

تعیین ماشین‌های بردار پشتیبان بهینه در طبقه‌بندی تصاویر فرا طیفی بر مبنای الگوریتم ژنتیک

فرهاد صمدزادگان*
حدیثه سادات حسینی**

* استاد، دانشکده مهندسی نقشه‌برداری، دانشگاه تهران، تهران

** دانشجوی دکتری فتوگرامتری، دانشکده مهندسی نقشه‌برداری، دانشگاه تهران، تهران

تاریخ دریافت: ۱۳۹۱/۰۴/۰۶

تاریخ پذیرش: ۱۳۹۱/۱۱/۰۹

چکیده

امروزه تصاویر فرا طیفی به علت غنای اطلاعات طیفی یک ابزار قوی و کارآمد در سنجش از دور به حساب می‌آیند و امکان تمایز بین عوارض مشابه را فراهم می‌آورند. با توجه به پایداری ماشین‌های بردار پشتیبان در فضاهایی با ابعاد بالا، یک گزینه مناسب در طبقه‌بندی تصاویر فرا طیفی محسوب می‌شوند. با این وجود، عملکرد این طبقه‌بندی کننده‌ها تحت تأثیر پارامترها و فضای ویژگی ورودی آن‌ها می‌باشد. به منظور استفاده از ماشین‌های بردار پشتیبان با بیشترین کارایی، می‌بایست مقادیر بهینه پارامترها و همچنین زیر مجموعه بهینه از ویژگی‌های ورودی تعیین گردند. در این تحقیق از توانایی الگوریتم ژنتیک به عنوان یک تکنیک بهینه‌سازی فرا ابتکاری، در تعیین مقادیر بهینه پارامترهای ماشین‌های بردار پشتیبان و همچنین انتخاب زیرمجموعه ویژگی‌های بهینه در طبقه‌بندی تصاویر فرا طیفی استفاده شده است. نتایج عملی از به‌کارگیری روش فوق در خصوص داده‌های فرا طیفی سنجنده AVIRIS نشان می‌دهند، ویژگی‌های ورودی و پارامترها هر کدام جداگانه تأثیر بسزایی بر عملکرد ماشین‌های بردار پشتیبان دارند ولی بهترین عملکرد طبقه‌بندی کننده با حل همزمان آن دو بدست می‌آید. در حل همزمان تعیین پارامتر و انتخاب ویژگی، برای کرنل گوسین و پلی‌نومیال به ترتیب ۵٪ و ۱۵٪ افزایش دقت با حذف بیش از نیمی از باندهای تصویر حاصل شد. همچنین الگوریتم بهینه‌سازی شبیه‌سازی تبرید تدریجی به منظور مقایسه با الگوریتم ژنتیک پیاده‌سازی شد که نتایج حاکی از برتری الگوریتم ژنتیک به ویژه با بزرگ و پیچیده شدن فضای جستجو در رویکرد حل همزمان تعیین پارامتر و انتخاب ویژگی می‌باشد.

۱. مقدمه

امروزه با پیشرفت‌های اخیر در زمینه تکنولوژی ساخت سنجنده‌های فرا طیفی در سنجش از دور، امکان اخذ تصاویر با صدها باند با قدرت تفکیک طیفی بالا فراهم است [۱]. افزایش تعداد باندها و در نتیجه افزایش اطلاعات طیفی، امکان استخراج اطلاعات بیشتر در مورد عوارض موجود در تصویر و همچنین تمایز بین عوارض مشابه را فراهم می‌کند. از سوی دیگر با بالا رفتن ابعاد فضای ورودی، نیاز به پردازش‌های خاصی به منظور به‌کارگیری این تصاویر در بسیاری از کاربردهای مطرح می‌باشد [۱].

یک مرحله مهم در پردازش تصاویر فرا طیفی به منظور استخراج اطلاعات، طبقه‌بندی آنها با یکسری کلاس‌های از پیش تعیین شده می‌باشد. در تصاویر فرا طیفی، طبقه‌بندی کننده‌های پارامتریک به علت نیاز به تخمین توزیع آماری کلاس‌ها و عدم توازن بین تعداد باندها و تعداد نمونه‌های آموزشی، با پدیده هیوز^۱ مواجه می‌شوند [۲]. در این شرایط به علت بزرگ شدن فضای فرضیه و محدودیت تعداد نمونه‌های آموزشی، احتمال بیش تطابق نمودن^۲ مدل به داده‌های آموزشی وجود دارد [۳]. به منظور رفع مشکلات روش‌های پارامتریک در سال‌های اخیر طبقه‌بندی کننده‌های غیر پارامتریک مختلفی به منظور طبقه‌بندی تصاویر فرا طیفی ارائه شده‌اند، از جمله: شبکه عصبی [۴]، درخت تصمیم‌گیری [۵]، Random Forest [۶] و روش‌های کرنل مینا [۳].

در این خصوص ماشین‌های بردار پشتیبان^۳ به عنوان یک روش کرنل مینا، توانسته‌اند به با توجه به عملکردشان بر مبنای ویژگی‌های

کلید واژگان: ماشین‌های بردار پشتیبان، تصاویر فرا طیفی، طبقه

بندی، انتخاب مدل، انتخاب ویژگی، الگوریتم ژنتیک.

¹ Hughes phenomena

² Over-fitting

³ Support Vector Machines

بودن و اجرای همزمان جستجوی سراسری^۲ و جستجوی محلی^۳ پتانسیل بالایی در حل مسائل پیچیده بهینه‌سازی دارد [۲۱].

در این تحقیق توانایی الگوریتم ژنتیک در تعیین طبقه‌بندی‌کننده‌های بردار پشتیبان در سه رویکرد: تعیین مقادیر بهینه پارامترهای ماشین‌های بردار پشتیبان، انتخاب زیرمجموعه ویژگی‌های بهینه و حل همزمان هر دو مفهوم در طبقه‌بندی تصاویر فرا طیفی مورد ارزیابی قرار گرفته است.


۲. ماشین‌های بردار پشتیبان

ماشین‌های بردار پشتیبان یک روش طبقه‌بندی با نظارت بر مبنای نظریه یادگیری آماری می‌باشند [۲۲]. ایده اساسی این طبقه‌بندی‌کننده، یافتن یک ابر صفحه بهینه به عنوان سطح تصمیم‌گیری به گونه‌ای می‌باشد که حاشیه بین دو کلاس را بیشینه کند. در صورتی که داده‌ها به صورت خطی جدا پذیر نباشد، داده‌ها با کرنلی غیرخطی به فضای با ابعاد بالاتر منتقل می‌شود و ابر صفحه بهینه در آن فضا تعیین می‌شود.

فرض کنید l داده‌های آموزشی موجود می‌باشد که هر یک با (x_i, y_i) نشان داده می‌شود، x_i بردار ویژگی n بعدی و $y_i \in \{-1, 1\}$ برچسب آن می‌باشد. هدف یافتن ابر صفحه است که دو کلاس با برچسب ۱ و -۱ را با بیشترین حاشیه از هم جدا کند. این ابر صفحه را می‌توان با معادله (۱) بیان کرد.

$$w^T \phi(x) + b = 0 \quad (1)$$

در این رابطه، بردار وزن w ، برداری عمود بر ابر صفحه، b بردار بایاس می‌باشد که به منظور اندازه‌گیری فاصله ابر صفحه تا مبدأ استفاده می‌شود و $\phi(\cdot)$ کرنلی برای انتقال داده به فضای با ابعاد بالاتر می‌باشد (شکل ۱).



شکل ۱- طبقه‌بندی داده‌هایی که به صورت خطی جدا پذیر نیستند، توسط ماشین‌های بردار پشتیبان

هندسی و عدم نیاز به تخمین ویژگی‌های آماری، ابزاری بسیار کارا و قدرتمند برای طبقه‌بندی تصاویر فرا طیفی به حساب آیند [۷-۹]. ایده ماشین‌های بردار پشتیبان یافتن یک صفحه تصمیم‌گیری بهینه برای جداسازی دو کلاس می‌باشد به صورتی که دو کلاس بیشترین حاشیه جداسازی را در یک طبقه‌بندی باینری داشته باشند. در صورتی که نمونه‌ها به صورت خطی جدا پذیر نباشند، ابتدا با یک کرنل به فضای با ابعاد بالاتر منتقل می‌شود و صفحه جداکننده در آن فضا تعریف می‌شود [۱۰].

هر چند در سال‌های اخیر ماشین‌های بردار پشتیبان با موفقیت در طبقه‌بندی بسیاری از تصاویر فرا طیفی به کار گرفته شده‌اند، با این حال می‌بایست به تأثیر دو عامل که بر عملکرد آن‌ها تأثیرگذار هستند، توجه داشت: پارامترهای ماشین‌های بردار پشتیبان و فضای ویژگی ورودی (باندهای ورودی طبقه‌بندی). به منظور طراحی یک سیستم بهینه طبقه‌بندی برای تصاویر فرا طیفی بر مبنای ماشین‌های بردار پشتیبان، انتخاب مقادیر بهینه پارامترهای مدل و انتخاب زیرمجموعه‌ای از باندهای بهینه چالش‌هایی است که در این زمینه وجود دارند. به علت اهمیت موضوع، مطالعات زیادی در سال‌های اخیر در این زمینه انجام شده است که می‌توان آن‌ها را به سه دسته تقسیم کرد. در دسته اول، از همه ویژگی‌های ورودی داده استفاده می‌شود و پارامترهای مدل بهینه می‌گردد تا کارایی ماشین‌های بردار پشتیبان بالا رود [۱۱-۱۳]. انتخاب ویژگی‌های بهینه با ثابت در نظر گرفتن پارامترها گروه دوم تحقیقات می‌باشد [۱۴-۱۶] که با حذف ویژگی‌های اضافی و وابسته، دقت و سرعت طبقه‌بندی را بهبود می‌بخشند. در این دسته از مطالعات، در ابتدا مقادیر پارامترهای مدل با استفاده از یک روش کلاسیک محاسبه شده و یا از مقادیر پیش فرض استفاده می‌کنند. سپس در پروسه انتخاب ویژگی آن مقادیر ثابت در نظر گرفته می‌شوند. با توجه به تأثیر فضای ورودی بر مقدار بهینه پارامترها و بالعکس، دسته سوم الگوریتم‌ها به حل همزمان تعیین پارامترها و انتخاب زیرمجموعه ویژگی‌های بهینه می‌پردازند [۱۷-۲۰].

به منظور حل این مسائل، با توجه به بزرگ بودن فضای مجهولات نیاز به یک الگوریتم بهینه‌سازی قوی و کارا می‌باشد تا بتواند جواب بهینه سراسری را بدست آورد. از آنجایی که الگوریتم‌های بهینه‌سازی مرسوم معمولاً در فضای جستجوی بزرگ با مشکل مواجه می‌شوند و به جواب زیر بهینه می‌رسند، در این تحقیق از الگوریتم فرا ابتکاری^۱ ژنتیک استفاده گردیده است. الگوریتم ژنتیک به علت جمعیت مینا

Archive of SID

در روش «یک در مقابل یک»، برای هر زوج کلاس ممکن از یک ماشین بردار پشتیبان باینری استفاده می‌شود. به این ترتیب برای M کلاس، $\frac{M(M-1)}{2}$ طبقه‌بندی کننده بردار پشتیبان باینری نیاز داریم. در نهایت همه ماشین‌های بردار پشتیبان باینری با روش رای گیری حداکثر ادغام می‌شود.

