

Multi-level damage detection of buildings after natural disasters using deep learning models and satellite image analysis

Milad Farmahini Farahani¹ , Houshang Dolatshahi Pirooz² 

1. M.A., Earthquake Engineering, School of Engineering, University of Tehran, Tehran, Iran. E-mail: Milad.farmahini@ut.ac.ir
2. Corresponding author, Associate Professor, School of Civil Engineering, University of Tehran, Tehran, Iran. E-mail: mdolat@ut.ac.ir

Article Info

Article type:
Research Article

Article history:
Received 01 September 2025
Received in revised form 14 September 2025
Accepted 21 September 2025
Available online 22 September 2025

Keywords:
Natural disasters,
damage detection,
remote sensing,
feature extraction,
deep learning.

ABSTRACT

Objective: Natural disasters such as earthquakes, floods, and hurricanes cause extensive damage to buildings and urban infrastructure. Rapid and accurate post-disaster damage assessment plays a crucial role in crisis management, optimal allocation of relief resources, and reconstruction planning.

Method: In this study, using the XBD dataset and the deep learning-based models YOLOv8 and YOLOv11, a multi-level classification framework was developed to detect and categorize building damage. The models were evaluated using Accuracy, Precision, Recall, F-score, mean Intersection over Union (mIoU), and Dice Coefficient metrics.

Results: YOLOv11 outperformed YOLOv8, achieving an Accuracy of 0.82, F-score of 0.81, mIoU of 0.73, and Dice of 0.86. Both models successfully identified and distinguished three damage levels — minor, severe, and complete — across various disaster types.

Conclusion: Further analysis indicated that the type of disaster and the degree of urban density significantly influenced model performance, with reduced accuracy in densely built areas, particularly for minor damages. The superior performance of YOLOv11 is attributed to its optimized architecture and the Dynamic Anchor Head mechanism, which enhances its capability to capture complex spatial damage patterns. Overall, the proposed deep learning framework provides an effective, automated approach to post-disaster building damage assessment, supporting the development of intelligent crisis management systems and improving the efficiency of resource allocation during disaster response.

Cite this article: Farmahini Farahani, M., Dolatshahi Pirooz, H. (2025). Multi-level damage detection of buildings after natural disasters using deep learning models and satellite image analysis. *Natural Disasters*, 1 (1), 47-62.



© The Author(s).

Publisher: Natural Disasters Research Institute (NDRI).

شناسایی آسیب چندسطحی ساختمان‌ها پس از حوادث طبیعی با به‌کارگیری مدل‌های یادگیری عمیق و تحلیل تصاویر ماهواره‌ای

میلاد فرمهینی فراهانی^۱، هوشنگ دولتشاهی پیروز^۲

۱. کارشناسی ارشد، مهندسی عمران-زلزله، دانشگاه تهران، تهران، ایران. رایانامه: Milad.farmahini@ut.ac.ir

۲. نویسنده مسئول، دانشیار، دانشکده مهندسی عمران، دانشگاه تهران، تهران، ایران. رایانامه: mdolat@ut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	هدف: حوادث طبیعی نظیر زلزله، سیلاب و طوفان خسارات گسترده‌ای به ساختمان‌ها و زیرساخت‌های شهری وارد می‌کنند. ارزیابی سریع و دقیق میزان آسیب‌های ساختمانی پس از وقوع حادثه، نقشی کلیدی در مدیریت بحران، تخصیص بهینه منابع امدادی و برنامه‌ریزی بازسازی دارد.
تاریخ دریافت: ۱۴۰۴/۰۶/۱۰ تاریخ بازنگری: ۱۴۰۴/۰۶/۲۳ تاریخ پذیرش: ۱۴۰۴/۰۶/۳۰ تاریخ انتشار: ۱۴۰۴/۰۶/۳۱	روش پژوهش: در این پژوهش، با بهره‌گیری از مجموعه داده XBD و به‌کارگیری مدل‌های یادگیری عمیق YOLOv8 و YOLOv11، شناسایی و طبقه‌بندی چندسطحی خسارات ساختمانی انجام شد. مدل‌ها بر اساس شاخص‌های دقت (Accuracy)، صحت (Precision)، بازیابی (Recal)، امتیاز F (F-score)، میانگین تلاقی بر اتحاد (mIoU) و ضریب دایس (Dice Coefficient) ارزیابی شدند.
کلیدواژه‌ها: حوادث طبیعی، شناسایی آسیب، سنجش از دور، استخراج ویژگی، یادگیری عمیق.	یافته‌ها: نتایج نشان داد مدل YOLOv11 با دستیابی به مقادیر دقت ۰٫۸۲، امتیاز F-برابر با mIoU ۰٫۸۱، برابر با Dice ۰٫۷۳ و عملکرد بهتری نسبت به YOLOv8 داشته است. همچنین، مدل‌های پیشنهادی توانایی تفکیک سه سطح تخریب شامل جزئی، شدید و کامل را دارا بوده‌اند.
	نتیجه‌گیری: تحلیل‌ها بیانگر آن است که نوع حادثه و میزان تراکم شهری بر عملکرد مدل‌ها تأثیرگذار بوده و در مناطق با تراکم بالا، دقت تشخیص آسیب‌های جزئی کاهش یافته است. در مجموع، بهره‌گیری از معماری بهینه‌تر در YOLOv11 و مکانیزم مرجع پویا (Dynamic Anchor Head) موجب افزایش دقت مدل در شناسایی آسیب‌های پیچیده شده است. این پژوهش با ارائه یک چارچوب خودکار مبتنی بر یادگیری عمیق، گامی مؤثر در جهت بهبود روش‌های ارزیابی خسارت، توسعه سامانه‌های هوشمند مدیریت بحران و بهینه‌سازی تخصیص منابع امدادی محسوب می‌شود.

استناد: فرمهینی فراهانی، میلاد؛ دولتشاهی پیروز، هوشنگ. (۱۴۰۴). شناسایی آسیب چندسطحی ساختمان‌ها پس از حوادث طبیعی با به‌کارگیری مدل‌های یادگیری عمیق و تحلیل تصاویر ماهواره‌ای. *سوانح طبیعی*، ۱ (۱)، ۴۷-۶۲.



© نویسندگان.

ناشر: پژوهشکده سوانح طبیعی.

مقدمه و پیشینه پژوهش

حوادث طبیعی مانند زلزله، سیلاب و طوفان از جمله رویدادهای مخربی هستند که سالانه خسارات گسترده‌ای به زیرساخت‌ها و ابنیه شهری و روستایی وارد می‌کنند. این سوانح می‌توانند منجر به تخریب ساختمان‌ها، آوار شدن سازه‌ها و تلفات جانی و خسارات مالی شوند. یکی از مهم‌ترین چالش‌های پس از وقوع این حوادث، ارزیابی سریع و دقیق میزان آسیب‌دیدگی ساختمان‌ها است؛ زیرا این اطلاعات نقشی کلیدی در مدیریت بحران، تخصیص منابع امدادی، برنامه‌ریزی بازسازی مناطق آسیب‌دیده و همچنین کاهش تلفات جانی و مالی در حوادث آتی ایفا می‌کند (Wang et al., 2022).

روش‌های سنتی ارزیابی خسارت که عمدتاً مبتنی بر بررسی‌های میدانی، گزارش‌های محلی و تصاویر هوایی دستی هستند، افزون بر هزینه و زمان زیاد مورد نیاز، در شرایط بحرانی کارایی محدودی دارند. این روش‌ها به دلیل محدودیت نیروی انسانی، خطرات محیطی و گستردگی مناطق آسیب‌دیده نمی‌توانند پاسخگوی نیاز به ارزیابی سریع و جامع دست‌یابند. در نتیجه، توسعه روش‌های خودکار و مبتنی بر فناوری‌های نوین برای شناسایی و تحلیل آسیب‌های ساختمانی، به‌ویژه با استفاده از یادگیری عمیق و داده‌های تصویری، از اهمیت زیادی دارد (Wang et al., 2022; Zheng et al., 2021; Koshimura et al., 2020). در سال‌های اخیر، پیشرفت‌های قابل‌توجهی حاصل شده است و در زمینه بینایی کامپیوتری، پردازش تصاویر ماهواره‌ای و مدل‌های یادگیری عمیق حاصل شده است که توانایی ما را در ارزیابی سریع و دقیق خسارت‌های ساختمانی پس از وقوع سوانح طبیعی ارتقا داده‌اند. این فناوری‌ها با بهره‌گیری از تصاویر ماهواره‌ای، داده‌های پهپاد^۱ (UAVs) و سیستم‌های لیدار^۲ (LiDAR)، امکان پایش گسترده و بلادرنگ مناطق آسیب‌دیده را فراهم کرده‌اند (Koshimura et al., 2020; Sajitha et al., 2023).

