



یادگیری هوشمند ابزاری مناسب در ارزیابی اثرات زمینلرزه بر رفتار سازه

سعید صبحانی قهرمانلو^۱، آلا دهرویه^۲، علی بیگلری فدافن^{۳*}

^۱ دانشجوی کارشناسی مهندسی عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان، گرگان، ایران

^۲ دانشجوی کارشناسی ارشد، گروه مهندسی عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان، گرگان، ایران

^{۳*} استادیار گروه مهندسی عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان، گرگان، ایران

(Biglari.a@gmail.com)

(تاریخ دریافت مقاله: ۱۴۰۰/۰۳/۱۷، تاریخ پذیرش مقاله: ۱۴۰۰/۰۶/۱۳)

چکیده

یادگیری ماشینی (ML) طی سالهای اخیر با تغییر قابل ملاحظه‌ای شکل گرفت و تقویت نقش علم داده در انواع مختلف آن، به سرعت تکامل یافت. در مقایسه با رویکردهای سنتی، ML مزایایی را برای رسیدگی به مشکلات پیچیده، ارائه کارایی محاسباتی، انتشار، درمان عدم قطعیت و تصمیم‌گیری‌ها را تسهیل می‌کند. همچنین، رشد ML منجر به پیشرفت‌های چشمگیری نه تنها در تحقیقات جریان اصلی هوش مصنوعی (AI) بلکه سایر زمینه‌های علوم و مهندسی، مانند علوم مواد، مهندسی زیستی، مدیریت ساخت و مهندسی حمل و نقل نیز شده است. این مقاله با توجه به ابعاد ناشناخته زمینلرزه و رفتار لرزه‌ای سازه به بررسی پیشرفت و چالش‌های اجرای ML در این حوزه می‌پردازد. بررسی‌ها نشان می‌دهد که میزان استفاده از ML در سه حوزه ارزیابی خطر وقوع زمینلرزه، ارزیابی خطر آسیب سازه‌ای پیش و پس از زمینلرزه و کنترل رفتار لرزه‌ای سازه با هدف کاهش اثرات زمینلرزه می‌تواند مورد توجه قرار گیرد.

کلمات کلیدی

یادگیری ماشین، ارزیابی خطر وقوع زمینلرزه، ارزیابی خطر آسیب سازه‌ای، ارزیابی آسیب سازه‌ای، کنترل رفتار لرزه‌ای سازه.



Intelligent Learning in Assessing the Effects of Earthquakes on Structural Behavior

Saeid Sobhani Ghahramanloo ¹, Ala Dehrouye ², Ali Biglari ^{3*}

¹ B.Sc., Department of Civil Engineering, Gorgan Faculty of Engineering, Golestan University, Gorgan, Iran

² M.Sc. Department of Civil Engineering, Gorgan Faculty of Engineering, Golestan University, Gorgan, Iran

^{3*} Assistant Professor, Department of Civil Engineering, Faculty of Engineering Golestan University, Gorgan, Iran

(Biglari.a@gmail.com)

(Date of received: 07/06/2021, Date of accepted: 04/09/2021)

ABSTRACT

Machine learning (ML) has undergone significant changes in recent years and the strengthening of the role of data science in its various forms evolved rapidly. Compared to traditional approaches, ML facilitates the benefits of dealing with complex problems, providing computational efficiency, dissemination, treatment of uncertainty, and decision making. Also, the growth of ML has led to significant advances not only in mainstream artificial intelligence (AI) research but also in other fields of science and engineering, such as materials science, bioengineering, construction management, and transportation engineering. Due to the unknown seismic dimensions and seismic behavior of the structure, this paper examines the progress and challenges of ML implementation in this area. Studies show that the use of ML in three areas of earthquake risk assessment, structural damage risk assessment before and after the earthquake and control of seismic behavior of the structure with the aim of reducing the effects of earthquakes can be considered.

Keywords:

Machine Learning, Earthquake Risk Assessment, Structural damage risk assessment, Structural damage assessment, Control of seismic behavior of structures.



۱- مقدمه

یادگیری هوشمند (ML) نقش محوری در بسیاری از زمینه‌های علمی، مالی و مهندسی را داراست. با تعریف ML [۱] یک زمینه مطالعه‌ای است که به کامپیوتر توانایی یادگیری را می‌دهد بدون اینکه به طور صریح برنامه ریزی شده باشد الگوریتم‌های ML به دو قسمت یادگیری تحت نظارت و یادگیری بدون نظارت تقسیم می‌شود. یادگیری تحت نظارت از دانش قبلی مجموعه داده‌های دارای برچسب برای یادگیری تابعی از آن استفاده می‌کند که رابطه بین ورودی و خروجی برچسب زده شده در داده‌ها را به بهترین شکل تقریب بزند. در مقابل آن یادگیری بدون نظارت وجود دارد که هدف آن استنباط ساختار طبیعی موجود با مجموعه‌ای از نقاط داده است که هیچ برچسب هدفی ندارند. که به ویژگی‌های داده بستگی دارد (به عنوان مثال گسسته یا مستمر باشد) اهداف و وظیفه یادگیری تحت نظارت را می‌توان بیشتر به طبقه بندی و رگرسیون تقسیم کرد، درحالی که یادگیری بدون نظارت شامل خوشه بندی و کاهش ابعاد است. شکل ۱ خلاصه‌ای از دو نوع ML و برخی الگوریتم‌های ML که معمولاً مورد استفاده قرار می‌گیرند می‌باشد [۲].



شکل ۱: انواع ML و برخی الگوریتم‌های ML که معمولاً مورد استفاده قرار می‌گیرند.

مطالعات پیشین، کاربردهای ML و سایر ابزارهای پیشرفته محاسبات نرم در مهندسی عمران را بررسی کرده است [۳]. آثار مربوط به تلفیق شبکه‌های عصبی مصنوعی (ANN) با پارادایم‌های محاسباتی مختلف مانند الگوریتم ژنتیک (GA^۲)، منطق فازی و تجزیه و تحلیل موجک، برای افزایش کاربرد ANN‌ها در مهندسی عمران را مرور کرد. یک مطالعه ادبی گسترده از محاسبات تکاملی در زمینه طراحی ساختاری، مانند طرح بهینه توپولوژیک، توسط [۴] انجام شده است. طبیعت تصادفی رفتار خاک در مهندسی ژئوتکنیک همچنین استفاده قابل توجهی از تکنیک‌های AI را به خود جلب کرده است، جایی که مطالعات مروری بر روی شالوده

