



REVIEW PAPER

A Systematic Review of Machine Learning Methods for Change Detection in Radar and Optical Images with a Focus on Deep Learning

M.R. Zargar¹, A. Aghabalaee^{*,2}, S. Khazai³, A. Mohtadi⁴¹ Department of Photogrammetry and Remote Sensing, School of Surveying and Geospatial Engineering, University of Tehran, Tehran, Iran² Department of Surveying and Spatial Data, Faculty of Civil Engineering, Water and Energy, Imam Hossein Comprehensive University, Tehran, Iran³ Department of Signature engineering, Faculty of Passive Defense, Imam Hossein Comprehensive University, Tehran, Iran⁴ Department of Surveying Engineering, Faculty of Technology and Engineering, Hekmat Higher Educational Institute, Qom, Iran

ABSTRACT

Received: 29 April 2025
 Reviewed: 05 June 2025
 Revised: 22 July 2025
 Accepted: 05 September 2025

KEYWORDS:

Change Detection
 Remote Sensing
 Radar Image
 Deep Learning

* Corresponding author

✉ remotesensing@ihu.ac.ir

☎ (+9821) 77105385

Background and Objectives: With the expansion of radar remote sensing data and increased access to high-resolution imagery through sensors such as Sentinel-1, change detection using deep learning has emerged as a strategic and innovative field in geospatial sciences. Radar imagery, with its capabilities for day-and-night imaging, cloud penetration, and sensitivity to structural characteristics of the Earth's surface, provides rich but complex data requiring advanced machine learning architectures for effective analysis. Accordingly, this study aims to systematically review deep learning-based methods for change detection in radar images, with a focus on comparative analysis of architectures, their strengths and limitations, and future research directions.

Methods: This systematic review covers literature published between 2014 and 2025 and includes 44 selected studies from reputable databases such as IEEE, Elsevier, and MDPI. Inclusion criteria involved the use of SAR data, application of deep learning algorithms, availability of quantitative performance metrics (e.g., accuracy and F1-score), and operational relevance in domains such as urban monitoring, natural resource assessment, and disaster management. The studies were classified based on the type of learning approach (supervised, unsupervised, self-supervised, multi-source) and architecture used (MLP, CNN, U-Net, Autoencoder, LSTM, GAN, MSCDUNet), and were analyzed using comparative tables.

Findings: The results indicate that supervised architectures such as U-Net performed best in urban and disaster-related applications, achieving up to 95% accuracy and F1-scores between 0.85 and 0.93. In unsupervised approaches, combining CNN with fuzzy clustering (FCM) reached accuracy levels up to 99.6%. Autoencoder-based models were successful in denoising and feature compression, while GAN architectures improved network performance through data augmentation. Multi-source models like MSCDUNet, integrating radar and optical data, reported F1-scores of up to 0.93. However, challenges persist, including inconsistent reporting of standard metrics such as F1, limited generalizability of models, and the computational complexity of processing heterogeneous datasets.

Conclusion: Despite significant advancements in the use of deep learning for change detection, ongoing challenges include the scarcity of labeled data, lack of publicly available benchmark multi-source datasets, and the limited availability of lightweight algorithms for real-time applications. Future research should prioritize self-supervised methods such as contrastive learning, the development of noise-resistant and lightweight architectures for UAV and edge deployments, and the creation of standardized open-access datasets with comprehensive metrics. This study, by offering a structured classification and comparative evaluation of algorithms, aims to inform intelligent decision-making in the design of change detection systems for researchers and developers alike.



NUMBER OF REFERENCES

44



NUMBER OF FIGURES

10



NUMBER OF TABLES

3

مقاله مروری

مروری نظام‌مند بر روش‌های یادگیری ماشین در شناسایی تغییرات تصاویر راداری و اپتیکی با تمرکز بر یادگیری عمیق

محمد رضا زرگر^۱، امیر آقابالائی^{۲*}، صفا خزائی^۳، علی مهتدی^۴^۱ گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشگاه تهران، تهران، ایران^۲ گروه نقشه برداری و داده های مکانی، دانشکده عمران، آب و انرژی، دانشگاه جامع امام حسین (ع)، تهران، ایران^۳ گروه مهندسی اثر، دانشکده پدافند غیرعامل، دانشگاه جامع امام حسین (ع)، تهران، ایران^۴ گروه نقشه برداری، دانشکده فنی و مهندسی، موسسه آموزش عالی حکمت، قم، ایران

چکیده

پیشینه و اهداف: با گسترش داده‌های سنجش از دور راداری و افزایش دسترسی به تصاویر باکیفیت از طریق سنجنده‌هایی مانند سنتینل-۱، تحلیل تغییرات در سطح زمین از طریق یادگیری عمیق به یکی از حوزه‌های راهبردی و نوظهور در علوم مکانی تبدیل شده است. تصاویر راداری با قابلیت تصویربرداری شبانه‌روزی، نفوذ در ابر، و حساسیت به ویژگی‌های ساختاری زمین، اطلاعات غنی اما پیچیده‌ای فراهم می‌کنند که تحلیل آن‌ها نیازمند بهره‌گیری از معماری‌های هوشمند یادگیری ماشین است. در این راستا، مقاله حاضر با هدف مرور نظام‌مند روش‌های مبتنی بر یادگیری عمیق در شناسایی تغییرات در تصاویر راداری، با تمرکز بر تحلیل تطبیقی معماری‌ها، نقاط قوت و ضعف آن‌ها و چشم‌اندازهای آینده طراحی شده است.

روش‌ها: این مرور بر اساس رویکرد مرور نظام‌مند در بازه زمانی ۲۰۱۴ تا ۲۰۲۵، شامل ۴۴ مقاله منتخب از پایگاه‌های معتبر مانند IEEE، Elsevier، MDPI و Elsevier است. معیارهای انتخاب شامل استفاده از داده‌های SAR، بهره‌گیری از الگوریتم‌های یادگیری عمیق، گزارش معیارهای کمی مانند دقت و F1-score و کاربردهای عملیاتی در حوزه‌هایی چون پایش شهری، منابع طبیعی و بلایای طبیعی بوده است. مقالات بر اساس نوع یادگیری (نظارتی، بدون نظارت، خودنظارتی، چندمنبعی) و نوع معماری (CNN، MLP، U-Net، Autoencoder، LSTM، GAN و MSCDUNet) طبقه‌بندی شده‌اند و در قالب جداول مقایسه‌ای تحلیل شده‌اند.

یافته‌ها: نتایج نشان می‌دهد معماری‌های نظارت‌شده نظیر U-Net با دقت تا ۹۵٪ و F1 در بازه ۰/۸۵ تا ۰/۹۳، به‌ویژه در کاربردهای شهری و ارزیابی خسارات بلایای طبیعی، بهترین عملکرد را داشته‌اند. در حوزه بدون نظارت، ترکیب CNN با خوشه‌بندی فازی (FCM) به دقتی تا ۹۹/۶٪ دست یافته است. مدل‌های مبتنی بر Autoencoder در کاهش نویز و فشرده‌سازی اطلاعات موفق عمل کرده‌اند و معماری‌های GAN با داده‌افزایی، عملکرد شبکه‌ها را بهبود بخشیده‌اند. مدل‌های چندمنبعی مانند MSCDUNet که داده‌های راداری و نوری را تلفیق می‌کنند، F1 معادل ۰/۹۳ را گزارش کرده‌اند. با این حال، کمبود گزارش‌های کمی استاندارد مانند F1، ضعف تعمیم‌پذیری مدل‌ها، و پیچیدگی پردازش داده‌های ناهمگن، از چالش‌های موجود محسوب می‌شود.

نتیجه‌گیری: با وجود پیشرفت‌های چشمگیر در کاربرد یادگیری عمیق در شناسایی تغییرات، چالش‌هایی مانند کمبود داده‌های برچسب‌خورده، عدم دسترسی به مجموعه داده‌های مرجع چندمنبعی، و ضعف الگوریتم‌های سبک برای کاربردهای بلادرنگ همچنان پابرجاست. توسعه الگوریتم‌های خودنظارتی مانند یادگیری تضادمحور، طراحی معماری‌های مقاوم به نویز و سبک برای UAVها و سامانه‌های لبه‌ای، و تدوین پایگاه‌های داده باز و معیارمحور از جمله اولویت‌های آتی این حوزه است. مطالعه حاضر با ارائه طبقه‌بندی ساختاریافته و تحلیل تطبیقی عملکرد الگوریتم‌ها، تلاش دارد زمینه تصمیم‌سازی هوشمند در طراحی سامانه‌های تحلیل تغییرات را برای پژوهشگران و توسعه‌دهندگان مهیا سازد.

تاریخ دریافت: ۰۹ اردیبهشت ۱۴۰۴
تاریخ داوری: ۱۵ خرداد ۱۴۰۴
تاریخ اصلاح: ۳۱ تیر ۱۴۰۴
تاریخ پذیرش: ۱۴ شهریور ۱۴۰۴

واژگان کلیدی:

شناسایی تغییرات
سنجش از دور
تصویر راداری
یادگیری عمیق

* نویسنده مسئول

remotesensing@ihu.ac.ir

۰۲۱-۷۷۱۰۵۳۸۵

مقدمه

مطالعه حاضر با هدف ارائه یک مرور نظام‌مند و ساختاریافته از روش‌های یادگیری ماشین با تأکید بر یادگیری عمیق در شناسایی تغییرات تصاویر راداری و اپتیکی، می‌کوشد با بررسی مطالعات انجام‌شده در بازه زمانی ۲۰۱۴ تا ۲۰۲۵، تصویری جامع از وضعیت موجود، شکاف‌های علمی و مسیرهای آینده این حوزه ترسیم نماید.

تحلیل/انتقادی پیشینه و خلأهای پژوهشی

مرور ادبیات انجام‌شده در زمینه شناسایی تغییرات در تصاویر سنجش از دور راداری با بهره‌گیری از یادگیری عمیق نشان می‌دهد که اگرچه در سال‌های اخیر مطالعات متعددی در این حوزه منتشر شده‌اند، اما اغلب آن‌ها با کاستی‌های مفهومی و ساختاری مواجه‌اند که ضرورت یک بازنگری جامع و تحلیلی را برجسته می‌سازد. تحلیل انتقادی این متون، چهار محور اصلی از خلأهای پژوهشی را آشکار می‌سازد:

نخست، اغلب مرورهای پیشین فاقد دسته‌بندی دقیق، منسجم و سلسله‌مراتبی از معماری‌های یادگیری عمیق هستند. در حالی که در حوزه‌هایی مانند بینایی ماشین یا پردازش زبان طبیعی، الگوریتم‌ها بر اساس ساختارهای استاندارد مانند CNN، RNN، Transformer و غیره طبقه‌بندی می‌شوند، بسیاری از مرورهای حوزه سنجش از دور راداری صرفاً به تمایز ساده میان روش‌های «نظارتی» و «بدون نظارت» بسنده کرده‌اند، بی‌آن‌که تحلیلی عمیق از انواع معماری‌های عصبی مانند U-Net، Autoencoder، GAN، یا شبکه‌های ترکیبی ارائه شود. پژوهش حاضر با طراحی یک چارچوب طبقه‌بندی چندمحوری، تلاش کرده است این کمبود را جبران کرده و تصویری نظام‌مند از معماری‌ها و کاربردهای آن‌ها ارائه دهد.

دوم، ضعف در ارائه تحلیل کمی و مقایسه‌پذیر عملکرد الگوریتم‌ها یکی دیگر از چالش‌های جدی مرورهای گذشته است. در حالی که ارزیابی کمی با شاخص‌هایی مانند دقت، F1-score و حساسیت، پایه‌ای برای قضاوت علمی در مورد اثربخشی مدل‌هاست، بسیاری از مطالعات صرفاً به بیان کیفی مزایا و معایب روش‌ها اکتفا کرده‌اند. حتی در مواردی که تحلیل عددی انجام شده، عدم یکسانی در نوع داده‌ها، سناریوهای آزمایشی، و شاخص‌های ارزیابی، امکان استنتاج تطبیقی را محدود ساخته است. مقاله حاضر با استخراج و تجمیع داده‌های کمی از مطالعات معتبر و ارائه آن‌ها در قالب جداول مقایسه‌ای، گامی در جهت استانداردسازی تحلیل‌ها برداشته است. با این حال، همچنان خلأ اجرای آزمایشات میدانی بر روی یک مجموعه‌داده مرجع باقی است که پژوهش‌های آینده باید به آن بپردازند.

سوم، بررسی‌ها نشان می‌دهد که بسیاری از معماری‌های نوظهور یادگیری عمیق، به‌ویژه مدل‌هایی مانند شبکه‌های مولد تخصصی (GAN)، خودرمزگذارها، شبکه‌های سیامی، و تبدیل‌گرهای مکانی-زمانی (Spatio-Temporal Transformers)، یا در مرورهای پیشین غایب بوده‌اند یا صرفاً به‌صورت سطحی معرفی شده‌اند. با توجه به اثرگذاری بالای این معماری‌ها از سال ۲۰۲۰ به بعد، در حل چالش‌هایی چون نویز، داده‌های ناقص یا برچسب‌نخورده، و تلفیق اطلاعات چندمنبعی،

شناسایی تغییرات یکی از بنیادی‌ترین وظایف در حوزه سنجش از دور به‌شمار می‌رود که نقشی اساسی در پایش پویایی‌های زمین، درک روندهای توسعه پدیده‌های طبیعی و انسانی، و تحلیل تعاملات میان آن‌ها ایفا می‌کند. این فرآیند، ناظر به استخراج تفاوت‌های ساختاری یا طیفی میان دو یا چند تصویر ثبت‌شده از یک منطقه در زمان‌های مختلف است که معمولاً به شناسایی پیکسل‌های دارای تغییرات معنادار ختم می‌شود [۱]. با وجود پیشینه طولانی این مسئله، چالش‌هایی نظیر تغییر شرایط نوری، تفاوت در زاویه برداشت، تنوع فصلی، و وجود نویز در تصاویر، همچنان بر دقت فرایند شناسایی تغییرات تأثیرگذارند [۲].

در دهه‌های اخیر، گسترش فناوری‌های سنجش از دور، موجب افزایش کم‌سابقه در دسترسی به داده‌های ماهواره‌ای شده است. در این میان، سنجنده‌های فعال راداری به‌دلیل قابلیت تصویربرداری در شرایط نامساعد جوی، نفوذ در پوشش ابری، دریافت اطلاعات در شب و روز، و حساسیت به ویژگی‌های ساختاری سطح زمین، به ابزارهایی کارآمد برای پایش تغییرات بدل شده‌اند. با این حال، وجود نویزهای لکه‌ای (Speckle) همچنان از موانع جدی در تحلیل دقیق تصاویر راداری به‌شمار می‌رود [۳].

هم‌زمان با پیشرفت الگوریتم‌های یادگیری ماشین، استفاده از روش‌های هوشمند در تحلیل داده‌های سنجش از دور، به‌ویژه در شناسایی تغییرات، گسترش یافته است. ترکیب قدرت استنتاجی یادگیری ماشین با داده‌های غنی سنجش از دور، امکان تحلیل خودکار و مقیاس‌پذیر پدیده‌ها را فراهم کرده و افق‌های تازه‌ای در حوزه‌هایی چون کشاورزی، منابع طبیعی، مدیریت بحران، مطالعات اقلیمی، و برنامه‌ریزی شهری گشوده است. هدف اصلی از به‌کارگیری یادگیری ماشین در این زمینه، افزایش دقت، کاهش وابستگی به داده‌های برچسب‌خورده و ارتقاء توان تفسیرپذیری مدل‌ها در شرایط داده‌ای متنوع و پرنویز است.

