

Performance and Reliability Assessment of Machine and Ensemble Learning Methods for Damage Detection of Reinforced Concrete Buildings

Pouya Mousavian¹, Razi Sheikholeslami^{2*}, Shariar Tavousi Tafreshi³

1 - MSc student of Earthquake Engineering, Islamic Azad University Central Tehran Branch, Tehran, Iran

2 – Assistant Professor, Faculty of Civil Engineering, Sharif University of Technology, Tehran, Iran

3 – Assistant Professor, Department of Civil Engineering, Islamic Azad University Central Tehran Branch, Tehran, Iran

Received: 29 February 2023 Revised: 23 April 2024 Accepted: 25 May 2024

Research paper

Abstract

Traditional methods for detecting damage, reliant on experts and human resources both before and after earthquakes, represent a time-consuming, costly, and inherently uncertain process. However, this process is pivotal for bolstering societal resilience. The field of structural health monitoring has witnessed significant advancement in recent years, attributed to the proliferation and refinement of Machine Learning (ML) methodologies. In this study, we leverage machine learning techniques, specifically focusing on Ensemble Learning (EL) methods, to improve the efficacy of building damage detection. Our investigation involves employing Support Vector Machine (SVM) and the Bagging methods to assess the extent of damage using datasets from earthquake-affected reinforced concrete buildings in South Korea, Nepal, Ecuador, and Haiti. The outcomes highlight the notable potential of the bagging algorithm, achieving an accuracy rate of 73% in one of the models. Beyond evaluating the performance of ML algorithms, we introduce an innovative Probabilistic Uncertainty Measure (PUM) to quantify the reliability of each method across various damage grades. The results from this analysis underscore the substantial reliability of EL methods, reaching a minimum of 84% in this critical domain. This research signifies a promising step towards more efficient, accurate, and reliable damage detection processes, with the potential to significantly impact disaster resilience initiatives.

Key Words: Damage Detection; Machine Learning; Probabilistic Uncertainty Measure; RC Buildings; Reliability

*Corresponding Author: Razi Sheikholeslami

Mousavian, P., Sheikholeslami, R., Tavousi Tafreshi, S. Performance and Reliability Assessment of Machine and Ensemble Learning Methods for Damage Detection of Reinforced Concrete Buildings. *Journal of Concrete Structures and Materials*, 2023; 8(2): -. <http://doi.org/10.30478/jcsm.2024.446297.1364>

2538-5828/ © 2024 The Authors. Published by Iranian Concrete Society

This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

مقایسه عملکرد و قابلیت اعتماد روش‌های یادگیری ماشین و یادگیری تجمیعی برای تشخیص آسیب در ساختمان‌های بتن مسلح

پویا موسویان^۱، سید رضی شیخ‌الاسلامی^{۲*}، شهریار طاوسی تفرشی^۲

۱ - دانشجوی کارشناسی ارشد زلزله، گروه مهندسی عمران و منابع زمین، دانشگاه آزاد اسلامی واحد تهران مرکزی

۲ - استادیار، دانشکده عمران، دانشگاه صنعتی شریف*

۳ - استادیار، گروه مهندسی عمران و منابع زمین، دانشگاه آزاد اسلامی واحد تهران مرکزی

پست الکترونیکی نویسنده مسئول: razi.sheikhosslami@sharif.edu

تاریخ دریافت: ۱۴۰۲/۱۲/۱۰، تاریخ بازنگری: ۱۴۰۳/۰۲/۰۴، تاریخ پذیرش: ۱۴۰۳/۰۳/۰۵

نوع مقاله: پژوهشی

چکیده

روش‌های مرسوم در تشخیص آسیب ساختمان‌ها عموماً زمان‌بر پرهزینه و با عدم قطعیت بالایی هستند. در سال‌های اخیر با گسترش و توسعه یادگیری ماشین و هوش مصنوعی از این روش‌ها در مهندسی عمران و زلزله استفاده به صورت گسترده‌ای استفاده شده است. در این مطالعه با استفاده از روش‌های یادگیری ماشین به ویژه یادگیری تجمیعی روند تشخیص آسیب ساختمان‌ها بهبود یافته است. مقایسه عملکرد دو الگوریتم ماشین بردار پشتیبان و بگینگ بر روی داده‌های ساختمان‌های بتن مسلح آسیب دیده از چهار کشور (نیپال کره جنوبی هائیتی و اکوادور) نشان می‌دهد که روش یادگیری تجمیعی با دقت ۷۳٪ عملکرد بهتری دارد. همچنین در مطالعه حاضر یک شاخص نوین جهت سنجش عدم قطعیت نتایج بدست آمده از الگوریتم‌های یادگیری ماشین نیز معرفی شده است. این شاخص قابلیت اعتماد هر یک از روش‌ها را در شناسایی درجه آسیب ساختمان‌ها محاسبه می‌کند. نتایج نشان می‌دهد که نتایج روش یادگیری تجمیعی قابلیت اعتماد بالاتری با حداقل ۸۴٪ را دارد.

کلمات کلیدی: تشخیص آسیب؛ یادگیری ماشین؛ معیار عدم قطعیت احتمالاتی؛ ساختمان بتن مسلح؛ قابلیت اعتماد

کاهش ریسک‌های اجتماعی-اقتصادی در بخش‌های عمومی و خصوصی در دوره‌های پیش و پس از زلزله نیازمند اقدامات مهمی است تا به ارزیابی آسیب‌پذیری ساختمان‌های موجود بپردازد. عدم شناسایی به‌موقع خسارات بهسازی و بازسازی در ساختمان‌ها می‌تواند به کاهش ایمنی کاهش ارزش ملک و افزایش هزینه‌های نگهداری منجر شود. بنابراین به‌منظور کاهش هزینه‌های تعمیر و جلوگیری از خطرات احتمالی تشخیص خسارت اولیه امری حیاتی است. روش‌های سنتی تشخیص آسیب معمولاً توسط مشاهده بصری شخصی اجرا می‌شوند تا پس از یک زلزله یا حوادث خطرناک دیگر در ساختمان‌ها پل‌ها و سازه‌های دیگر خسارات در عناصر سازه‌ای و غیرسازه‌ای را شناسایی کنند. روش‌های معمول ممکن است شهودی بوده و بستگی به تجربه بازرسان داشته باشد. همچنین بازرسی بصری و ارزیابی دستی خسارات معمولاً بسیار زمان‌بر هستند [۱-۲]. برای مقابله با این چالش‌ها در تحقیقات تشخیص و ارزیابی خسارت اخیراً از به کارگیری روش‌های یادگیری ماشین (ML) پیشنهاد شده است.

یادگیری ماشین ابزار منحصر به فردی است که با داشتن مزایای مهمی برای حل مسائل تشخیص خسارت در ساختمان‌ها می‌تواند مورد استفاده قرار بگیرد [۳-۶]. مزیت مهم این الگوریتم‌ها قابلیت کار با انواع مختلف داده‌های ورودی از جمله تصویر ویدئو داده‌های حسگرها و داده‌های تاریخی است که برای شناسایی خسارات و الگوهای احتمالی به کار می‌رود. به عنوان مثال با تجزیه و تحلیل تصاویر نمای ساختمان یا عناصر سازه‌ای الگوریتم‌های یادگیری ماشین می‌توانند ترک‌ها جابجایی‌ها یا سایر نشانه‌های خسارت را شناسایی کنند. برای مثال از شبکه‌های عصبی پیچشی (CNN)^۱ برای تشخیص آسیب ساختمان‌ها با استفاده از عکس و فیلم استفاده شده است [۷]. مثال دیگر استفاده از الگوریتم ماشین‌های بردار پشتیبان (SVM)^۲ آموزش داده شده براساس داده‌های سنسورها برای نظارت سلامت سازه‌ای است [۸]. علاوه بر این در مقایسه با روش‌های سنتی روش‌های مبتنی بر ML نتایج کمی و ثابتی را فراهم می‌کنند. به عبارت دیگر بدون توجه به تجربه کاربر نتایج آن‌ها ثابت و تکرارپذیر خواهد بود. به ویژه به‌منظور نگهداری و کاهش هزینه‌های تعمیرات احتمالی سازه‌ها این الگوریتم‌ها می‌توانند در تشخیص یا پیش‌بینی خسارت احتمالی حتی قبل از وقوع زلزله به کار گرفته شوند [۹].