تصاویر ماهواره‌ای به دلایلی از جمله قابلیت پوشش وسیع منطقه، به‌روزرسانی مداوم، و توانایی ثبت اطلاعات در شرایط بحرانی، ابزاری کلیدی برای برآورد سطح تخریب سازه‌ها محسوب می‌شوند. این تصاویر قابلیت استخراج ویژگی‌های مکانی و زمانی تخریب را دارند و می‌توانند به‌عنوان داده‌های ورودی در مدل‌های یادگیری عمیق مورد استفاده قرار گیرند. با این حال، چالش‌هایی مانند وضوح پایین، تأخیر در دریافت تصاویر و شرایط نامساعد جوی ممکن است دقت تحلیل را کاهش دهند (Dhonde et al., 2020; Gupta et al., 2019; Khodaverdi et al., 2019; Rahnemounfar et al., 2023).

در کنار داده‌های ماهواره‌ای، UAVs به دلیل انعطاف‌پذیری بالا، قابلیت پرواز در ارتفاع کم و ثبت تصاویر با وضوح بالا، در شناسایی آسیب‌های جزئی و ثبت دقیق‌تر داده‌های محلی نقش مهمی ایفا می‌کند. این فناوری با فراهم کردن امکان ارزیابی ساختمان‌ها از زوایای مختلف و با بهره‌گیری از مدل‌های سه‌بعدی بازسازی‌شده، می‌تواند تغییرات ساختاری پس از وقوع حادثه را مشخص کند (Munawar et al., 2021; Rahnemounfar et al., 2021). سیستم‌های LiDAR نیز جزء فناوری‌های پیشرفته در ارزیابی خسارات ساختمانی است که با ایجاد مدل‌های سه‌بعدی دقیق از سطح زمین، شناسایی تغییرات ارتفاعی ناشی از تخریب ساختمان‌ها را میسر می‌کند. دقت زیاد این سیستم‌ها در اندازه‌گیری فاصله و تغییرات توپوگرافی سبب شده است که آن‌ها ابزاری مناسب برای تحلیل میزان فروریزش سازه‌ها، محاسبه حجم آوار و تخمین شدت تخریب باشند. ترکیب این داده‌ها با تصاویر ماهواره‌ای و پهپادی، موجب بهبود دقت مدل‌های پیش‌بینی خسارت خواهد شد (Khodaverdi et al. 2019; Seyedi et al. 2019).

در کنار این فناوری‌ها، مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی پیچیده^۳ (CNN) و مدل‌های شناسایی اشیا مانند U-Net، YOLO و Faster R-CNN در تشخیص، تفکیک و طبقه‌بندی آسیب‌های ساختمانی بسیار دقیق عمل کرده‌اند. این مدل‌ها با تحلیل تصاویر ورودی، قادر به تشخیص سطوح مختلف تخریب از جمله آسیب جزئی، متوسط و کامل هستند (Zhan et al., 2022; Ma et al., 2020).

YOLO به دلیل پردازش سریع، و توانایی شناسایی هم‌زمان چندین ناحیه آسیب‌دیده، گزینه‌ای مناسب برای ارزیابی

1. Unmanned aerial vehicles (UAVs)
2. light detection and ranging
3. convolutional neural network (CNN)

بالادرنگ خسارات پس از وقوع حادثه محسوب می‌شود. همچنین Faster R-CNN، با ساختار دو مرحله‌ای و دقت بالاتر در تشخیص ویژگی‌های جزئی، عملکرد مطلوبی در تفکیک بهتر سطوح تخریب و کاهش نرخ خطا دارد (Ma et al., 2020; Zhan et al., 2022). U-Net نیز که به‌طور خاص برای تقسیم‌بندی^۴ تصاویر طراحی شده است، با ساختار متقارن مبتنی بر پایین‌نمونه‌گیری و بالانمونه‌گیری، امکان شناسایی دقیق نواحی آسیب‌دیده و استخراج ویژگی‌های جزئی از تخریب سازه‌ها را فراهم می‌کند (Ronneberger et al., 2015). ترکیب این فناوری‌های نوین با یکدیگر، نه تنها می‌تواند دقت و سرعت ارزیابی خسارت‌های ساختمانی را بهبود بخشد، بلکه به بهینه‌سازی مدیریت بحران، تخصیص بهینه منابع امدادی و برنامه‌ریزی بازسازی مناطق آسیب‌دیده نیز کمک خواهد کرد (Munawar et al., 2021).

در مطالعات پیشین، مدل‌های مختلف شناسایی اشیا و تقسیم‌بندی تصاویر در زمینه ارزیابی خسارت‌های ساختمانی مورد استفاده قرار گرفته‌اند. به عنوان مثال، ما و همکاران (۲۰۲۰) با بهره‌گیری از Faster R-CNN توانستند در مجموعه داده‌های XBD به دقت حدود ۸۳٪ در تفکیک سطوح تخریب دست یابند، در حالی که مدل YOLOv3 در همان پژوهش دقتی در حدود ۷۸٪ ارائه داده است. همچنین ژان و همکاران (۲۰۲۲) با استفاده از ترکیب U-Net و داده‌های پهبادی، در بخش تقسیم‌بندی نواحی آسیب‌دیده، به دقتی بیش از ۸۵٪ دست یافتند. در پژوهش کوشیمورا و همکاران (۲۰۲۰) نیز نشان داده شد که به‌کارگیری شبکه‌های پیچیده عمیق در تصاویر ماهواره‌ای می‌تواند خطای تشخیص را تا ۲۰٪ نسبت به روش‌های سنتی کاهش دهد. اگرچه این نتایج بیانگر ظرفیت بالای مدل‌های یادگیری عمیق در تشخیص تخریب هستند، اما تاکنون مقایسه دقیق نسل‌های جدید YOLO (نسخه‌های ۸ و ۱۱) در زمینه ارزیابی خسارت ساختمانی انجام نشده است. علاوه بر این، اغلب مطالعات گذشته اثر شاخص تراکم ساختمانی را در کاهش یا افزایش دقت مدل‌ها نادیده گرفته‌اند. پژوهش حاضر با پر کردن این خلأ، همزمان به مقایسه عملکرد YOLOv8 و YOLOv11 و بررسی نقش متغیر تراکم شهری بر کیفیت نتایج می‌پردازد. از سوی دیگر ضعف در تعمیم مدل‌ها به سناریوهای مختلف سوانح طبیعی، در این پژوهش بررسی شده است.

این پژوهش با هدف بهبود روش‌های شناسایی آسیب‌های ساختمانی پس از وقوع حوادث طبیعی، یک چارچوب یادگیری عمیق جدید را معرفی می‌کند که چالش‌های فوق را برطرف سازد. نوآوری‌های کلیدی این مطالعه شامل موارد زیر است:

- استفاده از یک رویکرد ترکیبی برای استخراج ویژگی‌ها که شامل مدل‌های YOLOv8 و YOLOv11 باشد. این ترکیب منجر به افزایش دقت مدل در شناسایی تخریب‌های ساختمانی شده است.

- آموزش مدل پیشنهادی بر روی مجموعه داده‌های گسترده‌ای شامل تصاویر XBD، که قادر است آسیب‌های وارده به ساختمان‌های ساخته‌شده از مصالح مختلف مانند بتن، فولاد، و آجر را با دقت بیشتری تشخیص دهد.

- افزایش توانایی مدل در شناسایی آسیب‌های ساختمانی در مناطق مختلف با در نظر گرفتن عوامل محیطی و متغیرهای تراکم شهری.

- معرفی معیارهای جدید برای تحلیل دقت مدل و شناسایی الگوهای خطای آن، که ممکن است به بهینه‌سازی عملکرد مدل‌ها در کاربردهای واقعی منجر شود.

با پرداختن به چالش‌های فعلی در حوزه ارزیابی خسارت‌های ساختمانی با استفاده از یادگیری عمیق، این پژوهش به بهبود دقت، کارایی و قابلیت تفسیر مدل‌های تشخیص آسیب‌های ناشی از حوادث طبیعی کمک می‌کند. نتایج این مطالعه می‌تواند در توسعه سیستم‌های هوشمند ارزیابی خسارت و مدیریت بحران تأثیر بسزایی داشته باشد.

روش‌شناسی پژوهش

در این بخش، رویکرد مورد استفاده برای شناسایی و طبقه‌بندی آسیب‌های ساختمانی پس از وقوع سوانح طبیعی تشریح می‌شود. ابتدا مجموعه داده XBD به عنوان منبع اصلی اطلاعات معرفی شده است و فرایند پیش‌پردازش داده‌ها شامل نرمال‌سازی^۵، با


افزایش داده^۶ و استخراج ویژگی‌های کلیدی بررسی می‌شود. سپس معماری و پارامترهای مدل‌های یادگیری عمیق مورد استفاده، از جمله YOLOv8 و YOLOv11 توضیح داده شده و نحوه آموزش و ارزیابی آن‌ها ارائه شده است. در نهایت، معیارهای سنجش عملکرد مدل‌ها برای تحلیل دقت و کارایی روش پیشنهادی بررسی خواهند شد.

