



دانشگاه آزاد اسلامی واحد اهر

فصلنامه‌ی علمی فضای جغرافیایی

دوره بیست و پنجم، شماره‌ی ۹۲

زمستان ۱۴۰۴، صفحات ۱۵۳-۱۳۶

علی حسینقلی زاده^۱

نجمه نیسانی سامانی^{۲*}

بکارگیری الگوریتم بهینه‌سازی ژنتیک در طبقه‌بندی نظارت‌نشده و مقایسه آن با روش‌های طبقه‌بندی K-means و ISO DATA

تاریخ پذیرش: ۱۴۰۱/۰۳/۱۸

تاریخ دریافت: ۱۴۰۰/۰۴/۳۱

چکیده

یکی از مهمترین روش‌های استخراج اطلاعات از تصاویر سنجش‌ازدور، طبقه‌بندی نظارت‌نشده است که به کاربران امکان تولید انواع اطلاعات از جمله نقشه‌های پوششی، کاربری و تغییرات را می‌دهد. این روش نیاز به داده آموزشی ندارد و الگوریتم طبق ویژگی‌های آماری، عملیات خوشه‌بندی را انجام می‌دهد. در این پژوهش در محیط کد نویسی MATLAB با تصاویر لندست-۸، به مقایسه روش‌های K-means و ISO DATA و الگوریتم ژنتیک در بخش‌هایی از شمال استان گلستان پرداخته شد. برای هر سه رویکرد شرایط بطور کامل ثابت در نظر گرفته شد تا مقایسه مناسب‌تری بین روش‌ها صورت گیرد. بمنظور اجرای الگوریتم ژنتیک از ۳۰ نقطه (کروموزم)، و جهت صحت سنجی و بررسی دقت نتایج برای هر طبقه، از ۱۰ نقطه حاصل از تصاویر Google earth به عنوان نقطه نمونه استفاده شد. نتایج نشان داد صحت کلی و ضریب کاپا در طبقه‌بندی نظارت‌نشده با استفاده از الگوریتم ژنتیک به ترتیب ۸۹ و ۸۶ درصد، K-means ۵۴ و ۴۷ درصد و در ISO DATA ۴۸ و ۴۲ درصد بدست آمد. بنابراین پیشنهاد می‌گردد با در نظر گرفتن هدف و شرایط موجود در پژوهش‌ها، استفاده از طبقه‌بندی نظارت‌نشده به کمک الگوریتم ژنتیک بویژه برای مناطقی که اطلاعات کافی از آن در دست نیست مورد بررسی قرار گیرد. کلیدواژه‌ها: الگوریتم ژنتیک، طبقه‌بندی نظارت‌نشده، Google earth، لندست ۸، استان گلستان

^۱ دانشجوی دکتری سنجش‌ازدور و سیستم اطلاعات جغرافیایی، دانشگاه تهران، تهران، ایران

^۲ گروه سنجش‌ازدور و سیستم اطلاعات جغرافیایی، دانشگاه تهران، تهران، ایران

مقدمه

در سال‌های اخیر استخراج اطلاعات پوشش سطح زمین با استفاده از سنجش‌ازدور، جنبه‌های کاربردی وسیعی پیدا کرده است (Qiao and wan, 2019). بطوریکه این نقشه‌های پوشش اراضی جزو مهمترین منابع اطلاعاتی در زمینه‌های مختلف علمی، نظیر بحث امنیت غذایی، مکان‌گزینی، مدیریت در بخش کشاورزی و برنامه‌های مربوط به گرم شدن عمومی هوا می‌باشند (Badreldin and Goossens, 2014). از طرفی تمامی عوارض سطح زمین دارای ویژگی‌هایی همچون رنگ، طیف، شکل و بافت هستند که برای طبقه‌بندی و انتخاب نقاط نمونه بسیار مؤثر است (Tilahun and Teferie, 2015; Usha and Vasuki, 2022). این ویژگی‌ها برای زمانی که منطقه مطالعاتی را می‌شناسیم و یا نقشه کاربری آن را در اختیار داریم بسیار مفید است. اما گاهی اوقات کاربر هیچ شناختی از منطقه ندارد تا طبقه‌بندی نظارت‌شده را با انتخاب نقاط آموزشی انجام دهد (Stolte, 2003; Faizi, 2020). در چنین شرایطی طبقه‌بندی نظارت‌نشده یا همان خوشه‌بندی گزینه مناسبی بنظر می‌رسد (Xu et al, 2019). در رویکرد نظارت‌نشده، کلاس‌ها ناشناخته هستند و تصویر به گروه‌ها (یا خوشه‌هایی) تقسیم می‌شود. بطور کلی در خوشه‌بندی نیاز به تعیین قبلی کلاس‌ها نیست بلکه خود الگوریتم بطور خودکار دسته‌های متمایز را پیدا می‌کند که باعث کاهش چشمگیر کار تحلیلی، هزینه و زمان می‌شود. به همین دلیل توجه بسیاری از پژوهشگران را به خود جلب نموده است (Pal et al, 2005). از دیگر مزیت‌های خوشه‌بندی هماهنگی با خصوصیات اشیا طبقه‌بندی شده است که با تغییر زمان بطور دینامیکی تغییر می‌کند. در این موارد استفاده از خوشه‌بندی یک راه حل مناسب برای نظارت بر این تغییرات است که در شرایط مشابه بسیار سریع‌تر از رویکرد نظارت‌شده عمل می‌کند (Omran and et al, 2005). از آنجا که هر کدام از داده‌ها در فرآیند طبقه‌بندی یک نقطه در فضای ویژگی است. تجزیه و تحلیل خوشه‌بندی، مجموعه داده‌ها را به تعداد معقولی از گروه‌های مجزا تقسیم می‌کند بطوریکه الگوهای همگنی بین داده‌های درون هر خوشه و الگوی ناهمگن با بیشترین فاصله بین خوشه‌ها وجود داشته باشد (Ghosh and etal, 2011).

از چالش‌های اصلی در سنجش‌ازدور، قرار دادن پیکسل‌های همگن در خوشه‌ها است. زیرا مناطق روی زمین پوشش‌های متفاوتی دارند و توزیع آن‌ها در تصویر نامنظم است. بطوریکه گاهی از یک نوع پوشش تعداد زیادی پیکسل با درجه خاکستری متفاوت وجود دارد، که قرار دادن آن‌ها در یک خوشه‌بندی صحیح همواره یکی از چالش‌های مهم بوده است. مسئله دیگر نداشتن هیچگونه اطلاعات زمینی برای خوشه‌بندی و عدم اطلاع از تعداد دقیق کلاس‌ها است که باعث عدم درک درست از منطقه می‌شود (Alok et al, 2016).

