

تاثیر انتخاب ویژگی به کمک الگوریتم ژنتیک بر طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی

داود اکبری^{۱*}، عبدالرضا صفری^۲، صفا خزائی^۳

۱- دانشجوی دکتری سنجش از دور، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، دانشگاه تهران

۲- دانشیار ژئودزی، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، دانشگاه تهران

۳- استادیار سنجش از دور، گروه مهندسی عمران، دانشگاه جامع امام حسین(ع)

تاریخ دریافت مقاله: ۱۳۹۴/۰۲/۰۹ تاریخ پذیرش مقاله: ۱۳۹۴/۰۸/۰۴

چکیده

فن آوری سنجش از دور ابرطیفی دارای کاربردهای فراوان در طبقه‌بندی پوشش‌های زمین و بررسی تغییرات آنها می‌باشد. با پیشرفت‌های اخیر و ایجاد تصاویری با قدرت تفکیک مکانی بالا، لزوم استفاده توأم از اطلاعات طیفی و مکانی را در طبقه‌بندی تصاویر ابرطیفی ایجاب می‌کند. در این تحقیق سعی می‌گردد تاثیر کاهش ابعاد به کمک الگوریتم ژنتیک را در فرآیند طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی بررسی شود. در میان الگوریتم‌های مختلف طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی، تاکنون سه الگوریتم قطعه‌بندی واترشد، هرمی و جنگل پوشای مینیمم مبتنی بر نشانه در ترکیب با الگوریتم طبقه‌بندی ماشین بردار پشتیبان به بهترین نتایج دست یافته‌اند. در روش پیشنهادی ابتدا به کمک الگوریتم ژنتیک ابعاد تصویر ابرطیفی کاهش یافته سپس بر روی باندهای حاصل، سه الگوریتم قطعه‌بندی مذکور پیاده‌سازی گردید. در نهایت نقشه‌های قطعه‌بندی بدست آمده به کمک قانون تصمیم رای اکثریت با نقشه طبقه‌بندی ماشین بردار پشتیبان ترکیب شد. روش پیشنهادی بر روی سه تصویر ابرطیفی Pavia، Telops و DC Mall پیاده‌سازی گردید، نتایج آزمایشات بدست آمده برتری استفاده از کاهش ابعاد در الگوریتم جنگل پوشای مینیمم مبتنی بر نشانه و استفاده از تمام باندهای تصویر در الگوریتم های واترشد و هرمی مبتنی بر نشانه را نشان می‌دهد.

کلیدواژه‌ها: تصویر ابرطیفی، طبقه‌بندی طیفی-مکانی، کاهش ابعاد، الگوریتم ژنتیک.

* نویسنده مکاتبه کننده خیابان کارگر شمالی (امیرآباد)، پردیس دانشکده‌های فنی دانشگاه تهران، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، تلفن همراه:

۰۹۱۵۵۶۱۹۷۹۹

۱- مقدمه

فن آوری سنجش از دور ابرطیفی، در دو دهه گذشته شاهد پیشرفت چشمگیری بوده است. این پیشرفت در طراحی و ساخت سنجنده‌ها و همچنین در توسعه و پیاده‌سازی روش‌های پردازش داده، بسیار مشهود است [۱]. امروزه اکثر تحقیقات در زمینه سنجش از دور ابرطیفی، بر طبقه‌بندی این تصاویر تاکید دارد. طبقه بندی یا تبدیل تصاویر به نقشه موضوعی در اثر عواملی از جمله پیچیدگی منطقه مورد مطالعه، انتخاب داده، پردازش تصویر و الگوریتم مورد استفاده، در معرض چالش جدی بوده و ممکن است بر موفقیت طبقه‌بندی تاثیر بگذارد [۲]. هر چند، توانایی تولید داده‌هایی با خصوصیات طیفی، مکانی و رادیومتریکی بالا، منجر به تجزیه و تحلیل بهتر و شناسایی موفقیت آمیز اهداف زمینی می‌شود، ولی مشکلاتی نیز پدید می‌آید که در مقایسه با داده‌های چندطیفی تجربه جدیدی است. اولین مشکل حجم نسبتاً زیاد این داده‌ها است، این حجم قابل توجه از داده، نیاز به سخت‌افزار و نرم‌افزارهای ویژه‌ای جهت پردازش دارد. زمان مورد نیاز برای پردازش این نوع داده‌ها، از مشکلات دیگر پیش رو است [۳]. تصاویر ابرطیفی به دلیل داشتن تعداد باندهای زیاد، دارای مشکل کمبود نمونه‌های برجسب‌گذاری شده در فرآیند طبقه‌بندی هستند. یکی از راه حل‌ها جهت رفع این مشکل، کاهش تعداد باندها می‌باشد. برای این منظور روش‌های مختلفی مانند استخراج ویژگی و انتخاب ویژگی ارائه شده است [۴].

به‌طور کلی روش‌های طبقه‌بندی تصاویر ابرطیفی، به دو دسته تقسیم‌بندی می‌شوند. دسته اول روش‌های طبقه‌بندی مبتنی بر پیکسل بوده که در آن هر پیکسل فقط با استفاده از اطلاعات طیفی خود و بدون در نظر گرفتن اطلاعات موجود در پیکسل‌های همسایه به یک کلاس مشخص اختصاص می‌یابد [۵]. دسته دوم روش‌های طبقه‌بندی، روش‌های طبقه‌بندی طیفی-مکانی بوده که علاوه بر اطلاعات طیفی پیکسل‌ها از اطلاعات

پیکسل‌های همسایه استفاده می‌نمایند. در این دسته از الگوریتم‌ها، استفاده از اطلاعات مکانی به روش‌های مختلف صورت می‌گیرد [۶]. ساده‌ترین روش، استفاده از اطلاعات نزدیکترین همسایگی‌ها است [۷]. بر اساس این راه حل، جکسون در سال ۲۰۰۲ میلادی [۸] طبقه‌بندی‌کننده آماری مبتنی بر مدل میدان تصادفی مارکو (MRF^1) پیشنهاد داد. هانگ در سال ۲۰۰۹ میلادی [۹] اطلاعات مکانی بدست آمده از ماتریس هم‌وقوع $GLCM^2$ را برای طبقه‌بندی داده ابرطیفی به کار گرفت. در روش پیشنهادی توسط هانگ ابتدا ویژگی‌های بافت^۳ از روی ماتریس $GLCM$ و با استفاده از چهار اندازه‌گیری مولفه دوم زاویه^۴، کنتراست^۵، آنترופی^۶ و یکنواختی^۷ استخراج گردید، سپس آنالیز مولفه‌های اصلی (PCA^8) بر روی ویژگی‌های بدست آمده اعمال گشته و مولفه‌های اصلی به عنوان ویژگی‌های ورودی برای طبقه‌بندی‌کننده بیشترین شباهت^۹ انتخاب شدند. بندیکسون در سال ۲۰۰۳ میلادی روش نیمرخ همسایگی^{۱۰} را به عنوان روشی دیگر جهت استفاده از اطلاعات مکانی پیشنهاد داد [۱۰]. نیمرخ همسایگی از ترکیب فیلترهای باز^{۱۱} و بسته^{۱۲} تشکیل یافته است. اعمال روش فوق بر روی باندهای مختلف تصویر به نام نیمرخ همسایگی توسعه یافته^{۱۳} شناخته می‌باشد [۱۱]. ایجاد نیمرخ همسایگی توسعه یافته بر روی تمام باندهای تصویر ابرطیفی باعث ایجاد ویژگی‌های وابسته زیادی

