نشریه علمی مهندسی فناوری اطلاعات مکانی

سال دوازدهم، شماره نخست، بهار ۱۴۰۳

Vol.12, No.1, Spring 2024

۴۳ -۵۹

مقاله پژوهشی

طبقه‌بندی تصاویر ابرطیفی با استفاده از شبکه نمایش محلی ماتریس کرنل وزن‌دار و طبقه‌بندی‌کننده ماشین بردار پشتیبان

بهنام اصغری بیرامی[1*]، مهدی مختارزاده[2]

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 مدل-ها علی‌رغم تولید نقشه‌های طبقه‌بندی‌شده 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 وزن‌دار و تبدیل کسر نویز 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 نویز 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 پاین و دانشگاه پاویا 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 پاین دقت روش پیشنهادی بیش از ۲۰٪ و دانشگاه پاویا 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 وزن‌دار، طبقه‌بندی، ابرطیفی، تولید ویژگی.

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

تلفن: ۰۲۱-۸۸۸۷۷۰۷۱

Email: Behnam.asghari1370@gmail.com

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

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[1] ویژگی‌های مستخرج از ماتریس هم‌رخداد، بانک فیلتر گابور، ویژگی‌های موجک، روش الگوی باینری محلی[2](*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[3] 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 الحاق شده،[4] شبکه‌های باور عمیق،[5] 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 روش-هایی ارائه شده‌اند که می‌توانند از هر دو مزیت روش-های عمیق و روش‌های سنتی بهره ببرند. از جمله مهم‌ترین این روش‌ها می‌توان به روش شبکه تبدیل مؤلفه اصلی[6](*PCANet*) اشاره کرد که در آن از تبدیل مؤلفه اصلی[7](*PCA*) به صورت سلسله مراتبی به منظور استخراج ویژگی‌های عمیق استفاده می‌شود [۷]. از

[1] *Morphological Profiles*
[2] *Local binary patterns*
[3] *Convolutional neural network*
[4] *Stacked autoencoders*
[5] *Deep belief network*
[6] *Principal components network*
[7] *Principal component analysis*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]
[DOI: 10.61186/jgit.12.1.43]

جمله مزیت‌های این شبکه‌ها این است که برای تولید ویژگی‌های مکانی نیازی به فاز آموزش متداول شبکه-های عمیق ندارند، از این رو استفاده از آنها به طور کلی با چالش‌های روش‌های عمیق همراه نیست. در حوزه سنجش از دور ابرطیفی شبکه‌های نواحی تصادفی[1] *(RPNet)* با الهام از شبکه‌های *PCANet* توسعه داده شده‌اند که در آنها از تبدیل *PCA* و اپراتورکانولوشنی تصادفی به صورت سلسله مراتبی و متوالی برای تولید ویژگی‌های طیفی-مکانی عمیق استفاده می‌شود [۶]. هرچند که ایده اصلی *RPNet* که تولید ویژگی‌های عمیق با استفاده از کانولوشن ساده و تبدیل *PCA* است، بسیار ساده و سریع است اما از آنجایی که این شبکه از عملگر کانولوشن 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[2] *(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 پشتیان[3] *(SVM)* با کرنل لگاریتم-اقلیدسی به منظور برچسب‌دهی به هر پیکسل استفاده شد. از مزیت‌های اصلی این روش سرعت طبقه-بندی 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[4] *(DPCR)* را توسعه دادند که در آن از بردار ویژگی چگالی جهت تولید ورودی ماتریس کوواریانس استفاده می‌شود [۹]. روش ارائه شده توسط آنها توانست تا حدودی دقت روش فانگ و همکاران را بهبود ببخشد. از آنجایی که در روش فانگ و همکاران از یک پنجره با ابعاد ثابت به منظور استخراج توصیفگرهای محلی استفاده می‌شود، ماتریس‌های کوواریانس محلی نمی-توانند 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 سنجش از دوری توسعه داده‌اند که

[1] *Random patches network*

[2] *Local covariance matrix representation*

[3] *Support vector machines*

[4] *Density peak covariance representation*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

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[1] 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[2] *(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 وزن‌دار و تبدیل کسر نویز کمینه[3] *(MNF)*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 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 نویز کمینه و روش تولید ویژگی‌های طیفی-مکانی نمایش محلی ماتریس کرنل وزن‌دار، روش تحقیق پیشنهادی ارائه شده است. در بخش سوم، دو مجموعه داده ابرطیفی ایندین پاین 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 می-شود. نهایتاً نیز در بخش آخر جمع‌بندی تحقیق صورت می‌گیرد.

