارند را تسهیل می‌نماید. واضح است که حتی اگر پژوهش‌گر دارای تخصص کافی در زمینه کانی‌شناسی باشد، ایجاد یک پایگاه داده مناسب از تصاویر مقاطع نازک،

۱-۲- کانی

کانی ماده‌ای طبیعی و جامد است که ترکیب شیمیایی ثابتی دارد [۱۸]. برخی کانی‌ها از یک عنصر خالص و بسیاری از آن‌ها از دو یا چند عنصر تشکیل شده‌اند. علاوه بر این که ترکیب شیمیایی کانی‌ها با هم متفاوت است، شکل ظاهری، رنگ، اندازه و دیگر ویژگی‌های آن‌ها هم تفاوت دارند. برای شناسایی کانی‌ها خواص فیزیکی و خواص شیمیایی و هم‌چنین خواص نوری آن‌ها مورد بررسی قرار می‌گیرند. برخی از روش‌های شناسایی کانی‌ها عبارتند از: شکل بلور، سختی، چگالی، رنگ، مقاومت در برابر گرما، خاصیت مغناطیسی، چکش خواری، جذب آب، جلا، رنگ خاکه، رنگ شعله و طیف نوری. هم‌چنین برای شناسایی کانی‌ها از میکروسکوپ‌های پلاریزان، میکروسکوپ الکترونی و پرتو ایکس نیز بهره می‌گیرند.

۲-۲- مقاطع نازک

مقاطع نازک سنگ، طی یک سری فرآیندهای تخصصی به دست می‌آیند. در ابتدا از سنگ‌های مناطق مختلف، نمونه‌برداری انجام می‌شود. سپس این قطعات نمونه‌برداری شده، به آزمایشگاه سنگ شناسی انتقال داده و بخش‌هایی که هدف پژوهش است، از نمونه جدا می‌شود. ضخامت بخش‌های جدا شده طی عملیات تخصصی، به حدود ۳۰ میکرون کاهش داده می‌شود. به این بخش‌های نازک، مقاطع نازک سنگ گفته می‌شود که از آن به منظور مطالعه کانی‌ها استفاده خواهد شد [۱۹]. در شکل ۱ تصویری از یک مقطع نازک نشان داده شده است. همان‌گونه که در شکل قابل مشاهده است، مقطع نازک، بافت و توزیع مواد معدنی را آشکار می‌کند. در مقطع نازک با این میزان ضخامت، بیشتر مواد معدنی شفاف می‌شوند و به این ترتیب با استفاده از نور منتقل شده در زیر میکروسکوپ، مورد مطالعه قرار می‌گیرند.

کانی‌هایی که بیشترین فراوانی را در هر مقطع نازک داشته باشند، به عنوان کانی شاخص شناخته می‌شوند. ممکن است مقطع نازک شامل چند کانی شاخص باشد، در این صورت می‌توان آن مقطع را به نام کانی شاخصی که فراوانی بیشتری را در آن مقطع دارد، نام‌گذاری کرد.

۳-۲- خواص نوری کانی‌ها

کانی‌ها دارای خواص نوری مختلف و خاصی بوده و در نورهای مختلف دارای رنگ‌های متفاوتی هستند [۱۹]. به طور کلی، مقصود از خواص نوری کانی‌ها، خواص نوری آن‌ها در مقاطع نازک است. بیشتر کانی‌های موجود در مقاطع نازک در نور معمولی هم‌رنگ هستند. به همین دلیل، منشورهای نیکیلی ثابت و متحرک در میکروسکوپ‌های انکساری قطبی‌کننده نور تعبیه شده‌اند که نور را قطبی کرده و می‌توان کانی‌ها را در نور قطبی و در رنگ‌های تداخلی مشاهده کرد. به رنگ‌های دیده شده بر روی

فرآیندی سخت و وقت‌گیر است، زیرا علاوه بر ضبط تصاویر، تمامی کانی‌های موجود در تصاویر باید توسط متخصص کانی-شناسی، شناسایی و برچسب‌گذاری شوند. بنابراین ایجاد چنین پایگاه داده‌ای برای تحقیقات آتی مفید و ارزشمند خواهد بود.

یکی از اهداف این پژوهش ایجاد یک سامانه تشخیص خودکار کانی مبتنی بر پردازش تصویر است که توانایی شناسایی کانی‌های موجود در تصاویر مقاطع نازک را با سرعت و دقت بالایی داشته باشد. هم‌چنین در این پژوهش تلاش شده است با کمک متخصصین زمین‌شناسی، یک پایگاه داده استاندارد از تصاویر مقاطع نازک ایجاد شود. به صورتی که این پایگاه داده قابلیت استفاده در پژوهش‌های آینده را داشته باشد و دیگر پژوهشگران به آن دسترسی داشته باشند.

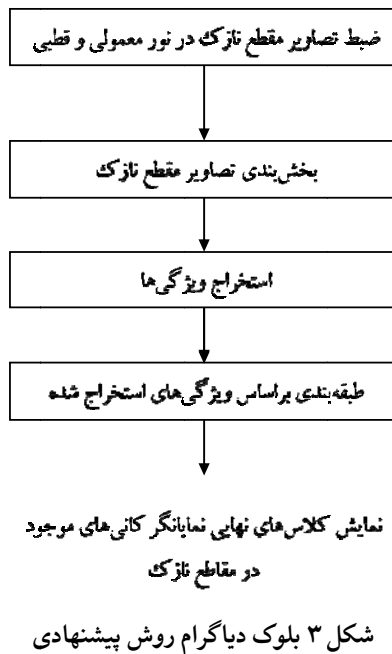
طبقه‌بندی سنگ نقش مهمی در بسیاری از زمینه‌های مربوط به علوم زمین‌شناسی دارد و از اجزای اساسی تجزیه و تحلیل زمین‌شناسی است. در حقیقت ادعای اصلی این تحقیق پیشنهاد یک سامانه کاربردی مبتنی بر پردازش تصویر جهت شناسایی خودکار کانی‌های موجود در تصاویر مقاطع نازک سنگ است. به طور خلاصه، مشارکت نویسندگان در این مقاله عبارتند از: (۱) پیشنهاد سیستمی کارا برای تشخیص خودکار کانی‌ها با دقتی قابل قبول (۲) در مقایسه با روش‌های پیشین از مجموعه ویژگی‌های موثرتر و متفاوتی مبتنی بر ترکیب رنگ و بافت استفاده شده است (۳) مجموعه داده مناسب با برچسب‌گذاری توسط کارشناسان خبره جمع‌آوری و مورد آزمایش قرار گرفته است (۴) شش طبقه‌بند مختلف شامل Linear Discriminant، Bagged Tree، Boosted Tree، Subspace Discriminant و Linear SVM و Weighted KNN ارزیابی و مورد بررسی و تجزیه و تحلیل قرار گرفته است.

در ادامه ساختار مقاله بدین صورت است: در بخش ۲ مفاهیم مربوط به کانی‌شناسی شرح داده شده است. در بخش ۳ روش پژوهش را بیان می‌کنیم و در بخش ۴ به ارزیابی روش پژوهش می‌پردازیم. در پایان نیز در بخش ۵ به نتیجه‌گیری و جمع‌بندی موضوع می‌پردازیم.