¹ Artificial neural network

² Genetic algorithm



کم عمق [5] و پایه‌های شمع [6] انجام شده است. کاربردهای ML در لرزه شناسی توسط [۲] ارائه شده است که در مورد مزایای تمرین الگوریتم‌های ML در تشخیص زمینلرزه و برداشت فاز، هشدار زود هنگام زمینلرزه، پیش بینی حرکت زمین، توموگرافی لرزه‌ای و ژئودزی زمینلرزه بحث کرده است. بر این اساس هفت کلاس ML که عبارتند از (ANN) ماشین بردار پشتیبان (SVM^۳)، مدل سطح پاسخ (RSM^۴)، رگرسیون منطقی (LR^۵)، درخت تصمیم (DT^۶) و جنگل تصادفی (RF^۷)، روشهای ترکیبی که دو یا چند الگوریتم محاسبات نرم را با هم دیگر ترکیب می‌کند و همه روش‌های دیگر (به عنوان مثال محاسبات تکاملی (EC^۸) و برنامه‌های بیان ژنتیکی (GEP^۹) که از نظر تعداد برنامه‌ها قابل توجه نیستند. تجزیه و تحلیل خطر لرزه‌ای شامل مطالعاتی است که سطح لرزش زمین و عدم اطمینان مربوط به آن را در یک سایت یا مکان مشخص پیش بینی می‌کند. همچنین، استفاده از ابزارهای ML برای ارزیابی پتانسیل روانگرایی خاک در این منطقه در نظر گرفته شده است. موضوع دوم یک منطقه دوگانه است که در آن سیستمی شناسایی می‌شود که شامل مجموعه‌ای از مطالعاتی است که با استفاده از ML برای تقلید از یک سیستم ساختاری و پیش بینی پاسخ لرزه‌ای قطعی آن و تشخیص آسیب‌ها به طور گسترده به عنوان استفاده از مدل‌های ML برای شناسایی، طبقه بندی و ارزیابی آسیب‌های لرزه‌ای به سازه‌ها تعریف می‌شود. موضوع سوم ارزیابی شکنندگی لرزه‌ای که منابع مختلف عدم قطعیت را در بر می‌گیرد که از روش‌های ML برای توسعه مدل‌های احتمالی لرزه‌ای (PSDMS^{۱۰}) و توابع شکنندگی پارامتر شده استفاده شده است. چهارمین مبحث مربوط به کنترل فعال و نیمه فعال مجهز به ML است که اثرات نامطلوب خطرات زلزله را کاهش می‌دهد.

۲- مروری بر شبکه عصبی مصنوعی

هنوز چیزهای زیادی در مورد نحوه آموزش مغز برای پردازش اطلاعات ناشناخته است بنابراین نظریه‌ها فراوان است. در مغز انسان یک نورون معمولی سیگنال‌های دیگران را از طریق انبوهی از ساختارهای ریز به نام دندریت‌ها جمع می‌کند (شکل ۱ را ببینید). نورون از طریق یک پایه بلند و نازک معروف به آکسون، پالس‌های فعالیت الکتریکی را ارسال می‌کند که به هزاران شاخه تقسیم می‌شود. در انتهای هر شاخه ساختاری به نام سیناپس فعالیت را از آکسون به اثرات الکتریکی تبدیل می‌کند که فعالیت آکسون را مهار یا تحریک می‌کند، به اثرات الکتریکی بازدارنده یا تحریک کننده فعالیت در سلولهای عصبی متصل می‌شود. هنگامی که یک نورون ورودی تحریکی را دریافت می‌کند که در مقایسه با ورودی بازدارنده آن به اندازه کافی بزرگ است یک پالس فعالیت الکتریکی را به پایین آکسون خود می‌فرستد. یادگیری با تغییر اثربخشی سیناپس‌ها به گونه‌ای اتفاق می‌افتد که تأثیر یک نورون بر دیگری تغییر کند. نورون مصنوعی دستگاهی با ورودی‌های زیاد و یک خروجی است. نورون دو حالت عملکرد دارد: حالت آموزش و حالت استفاده، در حالت آموزش می‌توان نورون را برای الگوهای ورودی خاص آموزش داد. در حالت استفاده وقتی یک الگوی ورودی آموزش داده شده در ورودی شناسایی می‌شود، خروجی مربوط به آن به خروجی فعلی تبدیل می‌شود. اگر الگوی ورودی در لیست آموزش داده شده الگوی ورودی قرار ندارد از قانون شلیک برای تعیین آتش زدن یا عدم استفاده، استفاده می‌شود.

³ Support vector machines

⁴ Response Surface model

⁵ Logistic regression


⁶ Decision Tree

⁷ Random Forest

⁸ Evolutionary Computation

⁹ genetic expression programming

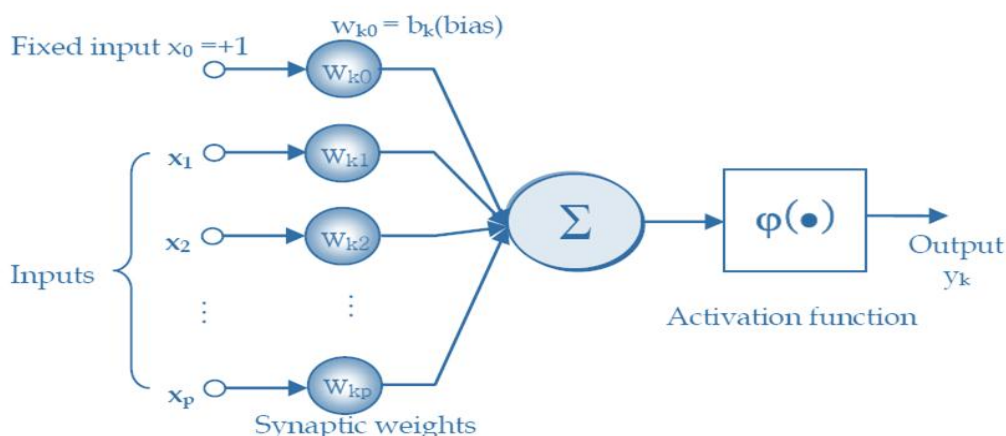
¹⁰ probabilistic seismic demand models



شکل ۲: شبیه سازی نورون های عصبی.

۲-۱- مدل سازی ریاضی AN

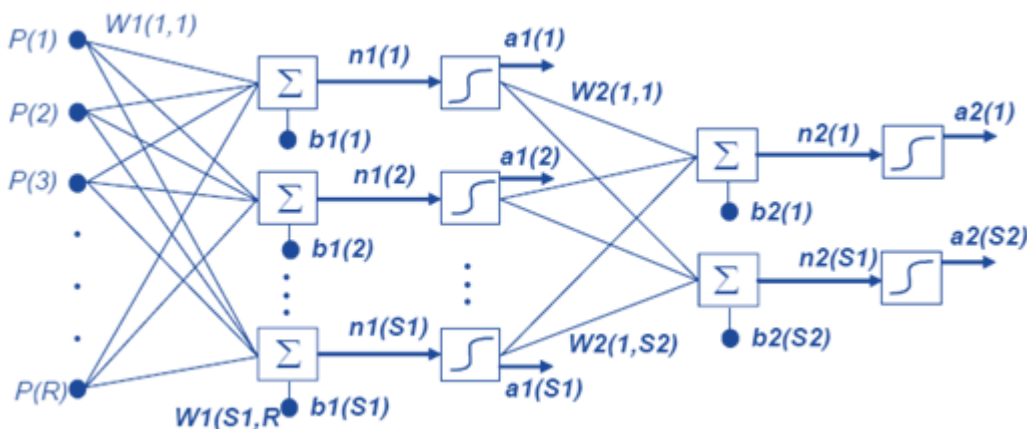
نورون یک واحد پردازش اطلاعات است که برای عملکرد شبکه عصبی اساسی است. همانطور که در شکل ۲ نشان داده شده است ما ممکن است سه عنصر اساسی مدل نورون را شناسایی کنیم. مجموعه‌ای از سیناپس‌ها که هر یک از آنها با وزن یا استحکام خاص خود مشخص می‌شوند. به طور خاص یک سیگنال x_j در ورودی سیناپس j متصل به نورون k در وزن سیناپسی w_{kj} ضرب می‌شود. یادداشت برداری از نحوه نوشتن اشتراک‌های وزن سیناپسی w_{kj} مهم است. زیر نویس اول به نورون مورد نظر و زیر نویس دوم به انتهای ورودی سیناپس اشاره دارد که وزن به آن اشاره دارد. اگر سیناپس مورد نظر تحریکی باشد وزن w_{kj} مثبت است، اگر سیناپس بازدارنده باشد منفی است. که شامل یک جمع کننده برای جمع آوری سیگنالهای ورودی، وزن شده توسط سیناپسهای مربوط به نورون و یک تابع فعال سازی برای محدود کردن دامنه خروجی یک نورون می‌باشد. در ادبیات از تابع فعال سازی به عنوان تابع له شدن نیز یاد می‌شود به این دلیل که دامنه مجاز سیگنال خروجی را به مقدار محدود خرد می‌کند (محدود می‌کند). به طور معمول دامنه نرمال شده خروجی یک نورون به عنوان فاصله‌ی بسته $[0,1]$ یا به صورت متناوب $[-1,1]$ نوشته می‌شود. مدل یک نورون همچنین شامل تعصب اعمال شده از خارج (آستانه) $w_{k0}=b_k$ است که تاثیر کاهش یا افزایش ورودی خالص عملکرد فعالسازی را دارد. در ماتریس ممکن است با نوشتن ماتریس زیر یک نورون k را توصیف کنیم.