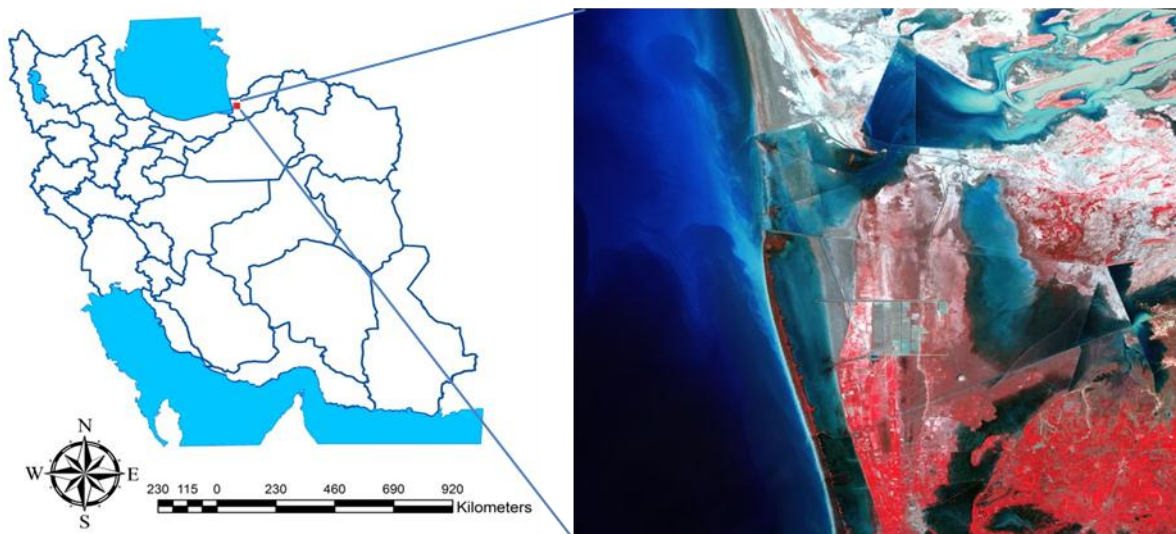
روش‌های طبقه‌بندی را می‌توان بر این اساس که از داده‌ها و اطلاعات غیر تصویری برای آنالیز تصویر استفاده می‌کنند به دو گروه روش‌های نظارت‌شده و نظارت‌نشده تقسیم‌بندی کرد. روش‌های نظارت‌شده علاوه بر داده‌های تصویری نیاز به یک سری اطلاعات جانبی و غیر تصویری در مورد منطقه و کلاس‌های مورد نظر دارند. در مقابل روش‌های نظارت‌نشده تنها از داده‌های تصویری برای طبقه‌بندی استفاده می‌کنند. روش‌های نظارت‌نشده در مقایسه با روش‌های نظارت‌شده اگر چه معمولاً به نتایج غیردقیق‌تری در طبقه‌بندی تصاویر سنجش‌ازدور منجر می‌گردند، اما اغلب به

صورت خودکار انجام می‌شوند، نیازمند داده‌ها و اطلاعات غیر تصویری نیستند و هزینه و زمان کمتری را صرف می‌کنند (Abburu and Golla., 2015). به همین دلیل، تاکنون پژوهش‌های بسیاری بر روی طبقه‌بندی تصاویر سنجنش‌ازدور با استفاده از روش‌های نظارت‌نشده انجام شده است (Rekik and Zribi., 2009; Lucas et al., 2020). طبقه‌بندی نظارت‌نشده تصاویر سنجنش‌ازدور معمولاً از طریق روش‌های خوشه‌بندی انجام می‌پذیرد. یکی از مشهورترین شیوه‌های خوشه‌بندی K-means و ISO DATA در آنالیز داده‌ها است. در این پژوهش قصد داریم این دو روش را با روش خوشه‌بندی ژنتیک مقایسه کنیم. تمامی وضعیت در هر سه روش ثابت در نظر گرفته می‌شود تا فقط خود الگوریتم‌ها در شرایط غیر نظارت‌شده مورد سنجنش قرار گیرد.

مواد و روش‌ها

محدوده مورد مطالعه

منطقه مورد مطالعه در ۴۰ کیلومتری شمال شهر بندر ترکمن در استان گلستان با طول جغرافیایی $53^{\circ}51'45''$ Long الی $54^{\circ}06'27''$ Long و عرض جغرافیایی $37^{\circ}10'41''$ Lat الی $37^{\circ}19'9''$ Lat در زون ۴۰ شمالی قرار دارد. شمال این منطقه به مرز بین‌المللی ایران و ترکمنستان، شرق به گل‌فشان گمیشان، جنوب به شهرستان گمیشان و غرب به دریای مازندران محدود می‌شود. این منطقه بدلیل قرار گرفتن در نزدیک ساحل دریای مازندران و ورود پساب‌های صنعتی و همچنین تغییرات بسیار زیاد آن در چند سال گذشته، به عنوان نمونه انتخاب شد تا روند خوشه‌بندی در آن مورد بررسی قرار گیرد. منطقه از نظر نوع آب‌وهوا براساس معیار کوپن بصورت معتدل مدیترانه‌ای و از نظر توپوگرافی کاملاً یکدست و شیب بسیار کم دارد. میانگین ارتفاع منطقه ۲۱ متر پایین‌تر از سطح دریا است (21m-). میانگین بارندگی و دمای آن نیز بر اساس آمار ایستگاه هواشناسی بندر ترکمن (نزدیک‌ترین ایستگاه به منطقه مورد مطالعه) در یک بازه زمانی ۱۰ ساله (۱۴۰۰-۱۳۹۰) به ترتیب ۴۶۲ میلی‌متر و ۱۸ درجه سانتی‌گراد است (شکل ۱).