روش «یک در مقابل مابقی»، روش مرسوم دیگر می‌باشد که در آن هر ماشین بردار پشتیبان باینری، داده‌های یک کلاس را از داده‌های کلاس‌های دیگر جدا می‌کند. در این روش، برای M کلاس، M طبقه‌بندی کننده باینری خواهیم داشت. پس از طبقه‌بندی داده جدید با M طبقه‌بندی کننده، داده به کلاسی که بیشترین نتیجه مثبت را داشته باشد، نسبت داده می‌شود [۱۰].

۳. مروری بر تحقیقات

با توجه به اطلاعات طیفی غنی موجود در تصاویر فرا طیفی، همراه با پیشرفت تکنولوژی ساخت سنجیده‌های فرا طیفی، الگوریتم‌های پردازش این دسته از تصاویر نیز رشد چشمگیری داشته‌اند که در این بین الگوریتم‌های طبقه‌بندی به منظور استخراج اطلاعات و همچنین تهیه نقشه‌های موضوعی بسیار مورد توجه قرار گرفته‌اند. از این رو مطالعات گسترده‌ای در زمینه ارزیابی عملکرد طبقه‌بندی کننده‌های گوناگون در تصاویر فرا طیفی صورت گرفته است. از اوایل سال ۲۰۰۰، نخستین تحقیقات بر مبنای استفاده از ماشین‌های بردار پشتیبان در طبقه‌بندی تصاویر فرا طیفی صورت پذیرفت. در سال‌های بعد عملکرد طبقه‌بندی کننده‌های دیگر از قبیل شبکه‌های عصبی، نزدیک‌ترین همسایه، کمترین فاصله، بیشترین شباهت، درخت تصمیم‌گیری و آنالیز تفکیک کرنل فیشر در مقایسه با ماشین‌های بردار پشتیبان بررسی شد که نتایج حاکی از برتری ماشین‌های بردار پشتیبان می‌باشد [۳، ۴، ۵، ۶]. از این رو در این تحقیق از طبقه‌بندی کننده ماشین‌های بردار پشتیبان به منظور پردازش تصویر فرا طیفی استفاده شده است.

هرچند ماشین‌های بردار پشتیبان به عنوان ابزاری کارا در طبقه‌بندی تصاویر فرا طیفی به کار برده شده‌اند، به منظور بهبود عملکرد این طبقه‌بندی کننده به لحاظ دقت و پیچیدگی‌های محاسباتی، می‌بایست به دو عامل تأثیرگذار توجه شود: پارامترهای طبقه‌بندی کننده و باندهای ورودی آن. از این رو مطالعات گوناگونی بر مبنای بهینه‌سازی سیستم طبقه‌بندی تصاویر فرا طیفی ارائه شده‌اند. تحقیقات موجود در این زمینه را می‌توان در سه بخش انتخاب مدل، انتخاب ویژگی و حل همزمان این دو دسته‌بندی کرد.

انتخاب بهینه پارامترهای تشکیل دهنده مدل در ماشین‌های بردار پشتیبان از تأثیر مستقیمی در کارایی این روش برخوردار می‌باشند

بیشینه نمودن حاشیه بین دو کلاس معادل کمینه کردن اندازه w می‌باشد که منجر به حل مسئله کمینه‌سازی مقید (۲) می‌شود.

$$\text{Min} \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^k \xi_i \right) \quad (2)$$

$$\text{Subjectto} : y_i(w\phi(x_i) + b) > 1 - \xi_i \quad i=1, \dots, k$$

که پارامتر C ، پارامتر تنظیم در ماشین‌های بردار پشتیبان می‌باشد. به منظور در نظر گرفتن نویز موجود در داده و تداخل بین داده‌های آموزشی، از متغیر $\xi_i > 0$ استفاده می‌شود. وجود قید ضمانت می‌کند که داده‌ای در حاشیه قرار نمی‌گیرد. هرچند برای جلوگیری از بیش تطابق نمودن به داده‌های نویزی، این قید با متغیرهای ξ_i نرم شده است.

سطح تصمیم‌گیری بهینه با حل مسئله مقید (۲) بر مبنای روش لاگرائز طبق معادله (۳) محاسبه می‌شود.

$$f(x) = \sum_{x_i \in SV} y_i \alpha_i \phi(x_i) \cdot \phi(x) + b \quad (3)$$

در این رابطه α_i ضرایب لاگرائز می‌باشد که در پروسه بهینه‌سازی محاسبه می‌شود، SV بردارهای پشتیبان هستند که ضریب لاگرائز متناظر آن‌ها بزرگ‌تر از صفر است. این داده‌های آموزشی، نزدیک‌ترین نمونه‌ها به ابر صفحه هستند. همان طور که رابطه (۳) نشان می‌دهد، تنها بردارهای پشتیبان هستند که در مرحله آموزش شرکت می‌کنند. در نتیجه ماشین‌های بردار پشتیبان نیاز به تعداد نمونه آموزشی زیاد ندارند. در رابطه (۳)، ضرب داخلی بین دو کرنل نگاشت شده، می‌تواند با کرنل آن دو نمونه محاسبه گردد. از پرکاربردترین کرنل‌ها، کرنل گوسین و پلی نومیال هستند که به ترتیب با روابط (۴) و (۵) تعریف می‌شوند.

$$\phi(x_i, x) = e^{-\frac{\|x_i - x\|}{2\sigma^2}} \quad (4)$$

$$\phi(x_i, x) = (x_i \cdot x + 1)^d \quad (5)$$

در این روابط، σ پارامتر کرنل گوسین و d متغیر کرنل پلی نومیال می‌باشد [۲۳].

الگوریتم پایه ماشین‌های بردار پشتیبان برای طبقه‌بندی باینری توسعه داده شده است. از آنجایی که در بیشتر کاربردها، بیش از دو کلاس وجود دارد، الگوریتم‌های مختلفی برای حل مسئله چند کلاسه به کار گرفته شده است [۱۰]. یک روش مرسوم در این زمینه تجزیه مسئله چند کلاسه به مسئله ای با چندین طبقه بندی کننده باینری می‌باشد. الگوریتم‌های «یک در مقابل یک» و «یک در مقابل مابقی»، دو الگوریتم پرکاربرد در این زمینه می‌باشد.

Archive of SID

انتخاب پارامترهای بهینه مدل در ماشین‌های بردار پشتیبان استفاده شده‌اند [۲۳، ۲۶]. الگوریتم ژنتیک به دو شکل در انتخاب مدل می‌تواند استفاده گردد: کدگذاری اعداد حقیقی [۱۳، ۲۳] و کدگذاری باینری [۱۵، ۲۶].

دسته دیگر مطالعات در زمینه بهینه‌سازی سیستم‌های طبقه‌بندی، به مسئله انتخاب زیرمجموعه بهینه باندهای ورودی می‌پردازند. الگوریتم‌های انتخاب ویژگی را می‌توان به دو دسته پوششی^۱ و فیلتر^۲ تقسیم کرد. تکنیک‌های پوششی به منظور ارزیابی کیفیت زیرمجموعه ویژگی‌های انتخاب شده، از دقت طبقه‌بندی کننده استفاده می‌کنند. در مقابل الگوریتم‌های فیلتر، از معیارهای دیگری مانند جداسازی بین کلاس‌ها، قدرت نمایش و غیره استفاده می‌کنند. این دسته از تکنیک‌ها دارای سرعت بالایی هستند ولی لزوماً دارای دقت طبقه‌بندی مناسبی نیستند [۱۴]. با توجه به اهمیت دقت طبقه‌بندی در این تحقیق از روش‌های پوششی که در آن کیفیت باندهای انتخابی به وسیله دقت طبقه‌بندی کننده‌ی ماشین‌های بردار پشتیبان بدست می‌آید، استفاده خواهد شد.

با توجه به ابعاد بالای ورودی در تصاویر فرا طیفی، انتخاب یک زیر مجموعه بهینه از باندها بدون پیش فرضی در مورد تعداد باندهای بهینه یک مسئله بهینه‌سازی NP-hard می‌باشد [۲۹]. در این راستا در سال‌های اخیر الگوریتم‌های بهینه‌سازی مختلفی از قبیل جستجوی ممنوع^۳ [۳۰]، الگوریتم‌های خرد جمعی [۳۱، ۳۲] و الگوریتم ژنتیک [۱۴، ۱۶، ۳۳] برای حل این موضوع ارائه گردیده است. با توجه به ساختار الگوریتم ژنتیک در حالت باینری، مسئله انتخاب ویژگی سازگاری بسیار مناسبی با الگوریتم ژنتیک دارد. لذا تحقیقات بسیاری در رابطه با انتخاب ویژگی بر مبنای الگوریتم ژنتیک در زمینه‌های گوناگون و با طبقه‌بندی کننده‌های مختلف وجود دارد [۱۴، ۳۳].

در سال ۲۰۰۶ هوئرتا و همکاران از الگوریتم ژنتیک به منظور کاهش ابعاد داده‌های پزشکی استفاده کردند. در این تحقیق در ابتدا در مرحله پیش پردازش با منطق فازی ابعاد فضای ورودی را کاهش داده و سپس با الگوریتم پوششی بر مبنای الگوریتم ژنتیک در فضای کاهش یافته، ویژگی‌های بهینه انتخاب گردید. همچنین پارامترهای ماشین‌های بردار پشتیبان ثابت در نظر گرفته شد [۱۴].

در سال ۲۰۰۸، بهاتیا و همکاران از الگوریتم ژنتیک که با اعداد صحیح کدگذاری شده بود به منظور انتخاب ویژگی با طبقه‌بندی کننده ماشین‌های بردار پشتیبان استفاده کردند [۳۴]. در الگوریتم ارائه شده،

[۱۳]. دو دسته پارامتر در این طبقه‌بندی کننده‌ها وجود دارد. پارامتر تنظیم که تعادل بین کمینه شدن خطا و کمینه شدن پیچیدگی‌های مدل را برقرار می‌کند (پارامتر C) و «پارامترهای کرنل» که با توجه به کرنل انتخابی، متغیرهای آن کرنل جزء مجهولات می‌شوند. مانند σ در کرنل گوسین و d در کرنل پلی نومیال [۱۳].

همان طور که در بخش قبل بیان شد، ماشین‌های بردار پشتیبان ذاتاً باینری هستند و برای مسائل چند کلاسه از ترکیب چندین طبقه‌بندی کننده باینری استفاده می‌شود. از این نقطه نظر می‌توان الگوریتم‌های موجود در تعیین پارامترهای ماشین‌های بردار پشتیبان که انتخاب مدل نیز نامیده می‌شوند، را به دو دسته تقسیم کرد. در دسته اول تکنیک‌های انتخاب مدل، برای همه‌ی ماشین‌های بردار پشتیبان باینری یک دسته پارامتر یکسان در نظر گرفته می‌شود [۱۳، ۲۶]. در حالی که در دسته دوم، برای هر طبقه‌بندی کننده باینری یکسری پارامتر متفاوت تعیین می‌شود [۲۳، ۲۷]. تحقیقات انجام شده نشان داده است که با اضافه شدن مجهولات در اکثر موارد نه تنها دقت طبقه‌بندی بالا نمی‌رود بلکه به دلیل بیش تطابق نمودن به داده‌های آموزشی، سیستم طبقه‌بندی دارای قدرت تعمیم کمی خواهد بود [۲۷]. در نتیجه در این تحقیق از یک دسته پارامتر برای همه ماشین‌های بردار پشتیبان باینری استفاده می‌شود.

