

ارائه یک روش جدید برای طبقه‌بندی تصاویر پلاریمتری رادار با روزنه مجازی براساس تلفیق ماشین بردار پشتیبان و میدان‌های تصادفی مارکوف

علی مسجودی^{۱*}، یاسر مقصودی^۲، محمدجواد ولدان‌زوج^۳

^۱ دانشجوی کارشناسی ارشد سنجش‌ازدور - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
amasjedi@mail.kntu.ac.ir

^۲ استادیار گروه فتوگرامتری و سنجش‌ازدور - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
ymaghsoudi@kntu.ac.ir

^۳ دانشیار گروه فتوگرامتری و سنجش‌ازدور - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
valadanzouj@kntu.ac.ir

(تاریخ دریافت آذر ۱۳۹۳، تاریخ تصویب مرداد ۱۳۹۴)

چکیده

در این مقاله یک روش نوین طبقه‌بندی متنی به منظور طبقه‌بندی تصاویر پلاریمتری رادار با روزنه مجازی ارائه شده است. روش پیشنهادی با تلفیق ماشین بردار پشتیبان (SVM) و طبقه‌بندی‌کننده ویشارت عمل می‌کند. بدین ترتیب این روش از مزایای هر دو نوع روش‌های پارامتریک و غیر پارامتریک بهره می‌برد. در این روش، ابتدا تابع انرژی اولیه میدان‌های تصادفی مارکوف (MRF) در یک همسایگی از هر پیکسل محاسبه می‌گردد. سپس با استفاده از ماتریس کوواریانس داده‌های پلاریمتری برای هر پیکسل و در نظر گرفتن توزیع ویشارت برای آن، تابع انرژی تفاضلی MRF محاسبه گردیده و در طبقه‌بندی‌کننده SVM وارد می‌شود. بنابراین روش پیشنهادی علاوه بر اطلاعات پراکنش مختلف، از اطلاعات همسایگی نیز بهره می‌برد و این باعث کاهش نویز نمک فلفلی در نتیجه طبقه‌بندی می‌گردد. به منظور انتخاب ویژگی‌های مناسب و تعیین پارامترهای بهینه برای طبقه‌بندی‌کننده SVM، از الگوریتم ژنتیک استفاده شده است. در این مقاله از دو تصویر پلاریمتری رادارست ۲ مربوط به فصل زمستان و تابستان از یک منطقه جنگلی دارای گونه‌های مختلف استفاده شده است. به منظور بررسی عملکرد روش پیشنهادی، نتایج بدست آمده از این روش با نتایج تعدادی از روش‌های پایه در طبقه‌بندی تصاویر پلاریمتری مقایسه شد. در نهایت طبقه‌بندی به این روش نسبت به روش‌های ویشارت، ویشارت-مارکوف و SVM، به ترتیب ۱۶، ۱۱ و ۷ درصد افزایش دقت را نشان می‌دهد.

واژگان کلیدی: تصاویر پلاریمتری رادار با روزنه مجازی، ماشین بردار پشتیبان، توزیع ویشارت، میدان‌های تصادفی مارکوف، طبقه‌بندی تصاویر سنجش‌ازدور

۱- مقدمه

طبقه‌بندی نوع پوشش مناطق جنگلی به دلیل اهمیت این مناطق و لزوم مراقبت از آن‌ها یکی از کاربردهای مهم سنجش‌ازدور می‌باشد. این در حالی است که در بسیاری از مناطق جنگلی همواره شاهد وجود مه و یا پوشش ابر و شرایط بارانی هستیم که این مساله باعث عدم توانایی استفاده از تصاویر اپتیکی در این مناطق می‌شود. بنابراین در این مناطق استفاده از تصاویر رادار با روزه مجازی^۱ به دلیل عدم تاثیرپذیری از ابر و مه اولویت دارد. از طرفی داده‌های پلاریمتری به دلیل وابستگی به تغییرات در ساختار و چگالی گونه‌های جنگلی، می‌تواند اطلاعات مفیدی از جنگل ارائه دهد.

اطلاعات ارائه شده توسط هوابرد سنجنده‌های SAR که به تازگی راه‌اندازی شده مانند RADARSAT-2 و TerraSAR-X، امکانات جدیدی را برای پایش منابع جنگلی مهیا کرده است. رادارست ۲ محصولاتی با پلاریزاسیون‌های VV، کراس-پلاریزاسیون (HV و یا VH)، پلاریزاسیون دوگانه (HH+HV و یا VV+VH) و یا پلاریزاسیون چهارگانه شامل چهار پلاریزاسیون HH، HV، VH و VV و وابستگی فاز بین آن‌ها را ارائه می‌دهد.

تصاویر پلاریمتری SAR به دلیل حساسیت به هندسه و ساختار گونه‌های جنگلی، شکل، اندازه، زاویه و رطوبت برگ گونه‌ها مزیت‌های زیادی نسبت به تصاویر نوری سنجش از دور دارند. این تصاویر پتانسیل بالای خود را برای اندازه‌گیری ویژگی‌های پراکنش و خصوصیات بیوفیزیکی جنگل [۱-۵] و تفکیک‌پذیری بین گونه‌های مختلف جنگلی و طبقه‌بندی [۶] آن‌ها نشان داده است. همچنین توانایی داده‌های پلاریمتری برداشت شده توسط سنجنده رادارست ۲ در طبقه‌بندی گونه‌های جنگلی در تحقیقات [۷، ۸] اثبات شده است.

طبقه‌بندی تصاویر پلاریمتری SAR در سال‌های اخیر مورد توجه بسیاری قرار گرفته است [۹-۱۵]. در تحقیقات انجام شده، روش‌های مختلفی برای تحلیل داده‌های پلاریمتری و همچنین استخراج ویژگی از آن، قبل از طبقه‌بندی مورد استفاده قرار گرفته است. اولین روش، استفاده از داده‌های مشاهده شده شامل ماتریس

پراکندگی، ماتریس کوواریانس و ماتریس هم‌دوسی می‌باشد. روش دوم استفاده از پارامترهای توصیف کننده ویژگی‌های پلاریمتری شامل تفکیک کننده‌های^۲ SAR می‌باشد. در نهایت روش سوم بر اساس تئوری تجزیه هدف^۳ می‌باشد که در آن داده را به مولفه‌های مستقل که نماینده مکانیزم پراکنش فیزیکی مشخصی می‌باشد، تجزیه می‌کند [۹]. تجزیه پلاریمتریک یک روش معمول است که شامل دو دسته تجزیه هم‌دوس^۴ و تجزیه ناهم‌دوس^۵ می‌باشد. در تجزیه هم‌دوس، ماتریس پراکندگی پلاریمتری به تعدادی ماتریس پراکندگی پایه تجزیه می‌شود. روش‌های اصلی در این دسته عبارتند از تجزیه پائولی [۱۶] و تجزیه SDH^۶ [۱۷]. تجزیه ناهم‌دوس، ماتریس کوواریانس (و یا ماتریس هم‌دوسی) را به تعدادی توصیف‌گر درجه دوم تجزیه می‌کند. روش‌های تجزیه Huynen [۱۸]، تجزیه Freeman [۱۹]، تجزیه چهار مولفه‌ای [۹، ۲۰] و تجزیه Cloude [۹] در این دسته جای دارند. استفاده از ویژگی‌های بدست آمده از روش‌های تجزیه منجر به افزایش تفکیک‌پذیری بین کلاس‌های مختلف گونه‌های جنگلی می‌گردد.

روش‌های طبقه‌بندی تصاویر سنجش از دور در حالت کلی به دو دسته پارامتریک و غیرپارامتریک تقسیم‌بندی می‌شوند. در روش‌های پارامتریک، مدل‌سازی دقیق توزیع آماری داده‌ها مورد نیاز است. برای داده‌های پلاریمتری SAR، با فرض‌های مختلف برای الگوی بافت این داده‌ها، تعدادی توزیع مختلف ارائه شده است که با استفاده از هر کدام روابط متفاوتی برای طبقه‌بندی بدست می‌آید. یکی از توزیع‌های مشهور برای داده‌های پلاریمتری SAR، توزیع پیچیده ویشارت می‌باشد که بر اساس آن طبقه‌بندی کننده ویشارت ارائه شده است [۲۱]. مزیت روش ویشارت، وابستگی آن به مکانیزم پراکنش در هر کلاس می‌باشد. بنابراین با استفاده از این روش کلاس‌هایی که مکانیسم پراکنش متفاوتی دارند به راحتی از هم تفکیک می‌شوند. اما در مواردی که پراکنش کلاس‌ها شبیه به یکدیگر می‌باشد مانند طبقه‌بندی مناطق جنگلی با گونه‌های متفاوت

^۲ Discriminator

^۳ Target Decomposition

^۴ Coherent Decomposition

^۵ Noncoherent Decomposition

^۶ Sphere, Deplane, Helix (SDH)

^۱ Synthetic Aperture Radar (SAR)

و دارای مکانیزم پراکنش مشابه، استفاده از تمام ویژگی-های دارای قدرت تفکیک پذیری قابل 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. بر خلاف روش‌های پارامتریک، در روش‌های غیرپارامتریک نظیر ماشین بردار پشتیبان^۱ [۲۲] و شبکه عصبی مصنوعی [۲۳]، توزیع آماری خاصی برای داده در نظر نمی‌گیرند و بنابراین می‌توان از آن در طبقه‌بندی چند زمانه [۲۴] و چند منبعی [۱۳] استفاده نمود. همچنین ویژگی‌های مختلف مانند ویژگی‌های بدست آمده از روش-های مختلف تجزیه هدف و پارامترهای تفکیک‌کننده SAR نیز قابل استفاده خواهند بود.

