

### چکیده

مهندسی ژئوتکنیک لرزه‌ای غالباً به‌عنوان یک شاخه علمی غیردقیق به حساب می‌آید، زیرا در طی مراحل طراحی سازه‌های ژئوتکنیکی با عدم قطعیت‌های اجتناب‌ناپذیر و ساده‌سازی‌هایی مواجه هستیم که ناچاریم آنها را بپذیریم. بنابراین پیش‌بینی‌های نسبتاً دقیق با استفاده از تکنیک‌های محاسبات نرم (SC) پیشرفته می‌تواند دشواری‌های کار در روش‌های حل متعارف را هموار کند. شبکه‌های عصبی مصنوعی (ANN) یکی از مشهورترین تکنیک‌های محاسبات نرم است که در زمینه‌های مختلف علمی و فناوری استفاده می‌شود. کاربرد این تکنیک در زمینه‌های کاربردی مهندسی زلزله در سازه‌ها نیز هم‌زمان با توسعه آن در سایر زمینه‌های علمی افزایش یافته است. این مقاله روی کاربرد شبکه عصبی مصنوعی بر روی شبیه‌سازی پاسخ لرزه‌ای خاک‌ریزها و سدهای خاکی متمرکز شده است. پاسخ دینامیکی خاک‌ریزها و سدهای خاکی با استفاده از روش اجزای محدود و با استفاده از مدل معادل خطی ارزیابی شده است. در پژوهش حاضر، این فرآیند نسبتاً زمان‌بر با پیش‌بینی‌های سریع شبکه‌های عصبی مصنوعی که به‌طور صحیح آموزش دیده است جایگزین شده است. در اینجا ورودی‌های مدل شبکه عصبی مصنوعی پارامترهای لرزه‌ای تحریک‌های زلزله وارد بر خاک‌ریز یا سد خاکی بوده و خروجی آن در این پژوهش شتاب افقی حداکثر تاج سد است. بررسی‌های انجام شده در این پژوهش نشان داد که مدل شبکه عصبی مصنوعی کلی ارائه شده جهت پیش‌بینی پاسخ لرزه‌ای خاک‌ریزها و سدهای خاکی می‌تواند نسبت به مدل جزئی پیشنهاد شده در پژوهش‌های پیشین کاربردی‌تر باشد.

**واژگان کلیدی:** خاک‌ریز، سد خاکی، تحلیل دینامیکی، روش معادل خطی، شبکه عصبی مصنوعی.

## پیش‌بینی پاسخ لرزه‌ای خاک‌ریزها و سدهای خاکی با شبکه عصبی مصنوعی

امین رضایان

دانشجوی دکتری مهندسی خاک، دانشکده عمران، واحد علوم و تحقیقات تهران، دانشگاه آزاد اسلامی، تهران، ایران

محمد داودی (نویسنده مسئول)

دانشیار، پژوهشکده مهندسی ژئوتکنیک، پژوهشگاه بین‌المللی زلزله‌شناسی و مهندسی زلزله، تهران، ایران،  
m-davood@iiees.ac.ir

محمد کاظم جعفری

استاد، پژوهشکده مدیریت خطریابی و بحران، پژوهشگاه بین‌المللی زلزله‌شناسی و مهندسی زلزله، تهران، ایران

### ۱- مقدمه

روش‌های هوش مصنوعی (AI)، معمولاً برای کاهش هزینه محاسبات و یا زمانی که پیچیدگی یا ابعاد مسئله مانع استفاده از تکنیک‌های متعارف می‌شود به کار گرفته می‌شود [۱-۲]؛ مخصوصاً شبکه‌های عصبی مصنوعی که به‌طور گسترده‌ای در بسیاری از عرصه‌های علمی و فناوری استفاده می‌شوند. این روش‌ها کاربردهای مهندسی روزافزونی داشته و دارند [۳-۱۵].

شبیه‌سازی، شبیه‌سازی معکوس و مسائل شناسایی سیستم، مشهورترین نمونه‌های مسائل مهندسی هستند که با استفاده از ابزار تکنیک‌های SC تحلیل می‌شوند. شبیه‌سازی با روش‌های مستقیم

بسیاری از کاربردهای پیچیده مهندسی، تخمین‌ها و پیش‌بینی‌های ارزان‌قیمت کامپیوتری مبتنی بر متامدل‌ها (مثل تکنیک‌های محاسباتی نرم (SC)) را می‌توان به‌جای حل مجموعه‌ای از معادلات ریاضی با روش تحلیلی یا حتی حل عددی استفاده کرد (که در بسیاری مسائل مهندسی به‌وفور استفاده می‌شود). بیشتر روش‌های SC از طبیعت الهام گرفته شده است و بنابراین تفاوت زیادی با روش‌های ریاضی متعارف دارند. شبکه‌های عصبی مصنوعی (ANN)، سیستم‌های فازی و روش‌های تکاملی معروف‌ترین تکنیک‌های SC هستند. به‌طور کلی

ارائه شده در آن تنها می‌تواند پاسخ لرزه‌ای خاصی را برای یک خاک ریز معین پیش‌بینی کند و ثانیاً شبکه عصبی به‌دست آمده برای همین محدوده هم کلی نبوده بلکه تفکیک شده است؛ به این معنا که جهت بهبود تخمین‌ها با توجه به پیچیدگی تحریک‌های زلزله برای هر تراز PGA شبکه عصبی مصنوعی مستقلی تعریف شده است. همچنین به‌عنوان سومین نقص، نظر به اینکه تحلیل‌های عددی خود داده‌های واقعی نبوده و تخمین‌هایی توأم با خطا هستند، قطعاً استفاده از شبکه‌های عصبی قطعاً بر این خطا افزوده و باعث کاهش دقت پاسخ‌های لرزه‌ای می‌شوند. در مطالعه حاضر، کاربرد شبکه عصبی در عرصه مهندسی ژئوتکنیک لرزه‌ای با هدف توسعه و رفع بخشی از نواقص موجود در شبیه‌سازی پاسخ لرزه‌ای خاک ریزها و سدهای خاکی صورت گرفته است.

خاک ریزها و سدهای خاکی بخش مهمی از سازه‌های ژئوتکنیکی را تشکیل می‌دهند و ایمنی و قابلیت استفاده بودنشان می‌تواند مستقیماً بر روی شاخص‌های زیست‌محیطی، اقتصادی و اجتماعی اثرگذار باشد. این نوع سازه‌ها پس از تجربه‌های متوالی گسیختگی تحت اثر بارهای لرزه‌ای در زلزله‌های نورتریج (۱۹۹۴) و کوبه (۱۹۹۵) و سایر زلزله‌های اخیر در جهان تحت مطالعات لرزه‌ای دقیق‌تری قرار گرفته‌اند.

در بسیاری اوقات طبق معمول مهندسی ژئوتکنیک، پاسخ غیرخطی دینامیکی یک خاک ریز با روش اجزای محدود ارزیابی می‌شود [۳۱]. این روش در این پژوهش هم استفاده شده است. در اینجا غیرخطی بودن مصالح با لحاظ روش نسبتاً وقت‌گیر و زمان‌بر معادل خطی در نظر گرفته شده است. بنابراین در این مطالعه برای کاهش هزینه محاسبات فوق‌الذکر، یک روش مؤثر و کارا مبتنی بر شبکه عصبی مصنوعی به کار گرفته شده است. در چیدمانی که در این پژوهش از آن استفاده شده است، شبکه عصبی در ابتدا با توجه به اطلاعات موجود به‌دست آمده از تحلیل‌های دینامیکی سازه خاکی مد نظر آموزش می‌بیند. به این ترتیب پس از طی این آموزش‌ها، شبکه عصبی به‌جای روش تحلیل دینامیکی متعارف برای پیش‌بینی سریع و

تحلیل عددی پیوند خورده است. در این مسائل برای ورودی‌ها و مشخصات معلوم سیستم تحت بررسی، در پی خروجی‌های مجهول (پاسخ‌های سیستم) هستیم. در مقابل شبیه‌سازی معکوس زمانی اتفاق می‌افتد که خصوصیات سیستم و پاسخ‌ها معلوم باشد ولی ورودی‌ها نامعلوم باشد. در واقع ما به‌عنوان خروجی در پی تحریکاتی هستیم که باعث ایجاد این رفتار در سیستمی معین می‌شوند. شناسایی نیز در ارتباط با تحلیل معکوس سیستم‌هایی است که شامل سازه‌ها و مصالح می‌شود. در اینجا تحریک‌ها و پاسخ‌ها معلوم و خصوصیات سیستم به‌عنوان مجهول جستجو می‌شود.

در کنار کاربردهای فوق‌الذکر شبکه عصبی مصنوعی در مسائل مهندسی گوناگون، در دهه اخیر افزایش مشهود و قابل توجه تعداد مقالات منتشر شده در زمینه کاربرد شبکه عصبی مصنوعی در مهندسی ژئوتکنیک لرزه‌ای مشهود بوده است. البته بیشتر این مطالعات بر روی پتانسیل روانگرایی تحت تحریک‌های لرزه‌ای متمرکز شده است زیرا این موضوع از نظر میزان محاسبات بسیار حجیم بوده و بنابراین استفاده از شبکه عصبی در این زمینه مناسب است [۱۶-۱۹]. در سایر مطالعات صورت گرفته در این زمینه، کاربرد شبکه عصبی مصنوعی در تحلیل دینامیکی خاک [۲۰-۲۴]، برای ایجاد شتاب‌نگاشت‌های سازگار با طیف [۲۵-۲۶]، پیش‌بینی پارامترهای زلزله [۲۷]، تخمین انتشار موج [۲۸]، تخمین شتاب پیک زمین با استفاده از میکروترموور [۲۹] و همچنین اکتشاف الگوهای میدان الکتریکی زلزله [۳۰] مورد بررسی و ارزیابی قرار گرفته است. در خصوص پیش‌بینی پاسخ لرزه‌ای خاک ریزها و سدهای خاکی با شبکه عصبی شاید بتوان گفت تنها تلاش صورت گرفته در این حوزه به سال ۲۰۰۹ برمی‌گردد و توسط سمپاناکیس و همکارانش [۱] صورت گرفته است. آنها با استفاده از شبکه عصبی مصنوعی پاسخ لرزه‌ای (شتاب افقی حداکثر) خاک ریز همگن و متقارن معینی را در نقاط مختلف آن پیش‌بینی کردند. شاید بتوان مهم‌ترین نقص این پژوهش را چنانچه نویسندگان این مقاله خود به آن معترف هستند در این دانست که اولاً مدل شبکه عصبی مصنوعی جزئی

توسط نیومارک [۳۲] صورت می‌پذیرد و به‌عنوان روش تحلیل بلوک لغزان نیز شناخته می‌شود. مکدیسی و سید [۳۳] روش فوق‌الذکر را با به کار بردن مقادیر میانگین وزنی ضریب زلزله توسعه دادند.

در آیین‌نامه‌های لرزه‌ای رایج مانند Eurocode8 [۳۴] و آیین‌نامه لرزه‌ای یونان [۳۵] تحلیل پایداری شیروانی لرزه‌ای معمولاً با استفاده از روش شبه‌استاتیکی انجام می‌شود که این تحلیل با استفاده از مقدار ضریب زلزله انجام می‌پذیرد که به‌صورت کسری از شتاب طراحی پیک زمین (PGA) بیان می‌شود. در این روش، پاسخ دینامیکی سازه به حساب نمی‌آید که این مسئله منجر به ناتوانی و نارسایی پیش‌بینی پایداری شیروانی واقع‌بینانه برای سازه‌های ژئوتکنیکی تحت حوادث لرزه‌ای با شدت متوسط و زیاد می‌شود. بحث کلیدی در روش شبه‌استاتیکی، انتخاب یک ضریب زلزله (یعنی شتاب افقی) صحیح و مناسب است که بتوان از آن برای محاسبه نیروهای اینرسی وارده بر جرم قطعات خاک استفاده نمود. بنابراین بدیهی است که همه روش‌های پایداری شیروانی (به‌جز روش‌های تنش تغییر شکل) نیاز به یک تخمین دقیق از سطوح شتاب مؤثر به خاک‌ریز، تحت تحریک وارده دارند. بنابراین تحلیل‌های وابسته به پاسخ از هر نوع تحلیل پایداری شیروانی لرزه‌ای دیگری مقدم هستند. برای پی بردن به جزئیات بیشتر در این موضوع بسیار مهم خواننده باید به کتاب کرامر [۳۶] رجوع کند.

