

طبقه‌بندی تصاویر پلاریمتری رادار با روزنه مجازی بر اساس تلفیق طبقه‌بندی کننده ماشین بردار پشتیبان و میدان‌های تصادفی مارکوف

علی مسجدی^{۱*}، یاسر مقصودی^۲، محمدجواد ولدان زوج^۲

- ۱ دانشجوی کارشناسی ارشد سنجش از دور دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۲ استادیار گروه فتوگرامتری و سنجش از دور دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۳ دانشیار گروه فتوگرامتری و سنجش از دور دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۳۹۴/۰۶/۰۳ تاریخ پذیرش مقاله: ۱۳۹۴/۰۲/۳۱

چکیده

تحقیقات اخیر نشان داده است که طبقه‌بندی تصاویر سنجش از دور با کمک روش‌هایی که از اطلاعات مکانی در کنار اطلاعات طیفی استفاده می‌کند، نسبت به روش‌های مبتنی بر فقط اطلاعات طیفی، دقیق‌تر می‌باشد. اگرچه طبقه‌بندی به روش ماشین بردار پشتیبان دارای نتایج دقیق در بیشتر تصاویر سنجش از دور می‌باشد ولی این طبقه‌بندی کننده ذاتاً بر مبنای فقط اطلاعات تک پیکسل عمل می‌کند، که این یک محدودیت برای استفاده از آن می‌باشد. در این مقاله، تلفیق ماشین بردار پشتیبان با میدان‌های تصادفی مارکوف به منظور طبقه‌بندی داده‌های پلاریمتری رادار با روزنه مجازی از یک منطقه شامل گونه‌های مختلف جنگلی، پوشش گیاهی و آب براساس افزودن اطلاعات مکانی انجام می‌شود. به منظور انتخاب ویژگی‌های پلاریمتری مناسب و همچنین برآورد خودکار پارامترهای بهینه موردنیاز، از الگوریتم ژنتیک استفاده می‌شود. به منظور بررسی عملکرد روش پیشنهادی، نتایج بدست آمده از این روش با نتایج تعدادی از روش‌های پایه در طبقه‌بندی تصاویر پلاریمتری و دو روش جدید به نامهای aMRF و MSVC مقایسه شد. در نهایت طبقه‌بندی به این روش نسبت به روش‌های ویشارت، ویشارت-مارکوف، SVM، aMRF و MSVC به ترتیب ۱۹، ۱۱، ۱۴، ۵ و ۳ درصد افزایش دقت را نشان می‌دهد.

کلید واژه‌ها: میدان تصادفی مارکوف، ماشین بردار پشتیبان، طبقه‌بندی متنی تصاویر، اطلاعات مکانی، سنجش از دور.

*نویسنده مسئول: تهران، خیابان ولی‌عصر، بالاتر از میرداماد، پلاک ۱۳۴۶ دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی ژئودزی و ژئوماتیک.

تلفن: ۰۹۱۳۸۶۹۸۵۸

۱- مقدمه

نحوه پراکنش ارائه می‌کند و لی برای طبقه‌بندی تصاویر پیچیده، استفاده از ویژگی‌های اضافی برای رسیدن به دقت مناسب ضروری است [۳]. بنابراین بکارگیری روش‌هایی که بتواند از انواع مختلف ویژگی‌های قابل استخراج از تصاویر پلاریمتری استفاده کند به دلیل افزایش تفکیک‌پذیری بین کلاس‌های مختلف کاملاً منطقی به نظر می‌رسد. بر خلاف روش ویشارت که یکی از روش‌های پارامتریک می‌باشد، در روش‌های غیرپارامتریک نظیر ماشین بردار پشتیبان (SVM) [۴] و شبکه عصبی مصنوعی [۵]، توزیع آماری خاصی برای داده در نظر نمی‌گیرند و بنابراین استفاده از ویژگی‌های مختلف مانند ویژگی‌های بدست آمده از روش‌های مختلف تجزیه هدف و پارامترهای تفکیک‌کننده SAR که توزیع آماری مشخصی ندارند نیز ممکن خواهد بود.

روش ماشین بردار پشتیبان یکی از روش‌های مشهور طبقه‌بندی می‌باشد و علاوه بر اینکه قابلیت اجرا بر روی انواع مختلف ویژگی از جنس‌های مختلف و به تعداد زیاد را دارد، می‌تواند کلاس‌هایی را که به‌طور خطی قابل تفکیک نیستند را نیز از هم تفکیک کند. به عنوان مثال، در سال ۲۰۱۰، ژانگ و همکاران [۶] با اعمال الگوریتم تجزیه هدف مدل پراکنش چند مولفه‌ای بر روی ماتریس کوواریانس میانگین‌گیری شده، پنج پارامتر فیزیکی مربوط به انواع مختلف پراکنش را از تصویر پلاریمتری باند L استخراج کردند. سپس طبقه‌بندی تصویر را با اجرای الگوریتم SVM بر روی پارامترهای فیزیکی به همراه چهار ویژگی بافت شامل ویژگی‌های انرژی، کنتراست، همبستگی و مجموع میانگین که از ماتریس هم‌خدادی استخراج شده بودند، انجام دادند. در نهایت به دقت حدود ۸۵٪ در طبقه‌بندی رسیدند که توانایی روش SVM در استفاده از اطلاعات پراکنش در کنار اطلاعات مکانی را نشان می‌دهد.

طبقه‌بندی مناطق جنگلی به دلیل اهمیت این مناطق و لزوم مراقبت از آن‌ها یکی از کاربردهای مهم سنجش از دور می‌باشد. در این حوزه، تصاویر پلاریمتری رادار با روزنگارهای مجازی (SAR) به دلیل در اختیار داشتن اطلاعات پراکنش در چهار کanal HH، HV، VH و VV و در نتیجه وابستگی این تصاویر به شکل و ساختار گونه‌های جنگلی، دارای قابلیت‌های زیادی می‌باشند. یکی از روش‌های پایه در طبقه‌بندی این تصاویر، روش ویشارت می‌باشد [۱]. در این روش، توزیع ویشارت برای ماتریس کوواریانس در نظر گرفته می‌شود و شبیه به روش بیشینه شباهت، با استفاده از توزیع در نظر گرفته شده، فاصله ویشارت هر پیکسل از کلاس‌های مختلف محاسبه شده و در نهایت طبقه‌بندی بر اساس این فاصله انجام می‌شود. روش ویشارت به نوع مکانیزم پراکنش در هر کلاس وابسته می‌باشد. بنابراین با استفاده از این روش کلاس‌هایی که مکانیزم پراکنش متفاوتی دارند به راحتی از هم تفکیک می‌شوند. برای نمونه کلاس آب در مقایسه با کلاس منطقه شهری پراکنش بسیار متفاوتی دارد و در بسیاری از موارد این دو کلاس کاملاً از یکدیگر تشخیص داده می‌شوند. در مواردی که پراکنش کلاس‌ها شبیه به یکدیگر می‌باشد مانند طبقه‌بندی مناطق جنگلی با گونه‌های متفاوت و دارای مکانیزم پراکنش مشابه، استفاده کامل از تمام ویژگی‌های دارای قدرت تفکیک‌پذیری قبل استخراج از داده‌های پلاریمتری SAR ضروری به نظر می‌رسد. این در حالی است که روش ویشارت فقط بر روی استفاده از ماتریس کوواریانس (و یا ماتریس همدوسی) تمرکز دارد و بنابراین نمی‌تواند دقت خوبی در طبقه‌بندی این مناطق داشته باشد [۲]. بنابراین همانگونه که آلبرجانیز در تحقیق خود نشان داده است، روش‌های بر پایه ماتریس کوواریانس، اطلاعات سودمندی از

در تحقیقی که در سال ۲۰۱۱ انجام شده است از MRF با پنج نوع همسایگی مختلف برای برآورد احتمال اولیه کلاس‌ها در توزیع ویشارت استفاده شده است. در اینصورت نیاز به یک نقشه طبقه‌بندی اولیه است که در این تحقیق از روش SVM برای بدست آوردن آن استفاده شده است. سپس با استفاده از MRF تنظیم به صورت تکراری انجام می‌شود. به این صورت که با استفاده از نقشه طبقه‌بندی موجود، ماتریس کوواریانس برای هر کلاس محاسبه می‌شود و با استفاده از آن، همسایگی انطباقی برای هر پیکسل تعیین شده و طبقه‌بندی آن پیکسل بر اساس کمترین فاصله از کلاس‌های مختلف انجام می‌شود. این بخش تا زمانی که شرط پایان تکرار برقرار نشود ادامه می‌یابد. نتایج اجرای این روش موفقیت آن را ثابت نمود. یکی از معایب این روش این است که از طبقه‌بندی کننده SVM فقط برای تهیه نقشه اولیه استفاده شده است و در مراحل بعد از آن فقط از تلفیق روش ویشارت و MRF استفاده شده است [۱۲]. پس از آن و در تحقیقی دیگر، به منظور طبقه‌بندی تصاویر فراتیفی یک روش مکانی‌طیفی با نام aMRF ارائه شده است که در آن از SVM برای هر پیکسل و برای کلاس‌های مختلف یک خروجی احتمال که احتمال عضویت به آن کلاس را مشخص می‌نمود محاسبه شد. سپس این مقدار در یک رابطه خطی در کنار اطلاعات همسایگی که تعداد پیکسل‌های همسایه عضو کلاس‌های مختلف را شمارش می‌نمود، قرار گرفته و برچسب جدیدی برای هر پیکسل با توجه به اطلاعات همسایگی آن محاسبه می‌شود. این روش با حل مشکل پیکسل‌های نویزی در طبقه‌بندی، موجب بهبود نتایج طبقه‌بندی شد [۱۳]. پس از آن، در [۱۴]، یک روش جدیدتر بر اساس تلفیق MRF و SVM در یک چهارچوب واحد ارائه شده است.

