



# سنگش از دور & GIS ایران



سنجش از دور و GIS ایران / سال ششم، شماره دوم، تابستان ۱۳۹۳  
Iranian Remote Sensing & GIS / Vol.6, No. 2, Summer 2014

۶۵-۸۳

## استفاده از آنالیزهای مورفولوژی به منظور بهبود دقت طبقه‌بندی تصاویر ابرطیفی با حد تفکیک بالا

سمیه یعقوبی<sup>۱</sup>، محمودرضا صاحبی<sup>۲\*</sup>، مهدی مختارزاده<sup>۳</sup>، برات مجردی<sup>۴</sup>

۱. دانشجوی کارشناسی ارشد سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲ و ۳. استادیار گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری و پژوهشکده سنجش از دور دانشگاه صنعتی خواجه نصیرالدین طوسی

۴. استادیار گروه نقشه‌برداری، دانشگاه علم و صنعت ایران

تاریخ پذیرش مقاله: ۱۳۹۳/۱۰/۲۷

تاریخ دریافت مقاله: ۱۳۹۰/۶/۱

### چکیده

آنالیز مورفولوژی، با تمرکز بر آنالیز روابط مکانی بین پیکسل‌های همسایه، پردازش تصویر کامل‌تری را در مقایسه با آنالیزهایی که بر پایه اثر طیفی یک پیکسل تنها هستند، به دست می‌دهد. روش پیشنهادی در این مقاله با استفاده هم‌زمان از اطلاعات طیفی و اطلاعات مکانی حاصل از آنالیز مورفولوژی نتایج نهایی طبقه‌بندی را در تصاویر ابرطیفی بهبود می‌بخشد. در این پژوهش ابتدا با استفاده از نمونه‌های آموزشی محدود، ویژگی‌های منتخب اولیه استخراج شدند و پس از اعمال آنالیزهای مورفولوژی روی هر یک از آنها، پروفایل‌های مورفولوژی تشکیل شدند و از ترکیب این پروفایل‌ها، پروفایل مورفولوژی گسترده تولید شد. سپس پروفایل مورفولوژی گسترده شده با ویژگی‌های منتخب اولیه ترکیب شد و مجدداً استخراج ویژگی نهایی صورت گرفت. ویژگی‌های منتخب نهایی با استفاده از طبقه‌بندی‌کننده ماشین بردار پشتیبان طبقه‌بندی شدند. سپس پس‌پردازش تصویر نهایی با استفاده از فیلتر رأی‌گیری اکثریت انجام شد. این روش، روی داده شهری و نیمه‌شهری از سنجنده ROSIS تست شد. دقت طبقه‌بندی نهایی از ۹۸/۸۶ و ۸۲/۷۰ درصد در روش‌های معمولی به ۹۹/۳۶ و ۹۵/۷۵ درصد در روش پیشنهادی به ترتیب در تصویر منطقه شهری و نیمه‌شهری افزایش یافته است.

**کلیدواژه‌ها:** آنالیز مورفولوژی، ماشین بردار پشتیبان، استخراج ویژگی، طبقه‌بندی، رأی‌گیری اکثریت.

\* نویسنده مکاتبه‌کننده: تهران، خیابان ولی عصر، تقاطع میرداماد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی نقشه‌برداری، گروه مهندسی سنجش از دور،

تلفن: ۸۸۸۸۸۴۴۵

## ۱- مقدمه

دارد (Scott, 1992). از روش‌های مطرح در این زمینه می‌توان به روش‌های DAFE، DBFE، NDA و استخراج ویژگی غیرپارامتریک وزن‌دار<sup>۵</sup> (NWFE) اشاره کرد (Rahimzadegan, 2007). اگرچه روش‌های مذکور با استخراج اطلاعات مفید طیفی نتایج طبقه‌بندی را بهبود می‌دهند، ولی کاربردشان در طبقه‌بندی صرفاً به استفاده از خصوصیات طیفی محدود می‌شود و از اطلاعات مرتبط با آرایش مکانی پیکسل‌ها در تصویر چشم می‌پوشند. این در حالی است که تصاویر ابرطیفی افزون بر اطلاعات طیفی شامل اطلاعات مکانی و بافتی نیز هستند و با ادغام اطلاعات مکانی، صحت طبقه‌بندی بهبود می‌یابد (Tarabalka, 2009, Pesaresi, 2001, Plaza, et al., 2005, Benediktsson, et al., 2005). به‌منظور استفاده از اطلاعات مکانی مانند مجاورت اشیاء، شکل هندسی اشیاء و مانند اینها روش‌هایی پیشنهاد شده است.

پالماسون و بندیکتسون<sup>۶</sup> در سال ۲۰۰۵ استفاده از تبدیلات مورفولوژی را برای ساخت یک پروفایل مورفولوژی<sup>۷</sup> (MP) به‌منظور طبقه‌بندی تصاویر ابرطیفی شهری با رزولوشن بالا پیشنهاد کردند. مورفولوژی ریاضی، نظریه‌ایست برای آنالیز روابط مکانی بین پیکسل‌ها. مورفولوژی ابتدا برای تصاویر باینری تعریف شد و سپس در مورد تصاویر با درجات خاکستری و همچنین تصاویر رنگی شرح و بسط پیدا کرد (Keshavarz & Ghasemiyan, 2005).

به‌منظور گسترش اپراتورهای مورفولوژی روی تصاویر چندطیفی و فراطیفی، پروفایل مورفولوژی و نسخه گسترش‌یافته آن برای تصویر چندباندی پروفایل

تصاویر ابرطیفی از ابزاری تحقیقاتی به وسیله‌ای کارآمد برای جامعه وسیعی از مصرف‌کنندگان داده‌های مکانی تبدیل شده‌اند (Goetz et al., 1985). اطلاعات طیفی موجود در این تصاویر، چشم‌اندازهای جدیدی را در زمینه‌های کاربردی زیادی از قبیل مانیتورینگ محیط، پردازش‌های شهری به‌منظور پیشگیری و پاسخ‌گویی ریسک (پیداکردن آتش‌سوزی‌های سریع و بزرگ)، شناسایی رفتارهای بیولوژیکی، مانیتورینگ لکه‌های نفتی و انواع دیگری از آلودگی‌های شیمیایی باز کرده است (Zortea and Plaza, 2009).

کلمن<sup>۱</sup> و همکارانش در سال ۲۰۰۹ از تصویر ابرطیفی برای طبقه‌بندی چند نمونه چای به‌منظور کنترل کیفیت استفاده کردند. تیان<sup>۲</sup> در سال ۲۰۱۰ برای استخراج اطلاعات مربوط به محتوای هیدروکربن از تصاویر ابرطیفی استفاده کرد. هی<sup>۳</sup> در سال ۲۰۱۰ روش MMA را برای شناسایی آلودگی هوا و نمایش لکه‌های نفتی با استفاده از تصاویر ابرطیفی ارائه کرد. تومین<sup>۴</sup> در سال ۲۰۱۱ به‌منظور شناسایی تغییرات محیط، تصاویر ابرطیفی را به‌کار گرفت.

به‌دلیل غنای بالای طیفی این داده‌ها، اکثر روش‌های تحقیقاتی در این حوزه صرفاً از داده‌های طیفی استفاده کرده‌اند. با اینکه داده‌های ابرطیفی، تصاویری با حد تفکیک بالای طیفی را برای تشخیص دقیق پوشش‌های مختلف زمین فراهم می‌کنند (Landgrebe, 2003)، ابعاد بالای داده‌ها، چالش‌های جدیدی را فراروی تکنیک‌های آنالیز داده‌ها به‌وجود می‌آورد (Chang, 2003; Jia et al., 1999). تحقیقات پیشین نشان می‌دهند که فضای داده‌ها با ابعاد بالا اکثراً خالی هستند و محتوای واقعی داده‌ها در زیرفضاهایی از فضای اولیه قرار دارند (Jimenez and Landgrebe, 1998). بنابراین نیاز به استخراج ویژگی برای کاهش ابعاد داده به زیرفضاهای صحیح، بدون از دست دادن اطلاعات اولیه برای جداسازی کلاس‌ها از یکدیگر وجود

1. Kelman
2. Tian
3. He
4. Tuominen
5. Nonparametric Weighted Feature Extraction
6. Palmason & Benediktsson
7. Morphological Profile

روش تکمیل‌کننده روش فاؤل و همکاران (۲۰۰۸) است. برای این منظور ابتدا یک پروفایل مورفولوژی با استفاده از ویژگی‌های استخراج‌شده اولیه از تصویر ابرطیفی ایجاد می‌شود، سپس روی پروفایل مورفولوژی گسترده‌شده و تصویر ابرطیفی اولیه استخراج ویژگی به صورت جداگانه انجام می‌گیرد. سرانجام بردارهای ویژگی استخراج‌شده از EMP و تصویر ابرطیفی اولیه، در یک بردار انباشته می‌شوند و بردار نهایی با استفاده از ماشین بردار پشتیبان<sup>۷</sup> طبقه‌بندی می‌شود.

