

ارائه روش بدون نظارت مبتنی بر خوشه‌بندی باندها در فضای پدیده اجزای خالص برای استخراج ویژگی‌های طیفی کاهش یافته از تصاویر ابرطیفی

سید احمد علیزاده مقدم^{*}، مهدی مختارزاده^۲

۱- کارشناس ارشد سنجش از دور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی
۲- دانشیار گروه سنجش از دور و فتوگرامتری، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۴۰۲/۰۳/۱۵ تاریخ پذیرش مقاله: ۱۴۰۲/۰۳/۳۰

چکیده

تصاویر ابرطیفی منبع غنی از داده‌های سنجش از دور محسوب می‌شوند که در مطالعات مختلفی از جمله کشاورزی، مدیریت و طبقه‌بندی پوشش/کاربری اراضی بکار گرفته می‌شوند. با اینحال، ابعاد بالای فضای ویژگی و تعداد محدود نمونه‌های آموزشی از چالش‌های اصلی در طبقه‌بندی این تصاویر و استخراج اطلاعات از آن‌ها بشمار می‌رود. بدین ترتیب، استفاده از روش‌های کاهش ویژگی به دو شکل انتخاب ویژگی و استخراج ویژگی از اهمیت بالایی برخوردار است. روش‌های کاهش ویژگی به دو دسته نظارت‌شده و بدون نظارت تقسیم می‌شوند، که روش‌های بدون نظارت به دلیل عدم نیاز به داده‌های آموزشی کاربردی‌تر هستند. در این مطالعه روشی بدون نظارت مبتنی بر خوشه‌بندی باندها در فضای پدیده اجزای خالص (EPBC) ارائه شده است. در این روش پس از تخمین بعد مجازی تصویر و استخراج اجزای خالص، فضای پدیده اجزای خالص تشکیل شده و باندها در این فضا به روش *K-Means* خوشه‌بندی می‌گردند و در نهایت میانگین وزن‌دار هر خوشه به عنوان یک ویژگی استخراج می‌شود. نتایج نهایی بدست آمده از طبقه‌بندی دو تصویر ابرطیفی نشان می‌دهد که دقت کلی طبقه‌بندی به روش بیشترین شباهت با ویژگی‌های استخراج شده از روش ارائه شده در بهترین حالت برای تصویر کاج‌های هندی برابر ۷۵/۶۶ درصد و برای تصویر دانشگاه پاویا برابر ۸۹/۷۱ درصد بوده است، که نسبت به روش‌های آنالیز مولفه‌های اصلی (PCA)، تبدیل کسر نوین کمینه (MNF) و آنالیز مولفه‌های مستقل (ICA) به عنوان روش‌های بدون نظارت و روش آنالیز تفکیک پذیری خطی (LDA) به عنوان روش نظارت شده عملکرد بهتری داشته است.

کلیدواژه‌ها: تصویر ابرطیفی، فضای پدیده، استخراج ویژگی، اجزای خالص، خوشه‌بندی، طبقه‌بندی.

* نویسنده مکاتبه کننده: تهران، خیابان ولیعصر، تقاطع میرداماد، روبروی اسکان، دانشکده مهندسی نقشه‌برداری دانشگاه صنعتی خواجه نصیرالدین طوسی.

تلفن: ۰۹۱۳۶۳۰۷۶۳۶

۱- مقدمه

تصاویر ابرطیفی^۱ اطلاعات بازتابندگی طیفی را در صدها باند باریک در محدوده ۴۰۰ تا ۲۵۰۰ نانومتر از امواج الکترومغناطیس اخذ می‌کنند. این تصاویر در مطالعات بسیاری شامل پایش محیط زیست، کشاورزی دقیق، مطالعات معدن، طبقه بندی پوشش اراضی بکار برده می‌شوند [۱ و ۲]. در واقع، تصاویر ابرطیفی با بهره‌گیری از قدرت تفکیک طیفی بالا امکان تشخیص پدیده‌های خاص را فراهم می‌کنند که تنها بوسیله اختلافات جزئی در بازتاب طیفی ممکن است [۳]. با اینحال، تعداد بسیار زیاد باندهای این تصاویر چالش‌های اساسی نظیر، افزایش فضای ذخیره‌سازی، پیچیدگی و هزینه‌های محاسباتی را به همراه دارد [۴ و ۵]. بطور کلی، از یک سو همبستگی باندهای همسایه و بروز بلای ابعاد^۲ و از سوی دیگر محدودیت نمونه‌های واقعیت زمینی چالش اساسی در طبقه‌بندی^۳ و استخراج اطلاعات از این تصاویر محسوب می‌شود [۶]. در واقع، براساس پدیده هیوز^۴، هرچه ابعاد فضای ویژگی^۵ مورد استفاده در طبقه‌بندی بزرگتر باشد، رسیدن به دقت‌های بالاتر، مستلزم افزایش تعداد نمونه‌های آموزشی^۶ می‌باشد [۷]. بدین ترتیب، بکارگیری روش‌های کاهش ابعاد فضای ویژگی در طبقه‌بندی تصاویر ابرطیفی از اهمیت بالایی برخوردار است. روش‌های مبتنی بر کاهش ویژگی، به دو دسته اصلی استخراج ویژگی^۷ و انتخاب ویژگی^۸ تقسیم می‌شوند [۸]. روش‌های انتخاب ویژگی، بر مبنای انتخاب زیرمجموعه‌ای بهینه از مجموعه ویژگی‌های اصلی می‌باشد [۹]. درحالی‌که در روش‌های استخراج ویژگی، این

زیرمجموعه با استفاده از تبدیل یا انتقال فضای ویژگی فعلی به فضای ویژگی جدید برآورد می‌شود. در هر دو دسته هدف انتخاب زیرمجموعه‌ای از ویژگی‌های اصلی است، به نحوی که زیرمجموعه جدید ضمن کاهش ابعاد فضای ویژگی بیشترین میزان اطلاعات را در خود داشته‌باشد [۱۰]. لازم بذکر است که این روش‌ها خود به دو دسته اصلی نظارت شده^۹ و بدون نظارت^{۱۰} تقسیم‌بندی می‌شوند. اختلاف این دو روش در بکارگیری نمونه‌های آموزشی در فرآیند انتخاب ویژگی-های بهینه است. از این رو، روش‌های بدون نظارت به علت عدم نیاز به نمونه‌های آموزشی به منظور کاهش فضای ویژگی و برآورد ویژگی‌های بهینه دارای برتری نسبت به روش‌های نظارت شده می‌باشند.

طی سالیان اخیر رویکردهای متفاوتی به منظور کاهش ابعاد فضای ویژگی بر مبنای روش‌های نظارت شده و بدون نظارت ارائه شده‌است. در روش‌های بدون نظارت، هدف اصلی تفکیک‌پذیری بین کلاس‌ها نمی‌باشد و تمرکز بر کاهش ابعاد فضای ویژگی با حفظ بیشینه اطلاعات باندی تصاویر است. روش‌هایی نظیر آنالیز مولفه‌های اصلی^{۱۱} (PCA) [۱۱]، آنالیز مولفه‌های مستقل^{۱۲} (ICA) [۱۲] و کسر نویز کمینه^{۱۳} (MNF) [۱۳] از جمله روش‌های معروف استخراج ویژگی بدون نظارت‌اند، که در مطالعات اخیر مورد استفاده قرار گرفتند. آنالیز مولفه‌های اصلی، داده‌ها را براساس واریانس آن‌ها به یک فضای غیر همبسته تصویر می‌کند. همچنین روش آنالیز مولفه‌های مستقل، تبدیل دیگری است که داده‌ها را براساس بیشینه‌سازی استقلال آماری آن‌ها به فضای جدید تصویر می‌نماید. از آنجایی‌که پارامترهای آماری نظیر واریانس همواره به انتخاب باندهای با کیفیت نمی‌انجامند و بروز داده‌های

