

شناسایی نظارت نشده تغییرات مناطق جنگلی مبتنی بر تلفیق شاخص های تغییرات به روش موجک گسسته غیر کاهشی و بهبود میدان تصادفی زنجره مارکوف

امین محسنی فر^۱، علی محمدزاده^۲، آرمین مقیمی^{۳*}

^۱ دانشجوی کارشناسی ارشد سنجش از دور - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیر الدین

طوسی

an.mohsenifar18@gmail.com

^۲ دانشیار دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیر الدین طوسی

almoh2@gmail.com

^۳ دانشجوی دکتری فتوگرامتری - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیر الدین طوسی

moghimi.armin@gmail.com

(تاریخ دریافت فروردین ۱۳۹۹، تاریخ تصویب آبان ۱۳۹۹)

چکیده

پایش و شناسایی تغییرات یکی از مهم ترین پردازش ها در فتوگرامتری و سنجش از دور به شمار می آید که در آن تغییرات رخ داده در یک منطقه ی جغرافیایی در اثر گذر زمان مورد مطالعه و بررسی قرار می گیرد. جنگل ها از سرمایه های ملی هر کشوری محسوب می شوند که نقش مهمی در تعدیل آب و هوا، شکل گیری آب های زیرزمینی و جلوگیری از وقوع سیل و فرسایش خاک دارند. بنابراین شناسایی هرچه دقیق تر تغییرات در مناطق جنگلی، می تواند نقشی مهم و انکارناپذیر در راستای حفظ و مدیریت این مناطق ایفا کند. در این تحقیق یک روش نظارت نشده ی دقیق برای شناسایی تغییرات در مناطق جنگلی ارائه شده است. مناطق مورد مطالعه در این تحقیق، جنگل های کشورهای آمریکا و استرالیا است که در اثر آتش سوزی تخریب شده اند. در روش ارائه شده، ابتدا شاخص تغییرات نهایی از طریق تلفیق شاخص های تغییرات NDVI (D_N) و GNDVI (D_G) با روش تبدیل موجک گسسته ایجاد شد. سپس برای کاهش تغییرات نویزی از فیلتر پخش کننده استفاده شد. برای خوشه بندی اولیه شاخص تلفیقی از روش خوشه بندی k-means بهبود یافته و برای در نظر گرفتن اطلاعات همسایگی در روند خوشه بندی، از میدان تصادفی مارکوف (MRF) پس از اعمال دو مرحله بهبود در ساختار تابع انرژی آن استفاده شد. مقایسه ی روش پیشنهادی در دو حالت استفاده از مدل MRF مرسوم و نوع بهبود یافته آن، برتری مدل MRF بهبود یافته را به اندازه ی ۴۹٪ و ۶۱٪، به ترتیب در مجموعه داده ی اول و دوم نشان داد. همچنین روش پیشنهادی در مقایسه با روش های Otsu، PCA، kmeans و GAFCM-GMM-MRF دارای عملکرد بهتری بود، بطوریکه میزان خطای کل را در آن ها به طور میانگین به اندازه ۹۳٪ و ۳۱٪، به ترتیب در مجموعه داده اول و دوم کاهش داد. براساس نتایج بدست آمده می توان گفت، روش ارائه شده در این تحقیق پتانسیل بالایی برای شناسایی نظارت نشده ی تغییرات در مناطق جنگلی دارد.

واژگان کلیدی: شناسایی تغییرات جنگل، تبدیل موجک گسسته، فیلتر پخش کننده، k-means، اطلاعات همسایگی

* نویسنده رابط

۱- مقدمه

پایش تغییرات پوشش سطح و کاربری زمین یکی از مهمترین مسائل پیش روی محققان علم زمین است که در آن به تعیین و شناسایی تغییرات رخ داده در یک منطقه جغرافیایی در اثر گذر زمان پرداخته می‌شود [۱]. تغییرات کشف‌شده می‌تواند به عنوان یک منبع اطلاعاتی ارزشمند در زمینه‌هایی نظیر جنگل‌زدایی، ارزیابی خسارت، پایش بلایای طبیعی، توسعه‌ی شهری، برنامه‌ریزی و مدیریت اراضی و ... بکار رود. در این راستا، امروزه با پیشرفت‌های رخ داده در صنایع فضایی و پرتاب ماهواره‌های سنجنش از دور، استفاده از داده‌های سنجنش‌از دور به عنوان یک منبع اطلاعاتی مناسب و کارآمد برای آشکارسازی تغییرات زمین رواج یافته‌است. بطور کلی اصلی که در پشت پرده استفاده از این داده‌ها در آشکارسازی تغییرات وجود دارد، متاثر از تنوع قدرت تفکیک مکانی، طیفی، زمانی و رادیومتریکی آن‌ها است که باعث شده‌است تا متخصصان علوم زمین بتوانند حداکثر استفاده را از این داده‌ها داشته باشند [۲].

جنگل‌ها از سرمایه‌های ملی هر کشوری محسوب شده و نقش فراوان و مهمی در تعدیل آب‌وهوا، شکل‌گیری آب‌های زیرزمینی و جلوگیری از فرسایش خاک و وقوع سیلاب دارند. متأسفانه جنگل‌ها به دلایل مختلف در معرض تخریب و نابودی قرار دارند. پایش خودکار تغییرات جنگل با استفاده از روش آشکارسازی تغییرات در سنجنش‌از دور، می‌تواند گامی مهم در جهت حفظ و مدیریت اراضی جنگلی به‌شمار آید. شناسایی تغییرات جنگل‌ها معمولاً به دو روش نظارت‌شده و نظارت‌نشده صورت می‌گیرد. با توجه به این موضوع که روش‌های شناسایی تغییرات نظارت‌شده مستلزم جمع‌آوری نمونه‌های آموزشی زمینی برای انجام فرآیند طبقه‌بندی می‌باشند، استفاده از آن‌ها زمانبر و مستلزم صرف هزینه بسیار است [۲۶]. همچنین، شناسایی تغییرات در این روش‌ها، متاثر از تعداد و صحت نمونه‌های جمع‌آوری‌شده است [۳۶، ۱]. البته استفاده از روش‌های نظارت‌شده، منجر به تولید نقشه ماهیت تغییرات می‌شود که می‌توان از آن در راستای بررسی تغییرات کاربری اراضی استفاده کرد. در مقابل، در روش‌های نظارت‌نشده هدف تنها تفکیک تغییر از عدم تغییر، صرف نظر از ماهیت تغییر است [۳۶-۳۸]. در واقع، استفاده از روش‌های نظارت‌نشده شناسایی

تغییرات منجر به تولید نقشه باینری تغییرات (ماسک تغییرات) می‌شود. از این روش‌ها معمولاً در راستای شناسایی محدوده تغییرات، بدون در نظر گرفتن ماهیت تغییرات استفاده می‌شود. این روش‌ها به دلیل سهولت و سرعت بالای تولید نقشه تغییرات و همچنین عدم نیاز به نمونه‌های آموزشی، معمولاً بیشتر از روش‌های نظارت‌نشده مورد توجه قرار می‌گیرند [۳۶-۳۸]. از آنجا که در جنگل‌ها با انبوه درختان روبرو هستیم، معمولاً نوع تغییرات اتفاق افتاده از نوع تغییر کلاس جنگل به سایر کاربری‌ها می‌باشد. بنابراین روش‌های شناسایی تغییرات می‌توانند به صورت عمده در زمینه کشف محدوده تغییرات در جنگل‌ها به کار بروند. فرآیند شناسایی نظارت‌نشده تغییرات به ترتیب دارای سه مرحله‌ی کلی (الف) پیش‌پردازش هندسی و رادیومتریکی، (ب) تولید شاخص تغییرات و (ج) تولید نقشه باینری تغییرات است [۳۶، ۱]. چالش‌های مطرح در زمینه‌ی پیش‌پردازش شامل تصحیحات رادیومتریکی، اتمسفری، توپوگرافی، تصحیح هندسی و هم‌مرجع‌سازی تصاویر است. هم‌مرجع‌سازی دقیق تصاویر برای جلوگیری از بروز نتایجی نادرست از جمله خطای جابجایی تصاویر است که این خطا منجر به شناسایی تغییرات کاذب (غیر واقعی) خواهد شد [۳]. بنابراین برای داشتن دقت بسیار بالا در فرآیند آشکارسازی تغییرات، هم‌مرجع‌سازی تصاویر باید با دقت بسیار بالایی انجام پذیرد. تصحیح رادیومتریکی به منظور حذف خطاهای تاثیرگذار بر مقادیر روشنایی تصویر انجام می‌پذیرد. عواملی که باعث بروز خطای رادیومتریکی می‌شود عمدتاً شامل تغییر شرایط اتمسفری، تغییر زاویه تابشی خورشید، عدم کالیبراسیون سنجنده و همچنین تغییر زاویه‌ی میدان دید سنجنده می‌باشد. عدم تصحیح این خطا موجب ایجاد اثرات مصنوعی روی سطح تصویر و تصمیم‌گیری اشتباه راجع به تشخیص تغییرات می‌شود. در راستای حذف و کاهش این خطا معمولاً از روش‌های تصحیح رادیومتریکی نسبی استفاده می‌شود [۴۲].

تحقیقات متعددی در زمینه شناسایی نظارت‌نشده‌ی تغییرات انجام شده‌است که از میان آن‌ها تعداد کمی به طور تخصصی به شناسایی تغییرات جنگل پرداخته‌اند. در این مطالعه تمرکز اصلی بر روی روش‌های ارائه‌شده جهت شناسایی تغییرات در مناطق جنگلی معطوف می‌شود. Pantze و همکاران [۱۰] روشی نظارت‌نشده را در زمینه شناسایی تغییرات مناطق جنگلی با استفاده از داده‌های

SAR با طول موج L ارائه کرده‌اند. در این روش، تصحیح رادیومتریکی و خوشه‌بندی اولیه تغییرات به‌ترتیب با استفاده از تطبیق هیستوگرام تصاویر و حدآستانه‌گذاری خودکار انجام شد و سپس برای شناسایی دقیق‌تر تغییرات از روش میدان تصادفی مارکوف^۱ استفاده شد که در آن اطلاعات مکانی و طیفی پیکسل‌های همسایه نیز در نظر گرفته می‌شوند. در این روش نواحی تخریب‌شده با دقت بالایی شناسایی شده و اغلب خطاهای موجود در طبقه‌بندی اولیه حذف شدند. Nori و همکاران [۲۸] روش‌های مختلف شامل مقایسه‌ی تصاویر طبقه‌بندی‌شده، ایجاد شاخص تغییرات برای چندین شاخص گیاهی، PCA، CVA، MAD و TCA^۲ را برای شناسایی تغییرات در منطقه‌ی جنگلی مورد بررسی و مقایسه قرار داده‌اند. درنهایت روش مبتنی‌بر طبقه‌بندی و پس از آن خوشه‌بندی تصویر حاصل از روش MAD بیشترین دقت را در شناسایی تغییرات از خود نشان دادند. در این تحقیق تلفیق شاخص‌های گیاهی مورد ارزیابی قرار نگرفته و شاخص تغییرات برای هریک از آن‌ها به‌طور مجزا ایجاد شد. Hughes و همکاران [۲۹] یک روش ترکیبی شی‌مبنا را برای پایش تغییرات مناطق جنگلی با استفاده از سری زمانی تصاویر سنجنده‌ی Landsat ارائه کرده‌اند. در تحقیق مذکور از روش شی‌مبنای ارائه‌شده برای تشخیص نواحی تخریب‌شده، پایدار و در حال گسترش جنگل استفاده شد. به‌گونه‌ای که یک کامپوزیت سالانه از تصاویر جمع‌آوری شده و شاخص‌های گیاهی برای آن کامپوزیت محاسبه شد. سپس تصاویر شاخص‌های گیاهی از نظر مکانی به چندین قطعه و از نظر زمانی نیز، سری زمانی ایجادشده به چندین ناحیه‌ی شیب‌دار تقسیم شد. در آخر، قطعات مورد نظر به‌صورت تخریب‌شده، پایدار و رو به رشد برچسب‌دهی شدند. نتایج نشان دادند که روش دارای صحت کلی بالایی در شناسایی تغییرات جنگل است.

