

طبقه بندی داده‌های فراطیفی براساس سیستم‌های ماشین‌های بردار پشتیبان چندگانه با استفاده از گروه بندی باندهای طیفی

بهناز بیگدلی^{۱*}، فرهاد صمدزادگان^۲

^۱ دکتری فتوگرامتری-گروه مهندسی نقشه برداری- پردیس دانشکده‌های فنی-دانشگاه تهران
bigdeli@ut.ac.ir

^۲ استاد گروه مهندسی نقشه برداری- پردیس دانشکده‌های فنی- دانشگاه تهران
samadz@ut.ac.ir

(تاریخ دریافت فروردین ۱۳۹۲، تاریخ تصویب آبان ۱۳۹۳)

چکیده

با پیشرفت‌های کنونی در سنجش از دور و علوم مرتبط با آن، داده سنجش از دور فراطیفی با فراهم آوردن حجم بالای اطلاعات طیفی برای تشخیص بهتر کلاس‌های زمینی مورد استفاده فراوان قرار می‌گیرد، اگرچه تعداد زیاد باندهای طیفی در مقابل تعداد کم نمونه‌های آموزشی در دسترس، مشکل "پدیده هیوز" را در این داده ایجاد می‌کند. به علاوه تعداد زیاد باندهای طیفی که اغلب به یکدیگر وابسته می‌باشند، شامل اطلاعات زاید فراوانی هستند. این سطح بالا از پیچیدگی در داده‌های فراطیفی، باعث عدم کارایی روش‌های طبقه بندی کلاسیک در طبقه بندی این نوع داده می‌شود. با توجه به محدودیت‌های طبقه بندی کننده‌های انفرادی در این شرایط، سیستم‌های حاوی مجموعه طبقه بندی کننده‌ها ممکن است کارایی بهتری نسبت به طبقه بندی کننده‌های انفرادی داشته باشند. تحقیق پیش رو یک روش نوین برای طبقه بندی داده‌های فراطیفی با بکارگیری یک سیستم چندگانه ماشین‌های بردار پشتیبان^۱ که شامل گروه بندی باندهای طیفی است، معرفی می‌کند. روش پیشنهادی در اولین گام برای گروه بندی باندهای طیفی از روشی براساس اطلاعات دوطرفه یا متقابل^۲ استفاده می‌کند. روش پیشنهادی در دومین گام، از ماشین بردار پشتیبان به منظور طبقه بندی هر گروه از باندهای طیفی استفاده می‌کند تا مجموعه ای از طبقه بندی کننده‌ها حاصل شود. سرانجام روش پیشنهادی یک الگوریتم ادغام طبقه بندی کننده‌ها براساس تئوری بیز با نام Naïve Bayes (NB) را بکار می‌برد. نتایج حاصل از روش پیشنهادی برای دو نمونه از داده‌های فراطیفی نشان می‌دهد که روش پیشنهادی در مقایسه با SVM استاندارد-طبقه بندی کننده ایی که همه باندها را در یک زمان طبقه بندی می‌کند- نتایج بهتری را ایجاد می‌کند. این نتایج همچنین کارایی مفهوم گروه بندی باندها و سیستم‌های طبقه بندی کننده چندگانه را در مقایسه با روش‌های معمول پیشین نشان می‌دهد.

واژگان کلیدی: داده فراطیفی، ماشین‌های بردار پشتیبان، سیستم‌های طبقه بندی کننده چندگانه، گروه بندی باندهای طیفی، تئوری بیزین

* نویسنده رابط

^۱ Multiple Support Vector Machine
^۲ Mutual Information

۱- مقدمه

نشان می‌دهد که تعداد مورد نیاز از نمونه‌های آموزشی برای طبقه بندی نظارت شده، بصورت تابعی از ابعاد فضا در حال افزایش است. مهمترین روش‌های پیشنهادی برای غلبه بر مشکل هیوز، کاهش ابعاد فضا بوسیله روش‌های انتخاب و استخراج ویژگی است.

با توجه به محدودیت و مشکلات مربوط به طبقه بندی داده‌های فراطیفی، روش‌های طبقه بندی معمول نمی‌توانند کارایی مناسبی داشته باشند. در این زمینه، سیستم‌های طبقه بندی کننده چندگانه^۵ (MCS) می‌توانند بر محدودیت‌های طبقه بندی کننده‌های منفرد فائق آیند. با ادغام طبقه بندی کننده‌های مختلف، سیستم‌های شامل چند طبقه بندی کننده می‌توانند دقت طبقه بندی را در مقایسه با طبقه بندی کننده‌های انفرادی بهبود دهند [۱۴-۱۲]. در چنین سیستمی ابتدا یک مجموعه از طبقه بندی کننده‌ها ایجاد می‌شوند و سپس بوسیله یک روش ادغام خاص با هم ترکیب می‌شوند. طبقه بندی حاصل از ادغام دقت بهتری نسبت به طبقه بندی کننده‌های انفرادی ایجاد می‌نماید. سیستم‌های شامل مجموعه طبقه بندی کننده‌ها^۶ به منظور بهبود دقت طبقه بندی در کاربردهای مرتبط با سنجش از دور مورد استفاده قرار گرفتند [۱۴-۱۳]. با توجه به نتایج حاصل از این تحقیقات، تمایل فراوانی برای استفاده از این مفهوم در سنجش از دور وجود دارد.

این تحقیق یک سیستم چندگانه ماشین‌های بردار پشتیبان را به منظور طبقه بندی داده فراطیفی مورد استفاده قرار می‌دهد. در مرحله اول فضای طیفی براساس روش گروه بندی باندها به چندین زیرمجموعه طیفی تقسیم می‌شود. سپس طبقه بندی کننده SVM به منظور طبقه بندی همه گروه باندها بکار می‌رود تا مجموعه‌ای از طبقه بندی کننده‌ها را ایجاد نماید. در آخرین گام، نتایج تمامی طبقه بندی کننده‌های انفرادی بکار رفته روی گروه باندها، با اعمال یک روش ادغام طبقه بندی کننده‌ها با یکدیگر ترکیب می‌شود تا نتایج طبقه بندی نهایی حاصل شود. مزایا و نوآوری روش پیشنهادی به منظور غلبه بر مشکلات پیشین در ادامه بیان شده است:

- اولین مزیت روش پیشنهادی در مفهوم گروه بندی باندها نهفته است. به منظور غلبه بر مشکلات مربوط به

با توسعه تکنولوژی تصویربرداری سنجش از دور و سنجنده‌های فراطیفی، طبقه بندی تصاویر فراطیفی در کاربردهای مختلفی مورد توجه قرار گرفته و گسترش یافت [۵-۱]. این نوع داده، محدوده گسترده‌ای از امواج طیفی از مرئی تا مادون قرمز را در قالب بیش از صدها کانال طیفی مورد پوشش قرار می‌دهد [۱].

تاکنون تحقیقات فراوانی در زمینه طبقه بندی داده‌های فراطیفی صورت پذیرفته است [۷-۱]. روش‌های تئوری بیزین [۲]، درخت‌های تصمیم‌گیری^۱ [۳]، شبکه‌های عصبی [۴]، الگوریتم ژنتیک [۵] و روش‌های براساس هسته مرکزی^۲ [۶-۷] از این جمله می‌باشند. یکی از روش‌های رایج در طبقه بندی داده‌ها، ماشین‌های بردار پشتیبان^۳ (SVM) هستند که برای اولین بار توسط Vapnik معرفی شدند. SVM یک طبقه بندی کننده براساس بیشترین حاشیه با ظرفیت تعمیم بالا است که در مسائلی با تعداد کمی از نمونه‌های آموزشی و در فضای با ابعاد بالا می‌تواند بکار برده شود [۸]. در سال‌های اخیر SVM بصورت موفقیت آمیزی در طبقه بندی داده‌های سنجش از دور فراطیفی بکار برده شد [۹-۱۱]. Camps- Bruzzone و valls در تحقیقات خود نشان دادند که SVM از نظر دقت، بهتر از سایر طبقه بندی کننده‌ها در طبقه بندی داده‌های فراطیفی عمل می‌کند. همچنین این تحقیقات نشان دادند که روش‌های رایج طبقه بندی در تصاویر فراطیفی به علت برخی ویژگی‌های خاص این نوع داده نمی‌توانند کارایی لازم را داشته باشند. به عنوان مثال تعداد زیاد مولفه‌های بردار ویژگی (باندهای طیفی) در این داده، در حالی که داده‌های آموزشی کافی در دسترس نباشد، می‌تواند باعث افت دقت در طبقه بندی داده‌های فراطیفی شود [۱]. این مشکل با نام "پدیده هیوز"^۴ شناخته شده است. پدیده هیوز به این معناست که اگر تعداد داده‌های آموزشی ثابت باشد، دقت طبقه بندی با افزایش ابعاد فضا (تعداد باندها) کاهش خواهد یافت [۱]. این مسئله یک مشکل بزرگ برای روش‌های تشخیص الگو است. زیرا روش‌های تشخیص الگو اساساً به ابعاد بالای فضای ویژگی حساس می‌باشند. این مسئله