فاؤل برای انتخاب ویژگی‌های منتخب اولیه از روش PCA استفاده کرده است، درحالی‌که روش NWFEE ویژگی‌های مناسب‌تری را برای جدایی بهتر کلاس‌ها انتخاب می‌کند که موجب بهبود دقت نهایی می‌شود. از طرف دیگر در روش فاؤل استخراج ویژگی نهایی روی اطلاعات طیفی و اطلاعات مکانی به صورت جداگانه انجام می‌شود، درحالی‌که حضور اطلاعات طیفی و مکانی به صورت هم‌زمان در استخراج ویژگی نهایی، دقت طبقه‌بندی را بیشتر افزایش می‌دهد. همچنین پس‌پردازش رأی‌گیری اکثریت، با حذف پیکسل‌های اشتباه (نویزی) در هر کلاس و یکپارچه‌کردن هر کلاس از لحاظ مکانی و مشخص‌تر کردن مرز بین کلاس‌ها بهبود جدی در دقت نهایی طبقه‌بندی ایجاد می‌کند. هدف پژوهش حاضر، رسیدن به روشی است که با در نظر گرفتن موارد ذکر شده، دقت طبقه‌بندی تصاویر ابرطیفی در روش فاؤل را بهبود بخشد.

در نوشتار حاضر پس از مقدمه، مراحل اصلی روش پیشنهادی شامل استخراج ویژگی، آنالیز مورفولوژی و طبقه‌بندی ماشین بردار پشتیبان معرفی می‌شوند.

مورفولوژی بسط‌یافته<sup>۱</sup> (EMP)، مطرح شدند (Fauvel, 2007). پروفایل مورفولوژی و نسخه بسط‌یافته آن، امکان استفاده از اطلاعات مکانی و بافت هندسی عوارض تصویر (شکل، سایز، کنتراست مورفولوژی، جهت و مانند اینها) را دارند و روی بسیاری از انواع داده‌ها (پانکروماتیک، چندطیفی و ابرطیفی) به خوبی عمل می‌کنند (Fauvel, 2007).

با اینکه پروفایل مورفولوژی به تفاوت پیکسل‌های همسایه حساس است ولی بدون در نظر گرفتن اطلاعات همسایگی انجام می‌شود. به همین دلیل آکایی و اکسوی<sup>۲</sup> در سال ۲۰۰۷ روشی را ارائه کردند که در آن افزون بر اطلاعات مورفولوژی از اطلاعات همسایگی و طیفی نیز استفاده می‌شود. علاوه بر پروفایل مورفولوژی، نقشه سگمنتیشن<sup>۳</sup> نیز یکی همسایگی تطابق‌پذیر<sup>۴</sup> برای هر پیکسل تعریف می‌کند. تارابالکا<sup>۵</sup> و همکاران در سال ۲۰۰۸ نتایج طبقه‌بندی SVM پیکسل‌مبنا و نقشه سگمنتیشن را با استفاده از رأی‌گیری اکثریت ترکیب کردند. نتایجی که با استفاده از این نوع اطلاعات همسایگی به دست آمدند، به مراتب بهتر از نتایج حاصل از روش‌های پیشین‌اند.

فاؤل<sup>۶</sup> و همکاران در سال ۲۰۰۸ راهبرد تلفیق اطلاعات طیفی و مکانی را به منظور طبقه‌بندی تصاویر ابرطیفی شهری پیشنهاد کردند. فاؤل پروفایل مورفولوژی را با استفاده از ویژگی‌های حاصل از PCA ایجاد کرد و ویژگی NWFEE را روی پروفایل مورفولوژی و تصویر ابرطیفی جداگانه استخراج کرد. در پژوهش حاضر به منظور بهبود نتایج روش فاؤل در نخستین مرحله از NWFEE به جای PCA استفاده شد و در پایان نیز با ایجاد یک بردار از ترکیب پروفایل مورفولوژی با ویژگی‌های اولیه، NWFEE تنها روی این بردار انجام گرفت. با بهره‌گیری از ابزارهای پس‌پردازش، دقت نهایی در این تحقیق افزایش یافته است.

ایده اصلی تحقیق حاضر، تلفیق هم‌زمان اطلاعات طیفی و مکانی در طبقه‌بندی‌کننده‌هاست، به نحوی که اطلاعات مکانی از آنالیز مورفولوژی به دست آید. این

1. Extended Morphological Profile
2. Akcay & Aksoy
3. Segmentation
4. Adaptive
5. Tarabalka
6. Fauvel
7. Support Vector Machine

کلاس‌ها انتخاب می‌کند، که موجب بهبود دقت نهایی می‌شود (Rahimzadegan, 2007). از طرف دیگر در روش فاول استخراج ویژگی نهایی روی اطلاعات طیفی و اطلاعات مکانی نهایی، دقت طبقه‌بندی را بیشتر افزایش می‌دهد. دلیل این امر را می‌توان افزودن اطلاعات، یعنی وجود اطلاعات مشترک در دو مجموعه اطلاعات طیفی و مکانی بیان کرد. با تلفیق این دو مجموعه و حذف اطلاعات مشترک، دقت طبقه‌بندی بهبود می‌یابد. پس پردازش رأی‌گیری اکثریت، با حذف پیکسل‌های اشتباه (نویزی) در هر کلاس و یکپارچه‌کردن هر کلاس و یکپارچه‌کردن هر کلاس و لحاظ مکانی و مشخص‌تر کردن مرز بین کلاس‌ها بهبود حدی در دقت نهایی طبقه‌بندی ایجاد می‌کند. در پژوهش حاضر کوشش شده است با در نظر گرفتن موارد ذکر شده، دقت طبقه‌بندی تصاویر ابرطیفی در روش فاول بهبود داده شود.

در روش پیشنهادی، پس از ایجاد پروفایل مورفولوژی گسترده‌شده، EMP با ویژگی‌های منتخب اولیه ترکیب می‌شود و ویژگی‌های منتخب نهایی با استخراج ویژگی به روش NWFE روی این بردار حاصل می‌شوند. سرانجام بردارهای ویژگی نهایی به وسیله ماشین بردار پشتیبان طبقه‌بندی می‌شود و برای بهبود دقت، پردازش رأی‌گیری اکثریت روی تصویر طبقه‌بندی شده نهایی انجام می‌شود.

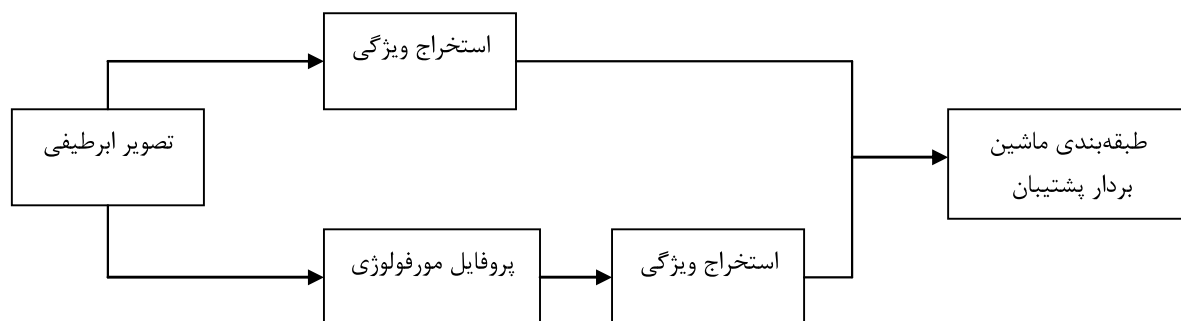
سپس نتایج حاصل از پیاده‌سازی روش پیشنهادی ارائه شده روی داده‌های سنسور ROSIS نشان داده می‌شود. در پایان، نتیجه‌گیری و پیشنهادها برای تحقیقات تکمیلی ارائه شده است.