1 Markov Random Field

2 Gray Level Co-occurrence Matrix

3 Texture Features

4 Angular Second Moment

5 Contrast

6 Entropy

7 Homogeneity

8 Principal Component Analysis

9 Maximum Likelihood

10 Morphological Profiles

11 Opening

12 Closing

13 Extended Morphological Profiles

به عنوان نشانه انتخاب نمودند [۱۹ و ۲۰]. در تحقیق دیگری که اخیراً توسط تارابالکا و همکاران او جهت طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی پیشنهاد شده است، از الگوریتم‌های قطعه‌بندی واترشد^۳، هرمی (HSEG^۴) و جنگل پوشای مینیمم (MSF^۵) مبتنی بر نشانه جهت استخراج اطلاعات مکانی استفاده شد [۱۳]. آنها به کمک نقشه طبقه بندی ماشین بردار پشتیبان (SVM^۶) پیکسل‌هایی با درجه تعلق بالا به هر کلاس را به عنوان نشانه انتخاب نمودند. برای این منظور ابتدا روی نقشه طبقه بندی SVM آنالیز برچسب‌گذاری مولفه‌های متصل صورت گرفته، سپس برای نواحی بزرگ ایجاد شده p درصد از پیکسل‌های با بالاترین احتمال و برای نواحی کوچک پیکسل‌هایی با درجه احتمال بیشتر از حد آستانه‌ای مشخص به عنوان نشانه در نظر گرفته شد.

با توجه به مطالعات صورت گرفته، تاکنون، الگوریتم‌های طبقه‌بندی تارابالکا و همکاران او در مقایسه با سایر الگوریتم‌های طبقه‌بندی طیفی-مکانی در تصاویر ابرطیفی به بهترین نتایج دست یافته است. از این رو در این تحقیق سعی می‌گردد الگوریتم‌های طبقه بندی مذکور به کمک تکنیک کاهش ابعاد تصاویر ابرطیفی بهبود داده شود. برای این منظور ابتدا به کمک الگوریتم ژنتیک ابعاد تصاویر ابرطیفی کاهش یافته، سپس سه الگوریتم قطعه بندی واترشد، هرمی و MSF مبتنی بر نشانه بر روی تصویر با ابعاد کاهش یافته پیاده‌سازی می‌گردد. در مرحله بعد نقشه‌های قطعه‌بندی به دست آمده به کمک قانون تصمیم رای اکثریت^۷

شده، از این رو کاهش تعداد باندهای تصویر ابرطیفی قبل از اعمال نیمرخ همسایگی الزامی است. در همین راستا در [۱۲] روش نیمرخ همسایگی توسعه یافته بر روی چندین ویژگی بدست آمده از تبدیل PCA که دارای بیشترین واریانس می‌باشند، اعمال گردید.

یکی دیگر از روشهای استخراج اطلاعات مکانی، روشهای قطعه‌بندی^۱ است که در آن بر اساس ویژگی‌هایی مانند یکنواختی، اشیاء موجود در تصویر (مجموعه‌ای از پیکسل‌ها با ویژگی یکسان) شناسایی می‌شوند [۱۳]. مزایای استفاده از روشهای قطعه‌بندی در [۱۴، ۱۵ و ۱۶] بیان شده است. در این روش‌ها هر شیء به صورت همسایگی مکانی برای همه پیکسل‌های داخل آن شیء تعریف می‌شود. این راه‌حل برای مناطق یکنواخت بزرگ، همسایگی‌های بزرگی را ایجاد کرده و از طرف دیگر مناطق با یک یا چند پیکسل را از دست نمی‌دهد. بنابراین اگر قرار باشد نقشه دقیقی از اشیاء بر اساس ساختارهای مکانی در تصویر ایجاد گردد، نقشه قطعه‌بندی، اطلاعات مکانی دقیق و کاملی را ایجاد خواهد کرد. یک روش معمول جهت داشتن نتایج قطعه‌بندی دقیق، قطعه‌بندی مبتنی بر نشانه^۲ است [۱۳ و ۱۷]، که در آن برای هر ناحیه مکانی از تصویر یک یا چند پیکسل به عنوان نشانه انتخاب شده، سپس نشانه‌های بدست آمده در فرآیند قطعه‌بندی رشد یافته و منجر به ناحیه‌ای مشخص در نقشه قطعه‌بندی می‌شود. در تحقیقات اولیه صورت گرفته، نشانه‌ها عموماً از روی مناطق یکنواخت یعنی مناطقی با مقادیر پیکسل یکسان یا بافت یکنواخت انتخاب می‌شدند [۱۷]. گومز در [۱۸] به کمک هیستوگرام تصویر، پیکسل‌های با مقادیر یکسان را به عنوان نشانه اختیار نمود. نویل و همکارانش با انجام طبقه‌بندی تصویر ابرطیفی و سپس فیلتر نمودن آن به کمک عملگرهای همسایگی، مناطق مکانی بزرگ را

3 Watershed

4 Hierarchical Segmentation

5 Minimum Spanning Forest

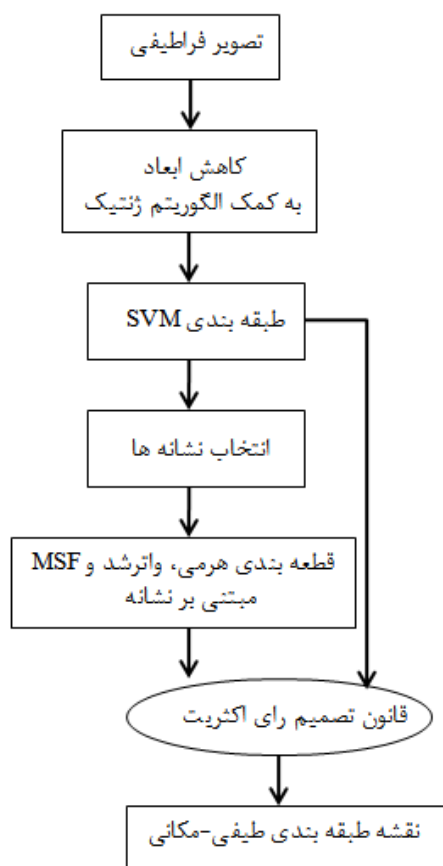
6 Support Vector Machines

7 Majority Voting

1 Segmentation

2 Marker

عملگرهای ژنتیک انتخاب^۱، تقاطع^۲ و جهش^۳، جمعیت جدیدی از راه‌حل‌ها تولید می‌گردد. این رویه تا زمان برقراری شرط خاتمه الگوریتم ادامه می‌یابد [۲۱]. در الگوریتم ژنتیک هر راه‌حل توسط یک رشته به نام کروموزوم نمایش داده شده و لازم است تابع هدف برای هدایت الگوریتم به سمت جواب بهینه، تعریف گردد [۲۱ و ۲۲]. در این تحقیق از پارامتر ضریب کاپا^۴ طبقه‌بندی SVM جهت تعیین ارزش هر کروموزوم استفاده شد.



