

پایش تغییرات ساختمانی در تصاویر ماهواره‌ای با توان تفکیک مکانی بالا: مقایسه روش‌های کلاسیک و یادگیری عمیق

محدثه مسواری^۱، رضا شاه‌حسینی*^۲، محسن نیرومند^۳

^۱ دانشجوی دکتری، گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشگاه تهران
m.mesvari@ut.ac.ir

^۲ دانشیار، گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشگاه تهران
rshahosseini@ut.ac.ir

^۳ کارشناس ارشد، گروه سیستم اطلاعات مکانی، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشگاه تهران
k.niroomand@ut.ac.ir

(دریافت: آذر ۱۴۰۳، تصویب: دی ۱۴۰۴)

چکیده

شناسایی تغییرات در ساختارهای شهری با استفاده از تصاویر ماهواره‌ای نقش مهمی در برنامه‌ریزی شهری، توسعه زیرساخت‌ها، تصمیم‌گیری و مدیریت بحران ایفا می‌کند. رشد سریع شهرها در کنار بروز بلایای طبیعی همچون زلزله و سیل، منجر به دگرگونی‌های چشمگیری در نواحی شهری شده است؛ موضوعی که لزوم پایش دقیق و مستمر این تغییرات را برجسته می‌سازد. روش‌های سنتی شناسایی تغییرات که مبتنی بر تحلیل دستی تصاویر هستند، با چالش‌هایی نظیر هزینه‌های بالا، مقیاس‌پذیری محدود و زمان‌بر بودن مواجه‌اند. پیشرفت‌های اخیر در پردازش تصاویر و یادگیری عمیق، امکان شناسایی خودکار تغییرات ساختاری را فراهم کرده‌اند. در این پژوهش، مجموعه‌ای از روش‌ها مورد ارزیابی و مقایسه قرار گرفته‌اند که شامل روش‌های سنتی مانند تحلیل بردار تغییرات (CVA)، تشخیص تغییرات چندمتغیره (MAD) و تحلیل ویژگی‌های کند (SFA) و نیز روش‌های مبتنی بر یادگیری عمیق مانند نسخه‌ی عمیق‌شده‌ی تحلیل ویژگی‌های کند (DSFA) و شبکه‌های توجه دوگانه (DAS) می‌گردد. روش‌های CVA و MAD اگرچه در شناسایی تغییرات عمده عملکرد نسبتاً مناسبی دارند، اما در تشخیص تغییرات جزئی یا پیچیده عملکرد ضعیفی از خود نشان می‌دهند. به‌عنوان نمونه، دقت این دو روش در مطالعه حاضر به ترتیب برابر با ۴۹.۳۲٪ و ۶۵.۶۷٪ گزارش شده است. در مقابل، روش DSFA با دستیابی به دقت ۸۴.۰۷٪ عملکرد بهتری نشان داده، هرچند نیاز بالای آن به منابع محاسباتی، کاربرد عملی آن را محدود می‌سازد. در میان روش‌های ارزیابی‌شده، روش DAS با دقت ۹۵.۶۸٪ بهترین عملکرد را ارائه داده و با بهره‌گیری مؤثر از سازوکارهای توجه مکانی و طیفی، قادر به تمایز تغییرات واقعی از نویز است. نتایج این پژوهش برتری روش‌های مبتنی بر یادگیری عمیق در شناسایی دقیق، کارآمد و خودکار تغییرات ساختاری را نشان می‌دهد و آن‌ها را به ابزاری ارزشمند جهت پایش و تصمیم‌گیری شهری تبدیل می‌نماید.

واژگان کلیدی: پایش تغییرات، تصاویر ماهواره‌ای، روش‌های یادگیری عمیق، تحلیل ویژگی‌های آهسته عمیق، شبکه‌های دوگانه توجه.

* نویسنده رابط

۱- مقدمه

طی دهه‌های اخیر، عواملی همچون افزایش جمعیت و صنعتی‌شدن، منجر به رشد و توسعه شهرهای سراسر جهان گشته‌است. در نتیجه این امر، گستره مناطق ساخت‌وساز شده افزایش یافته و احداث ساختمان‌ها، مناظر شهری را تغییر داده‌است [۱]. از سوی دیگر، هرساله پدیده‌هایی همچون سیل، زلزله و آتش‌سوزی سبب تخریب بناهای ساخته‌شده در نقاط مختلف جهان می‌گردد [۲]. بر این اساس، پایش تغییرات ساختمان‌ها امری ضروری در راستای سیاست‌گذاری کاربری اراضی، برنامه‌ریزی شهری، مدیریت بحران‌ها امدادسانی تلقی می‌گردد. پایش تغییرات فرایندی است که در آن تصاویر سنجش از دوری چندزمانه مورد تحلیل و بررسی قرار گرفته و تغییرات ایجاد شده در تصاویر از مناطق با موقعیت مکانی یکسان، شناسایی و آشکار می‌گردند [۳].

روش‌های غیر خودکار و سنتی پایش تغییرات، فرایندی زمان‌بر و پرهزینه محسوب می‌شوند. این امر اهمیت پایش تغییرات به صورت خودکار را نمایان می‌سازد. امروزه و با پیشرفت علوم در حوزه پردازش تصاویر و هوش مصنوعی، محققان گام‌های مهمی در این راستا برداشته‌اند [۳]. از سوی دیگر، توسعه علوم دورسنجی و دسترسی به تصاویر ماهواره‌ای متنوع با وضوح مکانی، زمانی و طیفی مختلف، امری تاثیرگذار در زمینه پایش تغییرات ساختمان‌ها تلقی می‌گردد [۴، ۵]. در این میان افزایش وضوح مکانی تصاویر ماهواره‌ای، سبب بهبود دقت پایش و شناسایی تغییرات ساختمان‌ها می‌شود. با این حال، استفاده از تصاویر با قدرت تفکیک مکانی بسیار بالا جهت پایش تغییرات، با چالش‌های گوناگونی روبه‌رو است. از جمله آن‌ها می‌توان به تغییرات زاویه تصویربرداری، تداخل نویزها، وجود سایه مربوط به عوارض مختلف سطح زمین، تغییر فصل، روز، زمان، شرایط آب‌وهوایی و محل قرارگیری خورشید هنگام اخذ تصاویر و جابه‌جایی‌های ارتفاعی اشاره نمود [۶، ۷].

مقاله حاضر با هدف ارائه روشی کارآمد جهت تشخیص تغییرات ساختمانی با استفاده از تصاویر ماهواره‌ای با قدرت تفکیک بالا و مدل‌های یادگیری ماشین تهیه شده است. بر خلاف دقت پایین شناسایی تغییرات جزئی روش‌های سنتی و غیر خودکار [۸]، این پژوهش می‌کوشد با بهره‌گیری از الگوریتم‌های یادگیری عمیق، از جمله شبکه‌های عصبی

پیشگی، دقت و سرعت تشخیص تغییرات را بهبود داده و امکان پایش خودکار و دقیق‌تری فراهم آورد. این رویکرد می‌تواند مدیران و برنامه‌ریزان شهری را در نظارت بر روند توسعه و مدیریت بحران‌های مرتبط با زیرساخت‌های شهری یاری داده و با ارائه اطلاعات جامع و به‌موقع، آن‌ها را در اتخاذ تصمیمات مؤثرتر توانمند سازد.

