

آشکارسازی تغییرات پوشش زمین با استفاده از الگوریتم‌های طبقه‌بندی، یادگیری ماشین و تلفیق تصاویر Sentinel-1 و Sentinel-2 مطالعه‌ی موردی: (منطقه ۲۲ تهران)

ابراهیم کرمی^{۱*}، حمید مهربانی^۲

^۱ دانشجوی دکتری سنجش از دور، گروه مهندسی نقشه‌برداری، دانشکده عمران و حمل و نقل، دانشگاه اصفهان

E.karami@email.ui.ac.ir

^۲ استادیار، گروه مهندسی نقشه‌برداری، دانشکده عمران و حمل و نقل، دانشگاه اصفهان

h.mehrabi@eng.ui.ac.ir

(دریافت: بهمن ۱۴۰۳، تصویب: مهر ۱۴۰۴)

چکیده

منطقه ۲۲ تهران به عنوان یکی از مناطق در حال توسعه شهری با تغییرات چشمگیر در کاربری زمین، موضوع مهمی برای مطالعات تغییرات محیطی است. این پژوهش با هدف تحلیل و شناسایی تغییرات محیطی و ساختاری در بازه زمانی ۲۰۱۶ تا ۲۰۲۱ انجام شد. روش‌های مختلف سنجش از دور شامل تحلیل تغییر برداری (CVA)، رگرسیون و شاخص‌های طیفی مورد بررسی قرار گرفتند. داده‌های ماهواره‌ای Sentinel-1 و Sentinel-2 به صورت تلفیقی مورد استفاده قرار گرفتند و ویژگی‌های بافتی از تصاویر اپتیک و راداری استخراج شد. نتایج نشان دادند که تلفیق داده‌ها موجب افزایش دقت طبقه‌بندی شده است؛ به طوری که دقت کلی در سال ۲۰۱۶ برابر با ۹۱٪ و ضریب کاپا ۸۹٪ و در سال ۲۰۲۱ دقت کلی ۸۶٪ و ضریب کاپا ۸۵٪ به دست آمد. علاوه بر تغییرات درصدی در کلاس‌های ساخت‌وساز (۱۳٪)، پوشش گیاهی (۱۵٪)، منابع آبی (۴٪) و خاکی (۱۱٪)، تحلیل پیکسلی نیز انجام شد. توانستیم درصد تغییرات و تعداد پیکسل‌های تغییر یافته بین کلاس‌های مختلف را شناسایی کنیم. همچنین، توانستیم درصد و تعداد پیکسل‌های تغییر یافته بین کلاس‌های مختلف را شناسایی کنیم. در کلاس آب، بیشترین تغییر به خاک (۱۸۳۰۰ پیکسل) اختصاص داشت. در کلاس جاده، ۲۱۰۰۰ پیکسل ثابت مانده و تغییراتی به سمت پوشش گیاهی، ساخت‌وساز و آب مشاهده شد. پوشش گیاهی با ۱۵۸۰۰۰ پیکسل ثابت، بیشترین پایداری را داشت اما بخشی از آن به خاک و ساخت‌وساز تبدیل شده است. در کلاس خاک نیز علاوه بر ۴۲۰۰۰ پیکسل ثابت، بیش از ۱۵۶۰۰۰ پیکسل به جاده و ۱۲۰۰۰ پیکسل به ساخت‌وساز تغییر یافته‌اند. این تحلیل جزئی، امکان شناسایی دقیق‌تر الگوهای تغییر و تدوین برنامه‌های مدیریتی هدفمند را فراهم کرده است.

واژگان کلیدی: کاربری زمین، داده‌های ماهواره‌ای، تحلیل رگرسیون، شبکه عصبی پرسپترون چندلایه (MLP)، ترکیب داده‌های نوری و راداری

* نویسنده رابط

۱- مقدمه

رشد شتابان شهرنشینی در دهه‌های اخیر، به‌ویژه در کشورهای در حال توسعه، موجب تحولات گسترده‌ای در ساختار فضایی و کاربری اراضی شهری شده است. این تغییرات نه تنها الگوهای پوشش زمین را دگرگون می‌سازند، بلکه پیامدهای عمیقی بر اکوسیستم‌های طبیعی، زیرساخت‌های شهری، و عدالت اجتماعی برجای می‌گذارند [۱]. در چنین شرایطی، پایش دقیق و مستمر این تحولات، ضرورتی اجتناب‌ناپذیر برای سیاست‌گذاران، برنامه‌ریزان شهری و پژوهشگران حوزه محیط‌زیست به‌شمار می‌رود [۲]. اطلاعات حاصل از تغییرات زمین معمولاً در دو دسته اصلی پوشش اراضی و کاربری اراضی طبقه‌بندی می‌شوند که پایه بسیاری از مطالعات محیطی، برنامه‌ریزی شهری و مدیریت منابع طبیعی را تشکیل می‌دهند [۳]. در این راستا، بهره‌گیری از فناوری‌های نوین سنجش از دور، به‌ویژه داده‌های ماهواره‌ای با وضوح بالا، به‌عنوان ابزاری قدرتمند برای تحلیل و مدل‌سازی این تحولات مطرح شده‌اند. داده‌های حاصل از ماهواره‌های Sentinel-1 و Sentinel-2، به‌دلیل قابلیت تصویربرداری در شرایط جوی مختلف، پوشش زمانی مناسب، و تنوع طیفی، به‌طور فزاینده‌ای در مطالعات تغییرات کاربری و پوشش زمین مورد استفاده قرار گرفته‌اند [۴، ۵].

پروژه Harmonized Landsat and Sentinel-2 (HLS) نیز با تلفیق داده‌های Landsat و Sentinel-2، امکان پایش دقیق‌تر تغییرات پوشش زمین را فراهم کرده و در کشاورزی، مدیریت منابع و پایش شهری کاربرد یافته است [۶]. تصاویر راداری و نوری این ماهواره‌ها، امکان پایش شبانه‌روزی و در شرایط ابری را فراهم می‌کنند که در مناطق شهری بسیار حیاتی است [۷]. به‌عنوان مثال، Hafner و همکاران با استفاده از داده‌های ترکیبی Sentinel-1 و Sentinel-2 و روش نیمه‌نظارتی، موفق به شناسایی دقیق تغییرات شهری در مناطق کم‌برچسب شدند [۸]. همچنین Zhang و همکاران با ارائه دیتاست جهانی GLC_FCS10، طبقه‌بندی پوشش زمین را با دقت ۸۵٪ در ایالات متحده انجام دادند [۹].

تکنیک‌های آشکارسازی تغییرات به دو دسته کلی تقسیم می‌شوند: (۱) کشف تغییرات باینری (تغییر کرده/تغییر نکرده) و (۲) تغییرات از-به که شامل

طبقه‌بندی دقیق‌تر نوع تغییرات است [۱۰]. روش‌های مبتنی بر پیکسل، شامل مقایسه مستقیم، تبدیلات و یادگیری ماشین، از جمله رویکردهای رایج در این حوزه هستند [۳]. در این میان، توسعه روش‌های پیشرفته یادگیری ماشین و یادگیری عمیق، امکان استخراج الگوهای پیچیده و شناسایی تغییرات جزئی را فراهم کرده‌اند؛ به‌طوری‌که امروزه ترکیب داده‌های چندمنبعی با الگوریتم‌های هوشمند، به‌عنوان رویکردی نوین در پایش تغییرات شهری شناخته می‌شود [۱۱].

