

# طبقه‌بندی تصاویر ابرطیفی سنجش از دور با استفاده از سیستم‌های طبقه‌بندی چندگانه

مجید محمدبیگی<sup>۱</sup>، ایمان خسروی<sup>۲\*</sup>، حمید چراغچی<sup>۳</sup>

<sup>۱</sup>استادیار گروه مهندسی پزشکی - دانشکده‌ی فنی - دانشگاه اصفهان  
majid.beigi@eng.ui.ac.ir

<sup>۲</sup>دانشجوی کارشناسی ارشد سنجش از دور - گروه مهندسی نقشه برداری - دانشکده‌ی فنی - دانشگاه اصفهان  
iman.khosravi@mi.hanmail.ir

<sup>۳</sup>دانشجوی کارشناسی ارشد سنجش از دور - گروه مهندسی نقشه برداری - دانشکده‌ی فنی - دانشگاه اصفهان  
h.cheraghchi@eng.ui.ac.ir

(تاریخ دریافت شهریور ۱۳۹۰، تاریخ تصویب فروردین ۱۳۹۱)

## چکیده

با پیشرفت سنجنده‌های سنجش از دور، امروزه یکی از پرکاربردترین محصولات مورد استفاده در این حوزه، تصاویر ابرطیفی است. این داده‌ها به دلیل داشتن باندهای زیاد طیفی باریک در محدوده‌ی مرئی تا مادون قرمز-طول موج کوتاه امکان شناسایی بهتر پوشش‌های مختلف زمینی را فراهم نموده است. با این وجود، استفاده از روش‌های قدیمی طبقه‌بندی در فضای ویژگی‌های با ابعاد بالا، ممکن است ما را با پدیده‌ی معروف هیوز مواجه نماید. مطالعات جدید در حوزه‌ی سنجش از دور، نشان داده‌اند که استفاده از روش ماشین‌های بردار پشتیبان برای حل این مسائل بسیار مناسب است. از قابلیت‌های این روش، استفاده‌ی بخشی از داده‌های آموزشی به جای تمام داده‌ها جهت طبقه‌بندی است. در این مقاله، می‌خواهیم تا طبقه‌بندی تصاویر ابرطیفی سنجش از دور، با استفاده از سیستم‌های طبقه‌بندی چندگانه را مورد بحث و بررسی قرار دهیم و همچنین یک سیستم جمعی مبتنی بر ماشین‌های بردار پشتیبان معرفی نماییم. در روش پیشنهادی مقاله، ابتدا ۲ زیرمجموعه از بهترین زیرمجموعه‌های ویژگی‌های بارزش و مفید را از کل ویژگی‌ها استخراج می‌کنیم. سپس زیرمجموعه‌های استخراج شده را با دو روش جداساز *SVM* چندکلاسه به ۳ کلاس موردنظر طبقه‌بندی می‌نماییم. همچنین با استفاده از سیستم طبقه‌بندی چندگانه مبتنی بر *SVM* چندکلاسه این طبقه‌بندی انجام می‌شود. نتایج دقت کلی طبقه‌بندی حاصل از استراتژی پیشنهادی، با نتایج به دست آمده از *SVM*‌های تکی و همچنین مجمع‌های طبقه‌بندی دیگر، از قبیل *bagging*، *boosting* و *random forests* مقایسه می‌گردد. داده‌ی مورد استفاده در این مقاله، تصویر ابرطیفی سنجنده‌ی آویز با ۲۲۴ باند طیفی از یک منطقه‌ی شهری است که نتایج حاصل از روش‌های پیاده‌شده روی آن نشان از توانایی کم‌نظیر این روش‌ها در طبقه‌بندی تصاویر ابرطیفی دارد.

**واژه‌های کلیدی:** طبقه‌بندی، تصاویر ابرطیفی، سیستم‌های طبقه‌بندی چندگانه، بردار پشتیبان، مجمع‌های طبقه‌بندی.

\* نویسنده رابط

## ۱- مقدمه

پیشرفت‌های گوناگونی در حوزه‌ی سنجنده‌های سنجش از دور انجام شده است. هم‌اکنون تصاویر ابرطیفی یکی از پرکاربردترین محصولات سنجش از دور به حساب می‌آید. با پیدایش این داده‌ها، محدوده‌ی طیفی فراوانی از حوزه‌ی طول موج‌های مرئی تا مادون قرمز-طول موج کوتاه در تعداد زیادی کانال باریک پوشش داده شده است [۱]. با داشتن این حجم زیاد اطلاعاتی، حل مسائلی که نیاز به تمایز دقیقی در محدوده‌ی طیفی دارند، با یک دقت بهتری عملی شده است. به عنوان مثال در یک کار طبقه بندی پوشش زمینی، با افزایش لایه‌های طیفی، کلاس‌ها با دقت بالاتری قابل جداسازی هستند [۱]. با این حال، اگر نمونه‌های آموزشی به مقدار کافی در دسترس نباشد، زیاد شدن بیش از حد ویژگی‌ها می‌تواند برای طبقه‌بندی در صحت نتایج حاصل، ایجاد اشکال نماید. این مسئله‌ای است که [۲] در پژوهش خود به آن اشاره کرد و لذا به همین دلیل، این پدیده به پدیده‌ی هیوز معروف است؛ لذا در این هنگام، دیگر روش‌های آماری قدیمی نمی‌تواند جواب‌گوی مناسبی برای طبقه‌بندی این داده‌ها باشد و بایستی به دنبال الگوریتم‌های جداساز کاراتری باشیم. در این خصوص، طی چندسال گذشته، الگوریتم‌های طبقه‌بندی مختلفی پیشنهاد شده است.

