

## بهبود طبقه بندی طیفی - مکانی جنگل پوشای مینیمم با کاهش ابعاد تصاویر فراطیفی

داود اکبری\*<sup>۱</sup>، عبدالرضا صفری<sup>۲</sup>، صفا خزائی<sup>۳</sup>، سعید همایونی<sup>۴</sup>

<sup>۱</sup> دانشجوی دکتری سنجش از دور - دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی دانشگاه تهران  
davoodakbari@ut.ac.ir

<sup>۲</sup> دانشیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران  
asafari@ut.ac.ir

<sup>۳</sup> استادیار گروه مهندسی عمران - دانشکده فنی - دانشگاه جامع امام حسین (ع)  
khazai@ut.ac.ir

<sup>۴</sup> استادیار گروه جغرافیا، مطالعات محیطی و ژئوماتیک - دانشگاه اوتاوا - کانادا  
saeid.homayouni@uottawa.ca

(تاریخ دریافت مرداد ۱۳۹۳، تاریخ تصویب تیر ۱۳۹۴)

### چکیده

فن آوری سنجش از دور فراطیفی دارای کاربردهای فراوان در طبقه بندی پوشش های زمین و بررسی تغییرات آنها است. با پیشرفت های اخیر و ایجاد تصاویری با قدرت تفکیک مکانی بالا، لزوم استفاده توأم از اطلاعات طیفی و مکانی را در طبقه بندی تصاویر فراطیفی ایجاب می کند. در این تحقیق روشی جدید جهت طبقه بندی طیفی-مکانی تصاویر فراطیفی به کمک الگوریتم جنگل پوشای مینیمم مبتنی بر نشانه ها که یکی از دقیق ترین الگوریتم ها در این زمینه است و تکنیک کاهش ابعاد معرفی می شود. در روش پیشنهادی تاثیر کاهش ابعاد تصاویر فراطیفی به کمک الگوریتم ژنتیک در سه مرحله قبل و بعد از انتخاب نشانه ها و به صورت همزمان بررسی می گردد. در این مطالعه نشانه ها از روی نقشه طبقه بندی ماشین بردار پشتیبان انتخاب شدند. روش پیشنهادی بر روی سه تصویر فراطیفی Pavia، Telops و Indian Pines پیاده سازی گردید، نتایج آزمایشات بدست آمده برتری به کارگیری الگوریتم ژنتیک را قبل از انتخاب نشانه ها در تصاویر Pavia و Telops نشان می دهد. در تصویر Indian Pines کاهش ابعاد در هر دو مرحله قبل و بعد از انتخاب نشانه ها و به صورت همزمان موجب افزایش دقت طبقه بندی می گردد.

**واژگان کلیدی:** تصویر فراطیفی، طبقه بندی طیفی-مکانی، الگوریتم جنگل پوشای مینیمم مبتنی بر نشانه ها، الگوریتم ژنتیک

\* نویسنده رابط

## ۱- مقدمه

فن آوری سنجش از دور فراطیفی، 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 می‌باشد [۱]، [۲]. هر چند، توانایی تولید داده‌هایی با خصوصیات طیفی، مکانی و رادیومتریکی بالا، منجر به تجزیه و تحلیل بهتر آن‌ها 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 ویژه جهت پردازش دارد. زمان مورد نیاز برای پردازش این نوع داده‌ها، از مشکلات دیگر پیش رو است [۳].

امروزه اکثر تحقیقات در زمینه فن آوری سنجش از دور فراطیفی، بر طبقه‌بندی این تصاویر تاکید دارد. طبقه‌بندی 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 [۴]. به طور کلی روش‌های طبقه‌بندی تصاویر فراطیفی، 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 [۶، ۷]. در این دسته از الگوریتم‌ها، استفاده از اطلاعات مکانی به روش‌های مختلف صورت می‌گیرد. ساده‌ترین روش، استفاده از اطلاعات نزدیکترین همسایگی‌ها است [۸]. بر اساس این راه حل، Jackson در سال ۲۰۰۲ میلادی [۹] طبقه‌بندی‌کننده آماری مبتنی بر مدل MRF<sup>۱</sup> پیشنهاد داد. Huang در سال ۲۰۰۹ میلادی [۱۰] اطلاعات مکانی بدست آمده از ماتریس هم‌وقوع (GLCM)<sup>۲</sup> را برای طبقه‌بندی داده فراطیفی به کار گرفت. در روش پیشنهاد شده توسط

