نشریه علمی مهندسی فناوری اطلاعات مکانی

سال هشتم، شماره دوم، تابستان ۱۳۹۹

Vol.8, No.2, Summer 2020

۱۹-۱

مقاله پژوهشی

طبقه‌بندی تصاویر ابرطیفی با استفاده از ترکیب ویژگی‌های مکانی مبتنی بر برازش محلی رویه و ویژگی‌های طیفی

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

۱- دانشجوی دکتری گروه فتوگرامتری و 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: ۱۳۹۷/۰۳/۰۵ تاریخ پذیرش مقاله: ۱۳۹۷/۰۶/۱۰

چکیده

سنجنده‌های ابرطیفی به واسطه اخذ تعداد زیادی از باندهای طیفی، همواره دارای اهمیت خاصی در پایش پدیده‌های سطح زمین می‌باشند. طبقه‌بندی تصاویر ابرطیفی از جمله مهم‌ترین شاخه‌های پردازشی داده‌های ابرطیفی است که تا به حال تلاش‌های زیادی برای افزایش دقت آن صورت گرفته است. ویژگی‌های بافتی به دلیل اینکه می‌توانند سبب افزایش دقت طبقه‌بندی شوند همواره مورد توجه بوده‌اند. در مقاله حاضر روشی جدید برای تولید ویژگی‌های مکانی از تصاویر ابرطیفی مبتنی بر برازش محلی رویه معرفی شده است. در این روش رویه‌ای به سطح خاکستری تصویر در محدوده اطراف هر پیکسل برازش داده می‌شود و از ضرایب رویه برازش داده شده، ضرایب فرم‌های اساسی اول و دوم، انحناهای سطح، دیورژانس گرادیان، مساحت سطح خاکستری تصویر و حجم محصور در زیر رویه در ابعاد پنجره گوناگون به عنوان ویژگی مکانی استفاده می‌شوند. ویژگی‌های مکانی پیشنهادی در کنار ویژگی‌های طیفی قرار گرفته بردار طیفی- مکانی حاصل به کمک دو روش K همسایگی نزدیک و ماشین بردار پشتیبان طبقه‌بندی می‌شود. آزمایش‌های این مقاله که بر روی دو تصویر ابرطیفی حقیقی از دو منطقه کشاورزی و شهری صورت گرفته است؛ نشان از برتری روش پیشنهادی دارد. نتایج نهایی نشان می‌دهد که دقت کلی طبقه‌بندی با روش پیشنهادی می‌تواند در بهترین حالت ۷ درصد از دقت کلی روش‌های رقیب بیشتر باشد.

کلید واژه‌ها : طبقه‌بندی، تصاویر ابرطیفی، ویژگی‌های برازش محلی رویه، بافت، استخراج ویژگی.

* نویسنده مکاتبه کننده: تهران – دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیر الدین طوسی

تلفن: ۰۹۳۵۵۸۴۵۶۳۶

Email: Behnam.Asqhari1370@Gmail.com

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]

[DOR: 20.1001.1.20089635.1399.8.2.1.3]

[DOI: 10.29252/jgit.8.2.1]

۱- مقدمه

سنجنده‌های ابرطیفی با اخذ تعداد زیادی از باندهای طیفی از نواحی فرابنفش تا اینفرارد[1] به ابزاری بسیار سودمند برای مطالعه پدیده‌های سطح زمین تبدیل شده است. استفاده از این اطلاعات طیفی ارزشمند هر چند که امکان شناسایی عوارض گوناگون را فراهم می‌کند اما با مشکلاتی نیز همراه است. یکی از این مهمترین این مشکلات که در اثرحجم بالای اطلاعات طیفی اخذ شده بوجود می‌آید و از عوامل محدود کننده دقت طبقه‌بندی تصاویر ابرطیفی است پدیده بلای ابعادی[2] است. این پدیده بیان می‌کند که پیچیدگی یک مسأله با افزایش ابعاد داده به طور نمایی رشد می‌کند[۱]. حجم بالای اطلاعات طیفی اخذ شده توسط سنجنده‌های ابرطیفی فضاهایی با ابعاد بالا را تولید می‌کنند که این فضاها عمدتا خالی هستند و ساختار داده در درجه اول در یک زیرفضا وجود دارد[۲]. از روش‌های کاهش بعد به منظور کاهش دادن بعد داده به زیر فضای بهینه استفاده می‌شود، به طوریکه اطلاعات ارزشمند از دست نرود. به بیان دیگر از روش‌های کاهش بعد به منظور انتقال داده از فضایی با ابعاد بالا به فضایی با ابعاد کمتر به منظور حل مشکل بلای ابعادی استفاده می‌شود[۳]. یکی از مهمترین روش‌های کاهش بعد روش آنالیز مولفه اصلی است که در این روش ویژگی‌ها به فضایی غیر همبسته منتقل می‌شوند و بر مبنای واریانس مرتب می‌شوند.

از سوی دیگر هنگامی که عوارض موجود رفتارهای طیفی نزدیک دارند، استفاده از ویژگی‌های طیفی به تنهایی در پروسه طبقه‌بندی عموماً منجر به دقت‌های بالایی نمی‌شود[۴ و ۵]. استفاده از ویژگی‌های مکانی در کنار ویژگی‌های طیفی می‌تواند این مشکل را تا حدودی برطرف کند. تا به حال روش‌های گوناگونی برای کمّی‌سازی ویژگی‌های مکانی پیشنهاد شده که پرکاربردترین آنها ویژگی‌های مستخرج از ماتریس هم‌رخداد، ویژگی‌های بانک فیلتر گابور، پروفایل‌های مورفولوژی ، تبدیل موجک گسسته و میدان‌های تصادفی مارکوف می‌باشد.

ویژگی‌های مستخرج از ماتریس هم‌رخداد، هم به صورت کلاسیک دوبعدی و هم به صورت سه بعدی به منظور طبقه‌بندی تصاویر سنجش از دوری مورد استفاده قرار گرفته است[۶]. نتایج تحقیق شن و همکاران نشان می‌دهد که استفاده از بانک فیلتر گابور که در مقیاس‌ها و جهت‌های گوناگون تولید می‌شود همواره توانایی بالایی در استخراج ویژگی‌های مکانی دارد[۷]. در تحقیقات فاول و همکاران و باریوسو و همکاران، نویسندگان با بسط مفهوم پروفایل مورفولوژی ساخته شده از تبدیلات مورفولوژی برای تصاویر ابرطیفی از این ویژگی‌های ساختاری به منظور طبقه‌بندی تصاویر ابرطیفی استفاده کردند [۸ و ۹]. دسته دیگر از ویژگی‌های مکانی پروفایل‌های خصوصیت[3] هستندکه با بسط مفهوم پروفایل مورفولوژی ایجاد شده‌اند که توانایی مدل‌سازی اطلاعات ساختاری گوناگون را دارا می‌باشند[۱۰]. استفاده از اطلاعات مکانی مبتنی بر موجک در کنار اطلاعات طیفی از جنس موجک در تحقیق کومار و همکاران پیشنهاد شده است[۱۱]. نتایج این تحقیق از افزایش حدود هفت درصدی دقت طبقه‌بندی حکایت دارد. همچنین نسخه سه بعدی روش استخراج ویژگی موجک در تحقیق پرسد و همکاران برای استخراج ویژگی‌های طیفی-مکانی استفاده شده است که توانایی بالایی در کمّی‌سازی اطلاعات مکانی بخصوص برای تصاویر نویزی دارد[۱۲]. اخیراً استفاده از گشتاورهای هندسی به منظور افزایش دقت طبقه بندی تصاویر ابرطیفی در تحقیق کومار و همکاران پیشنهاد شده است[۱۳]. در تحقیق مذکور ابتدا از مؤلفه‌های اصلی تصویر ابرطیفی اطلاعات گشتاور هندسی به دست

[1] *Infrared*
[2] *Curse of dimensionality*
[3] *Attribute*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

می‌آید و همراه با اطلاعات طیفی برای طبقه‌بندی تصویر ابرطیفی استفاده می‌شوند. در تحقیق مرندی و قاسمیان بانک فیلتری جدید مبتنی بر تفاضل فیلترهای گوسی که نسبت به دوران غیرحساس است پیشنهاد شده است که در هنگام وجود داده‌های آموزشی هم نیز به دقت‌های مطلوبی می‌رسد[۱۴]. همچنین از یکی از انواع اتوکورلیشن‌های مکانی به نام موران[1] به صورت محلی و سراسری در طبقه‌بندی تصاویر ابرطیفی در تحقیق اصغری و مختارزاده با موفقیت استفاده شده است[۱۵].

از ادغام چندین ویژگی مکانی با ویژگی‌های طیفی نیز در تحقیقاتی نظیر میزاپور و قاسمیان به منظور طبقه‌بندی تصاویر ابرطیفی استفاده شده است[۱۶]. در این مقاله ویژگی‌های مکانی مبتنی بر گابور، ماتریس هم رخداد ، ماتریس هم رخداد قطعه بندی-مبنا و پروفایل‌های مورفولوژی برای افزایش دقت طبقه‌بندی تصاویر ابرطیفی استفاده شده است. این ویژگی‌ها مکانی پس از استخراج از مؤلفه اصلی تصاویر ابرطیفی در ترکیبات گوناگونی با اطلاعات طیفی اصلی به طبقه‌بندی‌کننده ماشین بردار پشتیبان تزریق شدند. نتایج این تحقیق نشان از توانایی بالای روش پیشنهادی حتی در زمان وجود داده‌های آموزشی کم در افزایش دقت طبقه‌بندی تصاویر دارد.

مدل‌های میدان‌های تصادفی مارکوف مدل‌های احتمالاتی هستند که با یک سیستم همسایگی مکانی برای تزریق اطلاعات مکانی در طبقه‌بندی تصاویر استفاده می‌شوند[۱۶]. الگوریتم‌های که از میدان‌های تصادفی مارکوف استفاده می‌کنند عموماً سعی در مقیدسازی برچسب‌های طبقه‌بندی به کمک کمینه‌سازی یک تابع انرژی دارند. از الگوی محلی دودویی به همراه میدان تصادفی مارکوف در تحقیق یی و همکاران به منظور طبقه‌بندی تصاویر ابرطیفی استفاده شده است[۱۷]. در این تحقیق از علامت و بزرگی الگوی دودویی محلی برای به دست آوردن احتمالات شرطی کلاس‌ها به همراه احتمالات اولیه به دست آمده از میدان تصادفی مارکوف در فرمول‌بندی بیشینه احتمال پسین بیزی[2] به منظور طبقه‌بندی تصاویر ابرطیفی استفاده شده است.