در سال‌های اخیر روش‌های متنوعی به منظور تعیین پارامترهای بهینه در ماشین‌های بردار پشتیبان، توسط محققین مختلف ارائه گردیده است [۱۱-۱۳]. الگوریتم جستجوی شبکه‌ای، روش رایج در انتخاب پارامترهای بهینه مدل می‌باشد. در این روش، شبکه‌ای k بعدی بر روی محدوده پارامترها قرار می‌گیرد که k تعداد پارامترهای مجهول می‌باشد (در این تحقیق برای به کارگیری هر دو کرنل گوسین و پلی-نومیال $k=2$ در نظر گرفته شده است). سپس کیفیت تمام مجموعه جواب‌های ممکن در نقاط شبکه ارزیابی می‌شود و آن دسته از پارامترهایی که کمترین خطای طبقه‌بندی را دارند، به عنوان پارامترهای ماشین‌های بردار پشتیبان انتخاب می‌شوند [۲۸]. به علت پیوسته بودن مقادیر پارامترهای مورد نظر، برای رسیدن به دقت بالا می‌بایست شبکه‌ای با تراکم بالا در نظر گرفته شود که بررسی تمام این نقاط شبکه زمان محاسبات را به شدت افزایش می‌دهد.

با توجه به محدودیت‌های روش جستجوی شبکه‌ای در زمان و محاسبات، الگوریتم‌های بهینه‌سازی مختلفی برای حل این مسئله در نظر گرفته شده‌اند: الگوریتم‌های خرد جمعی [۱۲، ۲۷]، شبیه‌سازی تبرید تدریجی [۱۸] و الگوریتم ژنتیک [۱۳، ۲۳، ۲۶].

این الگوریتم ژنتیک از الگوریتم‌های فرا ابتکاری هستند که به طور موفقیت آمیز و گسترده‌ای در سال‌های اخیر در زمینه

^۱Wrapper

^۲Filter

^۳Tabu Search

Archive of SID

استفاده از توابعی همچون سیگموئید به بازه [0,1] منتقل می‌شود و برای ارزیابی ویژگی‌های انتخاب شده، این ویژگی‌ها به فضای باینری منتقل می‌شوند [۲۰، ۳۸]. در روش دوم پارامترهای ماشین‌های بردار پشتیبان، تبدیل به فرمت باینری شده و در کنار بردار ویژگی‌های انتخابی قرار می‌گیرند [۲۰].

در سال ۲۰۰۵، سوزا و کاروالو مقدار پارامتر تنظیم و زیرمجموعه بهینه ویژگی‌ها را بر مبنای الگوریتم ژنتیک باینری تعیین نمودند و مقدار پارامتر کرنل در این روش ثابت در نظر گرفته شد. همچنین در این تحقیق تنها سه مقدار ممکن برای پارامتر تنظیم در نظر گرفته شده است [۳۹].

در سال ۲۰۰۶، هوانگو وانگ پارامترهای کرنل RBF به همراه ویژگی‌های ورودی در حالت باینری بهینه گردید. نتایج بدست آمده در این روش با تکنیک جستجوی شبکه‌ای که قابلیت انتخاب ویژگی ندارد، مقایسه گردیده است که نشان می‌دهد، الگوریتم پیشنهادی با ویژگی‌های انتخاب شده به دقت بالاتری می‌رسد [۲۰]. در همین سال بگی و ملگانی الگوریتم ژنتیک را با کروموزم‌هایی به طول تعداد ویژگی‌ها به علاوه ۲ (دو پارامتر کرنل) پیاده سازی کردند. برای ارزیابی الگوریتم ارائه شده، از تصاویر فرا طیفی استفاده کردند [۷].

در سال ۲۰۰۷، میجیا-گوئوارا و اکوری-مولارساز ماشین‌های بردار پشتیبان برای رگرسیون استفاده کردند که در این حالت سه پارامتر مجهول برای ماشین‌های بردار پشتیبان وجود دارد. در این مقاله علاوه بر ویژگی و پارامترها، احتمال ترکیب و جهش در الگوریتم ژنتیک نیز به عنوان مجهول در نظر گرفته شده است. برای نمایش راه حل با کروموزم، از کدگذاری باینری استفاده شد [۳۶].

ژو و همکاران در سال ۲۰۰۸ الگوریتم ارائه شده در [۲۰] را بر روی تصاویر فرا طیفی هایپریون آزمایش کردند و مشاهده گردید نتایج بدست آمده نسبت به زمانی که از همه باندها استفاده شده باشد، بهبود یافته است [۱۵]. در این مطالعه تأثیر روش پیشنهادی تنها با استفاده از یک کرنل و یک روش چند کلاسه در ماشین‌های بردار پشتیبان بررسی شد.

در سال ۲۰۰۹، اکوی الگوریتمی ارائه داد که علاوه بر ویژگی و پارامترها، نوع کرنل نیز در یک پروسه مبتنی بر الگوریتم ژنتیک بهینه می‌گردید. در این مقاله، از انتقال موجک برای استخراج ویژگی استفاده گردیده و برای این منظور ۱۶ نوع موجک و ۸ نوع کرنل در نظر گرفته شده است. بعد از پایان الگوریتم، نوع موجک و کرنل بهینه به همراه پارامترهای آن بدست می‌آید [۳۸].

در سال ۲۰۱۱، ژائو و همکاران از الگوریتم ژنتیک در بهینه‌سازی ماشین‌های بردار پشتیبان به منظور طبقه‌بندی داده‌های UCI استفاده

طول کروموزم به تعداد ویژگی‌هایی است که انتخاب خواهد شد و درایه‌های کروموزم شماره‌های ویژگی‌های انتخاب شده می‌باشد. پارامترهای ماشین‌های بردار پشتیبان نیز قبل از انتخاب ویژگی با بررسی چندین مقدار و انتخاب بهترین آن‌ها محاسبه شده است [۳۴]. محدودیت این روش نیاز به دانستن تعداد ویژگی‌های بهینه به عنوان اطلاعات از پیش تعریف شده در مسئله می‌باشد. از آنجایی که این پارامتر از قبل مشخص نیست، به ازای مقادیر مختلف آزمایش تکرار شده و زیر مجموعه ویژگی‌ها با بهترین دقت طبقه‌بندی انتخاب شد که البته این روش در فضای با ابعاد بالا امکان پذیر نیست.

در سال ۲۰۰۹، ژانگ و همکاران الگوریتمی برای سرعت بخشیدن به انتخاب ویژگی بر مبنای الگوریتم ژنتیک ارائه دادند [۱۶]. در این مقاله برای ارزیابی هر عضو در الگوریتم ژنتیک، ابتدا پارامترهای ماشین‌های بردار پشتیبان با الگوریتم جستجوی شبکه‌ای محاسبه و سپس با ارزیابی ۱۰ قسمتی، دقت محاسبه می‌شود. به علت حجم محاسباتی بالای این الگوریتم از تکنیک محاسباتی موازی سازی^۱ در الگوریتم ژنتیک و ماشین‌های بردار پشتیبان استفاده شده است [۱۶].

در سال ۲۰۱۲، سنتوس و همکاران از الگوریتم ژنتیک به منظور انتخاب ویژگی بر اساس روش فیلتر استفاده کردند و سه روش طبقه‌بندی ماشین‌های بردار پشتیبان، نزدیک‌ترین همسایگی و شبکه‌های عصبی به منظور ارزیابی نتایج پیاده‌سازی شد [۳۵].

از آنجایی که پارامترهای ماشین‌های بردار پشتیبان دارای تأثیر متقابل بر زیر مجموعه ویژگی‌های مورد استفاده در طبقه‌بندی است، راه حل بهینه در انجام طبقه‌بندی حل همزمان پارامترها و فضای ویژگی می‌باشد [۲۰]. با این وجود با بزرگ شدن فضای جستجو و پیچیده شدن آن، نیاز به استفاده از تکنیک‌های بهینه‌سازی قدرتمندی در این وضعیت مطرح می‌گردد. در سال‌های اخیر الگوریتم‌های فرا ابتکاری متنوعی برای حل این مسئله مانند الگوریتم‌های خرد جمعی [۱۷، ۱۹]، شبیه‌سازی تبرید تدریجی [۱۸] و الگوریتم ژنتیک [۱۵، ۲۰، ۳۶، ۳۷] توسط محققین مختلف ارائه شده است.

در حل همزمان انتخاب مدل و ویژگی توجه به ماهیت متفاوت این دو مسئله ضروری می‌باشد که در آن پارامترهای ماشین‌های بردار پشتیبان دارای ماهیتی پیوسته است، برخلاف ویژگی‌های ورودی که دارای ماهیتی گسسته می‌باشد. به منظور ادغام این دو مفهوم، دو راه حل در مطالعات ارائه شده است [۲۰، ۳۸]. در روش اول بردار ویژگی‌ها نیز در کنار پارامترها به صورت پیوسته مدل‌سازی شده و با

¹ Parallelization

گردان^۱ کروموزم‌های منتخب مشخص و وارد نسل بعد می‌شود. انتقال نخبه^۲ هر مرحله که مستقیماً به مرحله بعد منتقل می‌شود نیز به منظور حفظ نتایج مطلوب در نظر گرفته شده است.


یک تکنیک رایج مرحله تلفیق^۳، روش تک نقطه‌ای^۴ می‌باشد که در این تحقیق نیز مورد استفاده قرار گرفته است. تلفیق تک نقطه‌ای توسط انتخاب یک نقطه به صورت تصادفی در کروموزم و تعویض اطلاعات دو کروموزم والد از نقطه مشخص شده، صورت می‌پذیرد.

به منظور ارزیابی مناطق جدید در فضای جستجو، از جهش^۵ استفاده می‌شود تا الگوریتم قابلیت جستجوی تصادفی را نیز داشته باشد. عملگر جهش باینری^۶ با تغییر مقدار درایه‌هایی (۰ را به ۱ و بالعکس) که احتمال آنها از احتمال جهش بیشتر شده است، عمل می‌کند. این پروسه تکرار می‌شود تا شرط توقف (حداکثر تکرار و یا عدم تغییر بهترین مقدار در طی تکرارهای مشخص) برقرار شود [۲۱].

با توجه به انعطاف پذیری الگوریتم ژنتیک نسبت به دیگر روش‌های دیگر در زمینه بهینه‌سازی فرا ابتکاری و حساسیت کمتر آن به تعریف پارامترهای مبنایی، در این تحقیق از الگوریتم ژنتیک به منظور انتخاب مدل، انتخاب ویژگی و حل همزمان این دو مسئله استفاده گردید.

