



مقاله پژوهشی

مدل سازی و تحلیل سیستم های درزه با رویکرد ترکیبی و چندمرحله ای خوشه بندی: مطالعه موردی توده گرانیتهی لوچو زاهدان

سهیل زارع مطلق^{۱*}، سید امیراسعد فاطمی^۱، محمدجواد آذین فر^۱

۱- گروه مهندسی معدن، دانشکده مهندسی شهید نیکبخت، دانشگاه سیستان و بلوچستان، زاهدان، ایران

(دریافت: دی ۱۴۰۳، پذیرش: فروردین ۱۴۰۴)

چکیده

درزه های ساختاری به دلیل تأثیر عمیق بر پایداری توده های سنگی و طراحی پروژه های مهندسی، نیازمند تحلیل دقیق و شناسایی صحیح دسته بندی ها هستند. این پژوهش باهدف ارائه روشی نوین برای شناسایی و تحلیل دسته های درزه، از رویکرد ترکیبی و چندمرحله ای شامل الگوریتم K-means برای خوشه بندی اولیه و الگوریتم خوشه بندی سلسله مراتبی (AHC) برای تحلیل روابط پیچیده استفاده کرده است. داده های مطالعه شامل امتداد و شیب ۱۷۲ صفحه درزه از توده گرانیتهی لوچو زاهدان است که از طریق برداشت میدانی گردآوری شده اند. در ابتدا، الگوریتم K-means با استفاده از معیار فاصله اقلیدسی خوشه بندی اولیه را در پنج مرحله انجام داد. در این مراحل، ۲۱ داده نوین یا پرت به تدریج حذف شدند و با کاهش واریانس درون خوشه ای، داده های باقی مانده در ۱۲ خوشه اولیه قرار گرفتند. سپس با استفاده از الگوریتم AHC و معیار شباهت کسینوسی و اعمال سطح برش ۰/۸۶۶، ۱۲ خوشه اولیه به شش خوشه نهایی تقسیم شدند. نتایج نشان داد که واریانس درون خوشه ای معادل ۱۶/۳۶ درصد و واریانس بین خوشه ای معادل ۸۳/۶۴ درصد از واریانس کل است که بیانگر تفکیک مؤثر و انسجام بالای خوشه های نهایی با ویژگی های فضایی و هندسی بهینه است. در این مطالعه درزه ها در شش گروه نهایی شامل درزه های افقی (J1)، درزه های با شیب متوسط (J2) و درزه های با شیب تند (J3، J4، J5 و J6) دسته بندی شدند که هر کدام ویژگی ها و چالش های خاص خود را در فرآیند استخراج و پایداری دیواره های معدن دارند. این روش امکان تحلیل سه بعدی الگوهای فضایی درزه ها را فراهم کرده و به آشکارسازی روابط پیچیده در داده ها و ارائه نتایج قابل اعتماد منجر شد. رویکرد پیشنهادی علاوه بر بهبود دقت و تفکیک دسته های درزه ها، محدودیت های روش های متعارف را برطرف کرده و پارامترهای کمی برای تفسیر دقیق تر الگوهای زمین شناسی مرتبط با جهت گیری درزه ها فراهم می کند. نتایج آن به عنوان ابزاری کارآمد در برنامه ریزی استخراج معدن، بهبود پایداری شیب ها، طراحی سازه های زیرزمینی و مدیریت ریسک های مرتبط با توده های سنگی در پروژه های مهندسی قابل استفاده است.

کلمات کلیدی

مدل سازی درزه ها، الگوهای فضایی، خوشه بندی سلسله مراتبی (AHC)، الگوریتم K-means، خوشه بندی ترکیبی و چندمرحله ای، گرانیتهی لوچو زاهدان

*عهده دار مکاتبات: s_zare@eng.usb.ac.ir

DOI: 10.22034/ANM.2025.22633.1658

۱- مقدمه

درزه‌ها به عنوان ناپیوستگی‌های طبیعی در سنگ‌ها، نقش مهمی در تعیین ویژگی‌های مهندسی توده‌های سنگی و ساختارهای زمین‌شناسی ایفا می‌کنند. مطالعه جامع و طبقه‌بندی مناسب درزه‌ها که نقش اساسی در پایداری شیب‌ها، جریان آب‌های زیرزمینی و انتقال تنش‌ها دارند، می‌تواند به مهندسان کمک کند تا در طراحی و اجرای پروژه‌هایی مانند تونل‌سازی، سدسازی، استخراج معادن و حفاری‌های نفت و گاز، تحلیل دقیق‌تری داشته باشند و در نتیجه ایمنی و بهره‌وری این پروژه‌ها را افزایش دهند [۱-۵]. تحلیل و شناسایی الگوهای درزه‌های زمین‌شناسی با چالش‌هایی مانند پیچیدگی‌های هندسی، تغییرپذیری زیاد در جهت‌گیری‌ها و فاصله‌های میان درزه‌ها روبه‌رو است که دسته‌بندی دقیق آن‌ها را دشوار می‌سازد. روش‌های متعارف، مانند استریونت و تور ولف، به عنوان ابزارهای پایه‌ای مفید برای نمایش گرافیکی و تحلیل دوبعدی وضعیت داده‌های درزه‌ها در پروژه‌های زمین‌شناسی ساختاری و مهندسی شناخته می‌شوند. این ابزارها، هرچند در تجسم ساده و تحلیل سریع داده‌ها و همچنین در تعیین جهت‌های تنش اصلی و شیب‌های بحرانی کارآمد هستند، به دلیل وابستگی به تفسیرهای ذهنی، توانایی لازم برای شناسایی الگوهای پنهان و تحلیل دقیق روابط پیچیده میان درزه‌ها را ندارند. علاوه بر این، محدودیت این روش‌ها به تحلیل دوبعدی، موجب می‌شود که از دقت کافی در پردازش داده‌های بزرگ و چندبعدی برخوردار نباشند و نتوانند عواملی مانند تراکم، فاصله و توزیع فضایی درزه‌ها را به صورت جامع بررسی کنند؛ بنابراین، در پروژه‌های بزرگ و شرایطی با هندسه‌های پیچیده یا نامنظم، تحلیل‌هایی که صرفاً بر این روش‌ها تکیه دارند، ممکن است منجر به نتایجی ناقص و غیرقابل اعتماد شوند [۶-۹].

محدودیت‌های روش‌های متعارف در تحلیل درزه‌ها، استفاده از روش‌های نوین داده‌محور نظیر داده‌کاوی، مدل‌سازی سه‌بعدی و یادگیری ماشین را ضروری ساخته است. این تکنیک‌ها با قابلیت‌های تحلیلی پیشرفته، امکان تحلیل دقیق‌تر و جامع‌تری از الگوهای رفتاری و هندسی درزه‌ها را فراهم می‌کنند. استفاده از این رویکردهای نوین نه تنها به کشف الگوهای پنهان و تحلیل چندلایه داده‌ها کمک می‌کند، بلکه امکان شناسایی دقیق‌تر و کاربردی‌تر

درزه‌ها را فراهم کرده و در نهایت منجر به نتایج قابل اعتمادتر در تحلیل‌های زمین‌شناسی و مهندسی می‌شود [۱۰-۱۶].

داده‌کاوی و خوشه‌بندی به عنوان دو ابزار کلیدی در تحلیل داده‌ها، در سال‌های اخیر پیشرفت‌های چشمگیری داشته‌اند. این روش‌ها با ساده‌سازی فرآیندهای پیچیده و ارائه دیدگاه‌های جدید، امکان درک بهتری از داده‌های چندبعدی و پیچیده را فراهم کرده‌اند. با توانایی شناسایی الگوهای پنهان و برقراری ارتباط میان داده‌ها، این تکنیک‌ها امکان طبقه‌بندی دقیق و پیش‌بینی رفتار سیستم‌ها را فراهم می‌آورند و به عنوان ابزارهای تحلیلی مهم در علوم زمین و دیگر رشته‌های مرتبط به کار گرفته می‌شوند [۱۷-۲۱].

خوشه‌بندی داده‌ها با استفاده از الگوریتم‌های مختلف، روشی کارآمد برای شناسایی شباهت‌ها و تفاوت‌ها میان مشاهدات و ویژگی‌ها در مطالعات علوم زمین محسوب می‌شود. این روش‌ها با تحلیل داده‌های زمین‌شناسی، به آشکارسازی دقیق‌تر الگوهای فضایی کمک کرده و امکان تفسیر جامع‌تری از رویدادهای زمین‌شناسی را فراهم می‌آورند. پیشرفت‌های اخیر در داده‌کاوی و خوشه‌بندی، این ابزارها را به روش‌های تحلیلی پیشرفته‌ای تبدیل کرده که تصمیم‌گیری‌های داده‌محور را در مطالعات زمین‌شناسی و مهندسی تسهیل می‌کنند. نرم‌افزارهای پیشرفته تحلیل داده نیز با افزایش سرعت و دقت پردازش و ارائه قابلیت‌های بصری‌سازی مانند نمایش سه‌بعدی و تحلیل گرافیکی، درک عمیق‌تری از الگوهای پیچیده و روابط میان داده‌ها فراهم کرده‌اند. این ابزارها امکان تحلیل دقیق‌تر ویژگی‌های زمین‌شناسی نظیر جهت‌گیری درزه‌ها و توزیع فضایی شکستگی‌ها را فراهم ساخته و به کاربران این امکان را می‌دهند که داده‌ها را در مقیاس‌ها و دیدگاه‌های مختلف بررسی کنند [۲۲-۲۶].

رویکردهای چندمرحله‌ای^۱ و چندمقیاسی^۲ ابزارهایی مؤثر برای تحلیل داده‌های پیچیده و چندبعدی هستند و به‌ویژه در شرایطی که داده‌ها دارای روابط پیچیده، مقیاس‌های متنوع و ناهمگنی بالا هستند، عملکرد بهتری نسبت به روش‌های رایج ارائه می‌دهند. این رویکردها با تحلیل تدریجی داده‌ها در چند مرحله و حذف نویز و داده‌های پرت، دقت خوشه‌بندی را بهبود بخشیده و شناسایی گروه‌های معنادارتر را تسهیل می‌کنند. توانایی تحلیل داده‌ها در مقیاس‌های مختلف یکی از ویژگی‌های برجسته این روش‌ها است که به محققان امکان می‌دهد ابتدا الگوهای کلی

۲- مواد و روش ها

۲-۱- کاربرد الگوریتم های خوشه بندی در تحلیل هندسی و فضایی درزه ها

در تحلیل های هندسی، آماری و ژئومکانیکی درزه ها و شکستگی ها در محیط های سنگی، از ابزارهای نرم افزاری متعددی استفاده می شود. این ابزارها عمدتاً بر اساس روش های متعارف و محاسباتی عمل کرده و در حوزه هایی نظیر رسم نمودارهای استریوگرافیک، تحلیل جهت گیری درزه ها، ارزیابی پایداری شیب ها و مدل سازی زیرسطحی، کارایی مطلوبی دارند [۹، ۳۸-۴۰]. با این وجود به دلیل تمرکز بر رویکردهای کلاسیک، استفاده مستقیم از الگوریتم های پیشرفته داده کاوی و خوشه بندی در آن ها محدود است. این موضوع ضرورت تلفیق فناوری های نوین داده کاوی در تحلیل های زمین شناسی را بیش از پیش نمایان می سازد.