در سالیان اخیر از روش‌های نمایش تنک[3] در چندین تحقیق برای طبقه‌بندی داده‌های ابرطیفی استفاده شده است[۱۸]. در این روش‌ها یک سیگنال به کمک یک ترکیب خطی تنک از داده‌های آموزشی از یک دیکشنری نمایش داده می‌شود. عملکرد این طبقه‌بندی‌کننده با شرکت دادن اطلاعات محتوایی که از پیکسل‌های همسایه بهبود پیدا می‌کند. از آنجایی که عملکرد این طبقه‌بندی‌کننده‌ها به میزان زیادی به دیکشنری آموزشی بستگی دارد.

در مقاله حاضر یک چهارچوب نوین برای طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی پیشنهاد شده است. ایده اولیه استفاده از ویژگی‌های مکانی به کمک برازش محلی رویه در تحقیق پیت و ساهوتا بر روی تصاویر معمولی ارائه شده است[۱۹]. در این روش با توجه به ابعاد همسایگی در اطراف هر پیکسل، رویه‌ای به سطح خاکستری تصویر برازش داده می‌شود و با محاسبه انحنا سطح ویژگی‌های مکانی تولید می‌شود. تحقیق پیش رو با بسط ایده تحقیق مذکور سعی در استفاده از این ویژگی به منظور طبقه‌بندی طیفی-مکانی تصاویر ابرطیفی دارد که بنا بر مطالعه نویسندگان در تحقیقات پیشین مورد توجه نبوده است. ساختار تحقیق به این صورت است که در قسمت دوم به مبانی نظری تحقیق پرداخته می‌شود که در آن طرز محاسبه ویژگی‌های برازش رویه معرفی می‌شود. در قسمت سوم طرح کلی تحقیق و روش پیشنهادی شرح داده می‌شود. در قسمت چهارم پس از معرفی دو داده ابرطیفی حقیقی مورد استفاده نتایج پیاده‌سازی‌ها ارائه

[1] *Moran's I*

[2] *Bayesian maximum a posteriori (MAP)*

[3] *Sparse representation*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

شده است. در قسمت آخر نیز نتیجه‌گیری و جمع‌بندی نهایی صورت می‌گیرد.

۲- مبانی نظری تحقیق

در این قسمت از تحقیق در ابتدا مروری بر روی روش‌های تولید ویژگی‌های مکانی انجام می شود و سپس روش پیشنهادی تحقیق با عنوان ویژگی‌های برازش محلی رویه شرح داده می‌شود.

۲-۱- روش‌های تولید ویژگی‌های مکانی

با بررسی دقیق پیشینه تحقیق می‌توان روش های استفاده از ویژگی‌های مکانی در طبقه بندی داده های ابرطیفی را به چهار دسته طبقه‌بندی کرد. دسته اول روش هایی هستند که به طور همزمان از ویژگی های مکانی و طیفی استفاده می‌کنند. مهم‌ترین رهیافت در این دسته شناسایی الگو کرنل-مبنا می‌باشد که در سالیان اخیر مورد توجه قرار گرفته‌اند[۲۰]. دسته دوم روش‌های هستند که سعی در مدل‌سازی کورلیشن مکانی پیکسل‌های تصویری بر مبنای میدان‌های تصادفی مارکوف دارند[۱۷]. دسته سوم مربوط به روش‌هایی می‌باشد که از اطلاعات مکانی در مرحله پس‌پردازش استفاده می‌کنند. به عنوان نمونه در تحقیق کانگ و همکاران از فیلتر های حافظ لبه به منظور افزایش دقت طبقه بندی استفاده شده است[۲۱]. دسته چهارم که روش تحقیق حاضر نیز در آن قرار می‌گیرد به مجموعه روش‌هایی اطلاق می‌شود که در آنها ویژگی های مکانی قبل از پروسه طبقه‌بندی و طی یک مرحله استخراج ویژگی تولید می‌شوند. چند نمونه از این ویژگی‌ها در ادامه به طور مختصر معرفی شده اند.

- ماتریس همرخداد: این یکی از مشهورترین روش تولید ویژگی‌های بافتی است. در این روش یک پنجره در اطراف هر پیکسل در نظر گرفته می‌شود و ماتریس همرخداد در آن پنجره ساخته می‌شود که هر درایه این ماتریس *(i,j)* نشان دهنده تعداد پیکسل‌های موجود در پنجره مورد نظر است که دارای سطح خاکستری *i* و *j* بوده و در فاصله و زاویه مشخصی از یکدیگر قرار دارند. پس از محاسبه ماتریس همرخداد تعدادی از ویژگی‌ها نظیر میانگین، انحراف معیار ، هموژنیتی و ... به عنوان ویژگی‌های بافتی استخراج می‌شوند.
- پروفایل‌های مورفولوژی: مورفولوژی ریاضی یکی از ابزار های مورد استفاده در پردازش تصویر است که به کمک آن می‌توان عوارض گوناگون موجود در تصویر را با توجه به شکل و اندازه‌شان استخراج کرد. اتساع[1] و فرسایش[2] دو عملگر پایه‌ای در موفولوژی ریاضی هستند. فرسایش (\ اتساع) یک تصویر با استفاده از یک المان ساختاری با ابعاد مشخص سبب می‌شود که عوارض یا نواحی روشن‌تر (\ تاریک‌تر) کوچکتر شوند. دو عملگر گشایش و بستن نیز با ترکیب روش‌های پایه فرسایش و اتساع تعریف می‌شود که نقش پایه‌ای در تعریف پروفایل‌های مورفولوژی دارند. اما باید توجه داشت از آنجایی که عملگر های فوق متصل نیستند[3]، استفاده از آنها سبب می‌شود که شکل عوارض استخراج شده حفظ نشود و گاها عوارض در هم ترکیب شوند. از این رو در پروفایل‌های مورفولوژی از مفهوم گشایش و بستن با بازسازی استفاده می‌شود که در این روش‌ها عوارض موجود بنا به ابعاد المان ساختاری یا کاملا حذف می‌شود یا کاملا حفظ می‌شوند[۲۲].
- فیلتر گابور: در پردازش تصویر و به منظور استخراج ویژگی‌های مکانی از فیلتر گابور به منظور اخذ خصوصیات محلی‌سازی در هر دو دامنه مکان و فرکانس استفاده می‌شود. این فیلتر به صورت کالنولوشنی بوده عموما در جهات و مقیاس‌های گوناگون بر روی تصویر اعمال می‌شود. پاسخ ضربه[4] فیلتر گابور به صورت حاصل ضرب یک تابع سینوسی در یک تابع گوسی می‌باشد. جهت اطلاعات بیشتر به

[1] *Dilation*
[2] *Erosion*
[3] *Connected operators*
[4] *Impulse response*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

تحقیق ایمانی و قاسمیان مراجعه شود[۲۳].

- گشتاورهای هندسی : در پردازش تصویر گشتاور هندسی از مرتبه $m+n$ از رابطه (۱) استفاده می‌شود.

$$M_{m,n} = \sum_{i=1}^{K}\sum_{j=1}^{K} i^m j^n G(i,j) \qquad \text{رابطه(۱)}$$

که در رابطه(۱) K ابعاد معین شده پنجره حول هر پیکسل توسط کاربر و G سطح خاکستری تصویر است. باید توجه داشت که بنا بر تحقیق کومار و همکاران ویژگی‌های نهایی پس از یک مرحله اعمال فیلتر مکانی اختلاف انحراف میانگین‌ها بر روی تصاویر گشتاور هندسی، استخراج می‌شود[۱۳].

- فیلتر *Law*: یکی از روش‌های تولید ویژگی‌های مکانی است که بر مبنای یکسری فیلترهای کانولوشنی کار می‌کند[۲۴]. در این روش از ضرب ترکیب‌های گوناگون بردارهای یک بعدی در هم ماسک‌هایی تولید می‌شوند. عموما از بردارهای سه مؤلفه‌ای [*1 2 1*] ، [*-1 0 1*] ، [*-1 2 -1*] و پنج مؤلفه‌ای *[1 4 6 4 1]*، *[-1 -2 0 2 1]*، *[-1 0 2 0 -1]*، *[1 2 0 2 1]*، *[-1 2 0 2 -1]* برای تولید این ویژگی‌های استفاده می‌شود.

۲-۲- تولید ویژگی‌های برازش محلی رویه

از آنجایی که مفهوم بافت تصویر با نرخ تغییرات مقادیر پیکسل‌ها نسبت به مختصات در ارتباط است، به نظر می‌رسد که انحنای سطح می‌تواند به خوبی بیانگر مفهوم بافت تصویر باشند[۱۹]. سطح خاکستری تصویر را می‌توان سطحی دو بعدی در فضای سه بعدی در نظر گرفت که دو محور آن شامل مختصات مکانی و محور سوم شدت را نشان می‌دهد. از این رو می‌توان این سطح را به کمک مفاهیم هندسه دیفرانسیل مورد بررسی قرار داد. یک همسایگی ۳×۳ را در اطراف یک پیکسل فرض کنید و سیستم مختصات را به صورت رابطه (۲) در نظر بگیرید (x,y):

$$\begin{matrix} (1,1) & (1,2) & (1,3) \\ (2,1) & (2,2) & (2,3) \\ (3,1) & (3,2) & (3,3) \end{matrix} \qquad \text{رابطه (۲)}$$

برای هر پیکسل یک مقدار درجه خاکستری $z(x,y)$ قابل تصور است که اگر بخواهیم آن را متناظر با سیستم مختصات بالا نشان دهیم به صورت رابطه (۳) در می‌آید:

$$\begin{matrix} z_1 & z_2 & z_3 \\ z_4 & z_5 & z_6 \\ z_7 & z_8 & z_9 \end{matrix} \qquad \text{رابطه(۳)}$$