شکل ۱: مراحل روش پیشنهادی.

همچنین از روش چرخ رولت^۵ برای عملگر انتخاب

با نقشه طبقه‌بندی SVM ترکیب می‌شود. در ادامه تحقیق، در بخش ۲، روش طبقه‌بندی طیفی-مکانی پیشنهادی بیان گشته سپس در بخش ۳ به تشریح آزمون‌های عملی صورت گرفته، پرداخته شده است و در نهایت در بخش پایانی نتیجه‌گیری از موارد بیان شده ارائه می‌گردد.

۲- روش پیشنهادی

در این مطالعه تاثیر کاهش ابعاد بر طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی بررسی می‌شود. شکل (۱) مراحل روش پیشنهادی را نشان می‌دهد. همانطور که در این شکل مشخص است، ابتدا ابعاد تصویر ابرطیفی به کمک الگوریتم ژنتیک کاهش یافته، سپس جهت انتخاب نشانه‌ها از نقشه طبقه‌بندی SVM استفاده و پیکسل‌های با درجه تعلق بالا به یک کلاس به عنوان نشانه انتخاب می‌شوند. در مرحله بعد بر روی نشانه‌های بدست آمده الگوریتم‌های قطعه‌بندی واترشد، هرمی و MSF اعمال گشته و در نهایت به کمک قانون تصمیم رای اکثریت نقشه‌های قطعه‌بندی با نقشه طبقه‌بندی SVM ترکیب می‌گردد. در قانون تصمیم رای اکثریت همانطوری که در شکل (۲) نشان داده شده است هر ناحیه از نقشه قطعه‌بندی به کلاسی که اکثر پیکسل‌های آن در نقشه طبقه‌بندی تعلق دارند، اختصاص می‌یابد. در ادامه این بخش با تفصیل بیشتری به الگوریتم‌های ژنتیک، واترشد، هرمی و MSF پرداخته شده است.

۲-۱ الگوریتم ژنتیک

الگوریتم ژنتیک_ که جزء تکنیک‌های بهینه‌سازی فرا ابتکاری می‌باشد_ متداول‌ترین نوع الگوریتم‌های تکاملی است که رویه واحدی برای آن وجود نداشته و دارای رویه‌ای تکراری است [۲۱]. در طی هر بار تکرار الگوریتم (نسل)، افراد موجود در جمعیت فعلی بر اساس میزان شایستگی‌شان مرتب شده و با استفاده از

- 1 Select
- 2 Crossover
- 3 Mutation
- 4 Kappa Coefficient
- 5 Roulette Wheel

آبریز^۳ و خطوط مرز^۴ را در تصویر تشکیل می‌دهد. این الگوریتم شامل دو مرحله مرتب سازی پیکسل‌ها و جاری شدن سیل است. مرحله مرتب سازی پیکسل‌ها، مبتنی بر افزایش مقدار درجه خاکستری پیکسل‌ها و جهت دسترسی مستقیم به آن‌ها در یک سطح مشخصی از مقادیر درجه خاکستری می‌باشد. همچنین مرحله جاری شدن سیل، به شکل سطح به سطح و با شروع از سطحی با کمترین مقدار درجه خاکستری صورت می‌گیرد [۲۳]. در نهایت جهت اختصاص هر پیکسل واترشد به ناحیه موردنظر، بردار میانه برای هر ناحیه S که شامل l پیکسل می‌باشد، با استفاده از رابطه (۲) محاسبه می‌شود.

$$S = \arg \min_{s \in S} \left\{ \sum_{j=1}^l \|s - s_j\| \right\} \quad \text{رابطه (۲)}$$

همانطوری که از رابطه (۲) مشخص است بردار فوق مجموع فواصل بین این بردار و همه بردارهای موجود در آن ناحیه را مینیمم می‌نماید. سپس هر پیکسل واترشد به ناحیه‌ای از همسایگی خود که دارای کمترین فاصله بین آن پیکسل و بردار میانه ناحیه باشد، تعلق می‌گیرد.

۲-۳- الگوریتم هرمی

الگوریتم هرمی مبتنی بر روش رشد ناحیه و بهینه سازی هرمی بوده [۲۴] و امکان ترکیب نواحی مکانی غیرمجاور را به وسیله پارامتر ورودی S_{weight} فراهم می‌سازد. پارامتر S_{weight} اهمیت نسبی خوشه‌بندی طیفی را در مقابل رشد ناحیه نشان می‌دهد. برای $S_{weight} = 0$ الگوریتم هرمی فقط نواحی مکانی مجاور را با یکدیگر ترکیب می‌کند و برای $S_{weight} = 1$ نواحی مجاور و غیر مجاور دارای وزن یکسانی در ترکیب می‌باشند و در نهایت برای مقادیر S_{weight} بین صفر و

استفاده شده است. در این روش احتمال انتخاب هر کروموزوم متناسب با مقدار شایستگی آن می‌باشد [۲۲]. از عملگر تقاطع با یک نقطه برش^۱ و نیز عملگر جهش جهت جلوگیری از انتخاب بهینه‌های محلی استفاده گردید. همچنین شرط توقف در این تحقیق بصورت شرط پویا در نظر گرفته شد، بدین صورت که اگر بهبودی در میزان تابع هدف تا قبل از تکرار مشخص - که صد نسل در نظر گرفته شده است - رخ ندهد، الگوریتم متوقف می‌شود و در غیر اینصورت تکرار تا نسل صدم ادامه می‌یابد.

۲-۲- الگوریتم واترشد

تبدیل واترشد بر روی تصویر شیب به کار گرفته می‌شود. تصویر شیب دارای بیشترین مقدار در مرز بین اشیا و کمترین مقدار در مناطق یکنواخت است [۲]. جهت محاسبه تصویر شیب، برای

هر بردار پیکسل x_p از تصویری با B باند، مجموعه‌ای از e بردار در همسایگی آن $\mathcal{V} = [x_p^1, x_p^2, \dots, x_p^e]$

در نظر گرفته به طوری که شامل x_p نباشد. در این حالت شیب به صورت اختلاف بین بیشترین و کمترین فاصله بین x_p و بردارهای \mathcal{V} تعریف می‌شود (رابطه ۱).

$$\nabla_{\mathcal{V}, d}(x_p) = -\inf\{d(x_p, x_p^j)\}_{j \in \mathcal{V}} \quad \text{رابطه (۱)}$$

در این رابطه ∇ معرف شیب، $d(,)$ معرف فاصله بین دو بردار و \inf بیانگر اختلاف بین بیشترین و کمترین فاصله می‌باشد. بعد از ایجاد تصویر شیب، با استفاده از الگوریتم وینسنت و سوئل^۲، تبدیل واترشد اعمال می‌گردد [۲۳]. الگوریتم فوق با شبیه‌سازی جاری شدن سیل از پیکسل‌های با ارتفاع بیشتر عمل کرده و جهت ایجاد نواحی مختلف، حوزه‌های

3 Catchment basins
4 Ridge lines

1 Single Point
2 Vincent and Soile

مقدار معیار عدم تشابه و ترکیب آنها
 (۴) اگر پارامتر $S_{wght} > 0$ باشد همه جفت
 نواحی غیر مجاور با مقدار معیار عدم تشابه
 کمتر یا مساوی حاصلضرب S_{wght} در
 کوچکترین مقدار معیار عدم تشابه برای جفت
 نواحی مجاور، ترکیب می‌گردد.
 (۵) پایان مراحل، در صورتی که ترکیب دیگری
 نیاز نباشد، در غیر این صورت مراحل ۲ به
 بعد تکرار می‌شود.

