

Accepted Manuscript

Accepted Manuscript (Uncorrected Proof)

Title: Development of an Intelligent Building Damage Assessment Model Using Deep Learning and Attention Mechanism

Authors: Nasrin Alvani¹, Seyed Enayatallah Alavi^{1,*}

1. *Department of Computer Engineering, Faculty of Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran*

To appear in: **Disaster Prevention and Management Knowledge**

Received date: 2025/09/9

Accepted date: 2026/01/7

First Online Published: 2026/10/04

This is a “Just Accepted” manuscript, which has been examined by the peer-review process and has been accepted for publication. A “Just Accepted” manuscript is published online shortly after its acceptance, which is prior to technical editing and formatting and author proofing. Archives of Rehabilitation provides “Just Accepted” as an optional service which allows authors to make their results available to the research community as soon as possible after acceptance. After a manuscript has been technically edited and formatted, it will be removed from the “Just Accepted” Website and published as a published article. Please note that technical editing may introduce minor changes to the manuscript text and/or graphics which may affect the content, and all legal disclaimers that apply to the journal pertain.

Please cite this article as:

Alvani, N., & Alavi, S. E. [Development of an Intelligent Building Damage Assessment Model Using Deep Learning and Attention Mechanism]. Disaster Prevention and Management Knowledge. Forthcoming 2026.

نسخه پذیرفته شده پیش از انتشار

عنوان: توسعه مدل ارزیابی هوشمند آسیب ساختمان‌ها با استفاده از یادگیری عمیق و مکانیزم توجه

نویسندگان: نسرين علوانی^۱، سید عنایت اله علوی^{۱*}

۱. گروه کامپیوتر، دانشکده مهندسی، دانشگاه شهید چمران اهواز، اهواز، ایران.

نشریه: دانش پیشگیری و مدیریت بحران

تاریخ دریافت: 1404/6/18

تاریخ پذیرش: 1404/10/17

تاریخ انتشار اولیه: 1405/07/12

این نسخه «پذیرفته‌شده پیش از انتشار» مقاله است که پس از طی فرایند داوری، برای چاپ، قابل پذیرش تشخیص داده شده است. این نسخه در مدت کوتاهی پس از اعلام پذیرش به صورت آنلاین و قبل از فرایند ویراستاری منتشر می‌شود. نشریه آرشیو توانبخشی گزینه «پذیرفته‌شده پیش از انتشار» را به عنوان خدمتی به نویسندگان ارائه می‌دهد تا نتایج آن‌ها در سریع‌ترین زمان ممکن پس از پذیرش برای جامعه علمی در دسترس باشد. پس از آنکه مقاله‌ای فرایند آماده سازی و انتشار نهایی را طی می‌کند، از نسخه «پذیرفته‌شده پیش از انتشار» خارج و در یک شماره مشخص در وبسایت نشریه منتشر می‌شود. شایان ذکر است صفحه آرای و ویراستاری فنی باعث ایجاد تغییرات صوری در متن مقاله می‌شود که ممکن است بر محتوای آن تأثیر بگذارد و این امر از حیطه مسئولیت دفتر نشریه خارج است.

لطفا این گونه استناد شود:

Alvani, N., & Alavi, S. E. [Development of an Intelligent Building Damage Assessment Model Using Deep Learning and Attention Mechanism]. Disaster Prevention and Management Knowledge. Forthcoming 2026.

Abstract:

Background and Aims : Natural disasters and military attacks can cause widespread destruction to buildings, making rapid and accurate damage assessment crucial for reducing casualties and speeding up rescue operations . • This study aims to present a novel method for assessing building damage using deep learning and image processing techniques.

Methodology : This research introduces a new method based on an encoder-decoder architecture that combines the **DeepLabV3** +model with a **self-attention mechanism** .The **xBD dataset** ,which contains pre- and post-disaster images from various incidents, was used to train and evaluate the model.

Findings : The proposed model successfully classified buildings into four damage levels: "no damage," "minor damage," "major damage," and "destroyed ."It achieved superior results compared to previous methods with an overall F1-Score of 0.94.

Conclusion and Innovation : The primary innovation of this research lies in the simultaneous use of DeepLabV3+ capabilities, the attention mechanism, and data augmentation techniques, which significantly improved detection accuracy .The method can be applied in natural disaster management as well as in passive defense and military scenarios to quickly assess damage from attacks.

Keywords: *Building Damage, DeepLabV3+ Network, Multiclass Segmentation, UNet Network, Remote Sensing, Self-Attention Mechanism*

چکیده

زمینه و هدف: بلایای طبیعی و حملات نظامی می‌توانند باعث تخریب گسترده ساختمان‌ها شوند. ارزیابی سریع و دقیق آسیب ساختمان‌ها برای کاهش تلفات و تسریع عملیات امداد و نجات حیاتی است. این پژوهش باهدف ارائه یک روش نوین برای ارزیابی آسیب ساختمان‌ها با استفاده از تکنیک‌های یادگیری عمیق و پردازش تصویر انجام شده است.

روش‌شناسی: در این تحقیق، روشی نوین مبتنی بر معماری رمزگذار-رمزگشا ارائه شده که مدل DeepLabV3+ را با مکانیزم خود توجهی ترکیب می‌کند. برای آموزش و ارزیابی این مدل، از مجموعه داده xBD که شامل تصاویر قبل و بعد از حوادث طبیعی مختلف است، استفاده شده است.

یافته‌ها: مدل پیشنهادی توانست ساختمان‌ها را در چهار سطح «سالم»، «آسیب کم»، «آسیب زیاد» و «تخریب‌شده» طبقه‌بندی کند. نتایج نشان داد که این مدل با کسب معیار F1 کلی معادل ۰.۹۴، عملکردی برتر نسبت به روش‌های پیشین دارد.


نتیجه‌گیری و نوآوری: نوآوری اصلی این پژوهش در استفاده هم‌زمان از قابلیت‌های DeepLabV3+، مکانیزم توجه و تکنیک‌های افزایش داده برای ارتقای چشمگیر دقت تشخیص است. این روش علاوه بر مدیریت بحران‌های طبیعی، می‌تواند در حوزه پدافند غیرعامل و سناریوهای نظامی - دفاعی نیز برای ارزیابی سریع خسارات ناشی از حملات مورد استفاده قرار گیرد.