Zanetti و همکاران [۳۰] روشی مبتنی‌بر آنالیز بردار تغییرات انطباقی (ACVA) و چندمتغیره در شناسایی تخریب مناطق جنگلی کشور اندونزی، با استفاده از تصاویر چندزمانه Sentinel-2 را بکار بردند. در این روش تغییرات با در نظر گرفتن مدلسازی گوسی، ACVA و استفاده از

یک حد آستانه مناسب شناسایی گردیدند. نتایج نشان داد که روش فوق دقت بالایی را در شناسایی نواحی تخریب‌شده دارد. Fernandez و همکاران [۳۱] تغییرات رخ‌داده در یک منطقه‌ی جنگلی از کشور مکزیک را با استفاده از تلفیق سری زمانی تصاویر Landsat و الگوریتم VCT^۴ شناسایی کردند. روش پیشنهادی دقت کلی بالایی را در شناسایی تغییرات ارائه کرد. برای تحلیل تخریب‌های منطقه‌ی مورد نظر از داده‌های رسمی موسسه ملی آمار و جغرافیای مکزیک استفاده شد. نتایج این پژوهش ۳۴٪ از منطقه‌ی جنگلی را به‌عنوان نواحی تخریب‌شده با نرخ سالانه‌ی ۱٫۳٪ شناسایی کرد، در حالی که این مقادیر برای داده‌های مرجع به‌ترتیب برابر ۲۸٪ و ۱٪ بود. Wei و همکاران [۳۹] به منظور بهبود عملکرد روش‌های حدآستانه گذاری در شناسایی نظارت‌نشده تغییرات در مناطق مختلف، از الگوریتم میدان تصادفی مارکوف (MRF) استفاده کردند. آن‌ها به این نتیجه رسیدند که در صورت تلفیق نتایج حدآستانه گذاری و مدل MRF، به نتایج با ثبات‌تری در زمینه شناسایی تغییرات می‌رسند. Lu و همکاران [۴۰] به منظور پایش تغییرات ناشی از مخاطرات طبیعی، از روش مبتنی بر الگوریتم میدان تصادفی مارکوف استفاده کردند. آن‌ها از تصاویر ماهواره‌ای اخذشده توسط سنجنده FORMOSAT-2، Sentinel-2 و Landsat-8 مربوط به زمان قبل و بعد از مخاطرات طبیعی نظیر زلزله، طوفان و سیل استفاده کردند. آن‌ها به این نتیجه رسیدند که استفاده از شاخص تغییرات مبتنی بر اختلاف NDVI و مبتنی بر الگوریتم‌های کاهش ابعاد ویژگی نظیر PCA و ICA، دارای صحت بالاتری در مقایسه با استفاده از شاخص تغییرات CVA در روند شناسایی تغییرات با الگوریتم MRF می‌باشند.

اگرچه تحقیقات فوق نتایج ارزشمندی را در زمینه شناسایی تغییرات ارائه کرده‌اند، اما پاره‌ای از محدودیت‌ها در آن‌ها به چشم می‌خورد که عبارتند از: ۱- عدم ارائه روشی مقاوم به نویز در تولید شاخص تغییرات با اعتمادپذیری بالا و همچنین عدم در نظر گرفتن تنوع تغییرات با شدت‌های متفاوت که می‌تواند دقت شناسایی تغییرات را به طور قابل ملاحظه‌ای تحت تاثیر قرار دهد، ۲- عدم ارائه روشی که در حین استفاده از اطلاعات

^۱ Markov Random Field

^۲ Multivariate Alteration Detection

^۳ Tasseled Cap Analysis

^۴ Vegetation Change Tracker

مکانی، خصوصیات توپولوژیکی (همبندی) یا شکل هندسی محدوده تغییرات را حفظ کند و ۳- عدم در نظر گرفتن تعادل نسبی در نرخ شناسایی اشتباه^۱ و نرخ هشدار نادرست^۲ در روش‌های بکار رفته.

جهت غلبه بر محدودیت‌های فوق الذکر، در این مطالعه روشی نوین در جهت پایش تغییرات جنگل‌ها مبتنی بر تبدیل گسسته موجک بدون تلفات (UDWT)^۳ و بهبود الگوریتم میدان تصادفی مارکوف ارائه شده است. در این روش ابتدا شاخص‌های تغییرات مبتنی بر شاخص‌های گیاهی NDVI و GNDVI برای هر یک از تصاویر زمان اول و دوم محاسبه شدند. در قدم بعدی، برای بهره‌مندی از اطلاعات شاخص‌های گیاهی NDVI و GNDVI در قالب یک شاخص تغییرات و همچنین در نظر گرفتن تنوع تغییرات رخ داده شده، دو شاخص مذکور با روشی مبتنی بر تبدیل موجک گسسته غیر کاهشی بدون تلفات (UDWT) با یکدیگر ادغام شدند. سپس به منظور تولید نقشه باینری تغییرات اولیه، الگوریتم k-means بهبودیافته [۱۹] بر شاخص تغییرات تلفیقی اعمال شد. در نهایت برای بهینه‌سازی نقشه‌ی اولیه تغییرات با تاکید بر حفظ اطلاعات همسایگی و توپولوژیکی محدوده تغییرات، از الگوریتم میدان تصادفی مارکوف بهبودیافته در این تحقیق استفاده شد.

به طور کلی این مطالعه شامل چهار نوآوری می‌باشد که عبارتند از:

- ۱- بکارگیری روشی مبتنی بر UDWT در ادغام شاخص‌های اختلاف پوشش گیاهی به منظور تولید نقشه تغییرات با اطلاعات جامع‌تر و با اعتمادپذیری بالا.
- ۲- بهره‌گیری از الگوریتم k-means بهبودیافته [۱۹] برای تعیین مراکز اولیه بهینه‌ی خوشه‌ها و کاهش قابل توجه زمان خوشه‌بندی شاخص تغییرات.
- ۳- ایجاد تعادل نسبی میان نرخ شناسایی اشتباه و نرخ هشدار نادرست، از طریق بهبود تابع انرژی طیفی الگوریتم میدان تصادفی مارکوف با اضافه کردن ترم مبتنی بر شباهت طیفی کلاس‌های تغییر و غیر تغییر.
- ۴- حفظ خصوصیات توپولوژیکی محدوده تغییرات نظیر مرزها در روند بهینه‌سازی نقشه اولیه تغییرات، با توسعه روشی مبتنی بر محاسبه‌ی گرادیان شاخص تغییرات با فیلتر Scharr [۱۱].

ساختار این مقاله از چهار بخش تشکیل شده است. در بخش اول مقدمه و ضرورت انجام این مطالعه بررسی شد. در بخش دوم جزئیات روش پیشنهادی به همراه فلوچارت آن ارائه خواهد شد. در بخش سوم نتایج حاصل از پیاده‌سازی روش پیشنهادی مورد ارزیابی و بحث قرار خواهد گرفت. نهایتاً در بخش چهارم نتیجه‌گیری و پیشنهادات مربوط به این تحقیق بیان خواهد شد.

۲- روش پیشنهادی

روش ارائه شده در این تحقیق، یک روش ترکیبی بر مبنای تلفیق شاخص‌های تغییرات گیاهی و بهبود میدان تصادفی مارکوف است که هدف از آن، شناسایی نظارت‌نشده‌ی دقیق تغییرات در مناطق جنگلی است. این روش از دو گام اصلی تشکیل شده است که شامل ۱- تولید شاخص بهینه تغییرات پوشش گیاهی مبتنی بر تلفیق به روش موجک گسسته بدون تلفات و ۲- تولید نقشه تغییرات مبتنی بر استفاده از اطلاعات طیفی با حفظ مرز تغییرات است. شکل ۱ نمایی کلی از روش پیشنهادی در این تحقیق را نشان می‌دهد. در ادامه، جزئیات مراحل روش پیشنهادی شرح داده خواهد شد.

۲-۱- قدم اول: تولید شاخص بهینه تغییرات پوشش گیاهی

قدم اول روش پیشنهادی با هدف تولید شاخص بهینه تغییرات مرتبط با پوشش گیاهی انجام می‌شود. از آنجایی که بازتابش طیفی گیاهان سالم در طیف‌های الکترومغناطیس مختلف از نظر جذب و بازتاب شرایط کاملاً متفاوتی را نسبت به یکدیگر دارند، این تفاوت در باندهای مادون قرمز و مرئی بیشتر از سایر محدوده‌های طیف الکترومغناطیسی مشاهده می‌شود، جایی که بیشترین بازتابندگی در طول موج‌های مادون قرمز نزدیک و سبز و بیشترین جذب در طول موج‌های آبی و قرمز صورت می‌گیرد. بنابراین با ترکیب باندهای طیفی مذکور از طریق عملگرهای جبری می‌توان رفتار طیفی گیاهان را تحت عنوان شاخص‌های طیفی مدل کرد [۱۲].

