



سنجش از دور & GIS ایران



سال اول، شماره اول، بهار ۱۳۸۸
Vol.1, No.1, Spring 2009

سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

۹۹-۱۱۴

ارائه روشی برای طبقه‌بندی داده‌های ابرطیفی AVIRIS، با استفاده از استخراج ویژگی و ترکیب طبقه‌بندی‌کننده‌ها

مجید رحیم‌زادگان^۱، محمدرضا مباشری^{۲*}، محمدجواد ولدان‌زوج^۳، یاسر مقصودی مهرانی^۳

- ۱- دانشجوی دکترای مهندسی سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۲- دانشیار گروه مهندسی سنجش از دور، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۳- دانشجوی دکتری سنجش از دور، دانشگاه Calgary کانادا

تاریخ پذیرش مقاله: ۸۸/۱۱/۵

تاریخ دریافت مقاله: ۸۸/۴/۲

چکیده

یکی از پرکاربردترین روش‌های طبقه‌بندی نظارت‌شده، روش بیشترین احتمال است که در آن، به‌منظور طبقه‌بندی از پارامترهایی آماری مانند ماتریس واریانس کوواریانس استفاده می‌شود. در تصاویر ماهواره‌ای ابرطیفی، به علت محدودیت نمونه‌های آموزشی و ابعاد بالای طیفی (زیاد بودن تعداد باندها)، احتمال یکتا شدن ماتریس‌های برآورد شده و یا کاهش دقت طبقه‌بندی وجود دارد. به‌منظور حل این مشکل از روش‌های مختلفی همچون کاهش تعداد ویژگی‌ها (کاهش تعداد باندهای استفاده شده) و یا ترکیب طبقه‌بندی‌کننده‌ها استفاده می‌گردد. در این پژوهش از تلفیق این دو روش استفاده شده است، بدین ترتیب که برای کاهش ابعاد، روش استخراج ویژگی غیرپارامتریک وزن‌دار به علت مزایای متعدد آن به کار رفته است؛ و در مورد ترکیب طبقه‌بندی‌کننده‌ها برای ایجاد ترکیبات مناسب از طبقه‌بندی‌کننده‌ها، از روش تغییر ویژگی‌های ورودی و روش استخراج ویژگی بر مبنای کلاس استفاده شده است. همچنین در ترکیب خروجی طبقه‌بندی‌کننده‌ها، از روش‌های سطح اندازه‌گیری استفاده شده است. تصویر ابرطیفی مورد استفاده در این پژوهش، تصویر سنجنده AVIRIS مربوط به منطقه‌ای جنگلی / کشاورزی در شمال ایالت ایندیانا در امریکاست. پس از پیاده‌سازی روش استخراج ویژگی غیرپارامتریک وزن‌دار، دقت طبقه‌بندی کلی ۸۵/۶۷ درصد حاصل گردید. در ترکیب طبقه‌بندی‌کننده‌ها، دقت طبقه‌بندی کلی ۸۹/۲۶ درصد و در روش پیشنهادی دقت طبقه‌بندی کلی ۸۹/۳۴ درصد به دست آمد، که در قیاس با دو روش تشکیل‌دهنده آن، دقت طبقه‌بندی بهبود یافته است. به‌رغم کم بودن میزان بهبود دقت، به علت کاهش پیچیدگی محاسبات و همچنین امکان انجام محاسبات موازی، روش پیشنهادی در این پژوهش مناسب‌تر به نظر می‌رسد.

کلیدواژه‌ها: ابرطیفی، طبقه‌بندی، استخراج ویژگی، ترکیب طبقه‌بندی‌کننده‌ها، کلاس.

* نویسنده مکاتبه‌کننده: تهران، خیابان ولیعصر، تقاطع میرداماد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده ژئودزی و ژئوماتیک، تلفن: ۰۹۱۲۱۲۲۶۳۰

۱- مقدمه

ماهواره‌های ابرطیفی وجود دارد که از مهم‌ترین و پراستفاده‌ترین آنها روش بیشترین احتمال^۲ است. روش بیشترین احتمال به کمک نمونه‌های آموزشی، پارامترهایی آماری (ماتریس واریانس کواریانس، میانگین و نظایر اینها) را برآورد می‌کند و به طبقه‌بندی این تصاویر می‌پردازد. به علت محدودیت نمونه‌های آموزشی و همچنین ابعاد بالای این تصاویر، برآورد نمونه‌های آموزشی با مشکل مواجه خواهد شد (Li et al., 2007)، و به همین خاطر بایستی به روشی تعداد ویژگی‌ها را کاهش داد.


۱-۱- طرح مسئله

در تصاویر مربوط به سنجش از دور، با بالا رفتن تعداد باندها، ممکن است دو اثر رخ دهد. نخست، با افزایش تعداد باندها، جدایی بین کلاس‌های مختلف افزایش می‌یابد، که این خود اثری مثبت برای تشخیص کلاس‌های مختلف است (شکل ۲، چپ). لیکن همزمان با این اثر با افزایش ابعاد، دقت برآورد پارامترهای آماری کلاس‌ها کاهش می‌یابد (شکل ۲، وسط). در واقع مجموع این دو اثر به این ترتیب عمل می‌کند که با افزایش ابعاد تا یک تعداد ثابت باند، دقت افزایش پیدا می‌کند؛ اما پس از این تعداد باند، دقت طبقه‌بندی شروع به کاهش می‌کند، که مجموع این دو اثر در (شکل ۲ راست) آمده است.

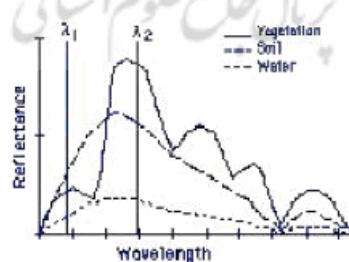
سنجنده‌های ابرطیفی^۱، سنجنده‌هایی هستند که قابلیت جمع‌آوری داده را در تعداد باندهای طیفی بسیار زیاد در خود دارند (بیش از ۲۰۰ باند طیفی) و بنابراین برای تجزیه و تحلیل این داده‌ها به روش‌های خاصی نیاز است. برای نمایش تصاویر ابرطیفی می‌توان از فضاهای مختلف استفاده کرد. این فضاها، که در شکل ۱ نشان داده شده، شامل اینهاست: (۱) فضای تصویری؛ (۲) فضای طیفی؛ و (۳) فضای ویژگی (Landgrebe, 1999).

در سنجنده‌های ابرطیفی، فضای تصویر را می‌توان به صورت مکعبی در نظر گرفت که دو بعد اول پیکسل‌های تصویر است؛ و بعد سوم، باندهای طیفی مختلف. فضای طیفی، پاسخ طیفی کلاس‌های مختلف را به صورت تابعی از طول موج بیان می‌کند. فضای آخر که در این مقاله مورد نظر است، فضای ویژگی است. در این فضا، باندهای مختلف در واقع محورهای مختصات اند و هر پیکسل با توجه به پاسخ طیفی خود، به صورت یک نقطه نمایش داده می‌شود.


یکی از معمول‌ترین روش‌های استخراج اطلاعات از تصاویر ماهواره‌ای ابرطیفی، طبقه‌بندی است که مقادیر پیکسل‌ها در تصویر اولیه را با کلاس‌ها جایگزین می‌کند و نقشه‌ای موضوعی بدین ترتیب به دست می‌آید. روش‌های مختلفی برای طبقه‌بندی تصاویر



(الف) فضای تصویر



(ب) فضای طیفی



(ج) فضای ویژگی

شکل ۱. فضاهای مختلف نمایش داده‌های ابرطیفی (برگرفته از Landgrebe, 2003)

1. Hyperspectrol
2. Maximum Likelihood

استخراج ویژگی، به علت اینکه از تمامی اطلاعات موجود در باندها استفاده می‌شود، امکان از دست رفتن اطلاعات کمتر است. در این مقاله روش‌های استخراج ویژگی مدنظر هستند، زیرا اطلاعات کمتری را در قیاس با روش‌های انتخاب ویژگی از دست می‌دهند.

