

Original Article

Iranian Remote Sensing & GIS
Journal of

Change Detection in Remote Sensing Data Using Attention Network

Roohollah Enayati¹, Reza Ravanmehr^{2*}, Vahe Aghazarian²

Affiliation

1. Ph.D. Student,
Department of Computer
Engineering, Central
Tehran Branch, Islamic
Azad University, Tehran,
Iran

2. Assistant Professor,
Department of Computer
Engineering, Central
Tehran Branch, Islamic
Azad University, Tehran,
Iran

ABSTRACT

Introduction: Detecting changes in remote sensing data is a critical task in environmental sciences, natural resource management, urban planning, and disaster management. Despite recent advancements in this field, many existing methods only address specific challenges and are unable to provide a comprehensive solution for various types of data and applications. These limitations include the inability to handle multispectral, hyperspectral, and radar data and the lack of capability to deliver accurate and timely results using parallel processing and optimized computing resources. Additionally, current methods are often confined to binary change detection and cannot accurately identify the specific types of changes. Therefore, the primary aim of this research is to develop an innovative and comprehensive change detection method that can overcome these limitations and be effectively used in real-world applications.

Materials and Methods: In this study, we propose a novel approach based on the combination of a transformer network and an automated attention model, capable of processing and analyzing remote sensing data with high accuracy and efficiency. This method utilizes multispectral, hyperspectral, and radar data obtained from Sentinel-2, QuickBird, and TerraSAR-X satellites. These data are collected over different time periods and include diverse information such as vegetation changes, land use, and structural changes. The proposed method employs feature fusion techniques using convolutional and transformer layers to integrate information from the data, thereby enhancing change detection accuracy. Additionally, the use of spatial attention mechanisms helps identify spatial relationships between features, focusing on key areas to improve change detection accuracy. The transformer-based network, developed to determine similarity, is enhanced with automated attention mechanisms that capture complex relationships between features over temporal sequences. This capability is especially important for detecting subtle changes that may be overlooked by other methods. For operational implementation, the proposed method was deployed and evaluated on a high-performance system, including a 24-core Xeon E5-2697 v2 CPU, 28 GB of memory, a 200 GB SSD, and a powerful RTX 2080 Ti graphics card with 11 GB of RAM and CUDA 11.

Results and Discussion: The results obtained from this research indicate the superiority of the proposed method compared to existing methods. Evaluations were conducted using metrics such as Precision, Recall, F1-score, Overall Accuracy (OA), and Intersection over Union (IoU). The proposed method outperformed other methods across all these metrics. Notably, overall accuracy (OA) increased significantly, reaching over 95% on some datasets. These results indicate that the proposed method can not only accurately detect binary changes but also identify the types of changed features with high precision. These capabilities are achieved through the use of advanced deep learning techniques and parallel processing. Moreover, the implementation of the SoFRB(Enayati et al. 2023) framework has enhanced the efficiency of the proposed method, enabling the processing of large volumes of data in less time. Our analysis demonstrates that the proposed method has high adaptability with different datasets and can effectively operate under various conditions. Furthermore, this method can serve as an efficient tool for various applications, including environmental monitoring, urban planning, precision agriculture, and disaster management.

Conclusion: The proposed method integrates modern deep learning techniques and parallel processing to significantly improve the accuracy and efficiency of change detection in remote sensing data. The findings of this study show that the proposed method is reliable not only in experimental settings but also in practical applications. Specifically, this method can effectively monitor environmental changes, detect alterations in urban infrastructures, and manage natural and human-induced disasters. These results promise widespread applications of this method in various fields. Future research could include further improvements in different areas, such as model optimization, the use of more diverse and extensive datasets, and the exploration of the impact of newer deep learning and parallel processing techniques.

Keywords: Change detection, convolutional neural network, Feature fusion, Remote sensing, Transformer.

Citation: Enayati R.,
Ravanmehr R., Aghazarian V.,
Change Detection in Remote
Sensing Data Using Attention
Network, Iran J Remote Sens
GIS, 16(4):139-163.

* Corresponding Author: r.ravanmehr@iauctb.ac.ir
DOI: <https://doi.org/10.48308/GISJ.2024.236243.1224>

Received: 2024.07.11
Accepted: 2024.10.06





تشخیص تغییرات در داده‌های سنجش از دور با استفاده از شبکه توجیه

روح‌اله عنایتی^۱، رضا روانمهر^۲، واهه آغازاریان^۲

سمت

۱. دانشجوی دکتری مهندسی کامپیوتر، گروه کامپیوتر، دانشکده مهندسی، دانشگاه آزاد اسلامی واحد تهران مرکزی، تهران، ایران
۲. استادیار گروه کامپیوتر، گروه کامپیوتر، دانشکده مهندسی، دانشگاه آزاد اسلامی واحد تهران مرکزی، تهران، ایران

چکیده

سابقه و هدف: تشخیص تغییرات، در داده‌های سنجش از دور، وظیفه‌ای بسیار مهم در علوم محیط‌زیست، مدیریت منابع طبیعی، برنامه‌ریزی شهری و مدیریت بحران‌هاست. با وجود پیشرفت‌های اخیر در این زمینه، بسیاری از روش‌های موجود صرفاً به چالش‌های خاصی می‌پردازند و قادر به دادن راه‌حلی جامع، برای انواع متفاوت داده‌ها و کاربردها نیستند. این محدودیت‌ها شامل ناتوانی در مدیریت داده‌های چندطیفی، فراطیفی و راداری، و نیز ناتوانی در بیان نتایج دقیق و سریع با استفاده از پردازش موازی و بهینه‌سازی منابع پردازشی می‌شود. علاوه بر این، روش‌های فعلی اغلب به تشخیص تغییرات باینری محدود می‌شوند و قادر به شناسایی دقیق نوع ویژگی‌های تغییر یافته نیستند. بنابراین هدف اصلی این تحقیق توسعه روشی نوآورانه و جامع برای تشخیص تغییرات است که بتواند این محدودیت‌ها را برطرف کند و در دنیای واقعی، کاربردهای مؤثری داشته باشد.

مواد و روش‌ها: در این مطالعه، روش جدیدی مبتنی بر ترکیب شبکه ترانسفورمر و مدل توجه خودکار مطرح می‌کنیم که قادر به پردازش و تحلیل داده‌های سنجش از دور، با دقت و کارایی بالاست. این روش از داده‌های چندطیفی، فراطیفی و راداری بهره می‌برد که از ماهواره‌های سنتینل-۲، QuickBird و TerraSAR-X به دست آمده‌اند. این داده‌ها در بازه‌های زمانی متفاوتی جمع‌آوری شده و شامل اطلاعات گوناگون، از جمله تغییرات پوشش گیاهی، کاربری زمین و تغییرات ساختاری‌اند. روش پیشنهادی از تکنیک‌های ادغام ویژگی‌ها بهره می‌برد که با استفاده از لایه‌های کانولوشن و ترانسفورمر، اطلاعات موجود در داده‌ها را ترکیب می‌کند و دقت تشخیص تغییرات را افزایش می‌دهد. علاوه بر این استفاده از مکانیسم توجه فضایی به شناسایی روابط مکانی بین ویژگی‌ها کمک می‌کند و با تمرکز بر نواحی کلیدی، دقت تشخیص تغییرات را بهبود می‌بخشد. شبکه مبتنی بر ترانسفورمر که برای تعیین شباهت توسعه یافته است، با مکانیسم‌های توجه خودکار تقویت شده که امکان دریافت روابط پیچیده بین ویژگی‌ها را در دنباله‌های زمانی فراهم می‌کند. این ویژگی، به ویژه برای تشخیص تغییرات جزئی که ممکن است در سایر روش‌ها نادیده گرفته شوند، اهمیت دارد. در بستر عملیاتی، روش پیشنهادی روی سیستمی با کارایی بالا، شامل یک CPU 24 هسته‌ای Xeon E5-2697 v2، ۲۸ گیگابایت حافظه، دیسک SSD با ظرفیت ۲۰۰ گیگابایت و یک کارت گرافیک RTX 2080 Ti با ۱۱ گیگابایت RAM و CUDA 11 اجرا و ارزیابی شد.

نتایج و بحث: نتایج این تحقیق برتری روش پیشنهادی را در مقایسه با روش‌های موجود نشان می‌دهند. ارزیابی‌ها بر اساس معیارهای دقت، بازخوانی، F1-score، دقت کلی (OA) و هم‌پوشانی متقاطع (IoU) انجام شد. این روش توانست، در تمامی این معیارها، عملکردی بهتر از روش‌های دیگر نشان دهد. به‌طور خاص دقت کلی افزایش چشمگیری یافت و در برخی مجموعه داده‌ها، به بیش از ۹۵٪ رسید. این نتایج حاکی از آن است که روش پیشنهادی نه تنها قادر به تشخیص دقیق تغییرات باینری است بلکه می‌تواند نوع ویژگی‌های تغییر یافته را نیز با دقت بالا شناسایی کند. این قابلیت‌ها به دلیل استفاده از تکنیک‌های پیشرفته یادگیری عمیق و پردازش موازی به دست آمده‌اند. همچنین استفاده از چارچوب SoFRB باعث بهبود کارایی روش پیشنهادی شده و امکان پردازش داده‌های حجیم را، در زمان کمتر، فراهم کرده است. تحلیل‌های ما بیان می‌کند که روش پیشنهادی می‌تواند، با مجموعه داده‌های متفاوت، انطباق بالایی نشان دهد و در شرایط گوناگون کارکرد مؤثری داشته باشد. به‌علاوه، این روش می‌تواند ابزار کارآمدی در زمینه‌های متفاوت، از جمله نظارت بر محیط‌زیست، برنامه‌ریزی شهری، کشاورزی دقیق و مدیریت بحران‌ها باشد.

نتیجه‌گیری: روش پیشنهادی ترکیبی از تکنیک‌های مدرن یادگیری عمیق و پردازش موازی است که دقت و کارایی تشخیص تغییرات در داده‌های سنجش از دور را بهبود چشمگیری بخشیده است. نتایج این تحقیق نشان می‌دهد که روش پیشنهادی نه تنها در شرایط آزمایشگاهی بلکه در کاربردهای عملی نیز مورد اعتماد است. به‌طور خاص این روش می‌تواند در نظارت بر تغییرات محیط‌زیست، شناسایی تغییرات در زیرساخت‌های شهری و مدیریت بحران‌های طبیعی و انسانی، نقش مؤثری داشته باشد. این نتایج نویدبخش کاربردهای گسترده این روش در حوزه‌های گوناگون است. همچنین تحقیقات آینده می‌تواند شامل بهبودهای بیشتری در زمینه‌های گوناگون، مانند بهینه‌سازی مدل، استفاده از داده‌های بیشتر و متنوع‌تر و بررسی تأثیر استفاده از تکنیک‌های جدیدتر یادگیری عمیق و پردازش موازی باشد.

کلیدواژه‌ها: تشخیص تغییرات، شبکه عصبی کانولوشن، ادغام ویژگی‌ها، سنجش از دور، ترانسفورمر.

استناد: عنایتی، ر.، روانمهر، ر.

آغازاریان، و.، تشخیص تغییرات در داده‌های سنجش از دور با استفاده از شبکه توجیه، نشریه سنجش از دور و GIS ایران، سال ۱۶، شماره ۴، زمستان ۱۴۰۳: ۱۶۳-۱۳۹.

دریافت: ۱۴۰۳/۰۴/۲۱

پذیرش: ۱۴۰۳/۰۷/۱۵

* نویسنده عهده‌دار مکاتبات: r.ravanmeh@iauctb.ac.ir

شناسه دیجیتال مقالات: https://doi.org/10.48308/GISJ.2024.236243.1224



Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license https://creativecommons.org/licenses/by/4.0/.

۱- مقدمه

به‌لطف رشد فناوری‌های سنجش از دور، امروزه ماهواره‌ها همانند چشم در آسمان‌اند؛ بنابراین شاهد تحول پایدار عظیمی در استفاده از ماهواره‌ها و سنجنده‌های گوناگون در فضا هستیم که تصویرهای سنجش از دور بسیاری برای کاربردهای گوناگون، مانند شهرهای هوشمند (Ismail et al., 2018; Rathee et al., 2024)، مدیریت حوادث (Boccardo & Giulio Tonolo, 2024)، کشاورزی (Pande & Temenos et al., 2015; 2024)، تغییرات کاربری (Moharir, 2023; Yusufovich & Yokubov, 2023) و تغییرات کاربری (Shafique et al., 2022; Bai et al., 2024) تولید می‌کنند.

ازجمله مسائل بسیار مهم تحقیقاتی در حوزه سنجش از دور، عملیات تشخیص تغییرات است (Asokan & Anitha, 2019). تشخیص تغییرات، در سنجش از دور، شامل شناسایی تغییرات شایان توجه در توزیع ویژگی‌های سطح، پوشش زمین یا شرایط محیطی در طول زمان است (Afaq & Manocha, 2021). این تغییرات ممکن است ناشی از فرایندهای طبیعی، مانند رشد گیاهان یا فرسایش (Viana et al., 2019)، یا فعالیت‌های انسانی مانند گسترش شهری و جنگل‌زدایی (Lu et al., 2016) باشند. تشخیص دقیق و به‌موقع این تغییرات برای تصمیم‌گیری آگاهانه ضرورت دارد و امکان مدیریت مؤثر منابع طبیعی، کاهش تأثیرات زیست‌محیطی و واکنش در برابر بلایای طبیعی را فراهم می‌کند.