^۱ Miss detection rate

^۲ False alarm rate

^۳ Undecimated Discrete Wavelet Transform

در مرحله نهایی، شاخص تغییرات بهینه مختص جنگل با استفاده از تبدیل موجک گسسته غیرکاهشی (UDWT) طی سه مرحله تولید می‌گردد. در مرحله اول، هر یک از تصاویر اختلاف به چهار زیرتصویر LL، LH، HL و HH که به آن‌ها ضرایب موجک^۳ گفته می‌شود، در K سطح تجزیه می‌شوند [۴۳، ۴۴]. LL زیرتصویر همگن و متناظر با تصویر با فرکانس پایین است و HL، LH و HH زیرتصاویر جزئیات هستند که فرکانس‌های بالا از شاخص‌های تغییرات ورودی را نشان می‌دهند.

$$D_N = \{D_N^1, D_N^2, \dots, D_N^K\} \\ = \{\{D_N^{1,LL}, D_N^{1,\omega}\}, \dots, \{D_N^{K,LL}, D_N^{K,\omega}\}\} \quad (5)$$


$$D_G = \{D_G^1, D_G^2, \dots, D_G^K\} \\ = \{\{D_G^{1,LL}, D_G^{1,\omega}\}, \dots, \{D_G^{K,LL}, D_G^{K,\omega}\}\} \quad (6)$$

در روابط فوق، ω بیانگر سه زیر تصویر جزئیات (LH، HL و HH) در هریک از سطوح تجزیه است. در گام بعدی در هر یک از سطوح، ضرایب موجک تولیدی با یکدیگر تلفیق می‌شوند. در این تحقیق جهت ادغام زیر تصاویرهای فرکانس پایین و بالا در هر یک از سطوح تجزیه، به ترتیب از روابط (۷) و (۸) استفاده شد.

$$D_F^{LL}(i, j) = \begin{cases} D_N^{LL}(i, j), & E_N < E_G \\ D_G^{LL}(i, j), & E_N \geq E_G \end{cases} \quad (7)$$

$$D_F^{\omega}(i, j) = \begin{cases} D_N^{\omega}(i, j), & P_N \geq P_G \\ D_G^{\omega}(i, j), & P_N < P_G \end{cases} \quad (8)$$

در روابط فوق، E_N و E_G میزان آنتروپی در یک همسایگی مکانی 3×3 حول پیکسلی با موقعیت مکانی (i, j) ، در هر یک از زیر تصاویر با فرکانس پایین از شاخص‌های تغییرات D_N و D_G می‌باشد. استفاده از معیار آنتروپی در این قاعده ادغام، به منظور بهره بردن از محتوای اطلاعاتی پیکسل‌های موجود در فرکانس پایین هستند. همچنین، P_N و P_G نسبت سیگنال به نویز در یک همسایگی مکانی 3×3 حول پیکسلی با موقعیت مکانی (i, j) در هر یک از زیر تصاویر با فرکانس بالا از شاخص‌های تغییرات D_N و D_G هستند. اتخاذ چنین رویکردی برای بهره‌بردن از فرکانس‌های بالا با کمترین



شکل ۱- نمایی کلی از روش پیشنهادی

در این راستا در این مطالعه، ابتدا شاخص گیاهی NDVI^۱ [۱۲] و شاخص GNDVI^۲ [۱۴] برای هر یک از تصاویر ورودی مطابق با روابط زیر محاسبه می‌شوند.

$$NDVI = \left(\frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \right) \quad (1)$$

$$GNDVI = \left(\frac{\rho_{NIR} - \rho_{Green}}{\rho_{NIR} + \rho_{Green}} \right) \quad (2)$$

در روابط فوق، ρ_{Red} ، ρ_{Green} و ρ_{NIR} به ترتیب مقادیر بازتاب طیفی در باندهای مادون قرمز نزدیک، سبز و قرمز می‌باشند. شاخص NDVI به خوبی فرم رویشی را با حداقل سازی اثرات سیگنال پس‌زمینه در نواحی پوشش گیاهی نشان می‌دهد [۱۲]. همچنین برتری شاخص GNDVI حساسیت بیشتر آن نسبت به محتوای کلروفیلی گیاه است [۱۴]. در مرحله بعدی، شاخص‌های تغییرات اولیه با اختلاف متناظر شاخص‌های طیفی مذکور به صورت زیر محاسبه می‌شوند:

$$D_N = NDVI_2 - NDVI_1 \quad (3)$$

$$D_G = GNDVI_2 - GNDVI_1 \quad (4)$$


که در آن‌ها $NDVI_1$ ، $GNDVI_1$ مقادیر شاخص‌ها در زمان اول و $NDVI_2$ ، $GNDVI_2$ مقادیر شاخص‌ها در زمان دوم است.

^۳ Wavelet Coefficients

^۱ Normalized Difference Vegetation Index

^۲ Green Normalized Difference Vegetation Index

میزان نویز است. در گام نهایی، شاخص بهینه تغییرات با تبدیل معکوس موجک گسسته غیرکاهشی (2D-IUDWT) تولید می‌شود. مراحل ادغام دو شاخص تغییرات با روش تبدیل موجک گسسته غیرکاهشی در یک سطح تجزیه در شکل ۲ نشان داده شده است [۱۷].



شکل ۲- روند تلفیق شاخص‌های اختلاف D_G و D_N

آنچه که در این تحقیق باعث شد تا از تبدیل UDWT به جای تبدیل DWT استفاده شود، خاصیت غیرکاهشی در مقادیر هر یک از شاخص‌های تغییرات ورودی است. در واقع، افزونگی داده‌ها از جمله خصوصیات تبدیل UDWT است که هیچ فرآیند بیش نمونه‌برداری در تصاویر ورودی رخ نمی‌دهد و اندازه تمامی زیرتصاویر در سطوح مختلف تجزیه با اندازه شاخص ورودی برابر است [۴۳].

۲-۲- قدم دوم: تولید نقشه تغییرات مبتنی بر بهبود میدان تصادفی مارکوف

این مرحله با هدف تولید نقشه باینری بهینه تغییرات با استفاده از اعمال مدل بهبودیافته میدان تصادفی مارکوف بر نقشه تغییرات اولیه صورت می‌گیرد. این روند خود از چند زیر مرحله تشکیل شده‌است که در ادامه به توضیح هر یک از آن‌ها پرداخته می‌شود.

ابتدا شاخص تغییرات تلفیقی تولیدشده در مرحله قبل با استفاده از یک عملگر نرم‌کننده، هموارسازی می‌شود. در این راستا از فیلتر پخش‌کننده که اولین بار توسط Perona و همکاران [۱۶] مطرح شد، استفاده گردید. علت استفاده از این اپراتور، نرم‌سازی نواحی موجود در شاخص تغییرات در یک فضای مقیاسی با حفظ مرزهای مرتبط با آن‌ها است. مبنای کار این فیلتر، معادله‌ی پخش‌کنندگی است که از رابطه (۹) بدست می‌آید:

$$D_{F_t} = \text{div}(c(i, j, t) \nabla D_F) \quad (9)$$

در رابطه فوق، $c(i, j, t)$ ضریب انتقال^۱ در مقیاس t ، (i, j) موقعیت مکانی پیکسل‌ها، ∇D_F گرادیان^۲ شاخص تلفیقی تغییرات و div عملگر دیورژانس است. با توجه به این‌که یک لبه به‌عنوان یک تابع کانالو شده با تابع گوسی مدل‌سازی می‌شود، می‌توان بدون از دست‌دادن کلیات فرض کرد که لبه در امتداد محور z قرار دارد. بنابراین عبارت مربوط به عملگر دیورژانس در رابطه‌ی (۹)، به شکل رابطه‌ی (۱۰) بازنویسی می‌شود.

$$\text{div}(c(i, j, t) \nabla I) = \frac{\partial}{\partial x} (c(i, j, t) D_{Fi}) \quad (10)$$

$$c(i, j, t) = g(D_{Fi}(i, j, t)) \quad (11)$$

در روابط فوق، I_i گرادیان تصویر در راستای i است. در نهایت معادله‌ی پخش‌کنندگی در حالت یک‌بعدی به شکل رابطه‌ی زیر محاسبه می‌شود:

$$D_{F_t} = \frac{\partial}{\partial i} \Phi(D_{Fi}) = \Phi(D_{Fi}) \cdot D_{F_{ii}} \quad (12)$$

در رابطه فوق، $D_{F_{ii}}$ مشتق دوم شاخص تغییرات تلفیقی در جهت i است و Φ بیانگر شار گرادیان است که از رابطه زیر بدست می‌آید:

$$\Phi(D_{Fi}) \doteq g(D_{Fi}) \cdot D_{Fi} \quad (13)$$

بطوریکه

$$g(D_{Fi}) = \frac{C}{\left(1 + \left(\frac{D_{Fi}}{K}\right)^{1+\alpha}\right)}; \alpha > 0 \quad (14)$$

که در آن K مقداری ثابت است و به عنوان حدآستانه‌ی شار و معیار تصمیم‌گیری فیلتر برای حذف نویز و حفظ لبه‌های شاخص تغییرات تلفیقی انتخاب می‌شود. عدد C نیز ثابتی دلخواه است. برای مطالعه بیشتر در این زمینه، به تحقیق [۱۶] مراجعه گردد. دلیل استفاده از این فیلتر در این تحقیق، این است که علاوه بر حذف نویز و نرم‌سازی شاخص تغییرات تلفیقی تولیدشده، اطلاعات مربوط به لبه‌های تصویر حفظ شده و فرآیند شناسایی لبه‌های شاخص تغییرات با فیلتر Scharr [۱۱]، برای معرفی به میدان تصادفی مارکوف به بهترین شکل انجام گیرد.

^۱ Conduction coefficient
^۲ Gradient

واریانس را در میان نواحی موجود داشته باشد، به عنوان متنوع ترین بخش از تصویر انتخاب می گردد تا هم شامل هر دو خوشه ی تغییر و عدم تغییر باشد و هم مبنای محاسبه ی مراکز اولیه ی خوشه ها قرار گیرد. بنابراین می توان مراحل توسعه الگوریتم [۱۹] را در این مطالعه مطابق با جدول ۲ بازنویسی کرد.

جدول ۲- مراحل خوشه بندی با الگوریتم k-means بهبود یافته [۱۹]

گام	شرح عملیات
۱	محاسبه ی مراکز اولیه ی خوشه ها با الگوریتم ارائه شده در جدول ۱.
آغاز تکرار	
۲	محاسبه ی فاصله ی هر پیکسل از مراکز خوشه ها و انتقال آن به خوشه ای که کمترین فاصله (d_i) را با مرکز آن خوشه دارد ($1 < i < n$).
۴	مقایسه ی فاصله ی هر پیکسل از مرکز جدید خوشه ی خود با فاصله ی قبلی آن (d_i) و تغییر خوشه ی پیکسل (تعلق به نزدیکترین خوشه) در صورتی که فاصله ی جدید بیشتر از d_i باشد.
۵	بهبود مرکز هر خوشه با میانگین گیری از پیکسل های تعلق یافته به آن.
۶	محاسبه ی مجدد مراکز خوشه ها پس از جابجایی پیکسل ها در مرحله ی ۴ [۱۹].
پایان تکرار	
۷	تکرار مراحل ۱ تا ۵، تا زمانی که شرط توقف برآورده شود.