شکل ۳: جزئیات ریاضی اصلی نورون‌های عصبی مصنوعی.

۲-۲- شبکه عصبی چند لایه ANN

گره‌های منبع در لایه ورودی شبکه عناصر مربوط به الگوی فعال سازی (بردار ورودی) را تأمین می‌کنند که سیگنال‌های ورودی اعمال شده به نورون‌ها در لایه دوم را تشکیل می‌دهند. سیگنال‌های خروجی لایه دوم به عنوان ورودی لایه سوم و غیره برای بقیه شبکه استفاده می‌شود. به طور معمول نورون‌های موجود در هر لایه از شبکه فقط سیگنال‌های خروجی لایه قبلی را به عنوان ورودی دارند. مجموعه سیگنال‌های خروجی نورون‌ها در لایه خروجی شبکه پاسخ کلی شبکه به الگوی فعال سازی ارائه شده توسط گره‌های منبع در لایه ورودی را تشکیل می‌دهد. رایج‌ترین نوع شبکه عصبی مصنوعی از سه گروه یا لایه از واحدها تشکیل شده است: یک لایه از واحدهای "ورودی" به یک لایه از واحدهای "پنهان" متصل است که به یک لایه از واحدهای "خروجی" متصل است. فعالیت واحدهای ورودی نشان دهنده اطلاعات خام است که به شبکه وارد می‌شود. فعالیت هر واحد پنهان توسط فعالیت‌های واحدهای ورودی و وزن روی اتصالات بین ورودی و واحدهای پنهان تعیین می‌شود. رفتار واحدهای خروجی به فعالیت واحدهای پنهان و وزن‌های بین واحدهای پنهان و خروجی بستگی دارد.



شکل ۴: جزئیات ریاضی شبکه عصبی مصنوعی.



۳- طراحی ساختار شبکه عصبی مصنوعی

طراحی ساختاری NN شامل تعیین لایه‌ها و نورون‌ها در هر لایه و انتخاب الگوریتم آموزش است. انتخاب فقط پارامترهای ورودی موثر به NN یکی از دشوارترین فرایندها است زیرا: (۱) ممکن است وابستگی‌های متقابل و افزونگی بین پارامترها وجود داشته باشد (۲) گاهی اوقات بهتر است برخی از پارامترها را حذف کنیم تا تعداد کل پارامترهای ورودی را کاهش دهد بنابراین پیچیدگی محاسباتی مشکل و توپولوژی شبکه است (۳) NN معمولاً در مورد مسائلی اعمال می‌شود که دانش قوی در مورد روابط بین ورودی و خروجی وجود نداشته باشد و بنابراین مشخص نیست که کدام یک از پارامترهای ورودی بیشترین کاربرد را دارند. علاوه بر این سایر پارامترهای طراحی معماری NN مانند تعداد سلولهای عصبی در لایه ورودی، تعداد لایه‌های پنهان، تعداد سلولهای عصبی در لایه‌های پنهان و تعداد سلولهای عصبی در لایه خروجی با استفاده از چندین تکرارسیستم که براساس روش آزمون و خطا یافت می‌شوند. هیچ چارچوبی برای انتخاب ساختار NN و پارامترهای آن وجود ندارد [۷]. با این وجود برخی از کارهای تحقیقاتی در تعیین تعداد لایه‌های پنهان، تعداد سلولهای عصبی در هر لایه، انتخاب پارامتر میزان یادگیری و سایر موارد کمک کرده است.

۳-۱- استفاده از روش ML در شبیه سازی رفتار دینامیکی سازه

پیشینه نظری روشهای ML در این بخش مورد بحث قرار گرفته است. روشهای نماینده ML به عنوان ANN، SVM، RSM، LR، DT، RF و روشهای ترکیبی که ANN را با الگوریتم‌های محاسبات نرم دیگر همانند منطق فازی^{۱۱} و تجزیه و تحلیل موجی می‌باشند، شایان ذکر است که روشهای ML دیگری نیز وجود دارد که دارای تعداد محدودی کاربرد هستند.

۳-۲- مروری بر روشهای نماینده ML

(1) ANN کلاسیک را می‌توان به صورت یک شبکه عصبی عمیق DNN یا DL که شامل چندین لایه پنهان می‌باشد تعمیم داد [8] (2) SVM یک الگوریتم طبقه بندی باینری^{۱۲} است که با استفاده از توابع هسته می‌تواند نگاشت ضمنی داده‌ها را در فضای ویژگی‌هایی با بعد بالا امکان پذیر کند (3) SVM همچنین می‌تواند به عنوان یک روش رگرسیون مورد استفاده قرار گیرد، که در این مطالعه، با حفظ ویژگی‌های اصلی که الگوریتم را مشخص می‌کند می‌توان (به عنوان مثال مفهوم حداکثر حاشیه) و اعمال چند متغیر جزئی به عنوان رگرسیون بردار پشتیبانی که (SVR) نامگذاری شده است را نام برد (4) LR که در شکل اساسی خود از طریق یک تابع توزیع لجستیک رابطه بین متغیر وابسته دسته‌ای و یک یا چند متغیر مستقل را اندازه گیری می‌کند [9] (5) DT که به عنوان درخت طبقه بندی و رگرسیون (CART^{۱۳}) نامگذاری شده است به صورت بازگشتی فضای ورودی را تقسیم می‌کند و در هر منطقه از فضای ورودی، یک مدل محلی تعریف می‌کند (6) RF برای غلبه بر احتمال بالا بردن و بی ثباتی مرتبط با یک درخت تصمیم در هنگام آموزش تعداد زیادی DT ایجاد می‌کند و میانگین پیش بینی درخت‌ها را به دست می‌آورد (7) روشهای ML به ویژه ANNها می‌توانند با سایر تکنیک‌های محاسبات نرم برای مقابله با پیچیدگی و ابهام در مدلسازی رفتار دینامیکی سازه‌ها ترکیب شوند، شبکه عصبی را می‌توان با الگوریتم‌های منطق فازی همراه کرد تا از قابلیت‌های محاسباتی هر دو الگوریتم به صورت تعریف شده بهره مند شوند، GA^{۱۴}ها می‌توانند در مراحل مختلف با ANNها ارتباط برقرار کنند تا عملکرد ANN را بهبود بخشند [۳].