مطالعات گسترده و گوناگونی در رابطه با کاربرد تکنیک‌های یادگیری ماشین و یادگیری عمیق در تشخیص آسیب ساختمان‌ها صورت گرفته است [۱۰]. برای مثال (نکس^۳ و همکاران) [۱۱] در مطالعه خود با استفاده از یک شبکه عصبی مصنوعی پیچشی بر روی داده‌های ماهواره‌ای از مناطق آسیب دیده توانسته‌اند به مدلی با کارایی بالا برای تشخیص آسیب مناطق زلزله‌زده با استفاده از تصاویر ماهواره‌ای در لحظه برسند. همچنین کاربرد ترکیب چند مدل شبکه عصبی پیچشی معروف مانند (ResNet)^۴ و (U-Net) برای تشخیص آسیب خودکار را می‌توان در مطالعه بای^۵ و همکاران [۱۲] یافت. مدل آن‌ها توانست در کنار دستیابی به عملکرد بالا در سطح محل وقوع سطح آسیب و نوع مصالح به دقت بالایی در طبقه بندی و جانمایی آسیب سازه‌ای برسد. همچنین چون^۶ و همکاران [۱۳] با ارائه‌ی یک الگوریتم ML در مطالعه خود به نام (LightGBM)^۷ توانستند بصورت خودکار ترک‌های روی سطوح بتنی را شناسایی کنند. بعلاوه استفاده از تصاویر هوایی بلافاصله پس از وقوع زلزله برای شناسایی ساختمان‌های آسیب دیده منطقه توسط

¹ Convolutional Neural Network

² Support Vector Machine

³ Nex

⁴ Residual Neural Network

⁵ Bai

⁶ Chun

⁷ Light Gradient Boosting Machine

نایتو^۸ و همکاران [۱۴] بررسی شده است که با ترکیب مدل‌های مبتنی بر ML نشان داده شد که بکارگیری چند الگوریتم یادگیری ماشینی می‌تواند موجب عملکرد بالای مدل نهایی شود. به عنوان یک مثال دیگر رویکردهای ML در شناسایی ترک در سازه‌های بتنی توسط میر^۹ و همکاران [۱۵] انجام شده است. نتایج پژوهش آن‌ها نشان می‌دهد که استفاده از الگوریتم‌های یادگیری ماشین برای شناسایی ترک در سازه‌ها در مواقعی‌ای که با کمبود تصاویر با وضوح بالا مواجه هستیم می‌تواند بسیار مناسب و کارآمد باشد. یکی از معمول‌ترین الگوریتم‌های یادگیری ماشین که بصورت مکرر در حل مسائل مربوط به طبقه‌بندی مورد استفاده قرار می‌گیرد الگوریتم ماشین‌های بردار پشتیبان است [۱۶-۱۷]. این الگوریتم ظرفیت بالایی در حل مسائلی دارد که با کمبود داده مواجه‌اند و همچنین دارای روابط غیرخطی و ابعاد زیادی هستند [۱۸]. با استفاده از توانایی الگوریتم ماشین بردار پشتیبان در حل مسائل طبقه‌بندی یک مدل یادگیری ماشین در طبقه‌بندی درجه‌بندی آسیب وارد به سازه برای ارزیابی ایمنی لرزه‌ای ساختمان‌های بتن مسلح توسط حریرچیان^{۱۰} و همکاران [۱۶] توسعه داده شده است. در مطالعه آن‌ها مدل پیشنهادی بر روی مجموعه داده جمع‌آوری شده از ساختمان‌های بتن مسلح بعد از زلزله‌های مشخص از کشورهای مختلف آموزش داده شده است. مطالعه آن‌ها نشان می‌دهد که مدل مبتنی بر ML توانسته عملکرد مناسبی در قبال ارزیابی ایمنی لرزه‌ای ساختمان‌های بتن مسلح داشته باشد. مدل آن‌ها بر روی داده‌های ورودی که شامل تعداد طبقه مساحت طبقه اول مجموع مساحت ستون‌های طبقه اول و غیره بوده آموزش داده شده و در نهایت نشان داده شده است که این مدل بر روی داده‌های آزمایش نیز عملکرد مناسبی دارد. باید خاطر نشان ساخت علاوه بر مزایای مدل‌های مبتنی بر ML در حل مسائل تشخیص آسیب کاربرد آن‌ها با چالش‌های مهمی نیز روبرو خواهد شد. از جمله می‌توان به نیازمند بودن این روش‌ها به داده‌های با حجم و کیفیت بالا اشاره کرد. چالش عمده دیگر این است که مدل‌های مبتنی بر ML می‌توانند پیچیده و نیازمند به هزینه محاسباتی بالا برای آموزش و پیاده‌سازی باشند.

به‌منظور بهبود دقت و کارایی فرآیند تشخیص خسارت و احتمالاً کاهش زمان و منابع مورد نیاز برای بازرسی و نگهداری مقایسه عملکرد تکنیک‌های مختلف یادگیری ماشین مهم است. به علاوه مقایسه نتایج چند روش می‌تواند در ایجاد یک معیار یا استاندارد برای ارزیابی کارایی سایر تکنیک‌های تشخیص خسارت کمک کند. این امر می‌تواند برای پژوهشگرانی که در حال ایجاد الگوریتم‌های جدید برای شناسایی و یا محل‌یابی خسارت هستند و همچنین مالکان و مدیران ساختمان که نیاز به ارزیابی کیفیت خدمات بازرسی دارند نیز مفید باشد. علاوه بر این مقایسه عملکرد تکنیک‌های مختلف می‌تواند منجر به بهبود بینش و کشف الگوها و داده‌ها در رابطه با نگاه ما به مسئله شود که این امر منجر به بالاتر رفتن درک ما در یافتن فاکتورهای تاثیرگذار در شناسایی آسیب ساختمان‌ها شود. در نتیجه این پژوهش در نظر دارد که با آزمایش مدل‌های مختلف یادگیری ماشین که بطور معمول در حل مسائل طبقه‌بندی مورد استفاده قرار می‌گیرند؛ یک چهارچوب برای ارزیابی ایمنی لرزه‌ای ساختمان‌های بتن مسلح ایجاد کند و همچنین با معرفی یک شاخص عدم قطعیت احتمالاتی مبتنی بر عملکرد مدل‌ها بهترین مدل با بالاترین دقت و کمترین عدم قطعیت را برای تشخیص درجه آسیب ساختمان‌های بتنی معرفی کند. این مدل‌ها بر روی مجموعه داده‌های ساختمان‌های بتنی بعد از زلزله‌های مشخص از چهار کشور مختلف شامل کره جنوبی، نپال، هائیتی و اکوادور آموزش داده شده‌اند و سپس عملکرد و قابلیت اعتماد هر مدل بر روی مجموعه داده استخراج و تحلیل شده است.

⁸ Naito

⁹ Mir

¹⁰ Harirchian

۲- روش تحقیق

در این پژوهش داده‌های عددی مربوط به مشخصات سازه‌های ساختمان‌های بتن مسلح بعد از زلزله‌های مشخص از چهار کشور کره جنوبی، نپال، هائیتی و اکوادور از منبع مجموعه‌های داده‌ی علمی [۱۹] جمع‌آوری شده‌اند. بطور کلی این پایگاه‌های داده توسط تیم‌های تحقیقاتی خبره دانشگاهی محلی و تحت نظر انجمن علمی بتن آمریکا جمع‌آوری شده‌اند که باعث یکپارچگی داده‌های جمع‌آوری شده است و همچنین بالارفتن قابلیت اعتماد این پایگاه‌های داده شده است که هر یک بصورت خلاصه در بخش بعدی شرح داده شده‌اند.

این پایگاه‌های داده بصورت آزاد قابل دسترسی هستند که می‌توان در آینده برای توسعه چنین روش‌هایی استفاده شوند تا توانایی مقایسه عملکرد چهارچوب‌ها فراهم شوند. نکته دیگر این است که با داشتن داده از مکان‌های جغرافیایی مختلف و روش ساخت متفاوت حساسیت ویژگی آیین نامه ساخت در کشورهای مختلف در بخش یادگیری الگوریتم‌ها حذف می‌شود که می‌تواند منجر به رسیدن به چهارچوبی غیر منطقه‌ای شود. با این وجود داشتن داده‌های بیشتر از آسیب ساختمان‌ها در زلزله‌های مختلف و مناطق مختلف منجر به توسعه مدلی دقیق‌تر و قدرتمندتر می‌شود.

۱-۲ معرفی زلزله‌های انتخابی

زلزله مورد مطالعه کشور نپال زلزله‌ای است که در ماه می سال ۲۰۱۵ میلادی رخ داد. با همکاری انجمن بتن آمریکا (ACI) دو تیم تحقیقاتی از دانشگاه پوردو و موسسه فناوری ناگویا^{۱۱} آسیب‌های رسیده به ساختمان‌های بتنی پس از زلزله مذکور مورد مطالعه قرار دادند. ۱۳۵ ساختمان بتنی با ارتفاع کوتاه با و یا بدون دیوارهای داخلی بنایی مشمول این مجموعه داده هستند که در مطالعه تکمیلی شاه^{۱۲} و همکاران [۲۰] جمع‌آوری و طبقه‌بندی شده‌اند. مشخصات خاک رسوبی منطقه زلزله‌زده دره‌ی کاتماندو^{۱۳} معمولاً شامل ترکیب ناهمگون ماسه رس و سیلت‌ها با ضخامت ۴۰۰ متر است [۲۱]. براساس نقشه لرزه برررسی زمین‌شناسی ایالات متحده^{۱۴} حرکت زمین با شدت VIII بوده و با فاصله رومرکزی ۱۹ کیلومتری از جنوب شرقی شهر کوداری^{۱۵} رخ داده است.