۲- پیشینه پژوهش

در سال‌های اخیر، تحقیقات گسترده‌ای با هدف بهبود روش‌های تشخیص تغییرات در محیط‌های شهری انجام شده‌است. جیانگ و همکاران (۲۰۲۴)، با هدف تشخیص تخریب ساختمان‌ها پس از زلزله ترکیه، یک مدل مبتنی بر یادگیری عمیق و شبکه DenseNet-121 را ارائه نمودند. این مدل با استفاده از داده‌های چندزمانه ماهواره‌ای و تعریف تابع زیان Tanimoto، توانست دقتی فراتر از ۷۰٪ در معیار F1-score به‌دست آورد. این پژوهش بر قابلیت مدل در شناسایی دقیق تخریب‌های ساختمانی و قابلیت تعمیم آن به سایر کاربردهای سنجش‌از‌دور تأکید دارد [۹]. در مطالعه‌ای دیگر، وان و همکاران (۲۰۲۴)، در روشی مبتنی بر مدل‌های Diffusion و با بهره‌گیری از ماژول Difference Attention و مبدل تصویر به متن، به تشخیص تغییرات ساختمان‌ها پرداختند. ارزیابی‌ها در چهار مجموعه داده، حاکی از برتری این مدل نسبت به روش‌های مرسوم یادگیری عمیق بوده و قابلیت آن در تولید خروجی‌های دقیق و جزئی از نواحی تغییریافته را اثبات می‌نماید [۱۰]. زیتسلزبرگر و پودهورانی (۲۰۲۳) یک روش پیشرفته بر پایه یادگیری انتقالی جهت شناسایی تغییرات ساختمانی در محیط‌های شهری معرفی نمودند [۱۱]. این روش با بهره‌گیری از داده‌های چندمنظوره ماهواره‌های Sentinel-1 و Sentinel-2، به شناسایی تغییرات ساختاری ساختمان‌ها پرداخت. نتایج، نشان‌دهنده دقت کلی بیش از ۹۵٪ مدل بوده و بر توانایی آن به‌ویژه در شرایط بحرانی همچون جنگ تأکید می‌نماید.

دینگ و همکاران (۲۰۲۱) شبکه یادگیری عمیق DSA-Net^۱ را به منظور تشخیص تغییرات ساختمانی در تصاویر با وضوح بالا پیشنهاد نمودند [۱۲]. مدل DSA-Net

^۱ Deeply Supervised Attention-guided network

با استفاده از مازول CLA-con-SAM به همگراسازی ویژگی‌های لایه‌های مختلف و کاهش ناهمگونی بین ویژگی‌های تصویر اصلی و ویژگی‌های استخراج شده می‌پردازد. این مدل با کاهش خطاهای تشخیصی، به مقدار IoU ۸۰.۰۵٪ در مجموعه داده LEVIR-CD و ۷۹.۳۵٪ در مجموعه داده WHU دست یافته‌است.

لیو و همکاران (۲۰۲۱) به منظور رفع مشکل حاصل از ایجاد مناطق با پوشش‌دهی ناقص در روند استخراج تغییرات ساختمان‌ها، یک مدل شبکه کانولوشنی عمیق Siamese با وظیفه دوگانه (DTCDCSN)^۱ را پیشنهاد نمودند [۱۳]. مدل پیشنهادی از یک زیرشبکه تشخیص تغییرات و دو زیرشبکه قطعه‌بندی معنایی تشکیل شده‌است. از این رو، مدل می‌تواند تشخیص تغییرات و قطعه‌بندی معنایی را به‌طور هم‌زمان انجام داده و با استفاده از یک مازول توجه دوگانه (DAM)^۲ ویژگی‌های سطح عوارض را بهتر استخراج نماید. نتایج حاصل با استفاده از مجموعه داده WHU، مقدار ۷۵.۸۳٪ در معیار اعتبارسنجی IoU را نمایش می‌دهد.

هوانگ و همکاران (۲۰۱۹) یک روش یادگیری عمیق به نام ABCDHDIL^۳ جهت تشخیص تغییرات ساختمان در تصاویر با قدرت تفکیک مکانی بالا معرفی نمودند [۸]. در این روش، ویژگی‌های طیفی، بافتی و مکانی از طریق عملیات کانولوشنی استخراج و یک بردار ویژگی برای هر پیکسل ایجاد می‌گردد. ارزیابی این روش در چهار منطقه آزمایشی صورت پذیرفته و دقت کلی ۹۱.۷٪ حاکی از عملکرد مناسب مدل است.

وانگ و همکاران (۲۰۱۸) از شبکه‌های عصبی کانولوشنی بازگشتی (R-CNN)^۴ جهت تشخیص تغییرات در تصاویر سنجش از دوری با وضوح بالا بهره گرفتند [۱۴]. مدل تغییرات مبتنی بر تغییر (SRRCNN)^۵ در این تحقیق به دقت کلی ۹۸.۸٪ دست یافته‌است. این امر، برتری مدل مورد استفاده بر روش‌های سنتی مانند آنالیز بردار تغییرات (CVA)^۶ و همچنین برخی مدل‌های یادگیری عمیق

همچون حافظه کوتاه‌مدت بلند (LSTM)^۷ را نشان می‌دهد. این روش با کاهش تشخیص اشتباه تغییرات و بهبود دقت در شناسایی تغییرات واقعی، امکان استخراج ویژگی‌های طیفی، هندسی و متنی را بدون نیاز به تنظیمات دستی پیچیده و زمان‌بر فراهم می‌کند.

شیائو و همکاران (۲۰۱۷) روشی بر اساس قطعه‌بندی را جهت تشخیص تغییرات ساختمان با استفاده از تصاویر سنجش از راه دور با قدرت تفکیک مکانی بالا ارائه نمودند [۱۵]. این روش، راه حلی نوین در راستای تشخیص تغییرات مبتنی بر عارضه^۸ محسوب می‌گردد. این روش با محاسبه اندازه تصویر تفاضلی به‌عنوان ویژگی تغییر آغاز شده و تقسیم‌بندی از طریق کمینه‌سازی تابع انرژی^۹ مبتنی بر گراف صورت می‌پذیرد. در این راستا، ویژگی‌های تغییر و ویژگی‌های تصویر در هر مرحله ترکیب شده و پیش‌زمینه‌ای از عوارض تغییر یافته و پس‌زمینه‌ای از ناحیه بدون تغییر ایجاد می‌نمایند. در ادامه، تحلیل همپوشانی مکانی برای تطبیق عوارض تغییر یافته به کار گرفته می‌شود. از جمله مزیت‌های این روش می‌توان به تهیه دو نقشه متناظر از تغییرات موضوعی، هندسی، و عددی از طریق استفاده هم‌زمان از ویژگی‌های تصویر و تغییر اشاره نمود. همچنین، با تعریف پس‌زمینه به‌عنوان ناحیه بدون تغییر، چالش‌های مربوط به عوارض ناسازگار در این روش کاهش می‌یابد. نتایج حاصل از پنج مجموعه داده با وضوح مکانی بالا نشان می‌دهد که این روش با میانگین مقدار FI-Score بیش از ۸۰٪ دقت و جامعیت بالایی در شناسایی تغییرات مبتنی بر عارضه داراست.