هدف از مطالعه حاضر بررسی جزئیات بیشتر بزرگنمایی شتاب افقی و جستجوی نسبت بین این بزرگنمایی و پتانسیل رفتار غیرخطی مصالح خاکی است. برای دست یافتن به این هدف، شبیه‌سازی‌های اجزای محدود دو بعدی در کنار تخمین‌های کارآمد مبتنی بر شبکه عصبی جهت جستجوی پاسخ لرزه‌ای غیرخطی یک خاک‌ریز و سد خاکی مشخص مورد استفاده قرار می‌گیرند. پارامترهای اصلی مورد بررسی عبارتند از مشخصات و سطوح شدت مختلف تحریک‌های لرزه‌ای. هر دوی این موارد با رفتار مصالح در سازه ژئوتکنیکی مرتبط هستند.

دقیق پاسخ سازه‌ی ژئوتکنیکی تحت بررسی برای تحریک‌های لرزه‌ای مختلف به کار برده می‌شود.

## ۲- پاسخ لرزه‌ای خاک‌ریزها

همه انواع سازه‌های ژئوتکنیکی مانند سدهای خاکی، خاک‌ریز بزرگراه‌ها و ... به دلیل ریسک بالا (اقتصادی، اجتماعی، محیط زیستی و ...) ناشی از پتانسیل تخریب این سازه‌ها مورد توجه زیاد مهندسين قرار دارند. چنانچه در مشاهدات انجام شده نشان داده شده، در نواحی با لرزه‌خیزی بالا خطر فوق‌الذکر شدیدتر است.

در مطالعه پاسخ لرزه‌ای یک خاک‌ریز علاوه بر مبحث پایداری شیروانی که باید مورد توجه قرار گیرد، تعیین اثر تحریک لرزه‌ای سازه‌های ژئوتکنیکی نیز باید مدنظر قرار گیرد. زلزله باعث ایجاد تغییر شکل‌های وابسته به زمان که در ارتباط با پاسخ دینامیکی یعنی شتاب‌های اینرسی گسترش یافته هستند می‌شود. از سوی دیگر تغییر شکل‌های ماندگار پس از زلزله با پتانسیل روانگرایی یا اثرات جابه‌جایی گسل‌ها بر روی سازه‌های ژئوتکنیکی در ارتباط هستند. تجربیات به‌دست آمده در تحلیل پایداری شیروانی لرزه‌ای باعث ایجاد سه روش تحلیل شده است که عبارتند از: تحلیل تنش تغییر شکل، تحلیل شبه‌استاتیکی و تحلیل تغییر شکل ماندگار. تحلیل تنش تغییر شکل، بیشتر با استفاده از روش اجزای محدود به همراه استفاده از مدل‌های ترکیبی پیچیده که قابلیت توصیف رفتار غیرخطی خاک را دارند شکل می‌گیرند. به‌هر حال پارامترهای مورد نیاز برای به کار گرفتن این مدل‌ها به آسانی و دقت در آزمایشگاه و در صحرا قابل اندازه‌گیری نیستند. همچنین در بررسی پایداری شیروانی با تحلیل شبه‌استاتیکی یک تخمین اولیه در این زمینه به دست می‌آید. در این روش با استفاده از روش‌های تعادل حدی، تحلیل پایداری شیروانی استاتیکی با اضافه کردن اثر نیروهای اینرسی افقی و قائم، در نهایت به ضریب اطمینان به‌عنوان خروجی این روش منجر می‌شود. تحلیل تغییر شکل ماندگار نیز بر مبنای محاسبات تغییر شکل‌های لرزه‌ای با روش ساده پیشنهاد شده

خروجی را طرح ریزی می کند [۳۸].

اگر مجموعه‌ای از مقادیر  $W$  که متناظر با ضرایب وزن است به شبکه اختصاصی پیدا کند، آنگاه یک نگاشت  $Y(X, W, A)$  بین ورودی‌های  $X$  و خروجی‌های  $Y$  تعریف می‌شود. کیفیت این نگاشت با مراجعه به مجموعه آموزشی به وسیله‌ی یک تابع خطا  $E_p$  اندازه‌گیری می‌شود که این خطا به صورت زیر تعریف می‌گردد [۳۸]:

$$E_D(D|W, A) = \sum_m \frac{1}{2} (y(x^m; W, A) - t^m)^2 \quad (1)$$

یک الگوریتم یادگیری سعی می‌کند مقادیر بهینه  $W$  را طوری تعیین کند که به ازای آن  $E_p$  حداقل شود و به این ترتیب به پاسخ صحیح برای هر بردار ورودی برسد. بدین ترتیب شبکه عصبی مصنوعی حاصل می‌شود. الگوریتم‌های کمینه‌یابی شمارشی که برای آموزش شبکه عصبی مصنوعی مورد استفاده قرار می‌گیرند یک زنجیره از پارامترهای وزنی  $W$  را از طریق یک فرآیند تکراری تولید می‌کنند. برای این کار یک عملگر الگوریتمی  $(O)$ ، برای آغاز کار پارامترهای وزنی  $W^{(0)}$  مورد نیاز است که این پارامتر بی‌دری به صورت زیر به روز می‌شود [۳۸]:

$$W^{(t+1)} = O(W^{(t)}) = W^{(t)} + \Delta W^{(t)} \quad (2)$$

قسمت متغیر بردار وزن‌ها،  $\Delta W^{(t)}$ ، می‌تواند به دو قسمت زیر تجزیه شود:

$$\Delta W^{(t)} = a_t \cdot d^{(t)} \quad (3)$$

که در اینجا  $d^{(t)}$  بردار راستای جستجو و  $a_t$  نیز اندازه گام در آن جهت است.

الگوریتم‌های یادگیری را می‌توان به دو دسته کلی و محلی طبقه‌بندی نمود [۳۹-۴۲]. الگوریتم‌های کلی برای آگاهی و شناسایی حالت جاری در کل شبکه همچون جهت بردار به‌روز کردن وزن کلی استفاده می‌شوند. به‌عنوان مثال، در الگوریتم یادگیری پس‌انتشار که به‌طور گسترده‌ای مورد استفاده قرار می‌گیرد از الگوریتم گرادیان نزولی استفاده شده است. در مقابل استراتژی‌های محلی، همچون رفتار موقتی مشتق‌های جزئی در


برنامه Quakew [۳۷] که در این پژوهش به کار برده شده است برنامه‌ای است که به‌طور گسترده‌ای برای ارزیابی پاسخ لرزه‌ای سازه‌های ژئوتکنیکی مورد استفاده قرار می‌گیرد. این نرم‌افزار توانایی انجام تحلیل‌های دینامیکی اجزای محدود دو بعدی با استفاده از مدل‌هایی همچون مدل معادل خطی (که در آن برای لحاظ رفتار غیرخطی مصالح، مدول برشی و خصوصیات میرایی وابسته به کرنش است) را دارد. این روش (روش معادل خطی) یک روش تحلیلی وابسته به زمان است که در آن از میرایی رایله استفاده می‌شود و در آن اجازه میرایی متغیر برای هر المان داده می‌شود. Quakew از یک پروسه تکراری برای تخمین خصوصیات غیرخطی وابسته به کرنش استفاده می‌کند. در ابتدا مدول برشی و نسبت میرایی برای هر المان، در مدل اجزای محدود تخمین زده می‌شود و سیستم با توجه به این تخمین اولیه تحلیل می‌شود. سپس متعاقباً در هر تکرار، مقادیر کرنش برشی مؤثر برای هر المان محاسبه می‌شود و خصوصیات مدول برشی و میرایی نظیر با سطح کرنش محاسبه شده با آنچه در تکرار قبلی تخمین زده شده مقایسه می‌شود. این روش تحلیل معادل خطی تکرار می‌شود تا این مقادیر به همگرایی برسند.

### ۳- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی مشهورترین نمونه محاسبات هوشمند است. یک شبکه عصبی مصنوعی از تعدادی واحد به‌هم پیوسته تشکیل شده است و تلاش می‌کند بین اطلاعات ورودی و خروجی یک ارتباط مطلوب ایجاد کند. برای دست یافتن به این هدف، یک مجموعه آموزشی  $D$  متشکل از جفت‌های ورودی-هدف  $D = [x^m, t^m]$  شکل می‌گیرد که در آن تعداد جفت‌ها و  $X$  اطلاعات ورودی و  $t$  هدف جفت‌ها است [۳۸].

معماری شبکه عصبی  $A$  از تعداد خاصی لایه و تعدادی نرون در هر لایه و یک تابع فعال‌سازی مناسب تشکیل می‌شود. لایه ورودی اطلاعات لایه یا لایه‌های میانی را طرح‌ریزی می‌کند. هر لایه میانی یا مخفی، اطلاعات لایه میانی بعدی را از خود عبور می‌دهد؛ درحالی‌که لایه مخفی نهائی اطلاعات نرون‌های

مقابل وزن‌ها، بر مبنای اطلاعات ویژه‌ای از مقادیر وزنی استوار هستند. روش‌های محلی، بیشتر با مفاهیم شبکه‌های عصبی مصنوعی در خصوص پردازش توزیع شده مرتبط است که در اینجا محاسبات مستقلاً انجام می‌شود. تجربیات موجود نشان می‌دهد که برای بسیاری کاربردها، استراتژی‌های محلی سریع‌تر از تکنیک‌های کلی به پیش‌بینی‌های قابل اطمینان می‌رسند [۴۱-۴۲]. در این مطالعه الگوریتم یادگیری کلی پس‌انتشار که به‌طور مخفف BP نامیده می‌شود و یکی از پرکاربردترین الگوریتم‌های شبکه عصبی است در کنار الگوریتم یادگیری محلی لوبنرگ مارکوآرت که به‌طور مخفف LM نامیده می‌شود مورد استفاده قرار گرفته است. لازم به ذکر است از آنجا که بر اساس توصیه متون فنی در شبکه‌های عصبی BP تابع فعال‌سازی تانژانت سیگموئید به دلایلی از جمله مشتق‌پذیری آن، یکی از مناسب‌ترین توابع فعال‌سازی است؛ در این پژوهش این تابع فعال‌سازی به کار گرفته شده است. به کار بردن LM بر اساس توصیه راهنمای MATLAB بوده، جدا از اینکه کارآیی خوب آن بر اساس متون فنی در کاربردهای مهندسی اثبات شده است [۳۸].



شکل (۱): مقطع خاک‌ریز مورد بررسی در مثال ۱.

برای پیکربندی شبکه عصبی مصنوعی از آموزش‌های مناسب جهت پیش‌بینی شتاب در گیرنده‌ها به ازای تحریک‌های جدید استفاده شده است. همچنین برای شناسایی رکورد‌های استفاده شده، از مجموعه‌ای از مقیاس‌های شدت (IMs) استفاده می‌کنند تا به این ترتیب شبکه عصبی مصنوعی فراهم شود که بتواند تحریک‌های مختلف را به خوبی پیش‌بینی کند. اصطلاح مقیاس‌های شدت برای مشخص کردن تعدادی از پارامترهای حرکت زمین به کار برده می‌شوند که به‌طور معمول در ارتباط با

مقابل وزن‌ها، بر مبنای اطلاعات ویژه‌ای از مقادیر وزنی استوار هستند. روش‌های محلی، بیشتر با مفاهیم شبکه‌های عصبی مصنوعی در خصوص پردازش توزیع شده مرتبط است که در اینجا محاسبات مستقلاً انجام می‌شود. تجربیات موجود نشان می‌دهد که برای بسیاری کاربردها، استراتژی‌های محلی سریع‌تر از تکنیک‌های کلی به پیش‌بینی‌های قابل اطمینان می‌رسند [۴۱-۴۲]. در این مطالعه الگوریتم یادگیری کلی پس‌انتشار که به‌طور مخفف BP نامیده می‌شود و یکی از پرکاربردترین الگوریتم‌های شبکه عصبی است در کنار الگوریتم یادگیری محلی لوبنرگ مارکوآرت که به‌طور مخفف LM نامیده می‌شود مورد استفاده قرار گرفته است. لازم به ذکر است از آنجا که بر اساس توصیه متون فنی در شبکه‌های عصبی BP تابع فعال‌سازی تانژانت سیگموئید به دلایلی از جمله مشتق‌پذیری آن، یکی از مناسب‌ترین توابع فعال‌سازی است؛ در این پژوهش این تابع فعال‌سازی به کار گرفته شده است. به کار بردن LM بر اساس توصیه راهنمای MATLAB بوده، جدا از اینکه کارآیی خوب آن بر اساس متون فنی در کاربردهای مهندسی اثبات شده است [۳۸].

