

ماشین‌های تصادفی بردار پشتیبان، طبقه‌بندی دسته‌جمعی بهینه داده‌های با ابعاد بالا

محسن جعفری^{۱*}، مهدی آخوندزاده^۲

۱- دانشجوی دکتری تخصصی، گروه سنجش‌ازدور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران
۲- استادیار، گروه سنجش‌ازدور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

تاریخ دریافت مقاله: ۱۳۹۴/۱۱/۰۹ تاریخ پذیرش مقاله: ۱۳۹۵/۱۰/۱۲

چکیده

افزایش ابعاد فضای ویژگی ورودی موجب تمایز بیش‌تر کلاس‌های پوششی در طبقه‌بندی تصاویر سنجش‌ازدور می‌شود اما تعداد کم نمونه‌های آموزشی مانع از بروز این عملکرد مثبت می‌شود. استفاده از روش‌های گروهی به‌جای طبقه‌بندی کننده‌های منفرد راه‌حل مناسبی برای برخورد با این مشکل است. در این مقاله روشی با عنوان "ماشین‌های تصادفی بردار پشتیبان (SVRMs)" برای جمعی کردن روش SVM پیشنهاد می‌شود. روش پیشنهادی نسبت به روش‌های قبلی در جمعی کردن SVM مزایای مؤثری دارد. اعمال هم‌زمان روش بگینگ در داده‌های آموزشی و فضای ویژگی و روش بوستینگ موجب بهبود صحت، استقلال و تنوع طبقه‌بندی کننده‌های پایه می‌شود. ادغام طبقه‌بندی کننده‌ها در روش پیشنهادی در سطح احتمال و به‌صورت غیرخطی با استفاده از یک تلفیق SVM انجام می‌شود. عملکرد روش پیشنهادی بر روی داده‌های فراطیفی و پلازمتریک رادار با روزه مصنوعی ارزیابی شده است. آزمایش‌ها از سه دیدگاه: ارزیابی در برابر سایر روش‌های دسته‌جمعی SVM، ارزیابی در برابر روش‌های انتخاب ویژگی و در نهایت سایر روش‌های طبقه‌بندی طراحی و تحلیل شده است. در داده فراطیفی روش پیشنهادی حدود ۱۶ درصد و در داده پلازمتریک حدود ۱۰ درصد نسبت به روش منفرد SVM بهبود نشان می‌دهد. روش پیشنهادی در هر دو منبع داده عملکرد بهتری در بیشتر کلاس‌های مورد بررسی خصوصاً کلاس‌های نزدیک نسبت سایر روش‌های جمعی نشان می‌دهد. نتایج نشان می‌دهد روش پیشنهادی ضمن حفظ هزینه محاسباتی مطلوب عملکرد بهتری نسبت به روش‌های انتخاب ویژگی همچون ژنتیک دارد. مطابق نتایج صحت و دقت مطلوب روش پیشنهادی نیز در برابر روش‌های پایه طبقه‌بندی در دو منبع داده (بیشترین شباهت و ویشارت) و همچنین روش‌های قدرتمند (جنگل تصادفی و شبکه عصبی) تصدیق می‌شود.

کلیدواژه‌ها: ماشین بردار پشتیبان، روش‌های دسته‌جمعی، فضای ویژگی، خود راه‌انداز تصادفی، تلفیق

*نویسنده مکاتبه کننده: تهران، کارگر شمالی، پردیس فنی دانشگاه تهران، دانشکده مهندسی نقشه‌برداری و فناوری اطلاعات مکانی.

تلفن: ۰۹۳۶۶۱۵۳۴۳۷

۱- مقدمه

به خاطر افزایش تمایز بین کلاس‌ها است اما از این نقطه به بعد به علت دقت پایین برآورد پارامترهای آماری، دقت طبقه‌بندی کاهش می‌یابد. به عبارت دیگر از این نقطه به بعد آن اثر مثبت توسط اثر منفی از بین می‌رود (شکل (۱-ج)) به این پدیده هاف گویند. دقت پایین برآورد پارامترهای آماری با افزایش باندها به دلیل کمبود داده‌های آموزشی است؛ بنابراین اگر داده‌های آموزشی کافی وجود داشته باشد افول دقت در طبقه‌بندی هم رخ نخواهد داد. افزایش داده‌های آموزشی باعث افزایش دقت طبقه‌بندی می‌شود به طوری که اگر تعداد نمونه‌های آموزشی به سمت بی‌نهایت رود دیگر هیچ افولی را در دقت طبقه‌بندی شاهد نخواهیم بود [۱۱].

• بزرگ بودن فضای فرضیات

معمولاً در فرآیند طبقه‌بندی با سه فضا روبرو هستیم. فضای ویژگی‌های ورودی، فضای کلاس‌های خروجی و فضای فرضیات. فضای فرضیات و یا به عبارتی فضای مدل‌ها، فضایی است که تمام فرضیات و یا طبقه‌بندی‌کننده‌های مختلف در داخل آن قرار می‌گیرند (مانند k همسایه نزدیک، شبکه عصبی، ماشین بردار پشتیبان و ...) این فضا در واقع یک فضای ارتباطی بین فضای ویژگی‌های ورودی و فضای کلاس‌های خروجی محسوب می‌شود (مدلی که می‌تواند به بهترین نحو ارتباط بین دو فضا را برقرار نماید). ثابت می‌شود که با افزایش ابعاد فضای ویژگی‌های ورودی، ابعاد فضای فرضیات به صورت نمایی رشد می‌کند [۱۲]. این مسئله فرآیند طبقه‌بندی را تا حد زیادی غیرقابل اطمینان و نامطمئن می‌سازد.

با پیشرفت فناوری در سنجنده‌های سنجش از دور و همچنین تکنیک‌های مختلف استخراج اطلاعات و ویژگی از داده‌های آن‌ها فضای ویژگی رو به افزایش است. از جمله این داده‌ها می‌توان به تصاویر سنجنده‌های فراطیفی که در برخی از آن‌ها تعداد باندها به بیش از ۲۰۰ باند طیفی می‌رسد اشاره کرد [۱، ۲ و ۳]. باندهای این تصاویر با پهنای کم اطلاعات دقیقی را از خصوصیات عوارض ارائه می‌دهد [۱]. داده‌های سنجنده‌های پلاریمتریک رادار با روزنه مصنوعی^۱ در سال‌های اخیر به واسطه استقلال از شرایط آب و هوایی و زمانی یکی از مهم‌ترین منابع اخذ اطلاعات می‌باشند [۴، ۵، ۶ و ۷]. به سبب فعال بودن در چهار کانال پلاریمتری و وجود روش‌هایی مختلفی که برای استخراج ویژگی‌های مفید و متنوع از این داده فضای ویژگی جهت کاربردهای مختلف می‌تواند به بیش از ۱۰۰ بعد برسد [۸ و ۹].


معمولاً در طبقه‌بندی تصاویر با فضای ویژگی با ابعاد بالا با دو مشکل روبرو هستیم:

• پدیده هیوز^۲ [۱۰] و نیاز به داده‌های آموزشی زیاد

افزایش فضای ویژگی دو اثر را به دنبال دارد. اولین اثر این است که با افزایش تعداد باندها تمایز بین کلاس‌ها در فضای ویژگی افزایش می‌یابد که این اثر مثبت در طبقه‌بندی به حساب می‌آید (شکل (۱-الف))؛ اما اثر دوم اینکه با افزایش تعداد باندها دقت برآورد پارامترهای آماری مربوط به کلاس‌ها کاهش می‌یابد که این یک اثر منفی در طبقه‌بندی است (شکل (۱-ب)). نتیجه این دو اثر بر روی عملکرد طبقه‌بندی به این ترتیب است که در ابتدا با افزایش تعداد باندها دقت طبقه‌بندی تا یک نقطه‌ای افزایش یافته که این

¹ Polarimetric Synthetic Aperture Radar

² Hough



شکل ۱: توصیف پدیده هاف. الف): تفکیک پذیری کلاس‌ها با افزایش تعداد باندها روند مثبت دارد؛ ب): دقت برآورد پارامترهای آماری با افزایش تعداد باندها کاهش می‌یابد؛ ج): ترکیب اثر افزایش باندها بر روی میزان تفکیک پذیری و دقت برآورد پارامترهای آماری موجب روند صعودی و سپس نزولی در دقت طبقه‌بندی می‌شود.

طرح ترکیب طبقه‌بندی کننده‌ها اولین بار توسط هانسن^۴ و سالامون^۵ [۲۰] در سال ۱۹۹۰ ارائه گردید. آن‌ها ثابت کردند در صورتی که هر یک از طبقه‌بندی کننده‌های اولیه مستقل باشند و نرخ خطای آن‌ها کمتر از ۵۰٪ باشد در این صورت ترکیب طبقه‌بندی کننده‌ها دارای دقت بالاتری نسبت به هر یک از طبقه‌بندی کننده‌ها به صورت منفرد خواهد بود. اسکالاک^۶ [۲۱] نیز طرح ترکیب طبقه‌بندی کننده‌های نزدیک‌ترین همسایه را با نمونه‌های آموزشی محدود در سال ۱۹۹۵ مطرح نمود. در سال ۱۹۹۸ برای^۷ [۲۲] ترکیب این طبقه‌بندی کننده را بر روی دسته‌های مختلف ویژگی به کار گرفت. در سال ۲۰۰۰ دیتریچ^۸ [۲۳] روش‌های مختلف ترکیب طبقه‌بندی کننده‌ها را مطرح و عملکرد آن‌ها را باهم مقایسه نمود. دامنه تحقیق بر روی این موضوع بسیار گسترده بوده و محققین مختلف نظریه‌های مختلفی را

یکی از روش‌های مقابله با مشکلات فوق استفاده از روش‌های استخراج/انتخاب ویژگی است [۱۳، ۱۴، ۱۵ و ۱۶]. اگرچه استفاده از این روش‌ها پیچیدگی محاسباتی را کاهش می‌دهد اما گاهی اوقات از تمام پتانسیل داده‌ها استفاده نمی‌شود و دقت طبقه‌بندی کاهش می‌یابد. راه‌حل دوم استفاده از روش‌های دسته‌جمعی^۱ در طبقه‌بندی است [۱۷، ۱۸ و ۱۹].