یک، ترکیب نواحی مجاور در مقایسه با نواحی
 $\frac{1}{S_{wght}}$
 غیرمجاور دارای برتری می‌باشد. به طور کلی
 الگوریتم هرمی شامل مراحل زیر می‌شود [۲۵]:
 (۱) شروع قطعه‌بندی با تخصیص برچسب یک
 ناحیه مجزا برای هر پیکسل. اگر قطعه‌بندی
 از قبل وجود داشته باشد می‌توان برچسب هر
 پیکسل را بر اساس آن انجام داد.
 (۲) محاسبه مقدار معیار عدم تشابه برای هر
 جفت از نواحی مکانی مجاور ($S_{wght} = 0$)
 (۳) پیدا کردن جفت نواحی مجاور با کوچکترین



شکل ۲: مثالی از قانون تصمیم رای اکثریت در نواحی قطعه‌بندی شده

۲-۴- الگوریتم MSF

در الگوریتم MSF هر پیکسل به صورت یک راس از
 گراف $G = (V, E)$ که در آن V و E به ترتیب مجموعه
 رئوس و یال‌های گراف هستند، در نظر گرفته می‌شود،
 به طوری که هر یال $e_{i,j} \in E$ دو راس i و j مربوط به
 پیکسل‌های همسایگی را به هم وصل می‌کند. علاوه بر
 این، هر یال $e_{i,j}$ دارای وزن $w_{i,j}$ بوده که بیانگر عدم
 تشابه رئوس مربوطه می‌باشد. در این تحقیق از هشت
 راس همسایگی و اندازه‌گیری عدم تشابه SAM
 جهت محاسبه وزن یال‌ها، استفاده شد [۲۶].

با در نظر گرفتن گراف $G = (V, E)$ ، درخت پوشا
 $T = (V, E_T)$ عبارت است از گرافی متصل و بدون
 چرخش با $E_T \subset E$ و جنگل پوشا $F = (V, E_F)$
 گرافی منفصل و بدون چرخش با $E_F \subset E$ می‌باشد

لازم به ذکر است جهت محاسبه عدم تشابه در الگوریتم
 هرمی اندازه‌گیری‌های مختلفی مانند نرم بردار^۱،
 اندازه‌گیری زاویه طیفی (SAM^۲) و دیورژانس اطلاعات
 طیفی (SID^۳) مورد استفاده قرار می‌گیرد. همچنین
 این الگوریتم دارای انعطاف جهت انتخاب سطح مناسبی
 از جزئیات در نقشه قطعه‌بندی بوده هر چند ترکیب
 نواحی غیر مجاور نیاز به محاسبات بالایی داشته،
 از این رو جهت کاهش محاسبات، تخمینی از آن
 به صورت الگوریتم هرمی بازگشتی (RHSEG^۴)
 به کار گرفته می‌شود.

1 Vector Norms
 2 Spectral Angle Measure
 3 Spectral Information Divergence
 4 Recursive HSEG

رشد یافته روی ریشه‌های $\{t_1, \dots, t_m\}$ می‌باشد.

۳- آزمون‌های عملی

۳-۱- داده‌های ابرطیفی مورد استفاده

در این تحقیق، برای ارزیابی روش پیشنهادی از سه تصویر ابرطیفی Pavia، Telops و DC Mall استفاده شد که مشخصات این تصاویر در جدول (۱) خلاصه شده‌اند. برای هر یک از کلاسها در هر سه داده تصویری، به صورت تصادفی حدود ۱۰ درصد از نمونه‌های برچسب‌گذاری شده را به عنوان داده آموزشی و مابقی آنها یعنی حدود ۹۰ درصد را به عنوان داده تست انتخاب نمودیم.

[۶]. همچنین درخت پوشای مینیمم به صورت درخت پوشا $T^* = (V, E_{T^*})$ ، به طوری که مجموع وزن یال‌های آن کمترین باشد تعریف می‌گردد (رابطه ۳).

$$T^* \in \arg \min_{T \in ST} \left\{ \sum_{e_{i,j} \in E_T} w_{i,j} \right\} \quad (3)$$

در رابطه (۳)، ST مجموعه تمام درخت‌های پوشا گراف G می‌باشد.

از طرف دیگر MSF روی m راس مجزا $\{t_1, \dots, t_m\}$ شامل پیدا کردن جنگل پوشا $F^* = (V, E_{F^*})$ بوده به طوری که هر درخت مجزا F^* ، از ریشه t_i رشد یافته و مجموع وزن یال‌های آن کمترین است (رابطه ۴).

$$F^* \in \arg \min_{F \in SF} \left\{ \sum_{e_{i,j} \in E_F} w_{i,j} \right\} \quad (4)$$