در آشکارسازی تغییرات با استفاده از روش های خوشه بندی که از جمله روش های پیکسل مبنا به شمار می آیند، اطلاعات همسایگی (بافت مکانی)^۱ پیکسل ها در نظر گرفته نمی شود [۱]. در این تحقیق برای رفع این نقص از میدان تصادفی مارکوف جهت تولید نقشه باینری تغییرات استفاده شده است. میدان تصادفی مارکوف یک مدل احتمالاتی است که اطلاعات همسایگی پیکسل ها را در روند بهبود برچسب دهی بکار می گیرد [۲۰]. در این تحقیق، عملکرد میدان تصادفی مارکوف بطور کلی در دو مرحله بهبود یافت. در مرحله ی اول یک معیار شباهت مبتنی بر میانگین خوشه ها، برای بهبود عملکرد الگوریتم به ساختار آن افزوده شد. علاوه بر این، از آنجایی که میدان تصادفی مارکوف روند بهینه سازی طبقه بندی تصویر را بدون حفظ لبه های موجود در تصویر انجام می دهد، در مرحله ی دوم لبه های موجود در تصویر اختلاف شناسایی شده و روند بهینه سازی بر اساس اطلاعات مرزها انجام می گیرد. در ادامه

در مرحله بعد، شاخص تغییرات تلفیقی نرم شده D_{F_t} با استفاده از الگوریتم خوشه بندی k-means بهبود یافته [۱۹] به دو دسته تغییر و غیر تغییر تقسیم می شود. تعیین مراکز اولیه و همچنین زمان بر بودن خوشه بندی، از جمله چالش هایی است که الگوریتم k-means مرسوم با آن ها مواجه است. در این تحقیق برای تعیین مراکز اولیه از الگوریتم بهینه ی ارائه شده در [۱۹] استفاده گردید تا فرآیند تولید نقشه باینری تغییرات اولیه با استفاده از الگوریتم خوشه بندی k-means بهبود یافته با سرعت بیشتری انجام پذیرد. مراحل محاسبه مراکز اولیه بهینه برای هریک از خوشه ها در تحقیق [۱۹] مطابق با جدول ۱ است.

جدول ۱- مراحل محاسبه مراکز اولیه خوشه ها [۱۹]

گام	شرح عملیات
۱	در نظر گرفتن مجموعه های Am ($1 < m < c$) که c بیانگر تعداد خوشه های معرفی شده از کاربر است (در اینجا با توجه به ماهیت مسئله برابر با دو (تغییر/ غیر تغییر) است).
۲	محاسبه ی فاصله ی هر پیکسل (d_i) از سایر پیکسل ها و یافتن دو پیکسل که کمترین فاصله را از یکدیگر داشته باشند؛ $1 < i < n$ (n تعداد کل پیکسل ها در D_{F_t} است).
۳	انتقال پیکسل های حاصل از مرحله ی ۲ به خوشه ی Am و حذف آن ها از D_{F_t} .
۴	محاسبه ی فاصله ی مابقی پیکسل های تصویر از مجموعه ی Am ، انتقال نزدیکترین پیکسل به آن و حذف پیکسل انتقال یافته از D_{F_t} .
۵	تکرار مرحله ی ۴ تا زمانی که تعداد پیکسل های باقیمانده در D_{F_t} به $D_{F_t} = 0.75 * (n/k)$ برسد.
۶	محاسبه ی میانگین پیکسل های موجود در مجموعه ی Am و در نظر گرفتن آن به عنوان مرکز خوشه ی Am .

بر اساس مراحل ذکر شده، پیکسل هایی که از نظر طیفی شبیه یکدیگر هستند، در یک خوشه ی خاص قرار می گیرند. سپس مرکز آن خوشه محاسبه شده و به الگوریتم k-means بهبود یافته [۱۹] معرفی می شود. اما مشکلی که در الگوریتم جدول ۱ وجود دارد، افزایش حجم و زمان محاسبات در محاسبه ی فاصله ی هر پیکسل از بقیه ی پیکسل ها (گام ۲)، بویژه در تصاویری با ابعاد بزرگ است. برای حل این مشکل، یک آنالیز محلی در این مطالعه پیشنهاد شد. در این آنالیز، ابتدا پنجره ای با ابعاد 101×101 در نظر گرفته شده و بر روی شاخص تغییرات D_{F_t} حرکت داده می شود. سپس، مقدار واریانس برای هر ناحیه از تصویر محاسبه شده و ناحیه ای که بیشترین

^۱ Contextual information

جزئیات مربوط به الگوریتم میدان تصادفی مارکوف و بهبود اعمال‌شده بر روی آن شرح داده خواهد شد.

۲-۲-۱- بهبود ساختار تابع انرژی طیفی میدان تصادفی مارکوف

در صورتی که شاخص تغییرات تلفیقی و مجموعه برچسب‌های مربوط به آن، به ترتیب به صورت مجموعه‌های $D_{F_t} = \{d_1, d_2, d_3, \dots, d_n\}$ (بیانگر تعداد پیکسل‌ها) و $L = \{l_1, l_2\}$ (تغییر/غیر تغییر) در نظر گرفته شوند، برای تولید برچسب‌های جدید از روش MAP^۱ مطابق با رابطه (۱۵) استفاده می‌شود که در آن $P(L)$ و $p(d|L)$ به ترتیب احتمال اولیه‌ی برچسب‌ها و تابع چگالی احتمال پیکسل‌ها در تصویر اختلاف هستند [۲۰].

$$L = \arg \max \{P(L)p(d|L)\} \quad (۱۵)$$

بیشینه‌سازی مقدار احتمال ثانویه در رابطه‌ی (۱۵)، معادل با کمینه‌سازی تابع انرژی کلی است که مطابق با رابطه‌ی زیر بیان می‌شود.

$$U_{MRF}(d_i) = U_{Spectral}(d_i) + U_{Spatial}(d_i) \quad (۱۶)$$

در این رابطه، $U_{Spectral}$ تابع انرژی طیفی و $U_{Spatial}$ تابع انرژی مکانی است که به ترتیب مطابق با روابط زیر محاسبه می‌شوند [۲۰].

$$U_{Spectral}(d_i) = \frac{1}{2} (\ln |2\pi\sigma_k^2|) + \frac{1}{2} (d_i - \mu_k)^2 (\sigma_k^2)^{-1} \quad (۱۷)$$

$$U_{Spatial}(d_i) = \beta \sum_{j \in N_i} I(l(d_i), l(d_j)) \quad (۱۸)$$

در روابط فوق، μ_k و σ_k^2 به ترتیب واریانس و میانگین کلاس k است. در رابطه‌ی (۱۸)، ضریب β مقداری ثابت و مثبت است که اثر همسایگی‌های پیکسل i (N_i) را کنترل می‌کند. همچنین، $l(d_i)$ و $l(d_j)$ به ترتیب بیانگر برچسب پیکسل موردنظر (i) و برچسب پیکسل همسایه‌ی آن (j) است [۲۰] و [۲۱]. تابع I نیز که از آن با عنوان مدل Potts در میدان تصادفی مارکوف یاد می‌شود، برچسب کلاس را با استفاده از یک احتمال اولیه بیان می‌کند [۲۱].

$$I(l(d_i), l(d_j)) = \begin{cases} -1 & l(d_i) = l(d_j) \\ 0 & l(d_i) \neq l(d_j) \end{cases} \quad (۱۹)$$

در این تحقیق از روش ICM^۲ [۲۲] برای حداقل‌سازی و حل معادله‌ی (۱۶) استفاده شد. همچنین برای بهبود عملکرد میدان تصادفی مارکوف، یک معیار شباهت مبتنی بر میانگین که رفتاری مشابه با معیار فاصله‌ی مالهالانوبیس نیز دارد به عنوان یک ترم جدید به ساختار تابع انرژی طیفی اضافه می‌شود که از رابطه زیر محاسبه می‌شود.

$$S(d_i) = \left| 1 - \frac{d_i}{\mu_k} \right| \quad (۲۰)$$

این معیار، مشابه با معیار فاصله‌ی مالهالانوبیس ارتباط عکس با میزان شباهت دارد. بنابراین رابطه‌ی (۱۷) به صورت رابطه زیر بازنویسی می‌شود:

$$U_{Spectral}(d_i) = \frac{1}{2} (\ln |2\pi\sigma_k^2|) + \frac{1}{2} (d_i - \mu_k)^2 (\sigma_k^2)^{-1} + S(d_i) \quad (۲۱)$$

۲-۲-۲- معرفی مرزهای تغییرات به میدان تصادفی مارکوف

همان‌طور که پیش‌تر نیز اشاره شد، میدان تصادفی مارکوف روند برچسب‌دهی جدید به تصویر اختلاف را بدون در نظر گرفتن مرزهای تغییرات انجام می‌دهد. در این بخش، محل مرزها استخراج شده و به میدان تصادفی مارکوف معرفی می‌شود. در این راستا جهت استخراج مرز-های تغییرات از فیلتر Scharr [۱۱] استفاده شد که به صورت زیر نشان داده می‌شود:

$$F_i = \begin{bmatrix} 3 & 0 & -3 \\ 10 & 0 & -10 \\ 3 & 0 & -3 \end{bmatrix}, F_j = F_i^T \quad (۲۲)$$


در رابطه فوق، F_i و F_j به ترتیب مولفه‌های i و j این فیلتر هستند. پس از محاسبه‌ی اندازه‌ی گرادیان برای تنظیم عملکرد میدان تصادفی مارکوف در مرزهای تغییرات، مقدار پارامتر β به عنوان تابعی از اندازه‌ی گرادیان تعریف می‌شود [۲۴]، به گونه‌ای که این پارامتر در مرزهای ضعیف مقداری کم در نظر گرفته می‌شود تا میدان تصادفی مارکوف با آزادی عمل بیشتری پیکسل‌های همسایه را در روند بهبود برچسب‌دهی هر پیکسل وارد کند. از طرفی در نقاطی از تصویر که اندازه‌ی گرادیان در آن‌ها زیاد بوده و یک مرز قوی را تشکیل

^۲ Iteration Condition Model

^۱ Maximum a Posteriori

۳-۲- داده‌ها و معیارهای ارزیابی

جهت ارزیابی عملکرد روش پیشنهادی در آشکارسازی تغییرات مربوط به مناطق جنگلی، دو مجموعه داده‌ی دو زمانه از دو جنگل در کشور آمریکا، ایالت تگزاس و کشور استرالیا، ایالت نیو ساوت ولز در نظر گرفته شد که در اثر آتش‌سوزی و بروز خشکسالی تخریب شده‌اند. محدوده مورد مطالعه در شکل ۳ نشان داده شده‌است.



