

پایش و برآورد خسارات ناشی از سیل به کمک آشکارسازی تغییرات شی‌گرا و تلفیق تصاویر راداری و نوری

رضا شاه‌حسینی^{۱*}، عبدالرضا صفری^۲، سعید همایونی^۳

^۱ استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران
rshahosseini@ut.ac.ir

^۲ استاد دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران
asafari@ut.ac.ir

^۳ استادیار گروه جغرافیا، محیط زیست و ژئوماتیک - دانشگاه اتاوا - کانادا
saeid.homayouni@uOttawa.ca

(تاریخ دریافت آذر ۱۳۹۶، تاریخ تصویب فروردین ۱۳۹۷)

چکیده

کشف تغییرات و خسارات ناشی از وقوع بلایای طبیعی، به علت محدودیت زمانی و اهمیت بالا در مدیریت بحران از جمله عملیات دشوار و حساسی هستند. در اواخر فروردین‌ماه سال ۱۳۹۶، بارش‌های شدید در حوضه کارون بزرگ و سد دز، باعث جاری شدن سیلابی بی‌سابقه در سال‌های اخیر با شدت هشت هزار مترمکعب در ثانیه شد. بروز این سیلاب منجر به وارد آمدن خسارات فراوانی به این روستاها و دشت‌های کشاورزی شد. بنابراین نیاز به روش‌های پایش تغییرات کارا و دقیق با حداقل وابستگی به کاربر ماهر جهت استخراج مناطق سیل‌زده و مدیریت بحران به شدت احساس می‌شود. از آنجاییکه در هنگام وقوع بلایای طبیعی همانند سیل، شرایط اتمسفری متلاطم بوده و استفاده از تصاویر نوری به تنهایی جهت تهیه نقشه تغییرات مناسب نیستند، لذا در این مقاله، یک روش کشف تغییرات نیمه نظارت شده کرنل پایه و در سطح شیء مبتنی بر روش‌های طبقه‌بندی شیء‌گرا و طبقه‌بندی‌کننده تک کلاسه کرنل پایه با استفاده همزمان از داده‌های راداری و نوری پیشنهاد شده است. ارزیابی مقایسه‌ای دقت روش کشف تغییرات پیشنهادی در حالت استفاده از داده‌های راداری و نوری تلفیق شده و کرنل گوسین (دقت کلی: ۹۴،۲۴ و سطح زیر منحنی (ROC (AUC: ۰،۹۸) نسبت به روش نوین کشف تغییرات چند متغیره وزن‌دهی شده تکراری (IR-MAD) (دقت کلی: ۸۵،۱۰ و AUC: ۰،۸۷) و روش‌های کشف تغییرات متداول مبتنی بر تبدیل آنالیز مولفه اصلی (PCA) (دقت کلی: ۷۷،۸۹ و AUC: ۰،۷۸) و روش نگارنده زاویه طیفی (SAM) (دقت کلی: ۸۰،۶۷ و AUC: ۰،۸۲) نشان‌دهنده دقت بالای الگوریتم پیشنهادی نسبت به روش‌های مرسوم کشف تغییرات و قابلیت بالای خودکار بودن آن در تعیین مناطق خسارت دیده ناشی از وقوع سیل به تفکیک هر کلاس کاربری و کمک به مدیریت بهینه بحران است.

واژگان کلیدی: کشف تغییرات، کرنل پایه، شیء‌گرا، توصیف داده بردار پشتیبان، ماشین بردار پشتیبان، تلفیق تصاویر، راداری و نوری

* نویسنده رابط

۱- مقدمه

هر اتفاق طبیعی غیر مترقبه و در موارد ناگهانی که موجبات تضعیف و نابودی توانمندی‌های اقتصادی، اجتماعی و فیزیکی مانند خسارات جانی و مالی، تخریب تاسیسات زیربنائی، منابع اقتصادی و زمینه‌های اشتغال جامعه را فراهم آورد به عنوان بلایای طبیعی تعریف می‌شود که از مصادیق بارز آن می‌توان زلزله، سیل، خشکسالی، پیشروی آب دریا، آتشفشان، لغزش لایه‌های زمین، رانش، طوفان و آفات طبیعی را نام برد [۱]. با بررسی‌های بعمل آمده از سوی کارشناسان دخیل در امر مدیریت بحران و سوانح، بیش از چهل نوع بلایای طبیعی در سطح جهان تشخیص داده شده که سیل و زمین لرزه در این میان بیشترین سهم را به خود اختصاص داده، به نحوی که هر از گاهی یکی از این دو سانحه طبیعی در یکی از کشورها رخ داده و خسارات زیادی را منجر می‌شود. هرچند حوادث و رویدادهای متعدد طبیعی در طول حیات بشر در جوامع مختلف منجر به بروز خسارات جانی و مالی فراوانی شده و کماکان بسته به سطح توسعه نیافتگی کشورها و جوامع بشری، خساراتی وارد می‌شود [۲]. اما جوامع پیشرفته با استفاده از توان علمی و فنی و سازماندهی اصولی توانسته‌اند به مقابله با این بلایا برخاسته و میزان خسارات ناشی از وقوع حوادث را به حداقل کاهش دهند [۳]. آنچه که مشخص است، پایش خسارات ناشی از وقوع بلایای طبیعی، به مدیریت خطرپذیری در سطح کلان و حل مشکلات آن کمک می‌کند. پایش باید در فواصل زمانی منظم تکرار شود که لازم است جهت تکمیل این فرآیند نظارتی، طراحی سیستم منظم پایش از محیط پیرامون برای ثبت تغییرات ممکن در آینده مورد توجه قرار گیرد [۴].

برای کشف و ارزیابی تغییرات، سنجش از دور به عنوان علم و فن تولید اطلاعات مکانمند می‌تواند نقش اساسی داشته باشد [۵]. تصاویر رقومی ماهواره‌ای به عنوان یکی از منابع اطلاعات مکانی نسبت به سایر منابع متداول (نظیر نقشه‌ها) دارای مزایایی از جمله پوشش فراوان، نیاز کمتر به انجام عملیات نقشه‌برداری، هزینه کمتر و همچنین به روز بودن اطلاعات می‌باشند که استفاده از آنها را برای کاربر جهت بررسی و کشف تغییرات کاربری زمین در هنگام وقوع بلایای طبیعی اجتناب‌ناپذیر می‌نماید. تجزیه

و تحلیل تصاویر ماهواره‌ای به صورتی که برای برنامه‌ریزان و مدیران قابل استفاده باشد، کارآمدترین راه حل جهت تولید اطلاعات مکانی بروز و دقیق است [۶]. امروزه، روش‌های زیادی با هدف پایش تغییرات ناشی از وقوع بلایای طبیعی با استفاده از تصاویر سنجش از دوری ارائه شده است. در یک تقسیم‌بندی کلی، روش‌های کشف تغییرات به دو دسته کلی تقسیم می‌شوند، ۱) روش‌های بانظارت مبتنی بر روش‌های طبقه‌بندی بانظارت و ۲) روش‌های بدون نظارت مبتنی بر تشخیص تغییرات طیفی و خوشه‌بندی تصاویر چندزمانه [۹] - [۷].

روش‌های آشکارسازی تغییرات بانظارت مبتنی بر طبقه‌بندی بر اساس مقایسه بین دو نقشه طبقه‌بندی شده مربوط به تاریخ‌های مختلف عمل می‌کنند. عواملی که از منظر کاربردی باعث ایجاد محدودیت در استفاده از روش آشکارسازی تغییرات مبتنی بر طبقه‌بندی می‌شوند را می‌توان چنین برشمرد: ۱) هزینه محاسباتی، ۲) قابلیت اطمینان نتایج و ۳) انتشار خطا. با توجه به حجم بالای تصاویر سنجش از دوری، طبقه‌بندی کل تصاویر یک منطقه در دوره‌های زمانی مختلف دارای هزینه محاسباتی بالایی است [۱۰]. عدم استحکام نتایج بدست آمده از این روش‌ها، به علت تفاوت در مفسرین نتایج طبقه‌بندی و محدودیت عملکرد آنهاست، بگونه‌ای که نتایج یک مفسر می‌تواند با مفسر دیگر متفاوت باشد. خطاهای طبقه‌بندی در این روش از مدل انتشار خطای ضربی پیروی می‌کند [۱۱]. از آنجاییکه خطای طبقه‌بندی در هر یک از تصاویر چندزمانه می‌تواند در نقشه تغییر نهایی خطا ایجاد کند، بنابراین احتمال رخداد اشتباه در نتایج این روش وجود خواهد داشت. بدلیل بانظارت بودن ماهیت این روش، در اختیار داشتن داده‌های واقعیت زمینی اجتناب ناپذیر خواهد بود [۱۲] [۱۳].