## ۲- مواد و روش‌ها

ایده اصلی تحقیق پژوهش حاضر، تلفیق هم‌زمان اطلاعات طیفی و مکانی در طبقه‌بندی کننده‌هاست، به گونه‌ای که اطلاعات مکانی از آنالیز مورفولوژی حاصل گردد. این روش، تکمیل کننده روش فاول و همکاران (۲۰۰۸) است.

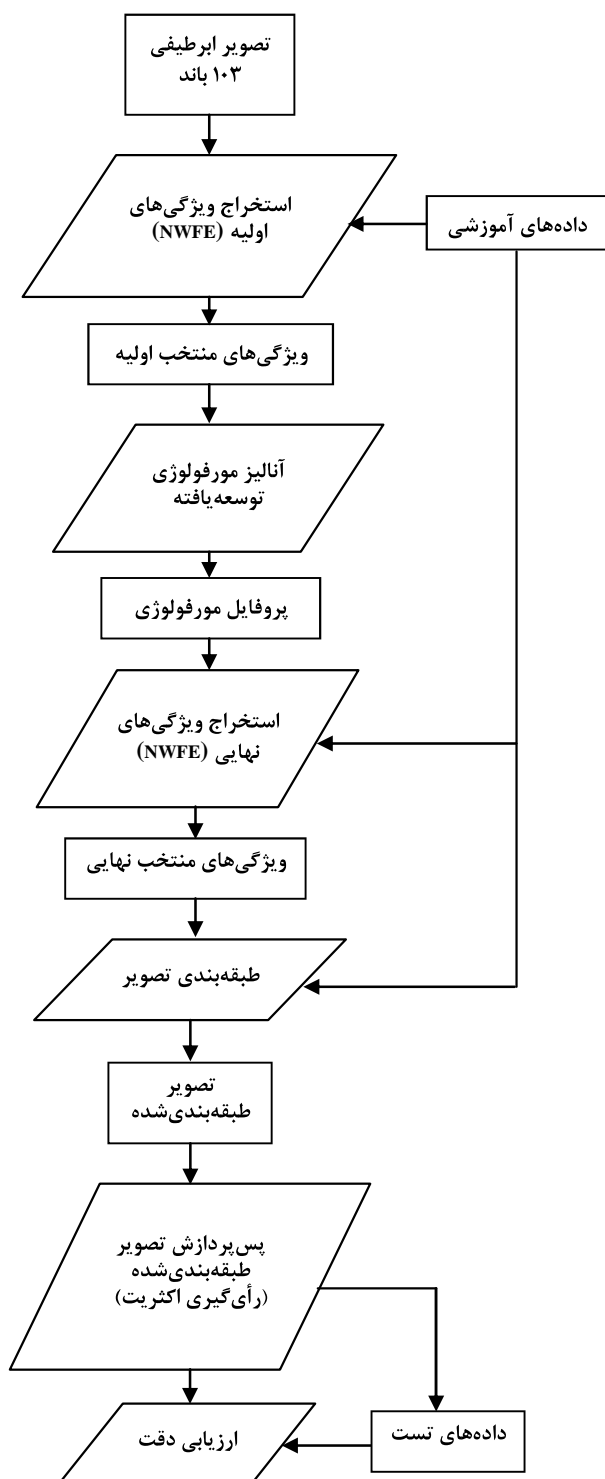
براین اساس ابتدا با استفاده از ویژگی‌های استخراج شده اولیه، یک پروفایل مورفولوژی از تصویر ابرطیفی ایجاد می‌شود، سپس روی پروفایل مورفولوژی گسترده شده و تصویر ابرطیفی اولیه، استخراج ویژگی به صورت جداگانه انجام می‌گیرد. سرانجام بردارهای ویژگی استخراج شده از پروفایل مورفولوژی گسترده شده (EMP) و تصویر ابرطیفی اولیه، در یک بردار انباشته می‌شود و بردار نهایی با استفاده از ماشین بردار پشتیبان طبقه‌بندی می‌گردد. در شکل ۱ نمودار روش فاول نشان داده شده است.

فاول در روش خود برای انتخاب ویژگی‌های منتخب اولیه از روش PCA استفاده کرده است، در حالی که روش NWFE ویژگی‌های مناسب‌تری را برای جداسازی بهتر



شکل ۱. نمودار روش طبقه‌بندی طیفی-مکانی (Fauvel et al., 2008)

استفاده از آنالیزهای مورفولوژی به منظور بهبود دقت طبقه‌بندی تصاویر ابرطیفی با حد تفکیک بالا



شکل ۲. نمودار روش طبقه‌بندی طیفی - مکانی پیشنهادی

## ۲-۲- آنالیز مورفولوژی بسط یافته روی

## ویژگی‌های منتخب طیفی

مورفولوژی ریاضی، نوعی تکنیک پردازشی مکانی غیرخطی است. مورفولوژی ابتدا برای تصاویر باینری تعریف شد و سپس در مورد تصاویر با درجات خاکستری و تصاویر رنگی توسعه پیدا کرد (Keshavarz and Ghasemiayn, 2005). اپراتورهای پایه در مورفولوژی، سایش<sup>۲</sup> و اتساع<sup>۳</sup> هستند (Gonzalez and Woods, 2008). ترکیب اتساع و سایش دو اپراتور باز<sup>۴</sup> و بسته<sup>۵</sup> را تولید می‌کند. اپراتور باز مورفولوژی، عوارض و اشیای کوچک را از تصویر حذف می‌کند، در حالی که شکل و سائز عوارض بزرگ‌تر در تصویر را حفظ می‌کند (Fauvel, 2007). با اینکه اپراتورهای باز و بسته مورفولوژی اپراتورهای قدرتمندی هستند، اشکال اصلی‌شان این است که از نوع فیلترهای متصل شده<sup>۶</sup> نیستند. همان‌طور که در شکل ۳ مشاهده می‌شود، پس از اعمال اپراتورهای باز و بسته کلاسیک، بسیاری از ساختارها در تصویر (برای مثال ساختمان‌های روشن در شکل ۳-الف) ادغام شده‌اند. برای اجتناب از این مشکل، می‌توان از مورفولوژی ژئودزیک و بازسازی<sup>۷</sup> استفاده کرد. فیلترهای ساختاریافته، فیلترهای متصل شده هستند (Fauvel, 2007) (شکل ۳-ب).

مفاهیم مورفولوژی ژئودزیک و بازسازی در اپراتورهای اتساع و سایش اعمال شده است. در اتساع و سایش ژئودزیک و ساختاریافته، ابتدا روی تصویر، اتساع یا سایش کلاسیک انجام می‌شود، سپس روی اشتراک تصویر حاصل از مورفولوژی با تصویر اولیه، مجدداً اپراتور اتساع یا سایش کلاسیک تا رسیدن به ثبات - یعنی تغییر نکردن تصویر حاصل از اشتراک‌گیری - تکرار می‌شود (Soille, 2003).

1. Landgrebe
2. Erosion
3. Dilation
4. Opening
5. Closing
6. Connected filters
7. Geodesic Morphology and reconstruction


نمودار روش پیشنهادی مطابق شکل ۲ است، که موارد زیر را دربرمی‌گیرد:

- انتخاب ویژگی‌های طیفی اولیه با انجام الگوریتم استخراج ویژگی روی داده ابرطیفی؛
  - انجام آنالیز مورفولوژی گسترش یافته روی ویژگی‌های منتخب طیفی؛
  - انجام الگوریتم استخراج ویژگی روی ترکیب EMP با ویژگی‌های طیفی اولیه به منظور استخراج ویژگی‌های نهایی؛
  - طبقه‌بندی تصویر؛ و
  - انجام پس پردازش رأی‌گیری اکثریت.
- در ادامه، هر یک از مراحل گفته شده با توضیحات تفصیلی تشریح شده است.

## ۲-۱- انتخاب ویژگی‌های طیفی اولیه

به منظور انتخاب ویژگی‌های طیفی می‌بایست الگوریتم استخراج ویژگی روی داده ابرطیفی انجام شود. روش‌های استخراج ویژگی، با محاسبه ماتریس‌های پراکندگی داخل کلاسی ( $S_w$ ) و بین کلاسی ( $S_b$ ) و بیشینه‌سازی معیار خاصی ویژگی‌های مطلوب را استخراج می‌کنند. برای این منظور روش‌های متعددی از استخراج ویژگی ارائه شده است (Mojaradi, 2009). از روش‌های مطرح در این زمینه، روش استخراج ویژگی غیر پارامتریک وزن دار (NWFE) است، که نخستین بار لندگرب<sup>۱</sup> در سال ۲۰۰۳ آن را مطرح کرد. در این روش به دلیل استفاده از همه نمونه‌های آموزشی کلاس‌ها و نیز محاسبه میانگین‌های وزن دار گوناگون و ارائه تعریف غیر پارامتریک جدیدی از ماتریس‌های پراکندگی داخل کلاسی و بین کلاسی، دقت‌های مطلوب‌تری در مقایسه با سایر روش‌های استخراج ویژگی (مانند DAFE، DBFE و NDA) حاصل می‌گردد (Rahimzadegan, 2007). برای مطالعات تکمیلی در خصوص اساس و تئوری این روش به پایان‌نامه قمصری اصل سال ۱۳۸۵ مراجعه کنید، که در آن از روش NWFE برای استخراج ویژگی استفاده شده است.

