

ارائه یک روش خودکار کشف تغییرات مبتنی بر کرنل در مناطق شهری با استفاده از تصاویر چندطیفی ماهواره لندست، مطالعه موردی: شهر کرج

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

^۱ دانشجوی دکتری سنجش از دور-دانشکده مهندسی نقشه برداری و اطلاعات مکانی-پردیس دانشکده های فنی-دانشگاه

تهران

rshahosseini@ut.ac.ir

^۲ دانشیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی-پردیس دانشکده های فنی-دانشگاه تهران

asafari@ut.ac.ir

^۳ استادیار گروه جغرافیا-محیط زیست و ژئوماتیک-دانشگاه اتاوا-کانادا

saeid.homayouni@uottawa.ca

(تاریخ دریافت فروردین ۱۳۹۴، تاریخ تصویب آذر ۱۳۹۴)

چکیده

در چند دهه ی گذشته جمعیت شهر نشین و در نتیجه توسعه مکانی مناطق شهری شتابی فزاینده داشته است. این مهم به بروز تغییرات محیطی در این مناطق منجر شده است. از این رو، کشف تغییرات در بازه های زمانی مختلف در مناطق شهری از اهمیت بالایی برخوردار است. روش های کشف تغییرات متداول با استفاده از تصاویر سنجش از دوری، بیشتر مبتنی بر تشخیص تغییرات طیفی و محاسبه فاصله طیفی بین پیکسل ها بوده و ماهیت تغییرات بصورت خطی در نظر گرفته می شود. این درحالیست که، معمولاً تصاویر سنجش از دوری تحت تاثیر نویز و یا تغییرات رادیومتریکی هستند و در نتیجه ماهیت تغییرات می تواند به صورت غیرخطی باشد. از طرف دیگر، یکی از چالش های اصلی در تولید نقشه تغییرات در مناطق شهری، محدودیت در جداسازی طیفی زمین های ساخته شده و زمین های بایر از یکدیگر در این مناطق است. بدین منظور، در این مقاله یک روش آشکارسازی تغییرات خودکار مبتنی بر کرنل و با قابلیت استفاده همزمان از اطلاعات طیفی و شاخص های طیفی مختلف پیشنهاد شده است. در مرحله اول، شاخص های طیفی مناسب برای جداسازی کلاس های پوششی در منطقه شهری از تصاویر چندزمانه استخراج می شوند. به کمک آنالیز مولفه بردار تغییر و تعیین خودکار حد آستانه، نمونه های شبه آموزشی غیر دقیق مربوط به کلاس های تغییر یافته و بدون تغییر استخراج می شوند. به منظور محاسبه تصویر تفاضلی، دو روش تفاضلی جدید در فضای اولیه طیف و در فضای هیلبرت ارائه شد. نمونه های شبه آموزشی بدست آمده از مرحله قبل به عنوان ورودی به الگوریتم خوشه بندی وارد شده و به طور همزمان با بهینه سازی یک تابع هزینه، مقادیر دقیق پارامترهای الگوریتم خوشه بندی و نمونه های آموزشی دقیق استخراج می شوند. از نمونه های آموزشی دقیق برای آموزش طبقه بندی کننده حداقل فاصله مبتنی بر کرنل استفاده می شود. در مرحله آخر هر یک از پیکسل های مجهول به طبقه بندی کننده وارد شده و کلاس هریک از این پیکسل ها مشخص می شود. به منظور ارزیابی دقت و کارایی الگوریتم کشف تغییرات پیشنهادی، این الگوریتم بر روی تصاویر چندطیفی و چندزمانه ماهواره لندست ۵ سنجنده TM از شهر کرج مربوط به دو تاریخ ۱۳۶۶ و ۱۳۹۰ اعمال شد. به منظور آنالیز حساسیت روش پیشنهادی کشف تغییرات نسبت به نوع ویژگی های مورد استفاده، از ۵ مجموعه ویژگی مختلف به عنوان ورودی به الگوریتم استفاده شد. به منظور انجام ارزیابی مقایسه ای، دقت روش پیشنهادی مبتنی بر کرنل در دو حالت استفاده از روش تفاضلی تصاویر در فضای ورودی اولیه (DFSS) (دقت کلی: ۸۶،۴۰ و کاپا: ۰،۸۳) و روش تفاضلی تصاویر در فضای ویژگی (DFHS) (دقت کلی: ۸۵،۵۴ و کاپا: ۰،۸۲)، با روش های کشف تغییرات مبتنی بر تبدیل MNF^۱ (دقت کلی: ۷۷،۴۲ و کاپا: ۰،۷۶)، نگارنده زاویه طیفی^۲ (SAM) (دقت کلی: ۶۴،۶۰ و کاپا: ۰،۶۰) و روش تفاضلی ساده^۳ (DIFF) (دقت کلی: ۷۳،۴۴ و کاپا: ۰،۷۰) برای این ۵ مجموعه ویژگی مقایسه شد. نتایج بدست آمده نشان دهنده کارایی و دقت بالای الگوریتم پیشنهادی نسبت به روش های مرسوم کشف تغییرات و توانایی بالای آن در جداسازی انواع کلاس های طیفی در مناطق شهری است.

واژگان کلیدی: شاخص های طیفی، روش های اتوماتیک کرنل پایه، نقشه تغییرات، الگوریتم خوشه بندی، نمونه های شبه آموزشی، طبقه بندی کننده تک کلاسه، تابع هزینه، بهینه سازی

* نویسنده رابط

^۱ Minimum Noise Fraction

^۲ Spectral Angle Mapper

^۳ Simple Image Subtraction

۱- مقدمه

پدیده توسعه شهری از عوامل اصلی تغییر پوشش و کاربری اراضی است که موجب بروز مشکلات فراوانی مانند از بین رفتن زمینهای کشاورزی، آلودگی آب، فرسایش خاک و معضلات اقتصادی-اجتماعی فراوان می‌گردد. علت این امر، متمرکز شدن اغلب فعالیت‌های اقتصادی، اجتماعی، سیاسی و حمل و نقل در مناطق شهری بیان شده است [۱]. از بین رفتن فضای سبز، باغات و زمین‌های کشاورزی، آلودگی هوا، آلودگی منابع آب سطحی و زیرزمینی، تجاوز به حریم رودخانه‌ها و آبراهه‌ها در حین ساخت و ساز از جمله مهمترین و معمولترین مشکلات زیست محیطی نواحی مسکونی هستند. تغییرات کاربری زمین که معمولاً به دلیل شهرنشینی و نرخ بالای توسعه مناطق مسکونی رخ می‌دهد، منجر به ایجاد تغییر در رواناب سطحی بالا، تغییرات در دما، تغییر مسیر دفع آلاینده‌های آب و کاهش کیفیت آب خواهد شد [۲]. در برخی از موارد، ممکن است توسعه شهری منجر به ایجاد زمین‌های بایر در منطقه شهری شود. این زمین‌های بایر بر اثر تغییرات کاربری زمین ایجاد می‌شود. در مناطق شهری، اراضی با کاربری‌ها مختلف در کنار یکدیگر قرار گرفته و این کاربری‌ها با سرعت بیشتری، نسبت به سایر مناطق، در طول زمان تغییر کرده و به پوشش‌ها و کاربری‌های دیگری تبدیل شده و بدین ترتیب اهمیت زیادی در برنامه‌ریزی‌ها و مدیریت شهری دارد. بنابراین، کشف تغییرات در بازه‌های زمانی مختلف در مورد گسترش مناطق شهری از اهمیت بالایی برخوردار است [۲].

امروزه، استفاده از داده‌های ماهواره‌ای امکان بررسی و ارزیابی روند رشد و گسترش یک شهر را در طول زمان فراهم می‌کنند. 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 [۳]. استفاده از اطلاعات مکانی و تهیه نقشه‌های موضوعی لازم از زمانهای مختلف باعث یافتن مقدار، جهت و سرعت ساخت و سازهای شهری و از سویی دیگر باعث یافتن مقدار، جهت و سرعت تخریب منابع طبیعی در سالهای اخیر می‌شود. تصاویر ماهواره‌ای قادر به ارائه امکانات بالقوه برای کشف تغییرات و مدل سازی فضایی در مناطق شهری هستند. امروزه، روش‌های زیادی به منظور آشکارسازی تغییرات در

مناطق شهری 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 [۳] [۴].

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 [۵]. 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 [۶]. از آنجائیکه 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 [۷].