این روش‌ها به صورت ترکیبی از طبقه‌بندی کننده‌ها (همسان و یا غیرهمسان) عمل می‌کنند. به طور کلی سه روش برای ایجاد طبقه‌بندی کننده‌های همسان و متنوع وجود دارد [۲۰]: دست‌کاری^۲ در داده‌های آموزشی، دست‌کاری در فضای ویژگی و دست‌کاری در خروجی. روش‌های دسته‌جمعی از یک طبقه‌بندی کننده پایه تشکیل شده‌اند که وقتی تکثیر می‌شوند باید مستقل از یکدیگر و تا حد امکان متنوع و سریع باشند.

مطالعه بر روی ترکیب طبقه‌بندی کننده‌ها از اوایل دهه ۹۰ آغاز شد و محققین مختلف با نام‌های مختلفی از آن استفاده کردند^۳.

- Hybrid Method - Multiple Experts -Combining Classifiers
 - Classifier Ensembles
 -Classifier Fusion -Mixture of Experts -Decision Combination -Decision Fusion

⁴ Hansen
⁵ Salamon
⁶ Skalak
⁷ Bay
⁸ Dietterich

¹ Ensemble Method
² Modification

^۳ این نام‌ها عبارت‌اند از:

طبقه‌بندی SVM با هر دسته داده آموزشی انجام و سپس نتایج حاصل از آن‌ها در فرآیندی تجمیع می‌شود.

روش‌های دیگری در جمعی سازی SVM در تحقیقات اخیر بسیار مورد توجه بوده است ایجاد طبقه‌بندی کننده‌های پایه از طریق دسته کردن ویژگی‌های ورودی است [۲۵ و ۲۶]. در این دسته از روش‌ها تمایز بین طبقه‌بندی کننده‌ها از طریق تنوع و چند دسته کردن فضای ویژگی است. مطابق آنچه در روش بگینگ وجود دارد با انتخاب همراه با جایگزینی ویژگی‌های ورودی در دسته‌های مختلف قرار می‌گیرند. در نهایت تجمیع طبقه‌بندی کننده‌ها تصمیم نهایی را نشان می‌دهد.

در منابع اثبات شده است که روش بگینگ موجب کاهش واریانس و روش بوستینگ موجب کاهش بایاس و تا حدودی واریانس در خطای طبقه‌بندی می‌شود [۲۵]. روش پیشنهادی در این مقاله به صورت ترکیبی از این دو روش با تأکید بر تصادفی‌تر شدن هر طبقه‌بندی کننده و ایجاد تنوع بیشتر در آن‌ها است. روش پیشنهادی روش بگینگ را در دو فضای داده‌های آموزشی و ویژگی‌های ورودی اعمال می‌شود و همچنین آموزش هر طبقه‌بندی کننده با روش بوستینگ همراه می‌شود. از دیگر مزایای روش پیشنهادی که در طرح‌های جمعی قبلی کمتر دیده شده است ادغام طبقه‌بندی کننده‌ها در سطح احتمال و با استفاده از یک طرح تلفیق SVM است که موجب ترکیب غیرخطی و دقیق‌تر طبقه‌بندی کننده‌ها می‌شود.

در ادامه این مقاله و در بخش دوم درباره مفاهیم روش‌های دسته‌جمعی در طبقه‌بندی و سه روش بگینگ، بوستینگ و جنگل تصادفی توضیحات مختصری ارائه می‌شود. بخش سوم طرح روش پیشنهادی معرفی می‌شود. بخش چهارم اختصاص به نتایج پیاده‌سازی روش پیشنهادی بر روی داده‌های فراطیفی و پلاریمتریک اختصاص دارد.

در مورد بحث ترکیب ارائه نموده‌اند [۲۴، ۲۵، ۲۶، ۲۷ و ۲۸]

روش ارائه شده در این مقاله تأکید بر استفاده از طبقه‌بندی کننده SVM به عنوان طبقه‌بندی کننده پایه دارد. طبقه‌بندی کننده SVM با تأکید بر جداکننده با بیشترین حاشیه^۱ توسط وپنیک^۲ ارائه شد [۲۹]. استفاده از این ماشین در طبقه‌بندی و رگرسیون در تحقیقات سال‌های اخیر رو به افزایش بوده است. عملکرد مطلوب در تعداد داده‌های آموزشی کم از جمله مزایای SVM و حساسیت آن به بالانس نبودن داده‌های آموزشی از جمله معایب SVM است [۳۰]. ترکیب طبقه‌بندی کننده‌های SVM در یک مسئله از جمله روش‌هایی بوده است که برای بهبود عملکرد این طبقه‌بندی کننده و رفع مشکلات آن ارائه شده است.

ایده SVM به صورت جمعی در [۳۱] مطرح گردید. آن‌ها از تکنیک بوستینگ^۳ برای آموزش یک تک طبقه‌بندی کننده SVM استفاده کردند. در روش ارائه شده در این تحقیق نمونه‌های آموزشی به اشتباه طبقه‌بندی شده در تکرار بعد با وزن بیشتری در طبقه‌بندی شرکت می‌کند که در این صورت با هر بار تکرار ابرصفحه جداکننده به سمتی که کمترین خطا را دچار شود میل پیدا می‌کند.

در سال ۲۰۰۲ کیم^۴ و همکاران [۳۲] SVM را با تکنیک بگینگ^۵ و ایجاد طبقه‌بندی کننده‌های متنوع از روی دست کاری داده‌های آموزشی به صورت جمعی ارائه کردند. در روش این تحقیق داده‌های آموزشی در دسته‌های تقسیم می‌شوند که انتخاب داده‌های آموزشی بر مبنای انتخاب جایگزینی انجام می‌شود.

¹ Marigin

² Vapnik

³ Boosting

⁴ Kim

⁵ Bagging

در نهایت در بخش پنجم نتیجه‌گیری از این تحقیق ارائه خواهد شد.

۲- روش‌های دسته‌جمعی در طبقه‌بندی

روش‌های دسته‌جمعی، چند یادگیرنده یا طبقه‌بندی کننده را آموزش می‌دهند تا یک مسئله را حل کنند. برخلاف رویکردهای یادگیری معمولی که تلاش بر ساخت یک یادگیرنده از داده‌های آموزشی دارند، روش‌های دسته‌جمعی مجموعه‌ای از یادگیرنده‌ها را باهم آموزش داده و ادغام می‌کنند. این روش‌ها از چند یادگیرنده پایه (در این تحقیق SVM) تشکیل شده‌اند که از داده‌های آموزشی ساخته می‌شود. این یادگیرنده‌ها باید تا حد امکان صحیح و گوناگون باشند [۳۳]. روش‌های مجموعه‌ای بیشتر به دلیل توانایی که در تقویت یادگیرنده‌های ضعیف دارند، جذاب هستند. از این رو به یادگیرنده‌های پایه، یادگیرنده‌های ضعیف هم گفته می‌شود. یک تحقیق تجربی نشان داده که پیش‌بینی‌های ساخته‌شده با ادغام یک مجموعه از طبقه‌بندی کننده‌ها، اغلب صحیح‌تر از پیش‌بینی‌هایی هستند که به‌وسیله بهترین تک طبقه‌بندی کننده به دست می‌آید [۲۰]. اغلب هزینه محاسباتی ساخت یک مجموعه قوی از ساخت یک یادگیرنده قوی کمتر است [۳۳]. سه نمونه از متداول‌ترین و پایه‌ای‌ترین روش‌های دسته‌جمعی بوستینگ، بگینگ و جنگل تصادفی است. بوستینگ روشی برای بهبود عملکرد یک طبقه‌بندی کننده ضعیف است. اساس روش بوستینگ این است که وزن‌هایی به المان‌های مجموعه داده آموزشی اختصاص داده می‌شود. وزن‌ها در مجموعه آغازی برابر است. خروجی طبقه‌بندی با برچسب معلوم هر المان داده آموزشی مقایسه می‌شود تا نمونه‌های آموزشی که به نادرستی طبقه‌بندی شده‌اند، تعیین شود. نمونه‌های آموزشی که خطا طبقه‌بندی شده‌اند یک وزن بزرگ‌تر را گرفته و طبقه‌بندی کننده دوباره اجرا می‌شود. این وزن بیشتر

برای نمونه‌های خطا جریمه‌ای برای طبقه‌بندی محسوب می‌شود و طبقه‌بندی کننده را مجبور می‌کند روی موارد خطا تمرکز کند [۳۴].