دومین زلزله انتخابی مربوط به کشور اکوادور در شانزدهم آوریل سال ۲۰۱۶ است که مناطق ساحلی منابی^{۱۶} و حومه را تحت تاثیر قرار داد. جمع‌آوری داده ساختمان‌های بتن مسلح آسیب دیده توسط تحریک زلزله توسط تیم تحقیقاتی انجمن بتن آمریکا به همراه یک تیم متشکل از دانشگاهیان دانشگاه (ESPOL)^{۱۷} انجام شده است [۲۲]. مجموعه داده ذکر شده شامل دو نوع مشخصات خاکی به نام‌های APO1 (که بر مبنای نام ایستگاه شتابنگاشت منطقه بوده) و لوس تماریندوس^{۱۸} است. پروفایل خاک APO1 در میان خاک‌های آبرفتی و نهشته‌های کلویی با سرعت موج برشی متوسط با ارتفاع ۳۰ متر (Vs30) برابر با ۲۴۰ متر بر ثانیه قرار دارد. درحالیکه تماریندوس در رسوبات رس و سیلت آبرفتی با Vs30 برابر با ۲۲۰ متر بر ثانیه قرار دارد [۲۳].

سومین مجموعه داده حاوی مشخصات آسیب ساختمان‌های بتن مسلح بعد از زلزله دوازدهم ژانویه سال ۲۰۱۰ میلادی در کشور

¹¹ Nagoya Institute of Technology

¹² Shah

¹³ Kathmandu Valley

¹⁴ ShakeMap of the U.S Geological Survey

¹⁵ Kudari

¹⁶ Manabí

¹⁷ Escuela Superior Politécnica del Litoral

¹⁸ Los Tamarindos

هائیتی است که ۱۴۵ ساختمان بتن مسلح مورد مطالعه لرزه‌شناسان از دانشگاه‌های پوردو^{۱۹} واشینگتن و کانزاس با همکاری محققان دانشگاه د اتات^{۲۰} هائیتی قرار گرفته و جمع‌آوری شده است [۲۴-۲۵]. مشخصات خاک مناطق مورد مطالعه برای جنوب و شمال صفحه‌ی شهر لئوگانه^{۲۱} به ترتیب رسوبات دانه‌ای و خاک رسی نرم طبقه‌بندی شده است که در غرب پورتاو پرنس واقع شده است که بیشترین خرابی و آسیب سازه‌ای را متحمل شده است [۲۶]. براساس نقشه لرزه برررسی زمین‌شناسی ایالات متحده لئوگان و پورتاو پرنس^{۲۲} به ترتیب بیشترین حرکت زمین به میزان شدت IX و VIII را داشته‌اند [۲۷].

در نهایت آخرین مجموعه داده انتخابی برای زلزله پانزدهم نوامبر سال ۲۰۱۵ میلادی کشور کره جنوبی است که بیشتر به دو کلانشهر هیونگائه^{۲۳} و پوهانگ^{۲۴} و حومه آن‌ها خسارات زیادی وارد کرد. بدلیل اتفاق این رخداد هزاران نفر از ساکنین این دو کلانشهر بی‌خانمان شدند که همین امر باعث تحمیل خسارت اقتصادی نزدیک به صد میلیون دلار برای هر دو بخش خصوصی و عمومی در زیرساخت این کشور شد. جمع‌آوری داده‌های این مجموعه نیز با همکاری یک تیم تحقیقاتی از انجمن بتن آمریکا و دیگر موسسات تحقیقاتی و دانشگاه‌های کره جنوبی انجام شده است [۲۸]. مشخصات خاک این مناطق شامل خاک دستی خاک هوازده خاک رسوبی سنگ هوازده و سنگ بستر است. شدت این زلزله براساس نقشه لرزه برررسی زمین‌شناسی ایالات متحده برابر با VII تعیین شده است [۲۹]. جدول ۱ مشخصات و پارامترهای مهندسی زلزله‌های مذکور را دربردارد.

جدول ۱ مشخصات زلزله‌های مورد مطالعه

زلزله	سال	بزرگا (Mw)	بیشینه شتاب زمین (g)	بیشینه سرعت زمین (cm/s)
اکوادور	۲۰۱۶	۷.۸	۰/۴	۸۲
هائیتی	۲۰۱۰	۷	۰/۴	۴۰
نپال	۲۰۱۵	۷.۳	۰/۲	۲۰
کره جنوبی	۲۰۱۷	۵.۴	۰/۲	۱۰

۲-۲ معرفی ویژگی‌های ساختمان‌ها و مجموعه‌های داده

مطالعات بسیاری در حوزه‌ی ارزیابی آسیب‌پذیری لرزه‌ای ساختمان‌ها توسط محققین این حوزه برای بررسی اثربخشی مشخصات سازه‌ای به عنوان داده‌های ورودی صورت گرفته است [۳۱-۳۰]. براساس آئین‌نامه FEMA-154 [۳۲] مناسب‌ترین پارامترهای ورودی شامل الف) نوع سیستم سازه‌ای ب) نامنظمی در ارتفاع پ) نامنظمی در پلان ت) سال ساخت و ث) کیفیت ساخت است. یاکوت و همکاران [۳۳] در مطالعه خود برای ارزیابی ریسک لرزه‌ای ساختمان‌ها پارامترهای بیشتری را مورد بررسی قرار داده‌اند. به دلیل بالا بودن تعداد ساختمان‌های موجود و مشخصات گوناگون هر کدام هشت مشخصه در ساختمان‌های بتن مسلح مربوط به تاثیرپذیری در مواقع زلزله هستند در این پژوهش انتخاب و مورد مطالعه قرار گرفته شده است. هشت ویژگی مربوط به ساختمان‌ها در هر کشور مورد مطالعه عبارتند از: ۱) تعداد طبقات ۲) مجموع مساحت طبقه ۳) مجموع مساحت ستون‌ها در طبقه ۴) مجموع

¹⁹ Purdu

²⁰ Université d'Etat d'Haïti

²¹ Léogâne city

²² Porta Prince

²³ Heunghae

²⁴ Pohang

مساحت دیوار بتنی در جهت X (۵) مجموع مساحت دیوار بتنی در جهت Y (۷) مجموع مساحت دیوارهای بنایی در جهت X (۸) مجموع مساحت دیوارهای بنایی در جهت Y و (۸) محصورشدگی ستون‌ها.

این هشت مشخصه سازه‌ای در مطالعه حسن^{۲۵} و سوزن^{۲۶} [۳۴] نیز برای ارائه‌ی شاخص اولویت (Priority Index) مورد بررسی قرار گرفته شده‌اند. برای حذف تاثیر تفاوت میان آئین‌نامه‌های مختلف و تاثیر آن‌ها بر روی محاسبات این هشت پارامتر انتخاب و آزمایش شده‌اند تا بتوان ارزیابی سازه‌ای درستی از مناطق مختلف داشت. کاربرد انتخاب این ویژگی‌های سازه‌ای این است که می‌توان در مناطق مختلف بدون در نظر گرفتن ضوابط و روش‌های ساخت مخصوص هر منطقه مدل‌سازی و تحلیل صورت داد. همچنین جمع‌آوری داده‌های مربوط به این ویژگی امری کم هزینه و آسان بوده و بازرسین می‌توانند با بررسی‌های بصری به راحتی داده‌ها را ثبت و جمع‌آوری کنند که منجر به کاهش زمان و کم شدن گنگ بودن روش گردآوری اطلاعات می‌شود. در جدول ۲ مشخصات این ویژگی‌ها آورده شده است.

جدول ۲ پارامترهای ارزیابی ایمنی لرزه‌ای انتخاب شده (حریرچیان و لامر^{۲۷}) [۳۲]

متغیر	مولفه	واحد	نوع
α_1	تعداد طبقه	N	کمی
α_2	مجموع مساحت طبقه	m ²	کمی
α_3	مجموع مساحت ستون	m ²	کمی
α_4	مساحت دیوار بتنی X	m ²	کمی
α_5	مساحت دیوار بتنی Y	m ²	کمی
α_6	مساحت دیوار بنایی X	m ²	کمی
α_7	مساحت دیوار بنایی Y	m ²	کمی
α_8	محصور شدگی ستون	{۱ و ۰}	باینری

در این پژوهش طبقه‌بندی براساس میزان و وضعیت آسیب ساختمان‌ها انجام گرفته‌است که رتبه‌بندی و تفسیر هر یک در جدول ۳ گزارش شده است.

