

یک الگوریتم سریع مبتنی بر ماشین بردار پشتیبان برای طبقه‌بندی تصاویر ابرطیفی با استفاده از همبستگی مکانی

احمد کشاورز و حسن قاسمیان یزدی

یکی از تحلیل‌های مهمی که بر روی داده‌های ابر طیفی انجام می‌شود، طبقه‌بندی این تصاویر است. برای یک طبقه‌بندی مطلوب مشخص کردن یک مجموعه کامل از کلاس‌ها ضروری است. تشکیل دادن مجموعه کاملی از کلاس‌ها باید به گونه‌ای باشد که:

۱- شامل تمام کلاس‌هایی که برای کاربر مفید است باشد.
 ۲- یک کلاس منطقی برای نسبت دادن به هر پیکسل از مجموعه داده‌ها وجود داشته باشد.

۳- کلاس‌ها به وسیله ویژگی‌های طیفی موجود قابل جداسازی باشند.
 با توجه به کامل بودن طیف حاصل از تصاویر ابرطیفی به نظر می‌رسد که طبقه‌بندی این تصاویر صحت مناسبی داشته باشد. اما وجود برخی از مشکلات مانع از انجام این کار است. مهمترین مشکلی که در پردازش تصاویر ابرطیفی وجود دارد، کم بودن تعداد نقاط آموزشی نسبت به تعداد باندها است. در واقع مسئله این است که اگر تعداد نقاط آموزشی نسبت به تعداد باندها از یک حد کمتر باشد، خطای تخمین پارامترهای طبقه‌بندی کننده با افزایش تعداد باندها بیشتر می‌شود. در حالت کلی هیوز این مسئله را بر اساس اصول تئوری اثبات کرده است [۲]. بر اساس پدیده هیوز برای تعداد نقاط آموزشی محدود، صحت طبقه‌بندی با افزایش تعداد باندها ابتدا شروع به افزایش می‌کند تا به حداکثر صحت برسد، پس از آن با افزایش تعداد باندها صحت طبقه‌بندی کاهش می‌یابد. مشکل دیگر در استفاده از تصاویر ابرطیفی زیاد بودن تعداد باندها و حجم اطلاعات می‌باشد که باعث می‌شود طبقه‌بندی تصاویر ابرطیفی بسیار زمان‌بر باشد [۳].

با توجه به دو مشکل ذکر شده، یک راه حل برای بهبود عملکرد طبقه‌بندی کننده‌های آماری، کاهش تعداد باندها قبل از طبقه‌بندی تصاویر ابر طیفی است. با کم کردن تعداد باندها، نسبت تعداد نقاط آموزشی به تعداد باندها افزایش می‌یابد. این کار با استفاده از الگوریتم‌های کاهش باند انجام می‌شود. این الگوریتم‌ها را می‌توان در حالت کلی به دو گروه تقسیم کرد. در گروه اول که به آنها الگوریتم‌های انتخاب باند می‌گویند، بعضی باندها با استفاده از یک سری معیارها انتخاب شده و بقیه باندها کنار گذاشته می‌شوند. اگر چه استفاده از این الگوریتم‌ها تعداد باندها را کم می‌کند، ولی دو مشکل اساسی در استفاده از این روش‌ها وجود دارد. اولین مشکل بهینه نبودن باندهای انتخابی برای طبقه‌بندی است. در نتیجه نمی‌توان تضمین کرد که با استفاده از باندهای انتخابی بهترین دقت طبقه‌بندی حاصل شود. مشکل دوم ریختن اطلاعات باندهای کنار گذاشته شده است. در نتیجه از تصویرهای ابرطیفی استفاده بهینه نشده است. گروه دوم الگوریتم‌های کاهش باند، داده‌ها را با استفاده از یک تبدیل از فضای اولیه به فضای ثانویه‌ای به نام فضای ویژگی منتقل می‌کنند. سپس با استفاده از یک معیار برخی از ویژگی‌ها انتخاب می‌شود. در این روش‌ها دقت حاصل از طبقه‌بندی وابستگی زیادی به الگوریتم استخراج ویژگی دارد. یک الگوریتم استخراج ویژگی بهینه باید به گونه‌ای باشد که اولاً در ویژگی‌های حاصل تمامی کلاس‌های مورد نظر وجود داشته و کلاس‌ها قابل جداسازی باشند. ثانیاً حداقل تعداد ویژگی‌های لازم برای طبقه‌بندی را در اختیار قرار دهد. در چند سال اخیر الگوریتم‌های استخراج ویژگی زیادی مانند تحلیل مؤلفه‌های اصلی، تحلیل مؤلفه‌های مستقل [۴]، نگاشت جستجوگر [۵]، استخراج ویژگی با رمز تصمیم‌گیری [۶]، تحلیل ممیز و تبدیل موجک [۷]، به منظور کاهش تعداد ویژگی‌ها و بهبود طبقه‌بندی تصاویر ابرطیفی مورد استفاده قرار گرفته‌اند. اما این الگوریتم‌ها به دلیل

چکیده: با افزایش تعداد باندهای تصاویر سنجنش از دور، الگوریتم‌های استخراج ویژگی مانند تحلیل مؤلفه‌های اصلی، تحلیل مؤلفه‌های مستقل، نگاشت جستجوگر، استخراج ویژگی با رمز تصمیم‌گیری، تحلیل ممیز و تبدیل موجک به منظور کاهش تعداد ویژگی‌ها و بهبود طبقه‌بندی مورد استفاده قرار گرفته‌اند. اما این الگوریتم‌ها به دلیل افزایش تعداد منابع اطلاعاتی، حجم داده‌ها و محدود بودن تعداد نمونه‌های آموزشی در تصاویر ابرطیفی، بازدهی مطلوبی ندارند. در این مقاله برای حل این مشکل، الگوریتم جدید مبتنی بر ماشین بردار پشتیبان ارائه گردیده است. این الگوریتم پس از یک طبقه‌بندی اولیه، با استفاده از کلاس هر پیکسل و همسایه‌هایش به صورت سلسله‌مراتبی تصمیم‌گیری می‌کند. تصمیم‌گیری در هر یک از سطوح این طبقه‌بندی کننده بوسیله یک ماشین بردار پشتیبان انجام می‌شود. این الگوریتم بر روی داده‌های واقعی ابر طیفی سنجنده AVIRIS اجرا شد. نتایج نشان می‌دهد که صحت طبقه‌بندی داده‌های ابرطیفی با استفاده از این الگوریتم بسیار مطلوب بوده و مشکل محدود بودن تعداد نمونه‌های آموزشی تا حد قابل توجهی جبران شده است. در واقع این تحقیق با ادغام اطلاعات مکانی و استفاده از طبقه‌بندی کننده ماشین بردار پشتیبان صحت طبقه‌بندی را بهبود می‌بخشد. این الگوریتم زمان لازم برای طبقه‌بندی تصاویر ابرطیفی را با استفاده از ماشین بردار پشتیبان، بسیار کاهش داده و کارایی الگوریتم ماشین بردار پشتیبان را به عنوان طبقه‌بندی کننده تصاویر ابرطیفی افزایش می‌دهد.


کلید واژه: تصاویر ابرطیفی، سنجنش از دور، طبقه‌بندی، طبقه‌بندی کننده سلسله‌مراتبی، ماشین بردار پشتیبان.

۱- مقدمه

سنجنده‌های ابرطیفی نوع خاصی از سنجنده‌های طیف سنجنی هستند که پهنای باند مورد نظر را به صدها باند باریک مجاور هم تقسیم می‌کنند. در دسترس قرار گرفتن سنجنده‌هایی با توان تفکیک طیفی بالا و تعداد باند زیاد، دستیابی به جزئیات بیشتر در مورد کلاس‌ها را امکان پذیر ساخته و باعث افزایش دقت و اعتبار طبقه‌بندی‌ها شده است. با توجه به تعداد زیاد باندها کاربردهای بسیار زیادی برای تصاویر ابرطیفی وجود دارد [۱]. استفاده از تصاویر ابرطیفی در کاربردهایی مانند کشاورزی و برآورد دقیق محصولات، جنگل‌داری و مطالعه پوشش‌های گیاهی، مطالعه منابع آب و شناسایی آلودگی‌ها، اکتشاف منابع طبیعی و معدنی، زمین شناسی و نفت، کاربردهای صلح آمیز از قبیل شناسایی و پاکسازی مناطق جنگی آلوده، کاربردهای نظامی و شناسایی ادوات استتار شده، نتایج قابل توجهی حاصل کرده است.

