

## استفاده از سیستم‌های طبقه‌بندی چندگانه به منظور بهبود دقت طبقه‌بندی تصاویر تمام پلاریمتریک راداری با فضای ویژگی ابعاد بالا

ایمان خسروی<sup>۱\*</sup>، مهدی آخوندزاده<sup>۲</sup>

۱- دانشجوی دکتری، گروه سنجش از دور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

۲- استادیار، گروه سنجش از دور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

تاریخ دریافت مقاله: ۹۴/۰۲/۰۵ تاریخ پذیرش مقاله: ۹۴/۰۳/۲۴

### چکیده

یک تصویر تمام پلاریمتریک راداری (POLSAR) قابلیت فراهم کردن یک داده با فضای ویژگی ابعاد بالا را دارد. این حجم بالای اطلاعاتی می‌تواند دقت کلی طبقه‌بندی پوشش زمینی را افزایش دهد. اما افزایش ابعاد داده در صورت ناکافی بودن تعداد نمونه‌های آموزشی ممکن است باعث پیچیده‌تر شدن طبقه‌بندی و رخ دادن پدیده نفرین ابعاد شود. یکی از راهکارهای حل این مشکل، استفاده از سیستم‌های طبقه‌بندی چندگانه (MCS) است که توانایی تقسیم و غلبه بر حجم بالای داده در مقایسه با طبقه‌بندی‌کننده‌های تکی را داراست. حتی برخی از روش‌های MCS می‌توانند با به‌کارگیری طبقه‌بندی‌کننده‌های ضعیف و ناپایدار همچون درخت تصمیم (DT) و شبکه عصبی (NN) به دقت بالایی در طبقه‌بندی ابعاد بالا دست یابند. هدف این مقاله نیز استفاده از چند روش مشهور MCS همچون آدابوست، بگینگ و جنگل‌های تصادفی به منظور بهبود دقت طبقه‌بندی پوشش زمینی از تصاویر POLSAR با ابعاد بالا است. داده‌های استفاده شده در این مقاله، تصاویر راداری رادارست-۲ از منطقه سانفرانسیسکو و تصویر ایرسار از منطقه فلورنسا است. برای طبقه‌بندی این دو تصویر، ۶۹ ویژگی پلاریمتریک از آن‌ها استخراج شد. دو جداساز NN و DT به‌عنوان طبقه‌بندی‌کننده پایه روش‌های آدابوست و بگینگ انتخاب شد. در ادامه، روش‌های MCS با طبقه‌بندی‌کننده‌های تکی NN و DT مقایسه شد. نتایج، نشان از دقت کلی بیشتر روش‌های MCS بین ۵٪-۸٪ برای طبقه‌بندی تصویر اول و ۹٪ تا ۱۶٪ برای طبقه‌بندی تصویر دوم داشت. حتی دقت تولید‌کننده و دقت کاربر روش‌های MCS در تمام کلاس‌ها نسبت به طبقه‌بندی‌کننده‌های تکی بیشتر بود. به‌گونه‌ای که در برخی کلاس‌ها این اختلاف بین ۲۰٪ تا حتی نزدیک به ۵۰٪ شد. این نتایج نشان داد که روش‌های MCS در مقایسه با طبقه‌بندی‌کننده‌های تکی نه تنها قادر به تولید دقت کلی بیشتر در طبقه‌بندی پوشش زمینی است، بلکه حتی کارایی و اعتمادپذیری نسبی بالاتری در تفکیک تک‌تک کلاس‌ها دارد.

**کلیدواژه‌ها:** سیستم طبقه‌بندی چندگانه، تصاویر تمام پلاریمتریک، رادار، فضای ویژگی ابعاد بالا.

\* نویسنده مکاتبه‌کننده: خیابان کارگر شمالی (امیرآباد)، پردیس دانشکده‌های فنی، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، گروه سنجش از دور.

تلفن: ۰۹۱۸۳۶۶۶۹۷۵

## ۱- مقدمه

تضمین کننده افزایش دقت کلی طبقه‌بندی بوده و حتی گاهی اوقات ممکن است باعث کاهش آن شود. همچنین روش‌های رپر نیز تنها برای طبقه‌بندی کننده به کار رفته در آن دقت بالایی دارد و ممکن است برای سایر طبقه‌بندی کننده‌ها دقت بالایی تولید نکند. ضمن آن که اکثر اوقات زمان محاسبات این روش‌ها بالا است.

راهکار دومی که می‌توان در یادگیری ماشین برای مسائل طبقه‌بندی ابعاد بالا مشاهده نمود، روش‌های مبتنی بر هسته<sup>۱</sup> و به‌طور خاص روش ماشین بردار پشتیبان<sup>۲</sup> (*SVM*) است. در ۱۵ سال اخیر، این روش در طبقه‌بندی داده‌های سنجش از دور به‌ویژه داده‌های ابعاد بالای فراطیفی و داده‌های تمام پولاریمتریک راداری استفاده شده است. ایده *SVM* در حالت دو کلاسه، معرفی یک ابرصفحه جداساز در فضای هسته است که فاصله با نزدیکترین نمونه‌های آموزشی هر دو کلاس را بیشینه نماید. این رویه باعث می‌شود تا *SVM* به نمونه‌های آموزشی کمتری نیاز پیدا کند. به همین دلیل به *SVM* یک ماشین هسته تنک گفته می‌شود که دارای قابلیت تعمیم‌پذیری بالاتری نسبت به روش‌های قدیمی‌تر یادگیری مانند شبکه عصبی و بیشترین شباهت است [۳]. با این حال یکی از مشکلات *SVM* دو کلاسه بودن آن است که البته با استراتژی‌هایی می‌توان آن را برای حالت چندکلاسه تعمیم داد [۳]. همچنین اگرچه استفاده از حقه هسته، *SVM* را از دردسر یافتن یک فضای نگاشت مناسب خلاص می‌کند اما با این حال افزایش تعداد هسته‌ها برای هر جفت نمونه آموزشی و زمان‌بر بودن آن یکی از مشکلات دیگر آن محسوب می‌شود.

علاوه بر دو راهکار قبلی، راهکار دیگر یادگیری ماشین

یکی از محصولات پرکاربرد اخیر سنجش از دور، تصویر تمام پولاریمتریک راداری (*POLSAR*) است که دارای هر چهار نوع پولاریزاسیون افقی-افقی، افقی-قائم، قائم-افقی و قائم-قائم می‌باشد. از یک تصویر *POLSAR*، یک داده با فضای ویژگی ابعاد بالا شامل ویژگی‌های ناشی از ماتریس‌های پراکنش، همدوسی و کواریانس، ویژگی‌های تولیدی از روش‌های تجزیه و همچنین شاخص‌های تفکیک‌کننده راداری ([۱]) قابل تولید است که قادر است در کاربردی همچون طبقه‌بندی پوشش زمینی باعث افزایش دقت کلی شود. با این حال تعداد فراوان ویژگی‌های پولاریمتریک ممکن است باعث پیچیده‌تر شدن مسأله و افزایش بار محاسباتی شود [۲]. همچنین، اگر تعداد نمونه‌های آموزشی نسبت به تعداد ویژگی‌ها ناکافی باشد و یا تعداد ویژگی‌ها نسبت به تعداد ثابتی از نمونه‌های آموزشی افزایش یابد، پدیده نفرین ابعاد (مشهور به پدیده هیوز) اتفاق می‌افتد. در این صورت استفاده از طبقه‌بندی کننده‌های قدیمی به تنهایی، جوابگوی حل مسایل طبقه‌بندی ابعاد بالا نخواهد بود [۳].

یکی از راهکارهایی که در یادگیری ماشین و شناسایی الگو برای رفع مشکل پدیده نفرین ابعاد یافت می‌شود، استفاده از روش‌های انتخاب ویژگی به‌منظور کاهش ابعاد است. تاکنون مطالعات متنوعی برای انتخاب ویژگی از تصاویر پولاریمتریک راداری ارائه شده است ([۱]، [۲]، [۴]، [۵]). روش‌های انتخاب ویژگی به دو دسته کلی فیلتر و رپر قابل تقسیم هستند و اساس آن‌ها، انتخاب زیرمجموعه ویژگی‌های مرتبط و حاوی اطلاعات و کنار گذاشتن ویژگی‌های اضافی و غیرمفید است [۶]. اگرچه این روش‌ها قادر به کاهش ابعاد داده و در نتیجه کاهش بار محاسباتی است، با این حال در برخی موارد، استفاده از روش‌های انتخاب ویژگی به‌ویژه روش‌های فیلتر نمی‌تواند