در رابطه (۴)، SF مجموعه تمام جنگل‌های پوشا G

جدول ۱: خصوصیات تصاویر ابرطیفی مورد استفاده

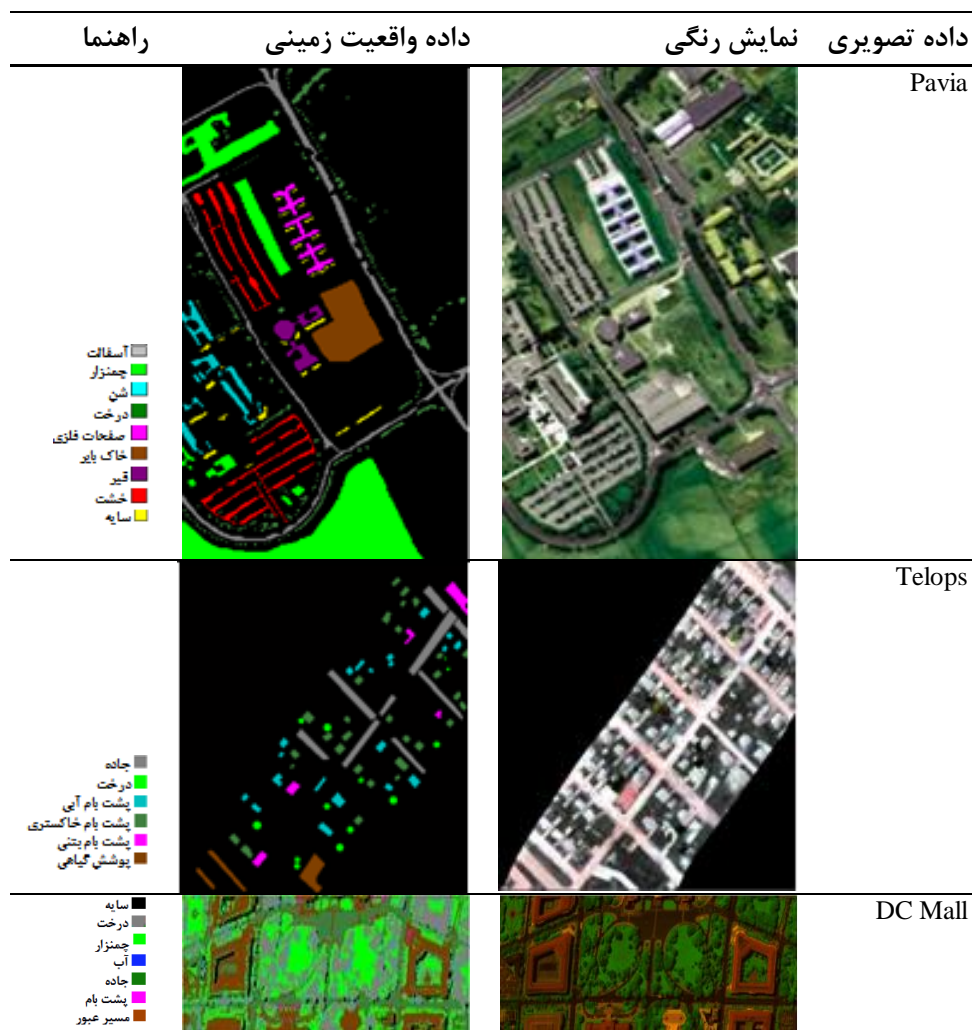
داده	سجنده	گستره	ابعاد مکانی	قدرت	تعداد	تعداد
تصویری		طیفی	(پیکسل)	تفکیک	باند‌های قابل	کلاسها
				مکانی (متر)	استفاده	
Pavia	ROSI-03	۰/۴۳-۰/۸۶	۶۱۰×۳۴۰	۱/۳	۱۰۳	۹
Telops	Hyper-Cam LWIR	۷/۸-۱۲/۵	۷۹۵×۵۶۴	۱	۸۴	۶
DC Mall	HYDICE	۰/۴-۲/۴	۱۰۰×۳۰۰	۱/۵	۱۹۱	۷

به ترتیب برابر با ۰/۵ و ۰/۰۵ در نظر گرفته شد. همچنین برای ایجاد تناسب بین دو پارامتر دقت و زمان محاسبات، اندازه جمعیت اولیه ۳۰ و حداکثر تعداد تکرار برای توقف ۱۰۰ در نظر گرفته شد. البته در عمل برای هر سه تصویر ابرطیفی با توجه به اینکه شرط فعال برای توقف الگوریتم استفاده گردیده است، پروسه تکرار به مرحله ۱۰۰ نرسیده و قبل از آن الگوریتم به وضعیت پایدار رسیده و متوقف می‌شود. شکل (۴) نمودار همگرایی الگوریتم ژنتیک و جدول (۲) تعداد باندهای انتخاب شده را برای سه تصویر ابرطیفی مورد استفاده نشان می‌دهد.

شکل (۳) نمایش رنگی سه تصویر ابرطیفی مورد استفاده به همراه داده واقعیت زمینی آنها را نشان می‌دهد. در تصویر Telops مقادیر پیکسلها برابر با مقادیر رادیانس بوده، از این رو بایستی قبل از انجام آزمون‌ها، تصحیحات اتمسفری بر روی تصویر انجام گیرد. برای این منظور از الگوریتم تصحیح حرارتی اتمسفری به کار گرفته شده در نرم افزار ENVI استفاده شد.

۳-۲- نتایج آزمون‌ها

در آزمون‌های صورت گرفته برای الگوریتم ژنتیک، کروموزوم‌ها دارای ژن‌هایی برابر با تعداد باندهای تصویر می‌باشند. در این آزمون‌ها میزان نرخ تقاطع و جهش



شکل ۳: نمایش رنگی و داده واقعیت زمینی تصاویر ابرطیفی مورد استفاده

استفاده شد [۲۷]. مقادیر دو پارامتر تنبیه C و کرنل گوسین (γ) در الگوریتم SVM به کمک تکنیک ارزیابی عرضی^۳ تعیین گردید. به طوری که مقادیر نهایی پارامترهای فوق در آزمون الگوریتم ژنتیک^۱ که برابر با مقادیر آنها در انتخاب نشانه‌ها است_ برای تصویر Pavia برابر با $C=128$ و $\gamma=0.02$ ، تصویر Telops برابر با $C=256$ و $\gamma=0.1$ و تصویر DC Mall برابر با $C=100$ و $\gamma=0.1$ بدست آمد.


جدول ۲: تعداد باندهای انتخاب شده با بکارگیری الگوریتم ژنتیک در سه تصویر ابرطیفی

داده تصویری	تعداد باندهای انتخاب شده
Pavia	۵۳
Telops	۴۷
DC Mall	۶۳

همانطور که در بخش ۲-۱ بیان شد، برای تعیین ارزش هر کروموزوم در الگوریتم ژنتیک و انتخاب نشانه‌ها از نقشه طبقه‌بندی SVM و کرنل پایه شعاعی گوسین^۱

2Penalty parameter
3Cross validation

1Gaussian Radial Basis Kernel




شکل ۴: نمودار همگرایی الگوریتم ژنتیک در تصویر (الف) Pavia، (ب) Telops و (ج) DC Mall

پارامتر S_{wght} برابر با ۰/۲ در نظر گرفته شد [۱۳]. بعد از انجام فرآیند قطعه‌بندی نقشه‌های بدست آمده به کمک قانون تصمیم‌گیری اکثریت با نقشه طبقه‌بندی SVM ترکیب گردید. روش پیشنهادی بیان شده در این تحقیق، با الگوریتم‌های واترشد مبتنی بر نشانه (M-watershed)، هرمی مبتنی بر نشانه (M-RHSEG) و MSF مبتنی بر نشانه (M-MSF) اعمال شده بر روی تمام باندهای تصویر مقایسه شد. شکل‌های (۵)، (۶) و (۷) نقشه‌های طبقه‌بندی حاصل از به کارگیری روش پیشنهادی (G-M-watershed، G-M-RHSEG، M-MSF) و روش‌های M-watershed، M-RHSEG و M-MSF را برای سه تصویر ابرطیفی

سپس آنالیز برجسب‌گذاری مولفه‌های متصل بر اساس ۸ پیکسل همسایگی بر روی نقشه طبقه‌بندی SVM انجام گرفت و برای نواحی با بیشتر از ۲۰ پیکسل، ۵ درصد از پیکسل‌های با بیشترین احتمال تعلق به یک کلاس به عنوان پیکسل‌های نشانه انتخاب شد. برای نواحی کوچک یعنی کمتر از ۲۰ پیکسل، پیکسل‌های با درجه احتمال بیشتر از یک حدآستانه به‌عنوان پیکسل‌های نشانه انتخاب گردید. حد آستانه انتخابی برابر با کمترین احتمال در بین ۲ درصد از بیشترین احتمالات کل تصویر می‌باشد [۲۶]. در آزمون‌های صورت گرفته برای الگوریتم هرمی، به دلیل پیچیدگی مناطق شهری تصاویر ابرطیفی مورد استفاده، مقدار

تصویر Pavia، Telops و DC Mall نقشه طبقه‌بندی G-M-MSF در مقایسه با سایر الگوریتم‌ها شامل مناطق یکنواختی است.