کلیدواژه‌ها: آسیب ساختمان، شبکه DeepLabV3+، بخش‌بندی چند کلاسی، شبکه UNet، سنجش‌ازدور، مکانیزم خود توجهی

۱- مقدمه

ارزیابی سریع و دقیق آسیب ساختمان‌ها پس از بلایای طبیعی، برای ارائه یک واکنش کارآمد و کمک‌رسانی فوری در شرایط بحرانی، بسیار حیاتی است. به‌منظور مقابله با این چالش، تکنیک بخش‌بندی تصویر به‌عنوان یک راهکار مؤثر موردتوجه قرار گرفته است. در این بخش، روش‌های پیشنهادی برای بخش‌بندی تصاویر باهدف تخمین میزان آسیب ساختمان‌ها پس از حوادث طبیعی به‌تفصیل تشریح می‌شوند. این پژوهش رویکردی نوین را برای بخش‌بندی تصاویر باهدف ارزیابی خسارات وارده به ساختمان‌ها معرفی می‌کند این رویکرد از تکنیک‌های یادگیری عمیق و پردازش تصویر بهره می‌برد تا به نتایجی دقیق و قابل‌اعتماد دست یابد. این روش پیشنهادی شامل سه مرحله اصلی است که در شکل ۱ نمایش داده شده است.

- پیش‌پردازش داده‌ها
- بخش‌بندی تصاویر
- طبقه‌بندی تصاویر



شکل (۱)- شمای کلی معماری مدل پیشنهادی که مبتنی بر شبکه DeepLabV3+ به عنوان استخراج‌کننده ویژگی است. بخش اصلی شامل مکانیزم توجه است که به منظور افزایش تمرکز بر ویژگی‌های محلی و مرزی خسارت، به ساختار اصلی مدل اضافه شده است.

- **پیش‌پردازش داده‌ها:** در این مرحله، داده‌های اولیه به فرمتی مناسب برای آموزش مدل تبدیل می‌شوند. همچنین، تکنیک‌های افزایش داده به کار گرفته می‌شوند تا حجم داده‌های آموزشی کافی برای مدل فراهم گردد.
- **بخش‌بندی تصویر:** شبکه‌های عصبی کانولوشن مانند ResNet101 و U-Net برای استخراج ویژگی‌های متنوع از تصاویر استفاده می‌شوند. استفاده از ماژول ASPP به مدل این امکان را می‌دهد که ویژگی‌های چند مقیاسی را بهتر تشخیص دهد که منجر به بخش‌بندی دقیق‌تر می‌شود.
- **طبقه‌بندی تصویر:** در نهایت، مدل یک نقشه خروجی تولید می‌کند که در آن هر پیکسل به یکی از چهار سطح آسیب‌دیدگی ساختمان‌ها (سالم، آسیب کم، آسیب زیاد، تخریب‌شده) اختصاص داده می‌شود.

۲- مرور کارهای گذشته

ارزیابی آسیب ساختمان‌ها پس از بلایای طبیعی، از بازرسی‌های میدانی که هم زمان‌بر و هم خطرناک هستند، به سمت روش‌های خودکار مبتنی بر یادگیری عمیق و سنجش‌ازدور پیشرفت کرده است. این نوآوری‌ها با فراهم‌آوردن اطلاعات دقیق و به‌موقع در مورد میزان خسارت، پتانسیل زیادی برای متحول کردن فرآیندهای امداد و بازسازی دارند. پژوهش‌های گوناگونی برای حل چالش‌های این حوزه صورت گرفته که برخی از آن‌ها عبارتند از:

- **مدل‌های بر پایه Siamese:** تحقیقاتی مانند (Xiao, et al., 2021) و (Wu, et al., 2021) کارایی شبکه‌های Siamese را در مقایسه تصاویر قبل و بعد از حادثه اثبات کرده‌اند. این شبکه‌ها قادرند به‌صورت هم‌زمان، موقعیت ساختمان‌ها را شناسایی کرده و میزان آسیب آن‌ها را مشخص کنند. با این حال، همان‌طور که در مقاله (Wu, et al., 2021) ذکر شده، میدان دید این شبکه‌ها ممکن است محدود باشد که بر ارزیابی آسیب تأثیرگذار است.
- **معماری U-Net:** معماری U-Net به دلیل توانایی‌اش در تحلیل بافت و جزئیات، به‌طور گسترده‌ای در ارزیابی خسارت ساختمان‌ها مورد استفاده قرار گرفته است. برای مثال، مقاله (Wu, et al., 2021) نیز از این معماری به همراه مکانیزم توجه برای تشخیص آسیب بهره برده است.
- **مکانیزم توجه (Attention Mechanism):** این مکانیزم برای افزایش کارایی مدل‌های یادگیری عمیق به کار می‌رود. پژوهش‌هایی مانند (Shen, et al., 2022) و (Liu, et al., 2022) از مکانیزم‌های توجه برای بالابردن دقت مدل‌ها در شناسایی آسیب ساختمان‌ها استفاده کرده‌اند. با توجه به مرور پژوهش‌های قبلی، همچنان نیاز به روش‌هایی با دقت بالاتر و قابلیت تعمیم‌پذیری بیشتر احساس می‌شود. این پژوهش با ارائه یک مدل جدید، در صدد پاسخ به این نیاز است. برای بررسی دقیق‌تر، برخی از روش‌های پیشین در جدول ۱ ارزیابی شده‌اند.

جدول (۱) بررسی برخی روش‌های پیشین

مرجع سال	هدف	روش	مجموعه داده	سنجه‌ها	مزایا	معایب
(Da, Ji, & Zhou, 2022)	ارزیابی آسیب ساختمان‌ها	Siamese Hierarchical Transformer	xBD	F1	نتایج نسبتاً مناسب	عدم تعادل در میزان داده‌های آموزشی حوادث مختلف
(Yang, Zhang, & Luo, 2021)	ارزیابی و طبقه‌بندی میزان آسیب ساختمان‌ها	CNN	xBD, Wenchuan Earthquake, Wenchuan, Beichuan	Accuracy, F1, Kappa	ارائه مدل با قابلیت تعمیم	ارزیابی یک حادثه
Amezquita-) Sanchez, Park, & Adeli, 2017	طبقه‌بندی میزان آسیب ساختمان‌ها	Attention based Deep Learning	xBD, 2010 Haiti earthquake	F1	ارائه مجموعه داده جدید که در ۴ سطح آسیب ساختمان‌ها را طبقه‌بندی کرده است.	عدم گزارش دقیق سنجه‌ها
(Bandara & Patel, 2022)	ارزیابی و طبقه‌بندی میزان آسیب ساختمان‌ها	Pyramid Pooling Module based Semi Siamese	xBD	F1	ارائه مدل با قابلیت تعمیم	عدم تعادل در میزان داده‌های آموزشی حوادث مختلف
(Liu, et al., 2022)	ارزیابی و طبقه‌بندی میزان آسیب ساختمان‌ها	U-Net with Attention Mechanism	xBD	F1	ارائه مدل با قابلیت تعمیم	عدم تعادل در میزان داده‌های آموزشی حوادث مختلف
(Bai, et al., 2020)	ارزیابی و طبقه‌بندی میزان آسیب ساختمان‌ها	Improved U-Net	xBD	F1	ارزیابی بلایای طبیعی مختلف	عدم تعادل در میزان داده‌های آموزشی حوادث مختلف
(Zhou, Dong, & Wang, 2022)	تشخیص تغییر مناطقی که به‌تازگی ساخته شده‌اند	STANET-BASE, STANET-BAM, STANET-PAM, SNUNET, BiT	Gf_2 Image	F1	بررسی شبکه‌های مختلف	ارزیابی تنها یک منطقه محدود

