

## Prediction of Liquefaction Potential Using a Soft Computing Approach (CNN-MVO): A Case Study on Sandy Soils of Northern Iran

Shima Aghakasiri

Department of Civil Engineering, ST.C., Islamic Azad University, Tehran (Iran)

Ghodratollah Mohammadi \*

Department of Civil Engineering, ST.C., Islamic Azad University, Tehran (Iran)

Amir Taban

Department of Civil Engineering, KHA.C., Islamic Azad University, Khorramabad (Iran)

Mohammad Emami Kourandeh

Department of Civil Engineering, ST.C., Islamic Azad University, Tehran (Iran)

Gh\_mohammadi@azad.ac.ir

### Keywords:

Liquefaction,

Machine learning,

Soft computing,

MVO,

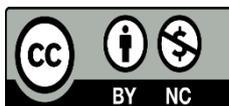
CNN

### Abstract

Liquefaction in sandy soils is one of the most critical geotechnical hazards during earthquakes, often resulting in severe structural and infrastructural damages. The present study aims to develop a soft computing model for predicting liquefaction potential using geotechnical data obtained from case studies in northern Iran. A dataset of 150 boreholes including Standard Penetration Test (SPT) results and key soil parameters such as soil type, groundwater level, fines content, SPT number, and depth was employed. The proposed approach integrates a Convolutional Neural Network (CNN) with the Multi-Verse Optimizer (MVO) algorithm, implemented in MATLAB. The results indicate a regression coefficient (R) of approximately 0.90 and a mean squared error (MSE) lower than 0.5. Comparison with conventional SPT-based empirical methods confirmed the superior accuracy of the CNN-MVO model in predicting liquefaction occurrence and associated settlements. Therefore, the proposed methodology provides a reliable tool for liquefaction hazard assessment and geotechnical decision-making in earthquake-prone regions.

This work is licensed under a [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/)

این نشریه تحت قانون بین‌المللی کپی‌رایت Creative Commons: BY-NC است.



\* Corresponding Author

## پیش‌بینی پتانسیل روانگرایی با رویکرد محاسبات نرم (CNN-MVO) مطالعه موردی خاک‌های ماسه‌ای شمال ایران

شیما آقاکثیری

گروه مهندسی عمران، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران  
قدرت الله محمدی\*

گروه مهندسی عمران، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران  
امیر تابان

گروه مهندسی عمران، واحد خرم‌آباد، دانشگاه آزاد اسلامی، خرم‌آباد، ایران.  
محمد امامی کورنده

گروه مهندسی عمران، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران  
Gh\_mohammadi@azad.ac.ir

تاریخ پذیرش: ۱۰ مهر ۱۴۰۴

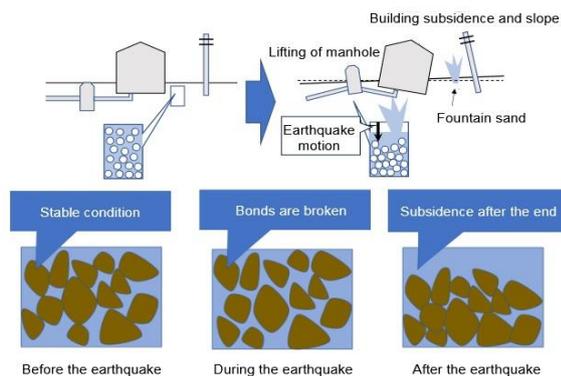
تاریخ دریافت: ۱۱ خرداد ۱۴۰۴

### چکیده

روانگرایی در خاک‌های ماسه‌ای یکی از مخاطرات مهم ژئوتکنیکی در هنگام زلزله است که می‌تواند منجر به خسارات جدی سازه‌ای و ژئوتکنیکی گردد. هدف این پژوهش، توسعه یک مدل محاسبات نرم برای پیش‌بینی پتانسیل روانگرایی با استفاده از داده‌های ژئوتکنیکی به‌دست‌آمده از پروژه‌های شمال ایران است. برای این منظور، مجموعه‌ای شامل ۱۵۰ گمانه صحرایی و داده‌های حاصل از آزمایش‌های SPT و پارامترهای ژئوتکنیکی شامل نوع خاک، سطح آب زیرزمینی، درصد ریزدانه، عدد نفوذ استاندارد و عمق مورد استفاده قرار گرفت. روش پیشنهادی ترکیبی از شبکه عصبی کانولوشن (CNN) و الگوریتم چندجهانی (MVO) بوده است که در محیط MATLAB پیاده‌سازی شد. نتایج نشان داد ضریب رگرسیون مدل توسعه‌یافته حدود ۰/۹ و شاخص خطای میانگین مربعات (MSE) کمتر از ۰/۵ است. مقایسه نتایج با روش تجربی مبتنی بر SPT نشان داد که مدل CNN-MVO دقت بالاتری در پیش‌بینی وقوع روانگرایی و نشست ناشی از آن دارد؛ بنابراین، روش ارائه‌شده می‌تواند به‌عنوان ابزاری کارآمد در ارزیابی خطر روانگرایی و تصمیم‌گیری‌های مهندسی ژئوتکنیک در مناطق مستعد زلزله مورد استفاده قرار گیرد.

**کلیدواژگان:** روانگرایی، یادگیری ماشین عمیق، محاسبات نرم، الگوریتم بهینه‌سازی (MVO)، شبکه عصبی CNN.

## ۱- مقدمه



شکل ۱- مکانیزم روانگرایی: ذرات خاک به دلیل افزایش فشار آب منافذ شناور می‌شوند [۷]

