

طبقه‌بندی تصاویر ابرطیفی با استفاده از شبکه نمایش محلی ماتریس کرنل وزن دار و طبقه‌بندی کننده ماشین بردار پشتیبان

بهنام اصغری بیرامی^{۱*}، مهدی مختارزاده^۲

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

تاریخ دریافت مقاله: ۱۴۰۰/۰۷/۲۸ تاریخ پذیرش مقاله: ۱۴۰۱/۰۲/۱۱

چکیده

در سال‌های اخیر مدل‌های مبتنی بر یادگیری عمیق به منظور طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی بسیار مورد توجه قرار گرفته‌اند. یکی از مهم‌ترین ویژگی‌های روش‌های عمیق در نظر گرفتن همزمان اطلاعات مکانی و طیفی در فرایند طبقه‌بندی تصاویر ابرطیفی است. این مدل‌ها علی‌رغم تولید نقشه‌های طبقه‌بندی شده با دقت‌های بالا، از نظر محاسباتی بسیار پیچیده هستند و تنظیم دقیق پارامترهای آن‌ها نیازمند تعداد زیادی نمونه آموزشی است. برای حل این مشکلات، نیاز به ارائه روشی با ساختار ساده‌تر که بتواند به طور مؤثری اطلاعات طیفی-مکانی موجود در تصویر ابرطیفی را استخراج کند، احساس می‌شود. در این راستا، در تحقیق حاضر روش جدیدی به منظور تولید ویژگی طیفی-مکانی از تصاویر ابرطیفی توسعه داده شده است. در روش ارائه شده از دو تکنیک نمایش محلی ماتریس کرنل وزن دار و تبدیل کسر نويز کمینه به صورت پشت سر هم و تکراری به منظور تولید ویژگی‌های طیفی-مکانی عمیق استفاده می‌شود. ویژگی‌های طیفی-مکانی تولید شده از شبکه پیشنهادی که بیانگر رابطه غیرخطی محلی میان ویژگی‌های استخراج شده از مؤلفه‌های تبدیل کسر نويز کمینه در عمق‌های مختلف است، در نهایت به یکدیگر الحاق شده و سپس به منظور طبقه‌بندی به الگوریتم ماشین بردار پشتیبان داده می‌شود. الگوریتم پیشنهادی بر روی دو تصویر ابرطیفی ایندین پابن و دانشگاه پابن پیاده‌سازی شده است. عملکرد روش پیشنهادی این مقاله با روش طبقه‌بندی طیفی و چهار روش طبقه‌بندی طیفی-مکانی دیگر که در سال‌های اخیر پیشنهاد شده‌اند، مقایسه شده است. مقایسه‌های صورت گرفته نشان می‌دهد که در تصویر ایندین پابن دقت روش پیشنهادی بیش از ۲۰٪ و دانشگاه پابن بیش از ۱۰٪ بهتر از دقت طبقه‌بندی تصویر با ویژگی‌های طیفی است. همچنین در مقایسه با چهار روش دیگر طبقه‌بندی طیفی-مکانی، دقت روش پیشنهادی به طور متوسط ۱٪ بهتر است.

کلیدواژه‌ها: نمایش محلی ماتریس کرنل وزن دار، طبقه‌بندی، ابرطیفی، تولید ویژگی.

* نویسنده مکاتبه کننده: تهران، خیابان ولی عصر، تقاطع میرداماد، دانشکده مهندسی نقشه‌برداری دانشگاه صنعتی خواجه نصیرالدین طوسی.

تلفن: ۰۲۱-۸۸۸۷۷۰۷۱

۱- مقدمه

استفاده از تصاویر ماهواره‌ای در سال‌های اخیر به منظور پایش پدیده‌های زمینی بسیار رایج شده است. سنجنده‌های ابرطیفی با اخذ باندهای باریک و متعدد از طیف الکترومغناطیسی توانایی شناسایی و تفکیک دقیق‌تر پدیده‌ها و کلاس‌های زمینی را فراهم می‌کند. از تصاویر ابرطیفی در حوزه‌های فراوانی استفاده می‌شود که یکی از مهم‌ترین آنها طبقه‌بندی پوشش‌های زمینی است. به طور سنتی به منظور طبقه‌بندی تصاویر ابرطیفی تنها از ویژگی‌های طیفی استفاده می‌شود، اما تحقیقات پیشین نشان داده است که استفاده از ویژگی‌های طیفی به تنهایی منجر به تولید نقشه‌های طبقه‌بندی شده با دقت بالا نمی‌شود. به عنوان یک راه‌حل برای افزایش دقت طبقه‌بندی، استفاده از ویژگی‌های مکانی و بافت تصویر نیز در کنار ویژگی‌های طیفی در پیشینه تحقیق پیشنهاد شده است [۱]. تاکنون روش‌های مختلفی به منظور استخراج ویژگی‌های مکانی پیشنهاد شده که هر کدام از منظری اطلاعات مکانی را مدل‌سازی می‌کنند. از مهم‌ترین آن‌ها می‌توان به پروفایل‌های مورفولوژی، ویژگی‌های مستخرج از ماتریس هم‌رخداد، بانک فیلتر گابور، ویژگی‌های موجک، روش الگوی باینری محلی (LBP) و ویژگی‌های فرکتالی اشاره کرد [۲ و ۳]. روش‌های ذکر شده اگرچه که از نظر زمان و دقت عملکرد مناسبی دارند اما عمدتاً نیازمند تنظیم دقیق پارامترهای مختلفی هستند. همچنین از سوی دیگر کاربر با توجه به منطقه می‌بایست در مورد مؤثر بودن هر یک از روش‌های تولید ویژگی مکانی تصمیم بگیرد. به عبارت دیگر یک ویژگی که در یک منطقه توانسته است دقت طبقه‌بندی بالایی را تولید کند امکان دارد در یک منطقه دیگر از آن عملکرد مناسب برخوردار نباشد. به منظور حل این چالش‌ها، در سال‌های اخیر محققین

از روش‌های یادگیری عمیق به منظور طبقه‌بندی تصاویر ابرطیفی استفاده کرده‌اند. یکپارچه‌سازی فاز تولید ویژگی و طبقه‌بندی از مهم‌ترین مزیت‌های روش‌های یادگیری عمیق نسبت به روش‌های سنتی است [۴]. به بیان دیگر روش‌های یادگیری عمیق مانند شبکه‌های کانولوشنی،^۴ این توانایی را دارند که ویژگی‌های طیفی-مکانی مناسب را به صورت خودکار تولید کنند. بر مبنای پیشینه تحقیق به طور کلی سه نوع شبکه‌های عصبی عمیق با نام‌های اتوانکدر الحاقی شده،^۵ شبکه‌های باور عمیق،^۵ و شبکه‌های کانولوشنی بیشترین کاربردها را در طبقه‌بندی تصاویر ابرطیفی داشته‌اند. به منظور جمع‌بندی تعدادی از مدل‌های عمیق که تاکنون در سنجش از دور استفاده شده‌اند می‌توان به تحقیق پائولتی و همکاران (۲۰۱۹) مراجعه کرد [۵]. علی‌رغم تمام مزیت‌ها و ویژگی‌های منحصر به فرد شبکه‌های عصبی کانولوشنی، استفاده از آن‌ها با چالش‌هایی نیز همراه است. دو مورد از مهم‌ترین این چالش‌ها زمان طولانی آموزش شبکه و نیاز به تعداد داده‌های آموزشی زیاد به منظور تعیین دقیق پارامترها است [۶].

به منظور حل چالش‌های ذکر شده در استفاده از شبکه‌های عمیق، اخیراً در حوزه بینایی ماشین روش‌هایی ارائه شده‌اند که می‌توانند از هر دو مزیت روش‌های عمیق و روش‌های سنتی بهره ببرند. از جمله مهم‌ترین این روش‌ها می‌توان به روش شبکه تبدیل مؤلفه اصلی (PCANet)^۶ اشاره کرد که در آن از تبدیل مؤلفه اصلی (PCA)^۷ به صورت سلسله مراتبی به منظور استخراج ویژگی‌های عمیق استفاده می‌شود [۷]. از

^۴Convolutional neural network^۵Stacked autoencoders^۵Deep belief network^۶Principal components network^۷Principal component analysis¹ Morphological Profiles² Local binary patterns

لگاریتم-اقلیدسی به منظور برچسب‌دهی به هر پیکسل استفاده شد. از مزیت‌های اصلی این روش سرعت طبقه‌بندی بالا و دقت مطلوب در هنگام وجود نمونه‌های آموزشی بسیار کم است. به دلیل آنکه روش فانگ و همکاران تنها از اطلاعات طیفی به منظور محاسبه توصیفگرهای کوواریانس استفاده می‌کنند نقشه‌های طبقه‌بندی تولید شده همچنان دارای نویز هستند. به منظور حل این مشکل، ژاوو و همکاران (۲۰۱۹) مفهوم ماتریس کوواریانس بر مبنای خوشه‌بندی قله چگالی^۴ (*DPCC*) را توسعه دادند که در آن از بردار ویژگی چگالی جهت تولید ورودی ماتریس کوواریانس استفاده می‌شود [۱۹]. روش ارائه شده توسط آنها توانست تا حدودی دقت روش فانگ و همکاران را بهبود بخشد. از آنجایی که در روش فانگ و همکاران از یک پنجره با ابعاد ثابت به منظور استخراج توصیفگرهای محلی استفاده می‌شود، ماتریس‌های کوواریانس محلی نمی‌توانند توصیفگرهای مناسبی برای تمام عوارض موجود در تصویر با ابعاد مختلف باشند. از این رو در تحقیق دیگری از ماتریس‌های کوواریانس چند مقیاسی (که حاصل از محاسبه ماتریس کوواریانس در ابعاد پنجره مختلف در اطراف هر پیکسل است) در کنار طبقه‌بندی-کننده شبکه عصبی عمیق پیچشی دو بعدی به منظور طبقه‌بندی تصاویر ابرطیفی استفاده شده است [۱۰]. مجدداً به عنوان راه حل دیگری برای مشکل ذکر شده در تحقیق فانگ و همکاران در مطالعه‌ی دیگری احمدی و مهرشاد (۲۰۲۰) روشی چند مقیاسی را بر مبنای مفهوم سوپر پیکسل و ماتریس کوواریانس برای طبقه‌بندی تصاویر ابرطیفی ارائه دادند [۱۱]. به منظور استفاده هم‌زمان از توانایی‌های شبکه‌های عصبی عمیق و توصیفگرهای کوواریانس، هی و همکاران (۲۰۱۹) شبکه‌های عمیق مبتنی بر کوواریانس را برای طبقه‌بندی تصاویر سنجنش از دوری توسعه داده‌اند که