استفاده از آنالیزهای مورفولوژی به منظور بهبود دقت طبقه‌بندی تصاویر ابرطیفی با حد تفکیک بالا



شکل ۳-الف. ابراتور باز کلاسیک و بسته کلاسیک؛ (ب) ابراتور باز ساختاریافته و بسته ساختاریافته  
بخشی از تصویر دانشگاه پاویا واقع در شمال ایتالیا (مجموعه اول از داده های ورودی)

رابطه (۱) تعریف می‌شود.

$$OP_i(x) = \gamma_R^{(i)}(x) \quad \text{رابطه (۱)}$$

$$\forall i \in [0, n]$$

$\gamma_R^i$ ، ابراتور بازترمیم‌شده با یک المان ساختاری به ساین  $i$  است و  $n$  تعداد تکرارهای ابراتور باز به‌زای هریک از المان‌های ساختاری است. ابراتور بسته نیز در پیکسل  $x$  از تصویر  $I$  به‌صورت رابطه (۲) در فضای  $n$  بعدی تعریف می‌شود.

رابطه (۲)

$$CP_i(x) = \gamma_R^{(i)}(x) \quad \forall i \in [0, n]$$

به‌وسیله ابراتور باز و پروفایل ابراتور بسته، پروفایل مورفولوژی تصویر  $I$  به‌صورت بردار  $2n+1$  به‌صورت رابطه (۳) تعریف می‌شود.

رابطه (۳)

$$MP(x) = \{CP_n(x), \dots, I(x), \dots, OP_n(x)\}$$

هر پروفایل مورفولوژی از  $n$  ابراتور باز ژئودزیک،  $n$  ابراتور بسته ژئودزیک، و خود جزء اصلی تشکیل شده است. المان ساختاری یک دیسک با شعاع اولیه  $r$  پیکسل و ساین افزایشی  $s$  است. از آنجاکه هر پروفایل

واضح است که نتیجه این تبدیلات، نویز کمتری درمقایسه با ابراتورهای باز و بسته کلاسیک دارد. مورفولوژی ژئودزیک و ساختاریافته، عوارض موجود در تصویر را یا کاملاً حفظ می‌کند یا کاملاً حذف. از طرفی برای تعیین ساین و شکل همه اشیا موجود در تصویر لازم است از المان‌های ساختاری با ساین‌های مختلف استفاده شود، که این مفهوم را گراندومتری<sup>۱</sup> می‌نامند (Fauvel, 2007).

به‌منظور بسط ابراتورهای مورفولوژی روی تصاویر چندطیفی و فراطیفی، ابتدا ویژگی‌های منتخب اولیه از تصویر استخراج می‌شوند؛ سپس روی هر یک از این ویژگی‌ها که تصویری خاکستری است، ابراتورهای باز و بسته مورفولوژی ژئودزیک و ساختاریافته با ابعاد مختلف المان ساختاری اعمال می‌شوند. هر ویژگی به‌همراه تصاویر حاصل از ابراتورهای باز و بسته در ساین‌های مختلف المان ساختاری، برداری از تصاویر را تشکیل می‌دهند که آن را پروفایل مورفولوژی می‌نامند (Fauvel, 2007).

پروفایل مورفولوژی با استفاده از گراندومتری تعریف می‌شود. پروفایل مورفولوژی ترکیبی از پروفایل ابراتور باز و پروفایل ابراتور بسته است. پروفایل ابراتور باز در پیکسل  $x$  از تصویر  $I$  در فضای  $n$  بعدی به‌صورت

1. Granulometry

طبقه‌بندی پارامتریک و غیرپارامتریک دسته‌بندی کرد (Palmason et al., 2005, Benediktsson et al., 2003, Chanussot et al., 2006, Benediktsson et al., 2005). مشکل اصلی روش‌های طبقه‌بندی پارامتریک، وابستگی آنها به توزیع آماری داده‌ها و تأثیر تعداد نمونه‌های آموزشی در برآورد این توزیع است. به همین دلیل روش‌های غیرپارامتریک - از جمله روش‌های مبتنی بر شبکه‌های عصبی و درخت تصمیم‌گیری - برای طبقه‌بندی تصاویر ابرطیفی به کار گرفته می‌شوند. شبکه‌های عصبی به‌رغم توانایی پردازش داده‌های پیچیده - نظیر داده‌های فراطیفی - در مرحله آموزشی کند هستند و در عین حال مانند جعبه سیاه عمل می‌کنند و فرایند داخلی‌شان مشخص نیست. در تحقیقات اخیر، ماشین بردار پشتیبان نتایج خوبی را نشان داده است (Halldorsson et al., 2003, Gualtieri and Crompton, 2000, Gualtieri and Chettri, 1998).

در روش ماشین بردار پشتیبان فقط کافی است که تابع هسته انتخاب شود و پارامترهای آزاد و مقدار قید تنظیم گردد (Keshavarz and Ghasemiyan, 2005). ماشین بردار پشتیبان یا SVM در واقع طبقه‌بندی‌کننده‌ای دودویی است که دو کلاس را با استفاده از یک مرکز خطی از هم جدا می‌کند (Fauvel et al., 2006). در روش SVM از کرنل‌های مختلفی به منظور طبقه‌بندی استفاده می‌شود که یکی از آنها گوسین نام دارد. در آزمایش‌های قبلی روی داده‌های استفاده‌شده در این مقاله، کرنل گوسین بهترین نتیجه را به دست داده و در این تحقیق نیز از همان برای انجام آزمایش‌ها استفاده‌شده است (Fauvel et al., 2006). در پژوهش حاضر از طبقه‌بندی‌کننده ماشین بردار پشتیبان استفاده‌شده و به منظور مقایسه نتایج آن با طبقه‌بندی‌کننده‌های دیگر، از دو طبقه‌بندی‌کننده بیشترین شباهت<sup>۱</sup> و نزدیک‌ترین همسایگی<sup>۲</sup>

مورفولوژی  $2n+1$  ویژگی دارد، EMP،  $m(2n+1)$  ویژگی خواهد داشت (Benediktsson et al., 2005).

رابطه (۴)

$$EMP(x) = \{MP_{FE^1}(x), \dots, MP_{FE^m}(x)\}$$

که در آن،  $m$  تعداد ویژگی‌های منتخب اولیه و  $n$  تعداد دفعات تکرار عملگرهای باز و بسته با سایزهای مختلف المان ساختاری است و منظور از FE، هریک از ویژگی‌های منتخب اولیه است. نمونه‌ای از پروفایل مورفولوژی در شکل ۴ نشان داده شده است. از آنجاکه پروفایل مورفولوژی فقط روی یک باند ساخته می‌شود، اطلاعات طیفی از دست می‌رود. یکی از روش‌های برخورد با این مشکل، استخراج چند تصویر است که شامل بهترین و کامل‌ترین اطلاعات طیفی برای جداسازی کلاس‌ها باشند؛ سپس روی هر تصویر به صورت جداگانه پروفایل مورفولوژی ساخته می‌شود. این روش EMP نامیده می‌شود (Benediktsson et al., 2005).

## ۲-۳- استخراج ویژگی نهایی

به منظور حفظ اطلاعات وابستگی بین باندها، و نیز به دلیل افزونگی اطلاعات در بردار انباشته‌شده حاصل از EMP و بردارهای منتخب اولیه، پس از تلفیق EMP و ویژگی‌های منتخب اولیه، مجدداً استخراج ویژگی انجام می‌شود. منظور از افزونگی اطلاعات، وجود اطلاعات مشترک در بردارهاست. در این بخش نیز از روش استخراج ویژگی NWFE استفاده‌شده است. بردار حاصل از این روش ضمن آنکه ابعاد مناسبی دارد، اطلاعات طیفی و مکانی را نیز شامل می‌شود و از این رو امکان استفاده هم‌زمان از این اطلاعات را فراهم می‌آورد.

