

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

بهنام اصغری بیرامی<sup>۱\*</sup>، مهدی مختارزاده<sup>۲</sup>

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، انحنای سطح، دیورژانس گرادینان، 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.

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

\* نویسنده مکاتبه کننده: تهران - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی

تلفن: ۰۹۳۵۵۸۴۵۶۳۶

## ۱- مقدمه

سنجنده‌های ابرطیفی با اخذ تعداد زیادی از باندهای طیفی از نواحی فرابنفش تا اینفرارد<sup>۱</sup> 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 اثر حجم بالای اطلاعات طیفی اخذ شده بوجود می‌آید و از عوامل محدود کننده دقت طبقه‌بندی تصاویر ابرطیفی است پدیده بلای ابعادی<sup>۲</sup> 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 عمدتاً 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 کمی‌سازی 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<sup>۳</sup> هستند که 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 کمی‌سازی اطلاعات مکانی بخصوص برای تصاویر نویری دارد [۱۲]. اخیراً استفاده از گشتاورهای هندسی به منظور افزایش دقت طبقه‌بندی 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

<sup>1</sup> Infrared<sup>2</sup> Curse of dimensionality<sup>3</sup> Attribute

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<sup>۲</sup> به منظور طبقه‌بندی تصاویر ابرطیفی استفاده شده است.

در سالیان اخیر از روش‌های نمایش تنک<sup>۳</sup> 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 انحنای 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

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<sup>۱</sup> 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

<sup>2</sup> Bayesian maximum a posteriori (MAP)

<sup>3</sup> Sparse representation

<sup>1</sup> Moran's I

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 روش‌های تولید ویژگی‌های مکانی انجام می‌شود و سپس روش پیشنهادی تحقیق با عنوان ویژگی‌های پردازش محلی رویه شرح داده می‌شود.

### ۲-۱- روش‌های تولید ویژگی‌های مکانی

با بررسی دقیق پیشینه تحقیق می‌توان روش‌های استفاده از ویژگی‌های مکانی در طبقه‌بندی داده‌های ابرطیفی را به چهار دسته طبقه‌بندی کرد. دسته اول روش‌هایی هستند که به طور همزمان از ویژگی‌های مکانی و طیفی استفاده می‌کنند. مهم‌ترین رهیافت در این دسته شناسایی الگو کرنل-مینا 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 فیلترهای حافظ لبه به منظور افزایش دقت طبقه‌بندی استفاده شده است [۲۱]. دسته چهارم که روش تحقیق حاضر نیز در آن قرار می‌گیرد به مجموعه روش‌هایی اطلاق می‌شود که در آنها ویژگی‌های مکانی قبل از پروسه طبقه‌بندی و طی یک مرحله استخراج ویژگی تولید می‌شوند. چند نمونه از این ویژگی‌ها در ادامه به طور مختصر معرفی شده‌اند.

• 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، هموزنیتی و ... به عنوان ویژگی‌های بافتی استخراج می‌شوند.

• پروفایل‌های مورفولوژی: مورفولوژی ریاضی یکی از ابزارهای 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<sup>۱</sup> و فرسایش<sup>۲</sup> دو عملگر پایه‌ای در مورفولوژی ریاضی هستند. فرسایش ( $\setminus$  اتساع) یک تصویر با استفاده از یک المان ساختاری با ابعاد مشخص سبب می‌شود که عوارض یا نواحی روشن‌تر ( $\setminus$  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 عملگرهای فوق متصل نیستند<sup>۳</sup>، استفاده از آنها سبب می‌شود که شکل عوارض استخراج شده حفظ نشود و گاهی 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 کاملاً حذف می‌شود یا کاملاً 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 کالولوشنی بوده عموماً در جهات و مقیاس‌های گوناگون بر روی تصویر اعمال می‌شود. پاسخ ضربه<sup>۴</sup> فیلتر گابور به صورت حاصل ضرب یک تابع سینوسی در یک تابع گوسی می‌باشد. جهت اطلاعات بیشتر به

<sup>1</sup> Dilation

<sup>2</sup> Erosion

<sup>3</sup> Connected operators

<sup>4</sup> Impulse response

قابل تصور است که اگر بخواهیم آن را متناظر با سیستم مختصات بالا نشان دهیم به صورت رابطه (۳) در می آید:

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

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

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

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

$$Z = XA \quad \text{رابطه (۵)}$$

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

$$\begin{bmatrix} z_1 \\ z_2 \\ z_3 \\ \vdots \\ z_n \end{bmatrix} = \begin{bmatrix} x_1^2 & x_1 y_1 & \dots & 1 \\ x_2^2 & x_2 y_2 & \dots & 1 \\ x_3^2 & x_3 y_3 & \dots & 1 \\ \vdots & \vdots & \vdots & \vdots \\ x_n^2 & x_n y_n & \dots & 1 \end{bmatrix} \begin{bmatrix} a \\ b \\ \vdots \\ g \end{bmatrix} \quad \text{رابطه (۶)}$$

برای به دست آوردن ماتریس مجهول ضرایب  $A$  از رابطه رابطه (۷) استفاده می شود:

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

با توجه به اینکه شش ضریب مجهول وجود دارد و هر پیکسل در همسایگی یک رابطه می دهد به حداقل شش نقطه برای حل معادله (۶) نیاز داریم از این رو با در نظر گرفتن حداقل ابعاد پنجره  $3 \times 3$  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:

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

تحقیق ایمانی و قاسمیان مراجعه شود [۲۳].