1 Kernel

2 Support Vector Machine

آدابوست داشت. در [۱۶]، درخت تصمیم بوسستینگ و  $RF$  برای طبقه‌بندی تصاویر چند زمانه راداری با طبقه‌بندی‌های تکی  $DT$  و بیشینه شباهت مقایسه شد. [۱۷] از روش‌های بگینگ و بوسستینگ برای طبقه‌بندی تصاویر پلاریمتریک امیسار در یک منطقه شهری-حاشیه شهری استفاده کرد و پس از مقایسه آن با  $SVM$ ، اذغان به کارایی و تعمیم‌پذیری بالاتر این دو روش کرد. [۱۸] با ادغام چندین ویژگی و سپس ادغام سه جداساز  $SVM$  اقدام به بهبود طبقه‌بندی تصاویر راداری کرد. در [۵] نیز چندین زیرمجموعه ویژگی توسط یک روش غیرپارامتریک انتخاب شده و سپس یک سیستم مجمعی مبتنی بر  $SVM$  به منظور طبقه‌بندی جنگل طراحی شد. در [۱۹]،  $RF$  همراه با طبقه‌بندی‌کننده‌های تکی همچون  $NN$ ،  $SVM$  و نزدیکترین همسایگی برای طبقه‌بندی دو تصویر راداری رادارست-۲ و ایرسار استفاده شد که نتایج حاصل نشان از دقت خوب و قابل قبول  $RF$  نسبت به روش‌های دیگر داشت. [۲۰] چندین روش مختلف  $MCS$  از جمله روش‌های بگینگ و بوسستینگ را برای تشخیص لکه‌های نفتی دریایی از تصاویر رادارست-۱ به کار برد که نتایج آن‌ها، کارایی بالای بگینگ و کارایی نسبتاً متوسط بوسستینگ را گزارش می‌داد. در مقاله [۲۱]، روش یادگیری کرنل‌های چندگانه تقویت شده<sup>۱</sup> و با استفاده از ویژگی‌های مکانی و پلاریمتریک برای طبقه‌بندی تصاویر پلاریمتریک استفاده شد.

با این حال در تمام مقالات بالا به جز [۵]، تعداد ویژگی پلاریمتریک کمی به کار رفته است. حتی در [۵] با اینکه ویژگی‌های پلاریمتریک زیادی استخراج شده ولی با روش انتخاب ویژگی ابتدا ابعاد داده کاهش یافته و سپس از  $MCS$  استفاده شده است. به همین دلیل در هیچ یک از این مقالات، توانایی و قابلیت

استفاده از مفهوم ادغام داده در سطح تصمیم یا ادغام طبقه‌بندی‌کننده‌ها است. این مفهوم که به روش‌های سیستم مجمعی<sup>۱</sup> یا سیستم‌های طبقه‌بندی چندگانه<sup>۲</sup> ( $MCS$ ) نیز معروف است می‌تواند به دو شیوه کلی ساخته شود [۳]: یا توسط ترکیبی از الگوریتم‌های مختلف طبقه‌بندی یا توسط ترکیبی از تنوعات یک الگوریتم یکسان طبقه‌بندی (الگوریتم پایه). معروفترین روش‌های نوع دوم، روش‌های بگینگ<sup>۳</sup>، بوسستینگ<sup>۴</sup> و جنگل‌های تصادفی<sup>۵</sup> ( $RF$ ) است. این روش‌ها برخلاف طبقه‌بندی‌کننده‌های تکی، قابلیت تقسیم و غلبه<sup>۶</sup> بر حجم بالای داده‌ها حتی با استفاده از طبقه‌بندی‌کننده‌های ضعیف و بی‌ثبات همچون درخت تصمیم<sup>۷</sup> ( $DT$ ) و شبکه عصبی<sup>۸</sup> ( $NN$ ) را دارا هستند [۳]، [۷]. بنابراین آن‌ها می‌توانند دقت کلی بیشتری نسبت به هر طبقه‌بندی‌کننده تکی تولید کنند.

تاکنون در سنجش از دور،  $MCS$ ‌ها به‌وفور برای طبقه‌بندی تصاویر نوری به‌ویژه تصاویر فراطیفی و داده‌های لیدار استفاده شده است (به‌عنوان مثال: [۳]، [۸] - [۱۳]). با این حال، این روش‌ها در مقالات کمتری برای طبقه‌بندی تصاویر راداری به‌ویژه تصاویر پلاریمتریک راداری به کار گرفته شده است. برای مثال، در [۱۴] مقایسه‌ای بین روش‌های آدابوست<sup>۹</sup> و بیشینه شباهت و در [۱۵] مقایسه‌ای بین آن با الگوریتم آنتروپی/زاویه آلفای میانگین به‌منظور طبقه‌بندی تصاویر رادارست-۲ صورت گرفت که نتایج هر دو نشان از کارایی بالاتر

- 1 Ensemble System
- 2 Multiple Classifier System
- 3 Bagging
- 4 Boosting
- 5 Random Forests
- 6 Divide and Conquer
- 7 Decision Tree
- 8 Neural Network
- 9 AdaBoost

در بخش ۳، داده‌ها و مناطق مطالعاتی معرفی می‌شود. داده‌های *POLSAR* به‌کار رفته در این مقاله از دو سنجنده مختلف راداری (رادارست-۲ ماهواره‌ای و ایرسار هوایی) و دو منطقه متفاوت (سانفرانسیسکو و فلورنسا) انتخاب می‌گردد. در بخش ۴، ابتدا ویژگی‌های پلاریمتریک ممکن از تصاویر مربوط استخراج شده، سپس روش‌های *MCS* و تکی پیاده‌سازی شده و نتایج آن‌ها با یکدیگر مقایسه و ارزیابی می‌شود. در نهایت بخش ۵ به نتیجه‌گیری مقاله ختم می‌شود.

## ۲- سیستم‌های طبقه‌بندی چندگانه

استفاده و ادغام چندین تصمیم در طبقه‌بندی نهایی به‌جای اتکا به تصمیم تکی، ایده اصلی یک *MCS* است [۳]. *MCS*ها برای فرض استوارند که یک مجموعه مستقل یا گوناگون از طبقه‌بندی‌کننده‌ها، خطاهای تکی تولید کنند که به‌وسیله اکثریت طبقه‌بندی‌کننده‌های دیگر تولید نمی‌شود. بنابراین، ترکیب خروجی‌شان می‌تواند بهتر از خروجی هر طبقه‌بندی‌کننده تکی باشد. یک راه تشکیل یک *MCS*، ترکیب تنوعات مختلف یک الگوریتم طبقه‌بندی‌کننده یکسان (به‌نام طبقه‌بندی‌کننده پایه) است [۳]. در این دسته، بگینگ و بوستینگ دو روش معروفی هستند که مبتنی بر دستکاری نمونه‌های آموزشی هستند [۲۲]. *RF* نیز یک نوع خاصی از بگینگ است که در این دسته قرار دارد. یکی از ویژگی‌های این روش‌ها، کارایی بالای آنها در طبقه‌بندی داده‌های ابعاد بالا حتی با استفاده از طبقه‌بندی‌کننده‌های ضعیف و ناپایدار همچون *DT* و *NN* است. در ادامه، هر سه روش به‌صورت خلاصه توضیح داده می‌شود. علاوه بر این، همانطور که در مقدمه نیز بیان شد، یک روش رأی‌گیری توسعه‌یافته در این مقاله پیشنهاد می‌شود که سعی می‌کند به‌صورت هدفمند ضعف‌های بالقوه موجود در روش رأی‌گیری حداکثریت کلاسیک را برطرف نماید. در ادامه، راجع به خصوصیات این روش و سازوکار آن

روش‌های *MCS* در مقایسه با روش‌های تکی به‌منظور طبقه‌بندی داده‌های ابعاد بالا بررسی نشده است. بنابراین، این پژوهش قصد دارد تا از روش‌های بگینگ، بوستینگ (آدابوست) و همچنین *RF* برای طبقه‌بندی داده تمام پلاریمتریک راداری با فضای ویژگی ابعاد بالا استفاده کند. دو طبقه‌بندی‌کننده *DT* و *NN* به‌عنوان طبقه‌بندی‌کننده‌های پایه برای الگوریتم‌های بگینگ و آدابوست انتخاب می‌شوند. بنابراین، ۵ روش *MCS* ساخته می‌شود شامل آدابوست (*DT*)، بگینگ (*DT*)، آدابوست (*NN*)، بگینگ (*NN*) و *RF*. علاوه بر این یک روش رأی‌گیری حداکثریت هدفمند<sup>۱</sup> (*OMV*) در این مقاله پیشنهاد می‌شود تا نتایج این ۵ روش *MCS* را با هم ادغام نماید. روش *OMV* پیشنهادی برخی نقاط ضعف و ابهامات موجود در روش رأی‌گیری حداکثریت (*MV*) را به‌صورت هدفمند برطرف می‌نماید. پس از آن، نتایج روش‌های *MCS* با نتایج طبقه‌بندی‌کننده‌های تکی *DT* و *NN* مقایسه می‌شود. نکته دیگر در این مقاله اینکه برای مقایسه و ارزیابی نتایج دو دسته روش، علاوه بر دقت کلی<sup>۲</sup> (*OA*) طبقه‌بندی از دقت‌های تولیدکننده<sup>۳</sup> (*PA*) و دقت‌های کاربر<sup>۴</sup> (*UA*) کلاس‌ها نیز به‌کار گرفته شده که در مقالات قبلی دیده نشده است. در اینصورت می‌توان توانایی و اعتمادپذیر بودن *MCS* را در تفکیک کلاس‌ها نیز بررسی نمود.