## ۲-۴- طبقه‌بندی تصویر

به منظور طبقه‌بندی تصاویر چندطیفی و فراطیفی روش‌های متعددی در تحقیقات پیشین ارائه شده است که می‌توان آنها را در دو دسته کلی شامل روش‌های

1. Maximum Likelihood  
2. Nearest neighbourhood



مربعی در آنالیز رأی‌گیری اکثریت بررسی می‌شوند. در ادامه ابتدا به تشریح داده‌های ورودی و سپس نتایج حاصل از اجرای روش پیشنهادی پرداخته خواهد شد.

### ۳-۱- داده‌های ورودی

در پژوهش حاضر به منظور پیاده‌سازی و تأثیر عملکرد روش پیشنهادی، دو تصویر یکی از منطقه شهری و دیگری از نیمه‌شهری واقع در شمال ایتالیا انتخاب شد. این تصاویر داده‌های هوابرد از سنجنده نوری ROSIS-3<sup>1</sup> هستند. این سنجنده در آزمایشگاه‌های سنجش از دور اروپا ساخته شده است و ۱۱۵ باند دارد که محدوده طیفی ۰/۴۳ تا ۰/۸۶ میکرومتر را پوشش می‌دهد. داده از نظر اتمسفری صحیح شده اما از نظر هندسی تصحیح نشده است. حد تفکیک مکانی هر پیکسل ۱/۳ متر است.

مجموعه نخست، تصویر دانشگاه پاویا واقع در شمال ایتالیا است. ابعاد تصویر استفاده شده ۶۱۰×۳۴۰ پیکسل است. تعداد ۱۲ باند به علت ماهیت نویزی بودن حذف شدند و ۱۰۳ باند برای پردازش باقی ماند. تصویر کاذب داده ورودی در شکل ۵-الف نمایش داده شده است. براساس ماهیت تصویر و داده‌های آموزشی موجود، ۹ کلاس اصلی شامل درخت، آسفالت، قیر، شن، صفحات فلزی، سایه، آجر، چمن‌زار و خاک در نظر گرفته شده است. ۳۹۲۱ داده آموزشی و ۴۰۰۲ داده تست با پراکندگی مناسب از همه کلاس‌ها برای این مجموعه انتخاب شدند.

مجموعه دوم، تصویر مرکز پاویا، شهری در شمال ایتالیا است. ابعاد این تصویر ۱۰۹۶×۴۹۰ است. تعداد ۱۳ باند به علت ماهیت نویزی بودن حذف شدند و ۱۰۲ باند برای پردازش باقی ماند. تصویر کاذب داده ورودی در شکل ۵-ب نمایش داده شده است.

استفاده شده است (Richards, 2006). برای مطالعه در خصوص مفاهیم نظری و اصول حاکم بر روش طبقه‌بندی کننده ماشین‌بردار پشتیبان به شاه‌حسینی و همکاران (۲۰۰۹) مراجعه کنید.

### ۲-۵- پس پردازش رأی‌گیری اکثریت

آنالیز رأی‌گیری اکثریت روی تصویر طبقه‌بندی شده انجام می‌شود. در این آنالیز از یک کرنل مربعی با سایز دلخواه استفاده می‌شود که روی تمام تصویر حرکت می‌کند. هر بار که این کرنل روی بخشی از تصویر قرار می‌گیرد، تعداد پیکسل‌های هر کلاس از تصویر که به وسیله کرنل مربعی پوشانده شده شمارش می‌شود. سپس برچسب کلاسی که بیشترین تعداد را داشته است، به پیکسل مرکزی داده می‌شود. در این آنالیز می‌توان به هر کلاس وزنی داد تا با آن در پردازش شرکت کند. پس از پردازش، کلاس‌ها مرزهای مشخص‌تر و واضح‌تری خواهند داشت و برچسب پیکسل‌هایی که به اشتباه در کلاس دیگری قرار گرفته بودند اصلاح خواهند شد. در نتیجه دقت طبقه‌بندی افزایش می‌یابد و تصویر یکدست‌تری به دست خواهد آمد (Richards, 2006).

### ۳- پیاده‌سازی و ارزیابی نتایج

استخراج ویژگی‌ها با استفاده از الگوریتم NWFE در نرم‌افزار MultiSpec (Landgrebe, 2003) انجام شد، و اپراتورهای مورفولوژی با برنامه نوشته شده در نرم‌افزار MATLAB روی تصاویر اعمال شدند. طبقه‌بندی SVM و بیشترین شباهت و آنالیز رأی‌گیری اکثریت در نرم‌افزار ENVI صورت گرفت. طبقه‌بندی نزدیک‌ترین همسایگی و آنالیز رأی‌گیری اکثریت روی نتایج حاصل از آن، در نرم‌افزار MATLAB انجام شد. عوامل بسیاری در نتیجه تصویر طبقه‌بندی شده نهایی تأثیرگذار هستند. در این بخش هر یک از عوامل تأثیرگذار از جمله المان ساختاری مورد استفاده در آنالیز مورفولوژی، تعداد ویژگی‌های نهایی در طبقه‌بندی و سایز کرنل

1. Reflective Optics System Imaging Spectrometer



شکل ۵-ب. تصویر مرکز پاویا، شهری در شمال ایتالیا که به وسیله سنسور Rosi3 تهیه شده است. تصویر کاذب داده ابرطیفی اولیه (مجموعه دوم)



شکل ۵-الف. تصویر دانشگاه پاویا واقع در شمال ایتالیا که به وسیله سنسور Rosi3 تهیه شده است. تصویر کاذب داده ابرطیفی اولیه (مجموعه اول)

استخراج می‌کند (Fauvel, 2007). بنابراین در این آزمایش‌ها در پژوهش حاضر از المان ساختاری ایزوتروپیک استفاده شد که نتایج مربوط به بهینه‌سازی المان ساختاری در جدول ۱ و شکل‌های ۶ و ۷ ارائه شده‌اند. در این شکل‌ها منظور از  $n=3, 6, 9, \dots, 30$  استفاده از المان‌های ساختاری با سایز شروع ۳ و گام‌های افزایشی ۳ تا رسیدن به  $n$  است.

در آزمایش‌های مربوط به این بخش، ابتدا تعداد تکرارها ثابت در نظر گرفته شدند و تأثیر اندازه اولیه و گام افزایشی المان ساختاری بررسی شد. برای این منظور از سه سایز شروع ۲، ۳ و ۴ و دو گام افزایش ۲ و ۳ استفاده گردید و در همه موارد تعداد تکرارها ۴ در نظر گرفته شد. همان‌طور که نتایج نشان می‌دهند، اندازه اولیه و گام افزایشی ۳ در مورد هر دو مجموعه، بهترین نتایج را ایجاد کرده‌اند (شکل‌های ۶ و ۷). در آزمایش بعدی با استفاده از اندازه اولیه و گام افزایشی ۳، تعداد تکرارهای استفاده از المان ساختاری بررسی شد. تعداد تکرار لازم به منظور رسیدن به بهترین دقت برای هر مجموعه متفاوت است. برای مجموعه نخست، بهترین دقت پس از هشت تکرار حاصل شد و برای مجموعه دوم پس از شش تکرار.

براساس ماهیت تصویر و داده‌های آموزشی موجود، ۹ کلاس اصلی شامل آب، درخت، آسفالت، قیر، موزاییک (کاشی)، سایه، آجر، چمن‌زار و خاک در نظر گرفته شده است. ۵۵۳۶ داده آموزشی و ۹۷۹۴۰ داده تست با پراکندگی مناسب از همه کلاس‌ها برای مجموعه دوم انتخاب شدند.