مدل OFNet با ترکیب جریان نوری و مکانیزم توجه دوگانه، دقت بالایی در تشخیص تغییرات شهری ارائه داده و از داده‌های چندزمانه سنتینل بهره گرفته است. Chen [۱۲] و همکاران روش تحلیل بردار تغییرات (CVA) را معرفی کردند که با کاهش نویز و شناسایی تغییرات جزئی، دقت بالایی در تحلیل تغییرات شهری دارد [۱۳]. در مطالعه‌ای دیگر، Li و همکاران با استفاده از داده‌های Sentinel-1 و الگوریتم SVM، موفق به شناسایی تغییرات شهری در چین با دقت ۹۸٪ شدند [۱۴].

Johnson و همکاران از تصاویر Sentinel-2 و شبکه‌های عصبی مصنوعی (ANN) برای پایش تغییرات پوشش زمین در آفریقا استفاده کردند و دقت ۹۹٪ را گزارش دادند [۱۵]. Davis نیز نشان دادند که CNN‌ها در طبقه‌بندی تصاویر ماهواره‌ای عملکرد بسیار دقیقی دارند و برای پایش تغییرات شهری مناسب هستند [۱۶]. Clark و همکاران با بهینه‌سازی معماری U-Net، دقت طبقه‌بندی پوشش زمین را در تصاویر هوایی شهری بهبود دادند [۱۷]. همچنین Fawzy و Barsi با استفاده از تصاویر با وضوح بسیار بالا و شبکه U-Net، طبقه‌بندی شهری را با دقت ۸۷.۵٪ انجام دادند [۱۸].

Alkhediri و همکاران روش‌های پیکسل‌پایه مانند PCA و اختلاف تصاویر را بر روی داده‌های آیکونوس اعمال کردند و سپس با تحلیل شیء‌گرا، تغییرات را با دقت بالا شناسایی کردند [۱۹]. Peterson و همکاران نشان دادند که استفاده از الگوریتم‌های یادگیری عمیق مانند CNN می‌تواند دقت شناسایی تغییرات را در مناطق شهری به‌طور قابل توجهی افزایش دهد [۲۰]. Zhang و همکاران با استفاده از داده‌های چندزمانه و الگوریتم‌های یادگیری ماشین، گسترش شهری را در مناطق مختلف تحلیل کردند [۲۱]. Ghorbanzadeh و همکاران با تلفیق داده‌های

Sentinel-1 و Sentinel-2، موفق به تولید نقشه‌های دقیق‌تری از تغییرات شهری شدند [۲۲].

Li و همکاران شبکه‌های Siamese را برای شناسایی تغییرات پیچیده در تصاویر چندزمانه معرفی کردند که عملکرد بالایی در مناطق با تغییرات جزئی داشتند [۲۳]. Hafner در رساله دکتری خود نشان داد که یادگیری چندمدلی با داده‌های سنتینل باعث بهبود تعمیم‌پذیری مدل‌ها در مناطق جدید می‌شود [۲۴]. و Ban همکاران ترکیب داده‌های SAR و اپتیکی را برای آشکارسازی تغییرات شهری پیشنهاد دادند و نشان دادند که داده‌های راداری در شرایط ابری عملکرد بهتری دارند [۷]. Mastro و همکاران نیز با استفاده از الگوریتم جنگل تصادفی و داده‌های Sentinel-1، تغییرات شهری و بلایای طبیعی را با دقت بالا شناسایی کردند [۲۵].

Zhang و همکاران با استفاده از شبکه‌های CNN و داده‌های Sentinel-2، موفق به شناسایی تغییرات شهری با دقت بالا شدند [۲۶]. Lambin و همکاران علل تغییرات کاربری زمین را بررسی کردند و تأکید کردند که این تغییرات نتیجه تعاملات پیچیده انسانی و طبیعی هستند [۱]. Turner و همکاران نیز بر اهمیت پایش تغییرات در مقیاس‌های مختلف تأکید کردند و چارچوبی برای تحلیل تغییرات ارائه دادند [۲].

در ایران نیز مطالعاتی در این زمینه انجام شده است. مقاله‌ای با عنوان «طبقه‌بندی پوشش زمین مبتنی بر روش‌های یادگیری ماشین و یادگیری عمیق با استفاده از تصاویر ماهواره‌ای سنتینل-۲، مطالعه موردی: منطقه شهری غرب تهران» در مجله علم و فنون منتشر شده است که نشان‌دهنده کاربرد موفق الگوریتم‌های ترکیبی در تحلیل تغییرات شهری است [۲۷].

پژوهش حاضر با هدف ارائه رویکردی جامع و نوآورانه برای شناسایی تغییرات محیطی و ساختاری در منطقه ۲۲ تهران طراحی شده است. در این مطالعه، از تصاویر ماهواره‌ای Sentinel-1 و Sentinel-2 به‌عنوان داده‌های اصلی استفاده شده و با ترکیب این داده‌ها از طریق روش‌های پیشرفته نظیر شبکه‌های عصبی، تلفیق تصاویر و مقایسه مستقیم، دقت و قابلیت اطمینان تحلیل‌ها بهبود یافته است. نوآوری اصلی این پژوهش در استفاده هم‌زمان از چند روش آشکارسازی تغییرات، تلفیق داده‌های چندمنبعی، و ارزیابی عملکرد آن‌ها در منطقه‌ای با توسعه سریع شهری نهفته

است. این رویکرد، امکان تحلیل دقیق‌تر و قابل اعتمادتر تغییرات را فراهم کرده و می‌تواند به‌عنوان الگویی برای مطالعات مشابه در سایر مناطق شهری مورد استفاده قرار گیرد.

۲- روش تحقیق


۲-۱- منطقه‌ی مورد مطالعه

منطقه مورد مطالعه در این تحقیق شامل بخش‌هایی از شهر تهران است که به سرعت در حال توسعه از نظر ساخت و سازهای مسکونی می‌باشد. این منطقه به ویژه ناحیه چینگر در منطقه ۲۲ شهرداری تهران و بخشی از منطقه ۲۱ شهرداری شهر قدس را دربر می‌گیرد. منطقه مورد مطالعه از شمال به رشته‌کوه‌های البرز مرکزی، از غرب به انتهای شهر قدس و شهریار، از شرق به فرودگاه مهرآباد و از جنوب به دشت تهران و شهریار محدود می‌شود. این ناحیه با ابعاد ۱۵ در ۱۵ کیلومتر مربع، در طول جغرافیایی ۵۱.۰۵ تا ۵۱.۲۸ درجه شرقی و عرض جغرافیایی ۳۵.۷۰ تا ۳۵.۷۹ درجه شمالی قرار دارد. این منطقه در شکل ۱ به وضوح نشان داده شده است.

۲-۲- داده‌های مورد استفاده

در این مطالعه، تصاویر ماهواره‌ای Sentinel-1 و Sentinel-2 متعلق به آژانس فضایی اروپا (ESA) با پوشش ابری کمتر از ۵٪، مربوط به بازه زمانی ۲۰۱۶ تا ۲۰۲۱، برای طبقه‌بندی تصاویر تهیه شدند. داده‌های Sentinel-1 در قالب (GRD) Ground Range Detected با وضوح مکانی ۱۰ متر دریافت شدند. همچنین تصاویر Sentinel-2 در سطح پردازش Level-2A شامل ۴، ۶ و ۳ باند طیفی با وضوح‌های مکانی ۱۰، ۲۰ و ۶۰ متر به‌دست آمدند.

با توجه به اینکه انواع مختلف پوشش‌های زمینی در فصل رشد بهتر قابل تفکیک هستند. تمامی تصاویر Sentinel-1 و Sentinel-2 در فصل‌های رشد جمع‌آوری شدند. لازم به ذکر است که تلاش شد تصاویر انتخاب‌شده دارای روز مشابهی از سال باشند (جدول ۱) تا شرایط نوری و محیطی نسبتاً مشابهی فراهم گردد. این هم‌زمانی در مقایسه طیفی نمونه‌های آموزشی اهمیت زیادی دارد.