جمله مزیت‌های این شبکه‌ها این است که برای تولید ویژگی‌های مکانی نیازی به فاز آموزش متداول شبکه‌های عمیق ندارند، از این رو استفاده از آنها به طور کلی با چالش‌های روش‌های عمیق همراه نیست. در حوزه سنجنش از دور ابرطیفی شبکه‌های نواحی تصادفی^۱ (*RPNet*) با الهام از شبکه‌های *PCANet* توسعه داده شده‌اند که در آنها از تبدیل *PCA* و اپراتور کانونولوشنی تصادفی به صورت سلسله مراتبی و متوالی برای تولید ویژگی‌های طیفی-مکانی عمیق استفاده می‌شود [۶]. هر چند که ایده اصلی *RPNet* که تولید ویژگی‌های عمیق با استفاده از کانونولوشن ساده و تبدیل *PCA* است، بسیار ساده و سریع است اما از آنجایی که این شبکه از عملگر کانونولوشن ساده و خطی در فاز تولید ویژگی استفاده می‌کنند، قادر نیست در مناطق پیچیده ویژگی‌های طیفی-مکانی مناسبی به منظور طبقه‌بندی تصاویر تولید کند.

تمامی روش‌های تولید ویژگی طیفی-مکانی که تاکنون در مورد آنها صحبت شد از کوواریانس‌های محلی یا وابستگی مکانی محلی بین باندها چشم‌پوشی می‌کنند. اطلاعات موجود در ماتریس کوواریانس محلی می‌تواند کمک شایانی به افزایش دقت طبقه‌بندی تصاویر ابرطیفی کند [۸]. در این راستا، فانگ و همکاران (۲۰۱۸) روش نمایش محلی ماتریس کوواریانس^۲ (*LCMR*) را برای طبقه‌بندی تصاویر ابرطیفی توسعه دادند [۸]. در این روش از توصیفگرهای مبتنی بر ماتریس کوواریانس در اطراف هر پیکسل به عنوان ویژگی‌های طیفی-مکانی استفاده می‌شود. از آنجایی که توصیفگرهای کوواریانس برای هر پیکسل به صورت ماتریس هستند در نهایت از طبقه‌بندی‌کننده ماشین بردار پشتیبان^۳ (*SVM*) با کرنل

^۱Random patches network^۲Local covariance matrix representation^۳Support vector machines^۴Density peak covariance representation

منظور تولید ویژگی دارای فاز آموزش به سبک شبکه-های عمیق نیست، از نظر محاسباتی نیز نسبت به روش‌های عمیق به صرفه‌تر است. ساختار مقاله در ادامه به شرح زیر است: در بخش دوم پس از معرفی روش استخراج ویژگی تبدیل کسر نويز کمینه و روش تولید ویژگی‌های طیفی-مکانی نمایش محلی ماتریس کرنل وزن دار، روش تحقیق پیشنهادی ارائه شده است. در بخش سوم، دو مجموعه داده ابرطیفی ایندین پایین و دانشگاه پاویا که آزمایش‌ها بر روی آنها انجام شده است، معرفی می‌شوند. در بخش چهارم در ابتدا پارامترهای تأثیرگذار بر عملکرد روش ارائه شده بررسی می‌شود و پس از آن نتایج دقت طبقه-بندی روش پیشنهادی با چند روش دیگر مقایسه می‌شود. نهایتاً نیز در بخش آخر جمع‌بندی تحقیق صورت می‌گیرد.

۲- روش تحقیق

در این قسمت پس از مرور کوتاه بر تبدیل کسر نويز کمینه و روش نمایش محلی کرنل وزن دار برای تولید ویژگی طیفی-مکانی، الگوریتم پیشنهادی تحقیق تشریح شده است.

۲-۱- تبدیل کسر نويز کمینه

ماتریس تبدیل $W \in R^{M \times d}$ را در نظر بگیرید. اگر $X \in R^{M \times P}$ را به عنوان ماتریس ویژگی‌های طیفی، M تعداد باندها و P تعداد پیکسل‌ها باشد، ویژگی‌های کاهش بعدیافته با رابطه (۱) به دست می‌آیند [۸]:

$$Y = W^T X \quad \text{رابطه (۱)}$$

ماتریس X را می‌توان به صورت حاصل جمع دو مؤلفه سیگنال S و نويز N به صورت رابطه (۲) بازنویسی کرد:

$$X = S + N \quad \text{رابطه (۲)}$$

بنا بر رابطه (۲) کوواریانس ماتریس X را می‌توان به صورت حاصل جمع رابطه (۳) نمایش داد:

توانایی مدل‌سازی آماره‌های مرتبه دوم را دارد [۱۲]. استفاده از توصیفگرهای کوواریانس اگر چه دارای مزیت‌هایی مانند سرعت بالا و عملکرد مطلوب در هنگام وجود نمونه‌های آموزشی محدود است اما باید توجه داشت که این توصیفگرها تنها توانایی مدل‌سازی وابستگی‌های خطی را دارد، در حالی که به طور کلی در یک فضا ویژگی پیچیده الزامی وجود ندارد که این فرض برقرار باشد [۱۳]. به منظور حل این مشکل اخیراً در حوزه بینایی و شناسایی الگو، روش نمایش ماتریس کرنل^۱ که قابلیت‌های بالاتری نسبت به نمایش ماتریس کوواریانس دارد پیشنهاد شده است که هنوز تحقیقاتی در این حوزه در سنجش از دور ابرطیفی انجام نشده است [۱۳ و ۱۴]. استفاده از نمایش محلی ماتریس کرنل این امکان را می‌دهد که وابستگی‌های غیرخطی و آماره‌های مرتبه بالا که می‌توانند در فرآیند طبقه‌بندی تصاویر ابرطیفی مؤثر باشند نیز در نظر گرفته شود.

با این اوصاف انگیزه اصلی این تحقیق ارائه روشی جدید است که بتواند بر مبنای ایده کلی شبکه‌های عمیق یعنی استخراج سلسله مراتبی ویژگی‌های طیفی-مکانی و روش تولید ویژگی نمایش محلی ماتریس کرنل وزن-دار^۲ ($WLKMR$) (که قادر به مدل‌سازی وابستگی‌های محلی غیرخطی و آماره‌های مرتبه بالا است)، ویژگی-های طیفی-مکانی با کیفیتی به منظور طبقه‌بندی تصاویر ابرطیفی تولید کند. پس به طور خلاصه نوآوری این تحقیق ارائه شبکه‌ای جدید بر مبنای روش نمایش محلی ماتریس کرنل وزن دار و تبدیل کسر نويز کمینه^۳ ($MINF$) است که قادر است به صورت سلسله مراتبی و عمیق ویژگی‌های طیفی-مکانی مناسب را برای طبقه بندی تصاویر ابرطیفی تولید کند. روش ارائه شده علاوه بر دقت مناسب، ساختار ساده‌ای داشته و از آنجایی که

^۱Kernel matrix representation

^۲Weighted local kernel matrix representation

^۳Minimum noise fraction

باند‌ها)، هر کدام از درایه‌های ماتریس کرنل با ابعاد $M \times M$ میان دو باند i و j در ادامه با استفاده از کرنل تابع پایه شعاعی (RBF) با رابطه (۵) محاسبه می‌شود:

$$\kappa(i, j) = \exp(-\beta \|X_i - X_j\|^2) \quad \text{رابطه (۵)}$$

در رابطه (۵)، β پارامتر کرنل است. باید توجه داشت که برخلاف ماتریس کوواریانس که احتمال تکینگی آن در صورت کوچک بودن پنجره محلی وجود دارد، ماتریس کرنل فوق فارغ از اندازه پنجره فرضی اطراف هر پیکسل، عمدتاً غیرتکینه است [۱۴]. استفاده از نمایش محلی ماتریس کرنل امکان استفاده از کرنل‌های مختلفی را در ساختار خود می‌دهد که هر کدام از جنبه‌های مختلفی توانایی مدل‌سازی روابط پیچیده میان ویژگی‌ها را دارد. در این مقاله از کرنل RBF که یک کرنل غیرخطی قوی است و عملکرد مناسبی نسبت به بقیه کرنل‌ها برای استخراج ویژگی‌های محلی دارد، استفاده شده است [۱۴].