مرور پژوهش‌های اخیر نشان می‌دهد که اگرچه کاربرد الگوریتم‌های یادگیری عمیق در حوزه پایش تغییرات ساختمانی گسترش یافته است، بخش قابل توجهی از این مطالعات تنها بر داده‌هایی با زاویه دید عمودی، تغییرات آشکار و شرایط تصویری کنترل شده تمرکز داشته‌اند. همچنین، ارزیابی هم‌زمان و تطبیقی روش‌های کلاسیک و یادگیری عمیق بر روی داده‌هایی با ویژگی‌های پیچیده نظیر زاویه دید جانبی، تنوع مکانی بالا و تغییرات جزئی، کمتر مورد توجه قرار گرفته است. در این راستا، پژوهش

۱ Dual Task Constrained Deep Siamese

۲ Dual Attention Module

۳ Automatic Building Change Detection in High-resolution Image Data using Deep Learning

۴ Recurrent Convolutional Neural Network

۵ Subtracted Faster Region-based Convolutional Neural Network

۶ Change Vector Analysis

۷ Long Short-Term Memory

۸ Object

۹ Energy Function

حاضر با بهره‌گیری از داده‌های واقعی و متنوع مجموعه S2Looking و مقایسه عملکرد پنج روش شناخته‌شده، در پی آن است تا خلأ مطالعاتی موجود را پوشش داده و مبنایی علمی جهت انتخاب مناسب‌ترین الگوریتم‌ها در کاربردهای عملی نظیر برنامه‌ریزی شهری و مدیریت بحران فراهم آورد. از این روی، انجام این تحقیق نه تنها از منظر روش‌شناسی حائز اهمیت است، بلکه به لحاظ کاربردی نیز پاسخ‌گوی نیاز روزافزون به پایش دقیق و قابل اتکای تغییرات در محیط‌های شهری است.

۳- مواد و روش‌ها


۳-۱- مجموعه داده

در این تحقیق مجموعه داده S2looking^۱ مورد استفاده قرار می‌گیرد که به طور ویژه جهت پایش تغییرات ساختمانی طراحی گردیده است [۱۶]. این مجموعه داده شامل تصاویر دو زمانه با زاویه دید جانبی است که به دلیل زاویه مایل، مناطق گسترده‌تری را پوشش داده و امکان بازدیدهای مکرر ماهواره‌ای از یک نقطه را افزایش می‌دهد. تصاویر موجود در این مجموعه با ابعاد ۱۰۲۴ در ۱۰۲۴ سلول^۲ دارای وضوح مکانی ۰.۵ تا ۰.۸ متر بوده و مناطق روستایی گوناگونی در سطح جهانی را شامل می‌شوند. این مجموعه داده بیش از ۶۵ هزار تغییر ساختمانی نشانه‌گذاری شده را در بر گرفته که به صورت دقیق، ساختمانی‌های احداث شده و تخریب شده در بازه زمانی سال ۲۰۱۷ تا ۲۰۲۰ میلادی را ثبت کرده‌اند [۱۶]. زاویه دید جانبی و تغییرات گسترده در شرایط نوری این تصاویر، تشخیص تغییرات را برای مدل‌های پردازش تصویر نسبت به تصاویر عمودی معمول، چالش‌برانگیزتر کرده و بستر مناسبی را برای توسعه الگوریتم‌های پیشرفته فراهم می‌سازد. به صورت کلی در این مجموعه داده زاویه Off-Nadir از حدود ۳۵- تا ۴۰ درجه متغیر هستند که بیانگر آن است که این تصاویر هم به صورت Back looking و هم به صورت Forward looking اخذ شده‌اند. به صورت کلی، ۲۸.۱٪ از زوج تصاویر این مجموعه داده دارای زاویه جانبی قابل توجه بوده و مابقی نزدیک به نادیر هست [۱۶]. نمونه-

ای از تصاویر مجموعه داده S2looking به همراه نقشه واقعیت مربوط به تغییرات ساختمانی‌ها طی بازه زمانی مورد نظر در شکل ۱ مشاهده می‌شود. همانطور که در این تصویر قابل مشاهده است، زاویه اخذ کمتر از میانگین زاویه انحراف از نادیر (۹.۸۶ درجه) است.



(ب) (ا)



(ج)

شکل ۱- نمونه‌ای از تصاویر مجموعه داده، (آ) سال ۲۰۱۷، (ب) سال ۲۰۲۰، (ج) نقشه تغییرات ساختمانی‌ها

۳-۲- پیش پردازش تصاویر

جهت افزایش دقت در روش‌های پایش تغییرات با استفاده از تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا، در ابتدا لازم است تصحیحاتی برای کاهش یا حذف اثرات نامطلوب، بر روی این تصاویر اعمال گردد. در این راستا، حذف نواحی تاریک ناشی از سایه عوارض سطح زمین و همچنین تصحیحات اتمسفری، صورت می‌پذیرد [۱۷، ۱۸].

۳-۳- روش‌شناسی تحقیق

پژوهش حاضر، با هدف پایش تغییرات ساختمانی‌ها به تحلیل تصاویر ماهواره‌ای می‌پردازد. به این منظور، روش‌های CVA^۳، MAD^۴، SFA^۵، DSFA^۶ و DAS^۷ مورد استفاده

^۳ Change Vector Analysis

^۴ Multivariate Alteration Detection

^۵ Slow Feature Analysis

^۶ Deep Slow Feature Analysis

^۷ Dual Attentive Fully Convolutional Siamese Networks

^۱ Satellite Side-Looking Dataset

^۲ pixel

قرار می‌گیرند. در ادامه، هر کدام از روش‌های ذکر شده مورد بررسی قرار می‌گیرند.

CVA-۱-۳-۳

در روش CVA، مقادیر بازتاب طیفی به صورت بردارهایی از باندهای طیفی در نظر گرفته می‌شوند و یک بردار تغییر به صورت تفاضل بردارهای هر سلول در زمان‌های متفاوت محاسبه می‌شود [۱۹]. اندازه بردار تغییر به منظور یافتن سلول‌های تغییر یافته به کار می‌رود و جهت این بردار نوع تغییر را مشخص می‌نماید. در راستای محاسبه بردار تغییر، رابطه ۱ جهت محاسبه تصویر تفاضلی مورد استفاده قرار می‌گیرد. در این رابطه b نشان‌دهنده شماره باند طیفی است. همچنین، $x_{1,b}$ و $x_{2,b}$ به ترتیب بیان‌گر بازتاب طیفی باند b در زمان‌های اولیه و ثانویه هستند [۲۰].

$$x_{D,b} = x_{2,b} - x_{1,b} \quad (1)$$

اندازه بردار تغییر (ρ) و زاویه تغییر (θ) با استفاده از تصویر تفاضلی و به ترتیب مطابق روابط ۲ و ۳ محاسبه می‌گردند. در این روابط B نشان‌دهنده تعداد کل باندهای طیفی تصویر است [۲۰].

$$\rho = \sqrt{\sum_{b=1}^B x_{D,b}^2} \quad (2)$$

$$\theta = \cos^{-1} \frac{1}{\sqrt{B}} \left(\frac{\sum_{b=1}^B x_{D,b}}{\sqrt{\sum_{b=1}^B x_{D,b}^2}} \right) \quad (3)$$

MAD-۲-۳-۳

شناسایی تغییرات چندمتغیره روشی نظارت‌نشده جهت تشخیص و پایش تغییرات ساختمان‌هاست [۲۱]. این روش به تجزیه و تحلیل تصاویر چندطیفی جهت شناسایی تغییرات می‌پردازد. در روش MAD، دو تصویر چندطیفی مربوط به دو زمان مختلف، از طریق تحلیل همبستگی خطی به گونه‌ای تبدیل می‌شوند که در تصویر تفاضلی، بیش‌ترین واریانس در هر باند ایجاد شود. این روش دارای سه مزیت مهم ذیل است [۲۱].