¹ Hyperspectral Images² Curse of Dimensionality³ Classification⁴ Hughes Phenomenon⁵ Feature Space⁶ Training Samples⁷ Feature Extraction⁸ Feature Selection⁹ Supervised¹⁰ Unsupervised¹¹ Principal Component Analysis¹² Independent Component Analysis¹³ Minimum Noise Fraction

بالا به فضای ویژگی با ابعاد پایین‌تر استفاده می‌کنند، به نحوی که فضای ویژگی تبدیل‌یافته با تعداد ویژگی کمتر حاوی بیشترین اطلاعات ممکن می‌باشد. علاوه بر دسته روش‌های مذکور، روش‌های دیگری با رویکردهای مبتنی بر بهینه‌سازی و یادگیری عمیق^۶ معرفی شدند. در این زمینه، یک روش استخراج ویژگی نظارت شده تحت عنوان یکپارچه‌سازی و قطعه‌بندی طیفی توسعه داده شد. در این روش منحنی امضای طیفی پیکسل‌ها به قطعات یکسان و بدون همپوشانی، به نام کانال، تقسیم می‌شوند و طی فرآیند قطعه‌بندی تعداد و پهنای هر کانال با استفاده از روش بهینه‌سازی ازدحام ذرات برآورد می‌شوند [۱۴]. در مطالعه‌ای مشابه، روش کاهش ویژگی بدون نظارت بر مبنای بهینه‌سازی ازدحام ذرات و با بهره‌گیری از واگرایی طیفی و اطلاعات گرادیان مکانی توسعه یافت [۲۱]. در این روش در ابتدا فیلتر نویز به منظور بهبود نسبت سیگنال به نویز در انتخاب ویژگی اعمال گردید و پس از خوشه‌بندی^۷ باندهای مشابه، به منظور انتخاب ویژگی‌های مناسب الگوریتم بهینه‌سازی ازدحام ذرات بکار گرفته شد. از سویی دیگر، روش استخراج ویژگی عمیق تنظیم شده به منظور طبقه‌بندی تصاویر ابرطیفی با استفاده از شبکه عصبی پیچشی^۸ توسعه یافت، که به منظور استخراج ویژگی‌های عمیق، چندین لایه‌ی پیچشی و ادغام در آن بکار گرفته شد [۲۲]. بطور کلی روش‌های مطرح شده نیازمند دسترسی به تعداد بالای نمونه‌های آموزشی می‌باشند و از سویی دیگر عمدتاً با فضای جستجوی وسیعی مواجه‌اند که منجر به پیچیدگی و افزایش بار محاسباتی می‌شود [۲۳].

دسته روش‌های دیگری مبتنی بر خوشه‌بندی باندها در سال‌های اخیر معرفی شدند که عملکرد قابل قبولی را در کاهش ابعاد فضای ویژگی از خود نشان داده‌اند. در

نویزی در فضای تبدیل یافته محتمل است، روش کسر نویز کمینه، با بهرمندی از بیشینه‌سازی نسبت سیگنال به نویز، داده‌ها را به فضای جدید تبدیل می‌کند. از آنجایی که این روش‌ها در حین فرآیند کاهش ویژگی از نمونه‌های آموزشی استفاده نمی‌کنند، نتایج حاصل لزوماً به تفکیک پذیری بهتر کلاس‌ها و افزایش دقت طبقه‌بندی منجر نمی‌شود [۱۴]. در مقابل روش‌هایی نظیر آنالیز تفکیک پذیری خطی (LDA)، آنالیز تفکیک پذیری تعمیم یافته^۲ (GDA) [۱۵]، استخراج ویژگی وزندار غیر پارامتریک^۳ (NWFE) [۱۶]، استخراج ویژگی مرز تصمیم‌گیری^۴ (DBFE) [۱۷] و استخراج ویژگی آنالیز تفکیک پذیری^۵ (DAFE) [۱۸] از جمله روش‌های نظارت شده‌اند. این روش‌ها با بهرمندی از نمونه‌های آموزشی در برآورد فضای ویژگی‌های جدید سعی بر بیشینه‌سازی تفکیک‌پذیری بین کلاس‌ها دارند. در این بین روش‌های استخراج ویژگی مرز تصمیم‌گیری و استخراج ویژگی آنالیز تفکیک‌پذیری زمانیکه تعداد نمونه‌های آموزشی محدوداند، در تخمین ماتریس کوواریانس هر کلاس با مشکل روبه‌رو می‌شوند و نمی‌توانند برآورد دقیقی از فضای ویژگی جدید ارائه دهند [۱۹]. در مقابل روش استخراج ویژگی وزندار غیر پارامتریک به ازای هر نمونه آموزشی وزن متفاوتی را لحاظ می‌کند [۲۰]. این روش از رویکرد غیر پارامتریک برای تخمین ماتریس‌های پراکندگی بین کلاسی و درون کلاسی استفاده می‌کند و برخلاف سایر روش‌های مذکور تعداد ویژگی‌های برآوردی این روش با محدودیت روبرو نیست، لیکن میزان بار محاسباتی این روش به میزان قابل توجهی بالاتر است [۱۹]. بطور کلی، روش‌های مطرح شده عموماً از پارامترهای آماری به منظور ایجاد یک تبدیل از فضای ویژگی اصلی با ابعاد

¹ Linear Discriminant Analysis² Generalized Discriminant Analysis³ Nonparametric Weighted Feature Extraction⁴ Decision Boundaries Feature Extraction⁵ Discriminant Analysis Feature Extraction⁶ Deep Learning⁷ Clustering⁸ Convolutional Neural Network

ویژگی‌های کاهش یافته طیفی از طریق خوشه‌بندی باندهای تصویر بر مبنای اجزای خالص تصویر است. بدین ترتیب خوشه‌بندی باندها بر مبنای اجزای خالص تصویر که یکی از مهم‌ترین تفاسیر فیزیکی هر تصویر به شمار می‌روند، انجام خواهد شد. به عنوان نوآوری در روش پیشنهادی این مقاله خوشه‌بندی باندها در فضای پدیده اجزای خالص صورت می‌پذیرد که محورهای این فضا همان اجزای خالص تصویر هستند. این مقاله شامل ۵ بخش مقدمه، روش تحقیق، داده‌های مورد استفاده، ارائه نتایج و بحث و نتیجه‌گیری و پیشنهادات است که بخش مقدمه مطرح شد و سایر بخش‌ها در ادامه مطرح شده است.

۲- روش تحقیق

فلوچارت روش پیشنهادی که خوشه‌بندی باندها در فضای پدیده اجزای خالص^۱ (*EPBC*) نامیده می‌شود، در شکل (۱) نشان داده شده است. همانطور که در تصویر مشاهده می‌شود، روش تحقیق دارای دو فاز کلی تولید ویژگی‌های کاهش یافته و ارزیابی نتایج است. فاز تولید ویژگی‌های کاهش یافته، همان روند روش *EPBC* است که شامل پنج بخش اصلی تخمین بعد مجازی^۲، استخراج اجزای خالص^۳ تصویر، تشکیل فضای پدیده، خوشه‌بندی باندها و استخراج ویژگی‌های طیفی است. همچنین در فاز ارزیابی نتایج، به منظور ارزیابی عملکرد روش پیشنهادی، از طبقه‌بندی تصویر با ویژگی‌های استخراج شده، استفاده شده است.