• گشتاورهای هندسی: در پردازش تصویر گشتاور هندسی از مرتبه  $m+n$  از رابطه (۱) استفاده می شود.

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

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 ویژگی های نهایی پس از یک مرحله اعمال فیلتر مکانی اختلاف انحراف میانگین ها بر روی تصاویر گشتاور هندسی، استخراج می شود [۱۳].

• فیلتر  $Law$ : یکی از روش های تولید ویژگی های مکانی است که بر مبنای یکسری فیلترهای کانولوشنی کار می کند [۲۴]. در این روش از ضرب ترکیب های گوناگون بردارهای یک بعدی در هم ماسک هایی تولید می شوند. عموماً از بردارهای سه مؤلفه ای  $[1 \ 2 \ 1]$ ،  $[-1 \ 0 \ 1]$ ،  $[1 \ -1 \ 0 \ 1]$ ،  $[1 \ 4 \ 6 \ 4 \ 1]$  و پنج مؤلفه ای  $[1 \ 4 \ 6 \ 4 \ 1]$ ،  $[-1 \ 2 \ 0 \ 2 \ 0 \ -1]$ ،  $[-1 \ 0 \ 2 \ 0 \ -1]$ ،  $[-1 \ -2 \ 0 \ 2 \ 1]$ ،  $[1 \ -1 \ -1 \ 2 \ 0 \ 2 \ 1]$ ،  $[1 \ -1 \ 0 \ 2 \ 0 \ -1]$  برای تولید این ویژگی های استفاده می شود.

## ۲-۲- تولید ویژگی های برازش محلی رویه

از آنجایی که مفهوم بافت تصویر با نرخ تغییرات مقادیر پیکسل ها نسبت به مختصات در ارتباط است، به نظر می رسد که انحناى سطح می تواند به خوبی بیانگر مفهوم بافت تصویر باشند [۱۹]. سطح خاکستری تصویر را می توان سطحی دو بعدی در فضای سه بعدی در نظر گرفت که دو محور آن شامل مختصات مکانی و محور سوم شدت را نشان می دهد. از این رو می توان این سطح را به کمک مفاهیم هندسه دیفرانسیل مورد بررسی قرار داد. یک همسایگی  $3 \times 3$  را در اطراف یک پیکسل فرض کنید و سیستم مختصات را به صورت رابطه (۲) در نظر بگیرید  $(x, y)$ :

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

برای هر پیکسل یک مقدار درجه خاکستری  $z(x, y)$

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

فرم اول اساسی بیانگر هندسه درونی سطح است و از آن در محاسبه طول خم طول مسیره 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:

$$\Pi = -dR \cdot dN = -(R_x dx + R_y dy) \cdot (N_x dx + N_y dy) \quad \text{رابطه (۱۴)}$$

$$N = \frac{R_x \times R_y}{|R_x \times R_y|} \quad \text{رابطه (۱۵)}$$

$$\Pi = (-R_x \cdot N_x) dx^2 + (-R_x \cdot N_y - R_y \cdot N_x) dx dy + (-R_y \cdot N_y) dy^2 \quad \text{رابطه (۱۶)}$$

$$e = \frac{\partial^2 z}{\partial x^2} \quad \text{رابطه (۲۲)}$$

$$f = \frac{\partial^2 z}{\partial x \partial y} \quad \text{رابطه (۲۳)}$$

$$g = \frac{\partial^2 z}{\partial y^2} \quad \text{رابطه (۲۴)}$$

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

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:

$$dR = R_x dx + R_y dy \quad \text{رابطه (۹)}$$

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.

$$I = dR \cdot dR = dR^2 = E dx^2 + 2F dx dy + G dy^2 \quad \text{رابطه (۱۰)}$$

که در عبارت فوق ضرایب  $E$ ،  $F$  و  $G$  را ضرایب فرم اول اساسی می‌گویند و به صورت روابط (۱۱) و (۱۲) و (۱۳) به دست می‌آیند.