در روش‌های قدیمی تشخیص تغییرات، اغلب پیکسل‌ها یا اشیا در تصاویر گوناگون، در زمان‌های متفاوت، مقایسه می‌شود تا تفاوت‌ها برجسته شوند. این روش‌ها با چالش‌های متعددی مواجه‌اند؛ شامل حساسیت به شرایط جوّی، تغییرات در ویژگی‌های حسگر و نیاز به دخالت دستی. همچنین این روش‌ها اغلب در درک الگوهای پیچیده مکانی و زمانی در مجموعه داده‌های بزرگ مقیاس ناکام می‌مانند و چه‌بسا این مسئله به نواقص و ناکارآمدی‌هایی در نتایج تشخیص تغییرات منجر شود (Shi et al., 2020).

امروزه سنجش از دور یکی از مهم‌ترین فناوری‌های کسب اطلاعات، از طریق جمع‌آوری و پردازش داده‌ها در سریع‌ترین زمان ممکن، از منطقه‌ای جغرافیایی محسوب می‌شود (Liu, 2015; Chi et al., 2016; Wang & Gamon, 2019; Zhang et al., 2019; Li et al., 2020). به‌طور کلی، در سطح کره زمین، تغییر و تحولات در زمان بسیار کوتاهی صورت می‌پذیرد. این سیاره هرروزه با بروز تغییراتی همچون تغییرات آب‌وهوایی، کاربری‌های اراضی و مستغلات، مناطق آبی و اقیانوسی در اقلیم‌ها و مناطق گوناگون جغرافیایی روبه‌روست. از این رو به‌دست‌آوردن اطلاعات جغرافیایی در زمینه‌های گوناگون اقتصادی، صنعتی، کشاورزی، اجتماعی بسیار مهم و اساسی است (Yang et al., 2013; Asokan & Anitha, 2019; Fingas, 2019; Li et al., 2020). به‌بیانی ساده، سنجش از دور را می‌توان دانش و فناوری کسب اطلاعات و تصویربرداری از زمین، بدون تماس فیزیکی با پدیده‌ها، دانست. در سنجش از دور با استفاده از سنجنده‌های متفاوت، حجم عظیمی از داده‌ها و اطلاعات با انواع گوناگون تولید و ضبط می‌شود. ازجمله این داده‌ها می‌توان به تصاویر ماهواره‌ای، داده‌های راداری و داده‌های مغناطیسی اشاره کرد (Liu, 2015; Toth & Józków, 2016; Fingas, 2019). از سویی، کسب اطلاعات مفید از طریق پردازش‌ها و تحلیل‌های حوزه سنجش از دور می‌تواند در تصمیم‌گیری‌ها و توسعه صنایع گوناگون تأثیر پررنگی بگذارد (Huang et al., 2018).

با بهره‌گیری از توسعه فناوری سنجش از دور فضایی، مقدار داده‌های تصویری سنجش از دور به‌دست‌آمده از طریق ماهواره‌ها به‌طرز چشمگیری در حال فزونی است. همچنین با افزایش نیاز به اطلاعات دقیق و به‌روز منابع و اطلاعات محیطی، برای نظارت منطقه‌ای و جهانی در سال‌های اخیر، مجموعه داده‌های سنجش از دور تحت پوشش مناطق بزرگ در دوره‌های زمانی و چندطبقی برای پردازش به کار می‌روند (Li et al., 2021b; Chen et al., 2022; Vance et al., 2024; Wang et al., 2024).

2023). SoFRB چارچوبی مبتنی بر سرویس است که برای تحلیل داده‌های حجیم سنجش از دور توسعه یافته است. هدف اساسی این مقاله ایجاد راه‌حلی پیشرفته است که علاوه بر شناسایی تغییرات در داده‌های سنجش از دور ماهواره‌ای، در چارچوب پویای SoFRB (Enayati et al., 2023) نیز عملکردی هماهنگ داشته باشد. برطبق مطالعات گذشته، در روش‌هایی که کاملاً از قابلیت‌های ترانسفورمر برای تشخیص تغییرات در این چارچوب چندمنظوره استفاده کنند، شکاف‌هایی وجود دارد. مشارکت اساسی این مقاله دو جنبه اصلی دارد؛ ابتدا، معماری ترانسفورمر در آن به‌طور یکپارچه ادغام شده است و سپس، با گنجاندن مکانیسم‌های توجه خودکار، تقویت می‌شود. در ادامه، نوآوری‌های مقاله به‌تفصیل آمده است:

۱) استفاده از شبکه ترانسفورمر^۲ و توجه خودکار: روش پیشنهادی پیشگام در ادغام، توجه خودکار ترانسفورمری در معماری شبکه ترانسفورمر برای تشخیص تغییرات است. با ترکیب این دو تکنیک قدرتمند، بُعد جدیدی از استخراج ویژگی‌ها معرفی شده است که روابط پیچیده و وابستگی‌های بلندمدت در داده‌های سنجش از دور را ثبت می‌کند؛

۲) دقت بهبودیافته در تشخیص تغییرات: ترکیب شبکه‌های عصبی کانولوشن و توجه خودکار ترانسفورمری، توانایی مدل را در تشخیص تغییرات معنادار، در مجموعه داده‌های پیچیده، افزایش می‌دهد. این ترکیب، به‌ویژه در سناریوهایی که اطلاعات متنی در آنها نقش حیاتی دارند، به بهبود دقت و صحت منجر می‌شود؛

۳) شناسایی جنس پدیده‌ها: در روش پیشنهادی، علاوه بر تشخیص تغییرات در انواع داده‌های سنجش از دور، راه‌حلی برای شناسایی جنس پدیده‌ها پیشنهاد شده است. این روش امکان می‌دهد که عناصر تشکیل‌دهنده پدیده‌های گوناگون در داده‌های سنجش از دور با دقت بیشتری شناسایی شوند؛

در سال‌های اخیر، پیشرفت‌های به‌دست‌آمده در حوزه یادگیری ماشین، به‌ویژه در یادگیری عمیق، بهبودهای شایان توجهی در زمینه سنجش از دور به ارمغان آورده است. شبکه‌های عصبی کانولوشن (CNN) (Peng et al., 2020; Zheng et al., 2021) و شبکه‌های عصبی بازگشتی (RNN) (Khan et al., 2017; Papadomanolaki et al., 2019) توانایی خود را در مدیریت پیچیدگی‌های مکانی و زمانی داده‌های سنجش از دور نشان داده‌اند. با این حال این مدل‌ها ممکن است همچنان، در گرفتن وابستگی‌های بلندمدت و روابط متنی دقیق، با محدودیت‌هایی مواجه شوند.

ترانسفورمرها، که ابتدا برای پردازش زبان طبیعی توسعه یافته‌اند، در نقش ابزارهای قدرتمندی برای انواع وظایف گوناگون ظاهر شده‌اند؛ بدین صورت که می‌توانند وابستگی‌های پیچیده و اطلاعات متنی را به‌طور مؤثر مدل‌سازی کنند. مکانیسم‌های توجه آنها امکان یادگیری روابط پیچیده در توالی داده‌ها را فراهم می‌کند و بدین ترتیب آنها را برای کاربردهای سنجش از دور که درک بافت مکانی و زمانی در آن بسیار حیاتی است، مناسب می‌سازد (Chen et al., 2021; Zhang et al., 2023).

در این مقاله، روشی نوآورانه مبتنی بر ترانسفورمر مطرح شده است که به‌طور خاص برای مقابله با چالش‌های منحصربه‌فرد تشخیص تغییرات طراحی شده و روش قدرتمند و کارآمدی، برای تحلیل مجموعه داده‌های حجیم سنجش از دور، فراهم می‌کند.

در حوزه سنجش از دور، یکی از چالش‌های اساسی تشخیص مؤثر تغییرات در مجموعه داده‌های حجیم و پیچیده است. بدین منظور روش پیشنهادی در این مقاله شیوه‌ای نوین را معرفی می‌کند که از توانمندی‌های ترانسفورمرها و مکانیسم توجه خودکار^۱ بهره می‌برد. رویکرد مطرح شده به‌منزله لایه‌ای پردازشی در چارچوب سرویس‌محور (SoFRB) عمل می‌کند و راه را برای تشخیص تغییرات مقیاس‌پذیر، کارآمد و تطبیق‌پذیر در کلان‌داده سنجش از دور هموار می‌سازد (Enayati et al., 2023).

1. Self-Attention Mechanism
2. Transformer Network

تصاویر سنجش از دور بررسی کرده‌اند. شی^۱ و همکاران (۲۰۲۱) شبکه‌ای جدید، مبتنی بر متریک عمیق با تمرکز قوی بر نظارت DSAMNet را معرفی کردند. الوه^۲ و همکاران (۲۰۲۳) شبکه‌ی عصبی تشخیص تغییرات با ادغام ماژول توجه به اطلاعات چندمقیاسی را در ساختار UNet مطرح کردند که به ترکیب تصاویر دوزمانه کمک می‌کند. جو^۳ و همکاران (۲۰۲۳) معماری شبکه‌ای جدید به نام ECFNet را برای تشخیص تغییرات تصاویر سنجش از دور پیشنهاد و استراتژی مؤثری را معرفی کردند. وو^۴ و همکاران (۲۰۲۱) روش تشخیص تغییراتی را برای تصاویر ناهمگون پیشنهاد کردند که از یک کدگذار خودکار پیچشی (CAE) برای استخراج ویژگی و یک کدگذار خودکار اشتراکی برای بررسی ویژگی‌های مشترک بهره می‌برد. وانگ^۵ و همکاران (۲۰۲۱) الگوریتم جدیدی برای تشخیص تغییرات پیشنهاد کردند و شبکه‌های دوقلوی کاملاً پیچشی را برای تجزیه و تحلیل تصاویر هوایی اپتیکی به کار بردند. جانگ^۶ و همکاران (۲۰۲۱) شبکه‌ی تشخیص تغییرات تقویت شده (ESNet) بوسیله سوپریکسل را برای تصاویر چندطیفی با وضوح بسیار بالا پیشنهاد کردند. ESCNet ترکیبی از بخش‌بندی سوپریکسل‌های تفکیک‌پذیر و شبکه‌ی عصبی دوقلویی مبتنی بر UNet است. شن^۷ و همکاران (۲۰۲۲) مدل دوقلوی چندوظیفه‌ای طراحی شده‌ای را برای تشخیص تغییرات در تصاویر با وضوح بالای دوزمانه (HSR)، با عنوان شبکه‌ی SFCCD، معرفی کردند. تشخیص تغییرات وظیفه‌ی اصلی این مدل و استخراج ویژگی به‌منزله‌ی عملکرد کمی آن است و مدل یادشده این دو کار را هم‌زمان انجام می‌دهد. یانگ^۸ و همکاران (۲۰۲۱)

(۴) مقیاس‌پذیری و پردازش موازی در چارچوب سرویس‌محور (Enayati et al., 2023): رویکرد پیشنهادی به‌منزله‌ی لایه‌ای پردازشی در چارچوب سرویس‌گرای کلان‌داده‌ی سنجش از دور عمل می‌کند و به چالش مقیاس‌پذیری، در تحلیل داده‌های حجیم سنجش از دور، پاسخ می‌دهد. با بهره‌گیری کارآمد از مزایای ترانسفورمر و توجه خودکار، روش پیشنهادی مقیاس‌پذیری و پردازش موازی را در زیرساخت کلان‌داده، بدون کاهش دقت، نشان می‌دهد.

(۵) استفاده از مجموعه داده‌های گوناگون به‌منزله‌ی ورودی: با توجه به اینکه برای پردازش تشخیص تغییرات، امکان استفاده از مجموعه داده‌های گوناگون ماهواره‌ای وجود دارد، به‌کاربردن ترکیب شبکه‌های ترانسفورمری با مدل توجه خودکار و همچنین بهره‌گیری از چارچوب SoFRB به استفاده از انواع مجموعه داده‌های ماهواره‌ای با توان تفکیک‌های متفاوت زمانی، طیفی، مکانی و رادیومتریک میسر می‌گردد.

در ادامه، منابع در زمینه‌ی تشخیص تغییرات در سنجش از دور مرور می‌شود. در بخش بعدی، روش پیشنهادی برای تشخیص تغییرات در سنجش از دور معرفی و سپس اجرا و ارزیابی می‌شود. در نهایت، نتایج و یافته‌های این تحقیق مورد بحث قرار می‌گیرد.

۲- پیشینه و منابع

در سال‌های اخیر، رویکردهای مبتنی بر یادگیری عمیق نتایج امیدوارکننده‌ای در حوزه‌ی تشخیص تغییرات در سنجش از دور، با بالاترین دقت و کارایی، دربرداشته‌اند. در بخش مرور منابع، خلاصه‌ی تحولات اخیر در تشخیص تغییرات، با استفاده از یادگیری عمیق در سنجش از دور، بیان شده است.

محققان طیف وسیعی از معماری‌ها، در زمینه‌ی تشخیص تغییرات مبتنی بر یادگیری عمیق را برای

1. Shi
2. Lv
3. Zhu
4. Wu
5. Wang
6. Zhang
7. Shen
8. Yang

کاربردشان به شرایط خاص محدود می‌شود. این محدودیت‌ها استفاده عملی آنها را در دنیای واقعی محدود می‌کند؛

- استفاده ناکافی از مکانیسم‌های توجه در روش‌های مبتنی بر ترانسفورمر: روش‌های تشخیص تغییرات که شبکه‌های ترانسفورمر را به کار می‌برند اغلب از مکانیسم‌های توجه به‌طور کامل بهره‌برداری نمی‌کنند که این مسئله توانایی مدل در ثبت روابط مکانی و ویژگی‌های معنایی در تصاویر سنجش از دور را محدود می‌کند و ممکن است در عملکرد کلی مدل تأثیر منفی بگذارد.

روش پیشنهادی که بر مبنای ترانسفورمر و مکانیسم‌های توجه خودکار توسعه یافته است، این محدودیت‌ها را برطرف می‌سازد و امکان خودکارسازی، مقیاس‌پذیری و دقت بالاتر در تشخیص تغییرات در داده‌های حجیم سنجش از دور را فراهم می‌کند.