با پیشرفت‌های حاصل شده در حوزه قدرت تفکیک مکانی، تصاویر برداشت شده دارای همبستگی بالا در بین پیکسل‌های مجاور خواهد بود. بنابراین توجه به اطلاعات همسایگی پیکسل در بهبود نتایج طبقه‌بندی ضروری به نظر می‌رسد. از طرف دیگر، یک جز جدا نشدنی تصاویر پلاریمتری SAR به دلیل نوع و هندسه تصویربرداری سنجنده‌های مربوطه، نویز اسپکل می‌باشد که تحلیل و تفسیر این تصاویر را پیچیده نموده و دقت طبقه‌بندی را کاهش می‌دهد [۲]. از طرفی می‌دانیم که در تصاویر سنجش از دور معمولاً سطح پوشش داده شده توسط یک پیکسل از سطح کلاس کمتر بوده و در نتیجه احتمال اینکه کلاس پیکسل مورد طبقه‌بندی مشابه با کلاس پیکسل‌های همسایه باشد، وجود دارد. این در حالی است که طبقه‌بندی کننده SVM روشی پیکسل مبنا می‌باشد. به عبارت دیگر این روش بر اساس مقادیر پیکسل‌ها و بدون توجه به اطلاعات همسایگی عمل می‌کند. بنابراین، این روش محدودیت ذاتی داشته و نتایج طبقه‌بندی بدست آمده با استفاده از آن دارای نویز نمک فلفلی می‌باشد.

استفاده از اطلاعات همسایگی در طبقه‌بندی، به عنوان یک منبع اطلاعاتی غنی توصیه می‌شود. این اطلاعات در تحقیقات گذشته به روش‌های مختلف در طبقه‌بندی مورد استفاده قرار گرفته است [۹-۷]. یکی از روش‌های استفاده از این اطلاعات، مدل‌سازی آن می‌باشد. یکی از بهترین و پرکاربردترین مدل‌های مورد استفاده در مدل‌سازی اطلاعات همسایگی، میدان تصادفی مارکوف است. این مدل معمولاً به صورت تکراری عمل نموده و باعث می‌شود برچسب هر پیکسل به برچسب پیکسل‌های همسایه نزدیک‌تر شود. در تحقیقات انجام شده معمولاً از مدل مارکوف در کنار روش طبقه‌بندی ویشارت برای بهبود دقت طبقه‌بندی تصاویر پلاریمتری بوسیله مدل‌سازی احتمالات اولیه کلاس‌ها، استفاده شده است [۱۰-۱۲]. به عنوان نمونه

تعدادی از این روش‌ها دارای دقت کافی نمی‌باشند و تعدادی دیگر زمان بر بوده و دارای محاسبات سنگین می‌باشد. بنابراین هدف از این مقاله ارائه یک روش جدید به منظور تلفیق SVM و مدل MRF است تا علاوه بر اینکه بتواند از قدرت هر دو به نحو بهینه‌ای استفاده کند، از نظر اجرا نیز زمان بر نباشد. در روش ارائه شده در این مقاله، ابتدا با استفاده از ویژگی‌های استخراج شده از تصویر ابتدا طبقه‌بندی به روش SVM انجام می‌گردد که حاصل آن یک نقشه طبقه‌بندی اولیه در مدل‌سازی اطلاعات مکانی توسط MRF مورد نیاز است. این مدل‌سازی با در نظر گرفتنتابع تصمیم‌گیری SVM صورت می‌گیرد. در نهایت نیز طبقه‌بندی به صورت تکراری انجام می‌گیرد.

این مقاله از ۶ بخش تشکیل شده است. بخش ۲ شامل مبانی تئوری مرتبط با این تحقیق می‌باشد. بخش ۳ روش پیشنهادی را توضیح می‌دهد. بخش ۴ به معرفی داده مورد استفاده و منطقه مورد مطالعه و نحوه آماده‌سازی داده پرداخته می‌شود و بخش ۵ نتایج اجرای الگوریتم پیشنهادی را بررسی می‌کند. در نهایت نیز نتیجه‌گیری و پیشنهادات ارائه شده است.

۲- مبانی تئوری تحقیق

۲-۱- طبقه‌بندی به روش SVM

روش SVM یکتابع خطی به نام f بین هر دو کلاس در یک فضای تبدیل یافته غیر خطی محاسبه نموده و از آن برای طبقه‌بندی دو کلاس استفاده می‌نماید. فرض کنیم I یک تصویر سنجش از دور با \mathbb{E}^d کانال، $x_i \in \mathbb{E}^d$ بردار ویژگی \mathcal{A} مین پیکسل و χ زیرمجموعه‌ای از \mathbb{E}^d شامل تمام نمونه‌های آموزشی x_i می‌باشد. در این صورت اگر F فضای برداری ایجاد شده با یک ضرب داخلی $\langle \cdot, \cdot \rangle_F$ و تبدیل $F \rightarrow \mathbb{X}$: وجود داشته باشد، آنگاه تابع کرنل

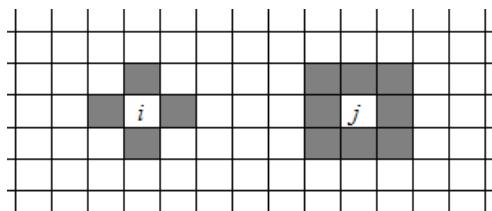
این روش بین تابع تصمیم‌گیری مارکوفین و کرنل SVM ارتباط برقرار می‌کند. این ارتباط توسطیک ویژگی مکانی-منی جدید که توسط مدل‌سازی MRF به دست می‌آید و وارد کرنل می‌شود ایجاد می‌شود. نتایج اجرای این روش SAR بر روی تصاویر چندطیغی، فراتیغی و MSVC نام‌گذاری شده است، نسبت به روش ارائه شده در [۱۳] دقیق‌تر است اما اجرای آن زمان بسیار بیشتری نیاز دارد. در تحقیق دیگری که در سال ۱۳۹۲ توسط درگاهی و همکاران انجام شده است، به منظور مقابله با مشکل وجود نویز اسپکل و همچنین بدست آوردن نقشه‌ای همگن از کلاس‌ها و حذف مشکل پیکسل‌های پراکنده از نقشه‌ی طبقه‌بندی، علاوه بر توزیع ویشارت، از مدل‌سازی اطلاعات همسایگی نیز استفاده شد. برای مدل‌سازی، مدل میدان تصادفی مارکوف به کار گرفته شده و با تلفیق آن با توزیع آماری تصاویر یعنی توزیع ویشارت طبقه‌بندی انجام شده است. در این تحقیق از یک مدل ایزوتروپیک با سیستم همسایگی مرتبه دوم استفاده شد و برای پیدا کردن بیشینه‌ی احتمال ثانویه معادل با کمینه‌ی تابع انرژی نیز از روش بیشینه‌سازی حاشیه‌ای مowx استفاده شده است. در نهایت با استفاده از این روش بیشترین دقت بدست آمده حدود ۸۵ درصد در طبقه‌بندی می‌باشد [۱۱]. نتایج بدست آمده از این تحقیقات نشان می‌دهد که استفاده از مدل میدان تصادفی مارکوف، ابزاری قدرتمند در مدل‌سازی اطلاعات همسایگی بوده و تلفیق آن با روش‌های مختلف طبقه‌بندی می‌تواند موفقیت‌آمیز باشد هرچند مقایسه کارهای انجام شده نشان از برتری طبقه‌بندی به روش SVM در مقایسه با استفاده از توزیع ویشارت و قانون بیز دارد. متأسفانه روش‌های ارائه شده در اینجا دارای دو مشکل است.

$$Q_{ij} = y_i y_j K(x_i, x_j), (i, j \in L)$$

مجموعه نمونه‌های آموزشی و C پارامتر تعدیل در این روش می‌باشد.

۲-۲- طبقه‌بندی تصویر به کمک میدان‌های تصادفی مارکوف

میدان‌های تصادفی مارکوف به علت قدرت و سرعت بالا، یکی از گسترده‌ترین مدل‌های تصادفی برای توزیع احتمال اولیه هر کلاس مدل‌سازی می‌شود [۱۵]. اگر فرض کنیم $\{\hat{o}_i\}_{i \in I}$ یک سیستم همسایگی بر روی I باشد در این صورت $\hat{o}_i \subset I$ مجموعه‌ای از پیکسل‌های همسایه اول پیکسل i می‌باشد. در شکل ۱ نمونه‌ای از همسایگی مرتبه اول و دوم مربوط به هر پیکسل را مشاهده می‌کنید که به ترتیب دارای ۴ و ۸ پیکسل همسایه می‌باشد.



شکل ۱: نمونه‌هایی از سیستم همسایگی: همسایگی مرتبه اول پیکسل i در سمت چپ و همسایگی مرتبه دوم پیکسل i در سمت راست نشان داده شده است.