Huang ابتدا ویژگی‌های بافت<sup>۳</sup> از روی ماتریس GLCM و با استفاده از چهار اندازه‌گیری، مولفه دوم زاویه‌ای<sup>۴</sup>، کنتراست<sup>۵</sup>، آنروپی<sup>۶</sup> و یکنواختی<sup>۷</sup> استخراج گردید، سپس آنالیز مولفه‌های اصلی (PCA)<sup>۸</sup> بر روی ویژگی‌های بدست آمده اعمال گشته و مولفه‌های اصلی به عنوان ویژگی‌های ورودی برای طبقه‌بندی‌کننده بیشترین شباهت<sup>۹</sup> انتخاب شدند. Bendiksoon در سال ۲۰۰۳ میلادی روش نیمرخ همسایگی<sup>۱۰</sup> را به عنوان روشی دیگر جهت استفاده از اطلاعات مکانی پیشنهاد داد [۱۱]. نیمرخ همسایگی از ترکیب فیلترهای Opening و Closing تشکیل یافته است. اعمال روش فوق بر روی باندهای مختلف تصویر به نام نیمرخ همسایگی توسعه یافته<sup>۱۱</sup> شناخته می‌باشد [۱۲]. ایجاد نیمرخ همسایگی توسعه یافته بر روی تمام باندهای تصویر فراطیفی نادرست بوده و باعث ایجاد ویژگی‌های وابسته می‌گردد، از این رو کاهش تعداد باندهای تصویر فراطیفی قبل از اعمال نیمرخ همسایگی الزامی است. در همین راستا در [۱۳] 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<sup>۱۲</sup> است که در آن بر اساس ویژگی‌هایی مانند یکنواختی، اهداف موجود در تصویر (مجموعه-ای از پیکسل‌ها با ویژگی یکسان) شناسایی می‌شوند [۱۴]. مزایای استفاده از روش‌های قطعه‌بندی در [۱۵، ۱۶، ۱۷] بیان شده است. یک روش معمول جهت داشتن نتایج قطعه‌بندی دقیق، روش قطعه‌بندی مبتنی بر نشانه‌ها می‌باشد [۱۴، ۱۸]، 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 [۱۸]. Gómez در [۱۹]

<sup>۳</sup> Texture Features

<sup>۴</sup> Angular Second Moment

<sup>۵</sup> Contrast

<sup>۶</sup> Entropy

<sup>۷</sup> Homogeneity

<sup>۸</sup> Principal Component Analysis

<sup>۹</sup> Maximum Likelihood

<sup>۱۰</sup> Morphological Profiles

<sup>۱۱</sup> Extended Morphological Profiles

<sup>۱۲</sup> Segmentation

<sup>۱</sup> Markov Random Field

<sup>۲</sup> Gray Level Co-occurrence Matrix

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  $e_{ij} \in E$  دو راس  $i$  و  $j$  مربوط به پیکسل‌های همسایگی را به هم وصل می‌کند. علاوه بر این، هر یال  $e_{ij}$  دارای وزن  $w_{ij}$  بوده که بیانگر عدم تشابه رئوس مربوطه می‌باشد. اندازه‌گیری‌های عدم تشابه مختلفی مانند نرم‌های برداری<sup>۳</sup>، اندازه‌گیری زاویه طیفی (SAM)<sup>۴</sup> و دیورژانس اطلاعات طیفی (SID)<sup>۵</sup> می‌تواند جهت محاسبه وزن یال‌ها مورد استفاده قرار گیرد [۲۲]. در این تحقیق از هشت راس همسایگی و اندازه‌گیری عدم تشابه SAM جهت محاسبه وزن یال‌ها، استفاده شد.

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. با حذف یک یال از درخت پوشا می‌توان دو درخت پوشا ایجاد کرد [۱۴]. همچنین درخت پوشای مینیمم به صورت درخت پوشا کمترین  $T^* = (V, E_{T^*})$ ، به طوری که مجموع وزن یال‌های آن کمترین باشد تعریف می‌گردد (رابطه ۱).

$$T^* \in \operatorname{argmin}_{T \in \mathcal{ST}} \left\{ \sum_{e_{ij} \in E_T} w_{ij} \right\} \quad (1)$$

در رابطه (۱)،  $\mathcal{ST}$  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 ۲).

$$F^* \in \operatorname{argmin}_{F \in \mathcal{SF}} \left\{ \sum_{e_{ij} \in E_F} w_{ij} \right\} \quad (2)$$

در رابطه (۲)،  $\mathcal{SF}$  مجموعه تمام جنگل‌های پوشا  $G$  رشد یافته روی ریشه‌های  $\{t_1, \dots, t_m\}$  می‌باشد.

برای ایجاد MSF مبتنی بر نشانه‌ها، ابتدا  $n$  راس  $(t_i \ i = 1, \dots, n)$  به گراف اضافه شده،  $n$  برابر تعداد

به کمک هیستوگرام تصویر پیکسل‌های با مقادیر یکسان را به عنوان نشانه اختیار نمود. Noyel و همکارانش با انجام طبقه‌بندی تصویر فراطیفی و سپس فیلتر نمودن آن به کمک عملگرهای همسایگی، مناطق مکانی بزرگ را به عنوان نشانه انتخاب نمودند [۲۰، ۲۱]. در تحقیق دیگری که اخیراً توسط Tarabalka و همکاران او جهت طبقه‌بندی طیفی-مکانی تصاویر فراطیفی پیشنهاد شده است، از الگوریتم قطعه‌بندی-طبقه‌بندی جنگل پوشای مینیمم (MSF)<sup>۱</sup> مبتنی بر نشانه‌ها استفاده شد [۱۴]. آنها به کمک نقشه طبقه‌بندی ماشین بردار پشتیبان (SVM)<sup>۲</sup> پیکسل‌هایی با درجه تعلق بالا به هر کلاس را به عنوان نشانه انتخاب نمودند. برای این منظور ابتدا روی نقشه طبقه‌بندی 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، روش طبقه‌بندی Tarabalka در مقایسه با سایر روش‌های طبقه‌بندی طیفی-مکانی در تصاویر فراطیفی به بهترین نتایج دست یافته است. از این رو در این تحقیق سعی می‌گردد روش طبقه‌بندی مذکور به کمک تکنیک کاهش ابعاد تصاویر فراطیفی بهبود داده شود. برای این منظور به کمک الگوریتم ژنتیک که یکی از دقیق‌ترین الگوریتم‌ها در این زمینه می‌باشد، در سه مرحله قبل و بعد از انتخاب نشانه‌ها و به صورت همزمان ابعاد تصویر فراطیفی کاهش یافت. در ادامه تحقیق، در بخش ۲ الگوریتم قطعه‌بندی-طبقه‌بندی MSF مبتنی بر نشانه‌ها، تشریح می‌شود. سپس در بخش ۳ روش طبقه‌بندی طیفی-مکانی پیشنهادی بیان گشته و در بخش ۴ به تشریح آزمون‌های عملی صورت گرفته، پرداخته شده است و در نهایت در بخش پایانی نتیجه‌گیری از موارد بیان شده ارائه می‌گردد.