۳- روش پیشنهادی

یکی از مهم‌ترین دغدغه‌های محققان سنجش از دور عملکرد بهینه تحلیل تشخیص تغییرات است. با بررسی مقالات در این حوزه، به نظر می‌رسد که هر کار تحقیقاتی راه‌حلی برای فرمت‌های داده خاص یا کاربردهای مشخص بیان کرده است. اما تا آنجا که نتایج تحقیقات نشان داده‌اند، یکی از مسائل بحرانی فقدان راه‌حل جامعی است که بتواند، با توجه به ذخیره و پردازش داده‌های گوناگون و ارائه نتایج دارای فرمت استاندارد سرویس، تغییرات را در کمترین زمان ممکن و با دقت بالا تشخیص دهد. در واقع، روش‌های پیشنهادی معمولاً عارضه‌ای خاص را تشخیص می‌دهند و راه‌حل جامعی برای همه انواع فرمت‌های داده و کاربردها مطرح نشده است. برای رفع کاستی‌های یادشده در تحقیقات فعلی، روشی نوآورانه با استفاده از شبکه ترانسفورمری مبتنی بر توجه خودکار معرفی می‌شود که در شکل ۱ نشان داده شده است.

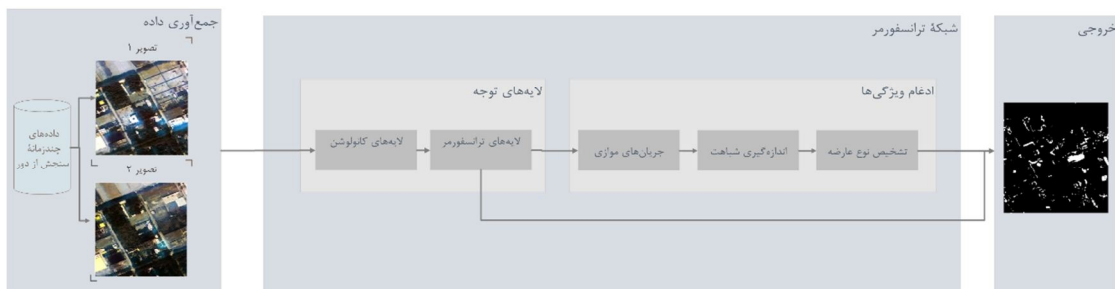
تکنیک تشخیص تغییرات تحت نظارتی را با استفاده از شبکه‌های تفکیک معنایی عمیق دوقلو، پیشنهاد کردند. این شبکه در مورد چالش تشخیص تغییرات، به‌منزله مسئله تفکیک معنایی دوتایی، تفسیر چشمگیری می‌دهد که امکان استخراج مستقیم ویژگی‌ها از جفت‌های تصویری را فراهم می‌سازد. در مقاله‌ای دیگر، سفرین و همکاران شبکه چند شاخه‌ای برای تشخیص تغییرات (MHCNet) را مبتنی بر ساختار دوقلو پیشنهاد کردند که دارای سه شاخه است: شاخه تفاوت، شاخه جهانی و شاخه شباهت (Seffrin et al., 2020). این شاخه‌ها با هم کار می‌کنند تا جزئیات معنایی را از تصاویر سنجش از دور تقویت و استخراج کنند.

اگرچه مدل‌ها و راه‌حل‌های مطرح‌شده تا کنون پیشرفت‌های درخور توجهی داشته‌اند، هنوز برخی محدودیت‌ها وجود دارند. این محدودیت‌ها عمدتاً شامل جنبه‌های زیر می‌شوند:

- چالش در خودکارسازی روش‌های تشخیص تغییرات: رویکردهای سنتی تشخیص تغییرات، به دلیل پیچیدگی چارچوب‌ها، نیازمند اجرای دستی الگوریتم‌های پردازش و انتخاب پارامترهای مناسب برای انواع گوناگون داده‌ها هستند. این مسئله فرایند را زمان‌بر و مستلزم دخالت انسانی می‌کند که باعث کاهش کارایی و دقت نهایی می‌شود؛

- مقیاس‌پذیری محدود در مواجهه با مجموعه داده‌های بزرگ سنجش از دور: بسیاری از روش‌های موجود، هنگام اعمال به مجموعه داده‌های حجیم سنجش از دور، به دلیل ادغام‌نشدن یکپارچه در چارچوب‌های سرویس‌محور مانند SoFRB، مقیاس‌پذیری مناسبی ندارند. این مقیاس‌پذیری نبودن سبب محدود شدن قابلیت پردازش کارآمد داده‌ها می‌شود و امکان تشخیص تغییرات به‌موقع و قدرتمند را کاهش می‌دهد؛

- انعطاف‌پذیری محدود در برخورد با داده‌های گوناگون سنجش از دور: برخی روش‌ها، در برخورد با داده‌های گوناگون سنجش از دور، انعطاف‌پذیری اندکی دارند و به‌دلیل تطبیق‌پذیری کم با تغییرات منابع ورودی،



شکل ۱. معماری پیشنهادی مدل تشخیص تغییر مبتنی بر ترانسفورمر

فروسرخ نزدیک، در تصاویر صحنه‌های طبیعی را تسهیل کرده‌اند.

همان‌طور که در شکل ۱ نشان داده شده است، این روش پیشنهادی جریان کاری جامع و بهبودیافته‌ای را مطرح می‌کند که شامل مراحل متمایز و منحصربه‌فردی است. این جریان کاری از مرحله جمع‌آوری داده‌ها آغاز می‌شود؛ در این مرحله، داده‌های سنجش از دور با استفاده از روش‌های پیشرفته پردازش می‌شوند تا داده‌های متنوع از حسگرها و توان تفکیک‌های گوناگون گردآوری و آماده شوند. در مرحله بعد، داده‌های آماده‌شده به شبکه ترانسفورمری وارد می‌شوند. این شبکه، با بهره‌گیری از مکانیسم‌های توجه خودکار ترانسفورمری، قادر به ارزیابی شباهت یا تفاوت بین بردارهای ویژگی‌های استخراج‌شده از داده‌های ورودی است.

در گام بعدی، لایه‌های چندگانه توجه به مدل کمک می‌کنند ویژگی‌های پیچیده و روابط فضایی را با دقت بالایی ثبت و پردازش کنند. این لایه‌ها، با به‌کارگیری لایه‌های کانولوشن و ترانسفورمری، اطلاعات حیاتی را به‌دقت از داده‌های ورودی استخراج و تحلیل می‌کنند. مکانیسم‌های توجه فضایی^۱ و زمانی ترانسفورمر در این مرحله نقش اصلی را دارند و به مدل این امکان را می‌دهند که روابط پیچیده بین ویژگی‌ها را به‌خوبی درک کند. سپس ویژگی‌های استخراج‌شده از داده‌های ورودی، به‌طور پیچیده‌ای، از طریق جریان‌های

این روش قدرتمند، شبکه ترانسفورمری را با مدل قدرتمند توجه خودکار به‌طور یکپارچه ترکیب می‌کند. این ادغام هم امکان مدیریت جفت داده‌های سنجش از دور و هم امکان طبقه‌بندی داده‌های سنجش از دور زمانی را، به دسته‌های تغییر و عدم تغییر، فراهم می‌آورد. علاوه‌براین، رویکرد ما از تکنیک‌های ادغام ویژگی‌ها استفاده می‌کند؛ در این ادغام، توصیفگرها از ترکیب جریان‌های داده مستقل برای تعیین شباهت یا تفاوت پچ‌های ورودی چندحالتی بهره می‌برند. این اجزای یکپارچه، همراه با روش‌های پیشرفته استخراج ویژگی مانند لایه‌های کانولوشن و ترانسفورمر، در افزایش دقت و اثربخشی سیستم تشخیص تغییرات ما عملکردی هم‌افزا دارند. این رویکرد جامع به پیچیدگی‌های ناشی از حسگرهای متنوع و انواع توان تفکیک‌ها می‌پردازد و آن را به دارایی ارزشمندی در حوزه سنجش از دور و تحلیل داده تبدیل می‌کند.

همچنین روش مورد نظر از معماری نوآورانه‌ای بهره می‌برد که به معماری پایه ترانسفورمری نزدیک است. شبکه‌های ترانسفورمری که با زیرشبکه‌های مشابه دارای وزن‌های مشترک شناخته می‌شوند، به‌طور ذاتی برای یادگیری شباهت‌ها یا تفاوت‌های بین ورودی‌ها طراحی شده‌اند. این ویژگی آنها را مختص وظایف متنوعی مانند تطابق تصویر، تفکیک جنس و به‌ویژه، تشخیص تغییرات مناسب می‌سازد. شبکه‌های ترانسفورمری موفقیت خود را در کاربردهای گوناگون بینایی رایانه‌ای و شناسایی سنجش از دور نشان داده‌اند و تطابق بین پچ‌های داده‌ای، مانند پچ‌های مرئی و

1. Spatial Attention

اطمینان قبل از آموزش مدل و تجزیه و تحلیل، از پیش‌پردازش کامل داده‌ها برخوردار است که شامل پاک‌سازی، کالیبراسیون و ژئورفرنس می‌شود. برای پشتیبانی از آموزش و ارزیابی مدل، داده‌های حقیقت زمینی با حاشیه‌نویسی ارائه می‌شود که به‌منزله معیار ارزیابی دقت و عملکرد مدل تشخیص تغییرات به کار خواهند رفت.

۳-۲- شبکه‌های ترانسفورمر

این شبکه‌ها یکی از روش‌های نوین و پیشرفته برای پردازش و تحلیل داده‌های سنجش از دورند و بر مبنای ایده شبکه‌های دوقطبی^۲ طراحی شده‌اند که در آنها دو یا چند زیرشبکه مشابه و هم‌وزن، برای پردازش داده‌ها استفاده می‌شود. تفاوت اصلی این شبکه‌ها با روش‌های قدیمی‌تر در استفاده از مکانیسم‌های توجه خودکار ترانسفورمر^۳ است که به مدل امکان می‌دهد ویژگی‌های پیچیده و روابط فضایی بین داده‌ها را دقیق‌تر تحلیل کند.

ساختار شبکه‌های ترانسفورمر شامل دو یا چند زیرشبکه ترانسفورمر مشابه است که هر یک مسئول پردازش یکی از جریان‌های داده است. این زیرشبکه‌ها، با بهره‌گیری از لایه‌های توجه خودکار، توانایی استخراج ویژگی‌های مهم را از داده‌های ورودی دارند. هر زیرشبکه داده‌های سنجش از دور ورودی خود را دریافت، و برای پردازش آماده می‌کند. این داده‌ها ممکن است شامل تصاویری با وضوح متفاوت و اطلاعات به‌دست‌آمده از حسگرهای گوناگون باشند. در لایه‌های کانولوشن، به‌منزله بخشی از فرایند استخراج ویژگی، ویژگی‌های ابتدایی و سطح پایین را از داده‌های ورودی استخراج می‌کنند. لایه‌های کانولوشن به مدل کمک می‌کنند الگوهای محلی و اطلاعات مکانی را به‌خوبی ثبت کند. لایه‌های ترانسفورمر، با بهره‌گیری از مکانیسم‌های توجه خودکار، ویژگی‌های سطح بالاتر و

موازی و اندازه‌گیری شباهت ادغام می‌شوند. این ادغام ویژگی‌ها به مدل کمک می‌کند شباهت‌ها و تفاوت‌های بین داده‌های ورودی را به‌دقت شناسایی کند و ویژگی‌های گوناگون را تشخیص دهد. این فرایند به‌طور مؤثر داده‌ها را به دسته‌های «تغییر» و «بدون تغییر» طبقه‌بندی می‌کند.

در مرحله آخر، نتایج خروجی به‌صورت نقشه‌ای دودویی^۱ از «تغییر» یا «بدون تغییر» ارائه می‌شود که می‌تواند در تحلیل‌های پیشرفته داده‌های سنجش از دور کاربرد داشته باشد.

این رویکرد بهبودیافته با ترکیب روش‌های مدرن و تکنیک‌های پیشرفته توانسته است دقت و کارایی تشخیص تغییرات در داده‌های سنجش از دور را بهبود بخشد و ابزار قدرتمندی برای تحلیل‌های پیچیده فراهم آورد. هر یک از مراحل بالا، با توضیح و شرح بیشتر، در ادامه مطرح خواهد شد.

۳-۱- جمع‌آوری داده

این بخش بر جنبه‌های مهم مرحله گردآوری داده‌های روش پیشنهادی مبروری جامع دارد و به‌طور خاص بر داده‌های سنجش از دور چندزمانه تمرکز می‌کند که برای موفقیت روش تشخیص تغییرات، ضروری است. مجموعه داده‌های به‌کاررفته معمولاً از منابع متفاوتی که مجهز به حسگرهای سنجش از دورند گرد آمده است و داده‌های متنوعی از مناطق و محیط‌های گوناگون، شامل تصاویر ماهواره‌ای، تصویربرداری هوایی و سایر فناوری‌های سنجش از دور را ثبت می‌کند. این مجموعه داده ویژگی‌های برجسته‌ای دارد؛ مانند وضوح زمانی، ثبت داده‌ها در چندین نقطه زمانی برای پایش تغییرات در فواصل زمانی متفاوت، وضوح مکانی که طیفی را برای تحلیل تغییرات در محیط‌های متفاوت دربرمی‌گیرد، وضوح طیفی، و ثبت داده‌ها در طول موج‌های متفاوت برای افزایش غنای تشخیص تغییرات (Toth & Józków, 2016). علاوه‌براین، مجموعه داده روش پیشنهادی، برای اطمینان از دقت و امکان

1. Binary Map
2. Siamese Networks
3. Transformer-Based Self-Attention

متفاوت را شناسایی کند. به‌علاوه، ساختار موازی شبکه‌های ترانسفورمر این امکان را برای مدل فراهم می‌کند که داده‌های ورودی را به‌طور موازی پردازش کند؛ این نکته باعث افزایش سرعت و کارایی مدل در تشخیص تغییرات می‌شود.