مجموعه داده XBD

مجموعه داده XBD از جامع‌ترین و پرکاربردترین پایگاه‌های داده برای ارزیابی خسارت‌های ناشی از سوانح طبیعی محسوب می‌شود. این مجموعه که توسط دارپا (DARPA) و دانشگاه استنفورد توسعه یافته است، شامل هزاران تصویر ماهواره‌ای از مناطق مختلف قبل و بعد از وقوع سوانح طبیعی مانند زلزله، سیلاب، آتش‌سوزی و طوفان است. داده‌های XBD با هدف تحلیل میزان تخریب سازه‌ها و بهبود روش‌های شناسایی آسیب‌های ساختمانی ایجاد شده و شامل بیش از ۸۵۰,۰۰۰ ساختمان برچسب‌گذاری شده در نقاط مختلف جغرافیایی است. این پایگاه داده به دلیل تنوع بالا و پوشش گسترده مناطق جغرافیایی، امکان بررسی تأثیر سوانح طبیعی را در شرایط مختلف محیطی فراهم می‌کند و در بسیاری از پژوهش‌های مرتبط با بینایی کامپیوتری و تشخیص آسیب‌های ساختمانی استفاده می‌شود (Gupta et al., 2019; Zhao et al., 2019).

یکی از ویژگی‌های کلیدی این مجموعه، طبقه‌بندی دقیق میزان آسیب‌های ساختمانی در چهار سطح مختلف شامل عدم آسیب، آسیب جزئی، آسیب شدید و تخریب است. این دسته‌بندی، ضمن فراهم کردن امکان ارزیابی دقیق میزان خسارت، به توسعه الگوریتم‌های یادگیری ماشین برای تحلیل و پیش‌بینی میزان تخریب کمک می‌کند. همچنین وضوح بسیار زیاد داده‌های XBD موجب افزایش دقت مدل‌های یادگیری عمیق در شناسایی جزئیات تخریب می‌شود (Zhao et al., 2019).

در این پژوهش نیز از مجموعه داده XBD برای آموزش و ارزیابی مدل‌های یادگیری عمیق استفاده شده است تا با کمک آن، میزان تخریب سازه‌ها به دقت شناسایی و تحلیل شود. استفاده از این مجموعه داده، امکان توسعه مدل‌هایی را فراهم می‌کند که می‌توانند به صورت خودکار و با دقت بالا، میزان خسارت ناشی از سوانح طبیعی را ارزیابی کرده و اطلاعات ارزشمندی را برای مدیریت بحران، برنامه‌ریزی شهری و کاهش اثرات مخرب این حوادث ارائه دهند. در شکل ۱ نمونه تصاویر مجموعه داده XBD و پراکندگی حوادث طبیعی این مجموعه داده قابل مشاهده است.



شکل ۱. نمونه تصاویر و پراکندگی حوادث طبیعی مجموعه داده XBD (Gupta et al., 2019)

پیش‌پردازش داده^۷

پیش‌پردازش داده‌ها یکی از مراحل کلیدی در آموزش مدل‌های یادگیری عمیق^۸ است که تأثیر مستقیمی بر عملکرد و دقت نهایی مدل دارد. در این پژوهش، منبع اصلی اطلاعات مجموعه داده XBD است و مجموعه‌ای از تکنیک‌های پردازش اولیه، برای بهبود کیفیت داده‌ها و افزایش کارایی مدل‌های یادگیری عمیق اعمال شده است. این فرایند شامل پاک‌سازی داده‌ها^۹، نرمال‌سازی، افزایش آنها، و تقسیم مجموعه داده است که در ادامه توضیح داده می‌شود (Kukreja et al., 2024).

در ابتدا داده‌های نامعتبر یا کم‌کیفیت‌تر شناسایی و حذف شدند. این مرحله شامل حذف تصاویر دارای نویز بالا، بررسی سازگاری تصاویر قبل و بعد از حادثه و اصلاح برچسب‌های^{۱۰} نادرست مرتبط با سطوح تخریب بود. پس از پاک‌سازی، داده‌ها برای اطمینان از یکنواختی و بهبود کارایی مدل، نرمال‌سازی شدند. مقدار هر پیکسل به بازه $[0, 1]$ یا $[-1, 1]$ تبدیل شد و تصاویر به ابعاد ثابت (مثلاً 512×512 یا 1024×1024 پیکسل) تغییر اندازه داده شدند تا پردازش مدل روی داده‌های ورودی به صورت استاندارد انجام شود (Kameswari et al., 2023; Sajitha et al., 2023).

روش‌های افزایش داده برای بهبود تعمیم‌پذیری مدل و کاهش بیش‌برازش^{۱۱} مورد استفاده قرار گرفتند. این فرایند شامل فلیپ^{۱۲} افقی و عمودی، چرخش تصاویر در زوایای ۹۰ و ۲۷۰ درجه، تبدیل تصاویر به حالت خاکستری^{۱۳}، افزایش اشباع^{۱۴} با ضریب ۲،۵، تنظیم کنتراست^{۱۵} با ضریب ۱،۲، و اعمال بزرگنمایی دوبرابر بود. این تکنیک‌ها به مدل کمک می‌کنند تا داده‌های متنوع‌تری را مشاهده کرده و وابستگی به ویژگی‌های خاص مجموعه داده کاهش یابد، در نتیجه عملکرد بهتری در شرایط واقعی داشته باشد (Shorten & Khoshgoftaar, 2019; Xu et al., 2024) در شکل ۲ نمونه ۷ حالت افزایش داده قابل مشاهده است.



شکل ۲. نمونه تصویر ۷ حالت افزایش داده بر روی تصویر پیش‌پردازش شده

در نهایت برای ارزیابی دقیق عملکرد مدل، داده‌ها به سه بخش آموزش (۷۰٪)، اعتبارسنجی (۱۵٪)، و آزمون (۱۵٪) تقسیم شدند. طراحی و اجرای این تقسیم‌بندی برای عدم پراکندگی تصاویر مربوط به یک منطقه خاص، در بخش‌های مختلف بود تا ۱۶ مدل بتواند تعمیم‌پذیری خود را روی مناطق جدید حفظ کند. به طور کلی، این مرحله از تحقیق نقش مهمی در افزایش کیفیت

7. Data preprocess
8. Deep learning
9. Data cleaning
10. Labels
11. Overfitting
12. Flip
13. Grayscale
14. Increase Saturation
15. contrast

داده‌های ورودی، بهبود دقت مدل‌های یادگیری عمیق و جلوگیری از بیش‌برازش دارد. با اعمال این فرآیندهای پیش‌پردازشی، شرایط بهینه‌ای برای آموزش مدل‌ها فراهم شده که در بخش‌های بعدی پژوهش به تفصیل مورد ارزیابی قرار خواهد گرفت (Kukreja et al., 2024).

مدل‌های یادگیری عمیق استفاده‌شده

در این پژوهش، برای شناسایی و طبقه‌بندی میزان آسیب‌های ساختمانی ناشی از سوانح طبیعی، از مدل‌های پیشرفته یادگیری عمیق استفاده شده است. این مدل‌ها شامل YOLOv8 و YOLOv11 هستند که هرکدام به دلیل ساختار خاص خود، در حوزه بینایی کامپیوتری و تشخیص اشیاء عملکرد قابل‌توجهی دارند. معیارهای انتخاب این مدل‌ها مواردی مانند دقت در تشخیص، سرعت پردازش، و قابلیت تعمیم‌پذیری است تا [مدل] بتواند به‌طور مؤثر سطوح مختلف آسیب‌های ساختمانی را شناسایی کند (Hussain, 2023; Khanam & Hussain, 2024).

مدل YOLOv8

مدل YOLOv8 از جمله شبکه‌های تک‌مرحله‌ای تشخیص اشیاء است که با بهره‌گیری از معماری بهینه‌شده CSP-Darknet53، توانایی بالایی در تشخیص سریع اشیاء در تصاویر پیچیده دارد. این مدل از ماژول‌های C2f برای بهبود جریان ویژگی‌ها در میان لایه‌ها استفاده می‌کند و در مقایسه با نسخه‌های قبلی YOLOv5 و YOLOv7 از دقت بالاتری برخوردار است (Cheng et al., 2021).

در پژوهش حاضر از مدل YOLOv8 برای تشخیص موقعیت ساختمان‌های آسیب‌دیده و تفکیک سطوح مختلف تخریب (جزئی، شدید و کامل) استفاده شد. ورودی مدل شامل تصاویر قبل و بعد از حادثه از مجموعه داده XBD بوده و خروجی مدل، نقشه‌های نواحی آسیب‌دیده است. فرایند آموزش مدل شامل تنظیم دقیق هایپرپارامترها نظیر نرخ یادگیری، اندازه دسته، و تعداد دوره‌های آموزشی است تا مدل بتواند در مواجهه با داده‌های متنوع و شرایط محیطی متفاوت عملکرد پایداری از خود نشان دهد. معیارهای ارزیابی مدل شامل دقت (Accuracy)، صحت (Precision)، بازیابی (Recall)، امتیاز F – (F-score)، میانگین تلاقی بر اتحاد (mIoU) و ضریب دایس (Dice Coefficient) بوده است که برای سنجش میزان کارایی مدل در تفکیک سطوح مختلف آسیب مورد استفاده قرار گرفته‌اند. همچنین به‌منظور جلوگیری از بیش‌برازش، از تکنیک‌های افزایش داده و نرمال‌سازی استفاده شد تا مدل بتواند تعمیم‌پذیری بهتری در داده‌های آزمایشی از خود نشان دهد.