میدان برچسب $\{y_i\}_{i \in I}$ یک میدان تصادفی مارکوف با توجه به این سیستم همسایگی خواهد بود اگر تابع چگالی احتمال آن $P(y_i)$ اکیداً مثبت بوده و ویژگی مارکوینتی طبق رابطه ۵ برقرار باشد.

$$P(y_i | y_{I-\{i\}}) = P(y_i | y_{\hat{o}_i}) \quad \text{رابطه (۵)}$$

فرض کنیم تابع چگالی احتمال توام x_I برای y_I داده شده بتواند به صورت $P(x_I | y_I) = \prod P(x_i | y_i)$ بیان شود که در آن $P(x_i | y_i)$ برابر

$K(x, x') \in \chi$ به صورت رابطه ۱ برای تمام $x, x' \in \chi$ تعريف می‌گردد [۱۵].

$$K(x, x') = \langle \varphi(x), \varphi(x') \rangle_F \quad \text{رابطه (۱)}$$

حال طبقه‌بندی کننده SVM می‌تواند یک تابع جداکننده خطی به صورت رابطه ۲ بیان شود.

$$f(x) = \langle w, \varphi(x) \rangle_F + b \quad \text{رابطه (۲)}$$

که w وزن و b شیفت تابع خطی در فضای F می‌باشد. این رابطه برای تمام نمونه‌های آموزشی به صورت جمع وزن‌دار تمام کرنل‌های قرار گرفته بر روی آن‌ها طبق رابطه ۳ بیان می‌شود. همچنین تابع کرنل می‌تواند از انواع توابع خطی، چندجمله‌ای، گوسین و ... باشد ولی باید در شرایط مرسّر^۱ صدق کند. در اینصورت تابع جداکننده خطی به صورت رابطه ۳ بیان می‌شود.

$$f(x) = \sum_{j \in S} \alpha_j y_j K(x, x_j) + b \quad \text{رابطه (۳)}$$

در این رابطه S زیرمجموعه‌ای از نمونه‌های آموزشی است که به اعضای آن بردارهای پشتیبان گفته می‌شود. در نهایت نیز، برچسب $\hat{y} = \text{sgn} f(x)$ به هر پیکسل توسط طبقه‌بندی کننده نسبت داده می‌شود. تعیین بردارهای پشتیبان و محاسبه ضرایب $\{\alpha_j\}_{j \in S}$ و b با حل مساله رابطه ۴ امکان‌پذیر است [۱۵].

$$\begin{cases} \min_{\alpha \in \mathbb{R}^l} \left(\frac{1}{2} \alpha^T Q \alpha - \mathbf{1}^T \alpha \right) \\ \alpha \in [0, C]^l, \quad \mathbf{y}_L^T \alpha = 0 \end{cases} \quad \text{رابطه (۴)}$$

در این رابطه l تعداد نمونه‌های آموزشی، 1 بردار $\mathbf{1}$ بعدی دارای مولفه‌های واحد و Q ماتریس به ابعاد $l \times l$ بوده که درایه (i, j) آن برابرست با

^۱ Mercer

اطلاعات مکانی است که این تلفیق توسط پارامتر β کنترل می‌شود و بنابراین β میزان نرم‌شدگی توسط MRF را مشخص می‌کند [۱۹].

در نهایت کلاس هر پیکسل از رابطه ۶ مشخص می‌گردد. به این صورت که مقدار انرژی ثانویه برای کلاس‌های مختلف محاسبه شده و در نهایت پیکسل به کلاسی تعلق می‌گیرد که انرژی ثانویه آن کمترین مقدار را داشته باشد.

۳- روش پیشنهادی

۱-۳- طبقه‌بندی تصویر به کمک تلفیق MRF و SVM روش

همانطور که بیان شد روش SVM دارای قدرت زیاد در طبقه‌بندی تصاویر می‌باشد. با این وجود عدم توانایی آن در استفاده از اطلاعات مکانی عیب اصلی این روش می‌باشد. بنابراین هدف ما در این بخش تلفیق طبقه‌بندی کننده SVM و MRF روش SVM در طبقه‌بندی و روش MRF در مدل‌سازی اطلاعات همسایگی می‌باشد. بدین منظور می‌بایست بین روابط ۳ و ۶ ارتباط منطقی برقرار گردد. از آنجایی که SVM اساساً یک روش دو کلاسی می‌باشد، اطلاعات مکانی برای هر پیکسل نیز باید به صورت دو کلاسی محاسبه گردد. بنابراین برای دو کلاس -۱ و +۱، برای کمینه‌سازی تابع انرژی بیان شده (طبقه‌بندی به روش بیشینه‌سازی ثانویه) از رابطه تابع انرژی تفاضلی با رابطه ۸ استفاده می‌شود [۱۴].

رابطه (۸)

$$\Delta U_i(x_i, y_{\partial_i}) = U_i(-1 | x_i, y_{\partial_i}) - U_i(+1 | x_i, y_{\partial_i})$$

طبقه‌بندی تابع انرژی تفاضلی می‌توان گفت:

با تابع چگالی احتمال y_i باشد (فرض استقلال شرایط) $\{y_i\}_{i \in I}$ میدان تصادفی مارکوف باشد. در این صورت طبق تئوری همرسی-کلیفورد^۱ بیشینه‌سازی توزیع توان ثانویه $P(y_i | x_i)$ برای تمام برچسب‌ها و برای تمام بردارهای ویژگی ارائه شده، با کمینه‌سازی تابع پتانسیل سراسری تعریف شده بر روی سیستم همسایگی معادل است [۱۴ و ۱۵]. همچنین توزیع توان ثانویه $P(y_i | x_i)$ به‌طور منحصر به فردی توسط جمع تمام توزیع‌های حاشیه‌ای ثانویه $(i \in I)$ $P(y_i | x_i, y_{\partial_i})$ بیان شود که در آن $\exp[-U_i(y_i | x_i, y_{\partial_i})]$ تابع انرژی ثانویه محلی بوده و از رابطه ۶ بدست می‌آید [۱۵].

رابطه (۶)

$$U_i(y_i | x_i, y_{\partial_i}) = -\ln p(x_i | y_i) + \beta E_i(y_i | y_{\partial_i})$$

در این رابطه β یک پارامتر مثبت، E_i تابع انرژی اولیه محلی مشخص کننده MRF انتخابی برای $\{y_i\}_{i \in I}$ که به عنوان نمونه می‌توان مدل مشهور پاتز^۲ با رابطه ۷ اشاره کرد [۱۶].

$$E_i(y_i | y_{\partial_i}) = -\sum_{j \in \partial_i} \delta(y_i, y_j)$$

رابطه (۷)

که در آن $\delta(a, b)$ برابر با ۱ است اگر $a = b$ باشد و در غیر اینصورت برابر با صفر خواهد بود. رابطه ۶ در واقع دو نوع داده را تلفیق می‌کند. نوع اول داده، اطلاعات آماری شرطی کلاس وابسته به اطلاعات ویژگی‌های استخراج شده است و نوع دوم

¹ Hammersley–Clifford

² Potts

$$\Delta U_i(x_i, y_{\theta_i}) = -\ln p(x_i | y_{-1}) + \ln p(x_i | y_{+1}) + \beta \varepsilon_i = \ln \frac{p(x_i | y_{+1})}{p(x_i | y_{-1})} + \beta \varepsilon_i \quad (9)$$

نویز نمک-فلفلی در نتیجه طبقه‌بندی با استفاده از این روش کاهش می‌یابد.

۲-۳- مدل میدان تصادفی مارکوف انطباقی

مدل میدان تصادفی مارکوف مورد استفاده اغلب یک ساختار همسایگی ثابت برای محاسبهتابع انرژی در کل تصویر استفاده می‌کند که این منجر به نرم‌شدگی بیش از حد تصویر و در نتیجه از دست دادن ساختارهای تصویری مانند لبه‌ها می‌گردد. برای حل این مشکل که به علت استفاده از ساختار همسایگی سخت ایجاد شده است، تعدادی مدل تصادفی مارکوف انطباقی ارائه شده است [۲۲-۲۰].

در بعضی از این مدل‌های ارائه شده، میزان همگن بودن تصویر در همسایگی نیز مورد توجه قرار می‌گیرد. در مناطق همگن تصویر، امکان مشابه بودن کلاس پیکسل‌های قرار گرفته در همسایگی پیکسل مورد مطالعه بیشتر خواهد بود در حالی که در مناطق ناهمگن، احتمال قرار گیری پیکسل‌های با کلاس‌های متفاوت در همسایگی بیشتر است. بنابراین باید ساختار همسایگی به گونه‌ای تعریف شود که میزان همگنی در آن ساختار بیش از دیگر ساختارهای ممکن باشد و همچنین تاثیر همسایگی در طبقه‌بندی، در مناطق همگن بیش از مناطق ناهمگن باشد [۲۳]. بدین منظور در این مقاله از ساختار همسایگی انطباقی و همچنین تابع انرژی انطباقی استفاده شده است. هرچه تصویر در یک منطقه همگن تر باشد، انحراف معیار تصویر در آن منطقه کمتر خواهد بود. بنابراین به منظور اندازه‌گیری میزان همگنی و ناهمگنی تصویر برای پیکسل‌های مختلف تصویر، از اندازه‌گیری انحراف معیار در همسایگی هر پیکسل استفاده می‌شود.