۴ Hughes phenomenon

۵ Multiple Classifier System

۶ Classifier Ensemble System

۱ Decision tree

۲ Kernel-based methods

۳ Support Vector Machine

۲- گروه بندی باندها در داده‌های فراطیفی

اساس گروه بندی باندها^۱ در داده‌های فراطیفی بر این اصل استوار است که باندهای مجاور با بیشترین وابستگی در یک گروه قرار می‌گیرند و آن دسته از باندهای طیفی که دارای وابستگی و شباهت کمتری می‌باشند، در گروه‌های متفاوت قرار می‌گیرند. امروزه در بیشتر تحقیقات، گروه بندی باندها در داده فراطیفی به عنوان یک گام اولیه برای انتخاب ویژگی^۲ یا مباحث کاهش ابعاد^۳ بکار برده می‌شود [۱۹-۱۳]. Benediktsson و Kanellopoulos وابستگی مطلق را به عنوان یک معیار شباهت بین باندهای طیفی پیشنهاد می‌کنند. پس از محاسبه ماتریس وابستگی بین باندها، آنها از گروه بندی دستی برای مجزا نمودن باندهای طیفی استفاده کردند [۱۳]. Prasad و همکارانش به منظور تقسیم کردن فضای فراطیفی به زیرفضاهای طیفی پیوسته، بعد از تقسیم کردن فضا براساس اطلاعات طیفی و بازتابشی، از آنالیز تشخیص هسته مرکزی^۴ (KDA) روی هر زیرفضا استفاده کردند. آنها این روش را در تشخیص اتوماتیک عوارض^۵ (ATR) بکار بردند. بکارگیری KDA در هر زیرفضا اطمینان لازم را در مورد جداسازی کلاس‌ها بوجود می‌آورد [۱۵]. در تحقیق دیگری آنها همچنین از یک روش گروه بندی در رابطه با طبقه بندی داده‌های فراطیفی - چندزمانه استفاده نمودند. مشابه تحقیق پیشین آنها ابتدا فضای طیفی را براساس اطلاعات بازتابشی تقسیم بندی کردند و سپس روی هر زیرفضا یک آنالیز تشخیص خطی^۶ (LDA) را بکار بردند. روش پیشنهادی حتی در حضور نمونه‌های آموزشی کم، توانست نتایج مناسبی را در طبقه بندی داده‌های فراطیفی کسب کند [۱۶].

Martinez و همکارانش از معیار محتوی اطلاعاتی^۷ به منظور گروه بندی داده فراطیفی استفاده کردند. آنها مفهوم گروه بندی باندها را به عنوان یک گام اولیه در انتخاب ویژگی‌های طیفی بکار بردند. روش آنها براساس یک ساختار گروه بندی بندی سلسله مراتبی برای یک دسته کردن باندها به منظور کمینه کردن وریانس درون گروه‌ای و بیشینه کردن وریانس بیرون گروه‌ای عمل می‌کرد. روش مورد استفاده در تحقیق مذکور نتایج پایدار و قابل توجهی

حجم بالای اطلاعات طیفی در داده‌های فراطیفی، پیش از این از روش‌های کاهش ابعاد فضا استفاده می‌شد. در روش‌های استخراج ویژگی هدف یافتن یک ترکیب خطی یا غیر-خطی از ویژگی‌های اولیه اندازه گیری شده با ابعاد کامل به فضای با ابعاد کم می‌باشد. در حالی که در روش‌های انتخاب ویژگی، هدف انتخاب مناسب‌ترین زیرمجموعه از ویژگی‌ها و سپس حذف سایر ویژگی‌هاست. این روش‌ها معمولاً باعث از دست رفتن بخش مفیدی از اطلاعات طیفی می‌شوند و یا ماهیت طیفی اطلاعات را تغییر می‌دهند. که این نکته باعث کاهش دقت طبقه بندی در این روش‌ها و از دست رفتن اطلاعات می‌شود. روش پیشنهادی سعی دارد با استفاده از مفهوم گروه بندی باندهای طیفی، از تمام فضای طیفی و بدون حذف یا تغییر ماهیت باندها، برای طبقه بندی استفاده کند در حالی که بر مشکل هیوز نیز فائق آید؛

- از سوی دیگر، یکی دیگر از مزیت‌های استفاده از مفهوم گروه بندی باندها، در استفاده از طبقه بندی کننده ماشین‌های بردار پشتیبان نهفته است. در روش‌های ساده معمولاً از یک طبقه بندی کننده SVM با یک هسته مرکزی که روی کل داده فراطیفی بکار برده می‌شود، استفاده می‌شود. در حالی که این هسته مرکزی نمی‌تواند به تنهایی تنوع و محتوای اطلاعاتی موجود در داده فراطیفی را پوشش دهد. با تقسیم بندی باندهای طیفی به چندین شاخه یا گروه، از یک هسته مرکزی یا SVM مجزا برای طبقه بندی هر یک از آنها استفاده می‌شود. تعریف چندین هسته مرکزی روی داده فراطیفی می‌تواند تنوع اطلاعات موجود در داده فراطیفی را پوشش دهد. به این ترتیب هسته مرکزی هر طبقه بندی کننده براساس محتوای اطلاعات همان گروه از باندهای طیفی می‌باشد؛

- آخرین مزیت روش پیشنهادی مربوط به استفاده و بکارگیری مفهوم مجموعه طبقه بندی کننده‌ها می‌باشد. ادغام نتایج حاصل از چندین طبقه بندی کننده می‌تواند باعث بهبود دقت نسبت به استفاده از طبقه بندی کننده‌های انفرادی شود. به ویژه روش پیشنهادی سعی می‌کند قابلیت سه روش ادغام طبقه بندی کننده‌ها را بررسی کند؛

^۱ Automatic Target Recognition

^۲ Linear Discriminate Analysis

^۳ Information measures

^۱ Band grouping

^۲ Feature selection

^۳ Dimension reduction

^۴ Kernel Discriminate Analysis

بنابراین تابع تصمیم‌گیری فراصفحه نهایی می‌تواند مطابق رابطه ۳ تعریف شود:

$$f(x) = \sum_{i=1}^L \alpha_i y_i k(x_i, x_j) + \gamma \quad (3)$$

که در آن α_i ضرایب لاگرانژ می‌باشند [۲۵-۲۰]. اخیراً SVM در کاربردهای سنجش از دور و به ویژه در داده‌های فراطیفی مورد توجه بسیار قرار گرفته است، بگونه‌ای که تحقیقات فراوانی در استفاده از SVM به منظور طبقه بندی داده‌های فراطیفی صورت پذیرفته است [۲۵-۲۱]. در این تحقیقات SVM نسبت به سایر طبقه بندی کننده‌های دیگر نتایج بهتری را از نظر دقت طبقه بندی فراهم کرد. Bruzzone و Melgani از SVM به منظور طبقه بندی داده‌های فراطیفی استفاده کردند. در تحقیق آنها ماشین‌های بردار پشتیبان دقت بیشتری را نسبت به سایر طبقه بندی کننده‌های دیگر بدست آورد [۲۲]. Watanachaturaporn در مطالعات خود سعی کرد تا تأثیر فاکتورهای دیگر را روی دقت طبقه بندی به روش SVM مورد بررسی قرار دهد. این فاکتورها شامل انتخاب روش چندکلاسه، انتخاب بهینه کننده^۶ و نوع تابع هسته مرکزی بوده است [۲۳]. Macronini یک روش SVM نیمه نظارت شده ترکیبی را برای طبقه بندی طیفی- مکانی داده‌های فراطیفی معرفی کرد [۲۴]. Tarabalka و همکارانش از یک روش دقیق طبقه بندی طیفی- مکانی داده‌های فراطیفی بر اساس SVM استفاده نمودند. روش پیشنهادی آنها شامل دو گام اساسی بوده است. در اولین مرحله، یک طبقه بندی کننده احتمالی SVM بر اساس پیکسل روی تصاویر فراطیفی بکار رفت و در گام دوم اطلاعات زمینه ای^۷ مکانی روی نتایج مرحله قبل بکار برده شد. این روش دقت طبقه بندی بوسیله SVM را روی داده‌های فراطیفی نسبت به سایر روش‌های پیشین بهبود بخشید.