تا پیش از سال ۲۰۱۴، داده‌های راداری به میزان کافی برای توسعه مدل‌های مبتنی بر یادگیری عمیق در دسترس نبودند. اما با ظهور سنسورهای جدید و رشد پایگاه‌های داده باز، زمینه برای بهره‌گیری از یادگیری عمیق در شناسایی تغییرات راداری فراهم شد. در میان معماری‌های یادگیری عمیق، شبکه‌های عصبی پیچشی (CNN) و ساختارهای رمزگذار-رمزگشا (مانند U-Net)، نقش محوری در تحلیل خودکار تغییرات ایفا کرده‌اند. این معماری‌ها به‌سبب قابلیت یادگیری ویژگی‌های مکانی و طیفی، در تشخیص دقیق تغییرات ساختاری در داده‌های راداری و اپتیکی کارآمد ظاهر شده‌اند. همچنین، شبکه‌های بازگشتی، خودرمزگذارها، مدل‌های مبتنی بر توجه و شبکه‌های مولد، افق‌های جدیدی برای توسعه مدل‌های هوشمند در این حوزه گشوده‌اند.

با این حال، مرورهای پیشین عمدتاً با محدود به داده‌های اپتیکی بوده‌اند، یا تمرکز خود را بر روش‌های سنتی و یادگیری ماشین کلاسیک قرار داده‌اند. همچنین، بسیاری از مطالعات فاقد ساختار تحلیلی و مقایسه‌پذیر در ارائه مزایا و محدودیت‌های معماری‌ها بوده‌اند. از این‌رو،

پوشش این طیف از الگوریتم‌ها در این مقاله، تلاشی برای پر کردن یکی از خلأهای جدی ادبیات موجود به شمار می‌آید.

چهارم، موضوع تلفیق داده‌های چندمنبعی، به‌ویژه ادغام تصاویر راداری و اپتیکی، که در بسیاری از مطالعات تجربی به‌عنوان راهکاری برای افزایش دقت و پایداری شناسایی تغییرات مطرح شده، در اغلب مرورهای پیشین جایگاهی شایسته نیافته است. مقاله حاضر با بررسی معماری‌هایی نظیر MSCDUNet و تحلیل توانمندی‌های آن‌ها در همگام‌سازی طیفی، مکانی و زمانی داده‌ها، سهم مهمی در تبیین مزایا، چالش‌ها و مسیرهای نوین این حوزه ارائه کرده است.

در مجموع، مرورهای پیشین در حوزه شناسایی تغییرات راداری با چالش‌هایی نظیر طبقه‌بندی ضعیف، تحلیل عددی ناکافی، پوشش محدود الگوریتم‌های نوین، و غفلت از رویکردهای چندمنبعی مواجه‌اند. پژوهش حاضر با هدف رفع این کاستی‌ها و طراحی چارچوبی جامع برای تحلیل تطبیقی روش‌های یادگیری عمیق، گامی مؤثر در جهت ارتقاء دانش موجود و تدوین نقشه‌راهی برای پژوهشگران و توسعه‌دهندگان در این حوزه برداشته است. با این حال، تکمیل این چارچوب با ارائه الگوهای پیشنهادی و تحلیل تجربی بر روی داده‌های عملیاتی، از جمله توصیه‌های کلیدی برای مطالعات آتی به‌شمار می‌رود. برای جمع‌بندی خلأهای پژوهشی شناسایی‌شده در مرورهای پیشین و اقدامات اصلاحی انجام‌شده در مطالعه حاضر، جدول ۱ ارائه شده است که به‌صورت تطبیقی این تفاوت‌ها را نشان می‌دهد.

روش تحقیق

این مرور با هدف بررسی جامع روش‌های شناسایی تغییرات در تصاویر سنجش از دور راداری با استفاده از الگوریتم‌های یادگیری عمیق انجام شد.

- پایگاه داده و استراتژی جست‌وجو

برای جمع‌آوری منابع، جست‌وجویی سیستماتیک در پایگاه اطلاعاتی گوگل اسکولار، که مجموعه گسترده‌ای از مقالات علمی، کتاب‌ها، مجموعه مقالات کنفرانس و پایان‌نامه‌ها را پوشش می‌دهد، صورت گرفت. کلیدواژه‌های اصلی شامل Radar، SAR، Change Detection و Deep Learning بودند. برای اطمینان از جامعیت، ترکیب‌های مختلفی از این کلیدواژه‌ها مانند SAR Change Detection Deep Learning استفاده شد. بازه زمانی جست‌وجو از سال ۲۰۱۴ تا ۲۰۲۵ تعیین شد، زیرا روش‌های یادگیری عمیق در شناسایی تغییرات راداری از حدود سال ۲۰۱۴ به بعد به‌طور گسترده مورد توجه قرار گرفتند.

- معیارهای انتخاب و فرایند طبقه‌بندی

معیارهای انتخاب مقالات به‌گونه‌ای تنظیم شدند که تنها منابعی بررسی شوند که به‌طور خاص از الگوریتم‌های یادگیری عمیق برای شناسایی تغییرات در تصاویر راداری استفاده کرده باشند. مقالات ژورنال، مجموعه مقالات کنفرانس و پایان‌نامه‌های معتبر به زبان انگلیسی در اولویت قرار گرفتند. معیارهای خروج شامل مقالاتی بودند که صرفاً به روش‌های سنتی (غیر یادگیری عمیق) پرداخته یا بر تصاویر غیرراداری (مانند تصاویر نوری به‌تنهایی) تمرکز داشتند. همچنین، مقالاتی که فاقد تحلیل کافی یا داده‌های تجربی بودند، کنار گذاشته شدند. این فرآیند منجر به انتخاب مجموعه‌ای از مقالات شد که روش‌های نظارت‌شده، بدون نظارت و شبه‌نظارت‌شده را پوشش می‌دادند.

پس از جمع‌آوری مقالات، فرآیند تحلیل در سه مرحله انجام شد. ابتدا، مقالات بر اساس نوع روش یادگیری عمیق (نظارت‌شده یا بدون نظارت) دسته‌بندی شدند.

جدول ۱: شناسایی خلأهای کلیدی مرورهای موجود و راهکارهای پیشنهادی در این مطالعه

Table 1: Key Gaps Identified in Previous Reviews and Corresponding Solutions Addressed in This Study

محور ضعف مرورهای پیشین Axis of weakness of previous reviews	نمونه ضعف‌ها Examples of weaknesses	اقدام اصلاحی در مقاله حاضر Corrective action in this paper
فقدان طبقه‌بندی ساخت‌یافته معماری‌ها Lack of structured classification of architectures	دسته‌بندی‌های ساده به نظارتی/غیربرچسب‌دار؛ فقدان تحلیل تفصیلی ساختارهای CNN، U-Net، GAN و ... Simple classifications into supervised/unlabeled; lack of detailed analysis of CNN, U-Net, GAN, etc. structures	تدوین طبقه‌بندی سلسله‌مراتبی بر مبنای نوع یادگیری، معماری، هدف و کاربرد Develop a hierarchical classification based on learning type, architecture, purpose, and application
ضعف در تحلیل عددی و مقایسه‌پذیر عملکردها Weakness in numerical and comparable analysis of performances	نبود جداول عددی از دقت و F1؛ مقایسه در شرایط غیرهم‌تراز No numerical tables of accuracy and F1; comparison in non-aligned conditions	ارائه جدول عددی مقایسه‌ای با داده‌های کمی از ۴۴ مقاله معتبر و هم‌ترازسازی نسبی معیارها Provide a comparative numerical table with quantitative data from 44 authoritative papers and relative alignment of criteria
بی‌توجهی به روش‌های نوظهور پس از ۲۰۲۰ Ignoring emerging methods after 2020	حذف GAN، Autoencoder، شبکه سیامی، تبدیل‌کننده‌های مکانی و زمانی Eliminate GAN, Autoencoder, Siamese network, spatial and temporal transforms	پوشش معماری‌های نوین در بازه ۲۰۱۴ تا ۲۰۲۵ با تمرکز ویژه بر مطالعات پنج‌ساله اخیر Coverage of new architectures in the period 2014-2025 with special focus on recent five-year studies
غفلت از مدل‌های چندمنبعی (راداری - اپتیکی) Neglecting multi-source models (radar-optical)	تمرکز صرف بر یک منبع داده؛ نادیده گرفتن مزایای ادغام منابع ناهمگن Focus solely on one data source; ignore the benefits of heterogeneous sources fusion	تحلیل ساختار مدلی مانند MSCDUNet، تبیین ظرفیت تلفیق داده‌های چندمنبعی و چالش‌های آن Analyze the structure of models such as MSCDUNet, explain the capacity of multi-source data fusion and its challenges

اقدام اصلاحی در مقاله حاضر Corrective action in this paper	نمونه ضعف‌ها Examples of weaknesses	محور ضعف مرورهای پیشین Axis of weakness of previous reviews
پیشنهاد توسعه الگوریتم‌های خودنظارتی، مدل‌های سبک و استفاده از شبکه‌های کاهش‌دهنده نویز مانند DnCNN Propose the development of self-supervising algorithms, lightweight models, and the use of noise reduction networks such as DnCNN	نادیده‌گرفتن مشکل نویز، فقدان داده‌های برچسب‌دار، هزینه محاسباتی بالا Ignore the problem of noise, lack of labeled data, high computational cost	کم‌توجهی به چالش‌های داده‌ای و اجراپذیری Insufficient attention to data and feasibility challenges

معماری‌های یادگیری عمیق مورد استفاده مبنای طبقه‌بندی قرار گرفتند. این معماری‌ها شامل شبکه‌های پرسپترون چندلایه (MLP)، شبکه‌های عصبی پیچشی (CNN)، معماری U-Net و انواع مشتق‌شده از آن، شبکه‌های بازگشتی (RNN)، رمزگذارهای خودکار (Autoencoder)، شبکه‌های مولد متخاصم (GAN)، و ساختارهای ترکیبی هستند. در سطح سوم نیز، برای هر مطالعه، معیارهای تحلیلی همچون نوع داده ورودی تصاویر راداری تک‌زمانه یا چندزمانه، یا ترکیب داده‌های راداری و نوری، روش‌های پیش‌پردازش، و شاخص‌های ارزیابی عملکرد از جمله Overall Accuracy، F1-score، ضریب کاپا و زمان محاسباتی مورد توجه قرار گرفتند. این ساختار لایه‌ای، امکان تحلیل تطبیقی دقیق عملکرد معماری‌های مختلف را در زمینه‌های متنوع کاربردی همچون پایش شهری، رصد تغییرات زیست‌محیطی، شناسایی تغییرات در مناطق جنگلی یا در شرایط وقوع بلایای طبیعی فراهم می‌سازد.

در راستای تدوین این چارچوب، روش‌های یادگیری عمیق مورد استفاده در حوزه آشکارسازی تغییرات در تصاویر راداری به سه دسته اصلی تقسیم شدند: (۱) روش‌های نظارت‌شده، که مبتنی بر استفاده از داده‌های برچسب‌خورده هستند و شامل معماری‌هایی مانند MLP، CNN، U-Net و RNN می‌شوند؛ (۲) روش‌های بدون نظارت، که با هدف کاهش وابستگی به داده‌های دستی برچسب‌دار، از ترکیب تکنیک‌هایی نظیر خوشه‌بندی فازی (FCM)، رمزگذارهای خودکار (Autoencoder)، شبکه‌های مولد (GAN)، و ساختارهای End-to-End بهره می‌برند مانند Autoencoder+FCM، GAN+FCM و CWNN+FCM و (۳) یک دسته مستقل و پیشرفته که به معماری چندمقیاسی اختصاصی MSCDUNet تعلق دارد. این مدل با طراحی دوگانه، ساختار رمزگذاری چندسطحی، و توانایی استخراج ویژگی‌های هم‌زمان محلی و جهانی، عملکرد بسیار دقیقی در آشکارسازی تغییرات راداری از خود نشان داده است و به دلیل تفاوت بنیادی در ساختار و دقت، به‌صورت جداگانه در تحلیل‌ها مدنظر قرار گرفته است.


سپس، برای هر دسته، معماری‌های پرکاربرد (مانند U-Net، شبکه عصبی پیچشی و FCM)، نقاط قوت (مانند دقت بالا یا انعطاف‌پذیری)، و ضعف‌ها (مانند نیاز به داده‌های برچسب‌دار یا حساسیت به نویز) شناسایی شدند. در نهایت، چالش‌های مشترک، مانند کمبود داده‌های آموزشی و نویز لکه‌ای، و راهکارهای پیشنهادی در مقالات (مانند استفاده از شبکه مولد متخاصمی یا روش‌های شبه‌نظارت‌شده) بررسی شدند. این تحلیل ساختار یافته امکان مقایسه روش‌ها و استخراج یافته‌های کلیدی را فراهم کرد.

- روند زمانی انتشار مقالات


شکل ۱ روند تعداد مقالات منتشرشده در حوزه شناسایی تغییرات راداری طی دهه گذشته یعنی سال ۲۰۱۴ تا ۲۰۲۴ را نشان می‌دهد. افزایش قابل‌توجه مقالات از سال ۲۰۱۶ به بعد، هم‌زمان با پیشرفت‌های یادگیری عمیق و دسترسی گسترده‌تر به داده‌های راداری از ماهواره‌هایی مانند سنتینل-۱ حاکی از رشد توجه علمی به این حوزه است. این روند نشان‌دهنده پتانسیل بالای یادگیری عمیق در رفع چالش‌های سنتی شناسایی تغییرات، مانند نویز لکه‌ای و ناهمگنی داده‌ها، و همچنین افزایش علاقه به کاربردهای عملی مانند پایش بلایای طبیعی و تغییرات شهری است.

- ساختار دسته‌بندی

در این مطالعه، به‌منظور حفظ انسجام ساختاری و فراهم‌سازی امکان مقایسه دقیق عملکرد روش‌های گوناگون آشکارسازی تغییرات، مقالات منتخب بر اساس یک چارچوب مفهومی چندسطحی دسته‌بندی شده‌اند. در سطح نخست، مبنای دسته‌بندی بر نوع یادگیری به‌کاررفته در هر مطالعه استوار است و به سه گروه اصلی «یادگیری نظارت‌شده (Supervised)» و «بدون نظارت و خودنظارتی (Unsupervised)» و چندمنبعی تقسیم شده‌اند. در سطح دوم، درون هر یک از این دو دسته،



شکل ۱: نمودار تعداد مقالات شناسایی تغییرات در تصاویر راداری برگرفته از جست‌وجو در پایگاه اطلاعاتی اسکولار
Fig. 1: Chart of number of change detection articles in radar images obtained from the search in the Scholar database



شکل ۲: ساختار دسته‌بندی روش‌های یادگیری عمیق در شناسایی تغییرات تصاویر راداری
Fig. 2: Classification structure of deep learning methods for change detection in radar imagery

این قطعه‌ها یا به اصطلاح اشیاء، ویژگی‌های مختلف را استخراج می‌کنند. در نهایت با استخراج شدن هفت ویژگی داده‌ها وارد شبکه‌ی عصبی آموزش دیده می‌شوند. تی‌اگو و همکارانش توانستند بر روی داده‌های تست خود کاپای ۶۶ درصد را کسب و نسبت به دیگر طبقه‌بندها مانند طبقه‌بند بیزی، KNN و J48 نتایج بهتری بدست آورند.

در همان سال، لیو و همکارانش [۸] نیز به منظور پایش توسعه شهری از شبکه‌های عصبی پرسپترون چند لایه برای شناسایی تغییرات استفاده کردند. با این تفاوت که شبکه می‌تواند با تعداد داده آموزشی کمی فرایند یادگیری را طی کند. آن‌ها ابتدا با توجه به دو تصویر راداری خود که در زمان‌های مختلف از یک منطقه اخذ شده بود، با روش تفاوت لگاریتمی، تصویر تفاوت را محاسبه و سپس انتظار داشتند شبکه‌ی عصبی آن‌ها از این تصویر به پیکسل‌های تغییر یافته و تغییر نیافته دست یابد. شبکه‌ی عصبی طراحی شده توسط آن‌ها در واقع سلسله از ماشین‌های بولتزمن محدود بودند که پیکسل‌های تصویر تفاوت را به عنوان ورودی در نظر می‌گرفتند. این روش توانست به راحتی بر دیگر روش‌های سنتی موجود غالب شود.