شکل ۱- منطقه‌ی مورد مطالعه (منطقه‌ی ۲۲ شهر تهران)

اپتیک (Sentinel-2) و راداری (Sentinel-1) انجام گرفت. تصاویر اپتیک ابتدا تحت اصلاحات هندسی و اتمسفری قرار گرفتند تا اعوجاج‌های مکانی و اثرات ناشی از جو حذف شده و بازتاب سطحی دقیق‌تری حاصل شود [۲۸]. سپس محدوده‌ی مکانی منطقه ۲۲ شهر تهران استخراج گردید و شاخص‌های طیفی نظیر NDVI، SAVI و NDBI به‌منظور تحلیل وضعیت پوشش گیاهی، خاک و ساخت‌وساز محاسبه شدند [۲۹-۳۰]. در خصوص داده‌های راداری، اصلاحات هندسی و رادیومتریک با بهره‌گیری از نرم‌افزار SNAP صورت پذیرفت و فیلترهای کاهش نویز اسپکل Gamma-MAP به‌کار گرفته شدند تا کیفیت تصویر و قابلیت استخراج ویژگی‌ها افزایش یابد [۳۱-۳۲]. به‌منظور غنی‌سازی اطلاعات استخراج‌شده از تصاویر راداری، ویژگی‌های بافتی شامل کنتراست، همگنی و آنتروپی محاسبه گردید که در مراحل بعدی طبقه‌بندی تغییرات نقش مؤثری ایفا می‌کنند [۳۳]. در مرحله‌ی نهایی، داده‌های اپتیک و راداری با استفاده از روش‌های تلفیق ویژگی‌ها ترکیب شدند.

۳-۲- روش‌های مقایسه‌ی مستقیم

۳-۲-۱- رگرسیون

رگرسیون تصویر یکی از روش‌های پیشرفته و مؤثر برای شناسایی تغییرات محیطی است. این روش بر این فرض استوار است که مقادیر پیکسل‌های دو تصویر زمانی، به‌طور

جدول ۱- مشخصات داده‌های مورد استفاده

نوع سنجنده	Sentinel-1	Sentinel-2
مأموریت فضایی	ESA	ESA
سال‌های مورد استفاده	۲۰۲۱-۲۰۱۶	۲۰۲۱-۲۰۱۶
نوع داده	GRD (راداری)	Level-2A (اپتیک)
وضوح مکانی (متر)	۱۰	۱۰، ۲۰، ۶۰
تعداد باندها	-	۱۳
نوع باند	باند C	مرئی، NIR، SWIR
ویژگی خاص	قطبش VV، مدار نزولی	مدار نزولی


۳- روش تحقیق

ماهواره‌ی سنتینل-۱ (راداری) و سنتینل-۲ (اپتیک) بهره گرفته شده است. رویکرد تحقیق شامل سه مسیر مکمل و مقایسه‌پذیر است: روش مقایسه‌ی مستقیم، الگوریتم‌های یادگیری ماشین، و روش تلفیقی که با هدف افزایش دقت و قابلیت تفسیر نتایج طراحی شده‌اند. فرآیند تحقیق به‌صورت ساختاریافته و مرحله‌به‌مرحله در شکل ۲ نمایش داده شده است؛

۳-۱- پیش‌پردازات

در راستای ارتقاء دقت تحلیل تغییرات پوشش زمین، فرآیند پیش‌پردازش داده‌ها به‌صورت مجزا برای تصاویر

کلی با یکدیگر مرتبط هستند و می‌توانند رابطه خطی بین آن‌ها برقرار باشد. در این روش، ابتدا با استفاده از یک مدل خطی، ارتباط بین تصویر زمان ۱ و تصویر زمان ۲ برقرار می‌شود و تصویر زمان دوم شبیه‌سازی می‌گردد.



شکل ۲- مراحل انجام کار

محاسبه خطای مربعات

$$e^2 = (I2 - I2_simulate)^2 \quad (4)$$

روش رگرسیون تصویر به دلیل دقت بالا و قابلیت شناسایی تغییرات جزئی، ابزاری قدرتمند برای تحلیل تغییرات محیطی محسوب می‌شود. این روش با استفاده از تصاویر ماهواره‌ای و داده‌های زمانی مختلف، امکان تحلیل دقیق‌تر و جامع‌تری از تغییرات محیطی را فراهم می‌آورد.

۳-۲-۲- روش CVA^۱

تحلیل تغییر برداری (CVA) یکی از روش‌های پایه در شناسایی تغییرات در حوزه سنجش از دور است. این روش برای هر پیکسل در تصاویر زمانی، یک بردار تغییر محاسبه می‌کند که دو ویژگی اصلی آن، بزرگی و جهت بردار، اهمیت ویژه‌ای دارند [۱۷].

سپس با مقایسه تفاوت بین تصویر شبیه‌سازی شده زمان دوم و تصویر واقعی زمان ۲، تغییرات محیطی شناسایی می‌شوند. علاوه بر این، از روش نسبت‌گیری نیز می‌توان استفاده نمود تا دقت تحلیل‌ها افزایش یابد. روش رگرسیون تصویر بر اساس محاسبات روش کمترین مربعات است که در آن مقادیر ضرایب a و b ، که پارامترهای اصلی ارتباط خطی بین تصاویر دو زمان هستند، محاسبه می‌شود. در ادامه، روابط و معادلات استفاده شده در این روش شرح داده شده‌اند [۳۵].

شبیه‌سازی تصویر زمان دوم

$$I2_simulate = a * I1 + b \quad (1)$$

محاسبه ضریب a

$$b = \frac{\sum I2 - a \sum I1}{n} \quad (2)$$

محاسبه ضریب b

$$a = \frac{n \sum I2 * I1 - \sum I2 \sum I1}{n \sum I1 - (\sum I1)^2} \quad (3)$$

^۱ Change Vector Analysis

۳-۲-۳- استفاده از ترکیب‌های باندى

در این بخش از شاخص‌های طیفی مختلف، برای تحلیل و شناسایی محیطی استفاده شده است.

۳-۲-۳-۱- شاخص توسعه شهری (NDBI)^۱

شاخص توسعه شهری نرمال شده (NDBI) به منظور شناسایی مناطق شهری و ساخت و سازها استفاده می‌شود. این شاخص بر اساس تفاوت بین باند مادون قرمز نزدیک (NIR) و باند مادون قرمز کوتاه (SWIR1) محاسبه می‌شود و به صورت زیر بیان می‌شود [۳۷].

$$NDBI = \frac{(SWIR1 - NIR)}{(SWIR1 + NIR)} \quad (۷)$$

این شاخص برای تعیین ساخت و سازها بسیار مفید است زیرا باند SWIR1 به دلیل تفاوت‌های مشخص در بازتابندگی مواد ساختمانی در مقایسه با مناطق طبیعی، اطلاعات دقیقی فراهم می‌کند.

۳-۲-۳-۲- شاخص پوشش گیاهی (NDVI)^۲

شاخص نرمال شده تفاوت پوشش گیاهی (NDVI) یکی از رایج‌ترین شاخص‌ها برای شناسایی پوشش گیاهی است. این شاخص از تفاوت بین باند مادون قرمز نزدیک (NIR) و باند قرمز (RED) استفاده می‌کند.

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (۸)$$


NDVI به دلیل توانایی بالا در تشخیص سلامت و تراکم پوشش گیاهی محبوب است. بازتابندگی بالای مادون قرمز نزدیک در گیاهان سالم و جذب قوی باند قرمز در کلروفیل گیاهان این شاخص را به ابزاری کارآمد تبدیل کرده است [۳۸].