را در گروه بندی باندها حاصل نمود [۱۷]. Guo در تحقیق دیگری نشان داد که گروه بندی باندها براساس معیارهای ساده اطلاعات دوجانبه یا اطلاعات متقابل (MI)، وقتی که وابستگی بین باندها بیشتر باشد، نتایج مناسبی را حاصل نمی‌کند [۱۸]. آنها همچنین نشان دادند که معیارهای MI به تنهایی به عنوان یک معیار شباهت نتایج مناسبی ایجاد نمی‌کنند. علت این نکته را می‌توان اینگونه بیان کرد که در مواردی که مقادیر آنتروپی باندها کم باشد، باندها از نظر این معیار، شباهت کمتری خواهند داشت [۱۸].

۳- طبقه بندی تصاویر فراطیفی با استفاده از SVM

در ماشین‌های بردار پشتیبان، دو کلاس بوسیله برازش دادن یک فراصفحه^۱ به نمونه‌های آموزشی در فضای ویژگی چند بعدی، از یکدیگر جدا می‌شوند. مسئله بهینه سازی براساس کمینه کردن احتمال خطرساختاری^۲ و بیشینه کردن حاشیه‌های بین فراصفحه جداکننده بهینه و نزدیکترین نمونه‌های آموزشی (بردارهای حمایت کننده^۳) حل می‌شود [۲۰-۱۹]. اگر برای یک مسئله طبقه بندی دو دویی در یک فضای مشخصه d بعدی، x_i مجموعه‌ای از داده‌های آموزشی از L نمونه و کلاس‌های متناظر با آنها $y_i \in \{1, -1\}$ باشد، فراصفحه $f(x)$ بوسیله بردار نرمال w و بایاس b تعریف می‌شود. در حالی که $\frac{|b|}{\|w\|}$ فاصله بین فراصفحه و مبدا می‌باشد.

$$f(x) = wx + b \quad (1)$$

برای نمونه‌هایی که بصورت خطی قابل جداسازی نباشند، داده ورودی در فضایی با ابعاد بالا تصویر می‌شود تا در فضای جدید با توزیع جدید نمونه‌ها، امکان برازش دادن یک فراصفحه خطی حاصل شود. حجم محاسبات در یک فضای با ابعاد بالا بوسیله یک هسته مرکزی^۴ مطلقاً مثبت^۵ (k) می‌تواند کاهش یابد [۲۰].

$$\Phi(x_i)\Phi(x_j) = k(x_i, x_j) \quad (2)$$

^۵ Positive definite

^۶ Optimizer

^۷ Contextual

^۱ Hyperplane

^۲ Structural risk minimization

^۳ Support vectors

^۴ Kernel

۴- سیستم‌های طبقه بندی کننده چندگانه^۱

ادغام طبقه بندی کننده‌ها به منظور اخذ دقت بالاتر در طبقه بندی داده‌ها یکی از موضوعات تحقیقاتی مهم می‌باشد که با نام‌های مختلفی مانند ادغام طبقه بندی کننده‌های چندگانه^۲، سیستم‌های طبقه بندی کننده چندگانه و یا سیستم‌های مجموعه طبقه بندی کننده‌ها شناخته شده است. در چنین سیستمی ابتدا مجموعه‌ای از طبقه بندی کننده‌ها حاصل می‌شوند و سپس خروجی مجموعه طبقه بندی کننده‌ها بوسیله یک روش ادغام با یکدیگر ادغام می‌شوند. طبقه بندی کننده حاصل از ادغام بصورت کلی نتایج دقیق‌تری از هر یک از طبقه بندی کننده‌های انفرادی خواهد داشت [۲۶-۲۸].

ابتدا هر طبقه بندی کننده با استفاده از داده‌های آموزشی آموزش می‌یابد و پس از اعمال طبقه بندی کننده‌ها، خروجی طبقه بندی کننده‌های مختلف با یکدیگر ادغام می‌شوند تا در نهایت یک تصمیم نهایی اخذ گردد. راه‌های ممکن برای ادغام L طبقه بندی کننده در یک مجموعه، بستگی به اطلاعاتی دارد که می‌توان از طبقه بندی کننده‌ها بدست آورد. Kuncheva روش‌های ادغام طبقه بندی کننده‌ها را براساس نوع خروجی آنها به دو گروه اساسی تقسیم کرد [۲۶]. اولین نوع از روش‌های ادغام روش‌هایی هستند که در آنها خروجی طبقه بندی کننده‌های انفرادی تک مقداری^۳ می‌باشد. این نوع طبقه بندی کننده‌ها هر نمونه را تنها به یک کلاس متعلق می‌دانند و در انتها نتیجه مجموعه‌ای از طبقه بندی کننده‌ها برای یک نمونه، یک بردار خواهد بود. روش‌های فضای دانش رفتار^۴، رأی گیری و بیزین از جمله این روش‌های ادغام می‌باشند. دومین نوع از روش‌های ادغام روش‌هایی هستند که روی نتایج طبقه بندی کننده‌های فازی^۵ عمل می‌کنند. در این حالت هر نمونه با درجه‌ای از تعلق به کلاس‌های مختلف متعلق می‌شود. در نهایت مجموعه‌ای از طبقه بندی کننده‌های فازی برای یک نمونه، یک ماتریس ایجاد می‌کنند. روش‌های ادغام نوع دوم سعی در ادغام نتایج طبقه بندی کننده‌های فازی دارد و از این جمله می‌توان روش الگوی تصمیم گیری^۶ را نام برد. [۲۶-۲۸].

۵- یک سیستم SVM چندگانه براساس گروه بندی باندها به منظور طبقه بندی داده فراطیفی

در این تحقیق یک سیستم مجموعه SVM براساس گروه بندی باندهای طیفی به منظور طبقه بندی داده فراطیفی معرفی می‌شود. شکل ۱ ساختار و مراحل کلی روش پیشنهادی را نمایش می‌دهد. روش پیشنهادی با تقسیم باندهای طیفی داده فراطیفی به تعدادی از گروه باندها آغاز می‌شود. این روش از اطلاعات متقابل بهبود یافته به این منظور استفاده می‌کند. یکی از فواید اصلی این روش در ارتباط با گام نخست یعنی گروه بندی باندها باشد. تحقیقات پیشین با استفاده از روش‌های کاهش ابعاد سعی می‌کنند تنها باندهای مناسب را انتخاب کنند در حالی که بقیه باندها دور انداخته می‌شوند.

مشکل این روش‌ها این است که در بسیاری مواقع باندهایی که حذف می‌شوند، حاوی اطلاعات مفیدی می‌باشند. برخلاف این روش‌ها، روش پیشنهادی سعی می‌کند تا با استفاده از تمامی باندهای طیفی بر مشکل از دست رفتن اطلاعات در روش‌های پیشین غلبه کند.

در گام دوم از روش پیشنهادی، طبقه بندی کننده SVM برای طبقه بندی همه گروه باندها که در گام پیشین حاصل شده است، بکار می‌رود. در بسیاری روش‌های پیشین SVM روی تمامی فضای داده فراطیفی بکار برده می‌شد و تنها یک تابع هسته مرکزی برای کل داده در نظر گرفته می‌شد، در حالی که یک هسته مرکزی به تنهایی نمی‌تواند تنوع فراوان موجود در باندهای طیفی متفاوت را تحت پوشش قرار دهد. به منظور رفع این مشکل، روش پیشنهادی برای هر گروه باند، یک SVM با هسته مرکزی مختص به خود را بکار می‌برد که این هسته مرکزی بر اطلاعات طیفی موجود در آن گروه منطبق می‌باشد. سرانجام و در آخرین گام از روش پیشنهادی، ادغام نتایج حاصل از طبقه بندی کننده‌های مختلف می‌تواند دقت طبقه بندی را بهبود بخشد. در این مرحله با توجه به پیچیدگی بالا و حجم زیاد داده‌های فراطیفی و از آنجا که روش‌های طبقه بندی مرسوم نمی‌توانند جواب مناسبی حاصل کنند، استفاده از یک سیستم مجموعه طبقه بندی کننده‌ها می‌تواند دقت طبقه بندی روی داده‌های فراطیفی را افزایش دهد.