¹¹ Fuzzy logic

¹² Binary Classification

¹³ Classification and Regression Tree

¹⁴ Genetic algorithm



۴- تجزیه و تحلیل لرزه‌ای در پیش بینی و تولید حرکت زمینی

پیش بینی و تولید حرکت زمینی یک بخش اساسی در تجزیه و تحلیل خطر لرزه‌ای است، روش‌های متداول تجربی با استفاده از روش‌های تجزیه و تحلیل متداول رگرسیون، برای استخراج معادلات میرایی برای اندازه گیری‌های مختلف شدت حرکت‌های زمینی به عنوان توابع منبع، مسیر و پارامترهای سایت، به تحلیل رگرسیون متکی هستند [۱۰]. یک معادله پیش بینی حرکت زمین (GMPE^{۱۵}) برای پیش بینی شتاب اوج زمین (PGA^{۱۶}) به شکل زیر است:

$$\log(PGA) = F_M + F_D + F_S + \varepsilon \quad (1)$$

که در آن F_S ، F_M ، F_D به ترتیب توابعی را برای کمیت سنجی تاثیر از اندازه، فاصله و تاثیرات سایت نشان می‌دهد و ε عبارت خطا است. انتخاب یک فرم عملکرد مناسب F_D ، F_M ، F_S ساده نیست زیرا نه تنها به شناسایی مناسب و درج متغیرهای مستقل قابل توجه بلکه به یک کمیت پارامتری معقول از رابطه بین این متغیرهای ورودی و خروجی نیز نیاز دارد. در این راستا اجرای اخیر روش‌های ML می‌تواند محدودیت‌های موجود در این ساختار ریاضی از پیش تعریف شده را حذف کند، تا جایی که می‌توان مدل پارامتری یا غیر پارامتری را استخراج کرد مطالعات ML پیش بینی GMPE از دسترس بودن پایگاه داده حرکت قوی در تایوان، ترکیه [۱۱]، ایران [۱۲]، اروپا [۱۳]، غرب ایالات متحده [۱۴-۱۵] و آمریکای مرکزی برای زمین لرزه‌های القایی [۱۶] گروهی از ۳ تا ۵ پارامتر مستقل معمولاً بعنوان پیش بینی کننده قابل توجهی برای پیش بینی اقدامات شدت دامنه زمانی، مانند (PGA) اوج شتاب زمین، (PGV^{۱۷}) اوج سرعت زمین و اوج جابجایی زمین (PGD^{۱۸}) و اقدامات دامنه فرکانس مانند شتاب طیفی (PSA^{۱۹}) پیش بینی‌های قابل توجه مشخص شده است که عبارت از اندازه بزرگی لحظه‌ای زمین لرزه‌ها، فاصله منبع از محل، میانگین سرعت موج برشی سایت، مکانیزم گسل و عمق کانونی هستند. که با برنامه نویسی ژنتیکی (GP^{۲۰}) [۱۷]، برنامه نویسی چند بیان (GEP) [۱۸] سیستم کشف معادله لاگرانژ^{۲۱} (ED) [۱۹]، (DNN)^{۲۲} [۲۰] روشهای ترکیبی مانند اتصال (GP) و ترکیبی از ANN و بازپخت شبیه سازی شده (SA^{۲۳}) [۲۱]، و اتصال (GA)، ANN و تحلیل رگرسیون (RA^{۲۴}) [۱۳] انجام شده است. پیشرفت‌های چشمگیری در جنبه‌های مختلف برای افزایش دقت و قابلیت تعمیم مدل‌های ML در GMPE حاصل شده است به عنوان مثال مطالعات قبلی مدل‌های تقریباً بی نقص ANN را برای کل مجموعه داده‌ها (با مقادیر نزدیک به یک R^2 ایجاد کرده اند) اما در انجام اقدامات لازم برای جلوگیری از نصب بیش از حد موفق نبوده، برخی از مطالعات فاقد یک مرحله آزمایش کاملاً ثابت هستند، در حالی که برخی دیگر عدم تطابق قابل توجهی را بین مجموعه داده‌های آزمایشی از خود نشان داده‌اند. با دسترسی به یک پایگاه جامع حرکت زمینی، یعنی پایگاه داده حرکت قوی پروژه این مشکلات حل شده است که شامل ۳۵۵۱ داده حرکت ثبت شده از ۱۷۳

¹⁵ Ground motion prediction equations

¹⁶ Peak ground acceleration

¹⁷ Peak ground velocity

¹⁸ Peak ground displacement

¹⁹ Pseudo Spectral Acceleration

²⁰ Genetic Programming

²¹ Lagrange equation detection system

²² Deep neural network

²³ Simulated Annealing

²⁴ Regression Analysis



زمینلرزه پوسته کم عمق است، این بزرگی‌ها از ۲.۴ تا ۹.۷ پیشرفت‌های زیر با استفاده از پایگاه داده حرکت (NGA²⁵) انجام شده است. که به صورت موارد زیر می‌باشند (۱) یادگیری، اعتبار سنجی و تست سازی کاملاً ساخته شده ساختار برای جلوگیری از نصب بیش از حد آن [۲۱]. ۲) یک روش آزمایش جداگانه در یک پایگاه داده حرکت متفاوت برای بررسی قابلیت تعمیم مدل به وجود آمد [۲۲]. ۳) یک چهارچوب ترکیبی که دو یا سه ابزار ML را زوج می‌کند که با این کار تاثیر بسزایی در عملکرد مدل دارد و می‌تواند تا میزان قابل توجهی آن را بهبود ببخشد [۱۳-۲۳]. علاوه بر این پایگاه داده حرکت قوی (NGAWEST2) که به تازگی جمع آوری شده است [۱۴]، متشکل از ۲۱۳۳۶ ضبط و رکورد از ۵۹۹ زمینلرزه پوسته کم عمق می‌باشد که منبع امیدوار کننده‌ای برای توسعه مدل‌های محاسبات پیچیده تر نرم را فراهم کرده است. برای این منظور [۲۰] از یک رویکرد و روش DNN برای ساخت مدل‌های پیش بینی قابل اطمینان تر برای تخمین سایت و مکان PGV، PGA، PGD براساس اندازه زمین لرزه، زاویه چنگک، فاصله منبع تا سایت و سرعت موجی برشی خاک استفاده کردند مدل‌های DNN آن‌ها با ضرایب همبستگی حدود ۹۰.۰ نشان داده شده است که قادر به پیشی گرفتن از سایر مدل‌ها می‌باشد با این حال، عوامل دیگری نیز وجود دارد که به معنای فیزیکی شناخته شده‌اند که بر تخمین‌های حرکت زمین تاثیر می‌گذارد، عواملی مانند افت استرس و اثرات هدایت پذیری در بیشتر مطالعات ذکر شده در بالا نادیده گرفته شده‌اند در نتیجه واریانس و مدل‌های مشتق گرفته شده تعبیه شده است، این مسئله توسط [۲۴] که یک الگوریتم RF برای ارتباط با افت فشار زلزله با PGA برای زمین لرزه‌ها در منطقه خلیج سانفرانسیسکو استفاده کرده و تا حدی شناخته شده و مورد توجه قرار گرفته است مطالعه آن‌ها تایید کرده است که تکنیک‌های ML می‌توانند حرکت دقیق زمین را تخمین بزنند اگر ویژگی‌های مستقل جدید در پیش بینی‌ها وجود داشته باشد. به غیر از GMPE، مطالعات نسبتاً کمی در استفاده از الگوریتم‌های ML برای تجزیه و تحلیل خطر لرزه‌ای انجام شده است [۲۵] از تجزیه و تحلیل مولفه‌های اصلی برای استخراج مجموعه‌ای از بردارهای بنیادی غیر طبیعی استفاده کرد که تغییرات غالب در تاریخ‌های زمانی امواج زلزله را رکورد کند. یک روش، روش فرآیند گاوسی متعاقباً در مطالعه آن‌ها برای رگرسیون‌ها مورد استفاده قرار گرفت تا طی یک سناریوی مشخص یک طیف خطر هدف احتمالی را ایجاد کند، سپس ترکیب خطی از بردارهای بنیادی متعادل برای مطابقت با طیف هدف از طریق یک فرآیند بهینه سازی ژنتیکی شناسایی شده مطالعه آن‌ها از سوالات معمول مرتبط با انتخاب و مقیاس گذاری حرکات ثبت شده زمینی در تحلیل لرزه‌ای و طراحی سازه‌های عمرانی جلوگیری کرد. پیشینه فنی برخی از روش‌های ML که معمولاً مورد استفاده قرار می‌گیرند ارائه شد در حالی که سازگاری و کاربرد این ابزارها در این موضوع می‌تواند به طور مفصل مورد بحث قرار گیرد. مطالعات مختلف نشان می‌دهد که تکنیک‌های ML توانایی یادگیری و استنتاج روابط متقابل پیچیده را در بین پارامترهای کمک کننده دارند و بنابراین اجازه می‌دهد تا با استفاده از روش‌های کلاسیک حل معادلات دینامیکی رفتار سازه در فضای غیر خطی که با دشواری فراوان همراه است به شبیه سازی رفتار سازه پرداخت. اگر چه پژوهش در این حوزه در مقایسه با روش‌های کلاسیک نسبتاً جدید است اما مشاهده می‌شود که عملکرد ML در حوزه بررسی رفتار دینامیکی سازه‌ها زمینه پژوهشی مناسبی را برای تحقیقات فراهم می‌آورد.