#### ۴- مطالعه عددی

در ادامه به بررسی کارآیی شبکه عصبی به‌عنوان جایگزین تحلیل‌های دینامیکی اجزای محدود نسبتاً گران‌قیمت و زمان‌بر می‌پردازیم. در این بخش دو مثال مورد بررسی قرار گرفته است. در مثال اول یک خاک‌ریزی همگن مورد بررسی قرار گرفته است. در مثال دوم نیز به بررسی بر روی پیش‌بینی پاسخ لرزه‌ای در سدهای خاکی مغزه‌دار با هسته رسی قائم با لحاظ اثر ارتفاع پرداخته شده است.

#### ۴-۱- مثال اول

در این مثال به بررسی عملکرد شبکه عصبی جهت پیش‌بینی شتاب افقی حداکثر در نقاطی از خاک‌ریز که در شکل (۱) نشان داده شده پرداخته شده است. خاک‌ریز بررسی شده در این مثال، همگن و متقارن است و فرض شده است که بر روی پی سنگی

مدل‌سازی) ۶۰ دقیقه به طول انجامید. در حالی که طبق مشاهدات صورت گرفته هزینه محاسبات برای دست یافتن به هر پیش‌بینی شبکه عصبی مصنوعی (پس از تکمیل فرآیند آموزش شبکه عصبی) در همه موارد، صرف‌نظر از خصوصیات ارتعاش تحمیلی و تراز PGA تنها چند ثانیه طول می‌کشد.

در این مطالعه از جعبه‌ابزار شبکه عصبی مصنوعی MATLAB استفاده شده است. نتایج شبیه‌سازی شده بر اساس شبکه عصبی مصنوعی با نتایج مدل‌های اجزای محدود غیرخطی به دست آمده از نرم‌افزار Quakew مقایسه شده است. از شبکه عصبی مصنوعی، برای پیش‌بینی پاسخ لرزه‌ای شتاب افقی زمین در سطح خاک‌ریز استفاده شده است. به همین خاطر همان‌طور که در شکل (۱) نشان داده شده است نقاطی در سطح خاک‌ریز در نظر گرفته شده که در اینجا به عنوان گیرنده نامیده می‌شوند (نقاطی که در آنها پاسخ لرزه‌ای محلی ارزیابی می‌شود و از نتایج آنها در محاسبات شبکه عصبی مصنوعی استفاده می‌شود). تعداد کل این گیرنده‌ها ۱۴ عدد بوده و این گیرنده‌ها با توجه به شکل مقارن این سازه ژئوتکنیکی تنها در نیمه سمت چپ خاک‌ریز قرار گرفته‌اند. واضح است که موقعیت گیرنده‌ها در کلیه نقاط واقع در سطح خاک‌ریز گسترش یافته است.

لازم به ذکر است که از مجموع رکوردهای زلزله مورد استفاده به صورت کاملاً تصادفی ۷۰ درصد آن جهت آموزش شبکه عصبی مصنوعی، ۱۵ درصد دیگر جهت صحت‌سنجی شبکه و ۱۵ درصد باقیمانده جهت آزمایش آن مورد استفاده قرار می‌گیرد. در ادامه جهت دست یافتن به پیش‌بینی‌های دقیق‌تر و واقع‌بینانه‌تر، شبکه عصبی مصنوعی در حالات مختلفی بررسی شده و بهبود یافته و از ترندهای مفیدی جهت رسیدن به این مقصود استفاده شده است.

در حالت اول از پیشنهاد‌های ارائه شده در متون فنی [۱] استفاده شده است. بر این اساس، مطابق شکل (۲) شبکه عصبی مصنوعی که برای پیش‌بینی پاسخ لرزه‌ای این خاک‌ریز استفاده شده است از سه لایه تشکیل شده است. لایه ورودی شامل ۱۶ گره (مختصات گیرنده‌ها  $(x, y)$ ، PGA، PGV، PGW/PGA،  $V_{RMS}$ ،  $A_{RMS}$ ، شدت آریاس  $(I_a)$ ، شدت مشخصه  $(I_c)$ ، چگالی

دامنه، محتوای فرکانسی و مدت تحریک یا ترکیبی از آنها هستند. در این بررسی اولاً شتاب‌نگاشت‌های مورد استفاده از نظر محتوای فرکانسی و پیچیدگی و ترازهای PGA از تنوع بالا و خوبی برخوردار بودند (که شامل ۲۰ تیپ شتاب‌نگاشت ارائه شده در جدول (۱) می‌شوند که همگی مربوط به تیپ خاک ۱ بر اساس آیین‌نامه ۲۸۰۰ بوده و هر یک در پنج مقیاس PGA به ترتیب  $0.1g$ ،  $0.05g$ ،  $0.1g$ ،  $0.2g$  و  $0.5g$  تنظیم گشته و لذا در کل ۱۰۰ تحریک زلزله را شامل شدند). ثانیاً انتخاب ترازهای PGA به نحوی انجام شد که پیش‌بینی‌ها هم برای حالت رفتار خطی و هم برای حالت رفتار غیرخطی مصالح پوشش داده شود.

جدول (۱): رکوردهای زلزله مورد استفاده جهت آموزش، صحت‌سنجی و آزمایش شبکه عصبی مصنوعی در مثال ۱.


نام زمین‌لرزه (محل وقوع)	بزرگا	تعداد رکورد
چی - چی، تایوان	۷/۶۲	۵
لوماپرتا، آمریکا	۶/۹۳	۴
نیگاتا، ژاپن	۶/۶۳	۴
توتوری، ژاپن	۶/۶۱	۴
ایواته، ژاپن	۶/۹	۲
چوئسو، ژاپن	۶/۸	۱

خاک‌ریز ساده مورد بررسی در این مطالعه می‌تواند به عنوان یک خاک‌ریز خاکی کوچک مقیاس که رفتار دینامیکی آن پیش‌تر توسط محققین دیگر مورد بررسی قرار گرفته است مورد ملاحظه قرار گیرد. نیاز به یک ابزار محاسباتی کارا برای شبیه‌سازی پاسخ لرزه‌ای چنین سازه‌های ژئوتکنیکی بزرگ مقیاسی کاملاً حیاتی به نظر می‌رسد. کاربرد مدل‌های کارای مبتنی بر شبکه عصبی مصنوعی با توجه به این حقیقت که تخمین زدن پاسخ لرزه‌ای این سازه‌ها با توجه به مدل‌های عددی اجزای محدود، زمان‌بر است، موضوعی جذاب و کاربردی است. مثلاً برای یک تحلیل پیچیده با یک رکورد زلزله واقعی با طول زیاد و سطح بالای رفتار غیرخطی با یک مدل دو بعدی که با کامپیوتر PC پنتیوم IV با پردازنده CPU ۲/۵۳ گیگاهرتز و RAM ۱ گیگابایت انجام شد، زمان تحلیل (صرف‌نظر از زمان

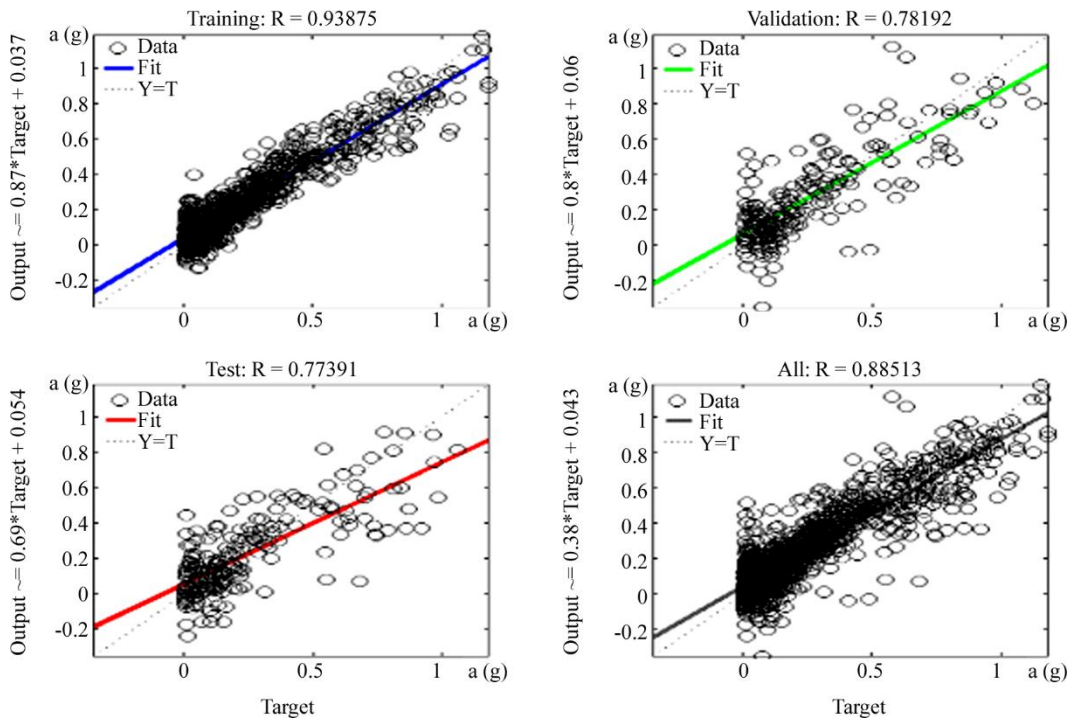
استفاده از یک لایه میانی شکل می‌گیرد) و همچنین لایه خروجی با یک گره (که همان پاسخ لرزه‌ای خاک‌ریز است که در اینجا شتاب افقی حداکثر می‌باشد).

همان‌طور که در شکل (۳) مشاهده می‌شود، نتایج به‌دست آمده از شبکه عصبی مصنوعی حالت اول مطلوب نبوده و پیش‌بینی‌های آن خصوصاً در محدوده غیرخطی (برای مقیاس‌های شتاب  $0.1g$  به بالا) از خطای بالایی نسبت به پاسخ‌های لرزه‌ای محاسبه شده برخوردار است. این نتیجه، کاملاً با آنچه در متون فنی [۱] از حل مثال‌های مشابه به‌دست آمده انطباق دارد.

