

## یک روش نوین استخراج ویژگی مبتنی بر شی با استفاده از ناحیه‌بندی به منظور طبقه‌بندی تصاویر ابرطیفی

زهرا طباطبایی<sup>۱</sup>، حمیدرضا شاه‌دوستی<sup>۲</sup>

<sup>۱</sup> کارشناسی ارشد برق الکترونیک، دانشگاه صنعتی همدان.  
<sup>۲</sup> استادیار دانشکده برق، دانشگاه صنعتی همدان، h.doosti@hut.ac.ir

### چکیده:

تصاویر ابرطیفی اطلاعات فراوانی را در زمینه‌ی سنجش از راه دور در اختیار قرار می‌دهند. برتری این تصاویر، کیفیت بالای آن‌ها در محدوده‌ی گسترده‌ی امواج الکترومغناطیسی است. در تصاویر ابرطیفی، به علت عدم تناسب تعداد باندها و تعداد نمونه‌های آموزشی، احتمال کاهش دقت طبقه‌بندی وجود دارد. برای حل این مشکل، از روش‌های مختلفی همچون کاهش و استخراج ویژگی استفاده می‌شوند. از طرفی، به منظور دستیابی به بیشینه دقت عملکردی در استخراج ویژگی، می‌توان از اطلاعات طیفی و مکانی تصاویر به طور همزمان بهره برد. بدین ترتیب، در این مقاله به معرفی یک روش استخراج ویژگی مبتنی بر شی با بهره‌گیری از اطلاعات مکانی و طیفی تصاویر می‌پردازیم. روش پیش‌رو از چهار گام اصلی تشکیل شده است؛ ابتدا، از الگوریتم PCA با هدف استخراج ویژگی‌های اولیه‌ی تصویر استفاده می‌کنیم. سپس برای دستیابی به اطلاعات مکانی داده‌ها، فیلتر گاوس و الگوریتم K-means را بر آن‌ها اعمال می‌کنیم. در نهایت، به منظور یافتن ضرایب تبدیل، یک تابع هزینه تشکیل می‌دهیم. یکی از نقاط قوت تابع پیشنهادی، قدرت آن در تخصیص پیکسل‌های یک ناحیه به یک کلاس است. نتایج آزمایش‌ها بر داده‌های ابر طیفی ایندیانا، سالیاناس و بوتسوانا با بهره‌گیری از طبقه‌بند K-NN به ترتیب دقت کلی ۸۴.۳۶، ۹۰.۵۰ و ۹۷.۶۵ را برای هر یک از داده‌ها ارائه می‌کنند.

### کلیدواژه

استخراج ویژگی، طبقه‌بندی تصاویر ابر طیفی، همسایگی پیکسل‌ها، طبقه‌بندی مبتنی بر شی، استخراج ویژگی مبتنی بر شی.

### مقدمه

روش‌های بهینه به‌منظور تحلیل و تفسیر آن برای دستیابی به اهداف مورد نظر، به یک مبحث چالش برانگیز برای محققین تبدیل شده است. یک فن مهم در تفسیر تصاویر ماهواره‌ای، تعیین روش استخراج ویژگی و طبقه‌بندی با دقت مناسب است [۳-۲]. تعداد بالای باندها می‌تواند منجر به ایجاد برخی خطاها و تولید داده‌های ناکارآمد شود. یکی از معروف‌ترین خطاها در تحلیل و تفسیر این نوع از داده‌ها، پدیده‌ی هیوز نام دارد. در واقع پدیده‌ی هیوز در اثر عدم تناسب در تعداد ویژگی‌ها و تعداد نمونه‌های آموزشی ایجاد می‌شود. بدین ترتیب که، با در اختیار داشتن تعداد نمونه‌های آموزشی کم و افزایش تعداد باندها، دقت طبقه‌بندی تا حدی افزایش و سپس کاهش می‌یابد [۶-۴]. بنابراین برای ایجاد توازن در نسبت بین تعداد باندها و تعداد نمونه‌های آموزشی، یک مرحله پیش‌پردازش به‌منظور استخراج و کاهش ویژگی‌های تصویر نیاز است.

با پیشرفت تکنولوژی محققین همواره در تلاشند تا از تصاویر به‌عنوان یک پایگاه داده‌ی قابل اطمینان در زمینه‌ی تحقیقاتی خود بهره بگیرند. امروزه تصاویر ابرطیفی<sup>۱</sup> با صدها باند یکی از مراجع قابل اطمینان در زمینه‌های مختلف علمی در نظر گرفته می‌شود. ویژگی متمایزکننده‌ی آن‌ها، کیفیت بالا و رنج گسترده‌ی امواج الکترومغناطیسی است [۱]. از جمله کاربردهای این تصاویر می‌توان به شناسایی ادوات نظامی استتار شده در سیستم‌های نظامی و دفاعی، شناسایی نوع پوشش گیاهی سطح زمین در مطالعات زمین‌شناسی، مطالعه‌ی بلایای طبیعی و مدیریت بحران، بررسی تغییرات دوره‌ای و ... اشاره کرد. با توجه به طیف گسترده‌ی کاربرد تصاویر ابرطیفی، نیاز به

<sup>۱</sup> Hyperspectral image

means یکی از معروفترین و پرکاربردترین آن‌ها است. این روش با اعمال یک الگوریتم تکرار شونده به منظور محاسبه بهترین مراکز خوشه‌ها می‌تواند تصویر را به  $k$  ناحیه تقسیم کند.

همانطور که پیش‌تر اشاره شد، در این مقاله یک روش نوین استخراج ویژگی مبتنی بر شی معرفی شده است که با کمک الگوریتم ناحیه‌بندی  $K$ -means می‌تواند اطلاعات مکانی تصویر را استخراج کند و در نهایت یک نقشه‌ی ناحیه‌بندی شده از تصویر در دسترس قرار دهد. با توجه به اینکه پایه و اساس روش پیشنهادی، ارتباط بین پیکسل‌های همسایه در تصویر است؛ این روش علاوه بر محاسبه‌ی نقشه‌ی ناحیه‌بندی، در تلاش است با در نظر گرفتن دو پارامتر دیگر به کمینه وابستگی در میان ویژگی‌های استخراج شده و بیشینه ارتباط درون کلاسی دست‌یابد تا متمایزکننده‌ترین ویژگی‌های تصویر را در اختیار کاربر قرار دهد.

در بخش‌های بعدی مقاله‌ی پیش‌رو ابتدا، به اختصار برخی از انواع روش‌های استخراج ویژگی پیشین مرور شده‌اند و سپس به بررسی جزئی‌تر ویژگی‌های استخراج ویژگی مبتنی بر شی و معرفی روش پیشنهادی معرفی می‌پردازیم. در ادامه، با مقایسه-ی دقت روش پیشنهادی با روش‌های پیشین قدرت روش پیش-رو اثبات می‌شود.

### مروری بر روش‌های پیشین

با توجه به مطالب مطرح شده در بخش قبل، روش‌های استخراج ویژگی از دیدگاه‌های متعددی قابل مطالعه هستند و به انواع؛ خطی و غیر خطی، تحت نظارت، نیمه نظارتی و بدون نظارت، مبتنی بر شی و مبتنی بر پیکسل دسته‌بندی می‌شوند که در ادامه چند نمونه از مهم‌ترین روش‌های هر گروه را مرور می‌کنیم.

در میان مجموعه‌ی گسترده‌ی روش‌های خطی می‌توان به FA اشاره کرد. الگوریتم تحلیل ضرایب<sup>۲</sup> (FA) یک روش آماری خطی است که از اطلاعات مفید تصویر به منظور حذف اطلاعات آن بهره می‌گیرد [۱۵]. تحلیل مؤلفه‌های اصلی<sup>۳</sup> (PCA) یک روش خطی بدون نظارت است که برای تشخیص همبستگی بین باندهای طیفی به منظور استخراج ویژگی‌های ذاتی تصویر به کار می‌رود [۱۶]. این روش تفکیک بین کلاس‌ها را در نظر نمی‌گیرد و بر اساس معیارهای دیگری از جمله حداقل خطای

روش‌های استخراج ویژگی مطلوب بایستی سه شرط را اغنا کنند. این سه شرط عبارتند از: ۱. فاصله‌ی اعضای درون کلاسی کمینه و فاصله‌ی برون کلاسی بیشینه باشد. ۲. وابستگی بین ویژگی‌های استخراجی باید کمینه باشد. ۳. پیکسل‌هایی که به یک شی واحد در تصویر اشاره دارند در یک کلاس نام‌گذاری شوند. این شرایط به اطلاعات مکانی از تصاویر ابرطیفی نیاز دارد [۷]. روش‌های استخراج ویژگی از دیدگاه‌های متفاوتی دسته‌بندی و قابل مطالعه و بررسی هستند. یکی از این دیدگاه-ها، این روش‌ها را به دو دسته‌ی خطی و غیرخطی دسته‌بندی می‌کند. از نقطه نظری دیگر، این روش‌ها به سه حوزه‌ی تحت نظارت، نیمه نظارتی و بدون نظارت تقسیم‌بندی می‌شوند. روش‌های تحت نظارت برای استخراج ویژگی از نمونه‌های آموزشی کمک می‌گیرند. از طرفی، در بسیاری از کاربردها، عملیات برچسب‌گذاری هزینه‌بر و زمان‌بر می‌باشد و به همین منظور برای افزایش کارایی و استفاده از کل توان سیستم در راستای حل مسئله، می‌توان از داده‌های بدون برچسب نیز استفاده کرد [۸-۹]. روش‌های نیمه نظارتی، با هدف بهبود طبقه‌بندی به کمک اطلاعات نام‌گذاری شده و بدون نام‌گذاری، ترکیبی از دو روش تحت نظارت و بدون نظارت هستند. روش‌های بدون نظارت نیز با صرف‌نظر از جدایی کلاس‌ها و بدون استفاده از نمونه‌های آموزشی، ویژگی‌های بارز تصویر را مشخص می‌کنند. علاوه بر این دو دیدگاه، می‌توان روش‌های استخراج ویژگی را در دو دسته‌ی مبتنی بر شی و مبتنی بر پیکسل در نظر گرفت که امروزه روش‌های گروه اول، روش‌های مبتنی بر شی، با توجه به دقت عملکرد بسیار بالای آن‌ها، توجه طیف وسیعی از جامعه‌ی محققین را به خود جلب کرده‌اند. طبقه‌بندی مبتنی بر شی عبارت است از: استخراج ویژگی‌های تصویر از طریق مدل‌سازی هم‌بستگی مکانی در راستای ناحیه-بندی تصویر و همچنین تخصیص کل پیکسل‌های تشکیل دهنده‌ی یک شی به یک کلاس به کمک اطلاعات محتوایی مانند: شکل، اندازه و هم‌بستگی‌های طیفی جهت طبقه‌بندی یک تصویر [۱۰]. در این روش فرض بر این است که هر ماده تنها مربوط به یک شی است و با گروه کردن پیکسل‌ها اشیای همگنی ایجاد می‌شوند [۱۱-۱۳]. سپس طبقه‌بند شباهت بین اشیای کلاس‌بندی نشده را با الگوی تصویر مقایسه می‌کند و هر کلاس را به نزدیک‌ترین الگو مربوط می‌کند [۱۴]. در روش‌های استخراج ویژگی مبتنی بر شی، ناحیه‌بندی تصویر یک گام بسیار مهم و موثر است. در این مرحله، با اعمال یک الگوریتم ناحیه‌بندی مناسب می‌توان اشیای تصویر را به نواحی مختلف دسته‌بندی و نام‌گذاری کرد به طوری که هر شی در تصویر، متعلق به یک کلاس با نام واحد باشد. در گذر زمان روش‌های ناحیه‌بندی متعددی معرفی شده است و روش  $K$ -