۲- روش تحقیق

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

۲-۱- تبدیل کسر نویز 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]:

$$Y = W^T X \qquad \text{رابطه(۱)}$$

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

$$X = S + N \qquad \text{رابطه(۲)}$$

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

[1] *Kernel matrix representation*

[2] *Weighted local kernel matrix representation*

[3] *Minimum noise fraction*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

$$\sum_X = \sum_S + \sum_N$$ 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]:

$$argmax_W (W^T \sum_S W) / (W^T \sum_N W)$$ رابطه(۴)

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

۲-۲- نمایش محلی ماتریس کرنل وزن‌دار

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 وزن‌دار $(WLKMR)$ توسعه داده شده است که در ادامه توضیح آن بیان می‌شود.

اگر در نظر بگیرید 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 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[۲] (RBF) با رابطه(۵) محاسبه می‌شود:

$$\kappa(i,j) = exp(-\beta \| X_i - X_j \|^2)$$ 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 (c, r) با رابطه (۷) به

[۱] *Maximum/minimum autocorrelation factor*

[۲] *Radial basis function*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

صورت زیر محاسبه می‌شود:

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

$$weight(r,c) = {}^{1}\!/_{(R+1)} \qquad \text{رابطه(۷)}$$

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:

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

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:

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

می‌توان به منظور تولید ماتریس مثبت تعریف[1] 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 $logm$ آن را می‌توان با $logm(K) = Ulog(\Sigma)U^T$ محاسبه کرد [۸]. پس از محاسبه لگاریتم ماتریس کرنل، از عناصر قطر اصلی و مثلث بالایی (یا پایین) 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 وزن‌دار یک روش ساده است که توانایی بالایی در مدل‌سازی محلی وابستگی‌های غیرخطی و آماره‌های مرتبه بالا دارد.