در فرایند توجه خودکار، بردارهای ویژگی (با نماد (x_i, x_j)) از دنباله ورودی به سه فضای متمایز پرسش^۱ با نماد Q ، کلید^۲ با نماد K و مقدار^۳ با نماد V تناسب می‌یابند. این دنباله با استفاده از ماتریس‌های وزنی w_V, w_K, w_Q که تبدیل‌ها را تعریف می‌کنند، ایجاد می‌شود (Boulila et al., 2024).

$$Q_i = x_i \cdot w_Q \quad \text{رابطه (۱)}$$

$$K_i = x_i \cdot w_K \quad \text{رابطه (۲)}$$

$$V_i = x_i \cdot w_V \quad \text{رابطه (۳)}$$

در روابط (۱)، (۲) و (۳)، Q_i نمایانگر تبدیل پرسش بردار ویژگی برای موقعیت i در دنباله ورودی، K_i نمایانگر تبدیل کلید بردار ویژگی برای موقعیت i ، V_i نمایانگر پروجکشن مقدار بردار ویژگی برای موقعیت i و ماتریس‌های وزنی w_V, w_K, w_Q به‌ترتیب برای فضاهای پرسش، کلید و مقدار هستند. امتیاز توجه^۴، بین موقعیت i و تمامی موقعیت‌های دیگر، با استفاده از حاصل ضرب نقطه‌ای بین تبدیل موقعیت i و کلیدهای تمامی موقعیت‌ها محاسبه می‌شود (Li et al., 2021c). نکته اصلی توجه خودکار در محاسبه امتیاز توجه نهفته است که روابط بین عناصر گوناگون در دنباله را تعیین می‌کند. سپس نتیجه با جذر ابعاد بردارهای کلید مقیاس‌دهی می‌شود.

$$Attention_i = \text{softmax} \left(\frac{Q_i \cdot K_j^T}{\sqrt{d}} \right) \quad \text{رابطه (۴)}$$

امتیاز توجه به‌صورت معادله (۴) به دست می‌آید؛

1. Query
2. Key
3. Value
4. Attention Score

روابط پیچیده‌تر بین داده‌ها را استخراج و تحلیل می‌کنند. این لایه‌ها امکان پردازش توالی‌های طولانی داده‌ها و استخراج روابط زمانی و مکانی را دارند. پس از استخراج ویژگی‌های مورد نیاز، لایه‌های ادغام ویژگی‌ها وظیفه ادغام و ترکیب ویژگی‌های استخراج‌شده را بر عهده می‌گیرند. این فرایند ادغام به مدل کمک می‌کند شباهت‌ها و تفاوت‌های بین داده‌های ورودی را به‌دقت شناسایی کند.

مکانیسم‌های توجه خودکار در شبکه‌های دوقطبی ترانسفورمر

این مکانیسم‌ها یکی از نقاط قوت اصلی شبکه‌های ترانسفورمرند و به مدل امکان می‌دهند، با توجه به همه بخش‌های داده، روابط پیچیده بین ویژگی‌های گوناگون را شناسایی و تحلیل کنند. در شبکه‌های ترانسفورمر، مکانیسم‌های توجه خودکار به‌طور موازی در هر زیرشبکه اعمال می‌شوند؛ بدین طریق هر زیرشبکه می‌تواند به‌طور مستقل و موازی داده‌های خود را پردازش کند. این مکانیسم به مدل کمک می‌کند که روابط مکانی بین ویژگی‌های متفاوت را در تصاویر سنجش از دور شناسایی کند. برای نمونه، در تصاویر ماهواره‌ای، توجه فضایی می‌تواند در تشخیص تغییرات زمین و تحلیل الگوهای مکانی نقش مهمی داشته باشد. همچنین این مکانیسم به مدل امکان شناسایی روابط زمانی بین داده‌ها را می‌دهد. این قابلیت، به‌ویژه در تحلیل داده‌های سنجش از دور زمانی، مانند تغییرات پوشش گیاهی یا تغییرات آب‌وهوا، بسیار مفید است (Aleissae et al., 2023).

شبکه‌های ترانسفورمر، با بهره‌گیری از مکانیسم‌های توجه خودکار، در شناسایی تغییرات پیچیده و جزئی داده‌های سنجش از دور توانایی بسیاری دارند. این ویژگی‌ها به مدل امکان می‌دهد تغییرات کوچک و بزرگ را با دقت بالا تشخیص دهد. به‌علاوه، این شبکه‌ها می‌توانند داده‌های ورودی از حسگرها و منابع گوناگون را پردازش کنند. این ویژگی به مدل امکان می‌دهد تا تغییرات داده‌های چندگانه و با وضوح‌های

کاهش ابعاد انجام می‌شود که گام مهمی در فرایند تشخیص تغییر ما است.

رابطه (۶) $D_{ij_transformer} = \text{concat}(z_i, z_j, F_i, F_j)$

همان‌طور که در معادله (۶) نشان داده شده است، توصیفگرهای ترکیبی $D_{ij_transformer}$ با ترکیب (z_i, z_j, F_i, F_j) تشکیل می‌شوند. این توصیفگرها نمایانگر تعامل غنی بین نمایش‌های زمینه‌دار حاصل از توجه خودکار و توصیفگرهای اصلی ویژگی‌اند.

الگوریتم ۱ فرایند ماژول توجه خودکار مبتنی بر ترانسفورمر، از جمله مؤلفه توجه خودکار را نشان می‌دهد. این شبه‌کد، ماژول توجه خودکار مبتنی بر ترانسفورمر را توضیح می‌دهد که شامل مقداردهی اولیه ویژگی‌های ورودی، تعریف ماتریس‌های وزن تبدیل، محاسبه امتیازهای توجه، محاسبه نمایش‌های زمینه‌دار و ترکیب آنها با توصیفگرهای اصلی برای به‌دست‌آوردن توصیفگرهای ترکیبی $D_{ij_transformer}$ است.

در این معادله، d نمایانگر بُعد بردارهای پرسش/کلید است. این امتیاز توجه میزان ارتباط هر عنصر در دنباله را با موقعیت i اندازه‌گیری می‌کند.

امتیازهای توجه محاسبه‌شده برای ایجاد نمایش‌های جدید و زمینه‌دار (z_i) در مورد هر عنصر در دنباله استفاده می‌شوند. این نمایش‌ها از طریق گرفتن مجموع وزنی مقادیر در تمامی موقعیت‌ها به دست می‌آیند؛ به طوری که وزن‌ها با امتیازهای توجه تعیین می‌شوند. در اصل، این فرایند به مدل امکان می‌دهد اطلاعاتی از عناصر در دنباله را که بیشتر به موقعیت فعلی مرتبط‌اند، اولویت‌بندی کند. در معادله (۵)، V_j نمایانگر تبدیل مقدار برای موقعیت j است.

$$z_i = \sum \text{Attention}_i \times V_j \quad (5)$$

نمایش‌های زمینه‌دار به‌دست‌آمده از طریق توجه خودکار (z_i, z_j) سپس، با توصیفگرهای اصلی (F_i, F_j) مشتق شده از تکه‌های ورودی، به‌دقت ترکیب می‌شوند. این ترکیب پیش از انتقال داده‌ها از طریق لایه‌های

الگوریتم ۱. فرایند ماژول توجه خودکار مبتنی بر ترانسفورمر

Inputs: F_i, F_j // Feature vectors
Outputs: $D_{ij_transformer}$ // Combined descriptors
 w_Q, w_K, w_V // Initialize query, key, and value projection weight matrices
 $Q_i = x_i * w_Q$
 $K_i = x_i * w_K$
 $V_i = x_i * w_V$
 d // Define the dimension of the query/key vectors
 $\text{Attention}_i = []$ // Initialize attention scores
for each position j in input_sequence **do**
 $\text{dot_product} = Q_i * K_j^T$
 $\text{scaled_dot_product} = \text{dot_product} / \text{sqrt}(d)$
 $\text{attention_score} = \text{softmax}(\text{scaled_dot_product})$
 $\text{Attention}_i.append(\text{attention_score})$
end
 $z_i = []$ // Initialize contextualized representation
for each position j in input_sequence **do**
 $z_i_element = \text{Attention}_i[j] * V_j$
 $z_i.append(z_i_element)$
end
 $D_{ij_transformer} = \text{concat}(z_i, z_j, F_i, F_j)$
return $D_{ij_transformer}$

۳-۳- توجه فضایی و ادغام ویژگی‌ها

توجه فضایی تکنیک پیشرفته‌ای در تحلیل داده‌های سنجش از دور است که به مدل‌ها اجازه می‌دهد به نواحی خاصی از داده‌ها که حاوی اطلاعات مهم‌اند، توجه بیشتری داشته باشند. این تکنیک به شناسایی روابط مکانی بین ویژگی‌های گوناگون در داده‌های ورودی کمک می‌کند و با تمرکز بر نواحی اصلی، دقت تشخیص تغییرات را افزایش می‌دهد. مکانیسم توجه مکانی به مدل کمک می‌کند بر بخش‌های مهم‌تر داده‌ها تمرکز داشته باشد. این مکانیسم، با استفاده از نقشه‌های توجه، وزن‌های متفاوتی را به هر ناحیه از داده‌ها اختصاص می‌دهد. این وزن‌ها نشان‌دهنده اهمیت هر ناحیه در فرایند تشخیص تغییرات‌اند. نقشه‌های توجه^۱، در این مکانیسم، نشان می‌دهند کدام بخش‌های داده‌های ورودی برای تشخیص تغییرات مهم‌تر است. این نقشه‌ها به مدل امکان می‌دهند، به نواحی کلیدی تصویر، توجه هوشمندانه‌ای داشته باشد و ویژگی‌های مهم را برجسته سازد. توجه فضایی، با تقویت ویژگی‌های کلیدی از نواحی مهم، به مدل کمک می‌کند ویژگی‌های بیشتری را از داده‌های ورودی استخراج کند. این فرایند به بهبود دقت و کارایی مدل در تشخیص تغییرات کمک می‌کند (Chen & Shi, 2020).

ادغام ویژگی‌ها^۲ فرایندی است که طی آن ویژگی‌های استخراج‌شده از منابع گوناگون داده با یکدیگر ترکیب می‌شوند تا نمایه‌ای جامع و ترکیبی از داده‌ها به دست آید. این فرایند امکان ترکیب اطلاعات مهم از منابع گوناگون را به مدل می‌دهد تا دیدگاهی جامع از داده‌ها فراهم آید. در این رویکرد، ویژگی‌های متفاوت از منابع و حسگرهای گوناگون داده‌ها با یکدیگر تلفیق می‌شوند. این فرایند باعث می‌شود مدل بتواند اطلاعات گوناگون را جامع‌تر تحلیل کند و ویژگی‌های محوری را از داده‌های ورودی استخراج کند. همچنین مدل این امکان را می‌یابد که داده‌های ورودی از منابع گوناگونی، مانند تصاویر ماهواره‌ای و داده‌های زمانی، با یکدیگر ترکیب کند (Chen et al., 2020). در این

بخش، ابتدا نقشه‌های توجه برای داده‌های ورودی ایجاد می‌شوند. این نقشه‌ها نشان می‌دهند که کدام بخش داده‌ها اهمیت بیشتری دارند و باید به آنها توجه بیشتری شود. در مرحله بعد، ویژگی‌های استخراج‌شده از داده‌های گوناگون با یکدیگر ترکیب می‌شوند تا نمایه‌ای جامع و ترکیبی از داده‌ها به دست آید. در نهایت، داده‌های تلفیق‌شده تحلیل می‌شوند و مدل تغییرات داده‌ها را جامع‌تر شناسایی می‌کند. در ادامه، فرایند ادغام ویژگی‌ها در قالب الگوریتم ۲ توضیح داده می‌شود.

۳-۴- طبقه‌بندی و نتایج خروجی

طبقه‌بندی و تولید خروجی نهایی از مهم‌ترین مراحل در فرایند تحلیل داده‌های سنجش از دور است. در این مرحله، مدل با استفاده از ویژگی‌ها و اطلاعات جمع‌آوری‌شده از مراحل قبلی، داده‌های ورودی را به دسته‌های مشخص طبقه‌بندی می‌کند و نتایج نهایی را به شکل نقشه‌ای دودویی از تغییرات یا عدم تغییرات ارائه می‌دهد. هدف اصلی این مرحله فراهم‌آوردن دیدگاهی جامع و مورد اعتماد درباره تغییرات در داده‌های سنجش از دور است.

نتیجه نهایی فرایند طبقه‌بندی یک نقشه دودویی است که تغییرات و بدون تغییرات را در داده‌های سنجش از دور نشان می‌دهد. این نقشه، به صورت تصویری واضح و قابل فهم، نتایج تحلیل‌های انجام‌شده را به کاربران ارائه می‌دهد. نقشه‌های تغییرات بخش‌هایی از داده‌های ورودی را که تغییرات مهمی در آنها رخ داده است، نشان می‌دهند. این نقشه‌ها به کاربران کمک می‌کنند تغییرات را به دقت در داده‌ها شناسایی کنند و تحلیل‌های لازم را انجام دهند. به علاوه، نقشه‌های بدون تغییر بخش‌هایی از داده‌ها را نمایش می‌دهند که تغییرات درخور توجهی در آنها رخ نداده است. این نقشه‌ها به کاربران امکان می‌دهد بخش‌های ثابت و بدون تغییر داده‌ها را نیز شناسایی و بررسی کنند.

