

توسعه روشی نوین به منظور شناسایی سریع و خودکار درجات تخریب ساختمان‌ها از تصاویر و ابرنقاط پهپادی بعد از زلزله (مطالعه موردی: منطقه سرپل ذهاب)

نرگس تخت کشها^{۱*}، علی محمدزاده^۲

^۱ دانشجوی کارشناسی ارشد سنجش از دور - دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
n.takhtkeshha@email.kntu.ac.ir

^۲ دانشیار دانشکده مهندسی نقشه برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
a_mohammadzadeh@kntu.ac.ir

(تاریخ دریافت اسفند ۱۴۰۰، تاریخ تصویب خرداد ۱۴۰۱)

چکیده

طی سه دهه اخیر، تولید نقشه تخریب ساختمان‌ها پس از زلزله، یکی از مهمترین چالش‌های مطرح در حوزه مدیریت بحران می‌باشد. در اکثر مطالعات پیشین از داده‌های ماهواره‌ای برای تولید نقشه‌های تخریب ساختمان‌ها استفاده شده‌است، ولی به دلیل هندسه ضعیف این نوع داده‌ها و نویز بالا، اخیراً تمایل زیادی جهت بکارگیری داده‌های پهپادی به منظور شناسایی درجات تخریب ساختمان‌ها طبق استاندارد EMS98 ایجاد شده‌است. لذا در این تحقیق، داده‌های اخذ شده پس از زلزله سرپل ذهاب به منظور شناسایی درجات تخریب ساختمان‌ها در چهار کلاس، شامل "تخریب نشده یا تخریب جزئی"، "تخریب کم"، "تخریب شدید" و "ویران شده" مورد استفاده قرار گرفته‌است. در روش پیشنهادی، ابتدا داده‌های خام به ابر نقاط و تصاویر اورتوفتو تبدیل شد. سپس، روش نوینی مبتنی بر تصمیم‌گیری درختی و به صورت حذفی ارائه گردید که با درجه اتوماسیون بالایی اقدام به تفکیک و شناسایی کلاس‌های تخریب بیان شده می‌نماید. علاوه بر این، جهت شناسایی کامل ساختمان‌های ویران شده، شاخص انباشتگی آوار نوینی در این تحقیق پیشنهاد گردیده‌است. از مهمترین ویژگی روش ارائه شده، در نظر گرفتن همزمان سه رکن مهم در مدیریت بحران شامل سرعت، دقت و هزینه در طراحی روش پیشنهادی می‌باشد. نتایج بدست آمده بر روی دو محدوده در شهر سرپل ذهاب، حاکی از حصول دقت کلی و ضریب کاپا به ترتیب ۸۶٪ و ۸۱٪ و نیز مدت زمان پردازش حدود ۱۵ ثانیه‌ای در منطقه‌ای با ۱۴۲ ساختمان می‌باشد و این نشان‌دهنده کارایی بالای روش پیشنهادی است.

واژگان کلیدی: نقشه تخریب زلزله، پهپاد، مدیریت بحران، روش درخت تصمیم‌گیری حذفی

* نویسنده رابط

۱- مقدمه

در سطح جهان، وقوع حوادث طبیعی مانند زلزله در چند دهه‌ی اخیر به صورت چشمگیری در حال افزایش بوده است [۱]-[۳]. پس از وقوع زلزله، ارزیابی خسارات ساختمان‌ها گامی اساسی در تعیین اولویت امداد و نجات، اسکان افراد بی سرپناه و برآورد میزان بازسازی لازم است [۴]. از طرفی بازدید میدانی به عنوان تنها راه حل با توجه به نا امنی شرایط حاکم پس از زلزله و وسعت منطقه عملاً کاری دشوار و زمانبر خواهد بود. لذا استفاده از علم فتوگرامتری و سنجش از دور با توجه به امکان اخذ و تحلیل سریع داده‌های دو/سه بعدی از منطقه آسیب‌دیده در مقیاس وسیع، راه حل مناسبی می‌باشد [۵]. به عنوان یکی از قدیمی‌ترین نمونه‌ها می‌توان به نقشه‌های تخریب تولید شده از طریق داده‌های هوایی اخذ شده با کایت از زلزله سال ۱۹۰۶ سانفرانسیسکو اشاره نمود [۶]. بعدها در زلزله ۱۹۶۴ آلاسکا نیز از تصاویر ماهواره‌ای برای ارزیابی خسارت استفاده گردید [۷]. روش‌های ارزیابی تخریب در یک دسته بندی کلی می‌تواند به روش‌های مبتنی بر داده‌های تک زمانه (بعد از حادثه) و یا چند زمانه (قبل و بعد از حادثه) تفکیک شوند. در روش‌های چند زمانه، احتمال شرایط متفاوت اخذ داده، طولانی بودن دوره‌ی اخذ مجدد داده و تفاوت زاویه‌ی تصویربرداری و مواردی از این قبیل، باعث ایجاد دشواری‌های عملی جدی در حصول به نتایج قابل اعتماد می‌شود [۸] و [۹]. لذا استفاده از داده‌های تک زمانه بعد از زلزله در کنار نقشه‌های موجود قبل از زلزله در اولویت می‌باشد. طی چند دهه‌ی اخیر، انواع مختلف سنجنده‌های لایدار هوایی [۱۴]-[۱۰]، راداری [۱۸]-[۱۵] و ماهواره‌ای نوری [۲۵]-[۱۹] توسط محققین زیادی به منظور تولید نقشه‌های تخریب ناشی از زلزله مورد بررسی و استفاده قرار گرفته‌اند. از مشکلات و معایب سنجنده‌های لایدار هوایی و راداری می‌توان به هزینه‌ی بالای اخذ این نوع داده‌ها و یا عدم دسترسی سریع به این نوع داده‌ها در زمان وقوع بحران مخصوصاً برای کاربران داخل کشور می‌توان اشاره کرد. سنجنده‌های نوری ماهواره‌ای نیز دارای مشکلات جدی امکان دسترسی به موقع در زمان وقوع بحران بوده و در صورتی که امکان دسترسی به داده‌های با قدرت تفکیک مکانی بالا میسر شود، هندسه‌ی ضعیف تصویر در زمان برداشت و میل

بالای زاویه‌ی برداشت از حالت قائم، مقدار پایین سیگنال به نویز و نهایتاً عدم امکان بازسازی سه بعدی تخریب با دقت مورد نیاز استاندارد EMS-۹۸، از مواردی است که دقت نتایج این نوع سنجنده‌ها را برای کاربران داخل کشور تحت تاثیر جدی قرار داده‌است [۲۹]-[۲۶].