شکل ۱: ایران و منطقه مورد مطالعه

Figure 1: Iran and the study area

پژوهش‌های پیشین

تاکنون استفاده‌های بسیاری از الگوریتم ژنتیک در حوزه‌های مختلف سنجش‌ازدور از جمله خوشه‌بندی صورت گرفته است که بطور خاص به مرور تعدادی از آن‌ها خواهیم پرداخت. Senthilnath و همکاران (۲۰۱۹) به خوشه‌بندی سلسه مراتبی، برای ارزیابی سیلاب، با استفاده از تصاویر سنجش‌ازدور چند سنسوره در چین پرداختند. آن‌ها روش‌های خوشه‌بندی سلسه مراتبی را بر روی (SAR) (در طی سیل) و LISS-III (قبل از سیل) بمنظور تجزیه و تحلیل آسیب‌های ناشی از آن استفاده نمودند. آن‌ها در این پژوهش ابتدا مناطق سیلابی و غیر سیلابی را از تصویر SAR و دیگر مناطق مختلف زمین را از تصویر LISS-III با استفاده از الگوریتم‌های بهینه یابی ژنتیک استخراج کردند. با معیار اطلاعات بیزی (BIC) محدودیت برای تعداد خوشه‌ها (حد مجاز) را محاسبه کردند. سپس مراکز بهینه خوشه‌ای را با استفاده از رویکرد خوشه‌بندی بدست آوردند. در مرحله بعد با روش‌های مختلف بهینه یابی GA و PSO بر روی داده‌های SAR و LISS-III خوشه‌ها را استخراج کردند. سرانجام مراکز خوشه‌ای بدست آمده را برای دسته‌بندی داده‌های مشابه با استفاده از روش ادغام در کلاس‌های مربوطه مورد استفاده قرار دادند. نتایج حاکی از بهبود نتایج بعد از استفاده از روش‌های بهینه یابی نسبت به روش ISO DATA داشت. MATCI و Avdan (۲۰۱۹) به مقایسه دقت طبقه‌بندی با کمک الگوریتم ژنتیک و مقایسه آن با طبقه‌بندی K-Means در تصاویر لندست ۸ پرداختند. نتایج نشان داد استفاده از الگوریتم ژنتیک دقت طبقه‌بندی را ۲۲ درصد افزایش می‌دهد. Ghrabat و همکاران (۲۰۱۹) به مقایسه طبقه‌بندی K-means و الگوریتم ژنتیک پرداختند. نتایج نشان داد استفاده از الگوریتم ژنتیک در طبقه‌بندی، نتایج بهتری نسبت به دو روش دیگر را در پی دارد. Chen و همکاران (۲۰۱۶) به کمک الگوریتم‌های ISO DATA و ژنتیک به طبقه‌بندی تصاویر لندست ۸ پرداختند. نتایج حاکی از کاهش خطا به میزان حدود ۲ درصد در هنگام استفاده از الگوریتم ژنتیک داشت. همچنین پژوهش‌های مشابه دیگری توسط Hassan (۲۰۱۳) و Merzougui (۲۰۱۸) صورت گرفته است. Senthilnath و همکاران (۲۰۱۶) به طبقه‌بندی تصاویر لندست با استفاده از الگوریتم ژنتیک و روش K-means در کالیفرنیا پرداختند. نتایج پژوهش حاکی از بهبود طبقه‌بندی نظارت‌نشده، با استفاده از الگوریتم ژنتیک در مقایسه با روش K-means را به همراه داشت.

مبانی نظری

الگوریتم ژنتیک

الگوریتم ژنتیک (GA)، الگوریتم بهینه‌سازی مبتنی بر تکرار است که از طبیعت درونی خود موجود زنده الهام گرفته شده که می‌توان از آن در مسائل مختلف از جمله طبقه‌بندی تصویر استفاده کرد. اساس این الگوریتم قانون تکامل داروین (بقای بهترین) است بر اساس این قانون موجودات ضعیف‌تر از بین می‌روند و موجودات قوی‌تر باقی می‌مانند. به عبارت دیگر بنا بر قانون انتخاب طبیعی، هر چه امکان تطبیق موجود با شرایط طبیعی آن بیشتر باشد بقای موجود امکان‌پذیرتر است و احتمال تولیدمثل بیشتری وجود دارد. الگوریتم ژنتیک به عنوان یک الگوریتم محاسباتی بهینه‌سازی با در نظر گرفتن مجموعه‌ای از نقاط فضای جواب در هر تکرار محاسباتی به نحو مؤثری نواحی مختلف فضای جواب را جستجو می‌کند (Bandyopadhyay, 2007). در این الگوریتم، در هر تکرار هر یک از رشته‌های

موجود در جمعیت، رمزگشایی شده و مقدار تابع هدف برای آن به دست می‌آید. بر اساس مقادیر به دست آمده تابع هدف، به هر رشته یک عدد برازندگی نسبت داده می‌شود. این عدد برازندگی احتمال انتخاب را برای هر رشته تعیین خواهد کرد که بر اساس این احتمال انتخاب، مجموعه‌ای از رشته‌ها انتخاب شده و با اعمال عملکردهای ژنتیکی روی آن‌ها، رشته‌های جدید جایگزین رشته‌هایی از جمعیت اولیه می‌شوند تا تعداد جمعیت رشته‌ها در تکرارهای محاسباتی مختلف ثابت باشد (Kutubi et al, 2018). به عبارت دیگر الگوریتم ژنتیک روشی تطبیقی است که برای حل مسائل نیازمند به جستجو و بهینه‌سازی، از جمله طبقه‌بندی استفاده می‌شود. یک طبقه‌بندی بدون نظارت (Unsupervised classification)، یک تصویر را بصورت پیکسل به پیکسل به کلاس‌های مربوطه تقسیم می‌کند. تعداد این کلاس‌ها باید قبل از شروع طبقه‌بندی مشخص شود، اما با اطلاعات کمی که از منطقه و شرایط آن در دسترس پژوهشگر قرار دارد به ندرت قابل تشخیص است. علاوه بر این، روابط بین کلاس‌های اطلاعاتی و کلاس‌های طیفی همیشه ثابت نیستند و ویژگی‌های طیفی کلاس‌های اطلاعاتی برای تصاویر ماهواره به صورت فصلی تغییر می‌کند. بنابراین نمی‌توان آن را به دلایلی همچون عدم شناخت کافی از منطقه به کل فصل‌ها و مناطق دیگر تعمیم داد. الگوریتم ژنتیک به ویژه برای حل مسائل بهینه‌سازی که دارای عارضه‌های بسیار زیادی هستند مناسب است (Alippi and Cucchiara, 1992; Sheikh et al., 2008; Dutta et al., 2021).

روش ISO DATA

روش طبقه‌بندی نظارت نشده ISO DATA بر اساس تصحیح تکراری انتساب برچسب‌ها عمل می‌کند. در این روش ابتدا پیکسل‌ها در تعدادی دسته مشخص دسته‌بندی شده سپس پیکسل‌ها به طور مداوم از یک دسته به دسته دیگر جابه‌جا شده تا جایی که تغییر محسوس در دسته‌های بوجود آمده ایجاد نشود (Celebi and Aydin, 2016). این تقسیم‌بندی در وهله اول صحیح نیست و باید تصحیح گردد. بنابراین دسته‌های جدید که در واقع همان تقسیم‌بندی‌های جدید فضای چند طیفی هستند شکل می‌پذیرد. این فرآیند تا جایی که بهترین تقسیم‌بندی فضای چند طیفی انجام می‌پذیرد ادامه خواهد یافت. لازمه این روش تعیین تعداد دسته‌ها (کلاس‌ها) است که این امر برای مناطقی که شناختی راجع محیط آن نداریم بسیار غیرواقعی است (Kumar et al, 2015).