۴.۱. انتخاب مدل

در روش پیشنهادی این تحقیق، با در نظر گرفتن عملگرهای معمول در کدگذاری باینری و همچنین ذات باینری قسمت‌های بعدی، از کدگذاری باینری استفاده شده است. همچنین هر کروموزم نمایشگر دو پارامتر تنظیم و کرنل می‌باشد که با یک رشته از صفر و یک تعریف می‌شود (شکل ۲). طول کروموزم متناسب با محدوده تغییرات پارامترها و همچنین دقت مورد نیاز مسئله تعیین می‌گردد.



شکل ۲- نمایش باینری پارامترهای ماشین‌های بردار پشتیبان

برای ارزیابی کیفیت هر عضو، می‌بایست هر یک از دو قسمت کروموزم به عدد حقیقی تبدیل شود. برای این منظور، از رابطه (۶) استفاده می‌کنیم.

کردند [۴۰]. در همین سال چن و همکاران در پیش‌بینی ورشکستگی بانک‌ها از الگوریتم بهینه‌سازی ژنتیک به منظور بهبود عملکرد سیستم تصمیم‌گیری بر مبنای انتخاب زیرمجموعه ویژگی‌های بهینه و تعیین پارامترهای شبکه عصبی (پیش‌بینی کننده) استفاده شد [۴۱].

۴. تعیین طبقه‌بندی کننده بهینه ماشین‌های بردار پشتیبان بر مبنای الگوریتم ژنتیک

در سال‌های اخیر ماشین‌های بردار پشتیبان به عنوان یکی از کاراترین طبقه‌بندی کننده‌های پایدار در تصاویر فرا طیفی مطرح شده‌اند [۳]. یکی از عوامل موثر بر عملکرد ماشین‌های بردار پشتیبان، پارامترهای آن می‌باشند [۲۳]. انتخاب زیر مجموعه بهینه به عنوان ورودی طبقه‌بندی یک گام مهم دیگر در بهینه‌سازی ماشین‌های بردار پشتیبان به منظور طبقه‌بندی تصاویر فرا طیفی است. هرچند ماشین‌های بردار پشتیبان در فضای با ابعاد بالا پایدار می‌باشند ولی انتخاب زیرمجموعه بهینه از ویژگی‌ها می‌تواند با حذف ویژگی‌های اضافی و زائد عملکرد طبقه‌بندی کننده را از لحاظ دقت، سرعت و هزینه بهبود ببخشد [۱۶].

با توجه به عوامل تأثیرگذار بر عملکرد ماشین‌های بردار پشتیبان، به منظور تعیین یک سیستم طبقه‌بندی بهینه در فضای با ابعاد بالای تصاویر فرا طیفی، می‌بایست از یک تکنیک بهینه‌سازی قدرتمند بهره برد [۲۰]. الگوریتم‌های فرا ابتکاری، تکنیک‌های محاسباتی هستند که در یک پروسه تکراری با توجه به تابع هدفی که کیفیت راه‌حل را بیان می‌کند، راه‌حل‌های کاندید را بهبود می‌بخشند (بدون پیش فرضی راجع به مسئله) و معمولاً در فضای جستجوی بزرگ کارا عمل می‌کنند [۲۴]. در نتیجه این دسته الگوریتم‌ها گزینه‌ای مناسب در بهینه‌سازی سیستم طبقه‌بندی تصاویر فرا طیفی بر مبنای ماشین‌های بردار پشتیبان باشند.

الگوریتم ژنتیک یک نمونه از الگوریتم‌های فرا ابتکاری می‌باشد که با موفقیت در بسیاری از مسائل بهینه‌سازی در کاربردهای مختلف به کار گرفته شده است [۱۴، ۲۰، ۲۵]. این الگوریتم، روشی جمعیت مبنایی می‌باشد که در یک پروسه تکراری تکاملی کیفیت جمعیت را بهبود می‌بخشد. در این الگوریتم ابتدا می‌بایست راه‌حل را به صورت یک رشته باینری که کروموزم نامیده می‌شود، نمایش دهیم. در مرحله بعد جمعیت اولیه به صورت تصادفی ساخته و کیفیت آن به وسیله تابع هدف ارزیابی می‌شود.

سه عملگر اصلی در الگوریتم ژنتیک عبارتند از: انتخاب، تلفیق و جهش. پس از اندازه‌گیری کیفیت اعضاء، احتمال انتخاب هر عضو برای www.SID.ir تلفیق مشخص می‌شود و با استفاده از چرخ

¹ Roulette wheel

² Elite

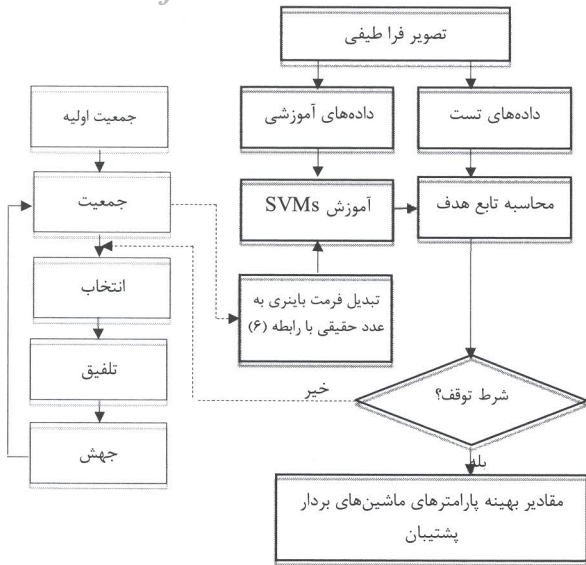
³ Crossover

⁴ Single Point

⁵ Mutation


⁶ Bit-Flip

Archive of SID



شکل ۳- فلوجارت تعیین مقادیر بهینه پارامترهای ماشین‌های بردار پشتیبان بر مبنای الگوریتم ژنتیک

استفاده شد که در آن هر عضو جمعیت به وسیله یک رشته از ۰ و ۱ به طول تعداد باندهای تصویر فرا طیفی نمایش داده می‌شود (شکل ۴). در این کروموزم، مقدار بیت ۰ به معنای حذف باند متناظر و ۱ به معنای انتخاب آن می‌باشد.



شکل ۴- نمایش کروموزم به منظور انتخاب ویژگی بر مبنای الگوریتم ژنتیک

به منظور تعریف معیاری برای ارزیابی کیفیت زیر مجموعه ویژگی‌های انتخاب شده، می‌بایست دو پارامتر دقت طبقه‌بندی و تعداد ویژگی‌های انتخاب شده را در نظر گرفت. به عبارت دیگر، طبقه‌بندی بر مبنای زیرمجموعه ویژگی‌های مطلوب دارای دقت طبقه‌بندی بالاتر و تعداد ویژگی‌های انتخاب شده کمتر می‌باشد. لذا تابع هدف با قرار دادن این دو معیار در یک تابع تعریف می‌شود و مسئله به بیشینه سازی معادله (۸) تبدیل می‌شود.

$$f = w \times accuracy + (1 - w) \times \frac{1}{N_f} \quad (8)$$

در این رابطه، f مقدار تابع هدف، w یک کمیت ثابت در بازه [۰، ۱] می‌باشد که وزن بین دقت طبقه‌بندی و تعداد ویژگی‌ها را مشخص می‌کند. همچنین $accuracy$ دقت طبقه‌بندی می‌باشد که با رابطه (۷) محاسبه می‌شود و N_f تعداد باندهای انتخاب شده می‌باشد. پس از ارزیابی اعضای جمعیت، سه عملگر انتخاب، تلفیق و جهش با توجه به کیفیت هر عضو عمل می‌کنند و مجدداً جمعیت

$$p = \min_p + \frac{\max_p - \min_p}{2^l - 1} \times d \quad (6)$$

که در این رابطه، p مقدار حقیقی پارامتر، \max_p و \min_p به ترتیب کمینه و بیشینه مقدار پارامتر، l تعداد بیت‌های نمایشگر پارامتر و d مقدار عددی رشته باینری در پایه ۱۰ می‌باشد.

در مرحله بعد ماشین‌های بردار پشتیبان به وسیله داده‌های آموزشی و پارامترهای محاسبه شده، آموزش دیده و ابر صفحه‌های مورد نظر ساخته می‌شوند. سپس به منظور محاسبه تابع هدف، داده‌های تست به وسیله ماشین‌های بردار پشتیبان آموزش دیده، طبقه‌بندی می‌شود و سپس ماتریس خطا تشکیل می‌شود. از ضرب کاپا به علت استفاده از تمام اطلاعات ماتریس خطا، به عنوان دقت طبقه‌بندی و تابع هدف در این بخش استفاده گردید که با رابطه (۷) تعریف می‌شود.

$$Kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad (7)$$

در این رابطه، N تعداد کل نمونه‌ها، r تعداد کلاس‌ها، x_{ii} عناصر روی قطر اصلی ماتریس خطا، x_{i+} جمع حاشیه ای سطرها و x_{+i} جمع حاشیه ای ستون‌ها می‌باشد. پس از ارزیابی اعضا، سه مرحله انتخاب، تلفیق و جهش بر روی فرمت باینری پارامترها انجام می‌شود و جمعیت جدید ساخته می‌شود و این مراحل تکرار می‌شود تا شرط توقف برقرار شود (شکل ۳).

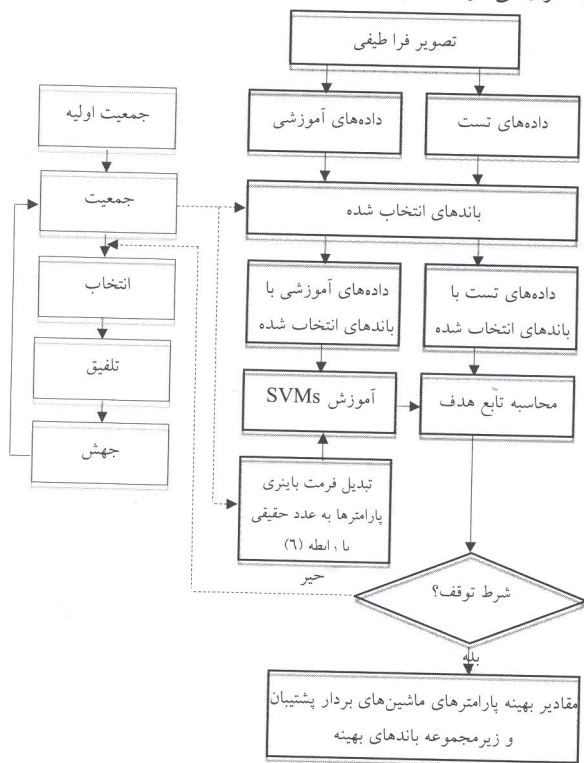
۴.۲. انتخاب ویژگی

انتخاب ویژگی یکی از مراحل تأثیرگذار در طبقه‌بندی تصاویر فرا طیفی بر مبنای ماشین‌های بردار پشتیبان می‌باشد که در آن با حذف باندهای نامربوط و نویزی، عملکرد طبقه‌بندی کننده را از لحاظ دقت و سرعت بهبود می‌بخشد.