## ۲- الگوریتم MSF مبتنی بر نشانه‌ها

در این تحقیق از الگوریتم MSF مبتنی بر نشانه‌ها جهت طبقه‌بندی طیفی-مکانی تصاویر فراطیفی استفاده شد. در الگوریتم MSF هر پیکسل به صورت یک راس از

<sup>۳</sup> Vector Norms

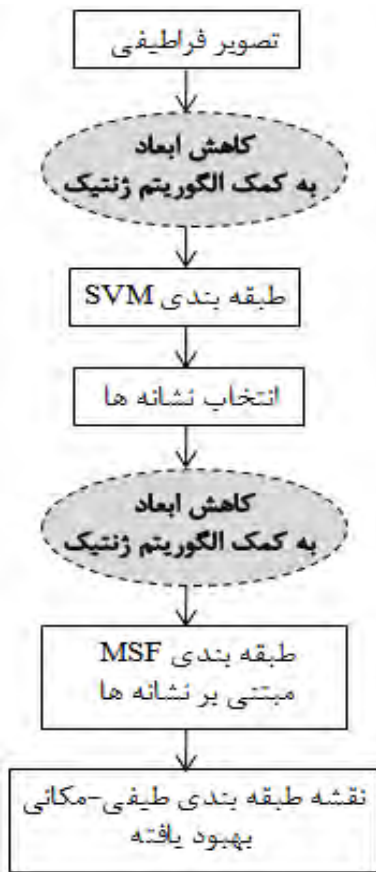
<sup>۴</sup> Spectral Angle Measure

<sup>۵</sup> Spectral Information Divergence

<sup>۱</sup> Minimum Spanning Forest

<sup>۲</sup> Support Vector Machines


سوم هر دو مرحله انتخاب نشانه‌ها و پیاده‌سازی الگوریتم MSF بر روی تصویر با باندهای کاهش یافته اعمال می‌شود.



شکل ۲- مراحل روش پیشنهادی

الگوریتم ژنتیک که جزء تکنیک‌های بهینه‌سازی فرا ابتکاری می‌باشد، متداول‌ترین نوع الگوریتم‌های تکاملی است که رویه واحدی برای آن وجود نداشته و دارای رویه-ای تکراری است [۲۳، ۲۴، ۲۵]. در طی هر بار تکرار الگوریتم (نسل)، افراد موجود در جمعیت فعلی بر اساس میزان شایستگی‌شان مرتب شده و با استفاده از عملگرهای ژنتیک انتخاب<sup>۱</sup>، تقاطع<sup>۲</sup> و جهش<sup>۳</sup>، جمعیت جدیدی از راه حل‌ها تولید می‌گردد. این رویه تا زمان برقراری شرط خاتمه الگوریتم ادامه می‌یابد [۲۳]. 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 [۲۳، ۲۶]. در این تحقیق از

کلاسهای مسئله است، سپس از نشانه‌های کلاس یک به راس یک، نشانه‌های کلاس دو به راس دو و به همین ترتیب نشانه‌های کلاس  $n$  به راس  $n$  یال‌هایی با وزن صفر ایجاد می‌شود. در مرحله بعد راس دیگری مانند  $r$  به مجموعه اضافه و از  $n$  راس اضافه شده در مرحله قبل یالهایی با وزن صفر به آن وصل می‌گردد (شکل ۱). بعد از ایجاد درخت پوشای مینیوم گراف  $G$  و حذف یال‌های مربوط به راس  $r$  MSF حاصل می‌شود. در MSF هر درخت روی یکی از  $n$  راس اضافه شده رشد می‌نماید. در نهایت با اختصاص دادن کلاس هر نشانه به همه پیکسل‌های رشد یافته از آن، نقشه طبقه‌بندی طیفی-مکانی حاصل می‌گردد.