در تحلیل عددی، روانگرایی ناشی از زلزله را می‌توان به‌عنوان پدیده یک‌بعدی در نظر گرفت که در آن افزایش فشار منفذی به دلیل برش چرخه‌ای ناشی از زلزله و نیروهای فشاری در میدان آزاد ایجاد می‌شود و در نتیجه باعث کاهش پایداری خاک می‌شود. هنگامی که جریان آب برای از بین بردن فشار اضافی منفذی  $u$  استفاده می‌شود، به دلیل نشست‌های عمودی سطح زمین پس از روان شدن، منجر به انجماد مجدد خاک می‌شود. در شرایطی که روانگرایی ممکن است منجر به آسیب قابل توجهی شود، پیچیدگی تجزیه و تحلیل و به دست آوردن نمونه‌های باکیفیت بالا از خاک شنی سست می‌تواند استفاده از نمونه‌ها را محدود کند. روش تحلیلی، روش عددی، آزمایش میدانی و آزمایشگاه‌های روش‌های مختلفی هستند که برای محاسبه نشست‌های زمینی ناشی از روانگرایی، از جمله ترکیب این دو روش، استفاده می‌شوند. روش‌های نیمه تجربی مبتنی بر داده‌های آزمایش میدانی برای تخمین پتانسیل روانگرایی و نشست‌های ناشی از روانگرایی برای پیش‌بینی و ارائه تخمین‌های اولیه برای کلیه پروژه‌ها مناسب‌ترین هستند [۱۰]. روانگرایی خاک یکی از جنبه‌های فاجعه‌بار زلزله است که عمدتاً در اثر زلزله به دلیل سه عامل ایجاد می‌شود: رسوبات دانه‌ای سست، رسوب اشباع از آب و تکان قوی که ممکن است آسیب‌های قابل توجهی مانند گسترش جانبی و روانگرایی ایجاد کند که به نوبه خود ممکن است به سازه‌ها و زیرساخت‌ها آسیب برساند. روش‌های مبتنی بر آزمون‌ها، مانند آزمون سرعت موج برشی ( $V_s$ )، آزمون نفوذ استاندارد (SPT)، آزمون نفوذ مخروط (CPT) و آزمون نفوذ دینامیکی (DPT)، آزمون‌های معروف و پرکاربرد برای پیش‌بینی هستند که می‌توانند روانگرایی خاک را ارزیابی کنند. محققان، رویکردها و روش‌های مختلفی را برای پیش‌بینی و ارزیابی وقوع روانگرایی به کار برده‌اند، رویکردهای قطعی و احتمالی رویکردهای پرکاربرد با مزیت رویکردهای احتمالی هستند. رویکرد قطعی به‌طور کلی بر اساس ضریب ایمنی  $FS$  بیان می‌شود که به‌عنوان تقسیم نسبت مقاومت چرخه‌ای (CRR) بر نسبت تنش چرخه‌ای (CSR) تعریف می‌شود. اگر  $FS < 1$  باشد، خاک به‌عنوان روانگرا طبقه‌بندی می‌شود، در غیر این صورت اگر  $FS > 1$  باشد، عدم روانگرایی رخ داده است. به‌طور کلی، در مدل‌های قطعی، یک خط مرزی به‌عنوان خط جداکننده برای طبقه‌بندی خاک روانگرا از خاک غیر

در هنگام ساخت طرح لرزه‌ای روانگرایی عامل مهمی است که مورد توجه قرار می‌گیرد. شکست پی ساختمان به دلیل کاهش مقاومت خاک رخ می‌دهد. هنگامی که خاک اشباع می‌شود مقاومت خاک کاهش می‌یابد. در نتیجه جابجایی زمین می‌تواند آسیب جدی به پی و خاک وارد کند و یکپارچگی سازه ساختمان‌ها را به خطر بیندازد. چندین زمین‌لرزه بزرگ نمونه‌های تاریخی روانگرایی هستند که تخریب قابل توجهی را به بار آورده‌اند. ریزش ساختمان‌ها در نتیجه روانگرایی و جابجایی قابل توجه خاک توسط زلزله سال ۱۹۶۴ توکیو در ژاپن آغاز شد. به این ترتیب، اثرات مخرب فروریختن برسازه‌های شهری توسط زلزله چینی تانگشان در سال ۱۹۷۶ و زمین‌لرزه چی-چی تایوانی در سال ۱۹۹۹ آشکار شد. در پاسخ به این حوادث، مهندسان و دانشگامان مطالعات گسترده‌ای را برای درک و کاهش این پدیده انجام داده‌اند [۱]. زمین‌لرزه‌ها همیشه توجه مهندسان عمران و ژئوتکنیک را به خود جلب کرده است، به‌خصوص در مورد روانگرایی [۲]. روانگرایی به‌عنوان یک نوع شکست زمین در نظر گرفته می‌شود که معمولاً در هنگام لرزش شدید زمین در اثر زلزله رخ می‌دهد. اولین ویرانی گسترده ناشی از روان شدن گسترده خاک در سال ۱۹۶۴ در طول زمین‌لرزه نیگاتا در ژاپن و زلزله آلاسکا در ایالات متحده مشاهده شد [۳]. تشخیص روانگرایی زمین‌لرزه‌ای یک روش پیچیده و غیرخطی است که تحت تأثیر انواع مختلف قرار می‌گیرد [۴]. پدیده روانگرایی خاک در هنگام زمین‌لرزه اثرات بسیار منفی بر خطوط حیاتی، پل‌ها و ساختمان‌ها دارد [۵]. آسیب‌های ساختاری قابل توجهی که اغلب در اثر نشست یا کج شدن سازه‌ها ایجاد می‌شود، به دلیل روانگرایی خاک‌های شنی اشباع‌شده در طول زمین‌لرزه‌های بزرگ، مدت‌هاست که یک نگرانی عمده در زمینه ژئوتکنیک بوده است، همان‌طور که در شکل ۱ نشان داده شده است. این پدیده که می‌تواند عواقب جدی داشته باشد [۶، ۷]. بنابراین، برای تضمین ایمنی افراد و اموال، برآورد احتمال روان شدن خاک و اثرات آن ضروری است. همچنین، آزمون نفوذ مخروط (CPT) و آزمون نفوذ استاندارد (SPT) به‌طور گسترده در بسیاری از بررسی‌های ژئوتکنیکی و عمرانی استفاده شده است [۵].

روانگرایی یک رویداد بالقوه آسیب مهم پس از زلزله است؛ بنابراین برای کاهش این خسارات، پتانسیل روانگرایی خاک باید به‌درستی برآورد شود. روش‌های بسیاری برای تخمین روانگرایی بر اساس روابط ساده نیمه‌تجربی توسعه داده شده است [۸]. در بسیاری از نقاط جهان، در اثر روانگرایی خاک دانه‌ای در حالت اشباع و سست، خطر جدی در هنگام زلزله رخ می‌دهد. بر این اساس، تغییر شکل‌های زمین رخ می‌دهد که در هنگام زلزله آسیب شدیدی به خطوط حیاتی سازه‌های طراحی شده وارد می‌کند. رایج‌ترین نوع این خرابی‌ها، تغییر شکل، گسترش جانبی و نشست زمین است که در اثر روانگرایی ایجاد شده است. تحت روانگرایی، خاک دانه‌ای سست متراکم می‌شود و در نتیجه به دلیل تغییر شکل عمودی ناشی از روانگرایی، نشست‌های افقی لایه‌های سطحی خاک ایجاد می‌شود [۹].

واژگون شدن خانه‌های مسکونی و خرابی جاده‌ها شد. اثرات آسیب‌دیدگی روانگرایی و نشست ساختمان‌ها در بسیاری از زمین‌لرزه‌ها مشاهده شده است که شامل گسیختگی ظرفیت باربری ساختمان‌ها در زلزله ۱۹۶۴ نیگاتا، زلزله‌های ژاپن و بیشتر در زلزله ۲۰۱۲ مائول، چیل، ۲۰۱۱ تو هوکو ژاپن و ۲۰۱۱ کریس چرچ نیوزیلند بوده است. محققان در مورد پاسخ اثرات روانگرایی بر روی ساختمان‌های بلند، آزمایش‌های فیزیکی (میز لرزه) یا آزمایش‌های مدل‌های عددی و یا موارد دیگری را انجام داده‌اند [۳۱].