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

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

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

$$R_{xx} \cdot N + N_x \cdot R_x = 0 \quad \text{رابطه (۱۷)}$$

$$R_{yy} \cdot N + N_y \cdot R_y = 0 \quad \text{رابطه (۱۸)}$$

$$R_{yx} \cdot N + N_x \cdot R_y = 0 \quad \text{رابطه (۱۹)}$$

$$R_{xy} \cdot N + N_y \cdot R_x = 0 \quad \text{رابطه (۲۰)}$$

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

$$\Pi = e dx^2 + 2f dx dy + g dy^2 \quad \text{رابطه (۲۱)}$$

است که در ادامه به توضیح هر کدام از بخش‌های آن می‌پردازیم.

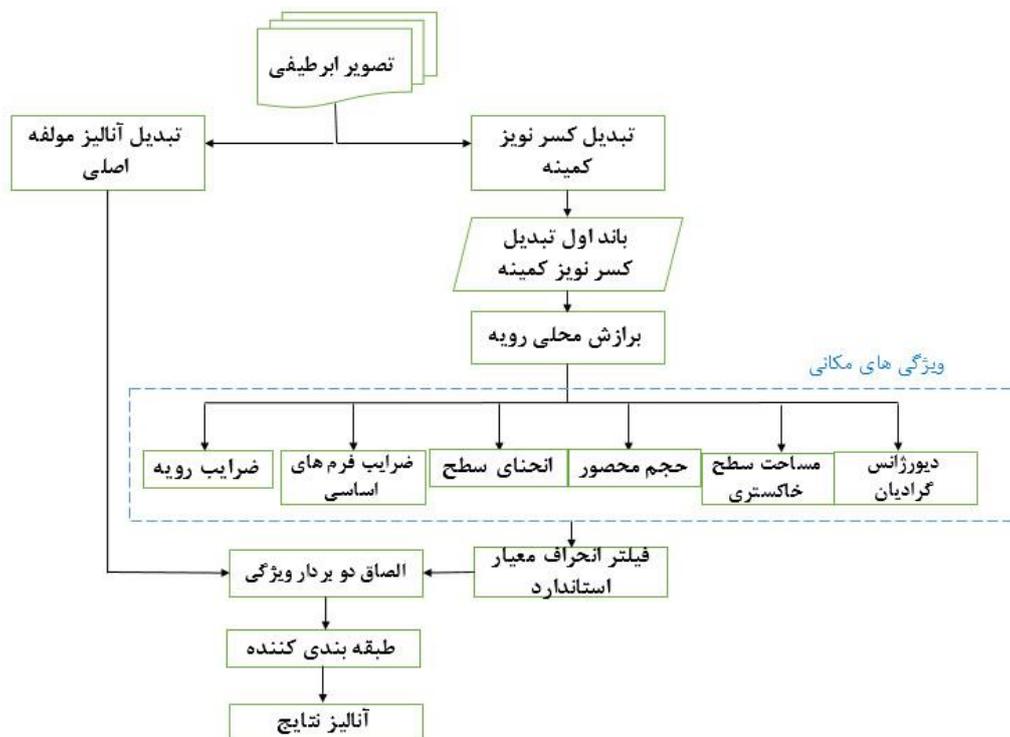
کمی‌سازی بافت معرفی شده است (جدول (۱)) [۱۹].

### ۳- روش تحقیق

فلوچارت کلی تحقیق در شکل (۱) نشان داده شده

جدول ۱: ویژگی‌های انحنا

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



شکل ۱: فلوچارت کلی تحقیق

مکانی استخراج شده شامل ضرایب رویه برآزش داده شده، ضرایب فرم های اساسی اول و دوم، انحنای سطح، دیورژانس گرادیان، حجم محصور در زیر رویه و مساحت سطح خاکستری است. طبقه محاسبه ضرایب رویه و فرم های اساسی اول و دوم و انحنای سطح پیشتر در قسمت ۲-۲ 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 روش های کمی سازی بافت پیشنهاد شده اند، می پردازیم.

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

$$\text{div}(\text{grad}(z(x, y))) = 2(a + c) \quad (25)$$

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

تبدیل مؤلفه اصلی (PCA) به عنوان یک روش نظارت نشده استخراج ویژگی را شاید بتوان به عنوان یکی از ساده ترین و در عین حال مهم ترین روش های استخراج ویژگی به شمار آورد. در این مقاله از این روش برای استخراج ویژگی های طیفی استفاده شده است. پس از اعمال تبدیل PCA از  $n$  مؤلفه اول که دارای ۹۹/۹ درصد واریانس هستند به عنوان ویژگی های طیفی استفاده شده است. همچنین، از آنجایی که تولید ویژگی های مکانی از تمام باندهای تصویر ابرطیفی از سویی سبب افزایش بسیار زیاد تعداد ویژگی های 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<sup>۲</sup> (MNF) به منظور تولید ویژگی های مکانی استفاده شده است. در مقاله حاضر ویژگی های

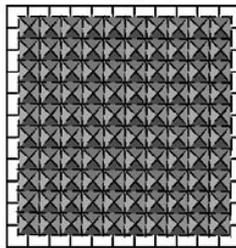
<sup>1</sup> Principal component Analysis