در روش‌های تشخیص تغییرات بدون نظارت مبتنی بر تشخیص تغییرات طیفی و خوشه‌بندی تصاویر چندزمانه، به غیر از روش تفاضل و تقسیم تصاویر خام اولیه، سایر روش‌ها با استفاده از یکسری توابع تبدیل به دنبال نرمال کردن و یا کاهش اثر اختلاف رادیومتریکی بین دو تصویر هستند. این روش‌ها با استفاده از تصاویر چندزمانه از یک منطقه مورد مطالعه و تولید یک تصویر تک بانندی و یا تصویر چند بانندی جدید، تغییرات طیفی را نمایش می‌دهند [۱۴]. از خصوصیت اصلی این روش‌ها اینست که

تصاویر باید با دقت بالایی نسبت به یکدیگر ثبت هندسی شوند. بنابراین در این روش‌ها دقت نتایج به دست آمده وابستگی زیادی به دقت ثبت هندسی تصاویر چند زمانه نسبت به یکدیگر دارند [۱۵]. از آنجاییکه در این روش‌ها برای آشکارسازی تغییرات از مقادیر انعکاس طیفی پیکسل‌ها استفاده می‌شود، بنابراین انجام تصحیحات رادیومتریکی در این روش یک مرحله مهم و ضروری به شمار می‌رود که در فرآیند زمان‌بر بودن روش و دقت نقشه تغییرات تاثیر بسزایی دارد. خروجی حاصل از این روش‌ها نقشه‌هایی هستند که در آن مکان‌هایی که دارای تغییر هستند نشان داده شده و به آن برچسب تغییر کاربری اختصاص می‌یابد. در برخی از کاربردهایی که تعیین مناطق تغییر یافته از مناطق تغییر نیافته مطلوب است، استفاده از این روش‌ها مناسب بنظر می‌رسد [۱۶]. از نقشه تغییر به دست آمده می‌توان برای اخذ اطلاعات بیشتر و یک نقشه پایه در کارهای زمینی بعدی استفاده کرد. در صورتی که میزان تغییر در منطقه نیز مهم باشد، می‌توان از تفاضل اندکس‌های پوشش گیاهی استفاده کرد. یکی از معایب این روش‌ها اینست که برای تعیین پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر و تولید نقشه تغییر پوشش زمین برچسب‌دار، پس از تولید نقشه تغییر نیاز به یکسری آنالیزهای اضافی دارد [۱۷].

اخیرا استفاده از توابع کرنل توجه بسیاری از پژوهشگران مسائل کاربردی سنجش از دوری به ویژه در طبقه‌بندی را به خود جلب کرده است [۸]، [۱۸] - [۲۰]. استفاده از توابع کرنل، برای به دست آوردن نمایشی ساده‌تر از داده‌ها، به عنوان یکی از راهکارهای افزایش دقت الگوریتم‌ها به تازگی مورد توجه زیادی قرار گرفته است. توابع کرنل با استفاده از نگاشتی غیرخطی داده‌ها را از فضای مشاهده به فضایی با بعد بالاتر به نام فضای کرنل انتقال می‌دهند که در آن روابط پیچیده و غیرخطی بین داده‌ها، به صورت خطی نگاشته می‌شود [۲۱]. پس می‌توان تفکیک بین کلاسی بهتر و در نتیجه دقت بالاتری را انتظار داشت. نتایج پژوهش‌های مختلف نشان داده‌اند که در مسائل آشکارسازی تغییرات در تصاویر دو زمانه، استفاده از مرزهای تصمیم‌گیری غیرخطی با کاهش False Alarm Rate دقت نقشه تغییرات به دست آمده را بهبود می‌دهد [۲۲]. ایده اصلی روش‌های مبتنی بر کرنل این است که یک تابع تصمیم‌گیری غیرخطی می‌تواند با پیاده‌سازی یک تابع تصمیم‌

گیری خطی در یک فضای عارضه‌ای با ابعاد بالاتر تحقق یابد که به این فضا Reproducing Kernel Hilbert Space گفته می‌شود [۲۳]. راه حل مورد استفاده در این فضا مشابه با حالت خطی است و انتقال به این فضا توسط توابع کرنل انجام می‌شود. از آنجاییکه به علت پیچیدگی بین کلاس‌های طیفی ممکن است یک تابع کرنل به خوبی نتواند جدایی بین کلاسی را در فضای کرنل فراهم نماید می‌توان از ترکیب توابع کرنل مختلف برای مدل‌سازی تابع جداسازی بین کلاسی استفاده نمود [۲۴].

در زمینه کشف تغییرات محیطی با استفاده از تصاویر سنجش از دوری و روش‌های کرنل پایه تحقیقات زیادی انجام شده است، که در ادامه به بررسی برخی از این تحقیقات پرداخته شده است.

Guorui و همکاران در سال ۲۰۰۶ از یک روش آشکارسازی تغییرات مبتنی بر کرنل برای آشکارسازی تغییرات در تصاویر ماهواره‌ای استفاده کردند. در این روش، ورودی الگوریتم شامل دو تصویر در دو زمان مختلف بوده و با استفاده از یک تبدیل غیر خطی، به یک فضای ویژگی با بعد بالاتر تصویر شده که در این فضا حاشیه خطی بین نواحی تغییر یافته و بدون تغییرافزایش می‌یابد. در مرحله بعد یک معیار اندازه‌گیری فاصله خطی بین این دو بردار ویژگی در فضای ویژگی تعریف می‌شود. این معیار فاصله ساده در فضای ویژگی معادل یک معیار فاصله غیر خطی پیچیده در فضای اولیه می‌باشد. نتایج بدست آمده نشان‌دهنده دقت بالای الگوریتم پیشنهادی می‌باشد [۲۵]. Camps-Valls و همکاران در سال ۲۰۰۸ یک روش ادغام داده مبتنی بر کرنل برای تلفیق داده‌های سنجش از دوری از منابع و سنجنده‌های مختلف ارائه کردند. برای طبقه‌بندی تصاویر چندزمانه، از الگوریتم‌های طبقه‌بندی دودویی SVM^۱ و SVDD^۲ با کرنل‌های غیر خطی استفاده کردند. کارایی این روش پیشنهادی با استفاده از تصاویر چندزمانه و شبیه‌سازی شده ارزیابی شد و نتایج نشان‌دهنده دقت و کارایی بالای این روش بودند [۲۶].

Bovolo و همکارانش در سال ۲۰۱۰ از یک الگوریتم طبقه‌بندی تک کلاسه مبتنی بر کرنل برای جداسازی پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر استفاده

^۱ Support Vector Machines

^۲ Support Vector Data Description

کردند. در این روش با تعریف یک مرز تصمیم‌گیری کروی شکل با حجم کمینه برای جدا کردن پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر استفاده می‌شود. نتایج به دست آمده از اعمال این الگوریتم بر روی تصاویر چندطیفی حاکی از کارایی و دقت مناسب این الگوریتم می‌باشد [۲۷]. Belgith و همکاران در سال ۲۰۱۱ با استفاده از روشی مبتنی بر الگوریتم SVDD به تشخیص تغییرات در تصاویر چندزمانه پرداختند. در این مقاله یک تابع کرنل جدید نیز توسعه داده شد. کارایی این الگوریتم پیشنهادی با استفاده از داده‌های واقعی و شبیه‌سازی شده ارزیابی شد و نتایج خوبی را به همراه داشت [۲۸]. Volpi و همکاران در سال ۲۰۱۳ با استفاده از یک طبقه‌بندی‌کننده غیر خطی مبتنی بر SVM به آشکارسازی تغییرات در تصاویر با رزولوشن مکانی بالا پرداختند. نتایج این الگوریتم بر روی تصاویر Quickbird نشان‌دهنده دقت بالای الگوریتم پیشنهادی است [۲۹].

بطور کلی روش‌های کشف تغییرات موجود به دلایلی که در ادامه ذکر خواهند شد، جهت کشف تغییرات محیطی ناشی از بروز بلایای طبیعی، بهینه و قابل کاربرد نیستند. (۱) در مواقعی که نمونه آموزشی کافی از منطقه مورد مطالعه در دسترس نیست، (۲) تصاویر سنجش از دوری چندزمانه با نویز یا تغییرات رادیومتریکی غیر نرمال تخریب شده باشند و ماهیت تغییرات غیر خطی باشد، (۳) تصویر تفاضلی تولید شده دارای کلاس‌های تغییر و بدون تغییر باشند که با یکدیگر همپوشانی طیفی داشته و بصورت خطی قابل جداسازی نباشند، (۴) وجود شرایط اتمسفری متفاوت در حین اخذ تصاویر چندزمانه که منجر به ایجاد برخی کلاس‌های تغییر ناخواسته و کاذب خواهد شد، (۵) وابستگی این روش‌ها به تعیین یک حدآستانه جهت جداسازی مناطق تغییر یافته از مناطق بدون تغییر که تعیین این حدآستانه نیاز به داشتن دانش قبلی از ماهیت داده‌ها، منطقه مورد مطالعه و کاربر ماهر داشته و اغلب با خطای زیادی همراه است و (۶) عدم داشتن کارایی لازم در کاربردهای کشف تغییرات محیطی بهنگام و تعیین میزان خسارات وارده به دلیل خودکار نبودن این روش‌ها [۹].

از آنجاییکه روش‌های کشف تغییرات مذکور در سطح پیکسل می‌باشند، لذا معمولاً نقشه‌های کشف تغییرات تولید شده دارای سطح نویز بالایی هستند. لذا با هدف حل این مشکل و افزایش دقت نقشه کشف تغییرات و دستیابی به قابلیت اعتماد بالا به نقشه‌های تولید شده، در این

پژوهش یک روش کشف تغییرات در سطح شیء پیشنهاد و پیاده‌سازی شده است.