امروزه 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. این در حالی است که SVM و همچنین طبقه‌بندی کننده ویشارت، روش‌هایی ذاتاً غیرمتنی^۲ و پیکسل مبنا هستند. به عبارت دیگر این روش‌ها بر اساس مقادیر پیکسل‌ها و بدون توجه به اطلاعات همسایگی عمل می‌کنند. بنابراین، این روش‌ها محدودیت ذاتی داشته و نتایج طبقه‌بندی بدست آمده با استفاده از آن دارای نویز نمک فلفلی می‌باشد. از طرف دیگر، یک جز جدا نشدنی تصاویر راداری نویز اسپکل می‌باشد که تحلیل و تفسیر این تصاویر را پیچیده نموده و دقت طبقه‌بندی را کاهش می‌دهد [۶]. به این دلایل استفاده از اطلاعات مکانی در طبقه‌بندی ضروری به نظر می‌رسد. در این راستا روش‌های متعددی برای افزودن اطلاعات مکانی به اطلاعات طیفی مورد استفاده در طبقه‌بندی ارائه شده است [۲۵-۲۷].

از جمله روش‌های مورد استفاده به منظور افزودن اطلاعات مکانی در فرآیند طبقه‌بندی، مدل‌سازی بافت تصویر با مدل‌هایی نظیر مدل میدان‌های تصادفی مارکوف است که در تحقیقات گذشته نتایج قابل توجهی داشته

است [۲۸-۳۰]. برای مثال در [۳۰]، به منظور مقابله با مشکل وجود نویز اسپکل و همچنین بدست آوردن نقشه-ای همگن از کلاس‌ها و حذف مشکل پیکسل‌های پراکنده از نقشه‌ی طبقه‌بندی، علاوه بر توزیع ویشارت، از مدل-سازی اطلاعات همسایگی نیز استفاده شد. برای مدل-سازی، مدل میدان تصادفی مارکوف به کار گرفته شده و با تلفیق آن با توزیع آماری تصاویر یعنی توزیع ویشارت طبقه‌بندی انجام شده است. در نهایت بیشترین دقت بدست آمده حدود ۸۵ درصد در طبقه‌بندی می‌باشد. نتایج بدست آمده در این تحقیقات نشان می‌دهد که استفاده از مدل میدان تصادفی مارکوف، ابزاری قدرتمند در مدل-سازی اطلاعات همسایگی بوده و تلفیق آن با روش‌های مختلف طبقه‌بندی می‌تواند موفقیت آمیز باشد. مقایسه تحقیقات انجام شده نشان می‌دهد که طبقه‌بندی به روش SVM در مقایسه با استفاده از توزیع ویشارت و قانون بیز، نتیجه بهتری دارد. در تعدادی از روش‌های ارائه شده، اطلاعات مکانی و طبقه‌بندی‌کننده SVM به منظور استفاده از اطلاعات مکانی تلفیق شده‌اند. برای مثال در یک تحقیق انجام شده، از SVM برای برآورد توزیع داده‌ها استفاده نموده و احتمال تعلق هر پیکسل به کلاس‌های مختلف را با استفاده از آن محاسبه می‌کند. سپس این احتمال در کنار اطلاعات مکانی در رابطه تابع انرژی میدان تصادفی مارکوف قرار گرفته و طبقه‌بندی بر اساس آن انجام می‌شود. نتایج این الگوریتم که بر روی تصاویر SAR اجرا شده است، دقت بالاتر این روش در مقایسه با روش SVM را نشان می‌داد [۳۱]. پس از آن و در تحقیقی دیگر، به منظور طبقه‌بندی تصاویر فراطیفی یک روش مکانی-طیفی 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 می‌شد. این روش با حل مشکل پیکسل‌های نویزی در طبقه‌بندی، موجب بهبود نتایج طبقه‌بندی شد [۳۲]. در [۳۳]، یک الگوریتم مکانی-متنی^۳ برای طبقه‌بندی ارائه

^۱ Support Vector Machine (SVM)

^۲ Non-Contextual

^۳ Spatial-Contextual

شده است که در آن تابع تصمیم‌گیری و شروط SVM را بر اساس ترم مکانی-متنی تغییر می‌کند. ابتدا طبقه‌بندی اولیه به روش SVM انجام شده و سپس با شمارش تعداد همسایگی در هر پیکسل اطلاعات همسایگی بدست آمده و سپس به روش SVM بهبود یافته، طبقه‌بندی انجام می‌گردد. در این روش ابرصفحه جداکننده کلاس‌ها در فضای ویژگی با استفاده از سیستم همسایگی به سمتی که توسط اطلاعات مکانی تعیین می‌شود، حرکت می‌کند. این روش موجب می‌شود کلاس هر پیکسل به کلاس پیکسل‌های همسایه نزدیک گردد. پس از آن، در [۳۴] یک روش جدیدتر بر اساس تلفیق MRF و SVM در یک چهارچوب واحد ارائه شده است. این روش بین تابع تصمیم‌گیری مارکوف و کرنل SVM ارتباط برقرار می‌کند. این ارتباط توسط یک ویژگی مکانی-متنی جدید که توسط مدل سازی MRF بدست می‌آید و وارد کرنل می‌شود ایجاد می‌شود. نتایج اجرای این روش بر روی تصاویر چندطیفی، فراطیفی و SAR دقت بالای آن را نشان می‌دهد. در مجموع، روش‌هایی که در آن از تلفیق SVM و MRF استفاده شده است دقت بالاتری نسبت به دیگر روش‌ها دارد [۳۳، ۳۴]. بیشتر تحقیقات انجام شده در این حوزه بر روی تصاویر فراطیفی انجام شده است. بیشتر روش‌های موجود برای افزودن اطلاعات مکانی در طبقه‌بندی تصاویر پلاریمتری، از تعداد کمی از ویژگی‌های پلاریمتری استفاده می‌کند. بنابراین روشی مناسب برای تصاویر پلاریمتری که بتواند از اطلاعات پراکنش مختلف در کنار اطلاعات مکانی استفاده کند، وجود ندارد و دقت روش‌های موجود نیز کافی نیست. هدف اصلی این مقاله ارائه یک روش مناسب برای این تصاویر است که بتواند انواع اطلاعات پراکنش را در کنار اطلاعات مکانی مورد استفاده قرار دهد.

مکانیزم پراکنش گونه‌های جنگلی شباهت بسیار بالایی دارد که این مساله باعث عملکرد ضعیف طبقه‌بندی می‌گردد. بنابراین استفاده از هر نوع اطلاعات که بتواند به فرآیند طبقه‌بندی کمک کند، ضروری به نظر می‌رسد. استفاده از تصاویر اخذ شده در زمان‌های متفاوت از یک منطقه به علت تحلیل رفتار پراکنش در طول زمان، باعث افزایش تفکیک‌پذیری بین کلاس‌های مختلف پوشش زمین می‌گردد. به عبارت دیگر، طبقه‌بندی با بررسی رفتار پراکنش در طول زمان انجام می‌شود [۳۵، ۳۶]. در این حوزه و در چند سال اخیر، استفاده از تصاویر چندزمانه

پلاریمتری و SAR برای طبقه‌بندی نوع پوشش زمین کاربرد زیادی داشته است [۲۴، ۳۵، ۳۶]. علاوه بر این، استفاده از تصاویر چندزمانه باعث کاهش محدودیت‌های استفاده از تصاویر SAR مانند محدودیت‌های هندسی (خطاهای ناشی از هندسه تصویر برداری مانند خطای shadow، layover و پدیده کوتاه‌شدگی)، پیچیدگی‌های پردازش پراکنش و وجود نویز اسپکل [۳۷] می‌گردد. منطقه مورد مطالعه در این تحقیق شامل دو نوع گونه درخت‌های سخت چوب و نرم چوب می‌باشد. درختان سخت چوب در تمام فصول دارای برگ می‌باشند در حالی که درختان نرم چوب در فصل زمستان بدون برگ می‌باشند. در صورتی که دو تصویر مربوط به دو فصل از گونه‌های جنگلی داشته باشیم که در یکی از تصاویر تمام درختان دارای برگ و در تصویر دیگر درختان نرم‌چوب بدون برگ باشند، تشخیص این دو نوع به سادگی صورت می‌گیرد. بنابراین در این تحقیق به منظور طبقه‌بندی مناطق جنگلی از دو تصویر که یکی مربوط به فصل زمستان و دیگری مربوط به فصل تابستان است، استفاده خواهد شد.