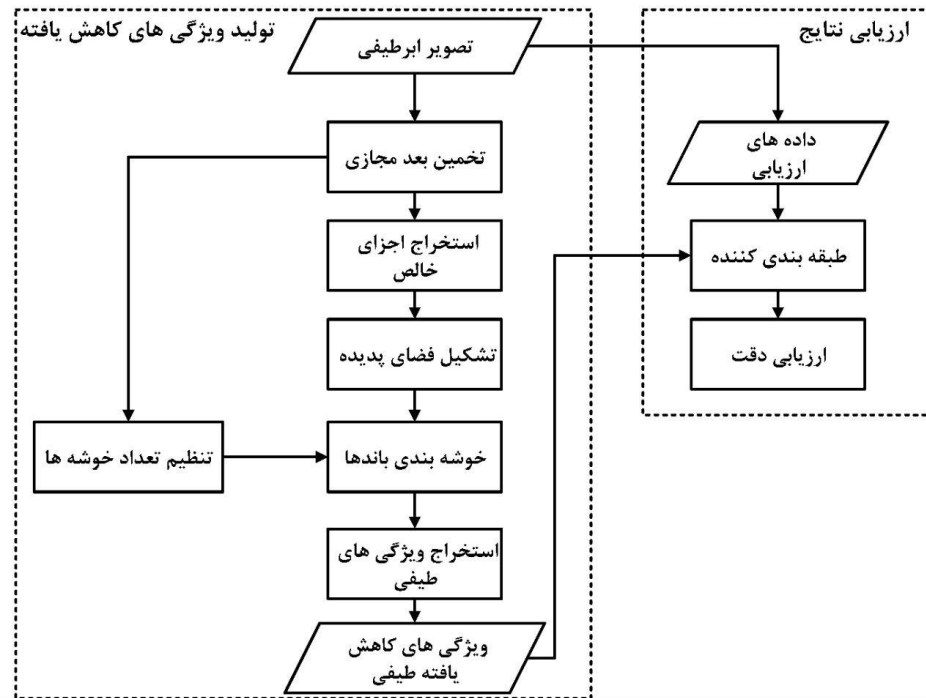
این زمینه، روش نظارت شده دیگری مبتنی بر خوشه‌بندی فازی به منظور کاهش فضای ویژگی با هدف قرارگیری باندهای همبسته در یک خوشه توسعه یافت [۲۴]. در همین دسته، ایمانی و قاسمیان (۲۰۱۴) روش استخراج ویژگی مبتنی بر خوشه‌بندی نظارت شده را ارائه دادند [۱۹]. این روش در مرحله اول مقادیر میانگین نمونه‌های آموزشی هر کلاس را به عنوان مشخصه هر باند در نظر می‌گیرد و به ازای هر باند برداری برآورد می‌شود که شامل مقادیر میانگین کلاس-های مختلف است. در نهایت باندهای مشابه با بکارگیری روش خوشه‌بندی *k-means* در یک دسته قرار می‌گیرند و ویژگی‌های جدید از هر خوشه استخراج می‌شود. با پیشرفت روش‌های اخیر در این حوزه، روش‌های بدون نظارت نیز در این دسته توسعه یافتند. بطور مثال، روش بدون نظارت استخراج ویژگی مبتنی بر خوشه‌بندی همبستگی باندها ارائه شد [۲۵]. در این روش در مرحله اول، ماتریس ضرایب همبستگی بین باندی تولید شده و با استفاده از روش خوشه‌بندی *K-means* باندهای همبسته در یک خوشه قرار می‌گیرند و متوسط هر خوشه به عنوان ویژگی‌های جدید استخراج می‌شوند. در مطالعه مشابه، خوشه‌بندی فازی بر روی فضای تبدیل یافته *PCA* اجرا شد و فضای ویژگی با قرارگیری باندهای مشابه در یک خوشه کاهش یافت [۲۶]. در مطالعه دیگر روش چند مرحله‌ای خوشه-مبنا به منظور کاهش فضای ویژگی توسعه یافت، که در آن در مرحله اول با استفاده از آنتروپی هر باند، باندهای نویزی شناسایی شده و در نهایت با ترکیب شاخص شباهت ساختاری و خوشه‌بندی *K-means* باندهای جدید استخراج می‌شوند [۲۷].

عمده روش‌های خوشه‌بندی بررسی شده از اطلاعات آماری و تفاسیر ریاضی مقادیر باندهای تصویر به منظور خوشه‌بندی این باندها استفاده می‌کنند و در این تحقیقات، بهره برداری از اطلاعات اجزای خالص تصویر مورد غفلت واقع شده است. بدین منظور هدف این مقاله توسعه روشی بدون نظارت جهت استخراج

¹ Endmember Prototype Band Clustering

² Virtual Dimensionality

³ Endmember Extraction



شکل ۱: فلوجارت روش پیشنهادی (EPBC)

۲-۱- تخمین بعد مجازی تصویر

از آنجا که اکثر الگوریتم‌های استخراج اجزای خالص نیاز به دانستن تعداد اجزای خالص تصویر دارند، در روش پیشنهادی از تخمین بعد مجازی تصویر برای تعیین تعداد اجزای خالص تصویر استفاده شده است. منظور از بعد مجازی کمترین تعداد منابع سیگنال متمایز طیفی است که تصاویر ابرطیفی را از نقطه نظر تشخیص و طبقه‌بندی عوارض تشریح می‌کند [۲۸]. در این مقاله از روش شناسایی زیرفضای سیگنال ابرطیفی با استفاده از کمترین خطا (HySime)، که از مرسوم ترین روش‌های تخمین بعد مجازی است، استفاده شده است. الگوریتم HySime نخستین بار در سال ۲۰۰۸ توسط دیاز و ناسیمنتو ارائه شد و جزئیات و روابط آن به تفصیل توسط ناسیمنتو همکاران (۲۰۰۷) بیان شده است [۲۹]. HySime یک روش بدون نظارت، اتوماتیک و

بر مبنای تجزیه بردار ویژه^۲ است. ایده اصلی این روش یافتن ابعاد زیرفضای سیگنال بوسیله جستجوی در زیر مجموعه‌ای از بردارهای ویژه است، به نحوی که بهترین نماینده برای زیرفضای سیگنال باشد. در واقع این روش با تخمین ماتریس‌های همبستگی سیگنال و نویز زیرمجموعه‌ای از بردارهای ویژه به نحوی برگزیده می‌شود، که زیرفضای سیگنال انتخابی حداقل مربعات خطا را داشته باشد. در این روش در مرحله اول ماتریس‌های همبستگی سیگنال و نویز با استفاده از رگرسیون چندگانه تخمین زده می‌شوند و سپس با بهره‌گیری از بردارهای ویژه ماتریس همبستگی سیگنال، دنباله‌ای از زیرفضای تودرتو ایجاد می‌شود. زیر فضای سیگنال بوسیله به حداقل رساندن مجموع توان خطای تصویر شده^۳ با توان نویز حاصل می‌گردد، که به ترتیب نقش کاهش‌دهنده و افزایش‌دهنده در ابعاد

² Decomposed-based

³ Projection Error Power

¹ Hyperspectral Signal Identification by Minimum Error

این روش به دنبال یافتن پوسته محدب با بیشترین حجم است که می‌تواند با استفاده از یک وارونگی غیر خطی ساده به داده ابرطیفی محاط شود. در این روش فرض بر وجود پیکسل‌های خالص در تصویر است؛ به عبارت دیگر فرض بر آن است که حداقل یک پیکسل خالص از هر یک از اجزای خالص در تصویر موجود است و نیازی به تعریف پوسته محدب اولیه وجود ندارد. در این الگوریتم در ابتدا یک پیش‌پردازش صورت می‌پذیرد که در آن برای آنکه حجم پوسته محدب تعیین گردد، ابعاد فضای ویژگی تصویر با استفاده از یکی از روش‌های تصویرسازی زیرفضای متعامد^۲ (OSP) به یک واحد کمتر از تعداد اجزای خالص تصویر کاهش می‌یابد. از جمله این روش‌ها می‌توان به تبدیل MNF اشاره کرد. در ادامه باید حجم پوسته محدب تعیین گردد. بدین منظور ماتریس E به صورت رابطه (۲) تعریف می‌گردد [۳۰].

$$E = \begin{bmatrix} 1 & 1 & \dots & 1 \\ \vec{e}_1 & \vec{e}_2 & \dots & \vec{e}_l \end{bmatrix} \quad \text{رابطه (۲)}$$

در ماتریس رابطه (۲)، e بردار ستونی طیف جز خالص i ام است. حجم پوسته محدب که با اجزای خالص تخمین زده شده تشکیل شده، متناسب با دترمینان ماتریس E است و از طریق رابطه (۳) محاسبه می‌شود.