۴ Behavior Knowledge Space (BKS)

۵ Fuzzy


۶ Decision Template (DT)

۱ Classifier ensemble system

۲ Multiple Classifier System (MCS)

۳ Crisp

۵-۱- گروه بندی باندها براساس اطلاعات متقابل (MI)



شکل ۱- روش پیشنهادی برای طبقه بندی داده فراطیفی براساس یک سیستم چندگانه SVM با استفاده از گروه بندی باندهای طیفی

آنجا که MI تنها وابستگی بین باندها را در نظر می‌گیرد، یک روش جستجو براساس الگوریتم ژنتیک- ماشین‌های بردار پشتیبان (GA-SVM) برای یافتن بهترین ترکیب از باندها که دارای اطلاعات مشابه بیشتری هستند نیز استفاده می‌شود. در ادامه به منظور بهبود نتایج حاصل از گروه بندی باندها، جستجویی براساس مفاهیم شاخه-مقید^۱ (BB) روی نتایج گروه‌ها بکار رفت. جزئیات و مفاهیم روش BB توسط Nakariyakul, Casasent معرفی و بررسی شده است [۳۴].

۵-۲- ادغام طبقه بندی کننده‌ها براساس روش Naïve Bayes

روش Naïve Bayes (NB) یک روش ادغام طبقه بندی کننده‌های آماری است که می‌تواند برای ادغام طبقه بندی کننده‌های با خروجی تک مقداری بکار برده شود. اساس روش NB بر مبنای تئوری بیزین می‌باشد [۲۶].

اگر $p(s_j)$ این احتمال باشد که طبقه بندی کننده D_i داده x را در کلاس s_j طبقه بندی کند L تعداد طبقه بندی کننده‌ها و C تعداد کلاس‌هاست و $S = [s_1, \dots, s_L]$ نمایش دهنده بردار خروجی مجموعه طبقه بندی کننده‌هاست:

$$p(S/w_k) = p(s_1, s_2, \dots, s_L/w_k) = \prod_{i=1}^L p(s_i/w_k) \quad (۷)$$

آنگاه احتمال پسین مورد نیاز برای طبقه بندی کردن نمونه x مطابق رابطه ۸ بیان می‌شود:

$$p(w_k/s) = \frac{p(w_k)p(s/w_k)}{p(s)} = \frac{p(w_k) \prod_{i=1}^L p(s_i/w_k)}{p(s)} \quad k=1, \dots, c \quad (۸)$$

مخرج کسر بالا به مقدار w_k وابسته نیست پس می‌توان از آن صرف نظر کرد. در نهایت حمایت نهایی برای کلاس w_k مطابق رابطه ۹ بیان می‌شود:

$$p(S/w_k) = p(s_1, s_2, \dots, s_L/w_k) = \prod_{i=1}^L p(s_i/w_k) \quad (۹)$$

طراحی عملی روش NB به منظور پیاده سازی برای مجموعه داده واقعی به شرح زیر می‌باشد. برای هر طبقه بندی کننده D_i یک ماتریس ابهام $C \times C$ با نام CM_i با استفاده از داده‌های آموزشی حاصل می‌شود [۲۶]. (k, s) امین ورودی

این تحقیق یک روش گروه بندی براساس اطلاعات متقابل را برای گروه بندی باندهای داده فراطیفی استفاده می‌کند. آنتروپی معیاری از عدم قطعیت متغیرهای اتفاقی است که برای انتخاب ویژگی‌ها مورد استفاده بسیار قرار می‌گیرد [۱۷-۱۵].

اگر متغیر اتفاقی گسسته X دارای مبادی Φ و تابع توزیع احتمال نیز $p(x)$ باشد، آنتروپی متغیر X مطابق رابطه ۴ بیان می‌شود:

$$H(X) = - \sum_{x \in \Phi} p(x) \log p(x) \quad (۴)$$

برای دو متغیر اتفاقی X, Y که دارای مبادی های Φ, Ψ می‌باشند تابع توزیع احتمال اتصالی $p(x, y)$ و آنتروپی متقابل برای X, Y با رابطه ۵ بیان می‌شود:

$$H(X, Y) = - \sum_{x \in \Phi} \sum_{y \in \Psi} p(x, y) \log p(x, y) \quad (۵)$$

اطلاعات متقابل معمولاً به عنوان معیاری پرکاربرد برای محاسبه وابستگی و شباهت بین دو متغیر اتفاقی مطابق رابطه ۶ بکار می‌رود.

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) = H(X) - H(X/Y) \quad (۶)$$

وقتی شباهت و افزونگی بین دو باند بیشتر باشد، مقدار MI یا اطلاعات متقابل بین دو باند بزرگتر خواهد بود. مفهوم اساسی گروه بندی باندها بر این اصل استوار است که باندها براساس نقاط کمینه محلی مقادیر MI گروه بندی می‌شوند. بعد از گروه بندی اولیه باندها براساس اطلاعات متقابل، از

^۱ Branch and Bound

شبکه یکی از روش‌های معروف برای انتخاب بهترین پارامترهای SVM است که جزییات آن در تحقیق Hsu بصورت کامل بیان شده است [۳۷].

پس از ایجاد نتایج طبقه بندی کننده‌های اولیه، روش‌های ادغام طبقه بندی کننده‌ها به منظور بهبود نتایج طبقه بندی بکار می‌رود. در این تحقیق علاوه بر روش NB از دو روش دیگر به منظور ادغام طبقه بندی کننده‌ها استفاده شد. اولین روش از این دسته، روش رأی گیری وزندار (WMV) می‌باشد که براساس مفاهیم رأی گیری عمل می‌کند. این روش توسط Kuncheva معرفی و روی داده‌های مصنوعی مورد استفاده و ارزیابی قرار گرفت. در این روش دقت حاصل برای هر طبقه بندی با استفاده از ماتریس ابهام آن قابل محاسبه می‌باشد و از همان دقت به عنوان وزن آن طبقه بندی کننده استفاده می‌شود. دومین روش ادغام طبقه بندی کننده‌ها بر اساس SVM می‌باشد. در این روش خروجی همه طبقه بندی کننده‌ها به عنوان بردار مشخصه-های جدید و به عنوان ورودی به یک SVM جدید معرفی می‌شوند، به شکلی که SVM نتایج تمام طبقه بندی کننده‌ها را با یکدیگر ادغام می‌کند. در این تحقیق علاوه بر روش پیشنهادی با استفاده از گروه بندی باندهای داده فراطیفی، یک طبقه بندی کننده SVM روی کل فضای داده فراطیفی مورد استفاده قرار می‌گیرد تا نتایج روش پیشنهادی با آن مورد مقایسه و ارزیابی قرار گیرد. این روش طبقه بندی که با بکار بردن یک طبقه بندی کننده SVM روی کل فضای داده حاصل می‌شود، طبقه بندی کننده استاندارد نامیده می‌شود. به علاوه روش پیشنهادی با دو مورد از روش‌های انتخاب ویژگی نیز مقایسه خواهد شد. روش‌های SFFS^۴ و SBFS^۵ از جمله ساده‌ترین روش‌های انتخاب ویژگی می‌باشند. این روش‌ها بهترین مجموعه از ویژگی‌ها یا باندهای طیفی را بگونه‌ای تشخیص می‌دهند که در روش SFFS از یک مجموعه خالی و با اضافه کردن ویژگی‌ها به این مجموعه استفاده می‌شود در صورتی که در روش SBFS از یک مجموعه کامل از باندهای طیفی و حذف کردن آنها استفاده می‌شود. جزییات مربوط به این روش‌ها را می‌توانید در تحقیقات Pudeil مطالعه و بررسی کنید [۳۸].

این ماتریس $CM_{k,s}^i$ تعداد المان‌هایی از داده است که کلاس واقعی آنها w_k است در حالی که توسط طبقه بندی کننده D_i به کلاس w_s متعلق شده‌اند. N_s تعداد کل نمونه‌هایی از Z است که به کلاس w_s تعلق دارد. اگر $CM_{k,s}^i / N_k$ به عنوان یک تخمین از احتمال پسین در نظر گرفته شود و N_k / N به عنوان یک تخمین از احتمال پیشین برای کلاس k باشد، آنگاه درجه حمایت نهایی برای داده x توسط هر کلاس k مطابق رابطه ۱۰ می‌باشد:

$$\mu_k(x) \propto \frac{1}{N_k^{L-1}} \prod_{i=1}^L cm_{k,s_i}^i \quad (10)$$

تحقیقات انجام شده نشان داده است که روش NB نتایج بسیار دقیق و کارآمدی را فراهم می‌کند. Kuncheva روش NB را به عنوان روش ادغام طبقه بندی کننده‌ها روی داده‌های مصنوعی بکار برد [۲۶]. طبقه بندی کننده‌های بیزین بصورت موفقیت آمیزی در طبقه بندی متون بکار رفتند که از این جمله می‌توان به تحقیق Xu در بکارگیری این روش برای تشخیص دست خط نام برد [۳۵].