نشان می‌دهد. در اسامی فوق حرف G نشانگر الگوریتم ژنتیک و حرف M بیانگر به کارگیری نشانه‌ها قبل از الگوریتم‌های قطعه‌بندی واترشد، هرمی و MSF می‌باشد. همانطوری که ملاحظه می‌گردد، در هر سه




شکل ۵: نقشه‌های طبقه‌بندی حاصل از اعمال الگوریتم‌های (۱) M-watershed، (۲) M-RHSEG، (۳) M-MSF، (۴) G-M-MSF، (۵) watershed، (۶) G-M-MSF بر روی تصویر ابرطیفی Pavia

طبقه‌بندی بدست آمده از تصاویر ابرطیفی Pavia، DC Mall و Telops را نشان می‌دهد.


به منظور ارزیابی دقت آزمون‌های صورت گرفته، ابتدا ماتریس خطا را به کمک داده واقعیت زمینی تشکیل داده، سپس پارامترهای دقت کلی^۱ (OA)، ضریب کاپا (K) و دقت تولید کننده^۲ مربوط به هر کلاس استخراج گردید. جداول (۳)، (۴) و (۵) به ترتیب مقادیر پارامترهای دقت نقشه‌های

1 Overall Accuracy
2 Producer Accuracy



شکل ۶: نقشه‌های طبقه‌بندی حاصل از اعمال الگوریتم‌های (۱) M-watershed، (۲) M-RHSEG، (۳) M-MSF، (۴) G-M-MSF

watershed، (۵) G-M-RHSEG، (۶) G-M-MSF بر روی تصویر ابرطیفی Telops



شکل ۷: نقشه‌های طبقه‌بندی حاصل از اعمال الگوریتم‌های (۱) M-watershed، (۲) M-RHSEG، (۳) M-MSF، (۴) G-M-MSF

watershed، (۵) G-M-RHSEG، (۶) G-M-MSF بر روی تصویر ابرطیفی DC Mall

جدول ۳: مقادیر پارامترهای دقت آزمون‌های صورت گرفته برای تصویر ابرطیفی Pavia

G-M-MSF	G-M-RHSEG	G-M-watershed	M-MSF	M-RHSEG	M-watershed	تعداد باند
۵۳	۵۳	۵۳	۱۰۳	۱۰۳	۱۰۳	OA
۹۸/۸	۹۳/۵	۹۰/۱	۹۴/۷	۹۶/۱	۹۱/۴	K
۹۶/۰	۹۱/۸	۸۹/۶	۹۲/۹	۹۴/۳	۹۰/۶	آسفالت
۹۵/۴	۹۳/۷	۹۱/۵	۹۴/۲	۹۶/۲	۹۳/۰	چمنزار
۹۷/۸	۹۵/۴	۹۵/۰	۹۶/۸	۹۷/۰	۹۶/۱	شن
۸۸/۷	۸۲/۹	۷۵/۱	۸۵/۷	۸۴/۵	۷۹/۶	درخت
۹۶/۲	۹۷/۵	۸۹/۵	۹۶/۰	۹۸/۶	۹۶/۲	صفحات فلزی
۹۹/۴	۹۹/۵	۹۷/۰	۹۵/۴	۹۷/۲	۹۵/۲	خاک بایر
۱۰۰	۹۵/۹	۹۵/۹	۹۵/۲	۹۹/۵	۹۶/۴	قیر
۹۶/۹	۹۶/۷	۹۱/۶	۹۴/۲	۹۳/۲	۹۵/۱	خشت
۹۴/۵	۸۸/۱	۸۸/۰	۹۲/۳	۹۴/۵	۹۰/۲	سایه
۹۹/۰	۹۸/۹	۹۱/۸	۹۶/۵	۹۶/۸	۸۹/۹	

جدول ۴: مقادیر پارامترهای دقت آزمون‌های صورت گرفته برای تصویر ابرطیفی Telops

G-M-MSF	G-M-RHSEG	G-M-watershed	M-MSF	M-RHSEG	M-watershed	
۴۷	۴۷	۴۷	۸۴	۸۴	۸۴	تعداد باند
۹۳/۸	۸۶/۵	۸۲/۲	۹۰/۵	۸۹/۲	۸۲/۵	OA
۹۰/۲	۸۴/۴	۸۰/۳	۸۸/۹	۸۷/۲	۸۰/۹	K
۹۹/۲	۹۹/۶	۹۸/۸	۹۹/۲	۹۹/۶	۹۹/۲	جاده
۹۲/۲	۸۶/۲	۷۱/۴	۹۰/۳	۸۷/۹	۸۱/۶	درخت
۸۹/۹	۸۵/۴	۷۳/۳	۸۹/۹	۸۸/۷	۸۷/۹	پشت‌بام آبی
۸۸/۲	۸۵/۷	۸۱/۸	۹۰/۴	۸۸/۴	۸۵/۳	پشت‌بام خاکستری
۸۸/۰	۸۷/۸	۷۹/۹	۸۲/۳	۸۳/۴	۸۰/۵	پشت‌بام بتنی
۹۴/۴	۹۱/۲	۹۶/۱	۹۳/۲	۹۴/۳	۹۲/۴	پوشش گیاهی


جدول ۵: مقادیر پارامترهای دقت آزمون‌های صورت گرفته برای تصویر ابرطیفی DC Mall

G-M-MSF	G-M-RHSEG	G-M-watershed	M-MSF	M-RHSEG	M-watershed	
۶۳	۶۳	۶۳	۱۹۱	۱۹۱	۱۹۱	تعداد باند
۹۶/۴	۹۳/۳	۸۵/۱	۹۳/۱	۹۴/۳	۸۸/۱	OA
۹۳/۵	۹۱/۰	۸۱/۹	۹۰/۷	۹۱/۲	۸۵/۶	K
۹۶/۳	۹۴/۶	۹۴/۵	۹۵/۳	۹۴/۶	۹۶/۲	سایه
۹۷/۲	۹۱/۸	۹۱/۴	۹۵/۲	۹۴/۳	۹۱/۱	درخت
۸۷/۵	۸۸/۸	۸۰/۸	۸۸/۵	۸۸/۹	۸۲/۴	چمنزار
۹۳/۵	۸۹/۰	۸۹/۰	۹۰/۰	۸۹/۶	۹۰/۵	آب
۹۲/۴	۹۰/۲	۸۸/۷	۹۰/۱	۹۱/۹	۸۷/۹	جاده
۹۸/۵	۹۶/۹	۹۴/۹	۹۶/۴	۹۸/۴	۹۵/۹	پشت‌بام
۹۳/۳	۸۷/۴	۸۱/۷	۹۰/۳	۸۹/۸	۸۶/۲	مسیر عبور


پارامتر دقت کلی است. میزان کاهش در تصویر Telops برای الگوریتم واترشد برابر ۰/۳ درصد و برای الگوریتم هرمی حدود ۳ درصد دقت کلی می‌باشد. همچنین برای تصویر DC Mall کاهش برابر با ۳ و ۱ درصد در الگوریتم‌های واترشد و هرمی به ترتیب رخ داده است. این کاهش مقادیر دقت در دو الگوریتم واترشد و هرمی می‌تواند به دلیل این باشد که این الگوریتم‌ها جزء الگوریتم‌های قطعه‌بندی رشد ناحیه بوده که به صورت مستقل از باندهای تصویر عمل می‌کنند.