در روش ارائه شده در این مقاله، ابتدا با استفاده از ویژگی‌های استخراج شده از هر دو تصویر ابتدا طبقه‌بندی به روش SVM انجام می‌گردد که حاصل آن یک نقشه طبقه‌بندی اولیه خواهد بود. این نقشه طبقه‌بندی اولیه در مدل‌سازی اطلاعات مکانی توسط MRF مورد نیاز است. این مدل‌سازی با در نظر گرفتن توزیع ویشارت برای ماتریس کوواریانس استخراج شده از تصویر صورت می‌گیرد. در نهایت اطلاعات همسایگی مدل شده به طبقه‌بندی کننده SVM اضافه گردیده و طبقه‌بندی به صورت تکراری انجام می‌گیرد. بنابراین در روش پیشنهادی از هر دو روش SVM و روش ویشارت استفاده شده است و به نوعی این دو روش تلفیق شده است. همچنین اطلاعات مکانی به نحو مطلوبی به روش SVM افزوده شده است.

این مقاله از ۵ 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 همچنین نتایج اجرای الگوریتم پیشنهادی می‌پردازد. در نهایت نیز نتیجه‌گیری و پیشنهادات در بخش ۵ ارائه شده است.

۲- مبانی تئوری تحقیق

۲-۱- طبقه‌بندی به روش SVM

$$\max_{\alpha} \left\{ \sum_i \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \phi(x_i)^T \phi(x_j) \right\} \quad (2)$$

$$\text{subject to } \sum_{i=1}^n \alpha_i y_i = 0,$$

$$0 \leq \alpha_i \leq C, i = 1, 2, \dots, n$$

که در آن متغیرهای مجازی α_i ضرایب لاگرانژ بوده و فقط برای بردارهای پشتیبان غیرصفر می‌باشد. ضرب داخلی نمونه‌ها در فضای ویژگی می‌تواند بدون در اختیار داشتن تابع نگاشت ϕ ، بطور مستقیم از داده‌ها در فضای اصلی با استفاده از تابع کرنل محاسبه شود. برای این منظور تابع کرنل $\phi(x_i)^T \phi(x_j) = k(x_i, x_j)$ باید در شرایط Mercer صدق کند [۳۹] که در این صورت تابع نگاشت ϕ در فضای هیلبرت وجود خواهد داشت بصورت $k(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ بنابراین رابطه (۲) با استفاده از روش کرنل به صورت رابطه (۳) نوشته می‌شود.

$$\max_{\alpha} \left\{ \sum_i \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j k(x_i, x_j) \right\} \quad (3)$$

$$\text{subject to } \sum_{i=1}^n \alpha_i y_i = 0$$

بعد از حل مساله بهینه‌سازی، ضرایب α_i همانطور که در [۴۰] توضیح داده شده است تعیین شده و پس از آن تابع تصمیم‌گیری برای طبقه‌بندی هر بردار دلخواه x توسط رابطه (۴) بیان می‌شود.

$$f_{SVM}(x) = \sum_{i=1}^n \alpha_i y_i k(x_i, x) + b \quad (4)$$

که در این رابطه، b به گونه‌ای تعیین می‌شود که شرط $y_i \left(\sum_{i=1}^n \alpha_i y_i k(x_i, x_j) + b \right) = 1$ برای هر x_j همراه با $0 \leq \alpha_j \leq C$ برقرار باشد. در نهایت نیز برچسب هر نمونه برابر با $\text{sgn}(f_{SVM}(x))$ خواهد بود.

۲-۲- طبقه‌بندی به روش ویشارت

برای طبقه‌بندی داده‌های PolSAR معمولاً از روش ویشارت استفاده می‌شود. این روش یک طبقه‌بندی‌کننده-ی بیشینه شباهت بر اساس توزیع ویشارت مختلط برای ماتریس کوواریانس پلاریمتری می‌باشد [۲۱]. با فرض

این روش اولین بار توسط Boser و همکاران به عنوان یک روش دو کلاسه ارائه شد [۲۲]. این روش نیاز به تعیین توزیع آماری داده‌ها ندارد و از داده‌های آموزشی برای آموزش طبقه‌بندی کننده استفاده می‌شود. فرض کنید برای یک تصویر که از d کانال تشکیل شده باشد و $x_i \in \mathbb{R}^d$ بردار ویژگی پیکسل i ام باشد. در اینصورت SVM یک ابرصفحه بهینه برای یک مجموعه داده آموزشی داده شده به صورت $\{(x_1, y_1), \dots, (x_n, y_n)\}$ که در آن $y_i \in \{-1, +1\}$ ، تصویر شده به فضای هیلبرت^۱ توسط یک نگاشت غیرخطی به صورت $\phi: \mathbb{R}^d \rightarrow \mathcal{H}$ ایجاد می‌کند. این ابر صفحه جدایی بین نمونه‌های کلاس‌ها را در فضای ویژگی چند بعدی بیشینه می‌کند. همچنین با اجازه دادن به میزان کمی خطا در جدایی بین نمونه‌های آموزشی در کلاس‌ها، ابرصفحه‌ی بهینه با بیشینه نمودن حاشیه^۲ و کمینه نمودن جمع خطاهای وارد شده بدست می‌آید [۳۸]. بنابراین SVM رابطه (۱) را حل می‌کند.

$$\min_{w, \xi, b} \left\{ \frac{1}{2} \|w\|^2 + C \sum_i \xi_i \right\} \quad (1)$$

$$\text{subject to } y_i (w^T \phi(x_i) + b) \geq 1 - \xi_i,$$

$$\xi_i \geq 0, i = 1, 2, \dots, n$$

که w وزن تابع خطی تصمیم‌گیر در $\mathcal{H}$ و به عنوان بردار عمود بر ابرصفحه و b میزان بایاس و یک مقدار ثابت بوده به طوری که $b/\|w\|$ فاصله بین ابرصفحه و مبدا را نشان می‌دهد. ξ_i متغیر خطا می‌باشد که خطای نمونه‌های آموزشی یعنی $\xi_i = [\xi_1, \dots, \xi_n]^T$ را نشان می‌دهد. در نهایت $C \in \mathbb{R}$ پارامتر تنظیم بوده که میزان عمومیت پذیری را تنظیم می‌کند. مساله بهینه‌سازی رابطه (۱) با استفاده از تابع دوگانه لاگرانژ که به صورت رابطه (۲) تعریف می‌شود، قابل حل است.

^۱ Hilbert Space

^۲ Margin

برقراری شرط $S_{HV} = S_{VH}$ ، بردار پراکنش برابر است با $S = [S_{HH} \quad \sqrt{2}S_{HV} \quad S_{VV}]^T$ ، که در آن T ترانهاده ماتریس می‌باشد و $\sqrt{2}$ بر روی عبارت S_{HV} برای کنترل ثبات در توان کل پراکنشی می‌باشد [۴۱]. بنابراین ماتریس کوواریانس پلاریمتری به صورت رابطه (۵) بیان می‌شود.

$$Z = \left(\sum_{i=1}^L x_i x_i^* \right) / L \quad (5)$$

در این رابطه، L تعداد منظر، x_i نمونه از منظر i ام x و * ترانهاده کانسوگیت مختلط می‌باشد. طبق این طبقه‌بندی کننده، Z دارای توزیع مختلط ویشارت طبق رابطه (۶) می‌باشد [۴۲].

$$p(Z) = \frac{L^q |Z|^{L-q} \exp\{-L \text{Tr}(\Sigma^{-1} Z)\}}{R(L, q) |\Sigma|^L} \quad (6)$$

که در آن $\Sigma = E\{Z\}$ میانگین Z و q تعداد کانال‌های پلاریمتری را نشان می‌دهد. $\text{Tr}(\cdot)$ ترانهاده، $|\cdot|$ دترمینان ماتریس، $R(L, q) = \pi^{q(q-1)/2} \Gamma(L) \dots \Gamma(L-q+1)$ فاکتور نرمال‌سازی و $\Gamma(\cdot)$ تابع گاما می‌باشند. لگاریتم این تابع چگالی احتمال میزان شباهت را نشان می‌دهد که به عنوان فاصله بین ماتریس کوواریانس داده شده Z و مقدار ماتریس کوواریانس مورد انتظار برای هر کلاس شناخته می‌شود. طبقه‌بندی کننده بیشینه شباهت علاوه بر مشخص نمودن ماتریس کوواریانس مورد انتظار برای هر کلاس، یک قاعده برای تعیین کلاس هر پیکسل مشخص می‌کند. به این صورت که Z به کلاس m ام (ω_m) تعلق دارد به طوری که

$$\omega_m = \arg \max_{\omega_k} \{p(Z | \omega_m) p(\omega_m)\} \quad (7)$$

و یا $p(Z | \omega_m) p(\omega_m) \geq p(Z | \omega_j) p(\omega_j)$ برای تمام $j \neq m$ که $p(\omega_m)$ احتمال اولیه برای کلاس ω_m را نشان می‌دهد. این بیشینه سازی احتمال متناظر است با کمینه نمودن تابع تمایز طبق رابطه (۸) شناخته می‌شود.