روش K-means

روش طبقه‌بندی نظارت نشده K-means همانند روش ISO Data نیاز به معرفی تعداد دسته‌ها دارد. با این وجود یکسری تفاوت جزئی با روش ISO DATA دارد. در این الگوریتم مراکز اولیه دسته‌ها انتخاب شده و برچسب دهی پیکسل‌ها آغاز می‌گردد. اولین پیکسل پس از بررسی به نزدیک‌ترین دسته در فضای چند طیفی انتساب می‌یابد. پس از انتساب پیکسل به دسته، مرکز جدید محاسبه می‌شود. حال یک پیکسل دیگر در نظر گرفته شده و همین مراحل برای آن تکرار می‌شود. این عملیات تا خوشه‌بندی تمام تصویر ادامه می‌یابد تا تصویر به تعداد طبقات معرفی شده طبقه‌بندی گردد (Cohn and Holm, 2021).

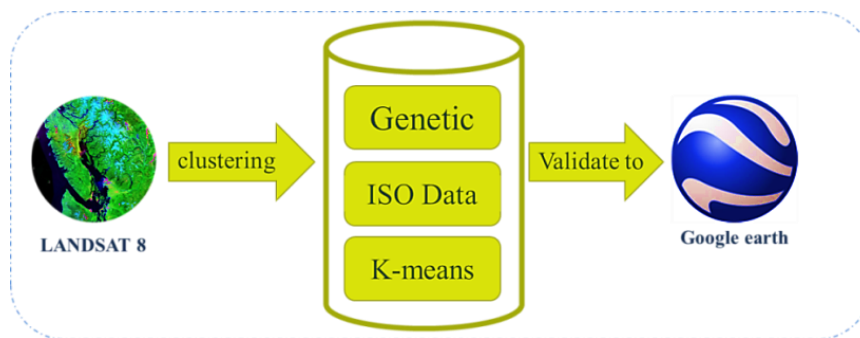
مواد و روش‌ها

در این پژوهش از تصویر لندست ۸ و محیط کد نویسی متلب (Matlab) استفاده شد (جدول ۱). همچنین جهت جلوگیری از ایجاد اختلال در الگوریتم‌های خوشه‌بندی، در انتخاب تصویر پوشش ابر صفر درصد مدنظر قرار گرفت. مشخصات تصویر مورد استفاده به همراه منبع دریافت آن (USGS:United States Geological Survey) در جدول ۱ آمده است (<https://earthexplorer.usgs.gov>). همچنین شکل ۲ مراحل کلی پژوهش را نشان می‌دهد.

جدول ۱: مشخصات تصویر مورد استفاده

Table 1: Features of the image used

منبع داده	باند‌های مورد استفاده	Path	Row	UTM-Zone	تاریخ داده	سنجنده
USGS	۵ - ۴ - ۳	۱۶۳	۳۴	۴۰N	۲۲ ژوئن ۲۰۱۹	OLI

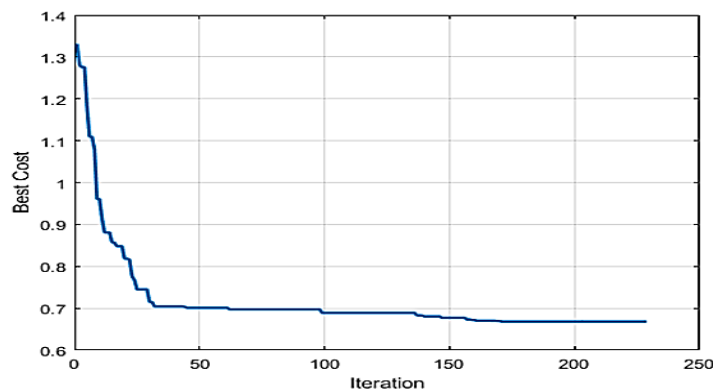


شکل ۲: مراحل کلی پژوهش

Figure 2: General stages of research

بمنظور طبقه‌بندی نظارت‌نشده با استفاده از الگوریتم ژنتیک، با توجه به پژوهش‌های گذشته (Yang et al., 2014; Beg et al 2016) عدد ۳۰ برای جمعیت اولیه کروموزم‌ها انتخاب شد که ضمن کاهش چشمگیر زمان پردازش، باعث افزایش دقت طبقه‌بندی نیز می‌شود. البته سایر اعداد برای جمعیت اولیه نیز ممکن است میزان دقت را با افزایش زمان و حجم پردازش‌ها کمی تغییر دهد که بنا به دلایل بیان شده (افزایش زمان و هزینه) توجیه ندارد. همچنین براساس پژوهش Yang و همکاران (۲۰۱۴) تعداد ۳۰ کروموزم، برای نوع طبقات انجام شده (آب، پوشش گیاهی و ...) مناسب‌تر است که با طبقات این پژوهش مطابقت دارد. بنابراین تعداد ۳۰ نقطه به عنوان جواب‌های اولیه که در واقع همان کروموزم‌ها می‌باشند انتخاب شد، در گام دوم با استفاده از تابع هدف، کمترین واریانس ممکن بین داده‌های هر خوشه تصادفی در هر یک از جواب‌ها مورد ارزیابی قرار گرفت. در ادامه پس از تعیین بهینه محلی، جمعیت ثانویه (جواب‌های ثانویه) با اعمال فرآیندهای mutation و cross over بر روی جمعیت اولیه (پاسخ‌های اولیه) تولید گردید. در گام سوم شرط توقف ۸۰ تکرار متوالی با شرط عدم تغییر در جواب‌ها، از آخرین تغییر صورت گرفته به عنوان شرط توقف به الگوریتم ژنتیک اضافه شد. همانطور که در پژوهش‌های پیشین اشاره شده است (Kutz, 2013; Zhi and Liu., 2019). شرط توقف تأثیر بسزایی در زمان و حجم پردازش‌ها دارد. براساس پردازش صورت گرفته و دقت در نمودار ۱، تا عدد ۱۵۰ نتایج دارای تغییراتی است که در نمودار با شیب کم صورت گرفته است و تغییرات با شکستگی زیاد که در ابتدای نمودار مشخص است مشاهده نمی‌شود.

بر اساس اصول الگوریتم ژنتیک که اغلب بخش‌های آن به صورت فرآیندهای تصادفی انتخاب می‌شوند بایستی جواب‌ها در تعداد تکرار مشخصی بدون تغییر باشند تا اطمینان کافی از پردازش‌ها، و احتمال قرار گرفتن الگوریتم در مینیمم (Minimum) های محلی به حداقل ممکن برسد. بنابراین دو یا سه تکرار متوالی بدون تغییر در نتیجه نمی‌تواند مبنای کار باشد. لذا انتخاب یک بازه بزرگ (مثلاً ۸۰ تکرار) قابل اطمینان برای بدون تغییر ماندن الگوریتم و عدم تغییر جواب ضروری است. پس از تعیین دوباره بهینه محلی فرآیند فوق تا رسیدن به تعداد تکرار ۲۳۰ (شرط توقف) ادامه یافت. به عبارت دیگر این تعداد شرط توقف بمنظور همگرایی جواب‌ها و اطمینان کافی از عدم رسیدن به بهینه‌های محلی صورت گرفت. نتایج پژوهش Ruban و همکاران (۲۰۱۷) و دیگر پژوهش‌ها از جمله Kowalski و همکاران (۲۰۱۶) و Dey و همکاران (۲۰۱۴) نیز این تعداد تکرار را تایید می‌کند.