²⁵ NGA-West2 Ground Motion Database



۵- کمیت و کیفیت داده ها

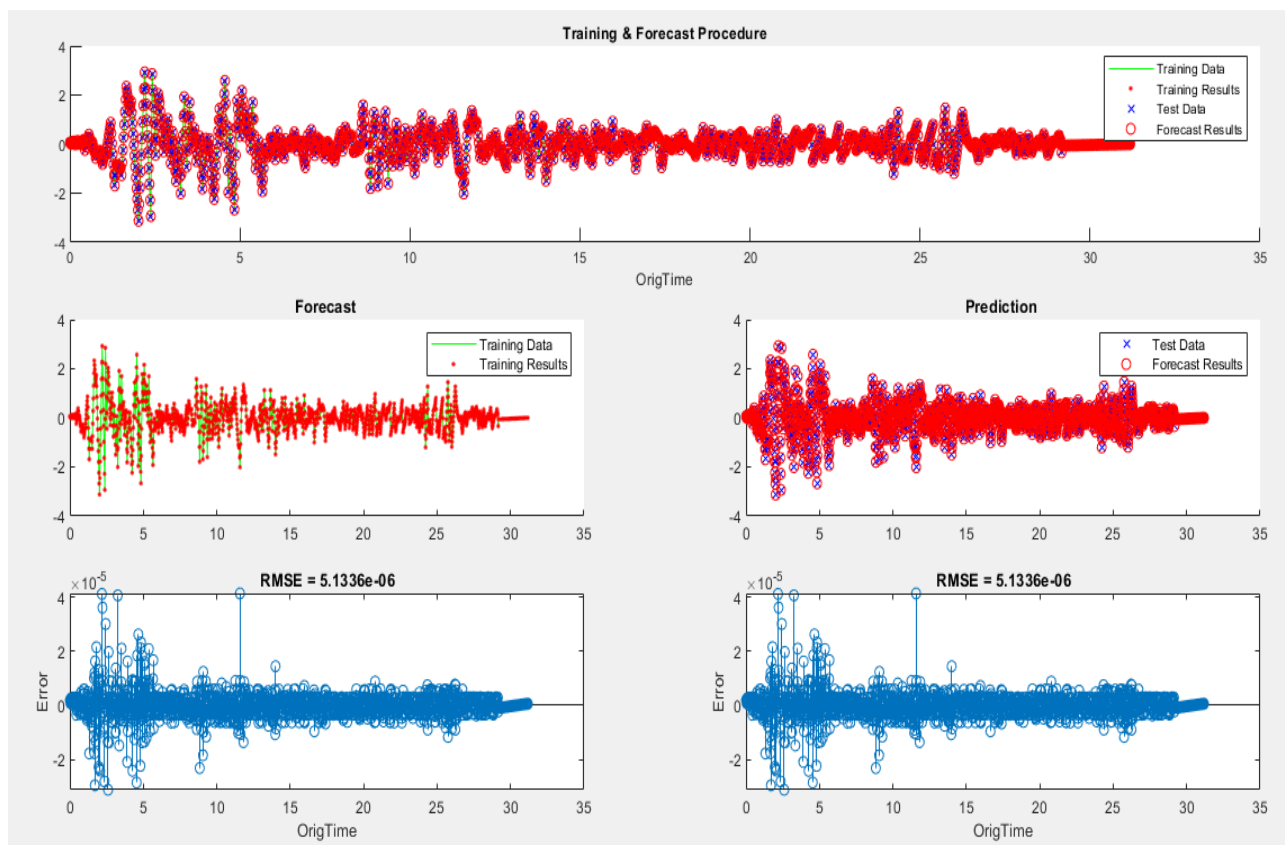
ML معمولاً برای تأثیرگذار بودن به مقدار زیادی داده با کیفیت بالا نیاز دارد. در دسترس بودن داده‌ها در زمینه GMPE، که در آن ده‌ها هزار مجموعه داده حرکت در پایگاه داده حرکت قوی NGA-West2 که به تازگی توسعه یافته است، وجود دارد که کمتر مسئله‌ای در این زمینه است [۱۴] با این حال، برای برخی از مناطق که نیاز به تجزیه و تحلیل محاسباتی با راستی آزمایشی بالا یا آزمایش‌های میدانی در مقیاس بزرگ دارند، نقاط داده با کیفیت بالا اغلب به صدها یا تعداد کمتری محدود می‌شوند. همانطور که انتظار می‌رود، ML در این مناطق با یک چالش جدی روبرو است. به عنوان مثال، قبل از اجرای مقررات طراحی لرزه‌ای مدرن، تعداد زیادی ساختمان و پل موجود با قاب‌های RC و پل‌های موجود در مناطق فعال لرزه‌ای ساخته شده است و ستون‌های RC مستعد ابتلا به شکست‌های برشی شکننده در این سازه‌ها هستند. اخیراً از ML برای پیش‌بینی ظرفیت جابجایی ستون‌های RC استفاده شده است، جایی که داده‌های ورودی برای ستون‌های برشی مهم وجود دارد بسیار کمتر از ستون‌های مهم خمشی است. در نتیجه، مدل‌های ML برای ستون‌های مهم برشی مانند مدل‌های خرابی خمش عملکرد خوبی ندارند [۲۶]. توجه داشته باشید که با تعویض یا توسعه یک مدل پیشرفته تر ML، نمی‌توان به راحتی با چنین مسائلی کمیت داده‌ای برخورد کرد [۲۷]. همچنین کیفیت پایین داده اغلب منجر به مدل‌های پایین تر ML در حوزه شبیه‌سازی رفتار دینامیکی سازه‌ها می‌شود. انتظار می‌رود در صورت دسترسی به نقاط داده با کیفیت بالاتر، ML پیش‌بینی‌های بسیار دقیق تری ارائه دهد. یک جنبه مهم که باعث عدم دقت در پیش‌بینی‌های گسترش جانبی می‌شود، اطلاعات ذهنی موجود در پایگاه داده خام است. به عنوان اثبات، پراکندگی ناشی از اطلاعات مبهم و ذهنی موجود در داده‌ها توسط [۲۸] هموار شده است. از طریق یک روش خوشه بندی فازی، پس از آن یک روش شبکه عصبی استفاده شد که به طور قابل توجهی دقت مدل را بهبود می‌بخشد. برای پرداختن به این مسئله داده‌ها، تلاش‌های تحقیق در جهت‌های زیر پیشنهاد می‌شود. ابتدا داده‌های شفاف تر، قابل دسترسی و با کیفیت بالا برای جمع‌آوری در فرم قابل خواندن توسط کامپیوتر لازم است. از آنجا که مجلات بیشتری در بررسی رفتار لرزه‌ای سازه پژوهشگران را ترغیب می‌کنند تا داده‌های مرتبط با انتشارات خود را در دسترس قرار دهند، یک سیستم کاملاً پذیرفته شده برای ذخیره و به اشتراک گذاری این داده‌ها با استفاده از یک ساختار داده استاندارد مورد نیاز است. در برنامه‌های ML، اگرچه تخصص قابل توجهی لازم است و تلاش برای تنظیم، آموزش، اعتبار سنجی و تفسیر مدل می‌باشد، اما به طور کلی، زمان صرف شده برای اجرای ML در مقایسه با زمان جمع‌آوری داده‌ها، یکپارچه سازی، تمیز کردن و پیش پردازش آن بسیار کمتر است [۲۷]. در این زمینه، بسیار مهم است که در مهندسی سازه، یک زیرساخت سایبری مبتنی بر جامعه که توسط جامعه پذیرفته شده است وجود داشته باشد که به محققان امکان دهد داده‌ها را به طور موثرتری به اشتراک بگذارند و تجزیه و تحلیل کنند، مجموعه داده‌های متنوعی را ادغام کنند و ابزارهای ML را تمرین و توسعه دهند. همچنین، از آنجا که پایگاه داده‌های آزمایشی آزمایشگاهی یا میدانی محدود است و شروع فعالیت‌های جدید در مقیاس بزرگ می‌تواند زمان بر و هزینه بر باشد، باید محققان را برای ارائه داده‌های مبتنی بر شبیه‌سازی بیشتر تشویق کرد، به ویژه برای افرادی که دارای داده‌هایی با کیفیت بالا هستند و در برابر نتایج آزمون موجود به خوبی تأیید شده‌اند. در حالی که سایر جوامع عملی از مدل‌های اشتراکی استقبال می‌کنند و از شبیه‌سازی‌ها نتیجه می‌گیرند، این فرهنگ هنوز در جامعه مهندسی سازه در مراحل ابتدایی است. با این حال، بسیاری از این مدل‌های با کیفیت بالا همچنین در ارائه داده‌های آموزشی برای برنامه‌های ML شایستگی زیادی دارند. علاوه بر این، انتظار می‌رود محققان ML در مهندسی سازه به طور فزاینده‌ای با منابع جدید داده تولید شده از سایر فناوری‌های پیشرفته مانند سنجش بی سیم، بینایی رایانه، اینترنت اشیا (IoT)، شهرهای هوشمند، سیستم (GIS) اطلاعات جغرافیایی، محاسبات کوانتومی و غیره سر و کار داشته باشند. پس از وقوع زلزله، این فناوری‌ها می‌توانند اشکال جدیدی از داده‌ها را در مقیاس کاملاً متفاوت ارائه دهند. به عنوان مثال، اینترنت اشیا برای شهرهای هوشمند می‌تواند از حسگرهای متصل در زمان واقعی برای تولید مقدار زیادی داده مکانی-زمانی