تحلیل عملکرد فنی

در این پژوهش، به‌منظور آشکارسازی تغییرات در تصاویر سنجش از دور، از یک شبکه عصبی مصنوعی (Artificial Neural Network) بهره گرفته شده است که ورودی آن بر پایه تصویر تفاضلی بین دو تاریخ تصویربرداری طراحی شده است (شکل ۳). فرآیند کار به این صورت است که برای هر پیکسل از تصویر تفاضلی، یک پنجره محلی با ابعاد ثابت (مانند 3×3 یا 5×5) تعریف می‌شود که شامل مقادیر خاکستری مربوط به ناحیه همسایگی آن پیکسل مرکزی است (شکل ۳ قسمت الف)، و سپس این داده به ساختار شبکه عصبی چندلایه با لایه‌های پنهان منتقل می‌شود (شکل ۳ قسمت ب). شبکه عصبی طراحی شده دارای یک لایه ورودی، چندین لایه پنهان (Hidden Layers) و یک لایه خروجی است. در لایه ورودی، هر نورون متناظر با یکی از پیکسل‌های پنجره ورودی است و مقدار آن برابر با شدت خاکستری (تفاوت طیفی) همان پیکسل در تصویر تفاضلی است. این مقادیر از طریق وزن‌های اتصال، به نورون‌های موجود در لایه‌های پنهان منتقل شده و با استفاده از توابع فعال‌سازی (نظیر سیگموئید یا ReLU) پردازش می‌شوند تا ویژگی‌های مکانی و طیفی استخراج گردند. در نهایت، لایه خروجی شامل یک نورون است که وظیفه آن دسته‌بندی پیکسل مرکزی پنجره

انواع معماری‌های یادگیری عمیق برای آشکارسازی تغییرات

با گسترش الگوریتم‌ها و معماری‌های یادگیری عمیق، حوزه‌ی شناسایی تغییرات در تصاویر سنجش از دور راداری نیز دستخوش تحولی اساسی شده است. مدل‌های سنتی مبتنی بر تحلیل پیکسلی، ویژگی‌های آماری یا آستانه‌گذاری، به تدریج جای خود را به مدل‌های یادگیرنده‌ی داده‌اند که توانایی استخراج الگوهای پیچیده و غیرخطی از داده‌های حجیم و متنوع را دارند.

در این بخش، بر اساس ساختار لایه‌ای ترسیم شده در بخش پیشین، انواع روش‌های مورد استفاده در ادبیات موضوع، در قالب دو رویکرد اصلی «نظارت شده»، «بدون نظارت و خودنظارتی» و «چندمنبعی» تحلیل می‌شوند. در هر رویکرد، معماری‌های پرکاربرد یادگیری عمیق، نحوه پردازش داده‌ها، مزایا، محدودیت‌ها و کاربردهای رایج به‌صورت دسته‌بندی شده و تطبیقی بررسی خواهد شد تا تصویری ساختاریافته از چشم‌انداز کنونی این حوزه ارائه گردد.

○ روش‌های نظارت شده

اگر چه بیشتر روش‌های موجود در این بخش قرار می‌گیرند. با این حال، اکثر محققین در این حوزه، به دلیل کمبود داده‌های آموزشی و مشکلاتی که در تهیه‌ی آن‌ها وجود دارد، تمایل بسیاری دارند تا با استفاده از روش‌های شبه نظارت شده [۵] و یا نظارت شده ضعیف [۶] نیاز روش مورد استفاده خود را به داده‌های آموزشی به حداقل ممکن برسانند.

شبکه‌ی عصبی پرسپترون چند لایه (MLP)

معرفی معماری و کاربرد اصلی

شبکه‌های عصبی پرسپترون چند لایه از اولین شبکه‌های توسعه یافته در زمینه یادگیری و شبکه‌های عصبی بودند و معمولاً نیاز به استخراج جداگانه ویژگی‌های مناسب در مراحل پیش‌پردازش هستند. لذا استفاده از این روش‌ها در سال‌های اولیه استفاده از روش‌های یادگیری عمیق در حوزه شناسایی تغییرات برمی‌گردد.

در سال ۲۰۱۶، تی‌اگو و همکارانش [۷] با هدف نظارت بر جنگل‌ها و شناسایی علائم جنگل‌زدایی که دروازه فعالیت‌های غیرقانونی مانند رشد بی‌رویه شهری و چرای مراتع است، از یک شبکه عصبی پرسپترون چند لایه استفاده کردند. در واقع آن‌ها ابتدا با استفاده از روش قطعه‌بندی ساده، خطی و تکراری (SLIC) تصاویر راداری خود را قطعه‌بندی و بر روی

با استفاده از MLP به سمت شبه نظارتی شدن حرکت کند. به این معنا که سعی شده است با استفاده از روش‌های گوناگون یا شبکه نیاز به داده کمتر داشته باشد و یا بر اساس داده‌های ورودی، داده‌های بیشتری برای یادگیری تشخیص داده شوند. برای مثال در شاناک و همکارانش [۹] یک روش نظارت شده ضعیف و نینگ و همکارانش [۱۰] یک روش شبه نظارت شده با استفاده از شبکه‌های عصبی پرسپترون چند لایه پیشنهاد دادند. تقریباً هر دوی آن‌ها از رمزگذارهای خودکار و روش‌های خوشه‌بندی فازی چون الگوریتم خوشه‌بندی C میانگین فازی (FCM) برای تقویت داده‌های خود استفاده کردند. در این پژوهش، به منظور آشکارسازی تغییرات در تصاویر سنجش از دور، از چارچوبی مبتنی بر یادگیری عمیق استفاده شده است که ساختار کلی آن در شکل ۴ نمایش داده شده است. در مرحله نخست، مجموعه‌ای از ویژگی‌های تصویری اولیه شامل تصویر لگاریتمی تفاوت، نسبت میانگین و نگاشت نویزی پواسون از تصاویر دو زمانه استخراج می‌شود تا اطلاعات طیفی و آماری اولیه پیرامون تغییرات تقویت شود. این ویژگی‌ها به صورت پنجره‌ای از تصویر به عنوان نمونه‌های آموزشی وارد مدل می‌شوند.


به یکی از دو کلاس «تغییر یافته» یا «تغییر نیافته» است. مقدار خروجی به صورت یک برچسب دودویی (۰ یا ۱) بازنمایی می‌شود و بیانگر وضعیت تغییر در پیکسل مرکزی می‌باشد. این شبکه با استفاده از داده‌های آموزش دارای برچسب (Labelled Samples) و با الگوریتم‌هایی نظیر پس‌انتشار خطا (Backpropagation) آموزش داده می‌شود تا بتواند الگوهای تغییر را به درستی یاد بگیرد و به سایر بخش‌های تصویر تعمیم دهد.

مزایا


این روش مبتنی بر یادگیری عمیق، با در نظر گرفتن اطلاعات بافتی- مکانی در کنار اطلاعات طیفی، نسبت به روش‌های کلاسیک آشکارسازی تغییرات از دقت بالاتری برخوردار بوده و توانایی بالایی در تفکیک تغییرات واقعی از نویزهای ناشی از شرایط متفاوت تصویربرداری دارد.

چالش‌ها و محدودیت‌ها

کمبود داده آموزشی کافی باعث شد دیگر روش‌های شناسایی تغییرات



شکل ۳: ساختار کلی روش پیشنهادی لیو و همکاران در به کارگیری ماشین‌های بولتزمن محدود [۸]
Fig. 3: The overall architecture of the method proposed by Liu et al. for employing Restricted Boltzmann Machines [8]



شکل ۴: نمای کلی از روش پیشنهادی شبه‌نظارتی ارائه‌شده توسط نینگ و همکاران برای آشکارسازی تغییرات [۱۰].

Fig. 4: Overall framework of the semi-supervised change detection method proposed by Ning et al [10].

پیش‌پردازش داده‌های راداری به کار رفت. در مطالعه‌ای دیگر، ونگ و همکارانش [۱۴] شبکه‌ای بر پایه PCA-Net [۱۵] طراحی کردند تا ویژگی‌های موثر را مستقیماً از تصاویر SAR استخراج و از آن‌ها برای تولید نقشه تفاوت استفاده کنند. همچنین، گائو و همکارانش [۱۶] با بهره‌گیری از معماری سیامی و مازول ادغام تطبیقی (AF) الگویی کارآمد برای آشکارسازی تغییرات ارائه دادند. با رشد سریع داده‌ها و نیاز به مقیاس‌پذیری، جین و همکارانش [۱۷] نیز معماری ترکیبی CNN با تحلیل معنایی را برای آشکارسازی تغییرات در مقیاس‌های بزرگ طراحی کردند.

تحلیل عملکرد فنی

ساختار FFDNet شامل تقسیم تصویر ورودی به زیرتصاویر کوچک‌تر است که همراه با نقشه شدت نویز به شبکه کانولوشنی چندلایه وارد می‌شوند. لایه‌های کانولوشن، توابع فعال‌سازی ReLU و نرمال‌سازی دسته‌ای، فرآیند کاهش نویز را به صورت محلی و دقیق انجام می‌دهند و سپس تصویر پاک‌سازی شده بازسازی می‌شود [۱۳] (شکل ۵).

در مطالعه [۱۴] مبتنی بر PCA-Net، هدف کاهش نویز لکه‌ای و استخراج ویژگی‌های عمیق بدون یادگیری وزن‌ها بود. اما استخراج همبستگی بین سطوح مختلف ویژگی‌ها با دشواری مواجه بود. برای رفع این چالش، گائو و همکاران [۱۶] معماری سیامی با سه سطح کانولوشن (پایین، میانی، بالا) و مازول ادغام تطبیقی طراحی کردند. در این ساختار، خروجی دو شاخه موازی به صورت بردارهای ویژگی سطح بالا (Fv1 و Fv2) استخراج و از طریق معیار شباهت L_2 به لایه Fully Connected ارسال شده و نقشه تغییر نهایی تولید می‌شود (شکل ۶).

در سال ۲۰۲۲، جین و همکاران [۱۷] با تلفیق تحلیل معنایی و شبکه‌های عصبی پیچشی، ساختاری برای کاهش بار محاسباتی در محیط‌های دارای داده حجیم ارائه دادند و با استفاده از محاسبات موازی، قابلیت استفاده از شبکه‌های عصبی پیچشی را در کاربردهای بلادرنگ تقویت کردند.

مزایا

مطالعات متعدد نشان داده‌اند که شبکه‌های عصبی پیچشی به‌ویژه در استخراج خودکار و چندلایه‌ای ویژگی‌های مکانی و طیفی از تصاویر راداری عملکردی بهتر از مدل‌های سنتی مانند MLP دارند [۱۶ و ۱۷]. ساختارهایی نظیر FFDNet در کاهش نویز و بهبود پیش‌پردازش [۱۲]، و ساختارهای سیامی در مقایسه دقیق پیکسل‌ها [۱۶]، اثربخشی بالایی در کاربردهای شهری و جنگلی نشان داده‌اند. همچنین قابلیت استفاده در محیط‌های داده‌سنگین و توانایی تطبیق با معماری‌های ترکیبی، از دیگر مزایای مهم آن‌هاست. در این رویکردها، مدل با استفاده از تعداد بسیار محدودی نمونه برچسب‌خورده و بهره‌گیری از اطلاعات پیشینی خود، قادر به یادگیری و تصمیم‌گیری در وظایفی مانند طبقه‌بندی یا آشکارسازی تغییرات است [۱۸].

مرحله بعدی شامل به کارگیری یک خودرمزگذار انقباضی پشته‌ای (Stacked Contractive Autoencoder) است که با معماری چندلایه خود، امکان استخراج نمایش‌های فشرده و غیربدیهی از داده‌ها را فراهم می‌سازد. این شبکه از طریق به حداقل رساندن حساسیت نسبت به اغتشاشات جزئی در ورودی و حفظ ساختار محلی داده‌ها، نمایش‌های مستحکمی از ویژگی‌های تغییر را استخراج می‌کند. خروجی این بخش، نمایش رمزگذاری‌شده‌ای از ویژگی‌هاست که در فضای ویژگی نیز قابلیت بصری‌سازی و تفکیک‌پذیری بالایی دارد.

در مرحله نهایی، با بهره‌گیری از الگوریتم خوشه‌بندی K-means بر روی بردارهای ویژگی رمزگذاری‌شده، نمونه‌ها به دو کلاس «تغییر یافته» و «تغییر نیافته» تفکیک می‌شوند و نقشه تغییرات نهایی حاصل می‌گردد.

مطالعات اخیر و نتیجه‌گیری


در یکی از گزارش‌های اخیر، امبابی و همکارانش [۱۱] در سال ۲۰۲۱ با ترکیب داده‌های نوری و راداری، از میان روش‌های مختلف موجود، شبکه‌های عصبی پرسپترون چندلایه را به کار گرفتند و به نتایج مطلوبی در زمینه آشکارسازی تغییرات دست یافتند. شبکه‌های عصبی پرسپترون چند لایه به دلیل ساختار ساده و قابلیت یادگیری روابط غیرخطی، در کاربردهای اولیه مانند پایش جنگل‌زدایی و توسعه شهری عملکرد مؤثری داشته‌اند و در مطالعه‌ی تیاگو و همکاران [۷] موفق به کسب ضریب کاپای ۶۶٪ شده‌اند.

این مدل‌ها به دلیل وابستگی به استخراج دستی ویژگی‌ها، امکان بهره‌گیری از ویژگی‌های طراحی‌شده توسط متخصص را فراهم می‌سازند؛ با این حال، نیاز به پیش‌پردازش مستقل و اتکا به داده‌های آموزشی باکیفیت، موجب کاهش کارایی آن‌ها شده است. در مقایسه با شبکه‌های پیچشی، معماری MLP هم دقت کمتری ارائه می‌دهد و هم زمان آموزش بالاتری دارد، به‌ویژه در مواجهه با داده‌های حجیم راداری [۸]. همین محدودیت‌ها سبب شده که در سال‌های اخیر، استفاده از شبکه عصبی پرسپترون چند لایه در حوزه آشکارسازی تغییرات کاهش یابد.

○ شبکه‌های عصبی پیچشی


جایگاه معماری و کاربرد اصلی

شبکه‌های عصبی پیچشی (Convolutional Neural Networks) و به اختصار CNN یکی از پرکاربردترین چارچوب‌های یادگیری عمیق در پردازش تصویر هستند که در حوزه‌ی سنجش از دور نیز جایگاهی ممتاز یافته‌اند. این شبکه‌ها، به دلیل توانایی در یادگیری ویژگی‌های مکانی - طیفی از طریق ساختارهای سلسله‌مراتبی، به‌طور گسترده در آشکارسازی تغییرات در تصاویر راداری SAR استفاده شده‌اند. برای مثال، هونگکه و همکارانش [۱۲] در سال ۲۰۲۱ با هدف کاهش نویز لکه‌ای (Speckle Noise) از معماری FFDNet [۱۳] استفاده کردند که در اصل برای حذف نویز طراحی شده بود و به صورت مؤثری به عنوان مرحله



شکل ۵: ساختار کلی شبکه FFDNet برای کاهش نویز تصویر [۱۳].

Fig. 5: Overall architecture of the FFDNet for image denoising [13]



شکل ۶: ساختار کلی روش پیشنهادی گائو و همکارانش در یک شبکه ادغام تطبیقی مبتنی بر معماری سیامی [۱۶]

Fig. 6: The general structure of the method proposed by Gao et. al. in an adaptive fusion network based on Siamese architecture [16]

به‌عنوان نمونه، آسکولد و همکارش [۲۰] در سال ۲۰۲۲، به‌منظور شناسایی تغییرات در گستره آب‌ها و رودخانه‌های کشور نروژ، دو شبکه طبقه‌بند پیچشی را مورد آزمایش قرار دادند: یکی معماری U-Net با ستون فقرات ResNet50 و دیگری DeepLabV3. هر دو مدل پیش‌تر با استفاده از مجموعه داده‌های استاندارد ImageNet و Cityscapes آموزش دیده بودند. نتایج نهایی حاکی از برتری معماری U-Net در این مسئله بود.