از طرفی دیگر، در اغلب تحقیقات فوق از مزایای تلفیق تصاویر نوری و راداری استفاده نشده است. این در حالیست که تصاویر راداری با پلاریزاسیون‌های مختلف تا حد زیادی به جداسازی کلاس‌های پیچیده پوشش زمین کمک می‌کنند. تصاویر راداری منبع مناسبی برای مطالعه، استخراج اطلاعات و آشکارسازی رفتار پراکنش پوشش‌ها و پدیده‌های زمینی هستند. تصاویر راداری به فرآیندهای پراکنش حساس‌اند و تحت تاثیر شکل، جهت و خواص دی‌الکتریک پراکنش‌کننده‌ها قرار می‌گیرند. سطوح زمینی بطور عمده به دو دسته تقسیم می‌گردند؛ یک دسته، سطوح طبیعی از قبیل مزارع، جنگل‌ها و آب‌ها و دسته دیگر، مناطق شهری که از ساختمان‌ها تشکیل شده‌اند. از آنجاییکه محتوی اطلاعاتی تصاویر راداری و نوری متفاوت بوده و به خصوص در مناطق متأثر از سیل، کمک زیادی به استخراج مناطق سیل زده از سایر کلاس‌ها می‌کند و با توجه به در دسترس بودن تصاویر راداری و نوری ماهواره سنتینل ۱ و ۲، در این پژوهش یک روش کشف تغییرات نیمه نظارت شده کرنل پایه و در سطح شیء مبتنی بر روش‌های طبقه‌بندی شیء‌گرا و طبقه‌بندی‌کننده تک کلاسه کرنل پایه با استفاده همزمان از داده‌های راداری و نوری پیشنهاد شده است. نوآوری‌های مقاله برای حل مشکلات متداول در کشف تغییرات محیطی ناشی از بروز بلایای طبیعی شامل (۱) ارائه یک روش کشف تغییرات کرنل پایه و غیر خطی (۲) استفاده از روش طبقه‌بندی تک-کلاسه کرنل پایه جهت مقایسه تصاویر قبل و بعد از تغییرات و تولید نقشه تغییرات، (۳) ارائه یک روش جهت تخمین خودکار پارامترهای طبقه‌بندی‌کننده تک کلاسه و کرنل پایه توصیف داده بردار پشتیبان و (۴) ارائه یک روش کرنل پایه جهت تلفیق تصاویر راداری و نوری.

۲- روش پیشنهادی

گردش کار الگوریتم پیشنهادی کشف تغییرات کرنل پایه و در سطح شیء در شکل (۱) نمایش داده شده است. در مرحله پیش‌پردازش، تصاویر راداری و نوری به کمک یک روش مبتنی بر کرنل، با یکدیگر تلفیق شدند. در مرحله بعد، تصویر قبل از تغییر با استفاده از یک روش قطعه‌بندی، طبقه‌بندی می‌شود. هریک از قطعات موجود در نقشه

اتمسفری و کالیبراسیون سنجنده‌ها است. وجود این شرایط، تاثیر بسزایی در دقت و کارایی الگوریتم‌های خودکار کشف تغییرات محیطی دارد. لذا در مراحل پیش‌پردازش تصاویر نوری ماهواره سننیتل-۲، یکنواخت‌سازی رادیومتریکی^۱ و ثبت متقابل هندسی بر روی تصاویر چندزمانه انجام شد. با هدف مقایسه تصاویر چندزمانه راداری ماهواره سننیتل-۱، مراحل کالیبراسیون مقادیر پس پراکنش، اعمال فیلتر Lee جهت کاهش اثرات نویز، انجام عملیات Multi-Looking با نسبت ۱ به ۴ تصاویر جهت تغییر ابعاد پیکسل از ۵*۲۰ به ۲۰*۲۰ و نهایتاً انجام تصحیح هندسی شامل حذف اثر توپوگرافی انجام شد.

در مرحله بعد، با هدف تلفیق داده‌های راداری و نوری با هدف بهبود دقت الگوریتم آشکارسازی تغییرات، یک روش مبتنی بر کرنل پیشنهاد شده است. فرض کنیم که اطلاعات نوری x_i^o و راداری x_i^r مربوط به پیکسل x_i در دو تصویر متناظر که نسبت به یکدیگر ثبت هندسی شده‌اند موجود بوده و فرم الحاقی آن بصورت $\{x_i^o, x_i^r\}$ باشد. روش‌های پیشنهادی به منظور تلفیق این داده‌ها به شکل زیر می‌باشد:

- کرنل مبتنی بر روی هم گذاری ویژگی:

$$K_{\{o,r\}} \equiv K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle \quad (1)$$

- کرنل مبتنی بر جمع مستقیم:

$$K(x_i, x_j) = K_o(x_i^o, x_j^o) + K_r(x_i^r, x_j^r) \quad (2)$$

- کرنل مبتنی بر اطلاعات متقابل:

$$K(x_i, x_j) = K_o(x_i^o, x_j^o) + K_r(x_i^r, x_j^r) + K_{or}(x_i^o, x_j^r) + K_{ro}(x_i^r, x_j^o) \quad (3)$$

لازمه صحیح بودن روابط فوق اینست که در آن x_i^o و x_j^r دارای ابعاد مساوی باشند ($N_o = N_s$).

بنابراین می‌توان یکی از مشکلات عمده در مسائل مربوط به آشکارسازی تغییرات که همانا تلفیق داده‌ها از منابع مختلف داده (راداری و نوری) را با نگاشت به فضای هیلبرت با ابعاد بالاتر و ترکیب نمودن آنها با یکی از روش‌های پیشنهادی مبتنی بر کرنل‌های ترکیبی حل نمود [۳۰].

طبقه‌بندی به عنوان نمونه آموزشی به طبقه‌بندی کننده توصیف داده بردار پشتیبان وارد شده و ابر کره احاطه کننده کلاس مربوطه تشکیل می‌شود. جهت تنظیم پارامترهای بهینه الگوریتم طبقه‌بندی کننده توصیف داده بردار پشتیبان از روش جدید مبتنی بر محاسبه فاصله بین خوشه‌ای پیشنهاد شده است. برای تخمین اولیه پارامتر کرنل گوسین، از یک روش جدید مبتنی بر نرم فاصله L_2 استفاده شده است [۹]. در مرحله اول دو مجموعه بردار طیفی از تصویر قبل از تغییر بطور تصادفی انتخاب می‌شوند. در مرحله بعد فاصله اقلیدسی بین این دو مجموعه داده محاسبه شده و مدین این فواصل انتخاب می‌شود. این فرآیند در تصویر بعد از تغییر نیز انجام می‌شود. در مرحله بعد، میانگین این دو فاصله به عنوان مقدار اولیه پارامتر پهنای باند کرنل گوسین در نظر گرفته می‌شود. از این مقدار اولیه جهت تنظیم محدوده تغییرات پارامتر کرنل گوسین استفاده می‌شود به گونه‌ای که این مقدار اولیه در وسط این محدوده قرار گیرد. این محدوده در یک فرآیند جستجوی شبکه‌ای وارد شده و مقدار دقیق پارامتر پهنای باند کرنل گوسین محاسبه می‌گردد [۸].


در مرحله بعد، پیکسل‌های متناظر با قطعه مورد نظر در تصویر بعد از تغییر، به عنوان پیکسل‌های مجهول وارد طبقه‌بندی کننده توصیف داده بردار پشتیبان، می‌شوند. پیکسل‌هایی که در داخل ابر کره قرار می‌گیرند، به عنوان پیکسل‌های بدون تغییر در نظر گرفته شده و پیکسل‌هایی که در خارج از ابر کره قرار گیرند، به عنوان پیکسل‌های تغییر یافته در نظر گرفته خواهند شد.

همانطور که گفته شد، روش پیشنهادی استخراج نیمه خودکار مناطق تغییر یافته ناشی از وقوع بلایای طبیعی، شامل مراحل (۱) پیش پردازش و تلفیق داده‌های راداری و نوری، (۲) طبقه‌بندی شیء گرای مبتنی بر روش ماشین بردار پشتیبان (SVM) تصاویر (۳) تخمین پارامترهای بهینه کرنل و (۴) طبقه‌بندی تک کلاسه مبتنی بر روش توصیف داده بردار پشتیبان (SVDD) است که در ادامه بررسی خواهد شد.

۲-۱- تلفیق داده‌های راداری و نوری

یکی از مشکلات عمده تلفیق تصاویر چندزمانه مربوط به سنجنده‌های مختلف، وجود تفاوت‌های رادیومتریکی ناشی از عوامل تغییرات زاویه تابش خورشید، شرایط متغیر

^۱ Radiometric Normalization



شکل ۱- چهارچوب پیشنهادی روش خودکار کشف تغییرات کرنل پایه در سطح شیء

۲-۲- طبقه بندی شیء گرا مبتنی بر SVM

طبقه بندی شیء گرا شامل دو مرحله اصلی است، (۱) قطعه بندی تصاویر که در آن پیکسل های تصویر براساس میزان شباهت از پیش تعریف شده به اشیاء مختلف با مقیاس های متفاوت تقسیم می شود و (۲) طبقه بندی

هریک از این اشیاء استخراج شده و اختصاص آن به یک کلاس مشخص. روش های قطعه بندی مختلفی در سطح محلی و جهانی برای قطعه بندی تصاویر سنجش از دوری ارائه شده است. در فرآیند قطعه بندی، اشیاء موجود در تصویر بر اساس میزان شباهت مکانی و طیفی مجموعه ای از پیکسل ها در قالب یک شیء تفکیک می شوند

در یک مسئله طبقه‌بندی دودویی، برای یک مجموعه داده که به دو کلاس تعلق دارند به دنبال یافتن یک فرافصله خطی هستیم. فرض کنیم که مجموعه آموزشی، شامل k نمونه آموزشی $\{(x_1, y_1), \dots, (x_k, y_k)\}$ است و $x \in R^N$ و هر نمونه به یکی از دو کلاس $y_i \in \{-1, +1\}$ تعلق دارد. هدف روش SVM، پیدا کردن یک تابع تصمیم‌گیری خطی با رابطه $f(x) = w \cdot x + b$ می‌باشد که در آن $w \in R^N$ جهت فرافصله را مشخص می‌کند و $b \in R$ پارامتر تمایل به یک طرف^۱ فرافصله می‌باشد. معادله فرافصله برای دو کلاس با رابطه $y_i(w \cdot x_i + b) \geq 1$ مشخص می‌شود. به علت وجود نویز و ترکیب کلاس‌ها در هنگام انتخاب نمونه‌های آموزشی، از متغیر آزاد $\xi_i > 0$ جهت در نظر گرفتن اثر نمونه‌های آموزشی بدون طبقه‌بندی^۲، استفاده می‌شود. بنابراین، معادله فرافصله برای دو کلاس، در این حالت، با رابطه $y_i(w \cdot x_i + b) \geq 1 - \xi_i$ مشخص می‌شود. فرافصله بهینه، در مکانی واقع است که حاشیه بین دو کلاس را بیشینه و مقدار خطا را کمینه کند [۳۴].