$$d(Z, \Sigma_m) = n \ln |\Sigma_m| + n \text{Tr}(\Sigma_m^{-1} Z) - \ln [P(\omega_m)] \quad (8)$$

احتمال اولیه در این رابطه را به دلیل عدم دسترسی به اطلاعات کلاس‌ها و همچنین کم کردن هزینه محاسبات، برای تمام کلاس‌ها برابر در نظر می‌گیرند. با فرض احتمال


اولیه برابر برای تمام کلاس‌ها، رابطه (۸) به رابطه (۹) معروف به فاصله ویشارت تغییر می‌کند. طبقه‌بندی با استفاده از این رابطه را طبقه‌بندی به روش ویشارت می‌نامند.

$$d(Z, \Sigma_m) = \ln |\Sigma_m| + \text{Tr}(\Sigma_m^{-1} Z) \quad (9)$$

با استفاده از این روش، ابتدا فاصله ویشارت برای هر پیکسل از تمام کلاس‌ها تعیین شده و پیکسل به کلاسی که کمترین فاصله را از آن دارد تعلق می‌یابد.

۲-۳- طبقه‌بندی تصویر به کمک میدان‌های تصادفی مارکوف

میدان‌های تصادفی مارکوف به علت قدرت و سرعت بالا، یکی از گسترده‌ترین مدل‌های تصادفی برای مدل‌سازی اطلاعات مکانی در تصاویر می‌باشد که در آن توزیع احتمال اولیه هر کلاس مدل‌سازی می‌شود [۴۳]. اگر فرض کنیم $\{\partial_i\}_{i \in I}$ یک سیستم همسایگی بر روی I باشد در این صورت $\partial_i \subset I$ مجموعه‌ای از پیکسل‌های همسایه 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 سمت چپ و همسایگی مرتبه دوم پیکسل j 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 (۱۰) برقرار باشد.

$$P(y_i | y_{I-\{i\}}) = P(y_i | y_{\partial_i}) \quad (10)$$

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 با تابع چگالی احتمال y_i

می‌گردد. در نهایت نیز در طبقه‌بندی MAP هر پیکسل به کلاسی که کمترین میزان انرژی را دارد تعلق می‌گیرد.

۳- روش پیشنهادی

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

روش SVM اگرچه دارای نتایج بسیار دقیق در طبقه‌بندی می‌باشد ولی عیب اصلی آن در نظر نگرفتن وابستگی مکانی پیکسل‌ها در فرآیند طبقه‌بندی می‌باشد. در روش پیشنهادی در این بخش، اطلاعات مکانی مدل شده توسط MRF به فرآیند طبقه‌بندی‌کننده SVM افزوده شده و در نتیجه یک طبقه‌بندی‌کننده جدید ایجاد می‌گردد. این طبقه‌بندی‌کننده از ماتریس کوواریانس داده‌های پلاریمتری و توزیع آن (توزیع ویشارت)، اطلاعات همسایگی مدل شده توسط MRF و تمام ویژگی‌ها و اطلاعات قابل استخراج از تصاویر پلاریمتری استفاده می‌کند. الگوریتم پیشنهادی در این تحقیق SVM^۳ نامیده می‌شود.

اطلاعات همسایگی برای هر پیکسل ابتدا توسط رابطه (۱۱) مدل شده و پس از آن به روابط مربوط به SVM افزوده می‌گردد. 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+، می‌توان از تابع انرژی تفاضلی با رابطه (۱۳) استفاده نمود [۳۴].

$$\Delta U_i(x_i, y_{\hat{c}_i}) = U_i(-1 | x_i, y_{\hat{c}_i}) - U_i(+1 | x_i, y_{\hat{c}_i}) \quad (13)$$

در این رابطه، اگر $\Delta U(x_i, y_{\hat{c}_i}) \geq 0$ باشد، انرژی کلاس ۱- بیشتر از انرژی کلاس ۱+ بوده و بنابراین پیکسل به کلاس ۱+ نزدیکتر است. بر عکس، اگر $\Delta U(x_i, y_{\hat{c}_i}) < 0$ باشد انرژی کلاس ۱- کمتر بوده و پیکسل به کلاس ۱- نزدیکتر است. به عبارت دیگر، کلاس هر پیکسل به صورت $\text{sgn}(\Delta U(x_i, y_{\hat{c}_i}))$ از $\Delta U(x_i, y_{\hat{c}_i})$ محاسبه می‌گردد که مشابه روش محاسبه کلاس هر پیکسل توسط تابع تصمیم‌گیری SVM می‌باشد.

باشد (فرض استقلال شرایط) و $\{y_i\}_{i \in I}$ میدان تصادفی مارکوف باشد. در این صورت طبق تئوری Hammersley-Clifford بیشینه‌سازی توزیع توام ثانویه^۱ $P(y_I | x_I)$ برای تمام برچسب‌ها و برای تمام بردارهای ویژگی ارائه شده، با کمینه‌سازی تابع پتانسیل سراسری^۲ تعریف شده بر روی سیستم همسایگی معادل است [۴۳، ۴۴]. همچنین توزیع توام ثانویه $P(y_I | x_I)$ به‌طور منحصر به فردی توسط جمع تمام توزیع‌های حاشیه‌ای ثانویه $P(y_i | x_i, y_{\hat{c}_i})$ ($i \in I$) هر برچسب به شرط بردار ویژگی مربوطه و سیستم همسایگی تعریف شده بدست می‌آید. این توزیع حاشیه‌ای ثانویه می‌تواند به صورت $\exp[-U_i(y_i | x_i, y_{\hat{c}_i})]$ بیان شود که در آن $U_i(y_i | x_i, y_{\hat{c}_i})$ تابع انرژی ثانویه محلی بوده و از رابطه (۱۱) بدست می‌آید [۴۳].

$$U_i(y_i | x_i, y_{\hat{c}_i}) = -\ln p(x_i | y_i) + \beta E_i(y_i | y_{\hat{c}_i}) \quad (11)$$

در این رابطه، β یک پارامتر مثبت، E_i تابع انرژی اولیه محلی مشخص‌کننده MRF انتخابی برای $\{y_i\}_{i \in I}$ که به عنوان نمونه می‌توان مدل مشهور Potts با رابطه (۱۲) اشاره کرد [۴۵]

$$E_i(y_i | y_{\hat{c}_i}) = -\sum_{j \in \hat{c}_i} \delta(y_i, y_j) \quad (12)$$

که در آن $\delta(a, b)$ برابر با ۱ است اگر $a = b$ باشد و در غیر اینصورت برابر با صفر خواهد بود. رابطه (۱۱) 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 اطلاعات مکانی است که این تلفیق توسط پارامتر β کنترل می‌شود و بنابراین β میزان نرم‌شدگی توسط MRF را مشخص می‌کند [۴۶].

در رابطه (۱۱) برای محاسبه تابع انرژی موخر MRF، توزیع آماری کلاس‌ها مورد نیاز است. برای هر نوع تصویر می‌توان توزیع مناسب را مشخص نمود. همانطور که در بخش قبل بیان شد، برای تصاویر پلاریمتری توزیع مختلط ویشارت طبق رابطه (۶) فرض می‌شود. بنابراین با استفاده از توزیع ویشارت و تابع انرژی اولیه، برای هر پیکسل و برای کلاس‌های موجود، تابع انرژی موخر MRF محاسبه

^۳ SVM-Wishart-MRF (SWM)

^۱ Maximum A Posteriori (MAP)

^۲ Global

برای هر پیکسل، $\Delta U(x_i, y_{\hat{\alpha}_i})$ بدست آمده به رابطه (۱) مربوط به طبقه‌بندی اضافه می‌شود. در این صورت مساله کمینه‌سازی بصورت زیر تعریف می‌گردد:

$$\min_{w, \xi_i, b} \left\{ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \right\} \quad (14)$$

subject to $y_i (w^T \phi(x_i) + b + \Delta U(x_i, y_{\hat{\alpha}_i})) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i=1, 2, \dots, n$