۳-۲-۳-۳- شاخص خاک (OSAV)^۳


شاخص نرمال شده اختلاف سطح خاک (OSAV) به منظور شناسایی خاک‌ها و مناطق بدون پوشش گیاهی

برای اجرای این روش، حداقل به دو باند طیفی از هر تصویر نیاز است. این بردار تغییر بین دو تصویر زمانی محاسبه می‌شود و به کمک آن می‌توان تغییرات موجود در هر پیکسل را تحلیل کرد. در صورتی که تعداد تصاویر بیشتر از دو باشد، مقایسه باید به صورت جفت‌جفت میان تصاویر انجام شود.

شکل کلی این روش در شکل ۳ نشان داده شده است، و در شکل ۴ نحوه محاسبه بزرگی و جهت بردار تغییر ارائه شده است.



شکل ۳- شمای کلی روش شناسایی تغییرات CVA [۳۶]



شکل ۴- نحوه محاسبه بزرگی و جهت بردار تغییر در روش شناسایی تغییرات CVA [۳۶]

بزرگی بردار تغییر نشان‌دهنده میزان تغییر در هر پیکسل است. فرمول محاسبه بزرگی به صورت زیر است.

$$M = \sqrt{\Delta I_x^2 + \Delta I_y^2} \quad (۵)$$

که در آن ΔI_x و ΔI_y تغییرات در باندهای مختلف طیفی هستند.

جهت بردار تغییر نشان‌دهنده نوع و سمت تغییر است. فرمول محاسبه جهت به صورت زیر است:

$$\theta = \arcc\left(\frac{\Delta I_y}{\Delta I_x}\right) \quad (۶)$$

^۱ Normalized Difference Built-up Index

^۲ Normalized Difference Vegetation Index

^۳ Optimized Soil Adjusted Vegetation Index

استفاده می‌شود. این شاخص بر اساس باند مادون قرمز نزدیک (NIR) و باند قرمز (RED) محاسبه می‌شود.

$$OSAVI = \frac{1.5 \cdot (NIR - RED)}{(NIR + RED + 0.16)} \quad (9)$$

OSAVI با تغییرات در بازتابندگی سطوح خاک سازگار شده و از عوامل کالیبراسیون برای بهبود دقت استفاده می‌کند، که آن را برای مطالعات خاک و محیط‌های نیمه خشک ایده‌آل می‌کند [۳۹].

۳-۲-۳-۴- شاخص تفاوت نرمال شده آب (MNDWI)^۱

شاخص MNDWI به منظور شناسایی منابع آبی و محدوده‌های آبی طراحی شده است. این شاخص از تفاوت بین باند سبز (GREEN) و باند مادون قرمز کوتاه (SWIR1) استفاده می‌کند.

$$MNDWI = \frac{(GREEN - SWIR1)}{(GREEN + SWIR1)} \quad (10)$$

MNDWI به دلیل توانایی بالا در تشخیص آب‌های سطحی و کاهش اثرات مناطق ساخت و ساز و شهرها بر تصاویر ماهواره‌ای مورد استفاده قرار می‌گیرد. با استفاده از این شاخص می‌توان محدوده‌های آبی را با دقت بیشتری شناسایی کرد [۴۰].

۳-۴-۳- تلفیق داده‌های راداری و نوری

۳-۴-۱- تلفیق داده در سطح ویژگی

در این مطالعه، برای تحلیل دقیق‌تر و بهره‌گیری از اطلاعات مکمل داده‌های اپتیک و رادار، فرآیند تلفیق داده در سطح ویژگی مورد استفاده قرار گرفته است. در گام نخست، تعداد ۱۰ ویژگی بافتی شامل کنتراست^۲، ناهمگنی^۳، همگنی^۴، ASM، انرژی^۵، حداکثر^۶، آنتروپی^۷،

میانگین^۸، واریانس^۹ و همبستگی^{۱۰} با استفاده از ماتریس GLCM^{۱۱} از هر یک از تصاویر اپتیک و رادار استخراج شده‌اند. این ویژگی‌ها با استفاده از نرم‌افزار SNAP، در یک پنجره ۵ در ۵ و در تمامی جهات محاسبه شده‌اند.

انتخاب باندها برای تحلیل بافتی از اهمیت بالایی برخوردار است. در بسیاری از مطالعات، به منظور افزایش دقت استخراج ویژگی‌های بافتی، ابتدا یک باند پانکروماتیک مجازی برای تصاویر اپتیک ایجاد می‌شود. این رویکرد نیز در این پژوهش به کار گرفته شده است، به گونه‌ای که ابتدا از تصاویر ۱۲ باندهی ماهواره سنتینل-۲، باند پانکروماتیک مجازی ساخته شده و سپس ویژگی‌های بافتی از آن استخراج گردیده‌اند. ویژگی‌های بافتی به دلیل اطلاعات تکمیلی که از ساختارهای سطح زمین ارائه می‌دهند، نقش مهمی در تحلیل داده‌ها دارند. به عنوان مثال، آنتروپی در مناطق شهری به دلیل پیچیدگی ساختاری، معمولاً بیشتر از مناطق آب، خاک یا پوشش گیاهی است. این ویژگی‌ها مکمل اطلاعات طیفی تصاویر هستند و انتظار می‌رود که استفاده از آن‌ها در کنار ویژگی‌های طیفی، دقت نقشه تغییرات نهایی را افزایش دهد. از آنجا که برخی ویژگی‌های بافتی ممکن است اطلاعات مشابهی ارائه دهند و تمایز کافی نداشته باشند، لازم است با کاهش ابعاد، تنها ویژگی‌هایی که اطلاعات متمایز و با تمایز بالا دارند، برای مراحل بعدی استفاده شوند. برای این منظور، از تبدیل مؤلفه‌های اصلی (PCA) استفاده شده است. در این روش، سه مؤلفه اول که بیشترین تمایز اطلاعاتی را دارند، به عنوان ویژگی‌های انتخابی در نظر گرفته شده‌اند. این رویکرد علاوه بر افزایش دقت تحلیل، سرعت پردازش را نیز بهبود می‌بخشد.

در ادامه، ویژگی‌های بافتی منتخب به مجموعه ویژگی‌های طیفی افزوده شده و داده‌ها با استفاده از ضرایب تلفیق مناسب ترکیب شده‌اند. در فرآیند تلفیق، ضرایب مربوط به مؤلفه LL از داده‌های اپتیک و سایر ضرایب از داده‌های رادار استخراج شده‌اند. این تلفیق به گونه‌ای طراحی شده است که از اطلاعات مکمل هر دو منبع داده بهره‌برداری بهینه صورت گیرد. فرآیند کامل استخراج

^۸ mean

^۹ variance

^{۱۰} correlation

^{۱۱} Gray-Level Co-occurrence Matrix

^۱ Modified Normalized Difference Water Index

^۲ contrast

^۳ dissimilarity

^۴ homogeneity


^۵ energy

^۶ max

^۷ entropy

کند. شکل ۵. فرآیند استخراج و تلفیق ویژگی‌های بافتی و طیفی از داده‌های اپتیک و رادار. با استفاده از این روش، دقت تشخیص تغییرات و تحلیل ویژگی‌های سطح زمین بهبود یافته و کارایی پردازش داده‌ها نیز افزایش یافته است.

ویژگی‌های بافتی، کاهش ابعاد و تلفیق آن‌ها با ویژگی‌های طیفی در شکل ۱ نمایش داده شده است. این روش با استفاده از مطالعات پیشین [۴۱-۴۲-۴۳] توسعه داده شده و انتظار می‌رود به بهبود نتایج تحلیل تغییرات کمک شایانی




شکل ۵- روش انجام کار تلفیق داده در سطح ویژگی

۵- بحث و نتیجه‌گیری

۵-۱- رگرسیون

نقشه تغییرات محاسبه شده با استفاده از روش رگرسیون تصویر شدت تغییرات بین دو بازه زمانی مختلف را به صورت بصری و با بهره‌گیری از یک مقیاس رنگی به تصویر می‌کشد. در این نقشه، مناطق مشکی نشان‌دهنده نواحی با تغییرات اندک یا بدون تغییر هستند، در حالی که مناطق زرد رنگ معرف نواحی با تغییرات قابل توجه می‌باشند. بررسی نقشه نشان می‌دهد که تغییرات قابل توجه عمدتاً در نواحی خاصی از منطقه متمرکز هستند. به عنوان مثال، مناطق کوهستانی در بخش‌های بالایی نقشه تغییرات شدیدی را نشان می‌دهند که ناشی از فرایندهای طبیعی مانند فرسایش خاک، تغییرات پوشش گیاهی، یا رانش زمین است. این تغییرات ممکن است به درصدهای بالایی از تغییرات شدتی معادل ۴۰ تا ۵۰ درصد برسد.