به عنوان یک روش متداول همانند سایر روش‌های تولید ویژگی‌های مکانی در این تحقیق ویژگی‌های $WLKMR$ با استفاده از پنجره‌هایی با اندازه ثابت در اطراف هر پیکسل محاسبه شده است. باید توجه داشت که به صورت معمول هرچه از پیکسل مرکزی پنجره فاصله گرفته می‌شود احتمال اینکه شباهت پیکسل‌های پنجره و پیکسل مرکزی کاهش یابد وجود دارد، از این رو می‌بایست وزن آنها در ویژگی‌های تولید شده نمایش محلی ماتریس کرنل کاهش پیدا کند. از این رو در این تحقیق رابطه (۵) طوری تغییر داده شده است تا هر پیکسل وزن مخصوص خود را بر اساس فاصله آن از پیکسل مرکزی در محاسبه ویژگی‌های نمایش محلی ماتریس کرنل داشته باشد. اگر مرکز سیستم مختصات روی پیکسل مرکزی پنجره $l \times l$ قرار گرفته باشد، وزن هر پیکسل در پنجره با مختصات (r, c) با رابطه (۷) به

$$\sum X = \sum S + \sum N \quad \text{رابطه (۳)}$$

در تبدیل MNF ویژگی‌های نهایی بر اساس نسبت SNR مرتب می‌شود از این رو ماتریس تبدیل W با رابطه (۴) به دست می‌آید [۸]:

$$\operatorname{argmax}_W (W^T \sum S W) / (W^T \sum N W) \quad \text{رابطه (۴)}$$

به صورت خلاصه ماتریس W از بردارهای ویژه متناظر با مقادیر ویژه مرتب شده $\Sigma_N^{-1} \Sigma_S$ به دست می‌آید. برای به دست آوردن کوواریانس ماتریس نویز N از روش بیشترین/کمترین فاکتور اتو کورلیشن^۱ (MAF) استفاده می‌شود [۱۵].

۲-۲- نمایش محلی ماتریس کرنل وزن دار

از نظر ریاضی می‌توان نشان داد که ماتریس کوواریانس به صورت یک تابع کرنل خطی بازنویسی می‌شود. به عبارت دیگر، ماتریس کوواریانس تنها توانایی مدل‌سازی وابستگی‌های خطی میان ویژگی‌ها را دارد و اطلاعاتی از آماره‌های مرتبه بالاتر نمی‌دهد [۱۴]. از سوی دیگر به صورت کلی هیچ الزامی وجود ندارد که وابستگی میان ویژگی‌ها در تصاویر ابرطیفی خطی باشد از این رو در یک حالت کلی به نظر می‌رسد که استفاده از توابع کرنل غیرخطی به جای کوواریانس خطی می‌تواند موجب تولید ویژگی‌های بهتری به منظور طبقه‌بندی تصاویر ابرطیفی شود. به این منظور در این تحقیق روشی تحت عنوان نمایش محلی ماتریس کرنل وزن دار ($WLKMR$) توسعه داده شده است که در ادامه توضیح آن بیان می‌شود.

اگر در نظر بگیریم که X_1 و X_2 و X_3 و ... و X_M هر کدام بردارهای نمایش‌دهنده درجات خاکستری مجموعه پیکسل‌ها در یک پنجره فرضی با ابعاد $L = l \times l$ (که L تعداد کل پیکسل‌های پنجره است) اطراف هر یک از پیکسل‌های تصویر باشد $X_i = L \times 1$ و M تعداد

^۱Radial basis function

^۱Maximum/minimum autocorrelation factor

صورت زیر محاسبه می‌شود:

$$R = \sqrt{(r^2 + c^2)} \quad \text{رابطه (۶)}$$

$$\text{weight}(r, c) = \frac{1}{(R+1)} \quad \text{رابطه (۷)}$$

عدد ۱ در مخرج رابطه (۷) برای اجتناب از بی‌نهایت شدن وزن در پیکسل مرکزی پنجره اعمال شده است. اگر بردار وزن پیکسل‌ها در پنجره با W نشان داده شود، نسخه وزن‌دار رابطه (۵) با رابطه (۸) نشان داده می‌شود:

$$\kappa(i, j) = \exp(-\beta \|W.X_i - W.X_j\|^2) \quad \text{رابطه (۸)}$$

این استراتژی ساده وزن‌دار کردن نمایش محلی ماتریس کرنل موجب بهبود عملکرد ویژگی‌های مستخرج از نمایش محلی ماتریس کرنل می‌شود. به منظور ساده‌سازی و کاهش تعداد پارامترهای روش پیشنهادی، در ادامه کار با استفاده از روش سعی و خطا مقدار β ، برابر با عدد ۱ در نظر گرفته شده است. رابطه (۸) بیانگر هر المان ماتریس نمایش محلی کرنل وزن‌دار است و ماتریس نمایش محلی کرنل به صورت کلی با رابطه (۹) نمایش داده می‌شود:

$$K = \begin{bmatrix} \kappa(1,1) & \dots & \kappa(1,M) \\ \vdots & \ddots & \vdots \\ \kappa(M,1) & \dots & \kappa(M,M) \end{bmatrix} \quad \text{رابطه (۹)}$$

می‌توان به منظور تولید ماتریس مثبت تعریف^۱ از ماتریس K از روش‌های مقیدسازی استفاده کرد. در ادامه به منظور تولید ویژگی‌هایی با کیفیت بالاتر از عملگر لگاریتم ماتریس استفاده می‌شود. اگر تجزیه مقادیر ویژه ماتریس K با $K = U\Sigma U^T$ نشان داده شود، عملگر لگاریتم $\log m$ آن را می‌توان با

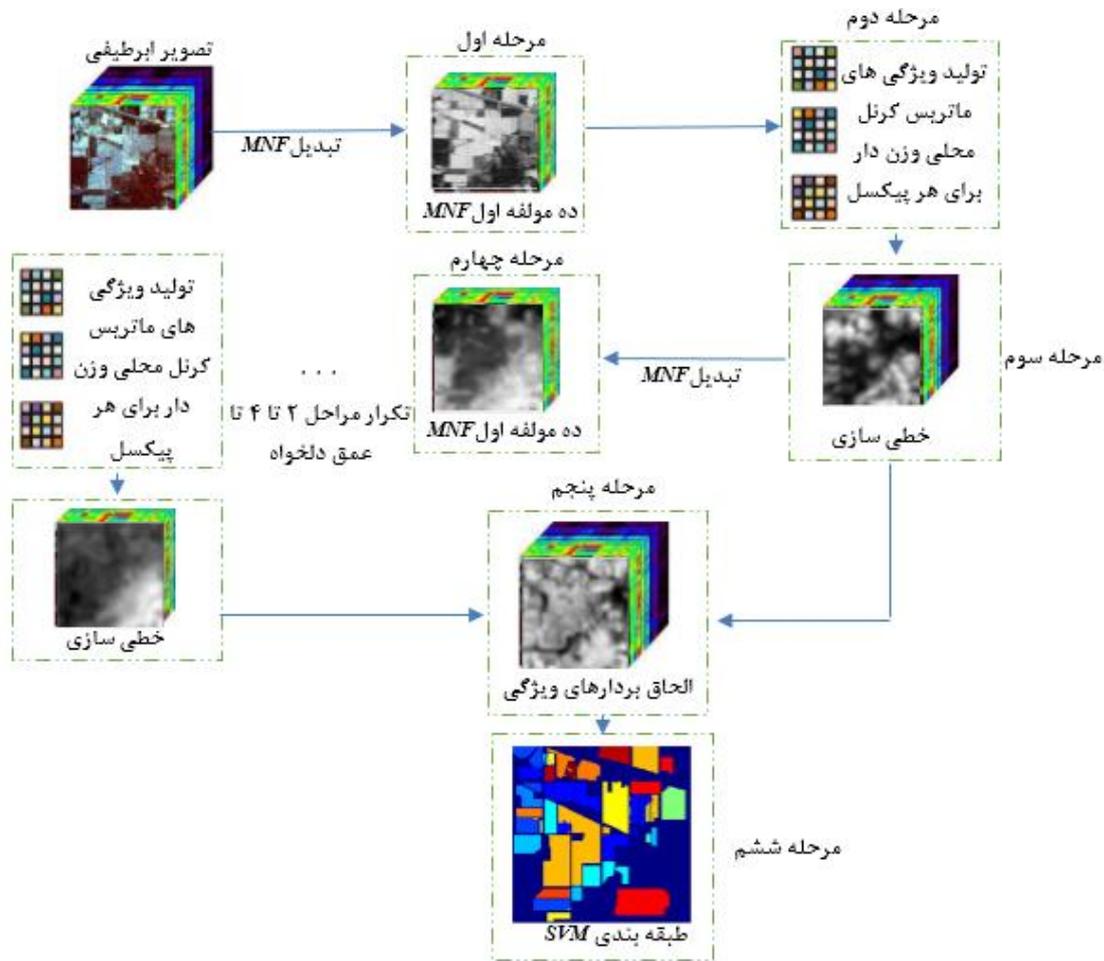
^۱Positive defined

$\log m(K) = U \log(\Sigma) U^T$ محاسبه کرد [۸]. پس از محاسبه لگاریتم ماتریس کرنل، از عناصر قطر اصلی و مثلث بالایی (یا پایینی) به عنوان ویژگی‌های نهایی استخراج شده استفاده می‌شود. این فرآیند در ادامه خطی‌سازی ماتریس نمایش محلی کرنل وزن‌دار نامیده می‌شود. بدیهی است که اگر تعداد باندهای تصویری M باشد ابعاد ماتریس K برابر با $M \times M$ و تعداد ویژگی‌های نهایی استخراج شده برابر با $M \times (M+1)/2$ است.

۲-۳- روش پیشنهادی

همان‌طور که پیش‌تر عنوان شد، در چند سال اخیر با الهام از ایده اصلی روش‌های شبکه عصبی عمیق، توسعه مدل‌هایی که بتواند ویژگی‌های طیفی-مکانی را به صورت سلسله مراتبی استخراج کند و بار محاسباتی کمتری نسبت به روش‌های عمیق داشته باشد، بسیار مورد توجه قرار گرفته است. به طور کلی این روش‌ها دارای این ایده اساسی هستند که فرایند تولید ویژگی طیفی-مکانی و کاهش بعد در آن‌ها به صورت تکراری انجام می‌شود. در همین راستا در تحقیق حاضر به منظور تولید ویژگی‌های طیفی-مکانی عمیق از روش نمایش محلی ماتریس کرنل وزن‌دار و روش کسر نویز کمینه به صورت تکراری استفاده می‌شود. روش تولید ویژگی طیفی-مکانی نمایش محلی ماتریس کرنل وزن-دار یک روش ساده است که توانایی بالایی در مدل-سازی محلی وابستگی‌های غیرخطی و آماره‌های مرتبه بالا دارد.