۲- اطلاعات کانی‌شناسی

سنگ‌ها از کانی‌های مختلفی تشکیل شده‌اند. در زمین‌شناسی، یکی از روش‌های مطالعه و بررسی کانی‌های موجود در سنگ‌ها، تجزیه و تحلیل مقاطع نازک جهت بررسی ترکیب مواد معدنی، بافت، ساختار و غیره است. برای تشخیص کانی‌های موجود در مقاطع نازک سنگ، این مقاطع با استفاده از میکروسکوپ‌های پلاریزان، در نور معمولی و قطبی مورد مطالعه قرار می‌گیرند [۱۷]. در ادامه این بخش، مفاهیم مربوط به کانی‌شناسی ارائه خواهد شد.


مختلفی داده می‌شود تا ناحیه‌های مختلف براساس کانی‌های موجود برچسب‌گذاری شوند. در ادامه، مراحل کلی روش پژوهشی به طور کامل تشریح خواهند شد.



مقطع نازک تحت نور قطبی رنگ‌های تداخلی گفته می‌شود که بسته به جهت برش مقطع نازک، نوع و خواص ذاتی کانی‌ها، متفاوت می‌باشد. بنابراین، به منظور شناسایی و طبقه‌بندی کانی‌ها در مقاطع نازک، علاوه بر بررسی آن‌ها تحت نور معمولی و رنگ معمولی، آن‌ها را تحت نور قطبی و رنگ‌های تداخلی نیز مورد بررسی قرار می‌دهند. در شکل ۲ مقطع نازک در نور قطبی نشان داده شده است.



شکل ۱ تصویر مقطع نازک سنگ زیر نور معمولی



شکل ۲ تصویر مقطع نازک سنگ زیر نور قطبی

۳-۱ ضبط تصاویر مقاطع نازک

در ابتدا یک پایگاه داده تخصصی و مناسب از کانی‌های متداول و قابل دسترس تهیه شد. تهیه تصویر از مقاطع نازک سنگ، توسط دوربین دیجیتال نصب شده بر روی میکروسکوپ پلاریزان در آزمایشگاه سنگ‌شناسی انجام شد. همانطور که پیش از این گفته شد، کانی‌ها در زیر نور معمولی بی‌رنگ هستند و تشخیص آن‌ها مشکل است، اما معمولاً در زیر نور قطبی، رنگ‌های متفاوتی دارند. بنابراین، تصاویر مقطع نازک، در نور معمولی و هم‌چنین نور قطبی، با وضوح 1200×1600 پیکسل و با فرمت JPEG گرفته شد.

۳-۲ قطعه‌بندی

با استفاده از قطعه‌بندی تصویر می‌توان مرز کانی‌ها را در مقاطع نازک سنگ، شناسایی کرد. روش‌های قطعه‌بندی، زمان لازم برای کمی‌سازی و استخراج ویژگی‌ها را کوتاه می‌کنند و همچنین به نتایج دقیق‌تر، منتهی می‌شوند. در پژوهش ارائه شده در [۴] چندین الگوریتم قطعه‌بندی مختلف بررسی شده است. از بین این الگوریتم‌ها، الگوریتم JSEG دارای بهترین نتایج بوده است و هر دو ویژگی بافت و رنگ را برای قطعه‌بندی در نظر می‌گیرد. بنابراین، یک کانی دارای یک بافت با چندین رنگ به عنوان یک ناحیه شناخته می‌شود. بر این مبنا در این پژوهش برای قطعه‌بندی تصاویر، از JSEG استفاده شده است.

الگوریتم JSEG یک الگوریتم قطعه‌بندی بدون نظارت، مبتنی بر رنگ و بافت است [۲۰]. در این روش تصاویر رنگی با نواحی همگن توسط یک الگوریتم برای ایجاد خوشه‌هایی در فضای

۳ روش پیشنهادی

روش پیشنهاد شده در این پژوهش بر پایه ویژگی‌های رنگ و ویژگی‌های بافت کانی‌ها می‌باشد. مراحل اصلی روش ارائه شده شامل جمع‌آوری تصاویر از مقاطع نازک سنگ، قطعه‌بندی تصاویر مقاطع نازک، استخراج ویژگی‌های رنگ و استخراج ویژگی‌های بافت و در نهایت طبقه‌بندی با استفاده از طبقه‌بندی‌های مختلف است. بلوک دیاگرام این مراحل در شکل ۳ نشان داده شده است. تصاویر مورد استفاده در این پژوهش در آزمایشگاه سنگ‌شناسی، با استفاده از میکروسکوپ پلاریزان گرفته شده است. این تصاویر در دو نور معمولی و قطبی گرفته شده‌اند. این تصاویر به صورت ورودی به مرحله قطعه‌بندی فرستاده می‌شوند. در مرحله قطعه‌بندی تصویر، از الگوریتم‌هایی برای قطعه‌بندی تصویر به نواحی مختلف استفاده می‌شود. در مرحله استخراج ویژگی‌ها، چندین ویژگی آماری مبتنی بر بافت و رنگ از ناحیه‌های مختلف تصویر استخراج می‌شود. در پایان، داده‌ها به طبقه‌بندی‌های

ترین مقیاس، که با مقیاس ۱ مشخص می‌شود، اندازه پنجره 9×9 است. برای مقیاس بزرگ‌تر بعدی، اندازه پنجره دو برابر مقیاس قبلی است. تصاویر J، از طریق فرآیند رشد ناحیه، برای قطعه‌بندی استفاده می‌شوند. پیش از رشد ناحیه، چند نقطه رشد اولیه تعیین می‌شود. سپس، نقاط رشد با بررسی پیکسل‌های همسایه و تعیین این‌که آیا آن‌ها باید به منطقه اضافه شوند یا نه، رشد می‌کنند [۲۰].

خروجی الگوریتم JSEG ماتریسی با نام r است که مشخص‌کننده ناحیه‌های موجود در تصویر اصلی است. ابعاد این ماتریس برابر با تصویر اصلی است و مقادیر آن از ۱ تا n است که n تعداد نواحی تصویر است. چنانچه الگوریتم JSEG بخشی از تصویر را به عنوان ناحیه i ام قطعه‌بندی کرده باشد، پیکسل‌های نظیر این ناحیه در ماتریس r با عدد i مقداردهی می‌شوند.

۳-۲ استخراج ویژگی

استخراج ویژگی یک بخش مهم در سامانه‌های شناسایی محسوب می‌شود. به گونه‌ای که اگر بخش استخراج ویژگی ضعیف باشد، در نهایت الگوریتم‌های طبقه‌بندی عملکرد رضایت‌بخشی نخواهند داشت. پس از قطعه‌بندی تصویر، باید از هر ناحیه موجود در تصویر، مجموعه‌ای از ویژگی‌ها استخراج شود. در این پژوهش در کل تعداد ۲۰۶ ویژگی برای هر ناحیه در تصویر مشخص شده است که این ویژگی‌ها با استفاده از تصویر اصلی در نور معمولی و نور قطبی و همچنین ماتریس r محاسبه می‌شود. ویژگی‌های استخراج شده شامل ویژگی‌های مربوط به رنگ و بافت در تصاویر گرفته شده در نور قطبی و نور معمولی است. همچنین این ویژگی‌ها در دو مدل رنگی RGB و HSI استخراج شده‌اند.