در پژوهش حاضر، از رویکردی نوآورانه مبتنی بر الگوریتم های داده کاوی برای تحلیل درزه ها استفاده شده است. این رویکرد نسبت به روش های متعارف و نرم افزارهای رایج مزایای قابل توجهی دارد و با ارائه تحلیل های کمی، خطاهای ناشی از تفسیر بصری کاربر را به حداقل می رساند. برای شناسایی و دسته بندی درزه ها، از رویکرد ترکیبی الگوریتم های خوشه بندی K-means و خوشه بندی سلسله مراتبی (AHC) استفاده شد. در گام نخست، الگوریتم K-means برای تقسیم بندی اولیه داده ها به خوشه های چندگانه به کار گرفته شد. سپس الگوریتم AHC بر مراکز این خوشه ها اعمال گردید و با بهینه سازی الگوی سلسله مراتبی، خوشه ها به تدریج ادغام شدند. این فرآیند باهدف کاهش واریانس درون خوشه ای و افزایش واریانس بین خوشه ای، منجر به شناسایی تعداد بهینه خوشه ها و مرز بندی دقیق تر دسته های درزه شد. رویکرد تلفیقی با استفاده از الگوریتم های خوشه بندی K-means و سلسله مراتبی (AHC)، ابزاری قدرتمند برای تحلیل داده های چندبعدی است که نقش مهمی در بهبود کیفیت تحلیل های زمین شناسی ساختاری ایفا می کند. این روش با شناسایی و حذف داده های پرت^۵، دقت گروه بندی را افزایش داده و خطاهای انسانی مرتبط با برداشت و تفسیر بصری را به حداقل می رساند. در قیاس با روش های سنتی که بیشتر بر تحلیل های کیفی و بصری موقعیت قطب صفحات درزه روی استریونت استوارند، این رویکرد داده محور زمینه را برای ارائه

را شناسایی و سپس جزئیات بیشتری را بررسی کنند. این روش ها در علوم زمین، به ویژه برای تحلیل داده های حجیم و پیچیده مانند درزه های، ابزار مؤثری برای شناسایی دقیق الگوهای هندسی و جهتی محسوب می شوند و نتایجی دقیق تر و قابل اعتمادتر ارائه می دهند [۲۲، ۲۷-۳۱].

ترکیب الگوریتم های K-means و خوشه بندی سلسله مراتبی تجمعی (AHC) یک رویکرد تحلیلی پیشرفته است که با رفع محدودیت های هر کدام، دقت و پایداری خوشه بندی داده های پیچیده را افزایش می دهد. الگوریتم K-means به دلیل سرعت و کارایی در گروه بندی داده های بزرگ شناخته می شود، اما در شناسایی الگوهای پیچیده و خوشه های نامنظم محدودیت هایی دارد. در مقابل، AHC با استفاده از الگوهای سلسله مراتبی^۲ و دندروگرام، روابط پیچیده میان داده ها را با دقت بیشتری تحلیل می کند. این ترکیب، به ویژه برای داده های چندلایه و پیچیده، ابزار مؤثری برای مدل سازی و تفسیر دقیق تر داده ها در زمینه های علمی مختلف فراهم می آورد [۳۲-۳۷].

این پژوهش یک رویکرد ترکیبی^۴ چندمرحله ای و چندمقیاسی را برای تحلیل دقیق تر داده های زمین شناسی معرفی می کند که از الگوریتم K-means برای خوشه بندی اولیه و AHC برای تحلیل سلسله مراتبی استفاده می کند. این ترکیب، با بهره گیری از سرعت پردازش K-means و دقت بالای AHC در شناسایی روابط پیچیده، نسبت به کاربرد مستقل هر یک از الگوریتم ها نتایج دقیق تر و قابل اعتمادتری ارائه می دهد. داده های این مطالعه از توده گرانتیوئیدی لوچو در جنوب غربی زاهدان، با ویژگی های تکتونیکی خاص، گردآوری شده است. در این راستا، امتداد و شیب ۱۷۲ صفحه درزه با استفاده از ابزارهای میدانی ثبت شد. اعمال این روش ترکیبی بر روی مجموعه داده منطقه مورد مطالعه، با حذف نویز و داده های پرت در مراحل اولیه، خطاهای احتمالی را کاهش داده و از طریق تحلیل چندمقیاسی، روابط پیچیده میان داده ها را نمایان می کند. علاوه بر بهبود روش های رایج، این رویکرد امکان شناسایی الگوهای پنهان در داده های غیرخطی و چندبعدی را فراهم کرده و پارامترهای کمی ارزشمندی برای تفسیر بهتر الگوهای زمین شناسی، از جمله جهت گیری درزه ها، ارائه می دهد. یافته های این پژوهش، ضمن بهبود تحلیل پایداری شیب ها و طراحی تونل ها و معادن، قابلیت کاربرد در تحلیل داده های پیچیده سایر حوزه های علوم زمین و مهندسی را نیز داراست.

شکل‌گیری سطوح شکستگی و واژگونی بلوک‌های سنگی در بخش‌هایی از توده شده است. این ویژگی‌ها توأم با کمبود اطلاعات جامع درباره وضعیت توزیع درزه‌ها و شکستگی‌ها، مشکلات فنی، اقتصادی و ایمنی قابل توجهی در پروژه‌های معدنی و زمین‌شناسی مهندسی منطقه ایجاد می‌کند.

۲-۳- برداشت صحرایی و آماده‌سازی داده‌ها

در این پژوهش، داده‌های میدانی شامل امتداد و شیب ۱۷۲ صفحه درزه از توده گرانیتهی لوچو توسط پنج گروه عملیاتی با دستگاه کمپاس جمع‌آوری شد. سپس موقعیت بردار قطب^۶ هر صفحه درزه محاسبه و مؤلفه‌های بردارهای قطب با طول واحد در سیستم مختصات کارتزین تعیین گردید. مختصات این بردارها با استفاده از رابطه (۱) محاسبه شد:

$$\begin{aligned} X_i &= \cos(Dip_i) \cdot \sin(Az_i) \\ Y_i &= \cos(Dip_i) \cdot \cos(Az_i) \\ Z_i &= \sin(Dip_i) \end{aligned} \quad (1)$$

که Az_i و Y_i و Z_i مختصات سه‌بعدی بردار قطب، Dip_i زاویه آزمون و Az_i زاویه شیب صفحه درزه i -ام هستند. این مختصات به‌عنوان داده‌های اصلی در تحلیل‌های بعدی و ارزیابی دقیق‌تر درزه‌ها مورد استفاده قرار گرفتند.

تحلیل آماری این داده‌ها نشان داد که درزه‌ها در فضای سه‌بعدی پراکندگی قابل توجهی دارند. میانگین زاویه شیب (۷۳/۷ درجه) حاکی از تمایل غالب صفحات درزه به زوایای نسبتاً بالا است. این ویژگی نقش مهمی برای شناسایی الگوهای هندسی، تحلیل تنش‌های مؤثر بر توده سنگ و برنامه‌ریزی بهینه برای استخراج بلوک‌های سنگی از توده گرانیتهی دارد. جدول ۱ توزیع آماری زاویه‌های آزمون، شیب و مختصات سه‌بعدی بردارهای قطب را نشان می‌دهد.

جدول ۱: تحلیل آماری مشخصات صفحات درزه و بردارهای قطب آن‌ها

ویژگی	حداقل	حداکثر	چارک اول	میانه	چارک سوم	میانگین	واریانس
آزمون بردار شیب درزه	۳	۳۵۵	۸۵/۸	۱۹۳/۵۰	۳	۱۷۳/۰۲۳	۹۰۶۶/۵۱۴
شیب درزه	۵	۹۰	۶۷	۸۱	۵	۷۳/۶۹۸	۳۵۳/۱۹۵
آزمون بردار قطب درزه	۵	۳۵۵	۳۲	۱۲۲	۵	۱۳۹/۵۳۵	۱۱۱۷۷/۹۴۶
شیب بردار قطب درزه	۰	۸۵	۳	۹	۰	۱۶/۳۰۲	۳۵۳/۱۹۵
مؤلفه X بردار قطب	-۰/۹۹۹	۰/۹۹۸	-۰/۶۷۲	۰/۱۸۲	۰/۵۶۲	۰/۰۲	۰/۴۰۶
مؤلفه Y بردار قطب	-۰/۹۹۶	۰/۹۹۶	-۰/۵۰۱	۰/۱۴	۰/۸۴۱	۰/۱۲۹	۰/۴۴۸
مؤلفه Z بردار قطب	۰	۰/۹۹۶	۰/۰۵۲	۰/۱۵۶	۰/۳۹۱	۰/۲۵۷	۰/۰۶۸

تحلیل‌های کمی دقیق‌تر و کارآمدتر فراهم می‌سازد و از توانمندی بالایی در گروه‌بندی هدفمند داده‌ها و دستیابی به نتایج قابل اعتماد برخوردار است.

۲-۲- ویژگی‌های زمین‌شناسی منطقه مورد مطالعه

باتولیت گرانیته‌ی زاهدان، با روند شمال غربی-جنوب شرقی، در میان فلیش‌های دگرگون شده استان سیستان و بلوچستان واقع شده است. این باتولیت از مجموعه حدواسط-اسیدی با ترکیب سنگ‌هایی از دیوریت تا گرانودیوریت و خاستگاه آذرین و همچنین مجموعه کوچک‌تر اسیدی با ترکیب عمدتاً بیوتیت گرانیته و خاستگاه پوسته‌ای تشکیل شده است. گرانودیوریت‌ها بخش اعظم این توده را دربرمی‌گیرند و به همراه آنکلاوهای میکروگرانولار مافیک، تنوع سنگی گسترده‌ای را نشان می‌دهند. علاوه بر این، دایک‌های آندزیتی-داسیتی که به‌صورت گسترده در منطقه دیده می‌شوند، اغلب به شکل موازی یا متقاطع در میان گرانیته‌ها و واحدهای فلیشی نفوذ کرده‌اند [۴۱، ۴۲].

نوار گرانیته‌ی زاهدان-سراوان در اثر فروانش ورقه اقیانوسی سیستان به زیر ورقه قاره‌ای بلوک افغان شکل گرفته است. توده‌های نفوذی در طول فرایند برخورد تکتونیکی در زون جوش خورده سیستان جایگزین شده‌اند. شواهدی از اختلاط ماگمایی در سنگ‌های گرانیتهی تا دیوریتی وجود دارد. مرزهای توده به‌ویژه در بخش جنوبی، با ساختارهای گسلی و میلونیتی همراه هستند که بازتابی از فرایندهای تکتونیکی فعال در منطقه است [۴۲، ۴۳].