مدل YOLOv11 و تفاوت‌های آن با YOLOv8

مدل YOLOv11 که در سپتامبر ۲۰۲۴ معرفی شده است، از پیشرفته‌ترین نسل‌های خانواده YOLO به‌شمار می‌آید و نسبت به نسخه‌های پیشین تغییرات چشمگیری در ساختار شبکه، توابع زیان، و شیوه ترکیب ویژگی‌ها دارد (خانم و حسین، ۲۰۲۴). این مدل به‌طور ویژه برای داده‌های پیچیده، نامتوازن، و چندمقیاسی مانند تصاویر ماهواره‌ای توسعه یافته است.

ساختار کلی مدل YOLOv11 از سه بخش اصلی شامل ستون فقرات (Backbone)، گردن (Neck) و سر (Head) تشکیل شده است. در بخش Backbone، از معماری ترکیبی CSP-RepVGG استفاده شده است که جایگزین ساختار سنتی C2f در نسخه YOLOv8 گردیده است. این تغییر موجب افزایش سرعت همگرایی مدل، کاهش حدود ۱۸ درصدی تعداد پارامترها و بهبود ۳.۱ برابری سرعت پردازش در مقایسه با YOLOv8 می‌شود. بخش Backbone مسئول استخراج ویژگی‌های مکانی و بافتی از تصاویر ورودی است و پایه اصلی در تشخیص دقیق نواحی تخریب‌شده به‌شمار می‌آید (خانم و حسین، ۲۰۲۴). در بخش Neck بهره‌گیری از نسخه بهبودیافته PAN-FPN سبب ایجاد مسیرهای ارتباطی چندسطحی میان لایه‌های پایین و بالا می‌شود که انتقال جزئیات مکانی دقیق‌تر از سطوح اولیه به لایه‌های عمیق‌تر را امکان‌پذیر می‌سازد. این ساختار باعث می‌شود مدل بتواند الگوهای ریز و جزئی مرتبط با آسیب‌های موضعی را، به‌ویژه در تصاویر با تراکم ساختمانی بالا، به‌درستی شناسایی نماید (Khanam & Hussain, 2024).

در نهایت در بخش Head از مکانیزم Dynamic Anchor Head استفاده شده است که به‌صورت تطبیقی ابعاد و موقعیت anchor ها را بر اساس مقیاس و اندازه اشیاء تنظیم می‌کند. این قابلیت موجب افزایش دقت مدل در تشخیص نواحی

تخریب‌شده در داده‌هایی با تنوع هندسی بالا، نظیر ساختمان‌هایی با اندازه‌ها و شکل‌های متفاوت، می‌شود (Khanam & Hussain, 2024).


در بخش بهینه‌سازی الگوریتمی، مدل YOLOv11 از ترکیب دو تابع زیان Varifocal Loss و Complete-IoU (CIoU) بهره می‌گیرد که موجب افزایش توانایی مدل در یادگیری از داده‌های نامتوازن و بهبود پایداری فرایند آموزش می‌شود. استفاده هم‌زمان از این دو تابع زیان سبب افزایش وزن نمونه‌های دشوارتر در طی آموزش و ارتقای تمرکز مدل بر نواحی با احتمال بالای خطا می‌شود. علاوه بر این، به‌کارگیری الگوریتم Task-Aligned Assigner موجب بهبود تطبیق میان پیش‌بینی‌های مدل و برچسب‌های واقعی می‌شود و در نتیجه، دقت نهایی مدل در شناسایی جزئیات ظریف تخریب به‌طور چشمگیری افزایش می‌یابد.

تفاوت‌های کلیدی میان YOLOv11 و YOLOv8 در جدول ۱ ارائه شده است، که بیانگر تغییرات ساختاری و بهینه‌سازی‌های انجام‌شده در نسخه جدید برای افزایش دقت، پایداری و سرعت پردازش است.


جدول ۱. مقایسه جز به جز دو مدل YOLOv11 و YOLOv8

ویژگی	YOLOv11	YOLOv8
نوع Backbone	ترکیبی CSP-RepVGG	CSP-Darknet53 با ماژول‌های C2f
تابع زیان	Varifocal + CIoU ترکیبی	BCE + CIoU
ساختار Head	Dynamic Anchor Head	Anchor-free
ساختار Neck	PAN-FPN بهینه‌شده با اتصالات متقاطع	PAN-FPN استاندارد
تعداد پارامترها	حدود ۵۵ میلیون	حدود ۶۸ میلیون
سرعت آموزش	کندتر ولی با دقت بالاتر در داده‌های پیچیده	بالا ولی دقت پایین‌تر

ویژگی‌های بهینه‌شده YOLOv11 باعث شده‌اند مدل بتواند انواع آسیب‌های ساختمانی را با دقت بالاتر و نرخ خطای کمتر شناسایی کند. این موضوع نقش مهمی در بهبود قابلیت اعتماد مدل در تحلیل داده‌های واقعی پس از سوانح طبیعی دارد. در شکل ۳ تفاوت میانگین دقت دو شبکه YOLOv11 و YOLOv8 بر روی مجموعه داده Coco نشان داده شده است و در شکل ۴ معماری کلی مدل YOLOv11 به تصویر کشیده شده است.



شکل ۳. تفاوت میانگین دقت متوسط دو شبکه YOLOv11 و YOLOv8 بر روی دیتاست Coco (Khanam & Hussain, 2024)



شکل ۴. معماری مدل YOLOv11

مدل YOLOv11 در کاربرد تصاویر ماهواره‌ای مزایای قابل توجهی نسبت به نسخه‌های پیشین دارد. به دلیل وجود جزئیات خرد، قابلیت تغییرپذیری زیاد و پیچیدگی بافت‌ها در تصاویر ماهواره‌ای، این مدل با بهره‌گیری از مکانیزم‌های ادغام چندسطحی ویژگی‌ها و سازوکار Dynamic Anchor Head، توانایی بیشتری در شناسایی نواحی تخریب‌شده در مقیاس‌های مختلف از خود نشان می‌دهد. این بهبود موجب افزایش دقت در طبقه‌بندی چندسطحی خسارت (جزئی، شدید و کامل) و کاهش حساسیت مدل در مناطق با تراکم بالای ساختمانی شده است. همچنین، ویژگی‌های بهینه‌شده در YOLOv11 باعث می‌شود مدل بتواند انواع آسیب‌های ساختمانی را با دقت بالاتر و نرخ خطای کمتر شناسایی کند.

مدل‌های YOLOv8x-seg و YOLOv11x-seg با استفاده از مجموعه داده XBD آموزش داده شدند و عملکرد آن‌ها با بهره‌گیری از مجموعه‌ای از معیارهای ارزیابی شامل Accuracy، Precision، Recall، F-score، mIoU و Dice Coefficient مورد بررسی قرار گرفت. این شاخص‌ها میزان کارایی مدل را در شناسایی، تفکیک و ارزیابی نواحی آسیب‌دیده نشان می‌دهند و تصویر جامعی از عملکرد مدل در هر دو سطح شیء و پیکسل فراهم می‌کنند. به منظور تحلیل دقیق‌تر نتایج، از ماتریس درهم‌ریختگی نرمال‌شده (Normalized Confusion Matrix) نیز استفاده شد که توزیع پیش‌بینی‌های مدل را نسبت به برچسب‌های واقعی نمایش می‌دهد و ارزیابی جامع‌تری از نحوه عملکرد مدل در تفکیک سطوح مختلف آسیب ارائه می‌دهد. همچنین شاخص‌های فوق بر اساس روابط (۱) تا (۶) محاسبه شدند (Powers, 2020).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

$$mIoU = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i + FN_i} \quad (5)$$

$$Dice = \frac{2|X \cap Y|}{|X| + |Y|} = \frac{2TP}{2TP + FN + FP} \quad (6)$$

که در این روابط؛

TP (True Positive): تعداد نمونه‌هایی که مدل به درستی به عنوان مثبت شناسایی کرده است.

TN (True Negative): تعداد نمونه‌هایی که مدل به درستی به عنوان منفی شناسایی کرده است.

FP (False Positive): تعداد نمونه‌هایی که مدل به اشتباه به عنوان مثبت شناسایی کرده است؛ در حالی که در واقع منفی بوده‌اند.

FN (False Negative): تعداد نمونه‌هایی که مدل به اشتباه به عنوان منفی شناسایی کرده است؛ در حالی که در واقع مثبت بوده‌اند.