### ۳-۲- بهینه‌سازی المان ساختاری

به منظور بررسی تأثیر سایز المان ساختاری در نتایج حاصل از طبقه‌بندی، المان ساختاری با سایزهای متفاوت و ترکیبات مختلف برای ساخت پروفایل مورفولوژی استفاده شد. یکی از عوامل تأثیرگذار بر نتایج حاصل از استفاده از آنالیز مورفولوژی در طبقه‌بندی تصاویر ابرطیفی شهری، نوع، سایز شروع، تعداد تکرارها و گام افزایشی المان ساختاری مورد استفاده در آنالیز مورفولوژی است. تحقیقات انجام شده در این زمینه نشان می‌دهند که المان ساختاری ایزوتروپیک (دایره‌ای) مناسب‌ترین نوع برای استخراج اطلاعات مکانی از تصاویر شهری به شمار می‌آیند، چراکه این نوع المان اطلاعات لازم را در همه زمینه‌ها


## استفاده از آنالیزهای مورفولوژی به منظور بهبود دقت طبقه‌بندی تصاویر ابرطیفی با حد تفکیک بالا

جدول ۱. حالت‌های گوناگون استفاده از المان ساختاری به منظور انتخاب المان ساختاری بهینه

دقت کلی (OA) برای مجموعه دوم	دقت کلی (OA) برای مجموعه اول	تعداد المان‌های ساختاری	گام افزایشی	سایز شروع المان ساختاری	حالت‌های مختلف استفاده از المان ساختاری
۹۷/۵۰	۷۳/۹۰	۴	۲	۲	۱
۹۷/۶۰	۷۴/۶۰	۴	۲	۴	۲
۹۷/۷۲	۷۴/۰۳	۴	۲	۳	۳
۹۷/۸۰	۷۵/۲۷	۴	۳	۳	۴



شکل ۶. انتخاب المان ساختاری بهینه برای مجموعه نخست




شکل ۷. انتخاب المان ساختاری بهینه برای مجموعه دوم


پارامتر، تعداد باندهای متفاوتی انتخاب شدند، سپس با استفاده از طبقه‌بندی کننده ماشین بردار پشتیبان طبقه‌بندی شدند. نتایج این آزمایش‌ها در شکل‌های ۸ و ۹ نشان داده شده‌اند.

### ۳-۳- بررسی تأثیر تعداد باندهای نهایی در دقت طبقه‌بندی

یکی دیگر از عوامل مؤثر در دقت تصویر طبقه‌بندی شده نهایی، تعداد باندهایی است که از استخراج ویژگی نهایی انتخاب می‌شوند. به منظور بررسی تأثیر این



شکل ۸. بررسی تأثیر تعداد باندهای نهایی در دقت طبقه‌بندی برای مجموعه نخست



شکل ۹. بررسی تأثیر تعداد باندهای نهایی در دقت طبقه‌بندی برای مجموعه دوم

پارامتر در دقت نهایی در شکل‌های ۱۰ و ۱۱ ارائه شده است.

آزمایش‌ها نشان می‌دهند که در مجموعه نخست تا سایز ۱۱ افزایش دقت وجود داشته و سایز ۱۱×۱۱ با اختلاف اندکی از سایز ۹ بهترین دقت را به دست آورده و در مورد مجموعه دوم، مناسب‌ترین سایز ۷×۷ است. علت اینکه مجموعه دوم در سایز کوچک‌تری در مقایسه با مجموعه اول به بیشینه دقت می‌رسد این است که مجموعه دوم شامل عوارضی با سایزهای کوچک‌تر است.


همان‌طور که در شکل‌های ۸ و ۹ مشاهده می‌شود، در مورد مجموعه اول با تعداد ۱۵۰ باند و در مورد مجموعه دوم با ۱۰۰ باند بهترین دقت طبقه‌بندی به دست آمده است؛ لذا در سایر بررسی‌های پیش رو از این تعداد ویژگی استفاده شده است.

### ۳-۴- بررسی تأثیر ابعاد کرنل مربعی در


#### پس‌پردازش رأی‌گیری اکثریت

پارامتر تأثیرگذار در آنالیز رأی‌گیری اکثریت، سایز کرنل مربعی مورد استفاده در آن است. نتایج تأثیر این

استفاده از آنالیزهای مورفولوژی به منظور بهبود دقت طبقه‌بندی تصاویر ابرطیفی با حد تفکیک بالا



شکل ۱۰. بررسی تأثیر سایز المان ساختاری در پس‌پردازش رأی‌گیری اکثریت برای مجموعه نخست



شکل ۱۱. بررسی تأثیر سایز المان ساختاری در پس‌پردازش رأی‌گیری اکثریت برای مجموعه دوم

ساخته شدند. برای ساخت EMPها، المان ساختاری دایره‌ای با گام افزایشی ۳ استفاده شد که نتیجه آن یک EMP، ۱۶۹ بعدی بود.

طبقه‌بندی با سه روش بیشترین شباهت، نزدیک‌ترین همسایگی و SVM روی اطلاعات طیفی و EMP انجام گرفت و نتایج آن در جدول‌های ۲ و ۳ گزارش شدند. مطابق دقت‌های کلی، روش SVM با دقت خوبی انجام شده و دقت EMP نیز از اطلاعات طیفی بهتر است. سپس EMP با ۱۶۹ باند با ویژگی‌های

### ۳-۵- پیاده‌سازی نهایی و بحث در مورد نتایج

به‌منظور ارزیابی روش پیشنهادی، ترکیبات گوناگونی از اطلاعات طیفی و مکانی با تعداد ویژگی‌های متفاوت ایجاد شدند و نتایج طبقه‌بندی آنها با یکدیگر مقایسه گردیدند. ابتدا ویژگی NWFE روی داده ابرطیفی استخراج شد. از بین ویژگی‌های حاصل از استخراج ویژگی، ۱۳ ویژگی با حفظ ۹۹ درصد معیار واریانس، به‌عنوان ویژگی‌های منتخب اولیه انتخاب شدند. EMPها مطابق توضیحات داده‌شده در بخش ۲-۲

برای مجموعه نخست و ۱۰۰ باند برای مجموعه دوم انتخاب شدند و با استفاده از طبقه‌بندی کننده‌های ML، Knn و SVM طبقه‌بندی شدند. مطابق جدول‌های ۲ و ۳ بهترین دقت با استفاده از SVM به دست آمد. شکل‌های ۱۲ و ۱۳ تصاویر طبقه‌بندی شده به روش فاول (الف)، روش پیشنهادی (ب) و روش پیشنهادی بعد از پس‌پردازش (ج) را به ترتیب برای مجموعه نخست و دوم نمایش می‌دهند.

منتخب اولیه ترکیب شدند و یک بردار انباشته شده را تشکیل دادند. مجدداً استخراج ویژگی NWFE روی بردار انباشته شده انجام شد. در این مرحله تعداد باندهای متفاوتی برای طبقه‌بندی انتخاب شدند. با توجه به آزمایش‌هایی که در بخش ۳-۳ انجام شدند، بهترین دقت برای طبقه‌کننده SVM، برای مجموعه نخست با ۱۵۰ باند و برای مجموعه دوم با ۱۰۰ باند به دست آمد. به منظور ارزیابی نهایی، ۱۵۰ باند

جدول ۲. نتایج طبقه‌بندی روش طیفی \_ مکانی پیشنهادی برای مجموعه نخست

بردار ویژگی	ابعاد	بیشترین شباهت		نزدیک‌ترین همسایگی		ماشین بردار پشتیبان	
		ضریب کاپا	دقت کلی	ضریب کاپا	دقت کلی	ضریب کاپا	دقت کلی
طیفی	۱۰۳	۰/۶۷۳۸	۰/۶۰۳۷	۰/۶۵۳۱	۷۰/۲۲	۷۷/۴۳	۰/۷۱۵۴
طیفی کاهش یافته	۱۳	۰/۸۱/۱۸	۰/۷۵۹۸	۰/۶۹۵۳	۷۴/۶۴	۷۲/۶۱	۰/۶۵۹۹
مکانی	۱۶۹	۰/۸۱/۷۴	۰/۷۶۴۰	۰/۷۱۶۹	۷۶/۶۷	۸۱/۵۱	۰/۷۶۴۸
طیفی_مکانی کاهش یافته	۱۵۰	۰/۸۳/۳۹	۰/۷۸۴۶	۰/۷۷۱۰	۸۱/۳۴	۸۲/۷۰	۰/۷۷۹۲
طیفی_مکانی کاهش یافته (روش پیشنهادی)	۱۵۰	۰/۸۴/۱۵	۰/۷۹۴۲	۰/۷۹۸۱	۸۳/۹۶	۸۸/۶۹	۰/۸۵۲۳
طیفی_مکانی کاهش یافته پس از پس‌پردازش (روش پیشنهادی)	۱۵۰	۰/۸۹/۳۱	۰/۸۶۰۵	۰/۸۹۲۳	۹۱/۲۹	۹۵/۷۵	۰/۹۴۳۱