در روش پیشنهادی این تحقیق، انتخاب ویژگی بر مبنای الگوریتم ژنتیک با استفاده از تکنیک پوششی پیاده‌سازی شده است. در مرحله پیش پردازش روش پیشنهادی ابتدا با حضور همه باندها، مقادیر در پروسه اصلی انتخاب ویژگی‌های بهینه، از کدگذاری باینری پارامترهای ماشین‌های بردار پشتیبان با روش جستجوی شبکه‌ای تعیین و این مقادیر در طول پروسه انتخاب ویژگی ثابت در نظر گرفته شدند.

Archive of SID

خطا تشکیل و دقت طبقه‌بندی با رابطه (۷) محاسبه می‌شود. سپس با توجه به قسمت اول هر عضو که بیانگر تعداد باندهای انتخابی است و دقت بدست آمده، مقدار تابع هدف با رابطه (۸) محاسبه می‌شود. در ادامه مشابه مسائل قبل، مراحل انتخاب، تلفیق و جهش انجام و این مراحل تکرار می‌شود تا شرط توقف برقرار شود (شکل ۷).



شکل ۷- فلوجارت تعیین مقادیر بهینه پارامترهای ماشین‌های بردار پشتیبان و زیرمجموعه بهینه باندها بر مبنای الگوریتم ژنتیک

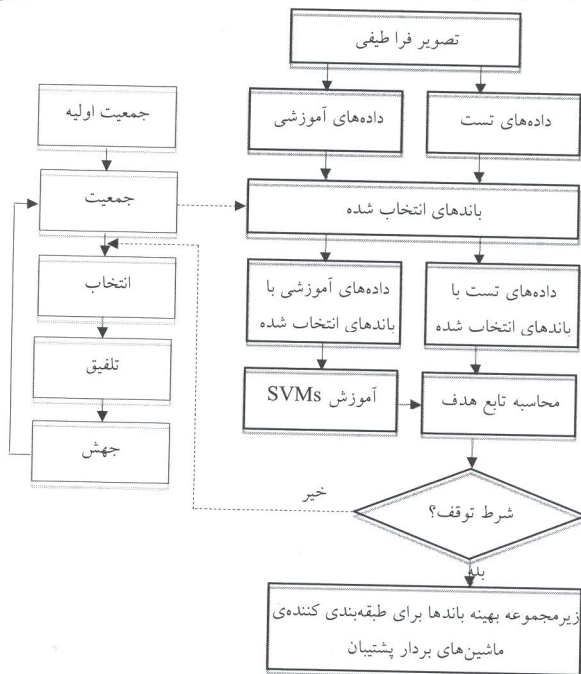
۵. نتایج عملی

به منظور ارزیابی توانایی روش‌های ارائه شده در این تحقیق، نسبت به پیاده‌سازی و به کارگیری آن‌ها در طبقه‌بندی تصویر فرا طیفی سنجنده AVIRIS اقدام گردید. نتایج حاصل در قالب سه گروه: انتخاب پارامترهای مدل، انتخاب ویژگی و حل همزمان هر دو شرح داده شده است. در ماشین‌های بردار پشتیبان از دو کرنل گوسین و پلی‌نومیال و دو روش چند کلاسه «یک در مقابل یک» و «یک در مقابل مابقی» استفاده شده است. به منظور مقایسه نتایج بدست آمده، الگوریتم شبیه‌سازی تبرید تدریجی نیز پیاده‌سازی شد.

۵.۱. مشخصات داده

برای پیاده سازی الگوریتم‌های ارائه شده از تصویر فرا طیفی مربوط به منطقه ای کشاورزی-جنگلی که توسط سنجنده AVIRIS در سال ۱۹۹۲ از شمال شرقی ایالت ایندیانا اخذ شده، استفاده گردید. به دلیل شباهت بین کلاس‌ها، این تصویر دارای پیچیدگی‌هایی برای طبقه بندی است. این تصویر دارای ۲۲۰ باند می‌باشد که ۱۵ باند


ساخته شده توسط تابع هدف ارزیابی خواهد شد و این پروسه تکرار می‌شود تا شرط توقف برقرار گردد (شکل ۵).



شکل ۵- فلوجارت انتخاب زیر مجموعه بهینه باندها بر مبنای الگوریتم ژنتیک

۴.۳. حل همزمان پارامتر و ویژگی

با توجه به هدف این تحقیق که حل همزمان تعیین پارامتر و انتخاب ویژگی در این بخش می‌باشد، در روش پیشنهادی ویژگی‌ها و پارامترهای کرنل در کروموزم به صورت باینری کدگذاری می‌شود. هر کروموزم از سه قسمت تشکیل شده است: ویژگی‌ها، پارامتر تنظیم و پارامتر کرنل (شکل ۶). طول قسمت اول به تعداد باندهای تصویر و طول دو قسمت آخر به دقت مورد نیاز برای پارامترها بستگی دارد.



شکل ۶- نمایش کروموزم به منظور حل همزمان انتخاب ویژگی و پارامترهای کرنل

در این مرحله بعد از ساخت جمعیت اولیه به صورت تصادفی، به منظور ارزیابی اعضای جمعیت، با توجه به قسمت اول کروموزم (ویژگی‌های انتخاب شده) در داده‌های آموزشی با باندهای انتخاب شده استخراج می‌شود. سپس دو قسمت پارامترها با استفاده از رابطه (۶) به مقدار حقیقی تبدیل می‌شود و ماشین‌های بردار پشتیبان با استفاده از داده‌های آموزشی با باندهای منتخب و پارامترهای بدست آمده آموزش می‌شود. در مرحله بعد داده‌های تست توسط ماشین‌های بردار پشتیبان آموزش دیده طبقه‌بندی می‌شوند و ماتریس

Archive of SID

باشند. همچنین پارامتر دمای اولیه و نرخ کاهش دما، به ترتیب ۱۰۰۰ و ۰/۰۱ در نظر گرفته شد.

۵.۳. ارزیابی نتایج

یکی از پارامترهای تأثیرگذار در طبقه بندی، تعیین معیاری برای ارزیابی نتایج می‌باشد. برای این منظور ابتدا ۵۰٪ داده‌ها به صورت تصادفی به داده آموزشی و ۵۰٪ باقیمانده به داده تست تخصیص داده شد. ماشین‌های بردار پشتیبان بر روی داده‌های آموزشی، آموزش دیده و ماتریس خطا با استفاده از داده تست تشکیل داده شد. دو معیار کلی ارزیابی دقت که از ماتریس خطا محاسبه می‌شوند، عبارتند از: ضریب کاپا که با رابطه (۷) محاسبه و دقت کلی که به رابطه (۹) محاسبه می‌گردد.

$$\text{Overall Accuracy} = \frac{\sum_{i=1}^r x_{ii}}{N} \times 100 \quad (9)$$


در این رابطه، N تعداد کل نمونه‌ها، r تعداد کلاس‌ها و x_{ii} عناصر روی قطر اصلی ماتریس خطا می‌باشد معیار دیگری که برای بررسی نتایج استفاده گردید، دقت برای هر کلاس می‌باشد که با رابطه (۱۰) محاسبه می‌شود.

$$k_i = \frac{N \times x_{ii} - x_{+i} \times x_{i+}}{N \times x_{i+} - x_{+i} \times x_{i+}} \quad (10)$$

از آنجایی که ضریب کاپا و دقت کلی معیارهایی کلی برای طبقه بندی می‌باشد، استفاده از دقت هر کلاس می‌تواند به صورت مناسب نمایانگر نحوه پخش خطا در بین کلاس‌ها باشد. از این رو در این تحقیق در کنار معیارهای کلی، از دقت هر کلاس نیز استفاده گردید. در ادامه نتایج بدست آمده در ۳ رویکرد بیان شده، ارائه گردیده است.

۵.۳.۱. نتایج انتخاب پارامترهای بهینه مدل

به منظور ارزیابی اثر هر یک از پارامترهای ماشین‌های بردار پشتیبان (C, d) بر روی دقت طبقه بندی تصاویر فرا طیفی، روند ذیل انجام پذیرفت. ابتدا در کرنل گوسین، پارامتر کرنل ثابت در نظر گرفته شد و دقت طبقه بندی بر اساس تغییرات پارامتر C محاسبه شد (شکل ۸-الف). سپس با تغییر پارامتر σ و ثابت نگه داشتن پارامتر C ، اثر پارامتر کرنل گوسین اندازه گیری شد (شکل ۸-ب). در نهایت در کرنل پلی‌نومیال، اثر درجه آن بر دقت طبقه بندی بدست آمد (شکل ۸-ج).



(الف)

نویزی و ۲۰ باند جذبی آب حذف گردید و در نهایت از ۱۸۵ باند باقیمانده استفاده شد. تصویر دارای 145×145 پیکسل، دقت رادیومتریکی ۸ بیت و دارای ۱۶ کلاس می‌باشد که برخی از کلاس‌ها به دلیل کوچک بودن تعداد نمونه‌های آموزشی برای ارزیابی مناسب نمی‌باشد. به همین علت از ۹ کلاس که بیشترین داده را در مقایسه با دیگر کلاس‌ها داشتند، در این تحقیق استفاده شده است.

۵.۲. تنظیم پارامترها

به منظور تعیین پارامترهای ماشین‌های بردار پشتیبان و فضای ویژگی، پارامترهای الگوریتم ژنتیک می‌بایست تنظیم شوند. پارامترهای مورد استفاده در الگوریتم ژنتیک به صورت تجربی و با آزمون و خطا طبق جدول ۱ بدست آمدند.


تعداد بیت‌های مورد نیاز برای نمایش پارامتر تنظیم، پارامتر کرنل گوسین و درجه پلی‌نومیال به ترتیب ۲۰، ۲۲ و ۴ تعیین شدند. در پروسه انتخاب ویژگی و حل همزمان تعیین پارامترها و انتخاب ویژگی با در نظر گرفتن ابعاد بزرگ فضای جستجو و به منظور تعیین جمعیت اولیه مناسب ابتدا یک جمعیت با ابعاد بزرگ به صورت اولیه ساخته می‌شود و سپس اعضای برتر به عنوان جمعیت اولیه انتخاب می‌شود. همچنین در تابع هدف، مطابق معادله (۸) با توجه به اهمیت بیشتر دقت نسبت به تعداد ویژگی، $w=0.8$ در نظر گرفته شد.