توسعه معماری با فناوری‌های نوین

هم‌زمان با پیشرفت‌های فناوریانه، شاهد ادغام نوآوری‌های جدید با معماری‌های موفق گذشته هستیم. به‌عنوان نمونه، در سال ۲۰۲۴، دو و همکارانش [۲۱] در ساختار پیشرفته U-Net++ از ماژول‌های مبتنی بر تبدیل‌کننده (Transformer) برای پردازش تصاویر راداری استفاده کردند. در این روش، ابتدا نقشه‌های ویژگی از تصاویر SAR تک‌زمانه با استفاده از شبکه‌های پیچشی استخراج شد و سپس وصله‌های تصویر (Image Patches) به‌صورت توکن (Tokenized) درآمده و توسط تبدیل‌کننده‌ها کدگذاری شدند تا اطلاعات زمینه‌ای در سطح سراسری مدل‌سازی شود. این طراحی منجر به ایجاد بازنمایی‌های غنی از ویژگی‌های متنی شد. در مرحله رمزگشایی، ویژگی‌های چندمقیاسی رمزگذاری‌شده مجدداً نمونه‌برداری شده و با اتصالات متوالی، یادگیری مؤثر ویژگی‌های معنایی محلی و سراسری ممکن گردید.

محدودیت‌ها و چالش‌ها

با این حال، استفاده از شبکه‌های عصبی پیچشی با چالش‌هایی نیز همراه است. از جمله آن‌ها نیاز بالا به داده‌های آموزشی برجسب‌خورده، پیچیدگی محاسباتی زیاد به‌ویژه در معماری‌های عمیق، زمان‌بر بودن فرآیند آموزش و استنتاج، و حساسیت به نویز لکه‌ای در صورت عدم انجام پیش‌پردازش مناسب [۳، ۱۲ و ۱۶]. این عوامل موجب شده‌اند استفاده مؤثر از شبکه‌های عصبی پیچشی در محیط‌های بلادرنگ یا منابع محدود نیازمند طراحی دقیق‌تر و بهینه‌سازی‌های چندجانبه باشد.

- معماری U-Net

جایگاه معماری و کاربرد اصلی

استفاده مکرر و قابل‌توجه از معماری U-Net در میان شبکه‌های عصبی پیچشی برای مسئله شناسایی تغییرات با استفاده از تصاویر راداری، نشان‌دهنده اهمیت این معماری در این حوزه است؛ به‌گونه‌ای که پرداختن جداگانه به این خانواده از شبکه‌ها ضرورتی منطقی می‌یابد. در این راستا، جاتوربیت و همکارانش [۱۹] در سال ۲۰۱۹ از یک ساختار ساده U-Net به‌منظور شناسایی تغییرات در ساختمان‌ها بهره گرفتند. هدف اصلی آن‌ها، طبقه‌بندی دقیق اشیاء دستخوش تغییر بود، به‌طوری‌که تغییرات ناشی از پدیده‌های فصلی به‌اشتباه در نظر گرفته نشوند. این رویکرد مبتنی بر طبقه‌بندی دقیق، در سال‌های بعد نیز مورد تأکید قرار گرفت و توسعه یافت.

مانند U-Net++، نیازمند حجم بالایی از داده‌های برچسب‌خورده و منابع محاسباتی قابل توجه برای آموزش است. همچنین، در صورت عدم تنوع کافی در داده‌های آموزشی، مدل دچار کاهش تعمیم‌پذیری نسبت به داده‌های جدید می‌شود [۱۹].

- شبکه‌های بازگشتی

جایگاه معماری و کاربرد اصلی

بر خلاف سایر حوزه‌های یادگیری عمیق، کاربرد شبکه‌های بازگشتی (Recurrent Neural Networks یا به اختصار RNN) در شناسایی تغییرات تصاویر راداری کمتر مورد توجه قرار گرفته است. با این حال، در مطالعه نیاگو و همکاران [۶] در سال ۲۰۱۹، از ساختاری مبتنی بر چندین لایه حافظه طولانی-کوتاه‌مدت (LSTM) برای طبقه‌بندی تغییرات استفاده شد. نتایج نشان داد که این مدل در مقایسه با طبقه‌بند سنتی ماشین بردار پشتیبان (SVM) عملکرد بهتری داشته و توانست دقت بالاتری در شناسایی تغییرات حاصل کند.

تحلیل عملکرد فنی

مدل‌های RNN، به‌ویژه LSTM، به‌دلیل توانایی در یادگیری روابط زمانی و درک وابستگی‌های توالی داده، برای تحلیل تغییرات زمانی-مکانی در سری‌های زمانی راداری مناسب هستند و در پایش تدریجی پدیده‌هایی مانند تغییرات زیست‌محیطی، کشاورزی یا فرسایش، پتانسیل بالایی دارند. با این حال، پیچیدگی محاسباتی، نیاز به داده‌های سری زمانی با وضوح و کیفیت بالا، و زمان طولانی آموزش، از جمله محدودیت‌های جدی آن‌ها محسوب می‌شوند. همچنین، در مقایسه با معماری‌های پیچشی مانند U-Net، دقت کلی و کارایی شبکه‌های بازگشتی در مقیاس‌های بزرگ معمولاً پایین‌تر است [۶].


ساختار کلی این مدل در شکل ۷ نمایش داده شده است. در این ساختار، دو شاخه موازی (branch1 و branch2) شامل مسیرهای پیچشی در سطوح مختلف قرار دارند. خروجی‌های چندمقیاسی این شاخه‌ها پس از عبور از چند مرحله پایین‌سازی (Downsampling) و عملیات رمزگذاری (Encoder)، در مسیر صعودی (Upsampling) با استفاده از عملیات الحاق (Concatenation) ترکیب شده و به‌تدریج برای بازسازی نقشه خروجی تغییرات بازنمونه‌برداری می‌شوند. استفاده از اطلاعات در سطوح مختلف مقیاسی و فشردگی ویژگی‌ها در این ساختار، امکان استخراج نمایه‌های معنایی قوی‌تر را فراهم کرده و موجب بهبود دقت در آشکارسازی تغییرات شده است.

تحلیل عملکرد فنی

در سال‌های اخیر، معماری U-Net همچنان به‌عنوان یکی از مؤثرترین ساختارها در حوزه شناسایی تغییرات با استفاده از تصاویر راداری مطرح بوده است. پژوهش‌هایی نظیر [۲۲]، [۲۳] و [۲۴] نیز این معماری را در محوریت ساختار پیشنهادی خود قرار داده و در کاربردهایی چون آشکارسازی تغییرات معادن و ساختمان‌ها به‌کار گرفته‌اند. ساختار رمزگذار-رمزگشای U-Net با حفظ اطلاعات مکانی در مسیرهای پایین‌رو و بالا‌رو، امکان تولید نقشه‌های تغییر دقیق را فراهم می‌کند. این معماری در مطالعات مختلف، دقت‌هایی تا حدود ۹۵٪ در پایش تغییرات شهری [۱۹] و F1-score در بازه ۰/۸۵ تا ۰/۹۳ در داده‌های چندمنبعی [۲۴] به‌دست آورده است. از جمله کاربردهای موفق آن می‌توان به شناسایی تغییرات ساختمانی، ارزیابی خسارات ناشی از بلایای طبیعی و بخش‌بندی نواحی آسیب‌دیده اشاره کرد [۲۱].

محدودیت‌ها و چالش‌ها

با وجود این مزایا، معماری U-Net به‌ویژه در نسخه‌های پیشرفته‌تری



شکل ۷: ساختار کلی روش پیشنهادی TransUNet++SAR توسط دو و همکاران [۲۱] برای آشکارسازی تغییرات در تصاویر راداری

Fig. 7: Overall architecture of the TransUNet++SAR method proposed by Do et al. [21] for SAR image change detection

تصویر تفاضلی (DI) از طریق نسبت لگاریتمی بین دو تصویر ورودی آغاز می‌شود. این تصویر تفاضلی به یک رمزگذار خودکار داده می‌شود تا ویژگی‌های فشرده‌ای از داده‌ها استخراج شده و نویزهای لکه‌ای سرکوب شوند.

سیس، خروجی رمزگذار که حاوی بازنمایی‌های ویژگی است، به خوشه‌بند FCM داده می‌شود تا مجموعه‌ای از پیکسل‌ها با برچسب‌های شبه‌نظارتی (Pseudo Labels) تولید شود. این برچسب‌ها در سه کلاس تعریف می‌شوند و به‌عنوان داده آموزشی برای مرحله بعدی مورد استفاده قرار می‌گیرند. در ادامه، شبکه عصبی پیچشی با استفاده از این داده‌های برچسب‌خورده آموزش دیده و پس از آن، ویژگی‌های تصویر از طریق لایه‌های شبکه عصبی پیچشی پردازش شده و نقشه تغییر نهایی تولید می‌شود.

- توسعه خوشه‌بندی فازی و معماری‌های پیشرفته پیچشی (FCM + CWNN)

در ادامه مسیرهای توسعه‌یافته بر مبنای ترکیب خوشه‌بندی و شبکه‌های پیچشی، در سال‌های اخیر نیز رویکردهایی مشابه با روش گانگ و همکاران [۲۵] دنبال شده است. برای نمونه، کوئی و همکاران [۲۶] در سال ۲۰۱۹، به‌منظور تعیین خودکار نمونه‌های آموزشی با اطمینان بالا، از یک استراتژی گروهی و ساختار خوشه‌بندی مبتنی بر ترکیب چندین FCM استفاده کردند. در این رویکرد، نمونه‌های خوشه‌بندی‌شده جهت آموزش یک شبکه پیچشی طراحی شده مورد استفاده قرار گرفت.

در سال ۲۰۲۰، مینگ و همکارانش [۲۷] از خوشه‌بندی فازی محلی (Local FCM) برای استخراج شبه‌برچسب‌ها استفاده کرده و سیس از یک شبکه موجک پیچشی (CWNN) برای طبقه‌بندی بهره گرفتند. به‌دنبال آن، ژنگ و همکارانش [۲۸] با هدف اعمال تحلیل شی‌گرا، ابتدا با بهره‌گیری از الگوریتم SLIC اقدام به قطعه‌بندی اولیه تصویر کردند و سیس در نسخه توسعه‌یافته‌ای از روش خود در سال بعد [۲۹]، از یک خوشه‌بندی دمرحله‌ای FCM در فضای پیکسل برای تولید داده‌های آموزشی اطمینان‌بخش بهره بردند.


○ رویکردهای یادگیری بدون نظارت و خودنظارتی

همان‌گونه که پیش‌تر اشاره شد، کمبود و دشواری دسترسی به داده‌های برچسب‌خورده در تصاویر سنجش از دور، به‌ویژه داده‌های راداری، یکی از چالش‌های اساسی در توسعه روش‌های یادگیری نظارت‌شده است. در پاسخ به این محدودیت، روش‌های نظارت‌نشده (Unsupervised) و خودنظارتی (Self-supervised) مورد توجه روزافزون قرار گرفته‌اند. در این رویکردها، مدل بدون نیاز به داده‌های برچسب‌خورده یا با تولید برچسب به‌صورت درون‌زایافته، فرآیند یادگیری را انجام می‌دهد و در نتیجه وابستگی به نمونه‌های دستی کاهش می‌یابد. در ادامه، این دسته از روش‌ها به‌تفصیل بررسی می‌شوند.

- استفاده پایه از شبکه‌های پیچشی در رویکردهای بدون نظارت (CNN) استفاده از شبکه‌های عصبی پیچشی بدون بهره‌گیری از معماری‌های خاص نیز در بسیاری از مطالعات توانسته نیازهای اصلی مرتبط با آشکارسازی تغییرات را برآورده سازد. با این حال، از آن‌جا که این شبکه‌ها ذاتاً نیازمند فرآیند یادگیری مبتنی بر داده برای تنظیم بهینه وزن‌ها هستند، تهیه داده‌های آموزشی پیش از آموزش مدل، به‌ویژه در حوزه تصاویر راداری، یک مرحله ضروری تلقی می‌شود. این داده‌ها معمولاً یا از طریق روش‌های یادگیری بدون نظارت استخراج می‌شوند، یا از مدل‌های از پیش آموزش‌دیده بهره گرفته می‌شود.

- ترکیب رمزگذارهای خودکار و خوشه‌بندی فازی در آشکارسازی تغییرات (Autoencoder + FCM)

در همین راستا، گانگ و همکارانش [۲۵] در سال ۲۰۱۷ چارچوبی ترکیبی برای آشکارسازی و دسته‌بندی تغییرات به دو نوع «مثبت» و «منفی» ارائه دادند. روش پیشنهادی آن‌ها ترکیبی از یک رمزگذار خودکار پراکنده (Sparse Autoencoder)، شبکه عصبی پیچشی و یک خوشه‌بند بدون نظارت مبتنی بر روش FCM (Fuzzy C-Means) بود. همان‌گونه که در شکل ۸ نمایش داده شده است، فرآیند با محاسبه



شکل ۸: ساختار کلی روش پیشنهادی گانگ و همکاران [۲۵] برای آشکارسازی تغییرات در تصاویر راداری با استفاده از ترکیب رمزگذار خودکار، خوشه‌بندی فازی و شبکه پیچشی.
Fig. 8: Overall structure of the change detection method proposed by Gang et al. [25], combining a sparse autoencoder, fuzzy C-means clustering, and a convolutional neural network (CNN).

از خوشه‌بندی فازی برای تولید برچسب‌های اولیه، از یک شبکه عصبی از پیش آموزش‌دیده استفاده می‌شود تا داده‌های آموزشی اولیه را فراهم کند. مزیت کلیدی این روش، ساده‌سازی فرایند و کاهش وابستگی به مراحل میانی است. نتایج نشان می‌دهد که این مدل پایان‌به‌پایان توانسته عملکرد بهتری نسبت به روش‌های مبتنی بر FCM در برخی معیارها از خود نشان دهد.

در ادامه این مسیر، دانگ و همکاران [۳۲] چارچوبی جدید مبتنی بر شبکه‌های تبدیل‌کننده ارائه کردند که ساختار آن بر پایه تقسیم‌بندی تصویر به وصله‌های محلی و اعمال لایه‌های محدودشده به پنجره‌های محاسباتی کوچک طراحی شده است. این طراحی موجب کاهش چشمگیر پیچیدگی محاسباتی و رسیدن به ساختاری با بار محاسباتی خطی شده و در عین حال امکان استخراج ویژگی‌های معنایی سطح بالا را فراهم کرده است.


- تحلیل تطبیقی مزایا و چالش‌های روش‌های بدون نظارت

با وجود رشد روش‌های جدید، همچنان روش‌های بدون نظارت مبتنی بر شبکه عصبی پیچشی و خوشه‌بندی فازی جایگاه خود را حفظ کرده‌اند. برای مثال، ژنگ و همکاران [۲۹] با تلفیق FCM و شبکه مولد متخاصم، موفق به تولید شبه‌برچسب‌های معتبر شدند و دقتی تا ۹۹/۶٪ گزارش کردند. این روش‌ها به‌ویژه برای سناریوهای دارای داده‌های برچسب‌خورده محدود، مانند پایش مناطق دورافتاده یا زیست‌محیطی، مناسب‌اند [۲۵]. با این حال، عملکرد نهایی آن‌ها وابسته به کیفیت خوشه‌بندی اولیه و میزان تأثیر نویز لکه‌ای در تصاویر است؛ عاملی که در برخی مطالعات مانند [۲۶] نیز به‌عنوان محدودیت اصلی گزارش شده است. از سوی دیگر، گرچه زمان محاسباتی این روش‌ها در مقایسه با مدل‌های یادگیری عمیق پیچیده نسبتاً پایین است، اما فرآیند بهینه‌سازی پارامترهای FCM خود می‌تواند پیچیدگی محاسباتی و حساسیت به تنظیمات اولیه را افزایش دهد.