ساختار ادامه مقاله بدین ترتیب است: بخش ۲ ابتدا به توضیح اجمالی در مورد سیستم‌های طبقه‌بندی چندگانه و سه روش بوستینگ، بگینگ و *RF* می‌پردازد. همچنین در مورد روش *OMV* پیشنهادی به‌طور مفصل در این بخش توضیحاتی ارائه می‌شود. سپس

- 1 Objective Majority Voting
- 2 Overall Accuracy
- 3 Producer's Accuracy
- 4 User's Accuracy

مفصلاً توضیحاتی ارائه می‌شود.

## ۱-۲- بوستینگ

بوستینگ یک روش عمومی و مشهور در  $MCS$  است که برای افزایش دقت هر طبقه‌بندی کننده استفاده می‌شود. در سال ۱۹۹۰، شاپیر ثابت کرد که یک طبقه‌بندی کننده ضعیف-الگوریتمی که بهتر از یک حدس تصادفی عمل می‌کند- می‌تواند تبدیل به یک طبقه‌بندی کننده قوی شود که قادر است به‌طور صحیح بخش زیادی از نمونه‌ها را طبقه‌بندی کند [۷]. تاکنون، انواع مختلفی از الگوریتم‌های بوستینگ در یادگیری ماشین ارائه شده که در این میان الگوریتم آدابوست  $MI$  به‌طور وسیع‌تری به کار گرفته شده است. این الگوریتم اولین بار در سال ۱۹۹۷ توسط فرند و شاپیر پیشنهاد شد [۷]. در شروع الگوریتم، همه نمونه‌ها دارای وزن یکسان هستند. سپس، الگوریتم با افزایش وزن نمونه‌های اشتباه طبقه‌بندی شده و تمرکز بر روی آن‌ها ادامه می‌یابد. بنابراین خروجی این الگوریتم ناشی از یک روش رأی‌گیری حداکثریت وزن‌دار است. امتیاز اصلی آدابوست این است که در بسیاری از موارد، دقت کلی طبقه‌بندی را افزایش می‌دهد. آدابوست برای حل بسیاری از مسائل طبقه‌بندی شامل نمونه‌هایی که به‌طور مساوی قابل طبقه‌بندی شدن نیستند، مناسب می‌باشد [۲۲].

## ۲-۲- بگینگ

در یادگیری ماشین، بگینگ مخفف کلمه جمع‌آوری خودراه‌انداز<sup>۱</sup> است [۲۲]. در بگینگ، زیرمجموعه‌های آموزشی مختلف، به‌طور تصادفی و با جایگذاری از کل داده‌های آموزشی انتخاب می‌شود. سپس، یک طبقه‌بندی کننده مختلف از یک نوع یکسان توسط هر زیرمجموعه، آموزش داده می‌شود.

این طبقه‌بندی کننده‌های تکی با به‌کارگیری یک روش رأی‌گیری حداکثری از تصمیماتشان با یکدیگر ترکیب می‌شوند. برای یک نمونه آزمایشی، کلاسی که توسط اکثر طبقه‌بندی کننده‌ها انتخاب می‌شود، کلاس برگزیده است [۷]. بگینگ در برخی موارد مشابه با بوستینگ است چون هر دو روش یک مجموعه‌ای از طبقه‌بندی کننده‌ها را طراحی کرده و نتایجشان را با یک رأی‌گیری حداکثری ترکیب می‌کنند. به‌هرحال، این دو روش با یکدیگر تفاوت‌هایی دارند، ازجمله آنکه بگینگ همواره از نمونه‌برداری مجدد به‌جای وزن‌دهی مجدد استفاده می‌کند. ضمن آن‌که این روش توزیع نمونه‌ها را تغییر نمی‌دهد و همه کلاس‌ها دارای وزن یکسان در طول فرآیند رأی‌گیری هستند. به‌علاوه بگینگ می‌تواند به‌صورت موازی انجام شود یعنی همه  $bag$ ها به‌صورت یکمرتبه طراحی می‌شوند. درمقابل، بوستینگ همواره به‌صورت پشت‌سرهم و دنباله‌ای انجام می‌شود و هر مجموعه نمونه مبتنی بر آخرین وزنش است [۲۲].

## ۲-۳- RF

$RF$  یک مدل بهبودیافته از روش بگینگ است و علت نامگذاری آن به این دلیل است که از درخت‌های تصمیم ساخته می‌شود [۲۳]. یک  $RF$  می‌تواند از درخت‌های تصمیم تکی ساخته شود که پارامترهای آموزشی مخصوص آن به‌طور تصادفی تغییر می‌کند. همانند روش بگینگ، چنین پارامترهایی می‌توانند جایگذاری‌های بوت استرپ شده داده‌های آموزشی باشند درعین حال همانند روش‌های جایگذاری تصادفی، آن‌ها می‌توانند زیرمجموعه‌های ویژگی مختلف نیز باشند [۷].  $RF$  نشان داده است که از لحاظ دقت قابل مقایسه با بوستینگ است بدون آنکه آسیب‌های آن از جمله حساسیت به نویز و بار محاسباتی بالا را داشته باشد [۲۴].

1 Bootstrap Aggregating

## ۲-۴- روش رأی‌گیری حداکثریت هدفمند (OMV)

روش OMV در واقع توسعه یافته روش رأی‌گیری حداکثریت کلاسیک<sup>۱</sup> (MV) است که به صورت هدفمندتر از آن در ادغام نتایج طبقه‌بندی کننده‌ها عمل کند. MV یک روش پرکاربرد و مشهور برای ادغام خروجی چندین طبقه‌بندی کننده است. به عنوان مثال، اگر قصد ادغام نتایج ۵ طبقه‌بندی کننده با MV باشد، برای هر نمونه در صورتی که حداقل سه طبقه‌بندی کننده، رأی به یک کلاس یکسان بدهد، MV نمونه مورد نظر را به این کلاس (کلاس برنده) اختصاص می‌دهد. با این حال، این روش ممکن است در دو مورد کلی دچار ابهام شود. مورد اول زمانی که دو طبقه‌بندی کننده رأی به یک کلاس یکسان و دو طبقه‌بندی کننده دیگر رأی به کلاس یکسان دیگر دهند. مورد دوم زمانی که همه طبقه‌بندی کننده‌ها، رأی به کلاس‌های مختلف داده و هیچ دو طبقه‌بندی کننده به یک کلاس یکسان رأی ندهد. روش OMV پیشنهادی سعی می‌کند تا با استفاده از دقت تولید کننده (PA) و دقت کلی (OA) این دو ابهام را تا حدود زیادی رفع نماید. چارچوب کلی روش OMV در شکل ۱ دیده می‌شود.

مطابق با شکل ۱، عملکرد OMV بدین صورت است: (۱) اگر حداقل سه طبقه‌بندی کننده از پنج طبقه‌بندی کننده رأی به کلاس یکسان برای نمونه  $p$  دهند، آن گاه  $p$  به این کلاس تعلق خواهد داشت (مشابه با عملکرد MV). (۲) اگر دو طبقه‌بندی کننده رأی به یک کلاس یکسان دهند (مثلاً کلاس آ یا ب) و دو طبقه‌بندی کننده دیگر رأی به کلاس یکسان دیگر دهند (مثلاً کلاس ج یا د) در این حالت OMV براساس دقت‌های تولیدی طبقه‌بندی کننده‌ها برای کلاس‌ها تصمیم‌گیری می‌کند (رفع ابهام اول). (۳) اگر همه

طبقه‌بندی کننده‌ها تصمیمات متمایزی درباره  $p$  بگیرند، آن گاه  $p$  مربوط به کلاسی است که توسط طبقه‌بندی کننده با بیشترین OA انتخاب شده باشد (رفع ابهام دوم).

## ۳- داده‌ها و مناطق مطالعاتی

در این مقاله، دو داده پلاریمتریک مربوط به دو سنجنده راداری مختلف از دو منطقه متفاوت استفاده شده است. داده اول، مربوط به باند C سنجنده ماهواره‌ای رادارست-۲ اخذ شده از شهر سانفرانسیسکو است. قدرت تفکیک اسمی آن در راستای رنج اریب ۱۱/۱ متر در رنج نزدیک و ۱۰/۵ متر در رنج دور است. داده دوم مربوط به باند L سنجنده هوایی ایرسار اخذ شده از شهر فلورنسا با قدرت تفکیک اسمی ۱۰ متر است. تصویر رنگی پائولی تک دید منطقه اول و ۴-دید منطقه دوم در شکل ۲ الف و ب مشاهده می‌شود.