جدول ۳ تفسیر و رتبه‌بندی میزان تخریب (برگرفته از یوسمن^{۲۸} و همکاران) [۳۳]

درجه آسیب	سطح آسیب	پدیداری
۰	بدون آسیب	بدون آسیب
۱	کم	باعث ترک‌های مویی در سازه؛ ریختن گچ
۲	متوسط	شکستن گچ؛ شکستن دیوار و دیده شدن مفاصل پانل‌ها
۳	شدید	از بین رفتن دیوارها و پانل‌ها

²⁵ Sozen

²⁶ Hassan

²⁷ Lahmer

²⁸ Yüçemen

داده می‌توان به (۱) مدیریت داده‌های گم‌شده^{۲۹} (۲) شناسایی داده‌های پرت و نویز^{۳۰} (۳) هم مقیاس کردن (۴) داده‌های نامتوازن^{۳۱} اشاره کرد. روش‌های بی‌شماری برای مدیریت داده‌های گم‌شده وجود دارد روش‌های آماری برای محاسبه داده گم‌شده با استفاده از شاخص‌های آماری مجموعه داده در آن ویژگی داده گم‌شده را محاسبه می‌کنند که روش‌های مرسوم جایگذاری مقادیر با یکی از مقادیر میانه میانگین کمینه و بیشینه است. همچنین با انجام روش‌های آماری اقدام به شناسایی داده‌های پرت کرد. از جمله راهکارهای شناسایی داده‌های پرت می‌توان به روش دامنه بین چارکی^{۳۲} (IQR) یا نمودار جعبه‌ای^{۳۳} اشاره کرد. عملکرد بیشتر الگوریتم‌های یادگیری ماشین با داده‌های هم‌مقیاس شده بالاتر می‌روند. داشتن مقادیر از جنس‌ها و مقادیر مختلف در مجموعه‌های داده امری معمول و اجتناب ناپذیر است که می‌تواند باعث افت دقت و عملکرد مدل شود. برای پرهیز از این اتفاق با استفاده از روش‌های آماری ساده مانند روش‌هایی از جمله نرمال‌سازی و استاندارد سازی از این امر جلوگیری می‌شود. با پیاده‌سازی روش نرمال‌سازی به تمام مقادیر در هر ویژگی مقادیری بین صفر تا یک اختصاص داده می‌شود. درحالی‌که با استفاده از روش استانداردسازی توزیع مقادیر داده به توزیعی دارای میانگین صفر و انحراف از معیار واحد ($std = 1$) تبدیل می‌شود.

۳-۱-۲ متوازن سازی داده‌ها

مدل یادگیری ماشین در مواقعی که به میزان مساوی نمونه به ازای هر کلاس دارد بصورت بهینه طبقه‌بندی را انجام می‌دهد. وجود نامتوازنی زیاد داشتن نمونه‌های فراوان به ازای یک کلاس و نمونه‌های اندک در کلاس دیگر منجر به بیش / کم برآزش مدل یادگیری ماشین می‌شود. روش‌های زیادی برای جلوگیری از این امر ایجاد و توسعه داده شده‌اند که برای مثال می‌توان به نمونه‌گیری اتفاقی^{۳۴} اشاره کرد. این روش جزو متداول‌ترین روش‌های جلوگیری از بیش / کم برآزش در مجموعه‌های داده نامتوازن است که شامل دو رویکرد است کم کردن اتفاقی نمونه‌ها^{۳۵} و افزایش اتفاقی نمونه‌ها^{۳۶} که در روش کم کردن اتفاقی داده‌ها داده‌ها در کلاس اکثریت حذف می‌شود تا به کلاس‌ها با تعداد مساوی برسیم که این روش منجر به حذف اطلاعات مسئله می‌شود که در علم داده این اتفاق مطلوب نمی‌باشد. درحالی‌که با استفاده از روش افزایش اتفاقی نمونه‌ها با افزودن به تعداد نمونه‌های کلاس اقلیت تا رسیدن به تعداد نمونه‌های کلاس اکثریت باعث از بین رفتن اطلاعات مسئله می‌شود. یکی از روش‌های مناسب برای استفاده از روش افزایش اتفاقی نمونه‌ها پیاده‌سازی روش تکنیک افزایش سنتتیک نمونه‌های اتفاقی اقلیت یا به اختصار (SMOTE^{۳۷}) است.

²⁹ Missing data

³⁰ Outliers and Noises

³¹ Imbalanced Data

³² Interquartile Range

³³ Box Plot

³⁴ Random Sampling

³⁵ Random Under Sampling

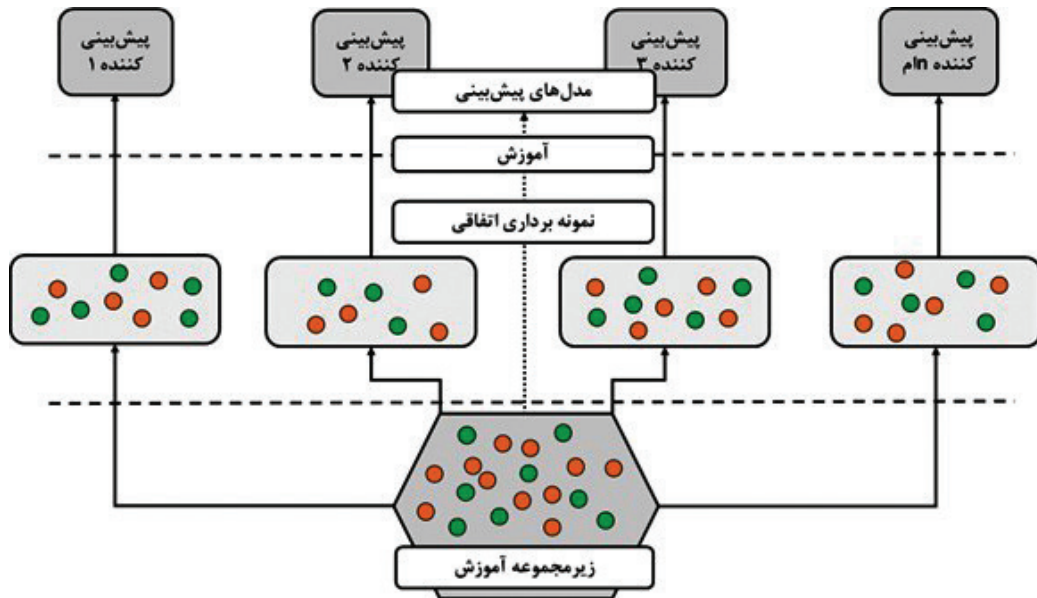
³⁶ Random Over Sampling

³⁷ Synthetic Minority Over Sampling Technique



۱-۴-۳ الگوریتم بگینگ

بگینگ (Bagging)^{۳۸} که به معنای جایگذاری با تکرار است جزو روش‌های بسیار معمول در یادگیری تجمیعی است. ایده پشت این رویکرد آموزش هر پیش‌بینی‌کننده با استفاده از الگوریتم آموزشی یکسان بر روی زیر مجموعه‌های تصادفی مختلف داده‌های آموزشی است. به بیان دیگر بگینگ نمونه‌های زیر مجموعه آموزش را قادر می‌سازد تا در زیر مجموعه‌های آموزشی برای پیش‌بینی‌کننده‌های مختلف گنجانده شوند یا چندین بار برای یک پیش‌بینی واحد نمونه‌برداری شوند. شکل ۳ فرآیند نمونه برداری و آموزش در روش بگینگ بندی را نشان می‌دهد.



شکل ۳ نحوه کار الگوریتم بگینگ

۳-۵ ارزیابی

یک عنصر اساسی در هر فرآیند مدل سازی ارزیابی عملکرد آن مدل است. برای پیش‌بینی دقیق داده‌های جدید یا ناشناخته بر اساس داده‌های نمونه بهترین مدل از بین مدل‌های طبقه بندی انتخاب می‌شود. یک مدل بیش‌برازش شده ممکن است فقط بر اساس نمونه‌های زیرمجموعه آموزش داده‌ها دارای دقت بالایی باشد. برای حل این مشکل بخشی از مجموعه داده که به آن زیرمجموعه آزمایش نیز گفته می‌شود به عنوان یک زیرمجموعه دیده نشده^{۳۹} کنار گذاشته می‌شود. سپس این زیرمجموعه آزمایش به مدل داده می‌شود. بدین صورت عملکرد مدل را می‌توان با مقایسه خروجی‌های پیش‌بینی شده با مقادیر واقعی با استفاده از معیارهایی مانند صحت ارزیابی کرد. هر مجموعه داده مورد استفاده در این مطالعه به دو زیرمجموعه برای آموزش و آزمایش با نسبت نمونه ۸۰ درصد و ۲۰ درصد تقسیم شده است.