توده گرانیتهی لوچو بخشی از باتولیت گرانیته‌ی است که در جنوب شهر زاهدان قرار دارد. این توده دارای بافت گرانولار و از کانی‌هایی نظیر کوارتز، فلدسپات پتاسیم، آلبیت، الیگوکلاز، بیوتیت و هورنبلند تشکیل شده است. وجود درزه‌های متعدد با امتدادها و شیب‌های متنوع، منجر به

۲-۴ خوشه بندی اولیه با روش K-means

الگوریتم K-means یکی از روش های پرکاربرد در خوشه بندی غیرنظارتی است که باهدف گروه بندی داده ها به K خوشه مجزا، بر اساس کمینه سازی مجموع مربعات فواصل داده ها از مراکز خوشه ها عمل می کند. این الگوریتم به صورت تکراری عمل کرده و در هر مرحله، داده ها را به نزدیک ترین مرکز خوشه اختصاص می دهد و سپس مراکز خوشه ها با توجه به موقعیت جدید داده ها به روزرسانی می شوند. انعطاف پذیری این روش، امکان تغییر دسته بندی داده ها در طول فرآیند را فراهم می کند و با استفاده از تکرارهای متعدد و نقاط شروع مختلف، خوشه بندی بهینه ای ایجاد می کند [۲۰، ۴۴، ۴۵]. این ویژگی ها باعث شده است که الگوریتم K-means به طور گسترده در زمینه های مختلف علمی، از جمله تحلیل های زمین شناسی ساختاری و زمین شناسی مهندسی، مورد استفاده قرار گیرد [۴۶-۴۸].

در این پژوهش، از الگوریتم K-means برای تحلیل داده های مرتبط با درزه ها استفاده شده است. مراحل اجرای الگوریتم شامل تعیین تعداد خوشه ها (K) بر اساس شواهد اولیه، انتخاب تصادفی مراکز اولیه خوشه ها و تخصیص داده ها به خوشه ها بر اساس فاصله اقلیدسی است.

با فرض اینکه هر مشاهده یا نقطه داده x_i به صورت $x_i = [x_{i1}, x_{i2}, \dots, x_{ip}]$ تعریف شود، فاصله اقلیدسی بین یک نقطه داده x_i و یک مرکز خوشه $c_j = [c_{j1}, c_{j2}, \dots, c_{jp}]$ به صورت رابطه (۲) تعریف می شود:

$$d(x_i, c_j) = \sqrt{\sum_{n=1}^p (x_{in} - c_{jn})^2} \quad (2)$$

در این فرمول x_i نمایانگر داده i -ام، c_j نمایانگر مرکز خوشه j -ام، p تعداد ویژگی ها، x_{in} ویژگی n -ام داده x_i و c_{jn} ویژگی n -ام مرکز خوشه c_j است. پس از اختصاص داده ها به خوشه ها، مراکز خوشه ها با استفاده از رابطه (۳) به روزرسانی می شوند:

$$c_j = \frac{\sum_{x_i \in C_j} x_i}{|C_j|} \quad (3)$$

در این فرمول $c_j = [c_{j1}, c_{j2}, \dots, c_{jp}]$ مرکز به روزرسانی شده خوشه C_j که هر مؤلفه نشان دهنده یک ویژگی مرکز خوشه است، $|C_j|$ تعداد داده هایی که به

خوشه C_j اختصاص داده شده اند و $x_i \in C_j$ داده هایی که به خوشه C_j تعلق دارند.

مراحل تخصیص داده ها و به روزرسانی مراکز خوشه ها تا زمانی ادامه می یابد که مراکز خوشه ها به پایداری برسند یعنی تغییرات چشمگیری در مراکز خوشه ها مشاهده نشود یا تعداد تکرارها از حد مشخصی فراتر رود. یکی از چالش های این روش، انتخاب تعداد بهینه خوشه ها (K) است که باید بر اساس تحلیل های پیشین و شواهد علمی تعیین شود.

۲-۴-۱- معیارهای ارزیابی کیفیت خوشه بندی K-means

یکی از معیارهای اصلی در ارزیابی کیفیت خوشه بندی، کاهش واریانس درون خوشه ای است. الگوریتم K-means برای کمینه سازی مجموع مربعات فاصله داده ها از مراکز خوشه ها طراحی شده است و هدف آن، کاهش واریانس داخلی خوشه ها و افزایش فاصله بین خوشه ها است که به بهبود کیفیت خوشه بندی و تفکیک واضح تر خوشه ها منجر می شود [۲۰، ۴۹، ۵۰]. معیار مذکور به صورت رابطه (۴) تعریف می شود:

$$W(C) = \sum_{j=1}^K \sum_{x \in C_j} \|x - c_j\|^2 \quad (4)$$

در این رابطه $W(C)$ موع واریانس درون خوشه ای برای کلیه نقطه داده ها، C_j خوشه j -ام، x هر نقطه داده درون خوشه C_j ، c_j مرکز خوشه C_j و $\|x - c_j\|$ فاصله اقلیدسی بین هر نقطه داده x و مرکز خوشه آن است.

برای بهینه سازی و بهبود عملکرد الگوریتم K-means، استفاده از ماتریس کوواریانس درون خوشه ای به عنوان یک معیار پیشرفته تر پیشنهاد شده است. این رویکرد باهدف حداقل کردن پراکندگی داده ها در هر خوشه و ایجاد خوشه هایی همگن تر، واریانس داخلی را کاهش می دهد [۵۱-۵۳]. ماتریس کوواریانس درون خوشه ای تلفیقی^۸ با محاسبه ماتریس های کوواریانس جداگانه برای هر خوشه و سپس تلفیق آن ها بر اساس وزن دهی مبتنی بر تعداد داده های هر خوشه (با وزن دهی بر اساس تعداد مشاهدات هر خوشه) به دست می آید. وزن دهی متناسب با اندازه خوشه ها باعث می شود خوشه های بزرگ تر تأثیر بیشتری در ارزیابی داشته باشند. فرمول محاسبه این ماتریس به صورت رابطه (۵) است:

$$S_{PWCM} = \frac{\sum_{i=1}^k (n_i - 1) S_i}{\sum_{i=1}^k (n_i - 1)} \quad (5)$$

درزه‌های تصادفی یا درزه‌های غیرسیستماتیک باشند. این اقدام موجب کاهش اثرات نویزهای محیطی و افزایش همگنی داده‌ها گردید که دقت تحلیل‌های بعدی را بهبود بخشید.

در مراحل بعدی، الگوریتم K-means مجدداً بر روی داده‌های اصلاح‌شده اعمال شد. در هر مرحله، مراکز خوشه‌ها به‌روزرسانی شده و داده‌ها بر اساس نزدیکی به این مراکز به خوشه‌های مناسب اختصاص یافتند. حذف داده‌های پرت در طول این فرآیند به کاهش واریانس درون‌خوشه‌ای و بهبود تفکیک بین خوشه‌ها منجر شد. این مراحل تا رسیدن به شرایطی ادامه یافت که در آن هیچ داده‌ای به‌عنوان مقدار پرت شناسایی نشد و خوشه‌بندی نهایی با بیشترین انسجام و یکنواختی ممکن حاصل گردید.

ارزیابی کیفیت خوشه‌بندی در هر مرحله با استفاده از معیارهایی نظیر واریانس درون‌خوشه‌ای^{۱۲} (برای سنجش انسجام داخلی)، واریانس بین‌خوشه‌ای^{۱۳} (برای اندازه‌گیری تمایز بین خوشه‌ها) و فاصله از مرکز خوشه^{۱۴} انجام شد. در پایان این مرحله، مراکز خوشه‌های نهایی به‌عنوان موقعیت قطب‌های هر دسته درزه در نظر گرفته شد که مبنای تحلیل‌های دقیق‌تر در مراحل بعدی قرار خواهد گرفت.

۲-۵- خوشه‌بندی نهایی با روش سلسله‌مراتبی تجمعی (AHC)

در این مطالعه، روش خوشه‌بندی سلسله‌مراتبی تجمعی (AHC) به‌عنوان مکمل الگوریتم K-means برای بهبود خوشه‌بندی معرفی شد. در این رویکرد مختصات مراکز خوشه‌های^{۱۵} حاصل از الگوریتم K-means به‌عنوان موقعیت بردارهای قطب درزه‌ها در نظر گرفته شد و با استفاده از AHC، دسته‌های درزه با بیشترین همبستگی فضایی تلفیق شدند. این فرآیند با ترکیب دسته‌هایی که زاویه‌ای کمتر از «زاویه همبستگی» دارند، دسته‌های نهایی را با الگوی هندسی منسجم‌تر و ویژگی‌های بهینه‌تر شناسایی کرد. زاویه همبستگی ۳۰ درجه به‌عنوان معیار اصلی تلفیق و تفکیک دسته‌های درزه، با توجه به تحلیل جهت‌یافتگی درزه‌ها، شرایط تکنیکی منطقه و نتایج بررسی‌های میدانی انتخاب شد. این زاویه باهدف حفظ پیوستگی هندسی و شباهت میان درزه‌ها تعیین گردید. افزون بر این، تحلیل واریانس درون‌کلاسی و بین‌کلاسی نشان داد که زاویه ۳۰ درجه با کاهش پراکندگی داخلی و افزایش تمایز بین‌کلاسی، خوشه‌بندی بهینه‌ای را فراهم کرده و دقت تفکیک دسته‌های

$$S_i = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)(x_{ij} - \bar{x}_i)^T \quad (6)$$

که S_{PWCM} ماتریس کوواریانس درون خوشه‌ای تلفیقی، S_i ماتریس کوواریانس درون خوشه‌ای برای i -ام، n_i تعداد داده‌های خوشه i ، k تعداد خوشه‌ها، x_{ij} نقاط داده‌ای در خوشه i ، $\bar{x}_i$ میانگین داده‌ها در خوشه i است.

در این مطالعه، دترمینان ماتریس واریانس درون خوشه‌ای به‌عنوان معیار خوشه‌بندی^۹ برای بهینه‌سازی الگوریتم K-means به‌کار گرفته شده است. کمینه‌سازی دترمینان این ماتریس منجر به کاهش پراکندگی داده‌ها درون هر خوشه و افزایش انسجام داخلی آن می‌شود. این امر باعث شکل‌گیری خوشه‌هایی فشرده‌تر و همگن‌تر می‌شود که در نتیجه، تفکیک‌پذیری بین خوشه‌ها بهبود می‌یابد. این رویکرد نه تنها به بهینه‌سازی الگوریتم کمک می‌کند، بلکه تحلیل دقیق‌تری از الگوی توزیع درزه‌ها و شناسایی دسته‌های معنادار را امکان‌پذیر می‌سازد. از مزایای برجسته این روش می‌توان به کاهش حساسیت به تفاوت در مقیاس داده‌ها اشاره کرد که آن را برای داده‌هایی با مقیاس‌های مختلف کارآمد می‌سازد. علاوه بر این، معیار مذکور توانایی تحلیل خوشه‌هایی با اندازه‌های متفاوت را داراست که در مجموعه داده‌های پیچیده و ناهمگن بسیار کاربردی است. هدف اصلی این رویکرد، بهینه‌سازی فرآیند خوشه‌بندی از طریق کاهش واریانس درون خوشه‌ای و بهبود دقت گروه‌بندی است.