نمودار ۱: روند وقوع شرط توقف در تکرارها

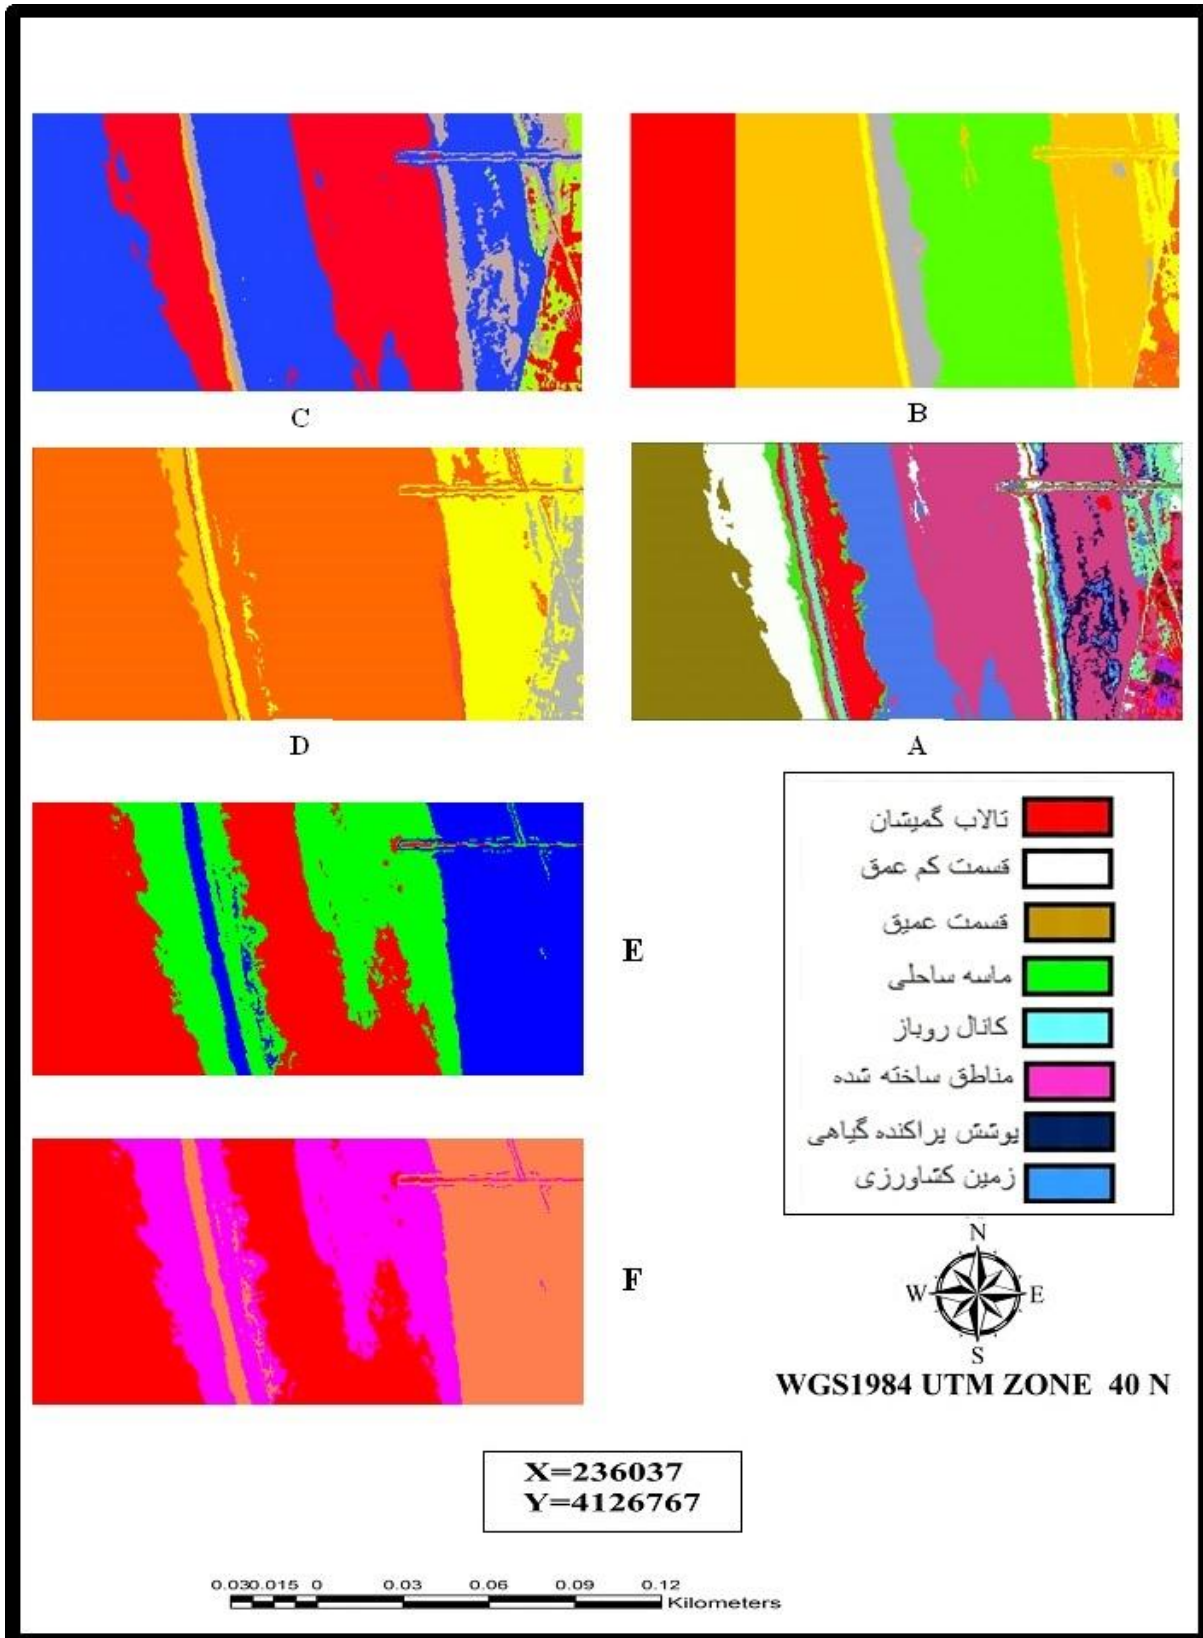
Diagram 1: The occurrence of the stop condition in iterations