افزودن $\Delta U(x_i, y_{\hat{\alpha}_i})$ به معادله شرط به این معنی است که ابرصفحه SVM برای هر پیکسل به گونه‌ای تغییر کند که کلاس هر پیکسل به کلاسی که انرژی آن کمتر است نزدیک شود. همانند روش SVM در بخش ۲-۱، مساله بهینه‌سازی به کمک تابع دوگانه لاگرانژ قابل حل است:

$$\max_{\alpha} \left\{ \sum_{i=1}^n (1 - y_i \gamma \Delta U(x_i, y_{\hat{\alpha}_i})) \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j k(x_i, x_j) \right\} \quad (15)$$

subject to $\sum_{i=1}^n \alpha_i y_i = 0, 0 \leq \alpha_i \leq C, i = 1, 2, \dots, n$

ضرایب α_i تعیین شده و پس از آن تابع تصمیم‌گیری برای طبقه‌بندی هر بردار دلخواه x توسط رابطه (۱۶) بیان می‌شود.

$$f_{SVM}(x) = \sum_{i=1}^n \alpha_i y_i k(x_i, x) + b + \Delta U(x_i, y_{\hat{\alpha}_i}) \quad (16)$$


و در نهایت نیز برچسب هر نمونه برابر با $\text{sgn}(f_{SVM}(x))$ خواهد بود. رابطه (۱۶) می‌تواند به صورت رابطه (۱۷) نیز نوشته شود:

$$f_{SVM}(x) = f_{SVM}(x) + \Delta U(x_i, y_{\hat{\alpha}_i}) \quad (17)$$

بنابراین، اگر $\Delta U(x_i, y_{\hat{\alpha}_i}) \geq 0$ باشد، آنگاه $f_{SVM}(x) \geq f_{SVM}(x)$ و اگر $\Delta U(x_i, y_{\hat{\alpha}_i}) < 0$ باشد، آنگاه $f_{SVM}(x) < f_{SVM}(x)$ خواهد بود. 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 نویز نمک-فلفلی در نتیجه طبقه‌بندی با استفاده از این روش کاهش می‌یابد.

۲-۳- الگوریتم روش پیشنهادی

فلوچارت الگوریتم روش پیشنهادی به منظور طبقه‌بندی تصاویر پلاریمتری با استفاده از اطلاعات همسایگی در شکل ۲ نشان داده شده است. این الگوریتم شامل دو مرحله اصلی می‌باشد که در این بخش شرح داده می‌شود.



شکل ۲- الگوریتم روش پیشنهادی

۳-۲-۱- مرحله اول

در این مرحله، استخراج ویژگی از تصاویر پلاریمتری مورد استفاده، انتخاب ویژگی و تعیین پارامترهای بهینه طبقه‌بندی‌کننده با استفاده از الگوریتم ژنتیک بصورت همزمان انجام می‌گردد.

در این مقاله از ویژگی‌های استخراج شده در [۶] استفاده شده است. این ویژگی‌ها عبارتند از: عناصر ماتریس پراکندگی، عناصر حاصل از تجزیه هدف و ویژگی‌های تفکیک‌کننده SAR. ویژگی‌های بیان شده با استفاده از نرم‌افزار POLSAR pro 4.2 و از ماتریس همدوسی پس از انجام مراحل تصحیح هندسی و زمین مرجع‌سازی بدست می‌آید. در مجموع ۵۸ ویژگی از هر تصویر پلاریمتری استخراج شد.

به علت تعداد ویژگی زیاد و همچنین وجود همبستگی بین تعدادی از آن‌ها، انتخاب ویژگی ضروری می‌باشد. برای این منظور از الگوریتم ژنتیک استفاده گردید. الگوریتم ژنتیک دارای قابلیت حل مسائل به صورت همزمان را دارد. در الگوریتم ژنتیک، دقت کلی طبقه‌بندی به عنوان معیار ارزیابی استفاده شده است. در این مقاله از کرنل RBF^۱ با رابطه (۱۸) در طبقه‌بندی‌کننده SVM استفاده می‌گردد.

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (18)$$

ویژگی‌های مناسب، مقدار بهینه برای پارامتر σ موجود در این کرنل و مقدار بهینه برای پارامتر تنظیم (C) در رابطه (۱) با استفاده از الگوریتم ژنتیک تعیین می‌گردد. همچنین طبقه‌بندی SVM به روش یک در برابر یک^۲ انجام می‌شود. بنابراین لازم است برای هر جفت کلاس مقدار بهینه برای پارامترهای طبقه‌بندی‌کننده برآورد گردد. در این الگوریتم جمعیت اولیه برابر با ۱۰۰ کروموزوم به صورت تصادفی تولید شد. در هر نسل ۱۰ کروموزوم برتر به نسل بعد انتقال پیدا می‌کنند. همچنین از روش تورنمنت^۳ برای انتخاب والدین، تقاطع تک نقطه-ای با نرخ ۰.۸٪ و جهش یکنواخت استفاده شد. در صورتی که تفاوت بین بهترین نتیجه ۱۰ نسل متوالی از ۰.۰۰۱٪

کمتر باشد، الگوریتم متوقف خواهد شد. پس از تعیین باند و پارامترهای بهینه، طبقه‌بندی به روش SVM انجام می‌گردد. نقشه طبقه‌بندی حاصل از این مرحله، ورودی مرحله دوم می‌باشد.

۳-۲-۲- مرحله دوم

در روش پیشنهادی به منظور کمینه‌سازی تابع انرژی MRF از روش حالت‌های شرطی تکرار شونده^۴ استفاده می‌شود. بنابراین مرحله دوم به صورت تکراری انجام می‌شود. ابتدا تابع انرژی اولیه MRF برای هر پیکسل با کمک نقشه طبقه‌بندی موجود محاسبه می‌گردد. پس از آن به کمک ماتریس کوواریانس داده‌های پلاریمتری و در نظر گرفتن توزیع ویشارت برای آن، تابع انرژی تفاضلی طبق رابطه (۱۳) برای هر پیکسل و برای هر جفت کلاس محاسبه می‌گردد. سپس با استفاده از آن، طبقه‌بندی SWM طبق رابطه (۱۷) انجام می‌گردد. بدین ترتیب نقشه‌ی طبقه‌بندی جدید بدست می‌آید. حال شرط همگرایی بررسی می‌شود بدین صورت که اگر درصد تغییر برچسب پیکسل‌ها بیش از حدآستانه (۱ درصد) 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 مزایا و معایب احتمالی روش در مقایسه با تعدادی از روش‌های دیگر، انجام می‌شود. ارزیابی روش با استفاده از دقت کلی طبقه‌بندی حاصل از ماتریس ابهام بدست آمده با استفاده از داده‌های آزمایشی، انجام می‌شود.

۴- نتایج تجربی

۴-۱- منطقه مطالعاتی و تصاویر مورد استفاده

منطقه‌ی مورد مطالعه در این تحقیق، یک منطقه جنگلی به نام Petawawa نزدیک Chalk River و در ایالت Ontario، 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

^۱ Radial Basis Function

^۲ One-Against-One (OAO)

^۳ Tournament

^۴ Iterated Conditional Modes (ICM)


شامل بلوط قرمز (Or)، صنوبر (Po)، کاج قرمز (Pr) و کاج سفید (Pw) و دو کلاس پوشش گیاهی (Gv) و آب (Wa) مدنظر می‌باشد. تصاویر مورد استفاده در این تحقیق توسط ماهواره رادارست-۲ در سال ۲۰۰۹ از منطقه مذکور، به صورت پلاریمتری اخذ شده است. یکی از این تصاویر مربوط به فصل تابستان و تصویر دیگر مربوط به فصل زمستان می‌باشد. 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 range و azimuth به ترتیب برابر با ۱۱ و ۹ متر است.

توجه شود که استفاده از داده‌های باند C سنجنده رادارست-۲ در بعضی از کاربردهای جنگل مانند برآورد تاج پوشش و یا تعیین بایومس به دلیل عمق نفوذ کم آن، مناسب نیست. اما در طبقه‌بندی گونه‌های جنگلی و با توجه به اینکه شکل برگ درختان متفاوت است و همچنین تعدادی از گونه‌ها بدون برگ و تعدادی دارای برگ می‌باشند، به عمق نفوذ بالا نیاز نبوده و با استفاده از باند C نیز می‌توان طبقه‌بندی گونه‌های جنگلی را انجام داد [۶، ۷، ۸].


داده‌های مرجع زمینی (آموزشی و آزمایشی) از نقشه-های سال ۲۰۰۲ منطقه، عکس‌های فتوگرامتری موجود از منطقه، تصاویر لندست ETM+ و بازپدیده‌های زمینی جمع-آوری شده است و پس از آن برای تاریخ اخذ تصاویر (سال ۲۰۰۹) بروز شده است. قسمتی از این داده‌ها به عنوان داده آموزشی، برای تخمین پارامترهای مورد نیاز و آموزش طبقه‌بندی‌کننده به کار می‌رود و بخشی دیگر به صورت داده آزمایشی برای ارزیابی نتایج استفاده می‌شوند. جدول ۱ تعداد داده‌های آموزشی و آزمایشی انتخاب شده را نشان می‌دهد. نیمی از داده‌های موجود برای آموزش و مابقی برای آزمایش در نظر گرفته شده است.