مطالعات جدید در سنجش از دور، نشان داده‌اند که ماشین‌های بردار پشتیبان (SVMs)، جداسازهای مناسبی برای مسائل طبقه‌بندی ابعاد بالا هستند (به عنوان مثال [۱،۳،۴،۵]). این روش بر مبنای یک نقطه نظر هندسی است نه آماری. ایده‌ی این روش در حالت دو کلاسه، معرفی یک ابرصفحه‌ی جداسازی است که فاصله با نزدیکترین نمونه‌های آموزشی هر دو کلاس را بیشینه نماید [۳]. این رویه باعث می‌شود تا SVM به نمونه‌های آموزشی کمی احتیاج پیدا کند. در این صورت، قابلیت تعمیم‌پذیری SVM بالا می‌رود. هم‌چنین، SVM می‌تواند با بهره بردن از حقه‌ی هسته، داده‌های به طور غیرخطی جداساز را به یک فضای ویژگی بالاتری نگاشت دهد و سپس در آن فضا به دنبال یک ابرصفحه‌ی جداساز خطی برای کلاس‌ها باشد [۶]. در کاربردهای سنجش از دور همانند طبقه‌بندی پوشش زمینی معمولاً بیش از دو

کلاس در اختیار داریم و لذا لازم است تا از ماشین‌های بردار پشتیبان در حالت چند کلاسه استفاده شود. استراتژی‌های فراوانی در حالت چندکلاسه مورد بررسی قرار گرفته است که از رایج‌ترین آن‌ها می‌توان به روش یکی با یکی و یکی با همه اشاره نمود [۷].

اولین کار در زمینه‌ی استفاده از ماشین‌های بردار پشتیبان در سنجش از دور توسط [۶] در طبقه‌بندی داده‌های ابرطیفی انجام شد. وی در پژوهش خود نشان داد که مسئله‌ی نفرین ابعاد در تصاویر ابرطیفی نمی‌تواند برای روش ماشین بردار پشتیبان مسئله‌ساز شود. بعد از وی، [۸] از این روش در حالت چندکلاسه برای داده‌های چندمنبعی استفاده نمود. وی در روش خود بهترین پارامترهای تنظیم هسته‌ی ماشین بردار پشتیبان را به دست آورد. هرچند که داده‌های وی، تصاویر ابرطیفی نبود، لیکن پژوهش وی در فضای ویژگی بالا بررسی شد و نهایتاً نتایج قانع کننده‌ای به دست آمد. در مطالعه‌ی دیگر، [۹] ادعا نموده بودند که SVMها نسبتاً تأثیری از پدیده‌ی هیوز ندارند. هرچند نتایج کارشان نشان‌دهنده‌ی قابلیت تعمیم‌پذیری بالای SVMها بود، لیکن داده‌ها پیش پردازش شده بودند؛ یعنی ابتدا سه باند، انتخاب و برای طبقه‌بندی استفاده شده بود؛ بنابراین کارآمدی آنها در فضای بالا بررسی نگردیده بود. [۱۰] در پژوهش خود تلاش کرد تا با در نظر گرفتن دو هسته‌ی متفاوت ضمن مقایسه‌ی بین آن دو، قابلیت تعمیم‌پذیری SVMها و همچنین توانایی آن‌ها برای حل مسائل با ویژگی‌های زیاد و مجموعه‌ی آموزشی بسیار کم، را مورد ارزیابی قرار دهد.

این روش نسبتاً جدید یادگیری ماشین در سال‌های اخیر کارایی قابل قبول‌تر و بهتری در طبقه‌بندی نسبت به روش‌های قدیمی‌تر یادگیری مانند شبکه‌های عصبی مصنوعی، بیشترین شباهت و غیره داشته است. در پژوهش [۱۱]، نتایج حاصل از طبقه‌بندی با SVMها، دقت مساوی یا حتی بهتر از دقت حاصل از طبقه‌بندی سایر جداسازها داشت.

در مورد تأثیر پیکربندی هسته‌ی ماشین‌های بردار پشتیبان نیز پژوهش‌هایی انجام شده است. پژوهش [۱۲] ماشین‌های بردار پشتیبان را جهت طبقه‌بندی پوشش زمینی با جداسازهای بیشترین شباهت، شبکه‌ی عصبی و درخت تصمیم مقایسه نمود. هرچند که داده‌ی

از قبیل bagging, boosting, random forests مقایسه می‌گردد.

در بخش‌های بعدی این مقاله اهداف زیر را دنبال خواهیم نمود: در بخش ۲، ماشین‌های بردار پشتیبان در دو حالت دو کلاسه و چندکلاسه مورد بررسی قرار می‌گیرند. در حالت چندکلاسه، دو روش از رایجترین روش‌ها توضیح داده می‌شود. در بخش ۳، به شرح سیستم‌های طبقه‌بندی چندگانه، می‌پردازیم. بخش ۴، اختصاص به روش پیشنهادی مقاله دارد. داده‌های مورد استفاده در این آزمایش و نتایج پیاده‌سازی روش‌های مقاله روی آن، در بخش ۵ آورده شده است و در نهایت بخش ۶، به بحث و نتیجه‌گیری نهایی مقاله ختم می‌شود.