1. Attention Maps
2. Feature Fusion

الگوریتم ۲. فرایند ادغام ویژگی‌ها

```

Inputs: Input patches
Outputs: similarity_score, feature_type
def parallel_streams(input_patches):
    num_streams = 2
    stream_features = []
    for i in range(num_streams) do
        stream_features.append(feature_extraction(input_patches[i]))
    end
    return stream_features
def upper_network_module(stream_features):
    fused_features = fusion_layer(stream_features)
    similarity_score = determine_similarity(fused_features)
    if similarity_score < threshold then
        feature_type = identify_feature_type(fused_features)
    end
    else if
        feature_type = None // Patches are similar
    end
return similarity_score, feature_type

```

برای حل چالش سایه‌ها در تصاویر سنجش از دور به‌منظور تشخیص تغییرات، روش پیشنهادی شامل چندین راهبرد است که تأثیر سایه‌ها را به حداقل می‌رساند و دقت نتایج را تضمین می‌کند. سایه‌ها می‌توانند در کیفیت و دقت داده‌های سنجش از دور تأثیر چشمگیری بگذارند و به تشخیص‌های نادرست و دسته‌بندی‌های اشتباه منجر شوند. در این روش، تکنیک‌های پیش‌پردازش، مانند تشخیص و حذف سایه اجرا شده است؛ این تکنیک‌ها مناطق سایه را براساس ویژگی‌های طیفی منحصربه‌فردشان شناسایی و آنها را با استفاده از تکنیک‌هایی مانند جبران سایه یا بازسازی، حذف یا تصحیح می‌کنند. برای اطمینان از مقادیر پیکسلی ثابت نیز نرمال‌سازی رادیومتریک در تصاویر گوناگون انجام می‌شود که تأثیر تغییرات روشنایی ناشی از سایه‌ها را کاهش می‌دهد. در مرحله افزایش داده‌ها، سایه‌های مصنوعی به مناطق غیرسایه‌دار افزوده می‌شود تا مدل بتواند، بین تغییرات واقعی و تأثیرات سایه‌ها، تفاوت قائل شود و استحکام آن در برابر تأثیر سایه‌ها در سناریوهای واقعی بهبود یابد. با استفاده از داده‌های

در مرحله بعد، روش مطرح‌شده در سطرهای پیشین در چارچوب SoFRB (Enayati et al., 2023) اجرا می‌شود. براساس این چارچوب، به‌دلیل استفاده از پردازش موازی و بهبود عملکرد تحلیل داده‌های ماهواره‌ای، باید بسترهای سخت‌افزاری مناسب آماده و راه‌اندازی شوند. در لایه بعدی، انواع گوناگون داده‌های سنجش از دور، به‌منزله ورودی، با فرمت‌ها و حجم‌ها و توان تفکیک‌های متفاوت به کار می‌روند.

در لایه پردازش چارچوب که مهم‌ترین لایه در نظر گرفته می‌شود، تشخیص تغییر مطرح‌شده در این لایه پردازش می‌شود. در این لایه، داده‌های سنجش از دور شامل اصلاح نقص‌ها و خطاهای موجود در داده‌های خام دریافتی از حسگرها پیش‌پردازش می‌شود. همچنین به‌منظور آماده‌سازی نتایج مراحل قبلی و انتشار خروجی در فرمتی مناسب، عملیات پس‌پردازش انجام می‌شود. فرایند تشخیص تغییر روش پیشنهادی در لایه پردازش، به‌منظور افزایش کارایی و اجرای موازی، به‌منظور دستیابی به سریع‌ترین زمان ممکن انجام می‌شود.

مانند Web Map Tile، Web Map Service (WMS) و Service (WMTS)، Tile Map Service (TMS) و Web Feature Service (WFS) ارائه می‌شود. در لایه پورتال، خدمات استاندارد به صورت برنامه‌های کاربردی و سرویس نقشه برای دستگاه‌های گوناگون عرضه می‌شود. شکل ۲ روش پیشنهادی در چارچوب SoFRB (Enayati et al., 2023) را نشان می‌دهد.

۴- ارزیابی روش پیشنهادی

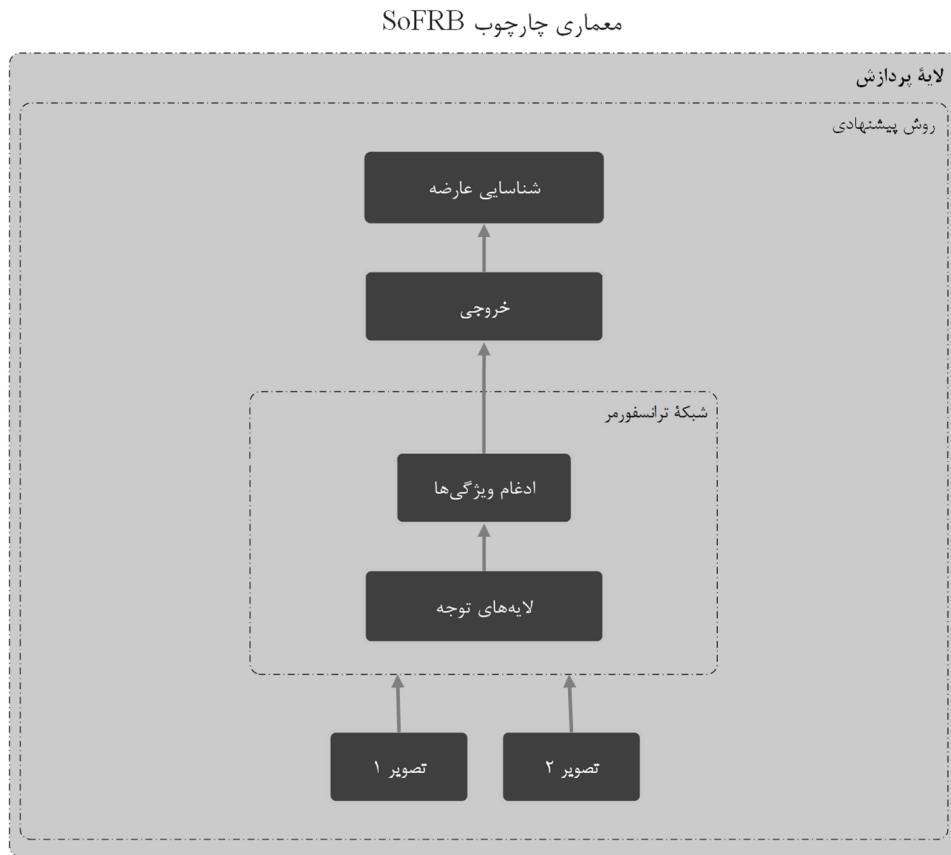
تشخیص تغییرات به چندین عامل و پارامتر اساسی متکی است تا به اهداف از پیش تعیین شده‌اش به‌طور مؤثر دست یابد. این بخش با معرفی مجموعه داده‌ها و داده‌های گوناگون سنجش از دور، دارای کاربرد در روش تشخیص تغییرات، آغاز می‌شود. سپس برای اطمینان از دقت و عملکرد بهینه روش، به پارامترهای ارزیابی لازم پرداخته می‌شود. در پایان این بخش، بین روش پیشنهادی و سایر روش‌های مشابه مقایسه‌ای جامع انجام می‌شود و نقاط قوت و اثربخشی کلیدی روش بیان شده در این پژوهش، در چارچوب SoFRB (Enayati et al., 2023) با توجه به عوامل متنوع، مورد توجه قرار خواهد گرفت.

۴-۱- دیتاست

سنجش از دور مجموعه داده‌های متنوعی را برای تشخیص تغییرات فراهم می‌کند که شامل داده‌های چندطیفی، فراطیفی و راداری می‌شود. تولیدکنندگان حسگرهایی را با محدوده‌های طیفی خاص توسعه می‌دهند تا کاربردهای گوناگون بیابند. برای نمونه، داده‌های SAR برای پایش مناطق شهری بسیار ارزشمند است (Gong et al., 2017). علاوه بر این تصاویر ماهواره‌ای مانند Landsat TM، Landsat MSS، Landsat TM، QuickBird و Ikonos، IRS، ASTER، SPOT، ETM+ هر یک با توان تفکیک‌های مکانی، زمانی، طیفی و رادیومتری متفاوت، به مجموعه داده‌های سنجش از دور در دست، برای تجزیه و تحلیل، کمک می‌کند.

چندطیفی و چندزمانی، مدل از اطلاعات باندهای طیفی متفاوت و دوره‌های زمانی بهره می‌برد که به شناسایی سایه‌ها کمک می‌کند. روش پیشنهادی همچنین شامل مکانیسم‌های توجه فضایی است که روابط فضایی بین ویژگی‌ها را تحلیل می‌کند و سایه‌ها را از تغییرات واقعی تمییز می‌دهد. استفاده از مکانیسم‌های توجه مبتنی بر ترانسفورمر به مدل اجازه می‌دهد بر بخش‌های مربوط به تصویر تمرکز کند و بخش‌های نامربوط، مانند سایه‌ها را نادیده بگیرد. وظایف یادگیری دوتایی نیز به مدل کمک می‌کند سایه‌ها را ویژگی‌های غیردائمی در نظر گیرد و آنها را از تغییرات واقعی، که دارای تداوم زمانی‌اند، متمایز کند. پس‌پردازش‌هایی مانند ماسک سایه نیز، برای فیلتر کردن تغییرات شناسایی شده دارای هم‌پوشانی با مناطق سایه، استفاده می‌شود و با تخصیص امتیاز اعتماد به تغییرات شناسایی شده، تغییراتی که احتمالاً تحت تأثیر سایه‌ها قرار دارند علامت‌گذاری یا حذف می‌شوند. این استراتژی‌های ترکیبی به‌طور مؤثر به سایه‌ها می‌پردازند و اطمینان حاصل می‌کنند که فرایند تشخیص تغییرات دقیق و مورد اعتماد باقی می‌ماند. این استراتژی‌ها، با توجه به نوع ورودی مجموعه داده‌ها و انتخاب از سوی کاربر در لایه پردازش چارچوب، ممکن است متفاوت و اعمال شدنی باشد.

یکی از مزایای روش پیشنهادی مطرح شده و نیز اجرای آن در چارچوب این است که پردازش تشخیص ویژگی پس از تشخیص تغییرات در داده‌های ورودی انجام می‌شود. این کار امکان تعیین شناسایی تغییرات و علاوه بر آن، شناسایی نوع ویژگی‌های تغییر یافته در داده‌های زمانی متفاوت را فراهم می‌کند. پس از انجام شدن عملیات پردازش در لایه سرویس، امکان ارائه خروجی‌های داده‌های پردازش شده برای سنجش از دور، از طریق استفاده از خدمات و ابزارهای نقشه‌برداری‌ای ممکن می‌شود که می‌توانند خدمات استاندارد عرضه کنند. در این لایه، خدمات استاندارد براساس Open Geospatial Consortium (OGC)



شکل ۲. روش پیشنهادی در چارچوب SoFRB

$$Recall = \frac{TP}{TP+FN} \times 100 \quad \text{رابطه (۸)}$$

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100 \quad \text{رابطه (۹)}$$

$$OA = \frac{TP+TN}{TP+FP+TN+FN} \times 100 \quad \text{رابطه (۱۰)}$$

$$IoU = \frac{TP}{TP+FP+FN} \times 100 \quad \text{رابطه (۱۱)}$$

۳-۴- بستر عملیاتی

برای اعتبارسنجی و نشان دادن کارایی مدل پیشنهادی، آزمایش‌هایی با استفاده از مجموعه داده‌ای واقعی انجام می‌دهیم که شامل روش‌های تصویربرداری گوناگون،

طی فرایند ارزیابی، مجموعه داده‌های ماهواره‌ای متنوعی، از جمله MSI MultiSpectral Instrument در سنتینل-۲، High-Resolution Imaging System (QB-2)، QuickBird HRIS در QuickBird و TerraSAR-X به کار رفتند.

۲-۴- معیارهای ارزیابی

به منظور ارزیابی کمی عملکرد روش پیشنهادی، چندین معیار ارزیابی به کار می‌رود. این معیارها شامل دقت^۱، بازخوانی^۲، F1-score، دقت کلی (OA)^۳ و هم‌پوشانی متقاطع (Intersection over Union - IoU) هستند که این‌گونه محاسبه می‌شوند:

$$Precision = \frac{TP}{TP+FP} \times 100 \quad \text{رابطه (۷)}$$

1. Precision
2. Recall
3. Overall Accuracy

برای تشخیص تغییرات را بررسی کنیم: پارامتر حاشیه (m) و اندازه دسته^۱. این هایپرپارامترها، در شکل‌دهی به عملکرد مدل ما، نقش مهمی دارند و درک تأثیر آنها برای بهینه‌سازی روش ضروری است.

۴-۴-۱- پارامتر حاشیه

پارامتر حاشیه هایپرپارامتری ضروری است که جداسازی بین نمونه‌های مثبت و منفی را در فضای ویژگی‌ها کنترل می‌کند. براساس آزمایش‌هایی که روی مجموعه داده‌های سنتینل-۲، QuickBird و TerraSAR-X انجام شد، مقادیر بهینه حاشیه با توجه به مجموعه داده‌ها متفاوت بود. برای نمونه، یک حاشیه ۰/۸ در مجموعه داده سنتینل-۲ بیشترین دقت کلی (۹۸.۹۹٪) را داشت. این مسئله اهمیت انتخاب حاشیه مناسب به‌منظور افزایش کارایی مدل تشخیص تغییرات را درمورد مجموعه داده‌های خاص سنجش از دور، برجسته می‌کند.