این مقاله در تاریخ ۲ خرداد ماه ۱۳۸۴ دریافت شد و در تاریخ ۲۷ شهریور ماه ۱۳۸۴ بازنگری شد.

احمد کشاورز، بخش مهندسی برق، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران.
 حسن قاسمیان یزدی، بخش مهندسی برق، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران.



شکل ۱: مرز خطی بهینه برای حالتی که دو کلاس کاملاً از یکدیگر جدا هستند.

۲- ماشین بردار پشتیبان

ماشین بردار پشتیبان یا SVM در واقع یک طبقه‌بندی کننده دودویی است که دو کلاس را با استفاده از یک مرز خطی از هم جدا می‌کند. در این روش با استفاده از تمامی باند‌ها و یک الگوریتم بهینه سازی، نمونه‌هایی که مرزهای کلاس‌ها را تشکیل می‌دهند به دست می‌آیند. این نمونه‌ها را بردارهای پشتیبان گویند. تعدادی از نقاط آموزشی که کمترین فاصله تا مرز تصمیم‌گیری را دارند می‌توانند به عنوان زیر مجموعه‌ای برای تعریف مرزهای تصمیم‌گیری و به عنوان بردار پشتیبان در نظر گرفته شوند. در شکل ۱ دو کلاس و بردارهای پشتیبان مربوط به آنها نشان داده شده است. فرض کنید داده‌ها از دو کلاس تشکیل شده و کلاس‌ها در مجموع دارای $X_i, i = 1, \dots, L$ نقطه آموزشی باشند که X_i یک بردار است. این دو کلاس با $y_i = \pm 1$ برچسب زده می‌شوند. برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم، از روش حاشیه بهینه استفاده می‌شود [۱۱]. در این روش مرز خطی بین دو کلاس به گونه‌ای محاسبه می‌شود که:

۱- تمام نمونه‌های کلاس +۱ در یک طرف مرز و تمام نمونه‌های کلاس -۱ در طرف دیگر مرز واقع شوند.

۲- مرز تصمیم‌گیری به گونه‌ای باشد که فاصله نزدیکترین نمونه‌های آموزشی هر دو کلاس از یکدیگر در راستای عمود بر مرز تصمیم‌گیری تا جایی که ممکن است حداکثر شود.

یک مرز تصمیم‌گیری خطی را در حالت کلی می‌توان به صورت زیر نوشت

$$\mathbf{w} \cdot \mathbf{x} + b = 0 \quad (1)$$

\mathbf{x} یک نقطه روی مرز تصمیم‌گیری و \mathbf{w} یک بردار n بعدی عمود بر مرز تصمیم‌گیری است. $b / \|\mathbf{w}\|$ فاصله مبدأ تا مرز تصمیم‌گیری و $\mathbf{w} \cdot \mathbf{x}$ بیانگر ضرب داخلی دو بردار \mathbf{x} و \mathbf{w} است. از آنجا که با ضرب یک ثابت در دو طرف (۱) باز هم تساوی برقرار خواهد بود، برای تعریف یکتای مقدار b و \mathbf{w} شرایط زیر بر روی آنها اعمال می‌شود.

$$\Rightarrow \text{اگر } X_i \text{ یک بردار پشتیبان باشد} \quad y_i (\mathbf{w} \cdot \mathbf{x}_i + b) = 1 \quad (2)$$

$$\Rightarrow \text{اگر } X_i \text{ یک بردار پشتیبان نباشد} \quad y_i (\mathbf{w} \cdot \mathbf{x}_i + b) > 1$$

اولین مرحله برای محاسبه مرز تصمیم‌گیری بهینه، پیدا کردن نزدیکترین نمونه‌های آموزشی دو کلاس است. در مرحله بعد فاصله آن نقاط از هم در راستای عمود بر مرزهایی که دو کلاس را به طور کامل جدا می‌کنند محاسبه می‌شود. مرز تصمیم‌گیری بهینه، مرزی است که حداکثر حاشیه را داشته باشد. مرز تصمیم‌گیری بهینه با حل مسئله بهینه سازی زیر محاسبه می‌شود.


$$\max_{\mathbf{w}, b} \min_{i=1, \dots, L} \left[y_i \frac{(\mathbf{w} \cdot \mathbf{x}_i + b)}{\|\mathbf{w}\|} \right] \quad (3)$$

با توجه به (۲) و انجام یک سری عملیات ریاضی، رابطه بالا به رابطه زیر تبدیل می‌شود.

زیاد بودن تعداد باند‌ها و محدود بودن تعداد نمونه‌های آموزشی کارایی مطلوبی ندارند. توجه به این امر اگر چه صحت طبقه‌بندی تصاویر ابرطیفی با استفاده از الگوریتم‌های استخراج ویژگی و طبقه‌بندی کننده‌های کلاسیک آماری افزایش یافته است، اما همچنان به دلیل کم بودن تعداد نقاط آموزشی صحت به دست آمده مطلوب نمی‌باشد. بنابراین به نظر می‌رسد استفاده از طبقه‌بندی کننده‌های غیر آماری که به تعداد نمونه آموزشی کم احتیاج دارند، صحت بهتری داشته باشد.

ماشین بردار پشتیبان یک طبقه‌بندی کننده دودویی غیر آماری است که در سال‌های اخیر بسیار مورد توجه قرار گرفته است [۸]. تفاوت اساسی این طبقه‌بندی کننده با طبقه‌بندی کننده‌های آماری در این است که برای پردازش و طبقه‌بندی داده‌های ابرطیفی نیازی به کاهش تعداد باند‌ها ندارد. در این روش با استفاده از تمامی باند‌ها و یک الگوریتم بهینه سازی نمونه‌هایی که مرزهای کلاس‌ها را تشکیل می‌دهند به دست می‌آید و با استفاده از آنها یک مرز تصمیم‌گیری خطی بهینه برای جدا کردن کلاس‌ها محاسبه می‌شود. این نمونه‌ها را بردارهای پشتیبان می‌گویند. در شکل ۱ مرز تصمیم‌گیری بهینه و بردارهای پشتیبان نشان داده شده است. مشخص است که در بین نمونه‌های آموزشی همواره زیر مجموعه‌ای وجود دارد که بتواند بهترین مرز تصمیم‌گیری را تعریف کند. برای مثال نقاط آموزشی دارای کمترین فاصله از مرزهای تصمیم‌گیری می‌توانند به عنوان زیر مجموعه‌ای برای تعریف مرزهای تصمیم‌گیری در نظر گرفته شوند.

یکی از مزایای بسیار مهم ماشین بردار پشتیبان بهبود بازده این طبقه‌بندی کننده با افزایش بعد داده‌ها است. در واقع این طبقه‌بندی کننده یک طبقه‌بندی کننده آماری نیست و مستقیماً با استفاده از نقاط آموزشی مرز تصمیم‌گیری بین دو کلاس را به دست می‌آورد. توجه داشته باشید که منظور از غیر آماری بودن ماشین بردار پشتیبان این است که در این طبقه‌بندی کننده از ممان‌های آماری استفاده نمی‌شود و بنابراین خطای حاصل از تخمین ممان‌های آماری که باعث پدیده هیوز می‌شود در اینجا وجود ندارد. از طرفی هر چه بعد داده‌ها بیشتر شود فاصله کلاس‌ها از یکدیگر بیشتر شده و امکان جدا سازی آنها با تعداد محدودی نقاط آموزشی افزایش می‌یابد. بنابراین می‌توان گفت این طبقه‌بندی کننده برای طبقه‌بندی تصاویر سنجنش از دوری ابرطیفی با نقاط آموزشی محدود بسیار مفید است. در چند ساله اخیر استفاده از ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ابر طیفی بسیار مورد توجه قرار گرفته است [۹] و [۱۰]. اما در تمام الگوریتم‌های رایج شده تنها از اطلاعات طیفی تصاویر ابرطیفی برای طبقه‌بندی استفاده شده است. این در حالی است که تصاویر ابرطیفی علاوه بر اطلاعات طیفی شامل اطلاعات مکانی و بافتی نیز می‌باشند. در این مقاله با ادغام اطلاعات مکانی و استفاده از طبقه‌بندی کننده ماشین بردار پشتیبان، صحت طبقه‌بندی بهبود یافته است. در ادامه طبقه‌بندی کننده ماشین بردار پشتیبان برای حالت دو کلاسه بررسی می‌شود. در بخش سوم ماشین بردار پشتیبان برای حالتی که تعداد کلاس‌ها بیشتر از دو کلاس باشد توضیح داده خواهد شد. در بخش چهارم پس از بررسی مزایا و معایب ماشین بردار پشتیبان چند کلاسه، الگوریتم پیشنهادی مطرح می‌گردد. در بخش پنجم نتایج حاصل از الگوریتم‌های کلاسیک طبقه‌بندی با الگوریتم پیشنهادی مقایسه خواهد شد.