شکل ۳- موقعیت مناطق مورد مطالعه، الف) ایالت تگزاس، منطقه شهر بسترپ، ب) ایالت نیو ساوت ولز، کانبرا

مجموعه داده‌ی اول شامل تصاویر ماهواره‌ای اخذ شده بوسیله سنجنده Landsat 5 است که در دو زمان مختلف از پارک جنگلی بسترپ، واقع در ایالت تگزاس از کشور آمریکا گرفته شده است (شکل ۴ الف-ب)). در تاریخ ۴ سپتامبر از سال ۲۰۱۱ میلادی آتش‌سوزی مهیبی در پارک جنگلی بسترپ رخ داد که در تاریخ ایالت تگزاس بی‌سابقه بود [۴۱]. گفتنی است که مجموعه داده اول به همراه نقشه مرجع تغییرات، در مطالعه [۴۱] مورد استفاده قرار گرفته‌است و با مکاتبه مستقیم، از نویسنده اول آن تحقیق دریافت شد. مجموعه داده دوم شامل تصاویر ماهواره‌ای سنجنده Sentinel 2A/B است که از پارک ملی کازیسکو واقع در غرب شهر کانبرا در ایالت نیو ساوت ولز از کشور استرالیا گرفته شده‌است (شکل ۴ د-ه)). پارک ملی کازیسکو مساحتی حدود ۶۹۰۰ کیلومتر مربع را در بر می‌گیرد که کوه کازیسکو-بلندترین قله استرالیا- در آن واقع است. بنابر دلایلی چون برخورد صاعقه، آتش افروزی عمدی، گرما و خشکسالی بی‌سابقه و تغییرات اقلیمی، آتش‌سوزی گسترده‌ای در پارک ملی کازیسکو و سایر مناطق جنگلی استرالیا رخ داد که از اکتبر سال ۲۰۱۹

می‌دهند، پارامتر β مقداری بزرگ را اختیار می‌کند تا اثر پیکسل‌های همسایه در برجسب‌دهی هر پیکسل کاهش یابد. در این مطالعه برای تقسیم‌بندی لبه‌های شاخص تغییرات D_{F_t} به سه دسته‌ی مرزهای ضعیف، متوسط و قوی از روش حدآستانه‌گذاری دوگانه [۲۵] استفاده می‌شود. در این روش، در گام اول میانگین شاخص D_{F_t} به عنوان یک حدآستانه‌ی اصلی اولیه انتخاب می‌شود. سپس D_{F_t} به دو بخش براساس حدآستانه‌ی اولیه تقسیم می‌شود و برای هر بخش نیز یک حدآستانه با استفاده از میانگین آن بخش محاسبه می‌شود. در نهایت، مقدار حدآستانه‌ی اصلی با میانگین‌گیری از دو حدآستانه‌ی محاسبه شده بهینه می‌شود. این روند تا زمانی تکرار می‌یابد که مقدار حدآستانه‌ی اصلی (T_m) به یک وضعیت پایدار برسد. بنابراین با الهام گرفتن از تحقیق [۲۴]، مدل‌سازی پارامتر β در لبه‌های مختلف از شاخص تغییرات، مطابق با رابطه (۲۳) محاسبه می‌گردد.

$$\beta = \begin{cases} \beta_d & \rho < T_d \\ A\rho + B & T_d < \rho < T_u \\ \beta_u & \rho > T_u \end{cases} \quad (23)$$

که در آن T_d و T_u حدآستانه‌های پایین و بالای گرادیان تصویر، ρ مقدار گرادیان هر پیکسل از شاخص تغییرات، β_d مقدار پارامتر β برای پیکسل‌های واقع در مرزهای ضعیف، β_u مقدار β برای پیکسل‌های قرار گرفته بر روی مرزهای قوی و $A\rho + B$ مقدار β در مرزهای متوسط است که رابطه‌ای خطی با مقدار گرادیان شاخص تغییرات دارد. بطوری که مقدار β در این مرزها مقداری متغیر بین مقدار آن در مرزهای ضعیف و قوی خواهد بود. ثابت‌های A و B نیز مطابق با روابط زیر بدست می‌آیند [۲۴].

$$A = \frac{\beta_u - \beta_d}{T_u - T_d} \quad (24)$$

$$B = \frac{\beta_d T_u - \beta_u T_d}{T_u - T_d} \quad (25)$$


بنابراین می‌توان گفت میدان تصادفی مارکوف در این حالت، اثر همسایگی برای هر پیکسل را متناسب با مقدار گرادیان در آن نقطه کنترل می‌کند. بنابراین با استفاده از مدل MRF بهبود داده شده در این تحقیق، انتظار می‌رود که خصوصیات توپولوژی محدوده تغییرات به خوبی حفظ شود و از اطلاعات مکانی اطراف پیکسل‌ها در بستری مناسب استفاده گردد.

میلادی به مدت چندین ماه به طول انجامید و منجر به خسارت‌های جانی و مالی بسیاری برای کشور استرالیا شد. این داده‌ها پیش از استفاده، با دقت زیر پیکسل نسبت به یکدیگر ثبت هندسی شدند. همچنین اعوجاجات رادیومتریکی تصویر زمان دوم، با استفاده از روش ارائه‌شده در مطالعه [۴۲] نسبت به تصویر اول کاهش یافت. برای تولید ترکیب رنگی کاذب تصاویر در شکل ۴ از سه باند آبی، سبز و مادون قرمز نزدیک استفاده شد. مشخصات داده‌های مورد استفاده در این تحقیق در جدول ۳ بیان شده‌است.

جدول ۳- مشخصات داده‌های مورد استفاده

ردیف	مکان	زمان تصویر		سنجنده	ابعاد تصویر (پیکسل)
		اول	دوم		
۱	آمریکا	۲۰۱۱/۸/۲۶	۲۰۱۱/۹/۱۱	Landsat 5	۱۵۳۴×۸۰۸
۲	استرالیا	۲۰۱۹/۳/۱۱	۲۰۲۰/۳/۱۳	Sentinel 2	۲۰۰۰×۲۰۰۰

در این تحقیق جهت ارزیابی کمی نتایج حاصل از آشکارسازی نظارت‌نشده تغییرات، از سه معیار نرخ هشدار نادرست، نرخ شناسایی اشتباه و نرخ خطای کلی استفاده شد.



شکل ۴- ترکیب رنگی کاذب از مجموعه داده‌های مورد استفاده.

مجموعه داده اول، (الف-ج)، تصویر زمان اول از سنجنده Landsat 5، (ب) تصویر زمان دوم از سنجنده Landsat 5، (ج) نقشه مرجع [۴۱]، مجموعه داده دوم، (د-و)، (د) تصویر زمان اول از سنجنده Sentinel 2، (ه) تصویر زمان دوم از سنجنده Sentinel 2، (و) نقشه مرجع

معیار هشدار نادرست^۱ (FA) بیانگر تعداد پیکسل‌های عدم تغییر در نقشه مرجع است که به اشتباه به عنوان

پیکسل‌های تغییر انتخاب گردیده‌اند. نرخ هشدار نادرست (P_{FA}) نیز به درصد از رابطه $P_{FA} = (FA/N_1) \times 100\%$ بدست می‌آید، بطوریکه N_1 بیانگر تعداد پیکسل‌های تغییر نکرده در نقشه مرجع است. علاوه بر این، معیار شناسایی اشتباه^۲ (MD) برابر تعداد پیکسل‌های تغییر در نقشه مرجع است که به اشتباه به عنوان پیکسل‌های عدم تغییر انتخاب گردیده‌اند. نرخ هشدار اشتباه (P_{MA}) نیز به درصد از رابطه $P_{MA} = (MA/N_0) \times 100\%$ بدست می‌آید، بطوریکه N_0 در آن بیانگر تعداد پیکسل‌های تغییر یافته در نقشه مرجع می‌باشد. خطای کل^۳ (OE) بیانگر مجموع پیکسل‌هایی است که به اشتباه تغییر یافته و تغییر نیافته تشخیص داده شده‌اند. همچنین نرخ خطای کلی در روند شناسایی نظارت‌نشده تغییرات (P_{OE}) به درصد از رابطه $P_{MA} = (FA + MA/N_0 + N1) \times 100\%$ بدست می‌آید. علاوه بر این، از معیار نمودار ROC^۴ نیز برای ارزیابی بصری الگوریتم‌های میدان تصادفی مارکوف مرسوم و بهبود یافته استفاده شد. نمودار ROC برای ارزیابی عملکرد الگوریتم مورد استفاده در کاربردهایی نظیر شناسایی هدف و شناسایی نظارت‌نشده تغییرات مورد استفاده قرار می‌گیرد. هرچه سطح زیر منحنی ROC برای یک الگوریتم بیشتر باشد، دقت آن الگوریتم بیشتر خواهد بود.

۳- پیاده‌سازی و ارزیابی

در این بخش نتایج حاصل از پیاده‌سازی روش پیشنهادی در سه بخش ارائه می‌شود. در گام اول به ارزیابی شاخص تغییرات پیشنهادی در این تحقیق پرداخته می‌شود. در گام دوم، روش پیشنهادی در دو حالت از نظر نحوه‌ی بکارگیری میدان تصادفی مارکوف مورد ارزیابی و بحث قرار می‌گیرد. در گام آخر، مقایسه‌ی روش پیشنهادی با سایر روش‌های شناسایی نظارت‌نشده‌ی تغییرات انجام می‌گیرد.

۳-۱- ارزیابی نتایج حاصل از تولید شاخص تغییرات پیشنهادی

در این بخش در گام اول، شاخص تغییرات تلفیق‌شده پیشنهادی به روش UDWT با هریک از شاخص‌های اختلاف

^۲ Miss Detection


^۳ Overall Error

^۴ Receiver Operating Characteristic

^۱ False Alarm

دقت خوشه‌بندی اولیه بیشتر باشد، روند بهینه‌سازی برچسب‌های خوشه‌بندی اولیه توسط میدان تصادفی مارکوف نیز با دقت بیشتری صورت خواهد گرفت. با توجه به جدول ۴، مقدار نرخ شناسایی اشتباه در مجموعه داده‌ی اول برای شاخص‌های اختلاف D_N ، D_G و D_F به ترتیب برابر ۳۰،۶۲، ۲۱،۴۱ و ۱۷،۹۳ است. نرخ هشدار نادرست برای شاخص‌های نام‌برده به ترتیب برابر ۰،۰۸، ۰،۰۹ و ۰،۰۶ بدست آمد. معیار نرخ خطای کلی نیز برای این شاخص‌ها به ترتیب برابر با ۳،۳۳، ۲،۳۶ و ۱،۹۶ است.

در مجموعه داده‌ی دوم نیز با ملاک قرار دادن نتایج الگوریتم kmeans بهبودیافته، معیار نرخ شناسایی اشتباه برای شاخص‌های اختلاف D_N ، D_G و D_F به ترتیب برابر با ۲۹،۸۸، ۲۰،۲ و ۱۲،۸۹ حاصل شد. برای شاخص‌های نام‌برده معیار نرخ هشدار نادرست، به ترتیب برابر با ۰،۳۳، ۱،۴۶ و ۰،۰۸ و معیار نرخ خطای کلی نیز برابر با ۱۰،۸۳، ۸،۱۲ و ۴،۶۳ بدست آمد.



شکل ۵- نتایج خوشه‌بندی شاخص‌های تغییرات تولیدشده از مجموعه داده اول، الف) نقشه مرجع [۴۱]، ب) D_F ، ج) D_G ، د) D_N

با توجه به این‌که نتایج دو الگوریتم خوشه‌بندی kmeans و نسخه‌ی بهبودیافته‌ی آن در مجموعه داده‌ی اول یکسان است، نقشه‌ی باینری تغییرات حاصل از خوشه‌بندی سه شاخص تغییرات با بکارگیری الگوریتم kmeans بهبودیافته [۱۹] در شکل ۵ آورده شده است.