شرایط متنوع تشخیص تغییرات و توان تفکیک‌های مکانی متفاوت است. این مجموعه داده شامل اطلاعاتی از حسگرها و منابع گوناگون است و سناریوهایی مانند ساخت و تخریب ساختمان‌ها، تغییرات در کاربری زمین‌های کشاورزی و تبدیل مراکز صنعتی در مناطق متفاوت را به تصویر می‌کشد. سیستمی با کارایی بالا، شامل یک CPU 24 هسته‌ای Xeon E5-2697 v2، ۲۸ گیگابایت حافظه، دیسک SSD با ظرفیت ۲۰۰ گیگابایت و یک کارت گرافیک قدرتمند RTX 2080 Ti با ۱۱ گیگابایت RAM و CUDA 11، برای ایجاد محیط آزمایش و بستر عملیاتی به کار گرفته شده است.

۴-۴-۲- ارزیابی هایپرپارامترها

در این بخش، فرایند تحلیل حساسیت صورت می‌پذیرد تا تأثیر دو هایپرپارامتر اساسی در روش پیشنهادی

جدول ۱. نتایج کمی پارامترهای حاشیه متفاوت روی مجموعه داده سنتینل-۲

حاشیه	دقت کلی (%)	هم‌پوشانی متقاطع (%)	F1-score (%)	بازخوانی (%)	دقت (%)
0/5	98/87	91/48	95/51	96/92	94/13
0/6	98/92	91/71	95/71	96/63	94/79
0/7	98/96	91/96	95/89	96/47	95/31
0/8	98/99	92/15	96/30	95/72	96/88
0/9	98/95	92/03	95/91	94/59	97/26
0/95	98/93	91/79	95/84	93/64	98/13

جدول ۲. نتایج کمی پارامترهای حاشیه متفاوت روی مجموعه داده QuickBird

حاشیه	دقت کلی (%)	هم‌پوشانی متقاطع (%)	F1-score (%)	بازخوانی (%)	دقت (%)
0/5	99/02	82/59	90/43	93/41	87/63
0/6	99/04	82/81	90/67	93/18	88/29
0/7	99/09	83/16	90/73	92/57	88/95
0/8	99/11	83/33	90/95	92/11	89/82
0/9	99/18	83/64	91/13	91/31	90/94
0/95	99/22	83/71	91/24	90/92	91/55

جدول ۳. نتایج کمی پارامترهای حاشیه متفاوت روی مجموعه داده TerraSAR-X

حاشیه	دقت کلی (%)	هم‌پوشانی متقاطع (%)	F1-score (%)	بازخوانی (%)	دقت (%)
0/5	98/83	91/44	95/56	96/96	94/19
0/6	98/89	91/57	95/76	96/44	95/08
0/7	99/12	91/69	95/81	95/37	96/25
0/8	98/97	91/88	95/88	94/29	97/51
0/9	98/56	91/76	96/02	93/78	98/36
0/95	98/03	91/74	95/81	92/84	98/97

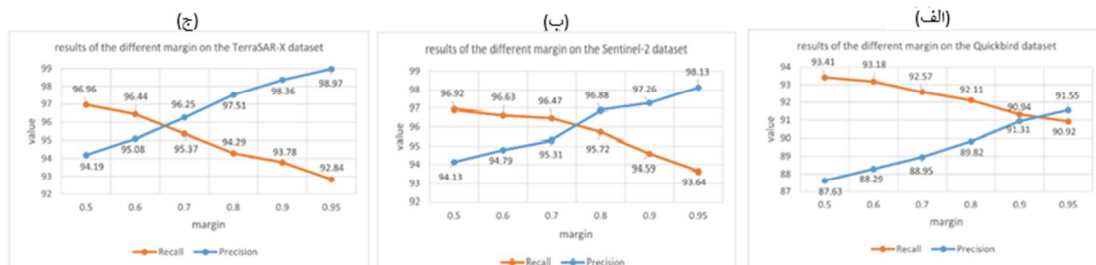
1. Batch Size

دست می‌دهند و کارآیی روش ما را در بهبود دقت تشخیص تغییرات، برجسته می‌کنند.

۴-۴-۲- پارامتر اندازه دسته

هایپرپارامترهای محوری، با تعیین تعداد نمونه‌هایی که در هر تکرار استفاده می‌شود، فرایند آموزش را شکل می‌دهند. آزمایش‌های ما که در جدول‌های ۴، ۵ و ۶ به تفصیل به آنها اشاره شده است، حساسیت مدل را در برابر اندازه‌های متفاوت دسته، ارزیابی می‌کند و تأثیر آنها در عملکرد، طی فرایند آموزش را روشن می‌سازد.

در شکل ۳، تأثیر مقادیر حاشیه در عملکرد تشخیص تغییرات در مجموعه داده‌های گوناگون سنجش از دور، به صورت بصری نشان داده شده و رابطه بین تنظیمات حاشیه و معیارهای مهم، مانند بازخوانی و دقت، تصویر شده است. این نمودارها این بینش ارائه می‌دهند که مقادیر متفاوت حاشیه، در شناسایی دقیق موارد تغییر (بازخوانی) و کاهش مثبت‌های کاذب (دقت)، چه تأثیری می‌گذارند و همچنین درک جامعی درباره انتخاب حاشیه بهینه، برای هر مجموعه داده، به



شکل ۳. نمودار خطی مقادیر فراخوان و دقت با حاشیه‌های متفاوت در QuickBird (الف)؛ سنتینل-۲ (ب)؛ TerraSAR-X (ج)

جدول ۴. نتایج کمی اندازه‌های متفاوت دسته در مجموعه داده سنتینل-۲

اندازه دسته	دقت کلی (%)	هم‌پوشانی متقاطع (%)	F1-score (%)	بازخوانی (%)	دقت (%)
16	99/04	82/92	90/28	89/22	91/36
32	99/06	83/36	90/89	91/18	90/59
64	99/09	83/71	91/14	91/24	91/03
128	98/93	82/58	90/51	90/93	90/08

جدول ۵. نتایج کمی اندازه‌های دسته‌های متفاوت در مجموعه داده‌های QuickBird

اندازه دسته	دقت کلی (%)	هم‌پوشانی متقاطع (%)	F1-score (%)	بازخوانی (%)	دقت (%)
16	98/91	82/94	89/99	93/66	86/59
32	98/96	83/32	90/21	93/45	87/18
64	99/01	83/78	90/36	93/27	87/61
128	98/82	82/47	89/65	93/69	85/94

جدول ۶. نتایج کمی اندازه‌های مختلف دسته در مجموعه داده TerraSAR-X

اندازه دسته	دقت کلی (%)	هم‌پوشانی متقاطع (%)	F1-score (%)	بازخوانی (%)	دقت (%)
16	98/82	90/16	94/27	94/19	94/35
32	98/94	90/64	95/68	94/63	96/74
64	99/03	91/39	95/99	94/82	97/18
128	98/96	90/75	95/77	94/93	96/61


سنتینل-۲، TerraSAR-X و QuickBird در شکل‌های ۴، ۵ و ۶ مطرح شده است. در طول فرایند آموزش، پیچ‌ها به صورت تصادفی از ماسک‌های تصاویر مورد نظر استخراج می‌شوند.

در شکل ۴، اعمال روش تشخیص تغییرات ما روی مجموعه داده سنتینل-۲، به صورت بصری، با نمودارهای ۴-الف و ۴-ب و همچنین تغییرات زمانی و نتایج بر مبنای ترانسفورمر در چارچوب سرویس‌گرایی (SoFRB) (شکل ۴-ج) نمایش داده شده است. به همین ترتیب، شکل‌های ۵ و ۶ نشان می‌دهند که روش ما روی مجموعه داده‌های TerraSAR-X و QuickBird با موفقیت عمل کرده است؛ این مجموعه داده‌ها ورودی‌های بصری از پویایی‌های زمانی را فراهم می‌آورند و کارایی و قابلیت انطباق روش در تحلیل کلان‌داده‌های سنجش از دور را تأیید می‌کنند.

همان‌گونه که تحلیل حساسیت ما، با هدف شناسایی مقداری بهینه نشان می‌دهد، انتخاب اندازه دسته نقش پرننگی در سرعت همگرایی و دقت مدل ایفا می‌کند. در مجموعه داده‌های سنتینل-۲، QuickBird و TerraSAR-X، آزمایش‌ها نشان می‌دهند اندازه دسته ۶۴ به طور مداوم بالاترین دقت کلی، IoU، F1-score، بازخوانی و دقت را دربردارد که نشان‌دهنده اثربخشی آن در تولید معیارهای عملکرد متعادل، در وظایف تشخیص تغییرات است و از پذیرش آن، در مجموعه داده‌های متفاوت سنجش از دور، حمایت می‌کند.

۴-۵- اجرا و ارزیابی نتایج


برای نمایش کارایی و عملکرد مؤثر روش پیشنهادی، چند نمونه اجرایی برای مجموعه داده‌های ماهواره‌ای




شکل ۴. اجرای روش پیشنهادی روی مجموعه داده سنتینل-۲: داده‌های دو زمان متفاوت (الف و ب)؛ تغییرات برجسته در تصویر ناشی از روش پیشنهادی است (ج)

عملکرد هر روش با استفاده از معیارهای کمی مانند دقت کلی، F1-score، بازخوانی و دقت دقیقاً ارزیابی شد و ارزیابی جامعی از توانایی‌های تشخیص تغییر آنها، در مجموعه داده‌های سنتینل-۲ و QuickBird و TerraSAR-X، در جدول‌های ۷، ۸ و ۹ گزارش داده شده است. روش پیشنهادی، در قیاس با هم‌تایان خود، پیشرفت ثابت چشمگیری دارد و OAهای معتنا بهی، به ترتیب برابر با ۹۸/۸۱٪، ۹۸/۹۶٪ و ۹۹/۰۸٪ در مجموعه داده‌های سنتینل-۲، QuickBird و TerraSAR-X به دست می‌آورد. این روش، افزون‌بر دقت بسیار، در اسکور F1 و بازخوانی هم برتری دارد و این نکته بیانگر کارایی و عملکرد قدرتمند آن، در صحنه‌های متفاوت داده‌گیری از دور است. این نتایج نشان می‌دهند روش پیشنهادی ما قابلیت تطبیق بر مجموعه داده‌های متنوع را دارد و مداوماً نتایجی برتر از روش‌های دیگر به دست می‌دهد. عملکرد استثنایی DMMSTNet و MASNet نشان می‌دهد که برای برخی برنامه‌ها مناسب‌اند.

برای ارزیابی کارایی روش پیشنهادی، این شیوه را با هشت روش پیشرو مبتنی بر یادگیری عمیق در حوزه تشخیص تغییر مقایسه کردیم؛ برای نمونه، شبکه عصبی کاملاً کانولوشنی با شبکه‌های حافظه کوتاه‌مدت بلند (FCN-LSTM) (Sefrin et al., 2020)، شبکه عصبی کانولوشنی سیامی عمیق (DSCN) (Zhan et al., 2017)، شبکه تشخیص تغییر مبتنی بر ترجمه عمیق (DTCDN) (Li et al., 2021a)، شبکه عصبی کاملاً کانولوشنی با استفاده از استخراج هرمی (FCN-PP) (Lei et al., 2019)، UNet++ چندمنبعی (CD(MSCDUNet) (Li et al., 2022b)، شبکه سیامی با توجه چندمقیاسی (MASNet) (Li et al., 2022a)، شبکه ترانسفورمر سیامی چندمقیاسی و توجه چندمقیاسی عمیق (DMMSTNet) (Zhang et al., 2023) و شبکه CD تقویت‌شده با اندازه‌گیری سوپرپیکسل (ESNet) (Zhang et al., 2021).



شکل ۵. اجرای روش پیشنهادی روی مجموعه داده TerraSAR-X: رنگ طبیعی از دو زمان متفاوت (الف و ب)؛ تغییرات برجسته در تصویر ناشی از روش پیشنهادی است (ج)



شکل ۶. اجرای روش پیشنهادی روی مجموعه داده QuickBird: داده‌های دو زمان متفاوت (الف و ب)؛ تغییرات برجسته در تصویر ناشی از روش پیشنهادی است (ج)

جدول ۷. نتایج کمی روش‌های گوناگون روی مجموعه داده سنتینل-۲

روش	دقت (%)	بازخوانی (%)	F1-score (%)	دقت کلی (%)
DSCN (Zhan et al., 2017)	52/34	82/96	64/19	93/59
FCN-PP (Lei et al., 2019)	51/8	74/93	61/26	96/85
FCN-LSTM (Sefrin et al., 2020)	79/37	85/08	82/13	97/91
DTCN (Li et al., 2021a)	80/66	88/15	84/24	98/22
ESNet (Zhang et al., 2021)	82/81	90/46	86/47	98/35
MSCDUNet (Li et al., 2022b)	79/92	92/87	85/91	98/04
MASNet (Li et al., 2022a)	82/73	93/06	87/59	98/49
DMMSTNet (Zhang et al., 2023)	86/14	91/82	88/89	98/81
Proposed method	92/25	92/07	92/16	99/23

جدول ۸. نتایج کمی روش‌های متفاوت در مجموعه داده‌های QuickBird

روش	دقت (%)	بازخوانی (%)	F1-score (%)	دقت کلی (%)
DSCN (Zhan et al., 2017)	85/05	83/91	84/48	95/61
FCN-PP (Lei et al., 2019)	89/37	87/45	88/40	96/31
FCN-LSTM (Sefrin et al., 2020)	93/84	87/61	90/62	97/29
DTCN (Li et al., 2021a)	92/15	90/59	91/37	97/58
ESNet (Zhang et al., 2021)	91/90	93/62	92/75	98/04
MSCDUNet (Li et al., 2022b)	89/81	92/37	91/08	96/83
MASNet (Li et al., 2022a)	93/12	92/95	93/04	98/35
DMMSTNet (Zhang et al., 2023)	94/07	94/18	94/13	98/49
Proposed method	96/83	94/67	95/74	98/96