### ۲- مبانی نظری تحقیق

در سال‌های اخیر، روش‌های مختلف آزمایشگاهی و صحرایی برای ارزیابی مقاومت روانگرایی خاک‌ها ارائه شده است. از جمله روش‌های صحرایی می‌توان به استفاده از آزمون‌های مقاومت نفوذ استاندارد [۲۵]، مقاومت نفوذ مخروط [۲۶]، آزمایش‌های ژئوفیزیکی با اندازه‌گیری سرعت موج‌برشی [۲۷] اشاره کرد. جهت ارزیابی روانگرایی از سه دیدگاه کلی می‌توان بهره جست که این سه دیدگاه شامل استفاده از روش‌های عددی [۲۸]، مدل‌سازی آزمایشگاهی [۲۹] و آزمایش‌های در محل [۳۰] است. زمانی که زلزله بزرگ ژاپن در سال ۲۰۱۱ رخ داد، خسارات ناشی از روانگرایی تا ۵۰۰ کیلومتری از توهوگو مشاهده شد. این امر باعث جوشش ماسه، بیرون‌زدگی منهول، خرابی داکت‌ها و تأسیسات، واژگون شدن خانه‌های مسکونی و خرابی جاده‌ها شد. اثرات آسیب‌دیدگی روانگرایی و نشست ساختمان‌ها در بسیاری از زمین‌لرزه‌ها مشاهده شده است که شامل گسیختگی ظرفیت باربری ساختمان‌ها در زلزله ۱۹۶۴ نیگاتا، زلزله‌های ژاپن و بیشتر در زلزله ۲۰۱۲ مائول، چیل، ۲۰۱۱ تو هوکو ژاپن و ۲۰۱۱ کریس چرچ نیوزیلند بوده است. محققان در مورد پاسخ اثرات روانگرایی بر روی ساختمان‌های بلند، آزمایش‌های فیزیکی (میز لرزه) یا آزمایش‌های مدل‌های عددی و یا موارد دیگری را انجام داده‌اند [۳۱].

### ۳- روش تحقیق (متدولوژی)

روش تحقیق حاضر به منظور ارزیابی و پیش‌بینی پتانسیل روانگرایی در خاک‌های ماسه‌ای شمال ایران طراحی شده است. چارچوب کلی پژوهش شامل مراحل زیر است:

- جمع‌آوری داده‌ها:

داده‌ها از پروژه‌های ژئوتکنیکی انجام شده در استان‌های شمالی کشور (گیلان، مازندران و گلستان) گردآوری شدند.

پایگاه داده شامل ۱۵۰ گمانه حفاری شده همراه با نتایج آزمایش‌های SPT و سایر پارامترهای ژئوتکنیکی نوع خاک، سطح آب زیرزمینی، درصد ریزدانه، عدد SPT و عمق بود.

برای اطمینان از صحت داده‌ها، نتایج با گزارش‌های آزمایشگاهی معتبر شرکت‌های ژئوتکنیکی و مقالات علمی مقایسه شد.

روانگرا استفاده می‌شود [۱۱، ۱۲]. نور حکمت در سال ۲۰۱۸ و هونگ و کیم در سال ۲۰۱۹ به بررسی داده‌ها برای استفاده در فناوری یادگیری عمیق پرداختند و به این نتیجه رسیدند اگر داده‌های جمع‌آوری شده متنوع‌تر باشند، تصمیمات اتخاذ شده بهتر خواهد بود. شبکه‌های عصبی کانولوشنال (CNN) که داده‌های ورودی را در قالب تصاویر پردازش می‌کنند، یکی از تکنیک‌های رایج یادگیری عمیق هستند [۱۳، ۱۴]. پوروانتو و همکار در سال ۲۰۲۳، با استفاده از روش یادگیری عمیق (CNN) برای نقشه‌برداری از تغییرات کاربری زمین بر اساس سیستم اطلاعات جغرافیایی: مطالعه موردی روانگرایی را انجام دادند [۱۵]. فادهیلا و همکاران در سال ۲۰۲۵، به شناسایی پدیده روانگرایی زلزله پس از زلزله پوهانگ ۲۰۱۷، کره جنوبی، با استفاده از رویکرد یادگیری عمیق ترکیبی با استفاده از روش CNN انجام دادند [۱۶]. یوان و همکاران در سال ۲۰۲۵ به بررسی مدل رفتاری یک مدل ترکیبی SSA-CNN-SVM برای تشخیص روانگرایی ماسه ناشی از زلزله پرداختند، نتایج نشان می‌دهد که مدل SSA-CNN-SVM عملکرد برتر در تشخیص روانگرایی ماسه را نشان می‌دهد و به دقت ۸۳٫۳۳٪، دقت ۸۳٫۳۳٪، فراخوانی ۸۳٫۳۳٪ و امتیاز  $F1 = 83.33\%$  دست یافته است [۱۷]. طبقه‌بندی خاک و پیش‌بینی روانگرایی با استفاده از الگوریتم‌های یادگیری عمیق و یادگیری گروهی این مطالعه به بررسی استفاده از تکنیک‌های یادگیری ماشین برای پیش‌بینی‌های دقیق و قابل اعتماد روانگرایی در چهار دسته از انواع خاک MI-ML-SM-SP، CH-CL و CL-MH-SC می‌پردازد، الگوریتم‌های یادگیری عمیق و یادگیری گروهی، یعنی حافظه کوتاه‌مدت بلند (LSTM)، شبکه عصبی کانولوشن (CNN)، تقویت گرادیان شدید (XGB) و CatBoost (CatB)، برای دستیابی به این هدف گنجانده شدند [۱۸]. علاوه بر این، بر اساس توزیع زمین‌شناسی نشان داده شده است که این منطقه دارای ترکیب آبرفتی کواترنری زیادی است، که نوعی خاک کاملاً مستعد روانگرایی است [۱۹]. همچنین در طی سال‌های اخیر، بسیاری از محققین به ارزیابی روانگرایی با استفاده از شبکه عصبی کانولوشن CNN پرداختند [۱۸، ۲۰-۲۴].

### ۲- مبانی نظری تحقیق

در سال‌های اخیر، روش‌های مختلف آزمایشگاهی و صحرایی برای ارزیابی مقاومت روانگرایی خاک‌ها ارائه شده است. از جمله روش‌های صحرایی می‌توان به استفاده از آزمون‌های مقاومت نفوذ استاندارد [۲۵]، مقاومت نفوذ مخروط [۲۶]، آزمایش‌های ژئوفیزیکی با اندازه‌گیری سرعت موج‌برشی [۲۷] اشاره کرد. جهت ارزیابی روانگرایی از سه دیدگاه کلی می‌توان بهره جست که این سه دیدگاه شامل استفاده از روش‌های عددی [۲۸]، مدل‌سازی آزمایشگاهی [۲۹] و آزمایش‌های در محل [۳۰] است. زمانی که زلزله بزرگ ژاپن در سال ۲۰۱۱ رخ داد، خسارات ناشی از روانگرایی تا ۵۰۰ کیلومتری از توهوگو مشاهده شد. این امر باعث جوشش ماسه، بیرون‌زدگی منهول، خرابی داکت‌ها و تأسیسات،

- پیش‌پردازش داده‌ها:

داده‌های خام پالایش و داده‌های پرت (Outliers) حذف شدند. متغیرهای کیفی مانند نوع خاک به صورت کدگذاری عددی (از GP=1 تا SC=12) وارد مدل شدند.