جدول ۱- پارامترهای الگوریتم ژنتیک


مقدار	پارامتر	روش
۵	سایز جمعیت	
۴۲	طول کروموزم (گوسین)	انتخاب مدل
۲۴	طول کروموزم (پلی‌نومیال)	
۳۰۰	سایز جمعیت اولیه	
۳۰	سایز جمعیت	انتخاب ویژگی
۱۸۵	طول کروموزم	
۵۰۰	سایز جمعیت اولیه	حل همزمان
۵۰	سایز جمعیت	تعیین پارامتر و
۲۲۷	طول کروموزم (گوسین)	انتخاب ویژگی
۲۰۹	طول کروموزم (پلی‌نومیال)	
۰/۵	نرخ تلفیق	پارامترهای عمومی
۰/۰۵	نرخ جهش	
۳۰۰	حداکثر تکرار	

پارامترهای الگوریتم شبیه‌سازی تبرید تدریجی نیز به گونه‌ای تنظیم شده‌اند که دارای حجم محاسباتی یکسان با الگوریتم ژنتیک

Archive of SID





شکل ۹- نمودار همگرایی تعیین پارامترهای ماشین‌های بردار پشتیبان بر مبنای الگوریتم شبیه‌سازی تبرید تدریجی برای کرنل گوسین و پلی‌نومیال در دو حالت یک در مقابل یک و یک در مقابل مابقی



شکل ۱۰- نمودار همگرایی تعیین پارامترهای ماشین‌های بردار پشتیبان بر مبنای الگوریتم ژنتیک برای کرنل گوسین و پلی‌نومیال در دو حالت یک در مقابل یک و یک در مقابل مابقی

مقادیر بهینه پارامترها و دقت متناظر با آن، برای دو کرنل گوسین و پلی‌نومیال در دو حالت چند کلاس، یک در مقابل یک و یک در مقابل مابقی در جدول ۲ ارائه شده است. همچنین دقت هر کلاس با رابطه (۱۰) محاسبه و در جدول ۲ ارائه شده است. همان طور که در جدول ۲ نشان داده شده است، دقت کلی طبقه‌بندی در روش‌های الگوریتم ژنتیک، شبیه‌سازی تبرید تدریجی و جستجوی شبکه‌ای نزدیک به هم می‌باشد. با توجه به حجم محاسباتی کمتر الگوریتم ژنتیک، سرعت همگرایی بالا و عدم جستجوی جامع، می‌تواند در زمان محاسباتی کمتر، به دقتی نزدیک و یا بالاتر از الگوریتم جستجوی شبکه‌ای و شبیه‌سازی تبرید تدریجی برسد. ولی نحوه پخش خطا در سه روش متفاوت است. از این رو در برخی از کلاس‌ها، دقت تعیین پارامتر بر مبنای الگوریتم ژنتیک، در برخی الگوریتم شبیه‌سازی تبرید تدریجی و در برخی کلاس‌ها الگوریتم جستجوی شبکه‌ای به دقت بالاتری رسیده است.



شکل ۸- تأثیر پارامترهای ماشین‌های بردار بر دقت طبقه‌بندی، الف) تأثیر پارامتر تنظیم (ب) تأثیر پارامتر کرنل گوسین (ج) تأثیر درجه پلی‌نومیال

همان طور که در شکل ۸ دیده می‌شود، هر سه پارامتر تأثیر بسزایی بر عملکرد طبقه‌بندی کننده دارند و در نتیجه تعیین مقدار بهینه این پارامترها از تأثیر بسزایی در دقت طبقه‌بندی برخوردار می‌باشد. از این رو در این مرحله از جستجوی شبکه‌ای، الگوریتم شبیه‌سازی تبرید تدریجی و الگوریتم ژنتیک برای تعیین مقادیر بهینه پارامترهای دو کرنل گوسین و پلی‌نومیال استفاده گردید. به منظور تعیین پارامترهای ماشین‌های بردار پشتیبان مبتنی بر این سه روش، پارامترهای C و σ و d به ترتیب در بازه‌های $[2^{-5}, \dots, 2^{12}]$ ، $[2^{-5}, \dots, 2^{10}]$ و $[1, \dots, 10]$ در نظر گرفته شدند. نمودار همگرایی انتخاب مدل بر مبنای الگوریتم شبیه‌سازی تبرید تدریجی و الگوریتم ژنتیک به ترتیب در شکل‌های ۹ و ۱۰ نمایش داده شده است. نمودار همگرایی الگوریتم ژنتیک حاکی از همگرایی سریع آن (حداکثر ۳۰ تکرار) به مقدار بهینه می‌باشد؛ در حالی که الگوریتم شبیه‌سازی تبرید تدریجی نیاز به تکرارهای بیشتری برای همگرایی دارد.

به منظور مقایسه نتایج بدست آمده، روش کلاسیک جستجوی شبکه‌ای پیاده سازی گردید. تغییر نمایی پارامترهای تنظیم و کرنل گوسین در این روش به صورت تجربی بدست آمده است. ابتدا دقت طبقه‌بندی با تمام زوج پارامترها در هر کرنل محاسبه و در نهایت زوج پارامتر با بیشترین دقت طبقه‌بندی به عنوان مقادیر نهایی ماشین‌های بردار پشتیبان انتخاب شدند. از آنجایی که الگوریتم جستجوی شبکه‌ای به منظور تعیین مقادیر بهینه پارامترها جستجوی جامع انجام می‌دهد، می‌توان انتظار داشت که دقت بدست آمده از این روش، دقتی نزدیک به بهینه باشد و در نتیجه معیار مناسبی به منظور مقایسه با الگوریتم ژنتیک و شبیه‌سازی تبرید تدریجی باشد.

Archive of SID

جدول ۲- نتایج تعیین پارامترهای بهینه بر مبنای الگوریتم ژنتیک، شبیه‌سازی تدریجی و جستجوی شبکه‌ای


تکنیک	پارامتر تنظیم	پارامتر کرنل	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	کلاس ۶	کلاس ۷	کلاس ۸	کلاس ۹	کاپا	ضریب کلی
شبکه‌ای	۶۴	۲۰۴۸	۰/۸۱۶	۱	۱	۰/۶۵۳	۰/۹۸۲	۰/۵۶۹	۰/۸۶۸	۰/۸۷۲	۰/۵۹۴	۰/۸۲	۸۴/۸۳
	۳۱۳/۳۰۴	۲۲۰۸	۰/۷۷	۱	۱	۰/۷۰۲	۰/۹۸۲	۰/۶۴۲	۰/۸۶۹	۰/۸۸۲	۰/۵۶۲	۰/۸۲۸	۸۵/۴۷
	۲۲۰/۲۲	۲۴۸۸/۶۱	۰/۷۸۵	۱	۱	۰/۷	۰/۹۸۲	۰/۶۴۲	۰/۸۶۸	۰/۸۷۲	۰/۵۹۵	۰/۸۲۸	۸۵/۴۷
شبکه‌ای	۱۰۲۴	۴۰۹۶	۰/۷۲۲	۱	۱	۰/۷۹	۱	۰/۴۹۲	۰/۹۱۲	۰/۸۱۹	۰/۷۲۵	۰/۸۱۹	۸۴/۶۲
	۹۳۲/۰۴۴	۳۸۵۲/۲۶۲	۰/۷۲۳	۱	۱	۰/۷۶۷	۱	۰/۵۴	۰/۹۱۲	۰/۸۰۸	۰/۷۲۵	۰/۸۱۹	۸۴/۶۲
	۹۵۰/۹۳	۳۸۹۱/۹۵	۰/۷۲۳	۱	۱	۰/۷۶۷	۱	۰/۵۴۱	۰/۹۱۲	۰/۸۱۹	۰/۷۲۵	۰/۸۲۱	۸۴/۳۳
شبکه‌ای	۶۴	۳	۰/۷۳۴	۰/۹۷۱	۱	۰/۵۴۶	۰/۹۶۴	۰/۴۵۳	۰/۹۱۲	۰/۶۷۲	۰/۶۵۸	۰/۷۴۶	۷۸/۴۲
	۶۵/۰۲	۳	۰/۷۳۴	۰/۹۷۱	۱	۰/۵۴۶	۰/۹۶۴	۰/۴۵۳	۰/۹۱۲	۰/۶۷۲	۰/۶۵۸	۰/۷۴۶	۷۸/۴۲
	۶۷/۶۱	۳	۰/۷۳۴	۰/۹۷۱	۱	۰/۵۴۶	۰/۹۶۴	۰/۴۵۳	۰/۹۱۲	۰/۶۷۲	۰/۶۵۸	۰/۷۴۶	۷۸/۴۲
شبکه‌ای	۵۱۲	۸	۰/۵۹۷	۰/۹۴۱	۱	۰/۵۱۷	۱	۰/۵۱۸	۰/۷۳۶	۰/۴۸۹	۰/۶۵۷	۰/۶۷۷	۷۲/۴۴
	۲۰۹/۳۷	۷/۶۶۹	۰/۵۹۸	۰/۹۴۱	۱	۰/۵۱۷	۱	۰/۵۴۵	۰/۷۳۶	۰/۴۸۹	۰/۶۵۶	۰/۶۸	۷۲/۶۵
	۶۶۱	۷/۶	۰/۵۹۸	۰/۹۴۱	۱	۰/۵۱۷	۱	۰/۵۴۵	۰/۷۳۶	۰/۴۸۹	۰/۶۵۶	۰/۶۸	۷۲/۶۵

الگوریتم شبیه‌سازی تدریجی و ژنتیک، معیارهای ضریب کاپا، دقت کلی و دقت هر کلاس، به کار گرفته شد (جدول ۳). نتایج نشان می‌دهند با حذف ویژگی‌های اضافی نه تنها سرعت طبقه‌بندی بالا می‌رود بلکه دقت آن نیز افزایش می‌یابد.


۵.۳.۲. نتایج انتخاب ویژگی

در این قسمت هدف یافتن زیرمجموعه‌ای از ویژگی‌های بهینه تصویر فرا طیفی به منظور طبقه‌بندی با بیشترین کارایی می‌باشد. در این قسمت پارامترهای ماشین‌های بردار پشتیبان، در حضور تمام باندها و با استفاده از الگوریتم جستجوی شبکه‌ای بدست آمده و مقدار آن‌ها در طول پروسه انتخاب ویژگی ثابت در نظر گرفته می‌شود.

شکل ۱۱ و ۱۲ به ترتیب نمودار همگرایی الگوریتم شبیه‌سازی تدریجی و الگوریتم ژنتیک برای ۴ مورد در نظر گرفته شده را نشان می‌دهد. همان طور که در این دو شکل دیده می‌شود، انتخاب ویژگی موجب بهبود قابل توجهی بر دقت کرنل‌های پلی‌نومیال و گوسین می‌شود. با توجه به شکل‌های ۹ و ۱۰، کرنل گوسین دقت بسیار بالاتری نسبت به کرنل پلی‌نومیال دارد ولی پروسه انتخاب ویژگی با تأثیر بالایی که بر کرنل پلی‌نومیال داشته، باعث نزدیکی دو کرنل در دو حالت یک در مقابل یک و یک در مقابل مابقی گردیده است که حاکی از تأثیر بیشتر انتخاب ویژگی بر کرنل پلی‌نومیال نسبت به کرنل گوسین می‌باشد. نکته دیگر تفاوت در سرعت همگرایی دو کرنل می‌باشد. با توجه به شکل ۱۲، کرنل گوسین در تکرارهای کمتری به دقت بهینه همگرا می‌شوند، از طرف مقابل دقت کرنل پلی‌نومیال تا تکرارهای پایانی افزایش پیدا می‌کند و به تکرارهای بیشتری برای رسیدن به ثبات احتیاج دارد.