شکل ۲: پیکسل‌های همسایه پیکسل (i,j).

پس از تعیین یک $k(\mathbf{x}_i, \mathbf{x}_j)$ مناسب، در (۹) به جای $\phi(\mathbf{x}_i)\phi(\mathbf{x}_j)$ تابع $k(\mathbf{x}_i, \mathbf{x}_j)$ قرار داده شده و مسئله بهینه سازی حل می‌شود. $k(\mathbf{x}_i, \mathbf{x}_j)$ در واقع یک تابع در فضای اولیه می‌باشد که برابر با ضرب داخلی دو بردار در فضای ویژگی است. برای معادل بودن تابع $k(\mathbf{x}_i, \mathbf{x}_j)$ با ضرب داخلی دو بردار در فضای ویژگی، باید $k(\mathbf{x}_i, \mathbf{x}_j)$ یک تابع معین مثبت متقارن بوده و در شرط مرسر^۱ صدق کند [۱۱]. برخی از مهمترین توابع هسته‌ای که در این شرط صدق می‌کنند، عبارتند از:

$$k(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y} + 1)^p$$

$$k(\mathbf{x}, \mathbf{y}) = e^{-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}}$$

$$k(\mathbf{x}, \mathbf{y}) = \tanh(k\mathbf{x} \cdot \mathbf{y} - \delta) \quad (11)$$

در این تحقیق برای طبقه‌بندی تصویر ابرطیفی از تابع هسته دوم که به آن تابع هسته گوسی می‌گویند استفاده شده است. طبقه‌بندی کننده نهایی را می‌توان با استفاده از رابطه زیر به دست آورد.

$$f(\mathbf{x}, \lambda_1, \dots, \lambda_L) = \text{sgn} \left(\sum_{i=1}^L \lambda_i y_i k(\mathbf{x}_i, \mathbf{x}) + b \right) \quad (12)$$

۳- الگوریتم پیشنهادی

ماشین بردار پشتیبان یک طبقه‌بندی کننده دودویی است. بنابراین در حالتی که بیش از دو کلاس وجود داشته باشد نمی‌توان مستقیماً از آن استفاده کرد. در حالت کلی برای استفاده از طبقه‌بندی کننده‌های دودویی در حالت چند کلاسه باید ابتدا چند طبقه‌بندی کننده دودویی طراحی شود. طبقه‌بندی نهایی با استفاده از ادغام اطلاعات طبقه‌بندی کننده‌های دودویی انجام می‌گردد. برای استفاده از ماشین بردار پشتیبان در حالت چند کلاسه این تکنیک کلی با دو روش متفاوت اجرا می‌شود [۱۲]. برای مثال فرض کنید k کلاس وجود داشته باشد. در روش اول که آن را روش یکی در مقابل بقیه می‌نامند، k طبقه‌بندی کننده دودویی که هر کدام برای جدا کردن یک کلاس از بقیه کلاس‌ها می‌باشد طراحی می‌شود. بنابراین در این حالت برای آموزش هر طبقه‌بندی کننده از تمام نقاط آموزشی k کلاس استفاده می‌گردد. هر داده آزمایشی با تمام k طبقه‌بندی کننده حاصل طبقه‌بندی می‌شود. در نهایت داده مورد نظر با شماره طبقه‌بندی کننده‌ای که دارای بیشترین مقدار $\mathbf{w} \cdot \mathbf{x} + b$ است برچسب زده خواهد شد. چون در این حالت از تمام نقاط آموزشی برای آموزش هر طبقه‌بندی کننده استفاده شده بنابراین زمان آموزش هر طبقه‌بندی کننده در این حالت بسیار زیاد است و در عمل به ندرت از آن استفاده می‌شود.

روش دوم که آن را دسته‌بندی کردن زوج-زوج می‌نامند، $\binom{k}{2} = k(k-1)/2$ طبقه‌بندی کننده دودویی که در واقع برابر با تمامی جفت‌های مختلف k کلاس می‌باشد

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2, y_i (\mathbf{w} \cdot \mathbf{x}_i + b) - 1 \geq 0 \quad i = 1, \dots, L \quad (4)$$

حل کردن مسئله بهینه سازی (۴) کار مشکلی است. برای ساده‌تر کردن آن با استفاده از روش ضرایب نامعین لاگرانژ این مسئله بهینه سازی را می‌توان به فرم زیر تبدیل کرد که λ_i ها ضرایب لاگرانژ می‌باشند.

$$\max_{\lambda_1, \dots, \lambda_L} \left[-\frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \lambda_i y_i (\mathbf{x}_i \cdot \mathbf{x}_j) y_j \lambda_j + \sum_{i=1}^L \lambda_i \right]$$

$$\lambda_i \geq 0 \quad i = 1, \dots, L \quad (5)$$

$$\sum_{i=1}^L \lambda_i y_i = 0$$

پس از حل مسئله بهینه سازی بالا و یافتن ضرایب لاگرانژ، \mathbf{w} با استفاده از رابطه زیر محاسبه می‌شود.

$$\mathbf{w} = \sum_{i=1}^L \lambda_i y_i \mathbf{x}_i \quad (6)$$

λ_i بردارهای پشتیبان بزرگتر از صفر، و λ_i نقاط دیگر صفر خواهد بود. بنابراین با توجه به (۶) و صفر بودن λ_i مربوط به \mathbf{x}_i هایی که بردار پشتیبان نیستند، برای به دست آوردن مرز تصمیم‌گیری فقط نیاز به تعداد محدودی از نقاط آموزشی که همان بردارهای پشتیبان هستند می‌باشد و همه آنها لازم نیستند. در نتیجه طبقه‌بندی تصاویر ابرطیفی با استفاده از ماشین بردار پشتیبان به تعداد محدودی نقطه آموزشی نیاز خواهد داشت. پس از یافتن \mathbf{w} با استفاده از رابطه زیر مقدار b به ازاء بردارهای پشتیبان مختلف محاسبه شده و b نهایی با میانگین‌گیری از b های حاصل به دست می‌آید.

$$\lambda_i [y_i (\mathbf{w} \cdot \mathbf{x}_i + b) - 1] = 0 \quad i = 1, \dots, L \quad (7)$$

طبقه‌بندی کننده نهایی از (۸) به دست می‌آید.

$$f(\mathbf{X}, \mathbf{W}, b) = \text{sgn}(\mathbf{W} \cdot \mathbf{X} + b) \quad (8)$$

الگوریتم بالا مرز خطی دو کلاس کاملاً جدا از هم را به دست می‌دهد، اما در حالتی که کلاس‌ها با هم همپوشانی داشته باشند جدا کردن کلاس‌ها بوسیله مرز تصمیم‌گیری خطی همواره با خطا همراه خواهد بود. برای حل این مشکل می‌توان ابتدا داده‌ها را از فضای اولیه \mathbf{R}^n با استفاده از یک تبدیل غیر خطی ϕ ، به فضای \mathbf{R}^m با ابعاد بیشتر منتقل کرد که در فضای جدید کلاس‌ها تداخل کمتری با یکدیگر داشته باشند. سپس در فضای جدید با استفاده از معادلات قبلی و جایگزینی \mathbf{x}_i با $\phi(\mathbf{x}_i)$ و در نظر گرفتن مقداری خطا مرز تصمیم‌گیری بهینه محاسبه می‌شود. با توجه به این امر و (۵) در این حالت یافتن مرز تصمیم‌گیری بهینه به حل مسئله بهینه سازی (۹) تبدیل می‌شود.


$$\max_{\lambda_1, \dots, \lambda_L} \left[-\frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \lambda_i y_i (\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)) y_j \lambda_j + \sum_{i=1}^L \lambda_i \right]$$

$$C \geq \lambda_i \geq 0 \quad i = 1, \dots, L \quad (9)$$

$$\sum_{i=1}^L \lambda_i y_i = 0$$

در این مسئله بهینه سازی C یک عدد ثابت است. اگر $C \rightarrow \infty$ ، مسئله بهینه سازی به سمت یافتن یک مرز بهینه برای کلاس‌هایی با تداخل بسیار زیاد پیش می‌رود. از طرفی اگر $C \rightarrow 0$ ، مسئله بهینه سازی به سمت یافتن مرز بهینه جداکننده دو کلاس که تداخل بسیار کمی دارند پیش خواهد رفت. در رابطه (۹) معمولاً به جای استفاده از ϕ ، از یک تابع هسته که به صورت زیر تعریف می‌گردد استفاده می‌شود.

$$k(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i) \phi(\mathbf{x}_j) \quad (10)$$



شکل ۳: درخت تصمیم‌گیری دودویی.