شکل ۶- تغییرات ایجاد شده با استفاده از روش رگرسیون

در مقابل، مناطق شهری که در بخش‌های میانی و پایینی نقشه قرار دارند، تغییرات متنوعی را در شدت نشان می‌دهند که ممکن است به دلیل فعالیت‌های انسانی نظیر ساخت‌وساز، تغییرات کاربری زمین، یا گسترش

زیرساخت‌های شهری رخ داده باشد. تغییرات در این مناطق در بازه ۲۰ تا ۲۵ درصد متغیر است. نتایج این بخش نشان می‌دهد که نواحی کوهستانی و بخش‌های طبیعی بیشتر تحت تأثیر فرایندهای طبیعی قرار دارند، در حالی که نواحی شهری تحت تأثیر فعالیت‌های انسانی متنوعی قرار می‌گیرند.

۵-۲- روش CVA

در این بخش، تحلیل بردار تغییرات (CVA) برای شناسایی و ارزیابی تغییرات در چهار کلاس مختلف شامل ساخت و ساز، پوشش گیاهی، آب و خاک انجام شد. نتایج به نشان می‌دهد که در کلاس ساخت و ساز، تغییرات قابل توجهی معادل ۲۰ درصد رخ داده که نشان‌دهنده افزایش مداخلات انسانی و توسعه شهری در منطقه است. در کلاس پوشش گیاهی، تغییرات ۱۴ درصد ثبت شده که احتمالاً به دلیل تغییرات فصلی یا فعالیت‌های کشاورزی است. در کلاس آب، تغییرات متوسط ۴ درصد بوده که ممکن است به نوسانات سطح آب و تغییر در ساختار منابع آبی مرتبط باشد. در نهایت، کلاس خاک نیز تغییرات ۴۰ درصدی را نشان می‌دهد که می‌تواند به تغییرات کاربری زمین، فرسایش خاک یا دیگر عوامل محیطی مرتبط باشد.



شکل ۷- تغییرات ایجاد شده با استفاده از روش CVA

۵-۳- استفاده از ترکیب‌های بانندی

در این بخش، از نقشه‌های بانندی (تغییر کرده و نکرده) برای تحلیل تغییرات محیطی در بازه زمانی ۲۰۱۶ تا ۲۰۲۱ استفاده شده است. این نقشه‌ها، که با تفاضل مقادیر شاخص‌های مختلف بین دو زمان تولید شده‌اند، تغییرات


محیطی را به صورت بصری نمایش می‌دهند و نقاط بدون تغییر را از مناطقی که تغییرات قابل توجهی داشته‌اند تفکیک می‌کنند. هر شاخص مورد استفاده در این پژوهش NDVI، MNDWI، OSAVI و ویژگی خاصی از محیط را هدف قرار داده و نقشه‌های change no change حاصل، بینش جامعی از تغییرات را ارائه می‌دهند. نقشه‌های بانندی حاصل از شاخص NDVI به وضوح نشان می‌دهند که گسترش مناطق ساخته شده، عمدتاً در بخش‌های میانی و شهری نقشه رخ داده است. این مناطق، که در سال ۲۰۱۶ حدود ۲۰ درصد از کل منطقه را شامل می‌شدند، تا سال ۲۰۲۱ به ۲۷ درصد افزایش یافته‌اند. این افزایش ۷ درصدی به طور مستقیم ناشی از گسترش زیرساخت‌ها، فعالیت‌های ساخت و ساز و تغییر کاربری زمین در مناطق شهری است. در مقابل، نواحی پیرامونی و روستایی تغییرات کمتری را تجربه کرده‌اند و در نقشه‌های تفاضلی به صورت مناطق تیره‌تر نمایش داده شده‌اند، که نشان‌دهنده ثبات نسبی در این مناطق است.

نقشه‌های بانندی شاخص NDVI نیز تغییرات قابل توجهی را در پوشش گیاهی منطقه نشان می‌دهند. در این نقشه‌ها، کاهش مقادیر NDVI در مناطق شهری به وضوح مشاهده می‌شود، که این کاهش به دلیل توسعه شهری و فعالیت‌های انسانی مانند ساخت و ساز و تغییر کاربری زمین رخ داده است. در مقابل، نواحی طبیعی و روستایی در حاشیه نقشه افزایش نسبی پوشش گیاهی را تجربه کرده‌اند که احتمالاً به دلیل احیای اراضی و فعالیت‌های حفاظت از محیط زیست بوده است. کاهش مساحت پوشش گیاهی متراکم از ۲۵ درصد در سال ۲۰۱۶ به ۲۰ درصد در سال ۲۰۲۱، نشان‌دهنده تأثیرات قابل توجه فعالیت‌های انسانی بر منابع طبیعی است. این کاهش، که معادل ۵ درصد از کل منطقه است، نیازمند توجه ویژه به مدیریت منابع طبیعی و پایش تغییرات زیست‌محیطی است.

برای تحلیل تغییرات در محدوده‌های آبی، از شاخص MNDWI استفاده شده است. نقشه‌های بانندی این شاخص نشان می‌دهند که محدوده‌های آبی در بیشتر بخش‌های نقشه تغییر قابل توجهی نداشته‌اند و عمده تغییرات مشاهده شده به تغییرات سطحی آب مربوط می‌شود. کاهش اندک ۴ درصدی مساحت مناطق آبی، از ۵ درصد در سال ۲۰۱۶ به ۹ درصد در سال ۲۰۲۱، نشان‌دهنده ثبات نسبی در این نواحی است. این نتایج، علاوه بر نمایش پایداری

مناطق از ۳۰ درصد در سال ۲۰۱۶ به ۴۰ درصد در سال ۲۰۲۱ افزایش یافته است، که نشان‌دهنده تغییرات قابل‌توجه در برخی از نواحی روستایی است. در شکل ۸ مقدار تغییرات ایجاد شده بین سال ۲۰۱۶ تا ۲۰۲۱ برای ۴ شاخص در نظر گرفته شده آورده شده‌است. برای نمایش بهتر تغییرات و مقایسه دقیق‌تر شاخص‌ها، نتایج در قالب جدول شماره ۲ ارائه شده‌اند تا دید بهتری نسبت به روند تغییرات در بازه زمانی موردنظر فراهم شود.