<sup>۲</sup> Factor analysis

<sup>۳</sup> Principal component analysis

محاسبه می‌شود. سپس دو توابع وزن دهی تعریف می‌شوند، به طوری که به نمونه‌های آموزشی در نزدیکی مرزهای کلاس وزن بیشتری در ماتریس پراکندگی بین کلاس‌ها تعلق می‌گیرد و نمونه‌های آموزشی در نزدیکی میانگین کلاس‌ها وزن بیشتری در ماتریس پراکندگی درون کلاس‌ها خواهند داشت [۲۰]. استخراج ویژگی با استفاده از رگرسیون خطی<sup>۱۱</sup> (FERR) یک روش تحت نظارت است و فقط بردار میانگین کلاس‌ها را تخمین می‌زند در حالی که نیازی به محاسبه‌ی پراکندگی کلاس‌ها ندارد. بنا به همین ویژگی، برای نمونه‌های آموزشی محدود مناسب است. علاوه بر این، FERR خلاف روش LDA در تعداد ویژگی استخراج شده محدودیت ندارد [۲۱]. روش تجزیه و تحلیل فضای ویژگی<sup>۱۲</sup> (FSDA) یک روش استخراج ویژگی تحت نظارت است که علاوه بر استفاده از ماتریس پراکندگی بین کلاسی و درون کلاسی از تفاوت طیفی بین باندها استفاده می‌کند. در این روش، تفاوت ویژگی‌ها و تفکیک پذیری کلاس‌ها از هم بیشینه است [۲۲-۲۳]. اگر تعداد نمونه‌های آموزشی محدود باشد، این روش نتیجه‌ی طبقه‌بندی را بهبود می‌بخشد و در صورتی که تعداد نمونه‌های آموزشی زیاد باشد نتیجه‌ی آن مشابه روش LDA است. علاوه بر روش‌های اشاره شده، روش دیگری به نام استخراج ویژگی با استفاده از نقطه‌ی جذب<sup>۱۳</sup> (FEUAP) وجود دارد که ویژگی برجسته‌ی آن ارائه‌ی نتیجه‌ی مطلوب با نمونه‌های آموزشی محدود و عدم استفاده از روابط آماری مانند، ماتریس کوواریانس و بردار میانگین است [۲۴-۲۵]. در مرجع [۲۶] یک روش جدید از ترکیب LDA و FEUAP برای طبقه‌بندی تصاویر ابرطیفی معرفی شده است. در این روش کلاس‌های مشابه به کمک الگوریتم K-means گروه بندی می‌شوند و در نهایت یک درخت با چند گره ایجاد شود. در تعیین شماره‌ی کلاس هر پیکسل بر اساس گره‌های درخت، از LDA برای تعداد نمونه‌های آموزشی کم و از FEUAP برای تعداد نمونه‌های آموزشی زیاد استفاده می‌شود.


با توجه به اینکه جدایی پذیری کلاس‌ها در محیط کرنل<sup>۱۴</sup> افزایش می‌یابد، می‌توان با بسط مدل‌های خطی به کمک تابع هسته‌ی مناسب، مدل‌های غیرخطی آن‌ها را به دست آورد. از جمله‌ی روش‌های غیرخطی حاصل از بسط LDA و PCA می‌توان به ترتیب به تحلیل تفکیک تعمیم یافته<sup>۱۵</sup> (GDA) و تحلیل مولفه‌های اصلی هسته‌ای<sup>۱۶</sup> (KPCA) اشاره کرد [۲۷].

بازسازی سیگنال عمل می‌کند. به سبب همین ویژگی، این الگوریتم در کاربردهای طبقه‌بندی چندان مفید واقع نمی‌شود. روش تحلیل تفکیک خطی<sup>۴</sup> (LDA) در راستای بهبود عملکرد الگوریتم PCA معرفی شده است. عملکرد LDA بر اساس بردار میانگین و ماتریس کوواریانس کلاس‌ها است. سه نقطه ضعف اساسی این روش عبارتند از: ۱. عملکرد آن بر اساس توزیع داده‌ها است. بنابراین، اگر توزیع کلاس‌ها نرمال نباشد، نتیجه‌ی آن مطلوب نخواهد بود. ۲. تعداد ویژگی‌های استخراج شده در این روش محدود است و این محدودیت برای طبقه‌بندی تصاویر ابرطیفی مناسب نیست. محدودیت به این معنا است که از تصویر با C کلاس، حداکثر می‌تواند C-1 ویژگی را استخراج کند. ۳. برای تصاویر با ابعاد کوچک نتیجه‌ی مطلوبی نخواهد داشت چرا که بر اساس ماتریس پراکندگی درون کلاس‌ها عمل می‌کند. گراف متمایز کننده‌ی تنک مرتبه پایین<sup>۵</sup> (SLGDA) گرافی با استفاده از نمونه‌های آموزشی محاسبه می‌کند؛ بدین صورت که در ابتدا وزن‌ها توسط نمایش نزولی محاسبه می‌شوند، سپس ساختار داده‌های کلی توسط نمونه‌هایی با درجه‌ی پایین حفظ می‌شوند [۱۷]. روش تحلیل تفکیکی در فضای ویژگی مورفولوژی<sup>۶</sup> (DAMFS) در راستای افزایش و بیشینه سازی تفاوت کلاس‌ها، از پراکندگی بین باند-مکانی در هر دو فضای ویژگی‌های طیفی و مکانی استفاده می‌شود. در ادامه، چندین تصویر مورفولوژی به دست می‌آید و در نهایت با اعمال الگوریتم رای اکثریت<sup>۷</sup> نقشه‌ی ناحیه‌بندی تصویر حاصل می‌شود [۱۸]. روش استخراج ویژگی با استفاده از جاسازی دوگانه<sup>۸</sup> (FEDDE) ترکیبی از دو روش موفق SLGDA و DAMFS در استخراج ویژگی‌ها است، به طوری که اولین روش تفاوت بین ویژگی‌های طیفی و دومین روش تفاوت بین کلاس‌ها را محاسبه می‌کند [۱۹].<sup>۹</sup> استخراج ویژگی غیر پارامتریک یک روش غیر پارامتریک وزن دار و تحت نظارت است که برای هر نمونه از یک کلاس، میانگین محلی را محاسبه می‌کند. بارزترین نقطه‌ی ضعف این روش، زمان محاسباتی زیاد است؛ به ویژه در شرایطی که تعداد نمونه‌های آموزشی تصویر زیاد باشد. در بهبود یافته‌ی استخراج ویژگی غیر پارامتریک<sup>۱۰</sup> (INWFE) ابتدا، با استفاده از پنجره‌ی پارزن، میانگین محلی

<sup>۱۱</sup> Feature extraction based on ridge regression  
<sup>۱۲</sup> Feature space discriminate analysis  
<sup>۱۳</sup> Feature extraction using attraction points  
<sup>۱۴</sup> Kernel function  
<sup>۱۵</sup> General discriminant analysis  
<sup>۱۶</sup> Kernel principal component analysis

<sup>۴</sup> Linear discriminant analysis  
<sup>۵</sup> Sparse and low-rank graph for discriminant  
<sup>۶</sup> Discriminant analysis in morphological feature space  
<sup>۷</sup> Majority vote  
<sup>۸</sup> Feature extraction by double discriminant emdedding  
<sup>۹</sup> Nonparametric weighted feature extraction  
<sup>۱۰</sup> Improved nonparametric feature extraction

ناهمگونی بسیار زیاد، طبقه‌بند با مشکلات متعددی مواجه می‌شود. در همین راستا اطلاعات مکانی پدیده‌ها نقش بسیار مهمی در جداسازی کلاس‌ها دارند [۳۵-۳۴]. در روش پیشنهادی در مقاله‌ی [۳۶] الگوریتم‌های ISODATA و EM<sup>۲۲</sup> به منظور خوشه‌بندی تصویر به کار رفته اند و برای بهبود اثر نویز در نقشه‌ی طبقه‌بندی تصویر از فیلتر کردن با پنجره‌ی ثابت استفاده شده است. در [۳۷] روش مبتنی بر شی معرفی شده از الگوریتم واترشد<sup>۲۳</sup> به منظور ناحیه‌بندی تصویر و استخراج اطلاعات مکانی آن استفاده می‌شود و در ادامه با اعمال قانون رای اکثریت<sup>۲۴</sup> به ترکیب اطلاعات حاصل از نقشه‌ی طبقه‌بندی شده توسط SVM و نقشه‌ی به دست آمده از الگوریتم واترشد می‌پردازد.



شکل ۱. روند تدریجی افزایش کاربرد استخراج ویژگی مبتنی بر شی.