³⁸ Bootstrap Aggregation

³⁹ Unseen data

۳-۶ معیار عدم قطعیت احتمالاتی (PUM)^{۴۰} پیشنهادی برای ارزیابی قابلیت اطمینان نتایج

در یادگیری ماشین محاسبه عدم قطعیت و قابلیت اعتماد الگوریتم‌های پیش‌بینی کننده (برای مثال برای برآورد بیش/کم برآزش مدل پیش‌بینی) بسیار حائز اهمیت است [۳۹-۴۰]. استفاده از معیارهای مناسب برای محاسبه این مقادیر امری تاثیرگذار برای ارزیابی کارایی روش‌های مبتنی بر یادگیری ماشین است. همچنین روش محاسبه عدم قطعیت و قابلیت اعتماد این روش‌ها در هر مسئله می‌تواند بنابر ذات مسئله و تعریف آن مختلف باشد مانند روش‌های بیزین سیستم‌های فازی و یا اسفاده از شاخص‌های آماری بدست آمده از نتایج پیش‌بینی در قیاس با نتایج از قبل محاسبه شده [۴۱].

در این مطالعه یک شاخص برای ارزیابی قابلیت اعتماد نتایج الگوریتم‌های استفاده شده بر اساس ماتریس آشفتگی^{۴۱} (درهم‌ریختگی) تمامی مدل‌ها توسعه داده شده است. با در نظر داشتن اهمیت ایمنی در رابطه با آسیب ساختمان‌ها به حداقل رساندن احتمال طبقه‌بندی نادرست به درجه‌های آسیب پایین‌تر امری مهم و حیاتی است. بدین معنی که شاخص معرفی شده در این پژوهش میزان اطمینان طبقه‌بندی نادرست مدل‌ها را اندازه‌گیری می‌کند. درجه آسیب پائین‌تر باعث کمتر شدن توجه به رسیدگی و تامین و نگهداری ساختمان بعد از وقوع زلزله می‌شود در صورتی که درجات آسیب بالاتر مستلزم راهکارهای جلوگیری از آسیب‌های بیشتر و در نتیجه بالاتر رفتن ایمنی لرزه‌ای بالاتر می‌شود.

در یادگیری ماشین ماتریس آشفتگی یک جدول است که برای ارزیابی عملکرد مدل‌های طبقه‌بندی استفاده می‌شود. این جدول ماتریسی است که مقادیر پیش‌بینی شده مدل را در برابر مقادیر واقعی نشان می‌دهد که بطور معمول بصورت مربعی است که دارای ابعاد هم اندازه به ازای هر کلاس طبقه‌بندی است. با داشتن مقادیر حاصله از ماتریس آشفتگی می‌توان معیارهای مختلفی برای ارزیابی عملکرد مدل‌های طبقه‌بندی استخراج کرد. این معیارها شامل صحت^{۴۲} دقت^{۴۳} بازخوانی^{۴۴} و معیار F1 هستند. مقادیر ماتریس آشفتگی درک عمیق‌تری از قدرت و ضعف مدل با فراهم کردن جزئیات طبقه‌بندی نمونه‌های مختلف برای تحلیل و ارزیابی مدل ایجاد می‌کند. برای مسائل باینری این ماتریس شامل دو ردیف و دو ستون است که نمایانگر دو کلاس محتمل (برای مثال کلاس مثبت و کلاس منفی) در این نوع طبقه‌بندی هستند. هر سلول در ماتریس آشفتگی بیانگر نتایج مختلف هستند:

مثبت صحیح^{۴۵}: مقادیری که مدل به درستی مثبت پیش‌بینی کرده است.

مثبت کاذب^{۴۶}: مقادیری که مدل به درستی منفی پیش‌بینی کرده است.

منفی صحیح^{۴۷}: مقادیری که مدل به اشتباه مثبت پیش‌بینی کرده است. (که به آن خطای تیپ یک نیز می‌گویند)

منفی کاذب^{۴۸}: مقادیری که مدل به اشتباه منفی پیش‌بینی کرده است. (که به آن خطای تیپ دو نیز می‌گویند)

معادله (۱) چگونگی محاسبه شاخص پیشنهادی PUM را بر اساس نتایج پیش‌بینی الگوریتم‌های یادگیری ماشین نشان می‌دهد. به بیان دیگر از مجموع ارقام قبل از قطر اصلی و تقسیم آن بر مجموع ارقام در هر ردیف ماتریس آشفتگی مقداری احتمالاتی بدست

⁴⁰ Probabilistic Uncertainty Measure

⁴¹ Confusion Matrix

⁴² Accuracy

⁴³ Precision

⁴⁴ Recall

⁴⁵ True Positive

⁴⁶ True Negative

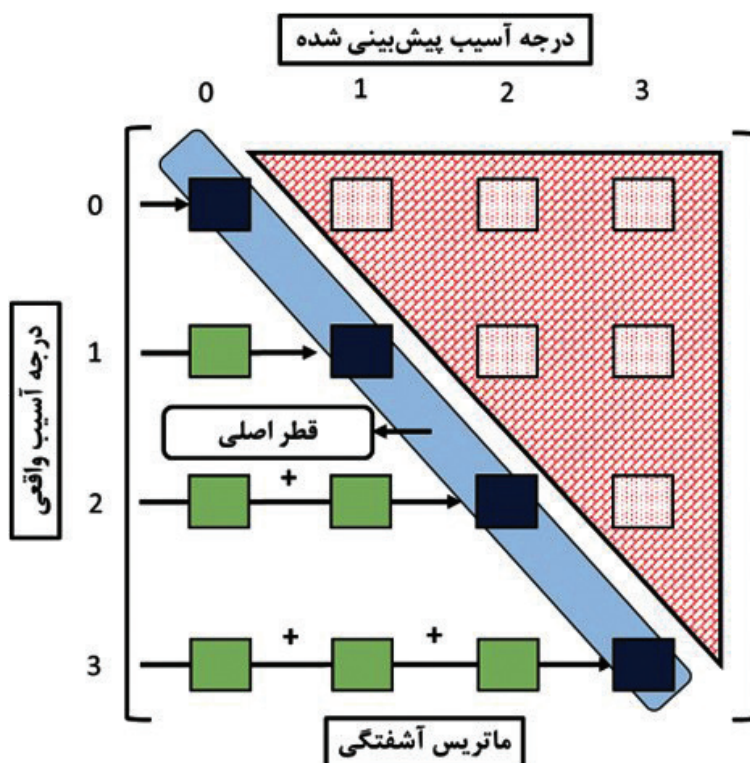
⁴⁷ False Positive

⁴⁸ False Negative

می‌آید که بیانگر احتمال طبقه‌بندی نادرست در هر درجه آسیب خواهد بود.

$$PUM_i = \frac{a_{i,j}}{\sum_{j=1}^n a_{i,j}} \quad (1)$$

در شکل ۴ نحوه محاسبه شاخص تعریف شده در این مطالعه با استفاده از ماتریس آشفتگی هر مدل نمایش شده است. برای بالا بردن اطمینان از ایمنی لرزه‌ای در تصمیم‌گیری ترجیح بر این است که طبقه‌بندی نادرست در درجات آسیب بالاتر باشد تا درجات آسیب پایین‌تر. بنابراین پایین‌تر بودن معیار PUM نشان‌دهنده بالاتر بودن قابلیت اطمینان در تشخیص آسیب است.



شکل ۴ نحوه محاسبه معیار PUM برای هر مدل


۴- نتایج عددی

۴-۱ مقایسه عملکرد مدل‌های یادگیری جمعی با استفاده از معیار صحت

مقادیر صحت هر مدل که منعکس‌کننده نسبت مقادیر پیش‌بینی شده درست به همه مقادیر است می‌تواند برای مقایسه عملکرد مدل‌ها استفاده شود. به بیان دیگر امتیاز دقت با تقسیم مجموع مقادیر مثبت واقعی (TP) منفی واقعی (TN) به تعداد کل مشاهدات تعیین می‌شود. اگرچه دقت اغلب به‌عنوان معیار اصلی برای ارزیابی عملکرد کلی این مدل‌ها استفاده می‌شود معیارهای دیگر از جمله دقت یادآوری و امتیاز F_1 نیز بیش‌تر در مورد اثربخشی و عملکرد مدل‌های یادگیری جمعی ارائه می‌دهند. نتایج صحت بر روی زیرمجموعه آزمون برای الگوریتم‌های بردار پشتیبان و بگینگ برای چهار مجموعه داده در جدول ۴ نشان داده شده است. همچنین در شکل ۵ نمودار مقایسه عملکرد این دو الگوریتم در تشخیص آسیب بر روی زیرمجموعه آزمون به ازای هر کشور مشخص شده است.