در مقابل روش‌های بوستینگ که عملکردی متوالی در ترکیب یادگیرنده‌ها دارند، روش‌های بگینگ مجموعه‌ای موازی از یادگیرنده‌ها هستند [۳۳]. انگیزه اساسی روش‌های گروهی موازی بهره‌گیری از استقلال بین یادگیرنده‌های پایه است زیرا خطا به‌طور چشم‌گیری به‌وسیله ترکیب یادگیرنده‌های مستقل کاهش می‌یابد. این روش‌ها به‌طور ذاتی برای محاسبات موازی مناسب می‌باشند و سرعت آموزش را می‌توان به‌آسانی با استفاده از پردازنده‌های چند هسته‌ای بالا برد [۳۳]. اصطلاح بگینگ از ترکیب دو کلمه تجمیع^۱ و خودراه‌انداز^۲ به معنای جمع‌آوری خود راه‌انداز آمده است. مجموعه نمونه‌های آموزشی تشکیل‌دهنده یادگیرنده‌های پایه خودراه‌انداز و روش ادغام نتایج حاصل از یادگیرنده‌های پایه را جمع‌آوری گویند. در بگینگ از روش انتخاب با جایگزینی از نمونه‌های آموزشی خود راه‌اندازها تشکیل و با رأی‌گیری حداکثر نتایج ادغام می‌شوند [۳۳].

جنگل تصادفی یک مدل بهبودیافته از روش بگینگ است و علت نام‌گذاری آن به این دلیل است که از درخت‌های تصمیم ساخته می‌شود [۱۹]. تفاوت اصلی این روش با بگینگ در انتخاب تصادفی ویژگی‌های ورودی می‌باشد یعنی علاوه بر دست‌کاری در نمونه‌های آموزشی، فضای ویژگی هم برای تشکیل یادگیرنده‌های متنوع و مستقل دست‌کاری می‌شود.

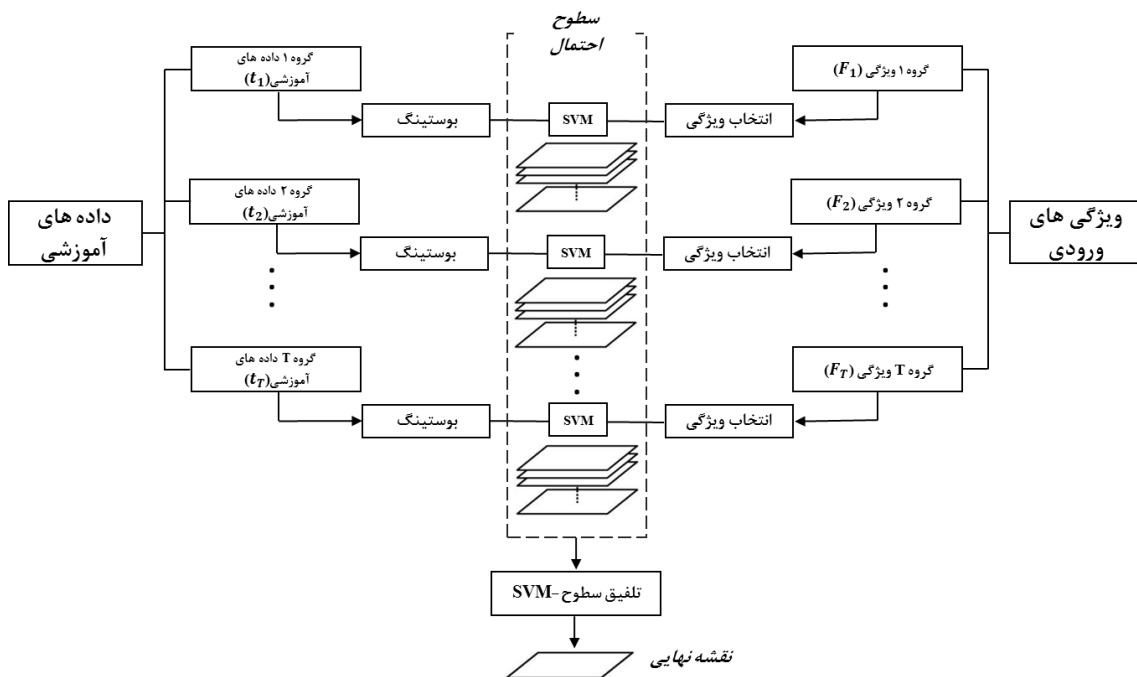
¹ Aggregating

² Bootstarp

۳- روش پیشنهادی

همان طور که پیش تر نیز اشاره شد هدف اصلی روش پیشنهادی این مقاله افزایش کارایی طبقه بندی کننده SVM از طریق دسته جمعی کردن آن است. روش گروهی سازی ارائه شده در این تحقیق از سه روش ذکر شده در بخش ۲ الهام گرفته است و مزایای هر کدام از روش ها را

در یک طرح دارد. روش پیشنهادی از سه مرحله تشکیل شده است (شکل ۲ شکل ۲). تشکیل طبقه بندی کننده های پایه با مجموعه نمونه های آموزشی و فضای ویژگی تصادفی، آموزش طبقه بندی کننده ها به صورت متوالی و در نهایت ادغام نتایج طبقه بندی کننده ها به صورت غیرخطی و در سطح احتمال و به روش SVM.



شکل ۲: روش پیشنهادی، ماشین های تصادفی بردار پشتیبان (طبقه بندی چندگانه بهینه داده های با ابعاد بالای فضای ویژگی)

در تشکیل خود راه اندازها در روش پیشنهادی علاوه بر انتخاب یک مجموعه تصادفی همراه با جایگزینی از نمونه های آموزشی برای استقلال بیشتر یادگیرنده ها فضای ویژگی ورودی هم با یک فرآیند مشابه انتخاب می شود به عبارت دیگر در یک یادگیرنده الگوریتمی مطابق شکل (۳) خواهیم داشت.

Algorithm. Bootstrap

INPUT: $F, U, K = \text{size of bootstrap samples}, R = \text{size of bootstrap features},$
 $T = \text{number of bootstraps}$
 OUTPUTS: U_t, F_t
for $t = 1$ to T **do**
 Draw a bootstrap sample U_t of size K in U .
 Draw a bootstrap feature F_t of size R in F .
end for

شکل ۳: الگوریتم خود راه انداز پیشنهادی

مشکل اصلی معیار IG این است که بدون در نظر گرفتن ارتباط ویژگی با طبقه‌بندی، ویژگی‌ای را انتخاب می‌کند که دارای مقادیر بیشتری است. برای مثال ممکن است یک ویژگی مثل "id" وجود داشته باشد که برای هر نمونه مقدار منحصربه‌فردی را دارد، در این صورت IG این ویژگی را به‌عنوان بهترین ویژگی برای تقسیم داده انتخاب می‌کند؛ درحالی‌که این ویژگی نمی‌تواند تعمیم داده شود و برای پیش‌بینی مناسب نیست [۳۳]. برای رفع این نقص می‌توان از نسبت محتوا^۲ که از رابطه (۳) به‌دست می‌آید استفاده کرد.

رابطه (۳)

$$P(D; D_1; \dots; D_k) = G(D; D_1; \dots; D_k) \cdot \left(\sum_{i=1}^k \frac{|D_k|}{|D|} \log \frac{|D_k|}{|D|} \right)^{-1}$$

گام مهم دیگر در روش پیشنهادی استفاده از روش تقویت در آموزش طبقه‌بندی کننده SVM است. برای مجموعه داده‌های آموزشی (x) تابع پیش‌بینی طبقه‌بندی کننده پایه SVM با در نظر گرفتن تابع کرنل K عبارت است از (رابطه (۴)) [۳۶]:

$$\text{sign}(f(x)) = \sum_{i=1}^n y_i \alpha_i K(x, x_i) + b \quad (4)$$

در این رابطه b بایاس است و ضرایب بهینه با بیشینه کردن معادله لاگرانژ مطابق رابطه (۵) حاصل می‌شود [۳۶]:

با معلوم بودن m نمونه‌ی آموزشی، احتمال اینکه نمونه‌ی آموزشی ۰، ۱، ۲ و ... دفعه انتخاب شده باشد، دارای توزیع پواسون با $(\lambda = 1)$ است لذا احتمال این که نمونه نام اتفاق بیفتد حداقل برابر $1 - 1/e \approx 0.632$ است [۳۵]. به عبارت دیگر برای هر یادگیرنده پایه در حدود ۳۶/۸ درصد از نمونه‌های آموزشی اولیه در پروسه یادگیری مورد استفاده قرار نمی‌گیرد. میزان شایستگی هر یادگیرنده پایه در روش پیشنهادی با استفاده از نمونه‌های استفاده‌نشده در آموزش آن برآورد می‌شود.

روش پیشنهادی به دلیل استفاده از زیرمجموعه تصادفی از فضای ویژگی در انتخاب خود راه‌اندازها نسبت به روش مرسوم بگینگ انعطاف بالاتری دارد که باعث قابلیت تعمیم بهتری می‌گردد. روش پیشنهادی اگرچه معمولاً نسبت به بگینگ نقطه شروع بدتری دارد اما آزمایش‌ها نشان داد در ادامه به سمت خطاهای پایین‌تر همگرا می‌شود. به‌منظور آموزش مؤثرتر پس از انتخاب یک زیرمجموعه تصادفی از ویژگی‌ها، ویژگی‌های بهینه با استفاده از پارامتر محتوای اطلاعاتی^۱ (IG) وارد طبقه‌بندی کننده SVM می‌شوند.

با معلوم بودن مجموعه آموزشی D ، آنتروپی D با رابطه (۱) محاسبه می‌گردد:

رابطه (۱)

$$\text{Ent}(D) = - \sum_{y \in Y} P(y|D) \log P(y|D)$$

اگر مجموعه آموزشی D به زیرمجموعه‌های D_1, \dots, D_k تقسیم گردد، ممکن است آنتروپی کاهش یابد و مقدار کاهش، همان (IG) است، یعنی:

رابطه (۲)

$$G(D; D_1, \dots, D_k) = \text{Ent}(D) - \sum_{i=1}^k \frac{|D_k|}{|D|} \text{Ent}(D_k)$$

بنابراین جفت مقدار ویژگی که باعث IG بزرگ‌تری بشود به‌عنوان معیار مناسب انتخاب می‌شود.