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

[1] *Positive defined*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

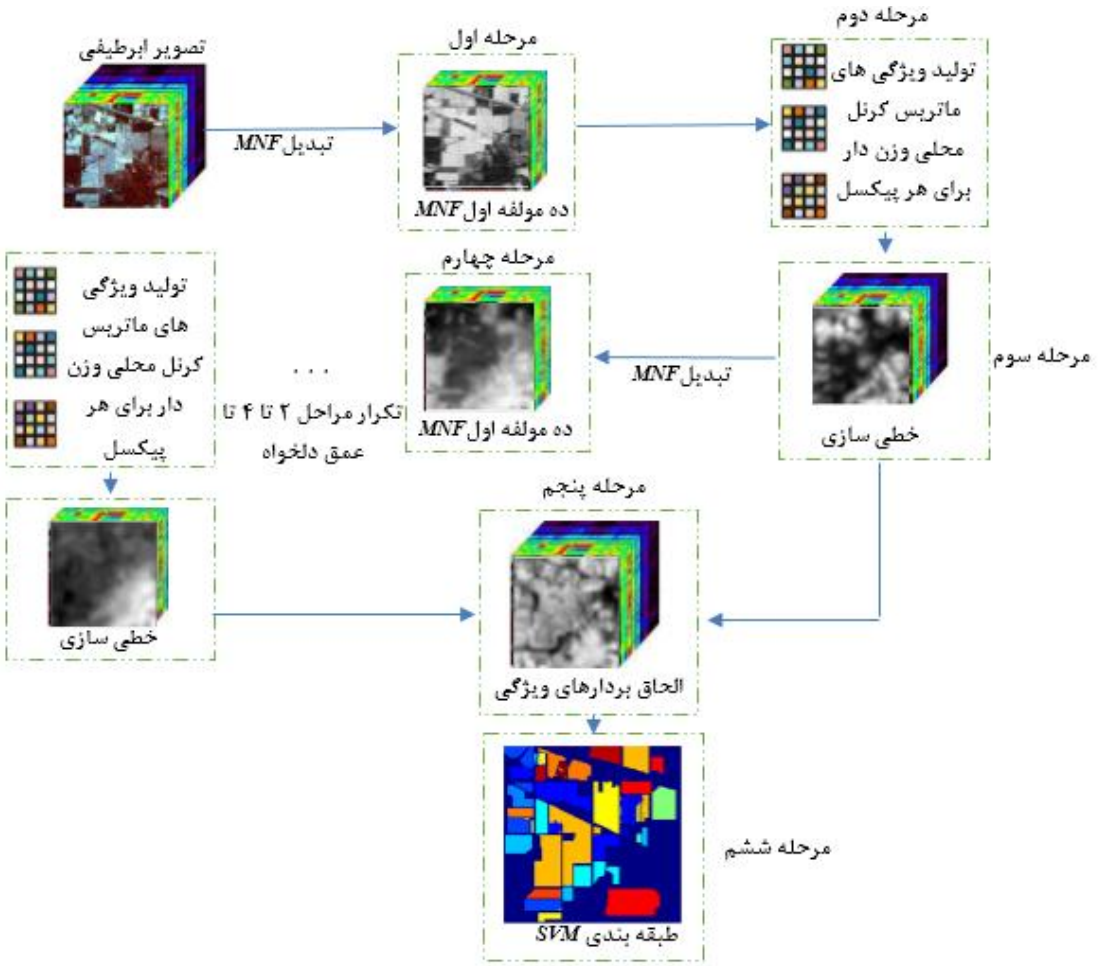

شکل ۱: فلوچارت روش پیشنهادی *(DeepWLKMR)* با عمق برابر با ۲

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 نویز 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.

۲) در مرحله دوم ماتریس نمایش محلی کرنل وزن‌دار (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 وزن‌دار انجام می‌شود. عملیات خطی‌سازی شامل انتخاب مؤلفه‌های قطر اصلی و درایه-های 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 نویز کمینه اعمال شده و ۱۰ مؤلفه اول آن انتخاب می‌شود و مجدداً مراحل ۲ و ۳ تا رسیدن به عمق موردنظر ادامه پیدا می‌کند.

۵) بردار ویژگی‌های طیفی-مکانی تولید شده از تمامی

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]
[DOI: 10.61186/jgit.12.1.43]

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 طبقه‌بندی‌کننده *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 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 نرم-شدگی بیشتر شده و ویژگی‌های استخراج شده بیشتر بیانگر بافت تصویر و عوارض موجود می‌باشند.

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

۳- معرفی داده‌ها

داده ایندین پاین: اولین داده مورد استفاده در این پژوهش تصویر اخذ شده توسط سنجنده هوابرد *AVIRIS* از منطقه ایندین پاین در شمال غربی منطقه ایندیانا 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 برگرفته است. با حذف ۲۴ باند دارای محتوای اطلاعاتی کم و نویزی، از بقیه ۲۰۰ باند باقی‌مانده در پردازش-های 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 ایندین پاین در شکل (۳-الف) نمایش داده شده است.

داده دانشگاه پاویا: دومین داده مورد استفاده در این پژوهش تصویر اخذ شده توسط سنجنده *ROSIS-3* از منطقه دانشگاه پاویا 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 ایندین پاین به دلیل وجود عوارضی با امضاهای طیفی نزدیک کار دشواری می‌باشد. یک ترکیب رنگی کاذب از داده ایندین پاین در شکل (۳-ب) نمایش داده شده است.