جدول ۴ مقایسه امتیاز صحت الگوریتم‌های استفاده شده در هر مجموعه داده

مقادیر امتیاز صحت مجموعه‌های داده (درصد)					
مدل‌ها	نیپال	هائیتی	اکوادور	کره جنوبی	میانگین
SVM	۶۷	۶۸	۶۰	۴۸	۶۰/۷۵
Bagging	۷۳	۶۷	۶۴	۵۸	۶۵/۳۱




شکل ۵ نمودار مقایسه عملکرد الگوریتم‌های بردار پشتیبان و بگینگ بر اساس امتیاز صحت به ازای مجموعه داده

همان‌طور که نتایج نشان می‌دهد روش بگینگ بالاترین دقت را با حداکثر دقت ۷۳ درصد در مجموعه داده نیپال به دست آورد. براساس نتایج روش یادگیری تجمیعی ارائه شده از مدل ماشین بردار پشتیبان (به جدول ۴ رجوع شود) معرفی شده توسط حریرچیان و همکاران (۲۰۲۰) [۱۶] عملکرد بهتری داشته است. به جز در یک مجموعه داده با اختلاف ناچیز ۱ درصدی، علی‌رغم مواجهه با کمبود نمونه در مجموعه داده کشور کره جنوبی مدل مبتنی بر یادگیری تجمیعی توانایی پیش بینی درجه آسیب بهتری را نسبت به مدل ماشین بردار پشتیبان نشان می‌دهند. این قابلیت کاربرد الگوریتم بگینگ را حتی در شرایطی که کمبود داده برای حل مسائل طبقه بندی وجود دارد را نشان می‌دهد. اما مدل ماشین بردار پشتیبان در مجموعه داده هائیتی نشان می‌دهد که در مجموعه‌های داده بزرگ‌تر می‌تواند به خوبی عمل می‌کند. بطور کلی نتایج حاکی از برتری مدل بگینگ نسبت به الگوریتم بردار پشتیبان است. امتیاز صحت و تعداد تطبیق برآوردگرها (Ω) برای مدل‌های بگینگ مجموعه داده های کره جنوبی و اکوادور به صورت نموداری در شکل‌های ۶ و ۷ نشان داده شده است. این نتایج نشان می‌دهند که مقدار ایده‌آل Ω برای هر مدل متفاوت است. مقدار ایده‌آل Ω برای کره جنوبی ۴۳ است در حالی که برای اکوادور ۳۱ است. این امر بر این واقعیت تأکید می‌کند که به دلیل واریانس‌های آماری ذاتی در هر مجموعه داده هر مدل بر روی مجموعه داده های متفاوت عملکرد متفاوتی دارد.



شکل ۶ مقادیر امتیاز صحت به ازای هر n در روش بگینگ در مجموعه داده کره جنوبی



شکل ۷ مقادیر امتیاز صحت به ازای هر n در روش بگینگ در مجموعه داده اکوادور

۴-۲ ارزیابی قابلیت اعتماد الگوریتم‌ها با استفاده از شاخص PUM

مقادیر شاخص PUM پیشنهادی محاسبه شده برای ارزیابی قابلیت اطمینان مدل‌ها در شکل ۸ و ۹ نشان داده شده است. به دلیل اندازه‌گیری تجمعی درجه نهایی آسیب برای هر مدل در مقایسه با کلاس‌های دیگر بالاترین مقدار را دارد. نتایج و نمودارها به طور مستقل محاسبه و در دو گروه به دلیل تفاوت در نحوه درجه بندی آسیب (سه و چهار درجه آسیب) نشان داده شدند. در شکل ۸ مقادیر PUM برای مجموعه داده کره جنوبی و نپال نشان داده شده است در حالی که شکل ۹ مقادیر PUM برای کشورهای هائیتی و اکوادور را نشان می‌دهد. همچنین درک بهتر دو نمونه از ماتریس‌های آشفتگی و نحوه محاسبه شاخص PUM برای دو مجموعه داده کره جنوبی و اکوادور در جدول ۵-۶ آورده شده است.

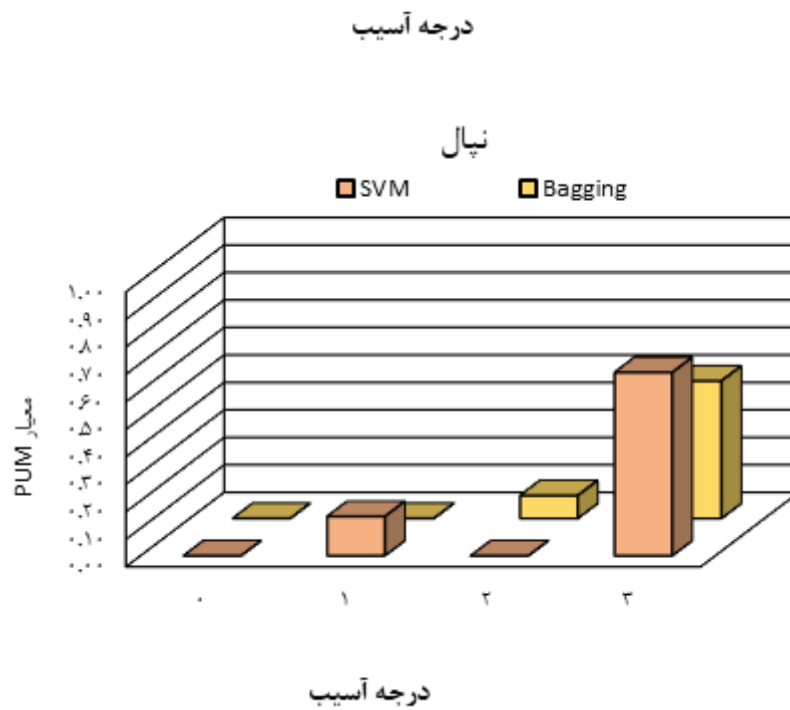
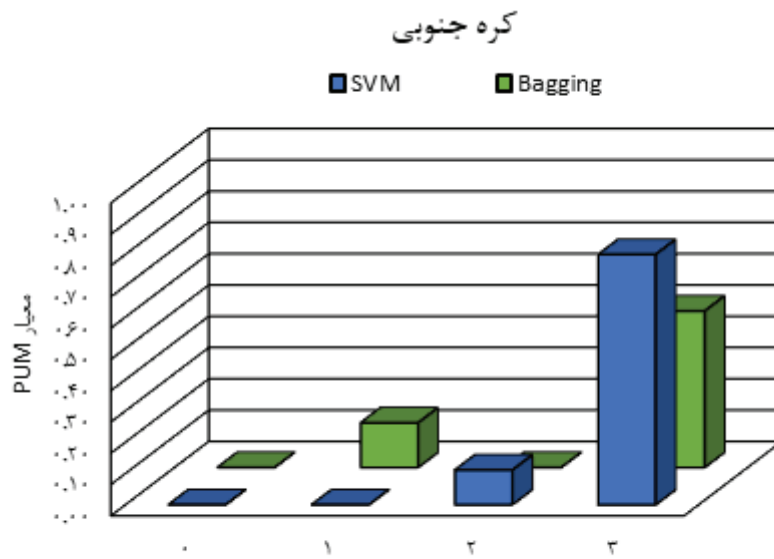
جدول ۵ ماتریس آشفتگی الگوریتم بردار پشتیبان برای مجموعه داده کره جنوبی

ماشین بردار پشتیبان - کره جنوبی				
طبقه‌بندی پیش‌بینی شده				
درجه آسیب	۰	۱	۲	۳
۰	۲	۰	۱	۰
۱	۰	۲	۴	۰
۲	۰	۱	۶	۲
۳	۱	۲	۱	۱