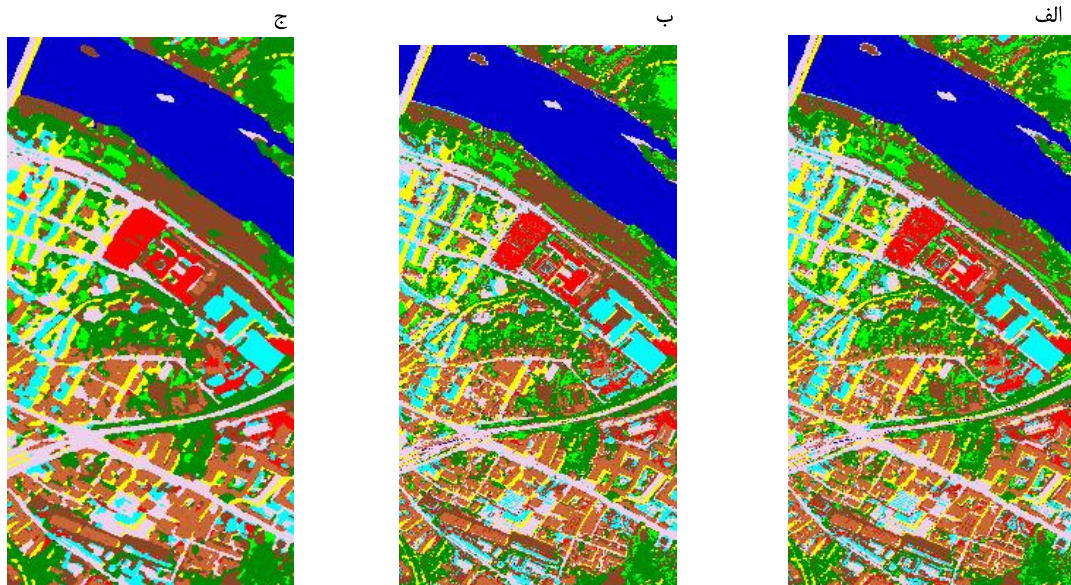
شکل ۱۲. نتایج حاصل از طبقه‌بندی مجموعه نخست (الف) به روش فاول؛ (ب) به روش پیشنهادی قبل از پس‌پردازش؛ (ج) به روش پیشنهادی پس از پس‌پردازش

استفاده از آنالیزهای مورفولوژی به منظور بهبود دقت طبقه‌بندی تصاویر ابرطیفی با حد تفکیک بالا


دقت طبقه‌بندی به وسیله دقت کلی (OA) و ضریب کاپا (K) ارزیابی می‌شود. همان‌طور که نتایج نشان می‌دهند بهترین دقت در مورد هر دو داده با طبقه‌بندی کننده SVM به دست آمده و روش پیشنهادی بهبود چشمگیری در دقت نهایی ایجاد کرده است. نتایج حاصل از پیاده‌سازی روش پیشنهادی روی مجموعه دوم در جدول ۳ ارائه شده است.

جدول ۳. نتایج طبقه‌بندی روش طیفی - مکانی پیشنهادی برای مجموعه دوم

بردار ویژگی	ابعاد	بیشترین شباهت		نزدیک‌ترین همسایگی		ماشین بردار پشتیبان	
		دقت کلی	ضریب کاپا	دقت کلی	ضریب کاپا	دقت کلی	ضریب کاپا
		طیفی	۱۰۲	۸۷/۳۰	۰/۷۸۶۳	۹۶/۶۱	۰/۹۳۲۵
طیفی_کاهش‌یافته	۱۳	۸۹/۲۰	۰/۸۲۱۱	۹۶/۸۳	۰/۹۴۶۳	۹۶/۷۵	۰/۹۴۱۳
مکانی (EMP)	۱۶۹	۸۳/۰۳	۰/۷۳۲۳	۹۷/۹۵	۰/۹۶۱۲	۹۸/۳۷	۰/۹۷۰۴
طیفی_مکانی کاهش یافته (Fauvel)	۱۰۰	۸۹/۸۴	۰/۸۲۹۸	۹۸/۰۸	۰/۹۷۰۱	۹۸/۸۶	۰/۹۷۹۴
طیفی_مکانی کاهش یافته (روش پیشنهادی)	۱۰۰	۸۹/۷۸	۰/۸۲۹۱	۹۸/۳۵	۰/۹۷۰۳	۹۸/۹۸	۰/۹۸۴۷
طیفی_مکانی کاهش یافته بعد از پس‌پردازش (روش پیشنهادی)	۱۰۰	۹۳/۲۰	۰/۸۸۳۵	۹۸/۸۵	۰/۹۸۲۴	۹۹/۳۶	۰/۹۸۷۴



شکل ۱۳. نتایج حاصل از طبقه‌بندی مجموعه دوم (الف) به روش فاول؛ (ب) به روش پیشنهادی قبل از پس‌پردازش؛ (ج) به روش پیشنهادی بعد از پس‌پردازش



شکل ۱۴. نمونه‌ای از تغییرات حاصل از استفاده از روش پس‌پردازش رأی‌گیری اکثریت روی مجموعه دوم (الف) قبل از پس‌پردازش؛ (ب) بعد از پس‌پردازش

کمتری دارد و مرز بین کلاس‌ها در آن واضح‌تر و دقیق‌تر است (شکل ۱۴).

به‌دلیل وجود افزونگی داده در داده ابرطیفی (Landgrebe, 2003)، و نیز در EMP (Fauvel, 2007) از استخراج ویژگی استفاده شد. روش ارائه‌شده، با در نظر گرفتن مزیت‌های اطلاعات طیفی و مکانی به‌صورت هم‌زمان موفق بوده است. برای انجام مطالعات آینده پیشنهاد می‌شود که خصوصیات بافت (Epifanio and Soille, 2007) نیز به‌عنوان اطلاعات مکانی به بردار نهایی برای طبقه‌بندی اضافه شود.

#### ۴- نتیجه‌گیری و پیشنهادها

در پژوهش حاضر طبقه‌بندی داده ابرطیفی با حد تفکیک مکانی بالا بررسی شد. ایده اصلی این مقاله تلفیق اطلاعات طیفی و مکانی برای پردازش طبقه‌بندی بود. آزمایش‌ها روی داده ROSIS انجام شدند و نتایج خوبی به‌دست آمد و دقت‌ها نسبت به طبقه‌بندی کننده پیکسل‌مبنا و طبقه‌کننده مورفولوژی‌مبنا<sup>۱</sup> بهبود یافت. چند دلیل برای بهبود دقت روش پیشنهادی در مقایسه با روش فاول وجود دارد. فاول در روش خود برای انتخاب ویژگی‌های منتخب اولیه از روش PCA استفاده کرده، در حالی که در روش پیشنهادی در این نوشتار از روش NWFE استفاده شده است و از آنجاکه

با توجه به نتایج آزمایش‌های بخش ۴-۳، با استفاده از کرنل  $11 \times 11$  برای مجموعه نخست و کرنل  $7 \times 7$  برای مجموعه دوم، آنالیز رأی‌گیری اکثریت روی تصاویر طبقه‌بندی‌شده انجام گرفت، که دقت نهایی طبقه‌بندی را افزایش داد (جدول‌های ۲ و ۳). با توجه به جدول ۲ که نتیجه آزمایش‌های انجام‌شده روی مجموعه نخست داده‌ها را نشان می‌دهد، در قسمت طیفی کاهش یافته با کاهش تعداد باندها به ۱۳، به‌دلیل حساسیت بالای طبقه‌بندی‌کننده SVM، دقت طبقه‌بندی کاهش یافته است. همچنین در طبقه‌بندی با استفاده از اطلاعات مکانی (EMP)، هرچند وجود اطلاعات مکانی دقت را اندکی افزایش داده است اما بازهم دقت آنها در مقایسه با استفاده از اطلاعات طیفی از لحاظ آماری چندان بالا نیست.