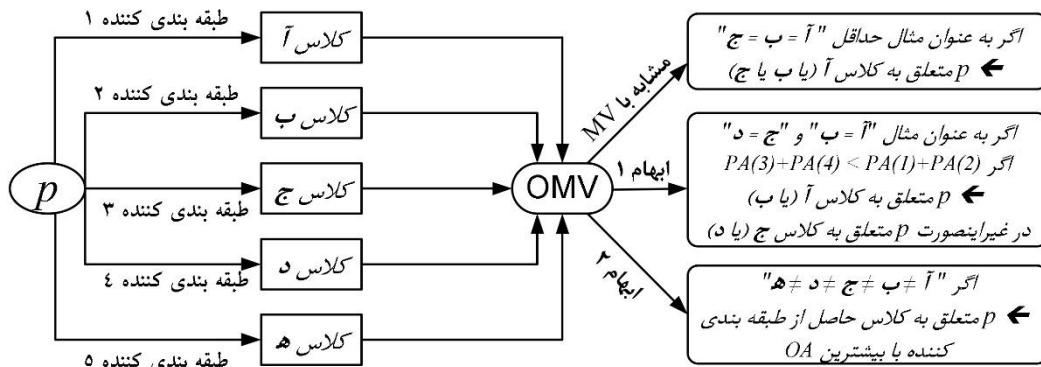
قبل از پردازش روی تصاویر مطالعاتی، فیلترینگ کاهش اسپیکل به عنوان پیش‌پردازش استفاده می‌شود. به منظور حفظ لبه‌ها و خصوصیات پلاریمتریک، در این مقاله فیلتر لی بهبود یافته به کار می‌رود [۲۵]. پس از انجام پیش‌پردازش، نمونه‌های آموزشی و آزمایشی هر کلاس از دو منطقه مورد مطالعاتی انتخاب می‌شود. براساس داده‌های رفرنس مناطق (شکل‌های ۲ ج و ۲ د)، چهار کلاس «آب، پوشش گیاهی، ساختمان و جاده» برای منطقه سانفرانسیسکو و ۱۱ کلاس «لوبیا، جنگل، آب، گوجه، دانه، گندم، خاک، یونجه، نخود، چمنزار و چوب» برای منطقه فلورنسا تعریف می‌شود. جدول ۱ و ۲ نام هر کلاس و تعداد نمونه‌های آموزشی و آزمایشی آن را برای هر منطقه به ترتیب نشان می‌دهد. به منظور ارزیابی منصفانه‌تر روش‌ها، تعداد نمونه‌های آزمایشی منطقه اول تقریباً ۵ برابر و تعداد نمونه‌های آزمایشی منطقه دوم تقریباً ۴ برابر تعداد نمونه‌های آموزشی‌شان در نظر گرفته شده است.

1 Majority Voting



استفاده از سیستم‌های طبقه‌بندی چندگانه به منظور...

ایمان خسروی، مهدی آخوندزاده




شکل ۱: چارچوب روش رأی گیری حداکثریت هدفمند (OMV) پیشنهاد شده در این مقاله.




(ب)



(الف)



(د)



(ج)

شکل ۲: تصویر رنگی پائولی مناطق مورد مطالعه. (الف) منطقه اول: سانفرانسیسکو. (ب) منطقه دوم: فلوولند. داده‌های واقعیت زمینی مناطق مورد مطالعه. (ج) منطقه اول: سانفرانسیسکو با ۴ کلاس آب، پوشش گیاهی، ساختمان و جاده. (د) منطقه دوم: فلوولند با ۱۱ کلاس لوبیا، جنگل، آب، گوجه، دانه، گندم، خاک، یونجه، نخود، چمنزار و چوب.

جدول ۱: تعداد نمونه‌های آموزشی و آزمایشی کلاس‌های تعریف شده در منطقه مطالعاتی اول سانفرانسیسکو.

کلاس	آب	پوشش گیاهی	ساختمان	جاده
# نمونه‌های آموزشی	۹۳	۷۹	۷۱	۵۵
# نمونه‌های آزمایشی	۴۲۴	۳۵۱	۳۰۳	۲۱۷

جدول ۲: تعداد نمونه‌های آموزشی و آزمایشی کلاس‌های تعریف‌شده در منطقه مطالعاتی دوم فلوولند.

کلاس	لوبیا	جنگل	آب	گوجه	دانه	گندم
# نمونه‌های آموزشی	۱۱۰	۱۰۳	۱۱۴	۱۱۵	۱۱۷	۱۲۲
# نمونه‌های آزمایشی	۴۴۱	۴۵۱	۴۰۳	۴۹۰	۴۴۵	۴۸۸
کلاس	خاک	یونجه	نخود	چمنزار	چوب	
# نمونه‌های آموزشی	۱۱۶	۱۱۲	۱۲۷	۱۱۵	۱۰۵	
# نمونه‌های آزمایشی	۴۳۱	۴۲۵	۴۶۰	۴۲۶	۴۷۵	

#### ۴- پیاده‌سازی و ارزیابی نتایج

##### ۴-۱- استخراج ویژگی‌های پلاریمتریک

برای طبقه‌بندی تصاویر مناطق مطالعاتی، لازم است تا ویژگی‌های مورد نیاز از تصاویر پلاریمتریک مربوطه استخراج شود. ویژگی‌های پلاریمتریک دارای تنوع فراوانی هستند که در مقالات گوناگون معرفی و استفاده شده‌اند. به‌طور کلی می‌توان این ویژگی‌ها را در سه دسته تقسیم‌بندی نمود [۲]: دسته اول،

شامل ویژگی‌هایی که به‌طور مستقیم از داده اصلی یا به‌عبارتی ماتریس‌های پراکنش، کواریانس و هم‌دوسی قابل استخراج می‌باشد. دسته دوم ویژگی‌های مستخرج از روش‌های تجزیه هدف و دسته سوم نیز به شاخص‌های تفکیک کننده راداری مشهور هستند. جدول ۳، این ویژگی‌ها، نام و تعداد هر یک را ارائه می‌دهد.

جدول ۳: ویژگی‌های پلاریمتریک استخراج شده در این مقاله.

تعداد	نماد ویژگی	عنوان ویژگی	ویژگی‌ها
۹	$[C]$	ماتریس کواریانس	ویژگی‌های اصلی
۸	$[T]$	ماتریس هم‌دوسی	
۳	$[C]$	ماتریس کواریانس پایه دایروی	
۳	$[Krog]$	روش تجزیه کروگاگر	ویژگی‌های تجزیه
۳	$[Free]$	روش تجزیه فریمن	
۴	$[Yama]$	روش تجزیه یاماگوچی	
۳۱	$H, A, \alpha, \beta, \lambda, \gamma, \delta, \text{asym}, HA, H(1-A), (1-H)A, (1-H)(1-A), SERD, DERD, RVI$	روش تجزیه بردار ویژه	شاخص‌های تفکیک کننده
۱	$SPAN$	توان کل شدت پراکنش یافته	
۱	$F$	پلاریزاسیون کسری	
۱	$[pol]$	درجه پلاریزاسیون	
۴	$CCC, Ro12, Ro13, Ro23$	ضریب همبستگی بین کانال‌ها	
۱	$ped$	ارتفاع پدستال	

کواریانس و دامنه دو عنصر اول بالا مثلثی ماتریس هم‌دوسی و (۳) دامنه ۳ عنصر بالا مثلثی ماتریس کواریانس در پایه پلاریزاسیون دایروی

در این مقاله برای ویژگی‌های اصلی، (۱) دامنه و فاز سه عنصر بالا مثلثی ماتریس کواریانس و ماتریس هم‌دوسی، (۲) دامنه سه عنصر بالا مثلثی ماتریس



بوده و لذا همواره حداقل دو طبقه‌بندی کننده دارای رأی مشترک به یک کلاس یکسان وجود خواهد داشت. جدول ۴ و ۵ نتایج ارزیابی دقت روش‌های فوق شامل PA کلاس‌ها، UA کلاس‌ها و OA طبقه‌بندی را برای هر دو داده ارائه می‌دهد. علاوه بر این، شکل‌های ۲ تا ۵، نمودارهای PA و UA روش‌های به کار رفته در دو داده را نمایش می‌دهد. کمیت‌های PA، UA و OA از ماتریس خطا ناشی می‌شود. PA هر کلاس از تقسیم عنصر قطری مربوط به آن کلاس بر مجموع عناصر سطر حاصل می‌شود (نسبت پیکسل‌های درست شناخته شده در کلاس مربوطه به کل پیکسل‌های شناخته شده در آن کلاس توسط الگوریتم) و UA هر کلاس نیز از تقسیم عنصر قطری مربوطه بر مجموع عناصر ستونی نظیر حاصل می‌شود (نسبت پیکسل‌های درست شناخته شده در کلاس مربوطه به کل پیکسل‌های مرجع در آن کلاس). مقدار بالای PA نشان‌دهنده کارایی بالای الگوریتم در شناسایی پیکسل‌های آن کلاس است. در حالی که مقدار بالای UA نشان‌دهنده اعتمادپذیری بالای پیکسل‌های شناسایی شده آن کلاس نسبت به داده فرانس است. OA نیز از تقسیم مجموع عناصر قطری بر تعداد کل پیکسل‌ها حاصل شده که یک معیار کلی از عملکرد الگوریتم در طبقه‌بندی ارائه می‌دهد [۲۶].