² Gain ratio

¹ Information Gain

$$L_P = \frac{\|\bar{\omega}\|^2}{2} + C + \sum_{\{i|y_i=+1\}} \xi_i^2 + C - \sum_{\{i|y_i=-1\}} \xi_i^2 - \sum_{i=1}^n \alpha_i [y_i(\omega \cdot x_i + b) - 1 + \xi_i] - \sum_{i=1}^n \mu_i \xi_i \quad (5)$$

طرح ادغام در روش پیشنهادی در سطح احتمال حاصل از طبقه‌بندی کننده‌های پایه و با روش SVM است. در صورتی که T خود راه‌انداز از مرحله اول (بگینگ) و Q طبقه‌بندی کننده در مرحله دوم از هریک از خود راه‌اندازها تشکیل شود آنگاه $T * Q$ طبقه‌بندی کننده پایه سطوح احتمال را تولید می‌کنند که در SVM- fusion به‌عنوان فضای ویژگی ورودی محسوب می‌شوند.

در تمام طبقه‌بندی‌های پایه (SVM) در این مقاله از کرنل گوسین^۱ RBF در SVM به دلیل توانایی‌اش در کنترل داده‌ها با ابعاد بالا استفاده شده است.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (9)$$

که در این کرنل σ واریانس در امتداد محورهای ویژگی‌ها را نشان می‌دهد. دو پارامتر SVM (C و σ) در این مقاله به کمک روش جستجوی شبکه‌ای در هر گره که یک SVM انجام می‌شود برآورد می‌گردد. این دو پارامتر در طبقه‌بندی SVM منفرد ۷۰۰ برای C و ۰/۰۱ برای σ با روش جستجوی شبکه‌ای محاسبه شده است. این دو پارامتر در تمام طبقه‌بندی کننده‌های پایه دوباره محاسبه می‌شود.

۴- مجموعه داده‌ی مورد استفاده

به‌منظور ارزیابی روش پیشنهادی دو مجموعه داده با ابعاد فضای ویژگی بالا انتخاب شد. داده هوابرد فراطیفی با ۱۸۵ باند طیفی و داده فضاپرد پلاریمتریک راداری که با استخراج ویژگی‌های مختلف به فضایی با ابعاد ۹۴ می‌رسد. به‌این ترتیب ابعاد بالای فضای ویژگی به همراه پیچیدگی‌های داده‌ها و نمونه‌های آموزشی کنترل شده می‌تواند چالش‌های مختلف روش پیشنهادی را بررسی کند.

در رابطه (۵) نامساوی‌ها مطابق رابطه (۶ و ۷) برقرار است [۳۶]:

$$C_+ \geq \alpha_i \geq 0, C_- \geq \alpha_i \geq 0, \frac{C_+}{C_-} = \frac{n_+}{n_-} \text{ and } \mu_i \geq 0$$


$$\xi_i^* = \xi_i / \|\beta\| \quad (7)$$

ξ_i میزان خطای هر نمونه آموزشی در اطراف حاشیه را نشان می‌دهد. مقدار این پارامتر به کمک رابطه (۸) قابل برآورد است [۳۶].

رابطه (۸)

$$\xi_i = \max(0, 1 - y_i(\sum_{i=1}^n y_i \alpha_i K(x, x_i) + b))$$


گام بعدی در آموزش SVM تغییر وزن ω_i در داده‌های آموزشی است به‌طوری‌که در طبقه‌بندی برچسب نمونه‌های x_i اصلاح صورت گیرد. روند اصلاح حاشیه در روش پیشنهادی در شکل (۴) نشان داده شده است. مزیت این روش این است که در هر بار تکرار مجموعه اصلاح شده از داده‌های آموزشی تولید می‌شود. خروجی هر بار تکرار طبقه‌بندی کننده‌های درنهایت می‌تواند در یک فرآیند ادغام برچسب نهایی نمونه‌ها را تعیین کند [۳۶].



شکل ۴: روند اصلاح حاشیه در آموزش SVM در روش پیشنهادی. نمونه‌های اشتباه در هر بار آموزش وزن بالاتری می‌گیرند تا به تدریج تابع جداکننده بهبود پیدا کند [۳۶]

¹ Gaussian

نشان می‌دهد. تاکنون آزمایش‌های زیادی بر روی این تصویر انجام شده است که در نتیجه اطلاعات مفیدی در رابطه با ویژگی‌های طیفی مشخصه‌های خالص آن در اختیار می‌باشند. با توجه به آزمایش‌های انجام شده در [۴۰] مشخصه‌های طیفی ۶ کلاس ۲، ۳، ۴، ۷، ۱۰ و ۱۲ از لحاظ سنجه‌های اندازه‌گیری تشابه طیفی به یکدیگر بسیار شبیه می‌باشند. در نتیجه تشخیص تمایز میان کلاس‌ها به شدت سخت است. بنابراین در بررسی نتایج طبقه‌بندی توجه به دقت این کلاس‌ها بسیار مناسب خواهد بود.



(الف)



(ب)

شکل ۵: منطقه‌ی مورد مطالعه اول الف): نقشه‌ی حقیقی زمینی از ۱۶ کلاس موجود؛ ب): تصویر باند ۱۲ از داده مورد استفاده

۴-۱- مجموعه داده فراطیفی

منطقه‌ی جنگلی/ کشاورزی در شمال غرب ایالت ایندیانا^۱ در کشور آمریکا به‌عنوان داده اول جهت انجام آزمایش‌ها انتخاب شده است [۳۷ و ۳۸]. بدون در نظر گرفتن پس‌زمینه ۱۶ کلاس در منطقه موجود است که نقشه‌ی پوششی آن در شکل (۵-الف) نشان داده شده است. این نقشه‌ی کاربری در سال ۱۹۹۲ و با کار زمینی تهیه شده است. حدود ۳۳ درصد منطقه پوشش جنگلی و ۶۶ درصد آن پوشش کشاورزی است. در آزمایش‌ها ۲۰ درصد این نقشه‌ی پوششی به‌عنوان داده آموزشی و مابقی به‌عنوان داده آزمایشی استفاده شده است. نام کلاس‌ها و شماره‌ی اختصاص داده شده به آن‌ها و تعداد داده‌های آموزشی در هر کلاس در جدول (۱) آمده است. معتبر بودن داده‌های حقیقی و داده ابرطیفی موجود از منطقه از دلایل مهم استفاده از این منطقه برای انجام آزمایش‌ها است.

تصویر ابرطیفی از این منطقه توسط سنجنده اویریس^۲ در ماه ژوئن سال ۱۹۹۲، به‌صورت هوابرد در ارتفاع ۲۰ کیلومتری تصویربرداری شده است. تصویر اخذ شده دارای ابعاد ۱۴۵×۱۴۵ پیکسل بوده و دارای قدرت تفکیک مکانی ۲۰ متر و قدرت تفکیک رادیومتریکی ۱۰ بیت است. این داده در ۲۲۰ باند طیفی با قدرت تفکیک طیفی ۱۰ نانومتر و در محدوده طیفی ۰/۴-۲/۵ نانومتر تهیه شده است. باندهای ۱۰۸-۱۰۴، ۱۶۳-۱۵۰ و ۲۲۰ جزو باندهای جذبی هستند همچنین باندهای ۱-۳، ۱۰۳، ۱۱۲-۱۰۹، ۱۴۸-۱۴۹، ۱۶۴-۱۶۵ و ۲۱۸-۲۱۹ در [۳۹] نویزی معرفی شده‌اند. یعنی داده مورد استفاده در مجموع شامل ۲۰ باند جذبی آب و ۱۵ باند نویزی می‌باشد که از تصویر اصلی حذف شده‌اند و طبقه‌بندی با ۱۸۵ باند باقی مانده صورت گرفته است. شکل (۵-ب) نمایشی از تصویر مورد نظر را

¹ Indiana

² AVIRIS

جدول ۱: تعداد داده‌های آموزشی کلاس‌های مورد بررسی در داده فراطیفی

شماره کلاس	نام کلاس	# آموزشی	شماره کلاس	نام کلاس	# آموزشی
۱	یونجه	۵۴	۹	جو دوسر	۲۰
۲	ذرت ۱	۱۴۲۳	۱۰	سویا ۱	۹۶۸
۳	ذرت ۲	۸۳۴	۱۱	سویا ۲	۲۴۶۸
۴	ذرت ۳	۲۳۴	۱۲	سویا ۳	۶۱۴
۵	چمن/مرتع	۴۹۷	۱۳	گندم	۲۱۲
۶	چمن/درخت	۷۴۷	۱۴	جنگل	۱۲۴۹
۷	چمن/مرتع-درو	۲۶	۱۵	ساختمان سبز	۳۸۰
۸	یونجه خشک	۴۸۹	۱۶	برج سنگی و فولادی	۹۵

در مورد روش‌های تجزیه ناهمدوس ابتدا کاهش نویز اسپکل انجام شد و سپس ویژگی‌ها استخراج شدند ولی در مورد ویژگی‌های تجزیه همدوس جهت حفظ اطلاعات فاز کاهش نویز بعد از استخراج ویژگی‌ها انجام شد. در مجموع فضای ویژگی ایجاد شده با ابعاد ۹۴ انجام شد. چالش مناسبی برای ارزیابی روش پیشنهادی به وجود می‌آورد. تصویر ترکیب رنگی پائولی داده مورد استفاده در شکل (۶-الف) و تصویر متناظر گوگل ارث^۷ آن در شکل (۶-ب) نشان داده شده است.