روش‌های آشکارسازی تغییرات بدون نظارت مبتنی بر تشخیص تغییرات طیفی، بر مبنای محاسبه فاصله طیفی بین پیکسل‌ها (روش‌های تفاضلی) و یا شباهت بین پیکسلی (روش‌های تقسیم تصاویر، ضرب داخلی تصاویر و یا همبستگی بین تصاویر) و استفاده از یک حدآستانه بمنظور جداسازی پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر عمل می‌کنند. یکی از متداول‌ترین آنالیزهای تحلیلی برای تعیین حدآستانه، آنالیز هیستوگرام نقشه تغییر است. پیکسل‌هایی که دارای تغییرات قابل ملاحظه‌ای هستند، معمولاً در انتهای منحنی توزیع هیستوگرام قرار دارند و پیکسل‌های بدون تغییر در اطراف میانگین توزیع قرار می‌گیرند [۸]. پس از تعیین حدآستانه، با مقایسه مقادیر عددی هریک از پیکسل‌ها در نقشه تغییر با حدآستانه، پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر تمیز داده

می‌شوند. با طبقه‌بندی تصویر تغییر به دست آمده بر مبنای کلاس‌های طیفی می‌توان نقشه تغییر را به دست آورد [۴]. با این حال، به دلیل وجود عوامل مختلف، استفاده از روش‌های متداول کشف تغییرات در مناطق شهری عملکرد قابل قبول ندارد. یکی از این موارد پیچیدگی میان کلاس‌های مختلف پوشش زمین در مناطق شهری است [۹]. سنجش از دور در مناطق شهری به دلیل تلفیق شدن طیفی کاربری‌های ساخته شده دست بشر و کاربری‌های طبیعی همواره با مشکلات اساسی روبرو است. از طرفی دیگر ماهیت تغییرات در روش‌های متداول کشف تغییر، بصورت خطی در نظر گرفته می‌شود و فضای پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر به صورت خطی از یکدیگر جدا می‌شوند. این در حالیست که در برخی موارد از جمله زمانی که تصاویر با نویز یا تغییرات رادیومتریکی نرمالایز نشده تخریب شوند و یا کلاس‌های طیفی در مناطق شهری با یکدیگر تلفیق شوند، ماهیت تغییرات می‌تواند به صورت غیرخطی باشد [۷]، [۱۰]. در این مقاله برای حل این مشکل و بهبود نتایج حاصل از کشف تغییرات پوشش زمین، از روش‌های کشف تغییرات مبتنی بر کرنل و استخراج شاخص‌های طیفی کارا در مناطق شهری استفاده شده است.

اخیرا استفاده از توابع کرنل توجه بسیاری از پژوهشگران مسائل کاربردی سنجش از دوری به ویژه در طبقه‌بندی و آشکارسازی تغییرات را به خود جلب کرده است [۱۱]. استفاده از توابع کرنل، برای بدست آوردن نمایشی ساده‌تر از داده‌ها، به عنوان یکی از راهکارهای افزایش دقت الگوریتم‌ها به تازگی مورد توجه زیادی قرار گرفته است. این توابع با استفاده از نگاشتی غیرخطی، داده‌ها را از فضای اولیه طیف 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 [۱۲]. ایده اصلی روش‌های مبتنی بر کرنل این است که یک تابع تصمیم‌گیری غیرخطی می‌تواند با پیاده‌سازی یک تابع تصمیم‌گیری خطی در یک فضای عارضه‌ای با ابعاد بالاتر تحقق یابد که به این فضا Reproducing Kernel Hilbert Space (RKHS) گفته می‌شود. پس می‌توان تفکیک بین کلاسی بهتر و در نتیجه دقت بالاتری را انتظار داشت [۱۳].

از طرفی دیگر، استفاده از شاخص‌های طیفی تا حد زیادی به جداسازی کلاس‌های پیچیده پوشش زمین کمک می‌کند، ولی هنوز هم جداسازی برخی از کلاس‌های پوششی از جمله کلاس‌های ساختمان و زمین‌های بایر با مشکلاتی همراه است. کارایی شاخص‌های استفاده شده در مطالعات قبلی از جمله شاخص مناطق ساخته شده نرمال شده^۱، شاخص مناطق ساخته شده جدید^۲ و اندکس تفاضلی خاک نرمال شده^۳ با تغییر موقعیت جغرافیایی از محلی به محل دیگر تغییر می‌کند [۹]. این پدیده بخصوص در مورد کلاس خاک عریان^۴ و مناطق ساخته شده^۵ کاملاً مشهود است. به عنوان مثال، ممکن است در یک منطقه خاص شاخص‌های ساختمان و خاک عریان به خوبی عمل کند ولی در منطقه دیگر به علت اختلاف واریانس پاسخ طیفی کلاس‌های خاک و مناطق ساخته شده، این شاخص‌ها ناکارآمد باشند [۱۴]. در ادامه به بررسی تحقیقات مشابه انجام شده در زمینه کشف تغییرات در مناطق شهری پرداخته شده است.

Phalke و Couloigner در سال ۲۰۰۵ به بررسی تغییرات عوارض ساخت دست بشر در منطقه شهری با استفاده تصاویر IKONOS با قدرت تفکیک مکانی بالا و تکنیک استخراج عوارض پرداخته‌اند. این تکنیک، بر اساس استخراج عوارض با استفاده از نقاط و لبه‌های مورد نظر صورت گرفته است. روش مذکور با روش PCA مقایسه شده و در نهایت به عنوان روشی کارآمدتر جهت آشکارسازی تغییرات عوارض دست ساخت خطی معرفی شده است [۱۵]. Chen و همکاران در سال ۲۰۰۶ با استفاده از چند شاخص سنجش از دور در دلتای رود مروارید چین با دقت بالایی به طبقه‌بندی در منطقه شهری پرداختند. شاخص‌های مختلفی برای طبقه‌بندی زمین‌های ساخته شده و زمین‌های بایر در مناطق شهری، مانند NDBI^۶، IBI^۷، UI^۸، BI^۹ در مطالعات مختلف استفاده شده است [۱۶]. MA Guorui و همکاران در سال ۲۰۰۶ از یک روش آشکارسازی تغییرات مبتنی بر کرنل

^۱ Normalized Built-up Index (NDBI)

^۲ New Built-up Index (NBI)

^۳ Normalized Difference Soil Index

^۴ Bare Soil

^۵ Built-up

^۶ Normalised Difference Built-Up Index

^۷ Index-based Built-Up Index

^۸ Urban Index

^۹ Bare soil index

مربوط به سال‌های ۱۳۶۶ و ۱۳۹۰ برای بررسی گسترش شهری و تولید نقشه تغییرات این شهر استفاده شد.

۲- روش پیشنهادی

۲-۱- استخراج شاخص‌های طیفی

یکی از مشکلات موجود در کشف تغییرات در مناطق شهری، مشابهت طیفی زیاد بین برخی از کلاس‌ها، از جمله کلاس‌های خاک عریان، ساختمان‌ها و جاده‌ها است. با وجود شباهت زیاد بین امضای طیفی این کلاس‌ها در مناطق شهری، احتمال بروز خطا در جداسازی بین این کلاس‌های پوشش زمینی افزایش می‌یابد. بنابراین در این مقاله، برای حل این مشکل، به ارائه برخی از شاخص‌های طیفی به منظور جداسازی انواع کلاس‌های موجود در مناطق شهری پرداخته شده است. برای جداسازی و استخراج مناطق شهری از زمین‌های بایر با استفاده از تصاویر ماهواره‌ای لندست، از شاخص‌های BRBA^۱، NDBI^۲، NBAI^۳، UI^۴ و SAVI^۵ استفاده شده است. این شاخص‌ها با روابط ریاضی زیر تعریف می‌شوند [۹]، [۱۴]، [۱۹]:

$$BRBA = \frac{band3}{band5} \quad (۱)$$

$$NDBI = \frac{band5 - band4}{band5 + band4} \quad (۲)$$

$$NBAI = \frac{band7 - \frac{band5}{band2}}{band7 + \frac{band5}{band2}} \quad (۳)$$

$$UI = \frac{band7 - band4}{band7 + band4} \quad (۴)$$

$$SAVI = \frac{(band4 - band3)(1 + I)}{band4 + band3 + 1} \quad (۵)$$

$$NDVI = \frac{band4 - band3}{band4 + band3} \quad (۶)$$

$$NDWI = \frac{band2 - band4}{band2 + band4} \quad (۷)$$

به منظور آشکارسازی تغییرات در تصاویر ماهواره‌ای استفاده کردند. در این روش، تصاویر چندزمانه با استفاده از یک تبدیل غیر خطی، به یک فضای ویژگی با بعد بالاتر تصویر می‌شود. در مرحله بعد از یک معیار اندازه‌گیری فاصله خطی بین این دو بردار ویژگی برای تولید نقشه تغییرات استفاده می‌شود. نتایج بدست آمده نشان‌دهنده دقت بالای الگوریتم پیشنهادی است [۵]. Nemmour و Chibani در سال ۲۰۰۶ به ارائه یک روش آشکارسازی تغییرات مبتنی بر SVM برای آشکارسازی توسعه شهری پرداختند. به منظور بهبود دقت نتایج در این مقاله، از دو روش Fuzzy Integral و Attractor Dynamics برای ترکیب چند طبقه‌بندی کننده SVM استفاده شد. الگوریتم پیشنهادی با روش شبکه‌های عصبی مقایسه شد و نتایج موید دقت و کارایی روش پیشنهادی بود [۱۷]. F. Bovolo و همکارانش در سال ۲۰۱۰ از یک الگوریتم طبقه‌بندی تک کلاسه مبتنی بر کرنل به منظور جداسازی پیکسل‌های تغییر یافته از پیکسل‌های بدون تغییر استفاده 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 است [۱۸].