## روش پیشنهادی

همانطور که در شکل (۱) قابل بررسی است، با گذشت زمان کاربرد روش‌های استخراج ویژگی مبتنی بر شی افزایش پیدا کرده و توجه تعداد کثیری از محققین را به خود جلب کرده است؛ به همین دلیل، در این مقاله یک روش استخراج ویژگی مبتنی بر شی را پیشنهاد می‌کنیم. در بخش‌های بعدی ابتدا به بسط جزئی تر اطلاعات و ویژگی‌های روش‌های استخراج ویژگی مبتنی بر شی می‌پردازیم و سپس مروری بر مقدمه‌ی روش پیشنهادی خواهیم داشت که شامل توضیحاتی اجمالی از نکات مهم به منظور محاسبه‌ی نقطه‌ی جذب هر کلاس به‌عنوان مرکز آن خواهد بود و در نهایت روش پیشنهادی با جزئیات دقیق تر

روش کرنل‌های ترکیبی تعمیم یافته<sup>۱۷</sup> (GCK) یک روش کرنلی انعطاف پذیر است که بدون وزن‌دهی به اطلاعات مکانی و طیفی، ویژگی‌های مکانی را با استفاده از چند جمله‌ای‌های رگرسیون منطقی استخراج می‌کند [۲۸]. در [۲۹] یک روش غیرخطی از ادغام دو روش KPCA و KSRC<sup>۱۸</sup> معرفی شده است که فضای اولیه‌ی ویژگی‌های تصویر را به فضای کرنلی با ابعاد کم تر پس از یک مرحله کاهش ویژگی منتقل می‌کند. LEE<sup>۱۹</sup> یک روش معروف غیرخطی کاهش ویژگی است که با حفظ ارتباط بین باندها ابعاد تصویر را کاهش می‌دهد. شبکه عصبی پیچشی<sup>۲۰</sup> (CNN) یک روش تحت نظارت است که ویژگی‌های طیفی، مکانی و طیفی-مکانی تصاویر ابرطیفی را به کمک فرایند یادگیری ماشین استخراج می‌کند و در مقاله‌ی [۳۰] با توجه به عملکرد مطلوب CNN، یک روش نوین با نام های 3-D CNN-based معرفی شده است که به استخراج ویژگی‌هایی با تفکیک پذیری بالا، غیرخطی و ثابت (ویژگی‌های عمیق) در تصویر می‌پردازد.

به طور کلی، تمامی روش‌های اشاره شده متعلق به مجموعه روش‌های استخراج ویژگی مبتنی بر پیکسل هستند. این روش‌ها اطلاعات طیفی را بدون در نظر گرفتن اطلاعات بافتی استخراج می‌کنند و همین موضوع موجب محدود شدن نتیجه‌ی عملکرد آن‌ها می‌شود. در ادامه می‌توان به روش‌های استخراج ویژگی مبتنی بر شی اشاره کرد. از مزایای روش‌های استخراج ویژگی مبتنی بر شی، می‌توان به افزایش سرعت طبقه‌بندی، کاهش زمان پردازش و استفاده‌ی مؤثر از حجم حافظه با دسترسی موقتی<sup>۲۱</sup> (RAM) بدون کاهش دقت طیفی-مکانی اشاره کرد. در مقالات [۳۱-۳۳] مقایسه‌های متعددی بین روش‌های مبتنی بر شی و مبتنی بر پیکسل صورت گرفته است. با توجه به ویژگی‌های مطرح شده، در این مقاله به معرفی یک روش استخراج ویژگی مبتنی بر شی می‌پردازیم. استخراج ویژگی مبتنی بر شی در مقایسه با استخراج ویژگی مبتنی بر پیکسل، علاوه بر دقت بالا در عملکرد، دارای الگوی یکنواخت‌تری در تصاویر با ابعاد طیفی بالا است. استخراج ویژگی مبتنی بر شی معمولاً در تصاویر ماهواره‌ای با توان تفکیک مکانی بالا استفاده می‌شود. در تصاویر با توان تفکیک مکانی بالا، تنوع کمی و کیفی پدیده‌ها مانع از متمایزسازی مطلوب کلاس‌ها صرفاً بر اساس اطلاعات آماری و طیفی می‌شود. در این تصاویر به علت

<sup>۱۷</sup> Generalized composite kernel

<sup>۱۸</sup> Kernel sparse representation-based classifier

<sup>۱۹</sup> Locally linear embedding

<sup>۲۰</sup> Convolutional neural network

<sup>۲۱</sup> Random access memory

<sup>۲۲</sup> Random access memory

<sup>۲۳</sup> Watershed segmentation

<sup>۲۴</sup> The majority voting rule

استخراج ویژگی‌های تصویر از طریق مدل‌سازی هم‌بستگی مکانی به‌منظور ناحیه‌بندی و تخصیص کل پیکسل‌های تشکیل‌دهنده‌ی یک شی به یک کلاس به کمک اطلاعات محتوایی (شکل، اندازه و هم‌بستگی‌های طیفی). به‌عبارت دیگر، این نوع از استخراج ویژگی می‌تواند با بهره‌گرفتن از چند باند (ارتفاع، مادون‌قرمز و شیب فایل‌ها) ویژگی‌های طیفی، مکانی و بافتی تصویر را استخراج کند و سپس، طبقه‌بند شباهت بین اشیای کلاس‌بندی نشده را با الگوی تصویر مقایسه می‌کند و هر کلاس را به نزدیک‌ترین الگو مربوط می‌کند.

دقت بالا در این نوع طبقه‌بندی، ناشی از به‌کارگیری موازی اطلاعات طیفی و مکانی تصویر به‌منظور دستیابی به ویژگی‌های متمایز کننده‌ی آن است. این روش بر مبنای اشیای تصویر عمل می‌کند و دربردارنده‌ی سه‌گام اصلی شامل: ۱. ناحیه‌بندی مبتنی بر شی، ۲. استخراج ویژگی مبتنی بر شی و ۳. طبقه‌بندی مبتنی بر شی است.

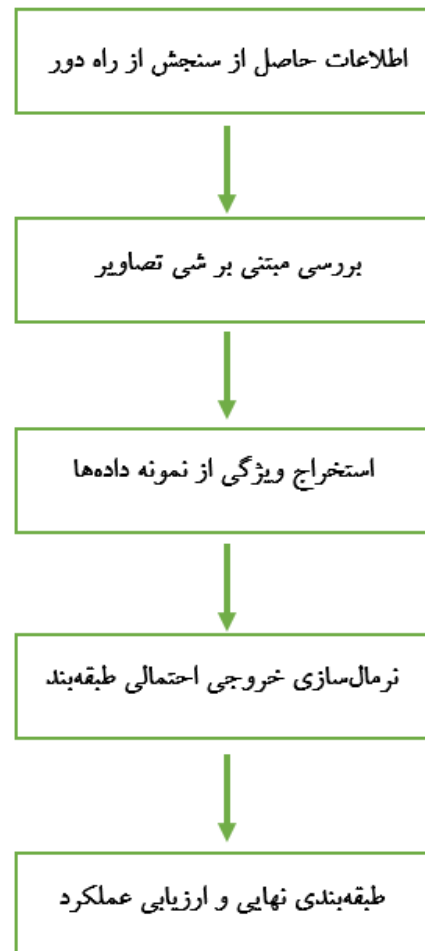
#### ۱. ناحیه‌بندی مبتنی بر شی:

اولین گام برای تحلیل مبتنی بر شی تصاویر، ناحیه‌بندی آن‌ها با هدف دسته‌بندی پیکسل‌ها بر اساس ویژگی‌های مشابه مانند رنگ، روشنایی و... است [۳۸]. ناحیه‌بندی را می‌توان به‌عنوان فرایند تقسیم تصویر به نواحی همگون بدون اشتراک در نظر گرفت؛ به‌گونه‌ای که هیچ دو ناحیه‌ی مجاوره‌ی شرط ادغام با یکدیگر را رعایت نکنند [۳۹]. از جمله مزایای این مرحله، علاوه بر ساده‌سازی شرایط تحلیل و مطالعه‌ی تصویر، می‌توان به فشرده‌سازی تصویر نیز اشاره کرد.

هنگامی که پیکسل‌های همسایه به‌منظور ساختن یک شی با هم ادغام می‌شوند حجم مورد نیاز از حافظه‌ی موقتی (RAM) برای ذخیره‌ی موقت اطلاعات تصویر ناحیه‌بندی شده، متناسب با ضریبی برابر اندازه‌ی متوسط شی کاهش می‌یابد. به بیان ساده‌تر، اختصاص دادن هر پیکسل به شی متناظر به آن در تصویر ناحیه‌بندی شده، حجم داده را به‌صورت قابل توجهی کاهش می‌دهد و فشرده‌سازی را امکان‌پذیر می‌کند [۴۰].

#### ۲. استخراج ویژگی مبتنی بر شی:

مطرح خواهد شد. شکل (۲) بدنه‌ی کلی روش پیشنهادی از ابتدا تا رسیدن به هدف را نمایش می‌دهد.




شکل ۲. فلوجارت گام‌های پیشنهادی مقاله.

مقدمه‌ای بر روش پیشنهادی

عملکرد مبتنی بر شی

رزولوشن‌های مکانی تصاویر ماهواره‌ای فاکتور مهمی در انتخاب تکنیک‌های طبقه‌بندی هستند. اگر رزولوشن بالا باشد هر شی در تصویر از چند پیکسل تشکیل می‌شود بنابراین، روش مبتنی بر شی نسبت به سایر روش‌ها برتری دارد چرا که در این روش فرض بر این است که هر ماده تنها به یک شی اشاره دارد. به‌طور کلی، طبقه‌بندی مبتنی بر شی عبارت است از:

دقت طبقه بندی در تصاویر سنجنش از راه دور را ارائه می کند [۴۱].



شکل ۳. ابعاد فضای ویژگی با جذب نقاط حول مرکز خوشه کاهش می یابد.

### معرفی روش FEUAP

FEUAP یک روش استخراج ویژگی تحت نظارت است که برای نمونه های محدود کاربردی است. در این الگوریتم، برای هر کلاس یک نقطه ی جذب تعریف می شود تا اعضای کلاس حول آن جمع شوند. با دور شدن نقاط جذب هر کلاس از یکدیگر، کلاس ها از هم جدا خواهند شد. پس گام اول در این روش، یافتن نقطه ی جذب مناسب برای هر کلاس است و گام دوم، یافتن تبدیل مناسب برای جمع کردن نقاط حول نقطه ی جذب مناسب آن ها است.

دو روش برای محاسبه ی نقطه ی جذب وجود دارد:

۱. به کمک محاسبه ی اندازه:

نقطه ی جذب در این روش باید به گونه ای انتخاب شود که کمترین فاصله را با نقاط کلاس مربوط به خود و بیشترین فاصله را با نقاط کلاس های دیگر داشته باشد.