حال تابعی به صورت رابطه (۴) را بر این سطح خاکستری برازش می‌دهیم:

$$z(x,y) = ax^2 + bxy + cy^2 + dx + fy + g \qquad \text{رابطه(۴)}$$

به منظور محاسبه ضرایب معادله فوق از تئوری کمترین مربعات استفاده می‌کنیم. با در نظر داشتن طرز نمایش ماتریسی معادله فوق را می‌توان به صورت رابطه (۵) نمایش داد:

$$Z = XA \qquad \text{رابطه(۵)}$$

که در فرم باز شده، عبارت فوق به صورت رابطه (۶) است:

$$\begin{bmatrix} z_1 \\ z_2 \\ z_3 \\ . \\ . \\ . \\ z_n \end{bmatrix} = \begin{bmatrix} x_1^2 & x_1y_1 & \dots & 1 \\ x_2^2 & x_2y_2 & \dots & 1 \\ x_3^2 & x_3y_3 & \dots & 1 \\ . & . & . & . \\ . & . & . & . \\ . & . & . & . \\ x_n^2 & x_ny_n & \dots & 1 \end{bmatrix} \begin{bmatrix} a \\ b \\ . \\ . \\ . \\ g \end{bmatrix} \qquad \text{رابطه(۶)}$$

برای به دست آوردن ماتریس مجهول ضرایب A از رابطه رابطه (۷) استفاده می‌شود:

$$A = (X^T X)^{-1} X^T Z \qquad \text{رابطه(۷)}$$

با توجه به اینکه شش ضریب مجهول وجود دارد و هر پیکسل در همسایگی یک رابطه می‌دهد به حداقل شش نقطه برای حل معادله (۶) نیاز داریم از این رو با در نظر گرفتن حداقل ابعاد پنجره ۳×۳ این شرط همواره برقرار است. هر نقطه بر روی سطح برازش داده شده را می توان با استفاده از بردار موقعیت رابطه (۸) نمایش داد:

$$R(x,y) = x\vec{i} + y\vec{j} + z(x,y)\vec{k} \qquad \text{رابطه(۸)}$$

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

نقطه فرضی M با بردار موقعیت R و یک نقطه بینهایت نزدیک به آن بردار موقعیت $R+dR$ را بر روی رویه در نظر بگیرید. بردار فاصله میان این دو نقطه (dR) را می‌توان به صورت رابطه (۹) بازنویسی کرد:

$$dR = R_x dx + R_y dy$$ رابطه(۹)

که R_x و R_y مشتق‌ها نسبت به x و y هستند. فرم اول اساسی از حاصل ضرب داخلی dR در خودش به صورت رابطه (۱۰) دست می‌آید.

$$I = dR.dR = dR^2 = E\,dx^2 + 2\,F\,dx\,dy + G\,dy^2$$ رابطه(۱۰)

که در عبارت فوق ضرایب E ، F و G را ضرایب فرم اول اساسی می‌گویند و به صورت روابط (۱۱و۱۲و۱۳) به دست می‌آیند.

$$E = 1 + (\frac{\partial z}{\partial x})^2$$ رابطه(۱۱)

$$F = \frac{\partial z}{\partial x}\frac{\partial z}{\partial y}$$ رابطه(۱۲)

$$G = 1 + (\frac{\partial z}{\partial y})^2$$ رابطه(۱۳)

فرم اول اساسی بیانگر هندسه درونی سطح است و از آن در محاسبه طول خم طول مسیرها بر روی صفحه و مساحت ناحیه استفاده می‌شود. باید توجه داشت که مشتقات بکار رفته در روابط فوق مشتق تابع $z(x,y)$ نسبت به متغیر مورد نظر در پیکسل مرکزی پنجره می‌باشد.

دومین فرم اساسی سطح که به کمک آن می‌توان انحنای سطح را تعیین کرد به صورت رابطه (۱۴) تعریف می‌شود *[۱۷]* که در این رابطه، N بردار قائم بر سطح می‌باشد که به صورت رابطه (۱۵) محاسبه می‌شود. با باز کردن رابطه (۱۴) به رابطه (۱۶) می‌رسیم:

$$II = -dR.dN = -(R_x dx + R_y dy).\left(N_x dx + N_y dy\right)$$ رابطه(۱۴)

$$N = \frac{R_x \times R_y}{\left|R_x \times R_y\right|}$$ رابطه(۱۵)

$$II = (-R_x.N_x)dx^2 + (-R_x.N_y - R_y.N_x)dx\,dy + (-R_y.N_y)dy^2$$ رابطه(۱۶)

با توجه به این که بردار قائم بر سطح، عمود بر بردار مشتقات R است؛ پس $R_x.N = 0$ و $R_y.N = 0$ است. با مشتق‌گیری از طرفین $R_x.N = 0$ و $R_y.N =$ خواهیم داشت:

$$R_{xx}.N + N_x.R_x = 0$$ رابطه(۱۷)

$$R_{yy}.N + N_y.R_y = 0$$ رابطه(۱۸)

$$R_{yx}.N + N_x.R_y = 0$$ رابطه(۱۹)

$$R_{xy}.N + N_y.R_x = 0$$ رابطه(۲۰)

با توجه به روابط بالا رابطه دومین فرم اساسی به صورت رابطه (۲۱) می باشد.

$$II = e\,dx^2 + 2\,f\,dx\,dy + g\,dy^2$$ رابطه(۲۱)

$$e = \frac{\frac{\partial^2 z}{\partial x^2}}{\sqrt{EG - F^2}}$$ رابطه(۲۲)

$$f = \frac{\frac{\partial^2 z}{\partial x \partial y}}{\sqrt{EG - F^2}}$$ رابطه(۲۳)

$$g = \frac{\frac{\partial^2 z}{\partial y^2}}{\sqrt{EG - F^2}}$$ رابطه(۲۴)

با در نظر داشتن روابط فوق، حال می‌توان ویژگی‌های انحنای سطح را محاسبه کرد. در پیت و ساهوتا ۱۱ نوع ویژگی انحنای سطح به منظور

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

کمّی‌سازی بافت معرفی شده است(جدول (۱)) [۱۹].

۳- روش تحقیق

فلوچارت کلی تحقیق در شکل (۱) نشان داده شده است که در ادامه به توضیح هر کدام از بخش‌های آن می‌پردازیم.

جدول ۱: ویژگی‌های انحنا

نام انحنا	رابطه
K_1	$\frac{gE - 2Ff + Ge - \left[\left(gE + Ge - 2Ff\right)^2 - 4\left(eg - f^2\right)\left(EG - F^2\right)\right]^{\frac{1}{2}}}{2\left(EG - F^2\right)}$
K_2	$\frac{gE - 2Ff + Ge + \left[\left(gE + Ge - 2Ff\right)^2 - 4\left(eg - f^2\right)\left(EG - F^2\right)\right]^{\frac{1}{2}}}{2\left(EG - F^2\right)}$
K_3	K_1K_2
K_4	$\frac{K_1 + K_2}{2}$
K_5	$\frac{K_2 - K_1}{2}$
K_6	$\max(\lvert K_1\rvert, \lvert K_2\rvert)$
K_7	$\min(\lvert K_1\rvert, \lvert K_2\rvert)$
K_8	$\lvert K_1\rvert$
K_9	$\lvert K_2\rvert$
K_{10}	$\frac{K_9 + K_8}{2}$
K_{11}	$\frac{K_9 - K_8}{2}$

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

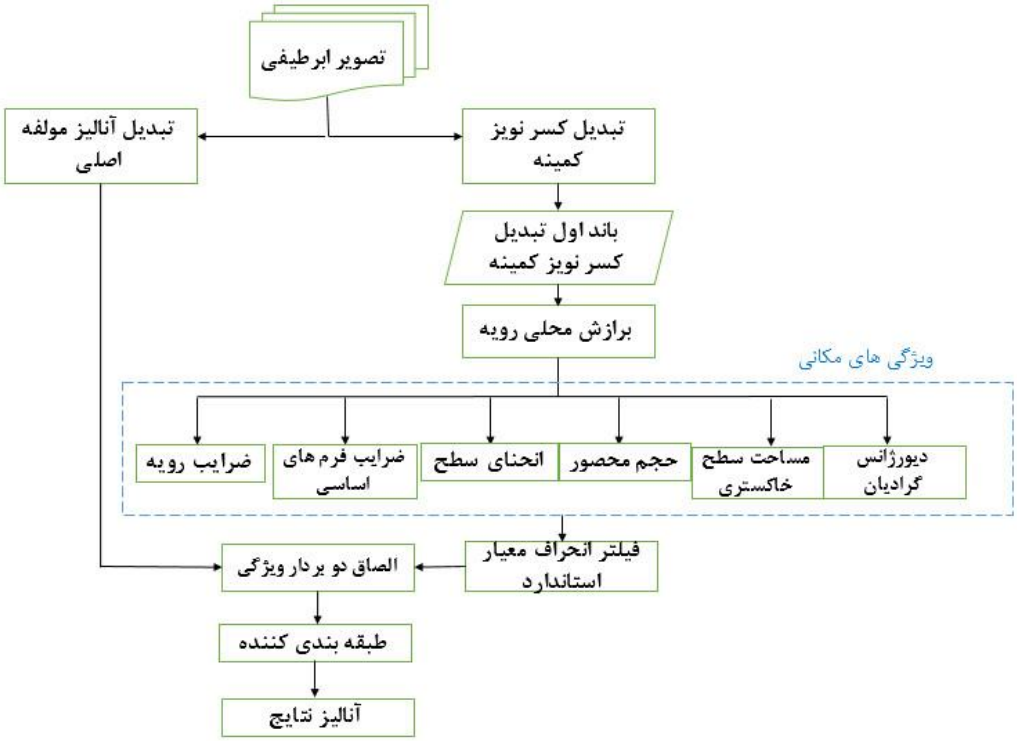

شکل ۱: فلوچارت کلی تحقیق

تبدیل مؤلفه اصلی[1] (*PCA*) به عنوان یک روش نظارت‌نشده استخراج ویژگی را شاید بتوان به عنوان یکی از ساده‌ترین و در عین حال مهم‌ترین روش‌های استخراج ویژگی به شمار آورد. در این مقاله از این روش برای استخراج ویژگی‌های طیفی استفاده شده است. پس از اعمال تبدیل *PCA* از n مؤلفه اول که دارای ۹۹/۹درصد واریانس هستند به عنوان ویژگی‌های طیفی استفاده شده است. همچنین، از آنجایی که تولید ویژگی‌های مکانی از تمام باندهای تصویر ابرطیفی از سویی سبب افزایش بسیار زیاد تعداد ویژگی‌های مکانی تولیدی و از سوی دیگر مستلزم صرف زمان زیاد است، در ابتدا یک مرحله کاهش بعد بر روی تصویر ابرطیفی اعمال شده است. در مقاله حاضر از مؤلفه اول تبدیل کسر نویز کمینه[2] (*MNF*) به منظور تولید ویژگی‌های مکانی استفاده شده است. در مقاله حاضر ویژگی‌های مکانی استخراج شده شامل ضرایب رویه برازش داده شده، ضرایب فرم‌های اساسی اول و دوم ، انحناهای سطح، دیورژانس گرادیان، حجم محصور در زیر رویه و مساحت سطح خاکستری است. طریقه محاسبه ضرایب رویه و فرم‌های اساسی اول و دوم و انحناهای سطح پیشتر در قسمت۲-۲ معرفی شد. در ادامه به معرفی سه ویژگی دیورژانس گرادیان، حجم محصور در زیر رویه و مساحت سطح خاکستری که در تحقیق حاضر به عنوان روش‌های کمی‌سازی بافت پیشنهاد شده‌اند، می‌پردازیم.