که در آن:

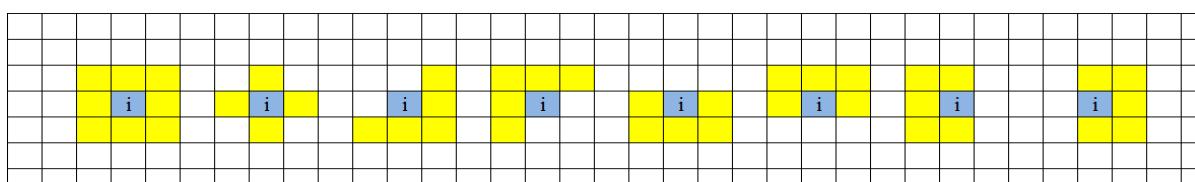
$$E_i = E_i(-1 | y_{\theta_i}) - E_i(+1 | y_{\theta_i}), \forall i \in I \quad (10)$$

رابطه ۹ از دو عبارت جداگانه تشکیل شده است. در عبارت اول احتمال تعلق پیکسل به کلاس ۱+ بر احتمال تعلق پیکسل به کلاس ۱- قرار گرفته و در عبارت دوم شاهد اختلاف توابع انرژی اولیه مربوط به دو کلاس هستیم. عبارت دوم با استفاده از رابطه ۷ و شمارش پیکسل‌های همسایه در یک نقشه طبقه‌بندی اولیه به راحتی قابل محاسبه است. برای محاسبه عبارت اول توجه شود که اگر پیکسل i متعلق به کلاس ۱+ باشد، آنگاه $p(x_i | y_{+1}) > p(x_i | y_{-1})$ و در این صورت

$$\ln \frac{p(x_i | y_{+1})}{p(x_i | y_{-1})} > 0 \quad \text{خواهد بود. متقابلاً اگر پیکسل } i \text{ متعلق به کلاس ۱- باشد، آنگاه} \\ \ln \frac{p(x_i | y_{-1})}{p(x_i | y_{+1})} < 0 \quad \text{خواهد بود. این مساله دقیقاً مشابه روش محاسبه کلاس هر پیکسل توسط تابع تصمیم‌گیری SVM می‌باشد. در مساله SVM در رابطه ۳ نیز هرگاه } f(x) \geq 0 \text{ باشد،} \\ \text{پیکسل به کلاس ۱+، و هرگاه } f(x) < 0 \text{ باشد، پیکسل به کلاس ۱- تعلق دارد. بنابراین با توجه به شباهت تابع تصمیم‌گیری SVM و عبارت اول رابطه ۹ داریم:} \\ \text{رابطه (11)}$$

$$\Delta U_i(x_i, y_{\theta_i}) = f(x) + \beta \varepsilon_i = \sum_{j \in S} \alpha_j y_j K(x, x_j) + b + \beta \varepsilon_i \quad \text{بنابراین، اگر} \\ \beta \varepsilon_i \geq 0 \quad \text{باشد، آنگاه} \\ \Delta U_i(x_i, y_{\theta_i}) \geq f_{SVM}(x) \quad \text{و اگر} \quad \beta \varepsilon_i < 0 \quad \text{باشد، آنگاه} \\ \Delta U_i(x_i, y_{\theta_i}) < f_{SVM}(x) \quad \text{خواهد بود.} \\ \text{این بدان معنی است که ابر صفحه برای هر پیکسل به سمت کلاسی حرکت می‌کند که پیکسل‌های همسایه بیشتری به آن کلاس تعلق دارند. در نتیجه}$$

کمترین انحراف معیار، به عنوان همسایگی پیکسل مورد مطالعه انتخاب می‌گردد [۲۳]. در شکل ۲، ساختارهای همسایگی مختلف نشان داده شده است که برای حالات مختلف قرارگیری پیکسل در مرز بین کلاس‌ها مناسب است. ساختار همسایگی اول در سمت چپ همان همسایگی متنبه دوم در مدل تصادفی مارکوف است که کل ناحیه اطراف پیکسل را پوشش می‌دهد و در مناطق بسیار همگن انتخاب می‌گردد.



شکل ۲: انواع سیستم‌های همسایگی برای پیکسل i مورد استفاده در این مقاله.

این ضریب برای هر پیکسل با قرارگیری یک پنجره با بعد مناسب (5×5 در این مقاله) بر روی تصویر توان و محاسبه انحراف معیار پنجره و سپس نرمال‌سازی آن در بازه صفر و یک، بدست می‌آید. تصویر توان در داده‌های پلاریمتری از جمع مقادیر ماتریس پراکنش به دست می‌آید. هر چه منطقه همگن‌تر باشد، مقدار این ضریب کمتر بوده و میزان تاثیر همسایگی در تابع انرژی بیشتر خواهد بود. از طرفی در مناطق مرز دو کلاس و مناطق بسیار ناهمگن، مقدار این ضریب به یک نزدیک شده و باعث کاهش اثر همسایگی در طبقه‌بندی می‌گردد.

۳-۳- الگوریتم روش پیشنهادی

فلوچارت الگوریتم روش پیشنهادی به منظور طبقه‌بندی تصویر پلاریمتری با استفاده از اطلاعات همسایگی در شکل ۳ نشان داده شده است. این الگوریتم یک طبقه‌بندی کننده بردار پشتیبان مارکوین انطباقی شامل سه مرحله اصلی می‌باشد که در این بخش شرح داده می‌شود.

۱-۲-۳- ساختار همسایگی انطباقی

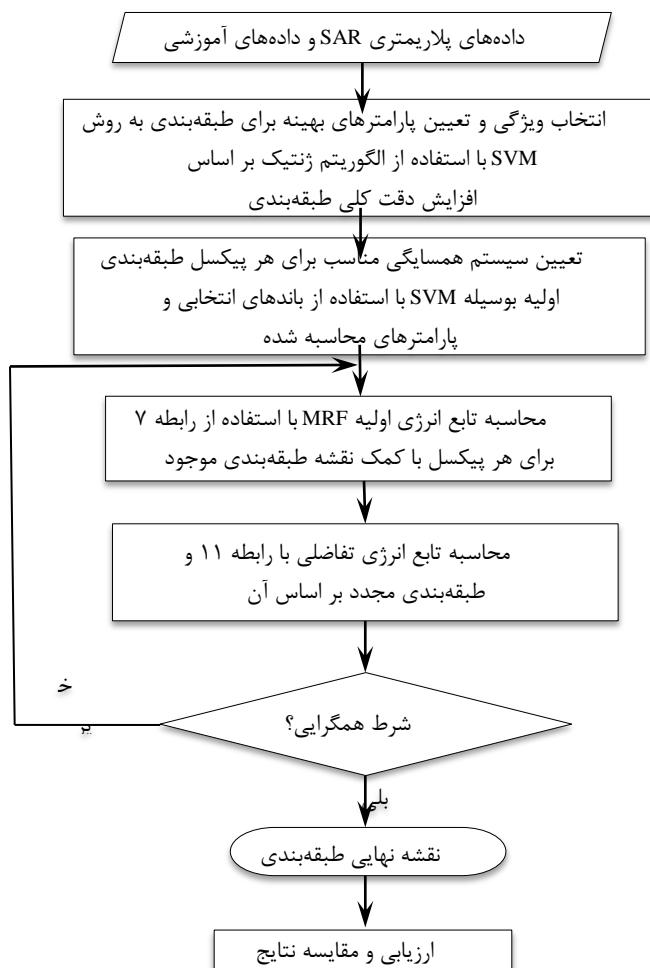
همانطور که بیان شد، استفاده از ساختار ثابت برای همسایگی در کل تصویر موجب نرم‌شدنگی بیش از حد تصویر حاصل از طبقه‌بندی می‌گردد. بنابراین هدف از تعریف همسایگی انطباقی، کاهش میزان نرم‌شدنگی بویژه در مناطق ناهمگن می‌باشد. بنابراین ابتدا ساختارهای همسایگی مختلف تعریف شده و سپس ازین آن‌ها، ساختار مطابق با بیشترین میزان همگنی، معادل با

۲-۲-۳- ساختار همسایگی انطباقی

همان‌طور که پیش از این بیان شد، تابع انرژی مورد استفاده در این مقاله از رابطه ۵ قابل محاسبه است. هدف ما در این قسمت این است که تاثیر همسایگی در مناطق ناهمگن کمتر از مناطق همگن باشد زیرا احتمال قرارگیری پیکسل‌های با کلاس متفاوت در یک همسایگی، در یک منطقه ناهمگن بیشتر است و توجه نکردن به این موضوع می‌تواند باعث نرم‌شدنگی تصویر حاصل از طبقه‌بندی گردد. بنابراین ضریب β را که برای تمام پیکسل‌های تصویر یکسان فرض شده بود را به صورت زیر تغییر می‌دهیم.

$$\beta_i = \beta(1 - std_i) \quad (12)$$

در اینصورت برای هر پیکسل تاثیر اطلاعات همسایگی که توسط پارامتر β_i مشخص می‌گردد، مقداری متفاوت خواهد بود. که در این رابطه، std_i ضریبی بین صفر و یک است و بیان کننده‌ی میزان ناهمگنی در همسایگی پیکسل مورد مطالعه می‌باشد.



شکل ۳: الگوریتم روش پیشنهادی.

پارامتر C در رابطه ۴ با استفاده از الگوریتم ژنتیک تعیین می‌گردد.

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (\text{رابطه } ۱۳)$$

طبقه‌بندی SVM به روش یک در برابر بک انجام می‌شود. بنابراین لازم است برای هر جفت کلاس مقدار بهینه برای پارامترهای طبقه‌بندی کننده برآورد گردد. تعداد کلاس‌ها برابر با ۶ کلاس و در نتیجه تعداد ۱۵ جفت کلاس وجود دارد. بنابراین نحوه کد نمودن مساله به صورت زیر می‌باشد.

۱-۳-۱- مرحله اول

در این مرحله انتخاب ویژگی و تعیین پارامترهای بهینه با استفاده از الگوریتم ژنتیک به صورت همزمان انجام می‌گردد. در این الگوریتم، دقت کلی طبقه‌بندی به عنوان معیار ارزیابی استفاده شده است. در این مقاله از کرنل گوسین با رابطه ۱۳ در طبقه‌بندی کننده SVM استفاده می‌گردد. از تصویر پلاریمتری موجود، ۸۸ ویژگی استخراج می‌گردد که در بخش ۳-۴ به آن می‌پردازیم. ویژگی‌های مناسب، مقدار بهینه برای پارامتر σ موجود در این کرنل و مقدار بهینه برای

حاصل از این مرحله ورودی مرحله دوم می‌باشد.
همچنین سیستم همسایگی مناسب برای هر پیکسل در
این مرحله تعیین می‌شود.