۳. روش‌شناسی

مدل DeepLabv3+ یک ابزار قدرتمند در حوزه **یادگیری عمیق** برای بخش‌بندی تصاویر به حساب می‌آید. برای افزایش کارایی این مدل در تشخیص آسیب‌های ساختمانی، می‌توان آن را با معماری‌های دیگر مانند **U-Net** ترکیب کرد تا جزئیات بهتری شناسایی شوند، یا از

مکانیزم‌های توجه استفاده نمود تا مدل بر نواحی مهم تصویر تمرکز بیشتری داشته باشد. در نهایت، با تلفیق این روش‌ها، می‌توان دقت و کارآمدی مدل DeepLabv3+ را در تشخیص آسیب‌های ساختمان به شکل چشمگیری بهبود بخشید.

روش پیشنهادی این پژوهش در سه مرحله اصلی اجرا می‌شود. در گام نخست، تصویر پیش از وقوع حادثه مورد پیش‌پردازش قرار گرفته و برای بخش‌بندی ساختمان‌ها به شبکه داده می‌شود تا محل دقیق آن‌ها مشخص گردد. سپس، تصاویر پس از حادثه نیز پس از پیش‌پردازش به‌عنوان ورودی به شبکه وارد می‌شوند. در این مرحله، وزن‌هایی که از مرحله بخش‌بندی به دست آمده‌اند، به شبکه منتقل می‌شوند تا مجدداً آموزش ببینند و میزان آسیب ساختمان‌ها را تخمین بزنند.

۱-۳- پیش‌پردازش داده‌ها

در مسائل یادگیری عمیق، پیش‌پردازش داده‌ها یک مرحله بسیار مهم است. این فرآیند در بخش‌بندی تصویر، داده‌های خام را به فرمتی تبدیل می‌کند که برای آموزش مدل مناسب باشد.

- **ایجاد تصاویر ماسک:** تصاویر ماسک در مجموعه داده‌ها ممکن است در فرمت‌های مختلفی باشند و لازم است به فرمتی تبدیل شوند که شبکه بتواند از آن‌ها استفاده کند.
- **افزایش داده:** به دلیل عدم توازن در تعداد نمونه‌های هر کلاس یا کمبود داده‌های آموزشی، نیاز به افزایش تعداد داده‌ها در کلاس‌ها وجود دارد. به همین دلیل، از تکنیک‌های مختلفی مانند چرخش و برش بر روی تصاویر و ماسک‌ها برای افزایش داده استفاده می‌شود.

۲-۳- بخش‌بندی

بخش‌بندی دقیق ساختمان‌ها در تصاویر هوایی، مرحله‌ای بسیار مهم در ارزیابی آسیب‌های پس از وقوع یک حادثه است. هدف اصلی در این مرحله، جداسازی دقیق ساختمان‌ها از سایر عناصر موجود در تصویر با استفاده از تصاویر پیش از حادثه است.

در این پژوهش، برای این منظور دو شبکه معرفی شده‌اند که قادرند الگوهای بصری پیچیده را بیاموزند و مرزهای ساختمان‌ها را با دقت بسیار بالایی شناسایی کنند. پس از انجام بخش‌بندی، اطلاعات مربوط به مکان و ابعاد هر ساختمان به دست می‌آید و برای پردازش‌های بعدی مورد استفاده قرار می‌گیرد.

۲-۳- طبقه‌بندی


پس از اینکه ساختمان‌ها در تصاویر هوایی پیش از حادثه با دقت شناسایی و بخش‌بندی شدند، مرحله حیاتی تخمین میزان آسیب به آن‌ها آغاز می‌شود. در این مرحله، مدل دوباره آموزش می‌بیند تا با استفاده از تصاویر پس از حادثه، تغییراتی که در ساختمان‌ها رخ داده است را تشخیص دهد. این تغییرات می‌توانند شامل تخریب جزئی، ریزش کامل، یا آسیب‌های کم باشند. در پایان، نتایج به شکل یک نقشه آسیب نمایش داده می‌شود که در آن، هر ساختمان با یک رنگ خاص میزان آسیب وارد شده به آن را نشان می‌دهد.

۴-۳- شبکه DeepLabV3+ با مکانیزم خودتوجهی

شبکه پیشنهادی یک مدل پیشرفته است، DeepLabv3+ را با مکانیزم خود توجهی ترکیب کرده است. این مدل از ویژگی‌های معنایی سطح بالا و جزئیات فضایی سطح پایین ResNet استفاده می‌کند و همچنین به کمک ماژول ASPP، قادر به استخراج ویژگی‌های چند مقیاسی است تا بتواند روی ویژگی‌های مهم تمرکز کند.

- **مکانیزم خود توجهی:** این بخش نوآوری جدیدی است که در مدل‌های DeepLabv3+ به صورت معمول وجود ندارد. این ماژول باعث می‌شود که شبکه توجه بیشتری به بخش‌های مهم تصویر داشته باشد که در نتیجه به نتایج بخش‌بندی دقیق‌تری منجر می‌شود.
- **معماری پیشنهادی:** در این معماری، از یک شبکه عصبی کانولوشنی از پیش آموزش‌دیده ResNet_101 به‌عنوان هسته اصلی برای استخراج ویژگی‌های معنایی و جزئیات دقیق‌تر استفاده می‌شود.

ماژول ASPP که بر روی خروجی ResNet اعمال می‌شود، از چهار پیچش آتروس با نرخ‌های گسترش (۱، ۶، ۱۲ و ۱۸) بهره می‌برد. خروجی ماژول ASPP سپس برای هم‌اندازه شدن با ویژگی‌های سطح پایین ResNet، نمونه‌برداری بالایی می‌شود. این خروجی به ماژول توجه فرستاده می‌شود تا برای بخش‌بندی بهتر، بر روی بخش‌های مرتبط نقشه ویژگی‌ها متمرکز شود^۸. سپس این ویژگی‌ها به یکدیگر متصل شده و از طریق یک لایه کانولوشن ۳×۳ و سپس یک مرحله نمونه‌برداری بالا دیگر پردازش می‌شوند^۹. در نهایت، یک لایه کانولوشن ۱×۱، احتمال کلاس هر پیکسل را پیش‌بینی می‌کند. معماری این شبکه در شکل ۲ قابل مشاهده است.