شکل (۱) فلوچارت کلی روش پیشنهادی با عمق فرضی ۲ را نشان می‌دهد.



شکل ۱: فلوچارت روش پیشنهادی (DeepWLKMR) با عمق برابر با ۲

۲) در مرحله دوم ماتریس نمایش محلی کرنل وزن دار (رابطه (۹)) با در نظر گرفتن یک مقدار معین ابعاد پنجره تولید شده و سپس لگاریتم آن محاسبه می‌شود. ۳) در این مرحله عملیات خطی‌سازی خروجی لگاریتم ماتریس نمایش محلی وزن دار انجام می‌شود. عملیات خطی‌سازی شامل انتخاب مؤلفه‌های قطر اصلی و درایه‌های مثلث بالایی (یا پایینی) ماتریس لگاریتم و تشکیل بردار ویژگی‌های طیفی-مکانی از آن‌ها است. ۴) بر روی بردار ویژگی‌های تولید شده بار دیگر تبدیل کسر نويز کمینه اعمال شده و ۱۰ مؤلفه اول آن انتخاب می‌شود و مجدداً مراحل ۲ و ۳ تا رسیدن به عمق مورد نظر ادامه پیدا می‌کند. ۵) بردار ویژگی‌های طیفی-مکانی تولید شده از تمامی

به طور کلی استخراج ویژگی‌های طیفی-مکانی سلسله مراتبی و طبقه‌بندی تصویر با روش ارائه شده که از این پس DeepWLKMR نامیده می‌شود، دارای ۶ مرحله به شرح زیر است: ۱) در ابتدا به کمک تبدیل کسر نويز کمینه ابعاد تصویر ابرطیفی اصلی کاهش پیدا می‌کند و ۱۰ مؤلفه اول آن انتخاب می‌شود. این مرحله به این دلیل انجام می‌شود که باندهای مجاور در تصویر ابرطیفی دارای همبستگی بالا می‌باشند و استفاده از تمامی این باندهای همبسته در فرایند تولید ویژگی DeepWLKMR سبب تولید بردار ویژگی با حجم بالا می‌شود که به تبع آن حجم محاسبات بعدی نیز بالا می‌رود.

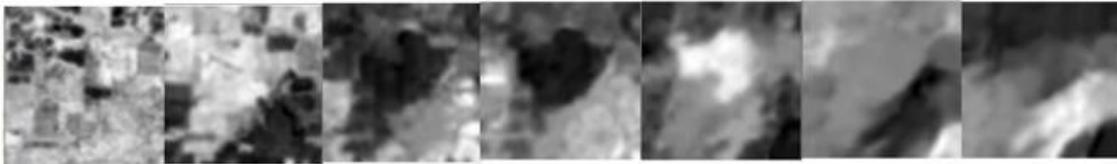
ویژگی‌های تولید شده در عمق‌های مختلف در شکل (۲) نمایش داده شده است. بر مبنای این شکل این‌گونه به نظر می‌رسد که در روش پیشنهادی در عمق‌های ابتدایی تصاویر استخراج شده دارای ویژگی‌های بصری نزدیک به تصویر اصلی است و در آنها لبه‌ها و خطوط مشهود هستند ولی با افزایش عمق شبکه، اثر نرم‌شدگی بیشتر شده و ویژگی‌های استخراج شده بیشتر بیابانگر بافت تصویر و عوارض موجود می‌باشند.

سطوح عمیق با یکدیگر الحاق شده و تشکیل یک بردار غنی از اطلاعات را به منظور طبقه‌بندی تصویر ابرطیفی می‌دهد.

۶) بردارهای ویژگی تولید شده در نهایت به کمک طبقه‌بندی کننده *SVM* طبقه‌بندی شده و ارزیابی نهایی به کمک نمونه‌های آزمون انجام می‌شود.

با هدف تفسیر بصری ویژگی‌های عمیق تولید شده با استفاده از روش *DeepWLKMR*، تصویر تعدادی از

افزایش عمق شبکه

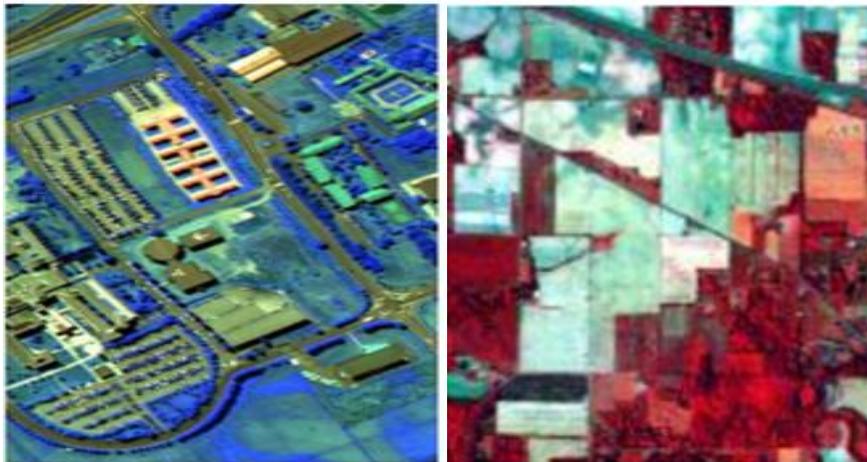
شکل ۲: بصری‌سازی ویژگی‌های استخراج شده به کمک روش *DeepWLKMR*

شکل (۳-الف) نمایش داده شده است.

داده آیندین پاپین: دومین داده مورد استفاده در این پژوهش تصویر اخذ شده توسط سنجنده *ROSIS-3* از منطقه دانشگاه پاپین در شمال ایتالیا در سال ۲۰۰۱ است [۱۶]. این تصویر با حد تفکیک مکانی ۱٫۳ متر دارای ابعاد ۳۴۰×۶۱۰ پیکسل و ۱۱۵ باند طیفی در محدوده ۴۳۰ تا ۸۶۰ نانومتر می‌باشد. عمده‌ی حجم این منطقه را کلاس‌های شهری مانند آسفالت، سایه، خاک لخت تشکیل می‌دهد. با حذف ۱۲ باند دارای محتوای اطلاعاتی کم و نویزی از بقیه ۱۰۳ باند باقی‌مانده در پردازش‌های بعدی این پژوهش استفاده شده است. طبقه‌بندی این تصویر نیز مانند داده‌ی آیندین پاپین به دلیل وجود عوارضی با امضاهای طیفی نزدیک کار دشواری می‌باشد. یک ترکیب رنگی کاذب از داده آیندین پاپین در شکل (۳-ب) نمایش داده شده است.

۳- معرفی داده‌ها

داده آیندین پاپین: اولین داده مورد استفاده در این پژوهش تصویر اخذ شده توسط سنجنده هواپرد *AVIRIS* از منطقه آیندین پاپین در شمال غربی منطقه آیندیانا در ایالات متحده آمریکا در تاریخ ۱۲ ژوئن ۱۹۹۲ است [۱۶]. این تصویر با حد تفکیک مکانی ۲۰ متر دارای ابعاد ۱۴۵×۱۴۵ پیکسل و ۲۲۴ باند طیفی در پهنای باند ۱۰ نانومتر می‌باشد. عمده‌ی حجم این منطقه را کلاس‌های کشاورزی، جنگل و گیاه در بر گرفته است. با حذف ۲۴ باند دارای محتوای اطلاعاتی کم و نویزی، از بقیه ۲۰۰ باند باقی‌مانده در پردازش‌های بعدی این پژوهش استفاده شده است. طبقه‌بندی این تصویر به علت نزدیک بودن امضاهای طیفی برخی از کلاس‌ها کار دشواری می‌باشد. از سوی دیگر وجود کلاس‌هایی با تعداد نمونه کم در نقشه واقعیت زمینی نیز کار طبقه‌بندی در این کلاس‌ها را با دشواری مواجه می‌کند. یک ترکیب رنگی کاذب از داده آیندین پاپین در



ب

الف

شکل ۳: تصویر رنگی کاذب (الف) ایندین پاین - ب) دانشگاه پاپوا

بندی از چهار معیار دقت کلی (OA)، دقت طبقه‌بندی هر کلاس (CA)، دقت متوسط (AA) و ضریب کاپا ($Kappa$) استفاده می‌شود.

به طور کلی روش $DeepWLKMR$ دارای سه پارامتر قابل تنظیم است. تعداد مؤلفه‌های MNF به کار رفته در فرایند تولید ویژگی اولین پارامتر تأثیرگذار است. برای بررسی تأثیر تعداد مؤلفه‌های MNF ، پس از استخراج مؤلفه‌های MNF از تصویر اولیه ابرطیفی از چندین مؤلفه اول برای طبقه‌بندی تصویر استفاده شده و نتایج آن برای هر دو مجموعه داده در شکل (۴) نشان داده شده است.

همان‌طور که در شکل (۴) ملاحظه می‌شود، با افزایش تعداد مؤلفه‌های MNF در ابتدا، دقت کلی طبقه‌بندی افزایش یافته و پس از آن پایدار می‌شود و افزودن اجزای بیشتر نمی‌تواند OA را افزایش دهد. برای هر دو مجموعه داده ده مؤلفه اول MNF انتخاب و در آزمایش‌های بعدی از آنها استفاده می‌شود.