۲-۳-۳- مرحله دوم

در این مرحله ابتدا تابع انرژی اولیه MRF برای هر پیکسل با کمک نقشه طبقه‌بندی موجود محاسبه می‌گردد. سپس طبقه‌بندی این بار با استفاده از رابطه ۱۱ انجام می‌گردد. همانطور که بیان شد این رابطه شبیه به رابطه SVM بوده و طبقه‌بندی نیز مشابه با آن ابتدا برای هر جفت کلاس انجام شده و سپس نقشه طبقه‌بندی نهایی با استفاده از روش یک در برابر یک بدست می‌آید. بدین ترتیب نقشه‌ی طبقه‌بندی جدید بدست می‌آید. حال شرط همگرایی بررسی می‌شود بدین صورت که اگر درصد تغییر برچسب پیکسل‌ها بیش از حداستانه (تعیداد ۱ درصد کل پیکسل‌ها) در نظر گرفته شده باشد، این مرحله تکرار می‌گردد. در غیر اینصورت تکرار متوقف می‌شود و نتیجه‌ی این مرحله خروجی نهایی طبقه‌بندی خواهد بود. در نهایت نیز ارزیابی روش مورد استفاده و برآورد مزايا و معایب احتمالي روش با استفاده از دقت کلی طبقه‌بندی حاصل از ماتریس ابهام بدست آمده با استفاده از داده‌های آزمایشي، انجام می‌شود.

۴- منطقه مطالعاتی و آماده‌سازی داده

۴-۱- منطقه مطالعاتی و داده اولیه

منطقه‌ی مورد مطالعه در این تحقیق، یک منطقه جنگلی به نام پتاواوا در ایالت انتاریو، یکی از ایالتهای شرقی کشور کانادا می‌باشد. این منطقه شامل نواحی جنگل، پوشش گیاهی و آب می‌باشد. ناحیه جنگلی به‌طور عمده از درختان نرم چوب و سخت چوب تشکیل شده است که چهار گونه درختی شامل بلوط قرمز (Or)، صنوبر (P_o)، کاج قرمز (Pr) و کاج سفید (Pw) و دو کلاس

۱. تعداد ۸۸ ژن اول در کروموزوم معادل با ۸۸ ویژگی استخراج شده می‌باشد. هر ژن که مقدار یک بگیرد معادل با انتخاب آن ویژگی و در صورتی که مقدار صفر بگیرد به معنای نامناسب بودن آن ویژگی می‌باشد.

۲. برای هر جفت کلاس مقدار پارامتر C می‌تواند بین صفر تا ۱۰۰ تغییر کند. بنابراین تعداد ۷ ژن برای این بازه در مبنای دو مورد نیاز می‌باشد و پس از مقدار دهی به مبنای ۱۰ بردۀ می‌شود. چون تعداد ۱۵ جفت کلاس داریم، ۱۰۵ ژن بعدی در هر کروموزوم به این پارامتر اختصاص می‌یابد.

۳. برای هر جفت کلاس مقدار پارامتر σ^2 می‌تواند بین صفر تا ۲۵ با دقت ۰/۱ اعشار، تغییر کند. بنابراین تعداد ۸ ژن برای این بازه در مبنای دو مورد نیاز می‌باشد و پس از مقدار دهی به مبنای ۱۰ بردۀ می‌شود سپس بر ده تقسیم می‌شود. بنابراین ۱۲۰ ژن بعدی در هر کروموزوم نیز به این پارامتر اختصاص می‌یابد.

در مجموع هر کروموزوم به تعداد ۳۱۳ ژن نیاز دارد. در این الگوریتم جمعیت اولیه برابر با ۵۰۰ کروموزوم به صورت تصادفی تولید شد. در هر نسل ۱۰ کروموزوم برتر به نسل بعد انتقال پیدا می‌کنند. همچنین از روش تورنممنت^۱ برای انتخاب والدین، تقاطع تک نقطه‌ای با نرخ ۸۰٪ و جهش یکنواخت استفاده شد. در صورتی که تفاوت بین بهترین نتیجه ۱۰ نسل متوالی از ۰/۰۰۰۱ کمتر باشد، الگوریتم متوقف خواهد شد.

پس از تعیین باند و پارامترهای بهینه، طبقه‌بندی به روش SVM انجام می‌گردد. نقشه طبقه‌بندی

^۱ Tournament

برای استخراج پارامترهای تجزیه و طبقه‌بندی مورد نیاز می‌باشند. این کار بدون هیچ گونه میانگین‌گیری بر روی پیکسل‌ها و بافرض تئوری معکوس‌پذیری تارگت ($S_{HV} = S_{VH}$) انجام می‌شود. سپس از فیلتر BoxCar با ابعاد 7×7 به منظور حذف نویز اسپکل استفاده می‌شود. دلیل انتخاب این فیلتر، سادگی محاسبات و همچنین عدم نیاز به تعیین مرز دقیق بین کلاس‌ها می‌باشد [11]. مرحله مهم دیگر قبل از استفاده از تصاویر، تصحیح هندسی و زمین مرجع سازی است. برای انجام این مرحله از نرم‌افزار Mapready ASF می‌استفاده می‌شود. در این مرحله از مدل ارتفاعی رقومی زمین مربوط به منطقه مورد مطالعه نیز به منظور انجام تصحیح هندسی دقیق و کاهش خطاهای مربوط به توپوگرافی زمین استفاده می‌شود. بنابراین ماتریس هندسی تصحیح هندسی و زمین مرجع می‌گردد و سپس از آن ویژگی‌های مورد نظر استخراج می‌شوند. در اینصورت ویژگی‌های استخراج شده نیز تصحیح شده و زمین مرجع می‌باشند.

۳-۴- استخراج ویژگی

در این مقاله از ویژگی‌های مختلف قابل استخراج از داده‌های پلاریمتری استفاده شده است. این ویژگی‌ها عبارتند از: عناصر ماتریس پراکندگی، عناصر حاصل از تجزیه هدف و ویژگی‌های تفکیک کننده SAR. ویژگی‌های بیان شده با استفاده از نرم‌افزار POLSAR 4.2 pro و از ماتریس هندسی پس از انجام مراحل تصحیح هندسی و زمین مرجع سازی بدست می‌آید. در مجموع ۷۸ ویژگی از داده پلاریمتری استخراج شد که در جدول ۲ قابل مشاهده است. برای اطلاع از جزئیات بیشتر راجع به هر کدام از این ویژگی‌ها به مراجع [۲] مراجعه شود.

پوشش گیاهی (Gv) و آب (Wa) مدنظر می‌باشد. تصویر مورد استفاده در این تحقیق توسط ماهواره رادارست-۲ در سال ۲۰۰۹ از منطقه مذکور، به صورت پلاریمتری اخذ شده است. از مشخصات اصلی رادارست-۲ می‌توان به، باند C با طول موج ۵/۵۵ سانتی‌متر و فرکانس ۵/۴۰۵ گیگاهرتز و قابلیت اخذ داده در هر چهار پلاریزاسیون HH، HV، VH و VV اشاره کرد. تصاویر در حالت SLC^۱ بوده و قدرت تفکیک در جهت رنج و آزیموت به ترتیب برابر با ۱۱ و ۹ متر است. قسمت الف در شکل ۴ تصویر منطقه را به صورت ترکیب رنگی پائولی و قسمت ب نمایی از منطقه در Google Earth را نشان می‌دهد. داده‌های مرجع زمینی (آموزشی و آزمایشی) از نقشه‌های سال ۲۰۰۲ منطقه، عکس‌های فتوگرامتری موجود از منطقه، تصاویر لندست ETM+ و بازدیدهای زمینی جمع‌آوری شده است و پس از آن برای تاریخ اخذ تصویر (سال ۲۰۰۹) بروز شده است. قسمتی از این داده‌ها به عنوان داده آموزشی، برای تخمین پارامترهای مورد نیاز و آموزش طبقه‌بندی کننده به کار می‌رود و بخشی دیگر به صورت داده آزمایشی برای ارزیابی نتایج استفاده می‌شوند. جدول ۱ مجموعه نهایی از کلاس‌ها و تعداد نمونه‌ها در هر کلاس را نشان می‌دهد. شکل ۴ قسمت پ نیز نقشه داده‌های واقیت زمینی استفاده شده را نشان می‌دهد.

۴- پیش‌پردازش داده

جهت آماده‌سازی و آنالیزهای اولیه تصاویر از نرم‌افزار POLSAR pro 4.2 استفاده می‌شود. تصویر خام ورودی شامل مقادیر شدت رسیده به سنجنده می‌باشد که کمیت نسبت مقدار شدت دریافتی به شدت ارسالی (σ^0) از آن استخراج می‌گردد. مرحله بعد استخراج ماتریس‌های کوریانس و هندسی است، که

^۱ Single Look Complex



شکل ۴: نمایی از منطقه: (الف) زیر تصویر مورد استفاده به صورت ترکیب رنگی پانولی، (ب) منطقه مورد مطالعه در Google Earth و (پ) نقشه واقعیت زمینی.