منابع آبی، می‌توانند اطلاعات ارزشمندی برای مدیریت بهتر منابع آبی منطقه فراهم کنند. نقشه‌های باینری شاخص OSAVI تغییرات مربوط به خاک و مناطق با پوشش گیاهی پراکنده را نشان می‌دهند. در این نقشه‌ها، نواحی با مقادیر بالای OSAVI (رنگ‌های روشن) عمدتاً در مناطق ساخت و ساز و ساز و خاکی مشاهده می‌شوند که گسترش آن‌ها به دلیل کاهش پوشش گیاهی متراکم و افزایش فعالیت‌های خاکی است. مساحت این



شکل ۸- نقشه های تغییرات ایجاد شده (الف) خاک (ب) ساخت و ساز شده (ج) پوشش گیاهی (د) آب

جدول ۲- نسبت تغییرات ایجاد شده

شاخص	سال ۲۰۱۶	سال ۲۰۲۱	میزان تغییر	توضیحات
NDBI	20%	27%	↑ 7%	گسترش زیرساخت‌ها و ساخت‌وساز در مناطق شهری
NDVI	25%	20%	↓ 5%	کاهش پوشش گیاهی به دلیل توسعه شهری
MNDWI	5%	9%	↑ 4%	تغییرات سطحی آب، ثبات نسبی منابع آبی
OSAVI	30%	40%	↑ 10%	افزایش فعالیت‌های خاکی و کاهش پوشش گیاهی متراکم



شکل ۹- مقدار اختلافات بین شاخص‌های محاسبه شده بین سال ۲۰۲۱ تا ۲۰۱۶

انتخاب باندها برای تحلیل بافت بسیار مهم است و در بسیاری از مطالعات انجام شده، معمولاً برای تصاویر اپتیک، در صورت عدم وجود باند پانکروماتیک، این باند به صورت مجازی ساخته می‌شود. در این پروژه نیز این رویکرد اتخاذ شده و ابتدا از تصاویر ۱۲ باندهی سنتینل-۲، باند پانکروماتیک مجازی ساخته شده است. این تصاویر با دقت بالا امکان استخراج ویژگی‌های بافتی را فراهم می‌کنند که برای تحلیل دقیق‌تر تغییرات سطح زمین بسیار مؤثر است.

- استخراج ویژگی‌های بافتی از تصاویر اپتیک
ابتدا با استفاده از باندهای موجود و ایجاد باند پانکروماتیک مجازی، ویژگی‌های بافتی استخراج شده‌اند. این ویژگی‌ها به تحلیل دقیق‌تر تفاوت‌های ساختاری و ترکیبی سطح زمین کمک می‌کنند.
- استخراج ویژگی‌های بافتی از تصاویر رادار
تصاویر رادار نیز به دلیل توانایی خود در ارائه اطلاعات شبانه‌روزی و در شرایط آب و هوایی مختلف، اطلاعات بافتی ارزشمندی ارائه می‌دهند. ویژگی‌های استخراج شده از این تصاویر به شناسایی تغییرات جزئی و دقیق در سطح زمین کمک می‌کنند.
- مقایسه و تحلیل ویژگی‌های بافتی
پس از استخراج ویژگی‌ها، این داده‌ها مورد تحلیل و مقایسه قرار گرفته‌اند تا تفاوت‌ها و تغییرات میان دو دوره زمانی مشخص شود

۵-۴- تلفیق داده‌های سنتینل-۱ و سنتینل-۲ در سطح ویژگی


در این مطالعه، برای تحلیل دقیق‌تر تغییرات سطح زمین، از ویژگی‌های بافتی استخراج شده از تصاویر اپتیک و رادار استفاده شده است. برای این منظور، تعداد ۱۰ ویژگی بافتی با استفاده از نرم افزار SNAP استخراج شده‌اند. این ویژگی‌ها از ماتریس هم‌رخدادی سطح خاکستری (GLCM) استخراج شده و اندازه پنجره محاسبه آن ۵ پیکسل در تمامی جهات در نظر گرفته شده است.

جدول ۵- پارامترهای شبکه عصبی MLP مورد استفاده

ویژگی	توضیحات
Contrast	میزان تفاوت بین شدت‌های پیکسلی مجاور
Dissimilarity	تفاوت مطلق شدت پیکسل‌ها
Homogeneity	میزان یکنواختی توزیع شدت پیکسل‌ها
ASM (Angular Second Moment)	اندازه‌ای از یکنواختی بافت
Energy	مجموع مجذور شدت پیکسل‌ها
Max	بیشترین مقدار شدت پیکسلی
Entropy	میزان اختلال یا تصادفی بودن توزیع شدت پیکسل‌ها
Mean	میانگین شدت پیکسل‌ها
Variance	میزان پراکندگی شدت پیکسل‌ها

برای تحلیل داده‌های تلفیقی حاصل از تصاویر اپتیک و رادار می‌باشد. ، یکی از روش‌های به‌کارگرفته شده، طبقه‌بندی با استفاده از شبکه عصبی چندلایه پرسپترون (MLP) است.


در این قسمت، پس از استخراج ویژگی‌های بافتی از تصاویر ماهواره‌ای مربوط به سال‌های ۲۰۱۶ و ۲۰۲۱، مرحله بعدی شامل استفاده از الگوریتم‌های پیشرفته طبقه‌بندی




شکل ۱۱- طبقه بندی تصاویر تلفیق شده الف) ۲۰۱۶ ب) ۲۰۲۱

۸۵٪ کاهش یافته است. این نتایج بیانگر عملکرد قوی روش تلفیقی در شناسایی و طبقه‌بندی دقیق تغییرات پوشش زمین در طول زمان است. در بخش بعدی، تعداد پیکسل‌های تغییر یافته در هر کاربری با استفاده از نتایج حاصل از این طبقه‌بندی نمایش داده خواهد شد. این تحلیل به ما کمک می‌کند تا بفهمیم چه مقدار از زمین در هر نوع کاربری دستخوش تغییر شده است.

این تصویر نتایج حاصل از طبقه‌بندی داده‌های تلفیقی تصاویر راداری و نوری برای سال‌های ۲۰۱۶ و ۲۰۲۱ را نشان می‌دهد. همان‌طور که مشاهده می‌شود، دقت طبقه‌بندی در هر دو سال قابل‌توجه است. در سال ۲۰۱۶، دقت کلی طبقه‌بندی (Overall Accuracy) به ۹۱٪ و ضریب کاپا (Kappa Coefficient) به ۸۹٪ رسیده است. در سال ۲۰۲۱، دقت کلی طبقه‌بندی به ۸۶٪ و ضریب کاپا به



شکل ۱۳- تعداد پیکسل‌های تغییر کرده سال ۲۰۱۶ تا ۲۰۲۱




شکل ۱۳- تعداد پیکسل‌های تغییر کرده از یک کلاس به کلاس دیگر سال ۲۰۱۶ تا ۲۰۲۱ (الف) تغییرات ایجاد شده در کلاس آب (ب) تغییرات ایجاد شده در کلاس راه (ج) تغییرات ایجاد شده در کلاس پوشش گیاهی (د) تغییرات ایجاد شده در کلاس ساخت و ساخت (ه) تغییرات ایجاد شده در کلاس خاک

نمودار بالا نشان می‌دهد که تغییرات تعداد پیکسل‌های مربوط به هر کاربری زمین در طول سال‌های ۲۰۱۶ و ۲۰۲۱ دارای نوسانات قابل توجهی بوده است. تعداد پیکسل‌های مربوط به کاربری آب از ۱۹,۹۴۱ در سال ۲۰۱۶ به ۱۸,۶۵۸ در سال ۲۰۲۱ کاهش یافته است، که نشان‌دهنده کاهش ۱,۲۸۳ پیکسل است. همچنین تعداد پیکسل‌های پوشش گیاهی از ۱۵۸,۴۳۳ در سال ۲۰۱۶ به ۱۴۳,۹۲۴ در سال ۲۰۲۱ افزایش یافته است، که نشان‌دهنده کاهش ۱۴,۵۰۹ پیکسل می‌باشد. در کاربری خاک، تعداد پیکسل‌ها از ۷۸۲,۲۶۹ در سال ۲۰۱۶ به ۸۲۰,۷۷۰ در سال ۲۰۲۱ افزایش یافته است که اختلاف ۳۸,۵۰۱ پیکسل را نشان می‌دهد. تعداد پیکسل‌های ساختمان‌ها

از ۲۲۰,۹۸۰ در سال ۲۰۱۶ به ۲۰۰,۱۶۱ در سال ۲۰۲۱ کاهش یافته و نشان‌دهنده کاهش ۲۰,۸۱۹ پیکسل است. تعداد پیکسل‌های جاده‌ها نیز از ۱۵۶,۷۹۳ در سال ۲۰۱۶ به ۱۲۹,۳۵۳ در سال ۲۰۲۱ کاهش یافته که اختلاف ۲۷,۴۴۰ پیکسل را نشان می‌دهد.