NDVI و GNDVI مورد مقایسه و ارزیابی قرار می‌گیرد. نتایج حاصل از این ارزیابی برای هر یک از مجموعه داده‌های مورد استفاده در جدول ۴ آورده شده است.

باتوجه به جدول ۴، با مقایسه‌ی عملکرد دو الگوریتم خوشه‌بندی بکارگرفته شده می‌توان گفت در مجموعه داده‌ی اول هر دو الگوریتم عملکرد یکسانی دارند اما در مجموعه داده‌ی دوم الگوریتم k-means بهبودیافته [۱۹]، در معیارهای نرخ شناسایی اشتباه و نرخ خطای کلی برتری اندکی نسبت به الگوریتم k-means دارد. به عبارتی دیگر می‌توان گفت در الگوریتم بهبودیافته تغییرات کمتری نسبت به الگوریتم مورد مقایسه از دست رفته‌اند. دلیل این برتری را می‌توان محاسبه‌ی مراکز اولیه و ساختار متفاوت الگوریتم بهبودیافته دانست. از نظر زمان خوشه‌بندی نیز الگوریتم بهبودیافته به‌طور میانگین ۴ و ۱۱ ثانیه به ترتیب در مجموعه داده‌های اول و دوم، نسبت به الگوریتم مورد مقایسه برتری دارد.

جدول ۴- نتایج خوشه‌بندی شاخص‌های اختلاف متفاوت

داده	الگوریتم خوشه‌بندی	شاخص تغییرات	شناسایی اشتباه	نرخ شناسایی اشتباه	هشدار نادرست	نرخ هشدار نادرست	نرخ خطای کلی	زمان (ثانیه)
مجموعه داده اول	k-means	D_N	۴۰۳۷۵	۳۰،۶۲	۹۱۶	۰،۰۸	۳،۳۳	۱۷،۳
		D_G	۲۸۲۳۰	۲۱،۴۱	۱۰۲۳	۰،۰۹	۲،۳۶	۱۷،۴
		D_F	۲۳۶۴۰	۱۷،۹۳	۶۹۱	۰،۰۶	۱،۹۶	۱۷،۱
	Ik-means	D_N	۴۰۳۷۵	۳۰،۶۲	۹۱۶	۰،۰۸	۳،۳۳	۱۳،۱
		D_G	۲۸۲۳۰	۲۱،۴۱	۱۰۲۳	۰،۰۹	۲،۳۶	۱۲،۸
		D_F	۲۳۶۴۰	۱۷،۹۳	۶۹۱	۰،۰۶	۱،۹۶	۱۳،۶
مجموعه داده دوم	k-means	D_N	۴۲۶۲۰۳	۲۹،۹۷	۸۲،۹۲	۰،۳۲	۱۰،۸۶	۶۳،۷
		D_G	۲۸۷۶۵۱	۲۰،۲۳	۳۷۵۸۶	۱،۴۶	۸،۱۳	۶۱،۴
		D_F	۱۸۳۵۵۹	۱۲،۹۱	۲۰۸۱	۰،۰۸	۴،۶۴	۶۲،۵
	Ik-means	D_N	۴۲۴۸۱۲	۲۹،۸۸	۸۳۸۳	۰،۳۳	۱۰،۸۳	۵۳،۳
		D_G	۲۸۷۲۷۱	۲۰،۲	۳۷۷۰۸	۱،۴۶	۸،۱۲	۴۹،۹
		D_F	۱۸۳۳۱۳	۱۲،۸۹	۲۰۸۶	۰،۰۸	۴،۶۳	۴۸،۶

برای بهره‌مندی از اطلاعات باندهای قرمز و سبز به‌صورت توأم، شاخص‌های اختلاف D_N و D_G با استفاده از روش تبدیل موجک گسسته با یکدیگر تلفیق شدند. هدف از این تلفیق دستیابی به یک شاخص تغییرات دقیق‌تر است؛ زیرا هرچقدر دقت شاخص تغییرات و به تبع آن


۳-۲- ارزیابی توسعه میدان تصادفی مارکوف

در این بخش الگوریتم پیشنهادی در دو حالت از نظر استفاده از مدل مرسوم و بهبودیافته‌ی میدان تصادفی مارکوف مورد مقایسه و ارزیابی قرار می‌گیرد. برای اختصار در بیان نتایج از مخفف لاتین میدان تصادفی مارکوف (MRF) در ادامه استفاده می‌شود. با توجه به جدول ۵، در مورد مجموعه داده‌ی اول می‌توان گفت نرخ شناسایی اشتباه، نرخ هشدار نادرست و نرخ خطای کلی در حالت استفاده از MRF مرسوم به ترتیب برابر با ۱،۰۷، ۱،۹۹ و ۱،۸۹ بدست آمدند. در حالت دوم که از الگوریتم MRF بهبودیافته برای بهینه‌سازی برچسب‌دهی اولیه استفاده شد، مقدار نرخ شناسایی اشتباه به ۱،۴ افزایش و نرخ هشدار نادرست به ۱،۳۹ کاهش یافت. همچنین نرخ خطای کلی نیز از ۱،۸۹ به ۱،۴ کاهش یافت. بنابراین می‌توان گفت الگوریتم پیشنهادی موجب بهبود روند برچسب‌دهی مجدد به شاخص تغییرات شده‌است. در مجموعه داده‌ی دوم، در حالت اول معیارهای نرخ شناسایی اشتباه، نرخ هشدار نادرست و نرخ خطای کلی به ترتیب برابر با ۵،۶۶، ۰،۴۴ و ۲،۳ است. در بهبود خوشه‌بندی با استفاده از MRF بهبودیافته، معیارهای نام‌برده به ترتیب برابر با ۱،۹۲، ۱،۵۶ و ۱،۶۹ بدست آمدند. بنابراین می‌توان گفت با شناسایی دقیق‌تر تغییرات، روند خوشه‌بندی بهبود یافته‌است. با نگاه دقیق به شکل ۸ (الف) می‌توان گفت مناطقی به عنوان پیکسل‌های تغییر شناسایی شده‌اند که در نقشه‌ی مرجع به عنوان پیکسل‌های عدم تغییر ثبت شده‌اند و موجب ایجاد خطا در روند شناسایی دقیق تغییرات شده‌اند. اما در حالت (ب)، این مشکل به دلیل حفظ مرزهای منطقه‌ی تغییر و در نتیجه کاهش قابل توجه پیکسل‌های تغییر یافته در خارج از محدوده تغییر، به طور چشمگیری کاهش یافته‌است.


جدول ۵- نتایج حالت‌های مختلف از نظر بکارگیری میدان تصادفی مارکوف

نرخ خطای کلی	نرخ هشدار نادرست	هشدار نادرست	نرخ شناسایی اشتباه	شناسایی اشتباه	مدل	مجموعه داده
۱،۸۹	۱،۹۹	۲۲۰۳۵	۱،۰۷	۱۴۱۶	MRF	۱
۱،۴	۱،۳۹	۱۵۴۴۹	۱،۴	۱۸۴۹	IMRF	
۲،۳	۰،۴۴	۱۱۳۹۵	۵،۶۶	۸۰۴۹۵	MRF	۲
۱،۶۹	۱،۵۶	۴۰۲۴۴	۱،۹۲	۲۷۳۱۰	IMRF	
مدل اصلی **MRF=			مدل توسعه داده شده **IMRF=			

شکل ۶ و ۷ نیز خوشه‌بندی اولیه‌ی تغییرات توسط دو الگوریتم مورد بحث را برای مجموعه داده‌ی دوم نشان می‌دهد، بطوری که عملکرد دو الگوریتم از نظر بصری قابل تمیز نیستند. با توجه به شکل‌های ۵ تا ۷، می‌توان بهبود خوشه‌بندی با شاخص تغییرات D_F را نسبت به دو شاخص تغییرات دیگر مشاهده کرد. بنابراین می‌توان گفت تلفیق شاخص‌های اختلاف D_N و D_G با روش تبدیل موجک گسسته، موجب بهبود چشم‌گیر در زمینه خوشه‌بندی و شناسایی اولیه تغییرات می‌شود.




شکل ۶- نتایج خوشه‌بندی k-means شاخص‌های تغییرات تولیدشده از مجموعه داده دوم، (الف) نقشه مرجع، (ب) D_F ، (ج) D_G ، (د) D_N




شکل ۷- نتایج خوشه‌بندی 1k-means شاخص‌های تغییرات تولیدشده از مجموعه داده دوم، (الف) نقشه مرجع، (ب) D_F ، (ج) D_G ، (د) D_N



شکل ۹- نقشه باینری تولید شده برای مجموعه داده دوم به وسیله الف)
MRF، ب) IMRF، و ج) نقشه مرجع



شکل ۱۰- نمودار ROC در حالت استفاده از مدل (الف) MRF و در حالت استفاده از (ب) IMRF برای مجموعه داده اول




شکل ۱۱- نمودار ROC در حالت استفاده از مدل (الف) MRF و در حالت استفاده از (ب) IMRF برای مجموعه داده دوم

۳-۳- ارزیابی عملکرد روش پیشنهادی در شناسایی تغییرات جنگل

برای ارزیابی عملکرد روش پیشنهادی در آشکارسازی نظارت نشده تغییرات جنگل، کارایی این روش با چندین روش شناخته شده دیگر مقایسه گردید که عبارتند از: روش مبتنی بر حد آستانه گذاری Otsu [۳۲]، روش PCA-kmeans [۳۳]، روش مبتنی بر بهینه سازی الگوریتم خوشه بندی FCM با الگوریتم فرا ابتکاری ژنتیک [۳۴] و روش مبتنی بر مدل آمیخته گوسی و الگوریتم میدان تصادفی مارکوف [۳۵]. نتایج کمی و کیفی آشکارسازی نظارت نشده تغییرات مناطق جنگلی با استفاده از روش های مذکور و روش پیشنهادی برای مجموعه داده های اول و دوم در جدول ۶ و جدول ۷ آورده شده است، همچنین

در شکل ۹ با مقایسه ای حالت (الف) و نقشه ی مرجع تغییرات می توان دریافت بخشی از تغییرات در مناطق مختلفی از تصویر از دست رفته اند و توسط الگوریتم شناسایی نشده اند. اما در حالت (ب)، این مناطق در نتیجه ی کنترل کنندگی و انعطاف پارامتر β به خوبی شناسایی شده اند. در شکل ۱۰ نمودار ROC دو حالت مورد مقایسه برای داده ی اول نشان داده شده است. این نمودار میزان صحت خوشه بندی هر طبقه را بیان می کند. در حالت (الف) صحت خوشه بندی طبقه ی تغییر با اختلاف بسیار کمی از صحت طبقه ی عدم تغییر بیشتر است. اما هر دو دارای نرخ صحتی بالاتر از ۰.۹ هستند. در نمودار (ب) که متعلق به روش پیشنهادی است، مقدار نرخ صحت هر دو طبقه از نظر بصری تقریباً با هم برابر و بر هم منطبق است و روند شناسایی تغییرات با ایجاد یک تعادل نسبی در شناسایی مناطق تغییر و عدم تغییر، با صحت بسیار بالایی صورت گرفته است. شکل ۱۱ نمودار ROC را برای مجموعه داده دوم نشان می دهد. در شکل (الف) تغییرات به خوبی شناسایی نشده اند و مقدار صحت خوشه بندی طبقه ی تغییر بسیار کمتر از طبقه ی عدم تغییر است. اما در نمودار (ب) صحت خوشه بندی هر دو طبقه به یک تعادل نسبی و با دقت بالا رسیده اند. برخلاف مجموعه داده اول که افزایش سطح زیر منحنی ROC در آن از نظر بصری محسوس نیست، در مجموعه داده دوم سطح زیر نمودار در شکل (۱۱-ب) در مقایسه با حالت (الف) افزایش یافته است و این موضوع حاکی از دقت بالای الگوریتم MRF بهبود یافته در مقایسه با نوع مرسوم آن است. بطور کلی می توان گفت تغییرات اعمال شده بر مدل MRF در این تحقیق، منجر به عملکرد بسیار بهتر آن در مقایسه با مدل MRF مرسوم در بهبود خوشه بندی اولیه شده است که با یک تعادل نسبی در نرخ شناسایی اشتباه و نرخ هشدار نادرست همراه است.