## ۲- ماشین‌های بردار پشتیبان<sup>۱</sup>

از روش‌های جدید یادگیری ماشین در حل مسائل طبقه‌بندی و رگرسیون، روش ماشین‌های بردار پشتیبان است. این روش بر پایه‌ی تئوری آماری است [۱۴] و به صورت نظارت‌شده تصمیم‌گیری می‌کند. با رجوع به بخش مقدمه می‌توان بخشی از پژوهش‌های صورت گرفته در راستای استفاده از این روش در مسائل سنجش از دور را مشاهده نمود. اولین تاریخچه‌ی استفاده از این الگوریتم به کار Vapnik در سال ۱۹۶۳ برمی‌گردد و سپس در سال ۱۹۹۵ وی به همراه Cortes، الگوریتم SVM را برای حالت غیرخطی تعمیم داد. در ادامه‌ی بحث راجع به ساختار ریاضی ماشین‌های بردار پشتیبان دو کلاسه و چند کلاسه توضیحات مختصری خواهیم داد:

### ۲-۱- ماشین‌های بردار پشتیبان دوکلاسه

برای یک مسئله‌ی دوکلاسه در فضای  $n$  بعدی  $R^n$ ، فرض می‌کنیم که  $l$  سمپل آموزشی  $x_i$  با برچسب‌های نظیرشان  $y_i = \pm 1$  موجود است یعنی:  $S = \{(x_i, y_i) \mid i \in [1, l]\}$ . روش SVM شامل پیدا کردن ابرصفحه‌ای در فضای ویژگی است که حاشیه را ماکزیمم می‌کند (شکل ۱)، یعنی، فاصله‌ی نزدیکترین نقاط داده‌ی آموزشی در هر دو

مورد استفاده در این مقاله، تصاویر ابرطیفی نبودند، لیکن ایشان تأثیر هسته‌های مختلف را بر روی کارایی SVM بررسی کرد. در نتایج این مطالعه، هسته‌ی چندجمله‌ای نتایج بهتری دارد و وی نتیجه می‌گیرد که درجات بالاتر هسته‌ی چندجمله‌ای برای داده‌های ورودی با ویژگی کمتر لازم است. در پژوهشی، [۳] چند هسته‌ی مختلف مبتنی بر طیف تعریف می‌کند و برای طبقه‌بندی مکعب داده‌ی ابرطیفی استفاده می‌کند. در این روش، معیارهای غیراقلیدسی متفاوتی جهت شباهت بین بردارها در نظر گرفته شده بود. هدف از پژوهش وی کاهش اشتباهاتی است که به دلیل نادیده گرفتن اثر طیفی به‌وسیله‌ی هسته‌های معمول به‌وجود می‌آید. در کار [۱۳] نیز دو هسته‌ی معمول چندجمله‌ای و پایه‌ای شعاعی در دو حالت چند کلاسه روی داده‌های ابرطیفی آویریس به کار برده شد. البته ایشان در کار خود، همزمان تأثیر سه عامل دیگر در دقت طبقه‌بندی نهایی را مورد بررسی قرار داد. یکی از این عوامل استفاده از دو معیار طیفی به جای معیار هندسی فاصله‌ی اقلیدسی است و لذا هسته‌های مبتنی بر این معیار جدید با هسته‌های مبتنی بر معیار فاصله‌ی اقلیدسی مقایسه می‌شوند. هرچند که وی کارایی این روش را نسبت به نوع هسته‌های مختلف مورد بررسی قرار می‌دهد لیکن هنوز روشی برای به دست آوردن پارامترهای بهینه‌ی این هسته‌ها ارائه نمی‌دهد.

در این مقاله، می‌خواهیم تا طبقه‌بندی تصاویر ابرطیفی سنجش از دور، با استفاده از سیستم‌های طبقه‌بندی چندگانه را مورد بحث و بررسی قرار دهیم و همچنین یک سیستم مجمعی مبتنی بر ماشین‌های بردار پشتیبان معرفی نماییم. در روش پیشنهادی مقاله، ابتدا ۲ زیرمجموعه از بهترین زیرمجموعه‌های ویژگی‌های بارزش و مفید را از کل ویژگی‌ها استخراج می‌کنیم. سپس زیرمجموعه‌های استخراج شده را با دو روش جداساز SVM چندکلاسه به ۳ کلاس موردنظر طبقه‌بندی می‌نماییم. همچنین با استفاده از سیستم طبقه‌بندی چندگانه مبتنی بر SVM چندکلاسه این طبقه‌بندی انجام می‌شود. نتایج دقت کلی طبقه‌بندی حاصل از استراتژی پیشنهادی، با نتایج به دست آمده از SVMهای تکی و همچنین مجمع‌های طبقه‌بندی دیگر،

<sup>۱</sup> Support vector machines

کلاس [۱۳]. توجه کنید که  $w \in R^n$  به عنوان بردار نرمال ابرصفحه و  $b \in R$  بایاس صفحه هستند. ابرصفحه  $H_p$  به صورت زیر تعریف می‌شود:

$$\langle w, x \rangle + b = 0, \quad x \in H_p \quad (1)$$

که  $\langle w, x \rangle$  ضرب داخلی بین  $w$  و  $x$  است. اگر  $x$  متعلق به  $H_p$  نباشد، در نتیجه  $f(x) = \langle w, x \rangle + b$  فاصله  $x$  تا ابرصفحه  $H_p$  می‌باشد. علامت  $f$  متناسب با تابع تصمیم  $y = \text{sgn}(f(x))$  است.