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

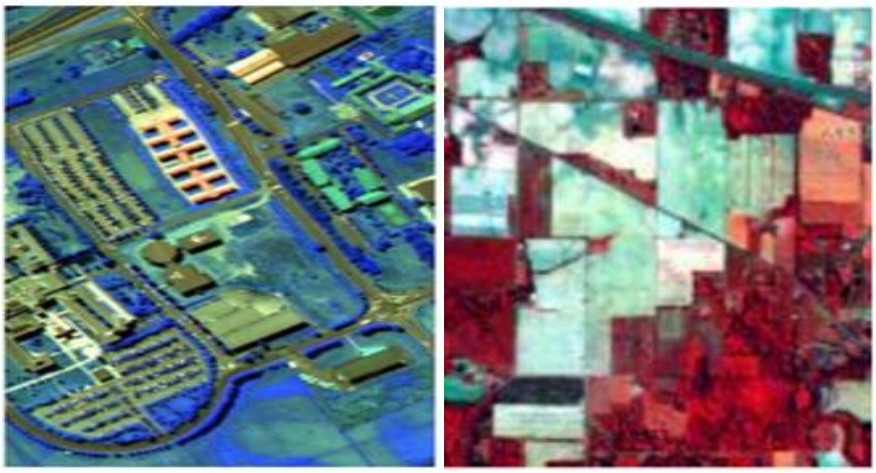

الف ب

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

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 پاویا 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-بندی از چهار معیار دقت کلی(*OA*)، دقت طبقه‌بندی هر کلاس (*CA*)، دقت متوسط[۲](*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.

[۱] *Overall accuracy*

[۲] *Average accuracy*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

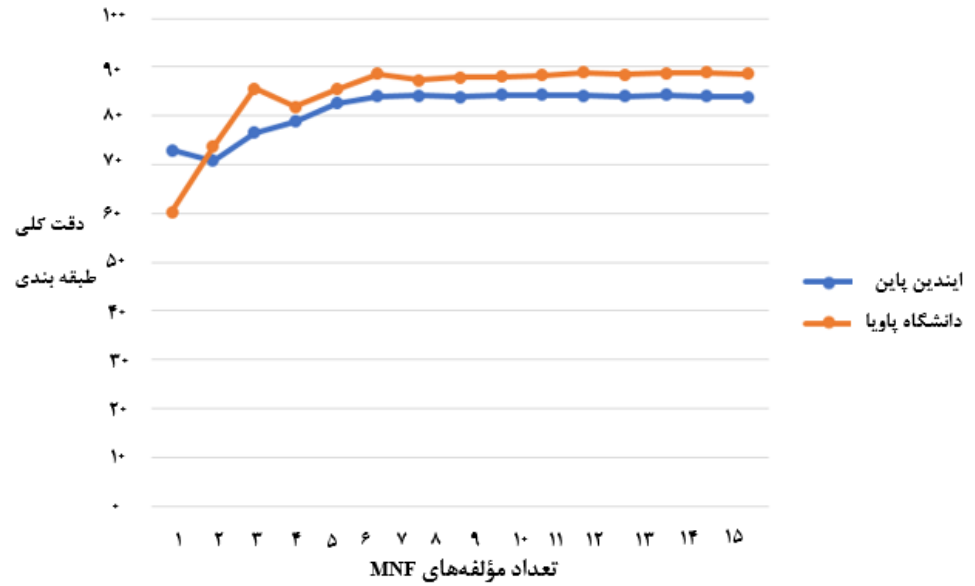

شکل ۴: دقت طبقه‌بندی به ازای چند مؤلفه اول *MNF*

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 عمق از ۱۰ مؤلفه اول *MNF* برای تولید ویژگی‌های نمایش ماتریس محلی کرنل وزن‌دار استفاده می‌شود، تعداد ویژگی‌های تولیدی بعد از عملیات خطی‌سازی 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 پاین و دانشگاه پاویا نشان می‌دهد.