برای بررسی بیشتر تغییرات هر کلاس کاربری به کلاس دیگر، در این مرحله تغییرات را به دقت تحلیل و نتایج حاصل از تحلیل‌ها را در شکل ۱۴ نشان داده شده اند. این تحلیل به ما کمک می‌کند تا بفهمیم چگونه کاربری‌های مختلف زمین در طول زمان تغییر کرده‌اند و هر کلاس کاربری چه میزان به کلاس دیگر تبدیل شده است. این اطلاعات می‌تواند به برنامه‌ریزی بهتر و مدیریت مؤثرتر منابع زمینی کمک کند.



شکل ۱۴- پیکسل‌های تغییر یافته از یک کلاس به کلاس دیگر در هر ۵ کلاس در نظر گرفته

برای بررسی دقیق‌تر تغییرات در هر کلاس کاربری، هر کدام از کلاس‌ها مورد تحلیل قرار گرفتند و تعداد پیکسل‌های تغییر کرده در هر کلاس بررسی شد. این تحلیل به شناسایی میزان و نوع تغییرات در هر کلاس کاربری کمک می‌کند. به عنوان مثال، با این روش می‌توان تعیین کرد که چه تعداد پیکسل از کلاس «آب» به کلاس «جاده» تغییر یافته‌اند یا چه تعداد پیکسل از کلاس «پوشش گیاهی» به کلاس «ساخت و ساز» تبدیل شده‌اند. این اطلاعات به تحلیل دقیق‌تر تغییرات محیطی و بهبود برنامه‌ریزی‌های مدیریتی کمک می‌کند.

برای بررسی دقیق‌تر تغییرات در هر کلاس کاربری، هر کدام از کلاس‌ها به صورت جداگانه تحلیل شدند و تعداد پیکسل‌های تغییر یافته در هر کلاس بررسی شد. این تحلیل به شناسایی میزان و نوع تغییرات در هر کلاس کاربری کمک می‌کند. برای مثال، تعداد ۱۸۲۵۸ پیکسل از کلاس آب به ثابت، ۱۲۰۰ پیکسل به جاده، ۷۰۰ پیکسل به پوشش گیاهی و ۶۰۰ پیکسل به ساخت و ساز تغییر یافته‌اند. همچنین، در کلاس جاده، ۲۱۰۰۴ پیکسل ثابت مانده و ۹۰۰ پیکسل به آب، ۱۳۰۰ پیکسل به پوشش گیاهی و ۱۵۰۰ پیکسل به ساخت و ساز تغییر یافته‌اند. در کلاس پوشش گیاهی،

۱۵۷۹۲۴ پیکسل ثابت مانده و ۱۸۲۵۸ پیکسل به خاک، ۹۰۰ پیکسل به آب و ۲۴۰۰ پیکسل به ساخت و ساز تغییر یافته‌اند. در کلاس ساخت و ساز، ۱۰۰۰۰ پیکسل ثابت مانده و ۵۴۰۰ پیکسل به آب، ۳۰۰۰ پیکسل به جاده و ۱۲۰۰ پیکسل به پوشش گیاهی تغییر یافته‌اند. نهایتاً در کلاس خاک، ۴۲۰۱۶ پیکسل ثابت مانده و ۱۸۲۵۸ پیکسل به آب، ۱۵۶۷۹۳ پیکسل به جاده و ۱۲۰۰۰ پیکسل به ساخت و ساز تغییر یافته‌اند. این تحلیل به ما کمک می‌کند تا بفهمیم چه مقدار از زمین در هر نوع کاربری دستخوش تغییر شده است و می‌تواند به بهبود برنامه‌ریزی‌های مدیریتی و محیطی کمک کند. تصویری که همراه این متن است، تغییرات پیکسل‌ها بین کلاس‌های مختلف را در بازه زمانی ۲۰۱۶ تا ۲۰۲۱ نشان می‌دهد. در این تصویر، محور افقی کلاس‌های اولیه و محور عمودی تعداد پیکسل‌های تغییر کرده را نشان می‌دهد. رنگ‌های مختلف نشان‌دهنده تغییرات به کلاس‌های مختلف هستند: آبی برای تغییر به آب، قرمز برای تغییر به جاده، سبز برای تغییر به پوشش گیاهی، زرد برای تغییر به ساخت و ساز و صورتی برای تغییر به خاک. این تحلیل‌ها به ما امکان می‌دهند تا با دقت بیشتری تغییرات محیطی و ساختاری را شناسایی کنیم.

۶- نتیجه‌گیری

در این پژوهش، روش‌های مختلف سنجش از دور شامل تحلیل تغییر برداری (CVA)، رگرسیون، و شاخص‌های گوناگون مورد بررسی قرار گرفتند. نتایج حاصل از این روش‌های مستقیم نشان دادند که تغییرات محیطی در کلاس‌های مختلف کاربری زمین تقریباً مشابه بوده و تغییرات چشمگیری در کلاس‌های ساخت‌وساز (۱۳ درصد) و پوشش گیاهی (۱۵ درصد) مشاهده شد. همچنین، تغییرات در منابع آبی و خاکی به ترتیب ۴ درصد و ۱۱ درصد بودند. هرچند نتایج بین روش‌ها نزدیک

منابع

به هم بودند، اما وابستگی زیادی به شاخص اتسو داشتند. برای دقت بیشتر و تحلیل جامع‌تر، داده‌های سنتینل-۱ و سنتینل-۲ تلفیق شدند و از ویژگی‌های بافتی استخراج شده از تصاویر اپتیک و رادار استفاده گردید. این تلفیق داده‌ها نتایج بهتری ارائه داد؛ به‌طوری که دقت کلی طبقه‌بندی در سال ۲۰۱۶ برابر با ۹۱٪ و ضریب کاپا ۸۹٪ و در سال ۲۰۲۱ دقت کلی به ۸۶٪ و ضریب کاپا به ۸۵٪ رسید. علاوه بر این، توانستیم درصد تغییرات را شناسایی کنیم و تعداد پیکسل‌های تغییر یافته بین کلاس‌های مختلف را نیز به دست آوریم. به‌عنوان مثال، تعداد ۱۸۲۵۸ پیکسل از کلاس آب به خاک، ۱۲۰۰ پیکسل به جاده، ۷۰۰ پیکسل به پوشش گیاهی و ۶۰۰ پیکسل به ساخت‌وساز تغییر یافته‌اند. همچنین، در کلاس جاده، ۲۱۰۰۴ پیکسل ثابت مانده و ۹۰۰ پیکسل به آب، ۱۳۰۰ پیکسل به پوشش گیاهی و ۱۵۰۰ پیکسل به ساخت‌وساز تغییر یافته‌اند. در کلاس پوشش گیاهی، ۱۵۷۹۲۴ پیکسل ثابت مانده و ۱۸۲۵۸ پیکسل به خاک، ۹۰۰ پیکسل به آب و ۲۴۰۰ پیکسل به ساخت‌وساز تبدیل شده‌اند. در نهایت، در کلاس خاک، ۴۲۰۱۶ پیکسل ثابت مانده و ۱۸۲۵۸ پیکسل به آب، ۱۵۶۷۹۳ پیکسل به جاده و ۱۲۰۰۰ پیکسل به ساخت‌وساز تبدیل شده‌اند. این نتایج به ما کمک می‌کنند تا تغییرات محیطی و ساختاری را با دقت بیشتری شناسایی کرده و برنامه‌های مدیریتی دقیق‌تری را برای مناطق مختلف طراحی نماییم.