در مورد شبکه‌های پل یا سیستم‌ها خط لوله استفاده کند. [۲۹] برای این منظور، با ادغام ML با این فناوری‌های جدید می‌توان مشکلات بلند پروازانه تری را در مهندسی سازه برطرف کرد. چنین مشکلاتی می‌تواند پیش بینی عملکرد لرزه‌ای بالا بودن یک مولفه ساختاری در سطح دانه‌ای یا ارزیابی انعطاف پذیری لرزه‌ای سیستم‌های زیرساختی متصل به هم در منطقه‌ای باشد. مزیت اصلی استفاده از شبکه‌های عصبی برای پیش بینی آمار پاسخ، پس انداز محاسباتی است. اما، برای آموزش شبکه عصبی، تعداد مشخصی از نمونه‌های محاسبه شده لازم است. برای اطمینان از اینکه یک شبکه عصبی قادر به انجام وظایف معین است، تهیه اطلاعات لازم بسیار مهم است. روش پیشنهادی شبکه عصبی را قادر می‌سازد تا در مقایسه با یک رویکرد شبکه عصبی استاندارد، وقایع کم احتمال را در ناحیه توزیع، پیش بینی کند. تلاش محاسباتی برای محاسبه مجموعه نمونه‌های پاسخ کامل در مقایسه با روش استاندارد مونت کارلو به طور قابل توجهی کاهش می‌یابد. ما عمداً از یک شبکه عصبی پیشخوان کوچک استفاده می‌کنیم، که به تعداد نسبتاً کمتری نمونه آموزشی نیاز دارد بنابراین، یک دوره آموزش کوتاه مدت برای بدست آوردن آمار پاسخ دقیق کافی است. شش پارامتر ورودی که از اقدامات احتمالی شدت زلزله انتخاب شده‌اند، برای ارائه دقیق پاسخ کافی هستند. در مقابل با رویکردهای یادگیری ماشین مرسوم، ما سازگاری با مشکلات مهندسی سازه را پیشنهاد می‌دهیم و برای آموزش شبکه عصبی، با در نظر گرفتن رفتار وابسته به سایت، از یک محدوده نمونه گسترده استفاده می‌کنیم. از این نظر، ما بر پیش بینی دقیق آمار پاسخ نزدیک به خرابی ساختاری متمرکز می‌شویم و اطمینان حاصل می‌کنیم که شبکه عصبی در این منطقه خاص به اندازه کافی آموزش دیده است. مزیت عمده این روش این است که شبکه عصبی مجبور نیست در صورت وقایع بسیار نادر، پیش بینی‌ها را برون ریز کند، که این امر منجر به پیش بینی‌های غیر قابل قبول در انتهای توزیع می‌شود. یک عارضه جانبی روش پیشنهادی، از دست دادن دقت در حوادث با احتمال زیاد است. رویکرد متعارف، با استفاده از محدوده نمونه استاندارد، می‌تواند این منطقه را بهتر پیش بینی کند. با این حال، برای ارزیابی احتمال خرابی ساختاری، می‌توان از این تجارت صرف نظر کرد. این ایده باعث می‌شود که روش ما به ویژه در پیش بینی وقایع نزدیک خرابی ساختاری موثر باشد.

۶- مدل‌سازی عددی

بر این اساس شبیه سازی رفتار یک سازه بر اساس تحلیل دینامیکی غیر خطی با در نظر گرفتن رفتار الاستو-پلاستیک سازه در اثر زمینلرزه تحت اثر چند شتابنگاشت مورد ارزیابی قرار گرفت. مدل اتخاذ شده برای مطالعه تحلیلی قاب فولادی با ۳۶ درجه آزادی می‌باشد که با استفاده از نرم افزار مورد تحلیل قرار گرفته‌اند. شبکه عصبی مصنوعی در مرحله اول آموزش دیده است و سپس توانایی آن مورد ارزیابی قرار گرفته است و نتایج ارزیابی با نتایج تحلیل اجزای محدود FEM مورد مقایسه قرار گرفته است. نتایج شبیه سازی توسط شبکه عصبی با ۲۵ سلول در مقایسه با نتایج تحلیل دقیق توسط روش اجزای محدود در شکل ۵ برای بالاترین تراز سازه آرایه شده است.