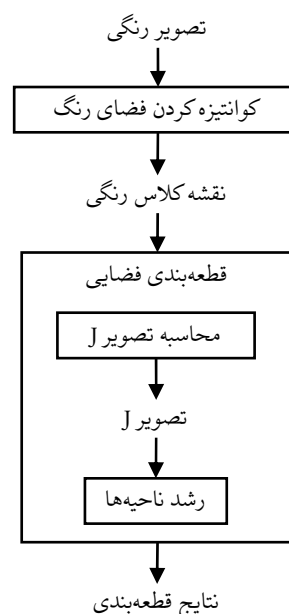
ویژگی‌های آماری کانال‌های رنگی R، G و B مجموعاً شامل ۱۶ ویژگی مختلف است؛ که شامل میانه، مینیمم، ماکسیمم، واریانس و میانگین سه کانال رنگی به صورت جداگانه و همچنین میانگین کل سه کانال است. ویژگی‌های آماری کانال‌های رنگی H، S و I نیز شامل ۱۶ ویژگی است و دقیقاً مشابه ویژگی‌های استخراج شده در کانال رنگی RGB است. ۶ توصیف‌گر مبتنی بر بافت نیز در فضای رنگی RGB و HSI در نظر گرفته شده است که عبارت‌اند از میانگین، انحراف استاندارد، صافی، گشتاور سوم، یکنواختی و آنتروپی.

همچنین عملگر LBP توانایی بالایی در بازنمایی بافت دارد [۲۱]. این عملگر رابطه بین پیکسل مرکزی و پیکسل‌های همسایه را توصیف می‌کند. بر همین اساس ۵۹ ویژگی بافت مبتنی بر LBP برای هر ناحیه استخراج می‌شود. در نهایت برای هر ناحیه تعداد ۱۰۳ ویژگی مبتنی بر رنگ و بافت استخراج می‌شود. در این پژوهش از تصاویر مقاطع نازک در دو نور معمولی و نور قطبی استفاده می‌شود، بنابراین در مجموع تعداد ۲۰۶ ویژگی برای هر ناحیه استخراج می‌شود.

رنگی، قطعه‌بندی می‌شوند. یک روش برای قطعه‌بندی تصاویر دارای بافت، در نظر گرفتن ترتیب خاص پیکسل‌ها با استفاده از تکنیک گسترش ناحیه است. جایی که یک حالت همگنی توسط پیکسل‌هایی تعریف می‌شود که در نواحی قطعه‌بندی، گروه بندی شده‌اند. علاوه بر این به منظور قطعه‌بندی تصاویر رنگی، مقیاس‌های متفاوت تصویر نیز باید در نظر گرفته شود.

الگوریتم JSEG فرضیات زیر را برای تصویر در نظر می‌گیرد: الف) تصویر شامل نواحی بافت-رنگ همگن است. ب) اطلاعات رنگی توسط پارامترهای کمی نشان داده می‌شوند.

پ) رنگ‌های بین دو ناحیه همسایه قابل تشخیص است. JSEG هر دو ویژگی بافت و رنگ را برای قطعه‌بندی در نظر می‌گیرد. بنابراین، یک کانی دارای یک بافت با چندین رنگ به عنوان یک ناحیه واحد شناخته می‌شود. این یک نکته مهم برای قطعه‌بندی تصاویر مقاطع نازک است، زیرا الگوریتم‌های قطعه‌بندی بر اساس رنگ، به طور کلی هر رنگ متفاوت را به عنوان یک ناحیه متفاوت در نظر می‌گیرند. فلوجارت الگوریتم JSEG، در شکل ۴ نشان داده شده است.



شکل ۴ مراحل الگوریتم قطعه‌بندی JSEG [۲۰]

الگوریتم JSEG، شامل دو مرحله کوانتیزه کردن فضای رنگی و قطعه‌بندی فضایی است. در مرحله اول، فضای رنگی تصویر، به چند کلاس نماینده، کوانتیزه می‌شود. سپس، با جایگزینی هر پیکسل تصویر با برجسب کلاس رنگ کوانتیزه مربوطه، یک کلاس نقشه ساخته می‌شود. این کلاس‌های نقشه، برای تمایز مناطق در تصویر استفاده می‌شوند. در مرحله دوم، مقادیر image-J-ها که معیاری برای قطعه‌بندی هستند، براساس نقشه کلاس، برای هر پیکسل بر روی پنجره‌هایی با مرکزیت پیکسل مربوطه محاسبه می‌شوند و به این ترتیب، تصاویر J، شکل می‌گیرند. معمولاً برای قطعه‌بندی از ۴ مقیاس برای پنجره استفاده می‌شود. در کوچک-

$$J(w) = \frac{w^T S_b w}{w^T S_w w} \quad (4)$$

که بردار w راستای افتراق بهینه فیشر است. می‌توان نشان داد که بردار w که مقدار $J(w)$ را بیشینه می‌کند برابر است با محاسبه بردارهای ویژه مسئله مقدار ویژه:

$$S_b w = \lambda S_w w \quad (5)$$

که مقدار ویژه λ نشان دهنده میزان تفکیک کلی بین کلاس-هاست. مجموعه‌ای از بردارهای ویژه S_w و S_b متناظر با m بزرگ-ترین بردار ویژه غیر صفر قابل محاسبه است. باید در نظر داشت که حداکثر $C - 1$ بردار ویژه وجود دارد. بنابراین تعداد المان‌های افتراق به تعداد کلاس‌ها بستگی دارد.

Bagging و Boosting پرکاربردترین الگوریتم‌های یادگیری ترکیبی هستند که به کارگیری آن‌ها در مسائل مختلف طبقه‌بندی منجر به بهبودهای چشمگیر شده است. هدف اصلی رویکرد ترکیبی بهبود کارایی طبقه‌بندی‌های مجزا از طریق ترکیب آن‌ها برای بدست آوردن یک طبقه‌بند جدید است، به طوری که کارایی طبقه‌بند جدید از همه طبقه‌بندی‌های مجزا بهتر باشد. بنابراین ایده اصلی، ساخت چندین طبقه‌بند مجزا از داده‌های اولیه و سپس ترکیب خروجی آن‌ها برای طبقه‌بندی داده‌های جدید و ناشناخته است. این ایده رفتار طبیعی انسان را دنبال می‌کند که قبل از گرفتن یک تصمیم مهم تمایل دارد که نظرهای مختلف را بررسی کند. انگیزه اصلی ترکیب طبقه‌بندی‌ها، بهبود توانایی تعمیم آن‌هاست: هر طبقه‌بند دارای خطای طبقه‌بندی است، اما چون این خطاها متفاوت هستند (بر روی مجموعه داده‌های متفاوت آموزش داده شده‌اند یا رفتارهای متفاوتی بر روی بخش‌های مختلف فضای داده ورودی دارند). نمونه‌هایی که اشتباه طبقه‌بندی می‌شوند لزوماً یکسان نیستند. طبقه‌بندی‌های مبتنی بر ترکیب معمولاً به ترکیبی از طبقه‌بندی‌ها ارجاع داده می‌شود که نوعی از طبقه‌بند پایه یکسان با تفاوت جزئی هستند. نکته اصلی در مورد طبقه‌بندی‌های پایه این است که باید یادگیرنده‌های ضعیف باشند. یک یادگیرنده، ضعیف نامیده می‌شود اگر تغییرات کوچک در داده‌ها باعث ایجاد تغییرات بزرگ در مدل شود. به همین دلیل است که معمولاً بهترین طبقه‌بندی‌های پایه به کار رفته معمولاً الگوریتم‌های درختی هستند.