شکل ۸- نقشه باینری تولید شده برای مجموعه داده اول به وسیله الف) MRF، ب) IMRF، و ج) نقشه مرجع [۴۱]

نقشه باینری تغییرات تولیدشده از این روش‌ها در شکل- هایشکل ۱۳ و شکل ۱۲ آورده شده‌اند. لازم بذکر است که جهت مقایسه هر یک از الگوریتم‌های فوق با روش پیشنهادی از شاخص تغییرات پیشنهادی در این تحقیق و فیلتر پخش‌کننده، به ترتیب به عنوان مبنای شاخص تغییرات و عملگر نرم‌کننده برای هر یک از روش‌ها استفاده شد تا همه روش‌های مورد مقایسه شرایط یکسانی را از نظر شاخص تغییرات و سطح نرم‌سازی داشته باشند.

جدول ۶- نتایج پیاده‌سازی روش‌های مختلف برای مجموعه داده اول

روش‌ها	MD	MD (%)	FA	FA (%)	TE (%)
Otsu	۲۹۵۰۴	۲۲,۳۷	۸۰۸	۰,۰۷	۲,۴۵
PCA-Kmeans	۲۰۴۶۰	۱۵,۵۲	۱۵۶۹۷	۱,۴۲	۲,۹۲
GAFCM	۵۶۰۵	۴,۲۵	۱۹۳۵۷	۱,۷۵	۲,۰۱
GMM-MRF	۱۱۷۵	۰,۸۹	۲۳۰۴۸	۲,۰۸	۱,۹۵
روش پیشنهادی	۱۸۴۹	۱,۴	۱۵۴۴۹	۱,۳۹	۱,۴

جدول ۷- نتایج پیاده‌سازی روش‌های مختلف برای مجموعه داده دوم


روش‌ها	MD	MD (%)	FA	FA (%)	TE (%)
Otsu	۲۸۷۰۳۳	۲۰,۱۹	۲۲۳۳۳	۰,۸۷	۷,۷۳
PCA-Kmeans	۱۳۱۲	۲۷,۴۰	۳۹۰۸۵۵	۰,۰۵	۹,۷۷
GAFCM	۷۴۹۲۶	۵,۲۷	۱۷۲۹۴۴	۶,۷۱	۶,۲۰
GMM-MRF	۱۷۰۰۴۷	۱۱,۹۶	۲۳۳۷	۰,۰۹	۴,۳۱
روش پیشنهادی	۲۷۳۱۰	۱,۹۲	۴۰۲۴۴	۱,۵۶	۱,۶۹

مطابق جدول ۶ و جدول ۷، روش پیشنهادی دارای بهترین عملکرد در مقایسه با سایر روش‌ها بوده‌است. از نظر کمی روش پیشنهادی توانسته‌است به اندازه ۱/۰۵، ۱/۵۲، ۰/۶۱، ۰/۵۵ درصد در مجموعه داده اول و ۶/۰۴، ۸/۰۸، ۴/۵۱، ۲/۶۲ درصد در مجموعه داده دوم به ترتیب در مقایسه با روش‌های Otsu، PCA-kmeans، GAFCM و GMM-MRF خطای کلی را کاهش دهد. پس از روش پیشنهادی، روش GMM-MRF به خوبی توانسته‌است تغییرات جنگل را مدل کند. علت عملکرد مناسب این دو روش نسبت به سایر روش‌ها را باید در بکارگیری الگوریتم میدان تصادفی مارکوف در بهینه‌سازی نقشه باینری اولیه تغییرات دانست که به خوبی توانسته است اطلاعات همسایگی را در تصمیم‌گیری نهایی دخیل کند. تفاوت روش پیشنهادی و روش GMM-MRF در مرزهای مربوط به محدوده‌های تغییر است، جایی‌که روش GMM-MRF در مرز-های محدوده تغییر دچار ضعف بوده و روش پیشنهادی به خوبی توانسته‌است این نقص را با بکارگیری عملگر فازی در پارامتر β جبران کند. این جبران به خوبی در هر دو مجموعه داده دیده می‌شود (شکل‌های شکل ۱۳ و شکل ۱۲). استفاده از الگوریتم

GA-FCM به خوبی توانسته‌است مرز تغییرات را تشخیص دهد اما در بهره بردن از اطلاعات همسایگی ناتوان بوده و بسیار حساس به نویز عمل کرده‌است. نقشه تغییرات حاصل از این روش در هر دو داده نسبت به نقشه مرجع دارای تفاوت‌هایی است. بکارگیری الگوریتم PCA-kmeans اگرچه تا حدی با بزرگ کردن پارامتر مقیاس PCA (در اینجا ۵ در نظر گرفته شد)، توانسته‌است اثر نویز را کاهش دهد، اما بدلیل در نظر گرفتن یک معیار تصمیم‌گیری سخت نظیر k-means بخشی از اطلاعات در مرزها از دست رفته‌است. با نگاه به نقشه تغییرات حاصل از بکارگیری حدآستانه‌گذاری Otsu می‌توان به این نتیجه رسید که روش فوق بسیار متنوع در برخورد با داده‌ها عمل کرده‌است. در این روش با توجه به اینکه واریانس درون کلاسی و برون کلاسی به عنوان مبنای انتخاب حدآستانه از روی هیستوگرام شاخص تغییرات در نظر گرفته شده است، نویزی بودن باعث شده‌است که حدآستانه مورد نظر در هر دو داده به درستی انتخاب نشود. در واقع با توجه به تفاوت زیاد مقادیر مناطق تغییر یافته و تغییر نیافته در شاخص تغییرات، حد آستانه انتخابی توسط این روش بیشتر به سمت مناطق تغییر نیافته میل کرده‌است. این امر باعث شده‌است که در نقشه تغییرات حاصل از این روش، اثر نویز کمتر شده و برخی از مناطق تغییر یافته که دارای مقادیر شبیه به نویز بودند به عنوان مناطق تغییر نیافته انتخاب شوند. علاوه بر موارد گفته‌شده، تعادل بین نرخ هشدار نادرست و نرخ شناسایی اشتباه در روش پیشنهادی بیشتر از سایر روش‌ها می‌باشد که این مورد نیز به نوعی توانسته است که بازنگری در روابط میدان تصادفی مارکوف را در مقایسه با نسخه متداول آن نشان دهد.

۴- نتیجه‌گیری و پیشنهادات


در این تحقیق روشی نظارت‌ننده برای شناسایی تغییرات در مناطق جنگلی ارائه شد که در آن ابتدا یک شاخص تغییرات از طریق تلفیق شاخص‌های تغییرات D_N و D_G با روش UDWT، برای بهره‌مندی از اطلاعات هر سه طیف مادون قرمز نزدیک، قرمز و سبز در قالب یک شاخص تغییرات ایجاد شد. سپس نرم‌سازی شاخص تغییرات با تاکید بر حفظ لبه‌های آن، با استفاده از فیلتر پخش‌کننده صورت گرفت. خوشه‌بندی اولیه‌ی شاخص تلفیقی (D_F) با استفاده از الگوریتم k-means بهبود یافته [۱۹] انجام گرفت.



شکل ۱۲- نتایج مربوط به شناسایی نظارت نشده تغییرات جنگل برای مجموعه داده دوم. نقشه باینری تولید شده: (الف) نقشه مرجع، (ب) روش Otsu [۳۲]، (ج) روش PCA-kmeans [۳۳]، (د) GAFCM [۳۴]، (ه) GMM-MRF [۳۵]، (و) روش پیشنهادی

فیلتر Scharr [۱۱] استخراج شده و به عنوان مرز تغییرات به MRF معرفی شد تا روند بهبود برجسبدهی اولیه با حفظ مرزهای تغییرات صورت گیرد. گفتنی است هرچقدر دقت خوشه‌بندی اولیه بیشتر باشد، روند بهبود آن بوسیله‌ی مدل MRF با دقت بیشتری انجام خواهد گرفت. نتایج حاصل از مقایسه‌ی شاخص تغییرات D_F با دو شاخص دیگر نشان داد که رویکرد تلفیق شاخص‌های تغییرات با روش UDWT منجر به افزایش دقت خوشه‌بندی اولیه شد تا بهبود آن بوسیله‌ی مدل MRF با دقت بیشتری انجام شود. مقایسه‌ی روش پیشنهادی در دو حالت مختلف از بکارگیری مدل MRF نشان داد بهبودهای اعمال شده بر این مدل در این تحقیق، موجب افزایش دقت و کارایی این الگوریتم بویژه در مناطق مرزی تغییرات شد. همچنین مقایسه این روش با برخی از روش‌های شناخته‌شده نشان می‌دهد که روش فوق در شناسایی تغییرات مناطق جنگلی دارای پتانسیل بالایی است.

روش ارائه‌شده در این تحقیق برای شناسایی تغییرات بویژه در مناطق جنگلی است. اما با اعمال تغییراتی در آن می‌توان این روش را در زمینه‌های دیگری از شناسایی تغییرات بکار گرفت. پیشنهاد می‌شود روش ارائه‌شده برای شناسایی تغییرات در سایر کاربردها نیز مورد ارزیابی قرار گیرد.