- ناهمبسته‌بودن مولفه‌ها

تمامی مؤلفه‌های MAD به‌طور کامل از یکدیگر ناهمبسته هستند؛ این ویژگی امکان مرتب‌سازی تغییرات مختلف را در مؤلفه‌های گوناگون تصویر نهایی فراهم می‌نماید.

- مرتب‌سازی بر اساس واریانس

مؤلفه‌های MAD بر اساس کاهش واریانس مرتب می‌گردند؛ به‌طوری‌که مؤلفه نخست بیش‌ترین تغییرات و اطلاعات را در مقادیر شدت سلولی خود شامل می‌شود، در حالی که مؤلفه آخر کمترین تغییرات را دارد.

- پایداری نسبت به تبدیل‌های خطی

متغیرهای MAD در برابر تبدیل‌های خطی شدت تصاویر اصلی پایدار هستند؛ این ویژگی سبب کاهش حساسیت روش به تغییرات جوی و تفاوت کالیبراسیون حسگرها در زمان‌های مختلف تصویربرداری می‌شود و نیاز به اصلاحات رادیومتر یا نرمال‌سازی را تا حد زیادی کاهش می‌دهد.

SFA-۳-۳-۳

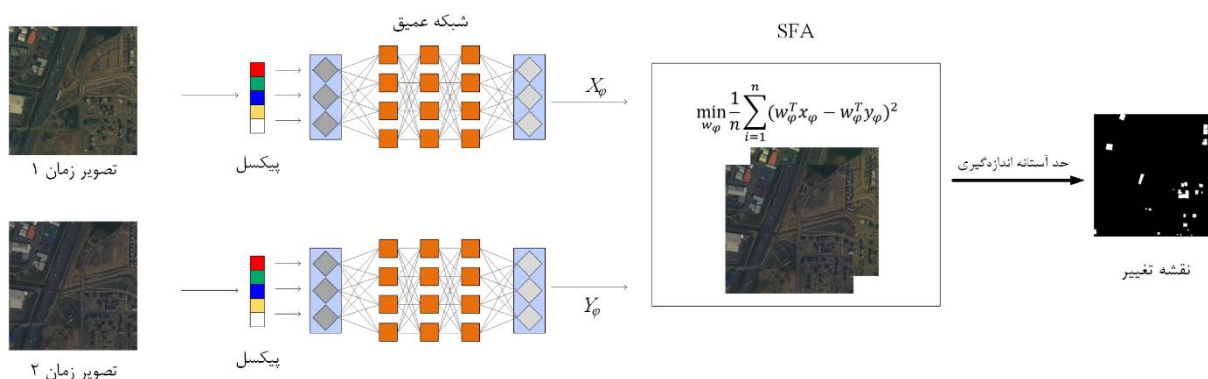
تحلیل ویژگی‌های آهسته یک روش نظارت‌نشده جهت شناسایی ویژگی‌های تغییر نیافته است که به طور عمده در تشخیص فعالیت‌های انسانی، متن و گسل به کار می‌رود [۲۲]. از منظر ریاضی این روش می‌تواند به صورت یک مسئله بهینه‌سازی در نظر گرفته شود. در این راستا، برای یک سیگنال ورودی چندبعدی X ، مجموعه‌ای از توابع Z به‌منظور به حداقل رساندن تغییرات زمانی سیگنال خروجی استفاده می‌شود. بر اساس روش SFA، تفاضل زمانی معمولاً به صورت جذر مشتق اول سیگنال خروجی محاسبه شده و بهینه‌سازی مطابق رابطه ۴ صورت می‌پذیرد [۲۳].

$$\Delta_j = \Delta(z_j) = z_j^2, j \in [1, \dots, M] \quad (4)$$

در این رابطه M تعداد کل ویژگی‌های استخراج شده توسط روش SFA، Δ میزان تغییرات زمانی سیگنال و z ویژگی استخراج شده یا سیگنال خروجی است. قیدهای این روش به صورت رابطه ۵ تعریف می‌گردند [۲۳].

DSFA - ۵-۳-۳

روش‌های تشخیص تغییر مبتنی بر تحلیل SFA به صورت خطی عمل می‌نمایند. جهت بهبود توانمندی شناسایی ویژگی‌ها و ارتقای عملکرد تشخیص تغییرات نهایی، روش DSFA توسعه داده شده است [۲۴]. در مدل DSFA، دو شبکه عمیق به منظور انتقال داده‌های ورودی دو زمانه به یک فضای ویژگی جدید به کار گرفته می‌شوند. در ادامه، روش SFA جهت استخراج پایدارترین مؤلفه‌های سلول‌های بدون تغییر و کاهش تأثیر آن‌ها در مناطق تغییر یافته به کار می‌رود تا مؤلفه‌های تغییر برجسته گردند [۲۴]. این روش به صورت نظارت‌نشده عمل می‌نماید؛ به این معنا که نیازی به استفاده از داده‌های برچسب‌گذاری شده طی مرحله آموزش نیست [۲۳]. معماری روش DSFA در شکل ۲ مشاهده می‌شود.



شکل ۲- معماری DSFA متشکل از دو شبکه عمیق

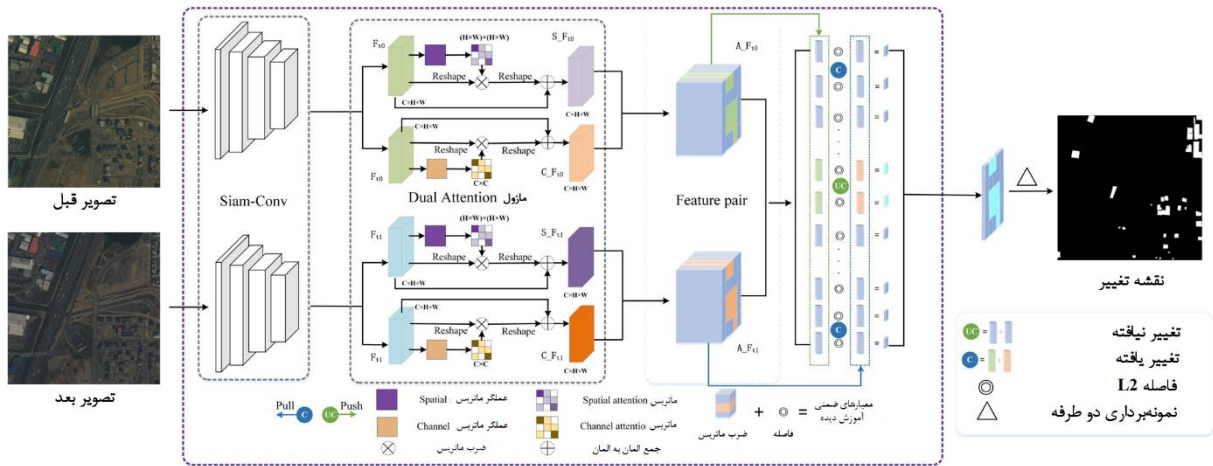
تفاوت‌ها به کار می‌رود. این فرایند شامل دو بخش Spatial attention و Channel attention می‌گردد [۲۵]. در بخش Spatial attention، تحلیل و تقویت روابط مکانی بین سلول‌ها صورت می‌پذیرد و در مرحله Channel attention وابستگی‌های طیفی بین ویژگی‌ها مدل‌سازی می‌شوند. در نهایت، خروجی این دو فرایند ترکیب شده و به فضای ویژگی منتقل می‌گردد تا مناطق تغییر یافته و بدون تغییر با دقت بیشتری تمایز داده شوند. در ادامه فرایندهای بخش Spatial attention و Channel attention مورد بررسی قرار می‌گیرند. شکل ۳ معماری شبکه DAS را نمایش می‌دهد [۲۵].