جدول ۱- مشخصات درجات تخریب براساس استاندارد EMS-98

درجه تخریب	مشخصات فیزیکی	نمونه
درجه ۱ ^۱	آسیب‌های بسیار ناچیز شامل: • ایجاد شکاف در سقف • ریختن تکه‌های کوچک از گچ ساختمان	
درجه ۲ ^۲	آسیب‌های متوسط شامل: • ایجاد شکاف در اکثر دیوارها • ریختن تکه‌های بزرگ گچ ساختمان	
درجه ۳ ^۳	آسیب‌های سنگین شامل: • ایجاد شکاف‌های بزرگ ممتد در اکثر دیوارها • ایجاد شکاف در سقف • شکستن کامل دودکش • از بین رفتن المان‌های بدون ساختار مثل لچکی دیوارها	
درجه ۴ ^۴	آسیب‌های خیلی سنگین شامل: • ریختن شدید دیوارها • از بین رفتن قسمتی از ساختار سقف و کف	
درجه ۵ ^۵	فروریختگی • فروریختگی کامل یا تقریباً کامل	

از این رو، طی چند سال اخیر تمایل بسیار زیادی به استفاده از داده‌های نوری اخذ شده از سکوه‌های پهپادی برای شناسایی تخریب ناشی از زلزله در سطح بین‌المللی آسیایی و اروپایی، مخصوصاً مراکز تحقیقاتی چین و ژاپن ایجاد شده است. داده‌های نوری اخذ شده از پهپاد، دارای سرعت بالا و سهولت دسترسی، اخذ تصاویر همپوشانی‌دار با قدرت تفکیک مکانی بسیار بالا، امکان تولید ابر نقاط و مدل رقومی سطح^۶ به نحوی که دارای دقت مناسب جهت تطبیق کلاس‌های تخریب استاندارد EMS-۹۸ می‌باشد. لذا استفاده از این نوع سنجنده‌ها فرصت‌های جدیدی را پیش روی محققین و

^۱ Negligible to Slight Damage

^۲ Moderately Damaged

^۳ Substantial to heavy damaged

^۴ Very heavy damaged

^۵ Destruction

^۶ Digital Surface Model (DSM)

کاملترین استانداردهای ارائه شده توسط سرویس کوپرنیکوس EMS و براساس مقیاس کلان لرزه‌ای اروپا هست که معرف ایده آل‌ترین تعداد درجات قابل شناسایی از ارزیابی‌های میدانی توسط کارشناسان است و شامل پنج درجه تخریب است [۳۱]. در جدول ۱، این سطوح تخریب و مشخصات فیزیکی هریک از آن‌ها بیان شده است.

سازمان‌ها به منظور ارائه محصولات عملیاتی و قابل اتکا جهت شناسایی و ارزیابی تخریب ساختمان‌ها ایجاد نموده است [۳۰]. لذا در این تحقیق، مطابق با استاندارد EMS-۹۸ و با استفاده از داده‌های اخذ شده‌ی همپوشانی‌دار پهبادی، اقدام به ارائه‌ی روشی عملیاتی به منظور شناسایی تخریب ساختمان‌ها شده است. این استاندارد یکی از معروفترین و

جدول ۲- مروری بر مطالعات انجام شده در زمینه شناسایی تخریب ساختمان‌ها با استفاده از داده‌های پهبادی و هوایی (به ترتیب سال)


محققین/سال	تک/چند زمانه	اساس روش	داده-رزولوشن(m)	درجات تخریب شناسایی شده
Li و همکاران (۲۰۱۱) [۴۱]	تک زمانه	قوانین مبنا شی‌گرا	هوایی (۰,۵)	تخریب نشده و تخریب کم و ویران شده
Zeng و همکاران (۲۰۱۲) [۴۲]	تک زمانه	یادگیری ماشین شی‌گرا	پهباد (۰,۵)	سالم، تخریب شده و ویران شده
Vetrivel و همکاران (۲۰۱۵) [۴۳]	تک زمانه	یادگیری ماشین شی‌گرا	ابرنقطه هوایی و پهبادی بدست آمده از تصاویر مایل	تخریب نشده و تخریب شده
Frank و همکاران (۲۰۱۷) [۴۴]	تک زمانه	یادگیری ماشین شی‌گرا	هوایی (۰,۱)	تخریب نشده و تخریب
Chen و همکاران (۲۰۱۸) [۸]	تک زمانه	قوانین مبنا شی‌گرا	پهباد (۰,۲)/هوایی (۰,۶۱)	تخریب نشده و تخریب شده
Huang و همکاران (۲۰۱۹) [۴۵]	تک زمانه	یادگیری عمیق	هوایی (۰,۶۷)	سالم، شکسته و آوار
Song و همکاران (۲۰۱۹) [۲۴]	تک زمانه	یادگیری عمیق (شبکه DeepLab V2)	هوایی (۰,۵)	سالم، نیمه ویران و ویران شده
Li و همکاران (۲۰۱۹) [۴۶]	تک زمانه	یادگیری عمیق (شبکه SSD)	هوایی (۰,۳)	تخریب نشده و آوار
Kalantar و همکاران (۲۰۲۰) [۲۱]	چند زمانه	یادگیری عمیق	هوایی (۰,۲۵)	تخریب نشده و تخریب کم و آوار
Li و همکاران (۲۰۲۰) [۴۷]	تک زمانه	قوانین مبنا	رزولوشن ۲,۵ سانتیمتر: سالم، تخریب کم، نسبتا ویران شده و ویران شده رزولوشن ۷,۹ سانتیمتر: سالم، نسبتا ویران شده و ویران شده	تلفیق ابرنقطه و تصویر اپتیک پهبادی (۰,۰۲۵ و ۰,۰۷۹)
Ma و همکاران (۲۰۲۰) [۴۸]	تک زمانه	یادگیری عمیق (شبکه Inception V3)	هوایی (۰,۳)	تخریب کم، متوسط و جدی
Ma و همکاران (۲۰۲۰) [۴۹]	تک زمانه	یادگیری عمیق (شبکه YOLO-V3)	هوایی (۰,۵)	ویران شده
Tilon و همکاران (۲۰۲۰) [۵۰]	تک زمانه	یادگیری عمیق (شبکه ADGAN)	پهباد (۰,۰۲ و ۰,۰۶)	تخریب نشده و تخریب شده
Calantropio و همکاران (۲۰۲۱) [۳۲]	تک زمانه	یادگیری عمیق	پهباد (۰,۰۹)	گستره‌ای از تخریب کم تا تخریب زیاد

۲- پیشینه تحقیق

تحقیقات اخیر، نقشه‌ی تخریب در دو درجه تخریب شده و تخریب نشده تولید شده است. همچنین در یک دسته‌بندی کلی تحقیقات انجام شده را در ۳ گروه روش‌های قوانین مبنا، یادگیری ماشین و یادگیری عمیق می‌توان دسته‌بندی نمود [۲۵]-[۲۴] و [۳۵]-[۳۲] وجود اشکال مختلف

خلاصه‌ای از مهمترین تحقیقات انجام شده در زمینه‌ی استفاده از داده‌های پهباد و هوایی نوری در شناسایی تخریب ساختمان‌ها در جدول ۲ آورده شده است. در اکثر

ریشتر در عمق ۱۱ کیلومتری در این منطقه رخ داد که به دنبال آن، نزدیک ۶۲۰ نفر کشته، ۷۰۰۰ نفر مجروح و ۷۰۰۰ نفر بی خانمان شدند [۵۱].



شکل ۱- منطقه‌ی مطالعاتی

همچنین داده‌های مورد استفاده، تصاویر پهپاد پوشش دار بعد از زلزله است که شامل سه باند RGB می‌باشد. پهپاد مورد استفاده جهت برداشت تصاویر، پهپاد فانتوم پرو ۴ بوده و تصاویر بصورت ژئوتگ اخذ شده‌اند. ابعاد تصاویر اخذ شده ۵۴۷۲*۳۶۴۸ پیکسل می‌باشد. ارتفاع پرواز حدود ۹۰ متر و مدل دوربین FC6310 با فاصله‌ی کانونی ۸،۸ میلیمتر و اندازه‌ی پیکسل ۲،۴۱ میکرومتری می‌باشد. علاوه بر این، از نقشه‌برداری ساختمان‌ها به عنوان داده‌ی کمکی جهت ماسک کردن محدوده‌های ساختمانی استفاده شده‌است. لازم به ذکر است، به دلیل نقص داده‌های OSM^۳، در این تحقیق بردار ساختمان‌ها توسط اپراتور خبره ترسیم شده است. لازم به ذکر است، می‌توان این بردار را از تصویر قبل از زلزله نیز استخراج کرد که یوآن و همکاران به آن پرداختند [۵۲].