۴- آنالیز نتایج

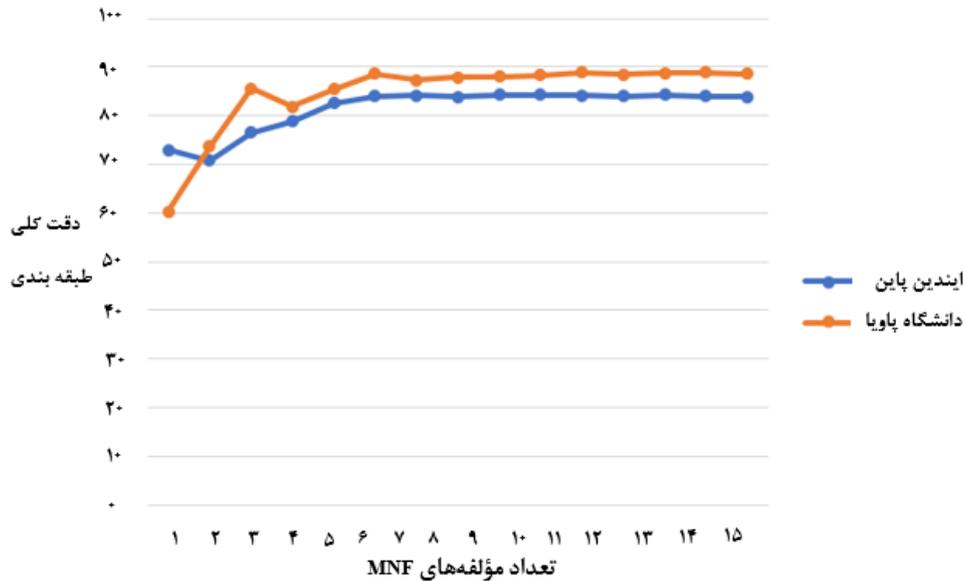
در این بخش، ابتدا اثر پارامترهای تأثیرگذار بر روی کیفیت ویژگی‌های تولید شده با روش پیشنهادی به منظور طبقه‌بندی بررسی می‌شود و سپس در قسمت بعدی نتایج حاصل شده از طبقه‌بندی با روش پیشنهادی با نتایج روش‌های دیگر مقایسه می‌شود.

۴-۱- تنظیم پارامترهای روش پیشنهادی

بر مبنای نقشه‌های واقعیت زمینی موجود، داده‌های ابرطیفی موجود در هر کلاس به صورت تصادفی در هر آزمایش به نمونه‌های آموزشی و آزمون تقسیم می‌شود. برای داده ایندین پاین از ۱۰ درصد مجموعه داده‌ها در هر کلاس به عنوان نمونه آموزشی و از بقیه نمونه‌ها به عنوان آزمون استفاده می‌شود. در داده دانشگاه پاپوا از ۱ درصد نمونه‌های هر کلاس به عنوان نمونه آموزشی و از الباقی آنها به عنوان نمونه آزمون استفاده می‌شود. از مجموعه نمونه‌های آموزشی برای آموزش طبقه‌بندی-کننده SVM استفاده شده و در نهایت نتایج با استفاده از نمونه‌های آزمون ارزیابی می‌شود. پارامترهای کرنل در طبقه‌بندی‌کننده SVM نیز به کمک روش کراس ولیدیشن برآورد می‌شوند. به منظور برآورد دقت طبقه-

^۱Overall accuracy

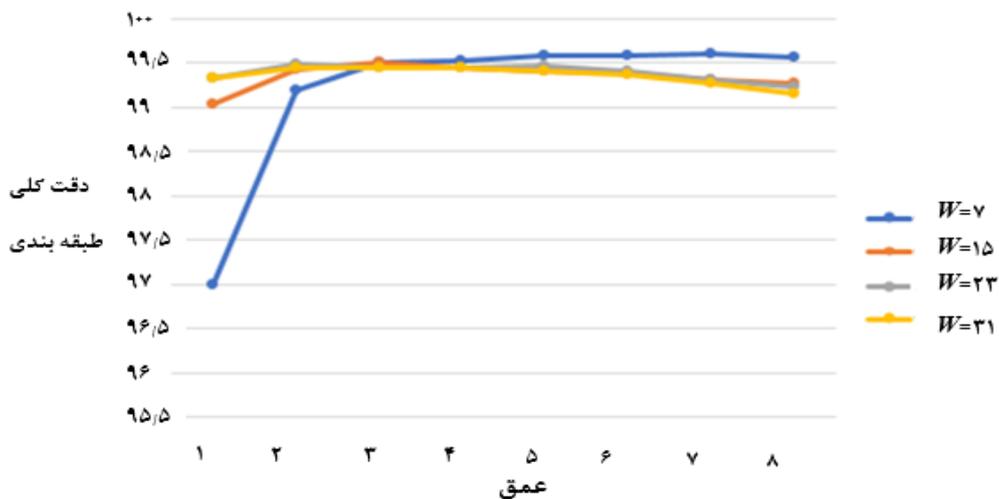
^۲Average accuracy



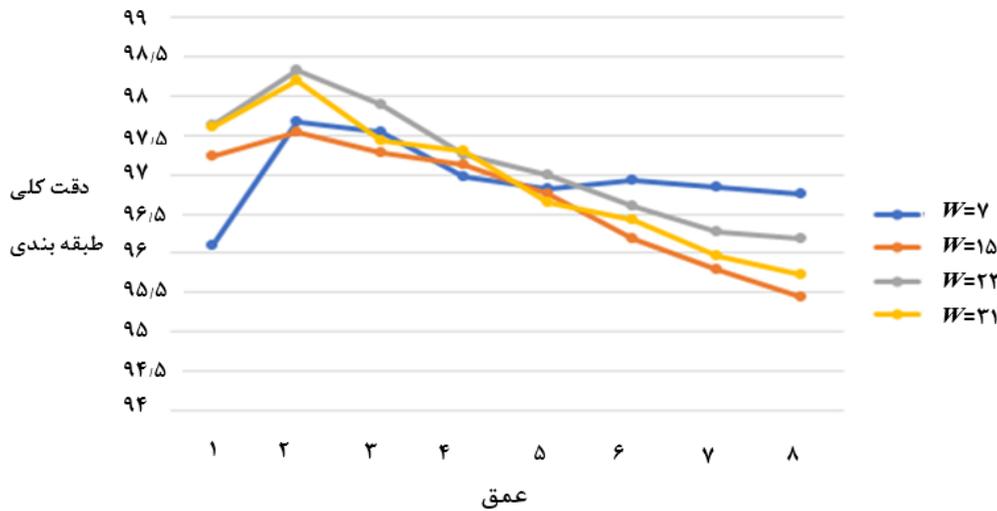
شکل ۴: دقت طبقه‌بندی به ازای چند مؤلفه اول MNF

عمق از ۱۰ مؤلفه اول MNF برای تولید ویژگی‌های نمایش ماتریس محلی کرنل وزن دار استفاده می‌شود، تعداد ویژگی‌های تولیدی بعد از عملیات خطی سازی در هر عمق برای هر دو داده برابر با ۵۵ است. شکل‌های (۵) و (۶) دقت‌های طبقه‌بندی را در مقابل مقادیر مختلف w و D به ترتیب برای دو مجموعه داده ایندین پایین و دانشگاه پاویا نشان می‌دهد.

پس از تنظیم تعداد مناسب مؤلفه‌های MNF، اثر دو پارامتر تأثیرگذار ابعاد پنجره (w) و عمق شبکه (D) در کیفیت ویژگی‌های تولید شده بررسی می‌شود. به این منظور در این آزمایش، پارامترهای w و D به ترتیب در محدوده $\{۷, ۱۵, ۲۳, ۳۱\}$ و $\{۱, ۲, ۳, ۴, ۵, ۶, ۷, ۸\}$ تغییر داده شده و ویژگی‌های تولید شده استفاده از SVM طبقه‌بندی شده‌اند. با توجه به این که در هر



شکل ۵: دقت طبقه‌بندی به ازای مقادیر مختلف ابعاد پنجره (w) و عمق (D) برای داده ایندین پایین



شکل ۶: دقت طبقه‌بندی به ازای مقادیر مختلف ابعاد پنجره (w) و عمق (D) داده دانشگاه پاویا

۴-۲- مقایسه و آنالیز نتایج

در این قسمت نتایج طبقه‌بندی به دست آمده از روش پیشنهادی *DeepWLKMR* با روش طبقه‌بندی طیفی و چهار روش طبقه‌بندی طیفی-مکانی دیگر مقایسه می‌شود. توضیح خلاصه این روش‌ها به شرح زیر است:

(۱) روش طبقه‌بندی تصاویر ابرطیفی با ویژگی‌های طیفی (بدون در نظر گرفتن ویژگی‌های مکانی) و طبقه‌بندی‌کننده *SVM (RBF-SVM)*: در این روش باندهای اصلی تصویر ابرطیفی به کمک طبقه‌بندی-کننده *SVM* با کرنل *RBF* طبقه‌بندی می‌شود. دلیل انتخاب این روش این است که این روش به عنوان یک روش پایه در طبقه‌بندی تصویر ابرطیفی در نظر گرفته می‌شود. به عبارت دیگر کارایی روش‌های طبقه‌بندی طیفی-مکانی در مقایسه با این روش پایه مشخص می‌شود.