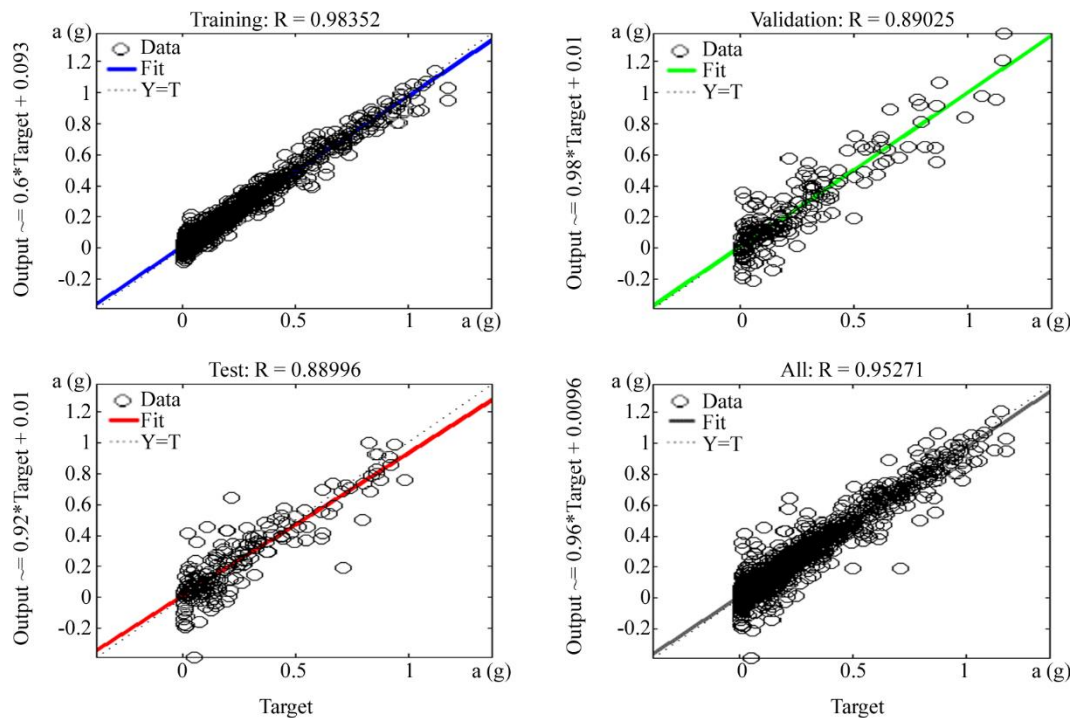
انرژی ویژه (SED)، شدت طیف شتاب (ASI)، شدت طیف سرعت (VSI)، سرعت حداکثر ماندگار (SMV)، شتاب مؤثر طراحی (EDA)، پریود غالب ( $T_p$ ) و مدت حرکات نیرومند زمین ( $T_d$ ))، یک لایه میانی با ۵۰ نرون (لازم به ذکر است که تعداد لایه‌های میانی و تعداد بهینه نرون‌های آن با استفاده از تجربیات ارائه شده در متون فنی [۱] و آزمون و خطا در نظر گرفته شده است. مشاهدات انجام شده نشان می‌دهد که افزایش تعداد لایه‌های پنهان به‌طور قابل‌ملاحظه‌ای بر روی عملکرد شبکه عصبی مصنوعی تأثیر نمی‌گذارد. بنابراین تحلیل‌ها با



شکل (۲): معماری استفاده شده برای شبکه عصبی مصنوعی جهت پیش‌بینی پاسخ لرزه‌ای خاک‌ریز مثال ۱.



شکل (۳): مقایسه بین پاسخ لرزه‌ای محاسبه شده توسط Quakew و پیش‌بینی شده توسط شبکه عصبی با ورودی‌های اصلاح نشده (حالت اول) برای پنج تراز PGA برای گیرنده‌های سطح فوقانی خاک‌ریز.



شکل (۴): مقایسه بین پاسخ لرزه‌ای محاسبه شده توسط Quakew و پیش‌بینی شده توسط شبکه عصبی با ورودی‌های اصلاح شده (حالت دوم) برای پنج تراز PGA برای گیرنده‌های سطح فوقانی خاکریز.

تخمین پاسخ‌های لرزه‌ای نسبت به مقادیر محاسبه شده کاملاً مشهود است. نتیجه حاصل شده نیز دقیقاً با نتایج به دست آمده در متون فنی انطباق دارد؛ با این تفاوت که در پژوهش‌های پیشین این تغییر در معماری شبکه عصبی‌های جزئی، گسترده‌تر بوده تا آنجا که ورودی‌های شبکه عصبی به ازای هر تراز PGA متفاوت بوده است، اما در این پژوهش بدون نیاز به تغییر چیدمان ورودی‌ها به ازای هر تراز PGA، نتایج مطلوبی حاصل شده است. همچنین با بررسی نتایج در همه حالات، چنانکه به وضوح در شکل‌های (۳) تا (۵) عیان است مشاهده می‌شود که در حالات خطی نتایج واقع‌بینانه‌تری نسبت به حالات غیرخطی به دست می‌آید.

جدول (۲): معماری استفاده شده برای شبکه عصبی مصنوعی در هر تراز PGA در مثال ۱.

PGA (g)	چیدمان شبکه عصبی
۰/۱	[۱۲-۷۵-۱]
۰/۰۵	[۱۲-۵۰-۱]
۰/۱	[۱۲-۱۰-۱]
۰/۲	[۱۲-۷۵-۱]
۰/۵	[۱۲-۷۵-۱]

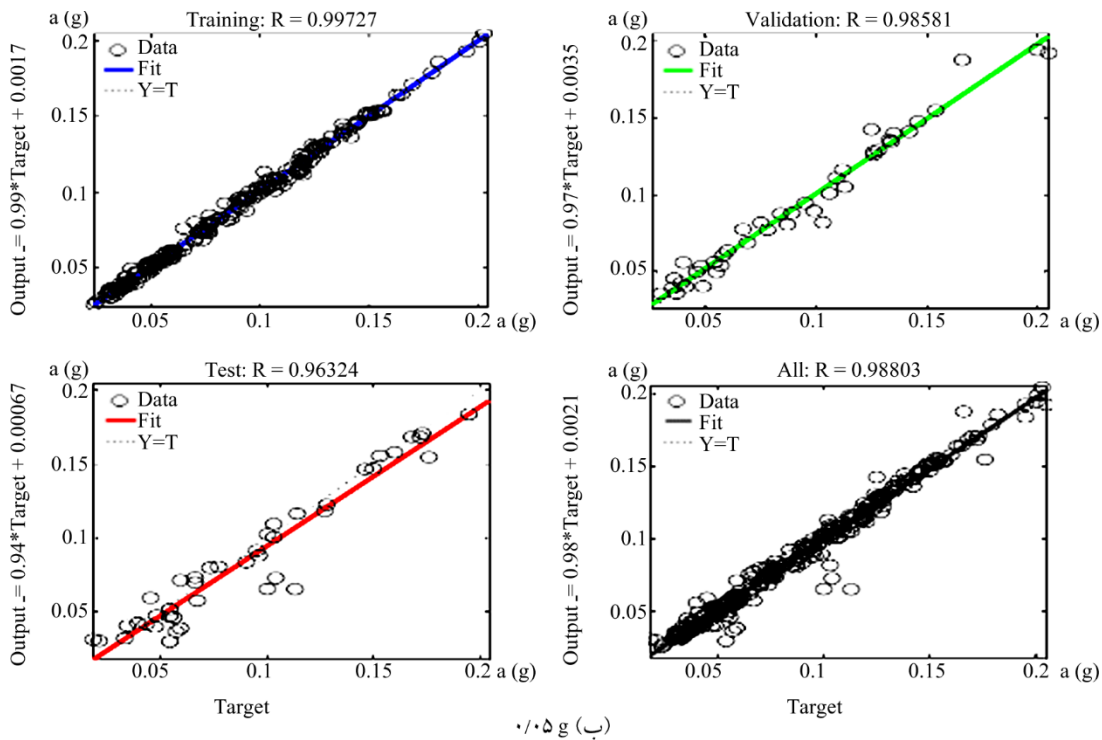
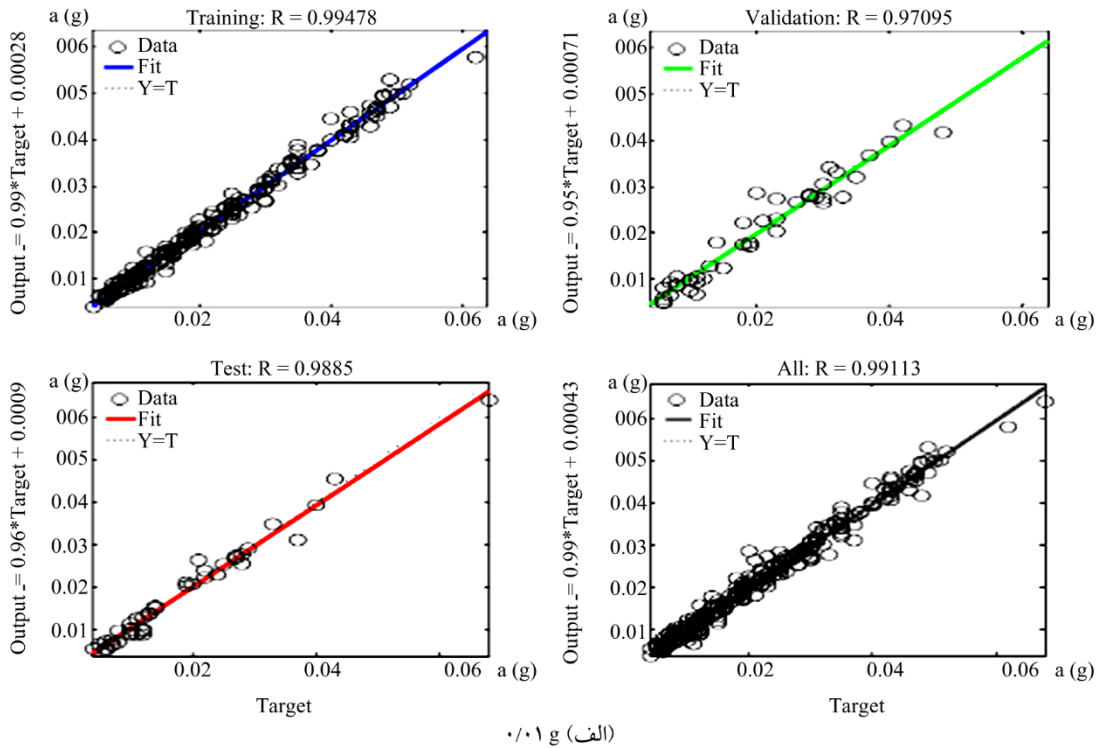
در حالت دوم جهت بهبود عملکرد شبکه عصبی مصنوعی با بازنگری ورودی‌های پیشنهاد شده توسط سمپاناکیس و همکارانش [۱]، برخی از ورودی‌ها که به نظر در فرآیند آموزش تأثیر منفی داشتند حذف شد. به این منظور با حذف چهار ورودی (ARMS، شدت آریاس ( $I_a$ )، شدت مشخصه ( $I_c$ ) و مدت حرکات نیرومند زمین ( $T_d$ )) تعداد ورودی‌ها از ۱۶ ورودی به ۱۲ ورودی کاهش یافته است (شکل ۲). این تغییر تأثیر قابل ملاحظه‌ای در بهبود عملکرد و کاهش خطای پیش‌بینی‌های شبکه عصبی اصلاح شده از خود نشان داده است که در شکل (۴) کاملاً مشهود است.