#### ۴-۳- بحث و بررسی

مطابق با نتایج جدول‌های ۴ و ۵ در هر دو داده، دقت کلی تمام MCS‌ها بیشتر از دقت کلی طبقه‌بندی کننده‌های تکی DT و NN شده است. برای داده سانفرانسیسکو (جدول ۴)، دقت کلی روش‌های DT و NN حدوداً ۸۵٪ و ۸۸٪ است در حالیکه روش‌های آدابوست و بگینگ که از هر دوی این طبقه‌بندی کننده‌ها به‌عنوان الگوریتم پایه استفاده کرده‌اند، توانسته‌اند دقت کلی حدوداً ۹۳٪ یعنی به ترتیب ۸٪ و ۵٪ بیشتر از DT و NN

استفاده شده است. برای ویژگی‌های ناشی از روش‌های تجزیه، هر دو دسته روش همدوس و غیرهمدوس به کار رفته است. این ویژگی‌ها شامل سه مولفه تک‌سطحی، دو سطحی و مارپیچی کروگاگر در روش‌های همدوس و سه مولفه تک‌سطحی، دو سطحی و حجمی فریمن، چهار مولفه تک‌سطحی، دو سطحی، حجمی و مارپیچی یاماگوچی و یازده مولفه مستخرج از روش تجزیه بردار ویژه ماتریس همدوسی در روش‌های غیرهمدوس می‌باشند. شاخص‌های تفکیک‌کننده SAR نیز شامل توان کل شدت پراکنش‌یافته، پلاریزاسیون کسری، درجه پلاریزاسیون، ضریب همبستگی بین کانال‌ها و ارتفاع پدستال می‌باشد. نهایتاً تعداد ۶۹ ویژگی پلاریمتریک برای طبقه‌بندی استخراج گردیده است.

#### ۴-۲- روش ارزیابی نتایج

در این بخش، ابتدا سه روش MCS توضیحی در بخش ۲ یعنی آدابوست، بگینگ (با هر دو طبقه‌بندی کننده DT و NN به‌عنوان طبقه‌بندی کننده پایه) و RF روی مناطق مطالعاتی پیاده‌سازی می‌شود. به‌منظور بررسی کارایی این روش‌ها، هر دو طبقه‌بندی کننده تکی DT و NN نیز روی داده‌های فوق به کار می‌رود. لازم به ذکر است که روش NN یک روش ناپایدار است و به شدت به نمونه‌های آموزشی وابسته است یعنی با هر بار اجرای روش، یک نتیجه مختلف و غیرمنحصر به فرد حاصل می‌شود. بنابراین در این بخش برای حصول بهترین نتایج حاصل از NN، چندین بار شبکه آموزش داده شده و نهایتاً بهترین نتایج با دقت کلی بالا گزارش می‌شود. علاوه بر این، نتایج حاصل از ۵ روش MCS به کار رفته در این مقاله توسط روش OMV پیشنهادی ادغام شده و با روش MV برای ادغام نتایج مقایسه می‌شود. لازم به ذکر است که ابهام دوم ذکر شده برای روش MV در مورد داده سانفرانسیسکو در این مقاله اتفاق نمی‌افتد. زیرا داده مورد نظر دارای چهار کلاس

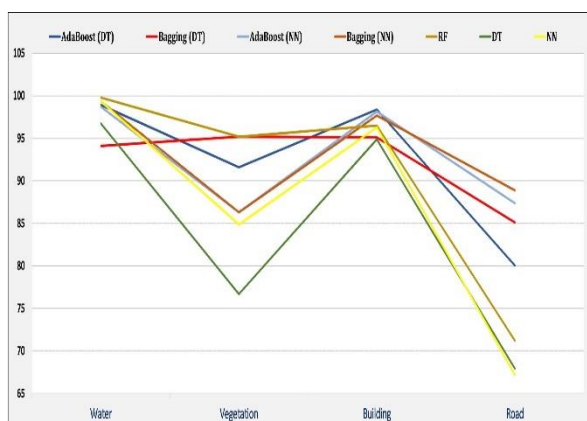
تولید نمایند. دقت کلی RF نیز ۹۱٪ بوده که حدود ۶٪ و ۳٪ بیشتر از روش‌های DT و NN بوده است.

جدول ۴: نتایج ارزیابی روش‌های طبقه‌بندی این مقاله روی منطقه مطالعاتی اول: سانفرانسیسکو.


روش	دقت	آب	گیاه	ساختمان	جاده	میانگین
آدابوست (DT)	PA	۱۰۰/۰۰	۹۸/۴۵	۸۳/۷۳	۸۹/۳۰	۹۲/۸۷
	UA	۹۸/۹۱	۹۱/۵۹	۹۸/۳۷	۸۰/۰۵	۹۲/۲۳
	OA	۹۲/۵۸				
بگینگ (DT)	PA	۱۰۰/۰۰	۸۳/۹۳	۸۷/۳۷	۹۲/۳۳	۹۴/۶۳
	UA	۹۴/۱۰	۹۵/۱۹	۹۵/۱۰	۸۵/۱۰	۹۲/۳۷
	OA	۹۲/۵۳				
آدابوست (NN)	PA	۱۰۰/۰۰	۹۹/۱۷	۸۸/۸۲	۸۴/۱۸	۹۳/۰۴
	UA	۹۸/۶۹	۸۶/۳۰	۹۸/۱۴	۸۷/۳۷	۹۲/۶۳
	OA	۹۲/۸۸				
بگینگ (NN)	PA	۱۰۰/۰۰	۹۲/۸۷	۸۹/۳۴	۸۶/۲۷	۹۳/۳۶
	UA	۹۹/۳۴	۸۶/۳۰	۹۷/۶۷	۸۸/۸۹	۹۳/۰۵
	OA	۹۳/۲۹				
RF	PA	۱۰۰/۰۰	۹۵/۴۲	۷۸/۷۱	۹۳/۶۹	۹۱/۹۶
	UA	۹۹/۷۸	۹۵/۱۹	۹۶/۵۰	۷۱/۲۱	۹۰/۶۷
	OA	۹۱/۱۷				
MV	PA	۱۰۰/۰۰	۹۷/۹۹	۸۸/۰۶	۹۱/۸۵	۹۴/۴۸
	UA	۹۹/۳۴	۹۳/۷۵	۹۸/۱۴	۸۵/۳۵	۹۴/۱۵
	OA	۹۴/۴۱				
OMV	PA	۱۰۰/۰۰	۹۷/۹۹	۸۸/۲۶	۹۱/۸۷	۹۴/۵۳
	UA	۹۹/۳۵	۹۳/۷۵	۹۸/۱۴	۸۵/۶۱	۹۴/۲۱
	OA	۹۴/۴۷				
DT	PA	۱۰۰/۰۰	۸۷/۴۰	۷۳/۷۳	۷۹/۳۵	۸۵/۱۲
	UA	۹۶/۷۲	۷۶/۶۸	۹۴/۸۷	۶۷/۹۳	۸۴/۰۵
	OA	۸۴/۶۴				
NN	PA	۱۰۰/۰۰	۹۶/۷۱	۷۵/۰۹	۸۰/۸۵	۸۸/۱۶
	UA	۹۹/۳۴	۸۴/۸۶	۹۶/۲۷	۶۷/۱۷	۸۶/۹۱
	OA	۸۷/۵۲				

جدول ۵: نتایج ارزیابی روش‌های طبقه‌بندی این مقاله روی منطقه مطالعاتی دوم: فولوند.