همانطور که در بخش ۵-۱ شرح داده شد، در این تحقیق الگوریتم گروه بندی باندها براساس MI برای تقسیم داده فراطیفی به چندین زیرفضای طیفی بکار می‌رود. نتایج این بخش، گروه‌هایی از باندهاست. پس از آن، طبقه بندی کننده SVM بصورت جداگانه برای طبقه بندی هر گروه بکار می‌رود. استفاده از هسته‌های مرکزی ساده مانند چندجمله‌ای‌ها برای داده‌ای با پیچیدگی‌های داده‌های فراطیفی کارآمد نمی‌باشد. از این رو هسته مرکزی RBF^۱ به عنوان هسته مرکزی پایه در طبقه بندی کننده SVM استفاده می‌شود. از آنجا که داده مورد استفاده دارای بیش از دو کلاس می‌باشد از روش طبقه بندی SVM چندکلاسه یک-درمقابل-یک استفاده خواهد شد. یکی از نکاتی که در بهبود نتایج طبقه بندی بوسیله SVM تأثیر فراوانی دارد، انتخاب بهترین پارامترها برای این طبقه بندی کننده می‌باشد. این پارامترها شامل پارامتر تنظیم C ^۲ و پارامترهای هسته مرکزی مانند پارامتر σ برای هسته مرکزی گوسین و درجه چندجمله‌ای برای هسته مرکزی چندجمله‌ای می‌باشد [۳۶]. در این تحقیق از روش جستجوی شبکه^۳ برای یافتن بهترین پارامترهای SVM استفاده شد. روش جستجوی

۴ Sequential Forward Floating Selection
۵ Sequential Backward Floating Selection

۱ Radial Basis Function
۲ Regularization parameter
۳ Grid search

۶- نتایج اجرایی

۶-۱- داده مورد استفاده

به منظور اجرای روش پیشنهادی از دو مورد از رایج‌ترین داده‌های فراطیفی استفاده شد. داده اول یک تصویر ۱۴۵*۱۴۵ از سنجنده AVIRIS می‌باشد که از بخش شمالی منطقه ایندیانا در ژوئن ۱۹۹۲ اخذ شده است [۳۸].



الف



ب


شکل ۲- داده فراطیفی سنجنده AVIRIS ، الف) داده اصلی و ب) واقعیت زمینی

جدول ۱- نمونه‌های هر کلاس برای داده ایندیانا

شماره	کلاس	تعداد
۱	Corn-no till	۱۴۳۴
۲	Corn-minimum till	۸۳۴
۳	Grass\Pasture	۴۹۷
۴	Grass\trees	۷۴۷
۵	Hay-Windrowed	۴۸۹
۶	Soybeans-no till	۹۶۸
۷	Soybeans-minimum till	۲۴۶۸
۸	Soybeans-clean till	۶۱۴
۹	Wood	۱۲۹۴

در داده AVIRIS همه ۲۲۰ باند طیفی مورد استفاده قرار نمی‌گیرد و ۱۸ باند که تحت تاثیر جذب اتمسفری می‌باشند حذف می‌شوند. بنابراین ابعاد داده AVIRIS شامل ۲۰۲ باند باقیمانده می‌باشد (شکل ۲). از ۱۶ کلاس موجود برای این داده، ۷ کلاس که دارای تعداد کمی از نمونه‌های آموزشی و آزمایشی می‌باشند حذف شدند و تنها ۹ کلاس

باقیمانده استفاده می‌شوند. جدول ۱ کلاس‌ها و تعداد نمونه‌های مرجع موجود برای هر کلاس را نمایش می‌دهد. داده دوم داده فراطیفی دانشگاه پاولا است که توسط سنجنده آلمانی ROSIS از شهر پاولا در ایتالیا اخذ شده است. این داده شامل ۱۰۳ باند طیفی در محدوده ۰،۸۶-۰،۴۳ میکرومتر از طیف الکترومغناطیس می‌باشد. شکل ۳ داده پاولا و واقعیت زمینی آن را نمایش می‌دهد.



ب

الف

شکل ۳- داده فراطیفی دانشگاه پاولا، الف) داده اصلی و ب) واقعیت زمینی

جدول ۲- نمونه‌های هر کلاس برای داده پاولا

شماره	کلاس	تعداد
۱	Tree	۵۲۴
۲	Asphalt	۵۴۸
۳	Bitumen	۳۷۵
۴	Gravel	۳۹۲
۵	Painted metal sheets	۲۶۵
۶	Shadows	۲۳۱
۷	Self-Blocking Bricks	۵۱۴
۸	Meadows	۵۴۰
۹	Bare Soil	۵۳۲


این داده یک تصویر ۳۴۰*۶۱۰ است که حاوی ۹ کلاس طیفی می‌باشد. جدول ۲ اطلاعات و نمونه‌های در دسترس برای داده فراطیفی پاولا را نشان می‌دهد.

۶-۲- نتایج اجرایی

روش پیشنهادی برای دو داده فراطیفی پیشنهادی بکار برده شد. در اولین گام از روش پیشنهادی، گروه بندی باندهای فراطیفی براساس اطلاعات متقابل به منظور تقسیم داده فراطیفی به زیر فضاهای شامل باندهای مشابه، انجام

پس از گروه بندی باندها، به منظور طبقه بندی تصویر فراطیفی، روش ماشین‌های بردار پشتیبان چندکلاسه یک-درمقابل-یک برای طبقه بندی ۱۲ گروه حاصل از داده فراطیفی بکار می‌رود. همانطور که پیش از این اشاره شد، روش جستجوی شبکه به منظور انتخاب بهترین پارامترهای SVM بکار می‌رود. محدوده جستجوی پارامترها، برای پارامتر C در فاصله $[2^{-10}, 2^2]$ و برای پارامتر γ در فاصله $[2^{-2}, 2^{10}]$ می‌باشد. جدول ۴ نتایج دقت طبقه بندی را برای ۱۲ گروه حاصل در بخش پیشین نشان می‌دهد. به منظور در نظر گرفتن تأثیر تعداد داده‌های آموزشی در دقت حاصل از طبقه بندی، نتایج اجرایی برای درصدهای متفاوتی از تعداد داده‌های آموزشی حاصل شد. پس از ایجاد مجموعه نتایج طبقه بندی، در آخرین گام از روش پیشنهادی سه روش ادغام طبقه بندی-کننده‌ها (روش بیز، روش رأی گیری وزندار و SVM) روی نتایج طبقه بندی کننده‌های حاصل از گام پیشین بکار رفت. به منظور بررسی و مقایسه روش پیشنهادی با الگوریتم‌های رایج طبقه بندی داده‌های فراطیفی، یک SVM استاندارد برای طبقه بندی کل فضای داده فراطیفی با تمامی باندهای موجود بکار برده شد. جدول ۵ نتایج دقت کلی طبقه بندی را برای سه روش ادغام طبقه بندی کننده‌ها و طبقه بندی کننده استاندارد برای تعداد مختلف از داده‌های آموزشی در هر گروه باند نمایش می‌دهد. نتایج حاصل از جدول ۵ نشان می‌دهد که تمامی روش‌های ادغام دقت بالاتری را نسبت به طبقه بندی کننده‌های انفرادی کسب نموده‌اند.

می‌شود. شکل ۴ نتایج اطلاعات متقابل را برای داده ایندینا به عنوان معیار شباهت بین باندها نمایش می‌دهد.



شکل ۴- اطلاعات متقابل برای داده ایندینا

نقاط کمینه این نمودار نشان از باندهای طیفی دارد که کمترین شباهت را با یکدیگر دارند. این نقاط در شکل با خطوط مشکی پر رنگ نمایش داده شده‌اند. باندهایی که در فاصله بین هر دو خط مشکی قرار گرفته‌اند، به عنوان یک گروه از باندهای طیفی در نظر گرفته می‌شود. تعیین این نقاط مینیمم محلی بصورت اتوماتیک انجام شده است. پس از ایجاد گروه‌های اولیه براساس نقاط کمینه اطلاعات متقابل، الگوریتم GA-SVM و BB روی این نتایج اولیه بکار برده می‌شود. نتایج نهایی گروه بندی باندها برای داده ایندینا در جدول ۳ نمایش داده شده است. نتایج حاصل از این جدول نشان می‌دهد، داده فراطیفی ایندینا به ۱۲ گروه متفاوت تبدیل می‌شود، به نحوی که باندهای مشابه از نظر رفتار طیفی در یک گروه قرار می‌گیرند.