شکل ۵: مقایسه نتایج تحلیل اجزای محدود و شبیه سازی بر اساس شبکه عصبی مصنوعی در مرحله آموزش و مرحله پیش بینی.

همانگونه که مشاهده می‌شود خطای محاسباتی بین نتایج و شبیه سازی در مرحله آموزش $5/1336e6$ و در مرحله ارزیابی با اندکی افزایش به $5/1336e-6$ محدود می‌شود. مقایسه نتایج شبیه سازی بر اساس شبکه عصبی مصنوعی با آنالیز دینامیکی FEM، همگرایی مناسب در بین هر دو روش را نشان داد. براساس مدل‌سازی‌های گسترده می‌توان مشاهده کرد که نتایج ارزیابی برای ساختار توسعه یافته داده‌های ورودی مستخرج از نرم افزارهای محاسباتی منجر به نتایج با دقت مناسب و کارایی بالایی می‌گردد.

۷- جمع بندی و نتیجه گیری

با توجه به رشد سریع بالقوه داده‌ها به دلیل فناوری‌های فوق الذکر، انتظار می‌رود ML فرصتی فوق العاده برای پیشرفت سیستماتیک تحقیق و عمل در مهندسی سازه فراهم کند. با این حال، انتظار می‌رود نسل بعدی داده‌های مکانی-زمانی، که مقیاس بزرگ، ابعادی بالا، غیرخطی، غیر ثابت و ناهمگن هستند، قابلیت‌های روش‌های ML موجود را که غالباً در حوزه بررسی رفتار دینامیکی سازه‌ها اتخاذ می‌کنند را به چالش بکشند. برای این منظور، تکنیک‌های پیشرفته تر ML، مانند یادگیری فعال، تقویت کننده و عمیق مورد بررسی قرار گرفته است [۳۰] برای (۱) مشخص کردن همبستگی و وابستگی مرتبه بالاتر در داده‌ها مورد نیاز است، (۲) انجام محاسبه و پیش بینی کارآمد و قابل اعتماد برای تصمیم گیری و (۳) توسعه مدل‌های یادگیری مقیاس پذیر برای مشکلات مقیاس بزرگ و وابسته به زمان. علاوه بر این، یک روند نوظهور برای تغییر پارادایم وجود دارد که محققان مهندسی سازه را ملزم می‌کند که چگونه با استفاده از مدل‌های ML مبتنی بر داده که منحصر به فرد نیستند و گاهی اوقات به سختی قابل تفسیر



هستند کار را انجام دهند. الگوریتم‌های ML متمایز از رویکردهای مبتنی بر فیزیک، یک مدل علم داده را با استفاده از مجموعه‌ای از الگوریتم‌ها، قوانین و معیارهایی یاد می‌گیرند که به طور خودکار روابط بین متغیرهای ورودی و خروجی را استخراج می‌کنند. چنین روابطی کاملاً مبتنی بر داده است و نمی‌تواند به تنهایی مکانیسم علت و معلولی فیزیکی بین متغیرها را توضیح دهد. به طور خاص، اگرچه می‌توان روابط جعلی را برای یک مسئله پیچیده یاد گرفت که در آموزش به طرز فریبنده‌ای دقیق به نظر می‌رسند، اما مدل ممکن است خارج از داده‌های دارای برچسب موجود بسیار بدتر عمل کند [۳۱]. یک مسیر منطقی به جلو در افزایش اختلاط دانش فیزیکی در مطالعات مهندسی سازه مبتنی بر ML نهفته است. اگر مدل ML نتواند درک فیزیکی از روند اساسی ایجاد کند، به سختی می‌توان از آن به عنوان یک راه حل قابل تعمیم برای حل سایر مشکلات مشابه استفاده کرد. همانطور که قبلاً در رشته‌های مختلف بررسی شده بود [۳۲]، تئوری هدایت شده ML از طریق روش‌های مختلف توسعه یافته است. [۳۱] فرصت‌هایی برای تسریع کار در این مسیر وجود دارد. اول، متخصصان دامنه می‌توانند در تبدیل داده‌های خام به یک فضای ویژگی جدید که منعکس کننده ماهیت علمی مسئله اساسی است، پیش قدم شوند. به عنوان مثال، پیش بینی‌ها و مشاهدات سازگار با ابعاد از نظر داده‌های اولیه در واحدهای اصلی خود، که شکل علمی RSM منطقی تر هستند [۳۳]. دوم، مجموعه‌ای از الگوریتم‌های مختلف ML، یا الگوریتم‌های مشابه با مقادیر مختلف برای پارامترهای داخلی خود، که باید بررسی شود تا یک مدل کلی قوی تر ایجاد شود [۳۴]. کارهای اخیر در مهندسی سازه این روند را پذیرفته است که در حل مسئله‌های یکسان از الگوریتم‌های ML متعددی استفاده می‌کنند، همانند روش‌هایی که در مقاله ذکر شده است که الگوریتم با بهترین عملکرد مشخص شده را از آن می‌دهد و بهترین نتیجه را به همراه دارد [۲۲-۲۵-۳۵-۳۶]. سوم، درک فیزیکی یک مسئله می‌تواند به طور فزاینده‌ای برای طراحی و یادگیری مدل‌های ML استفاده شود. به عنوان مثال، ANN می‌تواند برای حل وظایف یادگیری تحت نظارت ضمن رعایت قانون فیزیکی توصیف شده توسط معادلات دیفرانسیل جزئی غیر خطی، آموزش ببیند [۳۷] به طور خلاصه، با وجود تعداد روزافزون مطالعات هر ساله، اجرای ML در مهندسی سازه در مقایسه با سایر رشته‌ها هنوز در مراحل اولیه است. با این حال، ML با پشتیبانی نسل بعدی فناوری‌های متنوع به اشتراک گذاری داده‌ها و حسگرها، انقلابی بزرگی در حرفه مهندسی سازه به شمار می‌آید. علاوه بر این، انجمن مهندسی سازه این فرصت را دارد که الگوریتم‌های ML کشف نشده را در زمینه‌های مختلف بررسی کند، یا با الهام از نیازهای برنامه ما، در حالی که گفتگو در مورد بهترین روش‌ها برای ادغام روش‌های مبتنی بر فیزیک و داده محور برای حل چالش‌های بزرگ در مهندسی سازه آغاز شده است. در این بررسی پاسخ لرزه‌ای سازه با توجه به عدم اطمینان در مشخصات زمین لرزه‌ها بررسی شده است. در این مطالعه، یک نتایج مربوط به شتابنگاشت یک پایگاه داده از زمین لرزه‌های ثبت شده با استفاده از الگوریتم‌های مبتنی بر ML و یادگیری عمیق تقویت شده مورد استفاده قرار گرفت. بر این اساس نتیجه گیری می‌شود که امکان شبیه سازی رفتار دقیق سازه با بکار گیری این نوع از الگوریتم‌های تقویت شده وجود دارد.

۸- مراجع

- [1]- Samuel, A. L., 1959, **Some studies in machine learning using the game of checkers**, IBM Journal of Research and Development, 3(3), 535–554.
- [2]- Kong, Q., Trugman, D. T., Ross, Z. E., Bianco, M. J., Meade, B. J. and Gerstoft, P., 2018, **Machine learning in seismology: Turning data into insights**, Seismological Research Letters, 90(1), 3–14.
- [3]- Adeli, H., 2001, **Neural networks in civil engineering: 1989-2000**, Computer-Aided Civil and Infrastructure Engineering, 16(2), 126–142.