شکل ۱- مثالی از اضافه شدن رئوس  $t_1$ ،  $t_2$  و  $r$  به گراف تصویر جهت ساخت MSF روی نشانه‌های ۱ و ۲، پیکسل‌های غیر نشانه با عدد صفر نشان داده شده است

### ۳- روش پیشنهادی

شکل (۲) مراحل روش طبقه‌بندی طیفی-مکانی پیشنهادی را نشان می‌دهد. همانطوری که ملاحظه می‌گردد در روش پیشنهادی کاهش ابعاد تصویر فراطیفی در سه مرحله قبل و بعد از انتخاب نشانه‌ها و به صورت همزمان بررسی می‌شود. به‌طور کلی این تحقیق به دنبال تاثیر کاهش ابعاد تصاویر فراطیفی قبل از دو مرحله اصلی الگوریتم MSF مبتنی بر نشانه‌ها یعنی انتخاب نشانه‌ها و اعمال MSF است. برای این منظور در روش پیشنهادی اول ابتدا به کمک الگوریتم ژنتیک ابعاد تصویر فراطیفی کاهش یافته سپس طبقه‌بندی SVM جهت انتخاب نشانه‌ها-ها بر روی باندهای بدست آمده اعمال گشته و در ادامه الگوریتم MSF بر روی تمامی باندهای تصویر اولیه اعمال می‌شود. در روش پیشنهادی دوم نشانه‌ها از روی تمام باندهای تصویر انتخاب گشته سپس ابعاد تصویر به کمک الگوریتم ژنتیک کاهش یافته و الگوریتم MSF بر روی باندهای بدست آمده اعمال می‌گردد. در روش پیشنهادی

۱ Select

۲ Crossover

۳ Mutation

برای این منظور از الگوریتم تصحیح حرارتی اتمسفری به کار گرفته شده در نرم افزار ENVI استفاده شد. قابل ذکر است، از آنجایی که هدف اصلی این مطالعه ارائه و مقایسه الگوریتم‌هایی جهت طبقه‌بندی تصاویر فراطیفی است، از این‌رو گستره طیفی تصاویر مورد استفاده برای رسیدن به این هدف از اهمیتی برخوردار نمی‌باشد و همان‌طور که در جدول (۱) ملاحظه می‌گردد، تصویر Pavia در ناحیه مرئی و مادون قرمز نزدیک، تصویر Indian Pines در ناحیه مرئی، مادون قرمز نزدیک و میانه و تصویر Telops در ناحیه مادون قرمز دور طیف الکترومغناطیس قرار دارند.

#### ۴-۲- نتایج آزمون‌ها

در این تحقیق برای انتخاب نشانه‌ها از نقشه طبقه‌بندی SVM و کرنل پایه شعاعی گوسین<sup>۵</sup> استفاده شد [۲۷]. مقادیر دو پارامتر تنبیه<sup>۶</sup> (C) و کرنل گوسین (γ) در الگوریتم SVM به کمک تکنیک ارزیابی عرضی<sup>۷</sup> تعیین گردید. مقادیر پارامترهای فوق برای تصویر Pavia برابر با  $C=128$  و  $\gamma=0/02$ ، برای تصویر Telops برابر با  $C=256$  و  $\gamma=0/1$  و برای تصویر Indian Pines برابر با  $C=100$  و  $\gamma=0/001$  بدست آمد. سپس آنالیز برچسب‌گذاری 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 به عنوان پیکسل‌های نشانه انتخاب گردید. حد آستانه انتخابی برابر با کمترین احتمال در بین ۲ درصد از بیشترین احتمالات کل تصویر می‌باشد [۲۲].

پارامتر ضریب کاپا<sup>۱</sup> طبقه‌بندی SVM جهت تعیین ارزش هر کروموزوم استفاده شد. همچنین از روش چرخ رولت<sup>۲</sup> برای عملگر انتخاب استفاده شده است، در این روش احتمال انتخاب هر کروموزوم متناسب با مقدار شایستگی آن می‌باشد [۲۶]. از عملگر تقاطع با یک نقطه<sup>۳</sup> برش و نیز عملگر جهش جهت جلوگیری از انتخاب بهینه‌های محلی<sup>۴</sup> استفاده گردید [۲۳]. 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<sup>۴</sup> که صد نسل در نظر گرفته شده است رخ ندهد، الگوریتم متوقف می‌شود و در غیر اینصورت تکرار تا نسل صدم ادامه می‌یابد.

#### ۴-۲- آزمون‌های عملی

##### ۴-۱- داده‌های فراطیفی مورد استفاده

در این تحقیق، برای ارزیابی روش پیشنهادی از سه تصویر فراطیفی Pavia، Indian Pines و Telops که جزء تصاویر پنج مارک در حوزه سنجش از دور فراطیفی بوده و برای بررسی الگوریتم‌های طبقه‌بندی پیشنهادی به کار می‌روند، استفاده شد. مشخصات این تصاویر در جدول (۱) خلاصه شده‌اند. تصاویر Pavia و Telops به ترتیب مربوط به منطقه شهری Pavia از کشور ایتالیا و Quebec از کشور کانادا می‌باشند و تصویر سوم از یک منطقه کشاورزی در کشور هندوستان است. کلاس‌های مشخص شده در هر تصویر متناسب با نوع و عوارض موجود در آن تصویر می‌باشد. برای هر یک از کلاسها در هر سه داده تصویری، به صورت تصادفی حدود ۱۰ درصد از نمونه‌های برچسب گذاری شده را به عنوان داده آموزشی و مابقی آنها یعنی حدود ۹۰ درصد را به عنوان داده تست انتخاب نمودیم. شکل (۳) نمایش رنگی سه تصویر فراطیفی مورد استفاده به همراه داده واقعیت زمینی آنها را نشان می‌دهد. در تصویر Telops برخلاف دو تصویر دیگر مقادیر پیکسلها برابر با مقادیر رادیانس بوده، از این رو بایستی قبل از انجام آزمون‌ها، تصحیحات اتمسفری بر روی تصویر انجام گیرد.