برای استفاده از ویژگی همسایه همکلاس ابتدا باید کلاس همسایه‌های پیکسل (i, j) مشخص باشد. برای این منظور ابتدا با استفاده از یک الگوریتم استخراج ویژگی و طبقه‌بندی کننده حداکثر احتمال، یک طبقه‌بندی اولیه انجام می‌شود. به این ترتیب اطلاعات اولیه‌ای از کلاس همسایه‌های هر پیکسل به دست می‌آید. صحت این اطلاعات کاملاً وابسته به صحت طبقه‌بندی اولیه است. در طبقه‌بندی نهایی هر پیکسل با استفاده از ماشین بردار پشتیبان با یکی از همسایه‌های همکلاس در نظر گرفته شده و بر این اساس طبقه‌بندی می‌گردد. بنابراین هر چه صحت طبقه‌بندی اولیه بیشتر باشد طبقه‌بندی نهایی نیز صحت بهتری داشته و احتمال وجود کلاس واقعی هر پیکسل در بین کلاس همسایه‌هایش افزایش می‌یابد. در این مقاله برای بهبود طبقه‌بندی نهایی علاوه بر کلاس همسایه‌های هر پیکسل، از کلاس خود آن پیکسل نیز که از طبقه‌بندی اولیه به دست می‌آید برای طبقه‌بندی نهایی استفاده شده است. به این ترتیب برای پیکسل انتخاب گردد. در ادامه ابتدا احتمال وجود داشتن کلاس واقعی یک پیکسل در بین مجموعه کلاس آن پیکسل و همسایه‌هایش محاسبه شده و سپس به بیان الگوریتم طبقه‌بندی نهایی می‌پردازیم.

فرض کنید کلاس واقعی پیکسل $x(i, j)$ ، n باشد. حال اگر در طبقه‌بندی اولیه پیکسل $X(i, j)$ و همسایه‌هایش با کلاس n برچسب نخورده باشند، الگوریتم پیشنهادی این پیکسل را درست طبقه‌بندی نخواهد کرد. در ادامه نشان می‌دهیم که احتمال وقوع این حالت برای زمانی که طبقه‌بندی کننده اولیه، حداکثر احتمال باشد، بسیار کم است. فرض کنید $P_{x(i, j)}$ که در رابطه زیر نشان داده شده مجموعه احتمال‌های تعلق $x(i, j)$ به هر یک از کلاس‌ها بوده و کلاس واقعی پیکسل $x(i, j)$ باشد

$$P_{x(i, j)} = \{ p(0|x(i, j)), p(1|x(i, j)), \dots, p(M|x(i, j)) \}, \quad (13)$$

$$M = |C_{N(i, j)}|$$

$C_{N(i, j)}$ مجموعه کلاس پیکسل $X(i, j)$ و همسایه‌هایش است که از طبقه‌بندی اولیه به دست می‌آید و M برابر با تعداد اعضاء $C_{N(i, j)}$ است. در صورت استفاده از طبقه‌بندی کننده حداکثر احتمال، احتمال اینکه $X(i, j)$ با n برچسب نخورد برابر است با

$$p(c_{x(i, j)} \neq n) = \text{prob}(p(n|x(i, j)) \neq \max P_{x(i, j)}) \quad (14)$$

کلاس $C_{x(i, j)}$ حاصل از طبقه‌بندی اولیه پیکسل $X(i, j)$ است. اگر همسایه‌های $X(i, j)$ به دو دسته S_p (مجموعه‌ای از همسایه‌های همکلاس با $X(i, j)$) و S_q (مجموعه‌ای از همسایه‌های غیر همکلاس با $X(i, j)$) تقسیم شوند، (توجه کنید که $S_p \cup S_q$ همواره ۸ عضو دارد. بنابراین اگر n_p تعداد اعضاء S_p و n_q تعداد اعضاء S_q باشد، همواره $n_p + n_q = 8$ است.) حال احتمال اینکه $X(i, j)$ هیچ یک از همسایه‌هایش با n برچسب نخورد، برابر است با:

طراحی می‌شود. سپس هر داده آزمایشی با تمام این طبقه‌بندی کننده‌ها طبقه‌بندی شده و در هر طبقه‌بندی به کلاس برنده یک رای داده می‌شود. کلاسی که حداکثر آراء را آورده است به عنوان کلاس داده آزمایشی در نظر گرفته خواهد شد. در این روش چون هر طبقه‌بندی کننده با نقاط آموزشی کمتری آموزش داده می‌شود بنابراین زمان آموزش آن بسیار کمتر از حالت قبل است. اما چون در این حالت برای طبقه‌بندی کردن هر داده آزمایشی باید $k(k-1)/2$ طبقه‌بندی بر روی آن داده انجام شود، در نتیجه با افزایش تعداد کلاس‌ها طبقه‌بندی تمامی داده‌ها به زمان زیادی نیاز خواهد داشت. بنابراین یکی از مشکلات طبقه‌بندی داده‌های چند کلاسه با استفاده از ماشین بردار پشتیبان افزایش چشمگیر زمان طبقه‌بندی است. مشکل دیگری که با افزایش تعداد کلاس‌ها به وجود می‌آید، زیاد شدن خطای طبقه‌بندی نهایی است. در واقع هر طبقه‌بندی کننده دودویی دارای مقداری خطا می‌باشد. بنابراین با افزایش تعداد این طبقه‌بندی کننده‌ها خطای حاصل از تک تک آنها در تصمیم‌گیری نهایی دخالت داده می‌شود. در نتیجه خطای طبقه‌بندی نهایی افزایش خواهد یافت.

روش‌های یکی در مقابل بقیه و دسته‌بندی کردن زوج-زوج به نحوی سعی در استخراج اطلاعاتی از مرزهای بین کلاس‌ها دارند. در روش دسته‌بندی کردن زوج-زوج میزان اطلاعاتی که از مرز بین کلاس‌ها استخراج می‌شود بسیار بیشتر از اطلاعاتی است که با روش یکی در مقابل بقیه به دست می‌آید. بنابراین به نظر می‌رسد که استفاده از روش دسته‌بندی کردن زوج-زوج طبقه‌بندی بهتری را در اختیار ما قرار دهد. اما صحت طبقه‌بندی روش دسته‌بندی کردن زوج-زوج کاملاً وابسته به الگوریتمی است که برای ادغام تصمیم‌های طبقه‌بندی کننده‌ها مورد استفاده قرار می‌گیرد. روش یکی در مقابل بقیه اگرچه مشکل الگوریتم ادغام نهایی را ندارد، اما از آنجا که برای آموزش هر یک از n ماشین بردار پشتیبان از نقاط آموزشی تمامی کلاس‌ها استفاده می‌شود بسیار زمان بر خواهد بود. از طرفی صحت طبقه‌بندی این روش به دلیل کم بودن اطلاعاتی که از مرز بین کلاس‌ها در اختیار دارد، مطلوب نیست. بنابراین به نظر می‌رسد که استفاده از روش دسته‌بندی کردن زوج-زوج برای طبقه‌بندی تصاویر ابرطیفی مناسبتر از روش یکی در مقابل بقیه است. اما به دلیل تعداد زیاد کلاس‌های تصاویر ابرطیفی، طبقه‌بندی این تصاویر با استفاده از روش دسته‌بندی کردن زوج-زوج صحت مطلوبی ندارد. در این مقاله برای حل مشکل طبقه‌بندی تصاویر ابر طیفی با استفاده از ماشین بردار پشتیبان، از یک ویژگی مکانی تصاویر ابرطیفی استفاده شده است.

این ویژگی احتمال زیاد هم کلاس بودن یک پیکسل با حداقل یکی از هشت پیکسل همسایه‌اش می‌باشد [۱۳]. ما این ویژگی را ویژگی "همسایه همکلاس" می‌نامیم. در واقع فرض می‌شود پیکسل (i, j) با احتمال زیادی حداقل با یکی از هشت پیکسل همسایه‌اش همکلاس است. این مطلب در شکل ۲ نشان داده شده است. در این مقاله علاوه بر اطلاعات طیفی هر پیکسل، از این ویژگی نیز برای طبقه‌بندی استفاده خواهد شد. از آنجا که اطلاعات طیفی و اطلاعات به دست آمده از ویژگی همسایه همکلاس دو نوع متفاوت از اطلاعات می‌باشند، بنابراین نمی‌توان به راحتی آنها را با هم ادغام کرده و طبقه‌بندی را بهبود داد. برای ادغام مناسب این اطلاعات از یک الگوریتم طبقه‌بندی دو مرحله‌ای استفاده می‌شود.