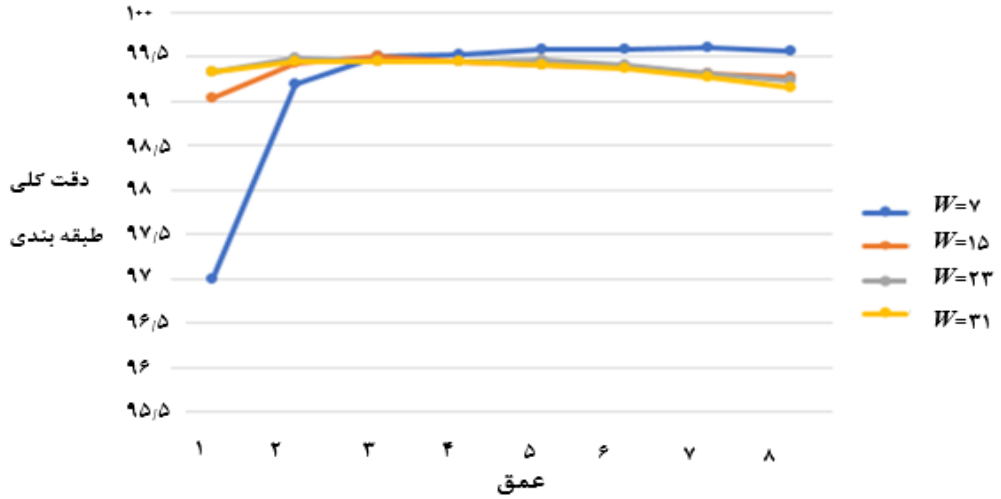

شکل ۵: دقت طبقه‌بندی به ازای مقادیر مختلف ابعاد پنجره *(w)* و عمق *(D)* برای داده ایندین پاین

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]
[DOI: 10.61186/jgit.12.1.43]

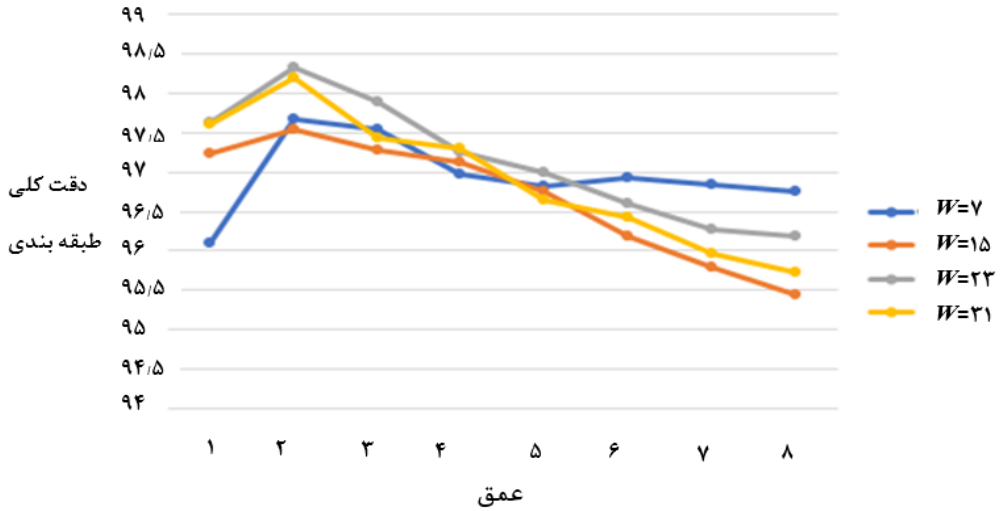

شکل ۶: دقت طبقه‌بندی به ازای مقادیر مختلف ابعاد پنجره *(w)* و عمق *(D)* برای داده دانشگاه پاویا

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=۲۳) اما برای ایندین پاین بهترین نتایج در ابعاد پنجره کوچک‌تر (w=۷) به دست آمده است. دلیل این امر این است که مجموعه داده دانشگاه پاویا شامل کلاس‌هایی با ابعاد فضایی بزرگ‌تر نسبت به ایندین پاین است. پارامتر عمق D متناسب با تعداد ویژگی‌های تولید شده است، با افزایش D، تعداد ویژگی‌های تولید شده افزایش می‌یابد. برای تصویر ایندین پاین عمق مناسب برابر با (D=۷) است ولی برای داده دانشگاه پاویا این عدد برابر با (D=۲) است. تعداد نهایی ویژگی‌های تولید شده در روش *DeepWLKMR* برای داده ایندین پاین برابر با ۳۸۵ و برای داده دانشگاه پاویا برابر با ۱۱۰ است. به نظر می‌رسد برای تصویر ایندین پاین 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 پاین به عمق بیشتری برای تولید ویژگی‌های *DeepWLKMR* نیاز است.

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 طبقه‌بندی‌کننده *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 {۳،۵،۷،۹،۱۱،۱۳،۱۵} از نوع دیسک شکل تولید شده و سپس به ویژگی‌های طیفی الحاق شده و به

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]
[DOI: 10.61186/jgit.12.1.43]

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 طبقه-بندی 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[۱]: در این روش از چند نوع ویژگی بافتی مبتنی بر هندسه فرکتال به همراه ویژگی‌های 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 *i*۵ مدل ۴۵۹۰ و رم ۸ گیگ استفاده شده است. نتایج دقت نهایی طبقه‌بندی روش‌های مختلف برای داده ایندین پاین 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 پاین، 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 راه حل‌های 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 می-یابد. اما همان‌طور که مشاهده می‌شود روش‌های مختلف به دقت‌های مختلفی رسیده‌اند و حتی همه روش‌ها در هر دو مجموعه عملکرد یکسانی نداشته‌اند.