در بازه فعالیت‌های انجام شده در زمینه استخراج ویژگی، روش‌های مختلفی وجود دارد. این روش‌ها هر یک نقاط ضعف روش‌های قبلی را پوشش می‌دهند و نقاط قوت آنها را در نظر می‌گیرند.


در این قسمت روش‌های مختلف استخراج ویژگی، چون استخراج ویژگی به روش آنالیز تفکیک^۱ (Loog et al.,^۲ (Fukunaga, 1990; Campbell, 1984) aPAC-LDR (2001)، استخراج ویژگی محدوده تصمیم‌گیری^۳ (Lee and Landgrebe, 1993) و استخراج ویژگی غیرپارامتریک وزن‌دار^۴ (Kuo and Landgrebe, 2001) مطرح است.

روشی که در این مقاله مدنظر است، روش استخراج ویژگی غیرپارامتریک وزن‌دار است که به نوعی نقاط ضعف روش‌های قبلی را پوشش می‌دهد و نقاط قوت آنها را در خود دارد.

مجموع این دو اثر مثبت و منفی، پدیده‌ای است که با نام اثر Hughes شناخته می‌شود (Hughes, 1968; Landgrebe, 2003). به علت مشکلات ناشی از پدیده Hughes، معمولاً به روشی برای کاهش تعداد ویژگی‌ها نیاز است.

۲- روش‌های استخراج ویژگی

همان‌طور که ذکر شد، به علت مشکلات عملی‌ای که ابعاد بالای تصاویر ابرطیفی ایجاد می‌کنند، همیشه به روشی برای کاستن ابعاد این تصاویر نیاز است. به‌طور کلی برای کاستن ابعاد تصاویر ابرطیفی دو روش وجود دارد: (۱) انتخاب ویژگی؛ و (۲) استخراج ویژگی. روش اول از میان تمام ویژگی‌ها، آنهایی را انتخاب می‌کند که بیشترین اطلاعات و کمترین نویز را داشته باشند؛ ولی روش دوم اطلاعات تمامی باندها را مورد استفاده قرار می‌دهد و فضای ویژگی را به فضایی نگاشت می‌کند که بیشترین اطلاعات موجود در فضا، به ویژگی‌های اول فضای جدید منتقل شود. روش انتخاب ویژگی، به علت اینکه تعدادی از باندها را حذف می‌کند، ممکن است مقداری از اطلاعات را از دست بدهد؛ اما در روش



شکل ۲. تأثیرات ایجاد شده به علت پدیده Hughes (چپ: افزایش جدایی بین کلاس‌ها با افزایش ابعاد، وسط: کاهش دقت برآورد پارامترهای آماری با افزایش ابعاد با تعدادی نمونه آموزشی ثابت، راست: ترکیب دو اثر متضاد قبلی بر روی دقت طبقه‌بندی) (بازسازی شده از Landgrebe, 2003)

1. Discriminant Analysis Feature Extraction
2. The approximated Pairwise Accuracy Criterion-Linear Dimension Reduction
3. Decision Boundary Feature Extraction
4. Nonparametric Weighted Feature Extractor

۲-۱- مشکلات روش‌های استخراج ویژگی

در روش‌های استخراج ویژگی معمولاً از بهینه کردن یک معیار - مانند معیار Fisher - استفاده می‌شود که در آن از ماکزیمم کردن ماتریس پراکندگی بین کلاسی و مینیمم کردن ماتریس پراکندگی داخلی کلاسی استفاده می‌شود. چون در این حالت، پراکندگی تمام کلاس‌ها مورد استفاده قرار می‌گیرد، ممکن است جدایی تمامی کلاس‌ها به خوبی مدل نشود. بنابراین می‌توان این معیارها را برای تک‌تک کلاس‌ها برآورد کرد و به استخراج ویژگی‌هایی برای هر کدام پرداخت، و در نهایت با کمک هر سری ویژگی استخراج شده، طبقه‌بندی‌کننده را نیز تعریف کرد و نهایتاً با کمک روش‌های ترکیب طبقه‌بندی‌کننده‌ها، به ترکیب کردن خروجی این طبقه‌بندی‌کننده‌ها با یکدیگر پرداخت.

۳- روش‌های موجود در زمینه ترکیب طبقه‌بندی‌کننده‌ها

یکی از روش‌هایی که می‌تواند مشکلات پدید آمده به علت ابعاد بالای تصاویر ابرطیفی و همچنین کافی نبودن تعداد نمونه‌های آموزشی را مرتفع سازد، استفاده از ترکیب طبقه‌بندی‌کننده‌هاست. در این روش با ایجاد طبقه‌بندی‌کننده‌های مختلف و طبقه‌بندی تصاویر ابرطیفی به وسیله هر کدام از آنها و نهایتاً ترکیب نتایج به دست آمده از هر یک از طبقه‌بندی‌کننده‌ها، می‌توان به دقت طبقه‌بندی بالاتری در قیاس با هر یک از طبقه‌بندی‌کننده‌ها دست یافت (Xu et al., 1992).

۳-۱- روش‌های ساخت ترکیبات طبقه‌بندی‌کننده‌ها

در ترکیب طبقه‌بندی‌کننده‌ها، هدف ساخت طبقه‌بندی‌کننده‌هایی است که دارای دو شرط تنوع و صحت باشند (Hansen and Salamon, 1990). طبقه‌بندی‌کننده صحیح، آنی است که دارای دقتی بالاتر از ۵۰ درصد باشد؛ و یا به عبارت دیگر، دقت آن از حدس تصادفی بیشتر باشد. همچنین دو طبقه‌بندی‌کننده، هنگامی متنوع‌اند که خطاهای

مختلفی در مورد داده‌های جدید ایجاد کنند. روش‌های بسیاری برای ساخت ترکیبات طبقه‌بندی‌کننده‌ها پیشنهاد شده است. به طور کلی سه روش برای ایجاد ترکیب‌های طبقه‌بندی‌کننده‌ها وجود دارد: تغییر نمونه‌های آموزشی، تغییر کلاس‌های خروجی و تغییر ویژگی‌های ورودی.

در روش تغییر نمونه‌های آموزشی برای ایجاد ترکیبات، الگوریتم آموزشی چندین بار - و هر بار با زیرمجموعه‌های مختلف از نمونه‌های آموزشی - انجام می‌شود این خود دارای سه روش است: Bagging (Breiman, 1996)، تجزیه داده‌های آموزشی (Chan and Stolfo, 1995) و Boosting (Freund and Schapire, 1995; Schapire, 1990).

روش تغییر کلاس‌های خروجی که Dietterich and Bakiri در سال ۱۹۹۵ مطرح کرده‌اند، برای ساختن ترکیبی خوب از طبقه‌بندی‌کننده‌ها، مقادیر خروجی کلاس‌ها را که به الگوریتم آموزش داده می‌شود، تغییر می‌دهد. برای نمونه، می‌توان مسئله چندکلاسی را به مسئله‌ای دو کلاسی تبدیل کرد.

در روش عمومی سوم که Benediktsson و دیگران (2008) و Dietterich (2000) مورد بررسی قرار داده‌اند، از تغییر بر روی ویژگی‌های موجود برای الگوریتم آموزش به منظور ایجاد چند طبقه‌بندی‌کننده استفاده می‌شود. این روش زمانی مؤثر می‌افتد که تعداد ویژگی‌های ورودی بسیار زیاد باشد. برای این مورد می‌توان دو روش کلی نام برد: انتخاب ویژگی، و استخراج ویژگی. هر دو روش، چندین سری ویژگی با استفاده از ویژگی‌های اصلی ایجاد می‌کنند و سپس هر یک از طبقه‌بندی‌کننده‌ها بر روی این سری‌ها آموزش می‌بیند. در این مقاله روش استخراج ویژگی، برای ایجاد طبقه‌بندی‌کننده‌ها مورد بررسی قرار گرفته است.