۵ Gaussian Radial Basis Kernel

۶ Penalty parameter

۷ Cross validation

۱ Kappa Coefficient

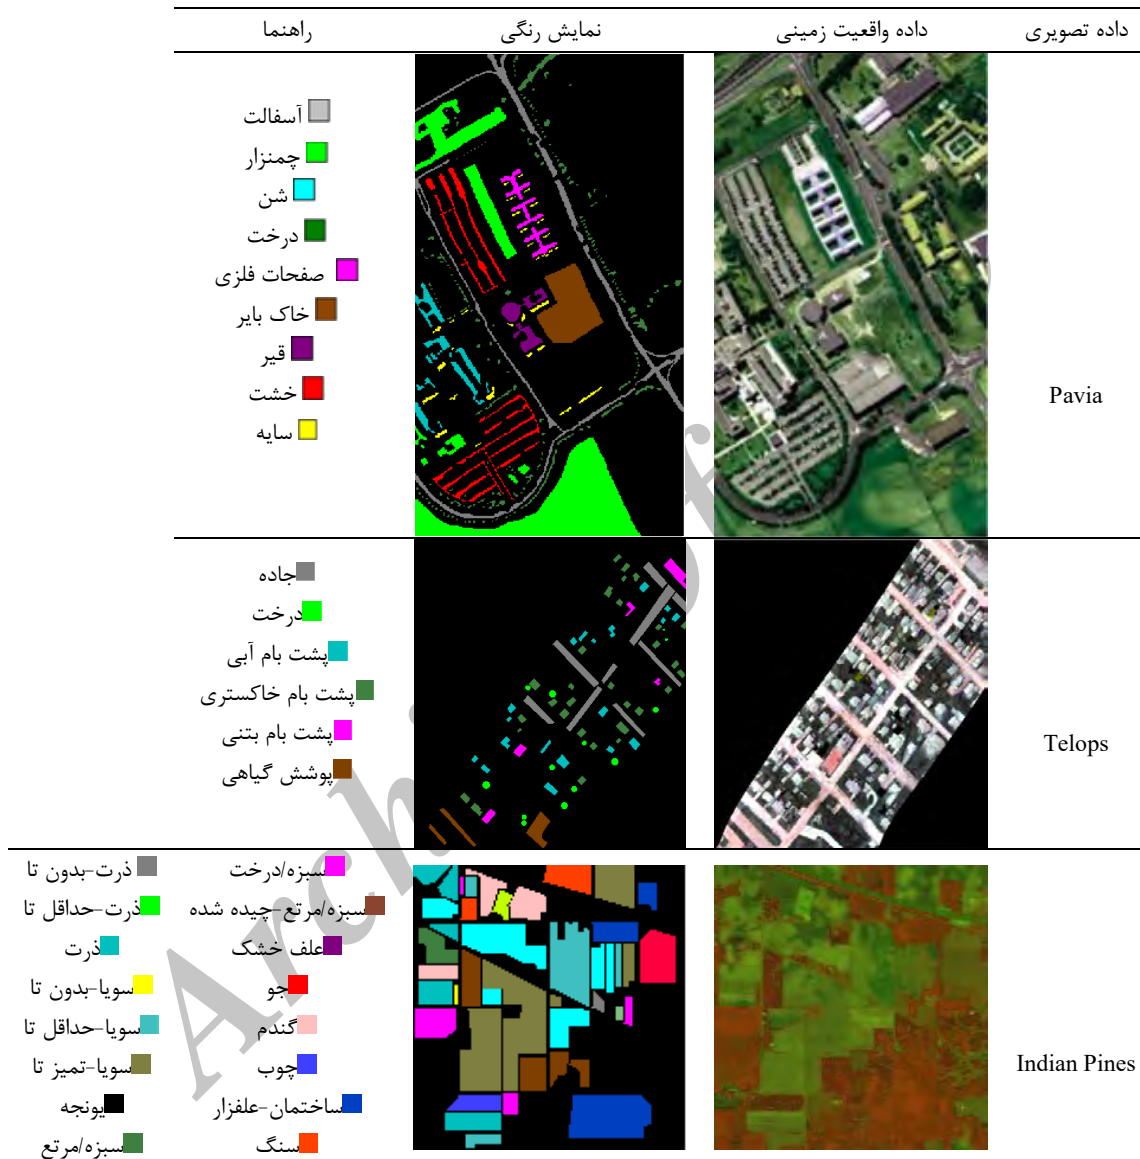
۲ Roulette Wheel

۳ Single Point

۴ Local Optimal

جدول ۱- خصوصیات تصاویر فراطیفی مورد استفاده

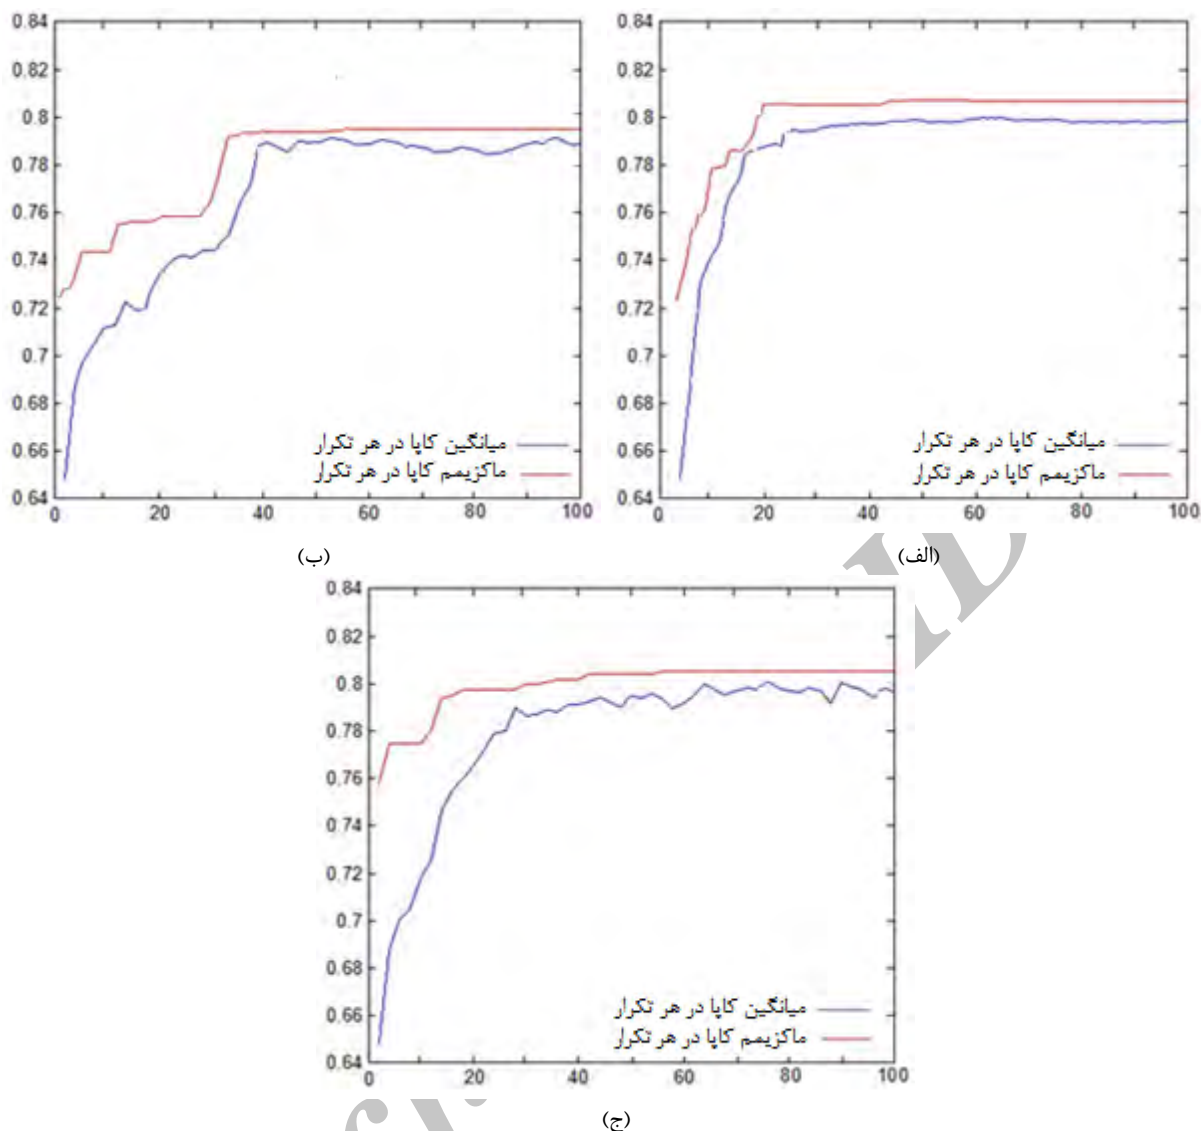
تعداد کلاسها	قدرت تفکیک طیفی (باند)	قدرت تفکیک مکانی (متر)	ابعاد مکانی (پیکسل)	گستره طیفی	سنجنده	داده تصویری
۹	۱۰۳	۱/۳	۶۱۰ × ۳۴۰	۰/۴۳-۰/۸۶	ROSIS-03	Pavia
۶	۸۴	۱	۷۹۵ × ۵۶۴	۷/۸-۱۲/۵	Hyper-Cam LWIR	Telops
۱۶	۲۰۰	۲۰	۱۴۵ × ۱۴۵	۰/۴-۲/۵	AVIRIS	Indian Pines



شکل ۳- نمایش رنگی و داده واقعیت زمینی تصاویر فراطیفی مورد استفاده

۱۰۰ در نظر گرفته شد. البته در عمل برای هر سه تصویر فراطیفی 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 را برای سه تصویر فراطیفی مورد استفاده نشان می‌دهد.

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



شکل ۴- نمودار همگرایی الگوریتم ژنتیک در تصویر (الف) Pavia، (ب) Telops، (ج) Indian Pines


MSF و در تصویر Indian Pines نقشه G-M-G-MSF شامل مناطق یکنواختی می‌گردد. به منظور ارزیابی دقت آزمون‌های صورت گرفته، ابتدا ماتریس خطا را به کمک داده واقعیت زمینی تشکیل داده، سپس پارامترهای دقت میانگین<sup>۱</sup> (AA)، دقت کلی<sup>۲</sup> (OA)، ضریب کاپا (K) و دقت تولید کننده<sup>۳</sup> مربوط به هر کلاس استخراج گردید [۱۴]. جدول (۲) مقادیر سه پارامتر AA، OA و K نقشه‌های طبقه‌بندی بدست‌آمده از سه تصویر فراطیفی مورد استفاده را نشان می‌دهد.