همانطوری که از این جداول و شکل (۸) مشخص است کاهش ابعاد در هر سه تصویر ابرطیفی برای الگوریتم MSF یعنی G-M-MSF، باعث افزایش دقت طبقه‌بندی شده است که این افزایش برای تصویر Pavia حدود ۴ درصد و برای تصاویر Telops و DC Mall حدود ۳ درصد در مقایسه با الگوریتم M-MSF در پارامتر دقت کلی می‌باشد. در دو الگوریتم واترشد و هرمی کاهش ابعاد سبب کاهش دقت طبقه‌بندی شده است، که این کاهش برای تصویر Pavia در الگوریتم واترشد حدود ۱ درصد و در الگوریتم هرمی حدود ۳ درصد


تاثیر انتخاب ویژگی به کمک الگوریتم ژنتیک بر طبقه‌بندی...
 داود اکبری، عبدالرضا صفری، صفا خزائی



(الف)



(ب)



(ج)

شکل ۸: مقادیر دقت کلی و ضریب کاپا برای الگوریتم‌های طبقه‌بندی مختلف در تصویر (الف) Pavia، (ب) Telops و (ج) DC Mall

دقت تولیدکننده در هر سه تصویر، اکثرا مربوط به الگوریتم G-M-MSF می‌شود. به طوری که در تصویر Pavia به جز کلاس شن و در تصویر DC Mall به جز کلاس چمنزار، مابقی کلاس‌ها دارای دقتی بیشتر از ۹۰ درصد هستند.

جدول (۶) مدت زمان اجرای الگوریتم‌های طبقه‌بندی مورد استفاده در این تحقیق را نشان می‌دهد. همانطور که ملاحظه می‌شود کمترین زمان مربوط به الگوریتم واترشد و بیشترین زمان مربوط به الگوریتم هر می در سه تصویر ابر طیفی مورد استفاده می‌باشد. همچنین مدت زمان به کارگیری الگوریتم G-M-MSF یعنی دقیق‌ترین الگوریتم پیشنهادی نزدیک به الگوریتم G-M-watershed و بسیار کمتر از الگوریتم G-M-RHSEG می‌باشد.

به عبارت دیگر الگوریتم‌های واترشد و هر می جزء روش‌های قطعه‌بندی مکانی بوده که عمل گروه‌بندی پیکسل‌های همسایه را با در نظر گرفتن معیاری مشخص انجام می‌دهند. در حالی که الگوریتم MSF جزء الگوریتم‌های قطعه‌بندی گراف مینا می‌باشد که به باندهای تصویر وابسته است و از این رو کاهش ابعاد و حذف باندهای نویزی می‌تواند باعث افزایش دقت این الگوریتم شود. به بیان دیگر، الگوریتم MSF جزء روش‌های قطعه‌بندی طیفی-مکانی است که با در نظر گرفتن اطلاعات طیفی و مکانی پیکسل‌ها، عمل قطعه‌بندی تصویر را انجام می‌دهد. از این رو در این الگوریتم نتایج حاصله متأثر از ویژگی‌های طیفی مورد استفاده بوده و با انتخاب ویژگی‌های طیفی بهینه می‌توان به نتایج بهتری دست یافت. همچنین با توجه به جداول (۳)، (۴) و (۵)، بهترین مقادیر

جدول ۶: مدت زمان اجرای الگوریتم‌های طبقه‌بندی مورد استفاده در سه تصویر ابرطیفی (اعداد بر حسب ثانیه می‌باشند).

داده	M-watershed	M-RHSEG	M-MSF	G-M-watershed	G-M-RHSEG	G-M-MSF
Pavia	۶۴	۳۵۵	۱۱۱	۳۳۲	۵۱۲	۳۵۱
Telops	۵۸	۳۲۲	۱۰۲	۲۴۸	۴۰۸	۲۷۱
DC Mall	۳۴	۲۶۸	۸۴	۱۵۲	۳۷۲	۱۹۸

SVM به کمک قانون تصمیم رای اکثریت ترکیب گردید. روش پیشنهادی بر روی سه تصویر ابرطیفی بنچ مارک Pavia، Telops و DC Mall پیاده سازی شد. آزمایشات عملی صورت گرفته برتری کمی و کیفی به کارگیری کاهش باند در الگوریتم MSF و استفاده از تمام باندهای تصویر را در الگوریتم‌های واترشد و هر می نشان می‌دهد. در بین الگوریتم‌های طبقه‌بندی اعمال شده بر روی تمام باندهای تصویر، الگوریتم هر می در تصویر Pavia و DC Mall و الگوریتم MSF در تصویر Telops به بهترین نتایج دست یافتند. از طرف دیگر در بین الگوریتم‌های اعمال شده بر روی باندهای کاهش یافته، الگوریتم MSF در هر سه تصویر ابرطیفی

۴- نتیجه‌گیری

در این تحقیق تاثیر کاهش ابعاد به کمک الگوریتم ژنتیک بر الگوریتم‌های طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی بررسی شد. الگوریتم ژنتیک یکی از کارآمدترین و موثرترین الگوریتم‌ها در کاهش ابعاد تصاویر ابرطیفی است. از طرف دیگر الگوریتم‌های قطعه‌بندی واترشد، هر می و MSF مبتنی بر نشانه مورد استفاده در این تحقیق نیز جزء دقیق‌ترین الگوریتم‌های استخراج اطلاعات مکانی در تصاویر ابرطیفی می‌باشند. در روش پیشنهادی بعد از انجام عمل قطعه‌بندی بر روی تصویر با باندهای کاهش یافته، نقشه نواحی بدست آمده با نقشه طبقه‌بندی

ضریب کاپا به میزان ۶، ۱۰ و ۸ درصد در مقایسه با الگوریتم M-watershed و به ترتیب در تصاویر Pavia، DC Mall و Telops شده است.