۴- روش پیشنهادی

شکل ۲، روند نمای کلی روش پیشنهادی برای تولید نقشه‌ی تخریب ساختمان‌ها را نشان می‌دهد. این روش براساس یک درخت تصمیم‌گیری فازی است که قوانین آن با انطباق‌سازی درجات تخریب EMS-۹۸، با ویژگی‌های

ساختمان‌ها و با خصوصیات هندسی و بعضاً طیفی متفاوت، انواع حالات تخریب ممکن برای ساختمان‌ها با توزیع مکانی گوناگون، ذاتاً موجب پیچیدگی بالای تخریب زلزله می‌شود [۳۶]. بنابراین بکارگیری روش‌های یادگیری عمیق در این حوزه به دلیل محدودیت دسترسی به داده‌ی آموزشی لازم در هنگام حادثه و نیز احتمال عدم تعمیم‌پذیری کافی مدل‌های آموزش داده‌شده‌ی قبلی، عموماً با بروز خطا همراه است. همچنین، در صورت وجود داده‌ی آموزشی، آموزش شبکه‌های عصبی عمیق زمان بسیار بالاتری را در مقایسه با سایر روش‌ها نیاز دارد [۳۷]. همچنین، در روش‌های یادگیری ماشین، انتخاب نوع مدل و نیز بهینه‌سازی پارامترهای آن اهمیت بسزایی در دقت نهایی نقشه‌ی تخریب تولیدشده دارد که بعضاً چالش برانگیز است. از طرفی دیگر، اولین و مهمترین نکته در تعیین درجات تخریب زلزله با استفاده از داده‌های سنجش ازدور، منطبق سازی استانداردهای تخریب با آنچه از این داده‌ها قابل حصول است، می‌باشد که کار تو و همکاران به آن پرداختند [۳۸]. در این راستا روش‌های قوانین‌مبنا، در حین سادگی و پتانسیل سرعت بالا، می‌توانند براساس منطبق‌سازی بیان شده طراحی شوند و قادرند تا نقشه‌ی تخریب قابل اعتمادتری تولید نمایند. هنوز نیز شناسایی تخریب ساختمان‌ها با چالش‌های اساسی مانند سطح خودکار بودن و انطباق با استانداردهای بین المللی تخریب همراه است؛ به نحوی که هنوز نیز سازمان‌های مهمی چون EMS^۱ و چارتر^۲، متکی به تفسیر بصری تصاویر نوری هستند که بسیار زمان بر و نیازمند نیروی متخصص است. لذا زمینه‌ی خودکارسازی و انطباق با استانداردهای تخریب هنوز نیز فعال است [۳۹] و [۴۰]. با توجه به لزوم برآورد سریع و دقیق خسارت، در این مقاله روشی بهینه و عملیاتی با تأکید بر سه رکن اساسی مدیریت بحران یعنی دقت، سرعت و هزینه و نیز منطبق بر استانداردهای تخریب ارائه شده‌است.

۳- مشخصات منطقه‌ی مطالعاتی و داده‌ها


مطالعه‌ی موردی این پژوهش، زلزله‌ی منطقه‌ی سرپل ذهاب واقع در استان کرمانشاه است (شکل ۱). در تاریخ ۱۳۹۶/۸/۲۱، زلزله‌ای به قدرت ۷،۳ درجه در مقیاس

^۳ Open Street Map


^۱ Copernicus Emergency Management Service

^۲ International Charter "Space and Major Disasters"


اثر آن‌ها را از فرایند تولید نقشه‌ی تخریب حذف نمود. شکل ۳، گیاهان شناسایی شده را به همراه خطای آن نمایش می‌دهد.



(الف)



(ب)



(ج)

شکل ۳- پیش‌پردازش داده‌ها؛ (الف) ارتوفتو بعد از زلزله، (ب) DSM بعد از زلزله، (ج) گیاهان شناسایی شده به همراه خطاها


با توجه به عدم حضور باند NIR در داده‌های پهباد این تحقیق، جهت شناسایی گیاهان از شاخص گیاهی TGI^۵ با حد آستانه‌ی ۰.۶ استفاده شده است [۵۳]. رابطه‌ی ۱، نحوه محاسبه‌ی این شاخص را نشان می‌دهد که در آن R، G و B به ترتیب باندهای قرمز، سبز و آبی می‌باشند. سپس، گیاهان شناسایی شده از تصویر ارتوفتو و DSM ماسک شده‌اند.

$$TGI = -0.5(190(R - G) - 120(R - B)) \quad (1)$$

۲-۴- شناسایی ساختمانهای ویران شده

شکل ۴ روندنمای روش پیشنهادی جهت شناسایی کامل ساختمان‌های ویران شده را نشان می‌دهد.

قابل مشاهده هر یک از درجات تخریب در داده‌های ارتوفتو و ابرنقطه با رزولوشن بالا بدست آمده‌است. در این درخت، ابتدا کلاس "تخریب ویران شده"^۱، (معادل تخریب درجه‌ی ۵ در EMS-۹۸)، سپس "عدم تخریب تا تخریب جزئی"^۲ (معادل تخریب درجه‌ی ۱) و پس از آن "تخریب شدید"^۳ (معادل تخریب‌های درجه‌ی ۳ و ۴) و "تخریب کم"^۴ (معادل تخریب درجه‌ی ۲) مشخص می‌گردند.



شکل ۲- روند کلی روش پیشنهادی تولید نقشه‌ی تخریب در ۴ درجه

درنهایت، نقشه‌ی تخریب ساختمان‌ها در چهار درجه تولید می‌گردد. در ادامه، هریک از مراحل بیان شده به تفصیل شرح داده شده‌است.

۴-۱- آماده‌سازی و پیش‌پردازش داده

در گام اول، ارتوفتو، ابرنقطه و مدل رقومی سطح از تصاویر پهبادی خام اخذ شده با دقت مکانی ۲۵ سانتی‌متر با استفاده از نرم‌افزار Agisoft تهیه شده‌است. سیستم پردازش سریع بکار رفته برای پردازش داده‌های پهبادی خام اخذ شده، مجهز به یک کارت گرافیکی NVIDIA GeForce RTX 2080 Titan با ۱۲۰ گیگابایت RAM بوده‌است. همچنین، با توجه به تاثیر منفی حضور گیاهان در شناسایی دقیق درجه‌ی تخریب ساختمان، می‌بایست


^۱ Collapsed

^۲ No visible to slight damaged

^۳ Major Damaged

^۴ Minor Damaged

° Triangular Greenness Index



شکل ۴- روندنمای روش پیشنهادی شناسایی ساختمان‌های ویران‌شده

یکی از روش‌های شناسایی ساختمان‌های ویران‌شده، اعمال حدآستانه بر روی مدل رقومی سطح نرمال^۱ شده است که به صورت خودکار و سریع صورت می‌پذیرد. nDSM از تفاضل مدل رقومی زمین^۲ از مدل رقومی سطح و طبق رابطه ۲ بدست می‌آید. این روش حدآستانه‌گذاری روی مدل رقومی سطح نرمال‌شده اعمال می‌گردد، در واقع به معنی قائل شدن یک ارتفاع حداقلی برای ساختمان سالم است. از آنجایی که تخریب کامل ساختمان منجر به کاهش ارتفاع شدید آن می‌شود، لذا اطلاعات ارتفاعی ابرنقاط در شناسایی این درجه‌ی تخریب بسیار مفید است. مقدار این حدآستانه با توجه به دقت DSM و DTM (وابسته به دقت فیلترینگ) انتخاب می‌شود.