جدول ۹. نتایج کمی روش‌های متفاوت روی مجموعه داده TerraSAR-X

روش	دقت (%)	بازخوانی (%)	F1-score (%)	دقت کلی (%)
DSCN (Zhan et al., 2017)	76/22	88/19	81/77	93/27
FCN-PP (Lei et al., 2019)	82/36	87/29	84/76	94/86
FCN-LSTM (Sefrin et al., 2020)	87/52	91/63	89/53	95/49
DTCN (Li et al., 2021a)	84/27	94/84	89/25	95/71
ESNet (Zhang et al., 2021)	93/51	91/89	92/70	97/16
MSCDUNet (Li et al., 2022b)	90/49	93/71	92/07	96/23
MASNet (Li et al., 2022a)	92/85	94/64	93/74	97/67
DMMSTNet (Zhang et al., 2023)	93/92	94/88	94/40	97/94
Proposed method	95/04	95/39	96/21	99/08

۴-۶- بحث و تحلیل

در مقایسه با روش‌های پیشین، نتایج حاصل از مدل ترانسفورمری پیشنهادی بهبود شایان توجهی را در دقت و کارایی تشخیص تغییرات نشان می‌دهد. روش پیشنهادی به‌طور خاص توانسته است، با بهره‌گیری از معماری ترانسفورمر و مکانیسم توجه خودکار، دقت کلی بیشتری را در مقایسه با روش‌های مشابه همچون UNet، DSAMNet، مبتنی بر ماژول‌های توجه، و ECFNet که در بخش مرور منابع به آنها اشاره شد، کسب کند. برای نمونه، جو و همکاران (۲۰۲۳)، با استفاده از ECFNet، به دقت کلی نزدیک به ۹۷٪ دست یافتند؛ در صورتی که روش پیشنهادی مطرح شده توانست دقت کلی بیشتر از ۹۸/۹۹٪ را در مجموعه داده‌های گوناگون، مانند سنتینل-۲ به ثبت برساند. این بهبود عمدتاً به دلیل استفاده از مکانیسم‌های توجه در مدل ترانسفورمر بوده که به‌طور مؤثری توانسته است ویژگی‌های مهم را از تصاویر سنجش از دور استخراج و به تشخیص تغییرات با دقتی بیشتر کمک کند.

یکی از مزایای اصلی روش پیشنهادی، خودکارسازی کامل فرایند تشخیص تغییرات است که از طریق مکانیسم‌های توجه خودکار امکان‌پذیر شده است. این ویژگی باعث می‌شود مدل، بدون نیاز به تنظیمات دستی و انتخاب پارامترهای خاص، به صورت پویا و با توجه به نوع و ویژگی‌های داده‌ها عمل کند. این قابلیت خودکارسازی که در روش‌های پیشین، مانند شبکه‌های دوقلوی کاملاً پیچشی و کدگذارهای خودکار

پیچشی به‌طور کامل وجود نداشت (Wang et al., 2021; Wu et al., 2021) باعث می‌شود مدل پیشنهادی، در مواجهه با مجموعه داده‌های حجیم و پیچیده، کارایی و سرعت بیشتری داشته باشد. این ویژگی، به‌خصوص در زمینه تحلیل کلان‌داده‌های سنجش از دور که به پردازش سریع و دقیق نیاز دارند، بسیار ارزشمند است.

روش پیشنهادی در برخورد با داده‌های سنجش از دور گوناگون، از جمله تصاویر اپتیکی، فرسرخ و راداری نیز، انعطاف‌پذیری بیشتری از خود نشان می‌دهد. برخلاف برخی روش‌های پیشین که به دلیل طراحی محدود، فقط قادر به کار با یک نوع داده خاص بودند، استفاده از ترانسفورمرها و مکانیسم‌های توجه خودکار این امکان را به مدل می‌دهد که با تغییرات در نوع و ویژگی‌های داده‌ها، به‌خوبی سازگار شود. برای نمونه، روش‌های مبتنی بر شبکه‌های دوقلوی تفکیک معنایی که یانگ و همکاران (۲۰۲۱) پیشنهاد کردند، اغلب بر تصاویر اپتیکی متمرکز بودند و در مواجهه با داده‌های راداری، انعطاف‌پذیری کمتری داشتند. اما روش پیشنهادی در پژوهش ما قادر به پردازش و تحلیل موفقیت‌آمیز داده‌های راداری، مانند TerraSAR-X است و عملکرد خوبی در این زمینه نشان داده است.

مکانیسم‌های توجه از ارکان محوری روش پیشنهادی‌اند که در بهبود دقت و کارایی مدل، نقش مهمی ایفا می‌کنند. این مکانیسم‌ها، با تمرکز بر ویژگی‌های مهم و نادیده گرفتن جزئیات غیرضروری، به

۵- نتیجه‌گیری

در این مقاله، شیوه‌ای نوآورانه و جامع برای تشخیص تغییرات در داده‌های سنجش از دور مطرح شده است که با استفاده از ترکیب شبکه‌های مبتنی بر ترانسفورمر و مدل توجه خودکار، توانسته است به بهبود دقت و قابلیت اطمینان در تشخیص تغییرات دست یابد. بخش «بحث» نشان می‌دهد این روش، با استفاده از تکنیک‌های یادگیری جفتی و ادغام ویژگی، به راه‌حلی همه‌جانبه برای مدیریت انواع گوناگون داده‌ها و سنسورها دست می‌یابد و با استفاده از چارچوب SoFRB (Enayati et al., 2023)، کارایی پردازش را بهبود می‌دهد.

از دستاوردهای مهم و محوری این تحقیق، می‌توان به بهبود در دقت تشخیص تغییرات و شناسایی نوع ویژگی‌ها اشاره کرد. در بخش «بحث» نیز بیان شد که روش پیشنهادی، افزون بر امکان تشخیص تغییرات، نوع ویژگی‌های تغییر یافته را نیز به دقت شناسایی می‌کند؛ این مسئله به تحلیل دقیق‌تر و کاربردی‌تر در زمینه‌های گوناگون یاری می‌رساند. درباره عملکرد روش پیشنهادی در مقایسه با روش‌های فعلی، آزمایش‌ها و مقایسه‌های انجام شده نشان داده‌اند که این شیوه، در مجموعه داده‌های متنوعی از جمله سنتینل-۲ و TerraSAR-X و QuickBird، از نظر معیارهای دقت کلی، F1-score، بازخوانی و دقت، عملکرد بهتری داشته است. همچنین این روش، با نشان دادن توانایی سازگاری با داده‌های گوناگون و ارائه نتایج دقیق، پتانسیل بالایی برای استفاده در نظارت بر محیط زیست، برنامه‌ریزی شهری، کشاورزی و مدیریت بلایا دارد؛ در بخش «بحث»، بر این نکته نیز تأکید شده است.

در نهایت، این تحقیق به توسعه ابزارهای دقیق‌تر و کارآمدتر برای تحلیل داده‌های سنجش از دور کمک می‌کند و افق‌های جدیدی را برای تحقیقات آینده می‌گشاید. براساس یافته‌های بحث، تلاش‌های آینده می‌تواند بر اصلاح این روش متمرکز شود تا با پیشرفت فناوری‌های سنجش از راه دور و کاوش در معماری‌های یادگیری عمیق اضافی و مکانیسم‌های توجه، تطبیق یابد.

مدل این امکان را می‌دهند که روابط پیچیده بین ویژگی‌ها را بهتر درک کند. این موضوع، در مقایسه با کاربرد روش‌هایی که توجه را به صورت محدود یا فقط در لایه‌های پایانی استفاده می‌کنند، برتری محسوسی ایجاد کرده است. برای نمونه، الوه و همکاران (۲۰۲۳) با استفاده از ماژول‌های توجه صرفاً در لایه‌های میانی UNet، در دقت تشخیص تغییرات به بهبودهایی دست یافته‌اند اما این بهبودها به اندازه روش پیشنهادی گسترده و درخور توجه نبوده است. مکانیسم‌های توجه، در معماری ترانسفورمری پیشنهادی، از لایه‌های متعدد و چندگانه بهره می‌برند که هم‌زمان توجه فضایی و زمانی را اعمال می‌کنند؛ این وضعیت به بهبود چشمگیری در دقت تشخیص تغییرات منجر شده است. به علاوه، تحلیل‌های حساسیت نشان داده‌اند که پارامترهای حاشیه و اندازه دسته، در بهینه‌سازی عملکرد مدل، نقش بسیار مهمی دارند. انتخاب مقادیر بهینه برای این پارامترها، همان‌طور که در نتایج آزمایش‌های انجام شده مشاهده شد، می‌تواند عملکرد مدل را بهبود بسیاری ببخشد. این مسئله اهمیت تنظیم دقیق پارامترهای تنظیمی، برای اطمینان از عملکرد بهینه مدل در شرایط گوناگون را بازگو می‌کند. مثلاً مقدار حاشیه ۰/۸ در مجموعه داده سنتینل-۲ توانست به دقت کلی ۹۸/۹۹٪ دست یابد؛ این نتایج هم‌سو با نتایج مطالعات دیگر، مانند تحقیقات شن و همکاران (۲۰۲۲)، اهمیت تنظیمات دقیق در بهره‌وری بیشتر مدل را می‌رساند.

به طور کلی مشخص شده است که روش پیشنهادی مبتنی بر ترانسفورمر و مکانیسم‌های توجه خودکار می‌تواند، در رفع محدودیت‌های روش‌های تشخیص تغییرات سنجش از دور، نقش مؤثری داشته باشد. این روش با بهره‌گیری از خودکارسازی، مقیاس‌پذیری، انعطاف‌پذیری و استفاده کامل از مکانیسم‌های توجه توانسته است به دقت و کارایی بالاتری در تشخیص تغییرات دست یابد. این یافته‌ها نشان‌دهنده پتانسیل بالای استفاده از معماری ترانسفورمری در تحلیل کلان‌داده‌های سنجش از دور و ایجاد راه‌حل‌های نوآورانه برای چالش‌های پیش روی این حوزه است.

۶- منابع

- Afaq, Y. & Manocha, A., 2021, **Analysis on Change Detection Techniques for Remote Sensing Applications: A Review**, Ecological Informatics, 63, P. 101310. <https://doi.org/10.1016/j.ecoinf.2021.101310>.
- Alaissae, A.A., Kumar, A., Anwer, R.M., Khan, S., Cholakkal, H., Xia, G.-S. & Khan, F.S., 2023, **Transformers in Remote Sensing: A Survey**, Remote Sensing, 15(7), P. 1860. <https://doi.org/10.3390/rs15071860>.
- Asokan, A. & Anitha, J., 2019, **Change Detection Techniques for Remote Sensing Applications: A Survey**, Earth Science Informatics, 12, PP. 143–160. <https://doi.org/10.1007/s12145-019-00380-5>.
- Bai, T., Wang, L., Yin, D., Sun, K., Chen, Y., Li, W. & Li, D., 2023, **Deep Learning for Change Detection in Remote Sensing: A Review**, Geo-Spatial Information Science, 26(3), PP. 262–288. <https://doi.org/10.1080/10095020.2022.2085633>.
- Boccardo, P. & Giulio Tonolo, F., 2015, **Remote Sensing Role in Emergency Mapping for Disaster Response**, In: Engineering Geology for Society and Territory-Volume 5, Urban Geology, Sustainable Planning and Landscape Exploitation. [place unknown], Springer, PP. 17–24. https://doi.org/10.1007/978-3-319-09048-1_3.
- Boulila, W., Ghandorh, H., Masood, S., Alzahem, A., Koubaa, A., Ahmed, F., Khan, Z. & Ahmad, J., 2024, **A Transformer-Based Approach Empowered by a Self-Attention Technique for Semantic Segmentation in Remote Sensing**, Heliyon, 10(8). <https://doi.org/10.1016/j.heliyon.2024.e29396>.
- Chen, H. & Shi, Z., 2020, **A Spatial-Temporal Attention-Based Method and a New Dataset for Remote Sensing Image Change Detection**, Remote Sensing, 12(10), P. 1662. <https://doi.org/10.3390/rs12101662>.
- Chen, L., Zhang, D., Li, P. & Lv, P., 2020, **Change Detection of Remote Sensing Images Based on Attention Mechanism**, Computational Intelligence and Neuroscience, 2020(1), P. 6430627. <https://doi.org/10.1155/2020/6430627>.
- Chen, H., Qi, Z. & Shi, Z., 2021, **Remote Sensing Image Change Detection with Transformers**, IEEE Transactions on Geoscience and Remote Sensing, 60, PP. 1–14. <https://doi.org/10.1109/TGRS.2021.3095166>.
- Chen, J., Chen, S., Fu, R., Li, D., Jiang, H., Wang, C., Peng, Y., Jia, K. & Hicks, B.J., 2022, **Remote Sensing Big Data for Water Environment Monitoring: Current Status, Challenges, and Future Prospects**, Earth's Future, 10(2), P. e2021EF002289. <https://doi.org/10.1029/2021EF002289>.
- Chi, M., Plaza, A., Benediktsson, J.A., Sun, Z., Shen, J. & Zhu, Y., 2016, **Big Data for Remote Sensing: Challenges and Opportunities**, Proceedings of the IEEE, 104(11), PP. 2207–2219. <https://doi.org/10.1109/JPROC.2016.2598228>.
- Enayati, R., Ravanmehr, R. & Aghazarian, V., 2023, **A Service-Oriented Framework for Remote Sensing Big Data Processing**, Earth Science Informatics, 16(1), PP. 591–616. <https://doi.org/10.1007/s12145-022-00900-w>.
- Fang, B., Pan, L. & Kou, R., 2019, **Dual Learning-Based Siamese Framework for Change Detection Using Bi-Temporal VHR Optical Remote Sensing Images**, Remote Sensing, 11(11), P. 1292. <https://doi.org/10.3390/rs11111292>.
- Fingas, M., 2019, **Remote Sensing for Marine Management**, In: World Seas: An Environmental Evaluation, [place unknown], Elsevier, PP. 103–119. <https://doi.org/10.1016/B978-0-12-805052-1.00005-X>.
- Gong, M., Niu, X., Zhang, P. & Li, Z., 2017, **Generative Adversarial Networks for Change Detection in Multispectral Imagery**, IEEE Geoscience and Remote Sensing Letters, 14(12), PP.2310–2314. <https://doi.org/10.1109/LGRS.2017.2762694>.
- Huang, Y., Chen, Z., Tao, Y., Huang, X. & Gu, X., 2018, **Agricultural Remote Sensing Big Data: Management and Applications**, Journal of Integrative Agriculture, 17(9), PP.