در این روش، برای غلبه بر کمبود داده، از شبکه‌های مولد متخاصم شرطی (DCGAN) جهت تولید وصله‌های تغییر مصنوعی استفاده شد و در ادامه، شبکه‌ی موجک پیچشی برای طبقه‌بندی نهایی به‌کار گرفته شد که در مجموع توانست به دقت چشمگیر ۹۹/۶٪ دست یابد. همچنین، در سال ۲۰۲۲، قوش و همکارانش [۳۰] با ارائه نسخه‌ای مکان‌محور از الگوریتم FCM، ساختاری مشابه اما با در نظر گرفتن وابستگی مکانی پیکسل‌ها پیاده‌سازی کردند. ساختار کلی این روش در شکل ۹ نمایش داده شده است. این روش با پیش‌پردازش اولیه شامل محاسبه نسبت لگاریتمی آغاز می‌شود و سپس با اعمال تبدیل چندمقیاسی (MSRDI) و استفاده از فضاها‌ی مقیاسی مختلف، ویژگی‌های تصویری استخراج می‌شوند. خروجی‌ها از طریق خوشه‌بندی موازی مبتنی بر الگوریتم TCCFCM پردازش و نقشه‌ای از شبه‌برچسب‌ها تولید می‌گردد. این نقشه، شامل نمونه‌های ساده تغییرنیافته، سخت، و ساده تغییر یافته است که هرکدام به‌طور جداگانه برای آموزش شبکه موجک پیچشی استفاده می‌شوند. همچنین، به‌منظور تقویت داده‌ها، از شبکه مولد DCGAN برای تولید وصله‌های تغییر مصنوعی بهره گرفته شده است که به بهبود عملکرد نهایی طبقه‌بند کمک می‌کند.

- معماری‌های پایان‌به‌پایان (End-to-End)

در کنار رویکردهای ترکیبی متداول که از خوشه‌بندی برای تولید برچسب‌های اولیه بهره می‌برند، در سال‌های اخیر روش‌هایی بدون نظارت طراحی شده‌اند که کل فرایند شناسایی تغییرات را به‌صورت پایان‌به‌پایان (End-to-End) و بدون نیاز به تصویر تفاوت یا اعمال فیلترهای پیش‌پردازشی انجام می‌دهند. برای نمونه، کیشک و همکاران [۳۱] در سال ۲۰۲۰ روشی مبتنی بر شبکه عصبی پیچشی ارائه کردند که تصاویر راداری را پس از انجام تصحیحات هندسی اولیه، مستقیماً به مدل وارد کرده و طبقه‌بندی نهایی را بدون نیاز به تولید تصویر تفاوت یا خوشه‌بندی واسطه انجام می‌دهد. در این رویکرد، به‌جای بهره‌گیری



شکل ۹: ساختار کلی روش پیشنهادی ژنگ و همکاران [۲۹] در سال ۲۰۲۱ برای آشکارسازی تغییرات در تصاویر راداری با استفاده از خوشه‌بندی فازی، شبکه موجک پیچشی و داده‌افزایی با DCGAN.

Fig. 9: Overall architecture of the change detection method proposed by Zheng et al [29]. (2021), combining fuzzy clustering, complex wavelet neural networks (CWNN), and data augmentation via DCGAN.

ادغام داده‌های راداری و نوری در معماری‌های پیشرفته

شناسایی تغییر

- ضرورت ادغام چندمنبعی در شناسایی تغییرات

ادغام داده‌های راداری با داده‌های نوری، از جمله تصاویر چندطیفی یا با تفکیک‌پذیری بسیار بالا (VHR) به‌عنوان یکی از راهبردهای مؤثر و نوظهور در شناسایی تغییرات مطرح شده است. این رویکرد، با بهره‌گیری از ویژگی‌های مکمل موجود در هر نوع داده، می‌تواند محدودیت‌های ذاتی آن‌ها را جبران کرده و دقت آشکارسازی تغییرات را افزایش دهد. تصاویر SAR قابلیت تصویربرداری مستقل از شرایط نوری و جوی را دارند و نسبت به ویژگی‌های ساختاری و فیزیکی سطح زمین مانند بافت، رطوبت و زبری حساس هستند [۳۳]. در مقابل، تصاویر نوری اطلاعات طیفی دقیق و غنی در باندهای مختلف (مانند RGB و مادون قرمز) ارائه می‌دهند که برای تحلیل پوشش گیاهی، کاربری اراضی و تغییرات بصری سطح زمین مفیدند [۳۴].

- معماری MSCDUNet: نمونه‌ای پیشرفته از ادغام چندسطحی داده‌ها
شکل ۱۰ ساختار کلی یک معماری ادغامی دوشاخه را نشان می‌دهد که در آن ویژگی‌های استخراج‌شده از داده‌های با وضوح بالا و تصاویر چندطیفی-راداری به‌صورت موازی پردازش و ترکیب می‌شوند. در این چارچوب، هر شاخه با ساختاری شبیه U-Net++، وظیفه پردازش نوع خاصی از داده‌ها را بر عهده دارد و لایه‌های دو کانولوشن (Double Convolution) در مسیر رمزگذاری و بازسازی اطلاعات عمل می‌کنند. اتصال‌های پرش (Connections Skip) و مسیرهای نمونه‌برداری معکوس (Upsampling) برای حفظ اطلاعات مکانی دقیق به‌کار رفته‌اند. پس از استخراج چندسطحی ویژگی‌ها، خروجی هر مسیر به‌صورت


مرحله به مرحله در بلوک‌های الحاق (Concatenation) با یکدیگر تلفیق شده و به یک شبکه نهایی برای طبقه‌بندی تغییرات منتقل می‌شود. این ساختار مشابه آن چیزی است که در چارچوب MSCDUNet توسط لی و همکاران [۳۴] ارائه شد؛ مدلی که با به‌کارگیری دو معماری U-Net++ و یکپارچه‌سازی ویژگی‌های کلیدی استخراج‌شده با استفاده از الگوریتم جنگل تصادفی، موفق به دستیابی به F1-score معادل ۹۳٪ در مجموعه داده‌های ترکیبی شد. این نتایج نشان می‌دهد که تلفیق هوشمند ویژگی‌های چندمنبعی می‌تواند نسبت به استفاده از داده‌های تک‌منبعی، عملکرد قابل‌توجهی بهتر ارائه دهد.

در مجموع، بهره‌گیری از معماری‌های چندشاخه، مانند نمونه ارائه‌شده در شکل ۱۰، مسیر مؤثری برای بهره‌برداری بهینه از مزایای داده‌های چندمنبعی فراهم می‌کند و می‌تواند دقت، پایداری و تعمیم‌پذیری مدل‌های آشکارسازی تغییرات را به‌طور محسوسی افزایش دهد.

- سطوح تلفیق اطلاعات در مدل‌های چندمنبعی

ادغام داده‌ها در این حوزه می‌تواند در سه سطح اصلی صورت گیرد:

- سطح پیکسل: نیازمند تطبیق دقیق مکانی-زمانی میان تصاویر راداری و نوری است و متکی به ترکیب مستقیم داده‌های خام است.
- سطح ویژگی: همان‌گونه که در شکل ۹ مشاهده می‌شود، شامل ترکیب ویژگی‌های استخراج‌شده از هر مسیر با استفاده از شبکه‌های یادگیری عمیق و انعطاف‌پذیری بیشتر در مواجهه با داده‌های ناهمگن است؛
- سطح تصمیم‌گیری: بر پایه ترکیب نتایج طبقه‌بندی مستقل برای هر منبع داده انجام می‌شود اما به دلیل عدم همگرایی در سطوح عمیق، دقت پایین‌تری دارد [۳۳].



شکل ۱۰: ساختار کلی شبکه‌ی MSCDUNet برای ادغام تصاویر چندمنبعی (SAR، چندطیفی و VHR) با استفاده از معماری دوشاخه، انتخاب ویژگی با جنگل تصادفی، و ترکیب سطوح مختلف ویژگی‌ها [۳۴].

Fig. 10: Overall architecture of the MSCDUNet network for multi-source image fusion (SAR, multispectral, and VHR), using a dual-branch design, feature selection via Random Forest, and multi-level feature integration [34].

- مزایای عملیاتی ادغام داده‌های راداری و نوری

○ افزایش دقت و پایداری نتایج: داده‌های طیفی حاصل از تصاویر نوری و اطلاعات ساختاری موجود در تصاویر راداری، ماهیتی مکمل دارند و می‌توانند محدودیت‌های ذاتی هر یک را جبران کنند. به‌عنوان نمونه، در فرآیند پایش تغییرات پوشش گیاهی، تصاویر نوری قادر به شناسایی تغییرات رنگ، بافت و ویژگی‌های بصری هستند، در حالی که تصاویر راداری اطلاعاتی درباره ساختار گیاهان و میزان رطوبت خاک فراهم می‌کنند. این هم‌افزایی موجب کاهش اثر نویز لکه‌ای در تصاویر SAR و محدودیت‌های ناشی از شرایط جوی در داده‌های نوری می‌شود [۳۴].

○ کاربردپذیری گسترده در سناریوهای مختلف: این رویکرد در حوزه‌های گوناگون از جمله پایش بلایای طبیعی نظیر سیلاب‌ها و رانش زمین، رصد تغییرات کاربری اراضی، و ارزیابی تحولات شهری عملکرد به‌مراتب بهتری نسبت به استفاده از داده‌های منفرد از خود نشان داده است. برای مثال، در مطالعه [۳۴]، ترکیب داده‌های نوری و راداری به شناسایی دقیق تغییرات در مناطق شهری منجر شد. افزایش تعمیم‌پذیری مدل‌های یادگیری عمیق این امکان را می‌دهد که در برابر تغییرات محیطی مانند تفاوت‌های فصلی، شرایط نوری متغیر یا ویژگی‌های مکانی متنوع، پایداری عملکرد بیشتری داشته باشند. این امر به دلیل فراهم شدن اطلاعات متنوع‌تر و غنی‌تر برای فرآیند آموزش مدل است [۳۳].

- چالش‌ها و محدودیت‌های فنی

با وجود مزایای چشمگیر، ادغام تصاویر راداری و نوری با چالش‌های مهمی مواجه است که در مطالعات آتی باید به‌طور نظام‌مند مورد توجه قرار گیرد:

○ ناهماهنگی زمانی و مکانی داده‌ها: تصاویر راداری و نوری معمولاً در بازه‌های زمانی متفاوت یا با تفکیک‌پذیری مکانی ناهمسان به‌دست می‌آیند. این عدم تطابق می‌تواند به تفسیر نادرست تغییرات واقعی منجر شود؛ چرا که ممکن است تفاوت‌های مشاهده‌شده ناشی از زمان تصویربرداری یا اختلافات مکانی، و نه تغییرات واقعی سطح زمین، تلقی گردند [۳۳]. به‌عنوان مثال، تصاویر نوری ممکن است تحت تأثیر پوشش ابری یا سایه قرار گیرند، در حالی که داده‌های SAR در همان بازه زمانی در دسترس هستند ولی با رزولوشن متفاوت.

○ پیچیدگی فرآیند پیش‌پردازش: برای هم‌راستا کردن داده‌های چندمنبعی، مراحل پیش‌پردازشی متعددی مانند تصحیح هندسی، هم‌زمان‌سازی زمانی و نرمال‌سازی داده‌ها ضروری است. این فرآیندها علاوه بر پیچیدگی، می‌توانند منابع محاسباتی قابل‌توجهی مصرف کرده و در صورت اجرا نادرست، منجر به بروز خطاهای تجمیعی شوند [۳۴].

○ افزایش حجم داده و بار محاسباتی: ادغام داده‌های راداری و نوری، حجم ورودی به مدل‌های یادگیری عمیق را به‌طور قابل‌توجهی افزایش می‌دهد و در نتیجه، نیاز به معماری‌های پیچیده‌تر و منابع محاسباتی قدرتمندتری ایجاد می‌کند. این موضوع خصوصاً در کاربردهای بلندپایه مانند پایش بحران‌های طبیعی، یک محدودیت جدی محسوب می‌شود [۳۳].

○ کمبود داده‌های مرجع استاندارد: نبود مجموعه‌داده‌های جامع، برچسب‌خورده و هم‌زمان از تصاویر راداری و نوری، امکان ارزیابی منسجم و مقایسه‌پذیر روش‌های مختلف ادغام را کاهش داده است. این چالش مانعی جدی برای توسعه مدل‌های تعمیم‌پذیر و قابل استفاده در مقیاس وسیع به‌شمار می‌رود [۳۴].

○ تأثیر نویز و شرایط محیطی: تصاویر SAR تحت تأثیر نویز لکه‌ای و تصاویر نوری تحت تأثیر عوامل محیطی مانند ابر، مه یا سایه قرار می‌گیرند. این عوامل می‌توانند موجب کاهش دقت الگوریتم‌های ادغام شوند. اگرچه روش‌هایی نظیر MSCDUNet توانسته‌اند تا حدی این محدودیت‌ها را کاهش دهند، اما همچنان نیاز به توسعه الگوریتم‌های مقاوم‌تر در برابر نویز و ناپایداری‌های محیطی احساس می‌شود [۳۴].

- ارزیابی تطبیقی روش‌های ادغام و محدودیت‌های تعمیم‌پذیری

ادغام تصاویر راداری و نوری را می‌توان گامی راهبردی در جهت رفع کاستی‌های روش‌های مبتنی بر داده‌های تک‌منبعی دانست. با این حال، تحقق کامل ظرفیت‌های این رویکرد در گرو توانایی آن در غلبه بر چالش‌های فنی و مفهومی موجود است. مطالعاتی همچون پژوهش لی و همکاران در قالب معماری MSCDUNet [۳۴] نشان داده‌اند که بهره‌گیری از ساختارهای یادگیری عمیق چندمسیره می‌تواند با استخراج هم‌زمان ویژگی‌های مکمل از منابع داده‌ای مختلف، دقت مدل را به شکل معناداری افزایش دهد. با وجود این، وابستگی جدی این روش‌ها به داده‌های آموزشی باکیفیت و دارای برچسب معتبر، همچنان چالشی مشابه سایر الگوهای یادگیری نظارت‌شده محسوب می‌شود. در عین حال، هرچند ادغام در سطح ویژگی همان‌گونه که در [۳۴] اجرا شده نسبت به روش‌های ادغام در سطوح پیکسل یا تصمیم‌گیری، انعطاف‌پذیری بیشتری در مواجهه با ناهمگنی منابع اطلاعاتی دارد، اما کارایی آن در تمامی سناریوها تضمین‌شده نیست. از این‌رو، ضرورت انجام مطالعات تطبیقی برای ارزیابی سیستماتیک مزایا و محدودیت‌های هر سطح از ادغام و شناسایی الگوی بهینه برای کاربردهای خاص بیش‌ازپیش احساس می‌شود [۳۳].

- راهبردهای آینده‌نگر در توسعه‌ی این مدل‌ها

از منظر عملیاتی نیز، ادغام داده‌های چندمنبعی در حوزه‌هایی چون پایش بلایای طبیعی، که نیازمند تصمیم‌گیری سریع و دقیق هستند، پتانسیل بالایی دارد. با این حال، پیچیدگی‌های فنی از جمله نیاز به

استخراج شده‌اند و برای روش‌هایی که داده‌های کمی گزارش نشده‌اند، تخمین کیفی ارائه شده است. تحلیل داده‌های جدول فوق نشان می‌دهد که معماری‌های پیش‌بینی نظارت‌شده، به‌ویژه U-Net، عملکرد بسیار موفقی در آشکارسازی تغییرات در حوزه‌هایی مانند پایش شهری و بلایای طبیعی داشته‌اند. بر اساس نتایج گزارش‌شده در منابعی مانند [۱۹] و [۳۴]، این شبکه‌ها توانسته‌اند به دقت کلی تا ۹۵٪ و مقدار F1-Score در بازه ۰/۸۵ تا ۰/۹۳ دست یابند. موفقیت U-Net به ساختار رمزگذار-رمزگشای آن نسبت داده می‌شود که امکان حفظ ویژگی‌های مکانی در سطوح عمیق شبکه را فراهم می‌سازد.

پیش‌پردازش‌های سنگین و هزینه‌های محاسباتی بالا، پیاده‌سازی بلادرنگ چنین مدل‌هایی را با محدودیت‌هایی مواجه می‌سازد. همچنین، فقدان مجموعه داده‌های مرجع استاندارد و هم‌زمان از تصاویر راداری و نوری، ارزیابی عینی و توسعه‌پذیر مدل‌ها را دشوار کرده و مانعی در مسیر تعمیم‌پذیری آن‌ها در مقیاس وسیع ایجاد کرده است.