[۱] *Fractal*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

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 پاویا 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

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

به عنوان نمونه در داده‌ی ایندین پاین شبکه *RPNet* عملکردی بهتر از *LCMR* داشته است، در حالی که برای داده دانشگاه پاویا بر عکس این اتفاق رخ داده است. در داده ایندین پاین جدی‌ترین رقیب روش پیشنهادی روش فرکتال است. این روش از آنجایی دارای چند مرحله در تولید ویژگی‌های مختلف فرکتالی است از نظر محاسباتی در مقابل روش ارائه شده که بسیار ساده است و فرایند تولید ویژگی‌ها در آنها تنها ۱۶ ثانیه طول می‌کشد در موضع ضعف قرار دارد. علت برتری روش پیشنهادی را می‌توان به قابلیت‌های روش نمایش محلی ماتریس کرنل وزن‌دار در مدل‌سازی همبستگی‌های مرتبه بالاتر و سیستم تولید ویژگی عمیق آن دانست. بنا بر تصاویر نقشه‌های طبقه‌بندی شده موجود در شکل (۷)، روش *DeepWLKMR* نسبت به سایر روش‌های طبقه‌بندی نقشه‌های طبقه‌بندی شده هموارتری تولید می‌کند.

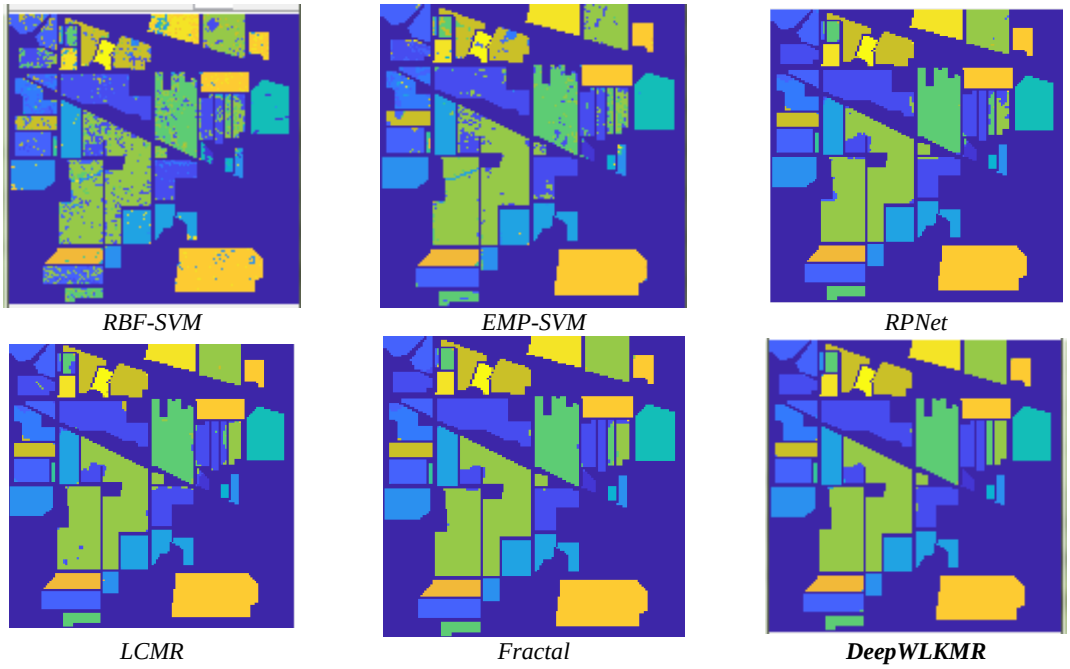

شکل ۷: نقشه‌های طبقه‌بندی برای داده ایندین پاین