روش	دقت	لوبیا	جنگل	آب	گوجه	دانه	گندم	خاک	یونجه	نخود	چمنزار	چوب	میانگین
آدابوست (DT)	PA	۹۷/۰۰	۷۲/۱۹	۹۹/۲۶	۹۶/۸۲	۹۹/۰۵	۷۳/۲۶	۹۹/۵۳	۸۹/۱۰	۹۴/۲۹	۸۹/۴۰	۹۵/۲۸	۹۱/۳۸
	UA	۹۵/۲۴	۸۹/۸۰	۱۰۰/۰۰	۶۸/۳۷	۹۳/۹۳	۹۰/۳۷	۹۸/۳۸	۱۰۰/۰۰	۹۶/۹۶	۶۳/۳۸	۹۷/۶۸	۹۰/۳۷
	OA	۹۰/۱۹											
بگینگ (DT)	PA	۹۸/۶۱	۶۷/۷۵	۹۹/۷۵	۹۷/۷۳	۹۸/۰۱	۸۹/۵۱	۱۰۰/۰۰	۷۳/۰۲	۹۸/۹۱	۹۳/۴۲	۹۴/۳۸	۹۱/۹۲
	UA	۹۶/۳۷	۸۸/۰۳	۱۰۰/۰۰	۶۱/۴۳	۹۹/۷۸	۸۹/۱۴	۹۸/۶۱	۱۰۰/۰۰	۹۸/۴۸	۶۶/۶۷	۹۸/۹۵	۹۰/۶۸
	OA	۹۰/۴۲											
آدابوست (NN)	PA	۹۸/۶۴	۶۶/۸۴	۹۹/۵۱	۹۲/۹۳	۹۸/۴۵	۹۰/۹۴	۱۰۰/۰۰	۹۳/۰۰	۹۴/۲۶	۹۹/۴۴	۹۳/۶۸	۹۳/۴۳
	UA	۹۸/۶۴	۸۵/۸۱	۱۰۰/۰۰	۵۶/۳۳	۱۰۰/۰۰	۹۸/۷۷	۹۸/۱۴	۱۰۰/۰۰	۱۰۰/۰۰	۸۳/۳۳	۹۹/۷۹	۹۲/۸۰
	OA	۹۲/۵۰											
بگینگ (NN)	PA	۹۸/۶۵	۶۲/۲۸	۹۸/۵۳	۹۱/۸۷	۹۸/۴۵	۹۰/۷۷	۱۰۰/۰۰	۹۳/۶۱	۹۳/۱۲	۹۹/۴۵	۹۴/۷۹	۹۲/۸۷
	UA	۹۹/۰۹	۸۶/۰۳	۱۰۰/۰۰	۴۶/۱۲	۹۹/۷۸	۹۸/۷۷	۹۷/۶۸	۱۰۰/۰۰	۱۰۰/۰۰	۸۴/۹۸	۹۹/۵۸	۹۲/۰۰
	OA	۹۱/۶۱											
RF	PA	۹۵/۳۵	۵۸/۲۶	۹۹/۲۶	۹۳/۶۹	۹۹/۰۶	۸۷/۶۵	۹۹/۷۷	۶۸/۲۲	۹۹/۷۸	۹۲/۷۰	۹۵/۴۸	۸۹/۹۳
	UA	۹۲/۹۷	۸۶/۰۳	۱۰۰/۰۰	۴۲/۴۵	۹۴/۳۸	۸۷/۳۰	۹۸/۸۴	۱۰۰/۰۰	۹۷/۳۹	۶۸/۵۴	۹۷/۸۹	۸۷/۸۰
	OA	۸۷/۳۶											
MV	PA	۹۸/۴۲	۶۶/۲۲	۹۹/۷۵	۹۶/۹۶	۹۸/۴۵	۸۹/۵۰	۱۰۰/۰۰	۸۴/۴۹	۹۹/۷۸	۹۸/۲۲	۹۵/۹۴	۹۳/۴۳
	UA	۹۸/۸۷	۸۸/۲۵	۱۰۰/۰۰	۵۸/۵۷	۱۰۰/۰۰	۹۶/۱۱	۹۸/۶۱	۱۰۰/۰۰	۹۹/۱۳	۷۷/۷۰	۹۹/۵۸	۹۲/۴۴
	OA	۹۲/۱۶											
OMV	PA	۹۸/۴۲	۶۶/۶۷	۹۹/۷۵	۹۷/۰۰	۹۸/۶۷	۹۰/۵۲	۱۰۰/۰۰	۸۹/۶۶	۹۹/۵۶	۹۷/۸۰	۹۴/۲۲	۹۳/۸۴
	UA	۹۸/۸۷	۸۸/۲۵	۱۰۰/۰۰	۵۹/۳۹	۱۰۰/۰۰	۹۵/۹۰	۹۸/۶۱	۱۰۰/۰۰	۹۹/۱۳	۸۳/۵۷	۹۹/۵۸	۹۳/۰۳
	OA	۹۲/۷۳											
DT	PA	۷۶/۹۴	۷۰/۲۶	۷۹/۷۳	۷۱/۱۷	۹۸/۴۵	۷۳/۰۳	۷۴/۰۱	۸۴/۴۴	۶۸/۶۱	۷۵/۶۸	۵۷/۵۳	۷۵/۴۴
	UA	۹۲/۲۹	۶۰/۷۵	۷۲/۲۱	۴۸/۳۷	۷۱/۴۶	۷۶/۰۲	۸۲/۶۰	۹۵/۷۶	۸۴/۵۷	۶۵/۰۲	۷۱/۵۸	۷۴/۶۰
	OA	۷۴/۳۱											
NN	PA	۶۹/۳۵	۶۹/۷۵	۹۸/۰۵	۸۶/۶۵	۹۸/۹۴	۹۸/۱۴	۹۸/۹۴	۴۲/۳۷	۱۰۰/۰۰	۹۳/۴۹	۹۲/۵۳	۸۳/۲۲
	UA	۴۱/۰۴	۶۶/۹۶	۱۰۰/۰۰	۶۷/۵۵	۸۴/۲۷	۹۵/۲۹	۹۷/۹۱	۱۰۰/۰۰	۵۵/۲۲	۴۷/۱۸	۹۹/۱۶	۷۷/۶۹
	OA	۷۷/۶۱											

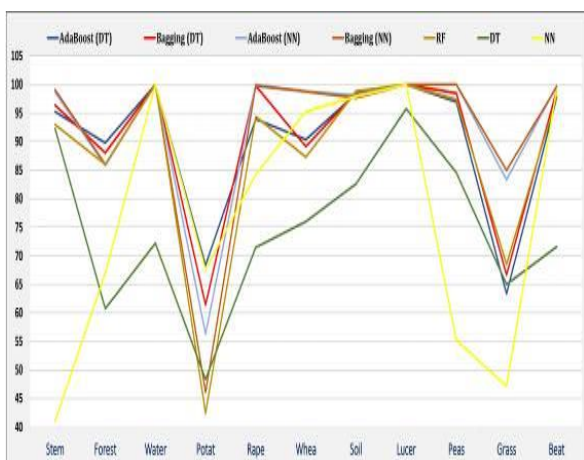


(ب)

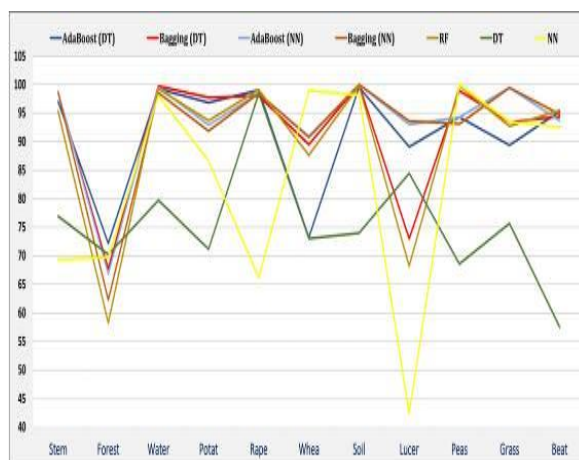


(الف)

شکل ۳: نمودار دقت‌های روش‌های استفاده‌شده در این مقاله برای داده سانفرانسیسکو بای (الف) نمودار PA، (ب) نمودار UA.



(ب)



(الف)

شکل ۴: نمودار دقت‌های روش‌های استفاده‌شده در این مقاله برای داده فلوولند (الف) نمودار PA، (ب) نمودار UA.

تولید کننده روش‌های آدابوست (DT) و بگینگ (DT) برابر با ۹۳٪ و ۹۵٪ و میانگین دقت کاربر آن‌ها برابر با ۹۲٪ می‌باشد، یعنی ۸٪ و ۱۰٪ بیشتر در دقت تولید کننده و ۸٪ بیشتر در دقت کاربر. همچنین میانگین دقت تولید کننده و میانگین دقت کاربر NN برابر با ۸۸٪ و ۸۷٪ است. در مقابل، آدابوست (NN) و بگینگ (NN) دارای میانگین دقت تولید کننده و کاربری حدوداً ۹۳٪ است یعنی حدود ۵٪ و ۶٪ بیشتر نسبت به NN. RF نیز میانگین دقت تولید کننده ۹۲٪ و میانگین دقت کاربر ۹۱٪ به دست آورده است یعنی ۷٪ و ۴٪ بیشتر در میانگین دقت تولید کننده و میانگین دقت کاربر نسبت به طبقه‌بندی کننده‌های تکی DT و NN.

برای داده فلوولند (جدول ۵) نیز موفقیت روش‌های MCS در میانگین دقت تولید کننده و میانگین دقت کاربر نسبت به طبقه‌بندی کننده‌های تکی نیز چشمگیر است. آدابوست (DT) و بگینگ (DT) دارای میانگین دقت تولید کننده ۹۱٪ و ۹۲٪ و میانگین دقت کاربر ۹۰٪ و ۹۱٪ هستند که نسبت به طبقه‌بندی کننده تکی DT به ترتیب ۱۶٪ و ۱۷٪ بیشتر در میانگین دقت تولید کننده و ۱۵٪ و ۱۶٪ بیشتر در میانگین دقت کاربر است که این یک اختلاف

در مورد داده فلوولند (جدول ۵) نیز روش‌های DT و NN به ترتیب دقت کلی برابر ۷۴٪ و ۷۸٪ تولید کرده‌اند. در مقابل، دقت کلی روش‌های آدابوست (DT) و بگینگ (DT) برابر ۹۰٪ (یعنی ۱۶٪ بیشتر از DT)، دقت کلی روش‌های آدابوست (NN) و بگینگ (NN) برابر ۹۳٪ و ۹۲٪ (حدود ۱۵٪ و ۱۴٪ بیشتر از NN) و نهایتاً دقت روش RF برابر ۸۷٪ یعنی حدود ۱۳٪ و ۹٪ بیشتر از دقت کلی روش DT و NN بوده است. در بین روش‌های MCS نیز دقت کلی روش‌ها بدین ترتیب بوده است: بگینگ (NN)، آدابوست (NN)، آدابوست (DT)، بگینگ (DT) و RF برای داده سانفرانسیسکو و برای داده فلوولند، آدابوست (NN)، بگینگ (NN)، بگینگ (DT)، آدابوست (DT) و RF.