$$V(E) = \frac{1}{(l-1)!} \text{abs}(|E|) \quad \text{رابطه (۳)}$$

در رابطه (۳)، $(l-1)$ ابعاد فضایی است که داده اشغال می‌کند و منظور از abs ، قدر مطلق دترمینان ماتریس E است. در این روش در ابتدا یک مجموعه تصادفی از پیکسل‌ها به عنوان اجزای خالص در نظر گرفته می‌شوند. سپس برای بهبود تخمین اجزای خالص، هر یک از پیکسل‌های تصویر باید از لحاظ آنکه یک پیکسل خالص یا تقریباً خالص باشد، ارزیابی شوند. بدین منظور حجم پوسته محدب باید با جایگزینی هر پیکسل با هر

زیرفضا دارند. بنابراین، هرگاه ابعاد زیرفضا بیش از حد برآورد گردد، ترم توان نویز بخش عمده را تشکیل می‌دهد و از سویی دیگر، اگر ابعاد زیرفضای کمتر از حد انتظار تخمین زده شود، ترم توان خطای تصویرسازی بخش غالب خواهد بود. بدین منظور بکار بردن متوسط حداقل مربعات خطا^۱ (MSE) به منظور انتخاب زیر مجموعه‌ای از بردارهای ویژگی مناسب، منجر به کمینه‌سازی تابع هدف می‌گردد که دارای دو ترم است. ترم اول، مربوط به توان خطای تصویر شده که نقش کاهش‌دهنده را در ابعاد زیرفضا ایفا می‌کند و ترم دوم مربوط به توان تصویرسازی نویز است، که نقش افزایش‌دهنده ابعاد زیرفضا را برعهده دارد. مطابق رابطه (۱)، هر پیکسل از تصویر ابرطیفی (v) را می‌توان به شکل یک بردار طیفی به شکل زیر فرض نمود:

$$y = x + n \quad \text{رابطه (۱)}$$

در رابطه (۱)، x و n بردارهای L -بعدی اند (L بیانگر تعداد باندها است) که به ترتیب بیانگر سیگنال و نویز جمع‌شونده‌اند. بدین ترتیب این الگوریتم در دو مرحله اصلی تخمین نویز و تخمین زیرفضای سیگنال دنبال می‌شود.

۲-۲- استخراج اجزای خالص تصویر

منظور از اجزای خالص، مشخصه طیفی موادی است که از نظر ماکروسکوپی خالص در نظر گرفته می‌شوند. در نتیجه منظور از استخراج اجزای خالص تصویر، تعیین منحنی امضای طیفی عوارض تشکیل‌دهنده تصویر است. روش‌های استخراج اجزای خالص تصویر را می‌توان به چهار دسته کلی مورفولوژیکی، آماری غیرپارامتریک، آماری پارامتریک و هندسی تقسیم بندی نمود. در این بین استفاده از روش‌های هندسی بسیار مرسوم است.

در این مقاله از روش هندسی N -FINDR برای استخراج اجزای خالص تصویر استفاده شده است [۳۰].

² Simplex

³ Orthogonal Subspace Projection

¹ Mean Square Error

به فضای کاهش‌بعدیافته از روش میانگین وزن‌دار استفاده شده‌است. بدین منظور در ابتدا یک وزن برای هر یک از باندهای تصویر محاسبه شده‌است. برای محاسبه این وزن، که براساس فاصله اقلیدسی هر باند از مرکز خوشه منتسب شده به آن در فضای پدیده است، از رابطه (۵) استفاده شده است.

$$w_i = \frac{1}{D_{b_i, c_i} + 1} \quad \text{رابطه (۵)}$$

در رابطه (۵) منظور از w_i وزن باند i ام تصویر، و منظور از D_{b_i, c_i} فاصله اقلیدسی باند i ام (B_i) و مرکز خوشه‌ای که باند i ام به آن منتسب شده (C_i) در فضای پدیده است. پس از محاسبه وزن هر یک از باندها، از رابطه (۶) (میانگین وزن‌دار) برای محاسبه مقادیر باندهای کاهش‌یافته برای تمامی پیکسل‌های تصویر استفاده شده است.

$$C_i = \frac{\sum_{k=1}^{n_i} w_{B_{k,i}} * B_{k,i}}{\sum_{k=1}^{n_i} w_{B_{k,i}}} \quad \text{رابطه (۶)}$$

در رابطه (۶) منظور از C_i باند استخراج شده از خوشه i ام، n_i تعداد باندهای منتسب شده به خوشه i ام، $B_{k,i}$ باند k ام منتسب به خوشه i ام و $w_{B_{k,i}}$ وزن این باند است. اگر تعداد خوشه‌ها در مرحله خوشه‌بندی را برابر k فرض کنیم، در نهایت k ویژگی طیفی استخراج شده و در نهایت یک تصویر کاهش‌یافته طیفی حاصل می‌گردد.

۲-۶- ارزیابی نتایج

برای بررسی و ارزیابی روش استخراج ویژگی پیشنهادی EPBC، از طبقه‌بندی‌کننده بیشترین شباهت (ML) که استفاده از آن جهت بررسی روش‌های کاهش ویژگی بسیار مرسوم است، استفاده شده است [۳۱]. از مزایای این روش می‌توان به سادگی، سرعت بالا برای فضای ویژگی با ابعاد پایین و عدم نیاز به تنظیم پارامترهای

جزخالص محاسبه گردد. اگر این جایگزینی باعث افزایش حجم پوسته محدب شود، آن پیکسل به جای آن جزخالص قرار خواهد گرفت و این پروسه تا جایی تکرار می‌شود که هیچ جایگزینی برای اجزای خالص صورت نپذیرد. در این صورت نقاط رئوس پوسته‌ی محدب، همان اجزای خالص تصویر خواهند بود. از مزیت‌های این روش می‌توان به سادگی و اجرای سریع آن اشاره نمود.

۲-۳- تشکیل فضای پدیده اجزای خالص تصویر

پس از استخراج طیف اجزای خالص تصویر، لازم است فضای پدیده اجزای خالص تصویر تشکیل شود. همانطور که گفته شد، محورهای این فضا همان اجزای خالص موجود در تصویر بوده و هر یک از باندهای تصویر به عنوان یک نقطه در این فضا حضور دارند. چنانچه تعداد اجزای خالص تصویر (بعد مجازی) را برابر n فرض کنیم، یک فضای پدیده n بعدی تشکیل می‌شود که هر باند از تصویر را می‌توان به شکل یک نقطه در این فضای n بعدی به فرم رابطه (۴) در نظر گرفت:

$$B_i = [m_{i,1} \quad m_{i,2} \quad \dots \quad m_{i,n}] \quad \text{رابطه (۴)}$$

در رابطه (۴)، B_i بیانگر باند i ام تصویر و $m_{i,j}$ بیانگر مقدار بازتاب طیفی جز خالص n ام در باند i ام تصویر است.

۲-۴- خوشه‌بندی باندها

پس از تشکیل فضای پدیده، باندها در این فضا با استفاده از روش K -means خوشه‌بندی می‌گردند. به منظور تعیین تعداد بهینه خوشه‌ها، می‌توان تعداد آن را برابر بعد مجازی تصویر در نظر گرفت. در این تحقیق برای بررسی بیشتر، تعداد خوشه‌ها از یک دوم مقدار بعد مجازی تا مقدار بعد مجازی تنظیم شده و مورد بررسی قرار گرفته است.