بگینگ مخفف عبارت Bootstrap aggregating (Bagging) است که توسط برایمن برای ساخت ترکیب‌ها و بهبود دقت طبقه‌بندی معرفی شد [۲۳]. روش بگینگ شامل آموزش طبقه‌بندی‌های مختلف با نسخه‌های bootstrapped شده مجموعه داده آموزشی اولیه است. یعنی، برای هر طبقه‌بند یک مجموعه داده جدید از طریق انتخاب تصادفی (با جایگزینی) نمونه‌هایی از مجموعه داده اولیه (معمولاً با حفظ اندازه مجموعه داده اولیه) ایجاد می‌شود. بنابراین، تنوع از طریق نمونه‌برداری مجدد و به کارگیری زیرمجموعه داده‌های متفاوت به دست می‌آید. در پایان، زمانی که یک نمونه ناشناخته به هر طبقه‌بند مجزا ارائه می‌شود، رای‌گیری

لازم به ذکر است که برای بررسی تاثیر انتخاب ویژگی بر روی نتایج طبقه‌بندی روش‌های PCA و ICA بر روی داده‌ها اعمال شد. نتایج طبقه‌بندی بعد از اعمال PCA و ICA نشان داد که اعمال آنها تاثیر مثبتی بر روی نتایج نداشته و باعث کاهش میزان دقت طبقه‌بندی شده است. لذا به این نتیجه رسیدیم که در این موضوع خاص برای طبقه‌بندی با دقت مناسب باید از تمام ویژگی‌ها استفاده کرد.

۳-۴ طبقه‌بندی

طبقه‌بندی علمی است که براساس داده‌های قبلی که دارای برجسب هستند، مدلی برای پیش‌بینی برجسب داده‌های جدید می‌سازد و اساس آن داده‌های جمع‌آوری شده از اعمال گذشته است. اعمالی که براساس دانش فرد خبره برجسب گذاری شده‌اند. به بیان کلی، طبقه‌بندی فرآیند قرار دادن نمونه‌های جدید در طبقات مختلف براساس داده‌های قدیمی است و برای این‌کار به یک مدل طبقه‌بند یا الگوریتم طبقه‌بند نیاز است. در این پژوهش کارایی ۵ طبقه‌بند Bagged Tree، Boosted Tree، Linear Discriminant، Weighted KNN و Linear SVM براساس معیارهای مختلف مورد ارزیابی قرار گرفته است.

الگوریتم آنالیز تشخیص خطی (Linear Discriminant) یکی از رایج‌ترین روش‌های کاهش ابعاد است که به صورت گسترده در طبقه‌بندی به کار می‌رود [۲۲]. این روش راستاهای نگاشتی را جستجو می‌کند که نقاط داده کلاس‌های مختلف تا حد امکان از یکدیگر دور شوند، درحالی که نقاط داده یک کلاس تا حد امکان نزدیک یکدیگر نگه داشته شوند.

فرض کنید X_i با ابعاد $N \times J$ ماتریس داده متناظر با نمونه‌های کلاس i باشد، به طوری که سطرها مشاهدات و ستون‌ها متغیرها باشند. x_i میانگین نمونه با ابعاد J برای کلاس i است. ماتریس پراکندگی درون کلاسی برای کلاس i به صورت زیر محاسبه می‌شود:

$$S_i = \sum_{x_i \in X_i} (x_i - \bar{x}_i)(x_i - \bar{x}_i)^T \quad (1)$$

بنابراین ماتریس پراکندگی درون کلاسی برای همه کلاس‌ها برابر است با:

$$S_w = \sum_{i=1}^C S_i \quad (2)$$

که C تعداد کلاس‌هاست.

ماتریس پراکندگی بین کلاسی به صورت زیر محاسبه می‌شود:

$$S_b = \sum_{x_i \in X_i} n_i (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T \quad (3)$$

که n_i تعداد مشاهدات در کلاس i و \bar{x} بردار میانگین کلی برای همه نمونه‌هاست.

المان‌های آنالیز تشخیص خطی با بیشینه سازی معیار فیشر (نرخ پراکندگی بین کلاسی به پراکندگی درون کلاسی) به دست می‌آید:

هستند تمرکز می‌کند. میزان این تمرکز توسط یک وزن اندازه‌گیری می‌شود، که در ابتدا برای همه نمونه‌ها یکسان است. بعد از هر تکرار، وزن نمونه‌هایی که به اشتباه طبقه‌بندی شده‌اند افزایش می‌یابد. از سوی دیگر، وزن نمونه‌هایی که به درستی طبقه‌بندی شده‌اند، کاهش می‌یابد. علاوه بر این، وزن دیگری هم به هر طبقه‌بند براساس دقت کلی آن اختصاص داده می‌شود که بعداً در مرحله آزمایش به کار می‌رود. به طوری که به طبقه‌بندهای با دقت بیشتر اعتبار بیشتری داده می‌شود. در پایان، زمانی که یک نمونه جدید ارسال شد، از هر طبقه‌بند یک رأی وزن‌دار به دست می‌آید و برچسب کلاس براساس اکثریت انتخاب می‌شود.

SVM یک روش طبقه‌بندی با نظارت بر مبنای نظریه یادگیری آماری است. ایده اصلی در این طبقه‌بند، یافتن ابرصفحه بهینه‌ای به عنوان سطح تصمیم‌گیری است به گونه‌ای که حاشیه بین دو کلاس را بیشینه کند. در صورتی که داده‌ها به صورت خطی جداناپذیر باشند، داده‌ها با کرنلی غیرخطی به فضای با ابعاد بالاتر منتقل می‌شود و ابرصفحه بهینه در آن فضا، تعیین می‌شود [۲۴].

فرض کنید هر داده آموزشی با (x_i, y_i) نشان داده می‌شود که x_i بردار ویژگی n بعدی و $y_i \in \{-1, 1\}$ برچسب آن است. ابرصفحه‌ای که دو کلاس را با بیشترین حاشیه از هم جدا کند، با معادله (۶) بیان می‌شود.

$$w^T \varphi(x) + b = 0 \quad (۶)$$

در این معادله بردار وزن w ، برداری عمود بر ابرصفحه، b بردار بایاس است که برای اندازه‌گیری فاصله مبدا تا ابرصفحه استفاده می‌شود و φ کرنلی برای انتقال داده به فضای با ابعاد بالاتر است. بیشینه کردن حاشیه بین دو کلاس معادل کمینه کردن اندازه w است که منجر به حل مسئله کمینه‌سازی مقید می‌شود.

$$\text{Min} \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^k \xi_i \right) \quad (۷)$$

پارامتر C ، پارامتر تنظیم در SVM است و برای در نظر گرفتن نویز در داده‌ها و تداخل بین داده‌های آموزشی، از متغیر $\xi_i > 0$ استفاده می‌شود. وجود قید ضمانت می‌کند که داده‌ای در حاشیه قرار نمی‌گیرد. هرچند برای جلوگیری از بیش تطابق نمودن به داده‌های نویزی، این قید با متغیرهای ξ_i نرم شده است.

سطح تصمیم‌گیری بهینه با حل معادله (۷) بر مبنای روش لاگرانژ طبق معادله (۸) محاسبه می‌شود.

$$f(x) = \sum_{x_i \in SV} y_i \alpha_i \varphi(x_i) \cdot \varphi(x) + b \quad (۸)$$

در این رابطه α_i ضریب لاگرانژ است که در پروسه بهینه‌سازی محاسبه می‌شود. SV بردارهای پشتیبان هستند که ضریب لاگرانژ متناظر آن‌ها بزرگ‌تر از صفر است. این داده‌های آموزشی، نزدیک‌ترین نمونه‌ها به ابرصفحه هستند. همان‌طور که در رابطه (۸) مشاهده می‌شود، تنها بردارهای پشتیبان هستند که در مرحله آموزش شرکت می‌کنند. در نتیجه ماشین‌های بردار پشتیبان نیاز به نمونه آموزشی زیاد ندارند. در معادله (۸)، ضرب داخلی

اکثریت یا وزن‌دار برای طبقه‌بندی به کار می‌رود. الگوریتم ۱ شبه کد برای بگینگ را نشان می‌دهد.