این فرافصله، با حل مسئله بهینه‌سازی قیددار زیر حل می‌شود:

$$\min \left\{ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^k \xi_i \right\} \quad (5)$$

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i \quad i = 1, \dots, k$$

پارامتر ثابت C ، که در آن $0 < C < \infty$ ، پارامتر تنظیم است، این پارامتر، تعادلی بین اثر نمونه‌های آموزشی بدون طبقه‌بندی و حاشیه بیشینه، برقرار می‌کند و مقدار آن با سعی و خطا بدست می‌آید. مسئله بهینه‌سازی قیددار بالا با روش ضرائب لاگرانژ، و تابع تصمیم‌گیری، برای طبقه‌بندی از رابطه زیر بدست می‌آید [35].


$$f(x) = \text{sign} \left(\sum_{SV} y_i \alpha_i^0 (x_i \cdot x) + b^0 \right) \quad (6)$$

با این وجود مواردی وجود دارد که در آن با یک فرافصله خطی، نمی‌توان داده‌ها را از یکدیگر جدا کرد. در این موارد، داده‌ها به فضایی با بعد بالاتر منتقل می‌شوند که در این فضا، با یک فرافصله خطی، قابل جدا

پارامترهای مورد استفاده جهت تعیین میزان مشابهت پیکسل‌ها معمولاً شامل بافت، شکل، ضریب فشردگی و میزان نرمی شکل است. همچنین تعیین مقیاس بهینه جهت قطعه‌بندی تصاویر یکی از عوامل تاثیرگذار در این فرآیند است. انتخاب مقادیر بزرگ و کوچک برای این معیار، اجازه تشکیل اشیاء با ابعاد بزرگ و کوچک در تصویر را خواهد داد. روش قطعه‌بندی مورد استفاده در این پژوهش، روش ادغام ناحیه‌ای است. در این روش، اشیاء مختلف بر اساس معیار همگونی در رنگ و شکل با یکدیگر ادغام می‌شوند.

$$f = w \times h_{\text{colour}} + (1-w) \times h_{\text{shape}} \quad (4)$$

که در آن f مقدار حد‌آستانه ادغام برای ادغام قطعات، h_{colour} معیار همگونی رنگ و h_{shape} معیار همگونی شکل اشیاء و w پارامتر وزن تعریف شده توسط کاربر می‌باشد [۳۱]. پس از قطعه‌بندی تصاویر، جهت طبقه‌بندی شیء‌گرای تصویر از روش طبقه‌بندی مبتنی بر ماشین‌های بردار پشتیبان استفاده شده است. این طبقه‌بندی‌کننده بر پایه تئوری یادگیری آماری که توسط آقایان گایون، وپنیک و بوزر ابداع شد، بنا شده است [۳۲]. بر اساس این تئوری می‌توان کران نرخ خطای ماشین یادگیری را برای داده‌های طبقه‌بندی نشده، به عنوان نرخ خطای تعمیم یافته، در نظر گرفت. این کران‌ها به عنوان تابعی از مجموع نرخ خطاهای آموزشی هستند که میزان پیچیدگی طبقه‌بندی‌کننده‌ها را نشان می‌دهند. برای کمینه‌کردن نرخ خطاهای تعمیم یافته، بایستی نرخ خطای آموزش و پیچیدگی طبقه‌بندی‌کننده کاهش یابد. این کار را می‌توان با بیشینه‌کردن حاشیه جداسازی انجام داد (شکل (۲)).




شکل ۲- ابرفصله جداکننده مبتنی بر SVM در فضای هیلبرت [۳۳]

^۱ Bias

^۲ Misclassification

این روش می‌توان نمونه داده‌های پس‌زمینه را نیز (در صورت وجود) در روند آموزش شرکت داد و به توصیف دقیق‌تری از داده‌ها رسید [۳۶].

ابتدا یک مدل $f(x; w)$ را که مرز اطراف داده را تعیین می‌کند بصورت یک فراکره در نظر گرفته می‌شود. یک کره با مرکز a و شعاع R مشخص می‌شود و هدف اینست که این کره تمام داده‌های آموزشی ($\mathcal{X}^T$) را در بر گیرد. وقتی کره شامل تمام داده‌های آموزشی باشد، خطای تجربی صفر می‌شود. در شکل (۳) این فراکره با مرکزیت a و شعاع R مشخص شده است. سه پیکسل قرار گرفته بر روی مرز، بردارهای پشتیبان هستند. پیکسل x_i نیز در خارج از مرز و با خطای $\xi_i > 0$ می‌باشد.



شکل ۳- فراکره در برگیرنده داده هدف، که با مرکز a و شعاع R مشخص شده است. سه داده روی مرز، بردارهای پشتیبان هستند. یک داده x_i خارج از مرز و $\xi_i > 0$ دارد [28].

بنابراین مانند طبقه‌بندی ماشین بردار پشتیبان، با معرفی متغیر ξ_i ، $\xi_i > 0$ ترکیبی از خطای تجربی و ساختاری بصورت زیر در نظر گرفته می‌شود [۲۸].

$$\varepsilon(R, a, \xi) = R^2 + C \sum_i \xi_i \quad (10)$$

با قیدهای زیر که تقریباً تمام داده‌ها داخل کره هستند:

$$\|x_i - a\|^2 \leq R^2 + \xi_i, \quad \forall \xi_i \geq 0, \quad \forall i \quad (11)$$

سازی باشند. برای این کار، یک تابع تبدیل غیر خطی ϕ به فرم یک تابع کرنل k با رابطه زیر در نظر گرفته می‌شود.

$$k(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (7)$$

این تابع کرنل، جایگزین ضرب نقطه‌ای در فضای جدید، بین بردارها می‌شود. مسئله بهینه‌سازی، در این حالت، به صورت زیر تغییر می‌یابد.

$$\text{Maximize: } \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (8)$$

$$\text{Subject to: } \sum_{i=1}^n \alpha_i y_i = 0 \text{ and } 0 \leq \alpha_i \leq C \quad i = 1, \dots, k$$

و تابع تصمیم‌گیری نیز از رابطه زیر بدست می‌آید.

$$f(x) = \text{sign} \left(\sum_{SV} y_i \alpha_i^0 K(x_i, x) + b^0 \right) \quad (9)$$

نمونه‌ای از کرنل‌های مورد استفاده در این تابع، برای تبدیل داده‌ها از فضای ورودی به فضایی با بعد بالاتر، به صورت زیر هستند.

$$K(x_i, x_j) = x_i \cdot x_j \quad (1) \text{ کرنل خطی}$$

$$K(x_i, x_j) = (x_i \cdot x_j + 1)^d \quad (2) \text{ کرنل چندجمله‌ای}$$

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3) \text{ کرنل گوسین} \\ (RBF)^1$$

۲-۳- طبقه‌بندی‌کننده تک کلاسه SVDD

در این بخش، به ارائه و بررسی روش توصیف داده بردار پشتیبان برای مشخص کردن مرز اطراف کلاس مورد علاقه (پیکسل‌های تغییر یافته) بطور مستقیم می‌پردازیم. در بیشتر موارد از یک فراکره برای تعیین این مرز جداکننده استفاده می‌شود، که دربرگیرنده تمامی پیکسل‌های کلاس مورد علاقه است. برای حداقل نمودن اثر در نظر گرفتن داده‌های پس زمینه (کلاس بدون تغییر) به عنوان هدف، حجم این فراکره کمینه می‌شود. در این روش می‌توان با استفاده از یک تبدیل (نگاشت) غیرخطی، داده‌ها را به یک فضای ویژگی جدید با ابعاد بالاتر، بدون انجام محاسبات سنگین انتقال داد. با استفاده از این نگاشت، توصیف بهتری (با انعطاف‌پذیری بالاتر) از داده‌ها حاصل می‌شود. در نهایت در

^۱ Radial Basis Function

پارامتر بهینه انتخاب خواهد شد. فاصله بین دو کلاس در فضای ویژگی از رابطه محاسبه می‌شود.

$$d_F(\bar{x}_+, \bar{x}_-) = \sqrt{\left(\frac{\sum_{x_i \in X_+} \phi(x_i)}{l_+} - \frac{\sum_{x_i \in X_-} \phi(x_i)}{l_-} \right)^2} \quad (14)$$

$$= \sqrt{\frac{\sum_{\substack{x_{ij} \in X_+ \\ x_{ij} \in X_+}} K(x_{ij}, x_{ij})}{l_+^2} + \frac{\sum_{\substack{x_{pq} \in X_- \\ x_{pq} \in X_-}} K(x_{pq}, x_{pq})}{l_-^2} - \frac{2 \sum_{\substack{x_{im} \in X_+ \\ x_{in} \in X_-}} K(x_{im}, x_{in})}{l_+ l_-}}$$

در رابطه فوق X_+ و X_- نمونه‌های آموزشی مربوط به کلاس‌های با برچسب مثبت و منفی بوده و l_+ و l_- تعداد نمونه‌های مربوط به کلاس‌های با برچسب مثبت و منفی هستند. $\bar{x}_+$ و $\bar{x}_-$ نیز میانگین نمونه‌های آموزشی مربوط به هریک از کلاس‌های X_+ و X_- هستند. از آنجاییکه در محاسبه فاصله بین کلاسی، تنها پارامتر کرنل دخیل می‌باشد، لذا مقدار بهینه پارامتر جریمه C باید در فرآیند ارزیابی طبقه‌بندی کننده ماشین‌های بردار پشتیبان تعیین گردد. بنابراین در این حالت، زمان مورد نیاز جهت انتخاب پارامتر بهینه کرنل ذخیره خواهد شد [۳۸].