مجموعه داده‌ها به صورت تصادفی به سه بخش تقسیم گردید: ۷۰٪ آموزش، ۱۵٪ اعتبارسنجی، ۱۵٪ آزمون.

- مدل‌سازی با روش محاسبات نرم (CNN-MVO):

شبکه عصبی کانولوشن (CNN): برای استخراج ویژگی‌ها و یادگیری الگوهای غیرخطی بین متغیرهای ورودی و خروجی به کار گرفته شد. الگوریتم چندجهانی (MVO): جهت بهینه‌سازی وزن‌ها و پارامترهای شبکه استفاده شد تا از گیرافتادن مدل در کمینه‌های محلی جلوگیری گردد.

مدل در نرم‌افزار (MATLAB 2018b) پیاده‌سازی شد.

- اعتبارسنجی مدل:

عملکرد مدل با استفاده از شاخص‌های آماری شامل ضریب رگرسیون (R) و میانگین مربعات خطا (MSE) ارزیابی شد.

علاوه بر این، نتایج مدل با روش تجربی مبتنی بر SPT (سید و ادريس ۱۹۸۳) مقایسه شد تا قابلیت اعتماد آن بررسی گردد.

- شرایط ژئوتکنیکی و لرزه‌ای مورد مطالعه:

خاک منطقه مورد بررسی عمدتاً از نوع ماسه‌های ریزدانه اشباع با درصد‌های مختلف ریزدانه بوده است.

بر اساس رده‌بندی خاک، خاک‌ها در رده دانه‌ای سست تا متراکم متوسط قرار می‌گیرند.

سطح آب زیرزمینی در محدوده ۲ تا ۸ متر از سطح زمین متغیر بوده است.

شرایط لرزه‌ای منطقه بر اساس مطالعات لرزه‌خیزی، با شتاب مینای طراحی  $a_{max}=0.3g$  و بزرگای زلزله  $M_w=7$  در نظر گرفته شد.

شرایط مرزی و زهکشی خاک در تحلیل‌ها به صورت اشباع کامل و زهکشی محدود فرض شد که متناظر با شرایط واقعی زمین‌لرزه در رسوبات ساحلی شمال ایران است.

- پیاده‌سازی روش یادگیری عمیق بر روی بانک اطلاعاتی

جمع‌آوری شده

در ادامه هر کدام از مراحل روش تحقیق حاضر به تشریح ارائه می‌گردد.

### ۳-۱- نوع خاک و ضریب زلزله

خاک مورد مطالعه باتوجه به اطلاعات به دست آمده در رده IV قرار دارد و بر همین اساس و باتوجه به میانگین عدد نفوذ استاندارد به دست آمده که ۱۲ است خاک در رده بندی ریزدانه سفت و درشت‌دانه تراکم متوسط قرار دارد. همچنین شتاب مینای زلزله بر روی سطح زمین یا آبرفت،  $a_{max}=0.3g$  در نظر گرفته شده است. عوامل زمین‌شناسی متعددی در میزان آب‌گونه شدن خاک دارند که مهم‌ترین آن‌ها عبارت‌اند از: فرآیند رسوب‌گذاری، سن رسوب، تاریخچه زمین‌شناسی، عمق سطح ایستایی، دانه‌بندی، عمق مدفون شدن، شیب دامنه و نزدیکی به یک سطح آزاد. بدیهی است با افزایش سن رسوب استعداد آب‌گونه شدن کاهش می‌یابد.

علت این امر پیش تحکیمی خاک بر اثر وزن رسوب یا زمین‌لرزه‌های قدیمی است. بیشترین استعداد آب‌گونه‌گی در نواحی ساحلی حاوی آبرفت‌های ماسه‌ای ریزدانه و اشباع‌شده که از تراکم و میزان رس کمی برخوردارند، دیده می‌شود.

### ۳-۲- محاسبه خطر روانگرایی

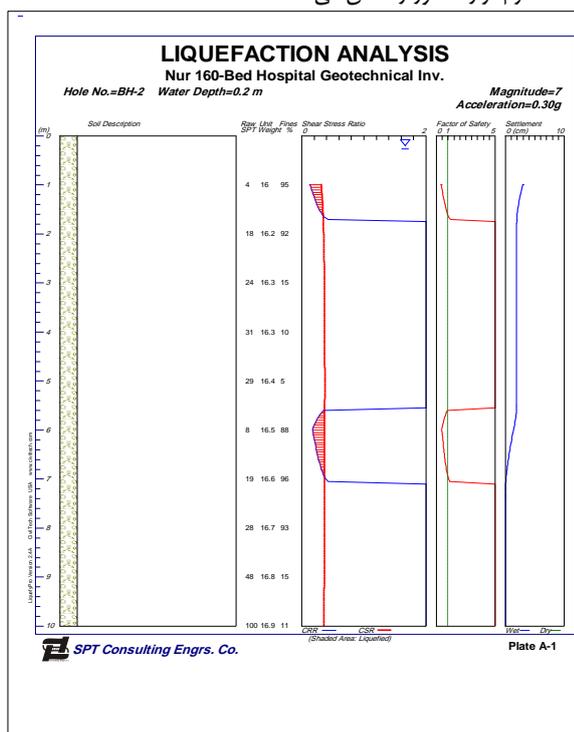
یکی از علل مهم خرابی‌ها در خلال زلزله‌ها گسیخته شدن زمین است. گسیختگی زمین ممکن است به واسطه وجود ترک‌ها و شکاف‌ها، حرکات غیرطبیعی و یا نامساوی و یا ازدست‌دادن مقاومت آن به وقوع پیوندد. ازدست‌دادن مقاومت زمین ممکن است در زمین‌های ماسه‌ای اشباع با تراکم پایین به علت افزایش فشار آب حفره‌ای اتفاق افتد که این پدیده را سیلان یا روانگرایی خاک می‌نامند. افزایش فشار حفره‌ای به کم شدن یا حتی از بین رفتن کامل مقاومت برشی خاک می‌انجامد. خاک‌هایی که مقاومت برشی خود را به طور کامل از دست می‌دهند؛ مانند یک مایع غلیظ عمل کرده و در خلال زلزله به صورت سیلان و جوشش ماسه ظاهر می‌شوند. باتوجه به وجود لایه‌های ماسه‌ای و سیلنی اشباع با ضخامت قابل توجه در اعماق مختلف و همچنین اعداد SPT، امکان بروز پدیده روانگرایی مورد بررسی قرار گرفته است.