<sup>2</sup> Minimum noise fraction

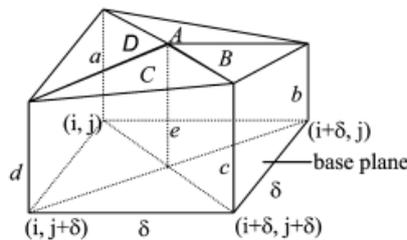
در هر مربع کوچک با استفاده از مقدار ارتفاع پیکسل‌های چهار گوشه،  $(A, B, C, D)$  مقدار ارتفاع پیکسل مرکزی  $(A)$  درونیابی می‌شود (مطابق شکل (۳)). با استفاده از مختصات‌های سه بعدی برای چهار نقطه گوشه و یک نقطه میانی درونیابی شده، مساحت رویه بالایی در هر مربع کوچک از حاصل جمع چهار مثلث محاسبه می‌شود. 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 می‌شود.

$$\iint_{x,y=1}^{\text{kemelsize}} z(x,y) dx dy \quad \text{رابطه (۲۶)}$$

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 مربع‌های پوششی با ابعاد  $1 \times 1$  مانند شکل (۲) پوشش داده می‌شود.



شکل ۲: طرز قرارگیری مربع‌های پوششی [۲۷]



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

$$S = \frac{1}{2} \sqrt{(x_2 \cdot y_3 - x_3 \cdot y_2)^2 + (x_3 \cdot y_1 - x_1 \cdot y_3)^2 + (x_1 \cdot y_2 - x_2 \cdot y_1)^2} \quad \text{رابطه (۲۷)}$$

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 می‌شود:

در واقع رابطه سه بعدی هرمن<sup>۱</sup> برای محاسبه مساحت به صورت رابطه (۲۷) می‌باشد. از حاصل جمع مساحت رویه هر مربع کوچک می‌توان به تقریبی از

<sup>1</sup> Heron

## ۴-۱- داده‌های مورد استفاده

اولین داده مورد استفاده در این مقاله تصویر اخذ شده توسط سنجنده هوارد اویریس<sup>۳</sup> از منطقه ایندین پاین<sup>۴</sup> 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.

<sup>3</sup> AVIRIS<sup>4</sup> Indian Pines

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

در رابطه فوق،  $N$  تعداد پیکسل‌های موجود در پنجره اطراف هر پیکسل و  $A_i$  مقادیر درجات خاکستری هر پیکسل و  $\mu$  میانگین مقادیر پیکسل‌ها در هر پنجره می‌باشد. باید توجه داشت که ابعاد این فیلتر لزوماً 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 پنجره‌مبنا است، می‌توان 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<sup>۲</sup> 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 پیاده‌سازی آورده شده است. در دو زیر بخش انتهایی نیز نتایج و آنالیز آنها ارائه شده است.

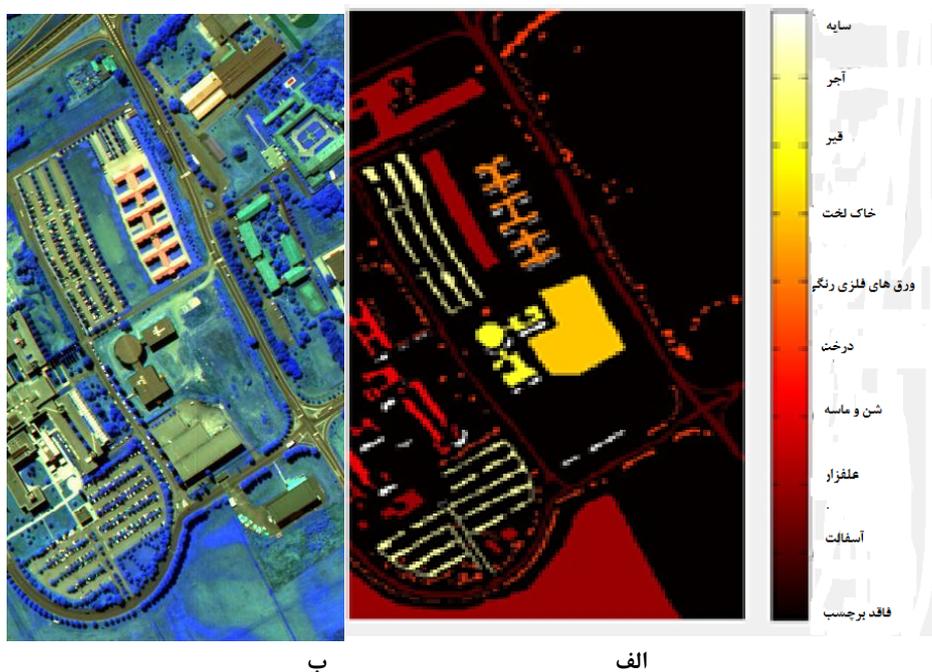
<sup>1</sup> Local surface fitting features<sup>2</sup> Stacking

خاک لخت و... می باشد. طبقه بندی این تصویر به دلیل وجود کلاس های پیچیده شهری و نواحی تودرتوی مکانی چالش برانگیز است. تصویر با ترکیب رنگی کاذب و نقشه حقیقت زمینی این داده که نشان دهنده پراکندگی کلاس ها است در شکل (۵) نمایش داده شده است.