جدول ۱: صحت کلی طبقه‌بندی هر یک از جفت کلاس‌های تصویر مورد بررسی بوسیله ماشین بردار پشتیبان.

		صحت کلی طبقه‌بندی (%)															
کلاس	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	
۱	-	۹۹	۹۹	۹۸	۹۹	۹۹	۹۳	۹۸	۹۷	۹۹	۱۰۰	۹۹	۱۰۰	۱۰۰	۹۸	۹۷	
۲	۹۹	-	۸۷	۸۴	۹۸	۹۸	۹۹	۱۰۰	۹۹	۹۰	۸۹	۹۰	۹۹	۱۰۰	۹۶	۸۸	
۳	۹۹	۸۷	-	۹۲	۹۸	۹۹	۹۹	۱۰۰	۱۰۰	۹۲	۸۸	۹۰	۱۰۰	۱۰۰	۹۸	۹۷	
۴	۹۸	۸۴	۹۲	-	۹۶	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۷	۹۶	۹۶	۱۰۰	۱۰۰	۹۹	۹۷	
۵	۹۹	۹۸	۹۸	۹۶	-	۹۷	۹۵	۹۹	۹۸	۹۸	۹۹	۹۸	۱۰۰	۹۶	۸۶	۹۶	
۶	۹۹	۹۸	۹۹	۱۰۰	۹۷	-	۱۰۰	۱۰۰	۱۰۰	۹۹	۹۸	۱۰۰	۱۰۰	۹۹	۹۵	۱۰۰	
۷	۹۳	۹۹	۹۹	۱۰۰	۹۵	۱۰۰	-	۹۹	۱۰۰	۹۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۷	۱۰۰	
۸	۹۸	۱۰۰	۱۰۰	۱۰۰	۹۹	۱۰۰	۹۹	-	۱۰۰	۹۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	
۹	۹۷	۹۹	۱۰۰	۱۰۰	۹۸	۱۰۰	۱۰۰	۱۰۰	-	۹۹	۱۰۰	۱۰۰	۹۹	۱۰۰	۱۰۰	۱۰۰	
۱۰	۹۹	۹۰	۹۲	۹۷	۹۸	۹۹	۹۹	۹۹	۹۹	-	۸۹	۹۵	۱۰۰	۱۰۰	۹۸	۹۴	
۱۱	۱۰۰	۸۹	۸۸	۹۶	۹۹	۹۸	۱۰۰	۱۰۰	۱۰۰	۸۹	-	۹۰	۱۰۰	۱۰۰	۹۷	۸۳	
۱۲	۹۹	۹۰	۹۰	۹۶	۹۸	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۵	۹۰	-	۱۰۰	۱۰۰	۹۹	۹۷	
۱۳	۱۰۰	۹۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۹	۱۰۰	۱۰۰	۱۰۰	-	۱۰۰	۹۹	۱۰۰	
۱۴	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۶	۹۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	-	۹۲	۱۰۰	
۱۵	۹۸	۹۶	۹۸	۹۹	۸۶	۹۵	۹۷	۱۰۰	۱۰۰	۹۸	۹۷	۹۹	۹۹	۹۲	-	۹۹	
۱۶	۹۷	۸۸	۹۷	۹۷	۹۶	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۴	۸۳	۹۷	۱۰۰	۱۰۰	۹۹	-	

سطح l ام درخت، l گره وجود دارد و هر گره سطح M ام نشان دهنده یکی از کلاس‌ها می‌باشد. پس از مشخص شدن ساختار کلی درخت باید جفت کلاس‌های مربوط به هر گره مشخص شود. برای این منظور از دو فرض زیر برای طراحی درخت استفاده شده است.

(۱) اگر در یک مرحله از درخت تصمیم‌گیری کلاسی کنار گذاشته شود، در مراحل بعدی هیچ کلاسی با آن مقایسه نخواهد شد.

(۲) فاصله جفت کلاس مربوط به گره‌های سطوح بالایی درخت باید تا جایی که امکان دارد زیاد باشد.

فرض یک در واقع به دلیل صحت بسیار مناسب ماشین بردار پشتیبان برای جدا سازی دو کلاس است. بنابراین اگر در یک مرحله کلاسی کنار گذاشته شود، به احتمال بسیار زیاد کلاس واقعی پیکسل مورد نظر نبوده و لازم نیست در مراحل بعدی با کلاس‌های دیگر مقایسه شود. فرض دوم به دلیل کم کردن انتشار خطا در سطوح پایین است. در واقع هرچه فاصله بین دو کلاس بیشتر باشد، طبقه‌بندی کننده ماشین بردار پشتیبان صحت مطلوبتری خواهد داشت. بنابراین اگر کلاس‌هایی که در گره‌های بالایی با هم مقایسه می‌شوند دارای فاصله زیادی باشند احتمال خطا کمتر خواهد بود. معیارهای زیادی برای محاسبه فاصله دو کلاس وجود دارد. در این تحقیق از فاصله باتاچریا که به صورت زیر تعریف می‌شود استفاده شده است. در این رابطه m_n و m_m به ترتیب بردارهای میانگین و \sum_m و \sum_n ماتریس‌های کوواریانس کلاس c_m و c_n می‌باشند.

$$d(c_m, c_n) = \frac{1}{\lambda} (\mathbf{m}_n - \mathbf{m}_m)^T \left[\frac{\sum_m + \sum_n}{2} \right]^{-1} (\mathbf{m}_n - \mathbf{m}_m) + \frac{1}{2} \ln \left[\frac{|\sum_m + \sum_n|}{\sqrt{|\sum_m| |\sum_n|}} \right] \quad (17)$$

حال اگر $C_{node(k,l)}$ زوج مرتبی باشد که نشان دهنده جفت کلاس گره l ام از سطح k ام درخت تصمیم‌گیری است، برای برقراری فرضیه اول باید رابطه زیر در مورد تمامی گره‌های درخت تصمیم‌گیری صدق کند.

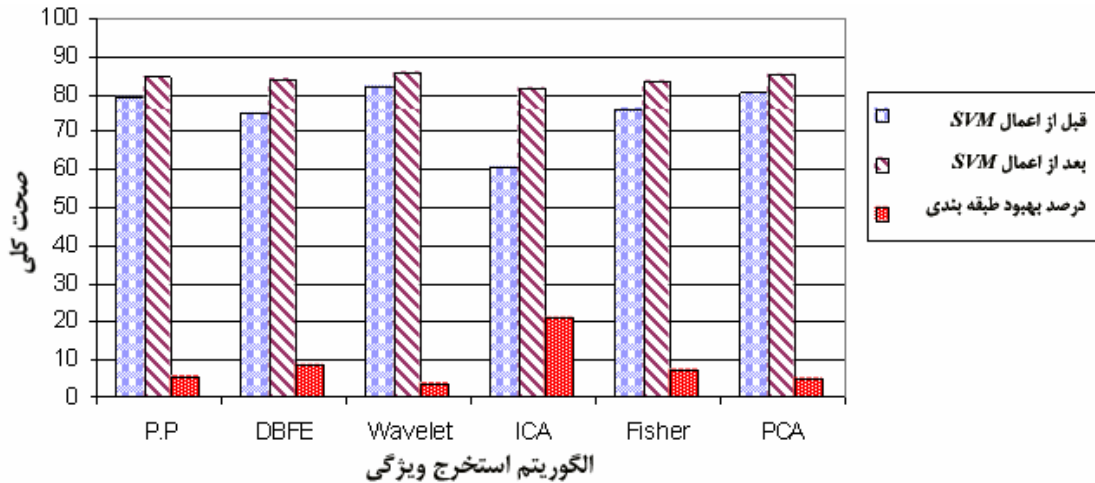
$$C_{node(k,l)} = (C_{(M,l)}, C_{(M,M+l-k)}) \quad (18)$$

$$P(n \notin C_{N(i,j)}) = P(c_{x(i,j)} \neq n) \left[\prod_{x(i',j') \in S_p} P(c_{x(i',j')} \neq n) \right] \left[\prod_{x(i',j') \in S_q} P(c_{x(i',j')} \neq n) \right] \quad (15)$$