جدول ۳- نتایج نهایی گروه بندی باندها براساس اطلاعات متقابل برای داده ایندینا

شماره گروه	۱	۲	۳	۴	۵	۶
گروه باند	۱-۱۸	۱۹-۳۳	۳۴-۴۴	۴۵-۵۷	۵۸-۷۷	۷۸-۱۰۵
شماره گروه	۷	۸	۹	۱۰	۱۱	۱۲
گروه باند	۱۰۶-۱۲۵	۱۲۶-۱۳۱	۱۳۲-۱۴۷	۱۴۸-۱۵۷	۱۵۸-۱۷۰	۱۷۱-۲۰۲


جدول ۴- نتایج طبقه بندی کننده SVM برای گروه‌های باندهای داده ایندینا

داده آموزشی	گروه ۱	گروه ۲	گروه ۳	گروه ۴	گروه ۵	گروه ۶
%۵	۵۳,۷۷	۶۳,۲۲	۶۲,۵۶	۴۹,۷۵	۵۶,۷۷	۶۰,۴۲
%۱۰	۵۷,۷۷	۶۷,۵۸	۶۶,۴۴	۵۳,۳۳	۵۹,۵۵	۶۳,۴۴
%۲۰	۶۰,۴۳	۷۱,۶۶	۶۹,۹۲	۵۶,۷۲	۶۳,۰۰	۶۷,۰۰
داده آموزشی	گروه ۷	گروه ۸	گروه ۹	گروه ۱۰	گروه ۱۱	گروه ۱۲
%۵	۵۲,۶۴	۴۱,۸۸	۵۲,۲۵	۴۹,۷۸	۵۴,۱۱	۵۴,۶۸
%۱۰	۵۷,۵۲	۴۶,۶۶	۵۵,۴۲	۵۱,۸۹	۵۷,۵۵	۵۹,۶۲
%۲۰	۶۰,۰۴	۴۹,۸۵	۵۶,۸۴	۵۳,۲۲	۵۹,۴۲	۶۴,۲۸

جدول ۵- مقایسه نتایج دقت طبقه بندی برای روش های مختلف طبقه بندی برای داده فراطیفی ایندیانا

اندازه داده آموزشی	روش ادغام پیشنهادی براساس گروه بندی باندها			روش های انتخاب ویژگی		
	WMV	SVM	NB	SVM استاندارد	SFFS	SBFS
۵٪	۸۲,۸۰	۸۴,۴	۸۶,۰۰	۸۲,۰۰	۸۴,۰۰	۸۳,۱
۱۰٪	۹۰,۰۰	۹۱,۸	۹۲,۸۹	۸۹,۷۷	۹۰,۴۰	۹۰,۳۴
۲۰٪	۹۱,۶۰	۹۲,۶	۹۴,۰۰	۹۱,۲۲	۹۳,۰۰	۹۱,۸۰

دقت کلاس ۴ (Grass/trees) و کلاس (minimum till) باعث کاهش دقت شده است.




شکل ۶- دقت کلاس‌های مختلف در روش‌های طبقه بندی برای داده ایندیانا

پس از روش NB روش ادغام براساس ماشین‌های بردار پشتیبان به عنوان یک روش ادغام طبقه بندی کننده‌ها دقت بالاتری را نسبت به روش ادغام براساس رأی گیری وزندار ایجاد نموده است. علت این پدیده را می‌توان در این نکته جستجو کرد که روش SVM از مبانی دقیق یادگیری ماشین پیروی می‌کند. این نکته که روش WMV تنها براساس مفاهیم رأی گیری عمل می‌کند، می‌تواند دلیلی برای کسب دقت پایین‌تر توسط این روش در مقایسه با دیگر روش‌های ادغام باشد. ذکر این نکته ضروری به نظر می‌رسد که دقت نهایی برای ۲۰٪ داده آموزشی توسط روش ادغام بیزین ۹۴ درصد بوده است. بهبود دقت طبقه بندی در جداول ۴ و ۵ با افزایش نمونه‌های آموزشی افزایش یافته است. اگرچه برای بعضی از طبقه بندی کننده‌ها این افزایش تاثیر چندانی نداشته و تنها ۲-۳ درصد باعث بهبود دقت شده است.

شکل ۷ تصویر نهایی طبقه بندی را برای طبقه بندی کننده استاندارد و بهترین روش ادغام (روش NB) نمایش می‌دهد. این تصاویر نیز توانایی و کارایی یک سیستم مجموعه طبقه بندی کننده‌ها را در مقایسه با یک طبقه بندی کننده استاندارد نمایش می‌دهد.

این نکته موید این ویژگی اساسی در سیستم‌های شامل چند طبقه بندی کننده است که نتیجه پس از ادغام، نتایج طبقه بندی کننده‌های انفرادی را بهبود می‌بخشد. مقایسه نتایج روش‌های ادغام با طبقه بندی کننده ماشین‌های بردار پشتیبان استاندارد تایید کننده قابلیت و کارآمدی روش پیشنهادی در طبقه بندی داده‌های فراطیفی است.

تمامی روش‌های ادغام طبقه بندی کننده‌ها در مقایسه با طبقه بندی کننده استاندارد و روش‌های انتخاب ویژگی باعث بهبود نتایج طبقه بندی شدند. علت این بهبود دقت را می‌توان در تأثیر مثبت حاصل از گروه بندی باندهای طیفی به جای استفاده از تمامی باندها و همچنین استفاده از مفهوم ادغام طبقه بندی کننده‌ها به منظور ادغام نتایج طبقه بندی کننده‌ها دانست (شکل ۵).



شکل ۵- مقایسه دقت طبقه بندی برای روش های مختلف طبقه بندی

بررسی نتایج روش‌های مختلف ادغام در سیستم‌های مجموعه طبقه بندی کننده‌ها نشان می‌دهد که روش ادغام بر اساس تئوری بیزین (NB) از دو روش دیگر ادغام (رأی گیری وزندار و SVM) دقیق‌تر می‌باشد (شکل ۵). علت این پدیده را می‌توان دقت و قابلیت بالای تئوری بیزین در مقایسه با دو روش دیگر دانست. شکل ۶ دقت کلاس‌های مختلف را تحت روش‌های مختلف طبقه بندی نمایش می‌دهد. مطابق شکل روش NB نسبت به طبقه بندی کننده استاندارد SVM در بیشتر کلاس‌های موجود دارای دقت بالاتری می‌باشد. اگرچه این روش برای کلاس‌های ۲ (Corn)

جدول ۶- نتایج نهایی گروه بندی باندها براساس اطلاعات متقابل برای داده پاویا

شماره گروه	۱	۲	۳	۴
گروه باند	۱-۲۲	۲۳-۳۳	۳۴-۴۶	۴۷-۵۷
شماره گروه	۵	۶	۷	۹
گروه باند	۵۸-۷۳	۷۴-۸۴	۸۵-۹۳	۹۴-۱۰۳

نتایج حاصل نشان می‌دهد، براساس اطلاعات متقابل هشت گروه باند برای داده فراطیفی حاصل شده است. شماره مربوط به این باندهای همسایه در جدول ۶ نمایش داده شده است. پس از گروه بندی باندهای طیفی، طبقه بندی کننده ماشین‌های بردار پشتیبان به منظور طبقه بندی گروه باندهای حاصل بکار برده می‌شود. نتایج حاصل مربوط به دقت طبقه بندی برای هشت گروه باند حاصل در جدول ۷ نمایش داده شده است.

جدول ۷- نتایج طبقه بندی کننده SVM برای گروه‌های باندهای داده پاویا

شماره گروه	۱	۲	۳	۴
گروه باند	۶۲,۳۳	۵۴,۸۶	۶۴,۱۱	۵۳,۵۵
شماره گروه	۵	۶	۷	۹
گروه باند	۶۲,۰۰	۶۶,۰۰	۵۷,۰۰	۴۷,۰۲

پس از طبقه بندی گروه باندهای طیفی برای داده فراطیفی پاویا، هشت نتیجه طبقه بندی تحت سیستم ادغام طبقه بندی کننده با یکدیگر ادغام می‌شوند. نتایج حاصل از طبقه‌بندی داده فراطیفی پاویا توسط روش‌های مختلف طبقه‌بندی استاندارد، روش پیشنهادی براساس ادغام طبقه بندی کننده‌ها و روش‌های انتخاب ویژگی در جدول ۸ نمایش داده شده است. بررسی نتایج نشان می‌دهد مانند داده پیشین، برای داده فراطیفی پاویا نیز روش ادغام طبقه بندی کننده‌ها براساس ادغام بیزین بیشترین دقت را بدست آورده است.