DAS - ۴-۳-۳

$$\begin{cases} \langle z_{jt} \rangle = 0 \\ \langle z_{jt}^2 \rangle = 1 \\ \forall i < j : \langle z_i z_{jt} \rangle = 0 \end{cases} \quad (5)$$

معادلات فوق به ترتیب بیان‌گر شرایط میانگین صفر، واریانس برابر یک و ناهمبستگی هستند. میانگین صفر محاسبات را ساده‌تر کرده و سرعت پردازش را افزایش می‌دهد. همچنین، واریانس یک سبب می‌شود هر سیگنال خروجی میزان معینی از اطلاعات را منتقل نماید. قید سوم نیز تضمین می‌کند سیگنال‌های خروجی از یکدیگر مستقل بوده و هیچ‌گونه همبستگی بین آن‌ها وجود ندارد. از آن جایی که در تصاویر سنجش از دوری ساختار زمانی پیوسته وجود ندارد، روش SFA به گونه‌ای توسعه یافته است که به جای مشتق اول، از تفاضل محدود استفاده کرده و امکان تشخیص تغییرات را فراهم آورد [۲۳].

تصاویر سنجش از دوری با قدرت تفکیک مکانی بالا، نسبت به تصاویر نوری معمولی، اطلاعات بیشتری ارائه داده و نیاز به الزامات پیچیده‌تری جهت استخراج ویژگی‌ها دارند. روش DAS جهت تشخیص تغییرات در تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا مورد استفاده قرار می‌گیرد [۲۵]. در این روش ویژگی‌های محلی به کمک ماژول Siam-Conv و با استفاده از جفت تصاویر با قدرت تفکیک مکانی بالا که در زمان‌های مختلف از یک مکان معین اخذ شده‌اند، تولید می‌گردند. در ادامه، فرایند dual-attention جهت ایجاد ارتباط بین ویژگی‌های محلی و برجسته‌سازی



شکل ۳- معماری شبکه DAS

• فرایند Spatial attention

مطابق آنچه بیان شد، نمایش دقیق و متمایز ویژگی‌ها جهت شناسایی نواحی تغییر یافته و تغییر نیافته از اهمیت ویژه‌ای برخوردار است. از آن جایی که مطالعات متعددی نشان داده‌اند استفاده از ویژگی‌های محلی ایجاد شده توسط شبکه‌های کاملاً کانولوشنی (FCNs) ممکن است منجر به طبقه‌بندی نادرست شود، ماژول Spatial attention به منظور مدل‌سازی مناسب بافت و غنای ویژگی‌های محلی معرفی می‌گردد. این ماژول با کدگذاری اطلاعات زمینه‌ای دوربرد در ویژگی‌های محلی، به بهبود عملکرد سیستم در شناسایی دقیق‌تر ویژگی‌ها و تغییرات منجر می‌شود [۲۶].

ویژگی F ، با عرض W ، ارتفاع H و تعداد باند طیفی C در فضای حقیقی و با استفاده از ماژول Siam-Conv تولید می‌گردد. این ویژگی به سه لایه کانولوشنی مشابه وارد می‌شود که هر کدام ویژگی‌های جدید Fa ، Fb و Fc را در همان ابعاد قبلی ایجاد می‌نمایند. در ادامه، ویژگی‌های Fa و Fb به فضای حقیقی با ابعاد C و N تصویر می‌شوند که N مطابق رابطه ۶ محاسبه می‌شود [۲۵].

$$N = W \times H \quad (6)$$

پس از محاسبه ضرب ماتریس ترانهاده ویژگی‌های Fa و نقشه Spatial attention از طریق لایه Softmax تهیه می‌شود. رابطه ۷ این فرایند را نشان می‌دهد [۲۵].

$$Fs_{ji} = \frac{\exp(Fa_i \cdot Fb_j)}{\sum_{i=1}^N \exp(Fa_i \cdot Fb_j)} \quad (7)$$

در این رابطه، Fs_{ji} نشان‌دهنده تاثیر ویژگی در موقعیت i بر ویژگی در موقعیت j است. مقادیر بالاتر Fs_{ji} ، بیان‌گر همبستگی بیشتر بین ویژگی‌ها است. در ادامه، ویژگی Fc به فضای حقیقی با ابعاد C و N تصویر می‌شود و پس از ضرب در Fs_{ji} ، به فضا با ابعاد C ، H و W بازمی‌گردد. در نهایت، نتیجه حاصل در متغیر مقیاس η ضرب شده و یک روند برابندگیری به منظور دستیابی به خروجی نهایی از طریق ویژگی‌های F صورت می‌پذیرد. رابطه ۸ این فرایند را شرح می‌دهد [۲۵].

$$Fsa_j = \eta \sum_{i=1}^N (Fs_{ji} Fc_j) + F_j \quad (8)$$

در این رابطه، مقدار اولیه η صفر در نظر گرفته شده و طی فرایند آموزش به تدریج به‌روز می‌گردد؛ به این ترتیب، وزن بیشتری را به خود اختصاص می‌دهد. در نتیجه، ویژگی‌های Fa در هر نقطه به صورت ترکیبی وزن‌دار از ویژگی‌های تمامی نقاط و ویژگی‌های اولیه محاسبه می‌گردد. این ویژگی‌ها دید کلی و زمینه‌ای را ایجاد کرده و بر اساس نقشه‌های Spatial Attention، به‌طور انتخابی زمینه‌ها را ترکیب می‌نمایند. این فرایند، ویژگی‌های مشابه را تقویت کرده و انسجام معنایی درون کلاس را بهبود می‌بخشد. در نتیجه، شبکه قادر به تمایز دقیق‌تر میان تغییرات و شبه‌تغییرات خواهد بود.

• فرایند Channel attention

در شبکه‌های عصبی، نقشه‌های ویژگی حاوی اطلاعات مختلفی از ورودی‌ها هستند که در قالب کانال‌ها ذخیره می‌شوند. هر کانال، ویژگی خاصی از داده‌ها را نمایان می‌سازند. هدف ماژول Channel Attention، شناسایی و تقویت روابط میان کانال‌ها است. این روابط به بهبود ویژگی‌های وابسته به یکدیگر کمک کرده و سبب شناسایی دقیق تغییرات موجود در داده‌ها می‌شود [۲۶]. برخلاف ماژول Spatial Attention که جهت استخراج ویژگی‌های جدید از لایه‌های کانولوشنی استفاده می‌کند، ماژول Channel Attention بدون نیاز به این لایه‌ها، روابط بین کانال‌ها را تقویت می‌نماید. در این ماژول، ابتدا لازم است جهت مدل کردن دقیق روابط بین کانال‌ها، ویژگی‌ها به فضای جدیدی تصویر گردند. به این منظور، ویژگی F استخراج شده توسط ماژول Siam-Conv از فضای حقیقی با ابعاد H ، C و W به فضای با ابعاد N و C منتقل می‌گردد؛ به طوری که N مطابق رابطه ۶ محاسبه می‌شود. در ادامه، با ضرب ماتریسی ویژگی F و ترانهاده آن، نقشه Channel Attention با استفاده از لایه Softmax تهیه می‌شود. بر این اساس، توزیع ویژگی‌های هر کانال نسبت به سایر کانال‌ها بر اساس رابطه ۹ محاسبه می‌شود [۲۵].

$$F_{x_{ji}} = \frac{\exp(F_i \cdot F_j)}{\sum_{i=1}^C \exp(F_i \cdot F_j)} \quad (9)$$

در این رابطه، $F_{x_{ji}}$ میزان تاثیر کانال i بر کانال j را نشان می‌دهد. هرچه ارتباط بین دو کانال قوی‌تر باشد، مقدار این متغیر بیشتر خواهد بود.