Algorithm 1 Bagging

Input: S : Training set; T : Number of iterations;
 n : Bootstrap size; I : Weak learner

Output: Bagged classifier: $H(x) = \text{sign} \left(\sum_{t=1}^T h_t(x) \right)$

where $h_t \in [-1, 1]$ are the induced classifiers

- 1: **for** $t = 1$ to T **do**
- 2: $S_t \leftarrow \text{RandomSampleReplacement}(n, S)$
- 3: $h_t \leftarrow I(S_t)$
- 4: **end for**

شکل ۵ الگوریتم بگینگ [۲۳]

روش بوستینگ (هم‌چنین به عنوان ARCing هم شناخته می‌شود) در سال ۱۹۹۰ توسط Schapire معرفی شد [۲۳]. Schapire ثابت کرد که یک یادگیرنده ضعیف (که کمی بهتر از حدس زدن تصادفی است) می‌تواند به یک یادگیرنده قوی تبدیل شود. Adaboost معروف‌ترین الگوریتم در این خانواده است که اولین رویکرد کاربردی بوستینگ بود.

Algorithm 2 AdaBoost

Input: Training set $S = \{x_i, y_i\}, i = 1, \dots, N$; and $y_i \in \{-1, +1\}$;
 T : Number of iterations; I : Weak learner

Output: Boosted classifier: $H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right)$

where h_t, α_t are the induced classifiers ($h_t \in \{-1, +1\}$) and their assigned weights, respectively

- 1: $D_1(i) \leftarrow 1/N$ for $i = 1, \dots, N$
- 2: **for** $t = 1$ to T **do**
- 3: $h_t \leftarrow I(S, D_t)$
- 4: $\alpha_t \leftarrow \sum_{i, y_i \neq h_t(x_i)} D_t(i)$
- 5: **if** $\alpha_t > 0.5$ **then**
- 6: $T \leftarrow t - 1$
- 7: **return**
- 8: **end if**
- 9: $\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \epsilon_t}{\epsilon_t} \right)$
- 10: $D_{t+1}(i) = D_t(i) \cdot e^{-\alpha_t h_t(x_i) y_i}$ for $i = 1, \dots, N$
- 11: Normalize D_{t+1} to be a proper distribution
- 12: **end for**

شکل ۶ الگوریتم بوستینگ [۲۳]

Adaboost از کل مجموعه داده برای آموزش هر طبقه‌بند به صورت سری استفاده می‌کند، اما بعد از هر تکرار، بر روی نمونه‌های سخت تمرکز می‌کند، با این هدف که نمونه‌هایی را که به صورت اشتباه طبقه‌بندی شده بودند، در تکرار بعدی درست طبقه‌بندی کند. بنابراین، بر روی نمونه‌هایی که برای طبقه‌بندی سخت‌تر

ساده، این الگوریتم از توان طبقه‌بندی مناسبی برخوردار است. در طبقه‌بندی با توجه به مقدار مشخص شده برای k ، به محاسبه فاصله نقطه‌ای که می‌خواهیم برچسب آن را مشخص کنیم با نزدیک‌ترین نقاط می‌پردازیم و با توجه به تعداد رای حداکثری نقاط همسایه، در رابطه با برچسب نقطه مورد نظر تصمیم‌گیری می‌کنیم. برای محاسبه این فاصله می‌توان از روش‌های مختلفی استفاده کرد که یکی از مطرح‌ترین این روش‌ها، فاصله اقلیدسی است که به صورت معادله ۱۱ محاسبه می‌شود.

$$d(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

$$X = (x_1, x_2, \dots, x_n) \quad (11)$$

$$Y = (y_1, y_2, \dots, y_n)$$

۴ نتایج تجربی

در مرحله ارزیابی روش پیشنهادی، هشتاد درصد داده‌ها در مرحله آموزش و بیست درصد باقی‌مانده در مرحله آزمایش روش پیشنهادی مورد استفاده قرار گرفت. اجراها بر روی لپ‌تاپ با پردازشگر Core i5-6200U و حافظه 8-GB RAM انجام شده است. همچنین برای هر طبقه بند اجراها ۱۰ بار تکرار شده است. چون در هر بار اجرا ممکن است طبقه بند نتایج متفاوتی ارائه دهد، از Dunn index [۲۶] برای انتخاب بهترین نتایج ارزیابی از بین ۱۰ اجرا، استفاده شده است. کانی‌های بررسی شده در این پژوهش شامل سه نوع کانی به نام‌های کوارتز، هومبلند و پلاژیوکلاز هستند که به صورت کلاس‌های A، B و C برچسب گذاری شدند.

برای ارزیابی و مقایسه روش‌های پیشنهادی، اصلی‌ترین شاخص، دقت طبقه‌بندی است. برای اندازه‌گیری دقت در مسائل طبقه‌بندی معیارهای مختلفی مطرح شده‌اند. در این پژوهش برای بررسی جنبه‌های مختلف طبقه‌بندها و همچنین بالا بردن توان مقایسه بین آنها، از ۳ معیار زیر استفاده شده است. لازم به ذکر است که با توجه به ساختار بعضی از روش‌های طبقه‌بندی در هر بار استفاده نتیجه بندی متفاوت خواهد شد و نیاز است با استفاده از روش‌های ارزیابی مانند Dunn index [۲۶] بهترین طبقه بندی بعد از تعداد مشخصی اجرای روش تعیین گردد تا نتایج روش‌های مختلف طبقه‌بندی قابل قیاس شود. لذا از این معیار نیز در استخراج نتایج استفاده شده است.

Accuracy: این معیار رایج‌ترین معیار مورد استفاده در ارزیابی طبقه‌بندی است که به صورت نسبت تعداد ناحیه‌های صحیح طبقه‌بندی شده تقسیم بر تعداد کل ناحیه‌ها تعریف شده است. نحوه محاسبه آن به صورت زیر است:

$$Accuracy = \frac{\text{correctly predicted class}}{\text{total testing class}} \times 100\% \quad (12)$$

بین دو کرنل نگاشت شده، می‌تواند با کرنل آن دو نمونه محاسبه گردد. از پرکاربردترین کرنل‌ها، کرنل گوسین و پلی‌نومیل هستند که با روابط (۹) و (۱۰) تعریف می‌شوند.

$$\varphi(x_i, x) = e^{\left(\frac{\|x_i - x\|}{2\sigma^2}\right)} \quad (9)$$

$$\varphi(x_i, x) = (x_i \cdot x + 1)^d \quad (10)$$

در این روابط، σ پرامتر کرنل گوسین و d متغیر پلی‌نومیل می‌باشد.

الگوریتم پایه SVM برای طبقه‌بندی باینری توسعه داده شده است. از آنجایی که در بیشتر کاربردها، بیش از دو کلاس وجود دارد، الگوریتم‌های مختلفی برای حل مسئله چندکلاسه به کار گرفته شده است. یک روش مرسوم در این زمینه، تجزیه مسئله چندکلاسه به مسئله ای با چندین طبقه‌بند باینری است. الگوریتم‌های «یک در مقابل یک» و «یک در مقابل مابقی»، دو الگوریتم پرکاربرد در این زمینه هستند.