۲-۴-۲- خوشه‌بندی چند مرحله‌ای K-means برای تحلیل هندسی درزه‌ها

در این مطالعه برای تحلیل درزه‌های منطقه مورد مطالعه، از رویکرد خوشه‌بندی چند مرحله‌ای مبتنی بر الگوریتم K-means استفاده شده است. در ابتدا الگوریتم K-means بر روی داده‌های خام اعمال شد تا جهت‌گیری‌های فضایی مختلف شناسایی و خوشه‌های اولیه تعیین شوند. تعداد خوشه‌ها به‌گونه‌ای تنظیم گردید که تمامی دسته‌های درزه‌ها بر اساس تفاوت‌های جهت‌گیری فضایی پوشش داده شوند. پس از آن فاصله هر درزه از مرکز خوشه^{۱۰} محاسبه شد و داده‌های با فاصله زیاد به‌عنوان داده‌های پرت^{۱۱} شناسایی و حذف شدند. این داده‌های پرت می‌توانند مرتبط با می‌تواند

$$d(A, B) = \frac{1}{|A| \cdot |B|} \sum_{x_i \in A} \sum_{x_j \in B} d(x_i - x_j) \quad (۸)$$

در این رابطه، $d(x_i - x_j)$ فاصله بین اعضای x_i از خوشه A و x_j از خوشه B است و $|A|$ و $|B|$ تعداد اعضای هر خوشه هستند. با توجه به زاویه همبستگی ۳۰ درجه، سطح برش ۱۹ دندروگرام معادل شباهت کسینوسی ۰/۸۶۶ تنظیم شد تا درزه هایی با زاویه کمتر از این مقدار در یک گروه قرار گیرند و خوشه بندی نهایی منسجم تر و دقیق تر را ارائه دهد.

۲-۵-۲- تحلیل خوشه ها با روش سلسله مراتبی تجمعی

در تحلیل نهایی دسته بندی درزه ها، مشخص شد که توجه به هر دو زاویه حاده و مکمل برای ارزیابی شباهت میان دسته ها ضروری است. این مسئله به ویژه برای درزه هایی با شیب نزدیک به ۹۰ درجه و جهت های متقابل اهمیت دارد، زیرا بردارهای قطب این دسته ها در نمودار زاویه ای اختلافی در حدود ۱۸۰ درجه نشان می دهند و ممکن است بر اساس معیار شباهت کسینوسی از یکدیگر جدا شوند. این جداسازی، برخلاف توزیع هندسی درزه ها، می تواند منجر به کاهش دقت تحلیل شود. برای حل این مسئله، زاویه حاده به عنوان معیار اصلاح شده در ماتریس مجاورت^{۲۰} لحاظ شد.

پس از اصلاح ماتریس مجاورت و استفاده از مقدار مطلق شباهت کسینوسی به عنوان معیار نهایی، روش خوشه بندی سلسله مراتبی تجمعی (AHC) با پیوند میانگین بدون وزن مجدداً اعمال شد. این اصلاحات دقت تحلیل و شناسایی تعداد بهینه خوشه ها را بهبود بخشید. برای تعیین سطح برش دندروگرام، آستانه شباهت کسینوسی برابر با ۰/۸۶۶ انتخاب شد که نتایج مطلوبی از نظر انسجام و یکنواختی خوشه های نهایی ارائه داد. این تغییر موجب افزایش همخوانی الگوهای هندسی درزه ها و تلفیق دقیق تر آن ها در یک خوشه شد که نتایج آن به صورت دندروگرام نمایش داده شدند و بهبود قابل توجهی در گروه بندی دسته های درزه را نشان دادند.

۳- نتایج و بحث

۳-۱- تحلیل خوشه بندی درزه ها با الگوریتم K-means

درزه را بهبود می بخشد. در این راستا، معیار شباهت کسینوسی معادل با زاویه ۳۰ درجه و سطح برش^{۱۶} برابر با ۰/۸۶۶ در دندروگرام انتخاب شده است.

۲-۵-۱- فرآیند خوشه بندی سلسله مراتبی تجمعی


روش خوشه بندی سلسله مراتبی تجمعی (AHC) یکی از ابزارهای پرکاربرد در تحلیل داده ها است که با ترکیب تدریجی مشاهدات بر اساس معیارهای شباهت، الگوی سلسله مراتبی از خوشه ها ایجاد می کند. در این روش، ابتدا میزان شباهت بین تمامی جفت داده ها محاسبه شده و داده هایی که بیشترین شباهت را دارند، در یک خوشه گروه بندی می شوند. سپس خوشه جدید به عنوان یک واحد مستقل در نظر گرفته شده و میزان شباهت آن با سایر داده ها دوباره ارزیابی می شود. این فرآیند به صورت تکراری ادامه می یابد تا تمامی داده ها در قالب یک خوشه واحد ادغام شوند. نتیجه نهایی این روش به شکل یک دندروگرام (نمودار درختی) ارائه می شود که الگوی سلسله مراتبی خوشه ها را نمایش می دهد. با برش دندروگرام در سطوح مختلف، می توان تعداد بهینه ای از خوشه ها را شناسایی و به تحلیل دقیق تری از الگوهای داده ها دست یافت [۲۰، ۵۴ و ۵۵]. در این مطالعه، برای تحلیل همبستگی فضایی بردارهای قطب درزه ها، از معیار شباهت کسینوسی^{۱۷} استفاده شده که امکان شناسایی الگوهای سلسله مراتبی مشابه و جهت گیری های مشترک را با دقت بالا فراهم می کند. این معیار برای دو بردار A و B در فضای n -بعدی به صورت رابطه (۷) تعریف می شود:

$$\begin{aligned} \text{Cosine Similarity} &= \cos(\theta) \\ &= \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \cdot \sqrt{\sum_{i=1}^n B_i^2}} \end{aligned} \quad (۷)$$

در این رابطه، $A \cdot B$ حاصل ضرب داخلی و $\|A\|$ و $\|B\|$ مقادیر نرم بردارها هستند.

برای ایجاد الگوی دقیق تر و حفظ همگنی نسبی خوشه ها، از روش پیوند میانگین بدون وزن زوج ها^{۱۸} در خوشه بندی سلسله مراتبی استفاده شده است. این روش تعادلی مطلوب میان پیوند ساده و کامل ایجاد می کند [۵۴، ۵۶]. به منظور محاسبه فاصله بین دو خوشه A و B از رابطه (۸) استفاده می شود:

اولیه^{۲۶} به صورت تصادفی^{۲۷} و الگوریتم در هر مرحله ۱۰۰ بار تکرار گردید تا به طبقه‌بندی قابل اعتمادی برسد. نتایج مراحل مختلف خوشه‌بندی که در جدول ۲ ارائه شده، نشان می‌دهد که تعداد داده‌های خارج از ردیف به تدریج با پیشرفت مراحل کاهش یافته و در نهایت به صفر رسیده است. هم‌زمان واریانس درون خوشه‌ای کاهش و واریانس بین خوشه‌ای افزایش یافته است. این تغییرات باعث بهبود انسجام داخلی و تفکیک دقیق‌تر خوشه‌ها از یکدیگر شده که دقت در جداسازی دسته‌های درزه‌ها را افزایش داده است. در مرحله نهایی اجرای الگوریتم K-means، مشخصات هر خوشه شامل مختصات مراکز خوشه‌ها، تعداد اعضای هر خوشه و واریانس درون خوشه‌ای در جدول ۳ ارائه شد. مختصات مرکز هر خوشه معادل مؤلفه‌های X، Y و Z بردار قطب دسته درزه‌های متناظر است. واریانس درون خوشه‌ای پایین‌تر نشان‌دهنده فشرده‌تر بودن داده‌ها در هر خوشه و تفکیک دقیق‌تر دسته درزه‌ها است. همچنین مختصات مراکز خوشه‌ها که در شکل ۲ نمایش داده شده‌اند، به وضوح وضعیت توزیع خوشه‌ها را نشان داده و به درک و تفسیر بهتر الگوی فضایی درزه‌ها در منطقه کمک می‌کنند. این مراکز نمایانگر موقعیت بردار قطب متناظر با هر دسته درزه هستند.



شکل ۱: شناسایی داده‌های پرت در مراحل مختلف فرایند خوشه‌بندی K-means.

با توجه به ویژگی‌های زمین‌شناسی، شرایط تکتونیکی منطقه و داده‌های میدانی موجود، تعداد ۱۲ خوشه اولیه برای تحلیل داده‌ها با استفاده از الگوریتم K-means در نظر گرفته شد. این انتخاب به منظور شناسایی و تفکیک درزه‌های با تفاوت‌های زاویه‌ای قابل توجه در منطقه انجام گردید. در مرحله اول، الگوریتم K-means روی مجموعه داده اولیه اعمال شد. به منظور ارزیابی کیفیت خوشه‌بندی داده‌ها، فاصله هر داده از مرکز خوشه محاسبه و نتایج آن در قالب نمودار جعبه‌ای^{۲۸} بررسی شد. در این نمودار، پارامتر کران بالا^{۲۹} خوشه‌ها به عنوان آستانه‌ای برای شناسایی و حذف داده‌های پرت، شامل درزه‌های غیرسیستماتیک و فاقد الگوهای مشخص، استفاده شد. این رویکرد خوشه‌هایی با انسجام درونی بالاتر و پراکندگی کم‌تر ایجاد کرد. در مراحل بعدی (مرحله ۲ تا مرحله ۵)، الگوریتم به صورت تکراری بر روی داده‌های اصلاح‌شده اعمال شد. در هر مرحله، مراکز خوشه‌ها به روزرسانی شدند و داده‌ها بر اساس نزدیکی به این مراکز به خوشه‌های مناسب تخصیص یافتند. در این فرایند، داده‌های پرت حذف و داده‌های باقی‌مانده به مراکز خوشه‌ها نزدیک‌تر و از سایر خوشه‌ها متمایزتر شدند. سرانجام الگوریتم در مرحله نهایی (مرحله ۵) به وضعیتی رسید که هیچ داده‌ای به عنوان مقدار پرت شناسایی نشد و خوشه‌بندی نهایی با بالاترین درجه انسجام به دست آمد. روند این فرایند در نمودار جعبه‌ای شکل ۱ نشان داده شده است.