دیورژانس گرادیان با استفاده از ضرایب به دست آمده سطح به صورت رابطه (۲۵) محاسبه می‌شود [۲۵]:

$$\mathrm{div}\left(\mathrm{grad}\left(z\left(x,y\right)\right)\right)=2\left(a+c\right) \qquad \text{رابطه(۲۵)}$$

همچنین حجم محصور در زیر سطح برازش داده شده را می‌توان به کمک مفهوم انتگرال دوگانه نمایش داده شده در رابطه(۲۶) محاسبه کرد[۲۶]:

[1] *Principal component Analysis*
[2] *Minimum noise fraction*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

$$\iint_{x,y=1}^{kernelsize} z(x,y)\,dxdy$$ رابطه(۲۶)

مساحت سطح خاکستری نیز به عنوان آخرین ویژگی تولیدی در این مقاله در نظر گرفته شده است[۲۷]. در نظر بگیرید که می‌خواهیم بعد مساحت سطح خاکستری را در یک پنجره‌ی با ابعاد مشخص حول یک پیکسل محاسبه کنیم. این پنجره به وسیله یک سری مربع های پوششی با ابعاد ۱×۱ مانند شکل(۲) پوشش داده می‌شود.

در هر مربع کوچک با استفاده از مقدار ارتفاع پیکسل‌های چهار گوشه, (A,B,C,D) مقدار ارتفاع پیکسل مرکزی (A)درونیابی می‌شود (مطابق شکل(۳)).

با استفاده از مختصات‌های سه بعدی برای چهار نقطه گوشه و یک نقطه میانی درون‌یابی شده، مساحت رویه بالایی در هر مربع کوچک از حاصل جمع چهار مثلث محاسبه می‌شود. در یک مثلث سه بعدی فرضی اگر راس‌های مثلث با A و B و C و ضلع $AB=(x_1,x_2,x_3)$ و $AC=(y_1,y_2,y_3)$ نمایش داده شود، مساحت توسط رابطه(۲۷) محاسبه می شود.

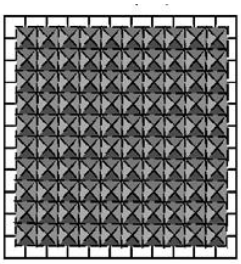

شکل۲: طرز قرارگیری مربع های پوششی [۲۷]

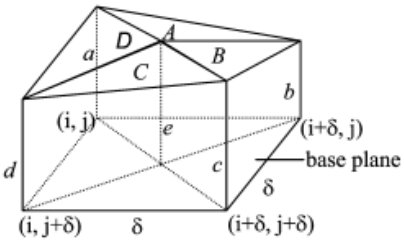

شکل ۳: درون یابی پیکسل مرکزی با استفاده از پیکسل های گوشه [۲۸]

$$S=\frac{1}{2}\sqrt{\left(x_2.y_3-x_3.y_2\right)^2+\left(x_3.y_1-x_1.y_3\right)^2+\left(x_1.y_2-x_2.y_1\right)^2}$$ رابطه(۲۷)

در واقع رابطه سه بعدی هرون[1] برای محاسبه مساحت به صورت رابطه (۲۷) می باشد. از حاصل جمع مساحت رویه هر مربع کوچک می‌توان به تقریبی از مساحت رویه کلی رسید.

پس از تولید ویژگی‌های مکانی فوق در هر اندازه پنجره، یک فیلتر انحراف معیار استاندارد برای استخراج ویژگی‌های نهایی به کار برده می‌شود که به صورت رابطه (۲۸) تعریف می شود:

[1] *Heron*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

$$S = \sqrt{\frac{1}{N-1}\sum_{i=1}^{N}|A_i-\mu|^2}$$ رابطه(۲۸)

در رابطه فوق، N تعداد پیکسل های موجود در پنجره اطراف هر پیکسل و A_i مقادیر درجات خاکستری هر پیکسل و μ میانگین مقادیر پیکسل ها در هر پنجره می باشد. باید توجه داشت که ابعاد این فیلتر لزوما برابر با ابعاد پنجره در نظر گرفته شده برای تولید ویژگی‌های مکانی نیست ولی در مقاله حاضر این ابعاد پنجره‌ها برابر در نظر گرفته شده‌اند.

در مجموع از آنجایی که روش استخراج ویژگی مکانی ارائه شده در این مقاله که از این به بعد آن را $LSFFs$[1] می‌نامیم، یک روش پنجره مبنا است، می توان این ویژگی‌ها را در ابعاد پنجره‌های گوناگون تولید کرد. در مجموع در هر ابعاد پنجره ۲۶ ویژگی مکانی شامل ۶ ضریب برازش محلی رویه، ۶ ضریب فرم اساسی اول و دوم ، ۱۱ ویژگی انحنا ،۱ ویژگی دیورژانس گرادیان، ۱ ویژگی انتگرال سطح و ۱ ویژگی مساحت رویه استخراج می‌شود. در مقاله حاضر این ویژگی‌ها در پنجره‌هایی با ابعاد ۳×۳ و ۹×۹ و ۱۵×۱۵ و ۲۱×۲۱ تولید می‌شوند که در مجموع ۱۰۴ ویژگی تولید می‌شود. بردار ویژگی‌های طیفی و مکانی تولید شده در کنار یکدیگر قرار می‌گیرند و بردار حاصل به طبقه‌بندی‌کننده داده می‌شود. روش الصاق[2] دو بردار ویژگی یکی از ساده‌ترین روش‌های تلفیق ویژگی است که در تحقیقات گوناگونی مورد توجه بوده است[۱۳].

۴- نتایج تجربی و بحث

در این قسمت از تحقیق در ابتدا دو داده‌ی ابرطیفی طبیعی مورد استفاده در آزمایش‌ها معرفی می‌شود. پس از آن نکات لازم در تنظیم پارامترهای تاثیرگذار روش تحت زیربخشی با نام ملاحظات پیاده سازی آورده شده است. در دو زیر بخش انتهایی نیز نتایج و آنالیز آنها ارائه شده است.

۴-۱- داده‌های مورد استفاده

اولین داده مورد استفاده در این مقاله تصویر اخذ شده توسط سنجنده هوابرد اویریس[3] از منطقه ایندین پاین[4] در شمال غربی ایالت ایندیانا در ایالات متحده آمریکا در تاریخ ۱۲ ژوئن ۱۹۹۲ است. این تصویر با حد تفکیک مکانی ۲۰ متر دارای ابعاد ۱۴۵×۱۴۵ پیکسل و ۲۲۴ باند طیفی در محدوده ۰/۴ تا ۲/۵ میکرومتر با پهنای باند ۱۰ نانومتر می‌باشد. حدود دو-سوم این تصویر را مناطق کشاورزی و یک-سوم آن را جنگل و گیاه در برگرفته است. همچنین در این تصویر نواحی ساختمانی، خط ریل و دو اتوبان دو لایه و جاده‌های کوچکی نیز به چشم می‌خورد. با حذف ۲۴ باند در محدوده‌های جذبی بخار آب با شماره‌های [۱۰۴-۱۰۸], [۱۵۰-۱۶۳], ۲۲۰ از بقیه ۲۰۰ باند باقی‌مانده در پردازش‌های این پژوهش استفاده شده است. این منطقه شامل شانزده کلاس از گیاهانی نظیر ذرت، سویا، علف و گندم و غیره است. در این تصویر به گونه‌های مختلف گیاهی با امضاهای طیفی نزدیک به هم از کلاس‌های ذرت و سویا وجود دارد که کار طبقه‌بندی را مشکل می‌کند. این تصویر به طور کلی ابعاد بزرگی ندارد و فاصله مکانی پوشش‌های مختلف زمینی بسیار کم است که این موضوع تعداد پیکسل‌های آمیخته را افزایش می‌دهد و طبقه‌بندی را با چالش مواجه می‌کند. مشکل دیگر این است که در برخی از کلاس‌ها تعداد پیکسل بسیار کم و در برخی کلاس‌ها تعداد پیکسل‌ها بسیار زیاد است. با توجه به نکاتی که ذکر شد طبقه‌بندی این داده همواره در سنجش از دور چالش‌برانگیز بوده است؛ از این رو طبقه‌بندی این تصویر می‌تواند یک محک جدی برای روش پیشنهادی باشد. یک ترکیب رنگی کاذب و نقشه حقیقت زمینی این داده که توسط آزمایشگاه سنجش از دور دانشگاه پردو تهیه شده است در شکل(۴) نشان داده شده است.

[1] *Local surface fitting features*
[2] *Stacking*
[3] *AVIRIS*
[4] *Indian Pines*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

تصویر دوم نیز توسط سنجنده رسیس ۳ از شمال ایتالیا و دانشگاه پاویا در ابعاد ۶۱۰×۳۴۰ اخذ شده است. سنجنده مذکور دارای ۱۵۵ باند طیفی در محدوده ۴۳۰ تا ۸۶۰ نانومتر می‌باشد. پس از حذف ۱۲ باند نویزی از ۱۰۳ باند باقی‌مانده در این تحقیق استفاده شده است. حد تفکیک مکانی این تصویر ۱٫۳ متر و دارای ۹ کلاس اطلاعاتی مانند آسفالت، سایه و خاک لخت و... می‌باشد. طبقه‌بندی این تصویر به دلیل وجود کلاس‌های پیچیده شهری و نواحی تودرتوی مکانی چالش‌برانگیز است. تصویر با ترکیب رنگی کاذب و نقشه حقیقت زمینی این داده که نشان‌دهنده پراکندگی کلاس‌ها است در شکل(۵) نمایش داده شده است.