۳-۲- روش‌های ترکیب نتایج طبقه‌بندی‌کننده‌ها

پژوهشگرانی چون (XU., 1992) و دیگران نشان دادند روش‌های ترکیب طبقه‌بندی‌کننده‌ها می‌تواند با توجه

۳-۳- مشکلات روش‌های ترکیب نتایج طبقه‌بندی‌کننده‌ها

در تمامی این روش‌ها می‌توان در اکثر موارد با ترکیب نتایج طبقه‌بندی‌کننده‌ها، به دقت بیشتری نسبت به هر یک از طبقه‌بندی‌کننده‌های پایه دست یافت. تمامی روش‌هایی که تاکنون پیاده‌سازی شده‌اند، در حالت تغییر ویژگی‌های ورودی، از انتخاب ویژگی به همراه ترکیب طبقه‌بندی‌کننده‌ها استفاده کرده‌اند. اما در تصاویر ابرطیفی، روش استخراج ویژگی، به علت اینکه از اطلاعات تمامی باندها استفاده می‌کند و هیچ اطلاعاتی را در مورد جدایی بین کلاس‌ها از دست نمی‌دهد، به دقت بالاتری در انتخاب ویژگی دست می‌یابد.

بنابراین با در نظر گرفتن استخراج ویژگی به همراه ترکیب طبقه‌بندی‌کننده‌ها می‌توان به دقت بالاتری در قیاس با روش‌های قبلی دست یافت.

۴- نظریه روش پیاده‌سازی شده

در این مقاله، هدف ایجاد طبقه‌بندی‌کننده‌های مختلف با استفاده از استخراج ویژگی بر مبنای کلاس و ترکیب نتایج این طبقه‌بندی‌کننده‌ها، به منظور دستیابی به طبقه‌بندی نهایی است. روش استخراج ویژگی منتخب، روش استخراج ویژگی غیرپارامتریک وزن‌دار است که در این مقاله برای ایجاد طبقه‌بندی‌کننده‌های مختلف، از استخراج ویژگی غیرپارامتریک وزن‌دار بر مبنای کلاس استفاده خواهد شد. روش در نظر گرفته شده برای ترکیب نتایج طبقه‌بندی‌کننده‌ها در این مقاله، روش ذکر شده به وسیله Maghsoudi Mehrani و همکاران (2006) است، که به نوعی از روش‌های سطح اندازه‌گیری استفاده می‌کند.

به نوع اطلاعات تولیدشده به وسیله هر یک از طبقه‌بندی‌کننده‌ها، دسته‌بندی شوند. این روش‌ها می‌توانند با توجه به خروجی‌های طبقه‌بندی‌کننده‌ها، به سه دسته تقسیم شوند:

روش‌های سطح مفهوم^۱ که در این سطح، خروجی هر طبقه‌بندی‌کننده، تنها یک برچسب کلاس برای هر پیکسل ورودی است. این روش خود به سه روش انجام شدنی است: رأی‌گیری اکثریت (Lam and Suen, 1997)، روش رأی‌گیری اکثریت وزن‌دار (Lam and Suen, 1995) و روش‌های مبتنی بر تئوری بیز (Lam and Suen, 1997).

در روش‌های سطح رتبه^۲ (Ho et al., 1996)، خروجی هر طبقه‌بندی‌کننده، فهرستی از کلاس‌های ممکن با رتبه‌های‌شان برای هر پیکسل ورودی است. در این روش کلاس برنده، کلاسی است که بیشترین رتبه را داشته باشد.

روش‌های سطح اندازه‌گیری^۳ (Kittler, 1996a) و (Kittler, 1996b) که در این سطح، خروجی هر طبقه‌بندی‌کننده، لیستی از سطوح اطمینان مربوط به کلاس‌ها به ازای هر پیکسل ورودی است. در این روش هر طبقه‌بندی‌کننده برای هر کلاس، یک سطح اطمینان در نظر می‌گیرد، که نهایتاً این سطوح اطمینان با هم ترکیب می‌گردند و نتیجه ترکیب نهایی حاصل می‌شود. برای ترکیب در سطوح اطمینان روش‌های مختلفی وجود دارد، که مهم‌ترین آنها روش‌های میانگین ساده، ضرب، بیشینه، کمینه، میانگین میانگین و روش پشته‌ای^۴ است. روشی که در این مقاله استفاده می‌شود، روش میانگین ساده است. این روش یکی از ساده‌ترین قوانین ترکیب در سطح اندازه‌گیری است که بر پایه میانگین‌گیری سطوح اطمینان خروجی طبقه‌بندی‌کننده‌های مربوط به یک کلاس بنا نهاده شده است.

1. Abstract-level
2. Rank-level
3. Measurement-level
4. Stacked

۴-۱- استخراج ویژگی NW بر مبنای کلاس

روش NWFE برای اولین بار به وسیله Kuo and Landgrebe (2001) مطرح شد. ایده اصلی این روش، در نظر گرفتن وزن‌های متفاوت برای هر نمونه به منظور محاسبه «میانگین محلی» و تعریف ماتریس پراکندگی بین کلاسی و داخل کلاسی غیرپارامتریک جدید برای استخراج ویژگی است (Kuo and Landgrebe, 2001). در NWFE، ماتریس پراکندگی بین کلاسی به صورت رابطه (۱) تعریف می‌شود.

رابطه (۱)

$$S_b = \sum_{i=1}^{nc} \frac{p_i}{nc-1} \sum_{j=1}^{nc} \sum_{\substack{k=1 \\ j \neq i}}^{n_i} \lambda_k^{(i,j)} (x_k^{(i)} - M_j(x_k^{(i)})) \times (X_k^{(i)} - M_j(x_k^{(i)}))^T$$

که در آن $x_k^{(i)}$ نمونه k ام کلاس I است. $\lambda_k^{(i,j)}$ وزن ماتریس پراکندگی است و به صورت رابطه (۲) می‌شود.

$$\lambda_k^{(i,j)} = \frac{\text{dist}(x_k^{(i)}, M_j(x_k^{(i)}))^{-1}}{\sum_{l=1}^{n_i} \text{dist}(x_l^{(i)}, M_j(x_l^{(i)}))^{-1}} \quad \text{رابطه (۲)}$$

در حالی که $\text{dist}(a,b)$ فاصله از a تا b است و $M_j(x_k^{(i)})$ میانگین محلی $x_k^{(i)}$ در کلاس j است که به صورت روابط (۳) و (۴) است.

$$M_j(x_k^{(i)}) = \sum_{l=1}^{n_i} W_l^{(i,j)} x_l^{(i)} x_l^{(j)} \quad \text{رابطه (۳)}$$

$$W_l^{(i,j)} = \frac{\text{dist}(x_k^{(i)}, x_l^{(j)})^{-1}}{\sum_{l=1}^{n_i} \text{dist}(x_k^{(i)}, x_l^{(j)})^{-1}} \quad \text{رابطه (۴)}$$

ماتریس پراکندگی داخلی کلاسی غیرپارامتریک وزن‌دار به صورت رابطه (۵) است.

$$S_w = \sum_{i=1}^{nc} p_i \sum_{k=1}^{n_i} \lambda_k^{(i,j)} (x_k^{(i)} - M_i(x_k^{(i)})) \quad \text{رابطه (۵)}$$

ویژگی‌های استخراجی، با بهینه کردن معیار Fisher تعیین می‌شود، که این معیار به صورت رابطه (۶) است.

$$J_{NWFE} = \text{tr}(\sum_w^{-1} \sum_B) \quad \text{رابطه (۶)}$$

برای جلوگیری از مشکل یکتایی ضرب خارجی فاصله‌های بین کلاسی و داخل کلاسی، S_w با رابطه (۷) جایگزین می‌گردد:

$$S_w = 0/5 S_w + 0/5 \text{diag}(S_w) \quad \text{رابطه (۷)}$$

در روش مورد نظر در این مقاله، از استخراج ویژگی بر مبنای کلاس استفاده شده است، تا بتوان به تعداد کلاس‌ها طبقه‌بندی‌کننده به دست آورد و با ترکیب نتایج این طبقه‌بندی‌کننده‌ها به تصویر طبقه‌بندی‌شده نهایی دست یافت. برای انجام استخراج ویژگی بر مبنای کلاس، برای هر کلاس m ، ماتریس‌های پراکندگی بین کلاسی و داخل کلاسی به وسیله روابط (۸) و (۹) به دست می‌آیند تا وارد مرحله ترکیب طبقه‌بندی‌کننده‌ها شوند.