پارامترهای بهینه‌ی  $(w, b)$  با حل معادله‌ی

$$\min \left[ \frac{\|w\|^2}{2} + C \sum_{i=1}^l \xi_i \right] \quad (2)$$

مشروط به

$$y_i (\langle w, x_i \rangle + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i \in [1, l] \quad (3)$$

به دست می‌آید. به طوری که ثابت  $C$ ، پارامتر تنظیم و  $\xi_i$  متغیرهای کمکی‌ای هستند که برای سروکار داشتن با نمونه‌های اشتباه طبقه‌بندی شده معرفی می‌شوند (شکل ۱). این مسئله‌ی بهینه‌سازی را از طریق مسئله‌ی دوگانه‌ی لاگرانژ حل می‌کنیم [۱۳]:

$$\max_{\alpha} \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle \quad (4)$$

$$0 \leq \alpha_i \leq C \quad \forall i \in [1, l],$$

مشروط به

$$\sum_{i=1}^l \alpha_i y_i = 0.$$


و در نهایت داریم:

$$w = \sum_{i=1}^l \alpha_i y_i x_i \quad (5)$$

بردار جواب یک ترکیب خطی از برخی نمونه‌های مجموعه‌ی آموزشی است که  $\alpha_i$ ‌های غیر صفر دارند (شرط KKT) [۱۵]. به این سмпل‌ها بردارهای پشتیبان گفته می‌شود. بنابراین ابرصفحه‌ی تابع تصمیم می‌تواند به صورت زیر نوشته شود:

$$y_u = \text{sgn}(\sum_{i=1}^l y_i \alpha_i \langle x_w, x_i \rangle + b) \quad (6)$$

که  $x_i$  یک نمونه‌ی تست است.



شکل ۱- طبقه‌بندی ماشین‌های بردار پشتیبان در حالت غیرخطی جداپذیر. یک بردار غیرجداساز در هر کلاس

با استفاده از ترنند یا حقه‌ی هسته<sup>۱</sup>، می‌توان ماشین‌های بردار پشتیبان را به توابع تصمیم غیرخطی تعمیم داد. با این ایده می‌توان توانایی طبقه‌بندی را بهبود بخشید که این ایده به صورت زیر است [۱۵]. از طریق یک نگاشت غیرخطی  $\Phi$ ، داده‌ها به یک فضای با ابعاد بالاتر نگاشت پیدا می‌کنند:

$$\begin{aligned} \Phi: R^n &\rightarrow F \\ x &\mapsto \Phi(x). \end{aligned} \quad (7)$$

بدین ترتیب، الگوریتم SVM به سادگی می‌تواند، با نمونه‌های آموزشی زیر در نظر گرفته شود:  $\Phi(S) = \{(\Phi(x_i), y_i) \mid i \in [1, l]\}$ . با این کار، یک نسخه‌ی جدید از معادله‌ی (۶) به دست می‌آید که بخش ضرب اسکالر آن تبدیل به  $\langle \Phi(x_i), \Phi(x_j) \rangle$  می‌شود. لذا به‌طور امیدوارانه‌ای، برای برخی توابع هسته، بار محاسباتی اضافی به شکل زیر کاهش پیدا می‌کند:

$$\langle \Phi(x_i), \Phi(x_j) \rangle = k(x_i, x_j). \quad (8)$$

<sup>۱</sup> Kernel trick

1/2) جداساز دوتایی وجود خواهد داشت. برای یک داده‌ی آزمایشی، هر طبقه‌بندی یک رأی به کلاس برنده می‌دهد و در نهایت برچسب آن داده کلاسی است که بیشترین رأی را کسب نموده باشد. البته می‌توان فرآیند رأی‌گیری این روش را به صورت وزن‌دار نیز انجام داد. تعداد جداسازهایی که به‌وسیله‌ی این روش ایجاد می‌شوند به طور کلی خیلی بیشتر از روش قبلی است. به‌هرحال، تعداد بردارهای داده‌ی آموزشی که برای هر جداساز مورد نیاز است خیلی کمتر می‌باشد.

### ۲-۲-۲- روش یکی با همه<sup>۵</sup> (OAA)

این روش همچنین به طبقه‌بندی winner-take-all معروف است. فرض کنید که یک مجموعه داده به  $M$  کلاس بایستی تقسیم‌بندی شود. Vapnik پیشنهاد نمود که هر کلاس با سایر کلاس‌های داده شده مقایسه شود [۱۳]. بنابراین،  $M$  جداساز SVM دوتایی باید ایجاد شود به طوری که هر جداساز، جداگانه آموزش داده می‌شود تا یک کلاس را از  $M-1$  کلاس باقیمانده متمایز نماید. سایر جداسازهای SVM نیز مشابه این حالت ساخته می‌شوند. سپس در مرحله‌ی آزمایش، بردارهای داده توسط پیدا نمودن حاشیه از ابرصفحه‌ی جداساز خطی طبقه‌بندی می‌شوند. خروجی نهایی، کلاسی هست که متناسب با SVMی با بزرگترین حاشیه باشد.

### ۳- سیستم‌های طبقه‌بندی چندگانه

هدف اصلی یک سیستم طبقه‌بندی چندگانه، در نظر گرفتن چندین تصمیم مختلف به جای متکی بودن به تنها یک تصمیم (جداساز) در طبقه‌بندی نهایی است [۴]. لذا می‌توان MCS را یک روش تأسیس شده جهت ادغام تصمیم‌های مختلف گرفته‌شده به‌وسیله‌ی گروهی از جداسازها تعریف نمود. نام‌های دیگری که می‌توان برای این مفهوم در یادگیری ماشین و شناسایی الگو پیدا نمود، «کمیت‌های از یادگیرنده‌ها، ترکیب مهارت‌ها، مجمع‌های طبقه‌بندی، تئوری اجماع» است [۱۳].