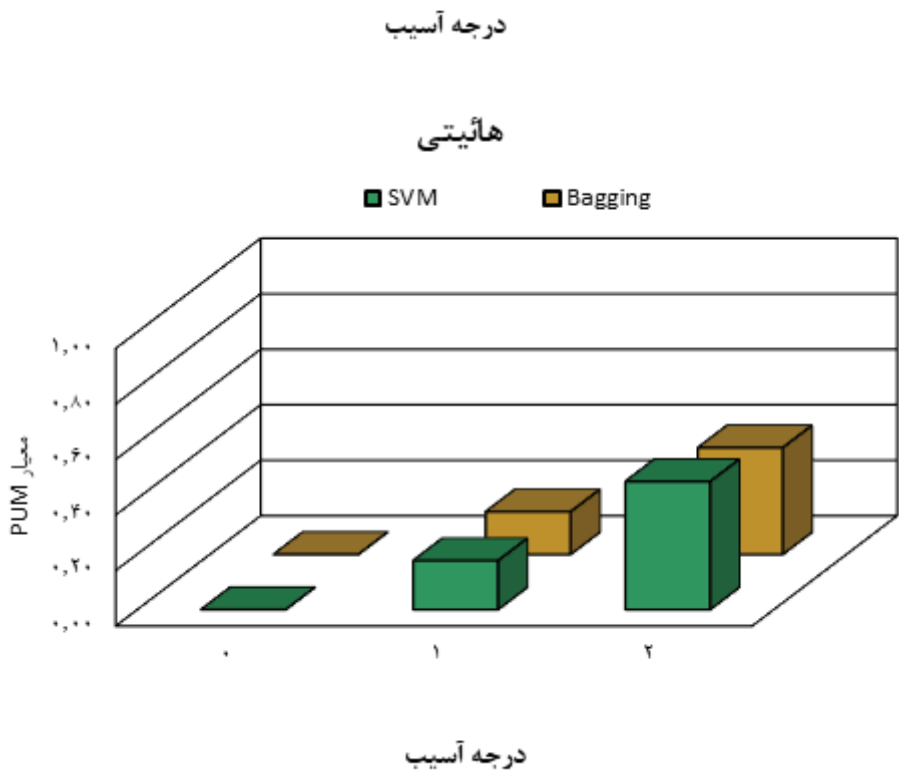
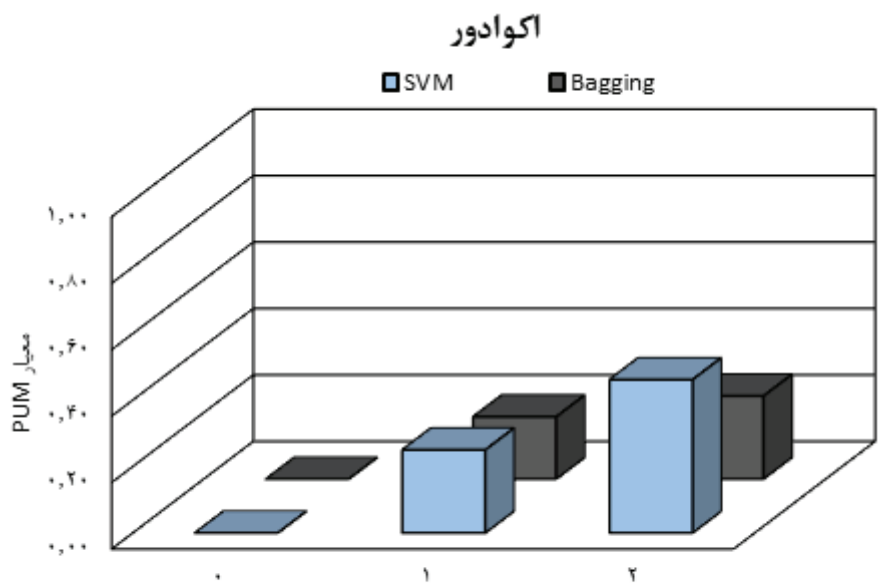
جدول ۶ ماتریس آشفتگی الگوریتم بگینگ برای مجموعه داده اکوادور

بگینگ - اکوادور			
طبقه‌بندی پیش‌بینی شده			
درجه آسیب	۰	۱	۲
۰	۹	۵	۱
۱	۳	۹	۴
۲	۲	۲	۱۲

همان‌طور که در جدول مشخص است درجه آسیب پیش‌بینی شده و واقعی در کنار هم آورده شده است. برای مثال در درجه آسیب صفر (جدول ۵) دو نمونه آزمایش به کلاس صفر تعلق گرفته‌اند که مقادیر واقعی نیز مربوط به همین درجه آسیب بوده‌اند و فقط در یک مورد نمونه‌ای در درجه آسیب ۲ طبقه‌بندی شده است که نشان‌دهنده خطا در پیش‌بینی کلاس این نمونه بوده است. براساس این ماتریس مقادیر قطر اصلی نشان‌دهنده پیش‌بینی‌های درست مدل براساس مقادیر واقعی بر روی نمونه‌های آزمایش است و برای محاسبه شاخص PUM مجموع مقادیر قبل از قطر اصلی بر کل مقادیر هر سطر تقسیم شده تا احتمال عدم قطعیت هر الگوریتم در هر درجه آسیب بدست آید که بیانگر میزان قابلیت اعتماد این مدل برای این مجموعه داده است. بدین صورت که مثلاً برای درجه آسیب دو در مجموعه داده کشور کره جنوبی مجموع مقادیر قبل از قطر اصلی برابر یک بوده و مجموع مقادیر طبقه بندی این الگوریتم در درجه آسیب یاد شده برابر هفت است. در نتیجه شاخص PUM در این درجه آسیب برابر ۰/۱۴ است. قابلیت اعتماد استخراج شده از این شاخص نیز در این مورد برابر ۰/۸۶ می‌شود. این قابلیت اعتماد بدین معنی است که این الگوریتم (ماشین بردار پشتیبان) در طبقه بندی آسیب درجه دو به میزان ۰/۸۶ درصد قابلیت اعتماد دارد. با توجه به خاصیت تجمعی این شاخص دلیل نبود درجه آسیب کمتر از درجه آسیب صفر مقادیر شاخص PUM برای این درجه آسیب همواره برابر صفر محاسبه می‌شوند.



شکل ۸ شاخص PUM برای مدل‌های یادگیری تجمیعی بر روی مجموعه‌های داده کره جنوبی و نیپال



شکل ۹ شاخص PUM برای مدل‌های یادگیری تجمیعی بر روی مجموعه‌های داده اکوادور و هائیتی

بر اساس نتایج مقدار شاخص PUM برای اکثر مجموعه‌ها نزدیک است (شکل ۹). همچنین در نیپال شاخص PUM مدل بگینگ در مقایسه با مدل ماشین بردار پشتیبان در درجه آسیب ۱ که برابر صفر است عملکرد بهتری نشان داده است. علاوه بر این بصورت کلی بگینگ در سایر درجه بندی‌های آسیب مقادیر کمتری از بردار پشتیبان بدست آورده که نشان دهنده قابلیت اعتماد بالای این مدل در طبقه بندی آسیب در این مجموعه داده است. همین روند در مجموعه داده کره جنوبی نیز وجود دارد. در شکل ۹ برای مجموعه‌های داده هائیتی و اکوادور افت شاخص PUM قابل رویت است. این تفاوت می‌تواند به دلیل کمتر شدن کلاس‌های طبقه بندی آسیب در این مجموعه‌های داده باشد (۳ درجه آسیب). نتایج در این بخش نیز حاکی از کمتر بودن شاخص PUM برای مدل بگینگ است که می‌توان نتیجه گرفت مدل مبتنی بر یادگیری تجمیعی نه تنها دارای عملکرد بهتر نسبت به مدل بردار پشتیبان است بلکه قابلیت اعتماد این الگوریتم در طبقه‌بندی آسیب نیز مقادیر قابل توجهی را کسب کرده است.

۵- نتیجه‌گیری

به‌منظور ارزیابی آسیب‌های سازه‌ای یا غیرسازه‌ای به روش‌های مرسوم بازرسی‌های بصری که توسط نیروی متخصص انجام می‌شود زمان‌بر و پرهزینه هستند. هدف از این مطالعه استفاده از تکنیک‌های یادگیری ماشین برای سرعت بخشیدن به تشخیص آسیب در سازه‌های بتن مسلح بوده است. بر روی مجموعه داده‌های از چهار کشور نیپال کره جنوبی هائیتی و اکوادور دو الگوریتم ماشین بردار پشتیبان و بگینگ برای پیش‌بینی سطح آسیب ساختمان‌های بتن مسلح استفاده شده است. علاوه بر این تجزیه و تحلیل مدل‌های یادگیری تجمیعی با استفاده از معیارهای عملکرد مانند امتیاز صحت و معیارهای عدم قطعیت احتمالی پیشنهادی (PUM) مزایا و معایب هر تکنیک را آشکار کرد. بالاترین نمره صحت در الگوریتم بگینگ (۷۳ درصد) در مجموعه داده نیپال بوده و در الگوریتم ماشین بردار پشتیبان نیز بالاترین عملکرد در مجموعه داده هائیتی با نمره صحت ۶۸ درصد بوده است. مقادیر پایین PUM با میانگین ۰/۱۶ به طور مداوم توسط مدل بگینگ بدست آمده است که قابلیت اعتماد این الگوریتم نسبت به الگوریتم بردار پشتیبان با میانگین ۰/۲۲ را در پیش‌بینی درجه آسیب نشان می‌دهد.

به عنوان پیشنهاد برای توسعه و گسترش استفاده از این روش‌ها می‌توان به استفاده از داده‌های محلی با کیفیت برای بومی‌سازی این مدل‌ها در کنار استفاده در ساختمان‌های فولادی نیز اشاره کرد. با داشتن مشخصات سازه‌ای دیگر مانند تعداد و اندازه میلگردهای مصرفی نوع و مقاومت بتن می‌توان مدلی با دقت و عملکرد بالاتری رسید. همچنین می‌توان از دیگر روش‌ها و تکنیک‌های یادگیری تجمیعی برای شناسایی بهینه‌ترین مدل برای پیش‌بینی سطح آسیب ساختمان‌ها نیز استفاده کرد.