در مرحله بعد، حاصل در یک متغیر مقیاس γ ضرب شده و با اعمال عملیات تجمیع بر روی ویژگی‌ها، خروجی نهایی مطابق رابطه ۱۰ تولید می‌شود. در این راستا، مقدار اولیه γ برابر صفر در نظر گرفته شده و در طول فرایند آموزش به‌روزرسانی می‌گردد [۲۵].

$$F_{ca_j} = \gamma \sum_{i=1}^C (F_{x_{ji}} F_i) + F_j \quad (10)$$

در این ماژول، خروجی نهایی هر کانال با جمع وزن‌دار ویژگی‌های تمامی کانال‌ها و ویژگی اولیه خود کانال به‌دست می‌آید. این امر منجر به بهبود مدل‌سازی وابستگی معنایی

میان ویژگی‌ها و در نتیجه تشخیص موثر تغییرات میان داده‌ها می‌گردد.

در نهایت، مطابق رابطه ۱۱ تابع اتلاف Contrastive Loss جهت بهبود فرایند آموزش و شناسایی مناسب تغییرات مورد استفاده قرار می‌گیرد [۲۵].

$$\text{contrastive loss} = \sum_{i,j} \frac{1}{2} \left[\left((1 - y_{i,j}) d_{i,j}^2 + y_{i,j} \max(d_{i,j} - m, 0)^2 \right) \right] \quad (11)$$

در این رابطه، d_{ij} بیان‌گر فاصله بین بردارهای ویژگی مدل‌های قبل و بعد از تغییرات و m حد آستانه‌ای است که جهت تفکیک مناطق تغییر یافته در جفت تصاویر استفاده می‌شود. همچنین مقدار y_{ij} در صورتی که جفت پیکسل‌های متناظر تغییر یافته باشند یک و در غیر آن صورت صفر در نظر گرفته می‌شود.

۳-۴- اعتبارسنجی

جهت اعتبارسنجی هر یک از روش‌های مذکور، نقشه تغییرات ساختمانی‌ها با استفاده از مجموعه داده مورد نظر تهیه شده و معیارهای F1-Score، صحت^۱، دقت کلی^۲ و حساسیت^۳ مورد استفاده قرار می‌گیرند. لازم به ذکر است که این معیارهای اعتبارسنجی با توجه به نوع داده حاضر در نظر گرفته شده‌اند.

۳-۴-۱- دقت کلی

معیار دقت کلی به محاسبه نسبت برآوردهای صحیح مدل در مقایسه با برچسب‌های مرجع می‌پردازد. این معیار بر اساس رابطه ۱۲ محاسبه می‌گردد. در این رابطه TP ^۴ بیان‌گر برآوردهای مثبت واقعی و TN ^۵ بیان‌گر برآوردهای مثبت کاذب است [۲۷].

$$OA = \frac{TP + TN}{TotalSamples} \quad (12)$$

۱ Precision

۲ Overall Accuracy

۳ Sensitivity

۴ True Positive

۵ True Negative

۳-۴-۲- صحت

معیار صحت بر برآوردهای مثبت تمرکز کرده و مطابق رابطه ۱۳، بر اساس نسبت تعداد برآوردهای مثبت واقعی به کل برآوردهای مثبت محاسبه می‌گردد. در این رابطه FP^1 نشان‌دهنده برآوردهای منفی واقعی است [۲۷].

$$Precision = \frac{TP}{TP + FP} \quad (13)$$

۳-۴-۳- حساسیت

معیار اعتبارسنجی حساسیت جهت ارزیابی عملکرد مدل‌های طبقه‌بندی دودویی مورد استفاده قرار می‌گیرد. این معیار، توانایی مدل در شناسایی نمونه‌های مثبت واقعی را نشان می‌دهد و مطابق رابطه ۱۴ محاسبه می‌گردد. در این رابطه FN^2 نشان‌دهنده برآوردهای منفی کاذب است [۲۷].

$$Sensitivity = \frac{TP}{TP + FN} \quad (14)$$

حساسیت بالا نشان‌دهنده دقت بیشتر مدل در شناسایی صحیح کلاس مثبت و کاهش موارد مثبت از دست رفته است. این معیار در حوزه‌هایی همچون پزشکی، مخاطرات طبیعی و تشخیص تغییرات ساختمان‌ها که شناسایی صحیح موارد مثبت اهمیت بالایی دارد، به‌طور گسترده مورد استفاده قرار می‌گیرد.

۳-۴-۵- F1-Score

معیار F1-Score بر اساس میانگین هارمونیک معیارهای اعتبارسنجی حساسیت و صحت محاسبه شده و میان آن‌ها توازن برقرار می‌سازد. این معیار مطابق رابطه ۱۵ محاسبه می‌شود [۲۷].

$$F1-Score = \frac{Precision \times Sensitivity}{Precision + Sensitivity} \times 2 \quad (15)$$

۳-۴-۶- ضریب کاپا

در مواجهه با مجموعه داده‌های نامتوازن، استفاده از معیارهایی چون دقت کلی به تنهایی نمی‌تواند ارزیابی

دقیقی از عملکرد مدل ارائه دهد؛ زیرا ممکن است به دلیل عدم توازن کلاس‌ها، نتایج اغراق‌آمیزی حاصل شود. از این رو، ضریب کاپا به‌عنوان معیاری مکمل جهت سنجش میزان توافق بین نتایج مدل و واقعیت مورد استفاده قرار می‌گیرد. این شاخص، علاوه بر ارزیابی انطباق کلی، احتمال بروز توافق تصادفی را نیز در نظر می‌گیرد. مقدار ضریب کاپا در بازه ۱- تا ۱ قرار دارد؛ به‌طوری‌که مقدار ۱ نشان‌دهنده‌ی توافق کامل، مقدار صفر بیانگر توافق ناشی از تصادف، و مقادیر منفی حاکی از نبود توافق و حتی تضاد سیستماتیک میان پیش‌بینی‌های مدل و داده‌های واقعی است. این معیار مطابق رابطه ۱۶ محاسبه می‌شود. در این رابطه $p(a)$ نشان‌دهنده نسبت انطباق مشاهده‌شده و $p(e)$ بیانگر تطابق مورد انتظار تصادفی است [۲۸].

$$k = \frac{p(a) - p(e)}{1 - p(e)} \quad (16)$$

۴- نتایج پژوهش

نقشه تغییرات ساختمان‌ها با استفاده از روش‌های ذکرشده و بر اساس تصاویر اولیه و ثانویه مربوط به سال‌های ۲۰۱۷ و ۲۰۲۰ موجود در مجموعه‌داده S2Looking تهیه می‌گردند. نقشه‌های حاصل، جهت ارزیابی با نقشه‌های تغییرات برجسب‌گذاری‌شده آن مجموعه‌داده مقایسه می‌شوند. جدول ۱، نتایج اعتبارسنجی روش‌های مورد استفاده در تحقیق را نمایش می‌دهد.