در مورد مجموعه دوم که نتیجه آزمایش‌های انجام‌شده روی آن در جدول ۳ نشان داده شده است، در قسمت طیفی کاهش یافته با کاهش تعداد باندها به ۱۳، از دقت طبقه‌بندی کم نشده اما افزایش درخورد توجهی نیز نداشته است. در روش طیفی - مکانی کاهش یافته، وجود اطلاعات مکانی و تعداد باندهای کافی برای طبقه‌بندی ماشین بردار پشتیبان، دقت نهایی طبقه‌بندی را آشکارا افزایش داده است. تصویر طبقه‌بندی‌شده نهایی به روش فاول و روش پیشنهادی برای مجموعه نخست در شکل ۱۲-ب و ۱۲-ج، و برای مجموعه دوم در شکل ۱۳-ب و ۱۳-ج نشان داده شده است. تصویر ۱۲-ج در مقایسه با شکل ۱۲-ب نويز

1. Morphological based



- Morphological Transformations**, IEEE Trans. Geosci. Remote Sens., Vol. 41, No. 9, PP. 1940–1949 .
- Chang C.I., 2003, **Hyperspectral Imaging: Techniques for Spectral Detection and Classification**, New York: Kluwer/Plenum.
- Chanussot J., J.A. Benediktsson and M. Fauvel, Jan., 2006, **Classification of Remote Sensing Images from Urban Areas Using a Fuzzy Possibilistic Model**, IEEE Geosci. Remote Sens. Lett., Vol. 3, No. 1, PP. 40–44.
- Epifanio I. and P. Soille, Apr., 2007, **Morphological Texture Features for Unsupervised and Supervised Segmentations of Natural Landscapes**, IEEE Trans. Geosci Remote Sens., Vol. 45, No. 4, PP. 1074–1083.
- Fauvel M., J. Chanussot and J.A. Benediktsson, 2006, **Evaluation of Kernels for Multiclass Classification of Hyperspectral Remote Sensing Data**, in Proc. ICASSP, Vol. 2, PP. 813–816.
- Fauvel Mathieu, 2007, **Spectral and Spatial Methods for the Classification of Urban Remote Sensing Data**, Doctoral Thesis.
- Fauvel Mathieu, Jón Atli Benediktsson, Jocelyn Chanussot, and Johannes R. Sveinsson, 2008, **Spectral and Spatial Classification of Hyperspectral Data Using SVMs and Morphological Profiles**, Transactions on Geoscience and Remote Sensing, Vol. 46, No. 11.
- این روش برای انتخاب ویژگی‌ها از نمونه‌های آموزشی استفاده می‌کند، ویژگی‌های مناسب‌تری را برای جداسازی بهتر کلاس‌ها انتخاب می‌کند که موجب بهبود دقت نهایی می‌گردد. از طرف دیگر، به دلیل حضور اطلاعات طیفی و مکانی به صورت هم‌زمان در استخراج ویژگی نهایی، در روش پیشنهادی ویژگی‌های منتخب نهایی، دقت طبقه‌بندی را بیشتر افزایش می‌دهند. یکی دیگر از دلایل افزایش دقت در روش پیشنهادی، استفاده از پس پردازش رأی‌گیری اکثریت روی تصویر طبقه‌بندی شده است که با حذف پیکسل‌های اشتباه (نویزی) در هر کلاس و یکپارچه‌کردن هر کلاس از لحاظ مکانی و مشخص‌تر کردن مرز بین کلاس‌ها بهبود جدی در دقت نهایی طبقه‌بندی ایجاد می‌کند.
- ۵- تشکر و قدردانی**
- لازم است از سرکار خانم یولیا تارابالکا<sup>۱</sup> که سخاوتمندانه تصاویر این تحقیق را در اختیار پژوهشگران قرار دادند و در تنظیم مقاله نیز از هیچ کمکی دریغ نورزیدند، سپاس‌گزاری شود.
- ۶- منابع**
- Akçay H. Gökhan and Selim Aksoy, 2007, **Morphological Segmentation of Urban Structures**, IEEE, Department of Computer Engineering, Bilkent University.
- Benediktsson J.A., J.A. Palmason, and J. Sveinsson, Mar., 2005, **Classification of Hyperspectral Data from Urban Areas Based on Extended Morphological Profiles**, IEEE Trans. Geosci. Remote Sens., Vol. 43, No. 3, PP. 480–491.
- Benediktsson J.A., M. Pesaresi, and K. Arnason, Sep. 2003, **Classification and Feature Extraction for Remote Sensing Images from Urban Areas Based on**

1. Yuliya Tarabalka

- Ghamari asl Mohsen, 2006, **Using Nonparametric Weighted Feature Extraction for Dimension Reduction of Hyrspectral Image**, Master of science thesis, K.N. Toosi University of Technology.
- Goetz A.F.H., G. Vane, J.E. Solomon and B.N. Rock, 1985, **Imaging Spectrometry for Earth Remote Sensing**, Science, Vol. 228, No. 4704, PP. 1147-1153.
- Gonzalez R.C. and R.E. Woods, 2008, **Digital Image Processing, Prentice Hall**.
- Gualtieri J.A. and R.F. Crompt, 1998, **Support Vector Machines for Hyperspectral Remote Sensing Classification**, Proc. SPIE, Vol. 3584, PP. 221–232.
- Gualtieri J.A. and S. Chettri, 2000, **Support Vector Machines for Classification of Hyperspectral Data**, in Proc. IGARSS, Vol. 2, PP. 813–815.
- Halldorsson G.H., J.A. Benediktsson and J.R. Sveinsson, 2003, **Support Vector Machines in Multisource Classification**, in Proc. IGARSS, Vol. 3, PP. 2054–2056.
- He Lin, 2010, **Multiscale-Multivariate Autoregressive Detection for Hyperspectral Imagery**, Artificial Intelligence and Computational Intelligence (AICI), PP. 120\_123.
- Jia X., J.A. Richards and D. E. Ricken, 1999, **Remote Sensing Digital Image Analysis: An Introduction**, Berlin, Germany: Springer-Verlag.
- Jimenez L. and D.A. Landgrebe, 1998, **Supervised Classification in High-dimensional Space: Geometrical, Statistical, and Asymptotical Properties of Multivariate Data**, IEEE Trans. Syst., Man, Cybern. C., Vol. 28, PP. 39–54.
- Kelman Timothy, 2009, **Classification of Chinese Tea Samples for Food Quality Control using Hyperspectral Imaging**, Centre for excellence in Signal and Image Processing, Dept of Electronic and Electrical Engineering, University of Strathclyde.
- Keshavarz Ahmad, Ghasemiyan Hasan, 2005, **A Fast Algorithm Based on Support Vector Machin for Classification of Hyperspectral Image Using Spatial Correlation**, Iranian Journal of Electrical and Computer Engineering (IJECE), No. 1.
- Landgrebe D. A., 2003, **Signal Theory Methods in Multispectral RemoteSensing**, Hoboken, NJ: Wiley.
- Mojaradi Barat, 2009, **Feature Extraction for Classification of Hyperspectral Image**, Doctoral thesis, K.N. Toosi Univrsity of Technology.
- Palmason J.A., J.A. Benediktsson, J.R. Sveinsson and J. Chanussot, 2005, **Classification of Hyperspectral Data from Urban Areas Using Morphological Preprocessing and Independent Component Analysis**, in Proc. IGARSS, Vol. 1, PP. 176–179.
- Pesaresi M., 2001, **A New Approach for the Morphological Segmentation of High-**

- Resolution Satellite Imagery**, IEEE Trans. Geosci. Remote Sens., Vol. 39, No. 2, PP. 309–320.
- Plaza A., P. Martinez, J. Plaza, R.M. Perez, 2005, **Dimensionality Reduction and Classification of Hyperspectral Image Data Using Sequences of Extended Morphological Transformations**, IEEE Trans. Geosci. Remote Sens., Vol. 43, No. 3, PP. 466-479.
- Rahimzadegan Majid, 2007, **Presentation of Method for Using Feature Extraction and Integeration of Classifiers for Classification of Hyperspectral Data**, master of science thesis, K.N. Toosi Univrsity of Technology.
- Richards John A., 2006, **Remote Sensing Digital Image Analysis**, The Australian National University Research School of Information Sciences, Springer-Verlag Berlin Heidelberg.
- Scott D.W., 1992, **The Curse of Dimensionality and Dimension Reduction, in Multivariate Density Estimation**, Theory, Practice, and Visualization, New York: Wiley, ch. 7, PP. 195–217.
- Shah hoseyni Reza, Homayooni Saeed, Serajian Mohamad Reza, 2009, **Classification of Hyperspectral Image Using of Support Vector Machin**, Tehran university, Geomatic conference.
- Soille Pierre, 2003, **Morphological Image Analysis: Principles and Applications**, Springer-Verlag New York, Inc. Secaucus, NJ.
- Tarabalka Yuliya, 2009, **Spectral–Spatial Classification of Hyperspectral Imagery Based on Partitional Clustering Techniques**, IEEE Geoscience and Remotesensing, Vol. 47, No. 8.
- Tian Qingjiu, 2010, **Extraction of Hydrocarbon Content Information by Using Hyperspectral Image**, Geoinformatics, 2010 18th International Conference on.
- Tuominen Jyrki, 2011, **Detection of Environmental Change Using Hyperspectral Remote Sensing**, Tampere University of Technology, Pori Unit.
- Zortea M., A. Plaza, 2009, **Spatial Preprocessing for Endmember Extraction**, IEEE, Transactions on Geoscince and Remote Sensing.