جدول ۲: داده‌های آموزشی و آزمایشی مجموعه داده اول

نماد کلاس	ماهیت	# آموزشی	# آزمایشی
Ro	جاده	۱۱۷	۱۵۲
Bu	ساختمان	۳۶۹	۵۲۸
Tr	درخت	۳۷۰	۴۴۲
Wa	آب	۳۴۰	۵۰۳
GV	پوشش گیاهی	۳۰۶	۵۳۷
مجموع		۱۵۰۲	۲۱۶۲

۴-۲- مجموعه داده پلاریمتریک

تصویر پلاریمتریک از منطقه‌ی شهری سانفرانسیسکو^۱ مجموعه داده دوم برای ارزیابی نتایج روش پیشنهادی در فضایی متمایز از تصاویر فراطیفی است. این تصویر مربوط به تاریخ ۲۰۰۸/۴/۹، از سنجنده رادارس-۲^۲ در باند C با طول موج ۵/۵۵ سانتی‌متر، در مد FQ9^۳ با فرمت SLC^۴ است. قدرت تفکیک مکانی این سنجنده در جهت برد^۵، ۱۱/۱ متر در برد نزدیک و تا ۱۰/۵ متر در برد دور است. کلاس‌های موردنظر و تعداد داده‌های آموزشی و آزمایشی متناسب با هر کدام در جدول (۲) آمده است.

مراحل پیش‌پردازش داده تمام پلاریمتریک سنجنده رادارس-۲ شامل کاهش نویز اسپکل، زمین مرجع کردن تصویر و در نهایت استخراج پارامترها (ویژگی‌های) پلاریمتریک است. در این تحقیق از فیلتر باکس کار^۶، با ابعاد 5 × 5 برای کاهش نویز اسپکل استفاده شده است. ویژگی‌های استخراج شده در جدول (۳) نشان داده شده‌اند. لازم به ذکر است که

¹ San Francisco

² Radarsat-2

³ Fine quad

⁴ Single Look Complex

⁵ Range

⁶ Box-car

⁷ Google Earth

جدول ۳: ویژگی‌های پلاریمتریک مورد استفاده

ویژگی	توصیف و نماد	تعداد
ویژگی‌های اصلی	ماتریس پراکنش ^۱ [S]	۳
	ماتریس هم‌دوسی ^۲ [T]	۸
	ماتریس کواریانس ^۳ [C]	۶
ویژگی‌های تجزیه	تجزیه کروگاگر ^۴	۳
	هوینن ^۵	۹
	بارنز ^۶	۹
	کلود ^۷	۹
	هلم ^۸	۹
	ون زیل ^۹	۳
	فریمن-دردن ^{۱۰}	۳
	یاماگوچی ^{۱۱}	۴
	توزی ^{۱۲}	۴
	کلود-پاتیر ^{۱۳}	۱۹
SAR تفکیک کننده‌های	توان ^{۱۴}	۱
	نسبت پلاریزاسیون ^{۱۵}	۱
	همبستگی پلاریزاسیون‌ها ^{۱۶}	۳
تمام ویژگی‌ها		۹۴

¹ Scattering Matrix

² Coherency matrix elements

³ Covariance matrix elements

⁴ Krogager

⁵ Huynen

⁶ Barnes

⁷ Cloude

⁸ Holm

⁹ Holm

¹⁰ Freeman-Durden

¹¹ Yamaguchi

¹² Touzi

¹³ Cloude-Pottier


¹⁴ SPAN

¹⁵ Fractional Polarization

¹⁶ Correlation Coefficients



(ب)



(الف)

شکل ۶: الف): ترکیب رنگی پائولی داده پلاریمتریک رنگ قرمز: $[HH-VV]$ ، رنگ سبز: $[HV]$ و رنگ آبی: $[HH+VV]$ است؛ ب): تصویر گوگل ارث از منطقه.

معیار کلی از عملکرد الگوریتم در طبقه‌بندی را نشان می‌دهد.

۵-۱- نتایج روش پیشنهادی در برابر سایر روش‌های دسته‌جمعی SVM

در آزمایش‌های مرحله اول بیشتر هدف صحت سنجی و ارزیابی قدرت روش پیشنهادی در گروهی کردن طبقه‌بندی کننده SVM در برابر سایر روش‌های گروهی‌سازی موجود در تحقیقات اخیر است. بنابراین دو روش معروف در گروهی کردن یعنی بگینگ و بوستینگ در برابر روش پیشنهادی و همچنین طبقه‌بندی کننده منفرد SVM ارزیابی می‌شوند. روش بگینگ در دو حالت دست‌کاری بر روی داده‌های آموزشی و ویژگی‌های ورودی نشان داده شده است. بنابراین نتایج ۴ روش طبقه‌بندی موردنظر در جدول (۴) آمده است.

جدول (۵) و جدول (۶) نتایج ارزیابی دقت روش‌های جدول (۴) را برای هر دو مجموعه داده نشان می‌دهد. مطابق نتایج دقت کلی تمام روش‌های گروهی بیشتر از طبقه‌بندی کننده منفرد SVM است. همچنین در هر دو داده فراطیفی و پلاریمتریک دقت روش پیشنهادی از سایر روش‌های جمعی بالاتر است.

۵- پیاده‌سازی و تحلیل نتایج

روند آزمایش‌ها و تحلیل آن‌ها به‌منظور ارزیابی روش پیشنهادی در این بخش ارائه می‌شود. در ارزیابی نتایج سه دیدگاه وجود دارد: (۱) ارزیابی روش پیشنهادی در برابر سایر روش‌های دسته‌جمعی که از SVM به‌عنوان طبقه‌بندی کننده پایه استفاده می‌شود. (۲) ارزیابی روش پیشنهادی در برابر روش‌های انتخاب ویژگی که با طبقه‌بندی کننده SVM استفاده می‌شوند. (۳) مقایسه نتایج طبقه‌بندی روش پیشنهادی در برابر سایر روش‌های طبقه‌بندی پایه (بیشترین شباهت/ویسارت) و قدرتمند (شبکه عصبی و جنگل تصادفی).

نتایج طبقه‌بندی با نمونه‌های آموزشی و آزمایشی یکسان با کمیت‌های UA^1 و OA^2 حاصل از ماتریس ابهام [۴۱] تحلیل می‌شوند. UA نسبت پیکسل‌های درست شناخته‌شده در کلاس مربوطه به کل پیکسل‌های مرجع در آن کلاس است. مقدار بالای UA هم اعتمادپذیری بالای پیکسل‌های شناسایی شده آن کلاس نسبت به داده رفرنس است. OA نسبت مجموع پیکسل‌های درست شناسایی شده به مجموع کل پیکسل‌های رفرنس در تمام کلاس‌ها است. OA

¹ User Accuracy

² Overall Accuracy

جدول ۴: مشخصات روش‌های مورد بررسی در دسته آزمایش‌های اول

نام روش	نماد	توضیحات
ماشین بردار پشتیبان ^۱	SVM	طبقه‌بندی کننده منفرد به روش ماشین بردار پشتیبان
بگینگ-ویژگی-SVM ^۲	BFSVM	روش گروهی SVM با دست‌کاری فضای ویژگی ورودی
بگینگ-داده‌های آموزشی-SVM ^۳	BTSVM	روش گروهی SVM با دست‌کاری نمونه‌های آموزشی
بوستینگ ماشین بردار پشتیبان ^۴	BSVM	روش گروهی SVM با تقویت در روند آموزش
ماشین‌های تصادفی بردار پشتیبان (روش پیشنهادی)	SVRMs	روش گروهی SVM با تولید ماشین‌های تصادفی (دست‌کاری نمونه‌های آموزشی و فضای ویژگی ورودی و تقویت در روند آموزش)

در تصویر فراطیفی دقت کلی روش پیشنهادی در مقایسه با طبقه‌بندی منفرد ۱۶ درصد افزایش نشان می‌دهد. این افزایش نشان می‌دهد روش پیشنهادی در حل مشکل فضای بزرگ ویژگی موفق بوده و پیچیدگی که در فضای ویژگی عملکرد SVM را تحت تأثیر قرار می‌داد رفع شده است. علاوه بر این روش پیشنهادی در مقایسه با سه روش گروهی دیگر عملکرد بهتری داشته است. مطابق انتظار روش پیشنهادی که تلفیقی از سه روش گروهی دیگر است مزایای هر یک را در بر می‌گیرد. در روش‌های گروهی صحت، تنوع و استقلال طبقه‌بندی کننده‌های پایه رکن مهمی است. در روش پیشنهادی با به‌کارگیری هم‌زمان ویژگی‌های ورودی و داده‌های آموزشی متمایز، تنوع و استقلال کافی در طبقه‌بندی کننده‌های پایه را تضمین می‌کند. همچنین استفاده از روش بوستینگ در روند آموزش SVM به‌صورت تدریجی صحت طبقه‌بندی کننده پایه را افزایش می‌دهد. بر این اساس در تصویر فراطیفی روش پیشنهادی به ترتیب حدود ۷، ۵ و ۴ درصد در دقت کلی طبقه‌بندی (OA)

عملکرد بهتری نسبت به روش‌های بگینگ در داده‌های آموزشی، بگینگ در فضای ویژگی ورودی و روش بوستینگ دارد. با نگاهی به دقت کلاسی روش‌ها عملکرد مطلوب روش پیشنهادی در بیشتر کلاس‌های مورد بررسی مشخص می‌شود. از بین ۱۶ کلاس ۱۱ کلاس دقت بالاتری در روش پیشنهادی دارند (دقت بیشینه در جدول با رنگ‌های تیره مشخص شده است) و در ۵ کلاس دیگر نیز بسیار نزدیک به عملکرد بیشینه در سایر روش‌ها هستند. همان‌طور که پیش‌تر نیز گفته شد کلاس‌های ۲، ۳، ۴، ۷، ۱۰ و ۱۲ با شباهت طیفی زیاد تفکیک آن‌ها از اهمیت بالایی برخوردار است روش پیشنهادی به‌جز کلاس ۴ بالاترین دقت را در کلاس‌های دیگر دارد. شکل (۷-الف) نقشه‌ی خروجی SVM و شکل (۷-ب) نقشه‌ی خروجی روش پیشنهادی را نشان می‌دهند. مطابق این خروجی روند بهبود نتیجه به‌خوبی مشخص است. اشتباهات و نویزی بودن خروجی در روش پیشنهادی به‌طور قابل توجهی کاهش یافته است.