- [4]- Kicinger, R., Arciszewski, T. and De Jong, K., 2005, **Evolutionary computation and structural design: A survey of the state-of-the-art**, Computers and Structures 83(23–24), 1943–1978.
- [5]- Shahin, M. A., 2014, **A review of artificial intelligence applications in shallow foundations**, International Journal of Geotechnical Engineering, 9(1), 49–60.
- [6]- Shahin, M. A., 2016, **State-of-the-art review of some artificial intelligence applications in pile foundations**, Geoscience Frontiers, 7(1), 33–44.
- [7]- Kusiak, A., and Lee, H., 1996, **Neural computing based design of components for cellular manufacturing**, International Journal of Production Research, 34(7), 1777-1790.
- [8]- LeCun, Y, Bengio, Y. and Hinton, G., 2015, **Deep learning**, Nature, 521, 436–444.
- [9]- Hosmer, D. W., and Lemeshow, S., 2000, **Applied Logistic Regression**, 2nd Ed. New York: John Wiley. Housner GW, Bergman LA, Caughey TK, Chassiakos AG, Claus RO, Masri SF, Skelton RE, Soong TT, Spencer BF and Yao JTP (1997) Structural control: Past, present, and future. Journal of Engineering Mechanics 123(9): 897–971.
- [10]- Douglas, J., 2003, **Earthquake ground motion estimation using strong-motion records: A review of equations for the estimation of peak ground acceleration and response spectral ordinates**, Earth Science Reviews, 61(1–2), 43–104.
- [11]-Gulkan, P., and Kalkan, E., 2002, **Attenuation modeling of recent earthquakes in Turkey**, Journal of Seismology, 6(3), 397–409.
- [12]- Amiri, G. G., Khorasani, M., Hessabi, R. M. and Amrei, S. A. R., 2010, **Ground-motion prediction equations of spectral ordinates and arias intensity for Iran**, Journal of Earthquake Engineering, 14(1), 1–29.
- [13]- Akhiani, M., Kashani, A. R., Mousavi, M. and Gandomi, A. H., 2019, **A hybrid computational intelligence approach to predict spectral acceleration**, Measurement, 138, 578–589.
- [14]-Ancheta, T. D., Darragh, R. B., Stewart, J. P., Seyhan, E., Silva, W. J., Chiou, B. S. J., Wooddell, K. E., Graves, R. W., Kottke, A., Boore, D. M., Kishida, T. and Donahue, J., 2014, **NGA-West2 database**, Earthquake Spectra, 30(3), 989–1005.
- [15]- Chiou, B., Darragh, R., Gregor, N., and Silva, W., 2008, **NGA project strong-motion database**, Earthquake Spectra, 24(1), 23–44.
- [16]- Khosravikia, F., Potter, A., Prakhov, V., Zalachoris, G., Cheng, T., Tiwari, A., Clayton, P., Cox, B., Rathje, E., Williamson, E., Paine, J., and Frohlich, C., 2018, **Seismic Vulnerability and Post-event Actions for Texas Bridge Infrastructure**, Austin, TX: The University of Texas at Austin.
- [17]- Cabalar, A. F., and Cevik, A., 2009, **Genetic programming-based attenuation relationship: An application of recent earthquakes in turkey**. Computers and Geosciences, 35(9), 1884–1896.
- [18]- Javan-Emrooz, H., Eskandari-Ghadi, M., and Mirzaei, N., 2018, **Prediction equations for horizontal and vertical PGA, PGV, and PGD in northern Iran using prefix gene expression programming**, Bulletin of the Seismological Society of America, 108(4), 2305–2332.



- [19]- Markić, S. and Stankovski, V., 2013, **An equation-discovery approach to earthquake-ground-motion prediction**, Engineering Applications of Artificial Intelligence, 26(4), 1339–1347.
- [20]- Derakhshani, A., and Foruzan, A. H., 2019, **Predicting the principal strong ground motion parameters: A deep learning approach**, Applied Soft Computing, 80, 192–201.
- [21]-Alavi, A. H., and Gandomi, A. H., 2011, **Prediction of principal ground-motion parameters using a hybrid method coupling artificial neural networks and simulated annealing**, Computers and Structures, 89, 2176–2194.
- [22]-Thomas, S., Pillai, G. N., and Pal, K., 2017, **Prediction of peak ground acceleration using e-SVR, n-SVR and Ls-SVR algorithm**. Geomatics, Natural Hazards and Risk, 8(2), 177–193.
- [23]- Hamze-Ziabari, S. M., and Bakhshpoori, T., 2018, **Improving the prediction of ground motion parameters based on an efficient bagging ensemble model of M5# and CART algorithms**, Applied Soft Computing Journal, 68, 147–161.
- [24]- Trugman, D. T. and Shearer, P. M., 2018, **Strong correlation between stress drop and peak ground acceleration for recent M 1–4 earthquakes in the San Francisco bay area**, Bulletin of the Seismological Society of America, 108(2), 929–945.
- [25]- Alimoradi, A., and Beck, J. L., 2015, **Machine-learning methods for earthquake ground motion analysis and simulation**, Journal of Engineering Mechanics, 141(4), 04014147.
- [26]- Luo, H., and Paal, S. G., 2019, **A locally weighted machine learning model for generalized prediction of drift capacity in seismic vulnerability assessments**, Computer-Aided Civil and Infrastructure Engineering, 34, 935–950.
- [27]- Domingos, P., 2012, **A few useful things to know about machine learning**, Communications of the ACM, 55(10), 78.
- [28]- Garcı́a, S. R., Romo, M. P. and Botero, E., 2008, **A neurofuzzy system to analyze liquefaction-induced lateral spread**, Soil Dynamics and Earthquake Engineering, 28(3), 169–180.
- [29]- Salehi, H., and Burgueño, R., 2018, **Emerging artificial intelligence methods in structural engineering**, Engineering Structures, 171, 170–189.
- [30]- Memarzadeh, M., and Pozzi, M., 2019, **Model-free reinforcement learning with model-based safe exploration: Optimizing adaptive recovery process of infrastructure systems**, Structural Safety, 80, 46–55
- [31]- Karpatne, A., Atluri, G., Faghmous, J. H., Steinbach, M., Banerjee, A., Ganguly, A., Shekhar, S., Samatova, N. F., and Kumar, V., 2017, **Theory-guided data science: A new paradigm for scientific discovery from data**, IEEE Transactions on Knowledge and Data Engineering, 29(10), 2318–2331.
- [32]- Wagner, N., and Rondinelli, J. M., 2016, **Theory-guided machine learning in materials science**, Frontiers in Materials, 3, 1–9
- [33]- Xie, Y., Zhang J., Des Roches, R. and Padgett, J. E., 2019a, **Seismic fragilities of single-column highway bridges with rocking column-footing**, Earthquake Engineering & Structural Dynamics, 48, 843–86.
- [34]- Butler, K. T., Davies, D. W., Cartwright, H., Isayev, O., and Walsh, A., 2018, **Machine learning for molecular and materials science**, Nature, 559(7715), 547–555.



- [35]- Mangalathu, S., and Jeon, J. S., 2018, **Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques**, Engineering Structures, 160, 85–94.
- [36]- Sichani, M. E., 2018, **Seismic risk assessment of vertical concrete dry casks**, PhD Dissertation, Rice University, Houston, TX.
- [37]- Raissi, M., and Karniadakis, G. E., 2018, **Hidden physics models: Machine learning of nonlinear partial differential equations**, Journal of Computational Physics, 357, 125–141.