جدول ۱: لیست کلاس‌ها و داده‌های آموزشی و آزمایشی برای هر کلاس

کلاس	توضیح	تعداد نمونه آموزشی	تعداد نمونه آزمایشی	
O	بلوط قرمز	۷۷۶	۸۸۲	r
Po	صنوبر	۸۴۵	۷۱۴	
Pr	کاج قرمز	۶۴۵	۸۸۶	
Pw	کاج سفید	۴۲۵	۵۲۰	
Gv	پوشش گیاهی	۱۵۶۷	۱۷۷۶	
Wa	آب	۶۸۲	۶۳۳	
مجموع				۴۹۲۸
۵۴۱۱				

جدول ۲: ویژگی‌های پلاریمتری مورد استفاده در این تحقیق

ویژگی	توصیف	تعداد ویژگی
ویژگی‌های اصلی	Scattering, Covariance, and Coherency matrix elements	۱۱
ویژگی‌های حاصل از تجزیه	Huynen, H / A / α , Yamaguchi, Touzi, Barends, Freeman, Holm	۵۹
توصیف کننده‌های SAR	SPAN, Pedestal height, Degree and completely polarization extrema, Received power extrema, Correlation coefficients, Depolarization ratio, Fractional polarization	۱۸

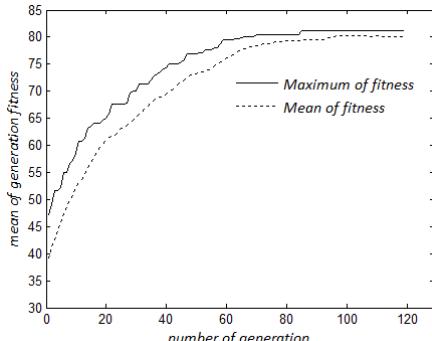
به دست آمده از ماتریس ابهام، آن‌ها را مقایسه می‌کنیم. در ابتدا و همانطور که بیان شد، برای انتخاب ویژگی‌های مناسب و تعیین پارامترهای SVM از الگوریتم ژنتیک استفاده می‌گردد. شکل ۵ نحوه همگرایی این الگوریتم را نشان می‌دهد. از تعداد ۸۸ ویژگی اولیه تعداد ۱۶ ویژگی

۵- نتایج تجربی

به منظور بررسی دقیقت و کارایی الگوریتم پیشنهادی، داده پلاریمتری شرح داده شده در بخش قبل را با استفاده از الگوریتم پیشنهادی و با تعداد دیگری از روش‌های ارائه شده در زمینه تلفیق MRF و SVM طبقه‌بندی نموده و با استفاده از دقیقت کلی

که برای مقایسه بکار گرفته شده اند روش‌های ویشارت و ویشارت-مارکوف [۱۱] می‌باشند. روش ویشارت که یک طبقه‌بندی کننده مشهور در زمینه طبقه‌بندی داده‌های پلاریمتری بوده و عموماً برای مقایسه به عنوان یک روش پایه استفاده می‌گردد. اما روش ویشارت-مارکوف در سال ۱۳۹۳ توسط آقای درگاهی و همکاران ارائه شده است. طبق شکل ۶، نقشه طبقه‌بندی حاصل از روش ویشارت به دلیل عدم استفاده از ویژگی‌های کمکی مانند ویژگی‌های حاصل از تجزیه پلاریمتری و طبقه‌بندی فقط بر مبنای ماتریس کوواریانس، دارای نویز زیادی می‌باشد. شکل ۷ قسمتی از تصویر طبقه‌بندی با استفاده از روش‌های بیان شده و مربوط به کلاس پوشش گیاهی نشان داده شده است.

انتخاب شدند. در جدول ۳ نیز ویژگی‌های انتخاب شده توسط الگوریتم ژنتیک ارائه شده است.



شکل ۵: نحوه همگرایی الگوریتم ژنتیک.

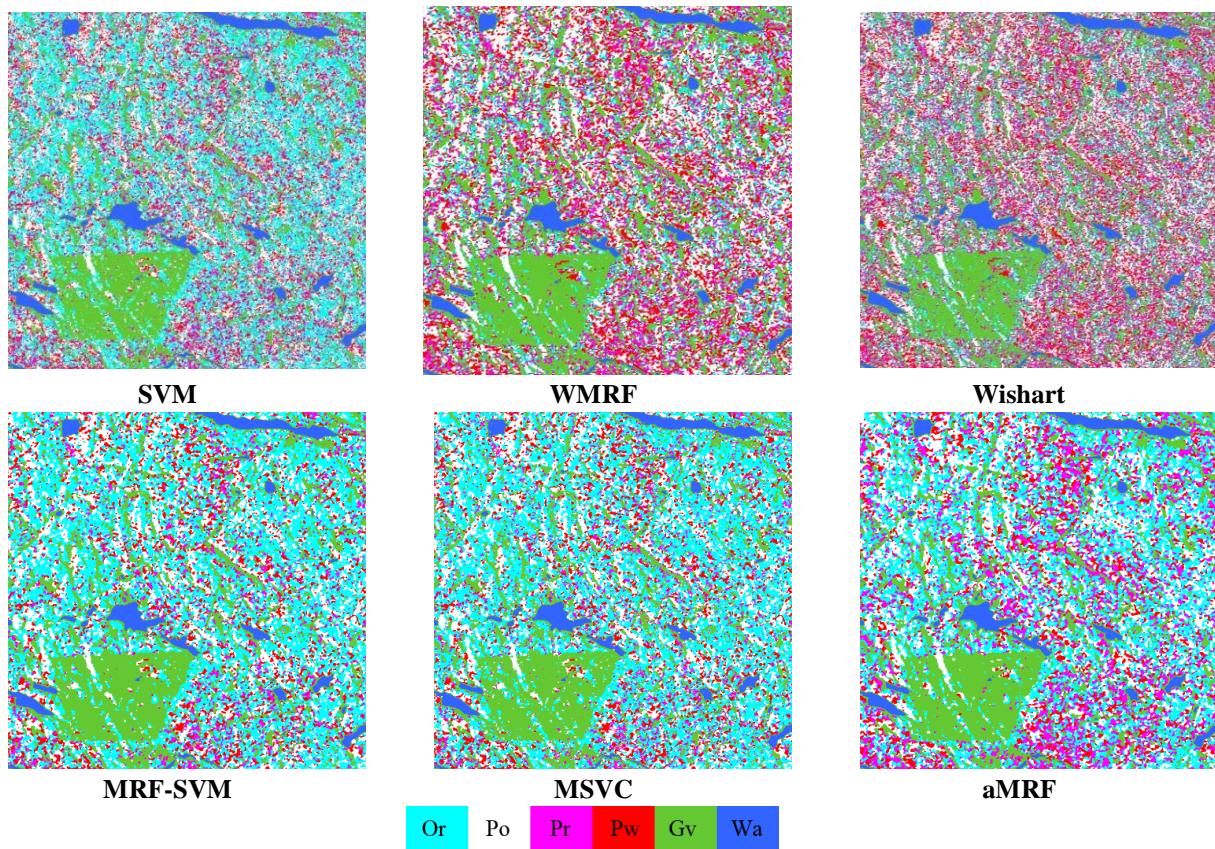
شکل ۶ تصاویر حاصل از طبقه‌بندی با استفاده از روش‌های مختلف و الگوریتم پیشنهادی (SVM-MRF) را نشان می‌دهد. جدول ۴ نیز دقت هر کلاس و دقت کلی در هر روش را نشان می‌دهد. دو روش اول

جدول ۳: ویژگی‌های پلاریمتری انتخاب شده توسط الگوریتم ژنتیک

تعداد ویژگی	توصیف	ویژگی انتخاب شده
۳		ویژگی‌های اصلی
۱۰	Huynen [T ₃₃], Barends [T ₂₂], Holm [T ₁₁], H / A / α [H, Eigenvalue (1)], Freeman[Odd, Dbl], Yamaguchi[Odd, Helix], Touzi [ψ]	ویژگی‌های حاصل از تجزیه
۳	Pedestal height, Correlation coefficients [Ro ₁₂], Degree of polarization	توصیف کننده‌های SAR

به کلاس پیکسل‌های همسایه شده و در نتیجه می‌تواند باعث کاهش نویز در نتیجه طبقه‌بندی و افزایش دقت آن گردد. روش ویشارت-مارکوف با استفاده از میدان تصادفی مارکوف اطلاعات همسایگی را مدل نموده و به عنوان احتمال اولیه کلاس‌ها به روش ویشارت در طبقه‌بندی اضافه می‌کند [۱۰]. طبق جدول ۳ و شکل ۶ و ۷، این افروzen اطلاعات همسایگی اگرچه باعث افزایش درصدی دقت طبقه‌بندی و کاهش نویز موجود در تصویر حاصل از طبقه‌بندی شده است اما همچنان تفکیک‌پذیری خوبی بین کلاس‌ها ایجاد نکرده است.

در این شکل نیز مشاهده می‌شود که بسیاری از پیکسل‌های مربوط به کلاس پوشش گیاهی در طبقه‌بندی به روش ویشارت، در کلاس گونه‌های جنگلی قرار گرفته است و بنابراین این روش نتوانسته است بین کلاس پوشش گیاهی با کلاس گونه‌های جنگلی تفکیک ایجاد کند. البته در این روش کلاس آب که دارای پراکنش بسیار متفاوت از دیگر کلاس‌ها می‌باشد تا حدود زیادی از دیگر کلاس‌ها تشخیص داده شده است به طوری که دقت طبقه‌بندی آن حدود ۹۴٪ می‌باشد. مدل‌سازی اطلاعات همسایگی و وارد نمودن آن به طبقه‌بندی باعث نزدیک شدن کلاس هر پیکسل



شکل ۶: نتیجه طبقه‌بندی به کمک روش‌های مختلف.