ب الف

شکل ۴: داده ایدین پاین الف- تصویر ترکیب رنگی کاذب ب- نقشه حقیقت زمینی

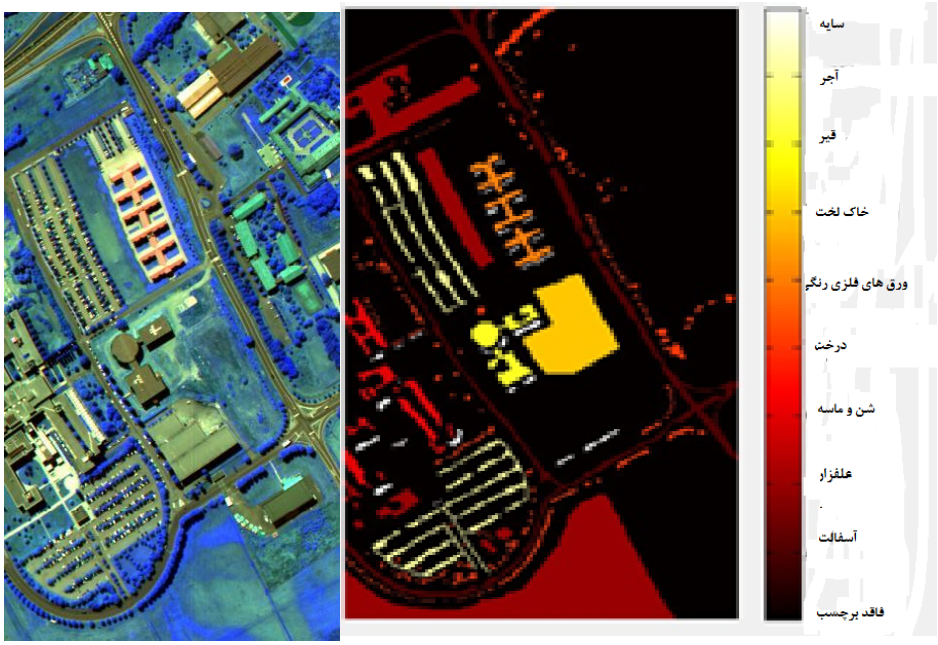

ب الف

شکل ۵: داده دانشگاه پاویا الف- تصویر ترکیب رنگی کاذب ب- نقشه حقیقت زمینی

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

۴-۲- ملاحظات پیاده‌سازی

بردار های طیفی- مکانی تولید شده بر مبنای روش پیشنهادی در ادامه به دو روش طبقه‌بندی نزدیکترین همسایگی[۱] *(KNN)* و بردار ماشین پشتیبان[۲] *(SVM)* داده می‌شوند. به منظور انجام این روش های طبقه‌بندی از نرم افزار متلب *2016b* استفاده شده است. در طبقه‌بندی‌کننده *SVM* از کرنل کیوبیک استفاده شده است.. در این مقاله ۵٪ و ۱۰٪ حقیقت زمینی در دو تصویر به طور تصادفی به عنوان داده‌ی آموزشی انتخاب شدند و الباقی پیکسل‌های حقیقت زمینی به عنوان نمونه‌های تست برای ارزیابی نهایی دقت طبقه‌بندی انتخاب شدند. پارامترهای طبقه‌بندی‌کننده *SVM* با روش جست و جوی شبکه[۳] و تکنیک کراس ولیدیشن پنج دسته[۴] اتخاب شده‌اند. در این تکنیک داده آموزشی به ۵ دسته با تعداد برابر تقسیم می شوند که چهار دسته از آنها به عنوان دسته‌ی آموزش [۵] (۸۰ درصد داده آموزشی انتخاب شده) و ۱ دسته آن (۲۰ درصد داده آموزشی انتخاب شده) به عنوان دسته‌ی تست[۶] در نظر گرفته می شوند[۲۹]. باید در نظر داشت که الباقی نمونه‌های موجود در حقیقت زمینی (کل نمونه ها بجز نمونه‌های آموزشی) به عنوان داده تست تنها برای ارزیابی نهایی انتخاب شده‌اند و وارد پروسه کراس ولیدیشن نشده‌اند. همچنین فضای جست و جو برای پارامتر گاما و C در طبقه‌بندی SVM $[2^{-5} - 2^{5}]$ در نظر گرفته شده است. از سه روش دقت کلی طبقه‌بندی، ضریب کاپا و دقت متوسط به برای ارزیابی عملکرد طبقه‌بندی‌کننده استفاده شده است (به منظور بررسی روابط این روش‌ها رجوع شود به [۱۵]).

به منظور ارزیابی روش کارایی روش پیشنهادی، این روش با شش روش رقیب مقایسه شده است که یکی از آنها تنها با ویژگی‌های طیفی و پنج روش دیگر جزء روش‌های طیفی-مکانی هستند. باید توجه داشت که در تمامی آزمایش‌ها داده‌های آموزشی و تست یکسان بوده است. پارامتر این روش‌ها در زیر معرفی شده است:

۱) ویژگی‌های طیفی[۷](*Spec*): همانطور که پیشتر عنوان شد به دلیل وجود باندهای همبسته و اضافی در تصاویر ابرطیفی یه منظور استخراج ویژگی‌های طیفی از تبدیل *PCA* استفاده شد و از n مؤلفه اول که شامل ۹۹٫۹ واریانس هستند به عنوان ویژگی‌های طیفی استفاده می‌شود. در تصویر ایندین پاین این تعداد برابر ۶۹ باند و در تصویر دانشگاه پاویا این تعداد برابر ۱۵ باند می‌باشد.

۲) ویژگی‌های ماتریس هم رخداد[۸] (*GLCM*): در این روش ۸ ویژگی مستخرج از ماتریس هم رخداد با نام‌های میانگین، واریانس، هموژنیتی، کنتراست، آنتروپی، عدم شباهت، کورلیشن و گشتاور مرتبه دوم با شیفت (۱و۱) در ابعاد پنجره ۳×۳ و ۹×۹ و ۱۵×۱۵ و ۲۱×۲۱ تولید می‌شوند که در مجموع ۳۲ ویژگی استخراج می‌شود.

۳) پروفایل‌های مورفولوژی[۹] (*MP*): برای تولید این پروفایل‌ها از عملگرهای مورفولوژی باز کردن و بستن با بازسازی با المان ساختاری دیسک شکل با اندازه‌های ۱ تا ۲۵ استفاده می‌شود[۱۶]. تعداد ویژگی‌های تولید شده در این روش ۵۰ می‌باشد.

۴) ویژگی‌های بانک فیلتر گابور[۱۰] (*gab*): به منظور تولید ویژگی‌های بانک فیلتر گابور از رهیافت ارائه شده درتحقیق میرزاپور و قاسمیان استفاده شده است[۳۰]. در این روش $N_d = 4$، $N_s = 6$، $U_h = 0.49$، $U_l = 0.01$ در نظر گرفته شده است و در مجموع ۲۴ ویژگی

[1] *K-nearest neighbour*
[2] *Support vector machine*
[3] *Grid search*
[4] *5-fold cross validation*
[5] *Training fold*
[6] *Testing fold*
[7] *Spectral features*
[8] *Gray level co-occurrence matrix*
[9] *Morphological Profiles*
[10] *Gabor filter bank*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

گابور تولید شده است.

۵) ویژگی‌های گشتاور هندسی[1] (*gmom*): در این روش که در تحقیق کومار و همکاران ارائه شده است گشاورهای هندسی تا مرتبه سوم در ابعاد پنجره‌های ۳×۳ و ۹×۹ و ۱۵×۱۵ و ۲۱×۲۱ تولید می‌شود[۱۳]. مجموع تعداد این ویژگی‌ها ۴۰ می‌باشد.

۶) فیلتر *Law* (*LF*): در این روش ماسک‌های تولید شده از ضرب ترکیب‌های گوناگون بردارهای یک بعدی در هم تولید می‌شوند. به طور کلی ۹ ویژگی با ماسک‌های سه مولفه‌ای و ۲۵ ویژگی با ماسک‌های پنج مولفه‌ای تولید می‌شود که در مجموع این روش ۳۴ ویژگی تولید می‌شود.

۴-۳- آنالیز نتایج

پس از تولید ویژگی‌های مکانی با روش‌های مختلف این ویژگی‌ها در کنار ویژگی‌های طیفی قرار می‌گیرند و بردار طیفی-مکانی حاصل به کمک دو طبقه‌بندی‌کننده *KNN* و *SVM* طبقه‌بندی می‌شوند. به منظور بررسی حساسیت روش‌ها به تعداد داده‌های آموزشی، دو اندازه مختلف ۵٪ و ۱۰٪ از کل پیکسل‌های حقیقت زمینی را برای داده‌های آموزشی مدنظر قرار داده‌ایم و از الباقی پیکسل‌های حقیقت زمینی به عنوان داده تست استفاده کرده‌ایم.

نتایج حاصل از طبقه‌بندی برای داده ایندین پاین در جدول (۲) نمایش داده شده است. همانطور که مشهود است طبقه‌بندی تنها با اطلاعات طیفی به نتایج نسبتا ضعیفی منجر شده است که این به علت نزدیکی رفتار طیفی میان کلاس‌های مختلف است. همچنین با توجه به ستون *Spec* می‌توان دید که طبقه‌بندی‌کننده *SVM* برای طبقه‌بندی ویژگی‌های طیفی بهتر از *KNN* عمل کرده است. در این داده اضافه شدن هر یک از ویژگی های مکانی سبب افزایش دقت کلی طبقه‌بندی شده است(ستون‌های ۵ و۶ و۷ و ۸و ۹ و۱۱) و *Spec+LSFFs* بجز در حالت طبقه‌بندی *SVM* با ۵٪ داده آموزشی که مغلوب روش *MP* شده است در باقی حالت همواره پیشرو بوده است. از این رو در این داده جدی‌ترین رقیب *Spec+LSFFs* روش *Spec+MP* و روش‌های *Spec+GLCM*و *Spec+gmom* در مراتب بعدی قرار دارند. در این داده بر عکس روش *Spec* برای روش *Spec+LSFFs* طبقه‌بندی‌کننده *KNN* نسبت به *SVM* عملکرد بهتری داشته است.