¹ Support Vector Machine


² Bagging-Features-SVM

³ Bagging-Training-SVM


⁴ Boosting Support Vector Machines

جدول ۵: دقت کلاسی (UA) و دقت کلی (OA) طبقه‌بندی داده فراطیفی

روشنی	کمیت	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶
SVM	UA	۸۴/۸	۷۱/۱	۶۳/۶	۵۴/۹	۸۹/۷	۹۱/۵	۹۶/۴	۹۶/۸	۱۰۰	۷۸/۱	۵۹/۳	۶۹/۶	۹۳/۶	۸۲/۲	۶۸/۱	۹۳/۵
	OA	۷۳/۵۲															
BTSVMs	UA	۸۸/۷	۸۳/۴	۷۳/۵	۷۴	۹۳/۴	۹۲/۵	۹۳/۸	۹۶/۳	۱۰۰	۸۴/۵	۷۶/۶	۶۸/۸	۹۶/۶	۸۷/۳	۷۲/۷	۹۵/۱
	OA	۸۲/۳۱															
BFSVMs	UA	۸۵/۱	۸۵/۳	۷۱/۸	۷۲/۹	۹۳/۳	۹۳/۶	۹۰/۱	۹۲/۳	۸۶/۷	۸۷/۳	۸۳/۱	۷۳/۲	۹۳/۵	۸۹/۶	۷۱/۸	۹۴/۸
	OA	۸۴/۵															
BSSVMs	UA	۹۵/۶	۷۹/۸	۷۶/۹	۷۶/۳	۹۳/۳	۹۳/۸	۹۶/۴	۹۸/۳	۱۰۰	۸۸/۵	۸۱/۲	۸۷/۵	۹۴/۱	۹۰	۷۳/۱	۹۵/۷
	OA	۸۵/۲۵															
SVRMs	UA	۹۵/۱	۸۹/۲	۷۷/۹	۷۵/۹	۹۳/۴	۹۵/۹	۹۷	۹۸/۱	۱۰۰	۹۱/۵	۸۹/۹	۸۹/۲	۹۶/۴	۹۲/۳	۷۸/۴	۹۴/۶
	OA	۸۹/۷۴															



(ب)



(الف)

شکل ۷: خروجی طبقه‌بندی داده فراطیفی؛ (الف) طبقه‌بندی منفرد SVM (ب) روش پیشنهادی (SVRMs)


مشهود است. به جز کلاس جاده در سایر کلاس‌ها بهترین نتایج مربوط به روش پیشنهادی است. به دلیل قدرت تفکیک مکانی نسبتاً پایین داده تفکیک کلاس‌های جاده و ساختمان در یک فضای ویژگی پیچیده دشوار است که در روش‌های جمعی از جمله روش پیشنهادی نسبت به منفرد بهبود قابل توجهی داشته است.

در داده پلاریمتریک (مجموعه دوم) عملکردی مشابه فراطیفی دیده می‌شود. فضای ویژگی در این داده هم مانع از عملکرد مطلوب طبقه‌بندی می‌شود. روش پیشنهادی در دقت کلی حدود ۱۰ درصد نسبت به طبقه‌بندی منفرد افزایش نشان می‌دهد. بهبود عملکرد ۳، ۶ و ۸ درصدی نسبت به سایر روش‌های جمعی در SVM هم در نتایج روش پیشنهادی


جدول ۶: دقت کلاسی (UA) و دقت کلی (OA) طبقه‌بندی داده پلاریمتریک

روش	کمیت	جاده	ساختمان	درخت	آب	پوشش گیاهی
SVM	UA	۶۱/۰۱	۷۹/۵	۷۷/۶۲	۹۸/۷۸	۱۰۰
	OA	۸۷/۳۹				
BTSVMs	UA	۷۲/۰۱	۸۳/۹۸	۷۹/۱۲	۹۶/۷۸	۱۰۰
	OA	۸۹/۲۹				
BFSVMs	UA	۷۸/۹۱	۸۱/۰۹	۸۶	۱۰۰	۱۰۰
	OA	۹۱/۰۳				
BSSVMs	UA	۸۲/۴۳	۹۱/۵۳	۸۹/۹۱	۱۰۰	۱۰۰
	OA	۹۴/۶۳				

۱۰۰	۱۰۰	۹۷/۵۱	۹۸/۶۷	۷۳/۰۳	UA	SVRMs
۹۷/۲۴					OA	



(ب)



(الف)

شکل ۸: خروجی طبقه‌بندی داده پلاریمتریک؛ (الف): طبقه‌بندی منفرد SVM؛ (ب): روش پیشنهادی (SVRMs)

موجود می‌باشد. الگوریتم ژنتیک دو عملگر شامل عملگر تقاطع و عملگر جهش دارد که عملگر تقاطع با نرخ $0/99$ و مقدار جهش ژنی 5 درصد تعداد کل ژن‌ها انتخاب شد. شرط توقف نیز تغییرات کمتر از $0/01$ درصد در دقت کلی قرار داده شد اما حداکثر تعداد 100 برای تکرار هم لحاظ گردید. در این الگوریتم دقت کلی طبقه‌بندی حاصل از داده‌های آزمایشی به‌عنوان تابع هزینه استفاده شده است. (شکل (۹))

برای ارزیابی جامع‌تر از دسته‌ی دیگر روش‌های انتخاب ویژگی هم استفاده شد. برخلاف روش ژنتیک در این دسته تنها با معیارهایی میزان تفکیک‌پذیری و همبستگی بین ویژگی‌ها ارزیابی شده و ویژگی‌های بهینه انتخاب می‌شوند. روش CFS^2 و کای-دو^۳ از جمله‌ی این روش‌ها هستند که برای مقایسه در این مقاله انتخاب شدند.

دقت کلی طبقه‌بندی با روش پیشنهادی و همچنین طبقه‌بندی کننده SVM همراه با روش‌های انتخاب ویژگی در دو داده فراطیفی و پلاریمتریک در جدول (۷) آمده است. همان‌طور که نتایج نشان می‌دهد در مقایسه با روش‌های انتخاب ویژگی هم موفقیت

۵-۲- نتایج روش پیشنهادی در برابر روش‌های طبقه‌بندی همراه با انتخاب ویژگی

این بخش به مقایسه و تحلیل نتایج روش پیشنهادی در برابر استفاده از روش‌های انتخاب ویژگی اختصاص دارد. همان‌طور که در مقدمه گفته شد برای مقابله با ابعاد بالای فضای ویژگی روش‌های جمعی و انتخاب ویژگی قابل‌استفاده هستند و با این مقایسه می‌توان روش پیشنهادی را از دیدگاه موفقیت در محاسبات ابعاد فضای ویژگی بالا ارزیابی نمود. به این منظور از بین روش‌های انتخاب ویژگی مختلف یکی از بهترین روش‌ها در تحقیقات اخیر [۴۲، ۴۳ و ۴۴] الگوریتم ژنتیک^۱ برای استفاده انتخاب شد. در الگوریتم ژنتیک برای انتخاب ویژگی یک جمعیت اولیه از راه‌حل‌های ممکن شامل 100 کروموزوم به‌صورت تصادفی ایجاد شد. هر کروموزوم از تعدادی ژن تشکیل شده است، تعداد ژن‌ها معادل با تعداد ویژگی‌های ورودی می‌باشد که هر ژن در هر کروموزوم معادل با یکی از ویژگی‌های تصویر است. 1 معادل بودن و 0 معادل نبودن آن ویژگی در راه‌حل (کروموزوم)

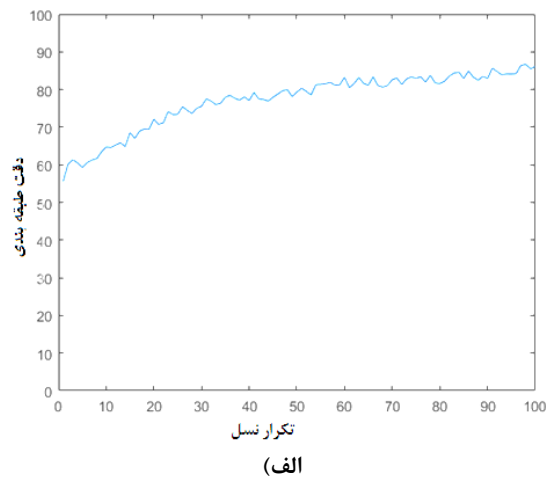

² Correlation-based Feature Selection

³ Chi-square

¹ Genetic Algorithm

بین روش‌های انتخاب ویژگی (ژنتیک) برتری دارد که این مسئله در داده پلاریمتریک هم با ۲ درصد خود را نشان می‌دهد.