شکل (۲): معماری شبکه DeeplabV3+ با مکانیزم خودتوجه



شکل (۳): نمونه‌هایی از تصاویر مجموعه داده مرجع xBD برای ارزیابی خسارت ساختمان‌ها. این تصاویر شامل حالت‌های 'قبل از حادثه' و 'بعد از حادثه' هستند که به صورت جفت ارائه شده‌اند. ماسک‌های سگمنتیشن نشان‌دهنده چهار رده خسارت تعریف‌شده (شامل بدون آسیب، آسیب کم، آسیب زیاد و تخریب کامل) هستند که در فاز آموزش و ارزیابی مدل به کار رفته‌اند.

۴- نتایج و تحلیل

در این بخش، عملکرد مدل پیشنهادی برای ارزیابی آسیب ساختمان‌ها، با استفاده از مجموعه داده xBD بررسی و با سایر مدل‌ها مقایسه شده است. برای این ارزیابی، از معیارهای استاندارد مانند **Intersection over Union (IoU)** و **F1-Score**، **Recall**، **Precision** استفاده شده است.

۴-۱- مجموعه داده

مجموعه داده‌ای که در این پژوهش استفاده شده، **مجموعه داده xBD** است. این مجموعه در سال ۲۰۱۹ برای رقابت‌های **xView2** معرفی شد و شامل تصاویر قبل و بعد از چندین حادثه طبیعی در سراسر جهان است. این حوادث شامل فوران آتشفشان، طوفان، زلزله، سیل، سونامی و آتش‌سوزی هستند.

هر تصویر در این مجموعه دارای ابعاد 1024×1024 پیکسل است. کارشناسان کمیته برگزارکننده چالش **xView2** میزان آسیب هر ساختمان را در چهار سطح دسته‌بندی کرده‌اند: تخریب‌شده^۱، آسیب فراوان^۲، آسیب کم^۳ و آسیب ندیده^۴. نمونه‌هایی از تصاویر قبل و بعد از حادثه در این مجموعه داده در شکل ۳ نشان داده شده است. همان‌طور که ذکر شد، این مجموعه داده انواع مختلفی از بلایای طبیعی را در بر می‌گیرد که در جدول ۲ فهرست شده‌اند. سهم هر یک از این حوادث از کل تصاویر نیز در شکل ۴ نشان داده شده است.

جدول (۲): - حوادث موجود در مجموعه داده

محل حادثه	تعداد تصاویر (بعد از حادثه)	حوادث
آمریکا	۱۴۸	گردباد جاپلین ^۵
آمریکا	۱۸۳	آتش‌فشان پونا ^۶
آمریکا	۷۰۰	آتش‌سوزی در جنوب کالیفرنیا ^۷
آمریکا	۲۲۲	گردباد مور ^۸
اندونزی	۱۹۳	سونامی پالو ^۹
آمریکا	۴۹۲	طوفان هاروی ^{۱۰}
آمریکا	۳۹۲	سیل در بخش میانی غرب آمریکا ^{۱۱}
گوآتمالا	۲۷	آتش‌فشان گوآتمالا ^{۱۲}
آمریکا	۵۲۰	طوفان فلورانس ^{۱۳}
آمریکا	۳۷۹	طوفان متیو ^{۱۴}
آمریکا	۵۳۴	طوفان مایکل ^{۱۵}
مکزیک	۱۹۳	زلزله مکزیک ^{۱۶}
آمریکا	۳۶۸	آتش‌سوزی سانتا روزا ^{۱۷}
نیپال	۵۷۶	سیل نیپال ^{۱۸}
استرالیا	۴۷۹	آتش‌سوزی پینری ^{۱۹}
پرتغال	۹۷۵	آتش‌سوزی پرتغال ^{۲۰}
اندونزی	۱۰۵	سونامی سوندا ^{۲۱}
آمریکا	۸	گردباد توسکالووسا ^{۲۲}

¹ destroyed

² Major damage

³ Minor damage

⁴ No damage

⁵ joplin-tornado

⁶ lower-puna-volcano

⁷ Socal-fire

⁸ moore-tornado

⁹ palu-tsunami

¹⁰ hurricane-harvey

¹¹ midwest-flooding

¹² guatemala-volcano

¹³ hurricane-florence

¹⁴ hurricane-matthew

¹⁵ hurricane-michael

¹⁶ mexico-earthquake

¹⁷ santa-rosa-wildfire


¹⁸ nepal-flooding

¹⁹ pinery-bushfire

²⁰ portugal-wildfire

²¹ sunda-tsunami

²² tuscaloosa-tornado



شکل (۴): سهم هر یک از حوادث از تعداد کل تصاویر xBD

این مجموعه داده شامل ۱۲۹۸۸ تصویر از قبل و بعد از حوادث طبیعی است. در این پژوهش، تلاش بر این بوده که برای ارزیابی میزان آسیب ساختمان‌ها، نیازی به تصاویر قبل از حادثه نباشد. به همین منظور، از تصاویر قبل از حادثه تنها برای آموزش اولیه مدل‌ها استفاده شده تا محل قرارگیری ساختمان‌ها را بیاموزند. سپس، با انتقال وزن‌ها، مدل برای تخمین میزان آسیب هر ساختمان آموزش داده شده است. در این تحقیق، تصاویر با نسبت ۸۰:۲۰ به ترتیب برای آموزش و آزمایش مورد استفاده قرار گرفتند. همچنین، ۱۰ درصد از داده‌های آموزشی به صورت تصادفی برای اعتبارسنجی اختصاص یافت.

۴-۲- معیارهای ارزیابی

برای ارزیابی کیفیت نتایج بخش‌بندی، از معیارهای مختلفی استفاده می‌شود. در این پژوهش نیز برخی از معیارهای رایج به کار گرفته شده‌اند که در ادامه توضیح داده می‌شوند.

- **تابع هزینه Dice:** این تابع میزان شباهت بین دو مجموعه را اندازه‌گیری می‌کند. در این پژوهش، این دو مجموعه شامل ماسک‌های بخش‌بندی پیش‌بینی شده و ماسک‌های واقعی هستند. فرمول ریاضی این تابع به شکل زیر است:

$$Dice\ loss = 1 - (2 * |A \cap B|) / (|A| + |B|) \quad (1)$$

که در آن A ماسک پیش‌بینی شده، B ماسک واقعی، $|A|$ اندازه مجموعه A ، $|B|$ اندازه مجموعه B و $|A \cap B|$ عملگر اشتراک هستند (Goodfellow, Bengio, & Courville, 2016).