یافته‌ها و بحث

با توجه به پژوهش‌های پیشین (Li and chen.,2018, Chen et al.,2019) از Google earth که دارای تصاویر IKONOS در تاریخ مورد پژوهش است استفاده شد. در ابتدا با بزرگنمایی بر روی نقشه Google earth، به نحوی که عوارض به خوبی مشاهده شود تعداد ۱۰ نقطه برای هر طبقه به عنوان نقاط نمونه انتخاب شدند. به منظور مطابقت هر چه بیشتر محیط با تاریخ تصویر لندست، از آرشیو نزدیک به تصویر لندست Google earth استفاده گردید. در مرحله بعد از این نقاط خروجی KML گرفته شد و Shapefile نقاط تهیه گردید. سپس با استفاده از نرم‌افزار Envi V5.3 این Shapfile ها به عنوان نقاط نمونه (Regin Of Interest) به نرم‌افزار معرفی شد تا در محاسبه ماتریس دقت (Confusion matrix) مورد استفاده قرار گیرد. در پایان با محاسبه آن میزان دقت خوشه‌بندی‌ها بدست آمد. شکل ۳ نحوه نمونه‌برداری در گوگل ارث نشان می‌دهد (مقیاس تصویر ۱/۱۰۰۰۰).



شکل ۳: تعیین نقاط نمونه با استفاده از Google earth
Figure 3: Determining sample points using Google earth



شکل ۴: ارائه نتایج با تغییر پارامترهای مختلف الگوریتم ژنتیک

Figure 4: Presenting the results by changing the various parameters of the genetic algorithm

نتایج نشان می‌دهد که استفاده از الگوریتم‌های فرا ابتکاری در خوشه‌بندی نتایج، در شرایط کاملاً مشابه، نتیجه بهتری را به همراه داشته است (جدول ۳). بطوریکه خط تقریبی برای مرز ساحل خشکی، قسمت‌های کم عمق و عمیق، ماسه‌های مناطق ساحلی، بخش‌هایی از پوشش گیاهی، مناطق ساخته شده از قبیل دیوار ساحلی نسبت به زمانی که از روش‌های ISO DATA و K-mens استفاده شد بهتر نشان داده شده است (شکل ۴). نکته قابل توجه در خروجی این است که قسمت کم عمق که معمولاً پساب‌ها و آلودگی‌ها را بیشتر در خود نگه می‌دارد به هنگام استفاده از الگوریتم ژنتیک به شکل مناسبی از بخش عمیق که تمیزتر است مشخص شده است (شکل ۴ قسمت A). البته این نتایج در زمانی که پارامترهای ژنتیک تغییر کرده است خروجی‌های متفاوتی را می‌دهند (شکل ۴ قسمت B,C,D). در این پژوهش مقادیر پارامترهای ژنتیکی از جمله: تعداد جمعیت (n Population)، نرخ ترکیب (Cross over Rate)، حداکثر تعداد تکرار (Max Iteration)، نرخ جهش (Mutation Rate)، بصورت مستقل و توأم تغییر کرد (جدول ۲) تا بهترین انطباق با وضع موجود بدست آید. برای این الگوریتم از شرط توقف حداکثر تعداد تکرار استفاده شد که نمودار ۱ حاکی از همگرایی نتایج در تکرارهای بعدی است. همانطور که در نمودار ۱ نشان داده شده، برای شرایط مختلف پارامترهای مسئله از عدد ۱۵۰ به بعد به همگرایی رسیده است. انتخاب تعداد مناسب یکی از مهمترین پارامترهای مسئله است بطوریکه انتخاب تعداد تکرار نامناسب یا بطور کلی شرط توقف اشتباه، باعث گیر افتادن الگوریتم در مینیمم‌های محلی خواهد شد که حساسیت انتخاب شرط توقف مناسب را بیش از پیش افزایش خواهد داد. در شکل (۴) در قسمت E و F به ترتیب از روش‌های ISO DATA و K-means برای خوشه‌بندی استفاده گردید. همانطور که در شکل ۴ نشان داده شده در هر دو قسمت E و F این کلاس‌ها به درستی تفکیک نشده برای مثال قسمت عمیق و کم عمق دریا یکی در نظر گرفته شده است. همچنین دیوار ساحلی اصلاً مشخص نشده و بخش ساحلی با عرض واقعی همخوانی ندارد. پوشش گیاهی نیز با کلاس‌های دیگر ادغام شده است که نزدیک بودن درجه خاکستری پیکسل‌ها و قرار دادن آن‌ها در یک کلاس می‌تواند باعث تشخیص اشتباه الگوریتم شود. براساس نتایج نشان داده شده در جدول ۲ و ۳ تعداد ۳۰ برای جمعیت اولیه و نرخ ترکیب و جهش ۰/۴ می‌تواند نتایج بهتری را به همراه داشته باشد (جدول ۲ و ۳ بخش ج).

جدول ۲: پارامترهای تغییر یافته در روش ژنتیک

Table 2: Modified parameters in the genetic method

حالت	تعداد جمعیت	نرخ ترکیب	نرخ جهش	حداکثر تعداد تکرار
الف	۲۴	۰/۷	۰/۳	۲۳۰
ب	۱۸	۰/۶	۰/۵	۲۳۰
ج	۳۰	۰/۴	۰/۴	۲۳۰
د	۴۵	۰/۳	۰/۵	۲۳۰

جدول ۳: دقت طبقه‌بندی‌های مختلف

Table 3: Accuracy of different classifications

دقت کلی (درصد)	ضریب کاپا (درصد)	نوع خوشه بندی
۷۳	۶۹	الگوریتم ژنتیک در حالت "الف"
۶۵	۵۹	الگوریتم ژنتیک در حالت "ب"
۸۹	۸۶	الگوریتم ژنتیک در حالت "ج"
۸۳	۷۶	الگوریتم ژنتیک در حالت "د"
۴۸	۴۲	ISO DATA
۵۴	۴۷	k-means

نتیجه‌گیری

در این پژوهش از سه روش Clustering شامل: ژنتیک، ISO DATA و K-means استفاده شد که با توجه به خروجی‌های بدست آمده و نتایج پیش رو، استفاده از الگوریتم ژنتیک علاوه بر بهبود ضریب کاپا و صحت کلی، کلاس‌ها را به درستی تشخیص داده که می‌توان از نتایج این پژوهش در کارهای مشابه بهره برد. همچنین از دیگر مزیت‌های استفاده از الگوریتم ژنتیک، عدم نیاز به مراجعه حضوری به محل و کاهش هزینه است که در این پژوهش به درستی مورد استفاده قرار گرفته است. همچنین تغییر پارامترهای ژنتیک مانند تعداد جمعیت، نرخ ترکیب، نرخ جهش و حداکثر تکرار می‌تواند به بهبود یا عدم بهبود نتایج منجر شود.