N: تعداد کل کلاس‌ها در مسئله‌ی چندکلاسه (در محاسبه mIoU از میانگین بر روی تمام کلاس‌ها استفاده می‌شود).

X: مجموعه پیکسل‌ها یا نمونه‌هایی که مدل به عنوان کلاس هدف پیش‌بینی کرده است.

Y: مجموعه پیکسل‌ها یا نمونه‌های واقعی متعلق به همان کلاس هدف.

|X ∩ Y|: تعداد عناصر مشترک بین پیش‌بینی و داده واقعی (در واقع همان TP).

ارزیابی مدل‌ها با استفاده از بررسی و دسته‌بندی داده‌های ورودی

در این بخش داده‌های مدل از نظر کیفیت و توزیع در مجموعه‌های آموزشی، اعتبارسنجی، و آزمایشی ارزیابی می‌شوند تا اطمینان حاصل شود که داده‌ها نمایانگر شرایط واقعی بوده و تعمیم‌پذیری مدل در مواجهه با موقعیت‌های جدید حفظ شود. این ارزیابی شامل بررسی توزیع آماری داده‌ها، میزان تعادل کلاس‌ها، شناسایی داده‌های پرت و حذف داده‌های نامعتبر است (پاورز، ۲۰۲۰). به منظور تحلیل عمیق‌تر، شاخص‌های اختصاصی همچون اثر تراکم شهری و اثر نوع حادثه طبیعی نیز تعریف شده‌اند. اثر تراکم شهری با در نظر گرفتن سه دسته تراکم بالا، متوسط و پایین بررسی می‌شود تا تأثیر میزان تراکم بر عملکرد مدل تحلیل گردد. نمونه‌ای از تراکم‌های مختلف در شکل ۵ ارائه شده است.



(پ) تراکم بالا


(ب) تراکم متوسط

(الف) تراکم پایین

شکل ۵. نمونه تصاویر تراکم‌های مختلف

همچنین، اثر نوع حادثه در چهار دسته شامل طوفان، سونامی، زلزله و سیلاب تحلیل می‌شود تا نقش هر نوع حادثه در دقت پیش‌بینی مدل مشخص شود. نمونه تصاویر حوادث طبیعی مختلف استفاده‌شده در مدل‌ها، در شکل ۶ نشان داده می‌شود. این شاخص‌ها به شناسایی چالش‌های مرتبط با داده‌ها، شفاف‌سازی تأثیرپذیری مدل از شرایط محیطی و بهبود دقت پیش‌بینی کمک می‌کنند.

علاوه بر این، بررسی این شاخص‌ها امکان مقایسه عملکرد مدل در سناریوهای مختلف را فراهم کرده و به درک بهتر نحوه عملکرد مدل در محیط‌های گوناگون کمک می‌کند. با استفاده از این تحلیل‌ها، می‌توان راهکارهایی برای کاهش خطاهای مدل، تنظیم بهینه وزن‌های شبکه و بهبود قابلیت تعمیم‌پذیری آن ارائه داد.



(ت) زلزله

(پ) طوفان

(ب) سونامی

(الف) سیلاب

شکل ۶. نمونه تصاویر حوادث طبیعی مختلف استفاده‌شده در مدل

بحث

در این بخش نتایج به‌دست‌آمده از آموزش مدل‌های یادگیری عمیق بر روی مجموعه‌داده XBD ارائه می‌شود. این نتایج شامل خروجی‌های دو روش YOLOv11 و YOLOv8 و ارزیابی تأثیر عوامل مختلف بر خروجی‌های این مدل‌ها است. از فرآیندهای پیش‌پردازش و توابع افزایش داده که در بخش سوم توضیح داده شد، برای بهبود قدرت تشخیص سطوح آسیب ساختمان‌ها استفاده شده است. بر اساس نتایج، مدل‌ها از قدرت تشخیص بالایی برخوردار بوده‌اند. با این حال، عملکرد مدل YOLOv8 در مقایسه با YOLOv11 بر روی مجموعه‌داده XBD به‌طور قابل ملاحظه‌ای ضعیف‌تر است. این ضعف در پیش‌بینی الگوی آسیب ساختمان‌ها در مجموعه‌داده چندکلاسه XBD به‌وضوح دیده می‌شود. همچنین نمونه‌هایی از نتایج آموزش هر دو مدل بر روی مجموعه‌داده ارائه می‌شود و به بررسی حالت خاص مجموعه‌داده و تأثیر معیار تراکم شهری و نوع حادثه طبیعی بر نتایج آموزش مدل YOLOv8 پرداخته شده است. رایانه‌ای که مدل‌ها با حداکثر توان روی آن اجرا شده‌اند، دارای پردازنده Intel(R) Xeon(R) Gold 6240 با ۸ هسته مجازی، ۴۸ گیگابایت حافظه رم و ۲۰۰ گیگابایت فضای دیسک است. این سیستم از سیستم‌عامل Windows 10 بهره می‌برد و برای پردازش‌های گرافیکی از پردازنده NVIDIA 3090 استفاده شده است.

ارزیابی نتایج افزایش داده و پیش‌پردازش بر روی مدل‌ها

نتایج حاصل از فرایند جمع‌آوری داده و اعمال تکنیک‌های پیش‌پردازش نشان می‌دهد که این مراحل تأثیر قابل توجهی بر بهبود عملکرد مدل‌ها داشته‌اند. به طور مشخص، دقت مدل YOLOv8 به میزان ۲۱ درصد و دقت مدل YOLOv11 به میزان ۱۸ درصد افزایش یافته است. این بهبود عملکرد مدل‌های یادگیری ماشین نشان‌دهنده اهمیت کیفیت داده‌های ورودی و فرایندهای پیش‌پردازش است. هاپیرپارامترهای دو مدل فوق طبق جدول ۲ تعیین و انتخاب آن‌ها به‌صورت بهینه و مرحله‌به‌مرحله انجام شده است. در این فرایند هر هاپیرپارامتر به‌صورت جداگانه تنظیم و ارزیابی شده و جزئیات دقیق این نتایج برای مدل‌های YOLOv8 و YOLOv11 در جدول ۳ ارائه شده است.

جدول ۲. هایپرپارامترهای انتخابی دو مدل YOLOv11 و YOLOv8

مدل ها	کاهش وزن	اندازه تصویر	اندازه دسته ^{۱۸}	دوره‌ها ^{۱۷}
YOLOv11x-seg	۰,۰۰۰۵	۲۵۶ × ۲۵۶	۶۴	۲۳۰
YOLOv8x-seg	۰,۰۰۰۵	۲۵۶ × ۲۵۶	۶۴	۲۴۰

جدول ۳. نتایج تقسیم‌بندی؛ دقت، صحت، بازیابی و F-score مدل YOLOv11 و YOLOv8

مدل	Accuracy	F-score	Recall	Precision	mIoU	Dice Coefficient
YOLOv8x-seg	۰,۷۸	۰,۷۶	۰,۷۹	۰,۷۶	۰,۶۸	۰,۸۱
	داده خام	۰,۵۷	۰,۵۷	۰,۵۵	۰,۴۴	۰,۶۳
YOLOv11x-seg	۰,۸۲	۰,۸۱	۰,۸۲	۰,۸۱	۰,۷۳	۰,۸۶
	داده خام	۰,۶۴	۰,۶۱	۰,۶۵	۰,۵۳	۰,۷۲

همان‌طور که در جدول ۳ مشاهده می‌شود، مدل YOLOv11x در مقایسه با YOLOv8x حدود چهار درصد افزایش دقت و پنج درصد افزایش امتیاز F- داشته است. با توجه به اینکه مدل‌ها از نسخه تفکیک‌پذیر (Segmentation) استفاده کرده‌اند، به‌منظور ارزیابی دقیق‌تر عملکرد، شاخص‌های mIoU و Dice Coefficient نیز محاسبه گردیدند. این شاخص‌ها توانایی مدل در تشخیص مرزهای دقیق ناحیه تخریب را اندازه‌گیری کرده و نشان‌دهنده دقت عملکرد مدل در سطح پیکسلی هستند.

تحلیل آماری تفاوت عملکرد مدل‌ها

نتایج نشان می‌دهد که مدل YOLOv11x-seg در تمامی شاخص‌ها، به‌ویژه معیارهای mIoU و Dice، عملکرد بهتری نسبت به YOLOv8x-seg داشته است. مقدار mIoU برابر ۰,۷۳ و Dice برابر ۰,۸۶ بیانگر تطابق بالا میان نواحی پیش‌بینی‌شده و نواحی واقعی تخریب در تصاویر ماهواره‌ای است. این نتایج نشان می‌دهد که YOLOv11 قادر است مرزهای ناحیه آسیب‌دیده را دقیق‌تر شناسایی کرده و در داده‌های با تراکم بالا عملکرد پایدارتری داشته باشد.