منابع

- [1] S. Mangalathu, H. Sun, C.C. Nweke, Z. Yi, H.V. Burton, *Classifying earthquake damage to buildings using machine learning*, *Earthquake Spectra*. 36 (2020) 183–208. <https://doi.org/10.1177/8755293019878137>.
- [2] O. Avci, O. Abdeljaber, S. Kiranyaz, M. Hussein, M. Gabbouj, D.J. Inman, *A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications*, *Mechanical Systems and Signal Processing*. 147 (2021) 107077. <https://doi.org/10.1016/j.ymsp.2020.107077>.
- [3] Y. Zhang, H.V. Burton, H. Sun, M. Shokrabadi, *A machine learning framework for assess-*

ing post-earthquake structural safety, *Structural Safety*. 72 (2018) 1–16. <https://doi.org/10.1016/j.strusafe.2017.12.001>.

[4] A. Abasi, V. Harsij, A. Soraghi, Damage detection of 3D structures using nearest neighbor search method, *Earthq. Eng. Eng. Vib.* 20 (2021) 705–725. <https://doi.org/10.1007/s11803-021-2048-1>.

[5] M.H. Chegeni, M.K. Sharbatdar, R. Mahjoub, M. Raftari, New supervised learning classifiers for structural damage diagnosis using time series features from a new feature extraction technique, *Earthq. Eng. Eng. Vib.* 21 (2022) 169–191. <https://doi.org/10.1007/s11803-022-2079-2>.

[6] Alcantara EAM, Saito T. Machine Learning-Based Rapid Post-Earthquake Damage Detection of RC Resisting-Moment Frame Buildings. *Sensors*. 2023; 23(10):4694. <https://doi.org/10.3390/s23104694>

[7] S. Ghaffarian, N. Kerle, E. Pasolli, J. Jokar Arsanjani, Post-Disaster Building Database Updating Using Automated Deep Learning: An Integration of Pre-Disaster OpenStreetMap and Multi-Temporal Satellite Data, *Remote Sensing*. 11 (2019) 2427. <https://doi.org/10.3390/rs11202427>.

[8] G. Gui, H. Pan, Z. Lin, Y. Li, Z. Yuan, Data-driven support vector machine with optimization techniques for structural health monitoring and damage detection, *KSCIE J Civ Eng.* 21 (2017) 523–534. <https://doi.org/10.1007/s12205-017-1518-5>.

[9] Naderpour H, Abbasi M, Kontoni D-PN, Mirrashid M, Ezami N, Savvides A-A. Integrating Image Processing and Machine Learning for the Non-Destructive Assessment of RC Beams Damage. *Buildings*. 2024; 14(1):214. <https://doi.org/10.3390/buildings14010214>

[10] Vahid Ahmadian, S. Bahram Beheshti Aval, Mohammad Noori, Tianyu Wang, Wael A. Alt-abeey, Comparative study of a newly proposed machine learning classification to detect damage occurrence in structures, *Engineering Applications of Artificial Intelligence*, 127 (2024), 107226, <https://doi.org/10.1016/j.engappai.2023.107226>.

[11] F. Nex, D. Duarte, F.G. Tonolo, N. Kerle, Structural Building Damage Detection with Deep Learning: Assessment of a State-of-the-Art CNN in Operational Conditions, *Remote Sensing*. 11 (2019) 2765. <https://doi.org/10.3390/rs11232765>.

[12] Y. Bai, B. Zha, H. Sezen, A. Yilmaz, Engineering deep learning methods on automatic detection of damage in infrastructure due to extreme events, *Structural Health Monitoring*. 22 (2023) 338–352. <https://doi.org/10.1177/14759217221083649>.

[13] P. Chun, S. Izumi, T. Yamane, Automatic detection method of cracks from concrete surface imagery using two-step light gradient boosting machine, *Computer-Aided Civil and Infrastructure Engineering*. 36 (2021) 61–72. <https://doi.org/10.1111/mice.12564>.

[14] S. Naito, H. Tomozawa, Y. Mori, T. Nagata, N. Monma, H. Nakamura, H. Fujiwara, G. Shoji, Building-damage detection method based on machine learning utilizing aerial photographs of the Kumamoto earthquake, *Earthquake Spectra*. 36 (2020) 1166–1187. <https://doi.org/10.1177/8755293019901309>.

[15] B.A. Mir, T. Sasaki, K. Nakao, K. Nagae, K. Nakada, M. Mitani, T. Tsukada, N. Osada, K. Terabayashi, M. Jindai, Machine learning-based evaluation of the damage caused by cracks on concrete structures, *Precision Engineering*. 76 (2022) 314–327. <https://doi.org/10.1016/j.precisioneng.2022.03.016>.

[16] E. Harirchian, V. Kumari, K. Jadhav, R. Raj Das, S. Rasulzade, T. Lahmer, A Machine Learn-

ing Framework for Assessing Seismic Hazard Safety of Reinforced Concrete Buildings, *Applied Sciences*. 10 (2020) 7153. <https://doi.org/10.3390/app10207153>.

[17] C. Zhu, Y. Xu, Y. Wu, M. He, C. Zhu, Q. Meng, Y. Lin, A hybrid artificial bee colony algorithm and support vector machine for predicting blast-induced ground vibration, *Earthq. Eng. Eng. Vib.* 21 (2022) 861–876. <https://doi.org/10.1007/s11803-022-2125-0>.

[18] H. Fattahi, M.A. Ebrahimi Farsangi, S. Shojaee, K. Nekooei, H. Mansouri, Application Of The Hybrid Harmony Search With Support Vector Machine For Identification And Classification Of Damaged Zone Around Underground Spaces, *IUST*. 3 (2013) 345–358.

[19] A.C. Catlin, C. Hewa Nadungodage, S. Pujol, L. Laughery, C. Sim, A. Puranam, A. Bejarano, A Cyberplatform for Sharing Scientific Research Data at DataCenterHub, *Comput. Sci. Eng.* 20 (2018) 49–70. <https://doi.org/10.1109/MCSE.2017.3301213>.

[20] P. Shah, S. Pujol, A. Puranam, L. Laughery, 2015 Nepal Earthquake Building Performance Database, (2016). <https://doi.org/10.7277/Z82F-0728>.

[21] S. Tallett-Williams, B. Gosh, S. Wilkinson, C. Fenton, P. Burton, M. Whitworth, S. Datla, G. Franco, A. Trieu, M. Dejong, V. Novellis, T. White, T. Lloyd, Site Amplification In The Kathmandu Valley During The 2015 M7.6 Gorkha, Nepal Earthquake, *Bull Earthquake Eng.* 14 (2016) 3301–3315. <https://doi.org/10.1007/s10518-016-0003-8>.

[22] C. Sim, E. Villalobos, J. Smith, P. Rojas, S. Pujol, A. Puranam, L. Laughery, Performance of Low-rise Reinforced Concrete Buildings in the 2016 Ecuador Earthquake, (2017). <https://doi.org/10.4231/R7ZC8111>.

[23] X. Vera-Grunauer, GEER-ATC Mw7.8 Ecuador 4/16/16 Earthquake Reconnaissance Part II: Selected Geotechnical Observations, in: 2017.

[24] P. O'Brien, M. Eberhard, O. Haraldsson, A. Irfanoglu, D. Lattanzi, S. Lauer, S. Pujol, Measures of the Seismic Vulnerability of Reinforced Concrete Buildings in Haiti, *Earthquake Spectra*. 27 (2011) 373–386. <https://doi.org/10.1193/1.3637034>.

[25] N. Sedra, M. Eberhard, A. Irfanoglu, A.B. Matamoros, S. Pujol, Olafur Sveinn Haraldsson, D.A. Lattanzi, S.L. Lauer, B. Lyon, J. Messmer, K. Nasi, J. Rautenberg, S. Symithe, R. Douilly, The Haiti Earthquake Database, (2010). <https://doi.org/10.4231/D3P843W0H>.

[26] R.O. de León, Flexible Soils Amplified The Damage In The 2010 Haiti Earthquake, in: A Coruña, Spain, 2013: pp. 433–444. <https://doi.org/10.2495/ERES130351>.

[27] B. Warf, *Encyclopedia of Geography*, SAGE Publications, Inc., 2455 Teller Road, Thousand Oaks California 91320 United States, 2010. <https://doi.org/10.4135/9781412939591>.

[28] C. Sim, L. Laughery, T. Chiou, P.-W. Weng, 2017 Pohang Earthquake, (2018). <https://doi.org/10.7277/04XV-FA16>.

[29] H.-S. Kim, C.-G. Sun, H.-I. Cho, Geospatial Assessment of the Post-Earthquake Hazard of the 2017 Pohang Earthquake Considering Seismic Site Effects, *IJGI*. 7 (2018) 375. <https://doi.org/10.3390/ijgi7090375>.

[30] E. Harirchian, T. Lahmer, V. Kumari, K. Jadhav, Application of Support Vector Machine Modeling for the Rapid Seismic Hazard Safety Evaluation of Existing Buildings, *Energies*. 13 (2020) 3340. <https://doi.org/10.3390/en13133340>.

[31] H. Stone, Exposure and vulnerability for seismic risk evaluations, Ph.D. Thesis, UCL (University College London), 2018. <https://discovery.ucl.ac.uk/id/eprint/10051591>.