۳- ارزیابی نتایج

جهت ارزیابی دقت و کارایی روش پیشنهادی، آنالیز حساسیت نسبت به نوع و پارامترهای کرنل، استفاده تلفیقی از داده‌های نوری و راداری و همچنین استفاده از داده‌های نوری و راداری به تنهایی انجام شد. محدوده تغییرات پارامترهای کرنل در روش کشف تغییرات پیشنهادی برای کرنل‌های چندجمله‌ای، گوسین و سیگموئید بدین صورت در نظر گرفته شد: محدوده تغییرات درجه کرنل چندجمله‌ای بین ۱ تا ۵ و همچنین پهنای باند کرنل گوسین بین ۰.۱ تا ۵ در نظر گرفته شد. با استفاده از روش جستجوی شبکه‌ای بر روی تابع هزینه رابطه (۱۴)، پارامتر بهینه هریک از کرنل‌های فوق محاسبه می‌شود.

۳-۱- منطقه مورد مطالعه و داده‌های مورد استفاده

در اواخر فروردین ماه سال ۱۳۹۶، بارش‌های شدید در مناطق غرب و جنوب‌غربی، باعث جریان سیلاب در حوضه کارون بزرگ و سد دز گردید و منجر به وارد آمدن خسارات فراوانی به این روستاها و دشت‌های کشاورزی

ضریب C ارتباط بین حجم توصیف و خطاها را برقرار می‌کند. متغیرهای a ، R و γ باید با توجه به قیدهای رابطه (۱۱) بهینه شوند. تابع تصمیم‌گیری در طبقه‌بندی-کننده تک‌کلاسه توصیف داده‌ی بردار پشتیبان به شکل زیر محاسبه می‌شود:

$$f_{SVDD}(z; \alpha, R) = I(\|z - a\|^2 \leq R^2)$$

$$= I\left((z, z) - 2 \sum_i \alpha_i (z, x_i) + \sum_{i,j} \alpha_i \alpha_j (x_i, x_j) \leq R^2\right) \quad (12)$$


که در آن تابع مقیاس به صورت زیر تعریف می‌شود:

$$I(A) = \begin{cases} 1 & \text{if } A \text{ is true} \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

در حالت غیر خطی می‌توان ضرب داخلی را با تابع کرنل جایگزین و توصیف دقیق‌تری از داده‌ها به دست آورد [۳۷].

۲-۴- انتخاب پارامترهای بهینه طبقه‌بندی-کننده‌های SVM و SVDD

با توجه به زمانبر بودن فرآیند انتخاب پارامترهای کرنل در طبقه‌بندی کننده SVDD، مانند روش جستجوی شبکه‌ای، در این پژوهش از روش مبتنی بر فاصله بین کلاسی در فضای ویژگی، جهت انتخاب پارامتر بهینه کرنل استفاده شده است. در این روش، از یک معیار جداسازی جهت برآورد میزان جدایی بین دو کلاس در فضای ویژگی استفاده می‌شود.



شکل ۴- ارتباط بین موقعیت قرارگیری نمونه‌های آموزشی مربوط به هر کلاس و موقعیت میانگین آن کلاس

به ازای انتخاب پارامتر کرنلی که مقدار فاصله بین کلاسی بزرگتری را بدست بدهد، آن پارامتر به عنوان

شد. موقعیت جغرافیایی منطقه مورد مطالعه در شکل (۵) نشان داده شد.


جهت بررسی دقت و کارایی الگوریتم پیشنهادی در استخراج مناطق سیل زده، این الگوریتم بر روی تصاویر چندزمانه نوری ماهواره سنتینل-۲ و تصاویر چندزمانه راداری سنتینل-۱ اخذ شده در تاریخ‌های قبل و بعد از وقوع سیل در شهرستان شوش در تاریخ ۲۶ فروردین‌ماه ۱۳۹۵ اعمال شد. قدرت تفکیک مکانی تصاویر نوری ماهواره سنتینل ۲، ۱۰، ۲۰ و ۶۰ متری و در ۱۳ باند طیفی و قدرت تفکیک مکانی تصاویر راداری ماهواره سنتینل ۱، ۲۰*۵ متری و در باند C است. تاریخ اخذ تصاویر ماهواره‌های سنتینل-۱ و ۲ و مشخصات طیفی و مکانی ویژگی‌های مورد استفاده جهت استخراج مناطق سیل زده در جدول (۱) نشان داده شده است.

جدول ۱- تاریخ اخذ تصاویر ماهواره‌های سنتینل ۱ و ۲ و مشخصات طیفی و مکانی ویژگی‌های مورد استفاده

تصاویر	تاریخ اخذ قبل از وقوع سیل	تاریخ اخذ بعد از وقوع سیل	قدرت تفکیک طیفی	قدرت تفکیک مکانی (m)
سنتینل-۱	۱۷ فروردین ۱۳۹۵	۲۸ فروردین ۱۳۹۵	۱۳ باند (از طول موج مرئی تا مادون قرمز کوتاه)	۱۰-۲۰- ۶۰
سنتینل-۲	۲۰ فروردین ۱۳۹۵	۳۰ فروردین ۱۳۹۵	باند C پلاریزه VV	۲۰

بعد از وقوع سیل انجام شد تا تغییری از این منظر در نقشه‌های تغییرات بوجود نیاید. لذا با توجه به فرضیات مذکور می‌توان اختلاف زمانی ۲ تا ۳ روز بین اخذ تصاویر راداری و نوری را نادیده گرفت.

نمایش ترکیب رنگی واقعی از تصاویر چندزمانه ماهواره سنتینل ۲ اخذ شده در زمان‌های قبل و بعد از وقوع سیل در شهرستان شوش به ترتیب در شکل‌های (۶-الف)، (۶-ب) نشان داده شده است. تصاویر مقادیر سیگمانات^۲ (انرژی بازگشتی) عوارض در واحد دسیبل مربوط به تصاویر راداری ماهواره سنتینل-۱ اخذ شده در زمان‌های قبل و بعد از وقوع سیل در شهرستان شوش به ترتیب در شکل‌های (۷-الف)، (۷-ب) نشان داده شده است.




شکل ۵- موقعیت جغرافیایی وقوع سیل در شهرستان شوش


الگوریتم پیشنهادی در یک زیر صحنه^۱ از تصاویر اصلی با ابعاد ۲۰۷۴×۳۵۹۵ پیکسل اجرا شد. علت انتخاب این منطقه به عنوان منطقه مورد مطالعه، وجود تنوع زیاد در کلاس‌های پوششی موجود در این منطقه و ایجاد قابلیت بررسی کارایی روش پیشنهادی در استخراج انواع کلاس‌های تغییر ناشی از وقوع سیل در منطقه بود. از آنجاییکه هدف، کشف تغییرات کاربری ناشی از وقوع سیل است و با فرض اینکه تغییرات به جای مانده از این حادثه طبیعی طی چند روز، دستخوش تغییر چندانی نمی‌شود. همچنین تصاویر نوری به نحوی انتخاب شدند که شرایط اتمسفری تغییر چندانی نداشته و حاوی ابر و برف نیستند و تصحیحات اتمسفری و رادیومتریکی روی تصاویر قبل و

^۲ Sigma0

^۱ Subscene



شکل ۶- ب- نمایش ترکیب رنگی واقعی از تصویر ماهواره سنتینل ۲ بعد از وقوع سیل در تاریخ ۳۰ فروردین ۱۳۹۵



شکل ۶- الف- نمایش ترکیب رنگی واقعی از تصویر ماهواره سنتینل ۲ قبل از وقوع سیل در تاریخ ۲۰ فروردین ۱۳۹۵



شکل ۷- ب- نمایش تصویر سیگمانات از ماهواره سنتینل ۱- بعد از وقوع سیل در تاریخ ۲۸ فروردین ۱۳۹۵




شکل ۷- الف- نمایش تصویر سیگمانات از ماهواره سنتینل ۱- قبل از وقوع سیل در تاریخ ۱۷ فروردین ۱۳۹۵

۳-۲- نتایج تجربی

۳-۲-۱- ارزیابی دقت الگوریتم پیشنهادی کشف تغییرات

در الگوریتم کشف تغییرات شیء‌گرای پیشنهادی، با استفاده از طبقه‌بندی‌کننده شیء‌گرا، تصویر قبل از وقوع سیل قطعه‌بندی و سپس طبقه‌بندی گردید. پارامترهای قطعه‌بندی بصورت آزمون و خطا و با در داشتن اطلاعات کسب شده از تصاویر Google Earth در خصوص تعداد


کلاس‌های غالب منطقه مورد مطالعه انجام شد. برای طبقه‌بندی شیء‌گرا نظارت شده تصویر قبل از وقوع سیل، نمونه‌های آموزشی با استفاده از تفسیر بصری تصاویر گوگل-ارث جمع‌آوری شد. نقشه طبقه‌بندی تصویر قبل از وقوع سیل با کمک روش مبتنی بر ماشین‌های بردار پشتیبان شیء‌گرا در شکل (۸) نشان داده شده است. ارزیابی دقت نقشه طبقه‌بندی مربوط به تصویر قبل از وقوع سیل با کمک نمونه‌های آزمایشی، نشان دهنده دقت کلی ۹۱٪ و ضریب کاپا ۰٫۸۹ است.



شکل ۹- نقشه مناطق سیل زده با استفاده از روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل گوسین و تصاویر تلفیق شده راداری و نوری

شیء‌گرا و ارزیابی دقت نقشه تغییرات علاوه بر دو معیار فوق از معیار سطح زیر منحنی ROC^۳ نیز استفاده شد. این معیار با نام اختصاری AUC نیز شناخته می‌شود. از آنجاییکه در مرحله پایانی روش پیشنهادی کشف تغییرات از یک روش طبقه‌بندی‌کننده تک کلاسه برای تولید نقشه تغییرات استفاده می‌گردد، لذا از این معیارها برای ارزیابی دقت الگوریتم پیشنهادی استفاده شد.