بطور کلی استفاده از تصاویر سنجش از دوری با رزولوشن مکانی بالا، نتایج بهتری در جداسازی کلاس‌ها در مناطق شهری و تهیه نقشه تغییرات این مناطق بدست می‌دهد. علت این امر بالا بودن دقت مکانی و غلبه بر پیچیدگی فضایی کلاس‌های موجود در مناطق شهری مانند ساختمان‌ها، جاده‌ها، باند فرودگاه، پوشش گیاهی، بتن، آسفالت و خاک است. در حالیکه در تصاویر با دقت مکانی متوسط و پایین، کلاس‌های مختلف موجود در یک منطقه کوچک شهری، با یکدیگر ترکیب می‌شوند [۱۴]. از آنجاییکه تهیه تصاویر با دقت مکانی بالا، برای تهیه نقشه تغییرات هزینه‌بر است، در این مقاله به امکان‌سنجی استفاده از چند شاخص طیفی جدید در الگوریتم پیشنهادی کشف تغییرات مبتنی بر کرنل، به منظور افزایش جدایی‌پذیری طیفی کلاس‌ها در مناطق شهری با استفاده از تصاویر ماهواره لندست پرداخته شده است. الگوریتم پیشنهادی بر روی تصاویر چندطیفی ماهواره لندست ۵ سنجنده TM اعمال شد. از تصاویر شهر کرج

^۱ Band Ratio for Built-up Area

^۲ Normalized Difference Built-up Index

^۳ Normalized Built-up Area Index


^۴ Urban Index

^۵ Soil Adjusted Vegetation Index

نرمالایز شده آب (NDWI) استفاده شد. این شاخص بازتاب آب در طول موج مرئی سبز را بیشینه و بازتاب آن را در طول موج مادون قرمز نزدیک کمینه می‌کند. در نتیجه با استفاده از این شاخص، کلاس آب از کلاس‌های گیاه و خاک متمایز می‌شود، زیرا مقدار این شاخص برای کلاس آب مثبت و مقدار آن برای کلاس‌های گیاه و خاک صفر یا منفی می‌شود [۱۴].

۲-۲- استخراج خودکار نمونه‌های شبه آموزشی

در این مقاله جهت استخراج نمونه‌های شبه آموزشی مربوط به کلاس‌های تغییر یافته و بدون تغییر، از روش آنالیز مولفه‌های بردار تغییر استفاده شد. فرض می‌کنیم که $X^{(t_1)} \in \mathbb{R}^d$ و $X^{(t_2)} \in \mathbb{R}^d$ دو تصویر با ابعاد $n \times d$ (n پیکسل و d باند طیفی) اخذ شده در دو تاریخ t_1 و t_2 بوده که نسبت به یکدیگر ثبت هندسی شده و تصحیح رادیومتریکی شده‌اند. بزرگی بردار l_۲ امین پیکسل در تصویر تفاضلی d بعدی $D = X^{(t_2)} - X^{(t_1)}$ با استفاده از نرم l_2 از رابطه $\delta_i = \|D_i\|_2 = (D_{i1}^2 + D_{i2}^2 + \dots + D_{id}^2)^{1/2}$ به دست می‌آید (شکل ۱). در این فضای جدید مقادیر نزدیک به صفر متناظر با پیکسل‌های بدون تغییر بوده، در حالیکه مقادیر بزرگتر از یک حد آستانه مشخص متناظر با پیکسل‌های تغییر یافته می‌باشند [۲۰]. این توزیع با استفاده از تابع توزیع Bimodal Gaussian Mixture و با الگوریتم Maximization Expectation مدل می‌شود. در شکل (۲) توزیع گوسی شکل بزرگی بردار تغییرات مربوط به کلاس‌های تغییر یافته و بدون تغییر نشان داده شده است. مناطق مترامی که در بین این دو مرز قرار می‌گیرند، متناسب با انحراف معیار بوده و به عنوان نمونه‌های شبه آموزشی در نظر گرفته می‌شوند. سایر مناطق (متاثر از نویز و داده‌های پرت) که در انتهای منحنی توزیع بزرگی تغییر قرار می‌گیرند، در نظر گرفته نمی‌شوند [۲۱]، [۱۰]. در شکل (۲) نمایی از چگونگی عملکرد این روش نشان داده شده است.




شکل ۱- نمایی از چگونگی عملکرد روش آنالیز مولفه‌های بردار تغییر [۲۲]

در رابطه (۵)، ۱ پارامتریست که از مقدار ۰ برای تراکم خیلی زیاد تا مقدار ۱ برای تراکم خیلی کم پوشش گیاهی نوسان می‌کند. شاخص‌های NDBI و UI برای نمایش مناطق ساختمانی و شاخص NDVI برای توصیف پوشش گیاهی مناسب می‌باشند. در شاخص طیفی NDBI، مقادیر مثبت حاصل از تفریق باند مادون قرمز نزدیک از باند مادون قرمز کوتاه، نمایانگر مناطق شهری و مقادیر منفی آن نمایانگر پوشش گیاهی می‌باشند [۹]. مطالعات نشان می‌دهد استفاده از باندهای طیفی مادون قرمز نزدیک از باند مادون قرمز کوتاه ماهواره لندست، برای جدایی کلاس زمین بایر از کلاس‌های ساختمان و پوشش گیاهی مناسب است. پوشش گیاهی بازتاب بالایی در باند مادون قرمز نزدیک دارد، اما بازتاب مناطق ساختمانی و بایر در باند مادون قرمز نزدیک پایین است. از تفاوت بازتاب در این دو بازه طیفی می‌توان برای تمایز مناطق ساختمانی و پوشش گیاهی استفاده کرد. از شاخص‌های UI و NDBI به تنهایی نمی‌توان به ترتیب برای استخراج زمین بایر و مناطق ساختمانی استفاده کرد. بنابراین در این مقاله به استفاده همزمان از این شاخص‌ها و باندهای طیفی استفاده می‌شود [۱۴].

در این مقاله، از شاخص‌های گیاهی مختلف مبتنی بر نسبت باند مادون قرمز نزدیک بر باند قرمز بمنظور استخراج کلاس پوشش گیاهی استفاده شده است. علت انتخاب این دو باند، بازتاب بالای گیاه در محدوده طیفی مادون قرمز نزدیک و جذب زیاد رنگدانه‌ها در باند قرمز است. استفاده از شاخص طیفی SAVI بر شاخص NDVI جهت استخراج پوشش گیاهی در مناطق شهری با پوشش گیاهی توصیه شده است. علت این امر آنست که شاخص SAVI در منطقه‌ای با ۱۵ درصد پوشش گیاهی قابلیت کاربر دارد، در حالیکه شاخص NDVI می‌تواند تنها در منطقه‌ای با بیش از ۳۰ درصد پوشش گیاهی بکار برده شود [۱۹]. شاخص SAVI در استخراج پوشش گیاهی مناطقی با ترکم کم، به علت افزایش محدوده دینامیکی داده‌ای تصویر، بسیار حساس‌تر از NDVI است. استفاده از این شاخص، می‌تواند تمایز کلاس پوشش گیاهی از کلاس زمین ساخته شده یا آب را ساده‌تر کند. تفاوت شاخص NDVI بین گیاه و زمین ساخته شده ۰٫۶۱ است، در حالیکه تفاوت شاخص SAVI بین این دو کلاس ۰٫۹۲ است [۹].

در این مقاله برای استخراج کلاس آب از سایر کلاس‌های موجود در منطقه شهری مورد مطالعه، از شاخص تفاضلی



شکل ۲- نحوه توزیع بزرگی بردار تغییرات مربوط به کلاس‌های تغییر یافته و بدون تغییر [۲۲].

انجام این مرحله، با استخراج نمونه‌های شبه آموزشی و استفاده از این داده‌ها جهت تخمین پارامترهای الگوریتم کشف تغییرات پیشنهادی، به پایداری و همگرا شدن این الگوریتم کمک قابل توجهی می‌شود.

۲-۳- نگاشت به فضای هیلبرت

روش‌های تفاضلی در فضای طیف در حالتیکه ماهیت تغییر بصورت غیرخطی باشد، ناکارآمد هستند، لذا در این مقاله از دو سناریو مختلف جهت محاسبه تفاضل تصاویر در فضای هیلبرت با ابعاد بالاتر استفاده شده است.

الف) تفاضل تصاویر در فضای ورودی اولیه (DFSS^۱): به منظور پیاده‌سازی این نگاشت، در مرحله اول تصاویر چندزمانه، پیکسل به پیکسل از یکدیگر کم می‌شوند تا فضای $D \in \mathbb{R}^d$ ایجاد شود. در مرحله بعد پیکسل‌های تفاضلی با استفاده از رابطه $\varphi(x) = \varphi(x^d)$ به فضای هیلبرت نگاشت می‌شوند. از آنجاییکه رابطه ریاضی تابع نگاشت φ به سادگی قابل پیاده‌سازی نیست، معمولاً از فرم کرنلی آن بصورت $K(x_i^d, x_j^d) = \langle \varphi(x_i^d), \varphi(x_j^d) \rangle$ استفاده شده و در معادلات مورد استفاده قرار می‌گیرد [۱۱].