در تمامی مراحل اجرای الگوریتم K-means، پارامترهای کلیدی خوشه‌بندی به طور ثابت تنظیم شدند. معیار خوشه‌بندی با کمینه‌سازی دترمینان ماتریس واریانس درون خوشه‌ای^{۳۰} برای بهینه‌سازی الگوریتم به کار گرفته شد. شرایط توقف الگوریتم شامل حداکثر تعداد ۵۰۰ تکرار^{۳۱} و آستانه همگرایی^{۳۲} ۰٫۰۰۰۰۱ تعیین گردید تا اطمینان حاصل شود که الگوریتم در حالت پایدار خاتمه می‌یابد. تعداد خوشه‌ها ثابت و برابر با ۱۲ تنظیم شد، درحالی‌که پارتیشن

جدول ۲: روند بهبود کیفیت نتایج خوشه‌بندی K-means در مراحل مختلف

مرحله	تعداد مشاهدات	آستانه مقادیر خارج از ردیف	تعداد مقادیر خارج از ردیف	درصد واریانس درون خوشه‌ای	درصد واریانس بین خوشه‌ای	واریانس کل
۱	۱۷۲	۰٫۳۷۶	۱۱	۴٫۹۷	۹۵٫۰۳	۰٫۹۲۲
۲	۱۶۱	۰٫۳۴۱	۵	۳٫۴۵	۹۶٫۵۵	۰٫۹۳۵
۳	۱۵۶	۰٫۳۰۴	۲	۲٫۹۰	۹۷٫۱۰	۰٫۹۳۷
۴	۱۵۴	۰٫۲۹۷	۳	۲٫۶۶	۹۷٫۳۴	۰٫۹۳۶
۵	۱۵۱	۰٫۳۱۵	۰	۲٫۴۸	۹۷٫۵۲	۰٫۹۳۴

جدول ۳: مشخصات خوشه های نهایی در مرحله نهایی خوشه بندی K-means

خوشه	مختصات X مرکز	مختصات Y مرکز	مختصات Z مرکز	تعداد اعضاء	واریانس درون خوشه ای
C1	-۰٫۰۳۳	-۰٫۰۱۳	۰٫۹۸۸	۶	۰٫۰۲۸
C2	۰٫۷۷۷	۰٫۱۵۱	۰٫۵۹	۱۵	۰٫۰۲۸
C3	-۰٫۸۱۱	-۰٫۴۲۹	۰٫۳۵۳	۸	۰٫۰۳۹
C4	-۰٫۰۱۷	-۰٫۹۴۸	۰٫۲۴۲	۱۵	۰٫۰۴۶
C5	۰٫۳۵۱	۰٫۸۵	۰٫۳۶۳	۱۲	۰٫۰۲۴
C6	۰٫۲۰۱	۰٫۹۶۲	۰٫۱۴۸	۲۳	۰٫۰۱۲
C7	۰٫۵۷۰	۰٫۸۱	۰٫۰۷۸	۱۸	۰٫۰۱۴
C8	-۰٫۹۸۶	-۰٫۰۶	۰٫۰۸۵	۱۵	۰٫۰۱۸
C9	۰٫۸۸۸	-۰٫۴۰۵	۰٫۱۵۳	۱۰	۰٫۰۲۷
C10	-۰٫۶۷۵	-۰٫۷۲۵	۰٫۰۶۴	۱۶	۰٫۰۱۶
C11	-۰٫۸۴۱	۰٫۵۲۱	۰٫۰۴۴	۸	۰٫۰۲۲
C12	۰٫۹۳۹	۰٫۳۰۲	۰٫۰۰۳	۵	۰٫۰۳۴

نهایی با الگوهای هندسی منسجم تر و ویژگی های بهینه تر را فراهم کرد. فرآیند تلفیق خوشه ها به گونه ای طراحی شد که همخوانی الگوهای بین درزه ها افزایش یابد و تلفیق دقیق تر آن ها در یک خوشه تضمین شود.


در اجرای الگوریتم AHC، سطح برش دندروگرام بر روی مقدار ۰٫۸۸۶ تعیین شد که معادل کسینوس زاویه همبستگی ۳۰ درجه میان درزه ها است. این مقدار به طور مؤثر دسته های درزه ای با زاویه کمتر از ۳۰ درجه را در یک گروه ادغام کرده و هماهنگی الگوهای هندسی بین دسته های مشابه را حفظ نمود. این تنظیم دقت تحلیل خوشه بندی را افزایش داده و با تلفیق دسته های دارای هم راستایی، گروه های درزه ای با پیوستگی فضایی و هندسی بهینه تری را شناسایی کرد. نتایج تحلیل واریانس برای دسته بندی بهینه ^{۳۱} در جدول ۴ ارائه شده است:

جدول ۴: نتایج تحلیل واریانس برای ارزیابی کیفیت خوشه بندی

در فرآیند AHC

مؤلفه	مقدار مطلق	درصد از واریانس کل
واریانس درون خوشه ای	۰٫۰۷۳	۷٫۴۷
واریانس بین خوشه ای	۰٫۹۱۰	۹۲٫۵۳
واریانس کل	۰٫۹۸۴	۱۰۰٫۰۰

واریانس کم درون خوشه ای ۰٫۰۷۳ (معادل ۷٫۴۷ درصد از کل واریانس) و واریانس زیاد بین خوشه ای ۰٫۹۱۰ (۹۲٫۵۳ درصد از کل واریانس) نشان دهنده انسجام بالای داخل هر خوشه و تفکیک مؤثر میان خوشه ها است. این نتایج حاکی از عملکرد مطلوب الگوریتم پیشنهادی در گروه بندی دسته های درزه با ویژگی های مشابه است. فرآیند ادغام و



شکل ۲: نمایش گرافیکی موقعیت مراکز خوشه های درزه ها در منطقه مورد مطالعه در مرحله نهایی الگوریتم K-means.


۲-۳- بهینه سازی خوشه بندی با روش سلسله مراتبی تجمعی

در این مطالعه، برای بهینه سازی خوشه بندی و تلفیق دسته های درزه با بیشترین همبستگی فضایی، از روش سلسله مراتبی تجمعی ^{۲۸} (AHC) به عنوان مکمل الگوریتم K-means استفاده شد. مراکز ۱۲ خوشه اولیه به عنوان مبنای ادامه تحلیل انتخاب و الگوریتم AHC بر اساس معیار شباهت بر آن ها اعمال گردید. این رویکرد با ادغام تدریجی داده ها، الگوی سلسله مراتبی ایجاد نمود و همبستگی فضایی بردارهای قطب درزه ها را بر پایه معیار شباهت کسینوسی ^{۲۹} بررسی کرد. برای دستیابی به دسته بندی دقیق تر و شناسایی تعداد بهینه ای از خوشه ها، از روش پیوند میانگین بدون وزن زوج ها ^{۳۰} استفاده شد. این روش امکان شناسایی دسته های

جدول ۵: نتایج تحلیل واریانس برای ارزیابی کیفیت خوشه‌بندی نهایی با روش اصلاح شده AHC

مؤلفه	مقدار مطلق	درصد از واریانس کل
واریانس درون خوشه‌ای	۰/۱۸۵	۱۶/۳۶
واریانس بین خوشه‌ای	۰/۹۴۶	۸۳/۶۴
واریانس کل	۱/۱۳۱	۱۰۰/۰۰

شکل ۴: دندروگرام گروه‌بندی نهایی دسته‌های درزه‌ها را با استفاده از الگوریتم سلسله‌مراتبی تجمعی (AHC) نشان می‌دهد و همبستگی فضایی میان دسته‌ها را مشخص می‌کند. خوشه‌های نزدیک از نظر جهت‌گیری فضایی شباهت بیشتری با یکدیگر دارند که این ویژگی امکان تحلیل دقیق‌تر و سازمان‌دهی بهتر درزه‌ها را فراهم می‌آورد.




شکل ۴: دندروگرام خوشه‌بندی سلسله‌مراتبی نهایی دسته‌های درزه بر اساس معیار شباهت اصلاح شده کسینوسی.

در تحلیل دندروگرام با سطح برش ۰/۸۸۶، درزه‌ها به شش گروه جدید و نهایی با ویژگی‌های متمایز تقسیم شدند. واریانس بالای بین خوشه‌ای (۸۳/۶۴ درصد) نشان‌دهنده تفکیک واضح خوشه‌ها و تمایز در جهت‌گیری فضایی درزه‌ها است. خوشه‌های ۱، ۲ و ۳ هر کدام با یک عضو (مرکز خوشه مرحله قبل)، انسجام و یکنواختی بالایی در ویژگی‌های هندسی و فضایی نشان می‌دهند که احتمالاً به درزه‌های پایدار و مشابه در ویژگی‌های زمین‌شناسی منطقه مرتبط هستند. در مقابل خوشه‌های ۴، ۵ و ۶ که به ترتیب شامل چهار، سه و دو عضو (مراکز خوشه‌های مرحله قبل)، واریانس درون خوشه‌ای بیشتر، نشان‌دهنده تنوع بالاتر در ویژگی‌های هندسی و تأثیر فرآیندهای تکتونیکی پیچیده‌تر است.

برای ارزیابی دقت و اعتبار نتایج خوشه‌بندی، تحلیل واریانس نشان داد که واریانس بین خوشه‌ای به طور معناداری بیشتر از واریانس درون خوشه‌ای است که بیانگر تفکیک مناسب خوشه‌ها و انسجام بالا درون هر خوشه است. شناسایی و حذف داده‌های پرت در مراحل اولیه، همراه با استفاده از معیارهای فاصله اقلیدسی و شباهت کسینوسی و

خوشه‌بندی نهایی در دندروگرام شکل ۳ روابط سلسله‌مراتبی بین دسته‌های درزه‌ها را نشان می‌دهد.



شکل ۳: دندروگرام خوشه‌بندی سلسله‌مراتبی دسته‌های درزه بر اساس معیار شباهت کسینوسی.

نتایج دندروگرام نشان می‌دهد که با اعمال سطح برش ۰/۸۸۶ و استفاده از معیار شباهت کسینوسی، دسته‌های درزه با بیشترین همبستگی فضایی (هم‌جهتی فضایی) در ۹ خوشه نهایی گروه‌بندی شده‌اند. این انسجام دندروگرام، شناسایی خوشه‌هایی با الگوهای فضایی مشابه را در سطوح مختلف شباهت زاویه‌ای تسهیل کرده است.

در راستای افزایش دقت و یکپارچگی خوشه‌بندی، از زاویه حاده بین بردارهای قطب به عنوان معیار شباهت در ماتریس مجاورت^{۳۲} استفاده شد. این اصلاح از جداسازی نادرست درزه‌ها جلوگیری کرده و امکان ادغام بهینه دسته‌های مشابه را فراهم ساخت. پس از اصلاح معیار شباهت کسینوسی و اعمال مجدد خوشه‌بندی سلسله‌مراتبی تجمعی (AHC) با روش پیوند میانگین بدون وزن^{۳۳}، سازمان‌دهی خوشه‌ها به طور قابل توجهی بهبود یافت.