شکل ۱۱-نمودار همگرایی انتخاب ویژگی بر مبنای الگوریتم شبیه‌سازی تدریجی تدریجی برای کرنل گوسین و پلی‌نومیال در دو حالت یک در مقابل یک و یک در مقابل مابقی




شکل ۱۲-نمودار همگرایی انتخاب ویژگی بر مبنای الگوریتم ژنتیک برای کرنل گوسین و پلی‌نومیال در دو حالت یک در مقابل یک و یک در مقابل مابقی

جدول ۳- نتایج حاصل از انتخاب ویژگی بر مبنای الگوریتم ژنتیک و شبیه‌سازی تبرید تدریجی در مقایسه با حضور همه باندها

تکنیک	تعداد باندها	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	کلاس ۶	کلاس ۷	کلاس ۸	کلاس ۹	ضریب کاپا	دقت کلی
همه باندها	۱۸۵	۰/۸۱۶	۱	۱	۰/۶۵۳	۰/۹۸۲	۰/۵۶۹	۰/۸۶۸	۰/۸۷۲	۰/۵۹۴	۰/۸۲	۸۴/۸۳
	SA	۰/۸۲	۱	۱	۰/۷۴۵	۱	۰/۶۴۱	۰/۸۶۸	۰/۹۰۸	۰/۶۲۸	۰/۸۵۳	۸۷/۶۱
	GA	۰/۸۵۱	۱	۱	۰/۷۲۳	۱	۰/۷۱۷	۰/۸۶۸	۰/۸۸۷	۰/۶۹۴	۰/۸۶۴	۸۸/۴۶
همه باندها	۱۸۵	۰/۷۲۲	۱	۱	۰/۷۸۹	۱	۰/۴۹۲	۰/۹۱۲	۰/۸۱۹	۰/۷۲۵	۰/۸۱۹	۸۴/۶۲
	SA	۰/۷۸۳	۱	۱	۰/۷۴۷	۱	۰/۴۶۹	۰/۹۱۲	۰/۸۳	۰/۷۲۵	۰/۸۲۳	۸۵/۰۴
	GA	۰/۸۱۶	۱	۱	۰/۷۲۵	۱	۰/۵۱۴	۰/۹۱۲	۰/۸۴۴	۰/۷۵۹	۰/۸۳۶	۸۶/۱۱
همه باندها	۱۸۵	۰/۷۳۴	۱	۰/۹۷۱	۰/۵۴۶	۰/۹۶۴	۰/۴۵۳	۰/۹۱۲	۰/۶۷۲	۰/۶۵۸	۰/۷۴۶	۷۸/۴۲
	SA	۰/۷۴۹	۱	۰/۹۷۱	۰/۶۵۹	۰/۹۸۲	۰/۴۸۵	۰/۹۱۲	۰/۷۸۵	۰/۷۹۵	۰/۸۰۵	۸۳/۱۲
	GA	۰/۷۹۷	۱	۱	۰/۶۳۳	۱	۰/۶۳۶	۰/۹۱۲	۰/۷۷۳	۰/۸۲۷	۰/۸۲۵	۸۵/۰۴
همه باندها	۱۸۵	۰/۵۹۷	۰/۹۴۱	۱	۰/۵۱۷	۱	۰/۵۱۸	۰/۷۳۶	۰/۴۸۹	۰/۶۵۷	۰/۶۷۷	۷۲/۴۴
	SA	۰/۷۸۳	۰/۹۴۱	۱	۰/۶۱۴	۰/۹۸۲	۰/۵۵۹	۰/۸۲۳	۰/۷۴۴	۰/۶۹۱	۰/۷۹۶	۸۱/۶۲
	GA	۰/۸۰۱	۱	۰/۹۵۸	۰/۶۷۹	۱	۰/۶۶۱	۰/۸۲۵	۰/۷۳۱	۰/۷۹	۰/۸۱۲	۸۳/۹۷

ژنتیک را برای ۴ وضعیت در نظر گرفته شده نشان می‌دهند. با توجه به این دو شکل با در نظر گرفتن همزمان پارامترها و ویژگی‌ها، دقت طبقه‌بندی بدست آمده بیشتر تحت تأثیر نوع کرنل می‌باشد و تأثیر نوع روش چند کلاسه کاهش یافته است. از طرف دیگر با توجه به بزرگ بودن ابعاد فضای جستجو در این بخش، زمان یافتن جواب بهینه نیز در هر ۴ وضعیت افزایش یافت.

به منظور ارزیابی دقیق‌تر نتایج، مقادیر پارامترهای ماشین‌های بردار پشتیبان، تعداد باندهای انتخابی، ضریب کاپا و دقت کلی به عنوان معیارهای دقت کلی و دقت کلاس‌ها به صورت مجزا در جدول ۴ ارائه شده است.



شکل ۱۳- نمودار همگرایی تعیین همزمان پارامترهای ماشین‌های بردار پشتیبان و زیرمجموعه بهینه ویژگی بر مبنای الگوریتم شبیه‌سازی تبرید تدریجی برای کرنل گوسین و پلی‌نومیال در دو حالت یک در مقابل یک و یک در مقابل مابقی


در تمام موارد الگوریتم ژنتیک به دقتی بالاتر از الگوریتم شبیه‌سازی تبرید تدریجی دست یافت. همچنین در نتایج بدست آمده از الگوریتم ژنتیک با کرنل گوسین در حالت یک در مقابل یک، مرحله انتخاب ویژگی با حذف ۸۳ باند اضافی، توانست دقت طبقه‌بندی را نسبت به حالتی که تمام باندها حضور دارند، ۰/۴٪ بهبود ببخشد. در مورد کرنل گوسین و در حالت یک در مقابل همه، ۸۶ باند اضافی حذف و دقتی ۰/۲٪ بالاتر از زمان حضور همه باندها حاصل گردید.

کرنل پلی‌نومیال با حذف باندهای بیشتر، افزایش دقت بیشتری نسبت به کرنل گوسین حاصل نمود. در حالت چند کلاسه‌ی یک در مقابل یک، دقت طبقه‌بندی با حذف ۹۱ باند اضافی، ۰/۷٪ افزایش یافت. در بین کرنل‌های در نظر گرفته شده، کرنل پلی‌نومیال در حالت یک در مقابل مابقی، با حذف بیشترین باندهای اضافی، بالاترین افزایش دقت را داشت. در این مورد، بیش از نیمی از باندها (۱۰۴ باند) حذف گردید و دقت ۰/۱۱٪ افزایش یافت. همچنین دقت هر کلاس هم پس از انتخاب ویژگی در اکثر موارد افزایش بهبود قابل توجهی نسبت به حضور همه باندها داشته است.

۵.۳.۳. نتایج حل همزمان انتخاب مدل و ویژگی

با توجه به تأثیر مقدار پارامترها در نحوه انتخاب زیرمجموعه بهینه ویژگی‌ها و بالعکس، در این مرحله نسبت به تعیین همزمان مقادیر پارامترها و ویژگی‌ها اقدام گردید. شکل‌های ۱۳ و ۱۴ به ترتیب نمودار همگرایی الگوریتم شبیه‌سازی تبرید تدریجی و الگوریتم

Archive of SID



شکل ۱۴- نمودار همگرایی تعیین همزمان پارامترهای ماشین‌های بردار پشتیبان و زیر مجموعه بهینه ویژگی بر مبنای الگوریتم ژنتیک برای کرنل گوسین و پلی‌نومیال در دو حالت یک در مقابل یک و یک در مقابل مابقی

جدول ۴- نتایج حاصل از حل همزمان تعیین پارامترها و انتخاب ویژگی بر مبنای الگوریتم ژنتیک و شبیه‌سازی تبرد تدریجی

وضعیت	روش	تعداد باندها	پارامتر تنظیم	پارامتر کرنل	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	کلاس ۶	کلاس ۷	کلاس ۸	کلاس ۹	ضریب کاپا	دقت کلی
گوسین - یک در مقابل یک	SA	۸۱	۶۲۷/۳۳۹	۱۵۵۰/۵۱	۰/۷۸۸	۱	۱	۰/۷۴۷	۰/۹۸۲	۰/۶۹۱	۰/۸۶۸	۰/۸۸۵	۰/۶۲۶	۰/۸۴۶	۸۶/۹۶
گوسین - یک در مقابل مابقی	GA	۹۰	۱۸۱/۱۶	۲۰۵۷/۵	۰/۸۵۱	۱	۱	۰/۷۶۹	۱	۰/۶۴۴	۰/۹۱۲	۰/۹۱	۰/۷۹۴	۰/۸۷۶	۸۹/۵۳
گوسین - یک در مقابل مابقی	SA	۷۸	۲۸۹/۷۵۳	۲۸۲۹/۳۶	۰/۸۵	۱	۱	۰/۷۶۹	۱	۰/۵۶۸	۰/۹۱۲	۰/۸۰۹	۰/۷۹۳	۰/۸۴۶	۸۶/۹۶
پلی‌نومیال - یک در مقابل یک	GA	۹۸	۵۶۵/۶۷	۲۰۹۳/۲۳	۰/۸۵۲	۱	۱	۰/۷۶۸	۱	۰/۶۹	۰/۹۱۳	۰/۸۸۷	۰/۷۲۵	۰/۸۷۱	۸۹/۱
پلی‌نومیال - یک در مقابل یک	SA	۹۳	۶۲۷/۳۳۹	۵/۱۹۶	۰/۷۹۸	۰/۹۷	۱	۰/۵۲۲	۰/۹۶۴	۰/۶۵۷	۰/۹۱۲	۰/۷۰۵	۰/۷۲۷	۰/۷۸۴	۸۱/۶۲
پلی‌نومیال - یک در مقابل مابقی	GA	۸۹	۴۰۴/۱	۴/۶	۰/۷۳۷	۰/۹۷۱	۱	۰/۶۱۱	۱	۰/۶۸۹	۰/۹۱۲	۰/۸۳۱	۰/۸۲۸	۰/۸۲۹	۸۵/۴۷
پلی‌نومیال - یک در مقابل مابقی	SA	۸۸	۹۵۵/۱۸۴	۴/۹۶۸	۰/۷۶۵	۰/۹۴۱	۱	۰/۵۴۸	۱	۰/۶۳۴	۰/۷۸	۰/۶۸۹	۰/۸۶۹	۰/۷۸	۸۱/۲
پلی‌نومیال - یک در مقابل مابقی	GA	۸۹	۷۳۸/۱۵	۱۰	۰/۸۱۸	۰/۹۴	۱	۰/۵۹۶	۱	۰/۷۱۲	۰/۸۲۴	۰/۷۶۹	۰/۷۹۲	۰/۸۱۴	۸۴/۱۹

انتخاب ویژگی بالاترین دقت را در ۴ وضعیت دارد. همچنین می‌توان از شکل ۱۲ نتیجه گرفت با توجه به افزایش دقت بیشتر در حل همزمان برای کرنل گوسین، تأثیر پارامترها بر فضای ورودی در این کرنل بیشتر از کرنل پلی‌نومیال می‌باشد.