ب) تفاضل تصاویر در فضای ویژگی (DFHS^۲): به منظور استخراج اطلاعات جداسازی بین پیکسل‌های تغییر یافته و بدون تغییر، تابع نگاشت به فضای هیلبرت به گونه‌ای طراحی می‌شود که به وضوح روابط غیر خطی بین پیکسل‌ها را نیز در نظر بگیرد. جهت نیل به این هدف، تابع نگاشت به گونه‌ای توسعه داده می‌شود تا تصویر تفاضل را در

فضای ویژگی با بعد بالاتر محاسبه نماید. بدین منظور، در مرحله اول تصاویر چندزمانه، با استفاده از رابطه $\varphi(x) = \varphi(x^d)$ به فضای هیلبرت نگاشت شده و در مرحله بعد پیکسل‌های متناظر از یکدیگر کم می‌شوند. برای یک پیکسل مشخص تابع نگاشت به فضای ویژگی $\varphi(\cdot)$ متناظر با پیکسل‌های تفاضلی به صورت زیر تعریف می‌شوند [۱۱]:

$$\varphi(x_i) = H^{(t_2)} \varphi(x_i^{(t_2)}) - H^{(t_1)} \varphi(x_i^{(t_1)}) \quad (۸)$$

که در آن $H^{(t)}$ یک ماتریس مقیاس معین مثبت متقارن است. میزان مشابهت دو بردار تفاضل در فضای ویژگی از طریق $\langle \varphi(x_i), \varphi(x_j) \rangle$ ارزیابی می‌شود. با بسط ضرب نقطه‌ای در معادله فوق و در نظر گرفتن شرایط Mercer's تابع کرنل متناظر با آن از رابطه زیر به دست می‌آید [۱۱]:

$$\begin{aligned} k(x_i, x_j) &= \langle \varphi(x_i), \varphi(x_j) \rangle \\ &= k(x_i^{(t_2)}, x_j^{(t_2)}) \\ &\quad + k(x_i^{(t_1)}, x_j^{(t_1)}) \\ &\quad - k(x_i^{(t_2)}, x_j^{(t_1)}) \\ &\quad - k(x_i^{(t_1)}, x_j^{(t_2)}) \end{aligned} \quad (۹)$$

این فرمول‌بندی از تفاضل تصاویر در فضای ویژگی فرم مناسبتری از مسئله را بیان می‌کند. نکته قابل توجه اینست که با تغییر ورودی‌های کرنل، پارامتر این کرنل‌های تفاضلی نیز بایستی تخمین زده شود. از آنجاییکه اطلاعات ورودی به کرنل تفاضلی شامل اطلاعات تک زمانه و اطلاعات چند زمانه هستند، بنابراین پارامترهای مربوط به این نوع کرنل‌ها نیز می‌تواند با یکدیگر تلفیق شده و هر گروه از اطلاعات ورودی به کرنل‌ها شامل پارامتر کرنل مشابهی خواهند بود. بنابراین می‌توان پارامترهای کرنل تفاضلی را به صورت $\theta = \{\sigma^{single}, \sigma^{cross}\}$ در نظر گرفته و با استفاده از بهینه‌سازی تابع هزینه پیشنهادی و روش‌های جستجوی شبکه‌ای بهترین مقادیر را برای این پارامترها تخمین زد [۱۱], [۲۳].

۲-۴- الگوریتم خوشه‌بندی kernel k-means

پس از استخراج نمونه‌های شبه آموزشی و انتقال به فضای هیلبرت، از این نمونه‌های شبه آموزشی به دست آمده از مرحله قبل به عنوان ورودی به یک الگوریتم خوشه‌بندی

^۱ Differential in Spectral Space

^۲ Differential in Hilbert Space

عادی را تا حدود زیادی خنثی نموده و نماینده‌های صحیح و منسجمی از دو کلاس مورد علاقه (کلاس‌های تغییر و بدون تغییر) را بدست آورد [۱۰].

۲-۵- انتخاب پارامترهای بهینه الگوریتم کشف تغییرات

انتخاب پارامترهای الگوریتم‌های مبتنی بر کرنل نقش مهمی در کارایی و دقت آنها دارد. در این مقاله، پارامترهای کرنل و مراکز خوشه‌ها در الگوریتم کشف تغییرات پیشنهادی، بطور اتوماتیک با بهینه‌سازی یک تابع هزینه با ماهیت هندسی و شباهت طیفی به دست می‌آید. با بهینه‌سازی این تابع هزینه، خوشه‌هایی با واریانس درون خوشه‌ای پایین و با فاصله زیاد از هم و میزان شباهت بین خوشه‌ای کمینه و شباهت درون خوشه‌ای بیشینه ایجاد خواهد شد. بدین منظور، از کمینه‌سازی اختلاف بین میانگین فاصله درون هر خوشه و میانگین فاصله بین مراکز خوشه‌ها در فضای ویژگی به عنوان معیار هندسی و از طرفی دیگر از کمینه‌سازی میزان شباهت بین کلاس‌های تغییر یافته و بدون تغییر به عنوان معیار شباهت طیفی استفاده می‌شود. این دو معیار بصورت وزن‌دار با یکدیگر ترکیب شده و وارد مرحله بهینه‌سازی می‌شوند. استفاده از این معیار ترکیبی بهینه منجر به انتخاب پارامترهای بهینه کرنل و الگوریتم خوشه‌بندی و استحکام نسبت به ناپایداری‌های عددی می‌شود. مجموعه پارامترهای بهینه هسته θ^{opt} از بهینه‌سازی رابطه زیر به دست می‌آید [۷].

$$\theta^{opt} = \arg \min \left\{ C_1 \times \left[\frac{1}{n} \sum_{q=1}^k \sum_{i \in \pi_q} d(\varphi(x_i), \mu_q) - \sum_{\pi_q \neq \pi_l} d(\mu_q, \mu_l) \right] + C_2 \right. \\ \left. \times \left[\left(1 - \frac{1}{n-1} \left(\frac{\sum_{i \in \pi_q} (\varphi(x_i) - \mu_q)(\varphi(x_j) - \mu_l)}{\sigma_q \sigma_l} \right) \right)^2 + \sum_{j \in \pi_l} d(\varphi(x_i), \varphi(x_j))^2 \right] \right\} \quad (12)$$

به منظور تعیین پارامترهای کرنل، الگوریتم خوشه‌بندی k-means با مقادیر مختلف θ بر روی داده‌های شبه آموزشی اجرا می‌شود. پارامترهای کرنل و مراکز خوشه‌ای که معادله فوق را کمینه می‌سازد، برای جداسازی پیکسل‌های تغییر یافته از بدون تغییر در تصویر چندزمانه بکار برده می‌شود. پیکسل x' در صورتی به خوشه با مرکز x_c نسبت داده می‌شود که شرط $\arg \min_{x_c} d(\varphi(x'), \varphi(x_c))$ برقرار شود [۱۰]، [۷]، [۲۴].

مبتنی بر کرنل به منظور تخمین پارامترهای اولیه آن استفاده می‌گردد. الگوریتم خوشه‌بندی k-means kernel فرم توسعه یافته الگوریتم خوشه‌بندی k-means خطی در فضای RKHS^۱ با استفاده از تابع تبدیل $\varphi(\cdot)$ است. از آنجاییکه فرمول‌بندی الگوریتم k-means با ضرب نقطه‌ای بیان می‌شود، بنابراین با استفاده از توابع کرنل و جایگزین کردن آن بجای ضرب نقطه‌ای، می‌توان مقادیر بدست آمده از ضرب نقطه‌ای را به فضای RKHS منتقل کرد. فرض کنیم که k تعداد کل خوشه‌های مورد نظر باشد $\{\pi_q\}_{q=1}^k$ که در اینجا $k=2$ است. الگوریتم خوشه‌بندی k-means kernel با کمینه‌سازی مجموع مربعات فاصله بین پیکسل‌های تصویر شده در فضای ویژگی $\varphi(x) \in \pi_q$ و مقدار میانگین آنها μ_q فرمول‌بندی می‌شوند [۱۰]:

$$d(\varphi(x), \mu) = \sum_{q=1}^k \sum_{i \in \pi_q} \|\varphi(x_i) - \mu_q\|_{\mathcal{H}}^2 \quad (10)$$

با جایگذاری $\mu_q = n_q^{-1} \sum_{j \in \pi_q} \varphi(x_j)$ و استفاده از توابع کرنل خواهیم داشت:

$$d(\varphi(x), \mu) = k(x_i, x_i) - \frac{2}{n_q} \sum_{j \in \pi_q} k(x_i, x_j) + \frac{1}{n_q^2} \sum_{j, l \in \pi_q} k(x_j, x_l) \quad (11)$$