روش طبقه‌بندی پیشنهادی بیان شده در بخش ۳، با الگوریتم Tarabalka [۱۴]، یعنی MSF مبتنی بر نشانه‌ها اعمال شده بر روی تمام باندهای تصویر فراطیفی، (M-MSF)، مقایسه گردید. شکل (۵) نقشه‌های طبقه‌بندی حاصل از به کارگیری روش پیشنهادی و روش M-MSF را نشان می‌دهد. در این شکل منظور از G-M-MSF، M-G-MSF و MSF به ترتیب مدل‌های اول، دوم و سوم از روش پیشنهادی می‌باشد. همچنین در اسامی فوق حرف G نشانگر الگوریتم ژنتیک و حرف M بیانگر به کارگیری نشانه‌ها قبل از الگوریتم MSF است.

همانطوری که ملاحظه می‌گردد، در تصاویر Pavia و Telops نقشه‌های طبقه‌بندی بدست آمده از روش G-M-

۱ Average Accuracy  
۲ Overall Accuracy  
۳ Producer Accuracy





شکل ۵- نقشه‌های طبقه‌بندی حاصل از آزمون‌های عملی صورت گرفته بر روی سه تصویر فرایطیفی مورد استفاده


جدول ۲- مقادیر پارامترهای دقت میانگین، دقت کلی و ضریب کاپا آزمون‌های صورت گرفته بر روی سه تصویر فرایطیفی

G-M-G-MSF	M-G-MSF	G-M-MSF	M-MSF	پارامترهای دقت	داده تصویری
۹۳/۰	۹۲/۷	۹۶/۲	۹۴/۸	AA	Pavia
۹۳/۵	۹۳/۱	۹۶/۱	۹۴/۴	OA	
۹۱/۸	۹۱/۶	۹۴/۳	۹۲/۶	K	
۸۵/۸	۸۵/۳	۸۸/۶	۸۵/۸	AA	Telops
۸۶/۵	۸۶/۲	۸۹/۲	۸۶/۵	OA	
۸۴/۴	۸۴/۳	۸۷/۲	۸۴/۹	K	
۹۴/۲	۹۲/۷	۹۲/۹	۹۱/۷	AA	Indian Pines
۹۴/۵	۹۲/۷	۹۳/۰	۹۱/۷	OA	
۹۳/۳	۹۱/۴	۹۱/۸	۹۰/۶	K	

نسبت به الگوریتم M-MSF می‌باشد. در تصویر Indian Pines به کارگیری کاهش ابعاد قبل و بعد از انتخاب نشانه‌ها باعث افزایش دقت طبقه‌بندی گشته است، که این افزایش در حالت همزمان به میزان ۳ درصد بیشتر از الگوریتم M-MSF در پارامتر دقت کلی می‌باشد. (شکل ۶)

همانطوری که از جدول (۲) مشخص است به کارگیری الگوریتم کاهش ابعاد ژنتیک برای انتخاب نشانه‌ها در دو تصویر Pavia و Telops می‌تواند باعث افزایش دقت طبقه‌بندی گردد که این افزایش برای تصویر Pavia حدود ۲ درصد و برای تصویر Telops حدود ۳ درصد دقت کلی





شکل ۶- مقادیر بدست آمده برای دقت هر کلاس در تصویر (الف) Pavia, (ب) Telops, (ج) Indian Pines

MSF مبتنی بر نشانه‌ها است، میزان تاثیر کاهش ابعاد تصویر فراطیفی در سه مرحله قبل و بعد از انتخاب نشانه‌ها و به صورت همزمان بررسی گردید. روش پیشنهادی بر روی سه تصویر فراطیفی Pavia, Indian Pines و Telops پیاده‌سازی شد و آزمایشات برتری کمی و کیفی به-کارگیری کاهش ابعاد تصاویر فراطیفی را قبل از انتخاب نشانه‌ها برای الگوریتم MSF نشان می‌دهد. این برتری در تصویر Pavia برابر با ۲ درصد، در تصویر Telops برابر با ۳ درصد و در تصویر Indian Pines برابر با ۱ درصد بیشتر از الگوریتم M-MSF در پارامتر ضریب کاپا می‌باشد. به علاوه در تصویر Indian Pines استفاده از الگوریتم ژنتیک بعد از انتخاب نشانه‌ها نیز باعث افزایش دقت نتایج شده است به

گراف مربوط به مقادیر دقت تولیدکننده هر کلاس در تصاویر فراطیفی مورد استفاده را نشان می‌دهد. نتایج بدست آمده اهمیت استفاده از کاهش ابعاد تصویر فراطیفی را قبل از انتخاب نشانه‌ها در طبقه‌بندی MSF نشان می‌دهد.