شاخص پتانسیل روانگرایی (LPI) به عنوان یک معیار کمی برای ارزیابی احتمال و شدت روانگرایی خاک در یک منطقه خاص ایجاد شده است [۳۳]. برای ارائه یک ارزیابی کامل از خطر روانگرایی، LPI متغیرهای مختلفی مانند ویژگی‌های لرزه‌ای، شرایط آب زیرزمینی و کیفیت خاک را در برمی‌گیرد. برای کاهش خسارات در هنگام رخدادهای لرزه‌ای، این شاخص به برنامه ریزان و مهندسان کمک می‌کند تا مکان‌های مستعد زلزله را شناسایی کرده و اقدامات مناسب کاهشی را انجام دهند. همبستگی‌های تجربی اولیه مورد استفاده در ارزیابی پتانسیل روانگرایی در گذشته از مشاهدات میدانی و مطالعات موردی بود. این تکنیک‌ها بر روی لایه‌های خاص خاک و حساسیت روانگرایی آن‌ها متمرکز بودند، اما آن‌ها اغلب اثرات ترکیبی بسیاری از لایه‌ها و شرایط کلی سایت را نادیده می‌گرفتند [۳۳]. برای تحلیل روانگرایی روش‌های مختلفی وجود دارد که یکی از مهم‌ترین آن‌ها، روش سید و همکاران (۱۹۸۳) است که بر اساس نتایج آزمایش SPT روانگرایی خاک را هنگام وقوع زلزله بررسی می‌کند. در این روش برای محاسبه تنش برشی تناوبی، پارامتر نسبت تنش تناوبی (CSR) Cyclic Stress Ratio با استفاده از تحلیل پاسخ لایه‌های خاک تحت ارتعاش زلزله و یا به وسیله روش ساده ارائه شده توسط سید و ادريس (۱۹۸۳) از رابطه زیر محاسبه می‌گردد [۳۴]:

$$CSR = (\tau_{av}/\sigma'_0) = 0.65 \left(\frac{a_{max}}{g}\right) \left(\frac{\sigma_v}{\sigma'_0}\right) r_d \quad (1)$$

که در آن  $a_{max}$  شتاب افقی حداکثر ناشی از زلزله در سطح زمین،  $g$  شتاب ثقل، تنش کل عمودی،  $\sigma_v$  تنش مؤثر عمودی و  $r_d$  ضریب کاهش تنش بر حسب عمق (Z) است که در سطح زمین مقدار آن برابر با یک بوده و با افزایش عمق کاهش می‌یابد. تغییرات ضریب  $r_d$  نسبت به عمق در شکل (۲) نشان داده شده است.

که خاک آن‌ها دارای شرایط روانگرایی بوده تحلیل شده و نتایج حاصله تحلیل و بررسی شده است. تحلیل‌ها با فرض وقوع زلزله‌هایی با شتاب و بزرگی  $M_w=7$ ,  $a_{max}=0.3g$  بر اساس شرایط لرزه‌خیزی استان‌های شمالی انجام شده است. شکل (۴) نمونه محاسبات و شبیه‌سازی‌ها به کمک نرم‌افزار مذکور را نشان می‌دهد.

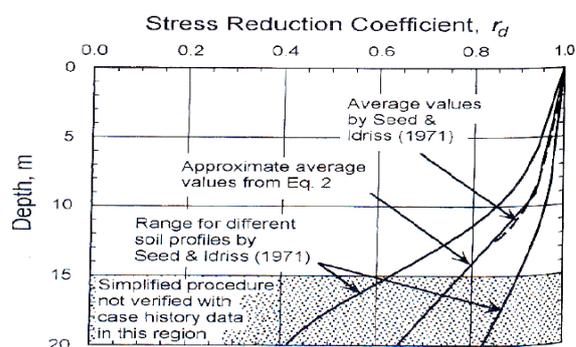


شکل ۴- نمونه‌ای از نتایج نرم‌افزار LiquefyPro در پیش‌بینی پتانسیل روانگرایی

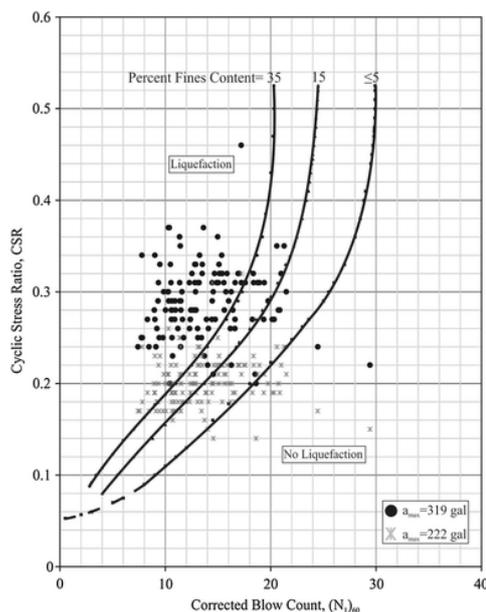
محاسبات و مدل‌سازی مذکور در این بخش برای بیش از ۱۵۰ گمانه حفاری شده در پروژه‌های مطالعات ژئوتکنیک واقع در استان‌های شمالی کشور انجام شده است تا در تکمیل بانک اطلاعاتی تحقیق حاضر مورد استفاده قرار بگیرد.

مهم‌ترین پارامترهای تأثیرگذار در خطر روانگرایی همان‌طور که در بخش دوم ذکر شد، شامل: ۱- جنس خاک، ۲- تراکم خاک، ۳- سطح آب زیرزمینی، ۴- درصد ریزدانه و ۵- شرایط لرزه‌خیزی محدوده طرح است. بر همین اساس مطالعات ژئوتکنیک انجام شده ارزیابی شده و پارامترهای مهم آن‌ها استخراج شده‌اند. شکل (۵) پوش دانه‌بندی یکی از پروژه‌های مورد بررسی را نشان داده و شکل (۶) نتایج آزمایش نفوذ استاندارد (SPT) را در این پروژه نشان می‌دهد. چنین بررسی و ارزیابی برای بیش از ۵۰ پروژه در محدوده مورد نظر تحقیق انجام شده است.

مقاومت برشی تناوبی یا به عبارت دیگر تنش برشی لازم جهت افزایش فشار آب حفره‌ای و صفرشدن تنش مؤثر را می‌توان با استفاده از آزمایش‌های صحرایی نظیر آزمایش نفوذ استاندارد SPT محاسبه نمود. روابط متعددی برای محاسبه نسبت مقاومت برشی تناوبی (CRR) Cyclic Resistance Ratio با استفاده از عدد SPT اصلاح شده، درصد ریزدانه و بعضاً خواص خمیری خاک ارائه شده است. سید و همکاران (۱۹۸۳) نمودار نشان داده شده در شکل (۳) را جهت محاسبه نسبت مقاومت برشی تناوبی  $(\tau_{av} / \sigma'_0)$  ارائه نمودند [۳۴].