رابطه (۸)

$$S_w = p_m \sum_{k=1}^{N_m} \lambda_k^{(m,j)} (x_k^{(m)} - M_m(x_k^{(m)})) \times (x_k^{(m)} - M_m(x_k^{(m)}))^T$$

$$S_b = \frac{p_m}{N-1} \sum_{j=1}^N \sum_{\substack{k=1 \\ j \neq m}}^{N_m} \lambda_k^{(m,j)} (x_k^{(m)} - M_j(x_k^{(m)})) \times (x_k^{(m)} - M_j(x_k^{(m)}))^T \quad \text{رابطه (۹)}$$

$$+ \sum_{\substack{i=1 \\ i \neq m}}^N \frac{p_i}{N-1} \sum_{k=1}^{N_i} \lambda_k^{(i,m)} (x_k^{(i)} - M_m(x_k^{(i)})) \times (X_k^{(i)} - M_m(x_k^{(i)}))^T$$

حال بایستی به روشی نتایج این طبقه‌بندی‌کننده‌ها را با هم ترکیب کرد. روش ترکیب منتخب، به نوعی از روش‌های سطح اندازه‌گیری استفاده می‌کند که در بخش بعد به تفصیل شرح داده می‌شود.

۴-۲- ترکیب طبقه‌بندی‌کننده‌های حاصل از

استخراج ویژگی بر مبنای کلاس

در روش منتخب این مقاله، بعد از استخراج ویژگی بر مبنای کلاس، روی هر سری از ویژگی‌های استخراج شده بر مبنای کلاس که به تعداد کلاس‌ها خواهد بود،

در مورد پیکسل موردنظر اظهارنظر کرده‌اند، استفاده می‌شود. در مورد پیکسل‌هایی که هیچ طبقه‌بندی‌کننده‌ای در مورد آنها اظهارنظر نکرده است نیز همین حالت وجود دارد، با این تفاوت که در این حالت از تمام طبقه‌بندی‌کننده‌ها استفاده می‌شود.

- پیکسل‌های دسته دوم که دو یا چند طبقه‌بندی‌کننده در موردشان اظهارنظر کرده‌اند، از قوانین ترکیب سطح اندازه‌گیری و از روش Mean، برای تصمیم‌گیری در مورد برجسب نهایی پیکسل‌ها استفاده می‌شود. در این حالت هم استفاده از طبقه‌بندی‌کننده‌ها مانند حالت در نظر گرفتن کلاس با تعداد نمونه آموزشی بیشتر است.

۵- پیاده‌سازی

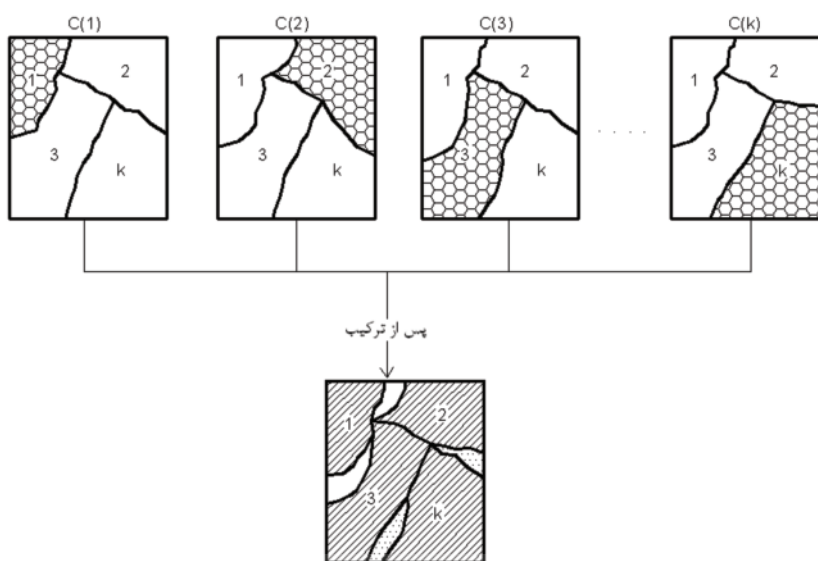
کلیه الگوریتم‌های ارائه شده در این مقاله بر روی تصویر ابرطیفی سنجنده AVIRIS پیاده‌سازی شده‌اند. این تصویر مربوط به یکی از مناطق کشاورزی / جنگلی است، که در ژوئن ۱۹۹۲، به صورت Airborne از ارتفاع ۲۰ کیلومتری، از منطقه‌ای در شمال ایالت ایندیانا گرفته شده است. تصویر موردنظر، تصویری دارای 145×145 پیکسل است که در 220 باند طیفی و با قدرت تفکیک مکانی 20 متر و قدرت تفکیک رادیومتریک 10 بیت گرفته شده است. این تصویر در محدوده طیفی $0.4-2.5$ میکرومتر و با قدرت تفکیک طیفی 10 نانومتر گرفته شده است. داده زمینی مورد استفاده در این مقاله، نقشه پوشش و کاربری زمین شامل 16 کلاس است که در شکل ۴ نشان داده شده، و نام هر کلاس به همراه پیکسل اختصاص داده شده به آنها در جدول ۱ آمده است. این نقشه کاربری در سال ۱۹۹۲ به وسیله کار زمینی تهیه گردیده که حدود 33 درصد آن منطقه جنگلی و 66 درصد آن منطقه‌ای کشاورزی بوده است. از این میان 9 کلاس که دارای فراوانی بیشتری هستند، انتخاب شده‌اند. تمامی برنامه‌های مربوط به این مقاله به وسیله نرم‌افزار MATLAB 7 نوشته شده است.

یک طبقه‌بندی‌کننده آموزش دیده و نیز طبقه‌بندی انجام می‌شود. با انجام این مرحله، به تعداد کلاس‌ها تصویر وجود خواهد داشت که همگی نتایج طبقه‌بندی‌کننده‌ها هستند. حال بایستی این نتایج به روشی با هم ترکیب شوند. در این مقاله از راهبرد زیر برای این ترکیب استفاده می‌شود:

اگر $C(1), C(2), \dots, C(k)$ تصاویر طبقه‌بندی‌شده مربوط به هر یک از طبقه‌بندی‌کننده‌ها باشند و C_T تصویر طبقه‌بندی‌شده نهایی باشد و k تعداد کلاس‌ها، در مورد پیکسل‌ها در تصویر طبقه‌بندی‌شده نهایی، ممکن است سه حالت رخ دهد:

۱. پیکسل‌هایی که تنها یک طبقه‌بندی‌کننده در موردشان اظهارنظر کرده است (قسمت‌هایی که در شکل ۳ به صورت هاشور نمایش داده شده‌اند).
۲. پیکسل‌هایی که دو یا چند طبقه‌بندی‌کننده در مورد آنها اظهارنظر کرده‌اند؛ یعنی در تصویر طبقه‌بندی‌شده نهایی بین دو یا چند کلاس هم‌پوشانی وجود دارد (قسمت‌هایی که در شکل ۳ به صورت لانه‌زنبوری نمایش داده شده‌اند).
۳. قسمت‌هایی که هیچ طبقه‌بندی‌کننده‌ای در مورد آنها اظهارنظر نکرده است؛ یعنی قسمت‌هایی که در تصویر طبقه‌بندی‌شده نهایی به صورت مناطق خالی قرار گرفته‌اند (قسمت‌های سفید در شکل ۳). در این مرحله پیکسل‌های دسته اول به سادگی طبقه‌بندی می‌شوند. برای طبقه‌بندی بقیه پیکسل‌ها روش‌های مختلفی می‌توان پیشنهاد کرد. در این مقاله دو روش مورد بررسی قرار گرفته است:

- در مورد پیکسل‌های دسته دوم که دو یا چند طبقه‌بندی‌کننده در موردشان اظهارنظر کرده‌اند، رأی نهایی به طبقه‌بندی‌کننده‌ای داده می‌شود که تعداد نمونه‌های آموزشی آن از بقیه طبقه‌بندی‌کننده‌ها بیشتر باشد. زیرا کلاسی که نمونه آموزشی بیشتری دارد، کلاسی است که دارای فراوانی بیشتری در مقایسه با دیگر کلاس‌هاست و بنابراین احتمال حضور آن از بقیه کلاس‌ها بیشتر است. در این مرحله فقط و فقط از طبقه‌بندی‌کننده‌هایی که



شکل ۳. نحوه ترکیب در استخراج ویژگی بر مبنای کلاس (Maghsoudi Mehrani et al., 2006)



شکل ۴. نقشه پوشش و کاربری زمین منطقه مورد مطالعه از منطقه‌ای به وسعت $2/9 \times 2/9$ کیلومتر

(بازسازی شده از <http://dynamo.ecn.purdue.edu/~biehl/multispec/documentation.html>)

گرفته و کلیه پردازش‌ها بر روی این ۱۹۵ باند انجام شده است.