تابع هسته‌ی  $k$  بایستی شرایط مرکز<sup>۱</sup> را برآورده نماید که در [۱۶] آورده شده است. مزیت استفاده از هسته‌ها در SVM این است که به کمک آن‌ها، می‌توان به‌طور ضمنی در فضای نگاشت یافته‌ی  $F$  کار کرد، در حالیکه همه‌ی محاسبات در فضای ورودی انجام می‌شود. رایج‌ترین هسته‌هایی که در سنجش از دور مورد استفاده قرار گرفته‌اند، هسته‌های چندجمله‌ای و تابع پایه‌ای شعاعی گوسی<sup>۲</sup> هستند [۷]:

$$k_{poly}(\mathbf{x}_i, \mathbf{x}_j) = [(\mathbf{x}_i \cdot \mathbf{x}_j) + 1]^p \quad (10)$$

$$k_{gauss}(\mathbf{x}_i, \mathbf{x}_j) = \exp[-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2] \quad (11)$$

### ۲-۲- ماشین‌های بردار پشتیبان چندکلاسه

همان‌طور که پیشتر بررسی شد، SVMها جهت حل مسائل دوتایی (دوکلاسه) طراحی شده‌اند، زمانی که برچسب‌های کلاس‌ها تنها می‌تواند دو مقدار  $\pm 1$  بگیرند. لیکن برای یک کاربرد سنجش از دور همانند طبقه‌بندی پوشش زمینی، معمولاً چندین کلاس (بیشتر از دوتا) مورد علاقه است. روش‌های فراوانی برای تولید SVMهای چندکلاسه از SVMهای دوتایی در پژوهش‌های مختلف پیشنهاد شده است که هم‌اکنون نیز از رایج‌ترین موضوعات پژوهشی به‌شمار می‌رود [۱۶]. در پژوهشی [۱۷]، شش روش طبقه‌بندی چندکلاسه با ماشین‌های بردار پشتیبان روی داده‌های سنجش از دور از لحاظ دقت طبقه‌بندی و بار محاسباتی با یکدیگر مقایسه شده است که در ادامه قصد داریم تا دو روش رایج‌تر برای این کار را توضیح دهیم:

### ۲-۲-۱- روش یکی با یکی<sup>۳</sup> (OAO)

نام دیگر این روش، روش جفت‌به‌جفت<sup>۴</sup> است. در این روش، جداسازهای SVM برای هر جفت ممکن کلاس‌ها ایجاد می‌شوند [۱۸]. بنابراین، برای  $M$  کلاس،  $M(M-1)$

<sup>۲</sup> Mercer

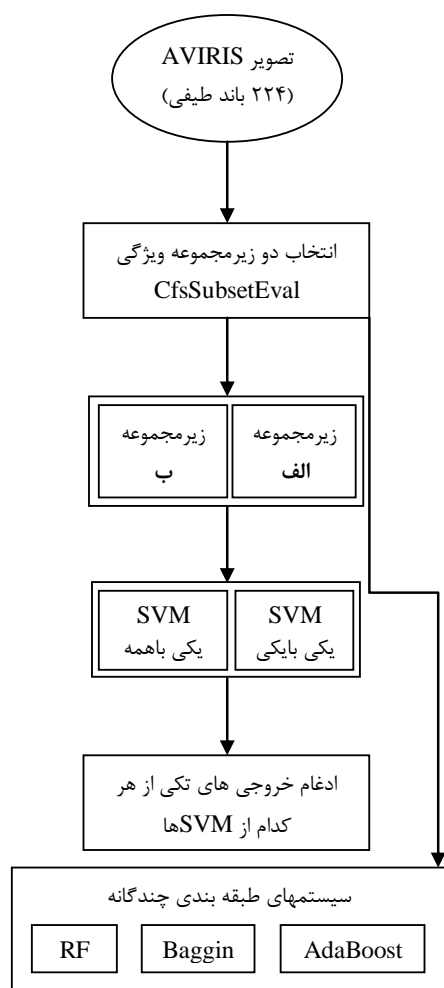
<sup>۱</sup> Radial basis function (RBF)

<sup>۳</sup> One against one

<sup>۴</sup> Pairwise

<sup>۴</sup> One against all

روش جداساز SVM چندکلاسه را روی تمام آن‌ها به صورت جداگانه آموزش می‌دهیم. برای این کار ابتدا به روش Model Selection بهترین پارامترهای تنظیم C و گاما  $\gamma$  برای SVM با هسته‌ی تابع پایه‌ی شعاعی انتخاب می‌شود [۲۵].



نمودار ۱- روش پیشنهادی مقاله

مجموعه‌های طبقه‌بندی برای فرض استوارند که یک مجموعه‌ی مستقل (یا گوناگون) از جداسازها، خطای تنهایی تولید کنند که بوسیله‌ی اکثریت جداسازهای دیگر ایجاد نمی‌شود. لذا، ترکیبی از این خروجی‌های جداساز می‌تواند دقت طبقه‌بندی را افزایش دهد. بنابراین، گوناگونی جداساز یک شرط پیش‌نیاز است و یک مجموعه‌ی جداساز (خروجی) به‌طور کم یا زیاد مشابه دقت طبقه‌بندی را افزایش نخواهد داد [۱۹].