$d$  و  $m$  نمایانگر تعداد باندهای تصویر است ( $m < d$ ).  $x_i$

اطلاعات با ابعاد زیاد،  $y_i$  اطلاعات با ابعاد کم و  $N$  تعداد نمونه های موجود در فضای ورودی و خروجی است.

$$y_i = Ax_i, \quad A_{m \times d} \quad (1)$$

$$\{x_i\}_{i=1}^N, \quad x_i \in R^d \quad (2)$$

$$\{y_i\}_{i=1}^N, \quad y_i \in R^d \quad (3)$$

این مرحله شامل جمع بندی ویژگی های طیفی، شکل و بافت است. ویژگی های طیفی شامل: روشنایی، انحراف معیار، نرخ نرمال شده ی سطح آب (NDWI)<sup>۲۵</sup>، نرخ نرمال شده ی تغییرات پوشش گیاهی (NDVI)<sup>۲۶</sup> و نرخ رشد پوشش گیاهی (SAVI)<sup>۲۷</sup> است. بافت حاوی ویژگی های اصلی تصویر است که در باندهای متعددی از جمله قرمز، سبز، آبی و نزدیک مادون قرمز محاسبه می شوند. علاوه بر ویژگی های بافتی؛ فضا، طول، جهت اصلی و شکل کلی، از ویژگی های شکلی تصویر به شمار می آیند [۳۷].

### ۳. طبقه بندی مبتنی بر شی:

در طبقه بندی اشیای ناحیه بندی شده به دو مجموعه داده ی ورودی نیاز است که عبارتند از: ۱. اطلاعات یک تصویر شناسایی شده به عنوان نمونه ی آموزشی و ۲. اشیای تصویری که با توجه به فضای ویژگی آن ها توسط طبقه بند آموزش دیده طبقه بندی شوند (داده ی آزمایشی). از طرفی، با توجه به کاربرد فراوان تصاویر سنجنش از راه دور به عنوان یک پایگاه عظیم اطلاعات در تحقیقات و مطالعات، همواره طبقه بندی داده های موجود در آن ها یکی از مطالب مورد توجه محققین در این زمینه بوده است. بنابراین با پیشرفت تکنولوژی و افزایش نیاز به اطلاعات نهفته در این تصاویر، مجموعه ی وسیعی از روش های متعدد طبقه بندی معرفی شده است. در این مطالعه، برای تعیین شماره کلاس هر شی، از طبقه بندی های  $K$  نزدیک ترین همسایه ( $K$ -NN) و پیشینه درست نمایی گوسی (GML) به عنوان طبقه بندی غیر پارامتریک تحت نظارت بر داده های ابرطیفی استفاده می کنیم.  $K$ -NN یکی از ساده ترین روش های آموزش ماشین است که در داده کاوی، یادگیری ماشین و تشخیص الگو مورد استفاده قرار می گیرد.  $K$  یک مقدار صحیح و مثبت است و معمولاً مقدار کمی دارد. اگر  $K=1$  در نظر گرفته شود، شی به تنها کلاس در نزدیک ترین همسایگی آن مربوط می شود. GML از ماتریس کوواریانس و بردار میانگین با تخمین داده های آموزشی به دست می آید و عمدتاً بیشترین

Normalized difference water inde  
Normalized difference vegetation inde:  
Soil adjusted vegetation inde:

$$y^{ac} = Ax^{ac} \quad (10)$$

$$y^{ic} = Ax_{ic} \quad (11)$$

$y^{ac}$  نقطه‌ی جذب در  $C$  امین کلاس در فضای جدید است. ماتریس  $A$  از رابطه‌ی زیر محاسبه می‌شود.

$$\min_A (\psi = \psi_1 + \psi_2) \quad (12)$$

$$\psi = \sum_{j=1}^n \sum_{i=1}^n w_{ij} \|y_i - y_j\|^2 \quad (13)$$

$$w_{ij} = \begin{cases} 1 & \text{if } c_1 \\ -1 & \text{if } c_2 \\ 0 & \text{if } c_3 \end{cases} \quad (14)$$

$c_1$ :  $y_i$  و  $y_j$  عضو یک کلاس باشند و یکی از این نقاط، نقطه جذب کلاس باشد.

$c_2$ :  $y_i$  و  $y_j$  عضو دو کلاس متفاوت باشند و حداقل یکی از آن‌ها نقطه‌ی جذب باشد.

$c_3$ :  $y_i$  و  $y_j$  هیچ‌کدام نقطه جذب نباشند.

$n$ : تعداد کل نمونه‌های آموزشی را شامل می‌شود.

$$n = \sum_{c=1}^{n_c} n_{t_c} \quad (15)$$

از طرفی، می‌توان رابطه‌ی بالا را به صورت زیر بازنویسی کرد:

$$D_{ii} = \sum_j w_{ij} \quad (16)$$

$$Y = [y_1, y_2, y_3, \dots, y_n] \quad (17)$$

$$G = D - W \quad (18)$$

$$\psi = 2tr(YGY^T) \quad (19)$$

$$S = \arg_{i=1, \dots, n_c} \min \left( \sum_{\substack{k=1 \\ k \neq i}}^{n_c} \|x_{ic} - x_{jc}\|^2 \right) \quad (4)$$

$$\sum_{j=1}^{n_c} \|x_{ic} - x_{jk}\|^2$$

$x_{ic}$  مشخص‌کننده‌ی  $i$  امین نمونه‌ی آموزشی در کلاس  $C$  است و  $n_{t_c}$  تعداد نمونه‌های آموزشی در  $C$  امین کلاس و  $n_c$  تعداد کلاس‌ها را نمایش می‌دهند.

۲. به کمک محاسبه‌ی تراکم:

$$F(x_{ic}) = \sum_{j=1}^{n_c} \exp(-\|x_{ic} - x_{jc}\|^2) \quad (5)$$

$$S = \arg_{i=1, \dots, n_c} \min (F(x_{ic})) \quad (6)$$

$$x^{ac} = x_{sc} \quad (7)$$

$x_{sc}$  نشان‌دهنده‌ی  $s$  امین نمونه‌ی آموزشی در کلاس  $C$  است و به‌عنوان نقطه جذب  $C$  امین کلاس به دست می‌آید. اگر نمونه‌ای از نمونه‌های آموزشی تراکم زیادی داشته باشد، به این معنا است که تعداد زیادی از داده‌ها حول آن جمع می‌شوند. به بیان دیگر، نمونه‌ی آموزشی با تراکم بالا می‌تواند به‌عنوان نقطه جذب پذیرفته شود. در روش FEUAP هر نمونه، فضای ویژگی‌ها را به صورت زیر کاهش می‌دهد:

➤ هر پیکسل، جذب نقطه‌ی جذب مربوط به کلاس خود شود.

➤ هر نمونه از نقطه‌ی جذب کلاس‌های دیگر فاصله بگیرد.

بنابراین دو تابع داریم:

• تابع کاهش فاصله درون کلاسی:

$$\psi_1 = \sum_{c=1}^{n_c} \sum_{i=1}^{n_c} \|y_{ic} - y^{ac}\|^2 \quad (8)$$

• تابع افزایش فاصله بین کلاسی:

$$\psi_2 = \sum_{c=1}^{n_c} \sum_{i=1}^{n_c} \sum_{\substack{k=1 \\ k \neq c}}^{n_c} \|y_{ic} - y^{ak}\|^2 \quad (9)$$

بنابراین، توانایی بالایی در استخراج ویژگی‌های تصویر دارد [۴۲]. فیلتر گابور در حالت کلی از رابطه‌ی زیر به دست می‌آید:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right) + 2\pi jw \cdot x\right] \quad (22)$$

در این رابطه  $\sigma_x, \sigma_y$  انحراف معیار تابع پوش گوسی در راستای محور  $x$  و  $y$  هستند و  $w$  نیز فرکانس موج سینوسی است. موجک‌های گابور با انتقال‌ها و چرخش‌های مناسب  $g(x, y)$  مطابق با رابطه‌های زیر به دست می‌آیند.

$$g_{mn}(x, y) = a^{-m} g(x', y') \quad (23)$$

$$x' = a^{-m} (x \cos \theta + y \sin \theta) \quad (24)$$

$$y' = a^{-m} (-x \sin \theta + y \cos \theta) \quad (25)$$

در این روابط،  $a > 1, \theta = \frac{n\pi}{k}$  و

$g_{mn}(x, y)$  نسخه‌ی تغییر مقیاس و چرخش یافته‌ی فیلتر مادر  $g(x, y)$  است.  $a$  پارامتر مقیاس،  $k$  تعداد کل جهت‌ها،  $s$  تعداد کل مقیاس و  $m$  و  $n$  به ترتیب مقیاس و جهت هر فیلتر می‌باشند.  $x'$  و  $y'$  مختصات تبدیل یافته هستند. با استفاده از این فیلترها تعدادی تصویر استخراج می‌شوند که فقط حاوی لبه‌های تصویر اصلی هستند. بنابراین به منظور استخراج ویژگی‌های مکانی (لبه‌ها) در طبقه بندی، از فیلتر گابور استفاده می‌شود.

در این مطالعه، برای دستیابی به اطلاعات مکانی تصویر، فیلتر گابور را به هر یک از سه باند خروجی از الگوریتم PCA اعمال می‌کنیم به طوری که نتیجه‌ی این مرحله تصویری با  $n \neq 41$  باند خواهد بود.

#### • ناحیه بندی K-means

$K$  میانگین ( $K$ -means)، یک روش پایه برای بسیاری از روش‌های خوشه بندی است. در این الگوریتم به تعداد خوشه‌های مورد نیاز نقاطی به طور تصادفی به عنوان مراکز خوشه‌ها انتخاب می‌شوند. سپس با محاسبه‌ی فاصله‌ی اقلیدسی نزدیک ترین داده‌ها به هم انتخاب شده و در یک گروه قرار می‌گیرند.

$$Y = AX \quad (20)$$

$$\min_A \psi = 2tr(AXGX^T A^T) \quad (21)$$

شکل (۳) نمایشی از یک مجموعه شامل دو نوع عنصر فرضی است که به نقاط مربوط به خود جذب می‌شوند. به این ترتیب اعضای مجموعه به دو گروه تفکیک می‌شوند.

#### معرفی روش پیشنهادی

روش پیشنهادی یک روش استخراج ویژگی مبتنی بر شی است و ایده‌ی اصلی آن بر اساس شباهت و همبستگی بین پیکسل‌ها در اطلاعات مکانی و طیفی آن‌ها در یک ناحیه‌ی یکسان است. روش پیش‌رو شامل مراحل زیر است:

✓ استخراج اولیه‌ی ویژگی‌های برجسته‌ی تصویر به کمک PCA.