که در آن n_q تعداد نمونه‌هایی است که به خوشه q نسبت داده شده است. از آنجاییکه تابع تبدیل مورد استفاده جهت انتقال داده‌ها از فضای اولیه طیف به فضای ویژگی RKHS بطور کامل مشخص نیست، لذا موقعیت دقیق مراکز خوشه‌ها در دسترس ناست. با این حال موقعیت تقریبی آنها با در نظر گرفتن نزدیکترین نمونه به مرکز خوشه از طریق رابطه $x_c = \arg \min_{x_i} d(\varphi(x_i), \mu_q)$ به دست می‌آید. استفاده از این الگوریتم خوشه‌بندی جهت تخمین مراکز خوشه‌ها کماکان تحت تاثیر خطاهای رادیومتریکی، نمونه‌های آموزشی اشتباه و ... است. با این وجود، با توجه به ماهیت غیرخطی بودن این الگوریتم، می‌توان اثر این انحرافات غیر

^۱ Reproducing Kernel Hilbert Space

۲-۶- طبقه‌بندی‌کننده حداقل فاصله مبتنی بر کرنل

پس از تعیین مراکز خوشه‌ها و بهینه‌سازی پارامترهای الگوریتم، نمونه‌های آموزشی دقیق مربوط به کلاس‌های تغییر یافته و بدون تغییر استخراج می‌شوند. در این مرحله از این نمونه‌های آموزشی برای آموزش طبقه‌بندی‌کننده حداقل فاصله مبتنی بر کرنل استفاده می‌شود. الگوریتم طبقه‌بندی حداقل فاصله بر اساس معیار اندازه‌گیری فاصله مبتنی بر کرنل عمل می‌کند. فرض کنیم که $S = \{x_1, \dots, x_l\}$ نمونه‌های موجود در فضای ورودی X بوده و $K(x, y) = \varphi(x)^T \varphi(y)$ تابع کرنل مورد استفاده جهت انتقال به فضای هیلبرت باشد. در این حالت، معیار اندازه‌گیری فاصله در فضای هیلبرت بصورت زیر تعریف می‌شود [۲۵]:

$$\begin{aligned} d^2(x, y) &= \|\varphi(x) - \varphi(y)\|^2 \\ &= K(x, x) \\ &\quad - 2K(x, y) \\ &\quad + K(y, y) \end{aligned} \quad (۱۳)$$


در صورتیکه مجموعه نمونه‌های آموزشی S شامل c کلاس مختلف $S_1, S_2, \dots, S_c$ باشد، تابع تصمیم‌گیری طبقه‌بندی‌کننده حداقل فاصله مبتنی بر کرنل بصورت زیر تعریف می‌شود:

$$h(x) = \arg \min_{1 \leq i \leq c} \{d^2(\varphi(x), \varphi_{S_i})\} \quad (۱۴)$$

در این الگوریتم، پیکسل مجهول x به کلاسی اختصاص می‌یابد که فاصله این پیکسل و مرکز آن کلاس خاص، دارای حداقل فاصله باشد [۲۵].

۳- پیاده‌سازی


از آنجاییکه شاخص‌های طیفی مورد استفاده در این مقاله ماهیتی فیزیکی دارند و وابسته با بازتاب طیفی پدیده‌ها هستند، در مرحله پیش‌پردازش تصاویر چندزمانه، تصحیحات رادیومتریک و اتمسفری بر روی این تصاویر انجام شد. از طرف دیگر، با توجه به فاصله زمانی ۲۴ ساله بین زمان اخذ تصاویر قبل و بعد از وقوع تغییرات در شهر کرج، اختلاف روشنایی و طیفی بین کلاس‌های مشابه بسیار چشمگیر بود. بنابراین این تصاویر چند زمانه نسبت به یکدیگر ثبت هندسی شده و مرحله پیش‌پردازشی تطابق هیستوگرام بر روی آنها انجام شد. گردش کار الگوریتم پیشنهادی کشف تغییرات مبتنی بر کرنل در شکل (۳) نمایش داده شده است.



شکل ۳- چهارچوب پیشنهادی روش خودکار کشف تغییرات کرنل پایه

پس از انجام مراحل پیش‌پردازشی، در مرحله دوم، شاخص‌های طیفی مناسب از تصاویر چندزمانه استخراج شده و با استفاده از دو روش تفاضلی مبتنی بر کرنل به فضای هیلبرت با بعد بالاتر نگاشت می‌شوند. در این فضای جدید، میزان جدایی پذیری کلاس‌های طیفی افزایش یافته و در نتیجه دقت و کارایی الگوریتم پیشنهادی افزایش می‌یابد. در مرحله سوم با استفاده از روش آنالیز بردار تغییر و انتخاب خودکار حد آستانه، نمونه‌های شبه آموزشی غیر دقیق مربوط به کلاس‌های تغییر یافته و بدون تغییر استخراج می‌شوند. از این نمونه‌های شبه آموزشی برای تخمین پارامترهای الگوریتم خوشه‌بندی مبتنی بر کرنل استفاده می‌شود. از آنجاییکه نمونه‌های شبه آموزشی استخراج شده در مرحله قبل، غیر دقیق هستند و استفاده از این نمونه‌ها در مرحله آموزش طبقه‌بندی‌کننده حداقل فاصله مبتنی بر کرنل، ایجاد خطا می‌کند، لذا در مرحله بعد، با استفاده از یک الگوریتم خوشه‌بندی مبتنی بر کرنل، نمونه‌های آموزشی دقیق مربوط به کلاس‌های تغییر یافته و بدون تغییر استخراج می‌شوند. با بهینه‌سازی یک تابع هزینه توسعه داده شده، مقادیر دقیق پارامترهای الگوریتم خوشه‌بندی تعیین می‌شوند. از این نمونه‌های آموزشی برای آموزش طبقه‌بندی‌کننده حداقل فاصله مبتنی بر کرنل

کرج اعمال شد. قدرت تفکیک مکانی این سنجنده ۳۰ متر و در ۷ باند طیفی بوده و الگوریتم‌های پیشنهادی در یک زیر صحنه^۳ از تصویر اصلی با ابعاد ۴۲۹×۴۳۰ پیکسل اجرا شد. این تصاویر به ترتیب در اواسط و اوایل فصل پاییز اخذ شده‌اند و بنابراین اثر تغییرات فصلی در آن به حداقل ممکن رسیده است. 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 در منطقه بود. این منطقه در سالهای گذشته تحت تاثیر تغییرات فراوانی بوده و گسترش مناطق شهری یکی از مهمترین این تغییرات است. نمایش ترکیب رنگی واقعی از تصاویر ماهواره لندست ۵ مربوط به سال‌های ۱۳۶۶ و ۱۳۹۰ در منطقه کرج به ترتیب در شکل‌های (۴-الف) و (۴-ب) نشان داده شده است.



شکل ۴- نمایش ترکیب رنگی واقعی از تصویر ماهواره لندست مربوط به سال ۱۳۶۶ (الف) و سال ۱۳۹۰ (ب) در منطقه کرج.

استفاده می‌شود. در مرحله آخر، هریک از پیکسل‌های مجهول به عنوان ورودی به این طبقه‌بندی‌کننده وارد شده و کلاس هریک از آنها مشخص می‌شود.

۴- ارزیابی نتایج

ارزیابی‌های انجام شده در این مقاله شامل (۱) آنالیز حساسیت الگوریتم کشف تغییرات پیشنهادی نسبت به نوع کرنل (خطی، چندجمله‌ای، گوسین و سیگموئید)، (۲) ارزیابی حساسیت الگوریتم کشف تغییرات پیشنهادی نسبت به استفاده از شاخص‌های طیفی مختلف، (۳) ارزیابی دقت دو سناریوی پیشنهادی جهت محاسبه تصویر تفاضلی شامل سناریوی تفاضل تصاویر چندزمانه در فضای اولیه طیف و سناریو تفاضل تصاویر چندزمانه در فضای هیلبرت و (۴) ارزیابی مقایسه‌ای دقت الگوریتم پیشنهادی نسبت به روش‌های کلاسیک کشف تغییرات. از آنجائیکه نمونه‌های آموزشی در روش پیشنهادی بصورت خودکار استخراج می‌شود، لذا نیازی به جمع‌آوری نمونه‌های آموزشی نبود. جهت ارزیابی دقت الگوریتم پیشنهادی، نمونه‌های آزمایشی مربوط به کلاس تغییر یافته (۱۵۹۴ پیکسل) و کلاس بدون تغییر (۸۸۴ پیکسل) بصورت بصری از تصاویر چندزمانه انتخاب و از دو معیار ضریب کاپا^۱ و دقت کلی^۲ برای نمایش دقت الگوریتم استفاده شد. از آنجائیکه در مرحله پایانی روش پیشنهادی کشف تغییرات از یک روش طبقه‌بندی‌کننده دو کلاسه برای تولید نقشه تغییرات استفاده می‌گردد، لذا از این دو معیار برای ارزیابی دقت الگوریتم پیشنهادی استفاده 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 هسته گوسین بین ۰.۱ تا ۵ در نظر گرفته شد. با استفاده از روش جستجوی شبکه‌ای بر روی تابع هزینه رابطه (۱۲)، پارامتر بهینه هریک از کرنل‌های فوق محاسبه می‌شود.