$$nDSM = DSM - DTM \quad (2)$$

جانعلی‌پور و محمدزاده [۵۴]، از حد آستانه‌گذاری یک ونیم‌متری روی nDSM به عنوان پس‌پردازش نقشه‌ی تخریب استفاده کردند. همچنین، لی و تانگ [۴۷]، با اعمال حدآستانه‌ی سه متر، ساختمان‌های ویران‌شده را شناسایی نمودند. در این مقاله، به منظور تولید nDSM، ابتدا در افزونه لایدار نرم‌افزار ENVI، نقاط غیر زمینی از ابرنقاط حذف شده و اصطلاحاً ابرنقاط فیلتر شده‌است. سپس با شبکه بندی^۳ بر روی نقاط زمینی باقیمانده، DTM بدست آمده است. در گام

بعد nDSM از تفاضل DTM و DSM براساس رابطه‌ی ۲ محاسبه شده‌است. شایان ذکر است با توجه به دقت nDSM محاسبه‌شده، حدآستانه سه متری جهت شناسایی ساختمان‌های ویران‌شده در نظر گرفته شده‌است که به معنای آن است که ارتفاع یک ساختمان سالم حداقل می‌بایست سه متر باشد. این حد آستانه بر روی میانه مقادیر ارتفاعی هر ساختمان اعمال شده‌است. روش حدآستانه گذاری روی nDSM پتانسیل بالایی در شناسایی ساختمان‌های ویران‌شده از نوع فشرده‌شده^۴ دارد. در واقع، ساختمان‌های فشرده‌شده اگرچه ممکن است در تصویر نوری قائم، سالم بنظر برسند، ولی عموماً با کاهش ارتفاعی شدید همراه هستند و از این رو می‌توان آن‌ها را با استفاده از ویژگی ارتفاعی nDSM شناسایی نمود. با این حال، نکته مهمی که در اینجا باید به آن توجه نمود آن است که ممکن است ساختمانی ویران شده باشد، ولی میانه (میانگین) ارتفاع آن بیشتر از ۳ متر باشد که دلیل این امر انباشتگی آوارها است که عموماً در ساختمان‌های مرتفع این حالت مطرح می‌شود و باید درنظر گرفته شود. از این رو، جهت شناسایی کامل درجه‌ی تخریب ویران‌شده، نیازمند به اطلاعات دیگری نیز می‌باشد که نشان‌دهنده‌ی انباشتگی آوار باشد.

از این رو، در این تحقیق ضمن بررسی تمامی ده ویژگی بافتی قابل استخراج از ماتریس هم‌رخداد^۵ در نرم افزار SNAP، از ویژگی عدم شباهت^۶ تصویر اپتیک برای حل این مشکل استفاده شده‌است. در حقیقت مناطقی که دارای انباشتگی آوار هستند دارای تغییرات طیفی زیادی هستند [۵۷]-[۵۵]. در نتیجه ویژگی عدم شباهت طیفی می‌تواند ویژگی مناسبی برای مدل کردن این تغییرات باشد. لذا در این پژوهش، میانه‌ی ویژگی عدم شباهت در هر ساختمان که بین صفر و یک نرمال شده‌است، به عنوان شاخص انباشتگی آوار در نظر گرفته شده‌است. این ویژگی از رابطه ۳ قابل محاسبه است که در آن $P_{i,j}$ مولفه‌های ماتریس هم رخداد می‌باشند.

$$\text{Dissimilarity} = \sum_{i,j=1}^N P_{i,j}[i-j] \quad (3)$$

^۴ Pancake

^۵ Co-occurrence matrix

^۶ Dissimilarity

^۱ Normalized Digital Surface Model (nDSM)

^۲ Digital Terrain Model (DTM)


^۳ Gridding

ویران شده صرفا براساس حد آستانه گذاری بر روی nDSM و بهبود حاصل از راه حل بیان شده، در شکل ۶ نشان داده شده است.



شکل ۶- شناسایی کامل ساختمان‌های "ویران شده (به رنگ قرمز)، با اعمال شاخص انباشتگی آوار؛ الف) ساختمان‌های ویران شده با حد آستانه گذاری روی nDSM، ب) ساختمان‌های ویران شده با حد آستانه گذاری روی شاخص انباشتگی آوار، ج) ساختمان‌های "ویران شده" با تلفیق شاخص nDSM و شاخص انباشتگی آوار، د) نقشه‌ی واقعیت زمینی ساختمان‌های ویران شده (بیضی سیاه: خطا)

با توجه به شکل ۶، همانطور که ملاحظه می‌گردد این روش توانسته است تمام ساختمان‌های "ویران شده دارای



شکل ۵- شاخص‌های مورد استفاده در شناسایی ساختمان‌های ویران شده، الف) nDSM، ب) شاخص nDSM در هر ساختمان، ج) ویژگی بافتی عدم شباهت و د) شاخص انباشتگی آوار در هر ساختمان

در گام بعد با اعمال حد آستانه بیشتر بودن این شاخص از مقدار ۰,۸، مناطق ویران شده‌ای که دارای انباشتگی آوار هستند شناسایی خواهند شد. در آخر با تلفیق نتایج حاصل از حد آستانه گذاری بر روی دو شاخص nDSM و شاخص انباشتگی آوار ارائه شده، با اپراتور اجتماع "یا" نقشه‌ی نهایی ساختمان‌های ویران شده بدست می‌آید. شاخص‌های ارائه شده در شکل ۵ نمایش داده شده‌اند. همچنین، نقطه ضعف شناسایی ساختمان‌های

انباشتگی آوار" را بدرستی شناسایی کند. لذا تلفیق حد آستانه‌گذاری بر روی شاخص انباشتگی آوار مطرح شده با روش متداول حد آستانه‌گذاری بر روی DSM، قادر است نقشه‌ی دقیق‌تری از ساختمان‌های کاملاً ویران شده بدست دهد.

۴-۳- شناسایی ساختمانهای تخریب نشده یا تخریب جزئی


با توجه به جدول ۱، ویژگی ساختمان‌های تخریب نشده یا دچار تخریب جزئی، ایجاد شکاف در سقف و ریختن تکه‌های کوچک از گچ ساختمان است. بنابراین، در این نوع تخریب، درجات خاکستری تصویر ارتوفتو هموزنیتی بالا و واریانس پایینی دارند. از طرفی، این نکته در داده‌ی ابرنقطه آنها نیز صادق است. با توجه به اینکه در تخریب کم که به معنای ایجاد شکاف در اکثر دیوارها و ریختن تکه‌های بزرگ گچ ساختمان است نیز تغییر ارتفاعی خیلی محسوسی به وجود نمی‌آید، لذا شناسایی ساختمان‌های تخریب نشده تا تخریب جزئی از روی تصویر ارتوفتو صحت بالاتری خواهد داشت و مناسب تر است. از این رو، در این تحقیق ابتدا طبق رابطه (۴)، باند شبه پانکروماتیک از باندهای RGB ساخته می‌شود [۵۸]. در این رابطه R، G و B به ترتیب اشاره به باندهای قرمز، سبز و آبی دارد. سپس، با ماسک نمودن آن با بردارهای ساختمان‌ها، انحراف معیار آن در هر ساختمان محاسبه می‌شود. سپس، ساختمانی که انحراف معیار آن کمتر از ۰.۲ باشد و همچنین در مرحله قبل، درجه تخریب ویران شده به آن تخصیص نشده باشد، تخریب نشده تا تخریب جزئی خواهد بود.

$$\text{pan} = 0.2989R + 0.587G + 0.114B \quad (4)$$

۴-۴- شناسایی ساختمانهای تخریب کم و تخریب شدید


در این بخش روشی جهت تفکیک درجه‌ی "تخریب شدید" از "تخریب کم" ارائه می‌شود. با توجه به استاندارد EMSR269 که بر مبنای انطباق‌پذیری EMS-98 با داده‌های سنجش از دوری بدست آمده‌است، حضور لکه‌های سیاه روی سقف ساختمان عموماً نشانه‌ی

فروریختن قسمتی از سقف و بیانگر تخریب شدید است. از طرفی دیگر، لکه‌های سفید نیز بیانگر تخریب کم می‌باشند.