^۳ Area Under Receiver Operating Characteristic (AUC)



شکل ۸- نقشه طبقه‌بندی شده تصویر تلفیق شده راداری و نوری قبل از وقوع سیل با کمک روش مبتنی بر ماشین‌های بردار پشتیبان شیء‌گرا

جهت ارزیابی دقت الگوریتم کشف تغییرات پیشنهادی، نمونه‌های آزمایشی مربوط به کلاس تغییر یافته (۸۱۳۲۰ پیکسل) و کلاس بدون تغییر (۶۳۷۷۵ پیکسل) بصورت بصری از تصاویر گوگل-ارث مربوط به قبل و بعد از وقوع سیل انتخاب گردید. از دو معیار ضریب کاپا^۱ و دقت کلی^۲ برای نمایش دقت روش طبقه‌بندی

^۱ Kappa Coefficient

^۲ Overall Accuracy

در حالت استفاده از تصاویر تلفیق شده سنتینل-۱ و ۲، آنالیز دقت روش کشف تغییرات پیشنهادی نشان داد که بهترین نتیجه مربوط به استفاده از کرنل گوسین است و کرنل‌های خطی و چندجمله‌ای و سیگموید در درجات بعدی از لحاظ دقت قرار دارند. بنابراین می‌توان نتیجه گرفت، برای این مجموعه داده تلفیق شده راداری و اپتیک، مرز جداسازی بین کلاس‌های تغییر یافته و بدون تغییر، نزدیک به یک تابع گوسین با پهنای باند ۲،۲۰ و نزدیک به حالت خطی است. چرا که با افزایش پهنای باند هسته گوسین، کرنل گوسین به کرنل خطی نزدیک می‌شود. بالا بودن دقت روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل‌های خطی و چندجمله‌ای با درجه پایین (درجه ۱) نیز موید همین مسئله است. بنابراین کرنل‌های با ماهیت خطی، انتخاب بهتری در این روش و برای این مجموعه داده می‌باشد.

جدول ۳- دقت روش کشف تغییرات پیشنهادی، در حالت استفاده از کرنل‌های مختلف در طبقه‌بندی کننده تک کلاسه SVDD و برای

تصاویر نوری

نوع کرنل	تصاویر سنتینل-۲		
	کاپا (/)	دقت کلی	AUC
خطی	۰.۸۵	۸۷.۹۲	۰.۸۹
چندجمله‌ای (درجه ۱)	۰.۸۱	۸۵.۲۶	۰.۸۵
گوسین (پهنای باند ۲،۷۰)	۰.۸۷	۸۸.۱۵	۰.۹۲
سیگموید (پهنای باند ۳،۶۰)	۰.۷۸	۸۲.۳۸	۰.۸۲

در حالت استفاده از تصاویر نوری سنتینل-۲ به تنهایی، آنالیز دقت روش کشف تغییرات پیشنهادی نشان داد که در این حالت نیز بهترین نتیجه مربوط به استفاده از کرنل گوسین است و کرنل‌های خطی و چندجمله‌ای و سیگموید در درجات بعدی از لحاظ دقت قرار دارند. بنابراین می‌توان نتیجه گرفت، برای این مجموعه داده و در حالت استفاده از تصاویر نوری به تنهایی، مرز جداسازی بین کلاس‌های تغییر یافته و بدون تغییر، نزدیک به یک تابع گوسین با پهنای باند ۲،۲۰ و نزدیک به حالت خطی است. چرا که با افزایش پهنای باند هسته گوسین، کرنل گوسین به کرنل خطی نزدیک می‌شود. نزدیک بودن دقت روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل‌های خطی و چندجمله‌ای با درجه پایین (درجه ۱) نیز موید همین مسئله است. بنابراین کرنل‌های با ماهیت خطی، انتخاب بهتری در این روش و برای این مجموعه

با هدف افزایش دقت نقشه طبقه‌بندی تصویر قبل از وقوع سیل و همچنین افزایش دقت نقشه تغییرات، از تلفیق ویژگی‌های مبتنی بر شاخص پوشش گیاهی و باندهای طیفی حاصل از تصاویر نوری سنتینل-۲ و تصویر سیگمانات حاصل از تصاویر راداری سنتینل-۱ در نظر گرفته و به عنوان ورودی به الگوریتم طبقه‌بندی و کشف تغییرات پیشنهادی وارد شده و نتایج حاصل از آن مورد تجزیه و تحلیل قرار گرفته است. ویژگی‌های پیشنهادی با استفاده از یک روش انتخاب ویژگی مبتنی بر فیلتر^۱ (آنالیز همبستگی^۲) انتخاب شدند. ویژگی‌های منتخب حاصل از تصاویر نوری و راداری شامل باندهای طیفی مرئی، مادون قرمز نزدیک (NIR)، لبه قرمز (Red Edge) و مادون قرمز کوتاه (SWIR) و شاخص تفاضلی پوشش گیاهی یکنواخت شده (NDVI) و ویژگی منتخب حاصل از تصاویر راداری شامل ویژگی سیگمانات است. این ویژگی‌ها به گونه‌ای انتخاب شده‌اند که حتی‌الامکان بتوانند نماینده مناسبی برای کلاس‌های پوششی موجود در منطقه مورد مطالعه باشند. برای ارزیابی بهبود دقت و کارایی الگوریتم پیشنهادی ناشی از تلفیق داده‌های راداری و نوری، ارزیابی دقت الگوریتم در دو حالت استفاده از تلفیق داده‌های راداری و نوری و داده نوری به تنهایی انجام شد. در جداول (۲) و (۳)، به ترتیب دقت روش کشف تغییرات شیء‌گرا و کرنل‌پایه پیشنهادی، برای تصاویر تلفیق شده و جداگانه راداری و نوری مربوط به ماهواره سنتینل-۱ و ۲، در حالت استفاده از کرنل‌های خطی، چندجمله‌ای، گوسین و سیگموید مورد آنالیز قرار گرفته است. لازم به ذکر است که دقت‌های ارائه شده حاصل از اعمال الگوریتم کرنل پایه پیشنهادی با انتخاب بهینه پارامتر کرنل می‌باشد.

جدول ۲- دقت روش کشف تغییرات پیشنهادی، در حالت استفاده از کرنل‌های مختلف در طبقه‌بندی کننده تک کلاسه SVDD و برای تصاویر راداری و نوری تلفیق شده

نوع کرنل	تلفیق تصاویر سنتینل-۱ و ۲		
	کاپا	دقت کلی	AUC
خطی	۰.۹۰	۹۳.۱۵	۰.۹۵
چندجمله‌ای (درجه ۱)	۰.۸۷	۹۱.۵۲	۰.۹۲
گوسین (پهنای باند ۲،۲۰)	۰.۹۳	۹۴.۲۴	۰.۹۸
سیگموید (پهنای باند ۳،۱۰)	۰.۸۴	۸۸.۶۷	۰.۸۹

1 Filter based Feature Selection
2 Correlation Analysis

داده می‌باشد. با مقایسه نتایج بدست آمده در جداول (۲) و (۳) نشان می‌دهد که استفاده از تصاویر راداری و نوری تلفیق شده، نسبت به استفاده تنها از تصاویر نوری، منجر به دستیابی به دقت بالاتری در نقشه تغییرات ناشی از وقوع سیل می‌شود.

پس از وقوع سیل در یک منطقه، بسته به میزان نفوذپذیری آب در خاک، میزان رطوبت موجود در خاک به میزان زیادی افزایش می‌یابد. در نقاطی که میزان نفوذپذیری کم است، پهنه آبی ایجاد شده و امواج راداری ساطع شده از سوی سنجنده به این مناطق، بصورت آینه-ای عمل نموده و مقدار پس پراکنش در این نواحی به صفر نزدیک خواهد بود. در مناطقی که میزان نفوذپذیری زیاد بوده و مقدار زبری^۱ سطح نیز کم هست، امواج راداری ساطع شده به این مناطق به میزان زیادی جذب می‌شود. لذا استفاده همزمان از امواج ماکروویو و نوری با هدف پایش مناطق سیل زده، بسیار کمک کننده بوده و دقت نقشه تغییرات تولید شده افزایش می‌یابد.


در شکل‌های (۹)، (۱۰) و (۱۱) نقشه مناطق سیل زده حاصل از اعمال روش پیشنهادی کشف تغییرات بر روی تصاویر راداری و نوری تلفیق شده نشان داده شده است. همانطور که مشاهده می‌شود، سطح نویز در نقشه‌های کشف تغییرات تولید شده بسیار پایین بوده و الگوریتم پیشنهادی کرنل پایه و شیء گرا بصورت کاملاً هدفمند مناطق سیل زده را از سایر مناطق جدا نموده است. علت این امر در استفاده از نقشه طبقه‌بندی شده شیء‌گرایی قبل از وقوع سیل است. چرا که برخلاف روش‌های مرسوم کشف تغییرات که در فضای کل تصویر و در سطح پیکسل به دنبال تغییر هستند، در این الگوریتم، فضای جستجو به هر یک از قطعات تصویر محدود شده و سطح نویز به میزان زیادی کاهش می‌یابد.