۲-۵- استخراج ویژگی‌های کاهش یافته طیفی

پس از خوشه‌بندی باندها و تعیین مرکز هر از یک خوشه‌ها، برای انتقال فضای تمامی پیکسل‌های تصویر

¹ Maximum Likelihood

۳-۱- تصویر کاج‌های هندی

این تصویر ابرطیفی در سال ۱۹۹۲ بوسیله سنجنده مرئی/مادون قرمز هوایی (AVIRIS) از پایگاه آزمایشی به مساحت تقریبی ۴ مایل مربع، واقع در شمال غربی ایالت ایندیانا و در ۲۲۴ باندطیفی در بازه‌ی طول موج ۴۰۰ تا ۲۵۰۰ نانومتر اخذ شده است. این تصویر دارای ابعاد ۱۴۵*۱۴۵ پیکسل و پیکسل سایز ۲۰ متری است. دو سوم سطح پوشش این تصویر، زمین‌های کشاورزی و یک سوم باقیمانده جنگل و سایر گیاهان طبیعی است. تعداد باندهای این تصویر پس از حذف باندهای جذبی آب به ۲۰۰ باند می‌رسد. همچنین برای عوارض موجود در این تصویر ۱۶ کلاس در نظر گرفته شده است. شکل (۲) یک ترکیب رنگی کاذب و نمونه‌های واقعی زمینی داده ابر طیفی کاج‌های هندی را نشان می‌دهد.

۳-۲- تصویر دانشگاه پاویا

این تصویر توسط سنجنده تصویربرداری سیستم اپتیک بازتابی (ROSIS) از دانشگاه پاویا در شمال کشور ایتالیا توسط آژانس فضایی ملی آلمان اخذ شده است. این مجموعه داده بطور کلی در ۱۱۵ باند طیفی اخذ شده بود، که ۱۲ باند آن به عنوان باندهای نویزی از این داده حذف گردیدند. بنابراین، در نهایت این تصویر دارای ۱۰۳ باند طیفی و ابعاد ۶۱۰*۳۴۰ پیکسل و پیکسل سایز ۱/۳ متری است. همچنین برای عوارض موجود در این تصویر ۹ کلاس در نظر گرفته شده است. شکل (۳) یک ترکیب رنگی کاذب به همراه نمونه‌های واقعی زمینی از این تصویر را نشان می‌دهد.

اولیه اشاره نمود. همچنین به منظور ارزیابی نتایج طبقه‌بندی از معیارهای دقت کلی^۱ و ضریب کاپا^۲ که از ماتریس ابهام^۳ استخراج می‌گردند، استفاده شده است. منظور از دقت کلی طبقه‌بندی نسبت تعداد نمونه‌های آزمایشی درست طبقه‌بندی شده به تعداد کل نمونه‌های آزمایشی است. این معیار بیانگر دقت طبقه‌بندی در کل تصویر است. ضریب کاپا معیاری از تطابق یا دقت بین نقشه طبقه‌بندی شده و داده‌های مرجع است. این معیار بیانگر کاهش خطای نسبی ایجادشده بوسیله طبقه‌بندی انجام شده در مقایسه با یک طبقه‌بندی کاملاً تصادفی است. رابطه (۷) نحوه‌ی محاسبه ضریب کاپا را بیان کرده است [۳۲].

رابطه (۷)

$$K = \frac{(M * \sum_{i=j=1}^r n_{i,j}) - (\sum_{i=j=1}^r n_i n_j)}{M^2 - \sum_{i=j=1}^r n_i n_j}$$

در رابطه (۷)، r تعداد سطرهای ماتریس ابهام، $n_{i,j}$ تعداد پیکسل‌های موجود در سطر i و ستون j ماتریس ابهام، n_i مجموع پیکسل‌های واقع در سطر i ام ماتریس ابهام، n_j مجموع پیکسل‌های واقع در ستون j ام ماتریس ابهام و M برابر با تعداد کل پیکسل‌های ماتریس ابهام است.

۳- داده‌های مورد استفاده

به منظور بررسی و ارزیابی کیفیت فضای ویژگی کاهش‌یافته طیفی تولیدشده با روش EPBC، به طبقه‌بندی دو تصویر ابرطیفی کاج‌های هندی^۴ و دانشگاه پاویا^۵ با این فضای ویژگی اقدام شده است. در ادامه در مورد این دو تصویر توضیحات مختصری ارائه شده است.

¹ Overall Accuracy

² Kappa Coefficient


³ Confusion Matrix

⁴ Indian Pines

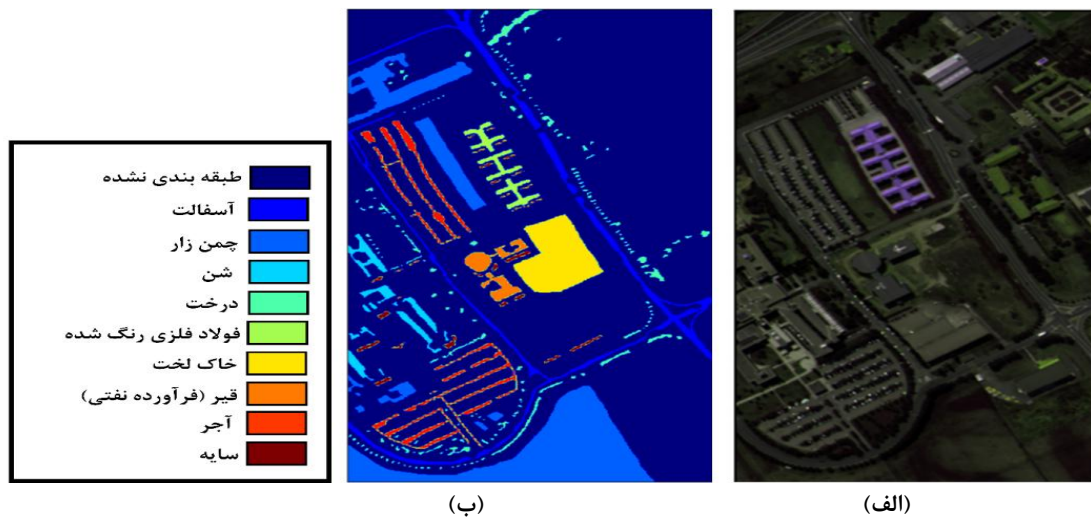
⁵ Pavia University

⁶ Airborne Visible/Infrared Imaging Spectrometer

⁷ Reflective Optics System Imaging Spectrometer



شکل ۲: تصویر ابر طیفی کاج‌های هندی (الف) ترکیب رنگی کاذب و (ب) نمونه‌های واقعیت زمینی



شکل ۳: تصویر ابر طیفی دانشگاه پابوا (الف) ترکیب رنگی کاذب و (ب) نمونه‌های واقعیت زمینی

۴- ارائه نتایج و بحث

برای ارزیابی روش پیشنهادی، این روش با چهار روش کاهش ویژگی مرسوم مقایسه شده است. این چهار روش شامل PCA ، MNF و ICA به عنوان روش‌های بدون نظارت و LDA به عنوان روش نظارت شده، می‌باشد. داده‌های آموزشی و آزمایشی برای تمامی روش‌ها یکسان در نظر گرفته شده است. تعداد حالات در نظر گرفته شده برای نمونه‌های آزمایشی دو تصویر مورد


استفاده، در جدول (۱) آمده است. لازم به ذکر است که کلیه داده‌های آموزشی به صورت کاملاً تصادفی انتخاب شده اند و منظور از درصد نمونه‌های آموزشی، درصد نمونه‌های آزمایشی برای هر کلاس است. برای مثال اگر درصد نمونه‌های آموزشی را ۱۰ فرض کنیم، منظور این است که ۱۰ درصد از کل داده‌های حقیقت زمینی هر کلاس به عنوان نمونه‌های آموزشی آن کلاس در نظر گرفته شده است.

جدول ۱: تعداد حالات در نظر گرفته شده برای نمونه‌های آزمایشی تصاویر مورد استفاده


تعداد نمونه‌های آزمایشی	تعداد نمونه‌های آموزشی	درصد نمونه‌های آموزشی	تعداد داده‌های حقیقت زمینی	تصویر
۹۲۴۰	۱۰۰۹	۱۰	۱۰۲۴۹	کاج‌های هندی
۸۲۳۱	۲۰۱۸	۲۰		
۴۱۷۱۱	۱۰۶۵	۲٫۵	۴۲۷۷۶	دانشگاه پاویا
۳۸۵۰۳	۴۲۷۳	۱۰		

پیشنهادی، ویژگی‌های استخراج شده در اجرای دفعات مختلف این روش یکتا نیستند، کلیه نتایج ارائه شده از روش EPBC میانگین ۱۰ بار اجرای این روش هستند. شکل (۴) نمودار دقت کلی طبقه بندی برای تصویر کاج‌های هندی را برای دو مجموعه داده‌های آموزشی (۱۰٪ و ۲۰٪ نمونه‌های واقعییت زمینی) برای تعداد ویژگی‌های استخراج شده (از ۷ تا ۱۵ ویژگی) نشان می‌دهد. بطور مشابه شکل (۵) نمودار دقت کلی طبقه بندی برای تصویر دانشگاه پاویا را برای دو مجموعه نمونه‌های آموزشی، در تعداد ویژگی‌های ۵ تا ۱۰ برای روش‌های ارائه شده نشان می‌دهد.