بنا بر یافته‌های جدول (۲) برای داده‌ی دانشگاه پاویا، دقت طبقه‌بندی با استفاده از ویژگی‌های طیفی به تنهایی کمتر از ۹۰٪ است این در حالی است که تمام روش‌های طیفی-مکانی دیگر به دقت‌های بالای ۹۵٪ رسیده‌اند و این باز مجدداً کارایی روش‌های طیفی-مکانی را در افزایش دقت طبقه‌بندی ثابت می‌کند. در داده دانشگاه پاویا از بین روش‌های موجود روش *LCMR* را می‌توان نزدیک‌ترین رقیب روش پیشنهادی دانست. این روش در این مجموعه داده حدوداً ۲۸٪ سریع‌تر از روش پیشنهادی عمل می‌کند و علت آن هم این است که روش پیشنهادی به صورت متوالی ویژگی-های طیفی-مکانی را استخراج می‌کند و این پدیده سبب کمی کندتر شدن روش *DeepWLKMR* نسبت به روش *LCMR* می‌شود. مجدداً بنا بر تصاویر نقشه‌های طبقه‌بندی‌شده موجود در شکل (۸)، روش *DeepWLKMR* هموارترین نقشه‌های طبقه‌بندی تولید کرده است.

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]
[DOI: 10.61186/jgit.12.1.43]

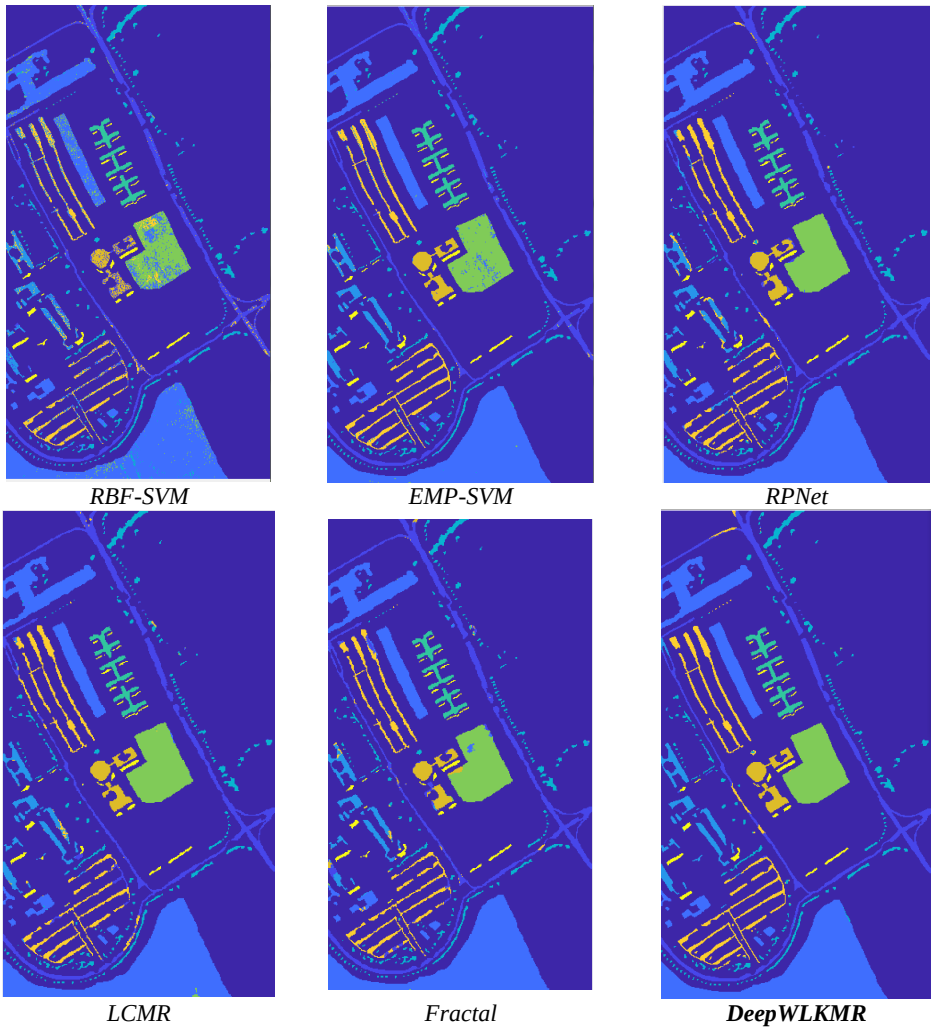

شکل ۸: نقشه‌های طبقه‌بندی برای داده دانشگاه پاویا

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 طبقه-بندی با بزرگ‌تر شدن اندازه نمونه‌های آموزشی عموماً افزایش می‌یابد. به طور کلی در هر دو مجموعه داده با 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.