تابع دایس مقداری بین ۰ و ۱ دارد. مقدار صفر (۰) نشان‌دهنده همپوشانی کامل بین ماسک پیش‌بینی شده و ماسک واقعی است. درحالی‌که مقدار یک (۱) به معنای عدم همپوشانی است. این تابع به طور مؤثر با داده‌های نامتوازن سروکار دارد و نسبت به تغییرات جزئی در ماسک‌های بخش‌بندی حساس‌تر از سایر معیارها عمل می‌کند.

- **اشتراک بر اجتماع^۱ (IoU)**

IoU همچنین به عنوان شاخص جاکارد شناخته می‌شود. یک معیار محبوب برای ارزیابی تقسیم‌بندی تصویر است. این معیار همپوشانی بین ماسک‌های پیش‌بینی شده و واقعی را نسبت به اجتماع آنها اندازه‌گیری می‌کند.

فرمول IoU به صورت زیر است:

$$IoU = |A \cap B| / |A \cup B| \quad (2)$$

¹ Intersection Over Union

که در آن A ماسک تقسیم‌بندی پیش‌بینی شده و B ماسک واقعی است. IoU نیز بین ۰ تا ۱ متغیر است. مقدار ۰ نشان دهنده عدم همپوشانی و مقدار ۱ نشان دهنده همپوشانی کامل است. این تابع نسبت به عدم تعادل کلاس‌ها حساس است.

• F1Score

ماتریس اغتشاش^۱ یک ابزار بصری است که در یادگیری ماشین برای ارزیابی عملکرد مدل‌های طبقه‌بندی استفاده می‌شود. این ماتریس یک نمایش جدولی از پیش‌بینی‌های انجام‌شده توسط یک مدل در برابر برچسب‌های حقیقت زمینی واقعی را ارائه می‌دهد.

- **مثبت واقعی**^۲ (TP): نمونه‌های مثبت که مدل به درستی آنها را مثبت پیش‌بینی کرده است.
- **مثبت کاذب**^۳ (FP): نمونه‌های منفی که مدل به اشتباه آنها را مثبت پیش‌بینی کرده است.
- **منفی کاذب**^۴ (FN): نمونه‌های مثبت که مدل به اشتباه آنها را منفی پیش‌بینی کرده است.
- **منفی واقعی**^۵ (TN): نمونه‌های منفی که مدل به درستی آنها را منفی پیش‌بینی کرده است.

صحت^۶ و پوشش^۷ معیارهایی هستند که معمولاً در وظایف طبقه‌بندی استفاده می‌شوند. آنها همچنین می‌توانند برای تقسیم‌بندی تصویر اعمال شوند. صحت تعداد نتایج مثبت واقعی تقسیم بر تعداد کل نتایج مثبت است. صحت نشان می‌دهد که از بین نتایج مثبت پیش‌بینی شده، چند مورد واقعاً مثبت هستند. به عبارت دیگر، چقدر دقیق مدل توانسته است نمونه‌های مثبت را شناسایی کند (Wu, et al., 2021).

$$precision = TP / (TP + FP) \quad (۳)$$

پوشش به عنوان حساسیت یا نرخ مثبت واقعی شناخته می‌شود، تعداد نتایج مثبت واقعی تقسیم بر تعداد کل نمونه‌هایی که باید به عنوان مثبت شناسایی می‌شدند. پوشش نشان می‌دهد که از بین نمونه‌های واقعی مثبت، چند مورد توسط مدل به درستی شناسایی شده‌اند. به عبارت دیگر، مدل چقدر در تشخیص نمونه‌های مثبت حساس بوده است (Wu, et al., 2021).

$$recall = TP / (TP + FN) \quad (۴)$$

صحت و پوشش برای دریافت تعادل بین مثبت‌های کاذب و منفی‌های کاذب استفاده می‌شوند و معیار F1 تعادلی بین این دو معیار است.

$$F1_{loc} = 2 * (precision * recall) / (precision + recall) \quad (۵)$$

در این پژوهش، برای سنجش دقت مدل مرحله دوم نیز، از معیار ارزیابی F1 استفاده شده است. سطوح آسیب ساختمان‌ها به چهار دسته تقسیم شده‌اند. برای محاسبه دقیق‌تر عملکرد مدل در تشخیص این سطوح، امتیازهای F1 به صورت میانگین وزنی محاسبه شده‌اند. به عبارت دیگر، به هر دسته از آسیب، وزنی متناسب با اهمیت آن داده شده است. فرمول دقیق این محاسبه به صورت زیر است:

$$F1_{cls} = \frac{4}{\sum_{l=0}^n \left(\frac{1}{F1_{cls}^l + \epsilon} \right)} \quad (۶)$$

برای ارزیابی کلی عملکرد مدل، از روشی مشابه مسابقه Xview2 استفاده شده است. در این روش، دو معیار اصلی $F1_{cls}$ و $F1_{loc}$ به صورت جداگانه محاسبه شده و سپس باتوجه به اهمیت هر کدام، به صورت وزنی ترکیب می‌شوند تا امتیاز نهایی $F1_{overall}$ به دست آید همچنین پارامتر اپسیلون یک عدد مثبت و کوچک اختیاری ثابت است که به منظور افزودن پایداری محاسباتی و جلوگیری از صفر شدن مخرج کسرها در حین محاسبه امتیاز $F1$ برای هر کلاس، به مخرج کسر اضافه می‌گردد. (Wu, et al., 2021).

$$F1_{overall} = 0.3 \times F1_{loc} + 0.7 \times F1_{cls} \quad (۷)$$

• دقت^۸

دقت یک معیار ساده است که نسبت پیکسل‌های طبقه‌بندی شده صحیح در تصویر را اندازه‌گیری می‌کند. باین حال، در مجموعه داده‌های نامتعادل، جایی که یک کلاس غالب است، می‌تواند گمراه‌کننده باشد.

$$Accuracy = \frac{TP+TN}{TP+TN+FN+FP} \quad (۸)$$

^۱ Confusion Matrix

^۲ True Positive

^۳ False Positive

^۴ False Negative

^۵ True Negative

^۶ Precision


^۷ Recall

^۸ Accuracy


۳-۴- پیش پردازش داده‌ها

در بخش پیش پردازش داده‌ها، سه مرحله اصلی برای آماده سازی تصاویر انجام شد:

- **تبدیل فایل های JSON به تصاویر ماسک:** در مجموعه داده **xBD**، اطلاعات ماسک در قالب فایل های JSON ذخیره شده بود؛ بنابراین، در مرحله اول، تصاویر ماسک که به عنوان برچسب های داده عمل می کنند، استخراج و با فرمت **png** ذخیره شدند. نمونه ای از تصویر پس از حادثه و ماسک آن در شکل ۴ نشان داده شده است.
- **تغییر اندازه و نرمال سازی:** مدل های پیشنهادی با روش آزمایشی با تصاویر با اندازه های گوناگون آموزش داده شدند. بر اساس نتایج به دست آمده، تصاویر با ابعاد 512×512 پیکسل برای آموزش مدل ها انتخاب شدند. علاوه بر این، تصاویر **نرمال سازی** شدند و سپس به عنوان ورودی به شبکه داده شدند.
- **افزایش داده ها:** برای حل مشکل نامتعادل بودن مجموعه داده، از تکنیک های افزایش داده استفاده شد. در این پژوهش از **وارون افقی**، **وارون عمودی** و **چرخش تصادفی** برای افزایش تعداد داده ها استفاده شد. نمونه ای از تصاویر تغییر یافته با این تکنیک ها در شکل ۵ قابل مشاهده است.



شکل (۴): نمونه تصویر پس از حادثه و ماسک واقعی آن



شکل (۵): نمونه افزایش داده

۴-۴- پیاده‌سازی شبکه +DeepLabV3 با مکانیزم خودتوجهی

شبکه پیشنهادی، مدل +DeepLabv3 را با افزودن مکانیزم خود توجهی برای انجام وظیفه بخش‌بندی معنایی بهبود داده است. DeepLabv3 یک معماری پیشرفته است که قادر به درک اطلاعات در مقیاس‌های مختلف است. ماژول خود - توجه برای بهبود توانایی مدل در یادگیری وابستگی‌های دوربرد و تمرکز بر ویژگی‌های مرتبط به آن اضافه شده است. مدل پیشنهادی از اجزای کلیدی زیر تشکیل شده است:

- **گلوگاه:** یک شبکه ResNet-101 به‌عنوان ستون فقرات برای استخراج ویژگی‌های تصویر ورودی استفاده می‌شود. این شبکه از لایه‌های کانولوشن، اتصالات باقیمانده^۱ و لایه‌های پولینگ تشکیل شده است. گلوگاه ویژگی‌ها را در سطوح مختلف انتزاعی، شامل اطلاعات سطح پایین و بالا، از تصویر استخراج می‌کند.
- **ASPP:** ماژول ASPP برای درک اطلاعات در مقیاس‌های مختلف روی ویژگی‌های سطح بالا اعمال می‌شود.
- **خودخواهی:** یک مکانیزم خود - توجه برای بهبود توانایی مدل در درک وابستگی‌های دوربرد ادغام شده است. این ماژول وزن‌های توجه را بر اساس روابط بین بخش‌های مختلف نقشه‌های ویژگی محاسبه می‌کند.
- **رمزگشا:** یک ماژول رمزگشا برای بزرگ‌نمایی ویژگی‌های استخراج شده توسط رمزگذار و اصلاح پیش‌بینی‌های بخش‌بندی استفاده می‌شود. این ماژول شامل لایه‌های کانولوشن، لایه‌های نمونه‌برداری بالا و عملیات الحاق است. همچنین ویژگی‌های سطح بالا را با ویژگی‌های سطح پایین ترکیب می‌کند تا پیش‌بینی‌های دقیق‌تری تولید شود.

۴-۵- بخش‌بندی (شبکه +DeepLabV3 با مکانیزم خودتوجهی)

در این بخش نیز از تابع هزینه دایس با تغییر به‌صورت چندکلاسی استفاده شده است.

- **بهینه‌ساز**

بهینه‌ساز مورد استفاده در این بخش که با روش تجربی انتخاب شده است بهینه‌ساز Adam است.

- **هایپرپارامترها**

هایپرپارامترهای این بخش با روش تجربی تنظیم شده‌اند تا عملکرد مدل بهینه شود و در جدول ۳ قابل مشاهده هستند.

جدول (۳): هایپرپارامترهای بخش‌بندی شبکه +DeepLabV3 با مکانیزم خودتوجهی

پارامتر	مقدار
نرخ یادگیری	۰.۰۰۰۱
اندازه دسته	۲
تعداد تکرار	۲۰
اندازه تصویر	۵۱۲*۵۱۲

۴-۶- طبقه‌بندی (شبکه +DeepLabV3 با مکانیزم خودتوجهی)

- تابع زیان، بهینه‌ساز و معیارهای ارزیابی همچون قسمت قبلی انتخاب شده‌اند. هایپرپارامترهای مدل در جدول ۴ قابل مشاهده هستند.

جدول (۴): هایپرپارامترهای طبقه‌بندی شبکه +DeepLabV3 با مکانیزم خودتوجهی

پارامتر	مقدار
نرخ یادگیری	۰.۰۰۰۲
اندازه دسته	۲
تعداد تکرار	۷۶
اندازه تصویر	۵۱۲*۵۱۲


۴-۷- نتایج

این شبکه که از ترکیب +DeepLabv3 با مکانیزم خود توجهی برای بخش‌بندی معنایی تقویت شده استفاده می‌کند، ارائه شد. نتایج تجربی

¹ residual connections


عملکرد برتر مدل را نسبت به مدل‌های پایه نشان می‌دهد و آن را به رویکردی امیدوارکننده برای کارهای مختلف بخش‌بندی معنایی تبدیل می‌کند. این مدل در مقایسه با سایر روش‌های پیشرفته، عملکرد رقابتی را به دست آورد که اثربخشی مکانیزم خود توجهی را در بهبود دقت بخش‌بندی نشان می‌دهد.

نمودار همگرایی تابع هزینه در شکل ۶ نشان می‌دهد که الگوریتم پیشنهادی به خوبی همگرا شده است.



شکل (۶): همگرایی تابع خطا در شبکه DeeplabV3+ با مکانیزم خودتوجهی

شکل ۷ تغییرات شاخص عملکرد IOU را در طول آموزش مدل در بخش‌های بخش‌بندی و طبقه‌بندی نشان می‌دهد.