روش پیشنهادی شامل دو پارامتر تنظیمی است. پارامتر اول نوع نویز در تخمین نویز مورد نیاز برای برآورد بعد مجازی تصویر به روش HySime است که در این مقاله نوع نویز برای هر دو تصویر، نویز جمع شونده (Additive)، در نظر گرفته شده است. خروجی مرحله تخمین بعد مجازی برای تصویر کاج‌های هندی برابر ۱۵ و برای تصویر دانشگاه پاویا برابر ۱۰ بوده است که تا حد زیادی با تعداد کلاس‌های واقعی موجود در این دو تصویر همخوان است. پارامتر دوم، تعداد خوشه‌ها یا همان تعداد باندهایی است که در نهایت استخراج می‌شوند. لازم به ذکر است از آنجا که به دلیل وجود مرحله خوشه‌بندی به روش K-means در روش




(ب)



(الف)

شکل ۴: نمودار دقت کلی طبقه بندی برای تصویر کاج‌های هندی، الف: ۱۰٪ نمونه آموزشی، ب: ۲۰٪ نمونه آموزشی



شکل ۵: نمودار دقت کلی طبقه‌بندی برای تصویر دانشگاه پابویا، الف: ۲۰٪ نمونه آموزشی، ب: ۱۰٪ نمونه آموزشی

تصاویر طبقه‌بندی شده کاج‌های هندی و دانشگاه پابویا با فضای ویژگی روش EPBC در بهترین دقت‌ها در دو حالت مختلف نمونه‌های آموزشی در کنار تصویر داده‌های حقیقت زمینی این تصاویر به ترتیب در شکل‌های (۶) و (۷) نشان داده شده است.


همچنین بهترین نتایج طبقه‌بندی با هر یک از روش‌های EPBC، PCA، MNF، ICA و LDA برای دو تصویر مورد استفاده در دو حالت در نظر گرفته شده برای نمونه‌های آموزشی، به ترتیب در جداول (۲) و (۳) آورده شده است.

جدول ۲: بهترین نتایج طبقه‌بندی تصویر کاج‌های هندی


EPBC	PCA	MNF	ICA	LDA	معیار ارزیابی	درصد نمونه آموزشی هر کلاس
۷۴٫۵۴	۵۹٫۸۵	۷۲٫۲۶	۵۹٫۳۶	۶۹٫۳۹	دقت کلی	۱۰٪
۰٫۷۱۲	۰٫۵۴۸	۰٫۶۸۲	۰٫۵۴۳	۰٫۶۵۴	ضریب کاپا	
۹	۱۲	۱۰	۱۲	۱۵	تعداد ویژگی استخراج شده	
۷۵٫۶۶	۶۲٫۷	۷۲٫۷۵	۶۳٫۶۰	۷۴٫۸۶	دقت کلی	۲۰٪
۰٫۷۲۱	۰٫۵۷۲	۰٫۶۸۵	۰٫۵۸۴	۰٫۷۱۲	ضریب کاپا	
۱۳	۱۰	۱۲	۱۴	۱۱	تعداد ویژگی استخراج شده	

جدول ۳: بهترین نتایج طبقه بندی تصویر دانشگاه پاویا

EPBC	PCA	MNF	ICA	LDA	معیار ارزیابی	درصد نمونه آموزشی هر کلاس
۸۶٫۶۵	۸۳٫۳۴	۸۱٫۱۱	۸۳٫۳۴	۸۲٫۹۶	دقت کلی	۲٫۵٪
۰٫۸۲۷	۰٫۷۸۶	۰٫۷۵۸	۰٫۷۸۶	۰٫۷۸۱	ضریب کاپا	
۱۰	۱۰	۱۰	۱۰	۸	تعداد ویژگی استخراج شده	
۸۹٫۷۱	۸۷٫۳۷	۸۵٫۷۴	۸۷٫۳۷	۸۶٫۷۷	دقت کلی	۱۰٪
۰٫۸۶۵	۰٫۸۳۵	۰٫۸۱۴	۰٫۸۳۵	۰٫۸۲۸	ضریب کاپا	
۱۰	۱۰	۱۰	۱۰	۸	تعداد ویژگی استخراج شده	



شکل ۶: (الف) داده‌های واقعیت زمینی، تصاویر طبقه بندی شده کاج‌های هندی با فضای ویژگی روش EPBC در بهترین دقت‌ها برای حالت‌های، (ب) ۲۰٪ نمونه‌های آموزشی با ۱۳ باند استخراج شده و (ج) ۱۰٪ نمونه‌های آموزشی با ۹ باند استخراج شده



شکل ۷: (الف) داده‌های واقعیت زمینی، تصاویر طبقه بندی شده دانشگاه پاویا با فضای ویژگی روش EPBC در بهترین دقت‌ها برای حالت‌های، (ب) ۱۰٪ نمونه‌های آموزشی با ۱۰ باند استخراج شده و (ج) ۲٫۵٪ نمونه‌های آموزشی با ۱۰ باند استخراج شده

آنجایی که طبقه‌بندی بیشترین شباهت با ویژگی‌های استخراج شده به روش *EPBC* نتایج خوبی به همراه داشته است، توزیع آماری این ویژگی‌های به توزیع نرمال نزدیک بوده است.

روش‌های استخراج ویژگی *PCA*، *MNF*، *ICA* و *LDA* معمولاً به عنوان یک پیش پردازش به منظور کاهش ابعاد فضای ویژگی اولیه تصاویر ابرطیفی مورد استفاده می‌گیرند و به ندرت فضای ویژگی کاهش یافته مستخرج از این روش‌ها مستقیماً برای طبقه‌بندی بکار گرفته می‌شود. در اینجا نیز اگرچه نتایج دقت طبقه‌بندی با فضای ویژگی استخراج شده به روش *EPBC* به منظور طبقه‌بندی تصویر با طبقه‌بندی کننده بیشترین شباهت کافی نیست، اما این روش توانسته است فضای ویژگی کاهش یافته ای استخراج کند که نسبت به چهار روش نامبرده از کیفیت بالاتری برخوردار است. بدین ترتیب می‌توان از فضای ویژگی استخراج شده به روش *EPBC* به عنوان یک ورودی برای پردازش‌های بعدی همچون استخراج ویژگی‌های مکانی از تصاویر ابرطیفی استفاده نمود و انتظار می‌رود خروجی این پردازش‌ها نیز از کیفیت بالاتری نسبت به خروجی اعمال همان پردازش‌ها بر روی فضای ویژگی مستخرج از روش‌های نامبرده برخوردار باشد.

برای بررسی جزئی‌تر روش ارائه شده، زمان مورد نیاز اجرای روش پیشنهادی نسبت به سایر روش‌ها مورد ارزیابی قرار گرفت. کلیه روش‌ها در محیط برنامه نویسی پایتون و در پلتفرم گوگل کولب^۱ اجرا شده‌اند. زمان مورد نیاز اجرای هر یک از روش‌ها برای تصویر کاج‌های هندی و به منظور استخراج ۱۵ ویژگی طیفی در جدول (۴) بیان شده است.