در حالت سوم جهت بهبود بیشتر کیفیت تخمین‌های شبکه عصبی مصنوعی با توجه به توصیه‌های سمپاناکیس و همکارانش [۱] و جهت بهبود فرآیند یادگیری شبکه عصبی با داده‌های موجود، شبکه عصبی مصنوعی کلی به دست آمده در حالت دوم، با همان چیدمان ورودی‌ها به پنج شبکه عصبی جزئی به ازای هر تراز PGA تفکیک شد. همان‌طور که در جدول (۲) مشاهده می‌شود تنها تفاوت در معماری این شبکه‌های عصبی جزئی، تعداد نرون‌های لایه میانی است. در شکل (۵) نتایج مطلوب ناشی از این تغییر در کاهش خطای

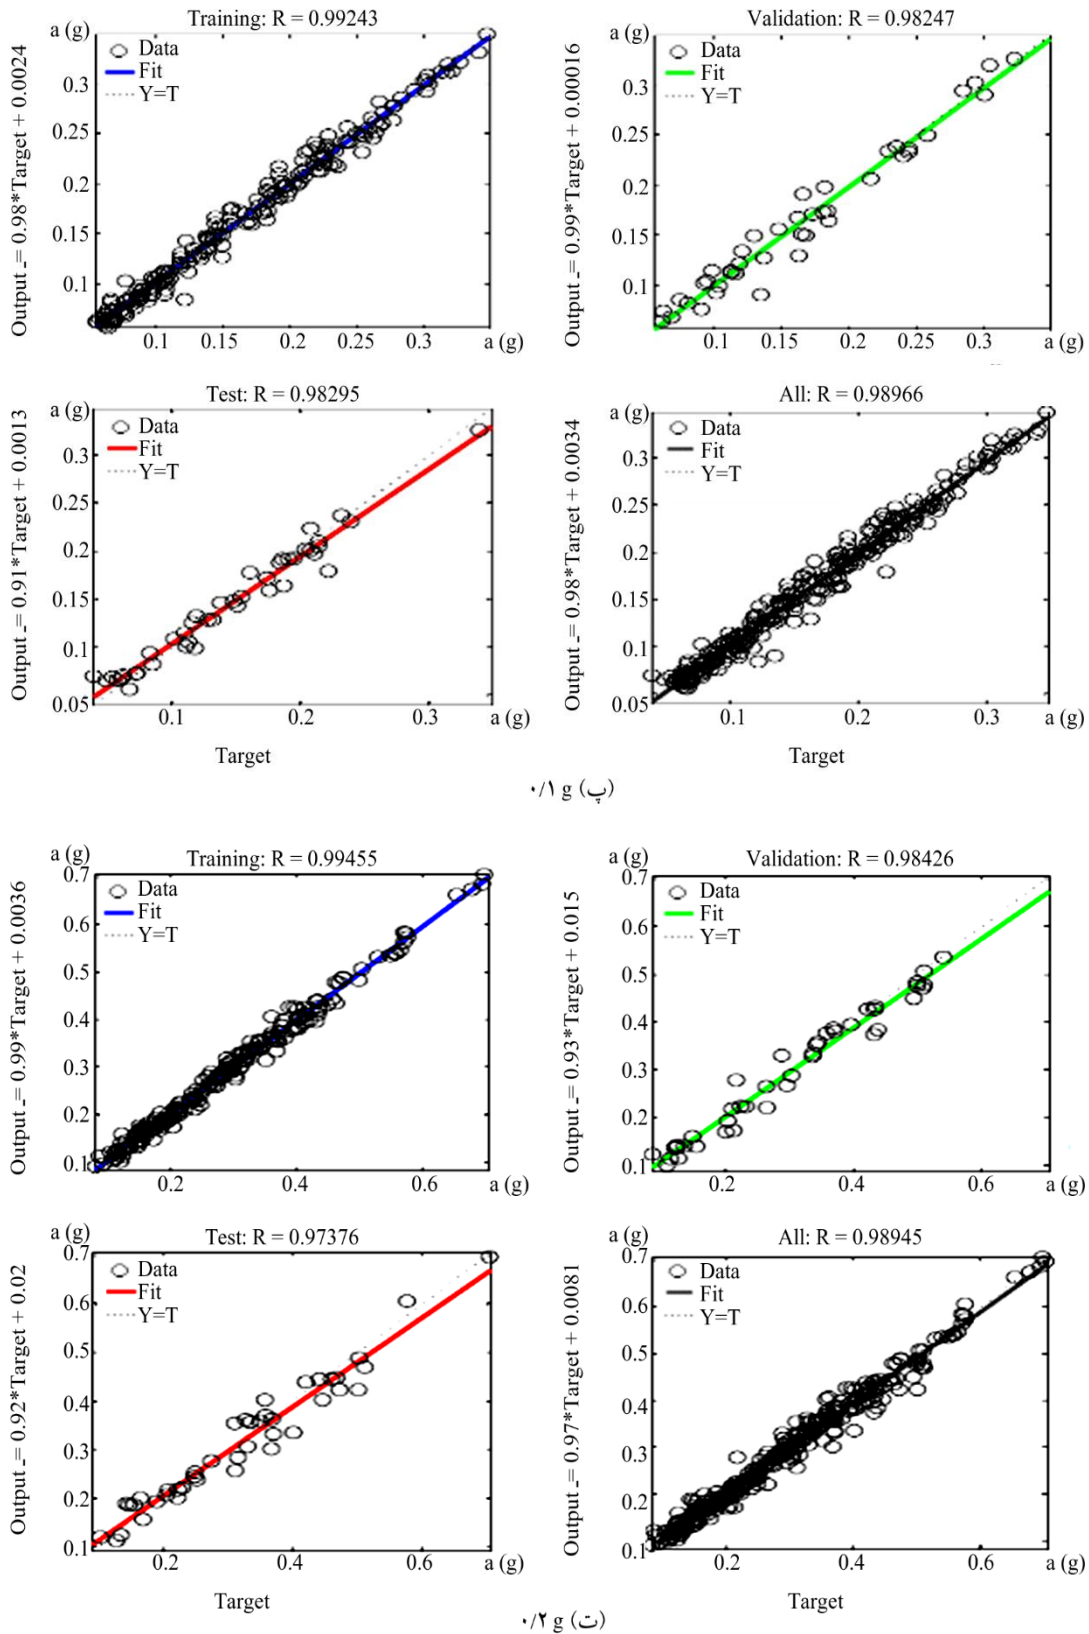


می‌کند. در شکل (۶) و جدول (۳) به‌عنوان نمونه نتایج مربوط به عملکرد شبکه عصبی کلی اصلاح شده (حالت دوم) ارائه شده است.

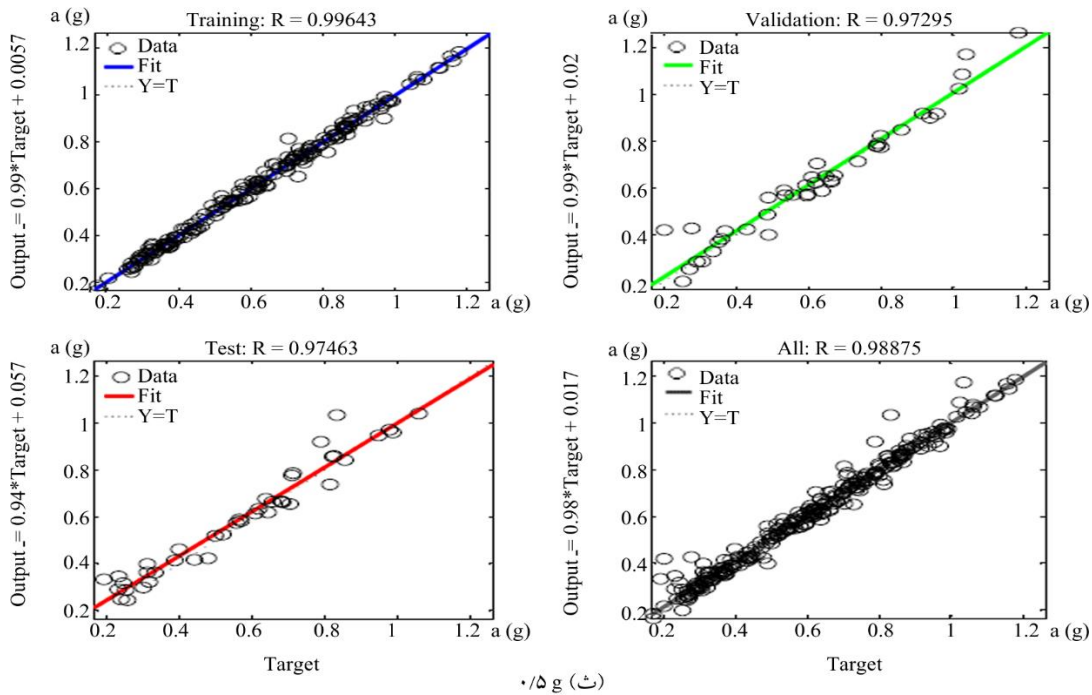
این مسئله را می‌توان به پدیده پیچیدگی انتشار امواج در حالت غیرخطی نسبت داد. این حقیقت، دشواری کار شبکه عصبی را در محاسبه پاسخ واقعی سازه‌های ژئوتکنیکی تأیید



شکل (۵): مقایسه بین پاسخ لرزه‌ای محاسبه شده توسط Quakew و پیش‌بینی شده توسط شبکه عصبی مجزا با ورودی‌های اصلاح شده (حالت سوم) برای ترازهای PGA به ترتیب الف) ۰/۱ g، ب) ۰/۰۵ g، پ) ۰/۱ g، ت) ۰/۲ g و ث) ۰/۵ g، برای گیرنده‌های سطح فوقانی خاک‌ریز.




ادامه شکل (۵).



ادامه شکل (۵).

تاج) سدهای خاکی مغزه‌دار با هسته رسی قائم واقع بر پی‌های سنگی سخت می‌باشد. هدف از این مثال، طرح‌ریزی مدل شبکه عصبی است که بتواند برای سدهای خاکی مغزه‌دار با هسته رسی واقع بر پی‌های سنگی با ارتفاع‌های گوناگون، مشروط به داشتن تشابه ابعادی، خصوصیات مصالح نزدیک و حالت بار یکسان با آنچه این مدل شبکه عصبی مصنوعی با آن آموزش دیده، پاسخ‌های لرزه‌ای را با دقت مناسبی پیش‌بینی نماید. به این منظور همان‌طور که در شکل (۷) نشان داده شده چهار تیپ ابعادی سد خاکی مغزه‌دار با هسته رسی قائم به ارتفاع‌های ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ متر با شیب پوسته بالادست و پایین دست ۲ به ۱، شیب هسته ۰/۲ به ۱ و عرض تاج‌های به ترتیب ۱۰، ۲۰، ۲۰ و ۲۰ متر مورد بررسی قرار گرفته است. لازم به ذکر است که هرچند نرم‌افزار Quakew می‌تواند مقادیر  $G_{max}$  را به صورت تابعی از تنش همه‌جانبه، تعریف و به المان‌ها تخصیص دهد و لذا از این منظر نیاز به افزایش لایه‌ها نیست، ولی نظر به اینکه توابع کاهش سختی و افزایش میرایی برای هر لایه به صورت مستقل از فشار همه‌جانبه تعریف می‌شود، لذا جهت تدقیق مدل، هسته و پوسته سد را در چند لایه تعریف نموده و به هر لایه توابع کاهش سختی و افزایش



شکل (۶): نمودار میانگین قدر مطلق خطای شبکه عصبی کلی اصلاح شده (حالت دوم) مثال ۱.

جدول (۳): نتایج مربوط به عملکرد شبکه عصبی کلی اصلاح شده (حالت دوم) مثال ۱.

R	MSE	Samples	ANN
۰/۹۸	۰/۰۰۴	۹۸۰	Training
۰/۸۹	۰/۰۱۵	۲۱۰	Validation
۰/۸۹	۰/۰۱۸	۲۱۰	Testing

## ۴-۲- مثال دوم

در این مثال، هدف ایجاد مدل شبکه عصبی مصنوعی عمومی‌تری برای پیش‌بینی پاسخ لرزه‌ای (شتاب افقی حداکثر

رفتار خطی و هم برای حالت رفتار غیر خطی مصالح پوشش داده شود. در این مثال نیز جهت دست یافتن به پیش‌بینی‌های دقیق‌تر و واقع‌بینانه‌تر، شبکه عصبی مصنوعی بهبود یافته و از ترندهای مفیدی جهت رسیدن به این مقصود استفاده شده است.

جدول (۴): خصوصیات مصالح سدهای خاکی بررسی شده در مثال ۲.

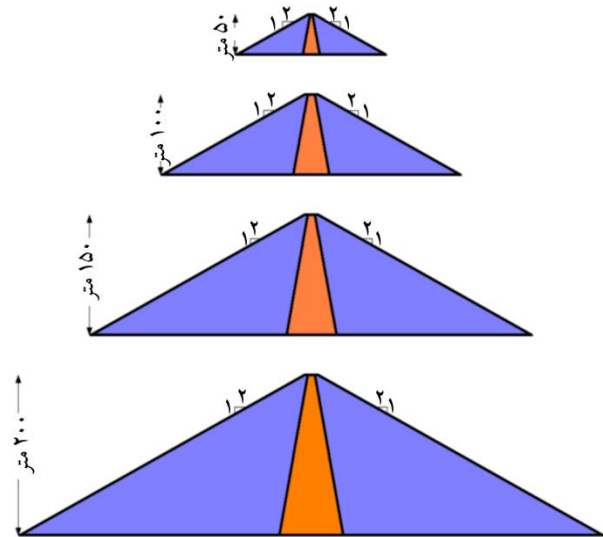
نام المان سد	Y (کیلو نیوتن بر متر مکعب)	C (کیلو پاسکال)	Ø (درجه)	ν
پوسته	۲۰	۰	۴۰	۰/۳۳۴
فیلتر	۲۰	۰	۴۰	۰/۳۳۴
هسته	۱۶	۱۰	۲۰	۰/۳۳۴

جدول (۵): رکوردهای زلزله مورد استفاده جهت آموزش، صحت‌سنجی و آزمایش شبکه عصبی مصنوعی در مثال ۲.