## ۵- نتیجه‌گیری

در این تحقیق روشی جدید جهت طبقه‌بندی طیفی- مکانی تصاویر فراطیفی به کمک الگوریتم ژنتیک معرفی گردید. الگوریتم ژنتیک یکی از کارآمدترین و موثرترین روشها در کاهش ابعاد تصاویر فراطیفی می‌باشد. در روش پیشنهادی که بر مبنای الگوریتم طبقه‌بندی طیفی- مکانی

دیگر باشد که ضرورت استفاده از فرآیند کاهش باندها را قبل از انجام عمل طبقه بندی MSF و در تمامی مراحل نشان می دهد.

طوری که استفاده همزمان از آن در قبل و بعد از انتخاب نشانه ها به بهترین نتایج دست یافته است که این می تواند به دلیل پیچیدگی تصویر، وجود باندهای نویزی و وابستگی بالایی باندهای تصویر Indian Pines در مقایسه با دو تصویر

## مراجع

- [1] Varshney, P.K. and Arora, M.K. (2004). "Advanced Image Processing Techniques for Remotely Sensed Hyperspectral Data." Springer Berlin Heidelberg New York.
- [2] Chang, C.-I (2003). "Hyperspectral Imaging: Techniques for spectral Detection and Classification." Orlando, FL: Kluwer Academic.
- [3] Homayouni, S. and Roux, M. (2003). "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.
- [4] Gonzalez, R.C. and Woods, R.E. (2002). "Digital Image Processing." Prentice Hall, 617 – 626.
- [5] Vapnik (1995). "The Nature of Statistical Learning Theory." New York, NY: Springer-Verlag.
- [6] Tarabalka, Y., Chanussot, J. and Benediktsson, J.A. (2010). "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.
- [7] Fauvel, M., Tarabalka, Y., Benediktsson, J.A., Chanussot J. and Tilton J.C. (2013). "Advances in Spectral-Spatial Classification of Hyperspectral Images." Proceedings of the IEEE 101(3): 652-675.
- [8] Richards, J.A. and Jia, X. (2006). "Remote Sensing Digital Image Analysis: An Introduction." Springer-Verlag Berlin Heidelberg.
- [9] Jackson, Q. and Landgrebe, D. (2002). "Adaptive bayesian contextual classification based on Markov random fields." IEEE Trans. Geos. And Remote Sens., 40(11):2454–2463.
- [10] Huang, X. and Zhang, L. (2009). "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.
- [11] Benediktsson, J.A., Pesaresi, M. and Arnason, K. (2003). "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.
- [12] Pesaresi, M. and Benediktsson, J.A. (2001). "A new approach for the morphological segmentation of high-resolution satellite imagery." IEEE Trans. Geosci. Remote Sens., vol. 39, no. 2, pp. 309–320.
- [13] Benediktsson, J.A., Palmason, J.A. and Sveinsson, J.R. (2005). "Classification of hyperspectral data from urban areas based on extended morphological profiles." IEEE Trans. Geos. and Remote Sens., 43(3):480–491.
- [14] Tarabalka, Y., Chanussot, J. and Benediktsson, J.A. (2010). "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.

- [15] Tarabalka, Y., Benediktsson, J.A. and Chanussot, J. (2009). "Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques." *IEEE Translation Geoscience Remote Sensing*, 47(9): 2973–2987.
- [16] Tarabalka, Y., Benediktsson, J.A., Chanussot, J. and Tilton, J.C. (2010). "Multiple spectral-spatial classification approach for hyperspectral data." *IEEE Translation Geoscience Remote Sensing*, 48(11): 4122–4132
- [17] Bitam, A. and Ameer, S. (2013). "A local-spectral fuzzy segmentation for MSG multispectral images." *International Journal of Remote Sensing*, 34: 8360–8372.
- [18] Soille, P. (2003). "Morphological Image Analysis." 2nd ed. Berlin, Germany: Springer-Verlag.
- [19] Gómez, O., González, J.A. and Morales, E.F. (2007). "Image segmentation using automatic seeded region growing and instance-based learning." in *Proc. 12th Iberoamerican Congress Pattern Recognition, Valparaiso, Chile*, 192–201.
- [20] Noyel, G., Angulo, J. and Jeulin, D. (2007). "Morphological segmentation of hyperspectral images." *Image Anal. Stereol.*, 26: 101–109.
- [21] Noyel, G. (2008). "Filtrage, Réduction de Dimension, Classification et Segmentation Morphologique Hyperspectrale." Ph.D. dissertation, Ctr. Mathematical Morphology, Paris Sch. Mines, Paris, France.
- [22] Van der Meer, F. (2006). "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.
- [23] Zhuo, L. and Zheng, J. (2008). "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.
- [24] Santos, A.B., et al. (2012). "Feature selection for classification of remote sensed hyperspectral images: A filter approach using genetic algorithm and cluster validity." *The 2012 International Conference on Image Processing, Computer Vision, and Pattern Recognition (IPCV'12)*.
- [25] Santos, A., Araújo, A. and Menotti, D. (2012). "Combining multiple approaches for accuracy improvement in remote sensed hyperspectral images classification." *Workshop of Thesis and Dissertations-XXV Conference on Graphics, Patterns and Images*.
- [26] Huang, C.-L. and Wang, C.-J. (2006). "A GA-based feature selection and parameter optimization for support vector machines." *Expert Systems with Application*, 231-240.
- [27] Cristianini, N. and Shawe-Taylor, J. (2000). "An Introduction to Support Vector Machines and Other Kernel-based Learning Methods." Cambridge University Press.