شکل ۷- انواع ناهنجاری‌های ارتفاعی؛ الف) ارتوفتو، ب) ابرنقطه (رنگ آبی و زرد به ترتیب معرف ناهنجاری ارتفاعی ۱ و ناهنجاری ارتفاعی ۲ است)

علاوه بر این، انباشته شدن توده‌های آوار روی سقف نیز نشان از تخریب کم است [۳۸]. لذا به طور کلی، تخریب باعث ایجاد تغییرات ارتفاعی می‌شود که در ادامه از آن به عنوان ناهنجاری‌های ارتفاعی یاد خواهد شد. این ناهنجاری‌ها باعث می‌شوند تا هیستوگرام ارتفاعی ساختمان تخریب شده نسبت به ساختمان سالم، از حالت یکدست بودن خارج گردد. این ناهنجاری‌های ارتفاعی به دو حالت می‌باشند: الف) ناهنجاری ارتفاعی شماره ۱: در این نوع ناهنجاری، ناحیه‌ی تخریب شده ارتفاعی کمتر از ارتفاع میانگین (میانه) ساختمان دارد. این نوع ناهنجاری متناظر با لکه‌های سیاه در داده‌ی اپتیک و نشان‌دهنده‌ی تخریب شدید هستند. ب) ناهنجاری ارتفاعی شماره ۲: ارتفاع بخش تخریب شده در این ناهنجاری، بیشتر از ارتفاع میانگین/میانه ساختمان است. این نوع ناهنجاری متناظر با آوار انباشته شده روی سقف ساختمان‌ها و نشان‌دهنده‌ی تخریب کم است. لازم به ذکر است با توجه به مشاهدات انجام شده، تغییرات ارتفاعی کم نظیر ترک و از بین رفتن لایه‌ای نازک از سقف ساختمان که نشان از تخریب کم هستند، تغییرات قابل ملاحظه‌ای در DSM ایجاد نمی‌کند؛ از این رو، برای شناسایی این نوع تغییرات ارتفاعی باید از تصویر اپتیک کمک گرفت که در بخش قبل بیان شد. شکل ۷ انواع ناهنجاری ارتفاعی را نشان می‌دهد.



شکل ۸- روش درخت حذفی ارائه شده جهت شناسایی تخریب ساختمان در ۴ درجه

۵- نتایج و ارزیابی

به منظور ارزیابی کارایی روش ارائه شده، دو منطقه از زلزله سرپل ذهاب در نظر گرفته شده‌اند. منطقه اول و دوم به ترتیب دارای ۵۲ و ۱۴۲ ساختمان هستند. شکل ۹، نقشه‌های تخریب بدست آمده به روش درخت تصمیم‌گیری حذفی پیشنهاد شده در این تحقیق را به همراه نقشه‌های مرجع تخریب که براساس استاندارد EMS-98 تهیه شده است نشان می‌دهد. در این نقشه، درجات تخریب یک الی چهار، به ترتیب با رنگ‌های سبز، زرد، نارنجی و قرمز نشان داده شده‌اند. لازم به ذکر است به دلیل آنکه نقشه‌ی تخریب تولیدشده از این منطقه توسط سازمان بین المللی UNITAR^۲ که با استفاده از تفسیر بصری تصاویر ماهواره‌ای Pleiades (۰.۵ متری) تولید شده است و نیز نقشه‌های تخریب حاصل‌شده در مطالعات پیشین، فاقد تفکیک درجات تخریب است، لذا از مقایسه‌ی نقشه‌ی تخریب بدست آمده در این مقاله با موارد مذکور به ناچار پرهیز شده‌است. همچنین، به دلیل عدم دسترسی به داده‌های میدانی، از نقشه‌ی مرجع تخریب که به کمک مشاهده داده‌های با رزولوشن سه سانتی‌متری و ابرنقاط سه‌بعدی توسط نویسندگان تهیه شده‌است، استفاده شده است.

جدول ۳- هیستوگرام ارتفاعی DSM بعد از زلزله

تعداد ناهنجاری ارتفاعی	هیستوگرام ارتفاعی	DSM بعد از زلزله	ارتوفتو بعد از زلزله
۱۰۳			
۲۰۶			
۲۴			
۱۹			


در این مقاله، به منظور تفکیک تخریب شدید از تخریب کم، الگوریتم DBSCAN^۱ استفاده شده‌است. این الگوریتم یک روش خوشه‌بندی نظارت‌نشده‌ی چگالی‌مبنا است [۶۰]. با استفاده از این روش، می‌توان تعداد پیکسل‌های با ارتفاع متفاوت از ارتفاع غالب را در هر ساختمان شناسایی نمود که در این تحقیق از آن‌ها به عنوان ناهنجاری‌های ارتفاعی ناشی از زلزله یاد شده‌است. مقادیر منفی در خوشه‌بندی DBSCAN، بیانگر ناهنجاری‌های ارتفاعی هستند. جدول ۳، هیستوگرام ارتفاعی DSM بعد از زلزله را به همراه تعداد پیکسل‌های ناهنجاری ارتفاعی نشان می‌دهد. با توجه به این جدول، هرچه میزان تخریب ساختمان شدیدتر باشد، تعداد ناهنجاری‌های ارتفاعی آن نیز بیشتر است.

۴-۵- تولید نقشه‌ی تخریب

در گام آخر، با استفاده از اصول و روش‌های پیش‌تر مطرح شده برای شناسایی هر یک از درجات تخریب، درخت تصمیم‌گیری حذفی برای تولید نقشه‌ی تخریب ساختمان‌ها با داشتن صرفاً تصاویر بعد از زلزله طراحی شده‌است. این درخت در شکل ۸ نمایش داده شده‌است.


^۲ <https://unitar.org/maps/map/2732>

^۱ Density-Based Spatial Clustering of Applications with Noise



شکل ۹- تولید نقشه‌ی تخریب به روش درختی حذفی در ۴ درجه تخریب؛ (الف) نقشه‌ی تخریب منطقه ۱، (ب) نقشه‌ی مرجع تخریب منطقه ۱، (ج) نقشه‌ی تخریب منطقه ۲، (د) نقشه‌ی مرجع تخریب منطقه ۲ و (ه) راهنمای نقشه

همچنین، نکته‌ی قابل توجه دیگر، عملکرد مناسب روش ارائه‌شده در مورد ساختمان‌های سالم با سقف شیروانی است.