(۲) روش پروفیل‌های مورفولوژی گسترده شده و طبقه‌بندی‌کننده *SVM (EMP-SVM)*: در این روش پروفیل‌های مورفولوژی گسترده شده از سه مؤلفه اول *PCA* تصویر اصلی با ابعاد المان ساختاری $\{3, 5, 7, 9, 11, 13, 15\}$ از نوع دیسک شکل تولید شده و سپس به ویژگی‌های طیفی الحاق شده و به

همان‌طور که در شکل‌های (۵) و (۶) نشان داده شده است، برای داده دانشگاه پاویا نتایج بهتری در اندازه پنجره‌های بزرگ‌تر به دست می‌آید ($w=23$) اما برای ایندین پایین بهترین نتایج در ابعاد پنجره کوچک‌تر ($w=7$) به دست آمده است. دلیل این امر این است که مجموعه داده دانشگاه پاویا شامل کلاس‌هایی با ابعاد فضایی بزرگ‌تر نسبت به ایندین پایین است. پارامتر عمق D متناسب با تعداد ویژگی‌های تولید شده است، با افزایش D ، تعداد ویژگی‌های تولید شده افزایش می‌یابد. برای تصویر ایندین پایین عمق مناسب برابر با ($D=7$) است ولی برای داده دانشگاه پاویا این عدد برابر با ($D=2$) است. تعداد نهایی ویژگی‌های تولید شده در روش *DeepWLKMR* برای داده ایندین پایین برابر با ۳۸۵ و برای داده دانشگاه پاویا برابر با ۱۱۰ است. به نظر می‌رسد برای تصویر ایندین پایین با توزیع کلاس‌های پیچیده‌تر، ویژگی‌های بیشتری برای دستیابی به نتایج مناسب در مقایسه با دانشگاه پاویا مورد نیاز است از این رو برای تصویر ایندین پایین به عمق بیشتری برای تولید ویژگی‌های *DeepWLKMR* نیاز است.

طیفی به منظور طبقه‌بندی استفاده می‌شود. در فرایند پیاده‌سازی کلیه پارامترهای این روش بر مبنای مقاله اصلی تنظیم شده است [۳]. این روش یکی از جدیدترین روش‌های طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی است و مقایسه عملکرد روش پیشنهادی با آن می‌تواند جایگاه روش پیشنهادی را در مقایسه با روش‌های جدید بهتر مشخص کند.

در مقاله حاضر به منظور پیاده‌سازی کلیه الگوریتم‌ها از نرم‌افزار متلب ۲۰۲۰ در سیستمی با پردازنده *i5* مدل ۴۵۹۰ و رم ۸ گیگ استفاده شده است. نتایج دقت نهایی طبقه‌بندی روش‌های مختلف برای داده ایندین پایین و دانشگاه پاویا به ترتیب در جداول (۱) و (۲) نمایش داده شده است.

به طور کلی در هر دو مجموعه داده روش پیشنهادی به بالاترین سطوح دقت رسیده است. همان‌طور که در جدول (۱) مشاهده می‌شود، در داده‌ی ایندین پایین، دقت طبقه‌بندی با استفاده از ویژگی‌های طیفی به تنهایی کمتر از ۸۰٪ است و نقشه طبقه‌بندی ایجاد شده دارای نویزهای فراوان است (شکل (۵)). از این رو می‌توان نتیجه گرفت که طبقه‌بندی تصاویر ابرطیفی تنها با ویژگی‌های طیفی نمی‌تواند به سطوح بالایی از دقت برسد. همان‌طور که پیش‌تر عنوان شد، یکی از راه‌حل‌های این مشکل شرگت دادن ویژگی‌های مکانی در فرایند طبقه‌بندی است. همان‌طور که جدول (۱) نشان می‌دهد به طور کلی با افزودن ویژگی‌های مکانی به فرایند طبقه‌بندی، دقت به طور چشمگیری بهبود می‌یابد. اما همان‌طور که مشاهده می‌شود روش‌های مختلف به دقت‌های مختلفی رسیده‌اند و حتی همه روش‌ها در هر دو مجموعه عملکرد یکسانی نداشته‌اند.

منظور طبقه‌بندی به طبقه‌بندی‌کننده *SVM* داده می‌شود. دلیل انتخاب این روش این است که پروفیل‌های مرفولوژی یکی از مهم‌ترین و پرکاربردترین ویژگی‌های مکانی است که در تحقیقات بسیاری به عنوان یک روش پایه‌ای مناسب برای طبقه‌بندی طیفی- مکانی تصاویر ابرطیفی شناخته می‌شود.

(۳) شبکه *RPNet*: در این روش، ویژگی‌های طیفی- مکانی به کمک تبدیل *PCA* و اپراتور کانولوشنی پنجره‌های تصادفی مستخرج از تصویر تولید شده و سپس از طبقه‌بندی‌کننده *SVM* برای طبقه‌بندی تصویر استفاده می‌شود. در فرایند پیاده‌سازی کلیه پارامترهای این روش به طور بهینه بر مبنای مقاله اصلی تنظیم شده است [۶]. دلیل اصلی انتخاب این روش شباهت ایده کلی آن با روش پیشنهادی است. به طور کلی روش *RPNet* نیز از دو مرحله کلی تولید ویژگی‌های مکانی و کاهش بعد به صورت متوالی و تکراری برای تولید ویژگی‌های عمیق استفاده می‌کند.

(۴) روش نمایش محلی کوواریانس (*LCMR*): در این روش از نمایش محلی ماتریس کوواریانس به عنوان ویژگی‌های طیفی- مکانی برای طبقه‌بندی استفاده می‌شود. ویژگی‌های ماتریسی تولید شده در نهایت به کمک *SVM* با کرنل لگاریتم اقلیدسی طبقه‌بندی می‌شود. در فرایند پیاده‌سازی کلیه پارامترهای این روش بر مبنای مقاله اصلی تنظیم شده است [۸]. دلیل اصلی انتخاب این روش این است که *LCMR* نیز شبیه به روش پیشنهادی از وابستگی محلی میان باندهای طیفی به عنوان ویژگی‌های طیفی- مکانی استفاده می‌کند.

(۵) روش فرکتال: در این روش از چند نوع ویژگی بافتی مبتنی بر هندسه فرکتال به همراه ویژگی‌های

^۱Fractal

جدول ۱: نتایج دقت طبقه‌بندی تصویر ابرطیفی ایندین پاین با استفاده از روش‌های مختلف

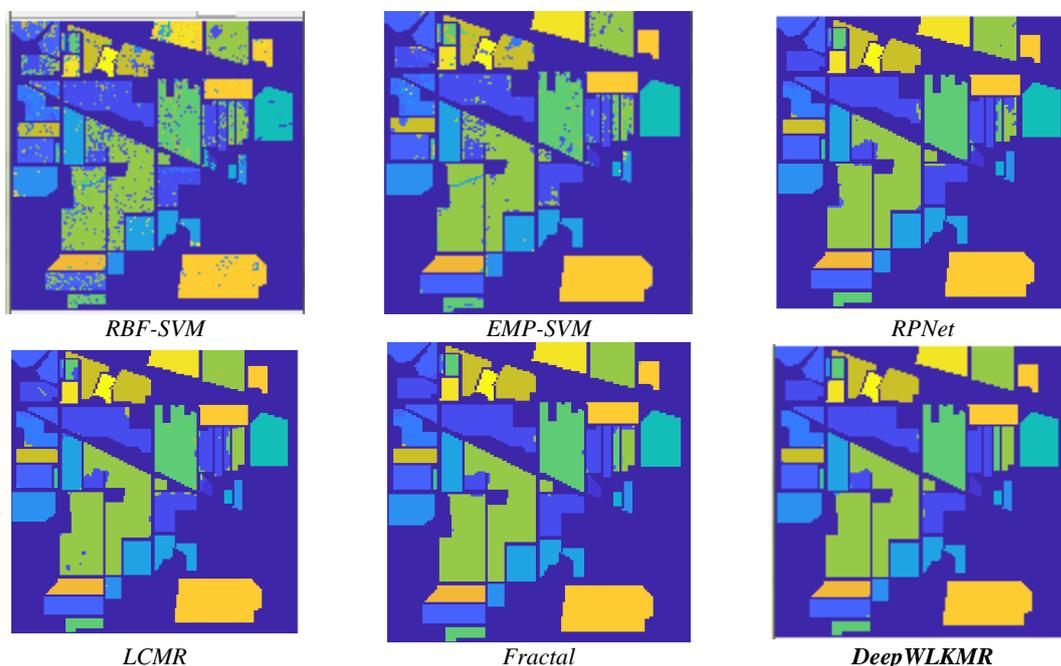
Class	RBF-SVM	EMP-SVM	RPNet	LCMR	Fractal	DeepWLKMR
۱	۴۵,۲۳	۹۰,۴۷	۸۵,۷۱	۶۹,۰۴	۹۷,۶۱	۱۰۰
۲	۸۰,۰۱	۸۷,۲۴	۹۷,۸۲	۹۶,۷۳	۹۹,۱۴	۹۹,۲۲
۳	۷۱,۷۵	۹۳,۳۰	۹۹,۴۶	۹۹,۱۹	۹۸,۷۹	۹۹,۴۶
۴	۶۹,۶۲	۷۱,۰۲	۸۸,۷۸	۹۰,۱۸	۸۹,۲۵	۹۹,۵۳
۵	۹۱,۴۹	۹۱,۹۵	۹۵,۸۶	۹۵,۶۳	۹۵,۸۶	۱۰۰
۶	۹۵,۸۹	۹۹,۳۹	۹۸,۹۳	۹۸,۴۷	۹۹,۸۴	۱۰۰
۷	۵۲	۹۲	۱۰۰	۱۰۰	۱۰۰	۱۰۰
۸	۹۶,۰۵	۹۹,۳۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
۹	۷۶,۴۷	۷۰,۵۸	۱۰۰	۱۰۰	۱۰۰	۱۰۰
۱۰	۶۶,۶۲	۸۳,۶۵	۹۷,۳۷	۹۱,۰۸	۹۸,۱۷	۹۹,۷۷
۱۱	۷۵,۴۲	۹۰,۱۳	۹۵,۷۹	۹۸,۱۹	۹۸,۵۵	۹۹,۵۴
۱۲	۷۳,۴۰	۸۲,۳۹	۹۹,۴۳	۹۹,۴۳	۱۰۰	۹۹,۶۲
۱۳	۹۵,۱۳	۹۶,۷۵	۱۰۰	۱۰۰	۱۰۰	۹۹,۴۵
۱۴	۸۹,۹۰	۹۷,۷۱	۱۰۰	۱۰۰	۹۹,۸۲	۹۹,۶۴
۱۵	۶۲,۰۶	۹۵,۴۰	۱۰۰	۱۰۰	۱۰۰	۹۹,۷۱
۱۶	۹۴,۰۴	۸۲,۱۴	۹۵,۲۳	۹۷,۶	۹۵,۲۳	۹۷,۶۱
OA	۷۹,۵۱	۹۰,۸۲	۹۷,۷۲	۹۷,۴۶	۹۸,۷۳	۹۹,۶
AA	۷۷,۱۹	۸۹,۲۹	۹۷,۱۵	۹۵,۹۷	۹۸,۲۶	۹۹,۶
Kappa	۰,۷۶	۸۸,۹۶	۰,۹۷	۰,۹۷	۰,۹۸۵	۰,۹۹۵