✓ اعمال فیلتر گابور به تصویر.

✓ ارائه‌ی نتیجه‌ی گام ۲ به الگوریتم K-

means به منظور ناحیه بندی تصویر بر مبنای اطلاعات مکانی.

✓ محاسبه‌ی تابع هزینه.

در نهایت به منظور طبقه بندی داده‌ها می‌توان نتایج حاصل از گام‌های پیشین را به طبقه بندی مناسب ارائه کرد.

#### • اعمال الگوریتم PCA

همانطور که در بخش‌های قبل به طور مفصل شرح داده شد، تصاویر ابرطیفی حاوی اطلاعات بالا در چند صد باند هستند و طبقه بندی این حجم از اطلاعات بسیار مشکل، وقت گیر و هزینه بر است در حالی که در نهایت نتیجه‌ی مطلوبی نیز ارائه نخواهد شد. به همین دلیل برای حذف اطلاعات غیرضروری تصویر، در روش پیشنهادی ابتدا ۳ ویژگی برجسته و متمایز کننده تصویر را به کمک الگوریتم بدون نظارت PCA محاسبه می‌کنیم. با فرض تصویر اولیه‌ی  $I$  با ابعاد  $(x, y, n)$ ، ابعاد تصویر خروجی در این مرحله برابر  $(x, y, 3)$  است. به عبارت دیگر، تعداد باند-ها به ۳ باند کاهش می‌یابد.

#### • نقش فیلتر گابور

این فیلتر حاصل ضرب یک موج سینوسی با پوش گوسی است. فیلتر گابور به دلیل خاصیت تفکیک پذیری چندگانه در حوزه مکان و فرکانس یک ابزار قوی برای تحلیل بافت است.



این تساوی، رابطه‌ی بالا را می‌توان به صورت زیر ساده کرد. می‌توان برای ساده‌سازی این رابطه بخشی از آن را به صورت زیر با پارامتر  $E$  نشان داد.

بنابراین برای کلاس‌بندی تصویر با روش پیشنهادی،

$$I = \text{tr} \left( A \sum_{c=1}^k \sum_i \sum_j ((X_{ic} - X_{jc})(X_{ic} - X_{jc})^T) A^T \right) \quad (27)$$

$$E = \sum_{c=1}^k \sum_i \sum_j ((X_{ic} - X_{jc})(X_{ic} - X_{jc})^T) \quad (28)$$

بایستی معادله‌ی زیر محاسبه شود.

$$\phi = 2\text{tr}(YGY^T) + AEA^T \quad (29)$$

### بررسی نتیجه‌ی الگوریتم پیشنهادی

#### معیار ارزیابی

در تمام زمینه‌های تحقیقاتی، برای بررسی قدرت عملکردی روش‌های مورد نظر لازم است نتیجه‌ی آن‌ها با مجموعه قوانین مشخصی مورد مطالعه قرار گیرند. در این مقاله از ماتریس ضریب کاپا<sup>۲۸</sup>، دقت کلی<sup>۲۹</sup>، دقت متوسط<sup>۳۰</sup> و اعتبار متوسط<sup>۳۱</sup> به منظور بررسی قدرت عملکردی روش پیشنهادی استفاده می‌کنیم. در ادامه به توضیح مختصر مفهوم هر یک از معیارهای اشاره شده، می‌پردازیم.

اعتبار متوسط، میانگین اعتبار به دست آمده برای تمام کلاس‌ها تعریف می‌شود و منظور از اعتبار برای هر کلاس، حاصل تقسیم تعداد نمونه‌هایی است که درست طبقه‌بندی شده‌اند، بر تعداد کل نمونه‌های همان کلاس. دقت متوسط نیز میانگین دقت به دست آمده برای تمام کلاس‌هاست. دقت کلی، درصد تعداد نمونه‌های مورد بررسی است که درست طبقه‌بندی شده‌اند. برای به دست آوردن نمونه‌های مرجع، می‌توان نمونه‌ها را به طور تصادفی از نقشه‌ی زمینی انتخاب کرد [۴۴].

در گام بعدی با میانگین‌گیری از داده‌ها، مراکز جدید محاسبه می‌شوند و دوباره داده‌ها به خوشه‌های جدید نسبت داده می‌شوند. این روند تا زمانی ادامه دارد که تغییری در داده‌ها مشاهده نشود [۴۳].

با اعمال این الگوریتم به تصویر خروجی از گام قبل، یک نقشه‌ی ناحیه‌بندی از داده‌های ورودی در دسترس خواهد بود.

#### • اثر همسایگی پیکسل‌ها

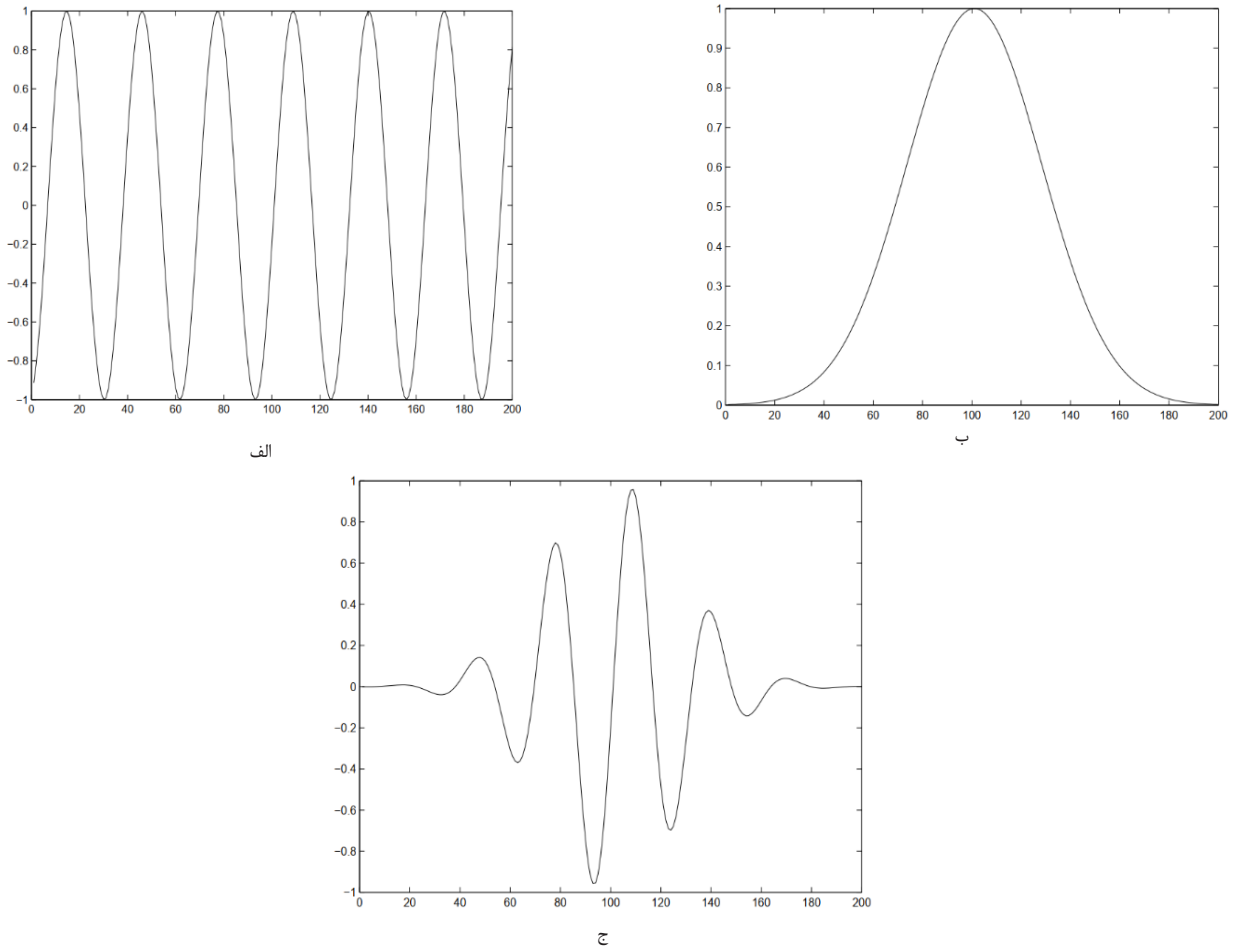
در نمایش انواع تصاویر اگر هر شی از اجتماع تعداد زیادی از پیکسل‌ها تشکیل شود، این تصویر در زمره‌ی تصاویر با دقت بالا در نظر گرفته می‌شود و اگر یک تک پیکسل از تعداد زیادی از اشیای کوچک تشکیل شود، آن شی را با دقت پایین می‌نامند.

در تصاویر سنجش از راه دور، موقعیت‌های با دقت بالا و پایین هم‌زمان رخ می‌دهند. بنابراین، وابستگی مکانی پیکسل‌ها به علت بزرگ بودن اندازه‌ی اشیای نسبت به اندازه‌ی پیکسل‌ها و دقت مکانی بالا در تصاویر افزایش می‌یابد. از طرفی، به دلیل عدم انطباق تک پیکسل‌ها با شکل و توزیع اشیای در سطح تصویر، این المان‌ها ورودی مناسبی برای اکثریت روش‌های پردازش تصویر از جمله الگوریتم‌های شناسایی، ردیابی و روش‌های پردازش مبتنی بر شی تصویر نیستند. به همین منظور، برای در دست داشتن ورودی متناسب با این الگوریتم‌ها بایستی از گروه‌هایی از پیکسل‌های مشابه با انطباق‌پذیری مناسب بر مرزهای اشیای موجود در سطح تصویر استفاده کرد. بدین ترتیب، در راستای گروه‌بندی کارآمدتر پیکسل‌ها لازم است از ویژگی‌های مشابه آن‌ها و روابط بین پیکسل‌ها استفاده کرد. از جمله بارزترین ویژگی‌های پیکسل‌ها، شباهت شدت پیکسل‌های همسایه (مقدار آن‌ها) به یکدیگر است. بدین معنا که، در یک تصویر پیکسل‌های همسایه مقادیر نزدیک به هم دارند و این ویژگی یک ارتباط معنادار در میان آن‌ها برقرار کرده است. بر همین اساس در روش پیشنهادی، مقدار شدت پیکسل‌ها به عنوان ویژگی مشابه برای جداسازی آن‌ها به منظور بهبود طبقه‌بندی تصاویر در نظر گرفته می‌شود


$$I = \sum_{c=1}^k \sum_j \left\| Y_{ic} - Y_{jc} \right\|^2 \quad (26)$$

در این رابطه،  $Y$  مقدار پیکسل در فضای ویژگی جدید و  $i$ ،  $z$  شماره‌ی پیکسل در کلاس  $C$  است.  $k$  تعداد کل کلاس‌ها است. از طرفی  $Y = AX$  در حالی که ماتریس  $A$  همان ماتریس انتقال محاسبه‌شده در روش FEUAP است. با در نظر گرفتن

Kappa	۲۸
Overall accuracy	۲۹
Average accuracy	۳۰
Average validity	۳۱



شکل ۴. الف. فیلتر گابور در حوزه زمان. ب. پوش گوسین در حوزه زمان. ج. موج سینوسی در حوزه زمان.