شکل ۱۳- نتایج مربوط به شناسایی نظارت نشده تغییرات جنگل برای مجموعه داده اول. نقشه باینری تولید شده: (الف) نقشه مرجع [۴۱]، (ب) روش Otsu [۳۲]، (ج) روش PCA-Kmeans [۳۳]، (د) GAFCM [۳۴]، (ه) GMM-MRF [۳۵]، (و) روش پیشنهادی

برای در نظر گرفتن اطلاعات همسایگی (بافت مکانی)، از مدل MRF پس از یک بهبود دو مرحله‌ای در ساختار آن استفاده شد. در مرحله‌ی اول، یک معیار شباهت مبتنی بر میانگین به ساختار تابع انرژی طیفی آن افزوده شد و در مرحله‌ی دوم، لبه‌های شاخص D_F با استفاده از

مراجع

- [1] M. Hussain, D. Chen, A. Cheng, H. Wei, and D. Stanley, "Change detection from remotely sensed images: From pixel-based to object-based approaches," *ISPRS Journal of photogrammetry and remote sensing*, vol. 80, pp. 91-106, 2013.
- [2] J. R. Jensen, *Introductory digital image processing: a remote sensing perspective* (no. Ed. 2). Prentice-Hall Inc., 1996.
- [3] G. Jianya, S. Haigang, M. Guorui, and Z. Qiming, "A review of multi-temporal remote sensing data change detection algorithms," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 37, no. B7, pp. 757-762, 2008.
- [4] X. Chen, L. Vierling, and D. Deering, "A simple and effective radiometric correction method to improve landscape change detection across sensors and across time," *Remote Sensing of Environment*, vol. 98, no. 1, pp. 63-79, 2005.
- [5] C. D. Elvidge, D. Yuan, R. D. Weerackoon, and R. S. Lunetta, "Relative radiometric normalization of Landsat multispectral scanner (MSS) data using a automatic scattergram-controlled regression," *Photogrammetric Engineering and Remote Sensing*, vol. 61, no. 10, pp. 1255-1260, 1995.
- [6] C. Song, C. E. Woodcock, K. C. Seto, M. P. Lenney, and S. A. Macomber, "Classification and change detection using Landsat TM data: when and how to correct atmospheric effects?," *Remote sensing of Environment*, vol. 75, no. 2, pp. 230-244, 2001.
- [7] J. A. Richards and X. Jia, "Image classification methodologies," *Remote Sensing Digital Image Analysis: An Introduction*, pp. 295-332, 2006.
- [8] K. Johansen, L. A. Arroyo, S. Phinn, and C. Witte, "Comparison of geo-object based and pixel-based change detection of riparian environments using high spatial resolution multi-spectral imagery," *Photogrammetric Engineering & Remote Sensing*, vol. 76, no. 2, pp. 123-136, 2010.
- [9] E. A. Addink, F. M. Van Coillie, and S. M. De Jong, "Introduction to the GEOBIA 2010 special issue: From pixels to geographic objects in remote sensing image analysis," ed: Elsevier, 2012.
- [10] A. Pantze, M. Santoro, and J. E. Fransson, "Change detection of boreal forest using bi-temporal ALOS PALSAR backscatter data," *Remote sensing of environment*, vol. 155, pp. 120-128, 2014.
- [11] H. Scharr, S. Körkel, and B. Jähne, "Numerische isotropieoptimierung von fir-filtern mittels querglättung," in *Mustererkennung 1997*: Springer, 1997, pp. 367-374.
- [12] J. Rouse, R. Haas, J. Schell, and D. Deering, "Monitoring vegetation systems in the Great Plains with ERTS," *NASA special publication*, vol. 351, p. 309, 1974.
- [13] N. Pettorelli, J. O. Vik, A. Mysterud, J.-M. Gaillard, C. J. Tucker, and N. C. Stenseth, "Using the satellite-derived NDVI to assess ecological responses to environmental change," *Trends in ecology & evolution*, vol. 20, no. 9, pp. 503-510, 2005.
- [14] A. A. Gitelson, Y. J. Kaufman, and M. N. Merzlyak, "Use of a green channel in remote sensing of global vegetation from EOS-MODIS," *Remote sensing of Environment*, vol. 58, no. 3, pp. 289-298, 1996.
- [15] S. Candiago, F. Remondino, M. De Giglio, M. Dubbini, and M. Gattelli, "Evaluating multispectral images and vegetation indices for precision farming applications from UAV images," *Remote sensing*, vol. 7, no. 4, pp. 4026-4047, 2015.
- [16] P. Perona and J. Malik, "Scale-space and edge detection using anisotropic diffusion," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 12, no. 7, pp. 629-639, 1990.
- [17] L. J. Chipman, T. M. Orr, and L. N. Graham, "Wavelets and image fusion," in *Proceedings., International Conference on Image Processing*, 1995, vol. 3: IEEE, pp. 248-251.
- [18] S. Z. Li, *Markov random field modeling in image analysis*. Springer Science & Business Media, 2009.
- [19] D. Napoleon and P. G. Lakshmi, "An enhanced k-means algorithm to improve the efficiency using normal distribution data points," *International Journal on Computer Science and Engineering*, vol. 2, no. 7, pp. 2409-2413, 2010.
- [20] M. Hao, H. Zhang, W. Shi, and K. Deng, "Unsupervised change detection using fuzzy c-means and MRF

- from remotely sensed images," *Remote Sensing Letters*, vol. 4, no. 12, pp. 1185-1194, 2013.
- [21] H. Zhang, W. Shi, Y. Wang, M. Hao, and Z. Miao, "Spatial-attraction-based Markov random field approach for classification of high spatial resolution multispectral imagery," *IEEE Geoscience and Remote sensing letters*, vol. 12, no. 2, pp. 489-493, 2013.
 - [22] A. H. S. Solberg, T. Taxt, and A. K. Jain, "A Markov random field model for classification of multisource satellite imagery," *IEEE transactions on geoscience and remote sensing*, vol. 34, no. 1, pp. 100-113, 1996.
 - [23] J. Weickert and H. Scharr, "A scheme for coherence-enhancing diffusion filtering with optimized rotation invariance," *Journal of Visual Communication and Image Representation*, vol. 13, no. 1-2, pp. 103-118, 2002.
 - [24] L. Ni, L. Gao, S. Li, J. Li, and B. Zhang, "Edge-constrained Markov random field classification by integrating hyperspectral image with LiDAR data over urban areas," *Journal of Applied Remote Sensing*, vol. 8, no. 1, p. 085089, 2014.
 - [25] R. C. Gonzales and R. E. Woods, "Digital image processing," ed: Prentice hall New Jersey, 2002
 - [26] Patra, Swarnajyoti, Susmita Ghosh, and Ashish Ghosh. "Histogram thresholding for unsupervised change detection of remote sensing images." *International journal of remote sensing* 32.21 (2011): 6071-6089.
 - [27] L. Bruzzone and D. F. Prieto, "Automatic analysis of the difference image for unsupervised change detection," *IEEE Transactions on Geoscience and Remote sensing*, vol. 38, no. 3, pp. 1171-1182, 2000.
 - [28] M. Gutierrez-Rodriguez, J. Escalante-Estrada, and M. Rodriguez-Gonzalez, "Canopy reflectance, stomatal conductance, and yield of *Phaseolus vulgaris* L. and *Phaseolus coccineus* L. under saline field conditions," *Int. J. Agric. Biol*, vol. 7, pp. 491-494, 2005.
 - [29] W. Nori, H. M. Sulieman, and I. Niemeyer, "Detection of land cover changes in El Rawashda Forest, Sudan: A systematic comparison," in 2009 IEEE International Geoscience and Remote Sensing Symposium, 2009, vol. 1: IEEE, pp. 1-88-1-91.
 - [30] M. J. Hughes, S. D. Kaylor, and D. J. Hayes, "Patch-based forest change detection from Landsat time series," *Forests*, vol. 8, no. 5, p. 166, 2017.
 - [31] M. Zanetti, L. Bruzzone, and D. Fernández-Prieto, "A Multivariate Change Vector Analysis System for Unsupervised Detection of Clear-Cuts in Sentinel-2 Time Series of the Indonesian Forest," in IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium, 2018: IEEE, pp. 1942-1945.
 - [32] A. Novo-Fernández, S. Franks, C. Wehenkel, P. M. López-Serrano, M. Molinier, and C. A. López-Sánchez, "Landsat time series analysis for temperate forest cover change detection in the Sierra Madre Occidental, Durango, Mexico," *International journal of applied earth observation and geoinformation*, vol. 73, pp. 230-244, 2018.
 - [33] Celik, Turgay. Unsupervised change detection in satellite images using principal component analysis and "k-means clustering". *IEEE Geoscience and Remote Sensing Letters*, 2009, 6.4: 772-776.
 - [34] Ghosh, Ashish, Niladri Shekhar Mishra, and Susmita Ghosh. "Fuzzy clustering algorithms for unsupervised change detection in remote sensing images." *Information Sciences* 181.4 (2011): 699-715.
 - [35] Khazaei S, Ghanbari H. Automatic Change Detection Analysis of the Difference Image Using Gaussian Mixture Model and Markov Random Fields. *JGST*. 2018; 8 (1) :35-51.
 - [36] Moghimi A, Ebadi H, Sadeghi V. Review of Change Detection Methods from Multitemporal Satellite Images by Pixel-Based and Object-Based Approach. *GEJ*. 2016; 7 (2) :99-110
 - [37] Tammimi. E, Ebadi. H, Kiani., A, "Investigate and evaluate techniques for change detection of high-resolution images based on computational basis". First National Conference on Spatial Information Technology Engineering. (2017).
 - [38] Khoshlahjeh M, Ranjbar B, Moghimi A, Beheshtifar S, Maghsudi Y, Mohammadzade A. An Overview of the Methods and Models Used to Identify Land use Changes Based on Remote Sensing and GIS (with Emphasis on Studies in Iran). *JGST*. 2019; 9 (2) :225-242
 - [39] L. Wei, Y. Zhong, L. Zhang and P. Li, "New Unsupervised change detection algorithm based on the MRF in remote sensing image," 2011 Joint Urban Remote Sensing Event, Munich, 2011, pp. 325-328.
 - [40] Lu, P., Qin, Y., Li, Z., Mondini, A. C., & Casagli, N. (2019). Landslide mapping from multi-sensor data through improved change detection-based Markov random field. *Remote Sensing of Environment*, 231, 111235.
 - [41] Volpi, M., Camps-Valls, G., & Tuia, D. (2015). Spectral alignment of multi-temporal cross-sensor images with automated kernel canonical correlation analysis. *ISPRS journal of photogrammetry and remote sensing*, 107, 50-63.

- [42] Moghimi, A., Mohammadzadeh, A., Celik, T., & Amani, M. (2020). A Novel Radiometric Control Set Sample Selection Strategy for Relative Radiometric Normalization of Multitemporal Satellite Images. *IEEE Transactions on Geoscience and Remote Sensing*.
- [43] Celik, T., & Ma, K. K. (2010). Multitemporal image change detection using undecimated discrete wavelet transform and active contours. *IEEE Transactions on Geoscience and Remote Sensing*, 49(2), 706-716.
- [44] Moghimi, A., Mohammadzadeh, A., & Khazai, S. (2017). Integrating thresholding with level set method for unsupervised change detection in multitemporal SAR images. *Canadian Journal of Remote Sensing*, 43(5), 412-431.