جدول ۸- مقایسه نتایج دقت طبقه بندی برای روش‌های مختلف طبقه بندی برای داده فراطیفی پاویا

روش‌های انتخاب ویژگی	طبقه بند کننده استاندارد	روش پیشنهادی ادغام طبقه بندی کننده براساس گروه بندی باندها	مجموعه روش‌های طبقه بندی
SFFS	Standard SVM	SVM	روش طبقه بندی
۹۳,۸۰	۹۳,۱۱	۹۳,۳۳	دقت
SFBS	NB	WMV	
۹۳,۴۰	۹۵,۱۱	۹۳,۱۱	




الف



ب

شکل ۷- تصاویر حاصل از طبقه بندی برای داده ایندیانا (الف) طبقه بندی کننده استاندارد و (ب) روش NB

روش پیشنهادی در ادامه برای دومین داده فراطیفی، یعنی داده فراطیفی دانشگاه پاویا بکار برده شد. نتایج مربوط به گروه بندی باندهای طیفی برای این داده در شکل ۸ و جدول ۶ نمایش داده شده است.




شکل ۸- اطلاعات متقابل برای داده پاویا

فراطیفی مورد ارزیابی و بررسی قرار داده است. روش پیشنهادی یک سیستم گروه بندی باندها را براساس اطلاعات متقابل برای داده فراطیفی استفاده می‌کند تا این داده را به تعدادی گروه شامل باندهای مشابه تقسیم کند. سپس طبقه بندی کننده‌های SVM برای طبقه بندی هر گروه حاصل از مرحله قبل آموزش یافته و نتایج لازم را برای سیستم مجموعه طبقه بندی کننده‌ها ایجاد می‌کنند. سرانجام روش‌های ادغام تصمیم گیری در سیستم‌های مجموعه طبقه بندی کننده‌ها بکار برده می‌شوند تا نتایج تمام طبقه بندی کننده‌ها با یکدیگر ادغام شوند و تصمیم نهایی حاصل شود. روش پیشنهادی از یک الگوریتم ادغام طبقه بندی کننده‌ها بر اساس مبانی تئوری بیرین استفاده می‌کند.


اولین هدف روش پیشنهادی به تأثیر مثبت استراتژی گروه بندی باندها برای حل مشکلات کاهش ابعاد در داده‌های فراطیفی اشاره دارد. بسیاری تحقیقات پیشین که در دسته روش‌های کاهش ابعاد قرار می‌گیرند، برای غلبه بر مشکل افزونگی داده در داده‌های فراطیفی تلاش کرده‌اند تا تنها باندهای مفید را انتخاب کنند. اگرچه ضعف اساسی روش‌های کاهش ابعاد، از دست رفتن برخی از اطلاعات مفید با حذف باندهای داده فراطیفی می‌باشد. با استفاده از مفهوم گروه بندی باندها، روش پیشنهادی در این تحقیق با بکارگیری سیستمی که از کل فضای طیفی استفاده می‌کند، سعی دارد تا بر ضعف‌های داده فراطیفی غلبه کند. به علاوه به علت حجم بالای اطلاعات طیفی و پیچیدگی بالای تصاویر فراطیفی، استفاده از یک هسته مرکزی در طبقه بندی کننده SVM نتایج دقیق و مناسبی را در طبقه بندی این داده ایجاد نمی‌کند. استفاده از SVM رایج روی کل داده فراطیفی، نیاز به تعریف تنها یک هسته مرکزی برای داده دارد در حالی که این هسته مرکزی نمی‌تواند تنوع اطلاعات موجود در این نوع داده را مورد پوشش قرار دهد.

به منظور حل این مشکل، تقسیم داده فراطیفی به چند زیرمجموعه و تعریف یک هسته مرکزی روی هر زیرمجموعه که تنها بر اطلاعات موجود در آن زیرمجموعه منطبق است، و ادغام نتایج حاصل، می‌تواند راهگشا باشد. به عبارتی گام گروه بندی باندها در روش پیشنهادی بر مشکلات مذکور غلبه می‌کند. در حقیقت هسته مرکزی هر طبقه بندی کننده انفرادی روی هر گروه، تنها براساس ویژگی‌ها و اطلاعات باندهای موجود در آن گروه تعریف می‌شود.



شکل ۹- دقت کلاس‌های مختلف در روش‌های طبقه بندی برای داده پویا

مقایسه نتایج دقت طبقه بندی برای ۹ کلاس موجود در داده فراطیفی پویا در شکل ۹ نمایش داده شده است. مقایسه و بررسی این شکل نشان می‌دهد، روش پیشنهادی ادغام براساس تئوری بیز دقت بیشتری را نسبت به سایر روش‌های طبقه بندی بدست می‌آورد. اگرچه برای کلاس‌های ۱ (درخت) و کلاس ۹ این نکته صادق نبوده است. و روش ادغام نتوانسته است بهبود دقت را حاصل کند. شکل ۱۰ تصویر حاصل از طبقه‌بندی به روش پیشنهادی ادغام بیزین را با روش طبقه بندی استاندارد مقایسه کرده است.



شکل ۱۰- شکل ۷- تصاویر حاصل از طبقه بندی برای داده پویا، (الف) طبقه بندی کننده استاندارد و (ب) روش NB

۳-۶- نتیجه گیری و بحث روی نتایج

در زمینه تصاویر فراطیفی، روش‌های طبقه بندی پیشین به دلایلی مانند تعداد محدود نمونه‌های آموزشی و تعداد بالای باندهای طیفی به اندازه کافی کارآمد و دقیق نبوده‌اند. این تحقیق، کارایی یک سیستم چندگانه ماشین‌های بردار پشتیبان را به منظور طبقه بندی داده‌های

روش پیشنهادی نشان می‌دهد که این روش دقت طبقه بندی بالاتر و پایداری بیشتری را نسبت به طبقه بندی کننده‌های رایج پیشین ایجاد می‌کند و همچنین بر بسیاری از ضعف‌ها در طبقه بندی داده فراطیفی غلبه می‌کند. مطالعات آینده می‌تواند به روش‌های دیگر با سرعت و دقت بیشتر در گروه بندی باندها، ادغام طبقه بندی کننده-ها، بکارگیری طبقه بندی کننده‌های فازی و روش‌های ادغام طبقه بندی کننده‌های فازی بپردازد.

دومین هدف روش پیشنهادی بهبود نتایج طبقه بندی بوسیله ادغام نتایج طبقه بندی کننده‌ها می‌باشد. یک سیستم مجموعه طبقه بندی کننده‌ها کارآیی فراوانی برای بهبود نتایج طبقه بندی تاکنون از خود نشان داده است. بگونه‌ای که تمامی روش‌های ادغام بکار رفته در این تحقیق از نظر دقت طبقه بندی بهتر از طبقه بندی کننده استاندارد بوده‌اند که از تمامی فضای داده فراطیفی استفاده می‌کند. در این میان به علت دقت و پایداری روش ادغام بیزین این روش نتایج دقیق‌تری را نسبت به دو روش دیگر ادغام حاصل کرده است. در انتها، نتایج بدست آمده از

مراجع

- [1] Li, S., Wu, H., Wan, D., Zhu, J. (2011). An effective feature selection method for hyper spectral image classification based on genetic algorithm and support vector machine, Knowledge-Based Systems, Vol. 24, pp.40-48.
- [2] D. A. Landgrebe. (2003). Signal Theory Methods in Multispectral Remote Sensing. New York: Wiley.
- [3] Goel, P. K., Prasher, S. O., Patel, R. M., Landry, J. A., Bonnell, R. B., Viau, A. A. (2003). Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn," Comput. Electron. Agric., vol. 39, no. 2, pp. 67-93.
- [4] Del Frate, F., Pacifici, F., Schiavon, G., and Solimini, C. (2007). Use of neural networks for automatic classification from high-resolution images," IEEE Trans. Geosci. Remote Sens., vol. 45, no. 4, pp. 800-809.
- [5] Vaiphasa, C. (2003). Innovative genetic algorithm for hyperspectral image classification," in Proc. Int. Conf. Map Asia, p. 20.
- [6] Müller, K. L., Mika, S., Rätsch, G., Tsuda, K. and Schölkopf, B. (2001). An introduction to kernel-based learning algorithms," IEEE Trans. Neural Netw., vol. 12, no. 2, pp. 181-202.
- [7] Camps-Valls, G. and Bruzzone, L. (2005). Kernel-based methods for hyper spectral image classification," IEEE Trans. Geosci. Remote Sens., vol. 43, no. 6, pp. 1351-1362.
- [8] Vapnik, V. N. (1998). Statistical Learning Theory. New York: Wiley.
- [9] Gualtieri, J. and Cromp, R. (1998). Support vector machines for hyper spectral remote sensing classification," in Proc. 27th AIPR Workshop Advances in Computer Assisted Recognition, Washington, DC, 1998, pp. 121-132.
- [10] Melgani, F., Bruzzone, L. (2004). Classification of Hyper spectral Remote Sensing Images With Support Vector Machines", IEEE Trans. Geosci. Remote Sensing, vol. 42, no. 8, pp. 1778-1790.
- [11] Serpico, S. B., and Moser, G. (2007). Extraction of spectral channels from hyper spectral images for classification purposes," IEEE Trans. Geosci. Remote Sens., vol. 45, no. 2, pp. 484-495.
- [12] Kuncheva, L. (2004). Combining Pattern Classifiers methods and algorithms. A John Wiley&sons, INC. publication, Hoboken, New jersey. Canada.
- [13] Benediktsson, J.A. and Kanellopoulos, I. (1999). Classification of multisource and hyper spectral databased on decision fusion. IEEE Transactions on Geoscience and Remote Sensing, 37 (3), 1367-1377.