شکل ۵. فلوجارت روش پیشنهادی OFEUK.

که پیش‌تر مطرح شد، طبقه‌بندهای  $K$ -NN و GML دو نمونه از کارآمدترین طبقه‌بندها در میان الگوریتم‌هایی هستند که تاکنون برای تصاویر ابرطیفی با تعداد نمونه‌ی آموزشی محدود معرفی شده‌اند. شکل (۵) خلاصه‌ای از مراحل روش OFEUK را معرفی می‌کند.

شکل (۶) و (۷) اثر تعداد نمونه‌ی آموزشی در دقت کلی طبقه‌بندهای  $K$ -NN و GML را نشان می‌دهند. همانطور که در شکل (۶) و (۷) قابل مشاهده است، تعداد نمونه‌های آموزشی ۱۲، ۱۵، ۱۸ به‌منظور استخراج ۱ تا ۱۰ ویژگی به دو طبقه‌بند اعمال شده‌است. شکل (۶) نشان می‌دهد در داده‌ی ایندیانا با افزایش تعداد نمونه‌های آموزشی، دقت طبقه‌بند در استخراج ویژگی‌های تصویر به مرور افزایش یافته است؛ به بیان دیگر، دقت عملکردی طبقه‌بند با ۱۸ نمونه‌ی آموزشی بیشتر از دقت آن با ۱۲ نمونه‌ی آموزشی است. بنابراین، در صورتی که تعداد نمونه‌های آموزشی بیشتری به سیستم ارائه شود، خروجی طبقه‌بند با دقت عملکردی بهتری به کاربر ارائه می‌شود. نکته‌ی حائز اهمیت در این داده، ثابت بودن دقت عملکردی پس از دستیابی به بیشینه مقدار خود پس از ۵ ویژگی استخراجی است.

بنابر آنچه از شکل (۷) قابل استدلال است، با توجه به اینکه حجم داده‌ی سالیانس بسیار بالا می‌باشد، با در نظر گرفتن تعداد محدودی از نمونه‌ها به منظور آموزش سیستم دقت طبقه‌بندی به‌مرور افزایش یافته و سپس کاهش می‌یابد. بنابراین، در این شکل اثر پدیده‌ی هیوز که نتیجه‌ی عدم تناسب تعداد نمونه‌های آموزشی با ابعاد مجموعه داده‌ی مورد مطالعه است، قابل ملاحظه می‌باشد. همانطور که مشاهده می‌شود، در داده‌ی سالیانس نیز دقت طبقه‌بندی با افزایش تعداد نمونه‌های آموزشی، افزایش یافته بنابراین اثر پدیده‌ی هیوز کم‌رنگ‌تر می‌شود. جدول (۲) قدرت عملکردی روش پیشنهادی با میانگین ۱۰ تکرار در طبقه‌بندهای  $K$ -NN و GML و با در نظر گرفتن ۱۸ نمونه‌ی آموزشی و ۱۰ ویژگی استخراج شده برای سه مجموعه داده‌ی ایندیانا، سالیانس و بوتسوانا با محاسبه‌ی هر چهار پارامتر ارزیابی مطرح شده در بخش قبل را نشان می‌دهد.

### مقایسه با سایر روش‌های استخراج ویژگی

روش‌های متفاوت و متنوعی به‌منظور مقایسه و دستیابی به اطلاعات دقیق‌تر و مشاهده‌ی نتیجه‌ی عملکرد OFEUK، وجود دارد. در این مطالعه قصد داریم در میان این مجموعه‌ی گسترده، به دو روش مقایسه‌ی آماری و مقایسه‌ی نقشه‌ی کلاس‌ها، دقت استخراج ویژگی پیشنهادی را شرح دهیم. در بخش گذشته به مطالعه‌ی آماری نتایج روش OFEUK به-

### معرفی تصاویر به‌کار رفته در مطالعه

یکی دیگر از پارامترهای موثر در دقت مقایسه‌ی کیفیت عملکرد روش‌های مختلف، وجود داده‌های یکسان در آزمایش‌ها و بررسی‌ها است. یکی از داده‌های ابرطیفی مورد استفاده در این پژوهش، تصویر سنجنده‌ی AVIRIS<sup>۳۲</sup> مربوط به منطقه‌ی جنگلی / کشاورزی در شمال ایالت ایندیانا<sup>۳۳</sup> در آمریکا است. این تصویر حاوی ۲۲۰ باند باریک با پهنای ۱۰۰ نانومتر در بازه‌ی فرکانسی ۰.۴ تا ۲.۵ میکرومتر، در  $۱۴۵ \times ۱۴۵$  پیکسل، دقت مکانی ۲۰ کیلومتر در هر پیکسل و دقت رادیو متریک ۸ بیت است. آزمایش‌ها و بررسی‌ها بر مجموعه داده‌ی ایندیانا پس از حذف ۲۰ کانال نویزی با ۲۰۰ باند و ۱۶ کلاس انجام می‌گیرند [۴۵]. داده‌ی دوم متعلق به تصویر ابرطیفی دره‌ی سالیانس<sup>۳۴</sup> در کالیفرنیا است. این داده نیز با استفاده از سنجنده‌ی AVIRIS اخذ شده است و ابعاد آن  $۵۱۲ \times ۲۱۷$  در ۱۶ طبقه است به‌طوری که آزمایش‌ها و بررسی‌ها بر این مجموعه اطلاعات پس از حذف ۲۰ کانال جذب، با ۲۰۴ باند باقی‌مانده انجام می‌شوند. داده‌ی سوم متعلق به تصاویر ابرطیفی به‌دست آمده از دلتای اوکوانگو واقع در کشور آفریقای بوتسوانا<sup>۳۵</sup> در ابعاد  $۲۵۶ \times ۱۴۷۵$  و تعداد باند ۲۴۲ است که آزمایش‌ها و بررسی‌ها پس از حذف نویز تصویر بر ۱۴۵ باند باقی‌مانده و با ۱۴ کلاس انجام می‌گیرند [۴۶]. جدول (۱) خلاصه‌ای از ویژگی‌های داده‌های مورد استفاده است.

### بررسی نتیجه‌ی عملکرد روش پیشنهادی

گام‌های روش OFEUK را می‌توان به‌طور خلاصه به این صورت تعریف و تبیین کرد که: ابتدا، بر سه ویژگی اول حاصل از ارائه‌ی تصویر به الگوریتم PCA، فیلتر گابور اعمال می‌شود و سپس نتیجه‌ی حاصل از فیلتر گابور، به‌عنوان تصویر ورودی مراحل بعد در نظر گرفته خواهد شد و سپس، برای اعمال الگوریتم طبقه‌بندی مبتنی بر شی لازم است تصویر ناحیه‌بندی شود. در این مطالعه از روش  $K$ -means برای این منظور استفاده شده است. در ادامه، با استفاده از فاصله‌ی اقلیدسی برای محاسبه‌ی نقاط جذب هر کلاس، مرکز مناسب آن‌ها محاسبه می‌شود و در نهایت با در نظر گرفتن اثر همسایگی پیکسل‌ها، داده‌ی مورد نظر آماده برای ارائه به طبقه‌بند است. همان‌طور

<sup>۳۲</sup> Airborne visible/Infrared imaging spectrometer

<sup>۳۳</sup> Indian

<sup>۳۴</sup> Salinas

<sup>۳۵</sup> Botswana

مجموعه داده‌های یکسان، قدرت عملکردی روش OFEUK را مشخص کنیم.

صورت فردی پرداختیم و با محاسبه‌ی معیارهای ارزیابی قدرت عملکردی روش پیشنهادی را ثابت کردیم. در این بخش قصد داریم با مقایسه‌ی نتایج روش OFEUK با روش‌های پیشین بر

جدول ۱. داده‌های ابرطیفی.


داده‌های ابرطیفی	سنسور	ابعاد	تعداد کلاس‌ها	تعداد باندهای طیفی	طول موج	رزولوشن طیفی
ایندیانا	AVIRIS	۱۴۵×۱۴۵	۱۶	۲۰۰	۰.۴-۲.۵	۲۰
سالیانس	AVIRIS	۵۱۲×۲۱۷	۱۶	۲۰۴	۰.۴-۲.۵	۲۰
بوتسوانا	NASA EO-1	۱۴۷۵×۲۵۶	۱۶	۱۴۵	۰.۴-۲.۵	۲۰

جدول ۲. نتیجه‌ی اعمال OFEUK بر داده‌های ایندیانا، سالیانس و بوتسوانا در طبقه‌بندی‌های K-NN و GML


داده‌ها	ایندیانا		سالیانس		بوتسوانا	
	GML	K-NN	GML	K-NN	GML	K-NN
طبقه‌بند معیار						
A.A	۸۳.۴۳۹۵	۹۱.۱۶۷۳	۹۳.۰۹۶۰	۹۲.۰۶۳۵	۹۴.۶۷۸۳	۹۶.۹۳۰۸
O.A	۸۱.۵۴۶۰	۸۴.۳۶۲۰	۹۴.۴۳۲۹	۹۰.۵۰۶۹	۹۳.۶۷۸۹	۹۷.۶۵۳۵
A.V	۸۹.۵۳۵۷	۷۰.۶۵۷۴	۹۳.۰۱۳۹	۸۷.۱۹۲۸	۹۲.۱۰۹۵	۹۴.۷۶۹۸
Kappa	۷۸.۵۰۹۰	۸۱.۹۶۲۷	۹۳.۷۸۱۳	۸۹.۴۵۶۸	۹۵.۶۷۹۳	۹۸.۱۵۶۷

جدول ۳. مقایسه‌ی نتایج روش‌های پیشین و OFEUK بر داده‌ی ایندیانا.