جدول ۱- لیست داده‌های آموزشی و آزمایشی در هر کلاس			
کلاس	توضیح	تعداد نمونه آموزشی	تعداد نمونه آزمایشی
Or	بلوط قرمز	۱۰۳۲	۱۱۶۰
Po	صنوبر	۷۲۴	۶۴۲
Pr	کاج قرمز	۵۷۰	۵۶۵
Pw	کاج سفید	۳۸۶	۴۷۷
Gv	پوشش گیاهی	۱۵۳۱	۱۸۷۸
Wa	آب	۶۸۹	۶۸۵
مجموع		۴۹۲۸	۵۴۱۱


قسمت الف و ب در شکل ۳ تصاویر منطقه را به صورت ترکیب رنگی پائولی و قسمت پ نمایي از منطقه در Google Earth را نشان می‌دهد.



(پ)



(ب)



(الف)

شکل ۳- نمایی از منطقه: زیرتصویر مورد استفاده به صورت ترکیب رنگی پائولی مربوط به (الف) فصل زمستان و (ب) فصل تابستان. (پ) منطقه مورد مطالعه در Google Earth

^۱ Singe Look Complex


۴-۲- نتایج طبقه‌بندی

به منظور بررسی دقت و کارایی الگوریتم پیشنهادی، داده‌های پلاریمتری شرح داده شده در بخش قبل را با استفاده از و با روش‌های ویشارت، ویشارت-مارکوف، SVM و الگوریتم پیشنهادی طبقه‌بندی نموده و با محاسبه دقت کلی بدست آمده از ماتریس ابهام، آن‌ها را


مقایسه می‌کنیم. شکل ۴، تصاویر حاصل از طبقه‌بندی با استفاده از روش‌های به ترتیب ویشارت، ویشارت-مارکوف (WMRF) [۳۰]، SVM و الگوریتم پیشنهادی (SWM) را نشان می‌دهد. جدول ۲ نیز دقت هر کلاس، دقت کلی، میانگین دقت چهار کلاس گونه‌های جنگلی و زمان مورد نیاز برای اجرای طبقه‌بندی در هر روش را نشان می‌دهد.

جدول ۲- دقت طبقه‌بندی کلاس‌ها و دقت کلی طبقه‌بندی با استفاده از روش‌های ویشارت، ویشارت-مارکوف، SVM و SWM.


کلاس/ روش	ویشارت	ویشارت-مارکوف	SVM	SWM
Or	۴۸/۸۲	۵۶/۴۳	۶۵/۲۶	۷۵/۹۵
Po	۵۵/۷۴	۶۰/۷۷	۶۷/۴۵	۷۰/۰۹
Pr	۳۱/۷۸	۳۵/۷۸	۵۱/۸۶	۵۶/۴۶
Pw	۲۹/۱۸	۳۷/۶۵	۵۶/۶۰	۶۹/۸۱
Gv	۸۱/۷۵	۸۲/۹۵	۸۳/۳۳	۸۹/۶۷
Wa	۱۰۰/۰۰	۱۰۰/۰۰	۹۰/۸۶	۹۲/۳۱
میانگین دقت گونه‌های جنگلی	۴۱/۳۸	۴۷/۶۵	۶۰/۲۹	۶۸/۰۷
دقت کلی	۶۳/۶۳	۶۸/۳۸	۷۲/۸۸	۷۹/۸۱
زمان اجرا	۳۳ ثانیه	۷ دقیقه و ۳ ثانیه	۱۵ دقیقه و ۵ ثانیه	۲۲ دقیقه و ۱۹ ثانیه




(ب)



(الف)



(ت)



(پ)



شکل ۴- نتیجه طبقه‌بندی: به روش (الف) ویشارت، (ب) ویشارت-مارکوف، (پ) SVM و (ت) SWM

همانطور که در شکل ۴ قسمت الف مشاهده می‌شود، نقشه طبقه‌بندی حاصل از روش ویشارت بویژه در کلاس‌های گونه‌های جنگلی، دارای نویز زیادی می‌باشد. این مساله به دلیل عدم استفاده از ویژگی‌های کمکی مانند ویژگی‌های حاصل از تجزیه پلاریزیمی و طبقه‌بندی فقط بر مبنای ماتریس کوواریانس، ایجاد شده است. البته در این روش کلاس آب که دارای پراکنش بسیار متفاوت از دیگر کلاس‌ها می‌باشد به طور کامل از دیگر کلاس‌ها تشخیص داده شده است به طوری که دقت طبقه‌بندی آن ۱۰۰٪ می‌باشد. مدل‌سازی اطلاعات همسایگی و وارد نمودن آن به طبقه‌بندی باعث نزدیک شدن کلاس هر پیکسل 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 [۳۰]. طبق جدول ۲ و شکل ۴ ب این افزودن اطلاعات همسایگی اگرچه باعث افزایش ۵ درصدی دقت طبقه‌بندی و کاهش نویز موجود در تصویر حاصل از طبقه‌بندی شده است اما همچنان دقت کافی برای طبقه‌بندی کلاس‌ها ارائه نکرده است. در واقع این روش بر اساس روش ویشارت و در نظر گرفتن توزیع ویشارت برای ماتریس کوواریانس داده‌های پلاریزیمی می‌باشد. بنابراین این روش بهبود دهنده روش ویشارت می‌باشد و نمی‌توان از این روش انتظار تفکیک‌پذیری مناسب در طبقه‌بندی کلاس‌هایی مانند جنگل که شباهت پراکنش بالایی دارند، داشت. برای بررسی دقیق‌تر دقت طبقه‌بندی گونه‌های جنگلی از معیار میانگین دقت چهار کلاس گونه‌های جنگلی (FAA) استفاده می‌کنیم. طبق جدول ۲، این معیار برای روش ویشارت و ویشارت-مارکوف برابر با ۴۱/۳۸ و ۴۷/۶۵ درصد می‌باشد. این میزان بیانگر این است که این دو روش عملاً نتوانسته است گونه‌های جنگلی را از یکدیگر تفکیک کند.

طبق جدول ۲، روش ویشارت نسبت به روش ویشارت-مارکوف بسیار سریع‌تر بوده و ۳۳ ثانیه زمان می‌برد. روش ویشارت-مارکوف به صورت تکراری عمل می‌کند و در هر تکرار تعداد منظر معادل^۱ و تابع انرژی محلی

باید محاسبه شود. بنابراین زمان اجرای آن حدود ۱۳ برابر روش ویشارت می‌باشد.

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 پراکنش، 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 در نتیجه دقت کلی طبقه‌بندی نسبت به روش ویشارت ۹ درصد افزایش یافته است. همچنین معیار FAA در این روش برابر با ۶۰/۲۹٪ بدست آمد که نشان‌دهنده افزایش حدود ۱۹ و ۱۳ درصدی نسبت به روش‌های ویشارت و ویشارت-مارکوف می‌باشد. همانطور که در شکل ۴ پ نیز مشاهده می‌شود، تصویر حاصل از طبقه‌بندی به این روش نسبت به هر دو روش ویشارت و ویشارت-مارکوف دارای نویز کمتر می‌باشد. محدودیت اصلی این روش، عدم استفاده از اطلاعات همسایگی پیکسل مورد طبقه‌بندی می‌باشد.

الگوریتم پیشنهادی در این مقاله از اطلاعات پراکنش مورد استفاده در روش SVM، اطلاعات مکانی در محاسبه تابع انرژی اولیه و ماتریس کوواریانس در محاسبه تابع انرژی ثانویه 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 شکل ۴ و همچنین افزایش ۱۶ و ۱۱ و ۷ درصدی دقت طبقه‌بندی نسبت به روش‌های به ترتیب ویشارت، ویشارت-مارکوف و SVM، توانایی بالای این روش را نشان می‌دهد.