References

- Abburu, S., & Golla, S. B. (2015). Satellite image classification methods and techniques: A review. *International journal of computer applications*, 119(8).
- Alok, A. K., Saha, S., & Ekbal, A. (2016). Multi-objective semi-supervised clustering for automatic pixel classification from remote sensing imagery. *Soft Computing*, 20(12), 4733-4751.
- Badreldin, N., & Goossens, R. (2014). Monitoring land use/land cover change using multi-temporal Landsat satellite images in an arid environment: a case study of El-Arish, Egypt. *Arabian Journal of Geosciences*, 7(5), 1671-1681.
- Bandyopadhyay, S., Maulik, U., & Mukhopadhyay, A. (2007). Multiobjective genetic clustering for pixel classification in remote sensing imagery. *IEEE transactions on Geoscience and Remote Sensing*, 45(5), 1506-1511.
- Beg, A. H., & Islam, M. Z. (2016, June). Advantages and limitations of genetic algorithms for clustering records. In *2016 IEEE 11th Conference on Industrial Electronics and Applications (ICIEA)* (pp. 2478-2483). IEEE.
- Celebi, M. E., & Aydin, K. (Eds.). (2016). *Unsupervised learning algorithms*. Berlin: Springer International Publishing.

Chen, L. G., Chiang, H. D., Dong, N., & Liu, R. P. (2016). Group-based chaos genetic algorithm and non-linear ensemble of neural networks for short-term load forecasting. *IET Generation, Transmission & Distribution*, 10(6), 1440-1447.

Cohn, R., & Holm, E. (2021). Unsupervised machine learning via transfer learning and k-means clustering to classify materials image data. *Integrating Materials and Manufacturing Innovation*, 10(2), 231-244.

Dey, N., Samanta, S., Chakraborty, S., Das, A., Chaudhuri, S. S., & Suri, J. S. (2014). Firefly algorithm for optimization of scaling factors during embedding of manifold medical information: an application in ophthalmology imaging. *Journal of Medical Imaging and health informatics*, 4(3), 384-394.

Dutta, T., Dey, S., Bhattacharyya, S., Mukhopadhyay, S., & Chakrabarti, P. (2021). Hyperspectral multi-level image thresholding using qutrit genetic algorithm. *Expert Systems with Applications*, 181, 115107.

Faizi, F., Mahmood, K., Chaudhry, M. H., & Rana, A. D. (2020). Satellite remote sensing and image processing techniques for monitoring MSW dumps. In *Proceedings of 5th EurAsia Waste Management Symposium* (pp. 26-28).

Ghosh, A., Mishra, N. S., & Ghosh, S. (2011). Fuzzy clustering algorithms for unsupervised change detection in remote sensing images. *Information Sciences*, 181(4), 699-715.

Ghrabat, M. J. J., Ma, G., Maolood, I. Y., Alresheedi, S. S., & Abduljabbar, Z. A. (2019). An effective image retrieval based on optimized genetic algorithm utilized a novel SVM-based convolutional neural network classifier. *Human-centric Computing and Information Sciences*, 9(1), 1-29.

Hassan, M. M. M. (2013). Network intrusion detection system using genetic algorithm and fuzzy logic. *International Journal of Innovative Research in Computer and Communication Engineering*, 1(7).

Kowalski, P. A., & Łukasik, S. (2016). Training neural networks with krill herd algorithm. *Neural Processing Letters*, 44(1), 5-17.

Kumar, R., & Srivastava, R. (2015). Cancer detection from microscopic biopsy images using image processing and pattern recognition tools: A review. *Journal of Medical Imaging and Health Informatics*, 5(5), 877-892.

Kutubi, A. A. R., Hong, M. G., & Kim, C. (2018). Evaluating the Performance of Four Selections in Genetic Algorithms-Based Multispectral Pixel Clustering, 34(1), 151-166.

Kutz, J. N. (2013). *Data-driven modeling & scientific computation: methods for complex systems & big data*. Oxford University Press.

Li, K., & Chen, Y. (2018). A Genetic Algorithm-based urban cluster automatic threshold method by combining VIIRS DNB, NDVI, and NDBI to monitor urbanization. *Remote Sensing*, 10(2), 277.

Lucas, B., Pelletier, C., Schmidt, D., Webb, G. I., & Petitjean, F. (2020, September). Unsupervised domain adaptation techniques for classification of satellite image time series. In *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium* (pp. 1074-1077). IEEE.

- MATCI, D. K., & Avdan, U. (2019). Optimization of remote sensing image attributes to improve classification accuracy. *International Journal of Environment and Geoinformatics*, 6(1), 50-56.
- Merzougui, M., & Allaoui, A. E. (2018). Unsupervised classification by Isodata using genetic algorithm and Xie-Beni criterion. *International Journal of Applied Engineering Research*, 13(5), 2163-2167.
- Omran, M., Engelbrecht, A. P., & Salman, A. (2005). Particle swarm optimization method for image clustering. *International Journal of Pattern Recognition and Artificial Intelligence*, 19(03), 297-321.
- Pal, N. R., Pal, K., Keller, J. M., & Bezdek, J. C. (2005). A possibilistic fuzzy c-means clustering algorithm. *IEEE transactions on fuzzy systems*, 13(4), 517-530.
- Qiao, H., & Wan, X. (2019). Object-Based Classification from Tiangong-2 Using Support Vector Machine Optimized with Evolutionary Algorithm. In *Proceedings of the Tiangong-2 Remote Sensing Application Conference* (pp. 222-231). Springer, Singapore.
- Rekik, A., Zribi, M., Hamida, A. B., & Benjelloun, M. (2009). An optimal unsupervised satellite image segmentation approach based on pearson system and k-means clustering algorithm initialization. *methods*, 8(9).
- Ruban, I., Khudov, H., Khudov, V., Khizhnyak, I., & Makoveichuk, O. (2017). Segmentation of the images obtained from onboard optoelectronic surveillance systems by the evolutionary method. *Восточно-Европейский журнал передовых технологий*, (5 (9)), 49-57.
- Senthilnath, J., Kulkarni, S., Benediktsson, J. A., & Yang, X. S. (2016). A novel approach for multispectral satellite image classification based on the bat algorithm. *IEEE Geoscience and Remote Sensing Letters*, 13(4), 599-603.
- Senthilnath, J., Rajendra, R., Suresh, S., Kulkarni, S., & Benediktsson, J. A. (2019). Hierarchical clustering approaches for flood assessment using multi-sensor satellite images. *International Journal of Image and Data Fusion*, 10(1), 28-44.
- Sheikh, R. H., Raghuvanshi, M. M., & Jaiswal, A. N. (2008, July). Genetic algorithm based clustering: a survey. In *2008 first international conference on emerging trends in engineering and technology* (pp. 314-319). IEEE.
- Stolte, M. (2003). The new Vienna classification of epithelial neoplasia of the gastrointestinal tract: advantages and disadvantages. *Virchows Archiv*, 442(2), 99-106.
- Tilahun, A., & Teferie, B. (2015). Accuracy assessment of land use land cover classification using Google Earth. *Am. J. Environ. Prot*, 4, 193-198.
- Usha, S. G. A., & Vasuki, S. (2022). Significance of texture features in the segmentation of remotely sensed images. *Optik*, 249, 168241.
- Xu, L., & Qiu, J. (2019). Unsupervised Multi-class Sentiment Classification Approach. *Knowledge Organization*, 46(1), 15-32.
- Yang, M. D., Yang, Y. F., Su, T. C., & Huang, K. S. (2014). An efficient fitness function in genetic algorithm classifier for landuse recognition on satellite images. *The Scientific World Journal*, 2014.