طبقه‌بند	معیار ارزیابی	FEUAP	FSDA	FERR	OFEUK
GML	A.A	۶۵.۸۰۴۵	۶۹.۸۵۰۲	۶۸.۰۹۸۱	۸۵.۹۱۲۱
	Kappa	۴۷.۸۰۱۷	۵۹.۵۷۹۵	۶۴.۲۳۵۶	۷۳.۹۶۷۴
K-NN	A.A	۶۶.۳۸۶۷	۷۰.۳۴۲۰	۷۱.۴۳۲۵	۹۱.۰۰۵۰
	Kappa	۴۵.۷۳۶۹	۶۳.۳۵۴۷	۶۳.۰۹۸۷	۸۱.۶۶۵۱




شکل ۶. نمایش دقت کلی (OA) روش پیشنهادی با طبقه‌بندهای K-NN و GML بر داده‌های ایندیانا در تعداد نمونه‌های آموزشی ۱۲، ۱۵، ۱۸ و ۱۸ و تعداد ویژگی‌های استخراج‌شده‌ی ۱ تا ۱۰ ویژگی.



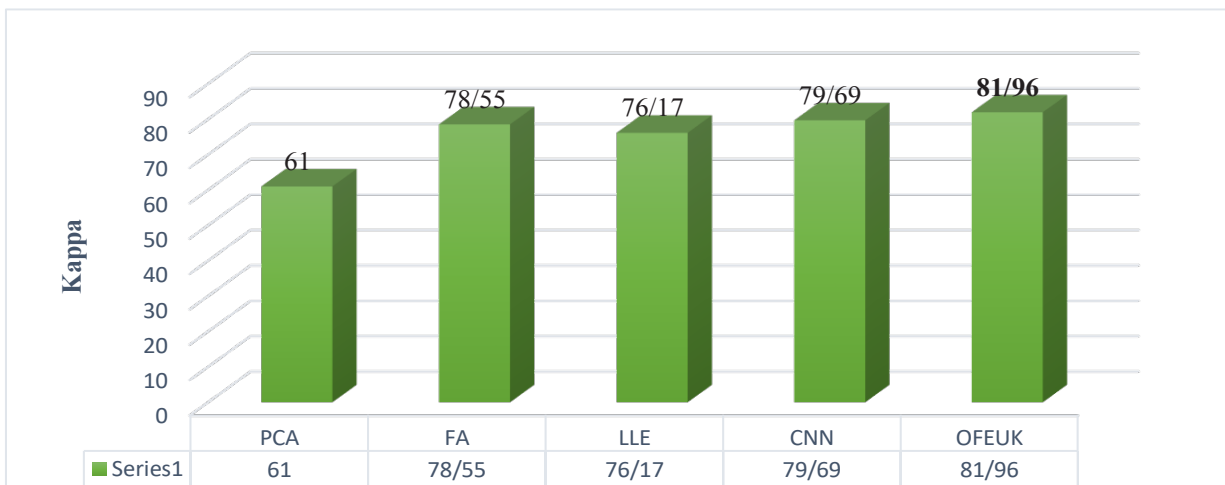
شکل ۷. نمایش دقت کلی (OA) روش پیشنهادی با طبقه‌بندهای K-NN و GML بر داده‌های سالیانس در تعداد نمونه‌های آموزشی ۱۲، ۱۵، ۱۸ و ۱۸ و تعداد ویژگی‌های استخراج‌شده‌ی ۱ تا ۱۰ ویژگی.



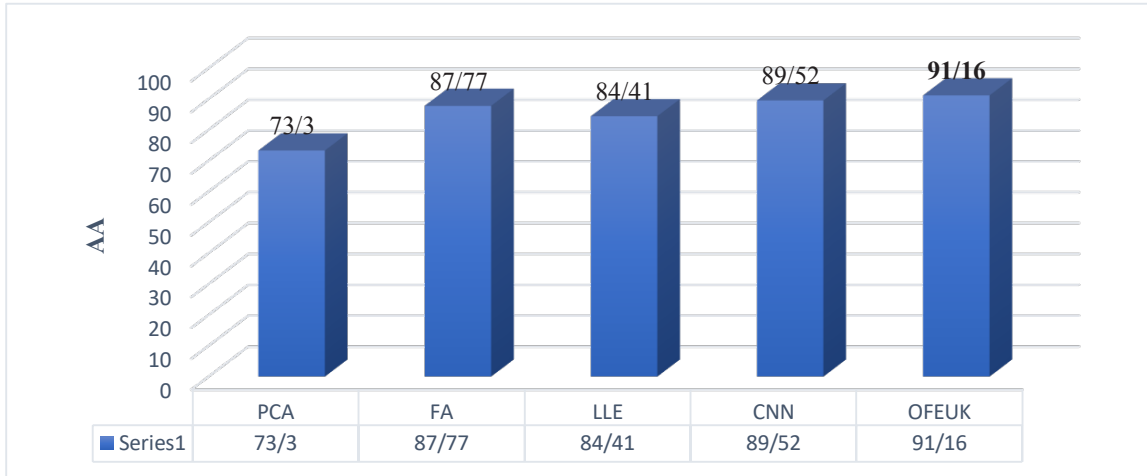
شکل ۸. مقایسه‌ی نتایج روش‌های پیشین و OFEUK بر داده‌ی ایندیانا.



الف



ب



ج

شکل ۹. مقایسه‌ی نتایج روش‌های پیشین و روش OFEUK بر داده‌های ایندیانا بر مبنای: الف. دقت کلی، ب. ضریب کاپا و ج. دقت متوسط


CNN به کمک معیارهای ارزیابی ضریب کاپا، دقت کلی و دقت متوسط مقایسه می‌کند. جدول (۳) به مقایسه‌ی نتایج روش‌های FEUAP، FSDA، FERR با OFEUK بر داده‌ی ایندیانا با دو طبقه‌بند K-NN و GML و در نظر گرفتن دو معیار ارزیابی ضریب کاپا و میانگین اعتبار می‌پردازد.

### مقایسه‌ی آماری

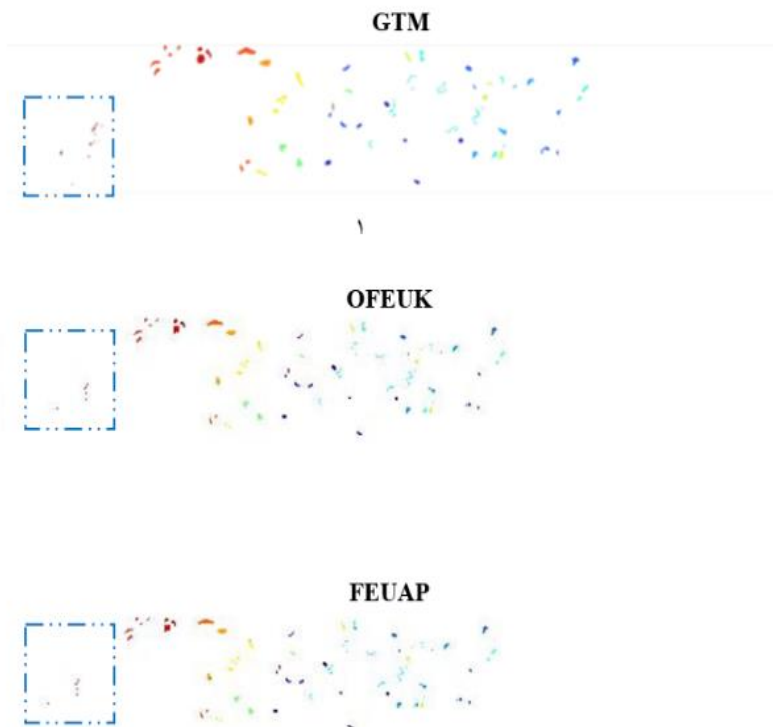
در شکل (۸)، OFEUK در مقایسه با NWFE، FSDA، LDA، FERR و GDA قرار گرفته است و اعتبار متوسط آن‌ها در استخراج ۱ تا ۱۰ ویژگی مشخص شده است. با توجه به نمودارهای آماری رسم شده، روش OFEUK از دقت عملکردی بسیار بالایی برخوردار است. شکل (۹) دقت عملکرد روش پیشنهادی بر داده‌ی ایندیانا را با PCA، FA، LLE و



شکل ۱۰. نتیجه‌ی به‌دست‌آمده با ۱۸ نمونه‌ی آموزشی برای داده‌ی ایندیانا توسط طبقه‌بند GML و تصویر نقشه حقیقی آن.



شکل ۱۱. نتیجه‌ی به‌دست‌آمده با ۱۸ نمونه‌ی آموزشی برای داده‌ی سالیانس توسط طبقه‌بند GML و تصویر نقشه حقیقی آن.



شکل ۱۲. نتیجه‌ی به‌دست‌آمده با ۱۸ نمونه‌ی آموزشی برای داده‌ی بوتسوانا توسط طبقه‌بند GML و تصویر نقشه حقیقی آن.



[2] Peng, Hanchuan; Long, Fuhui; Ding, Chris. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min redundancy. *IEEE Transactions on pattern analysis and machine intelligence*, 2005, 27.8: 1226-1238.

[۳] کیانی. ارزیابی صحت طبقه‌بندی تصویر ماهواره IRS-P6 با استفاده از پایگاه اطلاعاتی Google Earth به منظور تهیه نقشه پوششی/اکاربری اراضی (مطالعه موردی: حوزه آبخیز طالقان). (فصلنامه علمی-پژوهشی اطلاعات جغرافیایی سپهر 59: 23.90, 2014,

[4] Uddin, M. P.; Mamun, M. A.; Hossain, M. A. Feature extraction for hyperspectral image classification. In: *Humanitarian Technology Conference (R10-HTC), 2017 IEEE Region10. IEEE, 2017. p. 379-382.*

[5] Melgani, Farid; Bruzzone, Lorenzo. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on geoscience and remote sensing*, 2004, 42.8: 1778-1790.

[6] Pal, Mahesh; Foody, Giles M. Feature selection for classification of hyperspectral data by SVM. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48.5: 2297-2307.

[7] Shahdoosti, Hamid Reza; Tabatabaei, Zahra. Object-based feature extraction for hyperspectral data using firefly algorithm. *International Journal of Machine Learning and Cybernetics*, 2019, 1-15.

[8] Izquierdo-Verdiguier, Emma, et al. Semisupervised kernel feature extraction for remote sensing image analysis. *IEEE transactions on geoscience and remote sensing*, 2014, 52.9: 5567-5578.

[9] Imani, Maryam; Ghassemian, Hassan. Feature extraction using attraction points for classification of hyperspectral images in a small sample size situation. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11.11: 1986-1990.