تصویر دوم نیز توسط سنجنده رسیس ۳ از شمال ایتالیا و دانشگاه پاویا در ابعاد  $610 \times 340$  اخذ شده است. سنجنده مذکور دارای ۱۵۵ باند طیفی در محدوده ۴۳۰ تا ۸۶۰ نانومتر می باشد. پس از حذف ۱۲ باند نویزی از ۱۰۳ باند باقی مانده در این تحقیق استفاده شده است. حد تفکیک مکانی این تصویر ۱٫۳ متر و دارای ۹ کلاس اطلاعاتی مانند آسفالت، سایه و



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



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

## ۴-۲- ملاحظات پیاده‌سازی

بردار های طیفی- مکانی تولید شده بر مبنای روش پیشنهادی در ادامه به دو روش طبقه‌بندی نزدیکترین همسایگی<sup>۱</sup> (KNN) و بردار ماشین پشتیبان<sup>۲</sup> (SVM) داده می‌شوند. به منظور انجام این روش های طبقه‌بندی از نرم افزار متلب 2016b استفاده شده است. در طبقه‌بندی کننده 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 طبقه‌بندی کننده SVM با روش جست و جوی شبکه<sup>۳</sup> و تکنیک کراس ولیدیشن پنج دسته<sup>۴</sup> انتخاب شده‌اند. در این تکنیک داده آموزشی به ۵ دسته با تعداد برابر تقسیم می‌شوند که چهار دسته از آنها به عنوان دسته‌ی آموزش<sup>۵</sup> (۸۰ درصد داده آموزشی انتخاب شده) و ۱ دسته آن (۲۰ درصد داده آموزشی انتخاب شده) به عنوان دسته‌ی تست<sup>۶</sup> در نظر گرفته می‌شوند [۲۹]. باید در نظر داشت که الباقی نمونه‌های موجود در حقیقت زمینی (کل نمونه‌ها 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<sup>-5</sup> - 2<sup>5</sup>] در نظر گرفته شده است. از سه روش دقت کلی طبقه‌بندی، ضریب کاپا و دقت متوسط به برای ارزیابی عملکرد طبقه‌بندی کننده 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<sup>۷</sup> (Spec): همانطور که پیشتر عنوان شد به دلیل وجود باندهای همبسته و اضافی در تصاویر ابرطیفی به 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 پایین این تعداد برابر ۶۹ باند و در تصویر دانشگاه پابوا این تعداد برابر ۱۵ باند می‌باشد.

(۲) ویژگی‌های ماتریس هم رخداد<sup>۸</sup> (GLCM): در این روش ۸ ویژگی مستخرج از ماتریس هم رخداد با نام‌های میانگین، واریانس، هموزیته، کنتراست، آنتروپی، عدم شباهت، کورلیشن و گشتاور مرتبه دوم با شیفت (۱ و ۱) 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<sup>۹</sup> (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<sup>۱۰</sup> (gab): به منظور تولید ویژگی‌های بانک فیلتر گابور از رهیافت ارائه شده در تحقیق 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

<sup>1</sup> K-nearest neighbour

<sup>2</sup> Support vector machine

<sup>3</sup> Grid search

<sup>4</sup> 5-fold cross validation

<sup>5</sup> Training fold

<sup>6</sup> Testing fold

<sup>7</sup> Spectral features

<sup>8</sup> Gray level co-occurrence matrix

<sup>9</sup> Morphological Profiles

<sup>10</sup> Gabor filter bank

داده آموزشی که مغلوب روش  $MP$  شده است در باقی حالت همواره پیشرو بوده است. از این رو در این داده جدی ترین رقیب  $Spec+LSFFs$  روش  $Spec+MP$  و روش های  $Spec+GLCM$  و  $Spec+gmom$  در مراتب بعدی قرار دارند. در این داده بر عکس روش  $Spec$  برای روش  $Spec+LSFFs$  طبقه بندی کننده  $KNN$  نسبت به  $SVM$  عملکرد بهتری داشته است.