به دلیل اینکه بتوان میزان قوت الگوریتم را نشان داد، اکثر نمونه‌های موجود به‌عنوان آزمایشی در نظر گرفته شد و بقیه به‌عنوان داده تست انتخاب گردید؛ لذا در این مقاله ۳۰ درصد نمونه‌ها به عنوان نمونه آموزشی

به علت همبستگی بالا بین باندهای تصاویر ابرطیفی و همچنین وجود برخی از باندهای جذبی آب که باعث به وجود آمدن باندهای نویزی در این تصاویر می‌شود، معمولاً از برخی از باندهای 109×103 ، 163×149 و 220×218 به علت نویز بالا حذف شده و ۱۹۵ باند باقی‌مانده برای طبقه‌بندی مورد استفاده قرار

در این میان، حالتی که بیشترین دقت را به دست می‌دهد، حالت استفاده از ۱۴ ویژگی است، با دقت ۸۵/۶۷. در این تعداد ویژگی، دقت طبقه‌بندی کلاس‌های مختلف، در جدول ۱ آمده است.

جدول ۲. دقت طبقه‌بندی کلاس‌های مختلف در روش NWFE برای ۱۴ ویژگی

ردیف	نام کلاس	دقت طبقه‌بندی
۱	Corn-notill	۹۰/۶۵
۲	Corn-min	۷۸/۳۳
۳	Grass/pasture	۹۸/۴۶
۴	Grass/trees	۹۷/۰۲
۵	Hay-windrowed	۹۹/۶۳
۶	Soy-notill	۸۲/۳۸
۷	Soy-mintill	۶۷/۵۴
۸	Soy-clean	۹۲/۴۵
۹	Woods	۹۸/۳۵
Overall accuracy		۸۵/۶۷

همان‌طور که در جدول ۱ ملاحظه می‌شود، هر کلاس در این طبقه‌بندی دقت متفاوتی را نتیجه می‌دهد، که این خود انگیزه‌ای است برای اینکه استخراج ویژگی بر مبنای کلاس انجام گیرد و نتایج به دست آمده از آنها با یکدیگر مقایسه گردد.

۵-۲- پیاده‌سازی ترکیب طبقه‌بندی‌کننده‌ها

در این مقاله برای ایجاد ترکیب از طبقه‌بندی‌کننده‌ها، ابتدا استخراج ویژگی بر مبنای کلاس انجام گرفت؛ بدین ترتیب که برای ایجاد هر طبقه‌بندی‌کننده، هر بار به نحوی استخراج ویژگی انجام شده که بیشترین جدایی بین کلاس مورد نظر و بقیه کلاس‌ها ایجاد شود. مرحله بعد که می‌بایست انجام می‌شد، ایجاد ترکیبی از طبقه‌بندی‌کننده‌ها بود. برای ترکیب طبقه‌بندی‌کننده‌ها می‌توان از راهبردهای مختلفی استفاده کرد. یکی از این راهبردها بدین نحو عمل می‌کند که ابتدا در

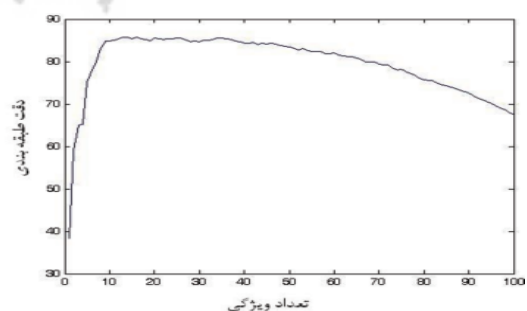
در نظر گرفته شده‌اند و ۷۰ درصد به عنوان نمونه آزمایشی.

۵-۱- پیاده‌سازی روش استخراج ویژگی NWFE

در این قسمت، استخراج ویژگی و طبقه‌بندی روی تصویر مورد نظر انجام شد. با توجه به تعداد ویژگی‌های مختلف استخراج شده، دقت‌های متفاوتی به دست آمده، که نتایج در نمودار شکل ۵ درج گردیده است.

جدول ۱. نام کلاس‌ها به همراه شماره اختصاص داده شده به هر کلاس و تعداد پیکسل هر کلاس

شماره	نام کلاس	تعداد پیکسل
۰	others	۱۰۶۷۰
۱	Alfalfa	۵۴
۲	Corn-notill	۱۴۲۳
۳	Corn-min	۸۳۴
۴	Corn	۲۳۴
۵	Grass/pasture	۴۹۷
۶	Grass/trees	۷۴۷
۷	Grass/pasture-mowed	۲۶
۸	Haywindrowed	۴۸۹
۹	Oats	۲۰
۱۰	Soy-notill	۹۶۸
۱۱	Soy-min till	۲۴۶۸
۱۲	Soy-clean	۶۱۴
۱۳	Wheat	۲۱۲
۱۴	Woods	۱۲۹۴
۱۵	Bldg-grass-trees- drives	۳۸۰
۱۶	Stone-steel towers	۹۵



شکل ۵. دقت طبقه‌بندی کلی نسبت به تعداد ویژگی‌ها در روش NWFE

حاصل نشد. در این حالت بایستی در نظر داشت که در هر کلاس در تعدادی از ویژگی‌های معین بیشترین جدایی را از کلاس‌های دیگر دارد. در جدول ۲ تعداد ویژگی‌های مربوط به طبقه‌بندی‌کننده‌ها، که بیشترین جدایی بین کلاس‌ها را ایجاد می‌کند، آمده است.

بنابراین با در نظر گرفتن تعداد ویژگی‌های استخراجی متفاوت برای هر طبقه‌بندی‌کننده، بایستی افزایش دقت ایجاد شود؛ ولی با در نظر گرفتن تعداد ویژگی‌های متفاوت برای کلاس‌ها و افزایش بیش از حد تعداد ویژگی‌های برخی از کلاس‌ها، احتمال تعدادی از کلاس‌ها بیش از حد افزایش یافته و به علت بالا رفتن احتمال این کلاس‌ها، شانس بقیه برای انتخاب شدن کم می‌شود و در نتیجه دقت کلی کاهش می‌یابد. برای حل این مشکل نیز می‌توان برای کلاس‌هایی که تعداد ویژگی‌های بهینه آنها بسیار زیاد است، حد بیشینه تعداد ویژگی استخراجی در نظر گرفت. در این مورد خاص، همان‌طور که در جدول ۳ مشاهده می‌شود، تعداد ویژگی استخراجی بیشینه که بیشترین دقت را نتیجه می‌دهد، تعداد ۴۰ ویژگی است.

همان‌طور که ملاحظه می‌شود، دقت طبقه‌بندی در حالت بیشینه، به ۸۶/۴۹ رسید که نسبت به حالت استخراج ویژگی و طبقه‌بندی (با دقت طبقه‌بندی ۸۵/۶۷) نشان از افزایش دقت دارد. همچنین دقت طبقه‌بندی هر یک از کلاس‌ها در بهترین حالت با بیشینه دقت، در جدول ۴ آمده است.