شکل ۱۰- ارزیابی دقت روش تولید نقشه‌ی تخریب ارائه‌شده

از طرف دیگر، حضور گیاهانی با سبزیگی کم و بوته‌های خشکی که شاخص گیاهی استفاده‌شده قادر به شناسایی آن‌ها نیست، وجود اشیا روی پشت بام‌ها، نظیر کیسه‌های پلاستیکی که روی کولر و وسایل کشیده شده، فرشی که پهن شده باشد، ساختمان‌هایی با سقف غیر یکدست

اعتبارسنجی روش تولید نقشه‌ی تخریب پیشنهادشده، با استفاده از معیارهای دقت کلی^۱ و ضریب کاپا^۲ انجام شده‌است. نتایج ارزیابی دقت و سرعت انجام‌شده در دو منطقه ذکر شده، در شکل‌های ۱۰ و ۱۱ قابل مشاهده است. با توجه به شکل ۱۱، دقت کلی روش ارائه‌شده در منطقه‌ی اول و دوم به ترتیب ۸۶٫۵٪ و ۸۸٫۷٪ است. همچنین، ضریب کاپا بدست‌آمده نیز برای منطقه‌ی اول مطالعاتی ۸۱٪ و در منطقه دوم ۶۵٫۹٪ می‌باشد. همچنین شکل ۱۲، بیانگر سرعت پردازشی مطلوب روش پیشنهادی است که به ترتیب در منطقه‌ی مطالعاتی اول و دوم ۴٫۸ ثانیه و ۱۴٫۷۴ ثانیه است. باتوجه به نتایج حاصل، روش ارائه‌شده توانسته است نقشه‌ی تخریبی با دقت مطلوب و در مدت‌زمان پردازشی بسیار کمی تولید کند.

^۱ Overall Accuracy

^۲ Kappa Coefficient


ارزیابی‌های خسارات انجام شده درمورد زلزله‌ی سرپل ذهاب، هنوز نیز فقدان برآورد تخریبی منطبق با استانداردهای جهانی احساس می‌شود [۱۷] و [۶۴] - [۶۱].

از این رو، مطالعه‌ی این زلزله به عنوان یکی از زیان بارترین زلزله‌های تاریخ ایران، همراه با در نظر گرفتن سه مولفه‌ی متضاد دقت، سرعت و هزینه، می‌تواند گام بزرگی در راستای ارائه‌ی روشی مناسب برای استفاده در سازمان‌های ذی‌ربط بردارد. علاوه بر این، پژوهش انجام شده به عنوان اولین تحقیق در زمینه‌ی استفاده از داده‌های پهپاد در ایران در برآورد خسارت زلزله، می‌تواند چشم‌انداز سودمندی از مزایا و چالش‌های احتمالی این داده‌ی سنجش از دوری در اختیار قرار دهد.

سپاسگزاری

نویسندگان از آزمایشگاه پوششگرهای لیزری دانشکده‌ی مهندسی نقشه برداری دانشگاه صنعتی خواجه نصیرالدین طوسی (<https://kntu.ac.ir/lidar>) به دلیل در اختیار قرار دادن داده‌های پهپادی مورد استفاده در این تحقیق، کمال تشکر را دارند.

(مانند وجود خرپشته) و نیز خطاهای تطبیق^۱ فتوگرامتری در فرایند تولید ارتوفتو و DSM از جمله منابع خطای این روش می‌باشند که در تحقیقات بعدی باید به آن‌ها پرداخته شود.



شکل ۱۱- ارزیابی سرعت روش تولید نقشه‌ی تخریب ارائه شده

۶- نتیجه گیری

در این تحقیق، یک روش حذفی درختی خودکار جهت تولید نقشه‌ی تخریب ساختمان‌ها با استفاده از داده‌های پهپاد بعد از زلزله ارائه شد که از سرعتی در حد چند ثانیه و دقتی بین ۸۶٫۵۳٪ تا ۸۸٫۷۳٪ برخوردار است. با این حال، یکی از بزرگترین چالش‌های تصاویر پهپادی در زمینه‌ی تولید نقشه‌ی تخریب ساختمان‌ها، حضور سایه در تصاویر است که موجب تشخیص اشتباه سایه به عنوان تخریب، به ویژه در درجه "تخریب کم" می‌شود. لذا پیشنهاد می‌شود تا مسئله‌ی سایه در تحقیقات آتی مورد توجه قرار گیرد. همچنین، جهت شناسایی مناطق گیاهی خشک و با سبزی‌نگی کم، لازم است روش دقیق‌تری نسبت به شاخص استفاده شده ارائه شود.

علاوه بر این، تفکیک تخریب خیلی سنگین از تخریب شدید و نیز بررسی تخریب ساختمان‌های نیمه-کاره در مطالعات آینده می‌تواند بررسی شود. همچنین، بررسی تاثیر و حساسیت سنجی قدرت تفکیک مکانی تصاویر بر روی دقت درجات تخریب شناسایی شده، از دیگر مباحثی است که در تحقیقات آینده می‌تواند دنبال شود. علاوه بر این، لازم است تا بروز بودن لایه‌های برداری ساختمان‌ها جهت بهره‌وری از پتانسیل روش ارائه شده، در دستور کار نهادهای مربوطه قرار گیرد. در آخر، شایان ذکر است که علی‌رغم