روش پیشنهادی تصدیق می‌شود. به عبارت دیگر روش پیشنهادی راه‌حلی مناسبی در مسائلی با ابعاد بالای فضای ویژگی است. در داده فراطیفی روش پیشنهادی حدود ۵ درصد نسبت به بهترین نتیجه در



شکل ۹: نمودار تغییرات دقت کلی طبقه‌بندی در تکرار نسل‌های مختلف روش بهینه‌سازی ژنتیک (الف): بهترین دقت؛ (ب): دقت میانگین در هر نسل

ساده‌تر هستند از روش پیشنهادی بهتر هستند اما این روش‌ها به دلیل عملکرد نامطلوب دقت طبقه‌بندی قابل‌تکا نیستند. نقشه‌ی خروجی طبقه‌بندی منفرد به همراه روش پیشنهادی در شکل (۸) نشان داده شده است. تفکیک دو کلاس ساختمان و راه در این داده مسئله‌ای است که در روش پیشنهادی بهبود یافته و به‌طور محسوس در نقشه نیز این موضوع مشخص است.

یکی دیگر از جنبه‌های این مقایسه هزینه‌ی محاسباتی روش‌ها است. در جدول (۷) این مقایسه در شرایط یکسان داده و سخت‌افزار انجام شده است. روش پیشنهادی اگرچه هزینه محاسباتی بالاتری نسبت به تک طبقه‌بندی کننده دارد اما در مقایسه با روش ژنتیک که ماهیتی تکراری در بهینه‌سازی دارد عملکرد نسبتاً مشابهی از خود نشان می‌دهد. اگرچه زمان محاسبات روش‌های CFS و کای-دو که

جدول ۷: دقت کلی (OA) طبقه‌بندی داده پلاریمتریک در روش‌های مختلف انتخاب ویژگی

روش طبقه‌بندی	روش انتخاب ویژگی	دقت کلی	زمان محاسباتی (ثانیه)	دقت کلی	زمان محاسباتی (ثانیه)
SVRMs		۸۹/۷۴	۲۳۶۰	۹۷/۲۴	۱۴۲۸
SVM	GA	۸۴/۲۷	۲۲۴۳	۹۵/۷۳	۱۳۰۵
SVM	CFS	۷۷/۸۸	۱۶۲۱	۹۰/۰۱	۶۵۳
SVM	کای-دو	۷۹/۷۷	۱۸۹۰	۸۹/۶۷	۷۴۱

۶- نتیجه‌گیری و پیشنهادها

در این مقاله به‌منظور بهبود عملکرد طبقه‌بندی کننده SVM در فضای ویژگی با ابعاد بالا روشی دسته‌جمعی متمایز از روش‌های ارائه‌شده در تحقیقات قبلی ارائه شد. روش‌های دسته‌جمعی از طبقه‌بندی کننده‌های پایه‌ای تشکیل شده‌اند که در نهایت تجمیع آن‌ها تصمیم نهایی را نشان می‌دهد. نحوه تولید این طبقه‌بندی کننده‌های پایه و تجمیع آن‌ها از نکات بارز در دقت نهایی روش‌ها و وجه تمایز آن‌ها است. روش‌های دسته‌جمعی همسان از طبقه‌بندی کننده‌های پایه همچون درخت تصمیم، شبکه عصبی، SVM و ... استفاده می‌کنند که مشهورترین آن‌ها الگوریتم جنگل تصادفی که با استفاده از درخت‌های تصمیم متنوع و مستقل همراه با خاصیت تصادفی بهره می‌برد است.

روش پیشنهادی این مقاله دارای سه وجه تمایز مهم در برابر سایر روش‌های پیشنهادی برای طبقه‌بندی چندگانه با SVM است. اول در تولید خود راه‌اندازها و طبقه‌بندی کننده‌های پایه است که با در نظر گرفتن یک دسته داده آموزشی مستقل و همچنین یک دسته ویژگی ورودی مستقل از سایر خود راه‌اندازها نوع و استقلال کافی را در بین طبقه‌بندی کننده‌های پایه ایجاد می‌کند. دوم در آموزش طبقه‌بندی کننده‌های پایه است. روش بوستینگ که قبلاً به‌صورت تنها در طرح‌های دسته‌جمعی استفاده می‌شد در روش پیشنهادی در کنار روش بگینگ به کار گرفته شد که خود موجب بهبود تعیین بهترین حاشیه در آموزش یادگیرنده SVM و همچنین تولید بیشتر طبقه‌بندی کننده‌های پایه می‌شود. سوم استفاده از یک طرح تجمیع غیرخطی و دقیق‌تر نسبت به طرح‌هایی همچون رأی‌گیری حداکثر است. در روش پیشنهادی از تلفیق کننده بر مبنای SVM استفاده شده است که سطوح احتمال حاصل از طبقه‌بندی کننده‌های پایه به‌عنوان ویژگی‌های ورودی آن می‌باشند.

۵-۳- نتایج روش پیشنهادی در برابر سایر روش‌های طبقه‌بندی

صحت روش پیشنهادی در برابر روش‌های مختلف طبقه‌بندی با دیدگاه‌های مختلف مانند بیشترین شباهت (پارامتریک)، شبکه مصنوعی عصبی و جنگل تصادفی (غیر پارامتریک) سنجیده می‌شود جدول (۸) دقت کلی و هزینه محاسباتی این روش‌ها را نشان می‌دهد. بر اساس این نتایج صحت روش پیشنهادی در داده فراطیفی و پلاریمتریک با مقایسه آن‌ها با روش‌های پایه به ترتیب بیشترین شباهت و ویشارت تأیید می‌شود. همچنین مطابق نتایج دقت روش پیشنهادی در برابر روش‌های جنگل تصادفی و شبکه عصبی مشهود است. یکی از پارامترهای مهم در روش جنگل تصادفی K میزان تصادفی بودن در پروسه انتخاب ویژگی را کنترل می‌کند. وقتی K برابر تعداد کل ویژگی‌ها باشد، درخت تصمیم ساخته شده مشابه درخت تصمیم قطعی قدیمی است؛ زمانی که $K=1$ باشد، یک ویژگی به‌صورت تصادفی انتخاب می‌شود. مقدار پیشنهادی این پارامتر در منابع مختلف لگاریتم تعداد ویژگی‌ها است. البته در برخی مطالعات این عدد برابر جذر تعداد ویژگی‌ها یا باندهای طیفی در نظر گرفته شده است. در این تحقیق مقدار لگاریتم ویژگی‌ها بهترین جواب را ارائه داد. همچنین تعداد درخت‌های تصمیم در این روش هم ۱۰۰ در نظر گرفته شده است. تعداد لایه‌های روش شبکه عصبی هم ۳ در نظر گرفته شد که بهترین پاسخ در نتایج طبقه‌بندی این روش را ارائه داد. تابع بهینه کننده مورد استفاده در این روش تابع سیگموید^۱ است.

1 Sigmoid

جدول ۸: دقت کلی (OA) طبقه‌بندی در روش‌های مختلف پایه و قدرتمند

داده پلاریمتریک		داده فراطیفی		روش طبقه‌بندی
زمان محاسباتی (ثانیه)	دقت کلی	زمان محاسباتی (ثانیه)	دقت کلی	
۱۴۲۸	۹۷/۲۴	۲۳۶۰	۸۹/۷۴	SVRMs
۹۸۰	۹۴/۹۷	۱۸۵۴	۸۷/۸۱	Random Forest
۹۹۲	۸۸/۵۲	۱۷۶۱	۸۳/۱۲	Neural Network
۶۵۱	۷۹/۷۵	۸۶۵	۶۷/۳۱	ML/Wishart

کاهش پیچیدگی فضای ویژگی در مقایسه با روش‌های انتخاب ویژگی مهم که در کنار طبقه‌بندی کننده SVM استفاده می‌شوند مقایسه شد. نتایج عملکرد مطلوب روش پیشنهادی به لحاظ دقت کلی در طبقه‌بندی و هزینه محاسباتی را نسبت به سایر روش‌ها نشان داد. بخش سوم صحت و دقت روش طبقه‌بندی پیشنهادی در برابر روش‌های طبقه‌بندی دیگر همچون جنگل تصادفی، شبکه عصبی و بیشترین شباهت/ ویشارت ارزیابی شد که نتایج عملکرد مناسب روش پیشنهادی را تصدیق می‌کرد.