نتایج جدول (۲) نشان می‌دهد، که در تصویر کاج‌های هندی استخراج ویژگی به روش *EPBC* توانسته در هر دو حالت مختلف تعداد نمونه‌های آموزشی، نسبت سایر روش‌ها دقت کلی و ضریب کاپای بالاتری را در طبقه‌بندی به روش بیشترین شباهت به دست دهد. همچنین با توجه به نمودارهای شکل (۴)، در تصویر کاج‌های هندی استخراج ویژگی به روش *EPBC* برای هر دو مجموعه داده‌ی آموزشی و به ازای تعداد مختلف ویژگی‌های استخراج شده، در بسیاری از حالات بهترین عملکرد را نشان داده است. همانطور که در شکل (۴) مشاهده می‌شود، جدی‌ترین رقیب روش *EPBC* در طبقه‌بندی تصویر کاج‌های هندی روش نظارت شده *LDA* بوده است. با این حال روش بدون نظارت *EPBC* در اغلب حالات، بخصوص در تعداد نمونه‌های آموزشی خیلی کم توانسته دقت کلی طبقه‌بندی بالاتری را در مقایسه با روش *LDA* داشته‌باشد، این امر بیانگر آن است که در صورتی که تعداد نمونه‌های آموزشی بسیار کم باشد، لزوماً روش‌های کاهش ویژگی نظارت شده نسبت به روش‌های بدون نظارت برتری ندارند. همچنین با بررسی نتایج جدول (۳) می‌توان بیان کرد که در طبقه‌بندی تصویر دانشگاه پالویا استخراج ویژگی به روش *EPBC* توانسته برای هر دو مجموعه داده نمونه‌های آموزشی، نسبت به سایر روش‌ها دقت کلی و ضریب کاپای بالاتری را در طبقه‌بندی به روش بیشترین شباهت برآورد نماید. از سویی دیگر، با توجه به نمودارهای شکل (۵)، در تصویر دانشگاه پالویا استخراج ویژگی به روش *EPBC* توانسته در هر دو حالت مختلف تعداد نمونه‌های آموزشی عملکرد بهتری را نسبت به سایر روش‌ها ارائه دهد. بدین ترتیب، می‌توان از اصلی‌ترین مزایای روش پیشنهادی این مطالعه به انطباق و تکیه آن بر عناصر ذاتی تصاویر ابرطیفی، یعنی اجزای خالص، اشاره نمود. همچنین دیگر مزیت استخراج ویژگی به روش *EPBC* این است، که این ویژگی‌ها تغییر ماهیت نمی‌دهند و همچنان دارای تفسیر فیزیکی هستند. همچنین می‌توان گفت از

¹ Google Colab

جدول ۴: زمان پردازش مورد نیاز برای استخراج ۱۵ ویژگی از تصویر کاج‌های هندی در هر روش بر حسب ثانیه

روش	LDA	ICA	MNF	PCA	EPBC
زمان اجرا (ثانیه)	۰٫۵	۲٫۶	۱٫۰	۱٫۰	۲٫۸

۵- نتیجه‌گیری و پیشنهادات

در این مقاله روش EPBC که یک روش بدون نظارت استخراج ویژگی از تصاویر ابرطیفی مبتنی بر خوشه‌بندی باندها در فضای پدیده اجزای خالص است، ارائه شد. در این روش پس از تخمین بعدمجازی تصویر به روش HySime، استخراج اجزای خالص تصویر به روش N-FINDR صورت می‌پذیرد. سپس فضای پدیده اجزای خالص تشکیل شده و باندها در این فضا به روش K-Means خوشه‌بندی می‌گردند. در نهایت با استفاده از میانگین وزن دار، از هر خوشه یک ویژگی استخراج می‌شود. در طبقه‌بندی داده کاج‌های هندی با ویژگی‌های استخراج شده به روش EPBC با طبقه‌بندی کننده بیشترین شباهت در بهترین حالت دقت کلی ۷۵٫۶۶ درصد حاصل شد که این دقت به ترتیب نسبت به روش‌های بدون نظارت PCA، MNF و ICA، ۱۲٫۹۶٪، ۲٫۹۱٪ و ۱۲٫۰۶٪ و نسبت به روش نظارت‌شده LDA، ۰٫۸۰٪ بالاتر بوده است. همچنین در طبقه‌بندی داده دانشگاه پاویا با ویژگی‌های استخراج شده به روش EPBC با طبقه‌بندی کننده بیشترین شباهت دقت کلی ۸۹٫۷۱ درصد حاصل شد که این دقت به ترتیب نسبت

به روش‌های بدون نظارت PCA، MNF و ICA، ۲٫۳۴٪، ۳٫۹۷٪ و ۲٫۳۴٪ و نسبت به روش نظارت‌شده LDA، ۲٫۹۴٪ بالاتر بوده است. بدین ترتیب نتایج بدست آمده، برتری این روش را در استخراج ویژگی‌های طیفی نسبت به چهار روش PCA، MNF، ICA و LDA نشان می‌دهد.

از مزیت‌های روش پیشنهادی EPBC می‌توان به سادگی، سرعت مناسب و انطباق و تکیه‌ی آن بر اجزای خالص تصاویر ابرطیفی، که از مهمترین تفاسیر فیزیکی این تصاویر به حساب می‌آیند، اشاره نمود. از معایب این روش نیز می‌توان به چند مرحله‌ای بودن فرآیند آن و یکتا نبودن نتایج آن در دفعات مختلف اجرای آن اشاره نمود.

به عنوان پیشنهاد برای تحقیقات آتی می‌توان به استفاده از سایر روش‌های تخمین بعد مجازی و روش‌های پیشرفته‌تر استخراج اجزای خالص و همچنین استفاده از روش‌های پیشرفته‌تر خوشه‌بندی مانند DBSCAN و K-medoids و بکارگیری روش پیشنهادی در دیگر تصاویر ابرطیفی با پوشش و حد تفکیک مکانی متفاوت اشاره کرد.

مراجع

- [1] B. B. Damodaran and R. R. Nidamanuri, "Dynamic Linear Classifier System for Hyperspectral Image Classification for Land Cover Mapping," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 7, no. 6, pp. 2080–2093, Jun. 2014, doi: 10.1109/JSTARS.2013.2294857.
- [2] R. Aghaee and M. Mokhtarzade, "Classification of Hyperspectral Images Using Subspace Projection Feature Space," *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 9, pp. 1803–1807, Sep. 2015, doi: 10.1109/LGRS.2015.2424911.
- [3] Y. Wei et al., "Applications of Hyperspectral Remote Sensing in Ground Object Identification and Classification," *Advances in Remote Sensing*, vol. 06, no. 03, pp. 201–211, 2017, doi: 10.4236/ars.2017.63015.
- [4] S. B. Serpico and G. Moser, "Extraction of Spectral Channels From Hyperspectral Images for Classification Purposes," *IEEE*