مورد هر پیکسل، میزان احتمال نسبت داده شده هر طبقه‌بندی‌کننده به آن پیکسل در مورد کلاس‌های مختلف، به دست می‌آید. در این حالت می‌توان با در نظر گرفتن بشینه آرای یک طبقه‌بندی‌کننده برای کلاس‌های مختلف، به ازای هر طبقه‌بندی‌کننده، یک تصویر به دست آورد. در این حالت برای به دست آوردن تصویر طبقه‌بندی‌شده نهایی از هر کدام از تصاویر طبقه‌بندی‌شده اولیه مربوط به هر طبقه‌بندی‌کننده، پیکسل‌های مربوط به کلاس آن طبقه‌بندی‌کننده (کلاسی که به ازای آن، استخراج ویژگی صورت گرفته است)، در تصویر طبقه‌بندی‌شده نهایی قرار می‌گیرد.

۵-۲-۱- تعلق پیکسل به کلاس با بیشترین تعداد نمونه آموزشی

در این روش در مورد پیکسل‌هایی که دو یا چند طبقه‌بندی‌کننده در مورد آنها اظهار نظر کرده بودند و همچنین در مورد پیکسل‌هایی که هیچ طبقه‌بندی‌کننده‌ای در مورد آنها اظهار نظر نکرده بود، کلاسی به عنوان کلاس برنده انتخاب شد که بیشترین تعداد نمونه‌های آموزشی را داشت.

در این روش ترکیب طبقه‌بندی‌کننده‌ها، ابتدا تمامی کلاس‌ها با تعداد ویژگی‌های استخراجی مساوی با روش ذکر شده، با یکدیگر ترکیب شدند که نتایج به دست آمده، دقت طبقه‌بندی کلی ۸۵/۶۰۶۷ را نشان داد. برخلاف انتظار، دقت بیشتری در مقایسه با حالت استخراج ویژگی بدون ترکیب طبقه‌بندی‌کننده‌ها،

جدول ۳. تعداد ویژگی بهینه برای به دست آوردن بیشترین دقت برای هر کلاس در حالت کلاس با نمونه آموزشی بیشتر به عنوان کلاس برنده

طبقه‌بندی‌کننده	۱	۲	۳	۴	۵	۶	۷	۸	۹
تعداد ویژگی	۱۴	۹	۱۳	۱۰	۴	۸	۱۲۴	۷	۸۶

جدول ۴. میزان دقت طبقه‌بندی کلی برای تعداد ویژگی‌های بیشینه مختلف در حالت کلاس با نمونه آموزشی بیشتر به عنوان کلاس برنده

تعداد ویژگی بیشینه	۳۰ ویژگی	۳۵ ویژگی	۴۰ ویژگی	۴۵ ویژگی	۵۰ ویژگی
دقت (درصد)	۸۶/۴۷	۸۶/۴۱	۸۶/۴۹	۸۶/۳۹	۸۶/۱۹

جدول ۵. دقت طبقه‌بندی کلاس‌های مختلف در حالت کلاس با نمونه آموزشی بیشتر به‌عنوان کلاس برنده، با در نظر گرفتن تعداد ویژگی بیشینه

ردیف	نام کلاس	دقت طبقه‌بندی (درصد)
۱	Corn-notill	۸۸/۳۸
۲	Corn-min	۷۲/۷۶
۳	Grass/pasture	۹۷/۳۱
۴	Grass/trees	۹۵/۸۳
۵	Hay-windrowed	۹۹/۶۳
۶	Soy-notill	۶۸/۹۴
۷	Soy-mintill	۸۳/۷۲
۸	Soy-clean	۸۳/۰۲
۹	Woods	۹۸/۱۱
۱۰	Overall accuracy	۸۶/۴۹

کلاس‌ها به اجرا درآمد، مشاهده شد که دقت برخلاف انتظار دچار افت شده است. این افت دقت به علت افزایش تعداد ویژگی به تعداد بسیار زیاد برای برخی از کلاس‌ها و در نتیجه افزایش احتمالات این کلاس‌ها، احتمالات کلاس‌های دیگر - و به تبع آن، دقت - به میزان بسیار زیادی کاهش می‌یابد. برای حل چنین مشکلی نوعی نرمال‌سازی بین احتمالات انجام شد.

۵-۲-۲-۱- نرمال‌سازی احتمالات به دست آمده از


طبقه‌بندی به منظور ترکیب

برای حل مشکل همسان نبودن احتمالات مربوط به طبقه‌بندی‌کننده‌های گوناگون برای کلاس‌های مختلف، به نوعی روی مقادیر احتمالات به دست آمده نرمال‌سازی انجام شد؛ بدین ترتیب که ابتدا احتمالات طبقه‌بندی‌کننده‌های مختلف نرمال‌سازی شدند؛ یعنی

۵-۲-۲- Mean تخصیص رأی با استفاده از قانون

در این حالت، رأی به کلاسی داده شد که میانگین رأی طبقه‌بندی‌کننده‌های مختلف به آن بیشینه باشد. مانند حالت قبل، ابتدا تمامی کلاس‌ها با تعداد ویژگی‌های مساوی در نظر گرفته شد و ترکیبی صورت گرفت که نتایج مطابق نمودار شکل ۶ بود.

در این مورد هم مشاهده می‌شود دقت در حالتی که تعداد ویژگی‌ها مساوی است، وقتی از ۲۵ ویژگی استفاده شود، بیشینه است (دقت طبقه‌بندی ۸۵/۷۵ درصد)، نشان از پیشرفت خواهد داشت. در این حالت مجدداً برای کلاس‌ها تعداد ویژگی‌های متفاوت در نظر گرفته شد. تعداد ویژگی‌هایی که در این حالت بیشترین جدایی هر طبقه‌بندی‌کننده نسبت به کلاس‌های دیگر را نتیجه می‌دهد، در جدول ۵ آمده است. وقتی که برنامه با تعداد ویژگی‌های متفاوت برای



شکل ۶. دقت طبقه‌بندی کلی نسبت به تعداد ویژگی‌های مختلف در حالت کلاس با میانگین آرای بیشتر، به عنوان کلاس برنده

جدول ۶. تعداد ویژگی بهینه برای به‌دست آوردن بیشترین دقت برای هر کلاس در حالت کلاس با میانگین آرای بیشتر، به‌عنوان کلاس برنده

۹	۸	۷	۶	۵	۴	۳	۲	۱	طبقه‌بندی‌کننده
۸۶	۷	۱۳۲	۵	۵	۳۶	۱۳	۱	۱۴	تعداد ویژگی

از بزرگ‌تر شدن احتمالات برخی از کلاس‌ها و در نتیجه کوچک شدن احتمالات کلاس‌های دیگر - و به تبع آن کاهش دقت کلی - حدی نهایی برای تعداد ویژگی‌های استخراجی قرار داده شود، دقت‌های به دست آمده به شکل جدول ۶ است.

همان‌طور که مشاهده می‌شود، با در نظر گرفتن حداکثر ۵۰ ویژگی استخراجی، دقت پیشرفت کرد، و دقت طبقه‌بندی کلی به ۸۸/۰۱ رسید.