در روش یک در مقابل یک، برای هر زوج کلاس ممکن از یک ماشین بردار پشتیبان باینری استفاده می‌شود. به این ترتیب برای M کلاس، $M(M-1)/2$ طبقه‌بند ماشین بردار پشتیبان باینری نیاز داریم. در نهایت همه ماشین‌های بردار پشتیبان باینری با روش رای گیری حداکثر ادغام می‌شوند.

روش یک در مقابل مابقی روش مرسوم دیگر است که در آن هر ماشین بردار پشتیبان باینری، داده‌های یک کلاس را از داده‌های کلاس‌های دیگر جدا می‌کند. در این روش، برای M کلاس، M طبقه‌بند باینری خواهیم داشت. پس از طبقه‌بندی داده جدید با M طبقه‌بند، داده به کلاسی که بیشترین نتیجه مثبت را داشته باشد، نسبت داده می‌شود.

KNN یکی از روش‌های داده‌کاوی است که هدف اصلی آن طبقه‌بندی و تخمین ویژگی‌های یک سری داده‌های مجهول با توجه به بیشترین شباهت این داده‌ها با داده‌های معلومی است که در همسایگی آنها قرار دارند. در مسائل واقعی طبقه‌بند KNN با یک مقدار k بهینه، می‌تواند به کارایی قابل توجهی دست یابد و نتایج قابل قیاسی با روش‌های با کارایی مناسب داشته باشد [۲۵]. در این الگوریتم برای تعیین برچسب یک نمونه جدید از یک مجموعه، از نمونه‌های جمع‌آوری شده با برچسب مشخص استفاده می‌شود که آن را مجموعه داده آموزشی می‌نامند. هر نمونه آموزشی، یک الگو نامیده می‌شود. برچسب نمونه جدید متناسب با برچسب k نزدیکترین الگوی آن تعیین می‌شود. برچسبی که بیشترین تکرار را در الگوهای همسایه دارد، به عنوان برچسب نمونه جدید انتخاب می‌شود. بنابراین، نتیجه طبقه‌بند KNN کاملاً به برچسب الگوها و معیار فاصله جهت تعیین نزدیکترین الگوها وابسته است. در این الگوریتم همه الگوها نگهداری می‌شوند و پیشینی برچسب نمونه جدید نیازمند محاسبه فاصله آن تا تمامی الگوها است که موجب افزایش بار محاسباتی و کندی الگوریتم در زمان طبقه‌بندی می‌شود. از سوی دیگر علیرغم پیاده‌سازی بسیار

قبل گفته شد، الگوریتم JSEG از ۴ مقیاس مختلف برای قطعه-بندی استفاده می‌کند. در این پژوهش از مقیاس ۲ الگوریتم برای قطعه‌بندی استفاده شد. انتخاب این مقیاس از طریق ارزیابی و بررسی خروجی الگوریتم در چهار مقیاس مختلف، توسط متخصصین زمین شناسی و کانی شناسی، انجام شد. نمونه‌ای از قطعه‌بندی الگوریتم JSEG در ۴ مقیاس بر روی یک مقطع نازک در شکل ۷ نشان داده شده است. همان‌گونه که در شکل قابل مشاهده است، قطعه‌بندی تصویر در مقیاس ۲، نسبت به سایر مقیاس‌ها دارای دقت بهتری است.

با استفاده از تصویر در نور معمولی و نور قطبی و همچنین ماتریس ۲، تعداد ۲۰۶ ویژگی که قبلاً معرفی شد، برای هر ناحیه در تصویر استخراج شد. ویژگی‌های استخراج شده شامل ویژگی‌های مربوط به رنگ و بافت در تصاویر گرفته شده در نور قطبی و نور معمولی است. همچنین این ویژگی‌ها در دو مقیاس RGB و HSI استخراج شدند.

ویژگی‌های استخراج شده به عنوان ورودی به ۶ طبقه‌بند مختلف داده شدند. خروجی هر یک از این طبقه‌بندها شامل کلاس پیش‌بینی شده برای کانی‌های موجود در مقطع نازک است. در نهایت کارایی هر یک از این طبقه‌بندها با استفاده از معیارهای مختلف ارزیابی شدند. اجراها ۱۰ بار تکرار شده و مقادیر Dunn index برای هر طبقه‌بند محاسبه شده است. از بین این ۶ طبقه‌بند، تنها طبقه‌بند Bagged Tree دارای مقادیر متفاوت Dunn index بود. بنابراین برای این طبقه‌بند نتایج ارزیابی بالاترین مقدار Dunn index به عنوان نتیجه نهایی انتخاب گردید. نتایج ارزیابی براساس سه معیار MAE، RMSE و Accuracy برای طبقه‌بندهای مختلف در جدول ۱ نشان داده شده است.

جدول ۱ نتایج ارزیابی طبقه‌بندهای مختلف

	MAE	RMSE	Accuracy
Linear Discriminant	۰/۰۷	۰/۲۶	۹۳/۸
Subspace Discriminant	۰/۰۶	۰/۲۵	۹۳/۷۷
Boosted Tree	۰/۰۷	۰/۲۷	۹۳/۲۴
Bagged Tree	۰/۰۴	۰/۲۱	۹۵/۵۲
Linear SVM	۰/۰۶	۰/۲۴	۹۴/۳۵
Weighted KNN	۰/۰۵	۰/۲۳	۹۴/۷۴

همان‌طور که در جدول ۱ مشاهده می‌شود، طبقه‌بند Bagged Tree دارای بهترین کارایی می‌باشد. این طبقه‌بند دارای بالاترین دقت به میزان ۹۵/۵۲ و کمترین میزان خطای MAE برابر با ۰/۰۴ و خطای RMSE برابر با ۰/۲۱ می‌باشد. از بین این طبقه‌بندها پایین‌ترین کارایی مربوط به Boosted Tree است. با این وجود هر ۶ طبقه‌بند دارای دقت قابل قبولی بوده و همگی دارای دقت بالای ۹۳٪ می‌باشند. همچنین میزان خطای MAE هر ۶ روش، کمتر از ۰/۰۷ و میزان خطای RMSE آن‌ها کمتر از ۰/۲۶ است که میزان خطای کاملاً قابل قبولی است. به منظور مقایسه

RMSE (Root Mean Square Error): خطای جذر میانگین مربعات، تفاوت میان مقدار پیش‌بینی شده توسط مدل و مقدار واقعی می‌باشد که به صورت زیر محاسبه می‌شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{\text{pred}} - y_{\text{ref}})^2}{n}} \quad (13)$$

MAE: میانگین خطای مطلق (Mean Absolute Error) میانگین قدر مطلق اختلاف بین مقدار پیش‌بینی شده و مقدار واقعی است و به صورت زیر محاسبه می‌شود:


$$MAE = \frac{\sum_{i=1}^n |y_{\text{pred}} - y_{\text{ref}}|}{n} \quad (14)$$

در معادلات (۱۳) و (۱۴)، مقدار n برابر با تعداد کل نواحی است. پارامترهای y_{pred} و y_{ref} به ترتیب نشان‌دهنده کلاس‌های پیش‌بینی شده و کلاس‌های واقعی برچسب‌گذاری شده در نواحی هستند.