- [14] Benediktsson, J.A., Chanussot, J., and Fauvel, M. (2007). Multiple classifier systems in remote sensing: from basics to recent developments. In: M. Haindl, J. Kittler and F. Roli, eds. *Multiple Classifier Systems*. Heidelberg, Germany: Springer, 501–512.
- [15] Prasad, S., Bruce, L.M. (2008). Decision Fusion with Confidencebased Weight Assignment for Hyper spectral Target Recognition, *IEEE Trans. Geoscience and Remote Sensing*, vol. 46, no. 5.
- [16] Prasad, S., Bruce, L.M., Kalluri, H. (2008). A Robust Multi-Classifer Decision Fusion Framework for Hyper spectral, Multi-temporal Classification, *IEEE, IGARSS 2008*, 273-276.
- [17] Wang, J., and Chang, C.I. (2006). Independent component analysis-based dimensionality reduction with applications in hyper spectral image analysis, *IEEE Trans. Geosci. Remote Sens.*, vol. 44, no. 6, pp. 1586–1600.
- [18] Serpico, S. B., and Bruzzone, L. (2001). A new search algorithm for feature selection in hyper spectral remote sensing images, *IEEE Trans. Geosci. Remote Sens.*, vol. 39, no. 7, pp. 1360–1367.
- [19] Plaza, A., Martinez, P., Plaza, J. and Perez, R. (2005). Dimensionality reduction and classification of hyper spectral image data using sequences of extended morphological transformations,” *IEEE Trans. Geosci. Remote Sens.*, vol. 43, no. 3, pp. 466–479.
- [20] Chang, C.-I, and Wang, S. (2006). Constrained band selection for hyper spectral imagery,” *IEEE Trans. Geosci. Remote Sens.*, vol. 44, no. 6, pp. 1575– 1585.
- [21] Martínez-Usó, A., Filiberto, P., Martínez Sotoca, J., García-Sevilla, P. (2007). Clustering-Based Hyper spectral Band Selection Using Information Measures, *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, VOL. 45, NO. 12, pp. 4148-4171.
- [22] Benediktsson, J.A. and Kanellopoulos, I. (1999). Classification of multisource and hyper spectral databased on decision fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 37 (3),1367–1377.
- [23] Martinez-Uso, A., Pla, F., Sotoca, J. M., and Garcia-Sevilla, P. (2006). Clustering based multispectral band selection using mutual information,” in *Proc.ICPR, 2006*, pp. 760–763.
- [24] Guo, B., Gunn, S. R., Damper, R. I. and Nelson, J. D. B. (2006). Band selection for hyperspectral image classification using mutual information,” *IEEE Geoscience and Remote Sensing Letters*, 3(4): 522-526.
- [25] Weston, J., and Watkins, C. (1998). Multi-class support vector machines, Technical report CSD-TR-98-04.
- [26] Scholkopf, B. and Smola, A.J. (2002). *Learning with kernels, support vector machines, regularization, optimization and beyond*. Cambridge: MIT Press.
- [27] Huang, C., Davis, L. S. and Townshend, J. R. (2002). An assessment of support vector machines for land cover classification,” *Int. J. Remote Sens.*, vol. 23, no. 4, pp. 725–749.
- [28] Melgani, F. and Bruzzone, L. (2004). Classification of hyper spectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42 (8),1778–1790.
- [29] Watanachaturaporn, P., and Arora, M. K. (2004). Support vector machines for classification of multi-andhyper spectral data. In P. K. Varshney & M. K. Arora (Eds.), *Advanced image processing techniques forremotely sensed hyper spectral data*: Springer-Verlag.
- [30] Marconcini, M., Bruzzone, L. (2009). A Composite Semisupervised SVM for Classification of Hyper spectral Images”, *IEEE GEOSCIENCE AND REMOTE SENSING LETTERS*, VOL. 6, NO. 2.
- [31] Tarabalka, Y., Fauvel, M., Chanussot, J., Benediktsson, J. (2010). SVM- and MRF-Based Method for Accurate Classification of Hyper spectral Images. *IEEE GEOSCIENCE AND REMOTE SENSING LETTERS*, VOL. 7, NO. 4.
- [32] Kuncheva, L. (2004). *Combining Pattern Classifiers methods and algorithms*. A John Wiley&sons, INC.publication, Hoboken, New jersey.Canada
- [33] Kuncheva, L.I., Whitaker, C.J. (2003). Measures of diversity in classifier ensemble and their relationship with the ensemble accuracy, *Machine Learning*, 51(2): 181- 207.

- [34] Ruta, D., Gabrys, B. (2000), An overview of classifier fusion methods. Computing and Information systems, Vol. 7, pp. 1-10.
- [35] Skalak, D. (1996), The Sources of Increased Accuracy for two Proposed Boosting Algorithms, In: Proc. American Association of Artificial Intelligence, AAAI-96, Integrating Multiple Learned Model Workshop.
- [36] Giacinto, G., Roli, F. (1999), Methods for Dynamic Classifier Selection", ICIAP '99, 10th Int. Conf. on Image Analysis and Processing, Venice, Italy, Sept 27 - 29, pp. 659-664.
- [37] Goebel, K., Yan, W., Cheetham, W. (2002), A method to calculate classifier correlation for decision fusion, Proc. IDC 2002, Adelaide, 11-13 February, 2002., pp. 135-140.
- [38] Fauvel, M., Benediktsson, J. (2007), A Combined Support Vector Machine Classification Based on Decision Fusion, Signal & Images Laboratory, LIS Grenoble, Grenoble National Polytechnical Institute, France.
- [39] Waske, B. and Van der Linden, S. (2008). Classifying multilevel imagery from SAR and optical sensors by decision fusion. IEEE Transactions on Geoscience and Remote Sensing, 46 (5), 1457-1466
- [40] S. Nakariyakul, D.P. Casasent. (2007). Adaptive branch and bound algorithm for selecting optimal features, Pattern Recognit. Lett. 28 (2007) 1415-1427.
- [41] Xu, L., et al., (1992). Methods of combining multiple classifiers and their applications to handwriting recognition. IEEE Transactions on Systems Man and Cybernetics, Vol. 22, No. 3, 418-435.
- [42] Imbault, F., and Lebart, K. (2004). A stochastic optimization approach for parameter tuning of support vector machines. In Proceedings of the 17th international conference on pattern recognition (ICPR'04), pp. 1051-4651.
- [43] Hsu, C.-W., Chung, C.-C., Lin, C.-J., (2010). A Practical Guide to Support Vector Classification, National Taiwan University, March 13, 2010 [Online]. Available: www.csie.ntu.edu.tw/~cjlin.
- [44] Pudil, P., Novovicova, J., and Kittler, J, 1994. Floating search methods in feature selection, Pattern Recognition Letter, 15(11): 1119-1125.
- [45] Watanachaturaporn, P., Arora, M. K., and Varshney, P. K. (2005). Hyperspectral image classification using support vector machines: A comparison with decision tree and neural network.

[۴۶] مقصودی یاسر، استفاده از ترکیب طبقه بندی کننده ها به منظور طبقه بندی تصاویر ابرطیفی " ، پایان نامه کارشناسی ارشد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده نقشه برداری، ۱۳۸۵

[۴۷] رحیم زادگان مجید، ارائه متدی جهت استفاده از استخراج ویژگی و ترکیب طبقه بندی کننده ها برای طبقه بندی داده های ابر طیفی " ، پایان نامه کارشناسی ارشد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده نقشه برداری، ۱۳۸۷