شکل ۳- ضریب  $r_d$  در روش سید و همکاران [۳۴]



شکل ۳- نمودار محاسبه نسبت مقاومت برشی تناوبی برحسب عدد SPT (سید و همکاران (۱۹۸۳) [۳۴])

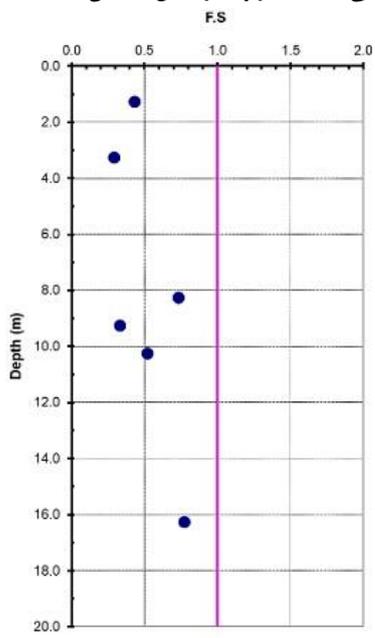
ضریب اطمینان در مقابل روانگرایی به صورت حاصل تقسیم نسبت مقاومت برشی تناوبی بر نسبت تنش برشی تناوبی تعریف می‌شود و در صورتی که ضریب اطمینان کمتر از یک باشد پدیده روانگرایی اتفاق خواهد افتاد. تحلیل روانگرایی به روش مذکور با استفاده از نرم‌افزار LiquefyPro (ویرایش 4.5D شرکت CivilTech) بر روی گمانه‌هایی

$$S_{BI} = \left[ 1 + \left( \frac{\ln PI}{1.938} \right)^{6.676} \right]^{-2.0} \quad (2)$$

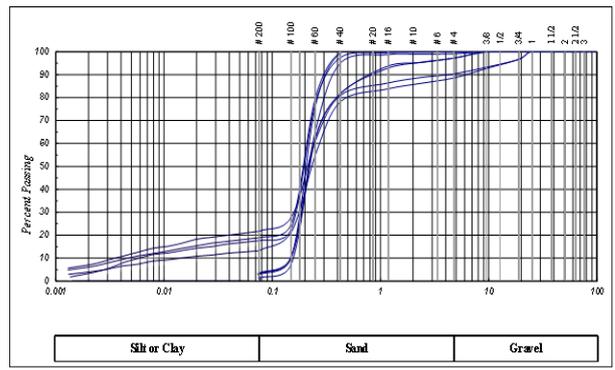
$$S_{BS} = \left[ 1 + \left( \frac{\ln PI}{2.778} \right)^{33.077} \right]^{-2.0} \left[ 1 + \left( \frac{4.401}{\ln(W_c/LL)} \right)^{360.471} \right]^{-2.0} \quad (3)$$

چنانچه متوسط این دو شاخص کوچک‌تر از ۰/۵ باشد، لایه مقاوم در برابر روانگرایی است و اگر این شاخص بیشتر از ۰/۵ باشد، لایه دارای استعداد روان گونگی است. برای خاک‌های ریزدانه دارای استعداد روانگرایی می‌توان از معیارهای یادشده برای خاک‌های ماسه‌ای بهره گرفت.

محاسبات مربوط به تعیین شاخص استعداد روانگرایی در جدول ۱ ارائه شده است. همچنین ضرایب اطمینان در برابر روانگرایی در جدول ۲ ارائه شده است. ضرایب اطمینان متوسط در برابر روانگرایی در اعماق مستعد روانگرایی با استفاده از روش‌های بولانگر و ادریس (۲۰۰۵) [۳۵] و مرکز بین‌المللی تحقیقات زلزله در شکل ۷ نشان داده شده است.

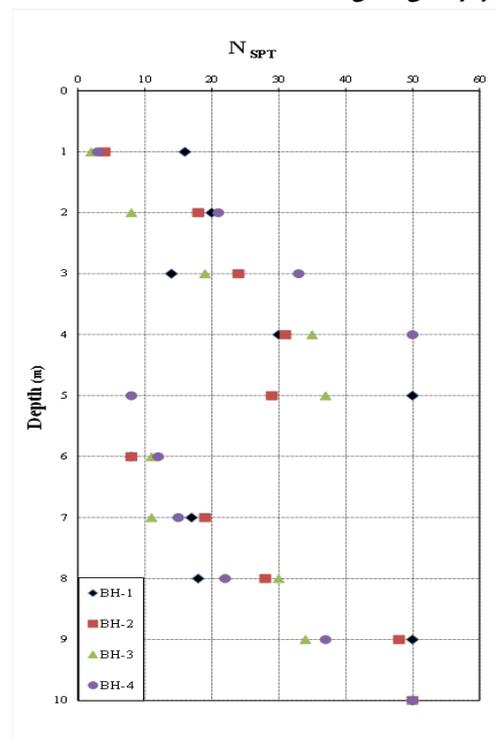


شکل ۷- ضرایب اطمینان متوسط در برابر روانگرایی در اعماق مستعد روانگرایی با استفاده از روش‌های بولانگر و ادریس [۹] و مرکز بین‌المللی تحقیقات زلزله



شکل ۵- پوش منحنی دانه‌بندی خاک‌های ماسه‌ای

بانک اطلاعاتی تحقیق حاضر نیز بر اساس پارامترهای مهم در محاسبات پتانسیل روانگرایی تکمیل شده است. پارامترهای ورودی و خروجی نیز بر همین اساس انتخاب شده‌اند.



شکل ۶- نتایج آزمون‌های SPT در یکی از پروژه‌ها

جهت بررسی استعداد روانگرایی خاک‌های ریزدانه از معیارهای بولانگر و ادریس (۲۰۰۵) [۳۵] و بری و سانکیو (۲۰۰۶) [۳۶] استفاده شده است. این معیارها بر اساس خواص خمیری خاک و نسبت درصد رطوبت خاک به حد روانی آن، شاخص استعداد روانگرایی را تعیین می‌کنند. هر چه این ضریب به ۰/۱۰ نزدیک باشد خاک ریزدانه رفتار ماسه‌ای و هر چه به ۰/۱۰ نزدیک باشد، خاک دارای رفتار رسی است. این معیارها در ذیل ارائه شده است:

جدول ۱- شاخص استعداد روانگرایی در سایت مورد مطالعه گمانه BH1

دوره ۲۲، شماره ۳، پاییز ۱۴۰۴

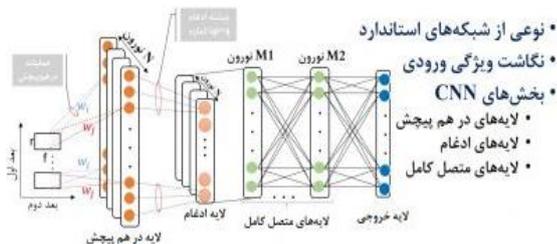
عمق (متر)	نوع خاک	FC	PI	Wc/LL	بولانگر و ادريس (۲۰۰۵)	بری و سانکیو (۲۰۰۶)	شاخص استعداد روانگرایی	پتانسیل روانگرایی
1.25	CL-ML	86.6	5	1.1	0.62	0.84	0.73	بله
2.25	CL	79.5	8	1.1	0.14	0.81	0.48	خیر
3.25	CL-ML	88.4	6	1.33	0.4	0.93	0.66	بله
4.25	CL	99.4	22	0.85	0	0.06	0.03	خیر
5.25	CL	99.1	18	0.72	0	0.08	0.04	خیر
6.25	CL	97	30	0.61	0	0	0	خیر
7.25	CL	94.5	24	0.58	0	0	0	خیر
8.25	ML	50.8	N.P.	N.P.	1	1	1	بله
9.25	SW	4.3	N.P.	N.P.	1	1	1	بله
10.25	SM	19.4	N.P.	N.P.	1	1	1	بله
12.25	CL	92.5	10	1	0.05	0.67	0.36	خیر
14.25	CL	70.8	12	0.85	0.02	0.42	0.22	خیر
16.25	CL-ML	53	6	1.11	0.4	0.84	0.62	بله
18.25	CL	99.2	20	0.68	0	0.04	0.02	خیر
20.25	SM	39	N.P.	N.P.	1	1	1	بله