یافته‌ها

- ارزیابی عملکرد روش‌های یادگیری عمیق

جدول ۲ عملکرد روش‌های مختلف را بر اساس معیارهای دقت، F1-score و زمان محاسباتی مقایسه می‌کند. مقادیر از ارجاعات مقاله

جدول ۲: مقایسه عملکرد روش‌های مختلف بر اساس معیارهای دقت، F1-score، و زمان محاسباتی

Table 2: Performance comparison of different methods based on accuracy criteria, F1 score and computing time

روش Method	معماری Architecture	یادگیری Learning	دقت Accuracy	F1-score	زمان محاسباتی Computational time	کاربرد اصلی Main application	مرجع Reference
نظارت‌شده Supervised	MLP	نیاز به داده برچسب‌خورده Need labeled data	۶۶٪ 66%	گزارش نشده Not reported	بالا (آموزش و پیش‌پردازش) High (training & preprocessing)	پایش جنگل‌زدایی، توسعه شهری Monitoring deforestation, urban development	[۷]
	CNN	با یادگیری عمیق By deep learning	بالا (کیفی) High (qualitative)	گزارش نشده Not reported	متوسط تا بالا (بسته به عمق شبکه) Medium to high (depending on network depth)	حذف نویز، تغییرات شهری Noise reduction, urban changes	[۱۷]
	U-Net	رمزگذار/رمزگشا Encoder/Decoder	تا ۹۵٪ Up to 95%	۰/۸۵ تا ۰/۹۳ 0.85 to 0.93	بالا (آموزش) High (training)	بخش‌بندی تغییرات ساختمانی Segmentation of building changes	[۱۹] و [۳۴]
	RNN (LSTM)	مناسب برای سری‌های زمانی Suitable for time series	متوسط (کیفی) Medium (qualitative)	گزارش نشده Not reported	بالا (سری‌های زمانی) High (time series)	تحلیل زمانی تصاویر راداری Temporal analysis of radar images	[۶]
بدون نظارت Unsupervised	CWNN + FCM	شبکه مولد GAN Generative GAN network	تا ۹۹/۶٪ Up to 99.6%	۰/۷۰ تا ۰/۹۰ 0.70 to 0.90	متوسط (خوشه‌بندی و آموزش) Medium (clustering & training)	پایش زیست‌محیطی و مناطق دورافتاده Environmental monitoring and remote areas	[۲۵] و [۲۹]
	Autoencoder + FCM	رمزگذار خودکار پراکنده Sparse Autoencoder	بالا (کیفی) High (qualitative)	گزارش نشده Not reported	متوسط Medium	کاهش نویز و داده‌افزایی Noise reduction and data augmentation	[۲۶]
	GAN + FCM	شبکه مولد Generative network	بسیار بالا (۹۹٪) Very High (99%)	بالا (کیفی) High (qualitative)	بالا High	برچسب‌گذاری داده، تقویت یادگیری Data labeling, reinforcement learning	[۲۹]
	End-to-End	بدون تصویر تفاوت No difference image	بالا (کیفی) High (qualitative)	گزارش نشده Not reported	نسبتاً پایین Relatively low	ساده‌سازی فرایند، حذف پیش‌پردازش Simplify the process, eliminate preprocessing	[۳۱]
چندمنبعی Multi-sources	MSCDUNet		گزارش نشده Not reported	۰/۹۳ 0.93	بالا (پیش‌پردازش و آموزش) High (preprocessing & training)	پایش چندمنبعی و ادغام اطلاعات ساختاری-طیفی Multi-source monitoring and structural-spectral information fusion	[۳۴]

○ شبکه مولد تخصصی عمدتاً برای تولید داده‌های مصنوعی، داده‌افزایی و شبیه‌سازی تغییرات مورد استفاده قرار می‌گیرد. ترکیب شبکه‌های عصبی با خوشه‌بندی فازی، به‌ویژه FCM، نیز در بسیاری از پژوهش‌های بدون‌نظارت نشان داده است که می‌تواند بدون اتکالی مستقیم به برچسب‌گذاری انسانی، عملکرد رقابتی ارائه دهد.

- مقایسه رویکردهای نظارت‌شده و بدون‌نظارت

این مقایسه می‌تواند در انتخاب مدل مناسب برای کاربردهای عملی نقش کلیدی داشته باشد. در جدول ۳، این روش‌ها از منظر نوع یادگیری، داده‌های مورد نیاز، دقت و پیچیدگی با یکدیگر مقایسه شده‌اند.

یافته‌های این مرور نشان می‌دهند که یادگیری عمیق، به‌عنوان ابزاری توانمند در استخراج ویژگی‌های پیچیده مکانی و زمانی، تحولی بنیادین در دقت و کارایی فرآیند آشکارسازی تغییرات ایجاد کرده است. در ادامه، تحلیل دقیق‌تری از این یافته‌ها ارائه می‌شود تا ابعاد مزایا و محدودیت‌های این روش‌ها در حوزه سنجش از دور راداری روشن‌تر گردد.

- امکانات معماری‌های ترکیبی و رمزگذارها

روش‌های نظارت‌شده، به‌ویژه معماری‌های مبتنی بر شبکه U-Net، به دلیل قابلیت حفظ اطلاعات مکانی در سطوح عمیق شبکه، در وظایف بخش‌بندی تصویر و آشکارسازی دقیق تغییرات عملکردی برجسته داشته‌اند [۱۹ و ۲۱]. برای مثال، جاتوریبت و همکاران [۱۹] با استفاده از یک U-Net ساده در شناسایی تغییرات ساختمانی در مناطق شهری، دقتی در حدود ۹۵٪ گزارش کردند که توانایی این مدل در تمایز تغییرات واقعی از تغییرات فصلی را به‌خوبی نشان می‌دهد. همچنین، دو همکاران [۲۱] با ترکیب معماری U-Net و تبدیل‌کننده‌ها در قالب مدل TransUNet++SAR، موفق به استخراج بازنمایی‌های معنایی چندمقیاسی شدند که بهبود چشمگیری در شاخص‌های عملکرد نسبت به مدل‌های متعارف داشت.

این یافته‌ها بیانگر آن‌اند که ساختار رمزگذار-رمزگشای U-Net، که امکان مدل‌سازی دقیق روابط مکانی را فراهم می‌سازد، آن را به گزینه‌ای پرکاربرد و مؤثر در زمینه یادگیری نظارت‌شده تبدیل کرده است. با این حال، موفقیت این دسته از روش‌ها به‌شدت به دسترسی به داده‌های آموزشی باکیفیت و برچسب‌خورده وابسته است. همان‌گونه که در مطالعات [۳] و [۵] اشاره شده، کمبود داده‌های برچسب‌دار پژوهشگران را به سمت روش‌های شبه‌نظارتی یا یادگیری با نظارت ضعیف سوق داده است. به‌عنوان نمونه، نینگ و همکاران [۱۰] با بهره‌گیری از رمزگذارهای خودکار و خوشه‌بندی فازی، داده‌های آموزشی تقویت‌شده‌ای تولید کردند و نیاز به برچسب‌گذاری گسترده انسانی را کاهش دادند. چنین رویکردهایی تلاش دارند ضمن حفظ دقت بالا، وابستگی به داده‌های برچسب‌خورده را کاهش دهند.

در مقابل، روش‌های ترکیبی بدون‌نظارت نظیر تلفیق شبکه عصبی پیچشی با خوشه‌بندی فازی یا بهره‌گیری از شبکه‌های مولد متخاصم، توانسته‌اند بدون نیاز به داده‌های برچسب‌خورده، به دقتی نزدیک به ۹۹٪/۶ دست پیدا کنند [۲۹]. این دستاورد نشان می‌دهد که در شرایط کمبود داده‌های آموزشی، استفاده هوشمندانه از تکنیک‌های خوشه‌بندی و داده‌افزایی می‌تواند جایگزینی مؤثر برای مدل‌های نظارت‌شده باشد. اگرچه شبکه‌های بازگشتی به‌ویژه مدل‌های LSTM، پتانسیل بالایی در تحلیل الگوهای زمانی-مکانی دارند، اما به دلیل پیچیدگی محاسباتی بالا و نیاز به داده‌های سری زمانی متراکم، در عمل کاربرد محدودتری داشته و دقت آن‌ها نسبت به شبکه عصبی پیچشی یا U-Net کمتر گزارش شده است [۶].

در حوزه تلفیق داده‌ها، مدل‌هایی نظیر MSCDUNet که از ترکیب داده‌های راداری و نوری بهره می‌گیرند، به F1-Score معادل ۰/۹۳ دست یافته‌اند [۳۴] که بالاتر از بسیاری از روش‌های تک‌منبعی است. هرچند این ترکیب موجب ارتقای دقت شده، اما هزینه آن، افزایش پیچیدگی محاسباتی و نیاز به پیش‌پردازش‌های گسترده‌تر بوده است. از منظر زمان اجرا، روش‌های نظارت‌شده مبتنی بر معماری‌های پیچشی مانند CNN و U-Net به منابع پردازشی قابل‌توجهی در مرحله آموزش نیاز دارند، در حالی که مدل‌های بدون‌نظارت، علیرغم بهره‌گیری از فرایندهای خوشه‌بندی، معمولاً سریع‌تر اجرا می‌شوند و در سناریوهای بلادرنگ گزینه‌های مناسب‌تری محسوب می‌گردند. برای برخی الگوریتم‌ها مانند شبکه‌ی عصبی پرسپترون چند لایه، شبکه عصبی پیچشی و ترکیب خودرمزگذار با FCM، مقادیر عددی F1-Score گزارش نشده‌اند. این موضوع می‌تواند ناشی از اهداف متفاوت پژوهش‌ها باشد؛ از جمله طراحی مدل‌ها برای کاهش نویز یا استخراج ویژگی‌های میانی، یا نبود داده‌های مرجع برچسب‌دار. در بسیاری از این مطالعات، ارزیابی‌ها صرفاً بر پایه شاخص‌های کیفی، دقت کلی، یا معیارهای درونی خوشه‌بندی انجام گرفته و F1 به‌صورت مستقیم محاسبه نشده یا گزارش نشده است.

در جمع‌بندی، هر یک از مدل‌های پرکاربرد یادگیری عمیق دارای مزایا و محدودیت‌های خاص خود هستند:

- شبکه‌ی عصبی پرسپترون چند لایه به‌عنوان مدلی ساده، معمولاً برای داده‌های ساختاریافته مناسب است و در پردازش تصویر کاربری محدودی دارد.
- شبکه عصبی پیچشی با استفاده از فیلترهای محلی در شناسایی الگوهای مکانی مؤثر است و در کاربردهای طبقه‌بندی و آشکارسازی تغییرات عملکرد بالایی دارد.
- U-Net با ساختار متقارن و قابلیت حفظ اطلاعات مکانی در سطوح عمیق، در بخش‌بندی تغییرات عملکرد برجسته‌ای دارد.
- RNN و LSTM برای داده‌های زمانی مناسب‌اند و در ترکیب با شبکه عصبی پیچشی می‌توانند تحلیل زمانی-مکانی را تقویت کنند.

جدول ۳: مقایسه تطبیقی روش‌های یادگیری نظارت‌شده و بدون نظارت در آشکارسازی تغییرات مبتنی بر تصاویر راداری

Table 3: Comparative analysis of supervised and unsupervised learning methods for radar-based

ویژگی Feature	روش‌های یادگیری نظارت‌شده Supervised learning methods	روش‌های یادگیری بدون نظارت Unsupervised learning methods
نوع داده آموزشی مورد نیاز Type of training data required	نیازمند حجم قابل توجهی از داده‌های برچسب‌خورده با تنوع مناسب برای تعمیم‌پذیری مطلوب Requires a significant amount of labeled data with appropriate diversity for optimal generalizability	نیازمند داده‌های خام و بدون برچسب؛ مناسب در شرایط فاقد اطلاعات مرجع Requires raw, unlabeled data; suitable for situations without reference information
الزامات محاسباتی و پیچیدگی مدل Computational requirements and model complexity	وابسته به حجم داده، معماری شبکه و پارامترهای یادگیری؛ پیچیدگی محاسباتی بالا Dependent on data size, network architecture, and learning parameters; high computational complexity	به‌طور معمول سبک‌تر و سریع‌تر؛ مناسب برای سناریوهای بلادرنگ و منابع محدود Typically lighter and faster; suitable for real-time and resource-constrained scenarios
سرعت پردازش و زمان اجرا Processing speed and execution time	فرآیند آموزش کندتر، اما نتایج دقیق‌تر در صورت آموزش مناسب Slower training process, but more accurate results if trained properly	اجرای سریع‌تر به دلیل حذف مرحله یادگیری با داده برچسب‌دار Faster execution due to elimination of the learning step with labeled data
دقت شناسایی تغییرات Accuracy of change detection	عملکرد بالا در صورت وجود داده‌های آموزشی غنی؛ F1-score تا ۰/۹۵ گزارش شده است [۱۹] High performance when rich training data is available; F1-scores up to 0.95 have been reported [19]	عملکرد وابسته به کیفیت الگوریتم‌های خوشه‌بندی؛ F1-score بین ۰/۷۰ تا ۰/۹۰ [۲۵ و ۲۶] Performance dependent on the quality of clustering algorithms; F1-score between 0.70 and 0.90 [25, 26]
معماری‌های متداول Common architectures	روش‌های MLP، CNN، U-Net، U-Net، CNN، MLP methods	CNN با FCM، Autoencoder با FCM، GAN-based networks
چالش‌های اصلی Main challenges	هزینه بالای تهیه داده‌های برچسب‌خورده، حساسیت به کیفیت داده آموزشی High cost of labeled data acquisition, sensitive to training data quality	حساسیت بالا به نویز لکه‌ای، دشواری در تفکیک دقیق تغییرات در غیاب داده مرجع High sensitivity to speckle noise, difficulty in accurately distinguishing changes in the absence of reference data
انعطاف‌پذیری در شرایط فاقد داده مرجع Flexibility in situations without reference data	محدود به کیفیت و تنوع داده‌های آموزشی اولیه Limited to the quality and diversity of the initial training data	انعطاف‌پذیرتر برای داده‌های جدید و ناشناخته بدون نیاز به برچسب‌گذاری More flexible for new and unknown data without the need for labeling
کاربردهای شاخص Indicator applications	پایش توسعه شهری، شناسایی جنگل‌زدایی، مدیریت بلایای طبیعی Urban development monitoring, deforestation detection, natural disaster management [7, 8, 19, 21]	پایش زیست‌محیطی مناطق دورافتاده، تحلیل تغییرات تدریجی در سری‌های زمانی [۲۵، ۲۷ و ۲۹] Remote environmental monitoring, analysis of gradual changes in time series [25, 27, 29]
شاخص‌های عملکرد گزارش‌شده Reported performance indicators	دقت تا ۹۵٪ با U-Net؛ F1-score در محدوده ۸۵٪ تا ۹۳٪ در داده‌های SAR [۱۹ و ۳۴]؛ کارایی ۶۶٪ با MLP در پایش جنگل [۷] Accuracy up to 95% with U-Net; F1-scores in the range of 0.85 to 0.93 on SAR data [19, 34]; Kappa of 66% with MLP in forest monitoring [7]	دقت تا ۹۹/۶٪ در مدل FCM+GAN برای پیکسل‌محور؛ F1-score تا ۹۰٪ بسته به کیفیت خوشه‌بندی [۲۵، ۲۶ و ۲۹] Accuracy up to 99.6% in the FCM+GAN model for pixel-based; F1-score up to 0.90 depending on the quality of clustering [25, 26, 29]

– تأثیر داده‌های چندمنبعی در بهبود دقت مدل‌ها

در شرایطی که داده‌های برچسب‌دار محدود یا غیرقابل دسترس هستند، روش‌های بدون نظارت، به‌ویژه آن‌هایی که از ترکیب خوشه‌بندی فازی و شبکه‌های عصبی پیچشی بهره می‌برند، انعطاف‌پذیری بالایی ارائه می‌دهند [۲۵ و ۲۹]. گانگ و همکاران [۲۵] با به‌کارگیری رمزگذار خودکار پراکنده به همراه الگوریتم خوشه‌بندی فازی، برچسب‌های شبه‌نظارتی تولید کردند که در آموزش شبکه پیچشی به‌کار رفت و منجر به دقتی قابل قبول در شناسایی تغییرات شد. همچنین، ژنگ و همکاران [۲۹] با بهره‌گیری از خوشه‌بندی دومرحله‌ای خوشه‌بندی فازی و شبکه مولد متخاصم برای داده‌افزایی، به دقتی در حدود ۹۹/۶٪ دست یافتند که کارایی بالای این روش‌ها در تولید داده‌های آموزشی معتبر را نشان می‌دهد.