جدول ۳ ماتریس ابهام طبقه‌بندی به روش SVM و جدول ۴ همان ماتریس برای روش SWM را نشان می‌دهد. طبق جدول ۳، بین کلاس‌های Or و Po و همچنین کلاس‌های Pr و Pw ابهام زیادی وجود دارد. علت این ابهام در نوع گونه‌های ذکر شده است. منطقه مورد مطالعه از شامل دو نوع گونه درخت‌های سخت چوب و نرم چوب می‌باشد. کلاس‌های Or و Po جز گونه‌های نرم چوب و کلاس‌های Pr و Pw جز گونه‌های سخت چوب می‌باشد. درختان سخت چوب در تمام فصول دارای برگ می‌باشند در حالی که درختان نرم چوب در فصل زمستان بدون برگ می‌باشند. بنابراین دو گونه از دو نوع متفاوت نسبت

^۱ Equivalent Number of Looks (ENL)

کلاس آب بدین صورت می‌باشد. این مساله باعث می‌شود که کلاس آب در روش ویشارت که بر اساس نوع پراکنش عمل می‌کند دارای دقت ۱۰۰ درصد باشد. کلاس دیگر موجود در منطقه کلاس پوشش گیاهی است که پراکنش آن نه کاملاً حجمی است مانند کلاس گونه‌های جنگلی و نه سطحی مانند کلاس آب. در واقع می‌توان گفت که پراکنش این کلاس در قسمت‌هایی سطحی بوده و در قسمت‌هایی به صورت حجمی می‌باشد البته با شدت کم‌تر نسبت به گونه‌های جنگلی. به عبارت دیگر، پراکنش این کلاس در قسمت‌هایی با گونه‌های جنگلی و در قسمت‌هایی دیگر با کلاس آب مشابهت دارد. به همین دلیل و همانطور که در جدول ۳ و جدول ۴ مشاهده می‌شود، نمونه‌های آزمایشی از این کلاس هم در کلاس آب و هم در کلاس‌های گونه‌های جنگلی قرار گرفته است. معیار FAA همانطور که بیان شد برابرست با میانگین دقت گونه‌های جنگلی و از آنجایی که تنها این کلاس‌ها هستند که دارای پراکنش حجمی خالص می‌باشند، می‌توان گفت که این معیار بیان‌گر دقت کلاس‌های دارای پراکنش حجمی می‌باشد و بنابراین بیشترین افزایش دقت در روش پیشنهادی نیز مربوط به این نوع پراکنش می‌باشد.

به دو گونه از یک نوع تفکیک‌پذیری بیشتری دارند. طبق ماتریس ابهام روش SVM، تعداد ۴۰۳ نمونه از کلاس Or در کلاس‌های دیگر بویژه کلاس Po طبقه‌بندی شده است در حالی که طبق جدول ۴، روش پیشنهادی تعداد ۱۲۴ نمونه از این تعداد را به درستی طبقه‌بندی کرده است. بنابراین در روش پیشنهادی دقت این کلاس با حدود ۱۱ درصد افزایش از حدود ۶۵ درصد به حدود ۷۶ درصد رسیده است. علاوه بر این، کلاس Pw نیز در روش SVM دارای ۵۶ درصد دقت است در صورتی که با استفاده از اطلاعات مکانی در روش پیشنهادی، دقت آن به ۶۹ درصد رسیده که افزایش ۱۳ درصدی را نشان می‌دهد. در مجموع روش پیشنهادی بیشترین اثر را بر روی کلاس‌های گونه‌های جنگلی داشته است بطوریکه در معیار FAA حاصل از این روش نسبت به روش‌های ویشارت، ویشارت-مارکوف و SVM به ترتیب حدود ۲۷، ۲۰ و ۸ درصد بهبود مشاهده شده است.

با توجه به پوشش‌های موجود در منطقه مورد مطالعه، دو نوع پراکنش وجود دارد. نوع اول پراکنش حجمی است که گونه‌های جنگلی دارای این نوع پراکنش می‌باشند. نوع دوم نیز پراکنش سطحی (آیینی گونه) است که پراکنش

جدول ۳- ماتریس ابهام برای داده‌های تست حاصل از طبقه‌بندی به روش SVM

دقت کلاسی (%)	کلاس طبقه‌بندی شده						کلاس درست
	Wa	Gv	Pw	Pr	Po	Or	
۶۵/۲۶	۰	۴	۸۷	۱۲۹	۱۸۳	۷۵۷	Or
۶۷/۴۵	۰	۲۵	۲	۶	۴۳۳	۱۷۶	Po
۵۱/۸۶	۰	۲۳	۶۹	۲۹۳	۳۷	۱۴۳	Pr
۵۶/۶۰	۰	۰	۲۷۰	۶۷	۳۸	۱۰۲	Pw
۸۳/۳۳	۹۱	۱۵۶۵	۲	۱۰۹	۶۹	۴۲	Gv
۹۰/۸۶	۶۲۶	۱۵	۰	۰	۴۸	۰	Wa

جدول ۴- ماتریس ابهام برای داده‌های تست حاصل از طبقه‌بندی به روش SVM

دقت کلاسی (%)	کلاس طبقه‌بندی شده						کلاس درست
	Wa	Gv	Pw	Pr	Po	Or	
۷۵/۹۵	۰	۰	۶۹	۱۱۲	۹۸	۸۸۱	Or
۷۰/۰۹	۰	۳۳	۰	۰	۴۵۰	۱۵۹	Po
۵۶/۴۶	۰	۲۵	۵۵	۳۱۹	۲۹	۱۳۷	Pr
۶۹/۸۱	۰	۰	۳۳۳	۵۳	۱۹	۷۲	Pw
۸۹/۶۷	۰	۱۶۸۴	۰	۱۱۶	۵۹	۱۹	Gv
۹۲/۳۱	۶۳۶	۵۳	۰	۰	۰	۰	Wa

طبق جدول ۲، مدت زمان لازم برای اجرای SVM و SWM به ترتیب برابر است با ۱۵ دقیقه و ۵ ثانیه و ۲۲ دقیقه و ۱۹ ثانیه. روش SVM در مقایسه با روش ویشارت به دلیل استفاده از تعداد ویژگی بیشتر و همچنین محاسبات بیشتر به دلیل تبدیل فضا با استفاده از تابع کرنل، زمان بسیار بیشتری برای اجرا نیاز دارد. این میزان افزایش در زمان اجرا در مقایسه با افزایش ۹ درصدی دقت طبقه‌بندی قابل قبول به نظر می‌رسد. روش SWM به دلیل افزودن اطلاعات مکانی به روش SVM و انجام محاسبات مورد نیاز برای محاسبه تابع انرژی ثانویه برای هر پیکسل، حدود ۵۰ درصد زمان بیشتری نسبت به روش SVM نیاز دارد. در اینجا نیز افزایش زمان در مقابل با افزایش ۷ درصدی دقت طبقه‌بندی قابل قبول می‌باشد.

۶- نتیجه‌گیری

در این مقاله یک روش نوین طبقه‌بندی متنی به منظور طبقه‌بندی تصاویر پلاریمتری رادار با روزه مجازی ارائه شد. روش پیشنهادی با تلفیق ماشین بردار پشتیبان (SVM) و طبقه‌بندی‌کننده ویشارت عمل نموده و بنابراین از مزایای هر دو نوع روش پارامتریک و غیر پارامتریک بهره می‌برد. در این روش، ابتدا تابع انرژی اولیه میدان‌های تصادفی مارکوف (MRF) در یک همسایگی از هر پیکسل

محاسبه شد. سپس با استفاده از ماتریس کوواریانس داده‌های پلاریمتری برای هر پیکسل و در نظر گرفتن توزیع ویشارت برای آن، تابع انرژی تفاضلی MRF محاسبه و در طبقه‌بندی‌کننده SVM وارد شد. روش پیشنهادی علاوه بر اطلاعات پراکنش مختلف توسط SVM، از اطلاعات همسایگی نیز بهره می‌برد و این باعث کاهش نویز نمک دلفلی در نتیجه طبقه‌بندی می‌گردد. از الگوریتم ژنتیک در تعیین ویژگی‌های مناسب استخراج شده از دو تصویر و تعیین پارامترهای کرنل SVM استفاده شد. در نهایت نیز مقایسه نتایج بدست آمده از روش پیشنهادی با نتایج تعدادی از روش‌های پایه، کارایی این روش را اثبات نمود. طبقه‌بندی به این روش نسبت به روش‌های ویشارت، ویشارت-مارکوف و SVM، به ترتیب باعث ۱۶، ۱۱ و ۷ درصد افزایش در دقت طبقه‌بندی شد.

در این تحقیق به دلیل محدودیت‌های موجود در سنجنده‌های پلاریمتری راداری، از تصاویر باند C استفاده شد. استفاده از این باند باعث می‌شود که دقت طبقه‌بندی گونه‌های جنگلی از یک حد مشخص بیشتر نشود. بنابراین پیشنهاد می‌شود در تحقیقات آتی از تصاویر باند P و L در طبقه‌بندی با استفاده از روش پیشنهادی با توجه به نفوذ بیشتر آن به درون درختان جنگل استفاده شود.