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]
[DOI: 10.61186/jgit.12.1.43]

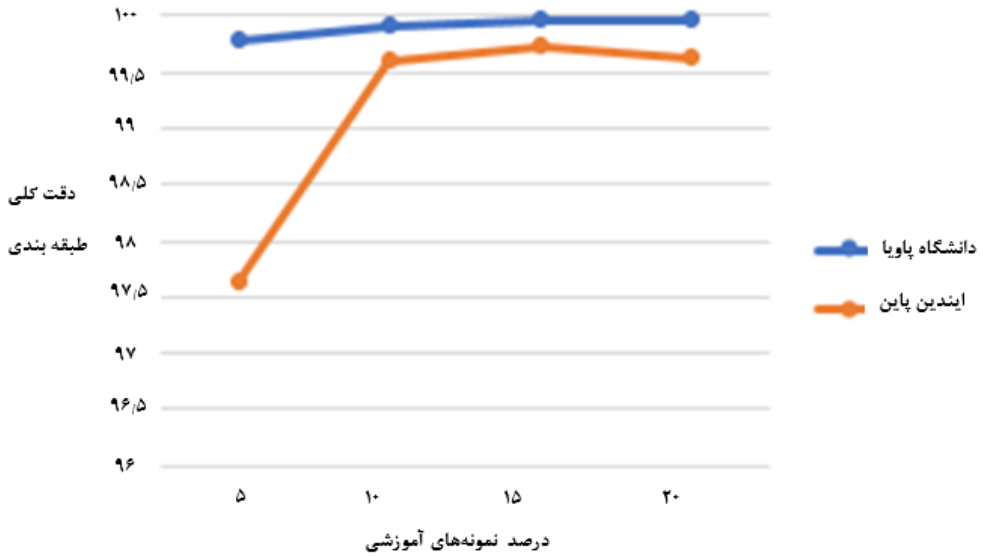

شکل ۹: بررسی حساسیت طبقه‌بندی با روش پیشنهادی به تعداد داده‌های آموزشی برای هر دو مجموعه داده ابرطیفی

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 نویز 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 پاین و دانشگاه پاویا برتری روش پیشنهادی را در مقایسه با چند روش رقیب اثبات می‌کند. به طور خلاصه مهم‌ترین یافته‌های این تحقیق به شرح زیر است:

۱) استفاده توأمان از روش تولید ویژگی طیفی-مکانی نمایش محلی کرنل وزن‌دار و تبدیل نویز کمینه به صورت تکراری سبب تولید ویژگی‌های با کیفیتی به منظور طبقه‌بندی تصاویر ابرطیفی می‌شود.

۲) روش پیشنهادی حتی در هنگام وجود نمونه‌های آموزشی کم نیز توانایی مناسبی در تولید نقشه‌های طبقه‌بندی با دقت بالا دارد.

۳) دقت‌های حاصل شده از روش پیشنهادی در مقایسه با روش *RPNet* که آن هم دارای ساختاری سلسله مراتبی و تکراری به منظور تولید ویژگی است، به طور متوسط حدود ۲٪ بالاتر است.

۴) 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.

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]
[DOI: 10.61186/jgit.12.1.43]

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-data-set.html.*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]

K. N. TOOSI UNIVERSITY OF TECHNOLOGY
FACULTY OF GEODESY AND GEOMATICS ENGINEERING

Journal of Geospatial Information Technology
Vol.12, No.1, Spring 2024

Research Paper

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.*

Correspondence Address: *Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics, K. N. Toosi University of Technology.*
Tel : *+98 21 88877071*
Email*: Behnam.asghari1370@gmail.com*

[Downloaded from jgit.kntu.ac.ir on 2025-12-16]

[DOI: 10.61186/jgit.12.1.43]