اگرچه روش‌های MCS توانستند دقت کلی بهتری نسبت به طبقه‌بندی کننده‌های تکی تولید کنند، با این حال تفاوت بین این دو در دقت‌های تولید کننده و کاربر مشهودتر است. این تمایز در شکل‌های ۳ و ۴ نیز قابل مشاهده است. به‌عنوان مثال در جدول ۴ (داده سانفرانسیسکو)، میانگین دقت تولید کننده کلاس‌ها حاصل از DT برابر با ۸۵٪ و میانگین دقت کاربر آن برابر با ۸۴٪ است. در مقابل، میانگین دقت

دقت بالایی تولید نکند. مشکلی که در اکثر طبقه‌بندی کننده‌های تکی آماری مشاهده می‌شود. مقایسه بین دقت‌های تولیدی و کاربری کلاس‌های داده فلوولند، ارزش روش‌های MCS نسبت به طبقه‌بندی کننده‌های تکی DT و NN در طبقه‌بندی داده‌های ابعاد بالا را بیشتر نشان می‌دهد. این موضوع در شکل ۴ الف و ۴ ب نیز مشاهده می‌شود. به‌عنوان مثال، اختلاف بیش از ۲۵٪، ۳۰٪ و حتی ۵۰٪ دقت تولید کننده کلاس‌های لوبیا، دانه و یونجه حاصل از روش‌های MCS با NN. سایر نتایج در شکل‌های ۴ و همچنین جدول ۵ قابل مشاهده است. البته بی‌انصافی است اگر نگوییم که طبقه‌بندی کننده‌های تکی NN و DT در برخی کلاس‌ها، دقت تولید کننده نزدیک و در برخی حتی کمی بیشتر از دقت تولید کننده روش‌های MCS کسب کرده‌اند. با اینحال، همانطور که قبل از این گفته شد، میانگین دقت تولید کننده و کاربری حاصل از این دو طبقه‌بندی کننده تکی کمتر از روش‌های MCS شده است.

نتیجه قابل بیان دیگر اینکه، در بین روش‌های MCS، سرعت عملکرد RF نسبت به سایر روش‌ها بالاتر شده است و پس از آن روش بگینگ (DT) و بگینگ (NN) سرعت عملکرد قابل قبولی داشته‌اند. اما در مقابل، زمان بسیار زیادی صرف پیاده‌سازی و اجرای روش‌های آدابوست (NN) و آدابوست (DT) شد. در مورد داده سانفرانسیسکو نیز مشاهده می‌شود که دقت کلی و میانگین دقت تولید کننده و میانگین دقت کاربر روش RF نزدیک به روش‌های آدابوست و بگینگ است. هرچند که در مورد داده فلوولند، اختلاف بین RF با چهار روش MCS دیگر کمی بیشتر شده است باز با این حال به دلیل سرعت عملکرد بیشتر و کارایی و اطمینان پذیری قابل قبولش، می‌تواند گزینه مناسبتری جهت طبقه‌بندی داده‌های با ابعاد بالاتر نسبت به سایر روش‌های MCS به‌ویژه روش‌های بوستینگ به‌شمار آید.

بسیار چشمگیری است. همچنین آدابوست (NN) و بگینگ (NN) توانستند میانگین دقت تولید کننده ۹۳٪ و میانگین دقت کاربر ۹۳٪ و ۹۲٪ کسب کنند که ۱۰٪ بیشتر از میانگین دقت تولید کننده طبقه‌بندی کننده تکی NN و ۱۵٪ و ۱۴٪ بیشتر از میانگین دقت کاربر آن است. RF نیز با میانگین دقت تولید کننده ۹۰٪ و میانگین دقت کاربر ۸۸٪ توانسته عملکرد موفقتری نسبت به طبقه‌بندی کننده‌های تکی DT و NN داشته باشد.

به‌صورت موردی نیز اگر بخواهیم بررسی کنیم، به‌عنوان مثال در نتایج حاصل از طبقه‌بندی داده سانفرانسیسکو (جدول ۵ و شکل ۳) مشاهده می‌شود که دقت تولید کننده کلاس ساختمان حاصل از طبقه‌بندی کننده تکی DT و NN برابر با ۷۴٪ و ۷۵٪ بوده است درحالی‌که دقت تولید کننده آن حاصل از روش‌های MCS بین مقادیر ۷۹٪ (توسط RF) تا حدود ۸۹٪ (توسط آدابوست (NN) و بگینگ (NN)) متغیر است یعنی مقداری بین ۴٪ تا ۱۵٪ بیشتر. با رجوع به شکل ۳ الف، اختلاف بسیار زیاد دقت تولید کننده کلاس ساختمان، جاده و گیاه بین DT و روش‌های MCS و همچنین اختلاف دقت تولید کننده کلاس ساختمان و جاده بین NN و روش‌های MCS به‌وضوح قابل مشاهده است. همچنین در مورد دقت کاربر کلاس گیاه و جاده که طبقه‌بندی کننده تکی DT دارای مقادیر ۷۷٪ و ۶۸٪ شده و حال آنکه دقت کاربر کلاس گیاه برخی روش‌های MCS همچون RF و بگینگ (DT) حدود ۱۸٪ و دقت کاربر کلاس جاده روش بگینگ (NN) حدود ۲۱٪ بیشتر از آن شده است. این نتایج نشان از کارایی و اعتمادپذیری بالای RF و بگینگ (DT) در ادغام استراتژیک چندین درخت تصمیم (به جای تک درخت تصمیم) و غلبه بر حجم بالای داده‌ها دارد. همانطور که در مطالعات گذشته نیز بیان شده، DT طبقه‌بندی کننده چندان قوی به شمار نمی‌رود و به‌ویژه در طبقه‌بندی داده‌های با ابعاد بالا ممکن است با مشکل مواجه شود و

تکی ضعیف و ناپایدار به دست می‌آید که نشان می‌دهد ادغام این جداسازها توانایی غلبه بر حجم بالای داده را داراست، در صورتیکه همانگونه که مشاهده شد DT و NN تقریباً ضعیف‌ترین عملکرد را در کسب دقت تولید کننده و دقت کاربر برخی کلاس‌ها نسبت به روش‌های MCS داشتند. به گونه‌ای که مقادیرشان بین ۲۰٪ تا ۵۰٪ کمتر از روش‌های MCS بود. در واقع می‌توان گفت که طبقه‌بندی‌کننده‌های تکی آماری قدیمی معمولاً در طبقه‌بندی داده‌های با ابعاد بالا دچار مشکل می‌شوند به ویژه اگر تعداد ویژگی‌ها نسبت به یک تعداد نمونه آموزشی ثابت افزایش یابد. این نتیجه جدیدی نبود لیکن تاکنون، مطالعات بسیار کمی به استفاده از روش‌های MCS در طبقه‌بندی داده‌های راداری با ابعاد بالا پرداخته بود.

در بین روش‌های MCS، بگینگ (NN) در طبقه‌بندی داده سانفرانسیسکو و آدابوست (NN) در طبقه‌بندی داده فلوولند بهتر از سایر روش‌ها عمل کرد. با این حال RF نیز نتایج خوبی به دست آورد به گونه‌ای که در برخی موارد، دقت کلی آن نزدیک به روش‌های آدابوست و بگینگ شد. اما سرعت عملکرد RF خیلی بالاتر از روش‌های بگینگ و آدابوست بود و پس از آن روش بگینگ سرعت عملکرد بالاتری داشت. در مقابل، زمان محاسبات آدابوست بسیار طولانی شد. بنابراین به عنوان یک نتیجه دیگر می‌توان بیان کرد که استفاده از RF در طبقه‌بندی داده‌های با ابعاد بالاتر می‌تواند به صرفه‌تر از روش‌های بوستینگ باشد.

در پایان لازم است تا به نتایج حاصل از روش رأی‌گیری OMV پردازیم. همانطور که در جدول ۴ و ۵ مشاهده می‌شود، دقت کلی حاصل از روش OMV بین روش‌های MCS برای داده سانفرانسیسکو کمتر از ۱٪ و برای داده فلوولند بیشتر از ۱٪ نسبت به بیشترین دقت کلی روش‌های MCS شده است. همین مسأله در مورد میانگین دقت تولید کننده و میانگین دقت کاربر این روش نسبت به روش‌های MCS صادق است. همچنین اگر نتایج دقت‌های روش OMV با روش MV کلاسیک مقایسه شود، بهبود نسبی روش OMV در دو داده در جدول‌های ۴ و ۵ مشاهده می‌شود.