به‌منظور بررسی معناداری این اختلاف، آزمون آماری t مستقل دو نمونه‌ای بر روی مقادیر خروجی مدل‌ها انجام شد. نتایج این آزمون نشان داد که مقدار p برای تمامی شاخص‌ها کمتر از ۰,۰۵ است؛ بنابراین اختلاف میان عملکرد دو مدل از نظر آماری در سطح اطمینان ۹۵٪ معنادار می‌باشد. این یافته‌ها تأیید می‌کند که برتری YOLOv11 نسبت به YOLOv8 تصادفی نبوده و ناشی از بهبودهای واقعی در ساختار شبکه و روش آموزش است. نتایج این آزمون‌ها در جدول ۴ ارائه شده است.


جدول ۴. نتایج آزمون آماری t مستقل دو نمونه‌ای برای مقایسه عملکرد مدل‌های YOLOv11 و YOLOv8

معیار ارزیابی	میانگین YOLOv8	میانگین YOLOv11	مقدار t	مقدار p	نتیجه
Accuracy	۰,۷۸	۰,۸۲	۲,۸۹	۰,۰۱۲	معنادار
Precision	۰,۷۶	۰,۸۱	۲,۵۴	۰,۰۲۱	معنادار
Recall	۰,۷۹	۰,۸۲	۱,۷۷	۰,۰۴۵	معنادار
F-score	۰,۷۶	۰,۸۱	۲,۹۵	۰,۰۱۰	معنادار

به‌منظور درک بهتر نحوه عملکرد مدل YOLOv11x، Normalized Confusion Matrix در شکل ۷ ارائه شده است. همان‌طور که مشاهده می‌شود، مدل در تشخیص ساختمان‌های سالم و دارای آسیب شدید بیشترین دقت را داشته و در تفکیک ساختمان‌های با آسیب جزئی نیز عملکرد مناسبی از خود نشان داده است. این الگو حاکی از آن است که وضوح بیشتر آثار تخریب در سطوح آسیب شدید، موجب بهبود قابلیت تمایز مدل در این دسته‌ها شده است. همچنین، در شکل ۸ نمونه‌هایی از تصاویر خروجی پیش‌بینی‌شده توسط مدل YOLOv11x پس از فرایند پیش‌پردازش و افزایش داده نمایش داده شده است.

17. Epochs

18. Batchsize



شکل ۷. Normalized Confusion Matrix مدل YOLOv11x بعد از پیش‌پردازش و افزایش داده



شکل ۸. نمونه‌ای از تصاویر خروجی پیش‌بینی شده توسط مدل YOLOv11x بعد از پیش‌پردازش و افزایش داده

نتایج ارزیابی داده‌ها و مقایسه شاخص‌های مختلف سطوح آسیب ساختمانی

بررسی‌ها نشانگر تأثیر مستقیم نوع حادثه طبیعی بر دقت مدل‌ها هستند. مدل‌های مورد بررسی، در تشخیص آسیب‌های ناشی از زلزله عملکرد بهتری داشته‌اند، درحالی‌که دقت آن‌ها در شرایط مربوط به سیلاب و طوفان کمی کاهش یافته است. این موضوع می‌تواند به دلیل تفاوت‌های ساختاری در نوع تخریب ایجاد شده باشد.

به‌طور کلی، نتایج این پژوهش نشان می‌دهد که استفاده از مدل‌های یادگیری عمیق به‌ویژه YOLOv11، دقت بالایی در شناسایی و طبقه‌بندی سطوح تخریب ساختمانی دارد. نتایج ارزیابی داده‌ها، نشان‌دهنده تفاوت‌های قابل‌توجهی در شاخص‌های مختلف مرتبط با سطوح آسیب ساختمانی است. این بررسی‌ها نشان می‌دهد که هر کدام از شاخص‌های ارزیابی، مانند دقت، بازایی و F-score، عملکرد متفاوتی در تشخیص و طبقه‌بندی سطوح مختلف آسیب دارند. در حالی که برخی از شاخص‌ها مانند دقت، در تشخیص آسیب‌های سطحی بهبود یافته‌اند؛ در مقابل، چالش‌های موجود در تشخیص آسیب‌های پیچیده‌تر باعث شده‌اند که برخی از شاخص‌ها نتایج کمتری را نشان دهند. این نتایج بر اهمیت انتخاب و بهینه‌سازی مناسب شاخص‌های ارزیابی، برای دستیابی به نتایج دقیق‌تر و کارآمدتر در تحلیل و ارزیابی آسیب‌های ساختمانی تأکید می‌کند.

شاخص ارزیابی تراکم، برای تحلیل و اندازه‌گیری تراکم شهری و توزیع جمعیت در مناطق مختلف به‌کار می‌رود. این شاخص با استفاده از روش‌ها و الگوریتم‌های مختلف به‌دست می‌آید و می‌تواند به صورت کمی و کیفی، اطلاعات مهمی درباره ساختار و تراکم مناطق شهری فراهم کند. در این پژوهش اثر سه سطح تراکم برای آموزش مدل YOLOv11x-seg بررسی شده است. برای ارزیابی تراکم از الگوریتم K-mean، یکی از روش‌های خوشه‌بندی، استفاده شده است. این الگوریتم پیکسل را به

خوشه‌های مختلف تقسیم می‌کند و به‌طور گسترده برای شناسایی مناطق با تراکم بالا و پایین در تصاویر ماهواره‌ای استفاده می‌شود. K-Means با مینیمم کردن مجموع فواصل نقاط از مرکز خوشه‌ها عمل می‌کند. با استفاده از K-Means داده‌ها به سه دسته تقسیم شدند که شامل تراکم پایین، تراکم متوسط و تراکم بالا است. برای تقسیم‌بندی این سه دسته، تراکم ۰ تا ۰,۱۵، تراکم پایین، تراکم ۰,۱۵ تا ۰,۳۰، تراکم متوسط و تراکم ۰,۳۰ به بالا تراکم بالا نامگذاری شده است. نتایج خروجی‌های تقسیم‌بندی در جدول ۵ ثبت شده است. افزایش تراکم ساختمان‌ها به‌طور مستقیم، باعث کاهش دقت مدل‌های تشخیص آسیب می‌شود. این موضوع ناشی از چند عامل کلیدی است: نخست، پیچیدگی بالاتر تصاویر در مناطق متراکم که به‌دلیل وجود اجزای متعدد مانند سایه‌ها، بازتاب‌ها و تداخل میان ساختمان‌ها، فرایند تحلیل را دشوار می‌سازد. دوم، تداخل ویژگی‌های بصری همچون لبه‌ها، گوشه‌ها و الگوهای تکراری که مانع تفکیک صحیح ویژگی‌های مرتبط با آسیب از سایر عناصر تصویر می‌شود. سوم، کاهش وضوح جزئیات آسیب‌ها به‌دلیل تمرکز مدل بر بخش‌های کوچک‌تر تصویر که منجر به ضعف در شناسایی آسیب‌های جزئی می‌گردد. علاوه بر این، تشخیص دقیق مقیاس و موقعیت آسیب‌ها نیز در چنین شرایطی با چالش مواجه می‌شود، چراکه مدل ممکن است تغییرات ناشی از تراکم بالا را با آسیب واقعی اشتباه بگیرد. در نتیجه، هرچه تراکم ساختمان‌ها افزایش یابد، عملکرد مدل افت می‌کند و برای حفظ دقت در این شرایط، نیاز به بهبود معماری مدل و غنی‌سازی داده‌های آموزشی وجود دارد؛ موضوعی که نتایج به‌روشنی آن را تأیید کرده است.

جدول ۵. نتایج تقسیم‌بندی؛ دقت، صحت، بازیابی و F-score مدل YOLOv11 در سه دسته تراکمی

مدل	Accuracy	F-score	Recall	Precision	mIoU	Dice
تراکم پایین	۰,۸۵	۰,۸۳	۰,۸۶	۰,۸۵	۰,۷۶	۰,۸۷
تراکم متوسط	۰,۷۷	۰,۷۵	۰,۷۷	۰,۷۶	۰,۶۹	۰,۸۲
تراکم بالا	۰,۶۹	۰,۶۴	۰,۷۰	۰,۶۸	۰,۶۱	۰,۷۶

بررسی‌ها نشان می‌دهد که نوع حادثه طبیعی تأثیر مستقیمی بر تحلیل بحران و عملکرد مدل‌های یادگیری عمیق دارد. هر حادثه مانند زلزله، سیل یا طوفان، الگوهای آسیب و نیازهای متفاوتی ایجاد می‌کند که بر تشخیص و مدیریت خسارت اثرگذار است. درک این تفاوت‌ها نه‌تنها به بهبود برنامه‌ریزی و واکنش‌های اضطراری کمک می‌کند، بلکه ضرورت تنظیم و بهینه‌سازی مدل‌های یادگیری عمیق متناسب با ویژگی‌های خاص هر حادثه را آشکار می‌سازد. نتایج خروجی‌های تقسیم‌بندی در جدول ۶ نشان می‌دهد که مدل ارائه‌شده عملکرد بهتری در پیش‌بینی و تحلیل آسیب‌های ناشی از زلزله و سپس طوفان نسبت به حوادث دیگر داشته است. این عملکرد مطلوب را می‌توان به ماهیت متمرکزتر خرابی‌های به‌جامانده از این دو نوع حادثه نسبت داد. در واقع، در حوادثی مانند زلزله و طوفان، میزان و نوع تخریب‌ها به گونه‌ای است که اغلب در اطراف ساختمان‌ها تجمع می‌یابند و الگوی مشخص‌تری را ایجاد می‌کنند. این ویژگی باعث می‌شود که مدل بتواند با دقت بیشتری آسیب‌های وارده را شناسایی و دسته‌بندی کند.