دارای بهترین نتایج می‌باشد. همچنین الگوریتم G-M-MSF بهترین مقادیر دقت را در بین الگوریتم‌های طبقه‌بندی مطرح شده داشته و باعث افزایش پارامتر

مراجع

- [1] P. K. Varshney, and M. K. Arora, "Advanced Image Processing Techniques for Remotely Sensed Hyperspectral Data", Springer Berlin Heidelberg New York, 2004.
- [2] R. C. Gonzalez, and R. E. Woods, "Digital Image Processing", Prentice Hall, 2002, 617 – 626.
- [3] S. Homayouni, and M. Roux, "Material Mapping from Hyperspectral Images using Spectral Matching in Urban Area", IEEE Workshop on Advances in Techniques for analysis of Remotely Sensed Data, NASA Goddard center, Washington DC, USA, 2003.
- [4] C. I. Chang, *Hyperspectral Imaging: Techniques for spectral Detection and Classification*. Orlando, FL: Kluwer Academic, 2003.
- [5] V. Vapnik, *The Nature of Statistical Learning Theory*. New York, NY: Springer-Verlag, 1995.
- [6] Y. Tarabalka, J. Chanussot, and J. A. Benediktsson, "Segmentation and classification of hyperspectral images using minimum spanning forest grown from automatically selected markers", IEEE Trans. Syst., Man, Cybern. B, Cybern., vol. 40, pp. 1267–1279, 2010.
- [7] J. A. Richards, and X. Jia, *Remote Sensing Digital Image Analysis: An Introduction*. Springer-Verlag Berlin Heidelberg, 2006.
- [8] J. A. Richards, and X. Jia, *Remote Sensing Digital Image Analysis: An Introduction*. Springer-Verlag Berlin Heidelberg, 2006.
- [9] X. Huang, and L. Zhang, "A comparative study of spatial approaches for urban mapping using hyperspectral rosis images over pavia city, northern Italy", International Journal of Remote Sensing, 30(12):3205–3221, 2009.
- [10] J. A. Benediktsson, M. Pesaresi, and K. Arnason, "Classification and feature extraction for remote sensing images from urban areas based on morphological transformations", IEEE Trans. Geos. And Remote Sens., 41(9):1940–1949, 2003.
- [11] M. Pesaresi, and J. A. Benediktsson, "A new approach for the morphological segmentation of high-resolution satellite imagery", IEEE Trans. Geosci. Remote Sens., vol. 39, no. 2, pp. 309–320, 2001.
- [12] J. A. Benediktsson, J. A. Palmason, and J. R. Sveinsson, "Classification of hyperspectral data from urban areas based on extended morphological profiles", IEEE Trans. Geos. and Remote Sens., 43(3):480–491, 2005.
- [13] Y. Tarabalka, J. C. Tilton, J. A. Benediktsson, and J. Chanussot, "A Marker-Based Approach for the Automated Selection of a Single Segmentation from a Hierarchical Set of Image Segmentations", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2011.
- [14] A. Bitam, and S. Ameur, "A local-spectral fuzzy segmentation for MSG multispectral images", International Journal of Remote Sensing, 34: 8360–8372, 2013.
- [15] Y. Tarabalka, J. A. Benediktsson, and J. Chanussot, "Spectral-spatial classification of hyperspectral imagery based on partitionial clustering techniques", IEEE Translation Geoscience Remote Sensing, 47(9): 2973–2987, 2009.
- [16] Y. Tarabalka, J. A. Benediktsson, J. Chanussot, and J. C. Tilton, "Multiple spectral-spatial classification approach for hyperspectral data", IEEE Translation Geoscience Remote Sensing, 48(11): 4122–4132, 2010.
- [17] P. Soille, *Morphological Image Analysis*. 2nd ed. Berlin, Germany: Springer-Verlag, 2003.
- [18] O. Gómez, J. A. González, and E. F. Morales, "Image segmentation using automatic seeded region growing and instance-based learning", in Proc. 12th Iberoamerican Congress Pattern Recognition, Valparaiso, Chile, 192–201, 2007.
- [19] G. Noyel, "Filtrage, Réduction de

- Dimension, Classification et Segmentation Morphologique Hyperspectrale", Ph.D. dissertation, Ctr. Mathematical Morphology, Paris Sch. Mines, Paris, France, 2008.
- [20] G. Noyel, J. Angulo, and D. Jeulin, "Morphological segmentation of hyperspectral images", *Image Anal. Stereol.*, 26: 101-109, 2007.
- [21] L. Zhuo, and J. Zheng, "A Genetic Algorithm Based Wrapper Feature Selection Method for Classification of Hyperspectral Image Using Support Vector Machine", *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 397-402, 2008.
- [22] C.-L. Huang, and C.-J. Wang, "A GA-based feature selection and parameter optimization for support vector machines", *Expert Systems with Application*, 231-240, 2006.
- [23] L. Vincent, and P. Soille, "Watersheds in digital spaces: an efficient algorithm based on immersion simulations", *IEEE Transaction Pattern Anal. Mach. Intell.*, 583-598, 1991.
- [24] J. Tilton, "Analysis of hierarchically related image segmentations", in *Proc. IEEE Workshop Adv. Tech. Anal. Remotely Sensed Data*, 60-69, 2003.
- [25] J. Tilton, "RHSEG User's Manual: Including the Core RHSEG Open Source Release, HSEGExtract, HSEGReader and HSEGViewer", 2009.
- [26] F. Van der Meer, "The effectiveness of spectral similarity measures for the analysis of hyperspectral imagery", *Int. J. Appl. Earth Observation Geoinformation*, vol. 8, no. 1, pp. 3-17, 2006.
- [27] N. Cristianini, and J. Shawe-Taylor, "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods", Cambridge University Press, 2000.



The effect of feature selection using genetic algorithms on spectral-spatial classification of hyperspectral imagery

Davood Akbari¹, Abdolreza Safari², Safa Khazai³

1- Remote Sensing PhD student, School of Surveying and Geospatial Engineering, University of Tehran

2- Associate Professor of Geodesy, School of Surveying and Geospatial Engineering, University of Tehran

3- Assistant Professor of Remote Sensing, Civil Engineering Department, Imam Hussein Comprehensive University

Abstract

Hyperspectral remote sensing technologies have many applications in land cover classification and study their changes. With recent developments and create images with high spatial resolution, it is necessary the use of both spatial and spectral information in hyperspectral image classification. In this paper, we have evaluated the effect of dimensionality reduction using genetic algorithm on spectral-spatial classification of hyperspectral imagery. So far, among the various algorithms spectral-spatial classification of hyperspectral images, three segmentation algorithms, watershed, hierarchical and Minimum Spanning Forest (MSF) based on markers, combined with Support Vector Machines (SVM) to achieve the best results. In the proposed approach, the dimension of hyperspectral images is first reduced by using genetic algorithm. Then, the three mentioned segmentation algorithms are applied on the resulting bands. Finally, the obtained segmentation maps are combined with SVM classification map using majority voting rule. The proposed approach was implemented on three hyperspectral data sets, the Pavia dataset, the Telops dataset, and the DC Mall dataset. The obtained experimental results indicate the superiority use of reduced bands in MSF based on markers algorithm and all bands in watershed and hierarchical based on markers algorithms.

Key words: Hyperspectral image, Spectral-Spatial Classification, Dimensionality reduction, Genetic algorithm.