۴-۱- تصاویر سنجنش از دوری مورد استفاده

جهت بررسی دقت و کارایی الگوریتم پیشنهادی، این الگوریتم بر روی تصاویر چندطیفی ماهواره لندست ۵ سنجنده TM، اخذ شده در سال‌های ۱۳۶۶ و ۱۳۹۰ مربوط به شهر

^۳ Subscene

^۱ Kappa Coefficient
^۲ Overall Accuracy

۴-۲- نتایج تجربی

۴-۲-۱- ارزیابی دقت الگوریتم پیشنهادی کشف تغییرات



در این مقاله، به منظور ارزیابی حساسیت الگوریتم پیشنهادی نسبت به ترکیبات مختلف ویژگی‌های طیفی به عنوان ورودی به الگوریتم پیشنهادی، پنج مجموعه ویژگی از ترکیبات مختلف شاخص‌ها و باندهای طیفی در نظر گرفته و به عنوان ورودی به الگوریتم کشف تغییرات پیشنهادی وارد شده و نتایج حاصل از آن مورد تجزیه و تحلیل قرار گرفته است. این مجموعه ویژگی‌ها با استفاده از یک روش انتخاب ویژگی مبتنی بر فیلتر^۱ (آنالیز همبستگی^۲) انتخاب شدند. در مرحله بعد از روش پیشنهادی کشف تغییرات علاوه بر تولید نقشه تغییرات، به عنوان یک روش انتخاب ویژگی مبتنی بر Wrapper^۳ نیز استفاده شد. خروجی این آنالیز، انتخاب یکی از این مجموعه ویژگی‌ها با هدف دستیابی به بالاترین دقت نقشه تغییرات خواهد بود. در جدول (۱) لیست این مجموعه ویژگی‌ها ارائه شده است.

جدول ۱- مجموعه ویژگی‌های مورد استفاده به عنوان ورودی به

الگوریتم پیشنهادی



B1, B2, B3, B4, B5, B7	مجموعه ویژگی اول
B1, B2, B3, NDBI, NDWI, NDVI	مجموعه ویژگی دوم
B1, B2, B3, BRBA, SAVI	مجموعه ویژگی سوم
B1, B2, B3, UI, NDVI	مجموعه ویژگی چهارم
B1, B2, B3, NBAI, NDWI, SAVI	مجموعه ویژگی پنجم

این مجموعه ویژگی‌ها به گونه‌ای انتخاب شده‌اند که حتی‌الامکان بتوانند نماینده مناسبی برای کلاس‌های پوششی موجود در منطقه مورد مطالعه باشند از اندکس‌های NDBI، NDVI، BRBA، UI و NBAI به عنوان شاخص کلاس ساختمان، اندکس NDWI به عنوان شاخص کلاس آب، اندکس‌های NDVI و SAVI به عنوان شاخص کلاس پوشش گیاهی و از ترکیب سایر باندهای طیفی اولیه نیز برای جداسازی سایر کلاس‌های پوششی استفاده شد. در شکل‌های ۵، ۶، ۷ و ۸ دقت روش‌های تفاضلی DFSS و DFHS در الگوریتم پیشنهادی، برای تمامی مجموعه ویژگی‌ها و در حالت استفاده از کرنل‌های خطی، چندجمله‌ای، گوسین و سیگموئید مورد آنالیز قرار گرفته است.



شکل ۵- آنالیز دقت روش‌های تفاضلی DFSS و DFHS با استفاده از معیار دقت کلی (الف) و معیار کاپا (ب) برای تمامی مجموعه ویژگی‌ها و در حالت استفاده از کرنل خطی

همانطور که در شکل (۵) دیده می‌شود، در حالت استفاده از کرنل خطی، دقت روش‌های تفاضلی DFSS.Linear و DFHS.Linear برای مجموعه ویژگی‌های اول و چهارم دارای بیشترین میزان دقت می‌باشند. بنظر می‌رسد هنگامیکه از مجموعه ویژگی‌های اول و چهارم به عنوان ورودی به الگوریتم پیشنهادی استفاده می‌شود، تابع جداسازی بین کلاس‌های تغییر یافته و بدون تغییر در فضای طیف بصورت خطی بوده و بنابراین استفاده از کرنل خطی مناسب است.




شکل ۶- آنالیز دقت روش‌های تفاضلی DFSS و DFHS با استفاده از معیار دقت کلی (الف) و معیار کاپا (ب) برای تمامی مجموعه ویژگی‌ها و در حالت استفاده از کرنل چندجمله‌ای

^۱ Filter based Feature Selection

^۲ Correlation Analysis

^۳ Wrapper based Feature Selection


بدست می‌دهد. ولی در روش تفاضلی DFSS.RBF در حالت استفاده از مجموعه ویژگی اول، تابع جداسازی بین کلاس‌های تغییر یافته و بدون تغییر در فضای طیف به صورت گوسین بوده و تنها در اینحالت استفاده از کرنل گوسین دقت بالاتری را بدست می‌دهد. با این وجود، روش تفاضلی DFSS.RBF در حالت استفاده از کلیه مجموعه ویژگی‌ها دارای دقتی به مراتب بالاتر از روش تفاضلی DFHS.RBF است.



شکل ۸- آنالیز دقت روش‌های تفاضلی DFSS و DFHS با استفاده از معیار دقت کلی (الف) و معیار کاپا (ب) برای تمامی مجموعه ویژگی‌ها و در حالت استفاده از کرنل سیگموئید



با مشاهده نتایج بدست آمده در شکل (۸) می‌توان فهمید، در حالت استفاده از کرنل سیگموئید، دقت روش تفاضلی DFSS.Sigmoid برای تمامی مجموعه ویژگی‌ها دارای بالاترین دقت است. این درحالیست که دقت روش تفاضلی DFHS.Sigmoid تنها برای مجموعه ویژگی‌های دوم و چهارم دارای دقت بالایی است. بنابراین می‌توان نتیجه گرفت در روش تفاضلی DFHS.Sigmoid با استفاده از مجموعه ویژگی‌های دوم و چهارم، تابع جداسازی بین کلاس‌های تغییر یافته و بدون تغییر در فضای طیف بصورت سیگموئید بوده و بنابراین استفاده از کرنل سیگموئید دقت بالاتری را بدست می‌دهد. ولی در روش تفاضلی DFSS.Sigmoid در حالت استفاده از کلیه مجموعه ویژگی‌ها، تابع جداسازی بین کلاس‌های تغییر یافته و بدون تغییر در فضای طیف به صورت سیگموئید

همانطور که در شکل (۶) دیده می‌شود، در حالت استفاده از کرنل چندجمله‌ای، دقت روش تفاضلی DFSS.Polynomial برای کلیه مجموعه ویژگی‌ها دارای دقت بالایی است. این درحالیست که دقت روش تفاضلی DFHS.Polynomial تنها برای مجموعه ویژگی دوم دارای دقت بالایی است. می‌توان نتیجه گرفت در روش تفاضلی DFHS.Polynomial ترکیب شاخص‌های موجود در مجموعه ویژگی دوم، تابع جداسازی بین کلاس‌های تغییر یافته و بدون تغییر در فضای طیف بصورت چندجمله‌ای بوده و بنابراین استفاده از کرنل چندجمله‌ای دقت بالاتری را بدست می‌دهد. ولی روش تفاضلی DFSS.Polynomial در حالت استفاده از کلیه مجموعه ویژگی‌ها دارای دقتی به مراتب بالاتر از روش تفاضلی DFHS.Polynomial است.



شکل ۷- آنالیز دقت روش‌های تفاضلی DFSS و DFHS با استفاده از معیار دقت کلی (الف) و معیار کاپا (ب) برای تمامی مجموعه ویژگی‌ها و در حالت استفاده از کرنل گوسین

با مشاهده نتایج بدست آمده در شکل (۷) می‌توان فهمید، در حالت استفاده از کرنل گوسین، دقت روش تفاضلی DFSS.RBF برای مجموعه ویژگی اول دارای بالاترین دقت است. این درحالیست که دقت روش تفاضلی DFHS.RBF برای مجموعه ویژگی پنجم دارای دقت بالایی است. بنابراین می‌توان نتیجه گرفت در روش تفاضلی DFHS.RBF ترکیب شاخص‌های موجود در مجموعه ویژگی پنجم، تابع جداسازی بین کلاس‌های تغییر یافته و بدون تغییر در فضای طیف بصورت گوسین بوده و بنابراین استفاده از کرنل گوسین دقت بالاتری را





شکل ۱۰- آنالیز دقت روش تفاضلی DFSS نسبت به استفاده از کرنل‌های مختلف با استفاده از معیار دقت کلی (الف) و معیار کاپا (ب) برای تمامی مجموعه ویژگی‌ها

با بررسی نتایج بدست آمده در شکل (۱۰) می‌توان نتیجه گرفت برای مجموعه ویژگی‌های اول، سوم و پنجم، استفاده از کرنل خطی در روش تفاضلی DFSS، دقت بالاتری را بدست می‌دهند. درحالیکه برای مجموعه ویژگی‌های دوم و چهارم، استفاده از کرنل سیگموید در روش تفاضلی DFSS، دقت بالاتری را بدست می‌دهند. این بدان معناست که برای این تصاویر و برای این روش تفاضلی، در حالت استفاده از مجموعه ویژگی‌های اول، سوم و پنجم، تابع جداسازی بین کلاس‌های مورد علاقه در فضای طیف، بصورت خطی است. ولی در حالت استفاده از مجموعه ویژگی‌های دوم و چهارم، تابع جداسازی بین کلاس‌های مورد علاقه در فضای طیف، تطابق بیشتری با تابع سیگموید دارد.