که (i', j') مختصات همسایه‌های (i, j) است. اگر از طبقه‌بندی کننده حداکثر احتمال برای طبقه‌بندی اولیه استفاده شود، در رابطه بالا $P(c_{x(i,j)} \neq n)$ برای پیکسل‌هایی که کلاس واقعی آنها n باشد مقدار کمی دارد. بنابراین با توجه به (۱۵) و ویژگی همسایه همکلاس در تصاویر سنجنش از دور، احتمال اینکه کلاس واقعی $x(i, j)$ عضو $C_{N(i,j)}$ نباشد بسیار کم است. بنابراین پس از یک طبقه‌بندی اولیه مناسب، در اکثر موارد کافی است از بین مجموعه کلاس‌های $C_{N(i,j)}$ یک کلاس به عنوان کلاس نهایی پیکسل $x(i, j)$ انتخاب شود. انتخاب یکی از اعضای $C_{N(i,j)}$ به عنوان کلاس نهایی پیکسل $x(i, j)$ ، با استفاده از ماشین بردار پشتیبان انجام می‌شود. توجه داشته باشید که تعداد کلاس‌های $C_{N(i,j)}$ حداکثر ۹ کلاس می‌باشد که در اکثر موارد به دلیل یکی بودن برخی از همسایه‌ها، خیلی کمتر از ۹ کلاس خواهد بود. بنابراین مشکل زیاد بودن تعداد کلاس‌ها در طبقه‌بندی با ماشین بردار پشتیبان تا حدودی حل شده است. اما با وجود کم شدن تعداد کلاس‌ها هنوز زمان طبقه‌بندی تصاویر ابرطیفی با استفاده از ماشین بردار پشتیبان و روش دسته‌بندی کردن زوج-زوج زیاد می‌باشد. یک راه حل برای کم کردن زمان طبقه‌بندی استفاده از طبقه‌بندی کننده سلسله مراتبی و درخت تصمیم‌گیری است. در این مقاله برای طبقه‌بندی نهایی از یک درخت تصمیم‌گیری دودویی استفاده شده است. در واقع به جای اینکه تمامی کلاس‌ها با هم مقایسه شوند، در هر گره درخت مقایسه‌ای بین یک جفت از کلاس‌ها با استفاده از ماشین بردار پشتیبان انجام شده و کلاس بازنده کنار گذاشته می‌شود. با توجه به صحت بسیار مطلوب ماشین بردار پشتیبان دو کلاسه، احتمال تصمیم‌گیری اشتباه در هر گره بسیار کم خواهد بود. حال فرض کنید که یک طبقه‌بندی اولیه بر روی تصویر انجام شده است. برای طبقه‌بندی نهایی $x(i, j)$ ، ابتدا اعضاء $C_{N(i,j)}$ تعیین می‌شود. در مرحله بعد یک درخت دودویی با M سطح برای طبقه‌بندی نهایی تشکیل می‌شود که M برابر است با

$$M = |C_{N(i,j)}| \quad (16)$$

در شکل ۳ شمای کلی این درخت نشان داده شده است. توجه داشته باشید که در



شکل ۴: مقایسه صحت کلی الگوریتم‌های استخراج ویژگی مختلف، قبل و بعد از اعمال الگوریتم پیشنهادی.

باند دارد و دارای 145×145 پیکسل می‌باشد. دقت رادیو متریک آن ۸ بیت بوده و دارای ۱۶ کلاس است. ۳۰ باند تصویر به دلیل تأثیرات نامطلوب جو بر روی آنها کنار گذاشته شده و از $23/63$ درصد نقاط تست برای آموزش استفاده شده است. برای طبقه‌بندی تصویر مورد بررسی با استفاده از ماشین بردار پشتیبان و روش دسته‌بندی کردن زوج-زوج باید ۱۲۰ ماشین بردار پشتیبان طراحی شود. تابع هسته تمام ماشین‌های بردار پشتیبان گوسی ($\sigma = 0.2$ و $c = 500$) است. زمان این طبقه‌بندی در حدود ۷۶ ساعت و صحت کلی آن $77/85$ درصد است. مشاهده می‌شود زمانی که تعداد کلاس‌ها زیاد باشد، استفاده از ماشین بردار پشتیبان بسیار زمان بر بوده و صحت مطلوبی ندارد.

ماشین بردار پشتیبان در حالتی که فقط دو کلاس وجود داشته باشد، صحت بسیار مطلوبی دارد. در جدول ۱ نتایج حاصل از طبقه‌بندی هر یک از جفت کلاس‌های تصویر مورد بررسی بوسیله ماشین بردار پشتیبان نشان داده شده است. هر ماشین بردار پشتیبان تنها با نقاط آموزشی یک جفت از کلاس‌ها آموزش دیده و سپس پیکسل‌های آزمایشی مربوط به آن دو کلاس را طبقه‌بندی کرده است. تابع هسته تمام ماشین‌های بردار پشتیبان گوسی ($\sigma = 0.2$ و $c = 500$) می‌باشد. مشاهده می‌شود در اکثر موارد صحت به دست آمده بیشتر از ۹۰ درصد است. بنابراین اگر در یک گره درخت کلاسی توسط ماشین بردار پشتیبان دو کلاسه کنار گذاشته شود، کلاس رد شده به احتمال زیاد کلاس واقعی پیکسل مورد نظر نبوده است. در آزمایش بعد تصویر منطقه مورد آزمایش با الگوریتم پیشنهادی طبقه‌بندی شد. در اولین مرحله الگوریتم پیشنهادی تصویر مورد بررسی با ویژگی‌های تبدیل موجک [۱۵] و طبقه‌بندی کننده حداکثر احتمال طبقه‌بندی شد. موجک به کار رفته در این حالت دایچی ۴ می‌باشد. زمان این طبقه‌بندی در حدود ۳ ساعت و ۲۳ دقیقه و صحت کلی آن $85/84$ درصد است. مشاهده می‌شود که علاوه بر بهبود صحت طبقه‌بندی نسبت به روش دسته‌بندی کردن زوج-زوج، سرعت طبقه‌بندی نیز بسیار بیشتر شده است. از طرفی صحت کلی طبقه‌بندی اولیه $82/07$ درصد است که مشاهده می‌شود پس از مرحله دوم $3/77$ درصد بهبود یافته است. اعتبار کلی مرحله اول الگوریتم پیشنهادی $78/37$ و مرحله دوم $82/89$ درصد است. بنابراین با استفاده از الگوریتم پیشنهادی اعتبار کلی $4/52$ درصد بهبود یافته است. ماتریس خطا این طبقه‌بندی در جدول ۲ نشان داده شده است. برای نشان دادن میزان وابستگی الگوریتم پیشنهادی به صحت طبقه‌بندی اولیه، الگوریتم پیشنهادی با طبقه‌بندی‌های اولیه متفاوت، پیاده سازی شد. در نمودار شکل ۴ صحت کلی حاصل از طبقه‌بندی اولیه، با صحت کلی مرحله دوم الگوریتم پیشنهادی مقایسه شده است. در تمام طبقه‌بندی‌های اولیه پس از اعمال الگوریتم استخراج ویژگی مورد نظر از طبقه‌بندی کننده حداکثر احتمال استفاده شده است. مشاهده می‌شود که صحت کلی طبقه‌بندی نهایی در تمام موارد بیشتر از ۸۰ درصد بوده و بهترین صحت مربوط به طبقه‌بندی اولیه با استفاده از تبدیل موجک است. همچنین با بررسی نمودار شکل ۴ مشاهده می‌شود که بیشترین درصد بهبود طبقه‌بندی مربوط به طبقه‌بندی با استفاده از مؤلفه‌های مستقل می‌باشد. از

در این رابطه $c_{(M,l)}$ و $c_{(M,M+l-k)}$ به ترتیب کلاس گره‌های پایانی $M+l-k$ و M از سطح M درخت تصمیم‌گیری هستند. یا توجه به (۱۸) برای مشخص کردن جفت کلاس گره‌های درخت تصمیم‌گیری کافی است $c_{(M,i)}$ مشخص شود. برای این منظور ابتدا باید $D_N(i,j)$ که به صورت زیر تعریف می‌شود محاسبه گردد.

$$D_N(i,j) = \left\{ d(c_m, c_n) \mid c_m, c_n \in C_N(i,j) \right\} \quad (19)$$

در رابطه بالا $d(c_m, c_n)$ بیانگر فاصله باتاجریا جفت کلاس c_m و c_n است. حال با استفاده از فرضیه دوم و (۱۹) دو کلاس $C_{(M,i)}$ و $C_{(M,M)}$ با استفاده از رابطه زیر مشخص می‌شود.

$$C_{(M,i)}, C_{(M,M)} = \left\{ (c_m, c_n) \mid d(c_m, c_n) = \max D_N(i,j) \right\} \quad (20)$$

برای تعیین بقیه کلاس‌ها از الگوریتم زیر استفاده می‌گردد.