مجموعه‌های طبقه‌بندی، می‌تواند یا با ترکیب روش‌های جداساز مختلف تولید شود [۵] و [۲۰] یا با ترکیب انواع الگوریتم‌های یکسان که جداساز پایه نامیده می‌شوند [۲۱] و [۲۲]. در [۵]، برای مثال، منابع مختلف داده به‌طور همزمان توسط یک شبکه‌ی عصبی و یک جداساز آماری طبقه‌بندی می‌شوند. خروجی‌های مختلف (یعنی برچسب‌های کلاس) بوسیله‌ی ادغام تصمیم ترکیب می‌شوند. در [۲۲]، می‌توان یک استراتژی ادغام مبتنی بر SVM را مثال زد که داده‌های سنجش از دور چندطیفی و SAR را با یکدیگر ترکیب می‌کند. هر منبع تصویری به‌طور جداگانه با یک SVM طبقه‌بندی می‌شود و خروجی‌های نهایی توسط یک SVM اضافی ترکیب می‌شوند. استراتژی پیشنهادی دقت طبقه‌بندی را در مقایسه با یک SVM تنها که روی تمام مجموعه داده‌ها به‌کار می‌رود افزایش می‌دهد. دیگر سیستم‌های طبقه‌بندی چندگانه، مبتنی بر تنوع‌های گوناگونی الگوریتم یکسان هستند. جداسازهای Boosting و Bagging از این دسته سیستم‌ها می‌باشند.

#### ۴- روش پیشنهادی

پس از این، خروجی‌های SVMهای تکی به عنوان ورودی برای ادغام تصمیم نهایی که مبتنی بر یک جداساز SVM اضافی است، استفاده می‌شود. همچنین مجموعه‌های طبقه‌بندی دیگر (در این مقاله توضیح داده شدند) نیز استفاده می‌شود. در پایان نتایج همه‌ی روش‌ها از لحاظ دقت کلی با یکدیگر مقایسه می‌شوند.

در این مقاله، یک سیستم طبقه‌بندی چندگانه مبتنی بر SVM جهت طبقه‌بندی داده‌های ابرطیفی سنجش از دور استفاده می‌شود. فرآیند پیشنهادی از قابلیت‌های هر دو مفهوم SVM و MCS استفاده می‌کند. همان‌طور که در نمودار ۱ نیز دیده می‌شود، در روش مقاله، ابتدا با استفاده از روش برآوردکننده‌ی ویژگی CfsSubsetEval با جستجو بر مبنای پراکندگی (scatter)، دو زیرمجموعه از بهترین زیرمجموعه‌های ویژگی‌های بارزش و حاوی اطلاعات مفید را انتخاب می‌کنیم [۲۳، ۲۴]. بعد از آن که زیرمجموعه‌های ویژگی‌های مناسب را انتخاب کردیم، دو

## ۵- آزمایش و نتایج

### ۵-۱- داده‌های مورد مطالعه

داده‌های مورداستفاده در این مقاله، تصاویر فراطیفی سنجندهی آویریس ۱ از شهر سان‌دیگو است. این تصاویری در ۲۲۴ کانال طیفی در بازه‌ی ۴۰۰ تا ۲۵۰۰ نانومتر ارائه می‌دهد. قدرت تفکیک مکانی آن به ارتفاع هواپیمای حامل آن (ER-2) بستگی دارد و معمولاً از ۴ تا ۲۰ متر تغییر می‌کند. تصاویر موجود دارای ابعاد ۴۰۰×۴۰۰ پیکسل می‌باشد. در مرحله‌ی پیش‌پردازش، ابتدا باندهای نوپزی و غیرمفید را از این تصاویر حذف می‌کنیم که در نهایت ۱۸۹ باند انتخاب می‌شود. بعد از آن با روش CfsSubsetEval با معیار جستجوی پراکندگی در نرم افزار وِکسا، ۲ زیرمجموعه از بهترین زیرمجموعه‌های ویژگی‌های مفید و بارزش انتخاب می‌شوند که باندهای انتخاب شده به قرار زیر می‌باشند:



شکل ۲- تصویر رنگی از منطقه‌ی سان‌دیگو

- زیرمجموعه‌ی الف: {۱، ۲، ۴، ۷، ۸، ۹، ۱۱، ۱۷، ۲۳، ۲۴، ۲۵، ۴۲، ۵۳، ۶۱، ۷۸، ۱۱۳، ۱۲۳، ۱۳۷، ۱۴۳، ۱۶۱، ۱۸۲، ۱۸۵} = ۲۲ باند
- زیرمجموعه‌ی ب: {۱۵، ۲۰، ۲۲، ۲۸، ۳۰، ۳۳، ۴۸، ۵۴، ۶۲، ۷۶، ۹۸، ۱۰۱، ۱۰۴، ۱۱۶، ۱۳۶، ۱۴۷، ۱۵۱، ۱۸۶، ۱۸۹} = ۱۹ باند

تعداد کلاس‌های موردنظر سه کلاس زمین، پوشش گیاهی و ساختمان هستند که تعداد نمونه‌های هر یک از آن‌ها در جدول ۱ آورده شده است. این داده‌های آموزشی به صورت پراکنده در تمام تصویر از هر سه کلاس انتخاب شده است. تصویررنگی منطقه‌ی مورد استفاده در شکل ۲ (بالا) نیز مشاهده می‌شود.