جدول ۱- ارزیابی روش‌های پایش تغییرات ساختمان‌ها

| روش | دقت کلی (%) | صحت (%) | حساسیت (%) | F1-Score (%) | ضریب کاپا |
|------|-------------|---------|------------|--------------|-----------|
| CVA | ۷۴.۶۸ | ۴۶.۸۵ | ۸۹.۷۶ | ۴۹.۳۲ | ۰.۴۲ |
| MAD | ۹۲.۲۸ | ۵۲.۹ | ۸۰.۲۹ | ۶۵.۶۷ | ۰.۶۱ |
| SFA | ۹۲.۳۹ | ۵۸.۵۵ | ۸۲.۰۱ | ۶۹.۰۱ | ۰.۶۶ |
| DSFA | ۹۴.۷۲ | ۶۲.۰۵ | ۸۴.۰۷ | ۷۶.۶۹ | ۰.۷۳ |
| DAS | ۹۵.۶۸ | ۸۲.۳۵ | ۹۵.۵۷ | ۷۳.۲۱ | ۰.۷۹ |

یافته‌های این پژوهش نشان می‌دهد که روش‌های مختلف پایش تغییرات ساختمان‌ها با استفاده از مجموعه‌داده S2Looking کارایی متفاوتی در شناسایی تغییرات داشته و هرکدام دارای نقاط قوت و ضعف خاصی هستند. روش DAS با دقت کلی ۹۵.۶۸٪، حساسیت ۹۵.۵۷٪ و ضریب کاپا ۰.۷۹ عملکرد بسیار مطلوبی در تشخیص تغییرات ساختمانی ارائه داده است. این روش به

۱ False positive

۲ False Negative

واسطه به‌کارگیری رویکردهای تحلیلی پیشرفته، قادر به تمایز دقیق میان تغییرات واقعی و نویزها بوده و تغییرات جزئی را به نحو مناسبی شناسایی می‌نماید. همچنین، مقدار بالای معیار FI-Score نشان‌دهنده توانمندی DAS در تفکیک صحیح تغییرات واقعی از نویزها در مقایسه با سایر روش‌ها است. شکل ۴، نمونه‌ای از نقشه تغییرات تهیه شده توسط روش DAS را نمایش می‌دهد.



شکل ۴- نقشه تغییرات ساختمان‌ها با استفاده از DAS

همانند DAS، روش DSFA نیز نتایج مطلوبی را ارائه می‌دهد. این روش به‌ویژه با دقت و حساسیت بالا در تفکیک تغییرات جزئی، عملکرد بهتری را نسبت به روش‌های سنتی‌تر CVA و MAD نشان می‌دهد.



شکل ۵- نقشه تغییرات ساختمان‌ها با استفاده از DSFA

DSFA به‌خوبی قادر است تغییرات پیچیده و محیط‌های پر از نویز را شناسایی کند؛ با این حال به دلیل

پیچیدگی‌های محاسباتی بالاتر، به زمان و منابع محاسباتی بیشتری نیاز دارد. شکل ۵، نمونه‌ای از نقشه تغییرات تهیه شده با استفاده از روش DSFA را نمایش می‌دهد. روش‌های MAD به دلیل استفاده از تحلیل‌های چندمتغیره نسبت به الگوریتم‌های ساده‌تر عملکرد بهتری از خود نشان می‌دهد. این روش، با تکیه بر تحلیل همبستگی خطی بین تصاویر چندطیفی دو زمان مختلف، تغییرات را بر اساس واریانس مرتب‌سازی می‌نماید. این ویژگی به MAD امکان می‌دهد مهم‌ترین تغییرات را در مولفه‌های ابتدایی شناسایی کرده و تغییرات جزئی‌تر را در مولفه‌های بعدی قرار دهد. همچنین، این روش به دلیل پایداری در برابر تغییرات خطی شدت تصویر نسبت به تفاوت‌های جوی و کالیبراسیون سنجنده‌ها حساسیت کمتری دارد و در مقایسه با سایر روش‌ها به اصلاحات رادیومتری کمتری نیازمند است. علی‌رغم عملکرد مناسب در حذف نویزها، MAD در شناسایی دقیق تغییرات جزئی نسبت به الگوریتم‌های پیشرفته‌تر مانند DAS و DSFA محدودیت‌هایی دارد. شکل ۶، نقشه تغییرات ایجاد شده با استفاده از روش MAD را نشان می‌دهد.



شکل ۶- نقشه تغییرات ساختمان‌ها با استفاده از MAD

به دلیل ساختار بهینه‌سازی، روش SFA تغییرات جزئی را به طور مناسبی شناسایی کرده و در مقایسه با MAD، بهبودهای قابل توجهی را در معیارهای اعتبارسنجی به ثبت رسانده‌است. این الگوریتم با به‌کارگیری فیلترهای پیچیده‌تر، نویز را به میزان بیشتری کاهش داده و تغییرات را با دقت بالاتری ثبت کرده‌است. با این حال، خطاهایی در شناسایی برخی تغییرات جزئی‌تر مشاهده می‌شود که سبب کاهش دقت روش SFA در مقایسه با روش‌های DSFA و DAS

می‌شود. شکل ۷ نقشه تغییرات حاصل از روش SFA را نشان می‌دهد.



شکل ۷- نقشه تغییرات ساختمان‌ها با استفاده از SFA



شکل ۸- نقشه تغییرات ساختمان‌ها با استفاده از CVA

نقشه تغییرات حاصل از روش CVA نشان می‌دهد که این روش به‌طور عمده بر تغییرات کلی در مقدار سلول‌های تصاویر تکیه دارد و به همین دلیل از حساسیت بالایی برخوردار است. با این حال، اتکای زیاد به مقادیر سلول‌ها موجب شده این روش توانایی لازم جهت شناسایی دقیق تغییرات را نداشته باشد و بسیاری از نواحی را به‌اشتباه به‌عنوان تغییر شناسایی نماید. در نتیجه، میزان بالایی از نویزها و تغییرات غیرواقعی در نقشه تغییرات حاصل از این

مراجع

- [۱] H. Li, J. Peng, L. Yanxu, and H. Yi'na, "Urbanization impact on landscape patterns in Beijing City, China: A spatial heterogeneity perspective," *Ecological Indicators*, vol. 82, pp. 50-60, 2017.

۵- نتیجه‌گیری

پژوهش حاضر با هدف بهبود شناسایی تغییرات ساختمانی در تصاویر ماهواره‌ای با وضوح بالا، به مقایسه روش‌های سنتی و الگوریتم‌های یادگیری عمیق پرداخته است. نتایج نشان می‌دهد که روش‌های پیشرفته یادگیری عمیق همچون DAS و DSFA عملکرد مطلوبی در شناسایی دقیق تغییرات ساختمانی داشته و قادرند تغییرات واقعی را از نویز تفکیک نمایند. این الگوریتم‌ها در مقایسه با روش‌های سنتی‌تر همچون CVA و MAD که مقادیر سلول‌های تصاویر ماهواره و تحلیل‌های خطی وابسته هستند، دقت بالاتری در شناسایی تغییرات جزئی دارند و نقشه‌های تغییرات حاصل از آن‌ها میزان نویز پایین‌تری را نشان می‌دهد. الگوریتم DAS با دقت کلی ۹۵.۶۸٪ بهترین عملکرد را در شناسایی تغییرات ساختمانی از خود نشان داده‌است. روش DSFA نیز با دقت کلی ۸۴.۰۷٪، گزینه مناسبی جهت پایش تغییرات ساختمان‌ها محسوب می‌گردد. روش SFA نیز به‌عنوان یک روش نظارت‌نشده، عملکردی بهتری را در مقایسه با روش‌های سنتی از خود نشان می‌دهد. با این وجود، در مقایسه با روش‌های پیشرفته نظارت‌شده محدودیت‌هایی دارد. علی‌رغم نتایج مناسب، روش‌های یادگیری عمیق به منابع محاسباتی بیشتری نیاز دارند که ممکن است به‌کارگیری آن‌ها را با مشکلاتی مواجه نماید.