نام زمین‌لرزه (محل وقوع)	بزرگا	تعداد رکورد
چی - چی، تایوان	۷/۶۲	۵
لوماپریتا، آمریکا	۶/۹۳	۴
نیگاتا، ژاپن	۶/۶۳	۴
توتوری، ژاپن	۶/۶۱	۴
ایواته، ژاپن	۶/۹	۳
چوتسو، ژاپن	۶/۸	۲

در این مثال از چهار شبکه عصبی مصنوعی مجزا برای پیش‌بینی پاسخ‌های لرزه‌ای سدهای خاکی با ارتفاع ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ متری استفاده شده است. برای تخمین پاسخ‌های لرزه‌ای سدهای خاکی با سایر ارتفاع‌ها از درون‌یابی و برون‌یابی خطی استفاده می‌شود.

لازم به ذکر است که برخلاف مثال اول که در حالت سوم جهت بهبود کیفیت شبکه عصبی مصنوعی و با توجه به نتایج حاصل از پژوهش سمپاناکیس و همکارانش [۱]، شبکه عصبی کلی که برای تمامی ترازهای PGA بود را تفکیک کردیم و برای هر تراز PGA شبکه عصبی مجزایی تعریف نمودیم، در این مثال هدف ایجاد مدلی کلی‌تر است که برای یک مقطع سد خاکی تحت تحریک‌های مختلف و PGAهای گوناگون، پاسخ قابل قبولی داشته باشد. در ادامه به شرح راهکارهای مورد استفاده جهت بهبود پیش‌بینی‌های شبکه عصبی مصنوعی در این مثال پرداخته می‌شود.



شکل (۷): تیپ مقطع سدهای خاکی مدل شده جهت مثال پیش‌بینی پاسخ لرزه‌ای سدهای خاکی با ارتفاع‌های ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ متر.

میرایی مربوط به آن اختصاص داده شده است. حالت بار مورد بررسی پایان ساخت می‌باشد. همچنین خصوصیات مصالح نواحی مختلف سدهای خاکی بررسی شده در جدول (۴) آمده است. در این مثال نیز اولاً شتاب‌نگاشت‌های مورد استفاده از نظر محتوای فرکانسی و پیچیدگی و ترازهای PGA از تنوع بالا و خوبی برخوردارند (که شامل ۲۲ تیپ شتاب‌نگاشت ارائه شده در جدول (۵) که همگی مربوط به تیپ خاک ۱ بر اساس آیین‌نامه ۲۸۰۰ بوده و هر یک در هفت مقیاس PGA به ترتیب ۰/۰۱ g، ۰/۰۵ g، ۰/۱ g، ۰/۲ g، ۰/۳ g، ۰/۴ g و ۰/۵ g تنظیم شده‌اند می‌شود و لذا شامل ۱۵۴ تحریک زلزله می‌باشند). لازم است که از مجموع رکوردهای زلزله مورد استفاده ۲۰ رکورد جدا شده و به صورت کاملاً تصادفی ۷۰ درصد جهت آموزش شبکه عصبی مصنوعی، ۱۵ درصد دیگر جهت صحت‌سنجی شبکه و ۱۵ درصد باقیمانده جهت آزمایش آن مورد استفاده قرار می‌گیرد. همچنین دو رکورد دیگر که یکی دارای محتوای فرکانسی بالا و دیگری پایین است بوده و تشابه کمتری با سایر رکوردها دارد جهت امتحان دقیق‌تر مدل شبکه عصبی به دست آمده مورد استفاده قرار گرفته است. در این مثال شتاب افقی حداکثر در تاج سد، پاسخ لرزه‌ای مورد بررسی است. همچنین در اینجا نیز انتخاب ترازهای PGA به نحوی انجام شده است که پیش‌بینی‌ها هم برای حالت

آورد این پژوهش در این بخش این بود که با بهبود عملکرد شبکه عصبی جامع تا حد رسیدن به تخمین‌های قابل قبول با تغییر در ورودی‌ها (و نه تفکیک و ایجاد تعدد در شبکه‌های عصبی به ازای ترازهای PGA) در امکان‌پذیر بودن این ایده که می‌توان از پیش‌بینی‌های سریع و قابل قبول شبکه عصبی در خصوص پاسخ‌های لرزه‌ای سدهای خاکی به‌عنوان جانشینی مناسب برای تحلیل‌های دشوار و زمان‌بر دینامیکی سدهای خاکی استفاده نمود تأیید شد.

در ادامه از آنجا که تعیین دقیق تر مناسب‌ترین حالت و چیدمان برای شبکه عصبی مصنوعی، جهت پیش‌بینی پاسخ‌های لرزه‌ای سدهای خاکی نیاز به بررسی دقیق‌تر کمی دارد، از دو رکورد زلزله Chuetsu و Iwate که تاکنون استفاده نشده بود و یکی جزو زلزله‌های با محتوای فرکانسی پایین و دیگری جزو زلزله‌های با محتوای فرکانسی بالاست، جهت ارزیابی و تدقیق چهار شبکه عصبی مذکور استفاده شده است. این بررسی برای چهار تراز PGA که به ترتیب عبارتند از  $0.1g$ ،  $0.1g$ ،  $0.2g$  و  $0.5g$  شده است و نتایج آن در جدول (۶) مشاهده می‌شود. همچنین در جدول (۷) معماری بهینه این شبکه‌های عصبی ارائه شده است. لازم به ذکر است که همان‌طور که از جدول مذکور برمی‌آید چیدمان منتخب شبکه‌های عصبی توان پیش‌بینی مناسب پاسخ‌های زلزله‌های گوناگون را دارند.

با الگوگیری از مثال اول و با تأیید مناسب‌تر نبودن ورودی‌های پیشنهاد شده در متون فنی [۱] پس از بررسی‌های انجام شده در این مثال، هر یک از چهار شبکه عصبی مصنوعی جزئی (برای سدهای خاکی با ارتفاع‌های ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ متر) به‌طور مجزا بررسی شده است. در این بررسی از همان ورودی‌های اصلاح شده مثال اول استفاده شده است.

در این مثال نیز شبکه‌های عصبی مصنوعی از سه لایه به شرح زیر تشکیل شده است. لازم به ذکر است که در اینجا با توجه به اینکه شتاب افقی حداکثر تنها در یک نقطه (تاج سد) مد نظر است لذا دو ورودی مختصات گیرنده‌ها  $(x,y)$  که در مثال اول آمده بود حذف شده است. لایه ورودی که با ۱۰ گره  $(PGA, PGV, PGV/PGA, V_{RMS},$  چگالی انرژی ویژه  $(SED),$  شدت طیف شتاب  $(ASI),$  شدت طیف سرعت  $(VSI),$  سرعت حداکثر ماندگار  $(SMV),$  شتاب مؤثر طراحی  $(EDA)$  و پرپود غالب  $(T_p))$ ، یک لایه میانی و همچنین لایه خروجی با یک گره (که همان پاسخ لرزه‌ای یعنی شتاب افقی حداکثر در تاج سد است). در این مثال نیز مانند مثال اول، پاسخ‌های حاصل از هر چهار شبکه عصبی که مستقل از نوع و تراز PGA تحریک زلزله آموزش دیده‌اند، با ورودی‌های پیشنهادی، مطلوب بوده است. این موضوع در شکل (۷) نشان داده شده است. ارزشمندترین دست

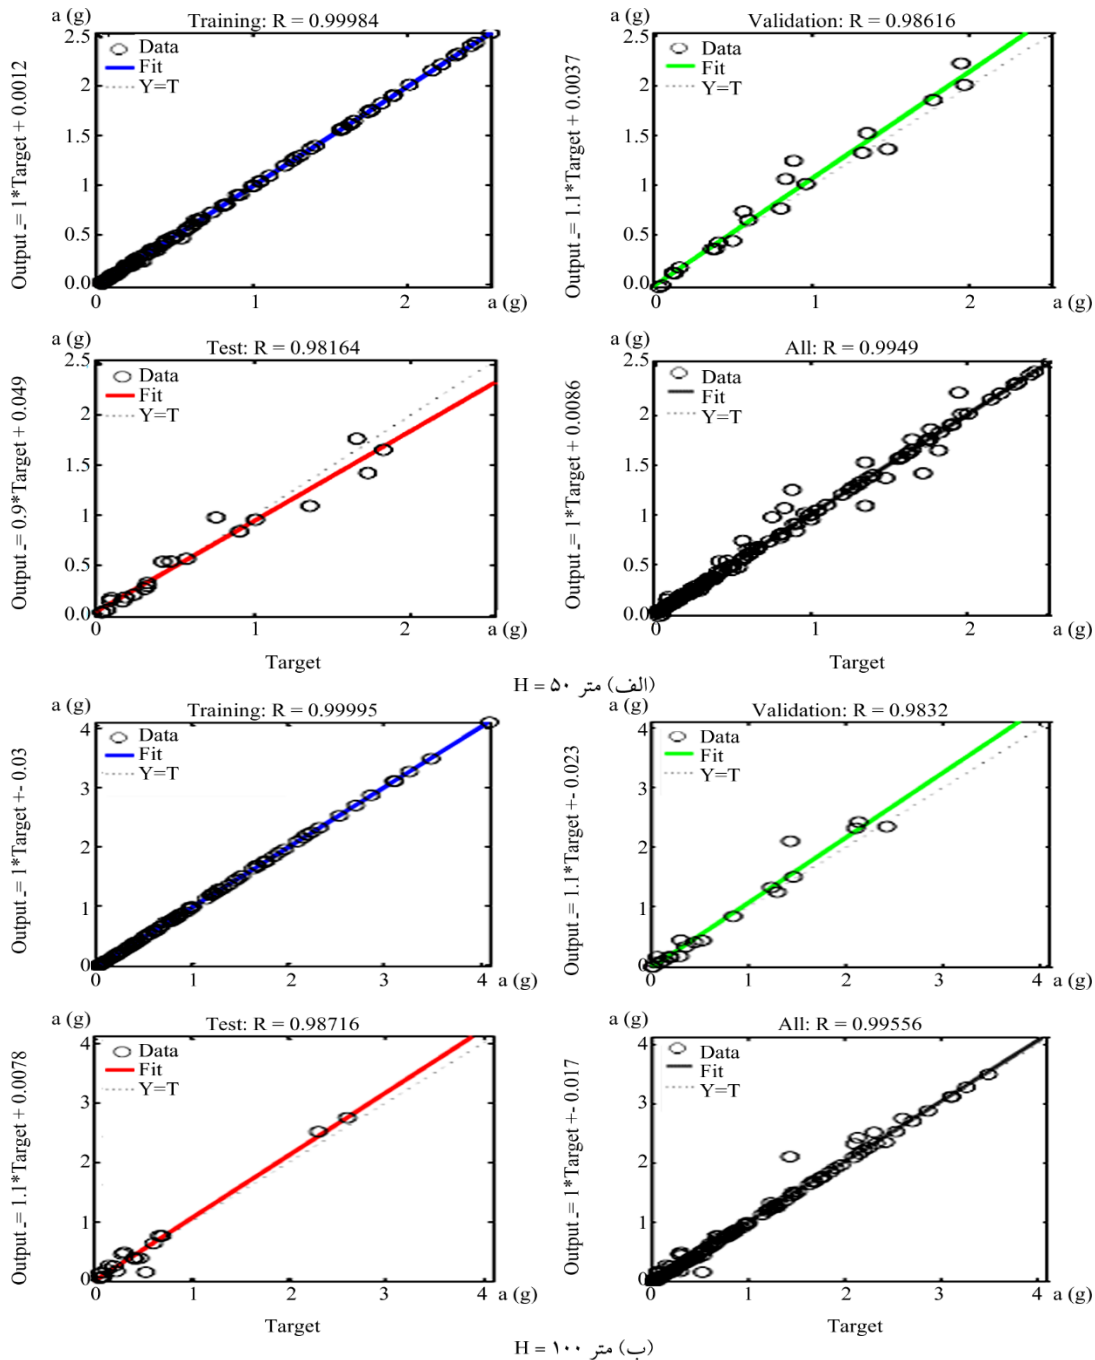
جدول (۶): نتایج مدل شبکه عصبی جهت پیش‌بینی شتاب افقی حداکثر در تاج سد با استفاده از رکورد زلزله Chuetsu و Iwate برای سدهای خاکی با ارتفاع ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ متر.