جدول ۱- تعداد داده‌های موجود در هر کلاس

کلاس	تعداد نمونه‌های هر کلاس
زمین	۲۰۶۳
پوشش گیاهی	۱۶۶۸
ساختمان	۲۲۵۶

### ۵-۲- نتایج

پس از اینکه ۲ زیرمجموعه‌ی مختلف ویژگی به وسیله‌ی روش CfsSubsetEval انتخاب گردید، در گام اول آزمایش، هر دونوع جداساز SVM چندگانه را توسط هرکدام از زیرمجموعه‌ها آموزش می‌دهیم. یعنی ۴ جداساز SVM1-1(الف)، SVM1-1(ب) و SVM1-all(الف)، SVM1-all(ب) را ایجاد می‌کنیم. البته همانطور که توضیح دادیم لازم است تا پارامترهای بهینه‌ی C و  $\gamma$  برای این نوع هسته به روش model selection برای هر ۲ زیرمجموعه تعیین شود. این پارامترها برای هرکدام از زیر مجموعه‌ها در جدول ۲ آورده شده است:

جدول ۲- پارامترهای بهینه‌ی تنظیم (C) و تابع پایه‌ی شعاعی گوسی (γ)

پارامتر تنظیم (C)	زیرمجموعه‌ی الف	زیرمجموعه‌ی ب
پارامتر تنظیم (C)	۱۰۰۰	۱۰۰۰۰
پارامتر تابع گوسی (γ)	۰/۰۰۰۳	۰/۰۰۰۷


جهت ارزیابی الگوریتم‌ها روش K-Fold Cross-Validation را به کار می‌بریم. در این روش کل نمونه‌های طبقه‌بندی شده به K بخش مساوی تقسیم می‌گردد. سپس یک بخش آن به عنوان نمونه‌ی آزمایشی و K-1 بخش دیگر، به عنوان نمونه‌ی آموزشی در نظر گرفته می‌شود. ما در اینجا داده‌ها را به ۵ بخش تقسیم کرده‌ایم.

دقت کلی طبقه‌بندی و ضریب کاپای حاصل از آن توسط هر یک از این ۴ جداساز در جدول ۳ آورده شده است.

جدول ۳- ماتریس خطا و دقت کلی هر ۸ جداساز

جدول ۳- ماتریس خطا و دقت کلی هر ۸ جداساز	
SVM1-1 (الف)	SVM1-all (الف)
دقت کلی = ۹۷/۲۳٪	دقت کلی = ۸۹/۵۸٪
ضریب کاپا = ۰/۸۹۳	ضریب کاپا = ۰/۸۰۲
SVM1-1 (ب)	SVM1-all (ب)
دقت کلی = ۹۶/۸۱٪	دقت کلی = ۹۱/۰۴٪
ضریب کاپا = ۰/۸۸۱	ضریب کاپا = ۰/۸۳۴

نمودار ۲ نیز، بیانگر عملکرد هریک از جداسازها از لحاظ زمان است.



نمودار ۲- مقایسه‌ی زمان هریک از جداسازها

در گام بعدی آزمایش، خروجی‌های SVMهای تکی به عنوان ورودی برای ادغام تصمیم نهایی که مبتنی بر یک جداساز SVM اضافیست، استفاده می‌شود. همچنین این خروجی‌ها را به کمک برخی سیستم‌های طبقه‌بندی چندگانه‌ی دیگر از قبیل AdaBoost، bagging با جداساز پایه‌ی درخت تصمیم و random forests با هم ادغام می‌کنیم. جهت بررسی کارایی و حساسیت روش‌های فوق به تعداد نمونه‌های آموزشی، این‌بار از روش k-fold cross validation در حالات k=5,10,20 استفاده می‌کنیم. نتایج دقت کلی همه‌ی این روش‌ها در جدول ۴، نشان داده شده است. همچنین ضریب کاپای حاصل از طبقه‌بندی و زمان انجام هرکدام از این روش‌ها نیز در پایین دقت کلی آنها بیان شده است.

جدول ۴- مقایسه‌ی دقت کلی روش‌های طبقه‌بندی به کار رفته در حالات مختلف تعداد داده‌های آموزشی

روش پیشنهادی با SVM	Adaboost	Bagging	Random forests
K=5	۹۹/۸۲٪	۹۹/۷۸٪	۹۹/۸۸٪
	۹/۷۲"	۰/۹۶۶	۰/۹۸۰
K=10	۹۹/۸۲٪	۹۹/۸۰٪	۹۹/۸۷٪
	۰/۹۷۲	۰/۹۶۹	۰/۹۸۰
K=20	۹۹/۸۵٪	۹۹/۸۲٪	۹۹/۸۸٪
	۰/۹۷۳	۰/۹۶۹	۰/۹۸۰
	۲۸"	۲۴۴"	۱۱"

## ۶- نتیجه‌گیری

در این مقاله، مشکل طبقه‌بندی تصاویر ابرطیفی سنجش از دور (فضاهای ویژگی با ابعاد بالا) مدنظر قرار گرفت. لذا ماشین‌های بردار پشتیبان معرفی گردید که نتایج حاصل از آن نشان می‌دهد این روش متأثر از پدیده‌ی هیوز نیست و می‌تواند یک روش موثر و کارا جهت طبقه‌بندی داده‌های ابرطیفی باشد. همچنین هردو روش چندکلاسه‌ی 1-1 و 1-all استفاده شد. آنچه از نتایج برمی‌آید این است که در اینجا روش SVM1-1 دقت بهتری نسبت به SVM1-all تولید می‌کند و در ضمن روش SVM1-1 زمان کمتری از روش SVM1-all جهت انجام طبقه‌بندی لازم دارد. در ادامه، یک سیستم طبقه‌بندی چندگانه مبتنی بر ادغام SVM پیشنهاد گردید. علاوه بر این، سایر مجمع‌های طبقه‌بندی مشهور دیگر از قبیل boosting، bagging و random forests نیز به کار گرفته شد. همان‌طور که از نتایج نیز مشخص است، روش پیشنهادی می‌تواند دقت طبقه‌بندی را بهبود داده و به دلیل قابلیت ویژه‌ی SVMها در استفاده از بخشی از داده‌ها (که بردارهای پشتیبان نامیده می‌شوند) این کار را با سرعت بالا و طی زمان کوتاه‌تری انجام می‌دهد. البته روش‌های boosting و bagging نیز قابلیت تولید دقت بالا در زمان نسبتاً مناسبی را دارند. ضمن اینکه جداساز پایه‌ی هریک، درخت تصمیم (J48) است و این نشان از توانایی بالای مجمع‌های طبقه‌بندی دارد که می‌تواند دقت بالایی از ادغام جداسازهای ضعیف به دست



همچنین همان طور که مشاهده می شود این سیستم نسبت به دو سیستم دیگر تقریباً زیاد به تعداد داده های آموزشی وابسته نیست. لذا در اینجا می توان این سیستم را برای طبقه بندی تصاویر ابرطیفی سنجش از دور (فضاهای ویژگی با ابعاد بالا) نیز پیشنهاد نمود.