Dunn index: این شاخص معیاری برای ارزیابی الگوریتم‌های دسته‌بندی است [۲۶]. هدف این شاخص شناسایی دسته‌های متراکم و جداسازی درست آنهاست و به عنوان نسبت بین کمترین فاصله بین دسته‌ای بر حداکثر فاصله درون دسته‌ای، تعریف شده است. هرچه قدر مقدار این شاخص بیشتر باشد، بهتر است و به صورت زیر محاسبه می‌شود:


$$D = \min_i \left\{ \min_{k \neq i} \left\{ \frac{d(v_i, v_k)}{\max_l S(v_l)} \right\} \right\} \quad (15)$$

که در آن $S(v_l)$ فاصله درون کلاسی و $d(v_i, v_k)$ فاصله بین-کلاسی است.



ب

الف



ت

پ

شکل ۷ خروجی الگوریتم JSEG در مقیاس‌های مختلف (الف) مقیاس ۱ (۹ × ۹)؛ (ب) مقیاس ۲ (۱۷ × ۱۷)؛ (پ) مقیاس ۳ (۳۳ × ۳۳)؛ (ت) مقیاس ۴ (۶۵ × ۶۵)

برای قطعه‌بندی مقاطع نازک از الگوریتم JSEG استفاده شد. خروجی این الگوریتم در ماتریس ۲ ذخیره شد که مشخص‌کننده ناحیه‌های موجود در تصویر اصلی است. همان‌گونه که در بخش

۵ جمع‌بندی و کارهای آینده

در این پژوهش یک روش برای تشخیص خودکار کانی‌های موجود در مقاطع نازک سنگ ارائه شد. هدف اصلی این کار شناسایی کانی‌های موجود به صورت خودکار و با دقت بالا، بدون نظارت متخصص کانی‌شناسی است. مراحل اصلی این پژوهش شامل جمع‌آوری تصاویر از مقاطع نازک سنگ، قطعه‌بندی تصاویر مقاطع نازک، استخراج ویژگی‌های رنگ و ویژگی‌های بافت و در نهایت طبقه‌بندی با استفاده از طبقه‌بندهای مختلف است.

پس از ایجاد پایگاه داده و برچسب‌گذاری تصاویر توسط متخصص کانی‌شناسی، از الگوریتم JSEG برای قطعه‌بندی نواحی مختلف تصاویر مقاطع نازک استفاده شد. الگوریتم JSEG از چهار مقیاس مختلف برای قطعه‌بندی استفاده می‌کند که در این پژوهش از مقیاس دوم الگوریتم برای قطعه‌بندی استفاده گردید. پس از قطعه‌بندی تصویر، تعداد ۲۰۶ ویژگی، برای هر ناحیه در تصویر استخراج شد. ویژگی‌های استخراج شده شامل ویژگی‌های مربوط به رنگ و بافت در تصاویر گرفته شده در نور قطبی و نور معمولی است. همچنین این ویژگی‌ها در دو مقیاس RGB و HSI استخراج شدند.


در نهایت ویژگی‌های استخراج شده از هر ناحیه، برای طبقه‌بندی به طبقه‌بند فرستاده شد و طبقه‌بند هر ناحیه را به عنوان یک کانی برچسب‌گذاری کرد. سپس کارایی طبقه‌بندهای مختلف برای شناسایی کانی‌ها، مورد بررسی قرار گرفت. به منظور ارزیابی بهتر طبقه‌بندها، از چند معیار مختلف برای ارزیابی آنها استفاده شد و نتایج به دست آمده از طبقه‌بندهای مختلف با هم مقایسه گردید. در این پژوهش کارایی شش طبقه‌بند Linear Discriminant، Bagged Tree، Boosted Tree، Subspace Discriminant و Linear SVM و Weighted KNN مورد ارزیابی قرار گرفت. براساس نتایج تجربی به دست آمده در بین شش طبقه‌بند، طبقه‌بند Bagged Tree دارای بالاترین دقت به میزان ۹۵/۵۲٪ و همچنین کمترین میزان خطای MAE برابر با ۰/۰۴ و خطای RMSE برابر با ۰/۲۱ بود. همچنین همه ی طبقه‌بندها دارای دقت قابل قبول بالای ۹۳٪ بودند. این نتایج نشان داد که روش استخراج ویژگی پیشنهادی دارای قابلیت مناسبی جهت شناسایی خودکار کانی-هاست.

در آینده می‌توان از روش‌های جدید مبتنی بر یادگیری انتخاب ویژگی برای تعیین ویژگی‌های برتر و کاهش ابعاد بردار ویژگی استفاده کرد و نتایج جدید را با نتایج به دست آمده در این تحقیق مقایسه کرد.

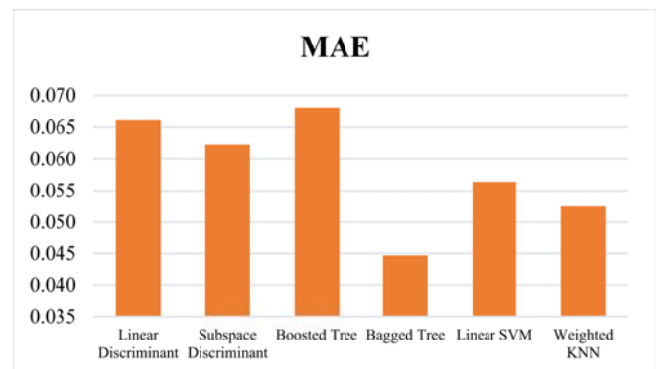
تقدیر و تشکر

نگارندگان بر خود لازم می‌دانند که از سرکار خانم مریم تقی‌زاده، دانشجوی دکتری دانشگاه رازی، به خاطر کمک ایشان در انجام این پژوهش تشکر نمایند.

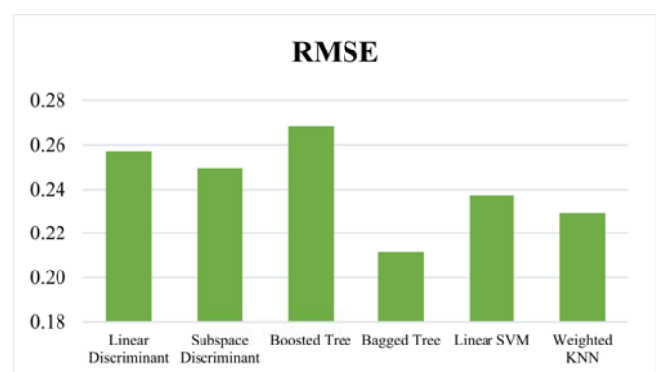
بهتر میزان کارایی طبقه‌بندهای مختلف، نمودار میله‌ای دقت و خطای طبقه‌بندهای مختلف در شکل های ۸، ۹ و ۱۰ نشان داده شده است. با توجه به نتایج تجربی به دست آمده در این پژوهش می‌توان نتیجه گرفت که طبقه‌بند Bagged Tree دارای بهترین کارایی برای طبقه‌بندی کانی‌ها می‌باشد. یکی از دلایل کارایی مناسب این الگوریتم این است که Bagging واریانس پیش‌بینی را از طریق ایجاد داده‌های اضافی برای آموزش کاهش می‌دهد. این داده‌های اضافی به صورت چندین زیرمجموعه از نمونه‌های آموزشی، که به صورت تصادفی و با جایگذاری انتخاب می‌شوند، ایجاد می‌شوند. سپس مجموعه‌ای از زیرمجموعه داده‌ها برای آموزش درخت‌های تصمیم به کار می‌رود.