لازم به ذکر است که انتخاب نوع کرنل مناسب جهت انتقال داده‌ها از فضای اولیه طیف به فضای ویژگی با بعد بالاتر جهت جداسازی بهتر کلاس‌های تغییر بسیار تاثیر گذار است. انتخاب نوع کرنل به ماهیت مرز جداسازی بین کلاس‌های تغییر برمی‌گردد. به عنوان مثال در نقشه کشف تغییرات بدست آمده در حالت استفاده از کرنل چند جمله‌ای درجه ۱ (شکل ۱۱)، علاوه بر مناطق سیل زده،

در برخی از مناطق کشاورزی و زمین‌های بایر نیز تغییر تشخیص داده شده است که اشتباه است.


جهت بررسی کیفی تاثیر تلفیق داده‌های راداری و اپتیک در نقشه کشف تغییرات تولید شده، نتایج مربوط به استفاده از تصاویر راداری و نوری به تنهایی در شکل‌های (۱۲) و (۱۳) نشان داده شده است. همانطور که در شکل (۱۲) دیده می‌شود، در حالت استفاده از داده نوری به تنهایی، مناطق سیل زده به طور کامل تشخیص داده نشده است و علت این امر عدم توانایی داده‌های نوری به تنهایی در جداسازی مناطق سیل زده از سایر مناطق است.

از طرفی دیگر، استفاده تنها از داده‌های راداری (شکل (۱۳)) برای کشف مناطق سیل زده، با توجه به پیچیدگی منطقه و نزدیکی طیفی کلاس‌های تغییر و محدودیت اطلاعات ورودی به الگوریتم پیشنهادی، منجر به عدم توانایی تشخیص تمامی مناطق سیل زده و همچنین تشخیص اشتباه مناطق سیل زده در برخی از مناطق کشاورزی و زمین‌های بایر شده است.



شکل ۱۰- نقشه مناطق سیل زده با استفاده از روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل خطی و تصاویر تلفیق شده راداری و نوری

^۱ Roughness



شکل ۱۳- نقشه مناطق سیل زده با استفاده از روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل گوسین و تصاویر چندزمانه راداری


۳-۲-۲- ارزیابی مقایسه‌ای با روش‌های نوین و متداول کشف تغییرات

با هدف ارزیابی دقت مقایسه‌ای با سایر روش‌های کشف تغییرات، روش‌های متداول کشف تغییرات مانند روش تبدیل مولفه اصلی^۱ PCA، نگارنده زاویه طیفی^۲ (SAM) و روش نوین تشخیص تغییرات چند متغیره وزن-دهی شده تکراری^۳ (IR-MAD) بر روی تصاویر تلفیق شده راداری و نوری پیاده‌سازی شده و نتایج آن با نتایج حاصل از روش کشف تغییرات مبتنی بر کرنل و شیء‌گرایی پیشنهادی مقایسه شدند. نتایج مربوط به این آنالیز دقت در جدول (۴) ارائه شده است.


^۱ Principal Component Analysis

^۲ Spectral Angle Mapper

^۳ Iteratively Reweighted-Multivariate Alteration Detection



شکل ۱۱- نقشه مناطق سیل زده با استفاده از روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل چند جمله‌ای درجه ۱ و تصاویر تلفیق شده راداری و نوری




شکل ۱۲- نقشه مناطق سیل زده با استفاده از روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل گوسین و تصاویر چندزمانه نوری


جدول ۴- آنالیز مقایسه‌ای دقت روش کشف تغییرات پیشنهادی و روش‌های کشف تغییرات متداول برای تصاویر راداری و نوری تلفیق شده

روش کشف تغییرات	تلفیق تصاویر سنتینل-۱ و ۲		
	کاپا	دقت کلی	AUC
نگارنده زاویه طیفی	۰,۷۸	۸۰,۶۷	۰,۸۲
تبدیل مولفه اصلی	۰,۷۴	۷۷,۸۹	۰,۷۸
تشخیص تغییرات چند متغیره وزن‌دهی شده تکراری	۰,۸۳	۸۵,۱۰	۰,۸۷
روش پیشنهادی (کرنل گوسین)	۰,۹۳	۹۴,۲۴	۰,۹۸

مقایسه نتایج بدست آمده از روش‌های متداول و نوین کشف تغییرات و روش پیشنهادی کرنل پایه حاکی از دقت و کارایی بالای روش پیشنهادی است. کارایی و دقت روش‌های متداول کشف تغییرات، به علت وابستگی زیاد این روش‌ها به کاربر جهت انتخاب حدآستانه و همچنین یک بعدی بودن فرآیند جداسازی کلاس‌های تغییر یافته از کلاس‌های بدون تغییر، نسبت به روش پیشنهادی کمتر است. نتایج مربوط به بررسی کیفی و مقایسه‌ای نقشه‌های کشف تغییرات بدست آمده از روش‌های نوین IR-MAD و متداول SAM نسبت به روش پیشنهادی، در شکل‌های (۱۴) و (۱۵) نشان داده شده است.



شکل ۱۵- نقشه مناطق سیل زده با استفاده از روش کشف تغییرات SAM برای تصاویر تلفیق شده راداری و نوری



شکل ۱۴- نقشه مناطق سیل زده با استفاده از روش کشف تغییرات IR-MAD برای تصاویر تلفیق شده راداری و نوری

با هدف بررسی میزان شدت تغییرات رخ داده در منطقه مورد مطالعه ناشی از وقوع سیل، پس از تولید نقشه تغییرات و ماسک مناطق تغییر یافته، مقادیر اندازه بردار تغییر (CVM)^۱ بین تصاویر قبل و بعد از وقوع تغییر

همانطور که در شکل‌های (۱۴) و (۱۵) دیده می‌شود، در نقشه کشف تغییرات بدست آمده از روش‌های نوین IR-MAD و متداول SAM، سطح نویز بالا بوده و علاوه بر مناطق سیل زده، در برخی از مناطق کشاورزی و زمین‌های بایر نیز تغییر تشخیص داده شده است که اشتباه است.

^۱ Change Vector Magnitude

مطالعه و در هنگام وقوع سیل، کلیه کاربری‌های متأثر از سیل به زمین بایر و یا مناطق سیلابی تبدیل می‌شوند و به دلیل محدود بودن کلاس‌های تغییر، صرفاً به تولید نقشه تغییر و عدم تغییر بسنده شد. بنابراین الگوریتم پیشنهادی قابلیت تولید نقشه From-To را نیز خواهد داشت.


۴- نتیجه‌گیری

در این پژوهش یک روش کشف تغییرات نیمه نظارت شده مبتنی بر کرنل و شیء‌گرا با استفاده همزمان از تصاویر راداری و نوری ماهواره سنتیل-۱ و ۲ در دوره‌های زمانی مختلف پیشنهاد شد. با توجه به اینکه تمامی بخش‌های مختلف الگوریتم پیشنهادی کشف تغییرات شامل مرحله پیش پردازش، فرآیند قطعه‌بندی تصاویر، تخمین پارامترهای طبقه‌بندی کننده SVM و SVDD و تعیین تابع تصمیم‌گیری و تولید نقشه تغییرات بصورت خودکار و بدون نظارت است و صرفاً فرآیند برچسب گذاری نقشه قطعه‌بندی به کمک روش SVM بصورت نظارت شده انجام می‌شود، لذا الگوریتم پیشنهادی بصورت نیمه نظارت شده معرفی گردید. لازم به توضیح است، در صورتیکه فرآیند برچسب گذاری نقشه قطعه‌بندی به کمک روش SVM انجام نشود و صرفاً از نقشه قطعه‌بندی شده به عنوان ورودی به بخش تولید نقشه تغییرات استفاده شود، در این حالت نیز، الگوریتم پیشنهادی قادر به تولید نقشه تغییرات خواهد بود.

جهت تلفیق تصاویر راداری و نوری، یک روش تلفیق مبتنی بر کرنل ارائه شده است. این روش بر روی داده چندطیفی ماهواره سنتیل-۱ و ۲ مربوط به قبل و بعد از وقوع سیل در شهرستان شوش پیاده‌سازی و مورد ارزیابی دقت قرار گرفت. نتایج بدست آمده حاکی از کارایی و دقت بالای الگوریتم پیشنهادی در کشف تغییرات ناشی از وقوع بلایای طبیعی (سیل) با وجود کلاس‌های طیفی پیچیده و نزدیک به هم از لحاظ طیفی است. استفاده از روش پیشنهادی کرنل پایه و شیء‌گرا و تلفیق داده‌های راداری و نوری، با ارائه یک روش غیر خطی، مسئله کشف تغییرات در مناطق با کلاس‌های طیفی پیچیده و دارای مرز جداسازی غیر خطی را حل نموده است.

در الگوریتم کشف تغییرات کرنل پایه پیشنهادی، با توجه به ماهیت کلاس‌های طیفی موجود در منطقه مورد

محاسبه گردید. در شکل (۱۶) نقشه اندازه بردار تغییر طبقه‌بندی شده به عنوان شدت تغییرات در مناطق سیل زده با استفاده از ماسک مناطق تغییر یافته با روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل گوسین و تصاویر تلفیق شده راداری و نوری نشان داده شده است. رنگ سبز مربوط به مناطق با شدت تغییرات کم و رنگ قرمز مربوط به شدت تغییرات زیاد است.



شکل ۱۶- نقشه شدت تغییرات مناطق سیل زده با استفاده از روش کشف تغییرات پیشنهادی در حالت استفاده از کرنل گوسین و تصاویر تلفیق شده راداری و نوری

همانطور که در شکل (۱۶) دیده می‌شود، غالب تغییرات با شدت بالا در مناطق کشاورزی اتفاق افتاده است.