آورد. نیز دیده می شود که با زیاد شدن تعداد نمونه های آموزشی (افزایش K) دقت کلی طبقه بندی اندکی افزایش می یابد. به عنوان نتیجه ی پایانی این مقاله، در این بین می توان به قابلیت سیستم random forests نیز اشاره ای نمود که می تواند دقت بالایی را در طی مدت زمان کمتری نسبت به سایر جداسازها ایجاد نماید.

## مراجع

- [1] Fauvel, M., Benediktsson, J. A., Chanussot, J., Sveinsson, J. R. (2008). Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 46, No. 11.
- [2] Hughes, G. F. (1968). On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*. Vol. IT-14, PP. 55-63.
- [3] Mercier, G., Lennon, M. (2003). Support vector machines for hyperspectral image classification with spectral-based kernels. *Geoscience and Remote Sensing Symposium*. Vol. 1. IGARSS '03. Proceedings.
- [4] Ceamanos, X., Waske, B., Benediktsson, J. A., Chanussot, J., Sveinsson, J. R. (2009). Ensemble strategies for classifying hyperspectral remote sensing data. *MCS 2009, LNCS 5519*, PP. 62-71..
- [5] Waske, B., Vander Linden, S. (2008). Classifying multilevel imagery from SAR and optical sensors by decision fusion. *IEEE Transactions in Geoscience and Remote Sensing*. Vol. 46, PP. 1457-1466.
- [6] Gualtieri, J. A., Chettri, S. (2000). Support vector machines for classification of hyperspectral data. *IEEE Transactions in Geoscience and Remote Sensing Symposium*. Vol. 2. IGARSS '00.
- [7] Pal, M. (2003). Multiclass Approaches for support vector machine based land cover classification.
- [8] Halldorsson, G. H., Benediktsson, J. A., Sveinsson, J. R. (2003). Support vector machines in multisource classification. *IEEE Transactions in Geoscience and Remote Sensing Symposium*, Vol. 3. IGARSS '03.
- [9] Pal, M., Mather, P. M. (2004). Assessment of the effectiveness of support vector machines for hyperspectral data. *Future Generation Computer Systems*. Vol. 20, PP. 1215-1225.
- [10] Foody, G. M., Mathur, A. (2004). A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 42, PP. 1335-1343.
- [11] Camps-Valls, G., Bruzzone, L. (2005). Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 43, No. 6, PP. 1351-1362.
- [12] Huang, C., Davis L. S., Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*. Vol. 23, No. 4, PP. 725-749.
- [13] Samadzadegan, F., Bigdeli, B., Ramzi, P. (2010). A multiple classifier system for classification of LIDAR remote sensing data using multi-class SVM. *MCS 2010, LNCS 5997*, PP. 254-263.
- [14] Vapnik, V. N. (1998). *Statistical learning theory*. New York: Wiley.
- [15] Scholkopf, B., Smola, A. J. (2002). *Learning with kernels, support vector machines, regularization, optimization and beyond*. Cambridge: MIT Press.
- [16] Camps-Valls, G., Bruzzone, L. (2009). *Kernel methods for remote sensing data analysis*. John Wiley & Sons, Ltd., Publication.
- [17] Hastie, T. J., Tibshirani, R. J. (1998). Classification by pair-wise coupling. *Advances in Neural Information Processing Systems (Jordan, M. I., Kearns, M. J., and Solla, S. A., eds.)*. Vol. 10, The MIT Press.
- [18] Polikar, R. (2006). Ensemble based systems in decision making. *IEEE Circuits and Systems Magazine*. Vol. 6, PP. 21-45.
- [19] Benediktsson, J. A., Kanellopoulos, I. (1999). Classification of multisource and hyperspectral data based

on decision fusion. *IEEE Transactions in Geoscience and Remote Sensing*. Vol. 37, PP. 1367-1377.

[20] Ham, J., Chen, Y., Crawford, M. M., Gosh, J. (2005). Investigation of the random forest framework for classification of hyperspectral data. *IEEE Trans. on Geoscience and Remote Sensing*. Vol. 43, PP. 492-501.

[21] Freund, Y., Schapire, R. E. (1996). Experiments with a new boosting algorithm. Proc. 13th Int. Conf. Machine Learning.

[22] Waske, B., Benediktsson, J. A. (2007). Fusion of support vector machines for classification of multisensor data. *IEEE Transactions in Geoscience and Remote Sensing*. Vol. 45, PP. 3858-3866.

[23] Lopez, F. G. (2004). Solving feature subset selection problem by a Parallel Scatter Search. Elsevier.

[24] Chen, C.-C., Lin, C.-J. (2001). LIBSVM: A library for support vector machines. Available from: <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.

[25] Hsu, C.-W., Lin, C.-J. (2002). A comparison of methods for multi-class support vector machines. *IEEE Trans. Neural Networks*. Vol. 13, PP. 415-425.