شکل ۸ نمودار میله‌ای دقت طبقه‌بندهای مختلف



شکل ۹ نمودار میله‌ای خطای MAE طبقه‌بندهای مختلف



شکل ۱۰ نمودار میله‌ای خطای RMSE طبقه‌بندهای مختلف

مراجع

- [14] S. Joseph, H. Ujir, I. Hipiny, "Unsupervised Classification of Intrusive Igneous Rock Thin Section Images using Edge Detection and Colour Analysis", IEEE International Conference on Signal and Image Processing Applications, 2017 .
- [15] G. Cheng, Q. Yue, "Rock Images Analysis of FCM Clustering Algorithm Based on Weighted Color Texture Features", Journal of Physics: Conf. Series, 2018 .
- [16] H. Izadi, J. Sadri, F. Hormozzade, V. Fattahpour, "Altered mineral segmentation in thin sections using an incremental-dynamic clustering algorithm", Engineering Applications of Artificial Intelligence, Vol. 90, pp. 1-19, 2020.
- [17] F. Fueten, "A computer controlled rotating polarizer stage for the petrographic microscope", Computers & Geosciences, Vol. 23, pp. 203-208, 1997.
- [18] W. Hans-Rudolf, B. Andrei, "Minerals: Their Constitution and Origin", Cambridge University Press, P. 10, 2004 .
- [۱۹] ملایی، حبیب. ۱۳۸۵. « اطلسکانی شناسی نوری». دانشگاه آزاد اسلامی مشهد، معاونت پژوهشی.
- [20] Y. Deng, B. S. Manjunath, "Unsupervised segmentation of color-texture regions in images and video", IEEE Trans Pattern Anal Mach Intell., Vol. 23, No. 8, pp. 800-810, 2001.
- [21] T. Ojala, M. Pietikainen, T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns", IEEE Transactions on pattern analysis and machine intelligence, pp. 971-987, 2002.
- [22] C. Zhao, F. Gao, "A Nested-loop Fisher Discriminant Analysis Algorithm", Chemometrics and Intelligent Laboratory Systems, Vol. 146, pp. 396-406, 2015.
- [23] M. Galar, A. Fern'andez, E. Barrenechea, H. Bustince, F. Herrera, "A Review on Ensembles for the Class Imbalance Problem: Bagging-, Boosting-, and Hybrid-Based Approaches", IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews. Vol. 42, No. 4, 2012.
- [۲۴] شاهسون، پوریا؛ علی اسماعیلی و احسان لاله‌زاری. ۱۳۹۴. «بهبود طبقه‌بندی تصویر فراطیفی AVIRIS با استفاده از الگوریتم‌های GA و GSA» کنفرانس ملی مهندسی فناوری اطلاعات مکانی.
- [25] J. Zavrel, "An empirical re-examination of weighted voting for KNN", In *Proceedings of the 7th Belgian Dutch conference on Mashin Learning*, pp. 139-148, 1997.
- [26] P. Maji, P. Jarai, "Simultaneous Feature Selection and Extraction Using Feature Significance", Fundamenta Informaticae, Vol. 136, No. 4, pp. 405-431, 2015.
- [1] M. Młynarczuk, A. Górszczyk, B. Ślipek, "The application of pattern recognition in the automatic classification of microscopic rock images", Computers & Geosciences, Vol. 60, pp. 126-133, 2013 .
- [۲] حامدی، رضا. ۱۳۷۷. «پردازش تصاویر مقاطع نازک میکروسکوپی». دومین همایش سالانه انجمن زمین شناسی ایران.
- [3] N. A. Baykan, N. Yilmaz, "Mineral identification using color spaces and artificial neural networks", Computers & Geosciences, Vol. 36, No. 1, pp. 91-97, 2010.
- [4] N. Yesiloglu-Gultekin, A. S. Keceli, E. A. Sezer, A. B. Can, C. Gokceoglu, H. Bayhan, "A computer program (TSecSoft) to determine mineral percentages using photographs obtained from thin sections", Computers & Geosciences, Vol. 46, pp. 310-316, 2012.
- [5] A. R. Weeks, G. E. Hague, "Colour segmentation in HIS color space using the K-means algorithm", Proceedings of the SPIE 3026, pp 143-156. 1997.
- [6] H. Izadi, J. Sadri, N. A. Mehran, "A new intelligent method for Minerals segmentation in thin Sections based on A novel incremental color clustering", Computers & Geosciences, Vol. 81, pp. 38-52, 2015.
- [7] H. Izadi, J. Sadri, M. Bayati, "An intelligent system for mineral identification in thin sections based on a cascade approach", Computers & Geosciences Vol. 99, 37-49, 2017
- [۸] زندی‌فر، سمیرا و محمد ولی ولی زاده. ۱۳۹۸. «ارائه مدل مناسب جهت تخمین درصد انواع کانیها و بررسی فضایی آنها در منطقه مورد مطالعه با استفاده از تصاویر میکروسکوپی (مطالعه موردی: اسکارن جنوب غرب تفت)». مجله زمین شناسی کاربردی پیشرفته.
- [۹] حسن‌پور، عبدالله؛ علی کنعانیان و محمدعلی برقی. ۱۳۸۸. «مرزبندی کانی‌ها در تصویر مقاطع سنگ شناسی با استفاده از نرم افزار ArcGIS». مجله بلور شناسی و کانی شناسی ایران، سال هفدهم شماره ۱، ص. ۱۳۳.
- [10] J. Starkey, A. K. Samantaray, "Edge detection in petrographic images", Journal of Microscopy Vol. 172, No. 3, pp. 263-266, 1993.
- [11] O. Baklanova, O. Shvets, "Cluster analysis methods for recognition of mineral rocks in the mining industry", International Conference on Image Processing Theory, Tools and Applications (IPTA), 2014.
- [12] S. Budenny, A. Pachezhertsev, A. Bukharev, A. Erofeev, D. Mitrushkin, B. Belozarov, "Image Processing and Machine Learning Approaches for Petrographic Thin Section Analysis", SPE Russian Petroleum Technology Conference, pp. 16-18, 2017.
- [13] M. M. Mezghani, S. Shammari, C. V. Dijk, "Automated Thin Section Textural Analysis Using Image Processing", 13th Middle East Geosciences Conference and Exhibition, 2018.



شکوفه ساعدی دارای مدرک کارشناسی مهندسی فناوری اطلاعات از دانشگاه صنعتی کرمانشاه و کارشناسی ارشد مهندسی فناوری اطلاعات (سیستم‌های چندرسانه‌ای) از دانشگاه رازی، کرمانشاه، ایران است. علایق تحقیقاتی وی شامل هوش مصنوعی و پردازش تصویر است.



عبدالله چاله‌چاله متولد کرمانشاه، ایران بوده و مدرک کارشناسی مهندسی برق (سخت افزار) و کارشناسی ارشد مهندسی کامپیوتر (نرم افزار) خود را از دانشگاه صنعتی شریف، تهران، ایران دریافت کرده است. وی مدرک دکترای مهندسی کامپیوتر خود را از دانشگاه ولونگونگ استرالیا در سال ۲۰۰۵ میلادی دریافت و در حال حاضر عضو هیأت علمی دانشگاه رازی در کرمانشاه است. علایق تحقیقاتی وی شامل هوش مصنوعی، پردازش تصویر و ویدئو، سیستم‌های توزیع شده و اینترنت اشیا است.