جدول ۴: دقت طبقه‌بندی کلاس‌ها و دقت کلی طبقه‌بندی با استفاده از روش‌های ویشارت، ویشارت-مارکوف، MSVC، aMRF، SVM و روش پیشنهادی (MRF-SVM).

کلاس / روش	Wishart	WMRF	SVM	aMRF	MSVC	MRF-SVM
Or	۲۹/۲۲	۳۲/۱۵	۶۶/۱۲	۶۵/۱۷	۷۸/۵۳	۸۱/۱۲
Po	۳۵/۹۸	۴۱/۱۲	۳۹/۱۰	۴۱/۷۴	۴۹/۶۹	۵۳/۷۴
Pr	۲۲/۳۰	۲۰/۳۵	۲۰/۳۵	۳۸/۷۶	۱۶/۶۴	۲۱/۹۵
Pw	۲۶/۰۰	۲۸/۹۳	۳۰/۸۲	۲۳/۲۷	۴۲/۵۶	۴۷/۵۹
Gv	۷۱/۵۷	۸۱/۹۴	۶۹/۸۱	۸۱/۳۶	۷۵/۸۳	۸۰/۳۰
Wa	۹۳/۷۶	۹۳/۷۶	۹۴/۹۲	۹۴/۷۸	۹۴/۶۳	۹۴/۶۳
دقت کلی طبقه‌بندی	۵۱/۹۳	۵۶/۸۳	۵۹/۹۷	۶۵/۴۶	۶۷/۰۵	۷۰/۵۴
زمان اجرا	۱۷ ثانیه	۴ دقیقه	۵ دقیقه	۸ دقیقه	۳۴ دقیقه	۱۰ دقیقه

ماتریس همدوسی، ویژگی‌های حاصل از تجزیه و ویژگی‌های تفکیک‌کننده SAR نیز استفاده می‌کند. استفاده از این اطلاعات پراکنش غنی موجب افزایش تفکیک‌پذیری بین کلاس‌های مختلف و

بر خلاف روش ویشارت، طبقه‌بندی کننده SVM از هر نوع اطلاعات مربوط به پیکسل می‌تواند استفاده کند. بنابراین علاوه بر عناصر ماتریس کوواریانس، از ماتریس پراکندگی،

دقت کلی طبقه‌بندی با کمک روش پیشنهادی نسبت به روش aMRF ۵ درصد بالاتر می‌باشد. این در حالی است که زمان اجرای آن فقط دو دقیقه بیشتر می‌باشد. همچنین مقایسه روش پیشنهادی با روش MSVC نیز نشان از برتری ۳ درصدی آن دارد. این در حالی است که روش MSVC حدود ۳۴ دقیقه زمان برای اجرا نیاز دارد (۴/۳ برابر روش پیشنهادی) و دقت آن ۳ درصد کمتر از روش پیشنهادی و فقط ۲ درصد از روش aMRF بالاتر می‌باشد.

برای بررسی دقیق‌تر روش پیشنهادی، ماتریس ابهام طبقه‌بندی به روش SVM در جدول ۵ و همان ماتریس برای روش پیشنهادی در جدول ۶ ارائه شده است. کلاس آب به دلیل رفتار متفاوت در پراکنش، دارای دقت بالا در طبقه‌بندی به هر دو روش بوده و طبقه‌بندی آن در روش SVM بسیار همگن بوده به طوری که استفاده از اطلاعات همسایگی نه تنها باعث افزایش دقت در طبقه‌بندی نشده بلکه تعداد کمی از پیکسل‌های مربوط به این کلاس را در کلاس پوشش گیاهی قرار داده است. کلاس گونه‌های جنگلی به دلیل شباهت بالا در پراکنش، دارای دقتهای کمتر بوده و تنها با تکیه بر اطلاعات پراکنش نمی‌توان انتظار دقت خوبی در طبقه‌بندی آن‌ها داشت ولی به کارگیری اطلاعات همسایگی تا حدودی باعث جبران این شباهت بالا می‌گردد به طوری که موجب افزایش ۱ تا ۱۷ درصدی دقت طبقه‌بندی در این کلاس‌ها شده است. طبق جدول ۵، در روش SVM بسیاری از گونه‌های جنگلی و پوشش گیاهی در کلاس Or قرار گرفته‌اند، در حالی که در روش پیشنهادی در کلاس اصلی قرار گرفته‌اند و در ضمن پیکسل‌هایی از این کلاس که به اشتباہ در کلاس‌های دیگر قرار گرفته بودند نیز به کلاس اصلی خود بازگشتند (جدول ۶). در مجموع مقایسه‌ی این دو ماتریس نشان می‌دهد که

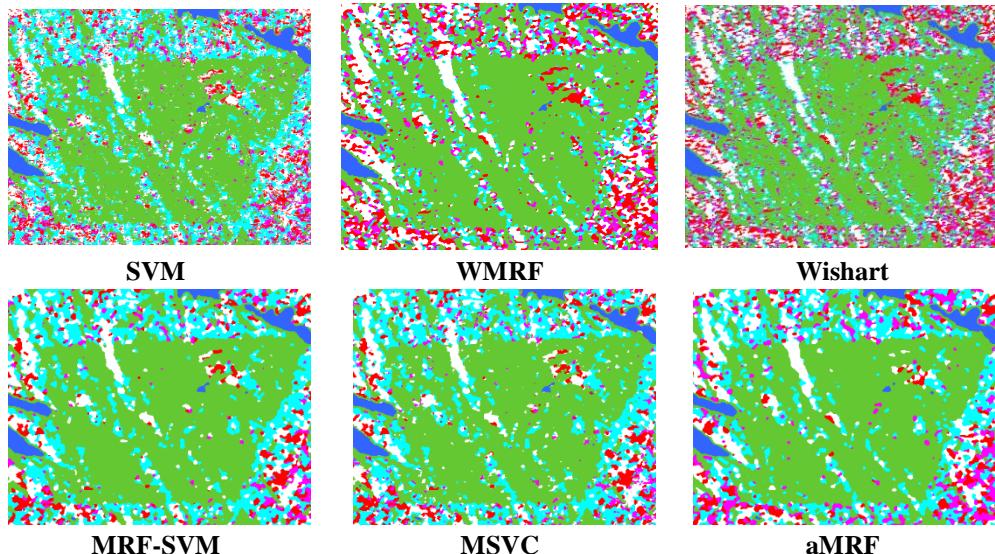
در نتیجه افزایش ۸ درصدی دقت کلی طبقه‌بندی نسبت به روش ویشارت شده است. همانطور که در شکل ۶ و ۷ نیز مشاهده می‌شود، تصویر حاصل از طبقه‌بندی به این روش نسبت روش ویشارت دارای نویز کمتری می‌باشد. محدودیت اصلی این روش، عدم استفاده از اطلاعات همسایگی پیکسل مورد طبقه‌بندی می‌باشد.

دو روش دیگری که در این قسمت اجرا شده است جز روش‌هایی است که در سال‌های اخیر و به منظور تلفیق طبقه‌بندی کننده SVM و مدل MRF به منظور طبقه‌بندی تصاویر فراتصیفی ارائه شده است. روش اول [۱۴] روش aMRF [۱۳] و روش دوم روش SVM می‌باشد که در قسمت مقدمه راجع به آن توضیح داده شده است. این دو روش نیز با استفاده از مدل MRF انطباقی پیاده‌سازی شده‌اند. لازم به ذکر است مبنای هر دوی این روش‌ها SVM بوده و بنابراین همان پارامترهای کرنل و ویژگی‌های مورد استفاده در روش SVM در این دو روش نیز استفاده شده است. همانطور که در جدول ۴ مشاهده می‌گردد، هر دوی این روش‌ها نسبت به روش SVM به دلیل استفاده از اطلاعات همسایگی دقیق‌تر می‌باشند.

الگوریتم پیشنهادی در این مقاله از اطلاعات پراکنش مورد استفاده در روش SVM، و اطلاعات مکانی در محاسبهتابع انرژی اولیه بهره می‌برد. بنابراین انتظار می‌رود که علاوه بر قدرت تفکیک‌پذیری بالا بین کلاس‌ها، نویز تصویر طبقه‌بندی حاصل از آن نیز کمتر از روش SVM باشد. مقایسه تصویر طبقه‌بندی روش‌های دیگر با این روش در شکل‌های ۶ و ۷ و همچنین افزایش ۱۹ و ۱۴ درصدی دقت طبقه‌بندی نسبت به روش‌های به ترتیب ویشارت، ویشارت-مارکوف و SVM توانایی بالای این روش را نشان می‌دهد.

۱۱ درصدی نسبت به روش SVM در دقت کلی طبقه‌بندی می‌گردد.

اس تفاهه از این روش باعث برچسب‌گذاری صحیح کلاس‌ها و در نهایت افزایش



شکل ۷: قسمتی از نتیجه طبقه‌بندی به کمک روش‌های مختلف.