^۱ Matching

مراجع

- [1] P. Hoeppe, "Trends in weather related disasters - Consequences for insurers and society," *Weather Clim. Extrem.*, vol. 11, pp. 70–79, 2016, doi: 10.1016/j.wace.2015.10.002.
- [2] J. L. Nel et al., "Natural hazards in a changing world: A case for ecosystem-based management," *PLoS One*, vol. 9, no. 5, 2014, doi: 10.1371/journal.pone.0095942.
- [3] M. Coronese, F. Lamperti, K. Keller, F. Chiaromonte, and A. Roventini, "Evidence for sharp increase in the economic damages of extreme natural disasters," *Proc. Natl. Acad. Sci. U. S. A.*, vol. 116, no. 43, pp. 21450–21455, 2019, doi: 10.1073/pnas.1907826116.
- [4] O. Altan et al., "Photogrammetry and geographic information systems for quick assessment, documentation and analysis of earthquakes," *ISPRS J. Photogramm. Remote Sens.*, vol. 55, no. 5–6, pp. 359–372, 2001, doi: 10.1016/S0924-2716(01)00025-9.
- [5] C. Axel and J. van Aardt, "Building damage assessment using airborne lidar," *J. Appl. Remote Sens.*, vol. 11, no. 04, p. 1, 2017, doi: 10.1117/1.jrs.11.046024.
- [6] S. Baker, "San francisco in ruins:The 1906 aerial photographs of george r. Lawrence," *Lawrence. Landsc.*
- [7] D. Moher et al., "Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement," *PLoS Med.*, vol. 6, no. 7, 2009, doi: 10.1371/journal.pmed.1000097.
- [8] J. Chen, W. Chen, A. Dou, W. Li, and Y. Sun, "Research on optimal observation scale for damaged buildings after earthquake based on optimal feature space," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 42, no. 3, pp. 155–160, 2018, doi: 10.5194/isprs-archives-XLII-3-155-2018.
- [9] L. Dong and J. Shan, "A comprehensive review of earthquake-induced building damage detection with remote sensing techniques," *ISPRS J. Photogramm. Remote Sens.*, vol. 84, pp. 85–99, 2013, doi: 10.1016/j.isprsjrs.2013.06.011.
- [10] F. Eslamizade, H. Rastiveis, N. K. Zahraee, A. Jouybari, and A. Shams, "Decision-level fusion of satellite imagery and LiDAR data for post-earthquake damage map generation in Haiti," *Arab. J. Geosci.*, vol. 14, no. 12, 2021, doi: 10.1007/s12517-021-07293-y.
- [11] M. Janalipour and A. Mohammadzadeh, "A novel and automatic framework for producing building damage map using post-event LiDAR data," *Int. J. Disaster Risk Reduct.*, vol. 39, no. March, p. 101238, 2019, doi: 10.1016/j.ijdrr.2019.101238.
- [12] N. Khodaverdi, H. Rastiveis, and A. Jouybari, "Combination of Post-Earthquake LiDAR Data and Satellite Imagery for Combination of Post-Earthquake LiDAR Data and Satellite Imagery for Buildings Damage detection," no. September, pp. 11–20, 2019, doi: 10.22059/eoge.2019.278307.1046.
- [13] K. Khoshelham, S. Oude Elberink, and S. Xu, "Segment-based classification of damaged building roofs in aerial laser scanning data," *IEEE Geosci. Remote Sens. Lett.*, vol. 10, no. 5, pp. 1258–1262, 2013, doi: 10.1109/LGRS.2013.2257676.
- [14] H. Xiu, T. Shinohara, M. Matsuoka, M. Inoguchi, K. Kawabe, and K. Horie, "Collapsed building detection using 3D point clouds and deep learning," *Remote Sens.*, vol. 12, no. 24 1, p. 24, 2020, doi: 10.3390/rs12244057.
- [15] P. Ge, H. Gokon, and K. Meguro, "A review on synthetic aperture radar-based building damage assessment in disasters," *Remote Sens. Environ.*, vol. 240, no. July 2019, p. 111693, 2020, doi: 10.1016/j.rse.2020.111693.
- [16] L. Moya et al., "Detecting urban changes using phase correlation and ℓ_1 -based sparse model for early disaster response: A case study of the 2018 Sulawesi Indonesia," *Remote Sens. Environ.*, vol. 242, no. July 2019, p. 111743, 2020, doi: 10.1016/j.rse.2020.111743.
- [17] M. Hasanlou, R. Shah-Hosseini, S. T. Seydi, S. Karimzadeh, and M. Matsuoka, "Earthquake damage region detection by multitemporal coherence map analysis of radar and multispectral imagery," *Remote Sens.*, vol. 13, no. 6, 2021, doi: 10.3390/rs13061195.
- [18] W. Zhai, C. Huang, and W. Pei, "Building damage assessment based on the fusion of multiple texture features using a single post-Earthquake PolSAR image," *Remote Sens.*, vol. 11, no. 8, 2019, doi: 10.3390/rs11080986.
- [19] X. Yuan et al., "Automated building segmentation and damage assessment from satellite images for disaster relief," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 43, no. B3-2021, pp. 741–748, 2021, doi: 10.5194/isprs-archives-XLIII-B3-2021-741-2021.
- [20] M. Moradi and R. Shah-Hosseini, "Earthquake Damage Assessment Based on Deep Learning Method Using VHR Images," *Environ. Sci. Proc.*, vol. 5, no. 1, p. 16, 2020, doi: 10.3390/iecg2020-08545.

- [21] B. Kalantar, N. Ueda, H. A. H. Al-najjar, and A. A. Halin, "Assessment of Convolutional Neural Network Architectures for Earthquake-Induced Building Damage Detection based on Pre- and Post-Event Orthophoto Images," 2020.
- [22] B. F. Davoud Omarzadeh, Sadra Karimzadeh, Masashi Matsuoka, "Earthquake Aftermath from Very High-Resolution WorldView-2 Image and Semi-Automated Object-Based Image Analysis (Case Study: Kermanshah, Sarpol-e Zahab, Iran)," *Remote Sens. mdpi*, 2021.
- [23] M. Ji, L. Liu, R. Du, and M. F. Buchroithner, "A comparative study of texture and convolutional neural network features for detecting collapsed buildings after earthquakes using pre- and post-event satellite imagery," *Remote Sens.*, vol. 11, no. 10, 2019, doi: 10.3390/rs11101202.
- [24] D. Song, X. Tan, B. Wang, L. Zhang, X. Shan, and J. Cui, "Integration of super-pixel segmentation and deep-learning methods for evaluating earthquake-damaged buildings using single-phase remote sensing imagery," *Int. J. Remote Sens.*, vol. 41, no. 3, pp. 1040–1066, 2020, doi: 10.1080/01431161.2019.1655175.
- [25] G. Abdi and S. Jabari, "A Multi-Feature Fusion Using Deep Transfer Learning for Earthquake Building Damage Detection A Multi-Feature Fusion Using Deep Transfer Learning for Earthquake," *Can. J. Remote Sens.*, vol. 47, no. 2, pp. 337–352, 2021, doi: 10.1080/07038992.2021.1925530.
- [26] K. Iizuka, M. Itoh, S. Shiodera, T. Matsubara, M. Dohar, and K. Watanabe, "Advantages of unmanned aerial vehicle (UAV) photogrammetry for landscape analysis compared with satellite data: A case study of postmining sites in Indonesia," *Cogent Geosci.*, vol. 4, no. 1, p. 1498180, 2018, doi: 10.1080/23312041.2018.1498180.
- [27] F. Nex, D. Duarte, F. G. Tonolo, and N. Kerle, "Structural building damage detection with deep learning: Assessment of a state-of-the-art CNN in operational conditions," *Remote Sens.*, vol. 11, no. 23, 2019, doi: 10.3390/rs11232765.
- [28] N. Kerle, F. Nex, M. Gerke, D. Duarte, and A. Vetrivel, "UAV-based structural damage mapping: A review," *ISPRS Int. J. Geo-Information*, vol. 9, no. 1, pp. 1–23, 2020, doi: 10.3390/ijgi9010014.
- [29] S. S. Matin and B. Pradhan, "Challenges and limitations of earthquake-induced building damage mapping techniques using remote sensing images-A systematic review," *Geocarto Int.*, vol. 0, no. 0, pp. 1–27, 2021, doi: 10.1080/10106049.2021.1933213.
- [30] N. Kerle, F. Nex, M. Gerke, D. Duarte, and A. Vetrivel, "UAV-based structural damage mapping: A review," *ISPRS Int. J. Geo-Information*, vol. 9, no. 1, 2019, doi: 10.3390/ijgi9010014.
- [31] G. G. (Ed.), "European Macroseismic Scale 1998 (EMS-98). European Seismological Commission, subcommission on Engineering Seismology.," *Cons. l'Europe, Cah. du Cent. Eur. Géodynamique Séismologie*, 15, Luxemb. 99 pp., 1998.
- [32] A. Calantropio, F. Chiabrando, M. Codastefano, and E. Bourke, "Deep Learning for Automatic Building Damage Assessment: Application in Post-Disaster Scenarios Using Uav Data," *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. V-1–2021, pp. 113–120, 2021, doi: 10.5194/isprs-annals-v-1-2021-113-2021.
- [33] Z. Zheng, Y. Zhong, J. Wang, A. Ma, and L. Zhang, "Building damage assessment for rapid disaster response with a deep object-based semantic change detection framework: From natural disasters to man-made disasters," *Remote Sens. Environ.*, vol. 265, no. July, p. 112636, 2021, doi: 10.1016/j.rse.2021.112636.
- [34] U. Bhangale, S. Durbha, A. Potnis, and R. Shinde, "RAPID EARTHQUAKE DAMAGE DETECTION USING DEEP LEARNING FROM VHR REMOTE SENSING IMAGES K. J. Somaiya College of Engineering, Vidyavihar, Mumbai 400077, India Centre of Studies in Resources Engineering, IIT Bombay, Powai, Mumbai - 400076, India," *IGARSS 2019 - 2019 IEEE Int. Geosci. Remote Sens. Symp.*, pp. 2654–2657, 2019.
- [35] M. Moradi and R. Shah-Hosseini, "Earthquake Damage Assessment Based on Deep Learning Method Using VHR Images," *Environ. Sci. Proc.*, vol. 5, no. 1, p. 16, 2021, doi: 10.3390/iecg2020-08545.
- [36] Y. H. Huang, Hui Genyun Sun, Xuming Zhang, "Combined multiscale segmentation convolutional neural network for rapid damage mapping from postearthquake very high-resolution images Hui," *J. Appl. Remote Sens.*, vol. 18, no. 3, pp. 035001–7, 2019, doi: 10.1117/1.
- [37] X. X. Zhu et al., "Deep learning in remote sensing: a review," no. december, 2017, doi: 10.1109/MGRS.2017.2762307.
- [38] S. Cotrufo et al., "Building damage assessment scale tailored to remote sensing vertical imagery," *Eur. J. Remote Sens.*, vol. 51, no. 1, pp. 991–1005, 2018, doi: 10.1080/22797254.2018.1527662.
- [39] P. G. Dell'Acqua, F., "Remote sensing and earthquake damage detection: experiences, limits and perspectives." 2012.