نتایج روش پیشنهادی بر روی دو داده با فضای ویژگی بالا ارزیابی شد. داده فراطیفی سنجنده اویریس از منطقه‌ی ایندیانا و داده پلاریمتریک از منطقه‌ی سانفرانسیسکو به‌عنوان داده‌های موردبررسی انتخاب شدند. آزمایش‌ها در سه بخش طراحی و تحلیل شدند. در بخش اول نتایج روش پیشنهادی در برابر سایر روش‌های جمعی با SVM مقایسه شد. نتایج نشان داد در دقت کلی و در اغلب کلاس‌ها مخصوصاً کلاس‌هایی با ویژگی‌های مشابه روش پیشنهادی در هر دو داده عملکرد بهتری نسبت به سایر روش‌ها دارد. در بخش دوم توانایی روش پیشنهادی در

مراجع

- [1] D. Landgrebe, "Hyperspectral image data analysis," *Signal Processing Magazine*, IEEE, Vol. 19, pp. 17-28, 2002.
- [2] M. T. Eismann, "Hyperspectral remote sensing," University of Maryland, 2012.
- [3] S. Vishnu, R. R. Nidamanuri, and R. Bremananth, "Spectral material mapping using hyperspectral imagery: a review of spectral matching and library search methods," *Geocarto International*, Vol. 28, pp. 171-190, 2013.
- [4] J.-S. Lee and E. Pottier, *Polarimetric radar imaging: from basics to applications*, CRC press, 2009.
- [5] M. Jafari, Y. Maghsoudi, M. J. V. Zoej, "A New Method for Land Cover Characterization and Classification of Polarimetric SAR Data Using Polarimetric Signatures", *Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE Journal of, Vol. 8, pp. 3595-3607, 2015.
- [6] Z. Qi, A. G.-O. Yeh, X. Li, and Z. Lin, "A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data," *Remote Sensing of Environment*, Vol. 118, pp. 21-39, 2012.
- [7] M. Jafari, Y. Maghsoudi, and M. J. V. Zoej, "Analyzing polarimetric signatures for different features in polarimetric SAR data," in *Geoscience and Remote Sensing Symposium (IGARSS)*, 2014 IEEE International, 2014, pp. 2782-2785.
- [8] M. Jafari, M. Valadan-zoej, and Y. Maghsoudi, "Knowledge-based Classification of Polarimetric SAR data using Support Vector Machine-Decision Tree (SVM-DT)," *Journal of Geomatics*

- Science and Technology, Vol. 5, pp. 93-108, 2015.
- [9] M. Jafari, Y. Maghsoudi, and M. Zoj, "A New Component Scattering Model Using Polarimetric Signatures Based Pattern Recognition on Polarimetric SAR Data," *Journal of the Indian Society of Remote Sensing*, Vol.8, pp. 1-10, 2016.
- [10] G. P. Hughes, "On the mean accuracy of statistical pattern recognizers," *Information Theory, IEEE Transactions on*, Vol. 14, pp. 55-63, 1968.
- [11] D. A. Landgrebe, *Signal theory methods in multispectral remote sensing vol. 29*: John Wiley & Sons, 2005.
- [12] S. Kumar, "Modular learning through output space decomposition," UNIVERSITY OF TEXAS AT AUSTIN, 2000.
- [13] M. Fauvel, J. A. Benediktsson, J. Chanussot, and J. R. Sveinsson, "Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles," *Geoscience and Remote Sensing, IEEE Transactions on*, Vol. 46, pp. 3804-3814, 2008.
- [14] J. Gualtieri and S. Chettri, "Support vector machines for classification of hyperspectral data," in *Geoscience and Remote Sensing Symposium, 2000. Proceedings. IGARSS 2000*, pp. 813-815.
- [15] M. Pal and P. M. Mather, "Assessment of the effectiveness of support vector machines for hyperspectral data," *Future Generation Computer Systems*, Vol. 20, pp. 1215-1225, 2004.
- [16] G. Camps-Valls and L. Bruzzone, "Kernel-based methods for hyperspectral image classification," *Geoscience and Remote Sensing, IEEE Transactions on*, Vol. 43, pp. 1351-1362, 2005.
- [17] G. Mercier and M. Lennon, "Support vector machines for hyperspectral image classification with spectral-based kernels," in *Geoscience and Remote Sensing Symposium, IGARSS2003, 2003*, pp. 288-290.
- [18] Y. Huang, J. Cai, L. Ji, and Y. Li, "Classifying G-protein coupled receptors with bagging classification tree," *Computational biology and chemistry*, Vol. 28, pp. 275-280, 2004.
- [19] A. Liaw and M. Wiener, "Classification and regression by randomForest," *R news*, Vol. 2, pp. 18-22, 2002.
- [20] L. K. Hansen and P. Salamon, "Neural network ensembles," *IEEE Transactions on Pattern Analysis & Machine Intelligence*, pp. 993-1001, 1990.
- [21] D. B. Skalak, "Prototype selection for composite nearest neighbor classifiers," University of Massachusetts Amherst, 1997.
- [22] S. D. Bay, "Nearest neighbor classification from multiple feature subsets," *Intelligent data analysis*, Vol. 3, pp. 191-209, 1999.
- [23] T. G. Dietterich, "Ensemble methods in machine learning," in *Multiple classifier systems*, ed: Springer, 2000, pp. 1-15.
- [24] D. Bahler and L. Navarro, "Combining heterogeneous sets of classifiers: Theoretical and experimental comparison of methods," presented at the 17th National Conference on Artificial Intelligence (AAAI 2000), Workshop on New Research Problems for Machine Learning, 2000.
- [25] G. Valentini and F. Masulli, "Ensembles of learning machines," in *Neural Nets*, ed: Springer, 2002, pp. 3-20.
- [26] D. Opitz and R. Maclin, "Popular ensemble methods: An empirical study," *Journal of Artificial Intelligence Research*, pp. 169-198, 1999.
- [27] G. Giacinto and F. Roli, "An approach to the automatic design of multiple classifier systems," *Pattern recognition letters*, Vol. 22, pp. 25-33, 2001.
- [28] J. M. P. d. Gama, "Combining classification algorithms," University of Porto, 1999.
- [29] C. Cortes and V. Vapnik, "Support-vector networks," *Machine learning*, Vol. 20, pp. 273-297, 1995.
- [30] C. J. Burges, "A tutorial on support vector

- machines for pattern recognition," Data mining and knowledge discovery, Vol. 2, pp. 121-167, 1998.
- [31] V. N. Vapnik and V. Vapnik, Statistical learning theory vol. 1: Wiley New York, 1998.
- [32] H.-C. Kim, S. Pang, H.-M. Je, D. Kim, and S.-Y. Bang, "Support vector machine ensemble with bagging," in Pattern recognition with support vector machines, ed: Springer, 2002, pp. 397-408.
- [33] Z.-H. Zhou, Ensemble methods: foundations and algorithms: CRC Press, 2012.
- [34] Y. Freund and R. E. Schapire, "Experiments with a new boosting algorithm," in ICML, 1996, pp. 148-156.
- [35] L. Breiman, "Bagging predictors," Machine learning, Vol. 24, pp. 123-140, 1996.
- [36] B. X. Wang and N. Japkowicz, "Boosting support vector machines for imbalanced data sets," Knowledge and Information Systems, Vol. 25, pp. 1-20, 2010.
- [37] Universidad-del-Pais-Vasco. Hyperspectral Remote Sensing Scenes [Online]. Available: http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes
- [38] Purdue-Research-Foundation. Hyperspectral Images by MultiSpec© [Online]. Available: <https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>
- [39] B. Mojaradi, H. Abrishami-Moghaddam, M. J. V. Zoj, and R. P. Duin, "Dimensionality reduction of hyperspectral data via spectral feature extraction," Geoscience and Remote Sensing, IEEE Transactions on, Vol. 47, pp. 2091-2105, 2009.
- [40] F. van der Meero and W. Bakker, "Cross correlogram spectral matching: application to surface mineralogical mapping by using AVIRIS data from Cuprite, Nevada," Remote Sensing of Environment, Vol. 61, pp. 371-382, 1997.
- [41] A. Hay, "The derivation of global estimates from a confusion matrix," International Journal of Remote Sensing, Vol. 9, pp. 1395-1398, 1988.
- [42] J. Yang and V. Honavar, "Feature subset selection using a genetic algorithm," in Feature extraction, construction and selection, ed: Springer, 1998, pp. 117-136.
- [43] R. Leardi, "Application of genetic algorithm-PLS for feature selection in spectral data sets," Journal of Chemometrics, Vol. 14, pp. 643-655, 2000.
- [44] S. Oreski and G. Oreski, "Genetic algorithm-based heuristic for feature selection in credit risk assessment," Expert systems with applications, Vol. 41, pp. 2052-2064, 2014.



Support Vector Random Machines (SVRMs), A Optimum Multiclassifier for Big Data

Mohsen Jafari *¹, Mehdi Akhoundzadeh ²

1- PhD. Student, Remote Sensing Department, Faculty of Surveying and Geoinformation Engineering, College of Engineering, University of Tehran
2- Assistant Professor, Remote Sensing Department, Faculty of Surveying and Geoinformation Engineering, College of Engineering, University of Tehran

Abstract

Although, the distinction between the land cover classes was increased in large feature space of remote sensing images, but the low number of training data prevent this. In order to solve this problem, ensemble classification methods can be used instead of individual classifiers. In this paper, a new method for ensemble support vector machine was proposed called "Support Vector Random Machines (SVRMs)". In proposed method, bootstrap was produced using modification of training data and feature space. Simultaneous boosting SVM was used for basic classifiers. Then, classification map was resulted using SVM fusion of basic classifier. Hyperspectral and Polarimetric SAR data was chosen for evaluation performance of the SVRMs. Experiments were evaluated from three different points of view: First, evaluation against other ensemble SVM methods; second, evaluation against various feature selection methods in classification and third, evaluation against the various basic and new classification methods. As the results, proposed method is 16% better than the individual SVM classifier in hyperspectral data and this is 10% in PolSAR data. Also, the classification results of SVRMs in various classes compared to other SVM ensemble method were improved. The results reported from the proposed method compared to the other feature selection method (Genetic Algorithm) has the effectual performance in classification. The results show that the proposed method presents a better performance compared to the basic classification methods (maximum likelihood and wishart) and advanced classification (random forest and neural network).

Key words: Support Vector Machine (SVM), Ensemble method, Feature space, Bootstarp, Aggregation.

Correspondence Address. Remote Sensing Department, Faculty of Surveying and Geoinformation Engineering, College of Engineering, University of Tehran, Iran.

Tel: +98 9366153637

Email: jafarim@ut.ac.ir