جدول ۲: نتایج دقت طبقه‌بندی تصویر ابرطیفی دانشگاه پابوا با استفاده از روش‌های مختلف

Class	RBF-SVM	EMP-SVM	RPNet	LCMR	Fractal	DeepWLKMR
۱	۹۲,۶۴	۹۸,۲۷	۹۶,۸۳	۹۵,۹۹	۹۸,۰۸	۹۴,۷۱
۲	۹۴,۵۴	۹۹,۴۹	۹۹,۹۵	۹۹,۷۴	۹۹,۶۸	۹۹,۸۷
۳	۷۷,۳۹	۹۶,۵۳	۸۶,۴۳	۹۵,۰۹	۸۸,۲۶	۹۹,۸۱
۴	۸۴,۱۴	۹۴,۲۶	۸۹,۴۵	۹۶,۲۷	۹۴,۶۹	۹۳,۷۷
۵	۹۸,۴۲	۹۹,۳۹	۹۹,۶۹	۹۹,۷۷	۱۰۰	۹۹,۹۲
۶	۷۳,۹۱	۹۳,۴۵	۹۹,۴۱	۹۹,۴۱	۹۵,۹۰	۹۹,۸۸
۷	۶۳,۷۰	۹۸,۷۰	۹۱,۱۱	۹۹,۹۲	۸۷,۳۱	۹۹,۹۲
۸	۶۷,۸۸	۹۳,۳۰	۹۱,۲۵	۹۳,۲۲	۹۰,۱۵	۹۹,۰۹
۹	۹۹,۸۹	۹۹,۸۹	۹۵,۶۲	۹۱,۶۸	۹۸,۸۲	۸۸,۷
OA	۸۷,۲۲	۹۷,۵۲	۹۶,۸۶	۹۷,۹۱	۹۶,۸۵	۹۸,۳۲
AA	۸۳,۶۱	۹۷,۰۳	۹۴,۴۲	۹۶,۷۹	۹۴,۷۶	۹۷,۳
Kappa	۰,۸۲	۰,۹۶۶	۰,۹۵۸	۰,۹۷۲	۰,۹۵۸	۰,۹۷۷

۱۶ ثانیه طول می کشد در موضع ضعف قرار دارد. علت برتری روش پیشنهادی را می توان به قابلیت های روش نمایش محلی ماتریس کرنل وزن دار در مدل سازی همبستگی های مرتبه بالاتر و سیستم تولید ویژگی عمیق آن دانست. بنا بر تصاویر نقشه های طبقه بندی شده موجود در شکل (۷)، روش *DeepWLKMR* نسبت به سایر روش های طبقه بندی نقشه های طبقه بندی شده هموارتری تولید می کند.

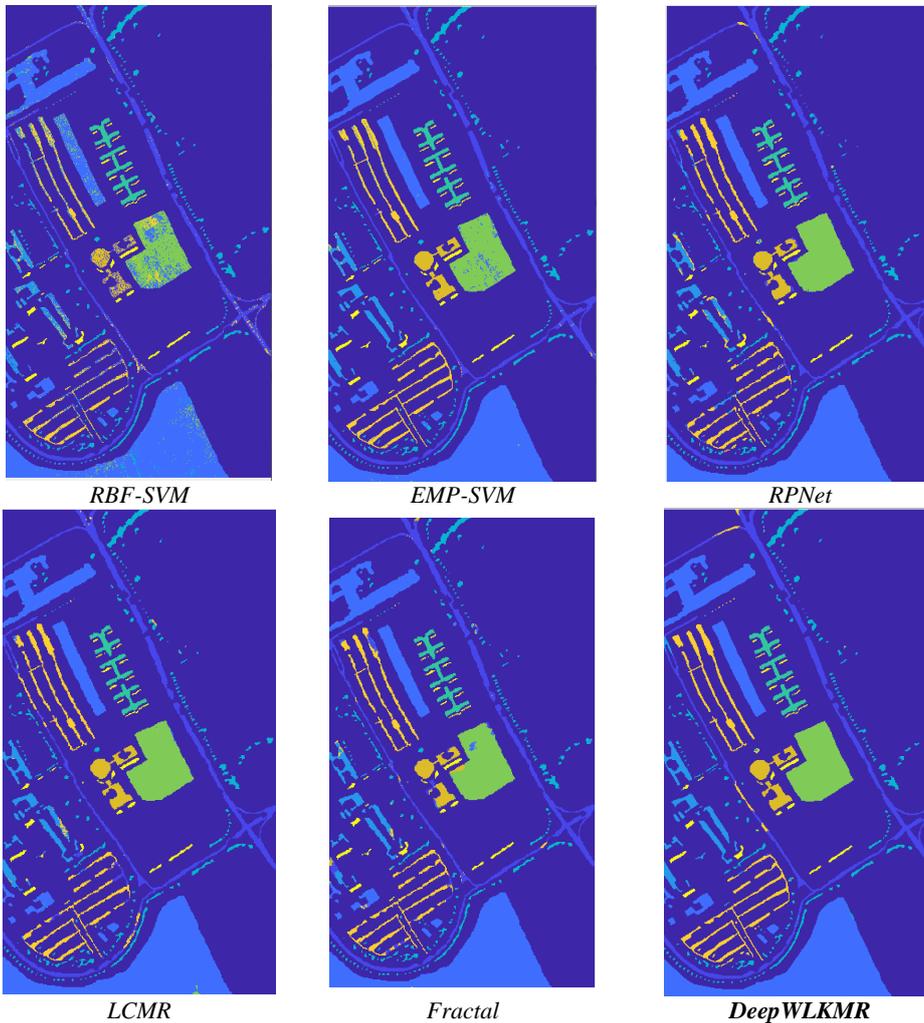
به عنوان نمونه در داده ی ایندین پایین شبکه *RPNet* عملکردی بهتر از *LCMR* داشته است، در حالی که برای داده دانشگاه پوویا بر عکس این اتفاق رخ داده است. در داده ایندین پایین جدی ترین رقیب روش پیشنهادی روش فرکتال است. این روش از آنجایی دارای چند مرحله در تولید ویژگی های مختلف فرکتالی است از نظر محاسباتی در مقابل روش ارائه شده که بسیار ساده است و فرایند تولید ویژگی ها در آنها تنها



شکل ۷: نقشه های طبقه بندی برای داده ایندین پایین

سریع تر از روش پیشنهادی عمل می کند و علت آن هم این است که روش پیشنهادی به صورت متوالی ویژگی های طیفی-مکانی را استخراج می کند و این پدیده سبب کمی کندتر شدن روش *DeepWLKMR* نسبت به روش *LCMR* می شود. مجدداً بنا بر تصاویر نقشه های طبقه بندی شده موجود در شکل (۸)، روش *DeepWLKMR* هموارترین نقشه های طبقه بندی تولید کرده است.

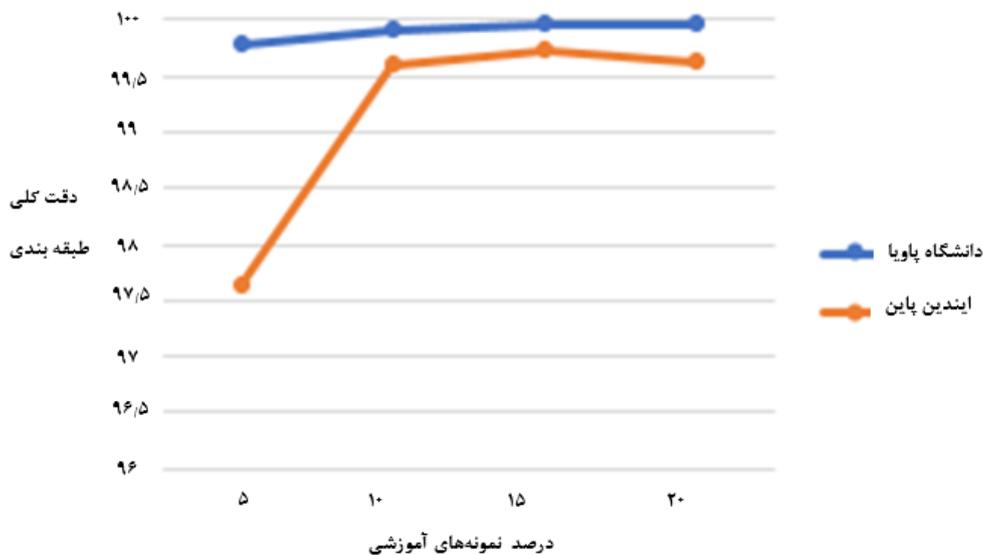
بنا بر یافته های جدول (۲) برای داده ی دانشگاه پوویا، دقت طبقه بندی با استفاده از ویژگی های طیفی به تنهایی کمتر از ۹۰٪ است این در حالی است که تمام روش های طیفی-مکانی دیگر به دقت های بالای ۹۵٪ رسیده اند و این باز مجدداً کارایی روش های طیفی-مکانی را در افزایش دقت طبقه بندی ثابت می کند. در داده دانشگاه پوویا از بین روش های موجود روش *LCMR* را می توان نزدیک ترین رقیب روش پیشنهادی دانست. این روش در این مجموعه داده حدوداً ۲۸٪



شکل ۸: نقشه‌های طبقه‌بندی برای داده دانشگاه پابوا

۱۰٪ نمونه آموزشی در هر کلاس برای روش پیشنهادی می‌توان به دقت‌های بالای ۹۹٫۵٪ رسید. همچنین، نتایج نهایی نشان می‌دهد که حتی زمانی که تعداد نمونه آموزشی محدود باشد هم روش ارائه شده کارایی مطلوبی دارد و این نکته یکی از مهم‌ترین برتری روش پیشنهادی نسبت به سایر روش‌های مبتنی بر یادگیری عمیق است.