به‌طور کلی، یافته‌های این پژوهش ضرورت استفاده از روش‌های پیشرفته و مبتنی بر یادگیری عمیق جهت پایش تغییرات ساختمانی را نشان می‌دهد. نتایج دقیق و به‌هنگام این روش‌ها می‌تواند برنامه‌ریزان و مدیران شهری را در راستای اخذ تصمیمات صحیح یاری دهد. پیشنهاد می‌شود در تحقیقات آینده با استفاده از مجموعه داده‌های متنوع و الگوریتم پیشرفته یادگیری عمیق، کارایی فرایند پایش تغییرات ساختمان‌ها بهبود یابد.

- [۲] P. K. Yadav, S. Pande, R. S. Kushwah, M. Mishra, and D. K. Dubey, "Investigation of the impact of natural disasters on civil structures".
- [۳] T. Bai et al., "Deep learning for change detection in remote sensing: a review," *Geo-spatial Information Science*, vol. 26, no. 3, pp. 262-288, 2023.
- [۴] B. Du, L. Zhang, D. Tao, and D. Zhang, "Unsupervised transfer learning for target detection from hyperspectral images," *Neurocomputing*, vol. 120, pp. 72-82, 2013.
- [۵] L. Zhang, L. Zhang, D. Tao, and X. Huang, "Tensor discriminative locality alignment for hyperspectral image spectral-spatial feature extraction," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 1, pp. 242-256, 2012.
- [۶] M. Li, X. Liu, X. Wang, and P. Xiao, "Detecting building changes using multi-modal Siamese multi-task networks from very high resolution satellite images," *IEEE Transactions on Geoscience and Remote Sensing*, 2023.
- [۷] J. Wang et al., "Automatic cloud and cloud shadow detection in tropical areas for PlanetScope satellite images," *Remote Sensing of Environment*, vol. 264, p. ۱۱۲۶۰۴, ۲۰۲۱.
- [۸] F. Huang, Y. Yu, and T. Feng, "Automatic building change image quality assessment in high resolution remote sensing based on deep learning," *Journal of Visual Communication and Image Representation*, vol. 63, p. 102585, 2019.
- [۹] Z. Jiang, H. Zhang, Z. Yang, J. Guo, and Z. Wang, "Mapping building change detection in very high-resolution remote sensing imagery with a deep learning method," in *Fourth International Conference on Geology, Mapping, and Remote Sensing (ICGMRS 2023)*, 2024, vol. ۱۲۹۷۸. SPIE, pp. 616-622.
- [۱۰] R. Wan, J. Zhang, Y. Huang, Y. Li, B. Hu, and B. Wang, "Leveraging diffusion modeling for remote sensing change detection in built-up urban areas," *IEEE Access*, vol. 12, pp. 7028-7039, 2024.
- [۱۱] G. Zitzlsberger and M. Podhoranyi, "Monitoring Urban Changes in Mariupol/Ukraine in 2022/23," *arXiv preprint arXiv:2309.08607*, 2023.
- [۱۲] Q. Ding, Z. Shao, X. Huang, and O. Altan, "DSA-Net: A novel deeply supervised attention-guided network for building change detection in high-resolution remote sensing images," *International Journal of Applied Earth Observation and Geoinformation*, vol. 105, p. 102591, 2021.
- [۱۳] Y. Liu, C. Pang, Z. Zhan, X. Zhang, and X. Yang, "Building change detection for remote sensing images using a dual-task constrained deep siamese convolutional network model," *IEEE Geoscience and Remote Sensing Letters*, vol. 18, no. 5, pp. 811-815, 2020.
- [۱۴] Q. Wang, X. Zhang, G. Chen, F. Dai, Y. Gong, and K. Zhu, "Change detection based on Faster R-CNN for high-resolution remote sensing images," *Remote sensing letters*, vol. 9, no. 10, pp. 923-932, 2018.
- [۱۵] P. Xiao, M. Yuan, X. Zhang, X. Feng, and Y. Guo, "Cosegmentation for object-based building change detection from high-resolution remotely sensed images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 3, pp. 1587-1603, 2017.
- [۱۶] L. Shen et al., "S2Looking: A satellite side-looking dataset for building change detection," *Remote Sensing*, vol. 13, no. 24, p. 5094, 2021.
- [۱۷] J.-g. Yuan, Z. Niu, and X.-p. Wang, "Atmospheric correction of Hyperion hyperspectral image based on FLAASH," *Spectroscopy and Spectral Analysis*, vol. 29, no. 5, pp. 1181-1185, 2009.
- [۱۸] N. Su, Y. Zhang, S. Tian, Y. Yan, and X. Miao, "Shadow detection and removal for occluded object information recovery in urban high-resolution panchromatic satellite images," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, no. 6, pp. 2568-2582, 2016.
- [۱۹] D. Lu, P. Mausel, E. Brondizio, and E. Moran, "Change detection techniques," *International journal of remote sensing*, vol. 25, no. 12, pp. 2365-2401, 2004.
- [۲۰] F. Bovolo and L. Bruzzone, "A theoretical framework for unsupervised change detection based on change vector analysis in the polar domain," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 1, pp. 218-236, 2006.

- [۲۱] A. Tahraoui, R. Kheddami, A. Bouakache, and A. Belhadj-Aissa, "Land change detection using multivariate alteration detection and Chi squared test thresholding," in 2018th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP), 2018: IEEE, pp. 1-6.
- [۲۲] Y. He, Z. Jia, J. Yang, and N. K. Kasabov, "Multispectral image change detection based on single-band slow feature analysis," *Remote Sensing*, vol. 13, no. 15, p. 2969, 2021.
- [۲۳] C. Wu, B. Du, and L. Zhang, "Slow feature analysis for change detection in multispectral imagery," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no. 5, pp. 2858-2874, 2013.
- [۲۴] B. Du, L. Ru, C. Wu, and L. Zhang, "Unsupervised deep slow feature analysis for change detection in multi-temporal remote sensing images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 12, pp. 9976-9992, 2019.
- [۲۵] J. Chen et al., "DASNet: Dual attentive fully convolutional Siamese networks for change detection in high-resolution satellite images," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 14, pp. 1194-1206, 2020.
- [۲۶] S. Woo, J. Park, J.-Y. Lee, and I. S. Kweon, "Cbam: Convolutional block attention module," in *Proceedings of the European conference on computer vision (ECCV)*, 2018, pp. 3-19.
- [۲۷] D. M. Powers, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation," *arXiv preprint arXiv:2010.16061*, 2020.
- [۲۸] J. Cohen, "A coefficient of agreement for nominal scales," *Educational and psychological measurement*, vol. 20, no. 1, pp. 37-46, 1960.