نتایج حاصل از طبقه بندی برای داده دانشگاه پاویا در جدول (۳) نمایش داده شده است. در این داده به طور کلی طبقه بندی کننده  $SVM$  عملکرد بهتری نسبت به  $KNN$  داشته است. همچنین اضافه کردن ویژگی  $LF$  به ویژگی های طیفی گاهها در برخی موارد سبب افزایش دقت نشده است، این در حالی است که باقی روش ها در این مورد موفق تر عمل کرده اند. روش  $Spec+LSFFs$  به جز در حالت طبقه بندی ۵٪ داده آموزشی که مغلوب روش  $Spec+MP$  شده است در بقیه حالت ها موفق بوده است. البته باید توجه داشت که ضریب کاپا هر دو روش برای حالت ۵٪ در طبقه بندی  $SVM$  تقریباً یکسان بوده است. در این داده نیز همانند داده ایندین پایین جدی ترین رقیب  $LSFFs$  روش  $MP$  است. با مقایسه عملکرد هر دو طبقه بندی کننده در این داده می توان 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 پایین و سرعت بالاتر این طبقه بندی کننده نسبت به  $SVM$ ، می توان گفت که طبقه بندی کننده  $KNN$  انتخاب مقرون به صرفه تری برای طبقه بندی با ویژگی های  $LSFFs$  است.

گابور تولید شده است.

۵) ویژگی های گشتاور هندسی<sup>۱</sup> ( $gmom$ ): در این روش که در تحقیق کومار و همکاران ارائه شده است گشاوهای هندسی تا مرتبه سوم در ابعاد پنجره های  $3 \times 3$  و  $9 \times 9$  و  $15 \times 15$  و  $21 \times 21$  تولید می شود [۱۳]. مجموع تعداد این ویژگی ها ۴۰ می باشد.

۶) فیلتر  $(LF)$  Law: در این روش ماسک های تولید شده از ضرب ترکیب های گوناگون بردارهای یک بعدی در هم تولید می شوند. به طور کلی ۹ ویژگی با ماسک های سه مولفه ای و ۲۵ ویژگی با ماسک های پنج مولفه ای تولید می شود که در مجموع این روش ۳۴ ویژگی تولید می شود.

#### ۴-۳- آنالیز نتایج

پس از تولید ویژگی های مکانی با روش های مختلف این ویژگی ها در کنار ویژگی های طیفی قرار می گیرند و بردار طیفی-مکانی حاصل به کمک دو طبقه بندی کننده  $KNN$  و  $SVM$  طبقه بندی می شوند. به منظور بررسی حساسیت روش ها به تعداد داده های آموزشی، دو اندازه مختلف ۵٪ و ۱۰٪ از کل پیکسل های حقیقت زمینی را برای داده های آموزشی مدنظر قرار داده ایم و از الباقی پیکسل های حقیقت زمینی به عنوان داده تست استفاده کرده ایم.

نتایج حاصل از طبقه بندی برای داده ایندین پایین در جدول (۲) نمایش داده شده است. همانطور که مشهود است طبقه بندی تنها با اطلاعات طیفی به نتایج نسبتاً ضعیفی منجر شده است که این به علت نزدیکی رفتار طیفی میان کلاس های مختلف است. همچنین با توجه به ستون  $Spec$  می توان دید که طبقه بندی کننده  $SVM$  برای طبقه بندی ویژگی های طیفی بهتر از  $KNN$  عمل کرده است. در این داده اضافه شدن هر یک از ویژگی های مکانی سبب افزایش دقت کلی طبقه بندی شده است (ستون های ۵ و ۶ و ۷ و ۸ و ۹ و ۱۱) و  $Spec+LSFFs$  بجز در حالت طبقه بندی  $SVM$  با ۵٪