به منظور بررسی حساسیت طبقه‌بندی با روش *DeepWLKMR* نسبت به تعداد داده‌های آموزشی در آزمایش بعدی درصد نمونه آموزشی از ۵ درصد تا ۲۰ درصد افزایش داده شده و نتایج طبقه‌بندی برای هر دو مجموعه داده در شکل (۹) نشان داده شده است. در این آزمایش، همان‌طور که انتظار می‌رفت، دقت طبقه‌بندی با بزرگ‌تر شدن اندازه نمونه‌های آموزشی عموماً افزایش می‌یابد. به طور کلی در هر دو مجموعه داده با



شکل ۹: بررسی حساسیت طبقه‌بندی با روش پیشنهادی به تعداد داده‌های آموزشی برای هر دو مجموعه داده ابرطیفی

۵- جمع‌بندی و نتیجه‌گیری

در این مقاله یک روش جدید مبتنی بر شبکه‌های نمایش محلی کرنل وزن‌دار به منظور تولید ویژگی‌های طیفی-مکانی از تصاویر ابرطیفی معرفی شده است. در این روش به منظور تولید ویژگی، به صورت متوالی از تبدیل کسر نويز کمینه و روش تولید ویژگی نمایش محلی کرنل وزن‌دار استفاده می‌شود. ویژگی‌های طیفی-مکانی تولید شده در سطوح مختلف عمق با یکدیگر الحاق شده و به منظور طبقه‌بندی به طبقه-بندی‌کننده ماشین بردار پشتیبان داده می‌شود. مقایسه‌های انجام شده بر روی دو تصویر ابرطیفی ایندین پابین و دانشگاه پابیا برتری روش پیشنهادی را در مقایسه با چند روش رقیب اثبات می‌کند. به طور خلاصه مهم‌ترین یافته‌های این تحقیق به شرح زیر است:

- استفاده توأمان از روش تولید ویژگی طیفی-مکانی نمایش محلی کرنل وزن‌دار و تبدیل نويز کمینه به صورت تکراری سبب تولید ویژگی‌های با کیفیتی به منظور طبقه‌بندی تصاویر ابرطیفی می‌شود.
- روش پیشنهادی حتی در هنگام وجود نمونه‌های آموزشی کم نیز توانایی مناسبی در تولید نقشه‌های

طبقه‌بندی با دقت بالا دارد.

- دقت‌های حاصل شده از روش پیشنهادی در مقایسه با روش *RPNNet* که آن هم دارای ساختاری سلسله مراتبی و تکراری به منظور تولید ویژگی است، به طور متوسط حدود ۲٪ بالاتر است.
- از آنجایی که روش پیشنهادی به صورت نظارت نشده ویژگی‌های طیفی-مکانی را در عمق‌های مختلف استخراج می‌کنند در مقایسه با مدل‌های یادگیری عمیق موجود از نظر حجم محاسباتی بسیار بهینه‌تر هستند. همچنین روش پیشنهادی می‌تواند جایگزینی مناسب برای مدل‌های عمیق در مواقعی که آنها کارایی لازم را ندارند (مانند مواقعی که نمونه‌های آموزشی محدود در دسترس است)، باشد.

به عنوان تحقیقات آتی پیشنهاد می‌شود که علاوه توسعه یک سیستم طبقه‌بندی‌کننده چندگانه بر مبنای ویژگی‌های پیشنهادی به منظور طبقه‌بندی تصاویر ابرطیفی، کارایی روش پیشنهادی با بررسی‌های آماری نیز اثبات شود.

مراجع

- [1] Rasti B, Hong D, Hang R, Ghamisi P, Kang X, Chanussot J, Benediktsson JA, "Feature extraction for hyperspectral imagery: The evolution from shallow to deep: Overview and toolbox", *IEEE Geoscience and Remote Sensing Magazine*, Vol. 8(4), pp. 60-88, 2020.
- [2] B. Kumar, O. Dikshit, A. Gupta, and M. K. Singh, "Feature extraction for hyperspectral image classification: A review", *International Journal of Remote Sensing*, Vol. 41(16), pp. 6248-6287, 2020.
- [3] B.A. Beirami. and M. Mokhtarzade, "Spatial-spectral classification of hyperspectral images based on multiple fractal-based features", *Geocarto International*, 37(1), pp. 231-245. 2022. <https://doi.org/10.1080/10106049.2020.1713232>
- [4] Li S, Song W, Fang L, Chen Y, Ghamisi P, Benediktsson JA., "Deep learning for hyperspectral image classification: An overview", *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), pp. 6690-6709. 2019.
- [5] Paoletti ME, Haut JM, Plaza J, Plaza A., "Deep learning classifiers for hyperspectral imaging: A review", *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, pp. 279-317, 2019.
- [6] Y. Xu, B. Du, F. Zhang, L. Zhang, "Hyperspectral image classification via a random patches network", *ISPRS journal of photogrammetry and remote sensing*, Vol. 142, pp. 344-357, 2018.
- [7] TH. Chan, K. Jia, S. Gao, J. Lu, Z. Zeng, Y. Ma, "PCANet: A simple deep learning baseline for image classification?", *IEEE Transactions on Image Processing*, Vol. 24(12), pp. 5017-5032, 2015.
- [8] L. Fang, N. He, S. Li, A. J. Plaza, J. Plaza, "A new spatial-spectral feature extraction method for hyperspectral images using local covariance matrix representation", *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 56(6), pp. 3534-3546, 2018.
- [9] G. Zhao, N. Li, B. Tu, G. Zhang, W. He, "Density peak covariance matrix for feature extraction of hyperspectral image", *IEEE Geoscience and Remote Sensing Letters*, Vol. 17(3), pp. 534-538, 2019.
- [10] N. He, ME. Paoletti, JM. Haut, L. Fang, S. Li, A. Plaza, J. Plaza, "Feature extraction with multiscale covariance maps for hyperspectral image classification", *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 57(2), pp. 755-769, 2018.
- [11] S.A. Ahmadi, and N. Mehrshad, "Spectral-spatial feature extraction method for hyperspectral images classification using multiscale superpixel and covariance map", *Geocarto International*, pp. 1-18, 2020. <https://doi.org/10.1080/10106049.2020.1734874>
- [12] He N, Fang L, Li S, Plaza J, Plaza A, "Skip-connected covariance network for remote sensing scene classification", *IEEE Transactions on Neural Networks and Learning Systems*, 31(5), pp. 1461-1474, 2019.
- [13] Zhang, J., Wang, L., Zhou, L., & Li, W, "Beyond covariance: Sice and kernel based visual feature representation", *International Journal of Computer Vision*, 1296(2), pp. 300-320, 2021.
- [14] L. Wang, J. Zhang, L. Zhou, C. Tang, W. Li. "Beyond covariance: Feature representation with nonlinear kernel matrices", Presented at *Proceedings of the IEEE International Conference on Computer Vision*. Santiago, Chile, 2015.
- [15] AA. Green, M. Berman, P. Switzer, MD. 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(1), pp. 65-74, 1988.
- [16] <http://lesun.weebly.com/hyperspectral-dataset.html>.



The Classification of Hyperspectral Images Using the Weighted Local Kernel Matrix Network and Support Vector Machines Classifier

Behnam Asghari Beirami^{1*}, *Mehdi Mokhtarzadeh*²

1- Ph. D student of remote sensing in Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics, K. N. Toosi University of Technology, Tehran, Iran

2- Associate Professor, Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics, K. N. Toosi University of Technology, Tehran, Iran

Abstract

Over the last few years, deep learning models have received a lot of attention for the spectral-spatial classification of the hyperspectral images. One of the significant advantages of deep learning methods is that they incorporate both spatial and spectral information in classifying hyperspectral images. Although these models produce accurate classified maps, they are computationally complex, and precise settings of their parameters require a large number of training samples. In order to address these issues, a simplified method that can efficiently extract the spectral-spatial information from a hyperspectral image must be developed. Therefore, the current study proposed a new method for generating the spectral-spatial features of the hyperspectral images. The proposed method uses weighted local kernel matrix representation and minimum noise fraction transformation sequentially and repetitively in order to generate deep spectral-spatial features. The proposed network's spectral-spatial features, which show the local nonlinear relationship between the features extracted from the components of the minimum noise fraction transform at different depths, will finally be stacked together and fed into the support vector machine algorithm for classification. Two hyperspectral benchmark images of the Indian Pines and data from Pavia University are used to test the proposed algorithm. The performance of the proposed method is compared to the spectral classification method and four other spectral-spatial classification methods proposed in recent years. Comparisons show that the proposed method is more accurate in the Indian Pines image more than 20% and in Pavia university image more than 10% than the image classification using the spectral features. In addition, the proposed method is 1% more accurate than the other four spectral-spatial classification methods on average.

Key words: Weighted local kernel matrix representation, Classification, Hyperspectral, Feature extraction.