استفاده از سطح برش^{۳۴} ۰/۸۸۶ (معادل زاویه همبستگی ۳۰ درجه) در این فرآیند، موجب افزایش انسجام درون خوشه‌ای و تفکیک دقیق‌تر دسته‌های درزه‌ها شد و در نهایت، شش خوشه نهایی با ویژگی‌های فضایی بهینه شناسایی شد. نتایج تحلیل واریانس نشان داد که واریانس درون خوشه‌ای برابر با ۰/۱۸۵ (۱۶/۳۶ درصد از واریانس کل) و واریانس بین خوشه‌ای برابر با ۰/۹۴۶ (۸۳/۶۴ درصد از واریانس کل) است که نشان‌دهنده کیفیت بالای هر خوشه و تفکیک مؤثر بین خوشه‌ها است. این نتایج تأکید می‌کنند که روش پیشنهادی به طور مؤثری هماهنگی الگوهای هندسی و همبستگی فضایی درزه‌ها را بهبود داده است. جدول ۵ خلاصه‌ای از نتایج تحلیل واریانس برای گروه‌بندی بهینه نهایی را ارائه و کیفیت بالای این فرآیند را نشان می‌دهد.

فراهم کرده است. این رویکرد علاوه بر دستیابی به خوشه بندی بهینه، درک بهتری از تنوع و توزیع فضایی درزه ها و ویژگی های زمین شناسی منطقه ارائه می دهد. ویژگی های هندسی و آماری خوشه ها که در جدول ۶ ارائه شده است، مبنای مناسبی برای تحلیل های آتی و شناسایی الگوهای موجود در مجموعه داده ها فراهم می آورد. نتایج نشان می دهند که شش دسته درزه نهایی (J1 تا J6) دارای توزیع فضایی و هندسی متفاوتی هستند که تحت تأثیر عوامل زمین شناسی و ساختاری منطقه قرار دارند. کمترین واریانس درون دسته های متعلق به دسته های J1 و J2 (۰/۰۲۸) است که نشان دهنده انسجام بالای هندسی این دسته درزه ها است، در حالی که بیشترین واریانس مربوط به دسته J5 (۰/۰۹۱) است که نمایانگر تنوع بالاتر در این دسته درزه است. به طور کلی دسته های با واریانس بیشتر احتمالاً تحت تأثیر فرآیندهای پیچیده تری در شکل گیری درزه ها قرار دارند. نمودارهای شکل ۵ توزیع فضایی شش دسته درزه نهایی را از طریق نگاشت های دوبعدی بردارهای قطب در راستای محورهای مختصات نمایش می دهند.

تنظیم سطح برش دندروگرام با زاویه همبستگی، به بهبود کیفیت خوشه بندی و تقویت انسجام خوشه ها منجر شد و خوشه های نهایی با بیشترین همبستگی فضایی و هندسی مشخص گردید. مقایسه روش ترکیبی K-means و AHC با روش های متعارف نشان داد که این رویکرد توانایی بالاتری در تفکیک دسته های درزه ها دارد و در شناسایی الگوهای پیچیده زمین شناسی عملکرد بهتری از خود نشان می دهد. در نهایت، داده های حاصل از خوشه بندی با ویژگی های زمین شناسی منطقه مقایسه شده و نتایج با اطلاعات حاصل از بازدیدهای صحرایی و مشاهدات زمینی تطابق بالایی را نشان داد که بر اعتبار و کارایی روش در تحلیل های پایداری و طراحی های مهندسی تأکید دارد.


۳-۳- الگوهای فضایی و جهتی درزه ها بر اساس تحلیل خوشه بندی

ترکیب نتایج خوشه بندی اولیه حاصل از الگوریتم K-means با الگوریتم سلسله مراتبی تجمعی (AHC) و ماتریس شباهت کسینوسی اصلاح شده، به طور مؤثری امکان شناسایی دقیق تر و تحلیل جامع تر الگوهای فضایی و جهتی درزه ها را

جدول ۶: ویژگی های هندسی و آماری خوشه های درزه های نهایی بر اساس تحلیل دندروگرام با سطح برش ۰/۸۶۶

دسته درزه نهایی	گروه بندی درزه های اولیه*	تعداد درزه ها	واریانس درون دسته ای	مؤلفه X بردار قطب	مؤلفه Y بردار قطب	مؤلفه Z بردار قطب	موقعیت قطب (آزیموت و شیب)
J1	C1	۶	۰/۰۲۸	-۰/۰۳۳	-۰/۰۱۳	۰/۹۸۸	Az ۲۴۸, ۹<۸۷, ۹
J2	C2	۱۵	۰/۰۲۸	۰/۷۷۷	۰/۱۵۱	۰/۵۹	Az ۷۹<۳۶, ۷
J3	C4	۱۵	۰/۰۴۶	-۰/۰۱۷	-۰/۰۹۴۸	۰/۲۴۲	Az ۱۸۱<۱۴, ۳
J4	((C5, C6), (C7, C10))	۶۹	۰/۰۶۵	۰/۴۴۹	۰/۸۳۷	۰/۱۳۱	Az ۲۸, ۲<۷, ۹
J5	((C8, C12), C3)	۲۸	۰/۰۹۱	-۰/۸۸۷	-۰/۳۰۵	۰/۱۹۷	Az ۲۵۱<۱۱, ۹
J6	(C9, C11)	۱۸	۰/۰۴۹	۰/۸۶۵	-۰/۴۶۳	۰/۰۵۵	Az ۱۱۸, ۲<۳, ۲

* نحوه تلفیق خوشه های اولیه (K-Means) توسط AHC



شکل ۵: توزیع فضایی دسته درزه های نهایی با نگاشت های دوبعدی بردارهای قطب در راستای محورهای مختصات.


باشند، درحالی‌که در شرایط تنش فشاری، این تقاطع‌ها اغلب با گسل‌های معکوس همراه هستند. تقاطع‌های با شیب متوسط (۱۰ تا ۵۰ درجه) بیشتر تحت تأثیر تنش‌های برشی بوده و معمولاً با گسل‌های امتدادلغز ارتباط دارند. در مقابل، تقاطع‌های با شیب زیاد (بیش از ۵۰ درجه) نشان‌دهنده مناطقی با تنش‌های برشی شدید هستند که در آن‌ها گسل‌های امتدادلغز غالب بوده و احتمال ناپایداری دیواره‌های سنگی افزایش می‌یابد. این تحلیل، با تأکید بر نقش تقاطع‌های درزه در ارزیابی پایداری توده‌های سنگی و مدیریت ریسک‌های مرتبط، می‌تواند به‌عنوان مبنایی برای مطالعات ژئوتکنیکی و تحقیقات آینده در مناطق مشابه مورد استفاده قرار گیرد.

۳-۴- تحلیل جهت‌گیری و ویژگی‌های درزه‌ها بر فرایند استخراج و پایداری توده گرانیته

جهت‌گیری‌ها و ویژگی‌های درزه‌ها در توده گرانیتهی لوچو، تأثیرات عمیقی بر فرایند استخراج و پایداری دیواره‌های معدن سنگ ساختمانی دارند. این درزه‌ها نمایانگر نیروهای تکتونیکی منطقه‌ای هستند که ساختار سنگ را شکل داده و بر شیوه‌های استخراج و پایداری عملیات معدن تأثیر می‌گذارند. در این بخش انواع مختلف درزه‌ها و تأثیرات آن‌ها بر استخراج و پایداری دیواره‌های معدن گرانیته لوچو مورد تحلیل قرار می‌گیرند. درزه‌های رهایی معمولاً تحت تأثیر تنش‌های کششی افقی یا نزدیک به افقی در توده‌های گرانیته، شکل می‌گیرند. درزه‌های با شیب افقی (J_1) به‌ویژه تحت تأثیر تنش‌های کششی تکتونیکی عمود بر سطح ایجاد می‌شوند و با شیب کم حدود ۲ درجه و جهت تقریباً افقی مشخص می‌گردند. این نوع درزه‌ها در استخراج بلوک‌های بزرگ سنگ مفید هستند، زیرا انرژی کمتری برای جداسازی بلوک‌ها نیاز است و خطر شکستن در امتداد سطح درزه نسبت به درزه‌های عمودی یا شیب‌دار کمتر است. این ویژگی باعث تسهیل فرایند استخراج و کاهش نیاز به روش‌های پیچیده برش می‌شود. با این حال، درعین حال که این درزه‌ها به استخراج کمک می‌کنند، مشکلاتی در پایداری دیواره‌های معدن به وجود می‌آید، به‌ویژه اگر سنگ‌های اطراف همبستگی کافی نداشته باشند. تنش‌های کششی که این درزه‌ها را ایجاد کرده‌اند، می‌توانند باعث ناپایداری دیواره‌ها شوند؛ بنابراین، تقویت دیواره‌ها برای جلوگیری از مشکلات ناپایداری در این نوع درزه‌ها ضروری است. درزه‌های با شیب

این نمودارها (شکل ۵) با بهره‌گیری از روش‌های داده‌کاوی و خوشه‌بندی، امکان تحلیل دقیق‌تری را نسبت به ابزارهای متعارف مانند استریونت فراهم کرده و اطلاعات جامعی از ویژگی‌های هندسی و فضایی درزه‌ها ارائه می‌دهند. توزیع فضایی قطب‌ها و جهت‌گیری دسته‌های درزه الگوهای شکل‌گیری و پراکندگی ساختارهای زمین‌شناسی منطقه را نشان می‌دهد. این تحلیل‌ها با نقش مؤثر خود در مطالعات زمین‌شناسی ساختاری و اکتشافی، می‌توانند در مدل‌سازی تنش‌های منطقه‌ای، طراحی سازه‌های عمرانی و معدنی و مدیریت خطرات زمین‌ساختی مورد استفاده قرار گیرند.

نمودار استریوگرافیکی شکل ۶ الگوی توزیع جهت‌گیری درزه‌ها در گرانیته لوچو را نمایش می‌دهد. این نمودار با نشان دادن موقعیت و تراکم قطب‌های درزه‌ها، امکان تحلیل روابط فضایی آن‌ها و تأثیر تنش‌های ناشی از گسل‌خوردگی و شرایط زمین‌ساختی را فراهم می‌کند. پس از تفکیک دسته‌های مختلف، تحلیل چگالی کانتور بردارهای قطب با استفاده از توزیع فیشر انجام شده است. هر دسته درزه با نمادها و رنگ‌های مشخص تفکیک و توزیع فضایی آن‌ها بر اساس چگالی نمایش داده شده است. نواحی با چگالی بالاتر نشان‌دهنده تمرکز بیشتر قطب‌ها و جهت‌های غالب درزه‌ها هستند. همچنین، محل‌های فصل مشترک صفحات درزه‌های مختلف در این شکل قابل مشاهده است.