با توجه به اینکه در الگوریتم پیشنهادی تغییرات در سطح قطعه بررسی می‌شوند، لذا با مقایسه امضاء طیفی پیکسل-های متناظر در تصویر بعد از وقوع تغییر با هریک از امضاءهای طیفی موجود در تصویر قبل از وقوع تغییر با کمک یک روش اندازه گیری شباهت مانند SAM، می‌توان کلاس پیکسل‌های تغییر را مشخص نمود و به اطلاعات From-To دست یافت. منتهی به دلیل اینکه در مورد منطقه مورد

مطالعه و میزان پیچیدگی طیفی آنها، تابع کرنل مناسب را انتخاب نمود. دقت الگوریتم کشف تغییرات پیشنهادی با استفاده همزمان از تصاویر نوری و راداری به میزان قابل توجهی افزایش پیدا نمود. مقایسه نتایج بدست آمده از روش‌های متداول و نوین کشف تغییرات و روش پیشنهادی حاکی از دقت و کارایی بالای روش پیشنهادی است. علت این امر آنست که در روش‌های متداول کشف تغییرات تنها بر اطلاعات یک بعدی تغییر مانند اندازه بردار تغییر تکیه شده و فضای عملکرد این روش‌ها در سطح پیکسل است. این درحالیست که در روش کشف تغییرات شیء‌گرای پیشنهادی، فضای جستجو به هر یک از قطعات تصویر محدود شده و سطح نویز به میزان زیادی کاهش می‌یابد.

مراجع

از مزایای این روش این است که با توجه به شی‌گرا بودن الگوریتم پیشنهادی، کمترین تاثیر را از شرایط اتمسفری و هندسی می‌پذیرد. همچنین در روش پیشنهادی تنها برای تولید نقشه طبقه‌بندی قبل از وقوع تغییر نیاز به نمونه‌های آموزشی محدود داریم. چراکه هم از روش طبقه‌بندی SVM با کمترین نیاز به نمونه‌های آموزشی استفاده شده است و با توجه به اینکه از روش قطعه‌بندی استفاده شده است، لذا صرفاً برای فرآیند برچسب گذاری از این داده‌های آموزشی استفاده می‌شود. از طرفی دیگر، از آنجائیکه تغییرات در سطح قطعه بررسی می‌شوند، می‌توان به طور کاملاً نظارت نشده الگوریتم را اجرا کرد و به نقشه‌های کشف تغییرات دست یافت.

- [1] A. Vetrivel, M. Gerke, N. Kerle, F. Nex, G. Vosselman, "Disaster damage detection through synergistic use of deep learning and 3D point cloud features derived from very high resolution oblique aerial images, and multiple-kernel-learning," ISPRS J. Photogramm. Remote Sens., 2017.
- [2] E. Skoufias, E. Strobl, T. B. Tveit, "Natural disaster damage indices based on remotely sensed data: an application to Indonesia," 2017.
- [3] B. E. Montz, G. A. Tobin, R. R. Hagelman, Natural hazards: explanation and integration. Guilford Publications, 2017.
- [4] J. Gaillard, "Natural Hazards and Disasters," Int. Encycl. Geogr., 2017.
- [5] G. M. Afrasinei, M. T. Melis, C. Buttau, J. M. Bradd, C. Arras, G. Ghiglieri, "Assessment of remote sensing-based classification methods for change detection of salt-affected areas (Biskra area, Algeria)," J. Appl. Remote Sens., 2017.
- [6] T. Leichtle, C. Geiß, M. Wurm, T. Lakes, H. Taubenböck, "Unsupervised change detection in VHR remote sensing imagery—an object-based clustering approach in a dynamic urban environment," Int. J. Appl. Earth Obs. Geoinformation, 2017.
- [7] J. Chen, P. Gong, C. He, R. Pu, P. Shi, "Land-use/land-cover change detection using improved change-vector analysis," Photogramm. Eng. Remote Sens., 2003.
- [8] R. Shah-Hosseini, S. Homayouni, A. Safari, "Environmental monitoring based on automatic change detection from remotely sensed data: kernel-based approach," J. Appl. Remote Sens., 2015.
- [9] R. Shah-Hosseini, S. Homayouni, A. Safari, "A Hybrid Kernel-Based Change Detection Method for Remotely Sensed Data in a Similarity Space," Remote Sens., 2015.
- [10] A. Paul, V. Chowdary, Y. Srivastava, D. Dutta, J. Sharma, "Change detection of linear features in temporally spaced remotely sensed images using edge-based grid analysis," Geocarto Int., 2017.
- [11] D. Peng, Y. Zhang, "Object-based change detection from satellite imagery by segmentation optimization and multi-features fusion," Int. J. Remote Sens., 2017.
- [12] W. Gu, Z. Lv, M. Hao, "Change detection method for remote sensing images based on an improved Markov random field," Multimed. Tools Appl., 2017.
- [13] P. Jian, K. Chen, C. Zhang, "A hypergraph-based context-sensitive representation technique for VHR remote-sensing image change detection," Int. J. Remote Sens., 2016.
- [14] P. Zhang, M. Gong, L. Su, J. Liu, Z. Li, "Change detection based on deep feature representation and mapping transformation for multi-spatial-resolution remote sensing images," ISPRS J. Photogramm. Remote Sens., 2016.
- [15] H. R. SHAHHOSEINI, M. ESMAEILI, A. SAFARI, S. HOMAYOUNI, J. AMINI, H. EZZATABADIPOUR, "AN AUTOMATIC ALGORITHM BASED ON ANGULAR HISTOGRAM FOR AN CORREGISTARTION OF SYNTHETIC APERTURE RADAR IMAGES," 2015.

- [16] J. Zhu, Y. Su, Q. Guo, T. C. Harmon, "Unsupervised Object-Based Differencing for Land-Cover Change Detection," *Photogramm. Eng. Remote Sens.*, 2017.
- [17] E. Bauman, K. Bauman, "One-Class Semi-Supervised Learning: Detecting Linearly Separable Class by its Mean," *ArXiv Prepr. ArXiv170500797*, 2017.
- [18] N. Longbotham et al. "Multi-Modal Change Detection, Application to the Detection of Flooded Areas: Outcome of the 2009– 2010 Data Fusion Contest," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 2012.
- [19] G. Cao, L. Zhou, Y. Li, "A new change-detection method in high-resolution remote sensing images based on a conditional random field model," *Int. J. Remote Sens.*, 2016.
- [20] R. Shah-Hoseini, A. Safari, S. Homayouni, "An Automated Kernel-based Change Detection Method in Urban Area Using Landsat Multispectral Images, Case Study: City of Karaj," *J. Geomat. Sci. Technol.*, 2016.
- [21] L. Jia, M. Li, P. Zhang, Y. Wu, L. An, W. Song, "Remote-sensing image change detection with fusion of multiple wavelet kernels," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 2016.
- [22] S. Ye, D. Chen, J. Yu, "A targeted change-detection procedure by combining change vector analysis and post-classification approach," *ISPRS J. Photogramm. Remote Sens.*, 2016.
- [23] Li, Zhe. "Reproducing Kernel Hilbert Space." 2014.
- [24] A. Bailly, L. Chapel, R. Tavenard, G. Camps-Valls, "Nonlinear Time-Series Adaptation for Land Cover Classification," *IEEE Geosci. Remote Sens. Letter*, 2017.
- [25] M. Guorui, S. Haigang, L. Pingxiang, Q. Qianqing, "A kernel change detection algorithm in remote sense imagery," 2006.
- [26] G. Camps-Valls, L. Gomez-Chova, J. Munoz-Mari, J. L. Rojo-Alvarez, M. Martinez-Ramon, "Kernel-Based Framework for Multitemporal and Multisource Remote Sensing Data Classification and Change Detection," *IEEE Trans. Geosci. Remote Sens.*, 2008.
- [27] F. Bovolo, G. Camps-Valls, L. Bruzzone, "A support vector domain method for change detection in multitemporal images," *Pattern Recognit. Letter*. 2010.
- [28] A. Belghith, C. Collet, J.-P. Armspach, "Change-detection based on support vector data description handling dependency," 2011.
- [29] M. Volpi, D. Tuia, F. Bovolo, M. Kanevski, L. Bruzzone, "Supervised change detection in VHR images using contextual information and support vector machines," *Int. J. Appl. Earth Obs. Geoinformation*, 2013.
- [30] X. Wang, J. Feng, Z. Cao, R. Min, "Polarimetric-spatial classification of PolSAR images based on composite kernel feature fusion," *Radar Conference (RadarConf)*, 2017 IEEE, 2017.
- [31] L. Ma, M. Li, X. Ma, L. Cheng, P. Du, Y. Liu, "A review of supervised object-based land-cover image classification," *ISPRS J. Photogramm. Remote Sens.*, 2017.
- [32] V. Vapnik, S. E. Golowich, A. Smola, "Support vector method for function approximation, regression estimation, and signal processing," *Advances in Neural Information Processing Systems* 9, 1996.
- [33] J. Muñoz-Marí, F. Bovolo, L. Gómez-Chova, L. Bruzzone, G. Camp-Valls, "Semisupervised One-Class Support Vector Machines for Classification of Remote Sensing Data," *IEEE Trans. Geosci. Remote Sens.*, 2010.
- [34] Z. Sun, Z. Guo, X. Wang, J. Liu, S. Liu, "Fast extended one-versus-rest multi-label SVM classification algorithm based on approximate extreme points," *International Conference on Database Systems for Advanced Applications*, 2017.
- [35] L. Gao et al. "Subspace-based support vector machines for hyperspectral image classification," *IEEE Geosci. Remote Sens. Letter*, 2015.
- [36] F. S. Uslu, H. Binol, M. Ilarslan, A. Bal, "Improving SVDD classification performance on hyperspectral images via correlation based ensemble technique," *Opt. Lasers Eng.*, 2017.
- [37] D. M. Tax, R. P. Duin, "Support vector data description," *Mach. Learn.*, 2004.
- [38] R. S. Hosseini, S. Homayouni, R. Safari, "Modified algorithm based on support vector machines for classification of hyperspectral images in a similarity space," *J. Appl. Remote Sens.*, 2012.