FOR $i = 2 : M/2$

$$C_{(M,i)} = \left\{ c_m \mid \begin{cases} d(c_{(M,M)}, c_m) \\ = \max D_N(i,j), & c_m \neq c_{(M,j)} \\ j = \{(1, \dots, i-1) \text{ and } (M-i+2, \dots, M)\} \end{cases} \right\} \quad (21)$$

$$C_{(M, M-i+1)} = \left\{ c_m \mid \begin{cases} d(c_{(M,i)}, c_m) \\ = \max D_N(i,j), & c_m \neq c_{(M,j)} \\ j = \{(1, \dots, i) \text{ and } (M-i+2, \dots, M)\} \end{cases} \right\}$$

END

پس از اتمام الگوریتم فوق اگر M فرد باشد کلاس گره $M+0.5$ از رابطه زیر به دست می‌آید.

$$W_{\left(M, \frac{M+1}{2}\right)} = \left\{ c_m \mid \begin{cases} c_m \neq c_{(M,j)} \\ j = \left\{ \left(1, \dots, \frac{M-1}{2}\right) \text{ and } \left(\frac{M+2}{2}, \dots, M\right) \right\} \end{cases} \right\} \quad (22)$$

۴- پیاده سازی و نتایج

این بخش به بررسی نتایج پیاده سازی الگوریتم پیشنهادی و مقایسه نتایج آن با الگوریتم‌های کلاسیک استخراج ویژگی و طبقه‌بندی می‌پردازد. الگوریتم‌های مختلف با نرم افزار MATLAB[®] و یک کامپیوتر P4 با سرعت $2/4$ گیگاهرتز و ۲۵۶ مگابایت RAM پیاده سازی شده است. تصویر استفاده شده در این تحقیق مربوط به منطقه‌ای کشاورزی-جنگلی است که توسط سنجنده AVIRIS در ژوئن ۱۹۹۲ از یک سایت آزمایشی در شمال شرقی ایالت ایندیانا گرفته شده است [۱۴]. این تصویر ۲۲۰

جدول ۲: ماتریس خطا الگوریتم پیشنهادی در حالتی که طبقه‌بندی اولیه با ویژگی‌های حاصل از تبدیل موجک انجام شده است.

کلاس	مجموع	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	صحت	اعتبار
۱	۵۱	۴۸	۰	۰	۰	۰	۰	۰	۳	۰	۰	۰	۰	۰	۰	۰	۰	۹۰/۵۶۶	۹۴/۱۱۸
۲	۱۲۵۳	۰	۱۱۲۳	۳۸	۰	۰	۰	۰	۰	۰	۲	۹۰	۰	۰	۰	۰	۰	۷۶/۰۷۴	۸۹/۶۲۴
۳	۸۷۸	۰	۷۸	۶۳۵	۳	۷	۰	۰	۰	۰	۴	۱۴۵	۶	۰	۰	۰	۰	۷۸/۲۹۸	۷۲/۳۲۳
۴	۲۸۳	۰	۲۵	۲۳	۲۲۱	۲	۰	۰	۰	۰	۰	۰	۲	۰	۰	۰	۰	۹۴/۴۴۴	۷۸/۰۹۱
۵	۴۶۴	۰	۰	۰	۴۴۸	۰	۰	۲	۰	۰	۰	۰	۰	۰	۱۲	۰	۰	۹۰/۱۴	۹۶/۵۵۱
۶	۷۵۹	۰	۵	۰	۰	۳	۷۱۹	۰	۰	۰	۶	۰	۳	۰	۲	۲۱	۰	۹۶/۲۵۱	۹۴/۷۲۹
۷	۴۹	۱	۰	۰	۰	۱۱	۰	۰	۳۱	۰	۲	۱	۲	۰	۰	۰	۰	۱۰۰	۶۳/۲۶۵
۸	۴۸۲	۰	۰	۰	۰	۰	۰	۰	۴۸۲	۰	۰	۰	۰	۰	۰	۰	۰	۹۸/۵۶۸	۱۰۰
۹	۳۱	۰	۲	۰	۰	۰	۰	۰	۰	۰	۲	۰	۲	۰	۱	۰	۰	۱۰۰	۶۴/۵۱۶
۱۰	۹۶۰	۲	۵۸	۰	۰	۰	۰	۰	۰	۰	۸۴۰	۵۶	۴	۰	۰	۰	۰	۸۷/۴۰۸	۸۷/۵
۱۱	۲۲۵۱	۱	۱۴۶	۲۹	۵	۸	۰	۰	۰	۰	۹۹	۱۹۵۲	۱۰	۱	۰	۰	۰	۷۹/۵۷۶	۸۶/۷۱۷
۱۲	۸۴۶	۰	۱۲	۸۴	۱	۸	۰	۰	۰	۰	۰	۵۷۳	۱۶۸	۰	۰	۰	۰	۹۳/۷۸	۶۷/۷۳
۱۳	۲۰۷	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۲۰۶	۰	۰	۰	۹۷/۶۳	۹۹/۵۱۶
۱۴	۱۳۴۷	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۲۵۳	۹۴	۰	۹۳/۸۳۱	۹۳/۰۲۱
۱۵	۳۶۹	۰	۹	۰	۴	۱۰	۲۶	۰	۳	۰	۶	۱۰	۶	۳	۳۹	۲۵۱	۲	۰	۶۸/۰۲۱
۱۶	۱۲۶	۰	۸	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۹۷/۹۵۹	۷۰/۵۸۸
مجموع	۱۰۳۶۶	۵۳	۱۳۷۶	۸۱۱	۲۳۴	۴۹۷	۷۴۷	۳۱	۴۸۹	۲۰	۹۶۱	۲۴۵۳	۶۱۱	۲۱۱	۱۲۹۴	۳۸۰	۹۸		
صحت کلی		۸۵/۸۴																	
اعتبار کلی		۸۲/۸۹																	

جدول ۳: صحت کلی طبقه‌بندی با استفاده از از توابع هسته و مقدار C های متفاوت.

هسته گوسی ($c=500$)	هسته چندجمله‌ای ($c=500$)	هسته گوسی ($c=0.2$)
σ	درجه چند جمله‌ای	C
-/۱	۱	۵۰
-/۲	۳	۵۰۰
-/۳	۵	۵۰۰۰
صحت	صحت	صحت
۷۷/۱	۸۰/۲۴	۸۴/۷۳
۸۵/۱۱	۸۲/۵۷	۸۵/۱۱
۸۴/۴۸	۸۲/۹۷	۸۴/۴۸

ویژگی حاصل از تحلیل مؤلفه‌های اصلی انجام گردید. در این حالت صحت کلی مرحله اول ۶۸/۳۳ درصد است که پس از مرحله دوم الگوریتم پیشنهادی ۷۶/۶۹ درصد شد. مشاهده می‌شود که صحت کلی نهایی نسبت به طبقه‌بندی اولیه ۸/۳۶ درصد بهبود یافته که بسیار قابل توجه می‌باشد. اعتبار کلی مرحله اول طبقه‌بندی ۶۹/۵۹ و پس از مرحله دوم ۷۵/۷۲ درصد است. در این حالت زمان طبقه‌بندی در حدود ۴۰ دقیقه بود.