Zhi, H., & Liu, S. (2019). Face recognition based on genetic algorithm. *Journal of Visual Communication and Image Representation*, 58, 495-502.

Applying genetic optimization algorithm in unsupervised classification and comparing it with ISO DATA and K-means classification methods.

Ali Hosingholizade

Ph.D. student of Remote Sensing and Geographical Information System, University of Tehran, Tehran, Iran

Najmeh Neysani Samany*

Associate Professor of Remote Sensing and Geographical Information System Department, University of Tehran, Tehran, Iran

Abstract

Unsupervised classification is a vital technique in remote sensing for extracting land cover information without prior training data. This study compares the performance of the Genetic Algorithm (GA) against two conventional unsupervised methods, ISO DATA and K-means, for image classification. The research aims to evaluate whether GA can overcome the limitations of traditional clustering methods, such as sensitivity to initial parameters and local minima, particularly in areas with limited ground truth data. Using Landsat 8 imagery of a coastal region in northern Golestan Province, Iran, the study conducts a comparative analysis under identical conditions. Validation was performed using 10 sample points per class derived from high-resolution Google Earth images, ensuring accuracy assessment through confusion matrices. The results demonstrate that the Genetic Algorithm significantly outperforms the other methods, achieving an overall accuracy of 89% and a Kappa coefficient of 86%. In contrast, K-means and ISO DATA yielded accuracies of 54% and 48%, with Kappa coefficients of 47% and 42%, respectively. The GA successfully distinguished subtle spectral differences, such as separating shallow from deep water zones and identifying coastal structures, which were often merged or misclassified by K-means and ISO DATA. The study highlights the importance of optimizing GA parameters, including population size, crossover rate, and mutation rate, to avoid local optima. It is concluded that GA is a superior tool for unsupervised classification, offering higher precision and reliability, especially in complex or data-scarce environments.

****Introduction****

Land cover extraction via remote sensing has become indispensable for applications ranging from food security to climate change monitoring. While supervised classification is common, it requires extensive training data, which is often unavailable or costly to acquire.

Unsupervised classification, or clustering, offers an automated alternative by grouping pixels based on spectral similarities without prior class knowledge. This approach reduces analyst workload and cost, making it suitable for dynamic monitoring and regions with limited geographical knowledge. However, traditional clustering algorithms like K-means and ISO

DATA face significant challenges. K-means is sensitive to initial seed selection and may converge to local minima, while ISO DATA requires predefined class numbers, which is impractical when the number of land cover types is unknown. Furthermore, these methods often struggle with spectral heterogeneity, leading to misclassification of pixels with similar grayscale values but different land covers. To address these limitations, heuristic optimization techniques, particularly Genetic Algorithms (GA), have gained attention. GA mimics natural selection processes, allowing for a more robust search of the solution space. Despite previous studies suggesting GA's potential, comparative analyses under strictly controlled conditions remain limited. This study addresses this gap by rigorously comparing GA with K-means and ISO DATA using consistent parameters, aiming to validate GA's efficacy in improving classification accuracy for remote sensing applications.

****Methodology****

The study area is located 40 km north of Bandar Torkaman in Golestan Province, Iran, characterized by a mild Mediterranean climate and flat topography. The region borders the Caspian Sea and is influenced by industrial effluents, making it a complex environment for classification. A cloud-free Landsat 8 OLI image acquired on June 22, 2019, was used. Bands 3 (Green), 4 (Red), and 5 (Near-Infrared) were selected for analysis. The processing was conducted in MATLAB. For the GA, a population size of 30 chromosomes was chosen based on prior literature to balance processing time and accuracy. The fitness function aimed to minimize intra-cluster variance. Termination criteria were set at 230 iterations, with a stop condition triggered if no improvement occurred for 80 consecutive iterations to ensure convergence and avoid local minima. Various GA parameters, including crossover and mutation rates, were tested; optimal results were found with a crossover rate of 0.4 and mutation rate of 0.4. For validation, 10 sample points per class were manually selected from Google Earth imagery, matching the Landsat acquisition date. These points were converted to shapefiles and used to generate confusion matrices for accuracy assessment. K-means and ISO DATA were executed under identical conditions for a fair comparison. The K-means method initialized centroids randomly, while ISO DATA iteratively split classes based on statistical thresholds. The spatial distribution of clusters was visually and quantitatively analyzed to evaluate the performance of each algorithm in distinguishing land cover features such as water depth variations, vegetation, and built-up areas.

****Discussion****

The comparative results reveal a substantial performance gap between the Genetic Algorithm and traditional methods. The GA's ability to explore the solution space globally allowed it to identify more homogeneous clusters, resulting in an 89% overall accuracy. This is significantly higher than K-means (54%) and ISO DATA (48%). The visual analysis of classified maps shows that GA effectively separated spectrally similar classes, such as shallow and deep water zones, which is critical for monitoring water quality and pollution. In

contrast, K-means and ISO DATA often merged these classes due to their reliance on local optimization and rigid clustering boundaries. The high accuracy of GA can be attributed to its adaptive nature, which adjusts cluster centers iteratively based on fitness evaluation rather than fixed rules. However, the study also highlights the sensitivity of GA to parameter settings. Incorrect parameter choices led to premature convergence or suboptimal solutions, emphasizing the need for careful calibration. The use of Google Earth for validation provided a reliable ground truth, although the resolution difference between Landsat and IKONOS imagery may introduce minor discrepancies. Despite this, the consistency of GA's performance across different parameter sets (when optimized) suggests its robustness. The findings align with previous studies indicating that evolutionary algorithms can enhance remote sensing classification, particularly in complex landscapes where traditional methods fail to capture spectral nuances.

****Conclusion****

This study demonstrates that the Genetic Algorithm is superior to K-means and ISO DATA for unsupervised classification of remote sensing imagery. With an overall accuracy of 89% and a Kappa coefficient of 86%, GA provides more precise and reliable land cover maps. It effectively handles spectral heterogeneity and avoids the local minima issues prevalent in traditional methods. The study recommends using GA, especially in data-scarce regions, while emphasizing the importance of optimizing algorithm parameters to ensure convergence. Future research should explore hybrid approaches combining GA with supervised techniques for even greater accuracy.