این نتایج نشان می‌دهد که الگوریتم FCM به‌عنوان یک ابزار کلیدی در یادگیری بدون نظارت، امکان استخراج بازنمایی‌های معنایی از تصاویر را

بدون نیاز به برچسب‌گذاری دستی فراهم می‌سازد. با این حال، دقت نهایی این روش‌ها به کیفیت خوشه‌بندی اولیه وابسته است و اغلب تحت تأثیر نویزهای لکه‌ای موجود در تصاویر راداری قرار می‌گیرد [۲۶ و ۳۰]. برای نمونه، کوئی و همکاران [۲۶] نشان دادند که هرچند استراتژی‌های گروهی مبتنی بر خوشه‌بندی فازی توانسته‌اند نمونه‌های آموزشی با اطمینان بالا تولید کنند، اما نویزهای ذاتی تصویر باعث کاهش دقت خوشه‌بندی شده‌اند. این چالش‌ها بیانگر آن است که بهبود تکنیک‌های پیش‌پردازش، مانند حذف نویز و افزایش کیفیت تصویر ورودی، برای ارتقای عملکرد مدل‌های بدون نظارت ضروری است.

– چالش‌های عملیاتی و مسیرهای آتی پژوهش

در بررسی روش‌های یادگیری عمیق برای آشکارسازی تغییرات در تصاویر راداری، مجموعه‌ای از چالش‌های فناورانه، داده‌ای و مفهومی دیده می‌شود که موجب به‌کارگیری گسترده این روش‌ها در کاربردهای

می‌تواند در پایش بلایای طبیعی، جنگل‌زدایی، توسعه شهری و مدیریت منابع، نقش مؤثری ایفا کند [۷ و ۳۴]. با این حال، تحقق این ظرفیت‌ها مستلزم رفع چالش‌هایی نظیر کمبود داده‌های استاندارد، توسعه الگوریتم‌های مقیاس‌پذیر و بهینه‌سازی زیرساخت‌های محاسباتی است. از منظر نظری، برتری نسبی برخی معماری‌ها نظیر U-Net با تبدیل‌کننده‌ها [۲۱] یا مدل‌های بدون نظارت مبتنی بر شبکه‌های مولد متخاصم [۲۹]، چشم‌اندازهای نوینی برای طراحی ساختارهای پیشرفته‌تر فراهم کرده‌اند. به‌طور کلی، آینده این حوزه در گرو پیوند میان پیشرفت‌های فناوریانه، دسترسی به داده‌های غنی، و همکاری‌های میان‌رشته‌ای میان علوم داده، سنجش از دور و سیاست‌گذاری محیطی خواهد بود. با اتکا به همین مرور نظام‌مند و با استفاده از یافته‌های آن، می‌توان جهت‌گیری‌های کلیدی پژوهش‌های آتی را نیز بر پایه ادبیات موجود، به شرح زیر ترسیم کرد:

نخست، مطابق با مطالعات اخیر [۳۶ و ۳۷]، توسعه روش‌های یادگیری خودنظارت‌شده و بدون نظارت پیشرفته به‌عنوان پاسخی به کمبود داده‌های برجسب‌دار ضروری است. روش‌هایی که از ساختار داده‌های بدون برجسب برای یادگیری ویژگی‌های معنایی استفاده می‌کنند، به‌ویژه با بهره‌گیری از یادگیری کنتراستی یا خوشه‌بندی پویا، می‌توانند تعمیم‌پذیری مدل‌ها را افزایش دهند. در این راستا، مدل‌های مبتنی بر تبدیل‌کننده‌های خودنظارتی در شناسایی تغییرات پیچیده در تصاویر SAR کنویدبخش بوده‌اند.

دوم، در پی پژوهش‌هایی مانند [۳۸ و ۳۹]، ادغام داده‌های چندمنبعی مانند راداری، اپتیک و LiDAR می‌تواند موجب افزایش دقت شناسایی تغییرات شود. توسعه روش‌هایی که ناهماهنگی‌های زمانی، مکانی و رزولوشنی میان این منابع را به‌صورت خودکار مدیریت کنند، حیاتی است [۳۸]. چارچوب‌های یادگیری عمیق چندوجهی (Multimodal) برای استخراج ویژگی‌های مشترک از داده‌های ناهمگن، به‌ویژه در کاربردهایی چون پایش بلایای طبیعی، کارایی بالایی دارند [۳۹].

سوم، بهبود روش‌های کاهش نویز لکه‌ای در تصاویر راداری همچنان یک ضرورت فنی محسوب می‌شود. گسترش شبکه‌هایی نظیر FFDNet یا PCA-Net با هدف حذف نویز، می‌تواند دقت شناسایی تغییرات را به‌ویژه در مناطق با پوشش همگن یا پیچیده افزایش دهد [۴۰]. همچنین بهره‌گیری از یادگیری انتقالی با استفاده از مدل‌های پیش‌آموزش‌دیده، رویکردی مکمل در کاهش نویز محسوب می‌شود [۴۱].

چهارم، توسعه معماری‌های سبک و مقیاس‌پذیر، متناسب با داده‌های تولیدی توسط ماهواره‌های نسل جدید مانند سنتینل-۱، اهمیت روزافزونی دارد. طراحی نسخه‌های بهینه‌شده U-Net یا تبدیل‌کننده‌های کم‌حجم، اجرای این مدل‌ها را در سیستم‌های تعبیه‌شده یا منابع پردازشی محدود ممکن می‌سازد [۴۲].

پنجم، ایجاد مجموعه‌داده‌های مرجع و عمومی با کیفیت بالا، گامی کلیدی برای استانداردسازی ارزیابی عملکرد الگوریتم‌هاست. نبود چنین منابعی، مقایسه منصفانه بین روش‌ها را دشوار ساخته و مانع شفافیت

عملی می‌شوند و افق‌های جدیدی نیز برای توسعه پژوهش‌های آینده ترسیم می‌کنند.

یکی از چالش‌های بنیادی در پردازش تصاویر SAR، نویز لکه‌ای (Speckle Noise) است که ناشی از ماهیت چندبخشی امواج راداری بوده و منجر به کاهش نسبت سیگنال به نویز (SNR) و تضعیف کیفیت بصری تصاویر می‌شود [۳ و ۱۲]. برای مقابله با این چالش، الگوریتم‌هایی همچون FFDNet و PCA-Net توسعه یافته‌اند که با هدف بهبود کیفیت تصویر، دقت مدل‌های آشکارسازی تغییرات را نیز ارتقاء داده‌اند. به‌طور خاص، هونگکه و همکاران [۱۲] با به‌کارگیری FFDNet موفق شدند تعادلی میان حذف مؤثر نویز و سرعت استنتاج برقرار کنند؛ قابلیت‌های برای کاربردهای بلادرنج نظیر پایش سریع مناطق حادثه‌خیز از اهمیت بالایی برخوردار است. همچنین، مدل PCA-Net با بهره‌گیری از تجزیه مؤلفه‌های اصلی، توانسته است در تقویت سیگنال‌های مهم و تضعیف مؤلفه‌های نویزی مؤثر واقع شود [۱۶]. با این حال، در شرایط پیچیده‌تر مانند مناطق با بافت متراکم یا تغییرات ناهمگن، همچنان نیاز به توسعه مدل‌های مقاوم‌تر و تطبیق‌پذیرتر احساس می‌شود.

از سوی دیگر، ادغام داده‌های چندمنبعی به‌ویژه ترکیب تصاویر راداری و نوری، به‌عنوان یکی از مهم‌ترین یافته‌های این مرور شناخته می‌شود. مطالعاتی نظیر پژوهش لی و همکاران [۳۴] با معرفی مدل MSCDUNet نشان داده‌اند که بهره‌گیری هم‌زمان از تصاویر SAR، چندطیفی و VHR، می‌تواند به ارتقای چشمگیر دقت منجر شود؛ به‌طوری‌که در این مدل، F1-score معادل ۹۳٪ به‌دست آمده است. مزیت اصلی این ادغام، بهره‌برداری از ویژگی‌های مکمل داده‌ها و جبران محدودیت‌های ذاتی هر منبع است، مانند کاهش اثر نویز در تصاویر SAR یا پوشش ابری در تصاویر نوری. با این حال، چالش‌هایی نظیر ناهماهنگی زمانی و مکانی میان منابع، پیچیدگی پیش‌پردازش، افزایش بار محاسباتی و کمبود داده‌های مرجع استاندارد، همچنان مانعی برای بهره‌برداری کامل از این رویکرد محسوب می‌شوند [۳۳ و ۳۴].

مقایسه میان روش‌های نظارت‌شده و بدون نظارت نیز حاکی از مزایا و محدودیت‌های خاص هر رویکرد است. روش‌های نظارت‌شده مبتنی بر معماری‌هایی نظیر U-Net در صورت دسترسی به داده‌های برجسب‌خورده کافی، از دقت و پایداری بالایی برخوردارند [۱۹ و ۲۱]، اما هزینه تهیه این داده‌ها و وابستگی به کیفیت آن‌ها، کاربرد آن‌ها را در بسیاری از سناریوهای واقعی محدود می‌کند. در مقابل، روش‌های بدون نظارت با وجود انعطاف‌پذیری بیشتر در شرایط فاقد داده مرجع، نسبت به نویز و کیفیت خوشه‌بندی حساس‌اند [۲۵ و ۲۹]. رویکردهای ترکیبی مانند یادگیری با نظارت ضعیف یا شبه‌نظارتی که در پژوهش‌هایی مانند [۵] و [۱۰] ارائه شده‌اند، می‌کوشند مزایای هر دو گروه را در قالبی یکپارچه تلفیق کنند.

یافته‌های این مطالعه پیامدهای کاربردی و نظری مهمی برای آینده حوزه آشکارسازی تغییرات مبتنی بر یادگیری عمیق دارد. از منظر کاربردی، توانایی مدل‌های یادگیری عمیق در شناسایی دقیق تغییرات

نویز لکه‌ای (Speckle Noise) به‌عنوان یک چالش ساختاری در تصاویر راداری، عاملی اثرگذار در عملکرد تمامی رویکردها محسوب می‌شود. اگرچه الگوریتم‌هایی چون FFDNet و PCA-Net تا حدی توانسته‌اند تعادلی میان حذف نویز و حفظ جزئیات مکانی برقرار کنند، اما نیاز به مدل‌هایی با توانایی بالاتر در تطبیق با پیچیدگی‌های محتوایی، مانند تغییرات ناهمگن یا بافت‌های متراکم، همچنان پابرجاست. در همین راستا، بهره‌گیری از تکنیک‌های یادگیری انتقالی و مدل‌های پیش‌آموزش‌دیده، می‌تواند در کاهش نویز و تقویت قابلیت تعمیم مدل‌ها مؤثر واقع شود.

از منظر راهبردی، ادغام داده‌های چندمنبعی، به‌ویژه ترکیب تصاویر راداری، نوری و چندطیفی، به‌عنوان یکی از مسیرهای نویدبخش در افزایش دقت شناسایی تغییرات شناسایی شده است. معماری‌هایی مانند MSCDUNet با بهره‌گیری از ویژگی‌های مکمل منابع مختلف و همجوشی اطلاعات طیفی و ساختاری، توانسته‌اند F1-scoreهایی تا ۹۳٪ کسب کنند. با این حال، چالش‌هایی نظیر ناهم‌آهنگی زمانی و مکانی میان منابع، پیچیدگی فرآیندهای پیش‌پردازش، افزایش بار محاسباتی و کمبود داده‌های مرجع عمومی و استاندارد، مانع از بهره‌برداری کامل از این ظرفیت شده‌اند.

بررسی تطبیقی میان رویکردهای گوناگون نشان می‌دهد که هیچ‌یک به‌تنهایی پاسخ‌گوی همه سناریوهای عملیاتی نیست. انتخاب روش مناسب، باید با توجه به ماهیت داده، هدف کاربردی، محدودیت‌های محاسباتی و سطح مورد انتظار از دقت و تعمیم‌پذیری صورت گیرد. در سطح کاربردی، یادگیری عمیق قابلیت آن را دارد که در بهبود تصمیم‌گیری در حوزه‌هایی چون مدیریت منابع طبیعی، پایش محیط‌زیست، تحلیل بلایای طبیعی، و برنامه‌ریزی شهری، نقشی تعیین‌کننده ایفا کند. در سطح نظری نیز، توسعه معماری‌های ترکیبی، با بهره‌گیری هم‌زمان از مزایای مدل‌های مبتنی بر U-Net، تبدیل‌کننده‌ها (Transformers)، خوشه‌بندی فازی و GAN، همراه با روش‌های یادگیری انتقالی، چندشانی و خودنظارتی، افق اصلی پژوهش‌های پیش‌رو خواهد بود.

در مجموع، مرور حاضر با ترسیم وضعیت موجود و شناسایی چالش‌ها و ظرفیت‌های موجود، مسیر آینده این حوزه را به‌سوی مدل‌های یادگیری هوشمند، مقاوم، مقیاس‌پذیر و مبتنی بر داده‌های چندمنبعی هدایت می‌کند. تحقق این مسیر، مستلزم توسعه الگوریتم‌های مقاوم به نویز، طراحی چارچوب‌های همجوشی پیشرفته، بهینه‌سازی منابع محاسباتی، و ایجاد زیرساخت‌های داده‌ای استاندارد و قابل اشتراک است. پیوند میان پیشرفت‌های فناوریانه، دسترسی به داده‌های غنی، و هم‌افزایی میان‌رشته‌ای میان علوم داده، سنجش از دور و سیاست‌گذاری محیطی، عامل تعیین‌کننده در تحقق این چشم‌انداز خواهد بود.

مشارکت نویسندگان

میزان مشارکت نویسندگان در نگارش مقاله بطور یکسان است.

پیشرفت‌ها شده است. مجموعه داده‌های جامع و برچسب‌دار با پوشش سناریوهای مختلف، مبنای توسعه قابل اعتماد مدل‌های آینده خواهد بود [۴۳].

در نهایت، کاربرد یادگیری عمیق در تحلیل سری‌های زمانی راداری، به‌ویژه برای مدل‌سازی پدیده‌های پویایی چون جنگل‌زدایی تدریجی یا نوسانات سطح آب، نیازمند مدل‌هایی با توانایی درک وابستگی‌های زمانی-مکانی است. بهره‌گیری از شبکه‌های بازگشتی یا تبدیل‌کننده‌های زمانی (Temporal Transformers) در این زمینه می‌تواند به تقویت دقت تحلیل‌های سری زمانی کمک کند [۴۴].

تمرکز پژوهش‌های آتی بر این محورهای راهبردی، زمینه را برای توسعه مدل‌های مقاوم‌تر، انعطاف‌پذیرتر و قابل‌اعتمادتر در شناسایی تغییرات زمین فراهم می‌سازد و می‌تواند کاربرد عملی سنجش از دور را در مدیریت منابع، پایش محیط‌زیست و برنامه‌ریزی شهری به‌طور معناداری ارتقاء دهد.