<sup>1</sup> Geometric moment

جدول ۲: دقت طبقه‌بندی برای تصویر ایندین پایین

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

جدول ۳: دقت طبقه‌بندی برای تصویر دانشگاه پابوا

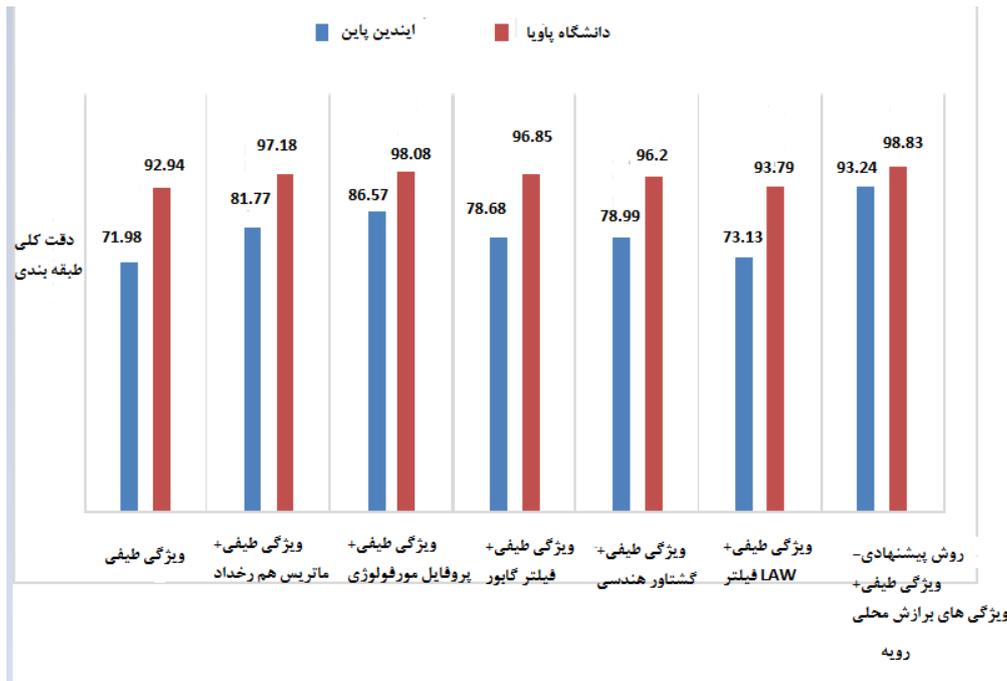
داده آموزشی	طبقه‌بندی کننده	روش ارزیابی	Spec	Spec+GLCM	Spec+MP	Spec+gab	Spec+g mom	Spec+LF	LSFFs	Spec+LSFFs
۵٪	KNN	AA	۸۴,۸۸	۸۴,۵۱	<u>۹۶,۱۵</u>	۸۹,۸۸	۸۴,۳۶	۸۰,۷۰	۸۹,۳۷	۹۳,۱۳
		OA	۸۷,۴۸	۸۷,۱۵	<u>۹۷,۰۸</u>	۹۱,۴۱	۸۸,۸۱	۸۳,۶۹	۹۴,۰۷	۹۵,۹۰
		k	۰,۸۳	۰,۸۲	<u>۰,۹۶</u>	۰,۸۸	۰,۸۵	۰,۷۷	۰,۹۲	۰,۹۵
	SVM	AA	۸۷,۹۲	۹۴,۴۴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

ویژگی‌های  $LSFFs$  بالاتر از 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

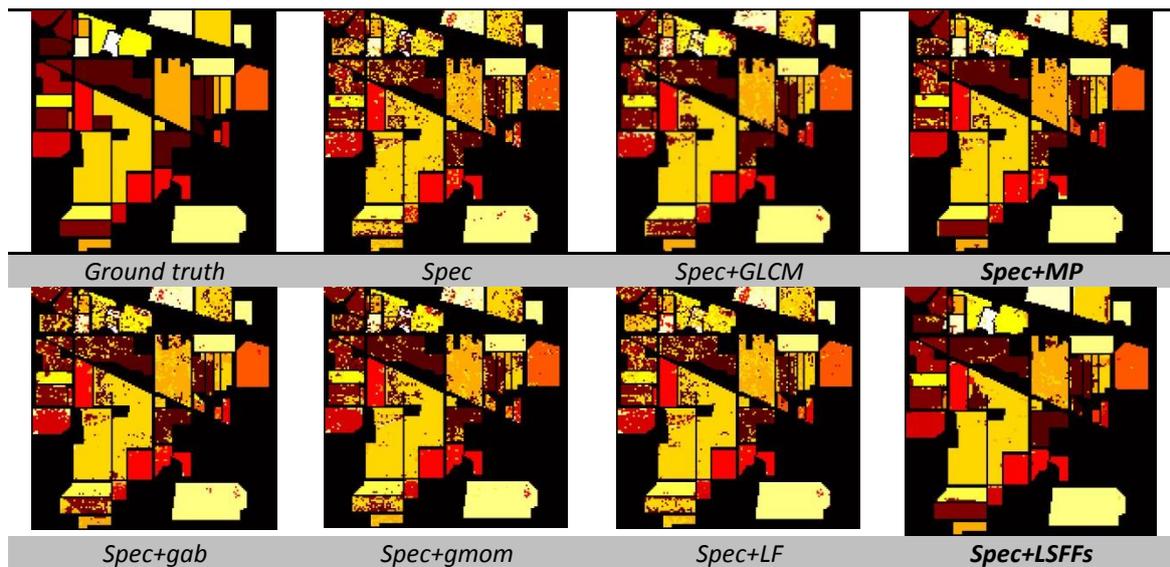
با توجه به ستون دهم هر دو جدول (۲ و ۳) که بیانگر دقت طبقه‌بندی تنها با ویژگی‌های مکانی  $LSFFs$  است و مقایسه آن با ستون چهارم یعنی طبقه‌بندی تنها با ویژگی‌های طیفی می‌توان به این نتیجه رسید که دقت طبقه‌بندی تنها با

را نشان می دهد. همچنین تصاویر طبقه بندی شده روش های مختلف نیز در مقایسه با تصویر حقیقت زمینی برای دو داده به ترتیب در شکل (۷ و ۸) نمایش داده شده است.