جدول ۲- ضرایب اطمینان در برابر روانگرایی با استفاده از روش‌های بولانگر و ادريس (۲۰۰۴) و مرکز بین‌المللی تحقیقات زلزله گمانه BH1

عمق (متر)	مرکز بین‌المللی تحقیقات زلزله				بولانگر و ادريس (۲۰۰۴)				FS(AV)
	N1(60)	CSR	CRR	FS	N1(60)	CSR	CRR	FS	
1.25	9.92	0.379	0.18	0.47	9.92	0.413	0.16	0.39	0.43
3.25	3.97	0.375	0.111	0.3	3.97	0.411	0.115	0.28	0.29
8.25	16.05	0.329	0.278	0.84	16.05	0.366	0.226	0.62	0.73
9.25	9.62	0.319	0.11	0.34	9.62	0.358	0.116	0.33	0.33
10.25	11.72	0.308	0.171	0.56	11.72	0.35	0.166	0.48	0.52
16.25	13.47	0.238	0.218	0.92	13.47	0.306	0.189	0.62	0.77
20.25	8.27	0.204	0.145	0.71	8.27	0.279	0.137	0.5	0.61

## ۳-۳- یادگیری عمیق

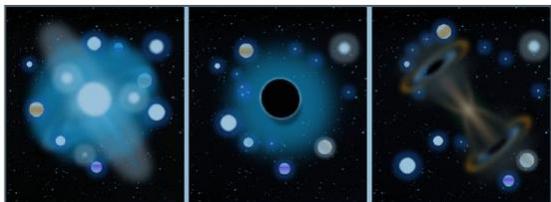
شامل یک لایه است که حاصل ضرب نقطه‌ای هسته کانولوشن را با ماتریس ورودی لایه انجام می‌دهد. در الگوریتم ConvNet در مقایسه با دیگر الگوریتم‌های دسته‌بندی به «پیش‌پردازش» (Pre Processing) کمتری نیاز است. درحالی‌که فیلترهای روش‌های اولیه به صورت دستی مهندسی شده‌اند، شبکه عصبی پیچشی (ConvNets)، با آموزش دیدن به اندازه کافی، توانایی فراگیری این فیلترها/مشخصات را کسب می‌کند. معماری ConvNet مشابه با الگوی اتصال «نورون‌ها» (Neurons) در مغز انسان است و از سازمان دهی «قشر بصری» (Visual Cortex) در مغز الهام گرفته شده است. هر نورون به محرک‌ها تنها در منطقه محدودی از میدان بصری که تحت عنوان «میدان تأثیر» (Receptive Field) شناخته شده است پاسخ می‌دهد. یک مجموعه از این میدان‌ها برای پوشش دادن کل ناحیه بصری با یکدیگر هم‌پوشانی دارند.



شکل ۸- شبکه عصبی CNN و نحوه عملکرد آن [۲۱]

## ۳-۲- الگوریتم چند متغیره (MVO)

الگوریتم MVO یک الگوریتم متاهوریستیک و مبتنی بر جمعیت است. یک الگوریتم مبتنی بر جمعیت روند جستجو را به دو مرحله مهم تقسیم می‌کند: مرحله اکتشاف (exploration) و مرحله بهره‌برداری (exploitation). در این الگوریتم از مفاهیم سفید چاله و سیاه‌چاله برای کشف فضاهای جستجو و از مفهوم کرم‌چاله در بهره‌برداری از فضاهای جستجو استفاده می‌شود. فرض می‌شود که هر راه‌حل با یک جهان نشان داده شود و هر متغیر در هر جهان یک شیء در آن است. علاوه بر این، به هر راه‌حل یا جواب یک نرخ تورم اختصاص می‌یابد که متناسب با مقدار عملکرد تابع تناسب مربوط به راه‌حل است. همچنین در این الگوریتم از اصطلاح زمان به جای تکرار استفاده شده، زیرا این یک اصطلاح رایج در نظریه و کیهان‌شناسی چند نظمی است [۴۰].



شکل ۹- شماتیک عملکرد الگوریتم (MVO) [۴۰]

## ۳-۳- مطالعات ژئوتکنیک

بانک اطلاعاتی در دقت روش‌های محاسبات نرم بسیار تأثیرگذار هستند. روش‌های مذکور هم از لحاظ تعداد داده‌ها و هم از لحاظ دقت داده بسیار به بانک اطلاعاتی وابسته است. در این تحقیق نیز بانک اطلاعاتی از

یادگیری ماشین، شاخه‌ای از هوش مصنوعی، بر ایجاد الگوریتم‌ها و مدل‌هایی تأکید دارد که رایانه‌ها را قادر می‌سازد تا وظایف را به طور مستقل و بدون نیاز به کارهای خاص انجام دهند. برنامه‌نویسی برای هر کار اساساً یک ماشین از داده‌ها می‌آموزد که الگوها را بیابد و بدون دخالت انسان پیش‌بینی یا تصمیم بگیرد. این الگوریتم‌های یادگیری ماشین پتانسیل بسیار زیادی در حل مسائل پیچیده در حوزه‌های مختلف نشان داده‌اند [۳۷]. الگوریتم‌های یادگیری ماشین اخیراً به دلیل کارآمد بودن آن‌ها به عنوان ابزاری برای پیش‌بینی نتایج و تجزیه و تحلیل داده‌های پیچیده در طیف وسیعی از صنایع، از جمله ساخت‌وساز ژئوتکنیک، توجه زیادی را به خود جلب کرده‌اند. با استفاده از مجموعه داده‌های مقیاس بزرگ و رمزگشایی روابط پیچیده بین خواص خاک و فعالیت لرزه‌ای، الگوریتم‌های یادگیری ماشین راهی مناسب برای بهبود درک و پیش‌بینی ما از خواص دینامیکی و ظرفیت روانگرایی خاک ارائه می‌کنند. یک روش مؤثر برای کسب دانش در مورد خواص خاک زیرسطحی، آزمون SPT است. انجام چندین اندازه‌گیری SPT در اعماق مختلف امکان شناسایی لایه‌بندی خاک، تغییرات در خواص خاک و تغییرات آسیب‌پذیری روانگرایی در پروفایل خاک را فراهم می‌کند. این اطلاعات توصیف سایت را آسان‌تر می‌کند و به مهندسان امکان می‌دهد تا احتمال توزیع جغرافیایی روانگرایی را ارزیابی کرده و برنامه‌های کاهش را در صورت نیاز اصلاح کنند [۳۸]. پس از آموزش، بسیاری از مدل‌های ML می‌توانند در طول زمان با یادگیری از داده‌های جدید سازگار شوند و به آن‌ها اجازه می‌دهد در محیط‌های در حال تغییر مرتبط بمانند. الگوریتم‌های ML به گونه‌ای طراحی شده‌اند که دید وسیعی از داده‌های آموزشی به سناریوهای غیرقابل مشاهده داشته باشند، به این معنی که می‌توانند موقعیت‌های مختلفی را که در مجموعه آموزشی اولیه وجود ندارد، مدیریت کنند [۳۷].