نتایج حاصل از طبقه‌بندی برای داده دانشگاه پاویا در جدول (۳) نمایش داده شده است. در این داده به‌طور کلی طبقه‌بندی‌کننده *SVM* عملکرد بهتری نسبت به *KNN* داشته است. همچنین اضافه کردن ویژگی *LF* به ویژگی‌های طیفی گاها در برخی موارد سبب افزایش دقت نشده است، این درحالی است که باقی روش‌ها در این مورد موفق‌تر عمل کرده‌اند. روش *Spec+LSFFs* به‌جز در حالت طبقه‌بندی ۵٪ داده آموزشی که مغلوب روش *Spec+MP* شده است در بقیه حالت‌ها موفق بوده است. البته باید توجه داشت که ضریب کاپا هر دو روش برای حالت ۵٪ در طبقه‌بندی *SVM* تقریباً یکسان بوده است. در این داده نیز همانند داده ایندین پاین جدی‌ترین رقیب *LSFFs* روش *MP* است. با مقایسه عملکرد هر دو طبقه‌بندی‌کننده در این داده می‌توان به این نتیجه رسید که اختلاف دقت *KNN* و *SVM* در حالت ۱۰٪ زیاد نیست و با توجه به عملکرد بهتر *KNN* در داده ایندین پاین و سرعت بالاتر این طبقه‌بندی‌کننده نسبت به *SVM* ، می‌توان گفت که طبقه‌بندی‌کننده *KNN* انتخاب مقرون به صرفه‌تری برای طبقه‌بندی با ویژگی‌های *LSFFs* است.

[1] *Geometric moment*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

جدول۲: دقت طبقه‌بندی برای تصویر ایندین پاین

داده آموزشی	طبقه‌بندی کننده	ارزیابی کننده دقت	*Spec*	*Spec+GLCM*	*Spec+MP*	*Spec+gab*	*Spec+gmom*	*Spec+LF*	*LSFFs*	*Spec+LSFFs*
٪۵	*KNN*	*AA*	۴۸٫۶۳	۶۳٫۸۶	۶۶٫۲۱	۶۴٫۵۵	۶۲٫۰۵	۵۲٫۱۸	۷۹٫۳۲	**۸۳٫۱۷**
		OA	۵۴٫۱۵	۶۷٫۹۳	۷۰٫۰۳	۶۵٫۹۶	۶۹٫۲۱	۵۶٫۷۵	۸۶٫۶۶	**۸۷٫۹۶**
		k	۰٫۴۸	۰٫۶۳	۰٫۶۶	۰٫۶۱	۰٫۶۵	۰٫۵۱	۰٫۸۵	**۰٫۸۶**
	SVM	*AA*	۴۸٫۳۵	۵۶٫۸۱	**۶۷٫۵۶**	۵۵٫۷۸	۴۹٫۵۹	۴۸٫۹۵	۶۲٫۸	۵۸٫۸۶
		OA	۶۷٫۸۰	۷۷٫۲۱	**۸۲٫۸۲**	۷۴٫۵۶	۷۰٫۵۳	۶۷٫۹۲	۷۹٫۹۰	۸۰
		k	۰٫۶۳	۰٫۷۴	**۰٫۸۰**	۰٫۷۱	۰٫۶۶	۰٫۶۳	۰٫۷۷	۰٫۷۷
٪۱۰	*KNN*	*AA*	۵۲٫۰۷	۷۱٫۱۲	۶۹٫۷۸	۶۹٫۴۸	۷۲	۵۷٫۵۵	۸۷٫۵	**۸۹٫۸۹**
		OA	۵۹٫۱۳	۷۴٫۲۹	۷۶٫۱۷	۷۲٫۱۷	۷۶٫۴۳	۶۱٫۱	۹۲٫۹۹	**۹۳٫۲۴**
		k	۰٫۵۳	۰٫۷۱	۰٫۷۳	۰٫۶۸	۰٫۷۳	۰٫۵۵	۰٫۹۲	**۰٫۹۲**
	SVM	*AA*	۵۳٫۸۲	۶۳٫۳۸	۷۰٫۷۱	۶۰٫۷۵	۶۰٫۹۴	۵۵٫۳۴	۸۲٫۶۵	**۷۱٫۳۱**
		OA	۷۱٫۹۸	۸۱٫۷۷	۸۶٫۵۷	۷۸٫۶۸	۷۸٫۹۹	۷۳٫۱۳	۹۱٫۷۶	**٫۳۳ ۸۸**
		k	۰٫۶۸	۰٫۷۹	۰٫۸۵	۰٫۷۵	۰٫۷۶	۰٫۶۹	۰٫۹۱	**۰٫۸۷**

جدول ۳: دقت طبقه‌بندی برای تصویر دانشگاه پاویا

داده آموزشی	طبقه‌بندی کننده	روش ارزیابی	*Spec*	*Spec+GLCM*	*Spec+MP*	*Spec+gab*	*Spec+gmom*	*Spec+LF*	*LSFFs*	*Spec+LSFFs*
٪۵	*KNN*	*AA*	۸۴٫۸۸	۸۴٫۵۱	**۹۶٫۱۵**	۸۹٫۸۸	۸۴٫۳۶	۸۰٫۷۰	۸۹٫۳۷	۹۳٫۱۳
		OA	۸۷٫۴۸	۸۷٫۱۵	**۹۷٫۰۸**	۹۱٫۴۱	۸۸٫۸۱	۸۳٫۶۹	۹۴٫۰۷	۹۵٫۹۰
		k	۰٫۸۳	۰٫۸۲	**۰٫۹۶**	۰٫۸۸	۰٫۸۵	۰٫۷۷	۰٫۹۲	۰٫۹۵
	SVM	*AA*	۸۷٫۹۲	۹۴٫۴۴	۹۵٫۹۸	۹۳٫۱۳	۹۲٫۱۱	۸۸٫۵۲	۸۵٫۵	**۹۶٫۱۹**
		OA	۹۱٫۱۲	۹۵٫۹۰	**۹۷٫۴۶**	۹۵٫۲۵	۹۴٫۲۷	۹۱٫۶۸	۹۱٫۴۵	۹۷٫۳۳
		k	۰٫۸۸	۰٫۹۴	**۰٫۹۶**	۰٫۹۳	۰٫۹۲	۰٫۸۹	۰٫۸۹	**۰٫۹۶**
٪۱۰	*KNN*	*AA*	۸۶٫۳۷	۹۵٫۶۹	۹۶٫۵۶	۹۳٫۵۱	۹۲٫۲۰	۸۳٫۰۷	۹۶٫۱۴	**۹۷٫۸۱**
		OA	۸۸٫۹۱	۹۷٫۱۳	۹۷٫۶۳	۹۴٫۱۹	۹۴٫۴۲	۸۵٫۵۴	۹۷٫۸۹	**۹۸٫۶۲**
		k	۰٫۸۵	۰٫۹۶	۰٫۹۷	۰٫۹۲	۰٫۹۲	۰٫۸۰	۰٫۹۷	**۰٫۹۸**
	SVM	*AA*	۹۰٫۴۵	۹۵٫۷۳	۹۶٫۸۸	۹۵٫۳۴	۹۴٫۴۳	۹۱٫۲۲	۹۲٫۹۴	**۹۸٫۲۶**
		OA	۹۲٫۹۴	۹۷٫۱۸	۹۸٫۰۸	۹۶٫۸۵	۹۶٫۲۰	۹۳٫۷۹	۹۶٫۱۶	**۹۸٫۸۳**
		k	۰٫۹۱	۰٫۹۶	۰٫۹۷	۰٫۹۶	۰٫۹۵	۰٫۹۲	۰٫۹۵	**۰٫۹۸**

با توجه به ستون دهم هر دو جدول(۲ و۳) که بیانگر دقت طبقه‌بندی تنها با ویژگی‌های مکانی *LSFFs* است و مقایسه آن با ستون چهارم یعنی طبقه‌بندی تنها با ویژگی‌های طیفی می‌توان به این نتیجه رسید که دقت طبقه‌بندی تنها با ویژگی‌های *LSFFs* بالاتر ار دقت طبقه‌بندی ویژگی‌های طیفی است که این خود بیانگر اهمیت بالای استفاده از ویژگی‌های مکانی در طبقه‌بندی داده‌های ابرطیفی است. همچنین با مقایسه ستون *LSFFs* و *Spec+LSFFs* می‌توان فهمید که در

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

عمده‌ی حالت‌ها ترکیب دو ویژگی طیفی و مکانی به سطوح بالاتری از دقت نسبت به طبقه‌بندی تنها با ویژگی‌های طیفی یا تنها با ویژگی‌های مکانی می‌رسد. شکل (۶) به طور خلاصه بهترین دقت‌های به دست آمده از روش‌های مختلف برای ۱۰٪ داده‌های آموزشی را نشان می‌دهد. همچنین تصاویر طبقه‌بندی شده روش‌های مختلف نیز در مقایسه با تصویر حقیقت زمینی برای دو داده به ترتیب در شکل(۷ و ۸) نمایش داده شده است.