- [40] L. U. A. V Solutions, F. Nex, D. Duarte, A. Steenbeek, and N. Kerle, "Towards Real-Time Building Damage Mapping with Low-Cost UAV Solutions." pp. 1–14, 2019.
- [41] X. Li, W. Yang, T. Ao, H. Li, and W. Chen, "An improved approach of information extraction for earthquake-damaged buildings using high-resolution imagery," *J. Earthq. Tsunami*, vol. 5, no. 4, pp. 389–399, 2011, doi: 10.1142/S1793431111001157.
- [42] T. Zeng, W. N. Yang, and X. D. Li, "Seismic damage information extent about the buildings based on low-altitude remote sensing images of mianzu quake-stricken areas," *Appl. Mech. Mater.*, vol. 105–107, pp. 1889–1893, 2012, doi: 10.4028/www.scientific.net/AMM.105-107.1889.
- [43] A. Vetrivel, M. Gerke, N. Kerle, and G. Vosselman, "Identification of damage in buildings based on gaps in 3D point clouds from very high resolution oblique airborne images ISPRS Journal of Photogrammetry and Remote Sensing Identification of damage in buildings based on gaps in 3D point clouds from very hi," *ISPRS J. Photogramm. Remote Sens.*, vol. 105, no. April, pp. 61–78, 2015, doi: 10.1016/j.isprsjprs.2015.03.016.
- [44] J. Frank, U. Rebbapragada, J. Bialas, T. Oommen, and T. C. Havens, "Effect of label noise on the machine-learned classification of earthquake damage," *Remote Sens.*, vol. 9, no. 8, pp. 1–18, 2017, doi: 10.3390/rs9080803.
- [45] A. Z. Huang, Hui, Genyun Sun, Xuming Zhang, Yanling Hao, "Combined multiscale segmentation convolutional neural network for rapid damage mapping from postearthquake very high-resolution images," *Journal-of-Applied-Remote-Sensing*, 2019.
- [46] Y. Li, W. Hu, H. Dong, and X. Zhang, "applied sciences Building Damage Detection from Post-Event Aerial Imagery Using Single Shot Multibox Detector," 2019, doi: 10.3390/app9061128.
- [47] S. Li and H. Tang, "Classification of Building Damage Triggered by Earthquakes Using Decision Tree," *Math. Probl. Eng.*, vol. 2020, 2020, doi: 10.1155/2020/2930515.
- [48] R. Remote and S. Images, "Improved CNN Classification Method for Groups of Buildings Damaged by Earthquake , Based on High Resolution Remote Sensing Images," 2020.
- [49] H. Ma, Y. Liu, Y. Ren, and J. Yu, "Detection of Collapsed Buildings in Post - Earthquake Remote Sensing Images Based on the Improved YOLOv3," 2020, doi: 10.3390/rs12010044.
- [50] S. Tilon, F. Nex, N. Kerle, and G. Vosselman, "Post-disaster building damage detection from earth observation imagery using unsupervised and transferable anomaly detecting generative adversarial networks," *Remote Sens.*, vol. 12, no. 24, pp. 1–27, 2020, doi: 10.3390/rs12244193.
- [51] M. Miyamjima et al., "Site Investigation of the Sarpole-Zahab Earthquake, Mw 7.3 in SW Iran of November 12, 2017," *JSCE J. Disaster FactSheets*, 2018.
- [52] X. Yuan et al., "Automated Building Segmentation and Damage Assessment From Satellite Images for Disaster Relief," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. XLIII-B3-2, pp. 741–748, 2021, doi: 10.5194/isprs-archives-xxiii-b3-2021-741-2021.
- [53] E. R. H. Jr et al., "A visible band index for remote sensing leaf chlorophyll content at the canopy scale," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 21, pp. 103–112, 2013.
- [54] M. Janalipour and A. Mohammadzadeh, "A novel and automatic framework for producing building damage map using post-event LiDAR data," *Int. J. Disaster Risk Reduct.*, vol. 39, no. July, p. 101238, 2019, doi: 10.1016/j.ijdrr.2019.101238.
- [55] C. Wang et al., "A Detection Method for Collapsed Buildings Combining Post-Earthquake High-Resolution Optical and Synthetic Aperture Radar Images," *Remote Sens.*, vol. 14, no. 5, 2022, doi: 10.3390/rs14051100.
- [56] J. Ding, J. Zhang, Z. Zhan, X. Tang, and X. Wang, "A Precision Efficient Method for Collapsed Building Detection in Post-Earthquake UAV Images Based on the Improved NMS Algorithm and Faster R-CNN," *Remote Sens.*, vol. 14, no. 3, 2022, doi: 10.3390/rs14030663.
- [57] M. Ishii, T. Goto, T. Sugiyama, H. Saji, and K. Abe, "Detection of Earthquake Damaged Areas from Aerial
- [58] D. Lu, G. Li, E. Moran, L. Dutra, and M. Batistella, "The roles of textural images in improving land-cover classification in the Brazilian Amazon," *Int. J. Remote Sens.*, vol. 35, no. 24, pp. 8188–8207, 2014, doi: 10.1080/01431161.2014.980920.
- [59] S. T. Seydi, M. Akhoondzadeh, M. Amani, and S. Mahdavi, "Wildfire damage assessment over australia using sentinel-2 imagery and modis land cover product within the google earth engine cloud platform," vol. 13, no. 2. 2021.
- [60] M. Daszykowski and B. Walczak, "Density-Based Clustering Methods," *Compr. Chemom.*, vol. 2, pp. 635–654, 2009, doi: 10.1016/B978-044452701-1.00067-3.

- [61] B. M. P. Shahbazi, "Loss Modeling for 2017 Sarpol-e Zahab Earthquake," J. Seismol. Earthq. Eng., no. 4, pp. 69–80, 2019.
- [62] O. L. Stephenson et al., "Deep Learning-Based Damage Mapping With InSAR Coherence Time Series," IEEE Trans. Geosci. Remote Sens., 2021, doi: 10.1109/TGRS.2021.3084209.
- [63] H. Aali, A. Sharifi, and A. Malian, "(CASE STUDY : SARPOL-ZAHAB EARTHQUAKE)," vol. XLII, no. October, pp. 12–14, 2019.
- [64] B. F. Omarzadeh, Davoud, Sadra Karimzadeh, Masashi Matsuoka, "Earthquake Aftermath from Very High-Resolution WorldView-2 Image and Semi-Automated Object-Based Image Analysis (Case Study: Kermanshah, Sarpol-e Zahab, Iran)," Remote Sens. mdpi, 2021.