مراجع

- [1] Y. Wang and F. Davis, (1997), "Decomposition of polarimetric synthetic aperture radar backscatter from upland and flooded forests," International Journal of Remote Sensing, vol. 18, pp. 1319-1332.
- [2] D. H. Hoekman and M. J. Quiñones, (2002), "Biophysical forest type characterization in the Colombian Amazon by airborne polarimetric SAR," Geoscience and Remote Sensing, IEEE Transactions on, vol. 40, pp. 1288-1300.
- [3] D. H. Hoekman and M. J. Quiriones, (2000), "Land cover type and biomass classification using AirSAR data for evaluation of monitoring scenarios in the Colombian Amazon," Geoscience and Remote Sensing, IEEE Transactions on, vol. 38, pp. 685-696.
- [4] O. Antropov, Y. Rauste, and T. Hame, (2011), "Volume scattering modeling in PolSAR decompositions: Study of ALOS PALSAR data over boreal forest," Geoscience and Remote Sensing, IEEE Transactions on, vol. 49, pp. 3838-3848.
- [5] M. Shimada, (2011), "Model-based polarimetric SAR calibration method using forest and surface-scattering targets," Geoscience and Remote Sensing, IEEE Transactions on, vol. 49, pp. 1712-1733.
- [6] Y. Maghsoudi, (2011), "Analysis of Radarsat-2 Full Polarimetric Data for Forest Mapping,"
- [7] Y. Maghsoudi, M. Collins, and D. G. Leckie, (2012), "Polarimetric classification of Boreal forest using nonparametric feature selection and multiple classifiers," International Journal of Applied Earth Observation and Geoinformation, vol. 19, pp. 139-150.
- [8] Y. Maghsoudi, M. J. Collins, and D. G. Leckie, (2013), "Radarsat-2 Polarimetric SAR Data for Boreal Forest Classification Using SVM and a Wrapper Feature Selector," Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of, vol. 6, pp. 1531-1538.

- [9] S. R. Cloude and E. Pottier, (1996), "A review of target decomposition theorems in radar polarimetry," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 34, pp. 498-518.
- [10] S. R. Cloude and E. Pottier, (1997), "An entropy based classification scheme for land applications of polarimetric SAR," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 35, pp. 68-78.
- [11] J.-S. Lee, M. R. Grunes, T. L. Ainsworth, L.-J. Du, D. L. Schuler, and S. R. Cloude, (1999), "Unsupervised classification using polarimetric decomposition and the complex Wishart classifier," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 37, pp. 2249-2258.
- [12] J.-S. Lee, M. R. Grunes, and E. Pottier, (2001), "Quantitative comparison of classification capability: fully polarimetric versus dual and single-polarization SAR," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 39, pp. 2343-2351.
- [13] C. Lardeux, P.-L. Frison, C. Tison, J.-C. Souyris, B. Stoll, B. Fruneau, et al., (2009), "Support vector machine for multifrequency SAR polarimetric data classification," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 47, pp. 4143-4152.
- [14] A. Lonnqvist, Y. Rauste, M. Molinier, and T. Hame, (2010), "Polarimetric SAR data in land cover mapping in boreal zone," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 48, pp. 3652-3662.
- [15] H. McNairn, J. Shang, X. Jiao, and C. Champagne, (2009), "The contribution of ALOS PALSAR multipolarization and polarimetric data to crop classification," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 47, pp. 3981-3992.
- [16] S. Cloude, (1986), "Group theory and polarisation algebra," *Optik*, vol. 75, pp. 26-36.
- [17] E. Krogager, (1990), "New decomposition of the radar target scattering matrix," *Electronics Letters*, vol. 26, pp. 1525-1527.
- [18] J. R. Huynen, "Phenomenological theory of radar targets," *Drukkerij Bronder-Offset NV*, 1970.
- [19] A. Freeman and S. L. Durden, (1998), "A three-component scattering model for polarimetric SAR data," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 36, pp. 963-973.
- [20] Y. Yamaguchi, T. Moriyama, M. Ishido, and H. Yamada, (2005), "Four-component scattering model for polarimetric SAR image decomposition," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 43, pp. 1699-1706.
- [21] J.-S. Lee, M. R. Grunes, and R. Kwok, (1994), "Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution," *International Journal of Remote Sensing*, vol. 15, pp. 2299-2311.
- [22] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," 1992, in *Proceedings of the fifth annual workshop on Computational learning theory*, pp. 144-152.
- [23] J. Benediktsson, P. H. Swain, and O. K. Ersoy, (1990), "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.
- [24] X. Niu and Y. Ban, (2013), "Multi-temporal RADARSAT-2 polarimetric SAR data for urban land-cover classification using an object-based support vector machine and a rule-based approach," *International Journal of Remote Sensing*, vol. 34, pp. 1-26.
- [25] D. Gleich, (2012), "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.
- [26] Y. Tarabalka, M. Fauvel, J. Chanussot, and J. A. Benediktsson, (2010), "SVM-and MRF-based method for accurate classification of hyperspectral images," *Geoscience and Remote Sensing Letters, IEEE*, vol. 7, pp. 736-740.
- [27] Y. Wu, K. Ji, W. Yu, and Y. Su, (2008), "Region-based classification of polarimetric SAR images using Wishart MRF," *Geoscience and Remote Sensing Letters, IEEE*, vol. 5, pp. 668-672.
- [28] Z. Wu and Q. Ouyang, "SVM-and MRF-based method for contextual classification of polarimetric SAR images," 2011, in *Remote Sensing, Environment and Transportation Engineering (RSETTE), 2011 International Conference on*, pp. 818-821.
- [29] A. Voisin, V. A. Krylov, G. Moser, S. B. Serpico, and J. Zerubia, (2013), "classification of very high resolution SAR images of urban areas using copulas and texture in a hierarchical Markov random field model,"

- [30] A. Dargahia, Y. Maghsoudib, and A. Abkarb, (2013), "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.
- [31] F. Bovolo and L. Bruzzone, "A context-sensitive technique based on support vector machines for image classification," in Pattern Recognition and Machine Intelligence, ed: Springer, 2005, pp. 260-265.
- [32] B. Zhang, S. Li, X. Jia, L. Gao, and M. Peng, (2011), "Adaptive Markov random field approach for classification of hyperspectral imagery," Geoscience and Remote Sensing Letters, IEEE, vol. 8, pp. 973-977.
- [33] C.-H. Li, B.-C. Kuo, C.-T. Lin, and C.-S. Huang, (2012), "A spatial-contextual support vector machine for remotely sensed image classification," Geoscience and Remote Sensing, IEEE Transactions on, vol. 50, pp. 784-799.
- [34] G. Moser and S. B. Serpico, (2013), "Combining support vector machines and markov random fields in an integrated framework for contextual image classification," Geoscience and Remote Sensing, IEEE Transactions on, vol. 51, pp. 2734-2752.
- [35] S. Quegan, T. Le Toan, J. J. Yu, F. Ribbes, and N. Floury, (2000), "Multitemporal ERS SAR analysis applied to forest mapping," Geoscience and Remote Sensing, IEEE Transactions on, vol. 38, pp. 741-753.
- [36] U. Wegmüller, A. Wiesmann, T. Strozzi, and C. Werner, "Forest mapping with multitemporal SAR," 2002, in Proceedings of ForestSAT'02 Conference, pp. 5-9.
- [37] C. Oliver and S. Quegan, (2004), Understanding synthetic aperture radar images: SciTech Publishing.
- [38] B. Scholkopf and A. Smola, "Learning with kernels," ed: MIT press Cambridge, 2002.
- [39] Y. Qian, M. Ye, and J. Zhou, (2013), "Hyperspectral image classification based on structured sparse logistic regression and three-dimensional wavelet texture features," Geoscience and Remote Sensing, IEEE Transactions on, vol. 51, pp. 2276-2291.
- [40] B. Scholkopf and A. J. Smola, (2001), Learning with kernels: support vector machines, regularization, optimization, and beyond: MIT press.
- [41] W.-M. Boerner, H. Mott, and E. Luneburg, "Polarimetry in remote sensing: Basic and applied concepts," 1997, in Geoscience and Remote Sensing, 1997. IGARSS'97. Remote Sensing-A Scientific Vision for Sustainable Development, 1997 IEEE International, pp. 1401-1403.
- [42] J.-S. Lee, K. W. Hoppel, S. A. Mango, and A. R. Miller, (1994), "Intensity and phase statistics of multilook polarimetric and interferometric SAR imagery," Geoscience and Remote Sensing, IEEE Transactions on, vol. 32, pp. 1017-1028.
- [43] S. Z. Li and S. Singh, (2009), Markov random field modeling in image analysis vol. 3: Springer.
- [44] S. Geman and D. Geman, (1984), "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images," Pattern Analysis and Machine Intelligence, IEEE Transactions on, pp. 721-741.
- [45] Q. Jackson and D. A. Landgrebe, (2002), "Adaptive Bayesian contextual classification based on Markov random fields," Geoscience and Remote Sensing, IEEE Transactions on, vol. 40, pp. 2454-2463.
- [46] A. H. Solberg, T. Taxt, and A. K. Jain, (1996), "A Markov random field model for classification of multisource satellite imagery," Geoscience and Remote Sensing, IEEE Transactions on, vol. 34, pp. 100-113.