۵-۲-۳- آستانه‌گذاری تعداد ویژگی‌ها و

نرمال‌سازی احتمالات و اعمال فیلتر اکثریت

روش دیگری که می‌توان پس از انجام نرمال‌سازی بین کلاس‌ها و تصاویر پیاده‌سازی کرد، استفاده از اعمال نوعی فیلتر اکثریت است. این روش بدین ترتیب است که در مورد پیکسل‌هایی که دو یا چند طبقه‌بندی‌کننده در مورد آنها اظهار نظر کرده است، از روش در نظر گرفتن میانگین استفاده شود. در واقع یعنی در مورد کلاس‌هایی که بین آنها اختلاف است، در مورد هر کلاس، میانگین احتمالات طبقه‌بندی‌کننده‌های مختلف آن کلاس به دست آورده می‌شود و کلاسی که این مقدار در مورد آن بزرگ‌تر باشد، به عنوان کلاس برنده انتخاب خواهد شد. اما در مورد پیکسل‌هایی که هیچ طبقه‌بندی‌کننده‌ای در مورد آنها اظهار نظر نکرده است، می‌توان از اعمال فیلتر استفاده کرد. این روش بدین ترتیب است که برای

اگر $P(i, j, k, l)$ احتمال مربوط به هر کلاس هر طبقه‌بندی‌کننده هر پیکسل باشد؛ و i نشان‌دهنده طبقه‌بندی‌کننده‌های مختلف و z و k مختصات هر پیکسل، و l مربوط به کلاس‌های مختلف باشد، میانگین (mean)، بیشینه (max) و کمینه (min) احتمالات هر طبقه‌بندی‌کننده برای آ‌های مختلف محاسبه شد و سپس رابطه ۱۰ روی هر احتمال اعمال گردید:

رابطه (۱۰)

$$P'(i, j, k, l) = \frac{P(i, j, k, l) - \text{mean}}{\text{max} - \text{min}}$$

در آن، $P'(i, j, k, l)$ احتمالات جدید به دست آمده بود. سپس بین پیکسل‌های مختلف نرمال‌سازی انجام شد؛ یعنی این‌بار میانگین (mean)، بیشینه (max) و کمینه (min) احتمالات بین پیکسل‌های مختلف (یعنی در طول z و k) محاسبه شد و در نهایت رابطه (۱۱) اعمال گردید:

رابطه (۱۱)

$$P''(i, j, k, l) = \frac{P'(i, j, k, l) - \text{mean}}{\text{max} - \text{min}}$$

بدین ترتیب، احتمالات جدیدی به دست آمد که نوعی نرمال‌سازی روی آنها انجام شده بود. در این راهبرد دقت طبقه‌بندی به ۸۷/۲۸ رسید که در مقایسه با حالات قبل نشان از پیشرفت داشت.

۵-۲-۲- آستانه‌گذاری تعداد ویژگی‌ها و

نرمال‌سازی احتمالات

اگر مانند حالات قبل برای جلوگیری از مشکلات ناشی

جدول ۷. میزان دقت طبقه‌بندی کلی برای تعداد ویژگی‌های بیشینه مختلف در حالت کلاس با میانگین آرای بیشتر، به عنوان کلاس برنده

تعداد ویژگی بیشینه	۳۵ ویژگی	۴۰ ویژگی	۴۵ ویژگی	۵۰ ویژگی	۵۵ ویژگی
دقت (درصد)	۸۷/۳۸	۸۷/۷۱	۸۷/۸۴	۸۸/۰۱	۸۷/۸۴

گیرد و سپس نرمال‌سازی انجام شود و نهایتاً نیز فیلتر به کار رود، نتایج ذکر شده در جدول ۸ به دست خواهد آمد.

در این قسمت دقت طبقه‌بندی ۸۹/۳۳۹۸ در حالت استفاده از بیشینه ۵۰ ویژگی، با استفاده از پنجره ۱۱×۱۱ به دست آمد، که از دقت به‌دست آمده در تمامی روش‌های قبلی بالاتر است.

۶- خلاصه و نتیجه‌گیری

در این مقاله، هدف استفاده از استخراج ویژگی بر مبنای کلاس به‌منظور ایجاد چندین طبقه‌بندی‌کننده و ترکیب نتایج این طبقه‌بندی‌کننده‌ها و دستیابی به نتایج طبقه‌بندی کلی بهتری در مقایسه با هر یک از روش‌های تشکیل‌دهنده این روش بوده است.

روش‌های استخراج ویژگی و طبقه‌بندی بیشترین احتمال مربوط به منطقه مورد مطالعه این مقاله به‌وسیله Kuo and Landgrebe (2001) با ۴۰ داده آموزشی و ۶ داده آزمایشی برای هر کلاس پیاده‌سازی شد که در بهترین حالت برای روش DAFE دقت در

پیکسل‌های موردنظر از پیکسل‌های داخل پنجره‌ای که مرکز آن در پیکسل قرار دارد، به‌عنوان پیکسل‌های مؤثر در انتخاب استفاده می‌شود. برای جلوگیری از مشکل این نوع فیلتر که در مناطق ذوعارضه و همچنین در مناطق مرزی ممکن است باعث تخریب اطلاعات شود، نوعی آستانه‌گذاری برای کلاس برنده انجام می‌گیرد. در واقع هنگامی کلاسی به عنوان کلاس برنده انتخاب می‌شود که حداقل ۵۱ درصد پیکسل‌های پنجره در نظر گرفته شده، به کلاس مورد نظر رأی دهند. در این حالت، پنجره‌هایی با ابعاد متفاوت در نظر گرفته شد و روی تصاویر طبقه‌بندی انجام گردید که نتایج به دست آمده به شرح جدول ۷ است. با توجه به نتایج در این جدول، دقت در حالت استفاده از پنجره ۱۳×۱۳ به بیشینه رسیده است، که افزایشی جدی و عمده در مقایسه با حالت استخراج ویژگی معمولی به‌شمار می‌آید.

اگر روش ذکر شده، با حالتی که برای تعداد ویژگی‌ها حد بیشینه قائل می‌شود، تلفیق گردد؛ یعنی برای تعداد ویژگی‌های استخراجی یک بیشینه قرار

جدول ۸. دقت طبقه‌بندی در حالت تعداد ویژگی‌های بهینه هر کلاس، با استفاده از کلاس با میانگین آرای بیشتر، به عنوان کلاس برنده، با ابعاد فیلترهای مختلف

ابعاد پنجره	۳×۳	۵×۵	۷×۷	۹×۹	۱۱×۱۱	۱۳×۱۳	۱۵×۱۵	۱۷×۱۷	۱۹×۱۹
دقت طبقه‌بندی (درصد)	۸۷/۷۸	۸۷/۹۴	۸۸/۰۷	۸۸/۰۷	۸۸/۰۹	۸۸/۱۰	۸۸/۰۴	۸۷/۹۵	۸۷/۹۳

جدول ۹. میزان دقت طبقه‌بندی کلی برای بیشینه تعداد ویژگی‌های مختلف در حالت کلاس با میانگین آرای بیشتر، به عنوان کلاس برنده، با فیلترهای مختلف

ابعاد پنجره انتخابی	۱۳×۱۳	۱۱×۱۱	۹×۹
تعداد ویژگی بیشینه	۳۵ ویژگی	۴۰ ویژگی	۴۵ ویژگی
دقت طبقه‌بندی (درصد)	۸۸/۶۱	۸۸/۵۷	۸۸/۶۱
	۸۸/۹۸	۸۸/۹۸	۸۹/۰۲
	۸۹/۰۰	۸۹/۰۴	۸۹/۰۴
	۸۹/۲۲	۸۹/۳۴	۸۹/۲۳
	۸۹/۰۵	۸۸/۹۱	۸۸/۹۳
	۸۸/۹۱	۸۸/۹۴	۸۸/۹۷

روش اخیر، می‌تواند نوع تصویر مورد استفاده باشد. در تصویر استفاده شده، کلاس‌ها کاملاً از یکدیگر جدا هستند و میزان تأثیر روش مطرح شده در یک تصویر با تراکم داده بیشتر روشن‌تر خواهد شد.

- به‌علاوه، استفاده از روش ترکیب طبقه‌بندی‌کننده‌ها به همراه انتخاب ویژگی که دارای دقت پذیرفتنی و مناسبی است، در مقایسه با روش استخراج ویژگی و ترکیب طبقه‌بندی‌کننده‌ها، روش زمان‌بری به‌شمار می‌آید که در آن قابلیت تقسیم محاسبات هم وجود ندارد، در حالی که در روش استخراج ویژگی و ترکیب طبقه‌بندی‌کننده‌ها علاوه بر سریع‌تر بودن، می‌توان محاسبات مربوط به الگوریتم‌ها را به صورت موازی^۵، در چندین رایانه اجرا کرد، که این خود سرعت محاسبات را بسیار بالاتر خواهد برد.