در شکل‌های ۱۱، ۱۲، ۱۳، ۱۴ و ۱۵، نقشه تغییرات بدست آمده از روش‌های تفاضلی DFSS و DFHS در الگوریتم پیشنهادی، برای تمامی مجموعه ویژگی‌ها و در حالت استفاده از کرنل‌های خطی، چندجمله‌ای، گوسین و سیگموید مورد نشان داده شده است.


بوده و استفاده از کرنل سیگموید دقت بالاتری را بدست می‌دهد. در این حالت نیز، روش تفاضلی DFSS.Sigmoid در حالت استفاده از کلیه مجموعه ویژگی‌ها دارای دقتی به مراتب بالاتر از روش تفاضلی DFHS.Sigmoid است.

در شکل‌های ۹ و ۱۰، دقت روش‌های تفاضلی DFSS و DFHS در الگوریتم پیشنهادی، برای تمامی مجموعه ویژگی‌ها، نسبت استفاده از کرنل‌های خطی، چندجمله‌ای، گوسین و سیگموید مورد آنالیز قرار گرفته است.




شکل ۹- آنالیز دقت روش تفاضلی DFSS نسبت به استفاده از کرنل‌های مختلف با استفاده از معیار دقت کلی (الف) و معیار کاپا (ب) برای تمامی مجموعه ویژگی‌ها


با بررسی نتایج بدست آمده در شکل (۹) می‌توان نتیجه گرفت استفاده از کرنل‌های چندجمله‌ای و سیگموید در روش تفاضلی DFSS، در حالت استفاده از تمامی مجموعه ویژگی‌ها، دقت بالاتری را بدست می‌دهند. این بدان معناست که برای این تصاویر، در حالت کلی تابع جداسازی بین کلاس‌های مورد علاقه در فضای طیف، تطابق بیشتری با توابع چندجمله‌ای و سیگموید دارد. بنابراین کرنل‌های چندجمله‌ای و سیگموید برای تولید نقشه تغییرات انتخاب‌های مناسبتری هستند.




(د)



(الف)




(ه)




(ب)

شکل ۱۱- نقشه تغییرات بدست آمده از سناریوهای پیشنهادی
 DFSS. Linear (الف)، DFSS. Polynomial (ب)، DFSS. RBF (ج)،
 DFSS. Linear (د)، DFSS. Linear (ه) و در حالت استفاده از
 مجموعه ویژگی اول

همانطور که در شکل‌های (۱۱-ب) و (۱۱-د) دیده می‌شود، در نقشه تغییرات تولید شده، سایه‌های موجود در مناطق کوهستانی نیز به عنوان کلاس تغییر استخراج شده‌اند و تعداد پیکسل‌های نویزی در این نقشه‌ها به فراوانی به چشم می‌خورد. با این وجود، مناطق تغییر یافته در نقشه تغییرات تولید شده برای مجموعه ویژگی اول و با استفاده از روش پیشنهادی، بخوبی آشکار شده است.




(ج)




شکل ۱۲- نقشه تغییرات بدست آمده از سناریوهای پیشنهادی DFBS. Linear (الف)، DFBS. Polynomial (ب)، DFBS. Sigmoid (ج)، DFHS. Linear (د)، DFHS. Sigmoid (ه) و در حالت استفاده از مجموعه ویژگی دوم.

کلاس‌های طیفی، مناطق تغییر یافته در نقشه تغییرات تولید شده برای مجموعه ویژگی دوم و با استفاده از روش پیشنهادی، بخوبی آشکار شده است.


همانطور که در شکل‌های (۱۲-الف)، (۱۲-ج) و (۱۲-ه) دیده می‌شود، در نقشه تغییرات تولید شده، تغییرات بوجود آمده ناشی از توسعه شهری بطور کامل به عنوان کلاس تغییر استخراج نشده‌اند. ولی در خصوص سایر




(د)



(الف)




(ه)




(ب)

شکل ۱۳- نقشه تغییرات بدست آمده از سناریوهای پیشنهادی
 (الف) DFFS. Linear، (ب) DFFS. Polynomial، (ج) DFFS. RBF، (د) DFFS. Sigmoid و (ه) DFHS. Linear در حالت استفاده از
 مجموعه ویژگی سوم


همانطور که در شکل (۱۳) دیده می‌شود، در نقشه
 تغییرات تولید شده با استفاده از روش پیشنهادی و برای
 مجموعه ویژگی سوم، مناطق تغییر یافته در تمامی
 کلاسهای طیفی بخوبی آشکار شده و سطح نویز در آن
 پایین است.




(ج)




(ب)




(الف)




(د)



(ج)



(و)




(ه)


شکل ۱۴- نقشه تغییرات بدست آمده از سناریوهای پیشنهادی DFBS. Linear (الف)، DFBS. Polynomial (ب)، DFBS. RBF (ج)، DFBS. Sigmoid (د)، DFHS. Linear (ه)، DFHS. Sigmoid (و) و در حالت استفاده از مجموعه ویژگی چهارم

طیفی، مناطق تغییر یافته در نقشه تغییرات تولید شده برای مجموعه ویژگی چهارم و با استفاده از روش پیشنهادی، بخوبی آشکار شده است.


همانطور که در شکل‌های (۱۴-الف)، (۱۴-ج) و (۱۴-ه) دیده می‌شود، در نقشه تغییرات تولید شده، تغییرات بوجود آمده ناشی از توسعه شهری بطور کامل به عنوان کلاس تغییر استخراج نشده‌اند. ولی در خصوص سایر کلاس‌های




(د)



(الف)




(ه)




(ب)

شکل ۱۵- نقشه تغییرات بدست آمده از سناریوهای پیشنهادی
 DFSS. Linear (الف)، DFSS. Polynomial (ب)، DFSS. RBF (ج)،
 DFHS. Linear (د)، و در حالت استفاده از
 مجموعه ویژگی پنجم

همانطور که در شکل‌های (۱۵-الف)، (۱۵-ج) و (۱۵-ه) دیده می‌شود، در نقشه تغییرات تولید شده، تغییرات بوجود آمده ناشی از توسعه شهری بطور کامل به عنوان کلاس تغییر استخراج نشده‌اند. ولی در خصوص سایر کلاس‌های طیفی، مناطق تغییر یافته در نقشه تغییرات تولید شده برای مجموعه ویژگی پنجم و با استفاده از روش پیشنهادی، بخوبی آشکار شده است.



(ج)



شکل ۱۶- آنالیز دقت مقایسه‌ای روش پیشنهادی و روش‌های متداول کشف تغییرات با استفاده از معیار دقت کلی (الف) و معیار کاپا (ب) برای تمامی مجموعه ویژگی‌ها

۵- نتیجه‌گیری

در این مقاله یک روش کشف تغییرات خودکار مبتنی بر کرنل و با قابلیت استفاده هم‌زمان از اطلاعات طیفی و شاخص‌های طیفی و در نظر گرفتن اطلاعات متقابل متغیر و ثابت بین پیکسل‌ها مربوط به تصاویر دوره‌های زمانی مختلف پیشنهاد شد. این روش بر روی داده چندطیفی ماهواره لندست مربوط به شهر کرج پیاده‌سازی و مورد ارزیابی دقت قرار گرفت. نتایج بدست آمده حاکی از کارایی و دقت بالای الگوریتم پیشنهادی در کشف تغییرات در مناطق شهری با وجود کلاس‌های طیفی پیچیده و نزدیک به هم از لحاظ طیفی است. استفاده از روش پیشنهادی کرنل پایه، با ارائه یک روش غیر خطی، مسئله کشف تغییرات در مناطق شهری با کلاس‌های طیفی پیچیده و دارای مرز جداسازی غیر خطی را حل نموده است. داده‌های شبه آموزشی و مقادیر حدآستانه برای جداسازی کلاس‌های تغییر یافته و بدون تغییر از یکدیگر، با روش آنالیز بردار تغییر به صورت خودکار استخراج شدند. با استفاده از این نمونه‌های شبه آموزشی و با تخمین مقادیر اولیه الگوریتم خوشه‌بندی مبتنی بر کرنل با استفاده از حل یک مسئله بهینه‌سازی در فضای هیلبرت، همگرایی جواب‌های مسئله کشف تغییرات تضمین می‌شود.

با مشاهده نتایج بدست آمده در شکل‌های ۱۱، ۱۲، ۱۳، ۱۴ و ۱۵، می‌توان نتیجه گرفت که نقشه تغییرات تولید شده در حالت استفاده از هر چهار نوع کرنل و با روش تفاضلی DFSS دارای دقت بالاتر و سطح نویز کمتری نسبت به روش تفاضلی DFHS است. بنابراین برای این تصاویر، مناسبتر است که ابتدا تفاضل تصاویر چندزمانه از یکدیگر در فضای طیف صورت گرفته و تصویر تفاضلی بدست آمده به فضای هیلبرت با بعد بالاتر منتقل شود. علت این امر آنست که مقادیر اختلاف طیفی کلاس‌های پوششی مختلف در تصویر تفاضلی بدست آمده در فضای اولیه طیف، به یکدیگر نزدیک بوده و مرز جدایی بین کلاس‌های تغییر یافته و بدون تغییر براحتی قابل تشخیص ناست. بنابراین با انتقال این تصویر تفاضلی به فضای هیلبرت با بعد بالاتر، میزان جدایی‌پذیری این دو کلاس افزایش می‌یابد.