نتیجه‌گیری

مرور حاضر نشان داد که طی دهه گذشته، بهره‌گیری از یادگیری عمیق در حوزه شناسایی تغییرات در تصاویر سنجش از دور، به‌ویژه داده‌های راداری، تحولی بنیادین در دقت، انعطاف‌پذیری و گستره کاربردهای عملیاتی این حوزه ایجاد کرده است. الگوریتم‌های یادگیری عمیق با توانایی در استخراج ویژگی‌های پیچیده و معنایی، قابلیت تمایز بهتر میان تغییرات واقعی و نویز یا نوسانات غیرمعنادار را فراهم ساخته‌اند. در این میان، روش‌های نظارت‌شده و به‌ویژه معماری‌هایی نظیر U-Net، به‌واسطه توانمندی بالا در حفظ اطلاعات فضایی و بازسازی دقیق ساختارهای تغییر یافته، عملکردی ممتاز در کاربردهایی چون پایش توسعه شهری، جنگل‌زدایی و رخدادهای طبیعی نشان داده‌اند. در برخی پژوهش‌ها، دقتی تا ۹۵٪ و F1-score بالای ۰/۹ گزارش شده است. با این حال، اتکای شدید این روش‌ها به داده‌های برچسب‌خورده، همراه با هزینه و دشواری تولید این نوع داده‌ها، یکی از موانع اصلی در گسترش عملی آن‌ها محسوب می‌شود.

برای مقابله با این چالش، رویکردهایی مانند یادگیری نظارت‌ضعیف، شبه‌نظارتی و خودنظارتی معرفی شده‌اند که تلاش دارند با بهره‌گیری از ساختار درونی داده‌ها و تکیه بر تکنیک‌هایی نظیر یادگیری کنتراستی یا رمزگذارهای خودکار، کارایی مدل‌ها را بدون نیاز کامل به برچسب انسانی حفظ کنند. در سوی دیگر، روش‌های بدون نظارت نیز از طریق ترکیب شبکه‌های پیچشی (CNN) با خوشه‌بندی فازی (FCM)، یا به‌کارگیری شبکه‌های مولد متخاصم (GAN)، به‌ویژه در شرایط فاقد داده‌های آموزشی، گزینه‌های عملیاتی قابل اتکایی ارائه داده‌اند. برخی پژوهش‌ها دقت‌هایی تا ۹۹/۶٪ برای این دسته از روش‌ها گزارش کرده‌اند. با این حال، وابستگی به خوشه‌بندی اولیه، حساسیت به نویز، و چالش در پایایی و تعمیم‌پذیری، همچنان محدودیت‌های کلیدی در این گروه از الگوریتم‌ها به شمار می‌رود.

[11] Mbaye M, Ngom N, Faye G, Baratoux D. Change detection and machine learning approach for mapping artisanal small-scale gold mining using C-band SAR and Google Earth Engine. 2021;GC24A-06.

[12] Duan H, Dong X, You S, Han S. A deep learning denoising framework based on FFDNet for SAR image change detection. In: ICEIEC 2021 - IEEE Int Conf Electron Inf Emerg Commun; 2021 Jun. p. 1–4. doi:10.1109/ICEIEC51955.2021.9463810.

[13] Zhang K, Zuo W, Zhang L. FFDNet: Toward a fast and flexible solution for CNN based image denoising. IEEE Trans Image Process. 2018;27(9):4608–22. doi:10.1109/TIP.2018.2839891.

[14] Wang R, Zhang J, Chen J, Jiao L, Wang M. Imbalanced learning-based automatic SAR images change detection by morphologically supervised PCA-Net. IEEE Geosci Remote Sens Lett. 2019;16(4):554–8. doi:10.1109/LGRS.2018.2878420.

[15] Chan T-H, Jia K, Gao S, Lu J, Zeng Z, Ma Y. PCANet: A simple deep learning baseline for image classification?. IEEE Trans Image Process. 2015;24(12):5017–32. doi:10.1109/TIP.2015.2475625.

[16] Gao Y, Gao F, Dong J, Du Q, Li H-C. Synthetic aperture radar image change detection via Siamese adaptive fusion network. IEEE J Sel Top Appl Earth Obs Remote Sens. 2021;14:10748–60. doi:10.1109/JSTARS.2021.3120381.

[17] Peng J, et al. A parallel change detection method for spatiotemporally multi-temporal SAR image based on Q-learning and wavelet. In: 14th Int Conf Digital Image Process (ICDIP 2022); 2022 Oct. p. 1078–91. doi:10.1117/12.2644622.

[18] Sun X, Wang B, Wang Z, Li H, Li H, Fu K. Research progress on few-shot learning for remote sensing image interpretation. IEEE J Sel Top Appl Earth Obs Remote Sens. 2021;14:2387–402. doi:10.1109/JSTARS.2021.3052869.

[19] Jaturapitpornchai R, Matsuoka M, Kanemoto N, Kuzuoka S, Ito R, Nakamura R. SAR-image based urban change detection in Bangkok, Thailand using deep learning. In: IGARSS 2019; 2019 Jul. p. 7403–6. doi:10.1109/IGARSS.2019.8899341.

[20] Askevold R, Vågen M. Automated mapping and change detection of rivers and inland water bodies by semantic segmentation of SAR imagery using deep learning [Master's thesis]. NTNU; 2022 [cited 2024 Apr 16].

[21] Du Z, Li X, Miao J, Huang Y, Shen H, Zhang L. Concatenated deep-learning framework for multitask change detection of optical and SAR images. IEEE J Sel Top Appl Earth Obs Remote Sens. 2024;17:719–31. doi:10.1109/JSTARS.2023.3333959.

[22] Murdaca G, Ricciuti F, Rucci A, Le Saux B, Fumagalli A, Prati C. A semi-supervised deep learning framework for change detection in open-pit mines using SAR imagery. Remote Sens. 2023;15(24):Article 24. doi:10.3390/rs15245664.

[23] Wang C, Su W, Gu H. SAR image change detection based on semisupervised learning and two-step training. IEEE Geosci Remote Sens Lett. 2022;19:1–5. doi:10.1109/LGRS.2021.3050746.

تشکر و قدردانی

نویسندگان مقاله از تمامی عزیزی که در این تحقیق همکاری داشته‌اند، کمال قدردانی و سپاس خود را اعلام می‌نمایند.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است».

منابع و مآخذ

[1] Parelius EJ. A review of deep-learning methods for change detection in multispectral remote sensing images. Remote Sens. 2023;15(8). doi:10.3390/rs15082092.

[2] Cheng G, et al. Change detection methods for remote sensing in the last decade: A comprehensive review. arXiv Preprint arXiv:2305.05813. 2023.

[3] Wang R, Wang W, Dong P, Haojiang W, Jiao L, Chen JW. SAR image change detection via a few-shot learning-based neural network. In: IGARSS 2021 - IEEE Int Geosci Remote Sens Symp; 2021 Jul. p. 5287–90. doi:10.1109/IGARSS47720.2021.9554705.

[4] Khan SH, He X, Porikli F, Bennamoun M. Forest change detection in incomplete satellite images with deep neural networks. IEEE Trans Geosci Remote Sens. 2017;55(9):5407–23.

[5] Hou X, et al. Deep collaborative learning with class-rebalancing for semi-supervised change detection in SAR images. Knowl Based Syst. 2023;264:110281. doi:10.1016/j.knosys.2023.110281.

[6] Neagoe V-E, Ciotec A-D, Bruzzone L. A weakly-supervised change detection technique for SAR images based on deep learning and synthetic training data generated by an ensemble of self-organizing maps. In: IGARSS 2019 - IEEE Int Geosci Remote Sens Symp; 2019 Jul. p. 1669–72. doi:10.1109/IGARSS.2019.8898344.

[7] Barreto TLM, Rosa RAS, Wimmer C, Nogueira JB, Almeida J, Cappabianco FAM. Deforestation change detection using high-resolution multi-temporal X-band SAR images and supervised learning classification. In: IGARSS 2016 - IEEE Int Geosci Remote Sens Symp; 2016 Jul. p. 5201–4. doi:10.1109/IGARSS.2016.7730355.

[8] Liu J, Gong M, Zhao J, Li H, Jiao L. Difference representation learning using stacked restricted Boltzmann machines for change detection in SAR images. Soft Comput. 2016;20(12):4645–57. doi:10.1007/s00500-014-1460-0.

[9] De S, Pirrone D, Bovolo F, Bruzzone L, Bhattacharya A. A novel change detection framework based on deep learning for the analysis of multi-temporal polarimetric SAR images. In: IGARSS 2017; 2017 Jul. p. 5193–6. doi:10.1109/IGARSS.2017.8128171.

[10] Lv N, Chen C, Qiu T, Sangaiah AK. Deep learning and superpixel feature extraction based on contractive autoencoder for change detection in SAR images. IEEE Trans Ind Inform. 2018;14(12):5530–8. doi:10.1109/TII.2018.2873492.

survey [Preprint]. arXiv:2410.07824 [cs.CV]. 2024 [cited 2025 Jun 12]. <https://doi.org/10.48550/arXiv.2410.07824>

[38] Shafique A, Cao G, Khan Z, Asad M, Aslam M. Deep learning-based change detection in remote sensing images: A review. *Remote Sens.* 2022;14(4):871. doi:10.3390/rs14040871.

[39] Wang L, Zhang M, Gao X, Shi W. Advances and challenges in deep learning-based change detection for remote sensing images: A review through various learning paradigms. *Remote Sens.* 2024;16(5):804. doi:10.3390/rs16050804.

[40] Gao F, Wang X, Gao Y, Dong J, et al. Sea ice change detection in SAR images based on convolutional-wavelet neural networks. *IEEE Geosci Remote Sens Lett.* 2019;PP(99):1–5. doi:10.1109/LGRS.2019.2895656.

[41] Chen H, Jiao L, Liang M, Liu F, Yang S, Hou B. Fast unsupervised deep fusion network for change detection of multitemporal SAR images. *Neurocomputing.* 2019 Mar 7;332:56–70.

[42] Khelifi L, Mignotte M. Deep learning for change detection in remote sensing images: Comprehensive review and meta-analysis. *IEEE Access.* 2020;PP(99):1. doi:10.1109/ACCESS.2020.3008036.

[43] Shi W, Zhang M, Zhang R, Chen S, Zhan Z. Change detection based on artificial intelligence: state-of-the-art and challenges. *Remote Sens.* 2020;12(10):1688. doi:10.3390/rs12101688.

[44] Gong M, Zhao J, Liu J, Miao Q, Jiao L. Change detection in synthetic aperture radar images based on deep neural networks. *IEEE Trans Neural Netw Learn Syst.* 2016;27(1):125–38. doi:10.1109/TNNLS.2015.2435783.

[24] Alatalo J, Sipola T, Rantonen M. Improved difference images for change detection classifiers in SAR imagery using deep learning. *IEEE Trans Geosci Remote Sens.* 2023;61:1–14. doi:10.1109/TGRS.2023.3324994.

[25] Gong M, Yang H, Zhang P. Feature learning and change feature classification based on deep learning for ternary change detection in SAR images. *ISPRS J Photogramm Remote Sens.* 2017;129:212–25. doi:10.1016/j.isprsjprs.2017.05.001.

[26] Cui B, Zhang Y, Yan L, Wei J, Wu H. An unsupervised SAR change detection method based on stochastic subspace ensemble learning. *Remote Sens.* 2019;11(11):Article 11. doi:10.3390/rs11111314.

[27] Meng W, Wang L, Du A, Li Y. SAR image change detection based on data optimization and self-supervised learning. *IEEE Access.* 2020;8:217290–305. doi:10.1109/ACCESS.2020.3042017.

[28] Zhang X, et al. Two-phase object-based deep learning for multi-temporal SAR image change detection. *Remote Sens.* 2020;12(3):Article 3. doi:10.3390/rs12030548.

[29] Robust unsupervised small area change detection from SAR imagery using deep learning. *ISPRS J Photogramm Remote Sens.* 2021;173:79–94. doi:10.1016/j.isprsjprs.2021.01.004.

[30] Ghosh C, Majumdar D, Mondal B. A deep learning-based SAR image change detection using spatial intuitionistic fuzzy C-means clustering. *Trans GIS.* 2022;26(6):2519–35. doi:10.1111/tgis.12966.

[31] Keshk HM, Yin X-C. Change detection in SAR images based on deep learning. *Int J Aeronaut Space Sci.* 2020;21(2):549–59. doi:10.1007/s42405-019-00222-0.

[32] Dong H, et al. A contrastive learning transformer for change detection in high-resolution SAR images. *SSRN [Preprint].* 2022 Jul 22. doi:10.2139/ssrn.4169439.

[33] Zhang J. Multi-source remote sensing data fusion: status and trends. *Int J Image Data Fusion.* 2010;1(1):5–24. doi:10.1080/19479830903561035.

[34] Li H, Zhu F, Zheng X, Liu M, Chen G. MSCDUNet: A deep learning framework for built-up area change detection integrating multispectral, SAR, and VHR data. *IEEE J Sel Top Appl Earth Obs Remote Sens.* 2022;15:5163–76. doi:10.1109/JSTARS.2022.3181155.

[35] Zhou Z, Siddiquee MMR, Tajbakhsh N, Liang J. UNet++: A nested U-Net architecture for medical image segmentation. *arXiv [Preprint].* 2018 Jul 18. doi:10.48550/arXiv.1807.10165.

[36] Cheng G, Huang Y, Li X, Lyu S, Xu Z, Zhao H, Zhao Q, Xiang S. Change detection methods for remote sensing in the last decade: A comprehensive review. *Remote Sens.* 2024;16(13):2355. doi:10.3390/rs16132355.

[37] Yu Z, Li T, Zhu Y, Pan R. Exploring foundation models in remote sensing image change detection: A comprehensive

معرفی نویسندگان

AUTHORS BIOSKETCHES



محمد رضا زرگر فارغ التحصیل کارشناسی ارشد در رشته مهندسی نقشه‌برداری - سنجش از دور می‌باشد. ایشان مدرک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی نقشه‌برداری به ترتیب در سال‌های ۱۳۹۹ و ۱۴۰۲ از دانشگاه تهران دریافت نمودند.

Zargar, M.R. M.Sc. in Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran

✉ Zargar.mr@ut.ac.ir



امیر آقابالائی مدرک کارشناسی خود را در رشته مهندسی نقشه‌برداری در سال ۱۳۸۹ از دانشگاه تهران و مدارک کارشناسی ارشد و دکتری خود را در رشته سنجش از دور به ترتیب در سال‌های ۱۳۹۴ و ۱۳۹۹ از دانشگاه صنعتی خواجه نصیرالدین طوسی دریافت کرد.

Khazai, S. Associate Professor, Imam Hossein Comprehensive University, Tehran, Iran

✉ Skhazai@ihu.ac.ir



علی مهتدی فارغ التحصیل کارشناسی ارشد در رشته مهندسی نقشه برداری گرایش سنجش از دور می باشد. ایشان مدرک کارشناسی خود را از دانشگاه صنعتی جندی شاپور دزفول و کارشناسی ارشد خود را از موسسه آموزش عالی حکمت قم سال ۱۴۰۳ دریافت کردند. سابقه‌ی

پژوهشی ایشان یک مقاله‌ی ژورنالی و دو مقاله‌ی کنفرانسی است.

Mohtadi, A. M.Sc. in Remote Sensing, Hekmat Higher Educational Institution, Qom, Iran

✉ Mohtadi1375@gmail.com

علاقه اصلی تحقیقاتی او پردازش و تجزیه و تحلیل داده و تصاویر سنجش از دوری است.

Aghabalaei, A. Assistant Professor, Imam Hossein Comprehensive University, Tehran, Iran

✉ Remotesensing@ihu.ac.ir



صفا خزائی مدرک کارشناسی خود را در رشته مهندسی نقشه برداری و ژئوماتیک در سال ۱۳۷۸ از دانشگاه امام حسین (ع) و مدارک کارشناسی ارشد و دکتری خود در رشته فتوگرامتری و سنجش از دور را به ترتیب در سال‌های ۱۳۸۱ و ۱۳۹۱ از دانشگاه تهران دریافت کرد. علاقه اصلی تحقیقاتی او شامل تشخیص ناهنجاری و هدف در تصاویر فرایطیفی و شبیه سازی تصاویر فرایطیفی است.

Citation (Vancouver): Zargar M.R, Aghabalaei A, Khazai S, Mohtadi A. [A Systematic Review of Machine Learning Methods for Change Detection in Radar and Optical Images with a Focus on Deep Learning]. *J. RS. GEOINF. RES.* 2024; 3(2): 235-256

 <https://doi.org/10.22061/jrsgr.2025.12190.1104>



COPYRIGHTS

© 2025 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(<https://creativecommons.org/licenses/by-nc/4.0/>)