بنابراین، با توجه به نتایج به‌دست آمده در این تحقیق، الگوریتم ارائه شده در این مقاله در قیاس با دیگر الگوریتم‌ها، دارای مزایای بیشتری است. با این روش، دقت بالاتری از دیگر روش‌ها (که خود در مقایسه با روش‌های NWFE و ترکیب طبقه‌بندی‌کننده‌ها دارای دقت کمتری هستند) نیز در طبقه‌بندی تصاویر ماهواره‌ای ابرطیفی به دست خواهد آمد.

۷- منابع

Benediktsson, J.A., Garcia, X. C., Waske, B., Fauvel, M., Sveinsson, J.R., Chanussot, J., 2008, **Ensemble Methods for Classification of Hyperspectral Data**, Proceedings 2008 IEEE International Geoscience and Remote Sensing Symposium (IGARSS2008), pp. I-62 – I-65, Boston.

1. Nonparametric Weighted Feature Extraction
2. Maximum Likelihood Estimation
3. Majority Analysis
4. Tree-Structured Markov Random Field
5. Parallel

حدود ۵۸ درصد، برای روش aPAC دقت در حدود ۵۷ درصد و برای استخراج ویژگی غیرپارامتریک وزن‌دار^۱ (NWFE) دقت حدود ۹۰ درصد به دست آمد. همچنین در روش پیاده‌سازی شده به‌وسیله Thoonen و دیگران (2008) از طریق روش تخمین بیشترین احتمال^۲ دقت طبقه‌بندی حدود ۷۴ درصد، با روش تحلیل اکثریت^۳ حدود ۸۱ درصد، و با روش میدانی تصادفی ساختار درختی مارکوف^۴ حدود ۸۲ درصد به دست آمد.

نتایجی که می‌توان از روش مطرح شده به دست آورد، بدین شرح است:

- اگر تصویر مورد استفاده با همین نمونه‌های آزمایشی و نمونه‌های آموزشی به‌وسیله روش بیشترین احتمال طبقه‌بندی گردد و ویژگی‌های اول در نظر گرفته شود، در بهترین حالت که در نظر گرفتن ۶۵ ویژگی است، دقت طبقه‌بندی کلی ۶۸/۳۰ خواهد بود که نشان می‌دهد، استفاده از روش استخراج ویژگی تا چه حد باعث بهبود دقت شده است.

- با انجام استخراج ویژگی به روش NWFE و انجام ترکیب طبقه‌بندی‌کننده‌ها، می‌توان دقت طبقه‌بندی را در مقایسه با هر یک از روش‌های دیگر بالاتر برد. این به گونه‌ای بود که در روش استخراج ویژگی و طبقه‌بندی معمولی، دقت طبقه‌بندی کلی در بهترین حالت به ۸۵/۶۷ رسید. همین‌طور، در روش ترکیب طبقه‌بندی‌کننده‌ها همراه با انتخاب ویژگی، در بهترین حالت که از روش‌های وزن‌دار برای انتخاب وزن به‌منظور ترکیب، و الگوریتم ژنتیک برای انتخاب وزن‌ها استفاده شده بود، این دقت به ۸۹/۲۶ رسید (Maghsoudi Mehrani et al., 2006). در حالی

که در روش پیاده شده در این مقاله، در بهترین حالت دقت طبقه‌بندی کلی به ۸۹/۳۴ رسید، که از تمامی روش‌های گذشته دارای دقت طبقه‌بندی کلی بیشتری بود. علت نزدیک بودن دقت‌ها در دو

- Breiman, L., 1996, **Bagging Predictors**, Machine Learning, vol. 24, 123-140.
- Campbell, A., 1984, **Canonical Variate Analysis, A General Model Formulation**, Australian, J. Statistics, vol. 26, 86-96.
- Chan, P., Stolfo, S., 1995, **A Comparative Evaluation of Voting and Meta-learning on Partitioned Data**, In proceeding of the twelfth International Conference on Machine Learning, 90-98.
- Dietterich, T.G., 2000, **Ensemble Methods in Machine Learning**, in Proc. Multiple Classifier Systems, Lecture Notes in Computer Science, 1-15.
- Dietterich, T.G., Bakiri, G., 1995, **Solving Multiclass Learning Problems via Error-Correcting Output codes**, Journal of Artificial Intelligence Research, Vol. 2, 263-286.
- Freund, Y., Schapire, R.E., 1995, **A Decision-Theoretic Generalization of On-line Learning and an Application to Boosting**, Tech. rep., AT and T Bell Laboratories, Murray Hill, NJ.
- Fukunaga, K., 1990, **Introduction to Statistical Pattern Recognition**, Second Ed., Boston, Academic Press, Boston.
- Hansen, L.K., Salamon, P., 1990, **Neural Network Ensembles**, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 12, 993-1001.
- Ho, T.K., Hull, J.J., Srihari, S.N., 1996, **Decision Combination in Multiple Classifier Systems**, IEEE Transaction, Pattern Analysis and Machine Intelligence, vol. 18(5), 66-75.
- <http://dynamo.ecn.purdue.edu/~biehl/multispec/documentation.html>
- Hughes, G.F., 1968, **On the Mean Accuracy of Statistical Pattern Recognition**, IEEE Trans. Information Theory, vol. 14(1), 55-63.
- Kittler, J., 1996, **Combining Classifiers: a Theoretical Framework**, Pattern Analysis, Appl. 1, 18-27.
- Kittler, J., 1996, **Improving Recognition Rates by Classifier Combination**, In the Fifth Internat, Workshop on Frontiers in Handwriting Recognition, Colchester, UK, 18-27.
- Kuo, B.C., Landgrebe, D.A., 2004, **Nonparametric Weighted Feature Extraction for Classification**, IEEE Transactions on Geoscience and Remote Sensing, vol. 42 No. 5, 1096-1105.
- Kuo, B.C., Landgrebe, D.A., December 2001 **Improved Statistics Estimation and Feature Extraction for Hyperspectral Data Classification**, Ph.D. Thesis and School of Electrical & Computer Engineering Technical Report, Purdue University, West Lafayette.
- Lam, L., Suen, C.Y., 1995, **Optimal Combination of Pattern Classifiers**, IEEE Trans. on Systems, Man, and Cybernetics, Vol. 16, 945-954.

- Lam, L., Suen, C.Y., 1997, **Application of Majority Voting to Pattern Recognition: an Analysis of its Behaviour and Performance**, IEEE Transactions on systems, Man and Cybernet, Vol. 27(5), 553-568.
- Landgrebe, D.A., 1999, **Information Extraction Principles and Methods for Multispectral and Hyperspectral Image Data**, Information Processing for Remote Sensing, World Scientific Publishing Co., Inc., River Edge, NJ, School of Electrical & Computer Engineering, Purdue University, West Lafayette.
- Landgrebe, D.A., 2003, **Signal Theory Methods in Multispectral Remote Sensing**, John Wiley & Sons, Hoboken, N.J.
- Lee, C., Landgrebe, D.A., 1993, **Feature Extraction and Classification Algorithms for High Dimensional Data**, Ph.D. Thesis and School of Electrical Engineering Purdue University Technical Report, West Lafayette, Indiana.
- Li, B., Chi, M., Fan, J., Xue, X., 2007, **Support Cluster Machine**, in Proc. 24th Int. Conf. Mach. Learn., Corvallis, OR, pp. 505-512.
- Maghsoudi Mehrani, Y., 2006, **Using Combination of Classifiers for Classification of Hyperspectral Images**, MSc. Thesis in Remote Sensing, KNTUoosi University of Technology.
- Schapire, R.E., 1990, **The Strength of Weak Learnability**, Machine Learning, Vol. 5, 197-227.
- Thoonen, G., De Backer, S., Provoost, S., Kempeneers, P., Scheunders, P., 2008, **Spatial Classification of Hyperspectral Data of Dune Vegetation along the Belgian Coast**, Geoscience and Remote Sensing Symposium, 2008. IGARSS 2008. IEEE International, 483-486.
- Weighted Pairwise Fisher Criteria, 2008, IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 23, pp. 762-766.