Iwate				Chuetsu				روش	ارتفاع سد (متر)
۰/۵ g	۰/۳ g	۰/۱ g	۰/۰۱ g	۰/۵ g	۰/۳ g	۰/۱ g	۰/۰۱ g		
۰/۹۹۷	۰/۶۳۷	۰/۱۹۷	۰/۰۰۲	۱/۹۸۲	۱/۵۹	۰/۵۵۸	۰/۱۰۹		
۰/۸۹	۰/۵۳	۰/۱۹	۰/۰۲۱	۲/۰۴	۱/۶	۰/۷۶	۰/۰۸۸		
۱/۲۲۱	۰/۶۶۷	۰/۲۵۲	۰/۰۶۷	۳/۶۸	۲/۰۹	۰/۵۸۷	۰/۰۸	۱۰۰	
۱/۰۶	۰/۷	۰/۲	۰/۰۱۸	۴/۳۱	۲/۶۱	۰/۵۶	۰/۰۷۱		
۱/۴۱۱	۰/۶۶۹	۰/۲۲۳	۰/۰۲۵	۳/۹۵۷	۲/۷۸۱	۰/۸۵۵	۰/۰۷۱	۱۵۰	
۱/۴۳	۰/۸۸	۰/۲۵	۰/۰۲۲	۴	۱/۶۷	۰/۶۸	۰/۰۷		
۰/۹۷۸	۰/۴۵۱	۰/۱۷۸	۰/۰۲۲	۴/۲۵۱	۲/۳۰۸	۰/۷۸۹	۰/۰۶۹		
۱/۰۴	۰/۶۱	۰/۱۹	۰/۰۱۸	۴/۳۷	۲/۵۶	۰/۸۵	۰/۰۹۶	۲۰۰	

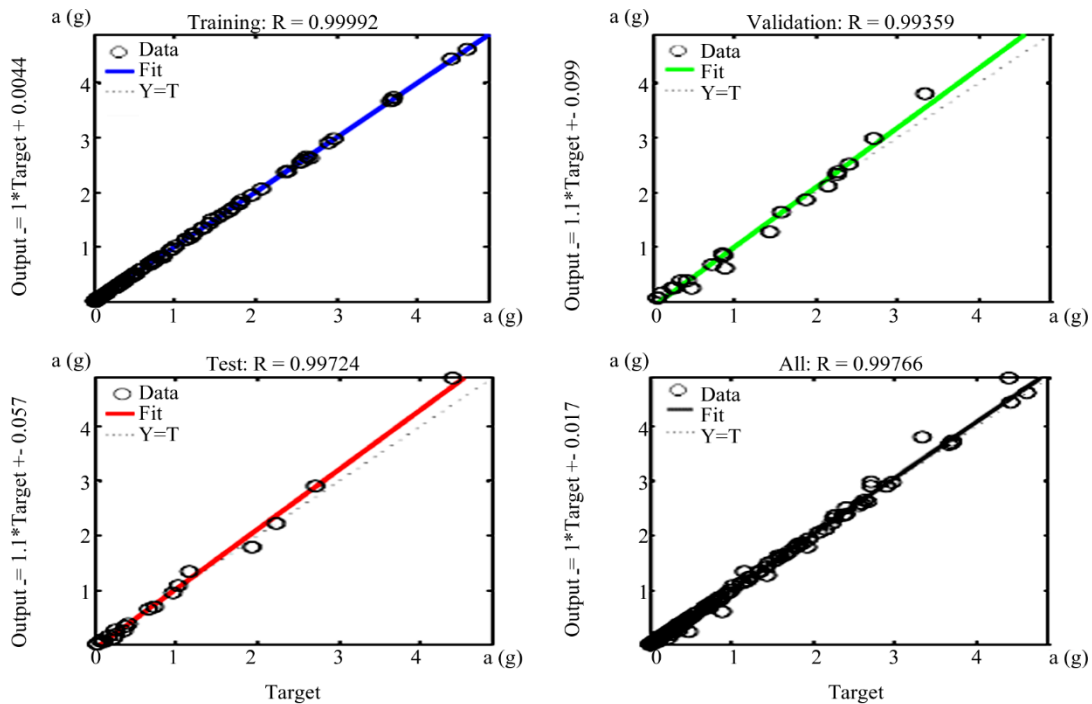
در این مثال هم واضح است که بزرگنمایی شتاب، اساساً با افزایش غیرخطی شدن کاهش پیدا می‌کند. همچنین با بررسی نتایج در همه حالات چنان که می‌توان به وضوح در شکل‌های (۷) و (۸) مشاهده کرد، مشخص می‌شود که در حالات خطی نتایج واقع بینانه تری نسبت به حالات غیرخطی به دست می‌آید.

جدول (۷): معماری استفاده شده برای در هر یک از زیرمجموعه‌های شبکه عصبی مصنوعی و تعیین حالات برگزیده.

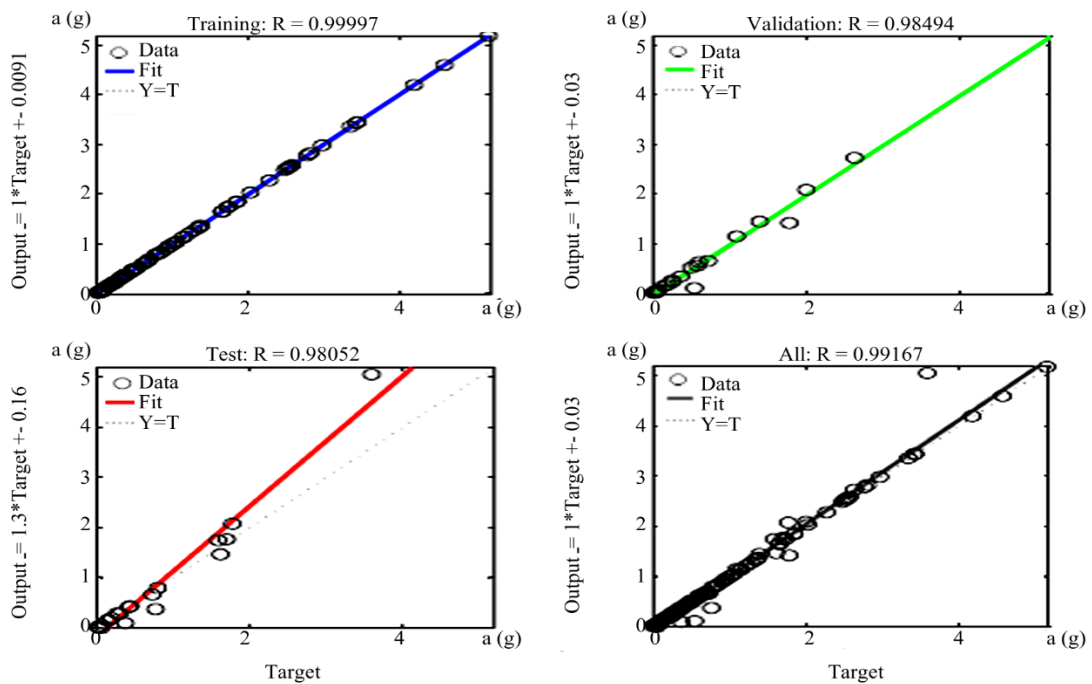
ارتفاع سد (متر)	آرایش شبکه عصبی
۵۰	[۱۰-۱۰-۱]
۱۰۰	[۱۰-۱۰-۱]
۱۵۰	[۱۰-۵۰-۱]
۲۰۰	[۱۰-۵۰-۱]



شکل (۸): مقایسه بین شتاب افقی حداکثر تاج، محاسبه شده توسط Quakew و پیش‌بینی شده توسط شبکه عصبی با ورودی‌های اصلاح شده برای سدهای خاکی با ارتفاع (الف) ۵۰ متر، (ب) ۱۰۰ متر، (پ) ۱۵۰ متر و (ت) ۲۰۰ متر.



(پ) متر ۱۵۰ H



(ت) متر ۲۰۰ H

ادامه شکل (۸).

### ۵- نتیجه گیری

مطالعه حاضر، با هدف بررسی توانایی شبکه عصبی مصنوعی در دست یافتن به پاسخ تحلیل دینامیکی یک خاک‌ریز و سد خاکی معین و همچنین پاسخ تحلیل دینامیکی خاک‌ریزها و سدهای خاکی با ارتفاع‌های گوناگون ولی دارای تشابه ابعادی

همچنین نتایج این مثال نشان می‌دهد دست یافتن به مدل شبکه عصبی مصنوعی عمومی‌تری که بتواند علاوه بر پیش‌بینی پاسخ لرزه‌ای یک خاک‌ریز یا سد خاکی معین، برای خاک‌ریزها و سدهای خاکی با ارتفاع‌های گوناگون نیز تخمین‌های ایده آلی ارائه دهد، شدنی است.

آموزش شبکه عصبی مصنوعی برای سایر حالات با تغییر ابعاد و خصوصیات مصالح و حالات بار، باعث نزدیک شدن به تحقق این ایده و ایجاد شبکه عصبی عمومی تر جهت این کاربرد خواهد شد. البته بی شک این تعمیم در مدل شبکه عصبی مصنوعی در قبال ایجاد کاهش در زمان تحلیل، افزایش میزان خطای تخمین ها را به همراه خواهد داشت.

### مراجع

1. Tsompanakis, Y., Lagros, N., Psarropoulos, P., and Georgopoulos, E. (2009) Simulating the seismic response of embankments via artificial neural. *Advances in Engineering Software*, **40**(8), 640-651.
2. Lagaros, N.D. and Tsompanakis, Y. (eds.) (2006) *Intelligent Computational Paradigms in Earthquake Engineering*. Idea Publishers.
3. Papadrakakis, M., Lagaros, N.D., and Tsompanakis, Y. (1998) Structural optimization using evolution strategies and neural networks. *Computer Methods in Applied Mechanics and Engineering*, **156**(1-4), 309-333.
4. Tsompanakis, Y., Lagaros, N.D., and Stavroulakis, G.E. (2008) Soft computing techniques in parameter identification and probabilistic seismic analysis of structures. *Advances in Engineering Software*, **39**(7), 612-624.
5. Stavroulakis, G.E., Foutsitzi, G., Hadjigeorgiou, E., Marinova, D., and Baniotopoulos, C.C. (2005) Design and robust optimal control of smart beams with application on vibration suppression. *Advances in Engineering Software*, **36**(11-12), 806-813.
6. Gonzalez, M.P. and Zapico, J.L. (2008) Seismic damage identification in buildings using neural networks and modal data. *Computers and Structures*, **86**(3-5), 416-426.
7. Fang, X. and Luo, H., and Tang, J. (2005) Structural damage detection using neural network with learning rate improvement. *Computers and Structures*, **83**(25-26), 2150-2161.
8. Kao, C.Y. and Shih-Lin, H. (2003) Detection of structural damage via free vibration responses generated by approximating artificial neural networks. *Computers and Structures*, **81**(28-29),