سپاسگزاری

در پایان، نویسندگان قصد دارند از تمام افراد و سازمان‌هایی که زمینه ایجاد این پژوهش را فراهم آورده‌اند تشکر کنند: آژانس فضایی اروپا جهت رایگان در اختیار قرار دادن داده‌های سنتینل - ۱، سنتینل-۲ و نرم‌افزارهای رایگان.

- [۱] Turner, B. L., Lambin, E. F., & Reenberg, A. (2007). The emergence of land change science for global environmental change and sustainability. *Proceedings of the National Academy of Sciences*, 104(52), 20666–20671. <https://doi.org/10.1073/pnas.0704119104>
- [۲] Lambin, E. F., Geist, H. J., & Lepers, E. (2003). Dynamics of land-use and land-cover change in tropical regions. *Annual Review of Environment and Resources*, 28(1), 205–241. <https://doi.org/10.1146/annurev.energy.28.050302.105459>
- [۳] Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823–870. <https://doi.org/10.1080/01431160600746456>

- [۴] Drusch, M., et al. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>
- [۵] Torres, R., et al. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9–24. <https://doi.org/10.1016/j.rse.2011.05.028>
- [۶] Claverie, M., et al. (2018). The Harmonized Landsat and Sentinel-2 surface reflectance data set. *Remote Sensing of Environment*, 219, 145–161. <https://doi.org/10.1016/j.rse.2018.09.002>
- [۷] Ban, Y., Jacob, A., & Gamba, P. (2015). Spaceborne SAR data for global urban mapping at 30 m resolution using a robust urban extractor. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 28–37. <https://doi.org/10.1016/j.isprsjprs.2015.01.011>
- [۸] Hafner, M., et al. (2020). Semi-supervised change detection using Sentinel-1 and Sentinel-2 time series. *Remote Sensing*, 12(3), 456. <https://doi.org/10.3390/rs12030456>
- [۹] Zhang, X., et al. (2021). GLC_FCS10: A 10 m resolution global land cover dataset based on Sentinel imagery. *Remote Sensing*, 13(5), 922. <https://doi.org/10.3390/rs13050922>
- [۱۰] Coppin, P., & Bauer, M. (1996). Digital change detection in forest ecosystems with remote sensing imagery. *Remote Sensing Reviews*, 13(3–4), 207–234. <https://doi.org/10.1080/02757259609532305>
- [۱۱] Zhu, X. X., et al. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 8–36. <https://doi.org/10.1109/MGRS.2017.2762307>
- [۱۲] Chen, Y., et al. (2021). OFNet: Optical flow guided network with dual attention for change detection. *Remote Sensing*, 13(2), 254. <https://doi.org/10.3390/rs13020254>
- [۱۳] Chen, J., et al. (2003). A simple method for detecting change in remotely sensed images by using the change vector analysis. *International Journal of Remote Sensing*, 24(8), 1657–1666. <https://doi.org/10.1080/01431160210163095>
- [۱۴] Li, X., et al. (2019). Urban change detection using Sentinel-1 data and support vector machines. *Remote Sensing Letters*, 10(5), 451–460. <https://doi.org/10.1080/2150704X.2019.1585183>
- [۱۵] Johnson, B. A., et al. (2020). Land cover classification in Africa using Sentinel-2 and artificial neural networks. *Remote Sensing*, 12(3), 456. <https://doi.org/10.3390/rs12030456>
- [۱۶] Davis, C., et al. (2019). Evaluating CNN architectures for satellite image classification. *ISPRS International Journal of Geo-Information*, 8(5), 219. <https://doi.org/10.3390/ijgi8050219>
- [۱۷] Clark, M., et al. (2021). Improving urban land cover classification using optimized U-Net architecture. *Remote Sensing*, 13(10), 1987. <https://doi.org/10.3390/rs13101987>
- [۱۸] Fawzy, M., & Barsi, Á. (2022). Urban land cover classification using high-resolution imagery and U-Net. *Remote Sensing*, 14(3), 678. <https://doi.org/10.3390/rs14030678>
- [۱۹] Alkhediri, M., et al. (2018). Object-based change detection using PCA and high-resolution imagery. *Remote Sensing Letters*, 9(2), 123–132. <https://doi.org/10.1080/2150704X.2017.1410292>
- [۲۰] Peterson, J., et al. (2020). Deep learning for urban change detection: A comparative study. *Remote Sensing*, 12(6), 1012. <https://doi.org/10.3390/rs12061012>
- [۲۱] Zhang, Y., et al. (2021). Multi-temporal urban expansion analysis using machine learning. *Remote Sensing*, 13(7), 1356. <https://doi.org/10.3390/rs13071356>
- [۲۲] Ghorbanzadeh, O., et al. (2020). Fusion of Sentinel-1 and Sentinel-2 data for urban change detection. *Remote Sensing*, 12(4), 678. <https://doi.org/10.3390/rs12040678>
- [۲۳] Li, Y., et al. (2022). Siamese networks for fine-grained urban change detection. *Remote Sensing*, 14(1), 123. <https://doi.org/10.3390/rs14010123>
- [۲۴] Hafner, M. (2021). Multi-modal learning for urban change detection using Sentinel data (Doctoral dissertation). [University Repository]
- [۲۵] Mastro, L., et al. (2020). Urban and disaster change detection using random forest and Sentinel-1. *Remote Sensing*, 12(9), 1456. <https://doi.org/10.3390/rs12091456>
- [۲۶] Zhang, X., et al. (2022). Urban change detection using CNN and Sentinel-2 imagery. *Remote Sensing*, 14(2), 456. <https://doi.org/10.3390/rs14020456>

- [۲۷] Saeedi, D., et al. (2024). Land cover classification based on machine learning and deep learning methods using Sentinel-2 satellite imagery: A case study of the western urban area of Tehran. *Journal of Surveying Science and Technology*, 14(2), 55–69..
- [۲۸] ESA. (2020). Sentinel-2 User Handbook. European Space Agency.
- [۲۹] Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Special Publication*, 351, 309.
- [۳۰] Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309.
- [۳۱] ESA. (2021). Sentinel-1 Toolbox - SNAP Documentation. European Space Agency.
- [۳۲] Lopes, A., Touzi, R., & Nezry, E. (1990). Adaptive speckle filters and scene heterogeneity. *IEEE Transactions on Geoscience and Remote Sensing*, 28(6), 992–1000.
- [۳۳] Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610–621.
- [۳۴] Zhang, Y., & Mishra, R. (2012). A review and comparison of commercially available SAR image fusion techniques. *International Journal of Remote Sensing*, 33(14), 4434–4460.
- [۳۵] Pohl, C., & Van Genderen, J. L. (1998). Multisensor image fusion in remote sensing: Concepts, methods and applications. *International Journal of Remote Sensing*, 19(5), 823–854.
- [۳۵] Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823–870.
- [۳۶] Malila, W. A. (1980). Change vector analysis: An approach for detecting forest changes with Landsat. *Proceedings of the 6th Annual Symposium on Machine Processing of Remotely Sensed Data*, Purdue University, 326–335.
- [۳۷] Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583–594.
- [۳۸] Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150.
- [۳۹] Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95–107.
- [۴۰] Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033.
- [۴۱] Joshi, N., Baumann, M., Ehammer, A., Fensholt, R., Grogan, K., Hostert, P., & Kuemmerle, T. (2016). A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sensing*, 8(1), 70.
- [۴۲] Mahyoub, S., Fadil, A., Mansour, E. M., Rhinane, H., & Al-Nahmi, F. (2019). Fusing of optical and synthetic aperture radar (SAR) remote sensing data: A systematic literature review. *ISPRS Archives*, XLII-4/W12, 127–134.
- [۴۳] Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95–107.