جدول ۵: ماتریس ابهام برای داده‌های تست حاصل از طبقه‌بندی به روش SVM

کلاس درست	کلاس طبقه‌بندی شده						دقت (%)
	Or	Po	Pr	Pw	Gv	Wa	
Or	۷۶۷	۱۳۹	۸۸	۸۰	۸۶	۰	۶۶/۱۲
Po	۲۲۷	۲۵۱	۲۴	۵۴	۸۶	۰	۳۹/۱۰
Pr	۱۴۶	۷۳	۱۱۵	۱۱۱	۱۲۰	۰	۲۰/۳۵
Pw	۱۲۹	۱۲۰	۷۳	۱۴۷	۸	۰	۳۰/۸۲
Gv	۲۸۸	۱۲۶	۹۰	۳۱	۱۳۱۱	۳۲	۶۹/۸۱
Wa	۰	۵	۵	۰	۲۵	۶۵۴	۹۴/۹۲

جدول ۶: ماتریس ابهام برای داده‌های تست حاصل از طبقه‌بندی به روش پیشنهادی

کلاس درست	کلاس طبقه‌بندی شده						دقت (%)
	Or	Po	Pr	Pw	Gv	Wa	
Or	۹۴۱	۴۲	۴۴	۶۴	۶۹	۰	۸۱/۱۲
Po	۲۱۳	۳۴۵	۱	۰	۸۳	۰	۵۳/۷۴
Pr	۱۶۳	۴۲	۱۲۴	۱۱۹	۱۱۷	۰	۲۱/۹۵
Pw	۱۰۲	۱۰۱	۴۶	۲۲۷	۱	۰	۴۷/۵۹
Gv	۱۹۵	۶۳	۶۱	۱۹	۱۵۰۸	۳۲	۸۰/۳۰
Wa	۰	۱۰	۰	۰	۲۷	۶۵۲	۹۴/۶۳

مدل‌سازی اطلاعات همسایگی در این روش باعث کاهش نویز و افزایش همگنی در نقشه‌ی حاصل از طبقه‌بندی می‌گردد. طبقه‌بندی داده‌ی پلاریمتری با استفاده از این روش، توانایی آن در تفکیک گونه‌های جنگلی را نشان داد. به طور که دقت طبقه‌بندی با این روش حدود ۱۹ و ۱۴ و ۱۱ درصد از دقت طبقه‌بندی حاصل از روش‌های به ترتیب ویشارت، ویشارت-مارکوف و SVM بیشتر بوده است. همچنین مقایسه این روش با دو روش جدید نیز حاکی از برتری ۵ و ۳ درصدی آن می‌باشد. در نهایت نتایج نشان می‌دهد که هدف این مقاله یعنی ارائه‌ی روشی دقیق و سریع به منظور طبقه‌بندی داده‌های پلاریمتری محقق گردیده است.

- [1] J.S. Lee, M.R. Grunes, and R. Kwok, "Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution," International Journal of Remote Sensing, 15(11), 2299–2311, 1994.
- [2] Maghsoudi, Y., "Analysis of Radarsat-2 Full Polarimetric Data for Forest Mapping," Ph.D. dissertation, Calgary University, Calgary, The Canada, 2011.
- [3] Alberga, V., "Comparison of polarimetric methods in image classification and SAR interferometry applications," PhD thesis, Fakultat fir Elektrotechnik und Informationstechnik der technischen Universität Chemnitz genehmigte, 2003.
- [4] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," in Proceedings of the fifth annual workshop on Computational learning theory, pp. 144 -152, 1992.
- [5] J. Benediktsson, P. H. Swain, and O. K. Ersoy, "Neural network approaches versus statistical methods in classification of multisource remote sensing data," IEEE Transactions on geoscience and remote sensing, vol. 28, pp. 540-552, 1990.
- [6] Zhang, B. Zou, J. Zhang and Y. Zhang,

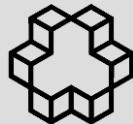
۶- نتیجه‌گیری

در این مقاله طبقه‌بندی داده‌های پلاریمتری SAR بر اساس تلفیق میدان‌های تصادفی مارکوف و طبقه‌بندی کننده ماشین بردار پشتیبان انجام شد. اساس روش ارائه شده، طبقه‌بندی کننده SVM می‌باشد و بنابراین توانایی استفاده از ویژگی‌های مختلف قابل استخراج از تصاویر پلاریمتری را دارا می‌باشد. علاوه بر این، به دلیل استفاده از تابع کرنل، قدرت تفکیک بین کلاس‌هایی که به طور خطی قابل تفکیک نیستند را نیز دارا می‌باشد. مزیت این روش نسبت به روش‌های ارائه شده در تحقیقات قبلی، دقت بالا و سرعت اجرای می‌باشد. در مجموع استفاده از میدان تصادفی مارکوف و

مراجع

- "Classification of polarimetric SAR image based on support vector machine using multiple-component scattering model and texture features," EURASIP Journal on Advances in Signal Processing, vol. 2010, p. 1, 2010.
- [7] D. Gleich, "Markov random field models for non-quadratic regularization of complex SAR images," Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of, vol. 5, pp. 952-961, 2012.
- [8] Y. Tarabalka, M. Fauvel, J. Chanussot, and J. A. Benediktsson, "SVM-and MRF-based method for accurate classification of hyperspectral images," Geoscience and Remote Sensing Letters, IEEE, vol. 7, pp. 736-740, 2010.
- [9] Y. Wu, K. Ji, W. Yu, and Y. Su, "Region-based classification of polarimetric SAR images using Wishart MRF," Geoscience and Remote Sensing Letters, IEEE, vol. 5, pp. 668-672, 2008.
- [10] A. Dargahi, Y. Maghsoudi, and A. Abkar, "Unsupervised Classification of Polarimetric SAR Imagery Using Scattering Mechanism and Markov Random Fields," Journal of Radar, vol. 1, pp. 15-25, 2013.

- [11] A. Dargahi, Y. Maghsoudi, and A. Abkar, "Supervised Classification of Polarimetric SAR Imagery Using Temporal and Contextual Information," *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 1, pp. 107-110, 2013.
- [12] Z. Wu, Q. Ouyang, "SVM- and MRF-Based Method for Contextual Classification of Polarimetric SAR Images," *Remote Sensing, Environment and Transportation Engineering (RSETE)*, International Conference on Digital Object Identifier, IEEE, pp. 818 - 821, 2011.
- [13] Zhang, B., Li, S., Jia, X., Gao, L., Peng, M. Adaptive Markov random field approach for classification of hyperspectral imagery. *Geoscience and Remote Sensing Letters*, IEEE 8, pp. 973-977, 2011.
- [14] G. Moser, and S. B. Serpico, "Combining Support Vector Machines and Markov Random Fields in an Integrated Framework for Contextual Image Classification," *IEEE Trans. Geosci. Remote Sensing*, vol. 51, no. 5, pp. 2734–2752, May. 2013.
- [15] V. N. Vapnik, *Statistical Learning Theory*. Hoboken, NJ: Wiley, 1998.
- [16] S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-6, no. 6, pp. 721–741, Nov. 1984.
- [17] S. Li, *Markov Random Field Modeling in Image Analysis*. Berlin, Germany: Springer-Verlag, 2009.
- [18] Q. Jackson and D. Landgrebe, "Adaptive Bayesian contextual classification based on Markov random fields," *IEEE Trans. Geosci. Remote Sensing*, vol. 40, no. 11, pp. 2454–2463, Nov. 2002.
- [19] A. H. S. Solberg, T. Taxt, and A. K. Jain, "A Markov random field model for classification of multisource satellite imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 34, no. 1, pp. 100–113, Jan. 1996.
- [20] T. Zhang, F. Hu, and R. Yang, "Polarimetric SAR image segmentation by an adaptive neighborhood Markov random field," *J. Test Meas. Technol.*, vol. 23, no. 5, pp. 462–465, 2009.
- [21] P. Zhong and R. Wang, "Image segmentation based on Markov random fields with adaptive neighborhood systems," *Opt. Eng.*, vol. 45, no. 9, pp. 462–465, 2009.
- [22] A. Garzelli, "Classification of polarimetric SAR images using adaptive neighborhood structures," *Int. J. Remote Sens.*, vol. 20, no. 8, pp. 1669–1675, 1999.
- [23] X., Niu, Y., Ban, "An Adaptive Contextual SEM Algorithm for Urban Land Cover Mapping Using Multitemporal High-Resolution Polarimetric SAR Data", *Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE Journal of, vol. 5, no. 4, pp. 1129-1139, 2012.



Classification of Polarimetric SAR Images Based on Combining Support Vector Machine Classifier and Markov Random Fields

Ali Masjedi^{*1}, Yasser Maghsoudi², Mohamad Javad Valadan Zoej³

1- M.Sc. student of remote sensing in Department of Geomatics, College of Engineering, K.N. Toosi University

2- Assistant professor in Department of Geomatics, College of Engineering, K.N. Toosi University

3- Associate professor in Department of Geomatics, College of Engineering, K.N. Toosi University

Abstract

Recent studies show that image classification techniques which use both spectral and spatial information are more suitable, effective, and robust than those that use only spectral information. Although late model support vector machines (SVMs) have been providing accurate results in the studies, this method is intrinsically non-contextual, which represents significant limitation in image classification. In this paper, we propose a rigorous framework which integrates SVMs and Markov random field models in a unique formulation for spatial contextual classification of various species of forest trees, ground vegetation, and water using polar metric synthetic aperture radar data. Genetic algorithm is employed for selecting appropriate features and automatic estimation of optimal parameters. Comparison of the accuracy of the proposed method with baseline methods was performed. Comparison of the accuracy of the proposed method with some other methods was carried out. The results show that this algorithm allowed approximately 19%, 14%, 11%, 5% and 3% increase in overall accuracy with respect to the Wishart, WMRF, SVM, aMRF and MSVC methods, respectively.

Key words: Markov Random Fields, Support Vector Machine, Contextual Image Classification, Spatial Information.

Correspondence Address Remote Sensing Group, Department of Geomatics, College of Engineering, K.N. Toosi University, Tehran, Iran
Tel: +98 9138669858.
Email: amasjedi@mail.kntu.ac.ir