شکل ۶: نمودار استریوگرافیکی جهت‌گیری و تراکم درزه‌ها و محل تقاطع آن‌ها در گرانیته لوچو.

تصویر استریوگرافیکی شکل ۶ با نمایش تقاطع‌های صفحات دسته‌های درزه بر اساس روند^{۳۵} و شیب^{۳۶}، امکان ارزیابی اثرات آن‌ها بر رفتار مکانیکی و پایداری توده‌های سنگی را فراهم می‌کند. تقاطع‌های با شیب کم (کمتر از ۱۰ درجه) معمولاً در شرایط تنش کششی به‌عنوان نقاط ضعف مکانیکی عمل کرده و ممکن است با گسل‌های نرمال مرتبط

بهبود پایداری کلی آن شود. با توجه به توانایی این روش ها در تحلیل مسائل پیچیده و چندبعدی، می توانند در آینده به طور گسترده برای بهینه سازی استخراج و طراحی معادن به کار گرفته شوند و در کاهش خطرات ناشی از ساختارهای درزه ای و ناپایداری های مرتبط ایفا کنند.

۳-۵- نتیجه گیری

در این پژوهش با استفاده از یک رویکرد ترکیبی مبتنی بر الگوریتم های K-means و AHC، تحلیل و خوشه بندی دقیق درزه های توده گرانیتهی لوچو در زاهدان انجام و شش خوشه مجزا با ویژگی های هندسی و فضایی مشخص شناسایی شد. نتایج نشان داد که در مرحله اول، الگوریتم K-means با معیار فاصله اقلیدسی خوشه بندی اولیه مناسبی انجام داده است و در مرحله بعد، با استفاده از الگوریتم AHC و معیار شباهت کسینوسی، خوشه های اولیه اصلاح و ادغام شدند. انتخاب سطح برش ۰.۸۶۶ منجر به تشکیل خوشه های بهینه ای با کمترین واریانس درون خوشه ای و بیشترین انسجام فضایی شد. این روش علاوه بر حذف داده های پرت که ناشی از درزه های غیرسیستماتیک و خطاهای برداشت بود، دقت و قابلیت اطمینان تحلیل ها را به طور قابل توجهی افزایش داد. تحلیل توزیع فضایی خوشه ها نشان داد که الگوهای درزه در این توده گرانیتهی تحت تأثیر نیروهای تکتونیکی مانند فشار، کشش و برش شکل گرفته اند که منجر به تنوع در شیب ها و جهت گیری های درزه ها می شود. درزه های با شیب زیاد (J3، J4، J5 و J6) به دلیل خطر بالای ریزش سنگ ها و جدایش بلوک ها، نیازمند برنامه ریزی دقیق برای تقویت دیواره ها و به کارگیری روش های برش مؤثر در استخراج سنگ هستند. در مقابل درزه های با شیب کمتر (J1 و J2)، با وجود خطر کمتر، همچنان به مدیریت مؤثر نیاز دارند. این تحقیق با ارائه توزیع فضایی دقیق تر درزه ها، مبنای مناسبی برای مدل سازی عددی و تحلیل های ژئومکانیکی فراهم کرده است. نتایج این پژوهش در برنامه ریزی استخراج معادن، طراحی تونل ها، ارزیابی پایداری شیب ها و مدل سازی مکانیکی رفتار توده های سنگی قابل استفاده است. همچنین، گسترش این رویکرد به داده های بزرگ تر و شبیه سازی دقیق تر می تواند به درک بهتر توزیع فضایی درزه ها و ساختارهای زمین شناسی کمک کند. در تحقیقات آینده، به کارگیری روش های تصمیم گیری چندمعیاره در کنار الگوریتم های بهینه سازی می تواند

متوسط (J2) معمولاً تحت تأثیر تنش های قائم حداقل شکل می گیرند و با گسل های معکوس مرتبط هستند.

این درزه ها با شیب حدود ۵۴ درجه به سمت جنوب غرب مشخص می شوند و معمولاً باعث پیچیدگی در فرآیند استخراج می شوند. این درزه ها به ویژه در استخراج بلوک های بزرگ و سالم مشکل ایجاد کرده و می توانند موجب جدایش بلوک های سنگی شوند و خطر ریزش و ناپایداری دیواره های معدن را افزایش دهند. تنش های برشی یا فشاری که در این درزه ها وجود دارند، نیاز به استفاده از روش های بهینه سازی استخراج و تقویت دیواره ها برای کاهش خطرات احتمالی را به وجود می آورند. به همین دلیل، فرآیند استخراج در این نوع درزه ها پیچیده تر از درزه های افقی است و باید با دقت و احتیاط بیشتری انجام گیرد.

درزه های با شیب زیاد (J3، J4، J5، J6) عمدتاً تحت تأثیر تنش های کششی القایی یا تنش های برشی ناشی از فعالیت گسل های امتدادلغز شکل می گیرند که این فرآیندها به تغییرات تنش موضعی در محیط های تکتونیکی مرتبط هستند. این درزه ها با شیب های بیش از ۷۵ درجه تا نزدیک به عمودی (۸۷ درجه)، به عنوان سطوح ناپیوستگی یا برشی طبیعی در فرآیند استخراج سنگ عمل می کنند و با کاهش هزینه جداسازی بلوک ها، امکان تسهیل استخراج را فراهم می آورند. با این حال، وجود این درزه ها چالش هایی در زمینه حفظ پایداری دیواره های معدن ایجاد می کند، زیرا تغییرات شدید تکتونیکی می توانند منجر به جدایش بلوک ها و افزایش خطر ریزش و لغزش سنگ ها شوند؛ بنابراین، علاوه بر بهره گیری از این درزه ها برای تسهیل استخراج، استفاده از روش های تقویتی پیشرفته و تکنیک های برش مؤثر برای حفظ پایداری دیواره ها و جلوگیری از ریزش سنگ ها ضروری است. مدیریت صحیح این ساختارها نقش کلیدی در کاهش خطرات ناشی از ناپایداری دارد. در این راستا، استفاده از روش های تصمیم گیری چندمعیاره^{۳۷} می تواند در ارزیابی و بهینه سازی فرآیندهای مرتبط با مهندسی معدن و زمین شناس مهندسی نقش مهمی ایفا کند [۵۹-۵۷]. این روش ها با بهبود فرآیند تصمیم گیری در شرایط پیچیده زمین شناسی و تکتونیکی، به بهینه سازی طراحی معادن و تحلیل قابلیت اطمینان سازه های مهندسی کمک می کنند [۶۰-۶۲]. به ویژه ترکیب روش های تصمیم گیری چندمعیاره با الگوریتم های بهینه سازی، می تواند منجر به توسعه استراتژی های استخراج بهینه، تقویت دیواره های معدن و

system by k-means and fuzzy c-means clustering algorithms. *Journal of Analytical and Numerical Methods in Mining Engineering*. 5(9): 73-84 (In Persian).

[13] Nikadat, N., & Yarahmadi Bafghi, A. (2014). Estimating Joint Normal and Shear Stiffness Coefficient Using Statistical Methods. *Journal of Analytical and Numerical Methods in Mining Engineering*. 3(6): 93-103 (In Persian).

[14] Liu, Y., Chen, J., Tan, C., Zhan, J., Song, S., Xu, W., Yan, J., Zhang, Y., Zhao, M., & Wang, Q. (2022). Intelligent scanning for optimal rock discontinuity sets considering multiple parameters based on manifold learning combined with UAV photogrammetry. *Engineering Geology*. 309: 106851.

[15] Farmakis, I., DiFrancesco, P.-M., Hutchinson, D. J., & Vlachopoulos, N. (2022). Rockfall detection using LiDAR and deep learning. *Engineering Geology*. 309: 106836.

[16] Chen, Q., Ge, Y., & Tang, H. (2024). Rock discontinuities characterization from large-scale point clouds using a point-based deep learning method. *Engineering Geology*. 337: 107585.

[17] Zangana, H. M., & Abdulazeez, A. M. (2023). Developed Clustering Algorithms for Engineering Applications: A Review. *International Journal of Informatics, Information System and Computer Engineering (INJIISCOM)*. 4(2): 147-169.

[18] Bouveyron, C., Hammer, B., & Villmann, T. (2012). Recent developments in clustering algorithms. *ESANN*,

[19] Alasali, T., & Ortakci, Y. (2024). Clustering Techniques in Data Mining: A Survey of Methods, Challenges, and Applications. *Computer Science*. 9(1): 32-50.

[20] Han, J., Pei, J., & Tong, H. (2022). Data mining: concepts and techniques. Morgan kaufmann.

[21] Zaremotlagh, S., Hezarkhani, A., & Sadeghi, M. (2016). Detecting homogenous clusters using whole-rock chemical compositions and REE patterns: A graph-based geochemical approach. *Journal of Geochemical Exploration*. 170: 94-106.

[22] Michalak, M., Turoboś, F., & Gladki, P. (2022). Explainable Clustering Models for Structural Geology Measurements. AGU Fall Meeting Abstracts,

[23] Tokhmechi, B., Memarian, H., Moshiri, B., Rasouli, V., & Noubari, H. A. (2011). Investigating the validity of conventional joint set clustering methods. *Engineering Geology*. 118(3-4): 75-81.

[24] Yang, X., Li, S., Liang, K., Nie, F., & Lin, L. (2022). Structured graph optimization for joint

راهکارهای مؤثرتری برای بهینه‌سازی فرآیندهای استخراج، تقویت دیواره‌های معدن و افزایش پایداری کلی آن ارائه دهد.

مراجع

[1] Hoek, E., & Brown, E. T. (1980). Empirical strength criterion for rock masses. *Journal of the geotechnical engineering division*. 106(9): 1013-1035.

[2] Rafiei Renani, H., & Cai, M. (2022). Forty-year review of the Hoek–Brown failure criterion for jointed rock masses. *Rock mechanics and rock engineering*. 55(1): 439-461.

[3] Wyllie, D. C., & Mah, C. (2017). *Rock slope engineering*. CRC Press.

[4] Delaney, R. K., Shakoob, A., & Watts, C. F. (2020). Evaluating the use of unmanned aerial systems (UAS) for collecting discontinuity orientation data for rock slope stability analysis. *Environmental & Engineering Geoscience*. 26(4): 427-447.

[5] Wang, Y., Zhou, J., Chen, Q., Chen, J., Zhu, C., & Li, H. (2024). Automatic interpretation of geometric information of discontinuities and its influence on the stability of highly-jointed rock slopes. *Journal of Rock Mechanics and Geotechnical Engineering*.

[6] Waldron, J., & Snyder, M. (2020). *Geological Structures: A practical introduction*.

[7] Lee, C.-Y., & Wang, I.-T. (2011). Analysis of highway slope failure by an application of the stereographic projection. *International Journal of Geological and Environmental Engineering*. 5(3): 122-129.