- 1915–1931. [https://doi.org/10.1016/S2095-3119\(17\)61859-8](https://doi.org/10.1016/S2095-3119(17)61859-8).
- Ismail, A., Bagula, B.A. & Tuyishimire, E., 2018, **Internet-of-Things in Motion: A Uav Coalition Model for Remote Sensing in Smart Cities**, *Sensors*, 18(7), P. 2184. <https://doi.org/10.3390/s18072184>.
- Khan, S.H., He, X., Porikli, F. & Bennamoun, M., 2017, **Forest Change Detection in Incomplete Satellite Images with Deep Neural Networks**, *IEEE Transactions on Geoscience and Remote Sensing*, 55(9), PP. 5407–5423. <https://doi.org/10.1109/TGRS.2017.2707528>.
- Lei, T., Zhang, Y., Lv, Z., Li, S., Liu, S. & Nandi, A.K., 2019, **Landslide Inventory Mapping from Bitemporal Images Using Deep Convolutional Neural Networks**, *IEEE Geoscience and Remote Sensing Letters*, 16(6), PP. 982–986. <https://doi.org/10.1109/LGRS.2018.2889307>.
- Li, K., Wan, G., Cheng, G., Meng, L. & Han, J., 2020, **Object Detection in Optical Remote Sensing Images: A Survey and a New Benchmark**, *ISPRS Journal of Photogrammetry and Remote Sensing*, 159, pp. 296–307. <https://doi.org/10.1016/j.isprsjprs.2019.11.023>.
- Li, X., Du, Z., Huang, Y. & Tan, Z., 2021a, **A Deep Translation (GAN) Based Change Detection Network for Optical and SAR Remote Sensing Images**, *ISPRS Journal of Photogrammetry and Remote Sensing*, 179, PP. 14–34. <https://doi.org/10.1016/j.isprsjprs.2021.07.007>.
- Li, Y., Ma, J. & Zhang, Y., 2021b, **Image Retrieval from Remote Sensing Big Data: A Survey**, *Information Fusion*, 67, PP. 94–115. <https://doi.org/10.1016/j.inffus.2020.10.008>.
- Li, Q., Yan, D. & Wu, W., 2021c, **Remote Sensing Image Scene Classification Based on Global Self-Attention Module**, *Remote Sensing*, 13(22), P. 4542. <https://doi.org/10.3390/rs13224542>.
- Li, J., Zhu, S., Gao, Y., Zhang, G. & Xu, Y., 2022a, **Change Detection for High-Resolution Remote Sensing Images Based on a Multi-Scale Attention Siamese Network**, *Remote Sensing*, 14(14), P. 3464. <https://doi.org/10.3390/rs14143464>.
- Li, H., Zhu, F., Zheng, X., Liu, M. & Chen, G., 2022b, **MSCDUNet: A Deep Learning Framework for Built-up Area Change Detection Integrating Multispectral, SAR, and VHR Data**, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, PP. 5163–5176. <https://doi.org/10.1109/JSTARS.2022.3181155>.
- Liu, P., 2015, **A Survey of Remote-Sensing Big Data**, *Frontiers in Environmental Science*, 3, P. 45. <https://doi.org/10.3389/fenvs.2015.00045>.
- Lu, M., Pebesma, E., Sanchez, A. & Verbesselt, J., 2016, **Spatio-Temporal Change Detection from Multidimensional Arrays: Detecting Deforestation from MODIS Time Series**, *ISPRS Journal of Photogrammetry and Remote Sensing*, 117, PP. 227–236. <https://doi.org/10.1016/j.isprsjprs.2016.03.007>.
- Lv, Z., Zhong, P., Wang, W., You, Z. & Falco, N., 2023, **Multi-Scale Attention Network Guided with Change Gradient Image for Land Cover Change Detection Using Remote Sensing Images**, *IEEE Geoscience and Remote Sensing Letters*. <https://doi.org/10.1109/LGRS.2023.3267879>.
- Pande, C.B. & Moharir, K.N., 2023, **Application of Hyperspectral Remote Sensing Role in Precision Farming and Sustainable Agriculture under Climate Change: A Review**, *Climate Change Impacts on Natural Resources, Ecosystems and Agricultural Systems*, PP. 503–520. https://doi.org/10.1007/978-3-031-19059-9_21.
- Papadomanolaki, M., Verma, S., Vakalopoulou, M., Gupta, S. & Karantzalos, K., 2019, **Detecting Urban Changes with Recurrent Neural Networks from Multitemporal Sentinel-2 Data**, In: *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*. [Place Unknown], IEEE, PP. 214–217. <https://doi.org/10.1109/IGARSS.2019.8900330>.
- Peng, D., Bruzzone, L., Zhang, Y., Guan, H., Ding, H. & Huang, X., 2020, **SemiCDNet: A**

- Semisupervised Convolutional Neural Network for Change Detection in High Resolution Remote-Sensing Images**, IEEE Transactions on Geoscience and Remote Sensing, 59(7), PP. 5891–5906. <https://doi.org/10.1109/TGRS.2020.3011913>.
- Rathee, G., Kerrache, C.A., Calafate, C.T., Bilal, M. & Song, H., 2024, **SMART: A Secure Remote Sensing Solution for Smart Cities' Urban Areas**, IEEE Sensors Journal. <https://doi.org/10.1109/JSEN.2024.3362377>.
- Sefrin, O., Riese, F.M. & Keller, S., 2020, **Deep Learning for Land Cover Change Detection**, Remote Sensing, 13(1), P. 78. <https://doi.org/10.3390/rs13010078>.
- Shafique, A., Cao, G., Khan, Z., Asad, M. & Aslam, M., 2022, **Deep Learning-Based Change Detection in Remote Sensing Images: A Review**, Remote Sensing, 14(4), P. 871. <https://doi.org/10.3390/rs14040871>.
- Shen, Q., Huang, J., Wang, M., Tao, S., Yang, R. & Zhang, X., 2022, **Semantic Feature-Constrained Multitask Siamese Network for Building Change Detection in High-Spatial-Resolution Remote Sensing Imagery**, ISPRS Journal of Photogrammetry and Remote Sensing, 189, PP. 78–94. <https://doi.org/10.1016/j.isprsjprs.2022.05.001>.
- Shi, W., Zhang, M., Zhang, R., Chen, S. & Zhan, Z., 2020, **Change Detection Based on Artificial Intelligence: State-of-the-Art and Challenges**, Remote Sensing, 12(10), P. 1688. <https://doi.org/10.3390/rs12101688>.
- Shi, Q., Liu, M., Li, S., Liu, X., Wang, F. & Zhang, L., 2021, **A Deeply Supervised Attention Metric-Based Network and an Open Aerial Image Dataset for Remote Sensing Change Detection**, IEEE Transactions on Geoscience and Remote Sensing, 60, PP. 1–16. <https://doi.org/10.1109/TGRS.2021.3085870>.
- Temenos, A., Temenos, N., Tzortzis, I.N., Rallis, I., Doulamis, A. & Doulamis, N., 2024, **C2A-DC: A Context-Aware Adaptive Data Cube Framework for Environmental Monitoring and Climate Change Crisis Management**, Remote Sensing Applications: Society and Environment, 34, P. 101171. <https://doi.org/10.1016/j.rsase.2024.101171>.
- Toth, C. & Józków, G., 2016, **Remote Sensing Platforms and Sensors: A Survey**, ISPRS Journal of Photogrammetry and Remote Sensing, 115, PP. 22–36. <https://doi.org/10.1016/j.isprsjprs.2015.10.004>.
- Vance, T.C., Huang, T. & Butler, K.A., 2024, **Big Data in Earth Science: Emerging Practice and Promise**, Science, 383(6688), P. eadh9607. <https://doi.org/10.1126/science.adh9607>.
- Viana, C.M., Oliveira, S., Oliveira, S.C. & Rocha, J., 2019, **Land Use/Land Cover Change Detection and Urban Sprawl Analysis**, In: Spatial Modeling in GIS and R for Earth and Environmental Sciences, [Place Unknown], Elsevier, PP. 621–651. <https://doi.org/10.1016/B978-0-12-815226-3.00029-6>.
- Wang, R. & Gamon, J.A., 2019, **Remote Sensing of Terrestrial Plant Biodiversity**, Remote Sensing of Environment, 231, P. 111218. <https://doi.org/10.1016/j.rse.2019.111218>.
- Wang, Z., Peng, C., Zhang, Y., Wang, N. & Luo, L., 2021, **Fully Convolutional Siamese Networks Based Change Detection for Optical Aerial Images with Focal Contrastive Loss**, Neurocomputing, 457, PP. 155–167. <https://doi.org/10.1016/j.neucom.2021.06.059>.
- Wang, S., Han, W., Huang, X., Zhang, X., Wang, L. & Li, J., 2024, **Trustworthy Remote Sensing Interpretation: Concepts, Technologies, and Applications**, ISPRS Journal of Photogrammetry and Remote Sensing, 209, PP. 150–172. <https://doi.org/10.1016/j.isprsjprs.2024.02.003>.
- Wu, Y., Li, J., Yuan, Y., Qin, A., Miao, Q.-G. & Gong, M.-G., 2021, **Commonality Autoencoder: Learning Common Features for Change Detection from Heterogeneous Images**, IEEE Transactions on Neural Networks and Learning Systems, 33(9), PP. 4257–4270. <https://doi.org/10.1109/TNNLS.2021.3056238>.

- Yang, J., Gong, P., Fu, R., Zhang, M., Chen, J., Liang, S., Xu, B., Shi, J. & Dickinson, R., 2013, **The Role of Satellite Remote Sensing in Climate Change Studies**, *Nature Climate Change*, 3(10), PP. 875–883. <https://doi.org/10.1038/nclimate1908>.
- Yang, L., Chen, Y., Song, S., Li, F. & Huang, G., 2021, **Deep Siamese Networks Based Change Detection with Remote Sensing Images**, *Remote Sensing*, 13(17), P. 3394. <https://doi.org/10.3390/rs13173394>.
- Yusufovich, G.Y. & Yokubov, Sh.Sh.o., 2023, **The Use of Remote Sensing Technologies in the Design of Maps of Agricultural Land**, *Texas Journal of Agriculture and Biological Sciences*, 23, PP. 17–21.
- Zhan, Y., Fu, K., Yan, M., Sun, X., Wang, H. & Qiu, X., 2017, **Change Detection Based on Deep Siamese Convolutional Network for Optical Aerial Images**, *IEEE Geoscience and Remote Sensing Letters*, 14(10), PP. 1845–1849. <https://doi.org/10.1109/LGRS.2017.2738149>.
- Zhang, J., Huang, Y., Pu, R., Gonzalez-Moreno, P., Yuan, L., Wu, K. & Huang, W., 2019, **Monitoring Plant Diseases and Pests through Remote Sensing Technology: A Review**, *Computers and Electronics in Agriculture*, 165, P. 104943. <https://doi.org/10.1016/j.compag.2019.104943>.
- Zhang, H., Lin, M., Yang, G. & Zhang, L., 2021, **ESNet: An End-to-End Superpixel-Enhanced Change Detection Network for Very-High-Resolution Remote Sensing Images**, *IEEE Transactions on Neural Networks and Learning Systems*. <https://doi.org/10.1109/TNNLS.2021.3089332>.
- Zhang, M., Liu, Z., Feng, J., Liu, L. & Jiao, L., 2023, **Remote Sensing Image Change Detection Based on Deep Multi-Scale Multi-Attention Siamese Transformer Network**, *Remote Sensing*, 15(3), P. 842. <https://doi.org/10.3390/rs15030842>.
- Zheng, Z., Wan, Y., Zhang, Y., Xiang, S., Peng, D. & Zhang, B., 2021, **CLNet: Cross-Layer Convolutional Neural Network for Change Detection in Optical Remote Sensing Imagery**, *ISPRS Journal of Photogrammetry and Remote Sensing*, 175, PP. 247–267. <https://doi.org/10.1016/j.isprsjprs.2021.03.005>.
- Zhu, Q., Guo, X., Deng, W., Shi, S., Guan, Q., Zhong, Y., Zhang, L. & Li, D., 2022, **Land-Use/Land-Cover Change Detection Based on a Siamese Global Learning Framework for High Spatial Resolution Remote Sensing Imagery**, *ISPRS Journal of Photogrammetry and Remote Sensing*, 184, PP. 63–78. <https://doi.org/10.1016/j.isprsjprs.2021.12.005>.
- Zhu, S., Song, Y., Zhang, Y. & Zhang, Y., 2023, **ECFNet: A Siamese Network with Fewer FPs and Fewer FNs for Change Detection of Remote-Sensing Images**, *IEEE Geoscience and Remote Sensing Letters*, 20, PP. 1–5. <https://doi.org/10.1109/LGRS.2023.3238553>.
- Zhu, Q., Guo, X., Li, Z. & Li, D., 2024, **A Review of Multi-Class Change Detection for Satellite Remote Sensing Imagery**, *Geospatial Information Science*, 27(1), PP. 1–15. <https://doi.org/10.1080/10095020.2022.2128902>.

This Page is Intentionally Left Blank