۴-۲-۲- ارزیابی مقایسه‌ای با روش‌های متداول کشف تغییرات

به منظور ارزیابی دقت و کارایی روش مبتنی بر کرنل پیشنهادی در مقایسه با روش‌های متداول کشف تغییرات، روش‌های تبدیل MNF^۱، نگارنده زاویه طیفی^۲ (SAM) و روش تفاضلی ساده^۳ (DIFF) بر روی این ۵ مجموعه ویژگی و ویژگی پیاده‌سازی شده و نتایج آن با نتایج حاصل از روش‌های تفاضلی DFSS.Linear و DFHS.Linear مقایسه شدند. نتایج مربوط به این آنالیز دقت در شکل (۱۶) ارائه شده است.

مقایسه نتایج بدست آمده از روش‌های متداول 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.

^۱ Minimum Noise Fraction

^۲ Spectral Angle Mapper

^۳ Simple Image Subtraction

حدود زیادی افزایش داد. مقایسه نتایج بدست آمده از روش‌های متداول کشف تغییرات و روش پیشنهادی کرنل-پایه 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 می‌شود. این درحالیست که در روش پیشنهادی مبتنی بر کرنل، از کلیه باندهای طیفی و اطلاعات متقابل بین باندها نیز برای جداسازی کلاس‌های تغییر یافته از بدون تغییر استفاده می‌شود.

آنالیز دقت نتایج نشان می‌دهد، با بازنویسی مجدد روش‌های تفاضلی ساده در فضای هیلبرت و ارائه دو روش تفاضلی مبتنی بر کرنل DFSS و DFHS، کارایی و دقت این روش‌ها نسبت به روش‌های تفاضلی ساده افزایش می‌یابد. در این الگوریتم کرنل پایه کشف تغییرات با قابلیت استفاده از کرنل‌ها مختلف، می‌توان با توجه به ماهیت داده‌های طیفی مورد استفاده و میزان پیچیدگی آنها، تابع کرنل مناسب را انتخاب نمود. استفاده از شاخص‌های طیفی کارا جهت جداسازی انواع کلاس‌های طیفی در مناطق شهری، دقت الگوریتم پیشنهادی را تا

مراجع

- [1] L. Møller-Jensen, R. Y. Kofie, and P. W. Yankson, "Large-area urban growth observations—a hierarchical kernel approach based on image texture," *Geogr. Tidsskr.-Dan. J. Geogr.*, vol. 105, no. 2, pp. 39–47, 2005.
- [2] S. M. de Jong, A. Bagre, P. B. van Teeffelen, and W. P. van Deursen, "Monitoring Trends in Urban Growth and Surveying City Quarters in Ouagadougou, Burkina Faso Using SPOT-XS," *Geocarto Int.*, vol. 15, no. 2, pp. 63–70, 2000.
- [3] A. Singh, "Review Article Digital change detection techniques using remotely-sensed data," *Int. J. Remote Sens.*, vol. 10, no. 6, pp. 989–1003, Jun. 1989.
- [4] A. P. Tewkesbury, A. J. Comber, N. J. Tate, A. Lamb, and P. F. Fisher, "A critical synthesis of remotely sensed optical image change detection techniques," *Remote Sens. Environ.*, vol. 160, pp. 1–14, Apr. 2015.
- [5] M. Guorui, S. Haigang, L. Pingxiang, and Q. Qianqing, "A kernel change detection algorithm in remote sense imagery," in *Geoscience and Remote Sensing Symposium, 2006. IGARSS 2006. IEEE International Conference on, 2006*, pp. 220–224.
- [6] J. Muñoz-Marí, F. Bovolo, L. Gómez-Chova, L. Bruzzone, and G. Camp-Valls, "Semisupervised One-Class Support Vector Machines for Classification of Remote Sensing Data," *IEEE Trans. Geosci. Remote Sens.*, vol. 48, no. 8, pp. 3188–3197, Aug. 2010.
- [7] M. Volpi, D. Tuia, G. Camps-Valls, and M. Kanevski, "Unsupervised change detection by kernel clustering," in *Remote Sensing, 2010*, p. 78300V–78300V.
- [8] F. Bovolo, L. Bruzzone, and M. Marconcini, "A Novel Approach to Unsupervised Change Detection Based on a Semisupervised SVM and a Similarity Measure," *IEEE Trans. Geosci. Remote Sens.*, vol. 46, no. 7, pp. 2070–2082, Jul. 2008.
- [9] H. Xu, "Extraction of urban built-up land features from Landsat imagery using a thematic-oriented index combination technique," *Photogramm. Eng. Remote Sens.*, vol. 73, no. 12, p. 1381, 2007.
- [10] G. Camps-Valls, L. Gomez-Chova, J. Munoz-Mari, J. L. Rojo-Alvarez, and M. Martinez-Ramon, "Kernel-Based Framework for Multitemporal and Multisource Remote Sensing Data Classification and Change Detection," *IEEE Trans. Geosci. Remote Sens.*, vol. 46, no. 6, pp. 1822–1835, Jun. 2008.
- [11] G. Camps-Valls, L. Gomez-Chova, J. Muñoz-Mari, L. Alonso, J. Calpe-Maravilla, and J. Moreno, "Multitemporal image classification and change detection with kernels," in *Remote Sensing, 2006*, p. 63650H–63650H.
- [12] G. Camps-Valls and L. Bruzzone, *Kernel methods for remote sensing data analysis*, vol. 26. Wiley Online Library, 2009.
- [13] F. Desobry, M. Davy, and C. Doncarli, "An online kernel change detection algorithm," *IEEE Trans. Signal Process.*, vol. 53, no. 8, pp. 2961–2974, Aug. 2005.

- [14] W. Mirza Muhammad, "Development of New Indices for Extraction of Built-Up Area & Bare Soil from Landsat Data," 2012.
- [15] S. M. Phalke and I. Couloigner, "Change detection of linear man-made objects using feature extraction technique," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 36, no. Part 8, p. W27, 2005.
- [16] X.-L. Chen, H.-M. Zhao, P.-X. Li, and Z.-Y. Yin, "Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes," *Remote Sens. Environ.*, vol. 104, no. 2, pp. 133–146, 2006.
- [17] H. Nemmour and Y. Chibani, "Multiple support vector machines for land cover change detection: An application for mapping urban extensions," *ISPRS J. Photogramm. Remote Sens.*, vol. 61, no. 2, pp. 125–133, Nov. 2006.
- [18] F. Bovolo, G. Camps-Valls, and L. Bruzzone, "A support vector domain method for change detection in multitemporal images," *Pattern Recognit. Lett.*, vol. 31, no. 10, pp. 1148–1154, Jul. 2010.
- [19] As-syakur Abd. Rahman, I. W. S. Adnyana, I. W. Arthana, and I. W. Nuarsa, "Enhanced Built-Up and Bareness Index (EBBI) for Mapping Built-Up and Bare Land in an Urban Area," *Remote Sens.*, vol. 4, no. 12, pp. 2957–2970, Oct. 2012.
- [20] R. B. Lorena, J. R. Santos, Y. E. Shimabukuro, I. F. Brown, and H. J. H. Kux, "A change vector analysis technique to monitor land use/land cover in sw Brazilian amazon: Acre state," *PECORA 15-Integrating Remote Sens. Glob. Reg. Local Scale*, pp. 8–15, 2002.
- [21] J. Chen, P. Gong, C. He, R. Pu, and P. Shi, "Land-use/land-cover change detection using improved change-vector analysis," *Photogramm. Eng. Remote Sens.*, vol. 69, no. 4, pp. 369–380, 2003.
- [22] R. B. Lorena, J. R. Santos, Y. E. Shimabukuro, I. F. Brown, and H. J. H. Kux, "A change vector analysis technique to monitor land use/land cover in sw Brazilian amazon: Acre state," *PECORA 15-Integrating Remote Sens. Glob. Reg. Local Scale*, pp. 8–15, 2002.
- [23] R. ShahHosseini, S. Homayouni, and R. Safari, "Modified algorithm based on support vector machines for classification of hyperspectral images in a similarity space," *J. Appl. Remote Sens.*, vol. 6, no. 1, pp. 063550–1, 2012.
- [24] N. Goela, K. Wilson, F. Niu, A. Divakaran, and I. Otsuka, "An svm framework for genre-independent scene change detection," in *Multimedia and Expo, 2007 IEEE International Conference on*, 2007, pp. 532–535.
- [25] G. M. Fung, O. L. Mangasarian, and A. J. Smola, "Minimal kernel classifiers," *J. Mach. Learn. Res.*, vol. 3, pp. 303–321, 2003.