#### ۵- نتیجه‌گیری

این مقاله به یکی از راهکارهای یادگیری ماشین یعنی سیستم‌های طبقه‌بندی چندگانه برای بهبود دقت طبقه‌بندی داده ابعاد بالای POLSAR پرداخت. دو داده POLSAR از دو سنجنده مختلف راداری (رادارست-۲ و ایرسار) و از دو منطقه متفاوت در این مقاله استفاده شد. روش‌های MCS شامل آدابوست (DT)، بگینگ (DT)، آدابوست (NN)، بگینگ (NN) و RF روی هر دو داده پیاده شده و سپس نتایجشان با نتایج طبقه‌بندی‌کننده‌های تکی DT و NN مقایسه شد. نتایج نشان دادند که دقت کلی MCS بیشتر از دقت کلی طبقه‌بندی‌کننده‌های تکی DT و NN است. حتی از لحاظ میانگین PA و میانگین UA، روش‌های MCS خیلی بهتری از طبقه‌بندی‌کننده‌های تکی شد. خود روش‌های آدابوست، بگینگ و RF از ادغام همین جداسازهای

#### مراجع

- [1] C. Lardeux, P-L. Frison, C. Tison, J-C. Souyris, B. Stoll, B. Fruneau, and J-P. Rudant, "Support vector machine for multifrequency SAR polarimetric data classification," IEEE Trans. Geosci. Remote Sens., vol. 47, no. 12, pp. 4143-4152, 2009.
- [2] M. Salehi, M. R. Sahebi, and Y. Maghsoudi, "Improving the accuracy of urban land cover classification using Radarsat-2 PolSAR data," IEEE J. Selected Topics in Appl. Earth Observ. Remote Sens., vol. 7, no. 4, pp. 1394-1401, 2014.
- [3] I. Khosravi, and M. Mohammad-Beigi, "Multiple classifier systems for hyperspectral remote sensing data classification," J. the Indian Society of



- Remote Sens., 42(2), pp. 423–428, 2014.
- [4] Y. Maghsoudi, M. J. Collins, and D. G. Leckie, "Radarsat-2 polarimetric SAR data for Boreal forest classification using SVM and a wrapper feature selector," IEEE J. Selected Topics in Appl. Earth Observ. Remote Sens., vol. 6, no. 3, pp. 1531–1538, 2013.
- [5] Y. Maghsoudi, M. J. Collins, and D. G. Leckie, "Polarimetric classification of Boreal forest using nonparametric feature selection and multiple classifiers," Int. J. Appl. Earth Observ. Geoinf., vol. 19, pp. 139–150, 2012.
- [6] S. Khalid, T. Khalil, and S. Nasreen, "A survey of feature selection and feature extraction techniques in machine learning," IEEE Science and Information Conference (SAI), pp. 372–378, 2014.
- [7] R. Polikar, "Ensemble based systems in decision making," IEEE Circuits and Systems Mag., pp. 21–24, 2006.
- [8] J. A. Benediktsson, and I. Kanellopoulos, "Classification of multi-source and hyperspectral data based on decision fusion," IEEE Trans. Geosci. Remote Sens., vol. 37, no. 3, pp. 1367–1377, 1999.
- [9] J. Ham, Y. Chen, M. M. Crawford, and J. Gosh, "Investigation of the random forest framework for classification of hyperspectral data," IEEE Trans. Geosci. Remote Sens., vol. 43, no. 3, pp. 492–501, 2005.
- [10] B. Waske, and J. A. Benediktsson, "Fusion of support vector machines for classification of multisensor data," IEEE Trans. Geosci. Remote Sens., vol. 45, no. 12, pp. 3858–3866, 2007.
- [11] X. Ceamanos, B. Waske, J. A. Benediktsson, J. Chanussot, M. Fauvel, and J. R. Sveinsson, "A classifier ensemble based on fusion of support vector machines for classifying hyperspectral data," Int. J. Image and Data Fusion, 1(4), pp. 293–307, 2010.
- [12] T. C. Malleswara Rao, G. Jai Sankar, and T. Roopesh Kumar, "A hierarchical hybrid SVM method for classification of remotely sensed data," J. the Indian Society of Remote Sens., 40(2), pp. 191–200, 2012.
- [13] B. Bigdeli, F. Samadzadegan, and P. Reinartz, "A decision fusion method based on multiple support vector machine system for fusion of hyperspectral and LIDAR data," Int. J. Image and Data Fusion, 5(3), pp. 196–209, 2014.
- [14] C. Jiong, C. Yilun, and J. Yang, "A novel supervised classification scheme based on Adaboost for Polarimetric SAR," 9th International Conference on Signal Processing, 2008. ICSP 2008, pp. 2400–2403.
- [15] R. Min, X. Yang, and Z. Zhao, "Application of AdaBoost in polarimetric SAR image classification," 2009 IEEE Radar Conference, pp. 1–4.
- [16] B. Waske, and M. Braun, "Classifier ensemble for land cover mapping using multi-temporal SAR imagery," ISPRS J. Photogrammetry and Remote Sens., vol. 65, no. 5, pp. 450–457, 2009.
- [17] L. Zhang, X. Wang, M. Li, and W. M. Moon, "Classification of fully polarimetric SAR images based on ensemble learning and feature integration," Geoscience and Remote Sensing Symposium (IGARSS), 2014 IEEE International, pp. 2758–2761, 2014.
- [18] Y. Wang, Y. Zhang, T. Zhuoc, and M. Liao, "Ensemble learning based on multi-features fusion and selection for polarimetric SAR image classification," Signal Processing (ICSP), 2014 12th International Conference on, pp. 734–737, 2014.
- [19] S. Uhlmann and S. Kiranyaz, "Evaluation of classifiers for polarimetric SAR classification," Geoscience and Remote Sensing Symposium (IGARSS), 2013 IEEE International, pp. 775–778, 2013.
- [20] L. Xu, J. Li, and A. Brenning, "A comparative study of different classification techniques for marine oil spill identification using RADARSAT-1 imagery," Remote

Sens. Environ., 141, pp. 14–23, 2014.

- [21] P. Du, A. Samata, P. Gamba, X. Xiea, “Polarimetric SAR image classification by Boosted Multiple-Kernel Extreme Learning Machines with polarimetric and spatial features,” *Int. J. Remote Sens.*, 35:23, pp. 7978–7990.
- [22] G. J. Briem, J. A. Benediktsson, and J. R. Sveinsson, “Multiple classifiers applied to multisource remote sensing data,” *IEEE Trans. Geosci. Remote Sens.*, vol. 40, no. 10, pp. 2291–2292, 2002.
- [23] L. Breiman, “Random Forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [24] J. A. Benediktsson, J. Chanussot, and M. Fauvel, “Multiple classifier systems in remote sensing: from basics to recent developments,” *MCS’07 Proceedings of the 7th international conference on multiple classifier systems*. Heidelberg, Germany: Springer.
- [25] J. S. Lee, M. R. Grunes, and G. de Grandi, “Polarimetric SAR speckle filtering and its implication for classification,” *IEEE Trans. Geosci. Remote Sens.*, vol. 37, no. 5, pp. 2363–2373, 1999.
- [26] R.G. Congalton, and K. Green, “Assessing the accuracy of remotely sensed data principles and practices,” 2nd edition, Taylor & Francis Group, 2009.



## The Use of Multiple Classifier Systems For Improving the Classification Accuracy of High-Dimensional Fully Polarimetric SAR Images

Iman Khosravi<sup>1</sup>, Mehdi Akhondzadeh<sup>2</sup>

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

A fully polarimetric synthetic aperture radar (POLSAR) image can provide a high-dimensional data. This large amount of information can increase the overall accuracy of land-cover classification. But increasing the data dimensions if inadequately number of training samples may increase the complexity and cause the curse of dimensionality phenomenon. One of the strategies for solving this problem is the use of multiple classifier systems (MCS) that has the capability of divide and conquer to the large data as compared to the individual classifiers. In addition, some of MCS methods using the weak and unstable classifiers such as decision tree (DT) and neural network (NN) can obtain the high accuracy in high-dimensional data. The objective of this paper is also to use several popular MCS methods such as adaboost, bagging and random forests in order to improve the accuracy of land-cover classification from high-dimensional PolSAR images. The data used in this paper are Radarsat-2 image from San Francisco Bay and AIRSAR image of Flevoland. For classifying two these images, 69 polarimetric features were extracted from them. Two classifiers of DT and NN were chosen as the base classifiers of adaboost and bagging methods. In the next, the MCS methods were compared with the individual classifiers of DT and NN. The results indicated the higher overall accuracy of MCS methods between 5%–8% for classifying first image and 9%–16% for classifying second image. Even, the producer's accuracy and user's accuracy of MCS methods at all classes were more than the those of individual classifiers. So that at some classes, the difference was between 20% to even near 50%. These results confirmed that the MCS methods not only can produce higher overall accuracy at land-cover classification, but also they have the higher efficiency and reliability at discriminate individual classes.

**Key words:** multiple classifier system, fully polarimetric image, radar, SAR, high-dimensional.