۵- نتیجه‌گیری و جمع بندی

با بررسی نتایج مشاهده می‌شود الگوریتم پیشنهادی طبقه‌بندی بسیار دقیقتری را نسبت به طبقه‌بندی اولیه انجام می‌دهد. یکی دیگر از مزایای الگوریتم پیشنهادی کم کردن زمان طبقه‌بندی ماشین‌های بردار پشتیبان است. در واقع با الگوریتم پیشنهادی استفاده از ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ابرطیفی از لحاظ زمانی اقتصادی می‌شود. از دیگر مزایای الگوریتم پیشنهادی بهبود صحت طبقه‌بندی نهایی با افزایش تعداد ویژگی‌ها است. البته این در حالتی است که ماشین‌های بردار پشتیبان درست طراحی شده باشند. در واقع اگر ماشین بردار پشتیبان درست طراحی شود، پیچیدگی ماشین بردار پشتیبان از بعد ویژگی‌ها مستقل خواهد بود. یکی از مزایای بسیار مهم الگوریتم پیشنهادی صحت مطلوب طبقه‌بندی نهایی با تعداد نقاط آموزشی بسیار کم است. بنابراین استفاده از این الگوریتم برای طبقه‌بندی تصاویر ابرطیفی با نقاط آموزشی کم بسیار مفید است. از طرفی ماشین‌های بردار پشتیبان برای طبقه‌بندی از برخی نقاط آموزشی کم به آنها بردارهای پشتیبان می‌گویند استفاده می‌کنند. در واقع وجود یا عدم وجود نقاط آموزشی‌ای که بردار پشتیبان نیستند تأثیری در طبقه‌بندی نهایی ندارد. بنابراین اگر بتوان قبل از آموزش ماشین‌های بردار پشتیبان، نقاط آموزشی که شانس کمتری برای بردار پشتیبان بودن را دارند کنار گذاشت، زمان طبقه‌بندی بسیار کم می‌شود. این در حالی است که صحت طبقه‌بندی تغییر چندانی نخواهد کرد. یک فاکتور بسیار مهم در صحت طبقه‌بندی نهایی معیار فاصله‌ای است که برای تشکیل درخت تصمیم‌گیری مورد استفاده قرار می‌گیرد. در این تحقیق از معیار فاصله باتاچریا برای طراحی درخت تصمیم‌گیری استفاده شد.

طرفی همانطور که انتظار می‌رفت هر چه صحت طبقه‌بندی اولیه بیشتر باشد، طبقه‌بندی نهایی نیز دارای صحت بیشتری خواهد بود. برای بررسی تأثیر پارامترهای ماشین بردار پشتیبان بر صحت کلی الگوریتم پیشنهادی، تصویر منطقه مورد آزمایش با توابع هسته و مقدار C های متفاوت طبقه‌بندی شد. نتایج حاصل در جدول ۳ نشان داده شده است. در طبقه‌بندی اولیه با تبدیل موجک، موجک دایبچی ۴ استفاده شده است. مشاهده می‌شود که استفاده از تابع هسته گوسی صحت مطلوبتری نسبت به تابع هسته چند جمله‌ای دارد. از طرفی برای تابع هسته گوسی تغییر C تأثیر چندانی بر صحت طبقه‌بندی نهایی ندارد. در آزمایش‌های قبلی برای آموزش ماشین‌های بردار پشتیبان از ۱۹۰ باند نمونه‌های آموزشی استفاده شد. حال تأثیر کمتر بودن ویژگی‌ها بر صحت طبقه‌بندی بررسی می‌شود. برای این منظور طبقه‌بندی اولیه با استفاده از ۳۰ ویژگی تحلیل مؤلفه‌های اصلی انجام شد و برای آموزش ماشین‌های بردار پشتیبان از همان ۳۰ ویژگی استفاده گردید. صحت کلی مرحله دوم الگوریتم پیشنهادی ۸۳/۹۷ درصد است. اما با آموزش ماشین بردار پشتیبان با استفاده از ۱۹۰ باند، صحت کلی ۸۵/۱۱ درصد است. مشاهده می‌شود که با کم شدن ویژگی‌ها صحت طبقه‌بندی نهایی ۱/۱۴ درصد کاهش یافته است. در واقع یکی از مزایای بسیار مهم ماشین بردار پشتیبان این است که بر خلاف طبقه‌بندی کننده‌های آماری، با افزایش تعداد ویژگی‌ها صحت طبقه‌بندی بیشتر می‌شود. دلیل این امر آن است که ماشین بردار پشتیبان پارامتری ندارد که با افزایش تعداد باندها و خطای حاصل از تخمین آن پارامتر دقت طبقه‌بندی کم شود. زمان طبقه‌بندی در این حالت در حدود ۳ ساعت بود که نسبت به حالتی که از تمام ۱۹۰ ویژگی استفاده شد در حدود ۲۳ دقیقه کمتر است. در آخرین آزمایش کارکرد الگوریتم پیشنهادی زمانی که تعداد نقاط آموزشی در دسترس بسیار کم باشد، بررسی شد. در این آزمایش از ۱۲/۹۸ درصد نقاط آزمایشی به عنوان نمونه‌های آموزشی استفاده شد. طبقه‌بندی اولیه با استفاده از ۳۰

- [12] K. Goh, E. Chang, and K. T. Cheng, "SVM Binary classifier ensembles for image classification," *ACM Int. Conf. on Information and Knowledge Management (CIKM)*, pp. 395-402, Nov. 2001.
- [13] H. Ghassemian and D. Landgrebe, "Object-Oriented feature extraction method for image data compaction," *IEEE Control System Magazine*, vol. 8, no. 3, pp. 42-46, Jun. 1988.
- [14] <http://dynamo.ecn.purdue.edu/~biehl/MultiSpec>
- [15] L. M. Bruce, C. H. Koger, and L. Jiang, "Dimensionality reduction of hyperspectral data using discrete wavelet transform feature extraction," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 40, no. 10, pp. 2331-2338, Oct. 2002.

احمد کشاورز کارشناسی و کارشناسی ارشد خود را به ترتیب در مهندسی مخابرات از دانشگاه شیراز و مهندسی مخابرات گرایش سیستم از دانشگاه تربیت مدرس در سال‌های ۱۳۸۰ و ۱۳۸۳ دریافت کرد. او اکنون در مقطع دکترای مهندسی مخابرات (گرایش سیستم) دانشگاه تربیت مدرس مشغول به تحصیل است. زمینه‌های پژوهشی مورد علاقه او شناسایی الگو، پردازش تصویر و مهندسی سیستم‌های سنجش از دور می‌باشد.

محمدحسن قاسمیان یزدی تحصیلات خود را در مقطع کارشناسی مهندسی مخابرات از دانشکده مخابرات در سال ۱۳۵۹ به اتمام رساند. از ۱۳۵۹ تا ۱۳۶۲ در مرکز تحقیقات مخابرات ایران به تحقیق مشغول بود. وی در ۱۳۶۳ و ۱۳۶۷ مدرک کارشناسی ارشد و دکترای خود را در رشته مهندسی مخابرات از دانشگاه Purdue آمریکا دریافت کرد. وی هم اکنون استاد بخش مهندسی برق دانشگاه تربیت مدرس است. برخی از زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پردازش و تحلیل تصاویر چند منبعی، شناسایی الگو و پردازش اطلاعات، مهندسی سیستم‌های سنجش از دور، پردازش سیگنال‌ها و تصاویر پزشکی.

مراجع

- [1] H. Ghassemian, A. Keshavarz, and D. Landgrebe, "Hyper-spectral image processing and analyses," *Space Magazine*, vol. 1, no. 3, pp. 32-41, Oct. 2003.
- [2] G. F. Hughes, "On the Mean accuracy of statistical pattern recognizers," *IEEE Trans. on Information Theory*, vol. 14, no. 1, Jan. 1968.
- [3] D. A. Landgrebe, "Hyperspectral image data analysis," *IEEE Signal Processing Magazine*, vol. 19, no. 1, pp. 17-28, Jan. 2002.
- [4] H. Du, H. Qi, X. Wang, R. Ramanath, and W. E. Snyder, "Band selection using independent component analysis for hyperspectral image processing," in *Proc of AIPR workshop*, pp. 93-98, 2003.
- [5] L. Jimenez and D. A. Landgrebe, "Hyperspectral data analysis and feature reduction via projection pursuit," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 37, no. 6, pp. 2653-2667, Nov. 1999.
- [6] C. Lee and D. A. Landgrebe, "Feature extraction based On decision boundaries," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 15, no. 4, pp. 388-400, Apr. 1993.
- [7] S. Kaewpajit, J. L. Moigne, and T. E. Ghazawi, "Automatic wavelet spectral analysis for reduction of hyperspectral imagery," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 41, no. 4, pp. 863-871, Apr. 2003.
- [8] P. Mantero, G. Moser, S. B. Serpico, "Partially supervised classification of remote sensing images through SVM-based probability density estimation," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 43, no. 3, pp. 559-570, Mar. 2005.
- [9] A. Keshavarz and H. Ghassemian, "Hierarchical classification of hyperspectral images by using SVMs and same class neighborhood property," in *Proc. of IEEE International Geoscience and Remote Sensing Symposium IGRSS2005*, pp. 3219-3222, Jul. 2005.
- [10] F. Melgani, L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 42, no. 8, pp. 1778-1790, Aug. 2004.
- [11] V. Vapnik and A. Chervonenkis, "The necessary and sufficient conditions for consistency in the empirical risk minimization method," *Pattern Recognition and Image Analysis*, vol. 1, no. 3, pp. 283-305, 1991.

Archive of SID