تحت تحریک های لرزه ای و ترازهای شدت گوناگون انجام شده است. هدف اصلی کاهش هزینه نسبتاً سنگین تحلیل های دینامیکی و تعیین پاسخ های دینامیکی برای این مسئله ی مهندسی ژئوتکنیک لرزه ای بزرگ مقیاس با قبول خطای مازاد تخمین های شبکه عصبی است که بر خطای برآوردهای عددی که خود با واقعیت برابری ندارد، افزوده می شود. برای رسیدن به این هدف بررسی همه جانبه ای صورت گرفت که با توجه به آن پارامترهای مختلف مورد ارزیابی قرار گرفتند. مطابق نتایج نشان داده شده، شبکه عصبی مصنوعی برای گیرنده هایی که در تاج و بخش فوقانی خاک ریز و بخش شیب دار آن قرار گرفته اند به تقریب خوبی از پاسخ لرزه ای می رسند. به عبارت دیگر، مدل مبتنی بر شبکه عصبی مصنوعی، تخمین کاملاً مطلوبی از پاسخ کلی خاک ریز به دست می دهد. هر چند مقایسه نتایج شبکه های عصبی مصنوعی تفکیک شده با نتایج شبکه عصبی مصنوعی یکپارچه، دقت بیشتر تخمین های شبکه عصبی مصنوعی با چیدمان متفاوت برای هر تراز PGA را خصوصاً در ناحیه خطی نشان می دهد؛ ولی این پژوهش با رفع نقص موجود در تحقیقات پیشین، به چیدمان مناسبی برای شبکه عصبی مصنوعی یکپارچه دست یافت که با آن می توان با استفاده از این نوع شبکه های عصبی نیز به تخمین مطلوبی برای همه ترازهای PGA دست یافت. در نهایت می توان نتیجه گرفت که قطعاً با ملاحظه پیچیدگی های مسئله مورد بررسی و عملکرد شبکه های عصبی مصنوعی در حل آنها و همچنین وجود سابقه گزارش های عملکرد موفق این ابزار در سایر کاربردهای مشابه، کاربرد شبکه های عصبی مصنوعی جهت تخمین و پیش بینی پاسخ های لرزه ای خاک ریزها و سدهای خاکی، مؤثر ارزیابی می شود و استفاده از شبکه های عصبی مصنوعی به این منظور موجب پایین آمدن فوق العاده زمان تحلیل ها و کاهش هزینه های محاسبات ارزیابی پاسخ لرزه ای یک خاک ریز و سد خاکی خواهند شد. بنابراین استفاده از این ابزار در این عرصه دشوار از مهندسی ژئوتکنیک لرزه ای بسیار امیدبخش به نظر می رسد. به هر حال پیشرفت و توسعه های آتی در پژوهش در این زمینه و توسعه



- soil dynamic amplification analysis. *Soil Dynamics and Earthquake Engineering*, **21**(7), 579-591.
21. Garcia, S.R., Romo, M.P., and Sarmiento, N. (2002) Modeling ground motion in Mexico City using artificial neural networks. *Geofísica Internacional*, **42**(2), 173-183.
  22. Paolucci, R., Colli, P., and Giacinto, G. (2002) Assessment of seismic site effects in 2-D alluvial valleys using neural networks. *Earthquake Spectra*, **16**(3), 661-680.
  23. Garcia, S.R. and Romo, M.P. (2004) Dynamic soil properties identification using earthquake records: a NN approximation. *Proceedings of the 13<sup>th</sup> World Conference on Earthquake Engineering*, Vancouver, B.C., Canada, Paper No.1817.
  24. Kerh, T. and Ting, S.B. (2005) Neural network estimation of ground peak acceleration at stations along Taiwan high-speed rail system. *Engineering Applications of Artificial Intelligence*, **18**(7), 857-866.
  25. Lin, C.C.J. and Ghaboussi, J. (2001) Generating multiple spectrum compatible accelerograms using stochastic neural networks. *Earthquake Engineering and Structural Dynamics*, **30**(7), 1021-1042.
  26. Seung, C.L. and Sang, W.H. (2002) Neural-network-based models for generating artificial earthquakes and response spectra. *Computers and Structures*, **80**(20-21), 1627-1038.
  27. Rajasekaran, S. and David, V.K. (2007) MicroARTMAP for pattern recognition problems. *Advances in Engineering Software*, **38**(10), 698-709.
  28. Ziemianski, L. (2003) Hybrid neural network/finite-element modelling of wave propagation in infinite domains. *Computers and Structures*, **81**(8-11), 1099-1109.
  29. Kerh, T. and Chu, D. (2002) Neural networks approach and microtremor measurements in estimating peak ground acceleration due to strong motion. *Advances in Engineering Software*, **33**(11-12), 733-742.
  30. Ozerdem, M.S., Ustundag, B., and Demirer, R.M. (2006) Self-organized maps based neural networks for detection of possible earthquake precursory 2631-2644.
  9. Kallassy, A. (2003) A new neural network for response estimation. *Computers and Structures*, **81**(26-27), 2417-2429.
  10. Chen, Q., Chan, Y.W., and Worden, K. (2003) Structural fault diagnosis and isolation using neural networks based on response-only data. *Computers and Structures*, **81**(22-23), 2165-2172.
  11. Kuz'niar, K. and Waszczyszyn, Z. (2003) Neural simulation of dynamic response of prefabricated buildings subjected to paraseismic excitations. *Computers and Structures*, **81**(24-25), 2353-2360.
  12. Cardoso, J.B., Almeida, J.R., Dias, J.M., and Coelho, P.G. (2008) Structural reliability analysis using Monte Carlo simulation and neural networks. *Advances in Engineering Software*, **39**(6), 505-513.
  13. Chau, K.W. (2007) Reliability and performance-based design by artificial neural network. *Advances in Engineering Software*, **38**(3), 145-149.
  14. Chau, K.W. (2007) Application of a PSO-based neural network in analysis of outcomes of construction claims. *Automat Construct*, **16**(5), 642-646.
  15. Wu, C.L. and Chau, K.W. (2006) A flood forecasting neural network model with genetic algorithm. *International Journal Environmental Pollution*, **28**(3-4), 261-273.
  16. Chouicha, M.A., Siller, T.J., and Charlie, W.A. (1994) An expert-system approach to liquefaction analysis: 2. Evaluation. *Computers and Geotechnics*, **16**(1), 37-69.
  17. Goh, A.T.C. (1994) Seismic liquefaction potential assessed by neural networks. *ASCE Journal of Geotechnical Engineering*, **120**(9), 1467-1480.
  18. Wang, J. and Rahman, M.S. (1999) A neural network model for liquefaction-induced horizontal ground displacement. *Soil Dynamics and Earthquake Engineering*, **18**(8), 555-568.
  19. Baziar, M.H. and Nilipour, N. (2003) Evaluation of liquefaction potential using neural networks and CPT results. *Soil Dynamics and Earthquake Engineering*, **23**(7), 631-636.
  20. Hurtado, J.E., Londono, J.M., and Meza, M.A. (2001) On the applicability of neural networks for

learning in multi-layer perceptions – from backpropagation to adaptive learning algorithms. *International Journal of Computer Standards and Interfaces - Special Issue on Neural Networks*, **16**, 265-278.

electric field patterns. *Advances in Engineering Software*, **37**(4), 207-217.

31. Psarropoulos, P.N., Tsompanakis, Y., and Karabatsos, Y. (2007) Effects of local site conditions on the seismic response of municipal solid waste landfills. *Soil Dynamics and Earthquake Engineering*, **27**(6), 553-563.
32. Newmark, N.M. (1965) Effects of earthquakes on dams and embankments. *Geotechnique*, **15**(2), 139-160.
33. Makdisi, F.I. and Seed, H.B. (1978) Simplified procedure for estimating dam and embankment earthquake induced deformations. *ASCE Journal of the Geotechnical Engineering Division*, **104**(7), 849-867.
34. EN 1998-1:2003 (2003) *Eurocode 8: Design of Structures for Earthquake Resistance. Part 1: General Rules, Seismic Actions and Rules for Buildings*. Commission of the European Communities, European Committee for Standardization.
35. EAK 2000 (2000) *Greek Seismic Design Code*. Greek Ministry of Public Works, Athens, Greece.
36. Kramer, S.L. (1996) *Geotechnical Earthquake Engineering*. New Jersey, Prentice Hall.
37. Dynamic Modelling with QUAKE/W 2007 (2007) *User Manual Fourth Edition*. Geo-Slope International Ltd. Calgary, Alberta, Canada.
38. Haykin, S. (1999) *Neural Networks*. Prentice Hall, New Jersey, USA.
39. MacKay, D.J.C. (1992) A practical Bayesian framework for back prop networks. *Neural Computation*, **4**(3), 448-472.
40. Schiffmann, W., Joost, M., and Werner, R. (1993) *Optimization of the Back-Propagation Algorithm for Training Multi-Layer Perceptrons*. Technical Report, University of Koblenz, Institute of Physics.
41. Riedmiller, M. and Braun, H. (1993) A direct adaptive method for faster back-propagation learning: the RPROP algorithm. *Proceedings of the IEEE International Conference on Neural Networks (ICNN)*, San Francisco, 586-591.
42. Riedmiller, M. (1994) Advanced supervised

## Predicting the Seismic Response of Embankments and Earth Dams with Artificial Neural Network

Amin Rezaeian<sup>1</sup>, Mohammad Davoodi<sup>2\*</sup>, and Mohammad Kazem Jafari<sup>3</sup>

1. Ph.D. Candidate, Department of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran
2. Associate Professor, Geotechnical Engineering Research Center, International Institute of Earthquake Engineering and Seismology (IIEES), Tehran, Iran, \*Corresponding Author, email: m-davood@iiees.ac.ir
3. Professor, Earthquake Risk Management Research Center, International Institute of Earthquake Engineering and Seismology (IIEES), Tehran, Iran

The artificial neural network (ANN), one of the most powerful tools of artificial intelligence, was used to control the seismic responses of the cross section, and to predict earth dam seismic responses rather than utilizing dynamic time-based analyses. In terms of the artificial neural network, apart from the aforementioned ANN-based applications in various engineering problems, an increasing number of articles have been published over the last decade where the efficient implementation of ANNs in geotechnical earthquake engineering is presented. Most of these studies focus on liquefaction potential under seismic excitations, which is an extremely computationally intensive issue and therefore suitable for ANNs. In some of the studies in this field, the applicability of ANNs in soil dynamic analysis was examined. In addition to the generation of spectrum compatible accelerograms, prediction of earthquake parameters, wave propagation approximations, estimation of peak ground acceleration using microtremors, and the detection of earthquake electric field patterns. Not much has been done into predicting the seismic responses of embankments and earth dams using artificial neural networks tools. The first study on the domain was carried out by Tsompanakis et al. [1] in 2009 in which using the artificial neural network, a seismic response (maximum horizontal acceleration) of homogeneous and symmetric embankment in different locations was predicted. Although being a case study on a simple embankment, earthquake records (accelerograms) were used, which contained a variety of frequency concepts, simplicity or complexity, and various PGA levels, in addition to a general neural network that could be used in all PGA levels the seismic response was not accurately predicted. The objective of the present study was to investigate the ability of the artificial neural network to reach the dynamic response of the embankment and earth dams under seismic loads and different levels of intensity. In other words, it was planned to reduce the heavy cost of calculating the applicable issue in seismic geotechnical engineering. To fulfill the aim, a comprehensive study was carried out and various parameters were evaluated. According to the results, the artificial neural network could reach a good approximation of the seismic response of embankments and earth dams. Although comparing the results of artificial neural networks segmented from generic artificial neural network showed the accuracy of the estimated artificial neural network structured for each PGA level, especially in the linear region, the study was successful in eliminating the defects of previous research, making a perfect arrangement for a generic artificial neural network to be used for this type of neural network to achieve a favorable estimation of all PGA levels. Finally, it can be concluded that considering the complexities of the problem and the performance of the artificial neural networks in solving them, as well as the history of successful performance reports on this tool in other similar applications, the application of Artificial Neural Networks proved useful for estimating and predicting seismic responses of embankments and earth dams. Using artificial neural networks to meet this purpose would reduce the cost of calculating the seismic response assessment of embankments and earth dams. Therefore, applying this tool in the complicated field of seismic geotechnical engineering may be highly promising. Overall, future developments in this research field and promotions in artificial neural network training in other situations by changing the dimensions and properties of materials and load conditions would realize this idea and create a more general neural network for this application.

**Reference**

1. Tsoimpanakis, Y., Lagaros, N.D., and Stavroulakis, G.E. (2008) Soft computing techniques in parameter identification and probabilistic seismic analysis of structures. *Advances in Engineering Software*, **39**(7), 612–624.

**Keywords:** Embankment, Earth dams, Dynamic analysis, linear equivalent method, artificial neural network.