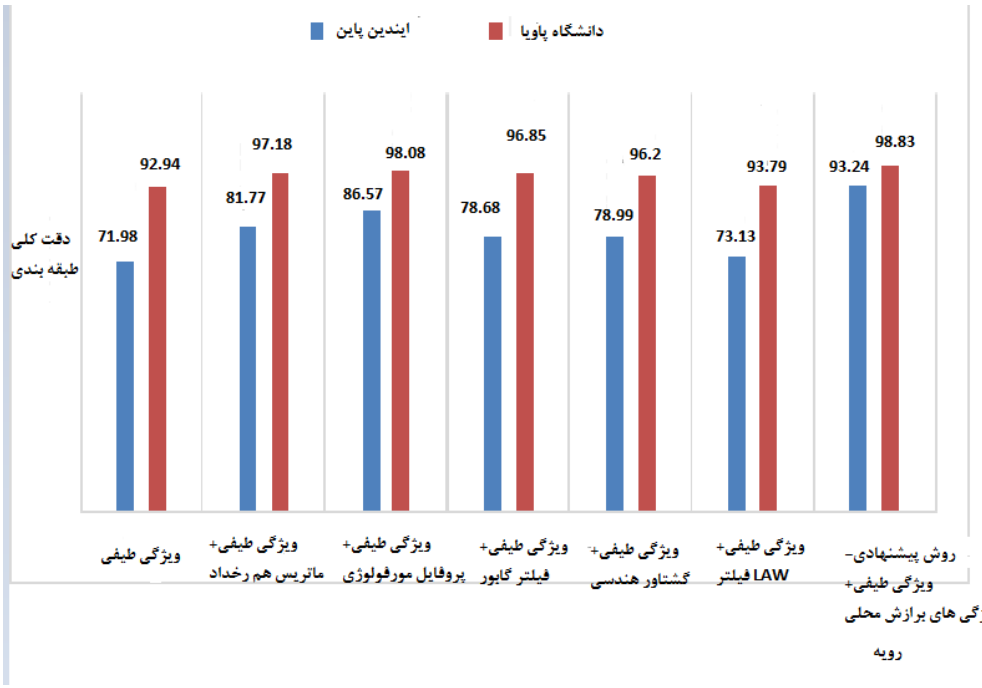

شکل ۶: خلاصه ای از نتایج طبقه بندی دو تصویر با ۱۰٪ داده آموزشی

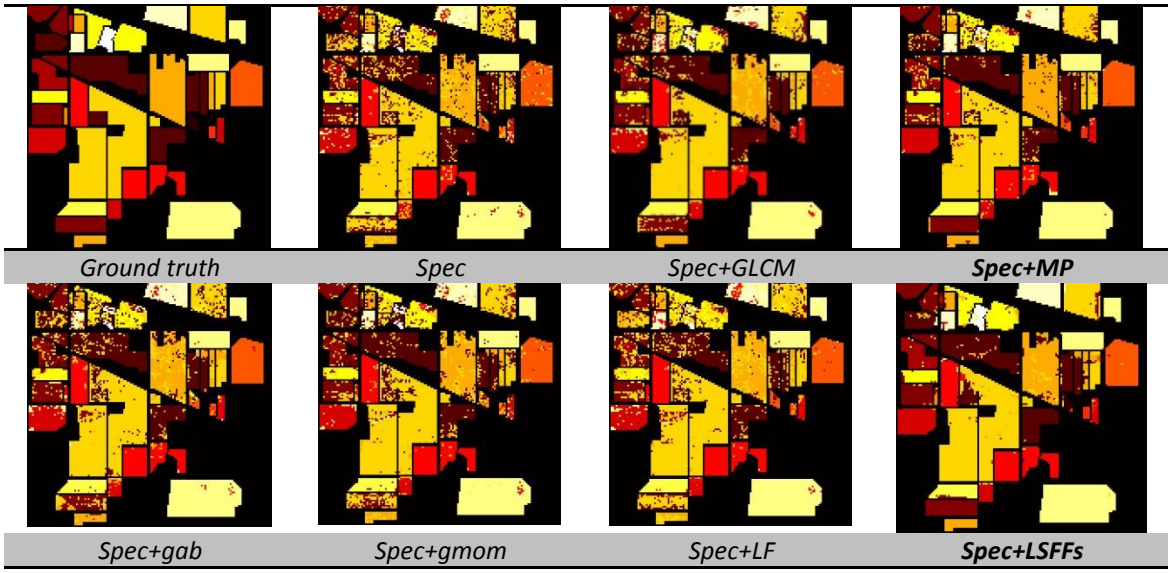

شکل ۷: تصاویر طبقه‌بندی شده حاصل از روش های مختلف برای داده ایندین پاین

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

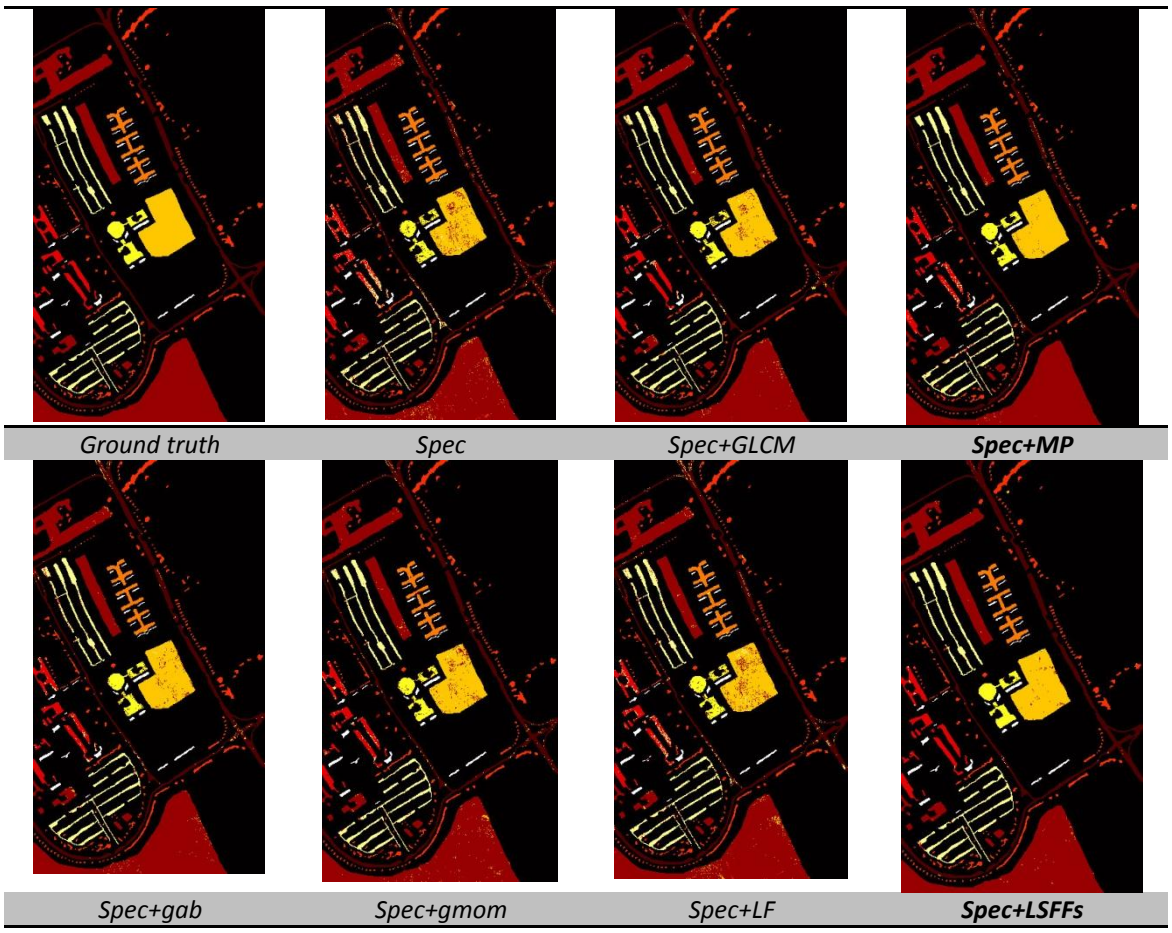

شکل ۸: تصاویر طبقه‌بندی شده حاصل از روش های مختلف برای داده دانشگاه پاویا

۴-۴- آنالیز زمان پردازش

در این قسمت زمان لازم برای تولید ویژگی‌های مکانی در روش‌های مختلف بررسی شده است. روش‌های مختلف در محیط نرم افزار متلب ۲۰۱۶ در سیستم کامپیوتری با مشخصات سی پی یو *Intel® Core™ Quad Q6700* با میزان کش ۸ مگابایت و ۴ گیگابایت رم پیاده سازی شده‌اند. جدول (۴) زمان سپری شده بر حسب ثانیه برای تولید ویژگی‌های مکانی در روش‌های مختلف برای تصویر ایندین پاین را نشان می‌دهد.

جدول ۴: زمان صرف شده برای تولید ویژگی های مکانی

روش	*GLCM*	*MP*	*GAB*	*GMOM*	*LF*	*LSFFS*
زمان (S)	۲۳۵٫۲	۱٫۴۲	۰٫۶۲	۴۵٫۶	۰٫۱۸	۶۲٫۳۵

از جدول(۴) می توان دریافت که تولید ویژگی‌های مکانی با روش‌های پروفایل‌های مرفولوژی، فیلتر گابور و فیلتر *Law* نیازمند زمان بسیار کمتری در مقایسه با روش *LSFFs*، *gmom* و *GLCM* است. علت این مسأله

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

به تفاوت‌های ماهیتی روش‌های مذکور برمی‌گردد. به عنوان نمونه، روش فیلتر *Law* به صورت کانولوشنی اجرا می‌شود که خود در مقایسه با روشی نظیر روش *LSFFs* که به صورت پنجره مبنا اجرا می‌شود، از سرعت بالاتری برخوردار است. با توجه به جدول فوق می‌توان گفت که روش *LSFFS* از لحاظ زمانی ۷۴٪ بهتر از روش *GLCM* و تنها ۲۷٪ کندتر از *gmom* است که علت آن نیز حجم محاسبات بالاتر در هر پنجره نسبت به روش *gmom* است.

۵- نتیجه‌گیری و پیشنهادات

در این مقاله روشی نوین برای تولید ویژگی‌های مکانی بر مبنای برازش محلی رویه به منظور طبقه‌بندی تصاویر ابرطیفی معرفی شده است. این ویژگی‌ها شامل ضرایب رویه، انحناها، ضرایب فرم‌های اساسی اول و دوم، دیورژانس گرادیان، حجم محصور زیر رویه و مساحت سطح خاکستری تصویر هستند. علاوه بر ویژگی‌های انحنای سطح که در تحقیقات پیشین برای آنالیز بافت تصاویر پیشنهاد شده است، در مقاله حاضر از خود ضرایب رویه برازش داده شده و ضرایب فرم‌های اساسی اول و دوم نیز به عنوان ویژگی‌های مکانی استفاده شده است. همچنین سه ویژگی دیورژانس گرادیان، حجم محصور در زیر رویه و مساحت سطح خاکستری تصویر به عنوان ویژگی‌های مکانی جدید در مقاله حاضر پیشنهاد شده است. در نوآوری دیگر در مقاله حاضر کلیه این ویژگی‌ها در ابعاد گوناگون پنجره از باند اول تبدیل *MNF* تولید شدند و عملکرد آنها در طبقه بندی تصاویر ابرطیفی هم به تنهایی و هم در ادغام با ویژگی‌های طیفی بررسی شده است. از ویژگی های پیشنهادی این مقاله در طبقه بندی دو تصویر ابرطیفی واقعی، در مورد اول از یک منطقه کشاورزی با حد تفکیک مکانی متوسط و دیگری از یک منطقه شهری با حد تفکیک بالا استفاده شده است. همچنین عملکرد ویژگی‌های پیشنهادی در افزایش دقت طبقه‌بندی با پنج روش دیگر استخراج ویژگی‌های مکانی مقایسه شده است و نتایج نهایی نشان از برتری روش پیشنهادی در عمده‌ی حالت‌های مورد آزمایش دارد. همچنین جدی‌ترین رقیب روش پیشنهادی را می‌توان پروفایل‌های مورفولوژی دانست که دقت طبقه‌بندی با روش پیشنهادی (با فرض ۱۰٪ داده آموزشی) در تصویر اول ۷ درصد و در تصویر دوم حدود ۱ درصد بیشتر از آن است.