شکل (۷): نمودار همگرایی IOU در شبکه DeeplabV3+ با مکانیزم خودتوجهی

شکل ۸ نتایج حاصل از اعمال مدل پیشنهادی بر روی پنج تصویر نمونه را به همراه ماسک‌های واقعی نشان می‌دهد. همانطور که مشاهده می‌شود این مدل پیشنهادی نیز عملکردی عالی در تخمین محل قرارگیری ساختمان‌ها دارد. در زمینه تخمین میزان آسیب نیز به‌جز در کلاس آسیب کم که مقداری خطا در آن وجود دارد، دیگر کلاس‌ها به خوبی تخمین زده می‌شوند. نتیجه مقایسه روش پیشنهادی با دیگر روش‌ها در جدول ۵ آمده است.

جدول (۵): مقایسه جامع عملکرد مدل پیشنهادی (DeepLabV3+) با مکانیزم توجه و افزایش داده) با سایر روش‌های موجود در ادبیات پژوهش. ارزیابی بر اساس چهار معیار تخصصی OF1، LF1، CF1 و F1 کلی انجام شده است. بهترین عملکرد در هر ستون با حروف درشت (Bold) مشخص شده است.

مطالعه	OF1	LF1	CF1	آسیب کم	آسیب زیاد	تخریب کامل	LMIoU	CMIoU
--------	-----	-----	-----	---------	-----------	------------	-------	-------

-	-	0.868	0.775	0.614	0.925	0.776	0.861	0.802	(Da, Ji, & Zhou, 2022)
0.611	0.771	0.859	0.768	0.582	0.916	0.758	0.871	0.792	(Yang, Zhang, & Luo, 2021)
0.872	-	0.772	0.765	0.711	0.978	0.796	-	-	(Kaur, et al., 2023)
0.611	0.771	0.859	0.768	0.582	0.916	0.758	0.871	0.792	Wu, et al.,) (2021)
-	-	-	-	-	-	-	-	0.7017	(Liu, et al., 2022)
-	82.17	69.55	65.36	41.36	89.85	61.55	77.70	-	(Bai, et al., 2020)
-	-	0.8335	0.7538	0.5778	0.9521	0.7536	0.8741	0.7898	(Deng & Wang, 2022)
0.8852	0.9314	0.9374	0.9569	0.9150	0.9460	0.9386	0.9429	0.9399	شبکه پیشنهادی

۴-۸- بحث و تحلیل نتایج

همان‌طور که در جدول ۵ مشاهده می‌شود، مدل پیشنهادی بر مبنای DeepLabV3+ با مکانیزم توجه و افزایش داده، در تمامی معیارهای ارزیابی (OF1, CF1, LF1) و همچنین معیار نهایی F1 کلی، عملکردی برتر نسبت به روش‌های پیشین و مدل‌های پایه‌ای داشته است. بولد (Bold) بودن اعداد در جدول ۵، نشان‌دهنده کسب بالاترین امتیاز در آن ستون (معیار) توسط روش پیشنهادی است. به‌ویژه، مدل موفق به کسب امتیاز F1 کلی معادل ۰.۹۳۹۹ (که در چکیده به‌صورت ۰.۹۴ گرد شده است) شد. این معیار، میانگین وزنی امتیازات F1 برای هر چهار کلاس آسیب است و نشان‌دهنده دقت بالای مدل در طبقه‌بندی کلی ساختمان‌ها است. تحلیل نتایج کلاس به کلاس نشان می‌دهد که مدل در تشخیص کلاس "تخریب‌شده" بالاترین دقت را دارد، درحالی‌که در کلاس "آسیب کم" با چالش‌هایی روبرو است. این امر به دلیل شباهت‌های بافتی و بصری بیشتر بین ساختمان‌های «سالم» و «آسیب کم» در تصاویر ماهواره‌ای است که نیازمند توجه ویژه به ریز تغییرات است. تصاویر نمونه خروجی در شکل ۸، این دقت بالا را در تمایز کلاس‌ها و استخراج دقیق مرزهای ساختمان‌ها به‌صورت بصری تأیید می‌کنند، اگرچه در برخی موارد شاهد اشتباه در کلاس «آسیب کم» هستیم که نیاز به تحقیقات آتی دارد.


۴-۹- مطالعه حذف تدریجی اجزا


به‌منظور توجیه علمی نوآوری اصلی این پژوهش که مبتنی بر تلفیق موفقیت‌آمیز مکانیزم خود توجهی (Self-Attention) و تکنیک‌های افزایش داده (Data Augmentation) با معماری DeepLabV3+ است، یک مطالعه حذف تدریجی اجزا (Ablation Study) طراحی و اجرا شد. هدف از این مطالعه، ارزیابی دقیق سهم و تأثیرگذاری مجزای هر یک از مؤلفه‌های نوآورانه بر عملکرد نهایی مدل است تا بتوان نشان داد که کارایی برتر مدل پیشنهادی، ناشی از هم‌افزایی این اجزا است. در این راستا، عملکرد مدل پایه DeepLabV3+ خالص، به‌صورت مرحله‌ای با افزودن هر مؤلفه ارزیابی گردید و نتایج بر اساس معیار F1 کلی در جدول ۶ خلاصه شده است.

جدول (۶) نتایج مطالعه حذف تدریجی اجزا به منظور تعیین سهم هر مؤلفه در عملکرد نهایی مدل. این ارزیابی نشان می‌دهد که افزودن مرحله‌ای مکانیزم توجه و افزایش داده به مدل پایه DeepLabV3+، چگونه به صورت هم‌افزا دقت نهایی (F1 کلی) را ارتقا داده است.	F1 کلی (Overall F1)
مدل DeepLabV3+ (مدل پایه)	۰.۹۱۶۰
DeepLabV3+ + Data Augmentation	۰.۹۲۷۵
DeepLabV3+ + Self-Attention	۰.۹۳۵۰
مدل پیشنهادی نهایی	۰.۹۳۹۹

همان‌طور که در جدول ۶ مشاهده می‌شود، هر یک از مؤلفه‌های افزوده شده به مدل، بهبود قابل‌توجهی در عملکرد نهایی ایجاد کرده است. مدل پایه DeepLabV3+ خالص، معیار F1 کلی ۰.۹۱۶۰ را کسب کرده است. با افزودن مؤلفه افزایش داده‌ها (Data Augmentation)، عملکرد مدل به ۰.۹۲۷۵ ارتقا یافت که نشان‌دهنده نقش حیاتی غنی‌سازی مجموعه آموزشی در کاهش بیش‌برازش و افزایش توانایی مدل در تعمیم‌دهی به تصاویر ناشناخته است. تأثیرگذارترین مؤلفه، افزودن مکانیزم خود توجهی (Self-Attention) بود که دقت را به ۰.۹۳۵۰ رساند. این افزایش قابل‌توجه، بیانگر این است که مکانیزم توجه توانسته است با تمرکز بر ویژگی‌های محلی مهم و ریز تغییرات حساس به آسیب، توانایی مدل را در تفکیک مرزها و کلاس‌های مشابه (به‌ویژه "آسیب کم") بهبود بخشد. در نهایت، مدل پیشنهادی نهایی که از ترکیب هم‌زمان DeepLabV3+، افزایش داده و مکانیزم خود توجهی بهره می‌برد، با کسب بالاترین امتیاز یعنی ۰.۹۳۹۹، بالاترین عملکرد را به ثبت رساند. این نتیجه، به‌وضوح نشان می‌دهد که نه تنها هر یک از اجزای نوآورانه، سهم مثبتی در بهبود دقت داشته‌اند، بلکه ترکیب آن‌ها یک هم‌افزایی قابل‌توجه ایجاد کرده است؛ بنابراین، داده‌های Ablation Study توجیه کاملی برای ساختار پیشنهادی ارائه کرده و برتری رویکرد تلفیقی در این پژوهش را اثبات می‌کند.