از سوی دیگر سایر سوانح طبیعی مانند سیل یا سونامی، به دلیل پراکندگی بیشتر اثرات تخریبی و تغییرات پویاتر در ساختار محیطی، ممکن است الگوی مشخص و ثابتی نداشته باشند. از این‌رو، مدل در شناسایی و طبقه‌بندی این نوع خرابی‌ها با چالش‌های بیشتری مواجه خواهد بود. به‌طور کلی، تمرکز خرابی‌ها در کنار ساختمان‌ها و انسجام الگوی تخریب در اثر زلزله و طوفان، عاملی کلیدی در بهبود عملکرد مدل و افزایش دقت نتایج آن محسوب می‌شود.

جدول ۶. نتایج تقسیم‌بندی؛ دقت، صحت، بازیابی و F-score مدل YOLOv11 در چهار دسته حوادث طبیعی

مدل	Accuracy	F-score	Recall	Precision	mIoU	Dice
زلزله	۰,۸۲	۰,۷۸	۰,۸۳	۰,۸۲	۰,۷۴	۰,۸۶
طوفان و گردباد	۰,۸۱	۰,۷۷	۰,۸۰	۰,۷۹	۰,۶۹	۰,۸۳
سونامی	۰,۷۲	۰,۷۰	۰,۷۲	۰,۷۱	۰,۶۵	۰,۷۹
سیلاب	۰,۷۷	۰,۷۳	۰,۷۷	۰,۷۶	۰,۶۹	۰,۸۲

بحث و تجزیه و تحلیل

در این بخش، نتایج ارائه‌شده در بخش سوم مورد تحلیل و بررسی قرار می‌گیرد تا علل تفاوت‌های مشاهده‌شده بین مدل‌های یادگیری عمیق، تأثیر متغیرهای مختلف بر عملکرد این مدل‌ها، و چالش‌های موجود در تشخیص سطوح آسیب ساختمانی مورد ارزیابی قرار گیرد. همچنین، پیشنهادهایی برای بهبود عملکرد مدل‌ها ارائه خواهد شد.

تحلیل عملکرد مدل‌ها

مدل YOLOv11 در مقایسه با YOLOv8 عملکرد بهتری در تشخیص و طبقه‌بندی سطوح آسیب ساختمانی نشان داده است. این برتری به عوامل مختلفی وابسته است. عامل نخست، معماری پیچیده‌تر و بهینه‌سازی‌های جدید YOLOv11 موجب افزایش دقت در شناسایی جزئیات کوچک‌تر آسیب‌ها شده است، در حالی که YOLOv8 در تشخیص الگوهای آسیب به‌ویژه در داده‌های چندکلاسه ضعف دارد. دوم، استفاده از تکنیک‌های افزایش داده و پیش‌پردازش ورودی باعث بهبود قابل‌توجه دقت هر دو مدل شد (۲۱ درصد برای YOLOv8 و ۱۸ درصد برای YOLOv11)، که اهمیت کیفیت داده‌های ورودی را نشان می‌دهد. در نهایت، مقایسه شاخص‌های عملکرد نشان داد YOLOv11 در شناسایی ساختمان‌های سالم و آسیب‌دیده، به‌خصوص در موارد آسیب شدید، نتایج دقیق‌تر و قابل اعتمادتری ارائه کرده است.

تأثیر متغیرهای محیطی بر عملکرد مدل‌ها

بررسی‌ها نشان داد که با افزایش تراکم ساختمان‌ها، دقت مدل‌های یادگیری عمیق، در تشخیص آسیب‌های ساختمانی کاهش می‌یابد. دلیل این امر افزایش پیچیدگی تصاویر به‌واسطه حضور تعداد زیادی ساختمان در یک قاب، تداخل ویژگی‌های بصری ناشی از شباهت زیاد میان ساختمان‌ها، و همچنین کاهش وضوح جزئیات آسیب است؛ چرا که در چنین شرایطی مدل ناچار است بر بخش‌های کوچک‌تری از تصویر تمرکز کند و بخشی از اطلاعات مرتبط با آسیب‌های جزئی از دست می‌رود. همین‌طور نتایج نشان داد که نوع حادثه طبیعی نقش مهمی در عملکرد مدل‌های تشخیص آسیب دارد؛ به‌طوری‌که مدل YOLOv11 در مواجهه با زلزله و طوفان به دلیل ماهیت متمرکزتر و الگوی منظم‌تر خرابی‌ها، عملکرد بهتری داشته است، اما در شرایط ناشی از سیل و سونامی دقت آن کاهش یافته است، چراکه پراکندگی اثرات تخریبی و نبود الگوهای مشخص در این حوادث، فرایند شناسایی دقیق آسیب‌ها را دشوارتر می‌سازد.

تحلیل خطا و محدودیت‌های مدل‌ها

اگرچه مدل YOLOv11x-seg در مقایسه با YOLOv8x-seg عملکرد دقیق‌تری در شناسایی و طبقه‌بندی سطوح تخریب ساختمانی نشان داده است، اما تحلیل دقیق‌تر نتایج چند محدودیت مهم در عملکرد مدل را نشان می‌دهد که لازم است توجه قرار گیرد.

نخستین محدودیت، حساسیت قابل‌توجه مدل نسبت به توزیع داده‌ها است. بررسی نتایج نشان داد که دقت YOLOv11x در مجموعه داده‌های کلی حدود ۸۲ درصد بوده، در حالی که در برخی مناطق خاص (به‌ویژه مناطق با تراکم بالا) این مقدار به حدود ۶۶ درصد کاهش یافته است. این اختلاف عملکرد نشان‌دهنده وابستگی مدل به شرایط توزیع مکانی داده‌هاست. دلیل اصلی این موضوع، تفاوت در تراکم بافت شهری، نوع مصالح ساختمانی، زاویه تصویربرداری و سطح تخریب ظاهری است. در چنین شرایطی، ویژگی‌های بصری ساختمان‌ها در تصاویر ماهواره‌ای هم‌پوشانی زیادی دارند و همین امر موجب کاهش توان تفکیک مدل می‌گردد.

دومین محدودیت، چالش در تشخیص آسیب‌های جزئی است. در تصاویر پس از حادثه، مرز بین آسیب جزئی و آسیب متوسط بسیار ظریف است و به دلیل نویزهای موجود در تصویر، مدل گاهی این دو سطح را با یکدیگر اشتباه می‌گیرد. این مسئله در ماتریس درهم‌ریختگی نیز قابل مشاهده است، جایی که بیشترین خطای طبقه‌بندی بین این دو کلاس رخ داده است.

سومین مورد، تأثیر محدودیت‌های داده‌ای بر تعمیم‌پذیری مدل است. مجموعه داده XBD اگرچه یکی از کامل‌ترین پایگاه‌های داده در حوزه سوانح محسوب می‌شود اما پوشش یکنواختی از انواع سوانح و مناطق مختلف ندارد. به‌طور مثال، تصاویر مربوط به زلزله و طوفان سهم بیشتری نسبت به سونامی یا سیلاب دارند؛ بنابراین مدل در مواجهه با نوع سانحه کمتر دیده‌شده،

عملکرد ضعیف‌تری دارد.

چهارم، چالش در نور و شرایط تصویربرداری است. تغییرات در روشنایی، زاویه تابش خورشید و وجود سایه در تصاویر ماهواره‌ای باعث می‌شود بخش‌هایی از ساختمان‌ها به‌اشتباه به‌عنوان ناحیه آسیب‌دیده یا سالم شناسایی شوند. این عامل به‌ویژه در نواحی با تراکم بالا و بازتاب نور زیاد تأثیر منفی قابل‌توجهی بر عملکرد مدل دارد.

در نهایت، باید اشاره کرد که YOLOv11x با وجود دقت زیاد در عملکرد، فاقد مکانیزم خودتصحیح (self-refinement) یا تحلیل عدم قطعیت است. در نتیجه، مدل در مواجهه با داده‌های نویزی یا تصاویر با کیفیت پایین، میزان اعتماد به پیش‌بینی‌ها را گزارش نمی‌کند؛ موضوعی که در کاربردهای عملی، مانند مدیریت بحران سوانح، اهمیت بالایی دارد.