- Transactions on Geoscience and Remote Sensing*, vol. 45, no. 2, pp. 484–495, Feb. 2007, doi: 10.1109/TGRS.2006.886177.
- [5] A. Paul and N. Chaki, “Dimensionality Reduction Using Band Correlation and Variance Measure from Discrete Wavelet Transformed Hyperspectral Imagery,” *Annals of Data Science*, vol. 8, no. 2, pp. 261–274, Jun. 2021, doi: 10.1007/s40745-019-00210-x.
- [6] G. Hughes, “On the mean accuracy of statistical pattern recognizers,” *IEEE Trans Inf Theory*, vol. 14, no. 1, pp. 55–63, Jan. 1968, doi: 10.1109/TIT.1968.1054102.
- [7] Y. Zhong and L. Zhang, “An Adaptive Artificial Immune Network for Supervised Classification of Multi-/Hyperspectral Remote Sensing Imagery,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, no. 3, pp. 894–909, Mar. 2012, doi: 10.1109/TGRS.2011.2162589.
- [8] X. Jia, B.-C. Kuo, and M. M. Crawford, “Feature Mining for Hyperspectral Image Classification,” *Proceedings of the IEEE*, vol. 101, no. 3, pp. 676–697, Mar. 2013, doi: 10.1109/JPROC.2012.2229082.
- [9] S. Li, Z. Zheng, Y. Wang, C. Chang, and Y. Yu, “A new hyperspectral band selection and classification framework based on combining multiple classifiers,” *Pattern Recognit Lett*, vol. 83, pp. 152–159, Nov. 2016, doi: 10.1016/j.patrec.2016.05.013.
- [10] S. A. Hosseini and H. Ghassemian, “Rational function approximation for feature reduction in hyperspectral data,” *Remote Sensing Letters*, vol. 7, no. 2, pp. 101–110, Feb. 2016, doi: 10.1080/2150704X.2015.1101180.
- [11] *Introduction to Statistical Pattern Recognition*. Elsevier, 1990. doi: 10.1016/C2009-0-27872-X.
- [12] H. Yang, Q. Du, H. Su, and Y. Sheng, “An Efficient Method for Supervised Hyperspectral Band Selection,” *IEEE Geoscience and Remote Sensing Letters*, vol. 8, no. 1, pp. 138–142, Jan. 2011, doi: 10.1109/LGRS.2010.2053516.
- [13] A. A. Green, M. Berman, P. Switzer, and M. D. Craig, “A transformation for ordering multispectral data in terms of image quality with implications for noise removal,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 26, no. 1, pp. 65–74, 1988, doi: 10.1109/36.3001.
- [14] S. H. Alizadeh Moghaddam, M. Mokhtarzade, and B. A. Beirami, “A feature extraction method based on spectral segmentation and integration of hyperspectral images,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 89, p. 102097, Jul. 2020, doi: 10.1016/j.jag.2020.102097.
- [15] G. Baudat and F. Anouar, “Generalized Discriminant Analysis Using a Kernel Approach,” *Neural Comput*, vol. 12, no. 10, pp. 2385–2404, Oct. 2000, doi: 10.1162/089976600300014980.
- [16] Bor-Chen Kuo and D. A. Landgrebe, “Nonparametric weighted feature extraction for classification,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 5, pp. 1096–1105, May 2004, doi: 10.1109/TGRS.2004.825578.
- [17] C. Lee and D. A. Landgrebe, “Feature extraction based on decision boundaries,” *IEEE Trans Pattern Anal Mach Intell*, vol. 15, no. 4, pp. 388–400, Apr. 1993, doi: 10.1109/34.206958.
- [18] J. A. Richards, *Remote Sensing Digital Image Analysis*. Cham: Springer International Publishing, 2022. doi: 10.1007/978-3-030-82327-6.
- [19] M. Imani and H. Ghassemian, “Band Clustering-Based Feature Extraction for Classification of Hyperspectral Images Using Limited Training Samples,” *IEEE Geoscience and Remote Sensing Letters*, vol. 11, no. 8, pp. 1325–1329, Aug. 2014, doi: 10.1109/LGRS.2013.2292892.
- [20] Bor-Chen Kuo, Cheng-Hsuan Li, and Jinn-Min Yang, “Kernel Nonparametric

- Weighted Feature Extraction for Hyperspectral Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 4, pp. 1139–1155, Apr. 2009, doi: 10.1109/TGRS.2008.2008308.
- [21] A. Paul and N. Chaki, "Band selection using spectral and spatial information in particle swarm optimization for hyperspectral image classification," *Soft comput.*, vol. 26, no. 6, pp. 2819–2834, Mar. 2022, doi: 10.1007/s00500-022-06821-6.
- [22] B. Asghari Beirami and M. Mokhtarzade, "Band Grouping SuperPCA for Feature Extraction and Extended Morphological Profile Production From Hyperspectral Images," *IEEE Geoscience and Remote Sensing Letters*, vol. 17, no. 11, pp. 1953–1957, Nov. 2020, doi: 10.1109/LGRS.2019.2958833.
- [23] N. Wambugu et al., "Hyperspectral image classification on insufficient-sample and feature learning using deep neural networks: A review," *International Journal of Applied Earth Observation and Geoinformation*, vol. 105, p. 102603, Dec. 2021, doi: 10.1016/j.jag.2021.102603.
- [24] B. Mojaradi, H. Abrishami-Moghaddam, M. J. V. Zoej, and R. P. W. Duin, "Dimensionality Reduction of Hyperspectral Data via Spectral Feature Extraction," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 7, pp. 2091–2105, Jul. 2009, doi: 10.1109/TGRS.2008.2010346.
- [25] A. Ghorbanian and A. Mohammadzadeh, "An unsupervised feature extraction method based on band correlation clustering for hyperspectral image classification using limited training samples," *Remote Sensing Letters*, vol. 9, no. 10, pp. 982–991, Oct. 2018, doi: 10.1080/2150704X.2018.1500723.
- [26] B. Beirami and M. Mokhtarzade, "An Automatic Method for Unsupervised Feature Selection of Hyperspectral Images Based on Fuzzy Clustering of Bands," *Traitement du Signal*, vol. 37, no. 2, pp. 319–324, Apr. 2020, doi: 10.18280/ts.370218.
- [27] A. Ghorbanian, Y. Maghsoudi, and A. Mohammadzadeh, "Clustering-Based Band Selection Using Structural Similarity Index and Entropy for Hyperspectral Image Classification," *Traitement du Signal*, vol. 37, no. 5, pp. 785–791, Nov. 2020, doi: 10.18280/ts.370510.
- [28] J. C. Harsanyi, W. H. Farrand, and C.-I. Chang, "Determining the number and identity of spectral endmembers: an integrated approach using Neyman-Pearson eigen-thresholding and iterative constrained RMS error minimization," in *Proceedings of the Thematic Conference on Geologic Remote Sensing*, 1993, p. 395.
- [29] J. M. P Nascimento and J. M. Bioucas-Dias, "Hyperspectral signal subspace estimation," in *2007 IEEE International Geoscience and Remote Sensing Symposium, IEEE*, 2007, pp. 3225–3228. doi: 10.1109/IGARSS.2007.4423531.
- [30] M. E. Winter, "N-FINDR: An algorithm for fast autonomous spectral end-member determination in hyperspectral data," in *Imaging Spectrometry V*, 1999, pp. 266–275.
- [31] R. O. Duda, P. E. Hart, and others, *Pattern classification*. John Wiley & Sons, 2006.
- [32] D. Chicco, M. J. Warrens, and G. Jurman, "The Matthews Correlation Coefficient (MCC) is More Informative Than Cohen's Kappa and Brier Score in Binary Classification Assessment," *IEEE Access*, vol. 9, pp. 78368–78381, 2021, doi: 10.1109/ACCESS.2021.3084050.



Proposing an Unsupervised Method for Extracting Reduced Spectral Features from Hyperspectral Images based on Band Clustering in Endmember Prototype Space

Sayyed Ahmad Alizadeh Moghaddam ^{1*}, Mehdi Mokhtarzadeh ²

1- MSc of Remote Sensing, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology
2- Associate professor, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

Abstract

Hyperspectral images are a rich source of remote sensing data that are used in various studies, including agriculture, land cover/land use management and classification. However, the high dimensionality of feature space and limited number of training samples are among the main challenges in classifying these images and extracting information from them. Therefore, the use of feature reduction methods in two forms of feature selection and feature extraction is of great importance. Feature reduction methods are divided into two categories: supervised and unsupervised, that the unsupervised ones are more practical as they do not need any training data. In this study, an unsupervised method based on band clustering in endmember prototype space (EPBC) is presented. In this method, after estimating the virtual dimensionality of the image and extracting the endmembers, the endmember prototype space is formed and the bands are clustered using K-means clustering method in. Finally, the weighted mean of each cluster is extracted as a new feature. The final results obtained from classifying two hyperspectral images showed that the best overall accuracy of classification using the maximum likelihood classifier with features extracted by EPBC was %75.66 for the Indian Pines image and %89.71 for the Pavia University image, which outperformed well known unsupervised methods such as principal component analysis (PCA), minimum noise fraction (MNF), independent component analysis (ICA) and supervised method linear discriminant analysis (LDA).

Key words: Hyperspectral Image, Prototype Space, Feature Extraction, Endmembers, Clustering, Classification.