۶. نتیجه‌گیری و پیشنهادات

در این تحقیق سه رویکرد در ایجاد یک طبقه‌بندی کننده بهینه مبتنی بر ماشین‌های بردار پشتیبان بر مبنای الگوریتم ژنتیک ارائه گردید. نتایج حاصل در مقایسه با الگوریتم شبیه‌سازی تبرد تدریجی، بیانگر برتری الگوریتم ژنتیک به خصوص با افزایش ابعاد فضای جستجو می‌باشد. همچنین نتایج بهینه با به‌کارگیری الگوریتم ژنتیک در حل همزمان تعیین پارامتر و انتخاب ویژگی حاصل می‌شود که در آن با انتخاب باندهای کمتر، دقت بالاتر حاصل شد. از این رو با استفاده از طبقه‌بندی کننده‌ی کارا و قدرتمند ماشین‌های بردار پشتیبان در کنار الگوریتم بهینه‌سازی و فرا ابتکاری ژنتیک، می‌تواند یک سیستم طبقه‌بندی ترکیبی بهینه برای تصاویر فرا طیفی طراحی کرد.

مقایسه نتایج این بخش با مراحل قبل، حاکی از رسیدن به دقت‌های بالاتری در هر چهار وضعیت می‌باشد که نشان از بهینه بودن نتایج در حل همزمان می‌باشد. همچنین مقایسه نتایج حاصل از دو روش حاکی از برتری بیشتر الگوریتم شبیه‌سازی تبرد تدریجی نسبت به الگوریتم ژنتیک می‌باشد که بیانگر توانایی الگوریتم ژنتیک در فضای جستجوی پیچیده می‌باشد.

۵.۳.۴. مقایسه نتایج





به منظور مقایسه بهتر بین نتایج بدست آمده، منحنی همگرایی الگوریتم ژنتیک در سه رویکرد ارائه شده (تعیین پارامترها، انتخاب ویژگی و حل همزمان هر دو) را بر روی ۴ وضعیت در نظر گرفته شده، در شکل ۱۵ نمایش داده شد. همان‌طور که در این شکل دیده می‌شود، تعیین پارامترهای بهینه ماشین‌های بردار پشتیبان در تکرارهای اولیه به همگرایی رسیده و نسبت به دو رویکرد دیگر بهبود کمتری در دقت ایجاد کرده است. در حالی که، انتخاب ویژگی با توجه به استفاده از پارامترهای بدست آمده از جستجوی شبکه‌ای دقت را نسبت به تعیین پارامترها افزایش داده است. در نهایت حل همزمان پارامترها و

Archive of SID

پشتیبان در تصاویر فرا طیفی استفاده گردد. همچنین بهینه‌سازی اتوماتیک پارامترهای الگوریتم ژنتیک که در این نوشته با آزمون و خطا بدست آمد، از موضوعات دیگر پیش رو می‌باشد.

پیشنهاد می‌شود در تحقیقات آینده با توجه به بزرگ بودن فضای جستجوی مسئله ارائه شده از الگوریتم‌های فرا ابتکاری دیگر از قبیل روش‌های مبنی بر خرد جمعی به منظور بهینه‌سازی ماشین‌های بردار

حل همزمان تعیین پارامترها و انتخاب ویژگی - - - انتخاب ویژگی - - - تعیین پارامترها



شکل ۱۵-مقایسه نتایج حاصل از الگوریتم ژنتیک در سه رویکرد ارائه شده بر روی الف) گوسین، یک در مقابل یک ب) گوسین، یک در مقابل مابقی ج) پلی‌نومیال، یک در مقابل یک د) پلی‌نومیال، یک در مقابل مابقی

مراجع

- [1]. C. Chang, *Hyperspectral data exploitation: theory and applications*: Wiley-Blackwell, 2007.
- [2]. G. Hughes, "On the mean accuracy of statistical pattern recognizers," *IEEE Transactions on Information Theory*, vol. 14, pp. 55-63, 2002.
- [3]. G. Camps-Valls and L. Bruzzone, "Kernel-based methods for hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, pp. 1351-1362, 2005.
- [4]. P. Du, K. Tan, W. Zhang, and Z. Yan, "ANN Classification of OMIS Hyperspectral Remotely Sensed Imagery: Experiments and Analysis," *Congress on Image and Signal Processing*, pp. 692-696, 2008.
- [5]. T. Waheed, R. Bonnell, S. Prasher, and E. Paulet, "Measuring performance in precision agriculture: CART--A decision tree approach," *Agricultural water management*, vol. 84, pp. 173-185, 2006.
- [6]. J. Ham, Y. Chen, M. Crawford, and J. Ghosh, "Investigation of the random forest framework for classification of hyperspectral data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, pp. 492-501, 2005.
- [7]. F. Melgani and L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, pp. 1778-1790, 2004.

- [8]. C. Dai, X. Huang, and G. Dong, "Support Vector Machine for Classification of Hyperspectral Remote Sensing Imagery," *Fourth International Conference on Fuzzy System and Knowledge Discovery*, pp. 77-80, 2007.
- [9]. B. Guo, S. Gunn, R. Damper, and J. Nelson, "Customizing kernel functions for SVM-based hyperspectral image classification," *IEEE Transactions on Image Processing*, vol. 17, pp. 622-629, 2008.
- [10]. P. Watanachaturaporn, M. Arora, and P. Varshney, "Hyperspectral image classification using support vector machines: A comparison with decision tree and neural network classifiers," 2006.
- [11]. S. Arlot and A. Celisse, "A survey of cross-validation procedures for model selection," *Statistics Surveys*, vol. 4, pp. 40-79, 2010.
- [12]. X. Zhang, X. Chen, and Z. He, "An ACO-based algorithm for parameter optimization of support vector machines," *Expert systems with applications*, 2010.
- [13]. C. Wu, G. Tzeng, Y. Goo, and W. Fang, "A real-valued genetic algorithm to optimize the parameters of support vector machine for predicting bankruptcy," *Expert systems with applications*, vol. 32, pp. 397-408, 2007.
- [14]. E. Huerta, B. Duval, and J. Hao, "A hybrid GA/SVM approach for gene selection and classification of microarray data," *Applications of Evolutionary Computing*, pp. 34-44, 2006.
- [15]. L. Zhuo, J. Zheng, F. Wang, X. Li, B. Ai, and L. Qian, "A genetic algorithm based wrapper feature selection method for classification of hyperspectral images using support vector

Archive of SID

- machine," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 37, pp. 397-402, 2008.
- [16]. T. Zhang, X. Fu, R. Goh, C. Kwoh, and G. Lee, "A GA-SVM feature selection model based on high performance computing techniques," *IEEE International Conference on System, Man and Cybernetics*, pp. 2653-2658, 2009.
- [17]. C. Huang, "ACO-based hybrid classification system with feature subset selection and model parameters optimization," *Neurocomputing*, vol. 73, pp. 438-448, 2009.
- [18]. S. Lin, Z. Lee, S. Chen, and T. Tseng, "Parameter determination of support vector machine and feature selection using simulated annealing approach," *Applied soft computing*, vol. 8, pp. 1505-1512, 2008.
- [19]. S. Lin, K. Ying, S. Chen, and Z. Lee, "Particle swarm optimization for parameter determination and feature selection of support vector machines," *Expert systems with applications*, vol. 35, pp. 1817-1824, 2008.
- [20]. C. Huang and C. Wang, "A GA-based feature selection and parameters optimization for support vector machines," *Expert systems with applications*, vol. 31, pp. 231-240, 2006.
- [21]. R. Haupt, S. Haupt, and J. Wiley, *Practical genetic algorithms*: Wiley Online Library, 1998.
- [22]. V. Vapnik, *The nature of statistical learning theory*: Springer Verlag, 2000.
- [23]. A. Lorena and A. de Carvalho, "Evolutionary tuning of SVM parameter values in multiclass problems," *Neurocomputing*, vol. 71, pp. 3326-3334, 2008.
- [24]. T. Weise, "Global Optimization Algorithms—Theory and Application," *Abrufdatum*, vol. 1, 2008.
- [25]. U. Maulik, "Medical image segmentation using genetic algorithms," *IEEE Transactions on Information Technology in Biomedicine*, vol. 13, pp. 166-173, 2009.
- [26]. E. Pourbasheer, S. Riahi, M. Ganjali, and P. Norouzi, "Application of genetic algorithm-support vector machine (GA-SVM) for prediction of BK-channels activity," *European journal of medicinal chemistry*, vol. 44, pp. 5023-5028, 2009.
- [27]. B. de Souza, A. de Carvalho, R. Calvo, and R. Ishii, "Multiclass SVM model selection using particle swarm optimization," 2006, p. 31.
- [28]. C. Hsu, C. Chang, and C. Lin, "A practical guide to support vector classification," Citeseer, 2003.
- [29]. I. Guyon and A. Elisseeff, "An introduction to variable and feature selection," *The Journal of Machine Learning Research*, vol. 3, pp. 1157-1182, 2003.
- [30]. M. Tahir, A. Bouridane, F. Kurugollu, and A. Amira, "Feature selection using tabu search for improving the classification rate of prostate needle biopsies," *Pattern Recognition*, vol. 2, pp. 335-333, 2004.
- [31]. C. Tu, L. Chuang, J. Chang, and C. Yang, "Feature selection using PSO-SVM," *IAENG International journal of computer science*, vol. 33, pp. 111-116, 2007.
- [32]. D. Niu, Y. Wang, and D. Wu, "Power load forecasting using support vector machine and ant colony optimization," *Expert systems with applications*, vol. 37, pp. 2531-2539, 2010.
- [33]. H. Frohlich, O. Chapelle, and B. Scholkopf, "Feature selection for support vector machines by means of genetic algorithm," 2003, pp. 142-148.
- [34]. S. Bhatia, P. Prakash, and G. Pillai, "SVM Based Decision Support System for Heart Disease Classification with Integer-Coded Genetic Algorithm to Select Critical Features," 2008.
- [35]. A.B. Santos, C.S.F. de S. Celes, A. de A. Araújo, D. Menotti, "Feature selection for classification of remote sensed hyperspectral images: A filter approach using genetic algorithm and cluster validity," *The 2012 International Conference on Image Processing, Computer Vision, and Pattern Recognition (ICCV'12)*, 2012.
- [36]. Y. Bazi and F. Melgani, "Toward an optimal SVM classification system for hyperspectral remote sensing images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, pp. 3374-3385, 2006.
- [37]. I. Mejía-Guevara and Ákuri-Morales, "Evolutionary feature and parameter selection in support vector regression," *MICAI 2007: Advances in Artificial Intelligence*, pp. 399-408, 2007.
- [38]. E. Avci, "Selecting of the optimal feature subset and kernel parameters in digital modulation classification by using hybrid genetic algorithm-support vector machines: HGASVM," *Expert systems with applications*, vol. 36, pp. 1391-1402, 2009.
- [39]. B. F. de Souza and A. P. d. L. F. de Carvalho, "Gene selection based on multi-class support vector machines and genetic algorithms," *Genetics and Molecular Research*, pp. 599-607, 2005.
- [40]. M. Zhao, C. Fu, L. Ji, K. Tang, and M. Zhou, "Feature selection and parameter determination for support vector machines: A new approach based on genetic algorithm with feature chromosomes," *Expert System with Applications*, Vol. 38, No. 5, pp. 5197-5204, 2011.
- [41]. N. Chen, B. Ribeiro, A. S. Vieira, J. Duarte, J. C. Neves, "A genetic algorithm-based approach to cost-sensitive bankruptcy prediction," *Expert System with Application*, Vol. 38, No. 10, pp. 12939-12945, 2011.