۵- نتیجه‌گیری و کارهای آینده





شکل (۸): نتایج نمونه خروجی مدل پیشنهادی برای تصاویر پس از حادثه، رده‌های خسارت از طریق رنگ‌بندی‌های استاندارد تفکیک شده‌اند: سبز (بدون آسیب)، زرد (آسیب کم)، نارنجی (آسیب زیاد) و قرمز (تخریب کامل). این تصاویر دقت مدل در تمایز رده‌ها و استخراج مرزهای ساختمان‌ها را نشان می‌دهند.

این پژوهش نشان داد که استفاده از ترکیب DeepLabV3+ با مکانیزم خود توجهی در ارزیابی میزان آسیب ساختمان‌ها پس از حوادث مختلف، عملکرد بسیار مناسبی دارد. مدل پیشنهادی با دقت بالا قادر است میزان تخریب را در چهار سطح مختلف شناسایی کرده و نقشه‌ای دقیق از وضعیت ساختمان‌ها ارائه دهد. چنین قابلیت‌هایی می‌تواند به طور مستقیم در عملیات امداد و نجات، تخصیص منابع، و بازسازی سریع پس از بلایای طبیعی مانند زلزله و سیل به کار رود. افزون بر این، روش معرفی شده قابلیت انطباق در شرایط جنگی و سناریوهای نظامی را نیز دارد، به گونه‌ای که می‌توان از آن برای تخمین سریع خسارات ناشی از بمباران، حملات موشکی یا سایر تهدیدات انسانی بهره گرفت. از این رو، پژوهش حاضر نه تنها در حوزه مدیریت بحران شهری، بلکه در پدافند غیرعامل و حوزه‌های امنیتی نیز دارای ارزش کاربردی بالاست.

۵-۱- کارهای آینده

برای ادامه این پژوهش، می‌توان پیشنهادهای زیر را مورد بررسی قرار داد:

۱. ادغام داده‌های چند حسی (Multispectral Data Fusion) برای بهبود دقت طبقه‌بندی، می‌توان تصاویر ماهواره‌ای را با داده‌های دیگر (مانند داده‌های LiDAR برای اطلاعات سه‌بعدی) یا داده‌های طیفی ترکیب کرد.
۲. پشتیبانی از فرمت‌های بیشتر: مدل کنونی فقط با تصاویر کار می‌کند. افزودن قابلیت پردازش فایل‌های دیگر مانند فرمت‌های

- سه بعدی (obj) یا (gltf) می تواند کارایی سیستم را افزایش دهد.
۳. انتقال یادگیری (Transfer Learning) می توان از مدل های از پیش آموزش دیده روی مجموعه داده های بزرگ تر برای تسریع آموزش و بهبود عملکرد بهره گرفت.
۴. بهبود تشخیص کلاس های نامتوازن: برای افزایش دقت در دسته هایی با داده های کمتر، می توان از تکنیک های پیشرفته تر افزایش داده یا الگوریتم های اختصاصی برای داده های نامتوازن استفاده کرد

تشکر و قدردانی

این تحقیق بخشی از حمایت های مالی دانشگاه شهید چمران اهواز با شماره گرنت SCU.EC1403.450 است.

نویسندگان از شرکت CSET برای در دسترس قراردادن عمومی مجموعه داده xBDکمال تشکر را دارند. این مجموعه داده از طریق نشانی پیوند زیر قابل دسترسی است

<https://xview2.org/dataset>

۶- مراجع

- Amezquita-Sanchez, J. P., Park, H. S., & Adeli, H. (2017). A novel methodology for modal parameters identification of large smart structures using MUSIC, empirical wavelet transform, and Hilbert transform. *Engineering Structures*, 147, 148–159.
- Bai, Y., et al. (2020). Pyramid pooling module-based Semi-Siamese Network: A benchmark model for assessing building damage from xbd satellite imagery datasets. *Remote Sensing*, 12(24), 4055.
- Bandara, W. G. C., & Patel, V. M. (2022). A transformer-based siamese network for change detection. *arXiv*.
- Da, Y., Ji, Z., & Zhou, Y. (2022). Building damage assessment based on Siamese hierarchical transformer framework. *Mathematics*, 10(11), 1898.
- Deng, L., & Wang, Y. (2022). Post-disaster building damage assessment based on improved U-Net. *Scientific Reports*, 12(1).
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Kaur, N., Lee, C., Mostafavi, A., & Mahdavi-Amiri, A. (2023). Large-scale building damage assessment using a novel hierarchical transformer architecture on satellite images. *Computer-Aided Civil and Infrastructure Engineering*, 38(15), 2072–2091.
- Liu, C., et al. (2022). A novel attention-based deep learning method for post-disaster Building Damage Classification. *Expert Systems with Applications*, 202, 117268.
- Shen, Y., et al. (2022). Bdanet: Multiscale convolutional neural network with cross-directional attention for building damage assessment from satellite images. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1–14.
- Wu, C., et al. (2021). Building damage detection using U-Net with attention mechanism from pre- and post-disaster remote sensing datasets. *Remote Sensing*, 13(5), 905.
- Xiao, H., Peng, Y., Tan, H., & Li, P. (2021). Dynamic Cross Fusion Network for Building-Based Damage Assessment. In *Proc. of the IEEE International Conference on Multimedia and Expo*, Shenzhen, China, pp. 1–6.
- Yang, W., X. Zhang, and P. Luo (2021). Transferability of convolutional neural network models for identifying damaged buildings due to earthquake. *Remote Sensing*, 13(3), 504.
- Zhou, S., Dong, Z., & Wang, G. (2022). Machine-learning-based change detection of newly constructed areas from GF-2 Imagery in Nanjing, China. *Remote Sensing*, 14(12), 2874.