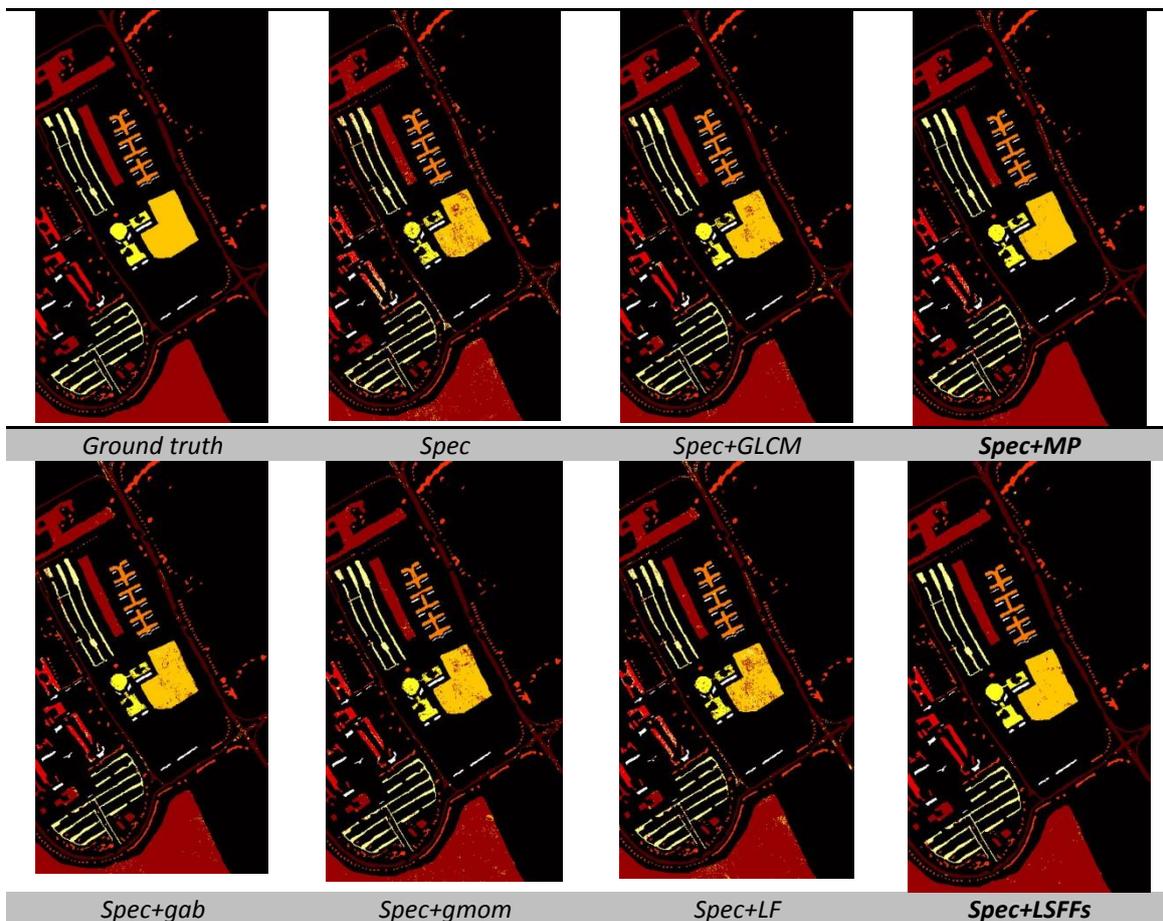
عمده ی حالت ها ترکیب دو ویژگی طیفی و مکانی به سطوح بالاتری از دقت نسبت به طبقه بندی تنها با ویژگی های طیفی یا تنها با ویژگی های مکانی می رسد. شکل (۶) به طور خلاصه بهترین دقت های به دست آمده از روش های مختلف برای ۱۰٪ داده های آموزشی



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



شکل ۷: تصاویر طبقه بندی شده حاصل از روش های مختلف برای داده ایندین پابین



شکل ۸: تصاویر طبقه‌بندی شده حاصل از روش‌های 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 پایین را نشان می‌دهد.

جدول ۴: زمان صرف شده برای تولید ویژگی‌های مکانی

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

فیلتر Law نیازمند زمان بسیار کمتری در مقایسه با روش LSFFs، gmom و GLCM است. علت این مسأله

از جدول (۴) می‌توان دریافت که تولید ویژگی‌های مکانی با روش‌های پروفایل‌های مرفولوژی، فیلتر گابور و

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 ویژگی‌های 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 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.

به تفاوت‌های ماهیتی روش‌های مذکور برمی‌گردد. به عنوان نمونه، روش فیلتر  $Law$  به صورت کانونوشنی 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

## 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*,

- 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

- 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.



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

*Behnam Asghari Beirami*<sup>1\*</sup>, *Mehdi Mokhtarzadeh*<sup>2</sup>

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.*