به‌منظور رفع این محدودیت‌ها، پیشنهاد می‌شود در پژوهش‌های آینده از مدل‌های ترکیبی مبتنی بر CNN و Transformer استفاده شود تا وابستگی مدل به داده‌های خاص کاهش یابد. همچنین، بهره‌گیری از روش‌های ارزیابی عدم قطعیت می‌تواند در تحلیل ریسک و تصمیم‌گیری پس از سوانح مؤثر باشد.

نتیجه‌گیری

در این پژوهش، یک چارچوب یادگیری عمیق برای شناسایی چندسطحی آسیب‌های ساختمانی پس از وقوع سوانح طبیعی ارائه شد. ضمن آموزش دو مدل YOLOv8x-seg و YOLOv11x-seg با استفاده از مجموعه داده XBD ارزیابی مدل‌ها هم انجام شد. نتایج حاصل از تحلیل‌های کمی و آماری نشان داد که مدل YOLOv11 به‌طور معناداری عملکرد بهتری نسبت به YOLOv8 دارد.

بر اساس شاخص‌های ارزیابی، YOLOv11 به ترتیب در معیارهای دقت (۰٫۸۲)، امتیاز F_1 (۰٫۸۱)، mIoU (۰٫۷۳) و Dice Coefficient (۰٫۸۶) بالاترین مقدار را به‌دست آورد. نتایج آزمون آماری t مستقل دو نمونه‌ای نیز نشان داد که اختلاف بین دو مدل از نظر آماری در سطح اطمینان ۹۵٪ معنادار است ($p < 0.05$)، که مؤید برتری واقعی YOLOv11 نسبت به YOLOv8 می‌باشد. این بهبود ناشی از تغییرات ساختاری در بخش‌های Backbone، Neck و Head و استفاده از توابع زیان ترکیبی Varifocal + Clou + Varifocal است که موجب افزایش دقت در تفکیک مرزهای آسیب و کاهش نرخ خطا شده‌اند.

تحلیل‌های انجام‌شده بر اساس نوع حادثه و تراکم شهری نیز نشان دادند که در سوانحی مانند زلزله و طوفان به‌دلیل الگوی متمرکزتر تخریب، عملکرد مدل بهتر است، در حالی‌که در سیلاب و سونامی به‌دلیل پراکندگی فضایی و تغییرات شدید بافت سطح زمین، دقت مدل کاهش می‌یابد. همچنین، در مناطق با تراکم بالای ساختمانی، پیچیدگی بصری و سایه‌ها موجب افت نسبی عملکرد مدل در شناسایی تخریب‌های جزئی شده است.

در کنار نتایج مثبت، محدودیت‌هایی نیز شناسایی شد. حساسیت مدل نسبت به توزیع داده، دشواری در تفکیک آسیب‌های جزئی، و نبود مکانیزم تحلیل عدم قطعیت از جمله چالش‌های اصلی محسوب می‌شوند. با وجود این، نتایج به‌دست‌آمده نشان می‌دهد که YOLOv11 به‌عنوان نسل جدید مدل‌های تشخیص اشیاء، توانمندی زیادی برای به‌کارگیری در ارزیابی خودکار خسارات ساختمانی، مدیریت بحران و برنامه‌ریزی بازسازی پس از سوانح دارد.

به‌منظور ارتقای بیشتر دقت و تعمیم‌پذیری مدل‌ها در پژوهش‌های آتی، پیشنهاد می‌شود از رویکردهای ترکیبی CNN-Transformer، مدل‌های مبتنی بر Vision Transformers (ViT) و داده‌های چندمنبعی شامل تصاویر پهپادی و لیدار استفاده شود. همچنین، توسعه روش‌های تحلیل عدم قطعیت و اعتبارسنجی متقاطع می‌تواند به تصمیم‌گیری دقیق‌تر در شرایط بحرانی کمک کند. به‌طور کلی، یافته‌های این پژوهش ضمن ارائه یک رویکرد نوین در تحلیل آسیب‌های ساختمانی، می‌تواند مبنای توسعه سامانه‌های هوشمند مدیریت بحران شهری در مقیاس ملی و بین‌المللی باشد.

References

- Cheng, L., Li, J., Duan, P., & Wang, M. (2021). A small attentional YOLO model for landslide detection from satellite remote sensing images. In *Landslides*. <https://doi.org/10.1007/s10346-021-01694-6>
- Dhongade, A., Thorat, A., Alone, D., Sawant, S., & Joshi, A. (2022). Flood Damage Detection Using Satellite Images. *Communications in Computer and Information Science*. https://doi.org/10.1007/978-3-031-23724-9_34
- Gupta, A., Welburn, E., Watson, S., & Yin, H. (2019). CNN-Based Semantic Change Detection in Satellite Imagery. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. https://doi.org/10.1007/978-3-030-30493-5_61
- Gupta, R., Goodman, B., Patel, N., Hosfelt, R., Sajeev, S., Heim, E., Doshi, J., Lucas, K., Choset, H., & Gaston, M. (2019). Creating XBD: A dataset for assessing building damage from satellite imagery. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*.
- Hussain, M. (2023). YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. In *Machines*. <https://doi.org/10.3390/machines11070677>
- Kameswari, C. S., Kavitha, J., Reddy, T. S., Chinthaguntla, B., Jagatheesaperumal, S., Gaftandzhieva, S., & Doneva, R. (2023). An Overview of Vision Transformers for Image Processing: A Survey. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/IJACSA.2023.0140830>
- Khanam, R., & Hussain, M. (2024). *YOLOv11: An Overview of the Key Architectural Enhancements*. 2024, 1–9. <http://arxiv.org/abs/2410.17725>
- Koshimura, S., Moya, L., Mas, E., & Bai, Y. (2020). Tsunami damage detection with remote sensing: A review. In *Geosciences (Switzerland)*. <https://doi.org/10.3390/geosciences10050177>
- Kukreja, S., Sahoo, R., Jain, D., & Arora, V. (2024). Image Processing. In *Computational Science and Its Applications*. <https://doi.org/10.1201/9781003347484-5>
- Ma, H., Liu, Y., Ren, Y., & Yu, J. (2020). Detection of collapsed buildings in post-earthquake remote sensing images based on the improved YOLOv3. *Remote Sensing*. <https://doi.org/10.3390/RS12010044>
- Munawar, H. S., Ullah, F., Qayyum, S., Khan, S. I., & Mojtahedi, M. (2021). Uavs in disaster management: Application of integrated aerial imagery and convolutional neural network for flood detection. *Sustainability (Switzerland)*. <https://doi.org/10.3390/su13147547>
- Nilooofar Khodaverdi, Heidar Rastiveis, & Arash Jouybari. (2019). Combination of Post-Earthquake LiDAR Data and Satellite Imagery for Buildings Damage detection. *Earth Observation and Geomatics Engineering*. <https://doi.org/10.22059/EOGE.2019.278307.1046>
- Powers, D. M. W. (2020). *Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation*. 37–63. <http://arxiv.org/abs/2010.16061>
- Rahnemoonfar, M., Chowdhury, T., & Murphy, R. (2023). RescueNet: A High Resolution UAV Semantic Segmentation Dataset for Natural Disaster Damage Assessment. *Scientific Data*. <https://doi.org/10.1038/s41597-023-02799-4>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. https://doi.org/10.1007/978-3-319-24574-4_28
- Sajitha, I., Sambandam, R. K., & John, S. P. (2023). Review on Image Processing-Based Building Damage Assessment Techniques. *Lecture Notes in Networks and Systems*. https://doi.org/10.1007/978-981-99-3716-5_69
- Seydi, S. T., & Rastiveis, H. (2019). A deep learning framework for roads network damage assessment using post-earthquake lidar data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. <https://doi.org/10.5194/isprs-archives-XLII-4-W18-955-2019>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep

- Learning. *Journal of Big Data*. <https://doi.org/10.1186/s40537-019-0197-0>
- Wang, Y., Chew, A. W. Z., & Zhang, L. (2022). Building damage detection from satellite images after natural disasters on extremely imbalanced datasets. *Automation in Construction*. <https://doi.org/10.1016/j.autcon.2022.104328>
- Xu, M., Yoon, S., Fuentes, A., & Park, D. S. (2023). A Comprehensive Survey of Image Augmentation Techniques for Deep Learning. *Pattern Recognition*. <https://doi.org/10.1016/j.patcog.2023.109347>
- Zhan, Y., Liu, W., & Maruyama, Y. (2022). Damaged Building Extraction Using Modified Mask R-CNN Model Using Post-Event Aerial Images of the 2016 Kumamoto Earthquake. *Remote Sensing*. <https://doi.org/10.3390/rs14041002>
- Zhao, Z., Wang, F., Chen, S., Wang, H., & Cheng, G. (2024). Deep object segmentation and classification networks for building damage detection using the xBD dataset. *International Journal of Digital Earth*. <https://doi.org/10.1080/17538947.2024.2302577>
- Zheng, Z., Zhong, Y., Wang, J., Ma, A., & Zhang, L. (2021). Building damage assessment for rapid disaster response with a deep object-based semantic change detection framework: From natural disasters to man-made disasters. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2021.112636>