[10] Myint, Soe W., et al. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote sensing of environment*, 2011, 115.5: 1145-1161.

[11] Huang, Zhi; JIA, Xiuping. A hybrid segmentation technique for object-based hyperspectral data classification over complex sub-urban landscape. In: *2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). IEEE, 2013. p. 1-4.*

[12] Shackelford, Aaron K.; Davis, Curt H. A combined fuzzy pixel-based and object-based

## مقایسه‌ی نقشه‌ی کلاس‌ها

در این بخش، با اعمال الگوریتم پیشنهادی بر هر یک از مجموعه داده‌های مورد مطالعه، خروجی حاصل را به طبقه‌بند ارائه کرده و تصویر نتیجه‌ی طبقه‌بندی شده را نمایش داده‌ایم. شکل‌های (۱۰) و (۱۱) و (۱۲) به ترتیب به مقایسه‌ی نتیجه‌ی OFEUK و FEUAP با تصویر حقیقی زمین داده‌های ایندیانا، سالیاناس و بوتسوانا می‌پردازند. برای بررسی کاربردی‌تر این تصاویر، حلقه‌هایی حول برخی بخش‌های هر یک از آن‌ها به منظور نمایش تفاوت‌های نتایج حاصل از هر یک از الگوریتم‌ها رسم شده است. همانطور که در این شکل‌ها مشخص شده است، الگوریتم FEUAP در مقایسه با تصویر حقیقی زمین هر یک از داده‌ها تفاوت چشمگیری دارد؛ این در حالی است که، روش پیشنهادی OFEUK به‌خوبی بخش‌های مختلف تصویر را مشخص کرده و بنا به مقایسه‌های انجام شده، همانطور که مشخص است نتیجه‌ی روش پیشنهادی از میزان قابلیت اطمینان و صحت بسیار بالایی در مقایسه با نقشه‌ی GTM هر یک از داده‌ها و نتیجه‌ی حاصل از اعمال الگوریتم FEUAP برخوردار است.

## نتیجه‌گیری

در این مطالعه یک روش استخراج ویژگی مبتنی بر شی‌راستای به‌کارگیری اطلاعات طیفی و مکانی تصویر به‌منظور افزایش دقت طبقه‌بندی ارائه کردیم. با کمک روش پیشنهادی دقت طبقه‌بند  $K$ -NN و GML در داده‌ی ایندیانا به‌ترتیب تا ۹۱.۱۶۷۳ و ۸۳.۴۳۹۵ افزایش یافته است که بیانگر قدرت روش OFEUK است. در این روش برای استفاده از اطلاعات مکانی از فیلتر گابور و الگوریتم ناحیه‌بندی  $K$ -means استفاده شده است. سپس در تصویر خروجی حاصل از فیلتر گابور، برای هر یک از کلاس‌ها با محاسبه‌ی نقطه‌ی جذب، مراکز آن‌ها به‌دست می‌آوریم و در گام بعدی، با اضافه کردن یک پارامتر به تابع هزینه‌ی به‌دست آمده، از حضور پیکسل‌های همسایه در یک کلاس اطمینان حاصل می‌کنیم و در نهایت نقشه‌ی ناحیه-بندی  $K$ -means و ویژگی‌های استخراج شده را به طبقه‌بند مورد نظر ارائه می‌کنیم. روش پیشنهادی بر سه مجموعه داده‌ی واقعی ایندیانا، سالیاناس و بوتسوانا اعمال شده و نتیجه‌ی آن با چندین روش پیشین مقایسه شده است. نتیجه‌ی این مقایسه‌ها مهر تاییدی بر توانمندی بالای روش پیشنهادی OFEUK است.

## مراجع:

[1] Landgrebe, David. Hyperspectral image data analysis. *IEEE Signal Processing Magazine*, 2002, 19.1: 17-28.

[23] Tarabalka, Yuliya, et al. 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*, 2012, 5.1: 262-272.

[۲۴] کیانی سرکله آزاده؛ قاسمیان محمدحسن. تحلیل ممیز غیرپارامتریک بهبودیافته برای دسته بندی تصاویر ابرطیفی با نمونه آموزشی محدود.

[25] Dhanjal, Charanpal; Gunn, Steve R.; Shawe-Taylor, John. Efficient sparse kernel feature extraction based on partial least squares. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31.8: 1347-1361.

[26] Reza Shahdoosti, Hamid; Javaheri, Nayereh. A new hybrid feature extraction method in a dyadic scheme for classification of hyperspectral data. *International journal of remote sensing*, 2018, 39.1: 101-130

[27] Baudat, Gaston; Anouar, Fatiha. Generalized discriminant analysis using a kernel approach. *Neural computation*, 2000, 12.10: 2385-2404.

[28] Li, Jun, et al. Generalized composite kernel framework for hyperspectral image classification. *IEEE transactions on geoscience and remote sensing*, 2013, 51.9: 4816-4829.

[29] Gan, Le, et al. Multiple feature kernel sparse representation classifier for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56.9: 5343-5356.

[30] Chen, Yushi, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54.10: 6232-6251.

[31] Castillejo-González, Isabel Luisa, et al. Object-and pixel-based analysis for mapping crops and their agro-environmental associated measures using QuickBird imagery. *Computers and Electronics in Agriculture*, 2009, 68.2: 207-215.

[32] Gu, Haiyan, et al. An object-based semantic classification method for high resolution remote sensing imagery using ontology. *Remote Sensing*, 2017, 9.4: 329.

[33] Dingle Robertson, Laura; King, Douglas J. Comparison of pixel-and object-based classification in land cover change mapping. *International Journal of Remote Sensing*, 2011, 32.6: 1505-1529.

approach for classification of high-resolution multispectral data over urban areas. *IEEE Transactions on GeoScience and Remote sensing*, 2003, 41.10: 2354-2363.

[13] Linli, Cui, et al. Comparison study on the pixel-based and object-oriented methods of land-use/cover classification with TM data. In: *2008 International Workshop on Earth Observation and Remote Sensing Applications*. IEEE, 2008. p. 1-5.

[14] Brik, Youcef; Zerrouki, Nabil; Bouchaffra, Djamel. Combining pixel-and object-based approaches for multispectral image classification using dempster-shafer theory. In: *2013 International Conference on Signal-Image Technology & Internet-Based Systems*. IEEE, 2013. p. 448-453.

[15] Bartholomew, David J.; Steele, Fiona; MOUSTAKI, Irini. *Analysis of multivariate social science data*. Chapman and Hall/CRC, 2008.

[16] Ye, Fei; SHI, Zhiping; Shi, Zhongzhi. A comparative study of PCA, LDA and Kernel LDA for image classification. In: *2009 International Symposium on Ubiquitous Virtual Reality*. IEEE, 2009. p. 51-54.

[17] LI, Wei; Liu, Jiabin; Du, Qian. Sparse and low-rank graph for discriminant analysis of hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54.7: 4094-4105.

[18] Imani, Maryam; Ghassemian, Hassan. Discriminant analysis in morphological feature space for high-dimensional image spatial-spectral classification. *Journal of Applied Remote Sensing*, 2018, 12.1: 016024.

[19] Imani, Maryam; Ghassemian, Hassan. High-dimensional image data feature extraction by double discriminant embedding. *Pattern Analysis and Applications*, 2017, 20.2: 473-484.

[20] Kianisarkaleh, Azadeh; Ghassemian, Hassan. Nonparametric feature extraction for classification of hyperspectral images with limited training samples. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 119: 64-78.

[21] Imani, Maryam; Ghassemian, Hassan. Ridge regression-based feature extraction for hyperspectral data. *International Journal of Remote Sensing*, 2015, 36.6: 1728-1742.

[۲۲] اکبری داوود؛ صفی عبدالرضا؛ خزائی صفا. تاثیر انتخاب ویژگی به کمک الگوریتم ژنتیک بر طبقه بندی طیفی-مکانی تصاویر ابرطیفی.

*Engineering and Service Science*. IEEE, 2013. p. 1002-1005.

[41] Vapnik, Vladimir. *The nature of statistical learning theory*. Springer science & business media, 2013.

[42] Ahmadian, A.; Mostafa, A. An efficient texture classification algorithm using Gabor wavelet. In: *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No. 03CH37439)*. IEEE, 2003. p. 930-933.

[43] Schlesinger, Michail I.; Hlavác, Václav. *Ten lectures on statistical and structural pattern recognition*. Springer Science & Business Media, 2013.

[44] Shafri, Helmi Zulhaidi Mohd; Hamedianfar, Alireza. Mapping of intra-urban land covers using pixel-based and object-based classifications from airborne hyperspectral imagery. In: *2015 2nd International Conference on Information Science and Security (ICISS)*. IEEE, 2015. p. 1-4.

[45] Tenenbaum, Joshua B.; De Silva, Vin; Langford, John C. A global geometric framework for nonlinear dimensionality, reduction. *Science* 2000, 290.5500: 2319-2323.

[۴۶] ایمانی مریم; قاسمیان حسن. کاهش ابعاد داده های ابرطیفی به منظور افزایش جدایی پذیری کلاس ها و حفظ ساختار داده.

[۳۴] رحیم زادگان مجید. ارایه روشی برای طبقه بندی داده های ابرطیفی AVIRIS ، با استفاده از استخراج ویژگی و ترکیب طبقه بندی کننده ها.

[35] Ball, Jhn E., et al. Level set hyperspectral image sementation using spectral information divergence-based best band selection. In: *2007 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2007. p. 4053-4056.

[36] Tarabalka, Yuliya; Benediktsson, Jón Atli; Chanussot, Jocelyn. Spectral-spatial classification of hyperspectral imagery based on partitionial clustering techniques. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47.8: 2973-2987.

[37] Tarabalka, Yuliya; Chanussot, Jocelyn; Benediktsson, Jon Atli. Segmentation and classification of hyperspectral images using watershed transformation. *Pattern Recognition*, 2010, 43.7: 2367-2379.

[38] Boskovitz, Victor; Guterman, Hugo. An adaptive neuro-fuzzy system for automatic image segmentation and edge detection. *IEEE Transactions on fuzzy systems*, 2002, 10.2: 247-262.

[۳۹] چاجی ناصر; قاسمیان حسن. ناحیه بندی تصویر با استفاده از ادغام ویژگی های لبه و بافت.

[40] LI, Yan, et al. A comparison of high resolution satellite imagery classification between object-oriented and pixel-based method. In: *2013 IEEE 4th International Conference on Software*