[8] To, P., & Sivakugan, N. (2023). Analytical solution for rock discontinuity prediction without stereonet. *Geotechnical and Geological Engineering*. 41(7): 4311-4320.

[9] Lisle, R. J., & Leyshon, P. R. (2004). *Stereographic projection techniques for geologists and civil engineers*. Cambridge University Press.

[10] Qu, H., Pan, M., Ming, J., Wu, Z., & Sun, Z. (2008). An efficient method for high-precision 3D geological modeling from intersected folded cross-sections. *Acta Scientiarum Naturalium Universitatis Pekinensis*. 44(6): 915-920.

[11] Abdollahipour, A., & Mansouri, H. (2013). SETDISC a Software for Joint Classification Based on Poisson Clustering. *Journal of Analytical and Numerical Methods in Mining Engineering*. 2(4): 11-19 (In Persian).

[12] Jalali, Z., & Mousavi Nasab, S. M. (2015). Modification of rock mass rating classification

- clustering. *International Journal of Emerging Trends in Engineering Research*. 8(5).
- [37] Govender, P., & Sivakumar, V. (2020). Application of k-means and hierarchical clustering techniques for analysis of air pollution: A review (1980–2019). *Atmospheric pollution research*. 11(1): 40-56.
- [38] Dulanjalee, P., & Gunathilake, J. (2017). Rock Slope Stability Assessment Using Stereographic Projection Method and Limit Equilibrium Analysis. *Advancing Culture of Living with Landslides: Volume 4 Diversity of Landslide Forms*,
- [39] Kınca, C. (2014). Application of two new stereographic projection techniques to slope stability problems. *International Journal of Rock Mechanics and Mining Sciences*. 66: 136-150.
- [40] Dershowitz, W., & Einstein, H. (1988). Characterizing rock joint geometry with joint system models. *Rock mechanics and rock engineering*. 21(1): 21-51.
- [41] Biabangard, H., Fatameian, M., Moridi Farimani, A., & Bakhshi Mohabi, M. (2017). Petrography, geochemistry and tectono-magmatic setting of the dykes of the north and the west of Zahedan (Southeast Iran). *Petrology*. 8(31): 147-164 (In Persian).
- [42] Ghasemi, H., Sadeghian, M., Kord, M., & Khanalizadeh, A. (2010). The evolution mechanism's of Zahedan granitoidic batholith, southeast Iran [Research]. *Iranian Journal of Crystallography and Mineralogy*. 17(4): 551-578 (In Persian).
- [43] Sadeghian, M., & Valizadeh, M. V. (2008). Emplacement Mechanism of Zahedan Granitoidic Pluton with the Aid of AMS Method. *Scientific Quarterly Journal of Geosciences*. 17(66): 134-159 (In Persian).
- [44] Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern recognition letters*. 31(8): 651-666.
- [45] Blömer, J., Lammersen, C., Schmidt, M., & Sohler, C. (2016). Theoretical analysis of the k-means algorithm—a survey. *Algorithm Engineering: Selected Results and Surveys*: 81-116.
- [46] Zhou, J.-w., Chen, J.-l., & Li, H.-b. (2024). An optimized fuzzy K-means clustering method for automated rock discontinuities extraction from point clouds. *International Journal of Rock Mechanics and Mining Sciences*. 173: 105627.
- [47] Tang, N., Wang, L., Jiang, H., Huang, X., Tan, G., & Zhou, X. (2023). A new clustering method of rock discontinuity sets based on modified K-means algorithm. *Bulletin of Engineering Geology and the Environment*. 82(11): 415.
- spectral embedding and clustering. *Neurocomputing*. 503: 62-72.
- [25] Shang, X., Li, X., Morales-Esteban, A., Dong, L., & Peng, K. (2017). K- Means Cluster for Seismicity Partitioning and Geological Structure Interpretation, with Application to the Yongshaba Mine (China). *Shock and Vibration*. 2017(1): 5913041.
- [26] Caumon, G., Collon-Drouaillet, P., Le Carlier de Veslud, C., Viseur, S., & Sausse, J. (2009). Surface-based 3D modeling of geological structures. *Mathematical geosciences*. 41: 927-945.
- [27] Zhao, Y., Li, A., Du, Z., Chen, Y., Sun, H., & Zhi, Z. (2024). Joint Structure Detection and Multi-Scale Clustering Filtering for Tunnel Lining Extraction From Point Clouds. *IEEE Transactions on Intelligent Transportation Systems*.
- [28] Ma, Y., Lin, H., Wang, Y., Huang, H., & He, X. (2021). A multi-stage hierarchical clustering algorithm based on centroid of tree and cut edge constraint. *Information Sciences*. 557: 194-219.
- [29] Fazli, M., Bertram, R., & Striegel, D. A. (2024). Multi-layer Bundling as a New Approach for Determining Multi-scale Correlations Within a High-Dimensional Dataset. *Bulletin of Mathematical Biology*. 86(9): 105.
- [30] Chen, S., Zhang, F., Zhang, Z., Yu, S., Qiu, A., Liu, S., & Zhao, X. (2023). Multi-Scale Massive Points Fast Clustering Based on Hierarchical Density Spanning Tree. *ISPRS International Journal of Geo-Information*. 12(1): 24.
- [31] Wang, J., Wu, B., Ren, Z., Zhang, H., & Zhou, Y. (2023). Multi-scale deep multi-view subspace clustering with self-weighting fusion and structure preserving. *Expert Systems with Applications*. 213: 119031.
- [32] Murtagh, F., & Contreras, P. (2012). Algorithms for hierarchical clustering: an overview. *Wiley interdisciplinary reviews: data mining and knowledge discovery*. 2(1): 86-97.
- [33] Gupta, A., Sharma, H., & Akhtar, A. (2021). A comparative analysis of k-means and hierarchical clustering. *EPRA International Journal of Multidisciplinary Research (IJMR)*. 7(8).
- [34] Abdulhafedh, A. (2021). Incorporating k-means, hierarchical clustering and pca in customer segmentation. *Journal of City and Development*. 3(1): 12-30.
- [35] Liu, Y., & Li, B. (2020). Bayesian hierarchical K-means clustering. *Intelligent Data Analysis*. 24(5): 977-992.
- [36] Karthikeyan, B., George, D. J., Manikandan, G., & Thomas, T. (2020). A comparative study on k-means clustering and agglomerative hierarchical

constraints: Theoretical and empirical results. European Conference on Principles of Data Mining and Knowledge Discovery,

[57] Bejari, H., Daya, A., & Roudini, A. (2017). Selection of chromite processing plant site using fuzzy analytic hierarchy process (FAHP). *Journal of Mining and Environment*. 8(2): 155-162.

[58] Ahmadi Khounsarakhi, V., Uromeihy, A., Amiri, M., & Nikudel, M. (2024). Angouran mine access tunnel stability assessment using the experimental classification method and fuzzy hierarchical analysis (FAHP). *New Findings in Applied Geology*. 18(35): 47-66 (In Persian).

[59] Bagloo, H., & Ataee-pour, M. (2024). A Classification Model of Dimensional Stones Using AHP and Fuzzy Logic. *Geotechnical and Geological Engineering*. 42(2): 1173-1187.

[60] Ghanbarpour, A., Zaremotlagh, S., & Dabaghi-Zarandi, F. (2024). Addressing Dependent Data in Constrained Optimization Problems: A WOA-based Algorithm. *International Journal of Industrial Electronics Control and Optimization*. 7(2): 119-127.

[61] Yuan, Y.-l., Hu, C.-m., Li, L., Xu, J., & Hou, X.-h. (2024). Efficient slope reliability analysis using a surrogate-assisted normal search particle swarm optimization algorithm. *Journal of Computational Design and Engineering*. 11(1): 173-194.

[62] Li, P., Chen, T., Liu, Y., Cai, M., Sun, L., Wang, P., Wang, Y., & Zhang, X. (2025). Automatic Identification of Rock Discontinuity Sets by a Fuzzy C-Means Clustering Method Based on Artificial Bee Colony Algorithm. *Applied Sciences*. 15(3): 1497.

[48] Clero, K., Ed-Diny, S., Achalhi, M., Cherkaoui, M., Benzakour, I., Soror, T., Rzihi, S., El Fkihi, S., Nadour, M., & Tagemouati, H. (2024). Rock mass joint set identification at Draa Sfar mine in Morocco through stereographic projection and K-means clustering. *Mediterranean Geoscience Reviews*. 6(1): 49-56.

[49] Burkardt, J. (2009). K-means clustering. Virginia Tech, Advanced Research Computing, Interdisciplinary Center for Applied Mathematics.

[50] Suhui, W., Ying, C., Yanning, Z., & Yuntao, P. (2011). Survey on K-means Algorithm. *Data Analysis and Knowledge Discovery*. 27(5): 28-35.

[51] Muthén, B. O. (1989). Latent variable modeling in heterogeneous populations. *Psychometrika*. 54: 557-585.

[52] Muthén, B. O. (1994). Multilevel covariance structure analysis. *Sociological methods & research*. 22(3): 376-398.

[53] Hoff, P. D. (2009). A hierarchical eigenmodel for pooled covariance estimation. *Journal of the Royal Statistical Society Series B: Statistical Methodology*. 71(5): 971-992.

[54] Miyamoto, S. (2022). Theory of agglomerative hierarchical clustering (Vol. 15). Springer.

[55] Bouguettaya, A., Yu, Q., Liu, X., Zhou, X., & Song, A. (2015). Efficient agglomerative hierarchical clustering. *Expert Systems with Applications*. 42(5): 2785-2797.

[56] Davidson, I., & Ravi, S. (2005). Agglomerative hierarchical clustering with

²⁰ Proximity matrix

²¹ Box and Whisker

²² Upper Bound

²³ Clustering Criterion

²⁴ Iterations

²⁵ Convergence

²⁶ Initial Partition

²⁷ Random

²⁸ Agglomerative Hierarchical Clustering

²⁹ Cosine

³⁰ Unweighted Pair-Group Average Linkage

³¹ Variance decomposition for the optimal classification

³² Proximity matrix

³³ Unweighted Pair-Group Average

³⁴ Truncation

³⁵ Trend

³⁶ Plunge

³⁷ Multi-Criteria Decision-Making

¹ Multi-stage

² Multi-scale

³ Hierarchical Patterns

⁴ Hybrid approach

⁵ Outliers

⁶ Pole Vector

⁷ Data Point

⁸ Pooled Within Covariance Matrix

⁹ Clustering Criterion

¹⁰ Centroid

¹¹ Outliers

¹² Within-class Variance

¹³ Between-class Variance

¹⁴ Distance to centroid

¹⁵ Class centroids

¹⁶ Truncation

¹⁷ Cosine similarity

¹⁸ Unweighted Pair-Group Average Linkage

¹⁹ Truncation level