در تحقیقات آتی می‌توان عملکرد ترکیبی روش پیشنهادی با دیگر ویژگی‌های مکانی را به منظور رسیدن به دقت‌های بالاتر مدنظر داشت. همچنین استفاده از مولفه‌های بیشتر *MNF* به منظور تولید ویژگی‌های *LSFFs* بیشتر با هدف رسیدن به دقت‌های بالاتر و ارائه روشی به منظور مدیریت ابعاد بردارهای ویژگی تولید شده نیازمند تحقیقات بیشتر است.

مراجع

[1] *I. Pesenson, Q.T. Le Gia, A. Mayeli, H. Mhaskar, D.X. Zhou, Recent Applications of Harmonic Analysis to Function Spaces. Differential Equations, and Data Science: Novel Methods in Harmonic Analysis 2, 2017.*

[2] *L.O. Jimenez, D.A. Landgrebe, "Supervised classification in high-dimensional space: geometrical, statistical, and asymptotical properties of multivariate data", IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews),Vol 28, p. 39-54, 1998.*

[3] *A. Plaza, P. Martinez, J. Plaza, R. Perez, "Dimensionality reduction and classification of hyperspectral image data using sequences of extended morphological transformations", IEEE Transactions on Geoscience and remote sensing,Vol 43, p. 466-479, 2005.*

[4] *B. Kumar, O. Dikshit, "Texture based hyperspectral image classification", The International Archives of Photogrammetry,*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

Remote Sensing and Spatial Information Sciences, Vol 40, p. 793, 2014.

[5] *Ö. Akar, O. Güngör, "Integrating multiple texture methods and NDVI to the Random Forest classification algorithm to detect tea and hazelnut plantation areas in northeast Turkey", International Journal of Remote Sensing, Vol 36, p. 442-464, 2015.*

[6] *F. Tsai, C. K. Chang, , J. Y. Rau, T. H Lin, G. R Liu, "3D Computation of Gray Level Co-occurrence in Hyperspectral Image Cubes", International Workshop on Energy Minimization Methods in Computer Vision and Pattern Recognition, Ezhou, 2007.*

[7] *L. Shen, Z. Zhu, S. Jia, J. Zhu, Y. Sun, "Discriminative Gabor Feature Selection for Hyperspectral Image Classification", IEEE Geoscience and Remote Sensing Letters, Vol. 10, p. 29-33, 2013.*

[8] *M. Fauvel, J. A.Benediktsson, J. Chanussot, J. R Sveinsson, "Spectral and Spatial Classification of Hyperspectral Data Using SVMs and Morphological Profiles", IEEE Transactions on Geoscience and Remote Sensing, Vol. 46, p. 3804-3814, 2008.*

[9] *P. Quesada-Barriuso, F. Arguello, D.B. Heras, "Spectral–Spatial Classification of Hyperspectral Images Using Wavelets and Extended Morphological Profiles", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 7, p. 1177-118, 2014.*

[10] *M. Dalla Mura, A. Villa, J. A. Benediktsson, J. Chanussot, L. Bruzzone, "Classification of Hyperspectral Images by Using Extended Morphological Attribute Profiles and Independent Component Analysis", IEEE Geoscience and Remote Sensing Letters, Vol. 8, p. 542-546, 2011.*

[11] *B. Kumar, O. Dikshit, "Integrating Spectral and Textural Features for Urban Land Cover Classification with Hyperspectral data", in Urban Remote Sensing Event (JURSE), 2015, Lausanne, Switzerland, 2015. IEEE.*

[12] *Z. Ye, S. Prasad, W. Li, J. E. Fowler, M. He, "Classification Based on 3-D DWT and Decision Fusion for Hyperspectral Image Analysis", IEEE Geoscience and Remote Sensing Letters, Vol. 11, p. 173-177, 2014.*

[13] *B. Kumar, O. Dikshit, "Spectral–Spatial Classification of Hyperspectral Imagery Based on Moment Invariants", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 8, p. 2457-2463, 2015.*

[14] *R.N. Marandi, H. Ghassemian, "A New Feature Fusion Method for Hyperspectral Image Classification", in Electrical Engineering (ICEE), 2017 Iranian Conference on, Tehran, Iran, 2017. IEEE.*

[15] *B.A. Beirami, M. Mokhtarzade, "SVM Classification of Hyperspectral Images Using the Combination of Spectral Bands and Moran's I Features", in Machine Vision and Image Processing (MVIP), 2017 10th Iranian Conference on, Isfahan, Iran , 2017. IEEE.*

[16] *F. Mirzapour, H. Ghassemian, "Improving Hyperspectral Image Classification by Combining Spectral, Texture, and Shape Features", International Journal of Remote Sensing, Vol. 36, p. 1070-1096, 2015.*

[17] *Z. Ye, J.E. Fowler, L. Bai, "Spatial–Spectral Hyperspectral Classification Using Local Binary Patterns and Markov Random Fields", Journal of Applied Remote Sensing, Vol. 11, p. 035002, 2017.*

[18] *Y. Chen, N.M. Nasrabadi, T.D. Tran, "Hyperspectral Image Classification Using Dictionary-Based Sparse Representation", IEEE Transactions on Geoscience and Remote Sensing, Vol. 49, p. 3973-3985, 2011.*

[19] *F. Peet, T. Sahota, "Surface curvature as a measure of image texture", IEEE transactions on pattern analysis and machine intelligence, Vol. 6, p. 734-738, 1985.*

[20] *G. Camps-Valls, L. Gomez-Chova, J. Muñoz-Marí, , J. Vila-Francés, J. Calpe-Maravilla, " Composite kernels for*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

hyperspectral image classification", IEEE Geoscience and Remote Sensing Letters, Vol 3, p. 93-97, 2006.

[21]X. Kang, S. Li, J.A. Benediktsson, " Spectral–spatial hyperspectral image classification with edge-preserving filtering", IEEE transactions on geoscience and remote sensing, Vol 52, p. 2666-2677, 2014.

[22]M. Fauvel, Y. Tarabalka, J. A.Benediktsson, J. Chanussot, J. C.Tilton, "Advances in spectral-spatial classification of hyperspectral images", Proceedings of the IEEE,Vol 101, p. 652-67, 2013.

[23]M. Imani, H. Ghassemian, "GLCM, Gabor, and morphology profiles fusion for hyperspectral image classification". in Electrical Engineering (ICEE), 2016 24th Iranian Conference on. 2016. IEEE.

[24]O.F. Ertugrul, "Adaptive Texture Energy Measure Method". arXiv preprint arXiv:1406.7075, 2014.

[25]R. Lai, Computational differential geometry and intrinsic surface processing, University of California, Los Angeles, 2010

[26]R.A. Adams, A complete course calculus, Addison-Wesley Publishers Limited ,1995

[27]W. Ju, N.S.-N. Lam, "An Improved Algorithm for Computing Local Fractal Dimension Using the Triangular Prism Method", Computers & Geosciences, Vol. 35, p. 1224-1233, 2009.

[28]W. Sun, G. Xu, P. Gong, S. Liang, "Fractal Analysis of Remotely Sensed Images: A Review of Methods and Applications", International Journal of remote sensing, Vol. 27, p. 4963-4990, 2006.

[29]Mathworks.ClassificationPartitionedModel class. 2018 [cited 2018],

[30]F. Mirzapour, H. Ghassemian, "Using GLCM and Gabor Filters for Classification of PAN Images". in Electrical Engineering (ICEE), 2013 21st Iranian Conference on, Mashhad, Iran, 2013. IEEE.

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]

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

Journal of Geospatial Information Technology
Vol.8 No.2, Summer 2020

Research Paper

Hyperspectral Images Classification by Combination of Spatial Features Based on Local Surface Fitting and Spectral Features

Behnam Asghari Beirami[1*], Mehdi Mokhtarzadeh [2]

1- Ms.c of Remote sensing, Geomatics Engineering Faculty. K.N. Toosi University of Technology
2- Associate professor in Geomatics Engineering Faculty. K.N. Toosi University of Technology

Abstract

Hyperspectral sensors are important tools in monitoring the phenomena of the Earth due to the acquisition of a large number of spectral bands. Hyperspectral image classification is one of the most important fields of hyperspectral data processing, and so far there have been many attempts to increase its accuracy. Spatial features are important due to their ability to increase classification accuracy. In the present paper, a new method is proposed for the spatial features generation of hyperspectral images based on local surface fitting technique. In this method, a surface is fitted to the gray level intensity of the image in the local window around each pixel, and the fitted coefficients, the coefficients of the first and second fundamental forms, curvatures, divergence of the gradient, the area of the gray level intensity of the image and the volume enclosed below the surface are produced in the various window sizes as spatial features. Proposed spatial features stacked with spectral features and form the spectral-spatial vector. this rich spatial-spectral vector is classified with K-nearest neighbor and support vector machine classifiers. The experiments of this paper that are conducted on two real hyperspectral images in agricultural and urban areas show the superiority of the proposed method. The final results show that the overall accuracy of the proposed method in the best case is 7% higher than other competitor methods.

Key words: *Classification, Hyperspectral Images, Local Surface Fitting Features, Texture, Feature extraction.*

Correspondence Address *: The Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Mirdamad Blvd, Tehran, Iran.*
Tel *: 09355845636*
Email*: Behnam.Asghari1370@Gmail.com*

[Downloaded from jgit.kntu.ac.ir on 2026-01-31]
[DOR: 20.1001.1.20089635.1399.8.2.1.3]
[DOI: 10.29252/jgit.8.2.1]