## ۳-۲-۱ شبکه عصبی مصنوعی CNN

شبکه عصبی CNN نوعی جدیدی از شبکه‌های عصبی هستند که در دهه‌های اخیر معرفی شده‌اند. این شبکه‌ها نوع تخصصی از شبکه‌های عصبی مصنوعی هستند که از یک عملیات ریاضی به نام کانولوشن به جای ضرب ماتریس عمومی حداقل در یکی از لایه‌های خود استفاده می‌کنند. یک شبکه عصبی CNN از یک لایه ورودی، لایه‌های پنهان و یک لایه خروجی تشکیل شده است [۲۱].

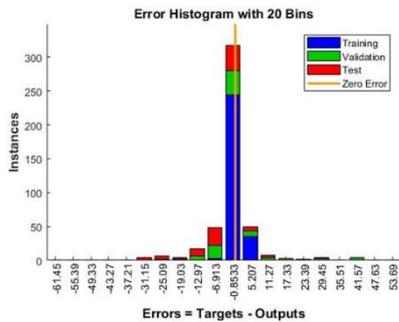
واریانس نوع داده‌ها و توسعه مقدار داده، محققان را بر آن داشته تا بر محدودیت‌های رویکرد مرسوم غلبه کنند، سپس شبکه عصبی کانولوشنال (CNN) را پیشنهاد کنند. لایه کانولوشن شامل چندین فیلتر و لایه از لایه‌های کانولوشن، لایه‌های ادغام و لایه‌های کاملاً متصل است که داده‌های ورودی را به قطعات ابعادی کوچک‌تر با جمع‌آوری اطلاعات هم‌زمان با استخراج ویژگی تقسیم می‌کند [۳۹].

در هر شبکه عصبی پیش‌خور، هر لایه میانی پنهان نامیده می‌شود، زیرا ورودی و خروجی آن‌ها توسط تابع فعال‌سازی و تابع ویژگی نهایی پوشانده می‌شود. در یک شبکه عصبی کانولوشن، لایه‌های پنهان شامل لایه‌هایی هستند که عملیات ریاضی مورد نظر را انجام می‌دهند. معمولاً

#### ۴- پیاده‌سازی روش یادگیری عمیق

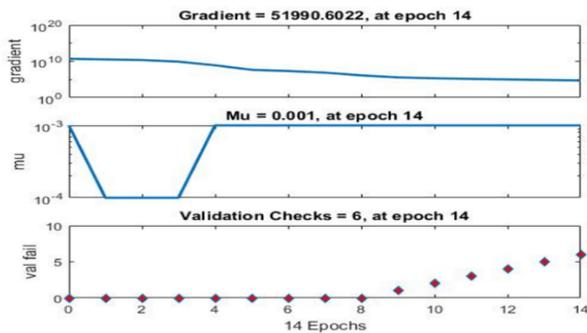
برای پیاده‌سازی کدنویسی مورد استفاده، آموزش و ارزیابی آن‌ها از نرم‌افزار MATLAB 9.5 (20018b) استفاده شده است. این نرم‌افزار باتوجه به توابع متعدد، قابلیت برنامه‌نویسی، الگوریتم‌های آموزشی و ساختارهای متعدد برای شبکه‌های عصبی و قدرت پردازش و تحلیل‌های آماری در حل مسائل مهندسی بسیار مورد توجه محققین بوده است. کدنویسی انجام شده در نرم‌افزار متلب قابل ارائه بوده و مطابق شرایط مقاله در این قسمت ارائه نشده است [۴۱].

در این بخش جهت ارزیابی کارایی روش یادگیری عمیق از دو شاخص ارزیابی استفاده شده است. ضریب رگرسیون (R) و شاخص خطا (MSE) که در شکل‌های ادامه ارائه شده‌اند. در شکل (۱۰) منحنی آموزشی برای کد نویسی انجام شده، نشان داده شده است. پس از پایان آموزش مقادیر وزن‌ها ذخیره شده و شبکه مورد نظر آماده است. همچنین نمونه‌ای از داده‌های بانک اطلاعاتی روش یادگیری عمیق در جدول ۳ آمده است.



شکل ۱۰- دیاگرام آموزش یادگیری عمیق (خروجی ۱)

همچنین نمودار هیستوگرام خطا و شکل رگرسیون داده‌های در فرایندهای آموزش، آزمایش و اعتبارسنجی در شکل‌های (۱۱) و (۱۲) نشان داده شده است.



شکل ۱۱- دیاگرام آموزش یادگیری عمیق (خروجی ۲)

مطالعات ژئوتکنیک انجام شده در پروژه‌های شمالی کشور تکمیل شده است. لازم به ذکر است تمامی داده‌های مورد استفاده از داده‌های آزمایشگاهی به دست آمده از شرکت‌های ژئوتکنیکی واقع در شمال کشور است. همچنین برای صحت سنجی کار از داده‌های مقالات علمی نیز استفاده گردیده است.

#### ۳-۳-۱ مجموع داده‌های ژئوتکنیکی

علاوه بر داده‌های موجود از آزمایش‌های ژئوتکنیکی که در ابتدا قبل توضیح داده شد، طیف گسترده‌ای از داده‌ها از منابع معتبر، از جمله مقالات معتبری جمع‌آوری شد. پایگاه داده، متشکل از ۱۵۰ نمونه، بر اساس پارامترهای کلیدی ژئوتکنیکی مانند محدوده SPT، عمق گمانه، سطح آب زیرزمینی و موارد دیگر ساختاریافته است. برای تسهیل توسعه مدل، پایگاه داده به چندین مجموعه داده تقسیم شد:

۱- یک زیرمجموعه برای آموزش مدل اختصاص داده شد.

۲- زیرمجموعه دیگری برای اهداف اعتبارسنجی استفاده شد.

تقسیم داده‌ها به این مجموعه‌ها به صورت تصادفی انجام شده تا عدالت رعایت شود و از سوگیری در فرایند یادگیری مدل جلوگیری شود.

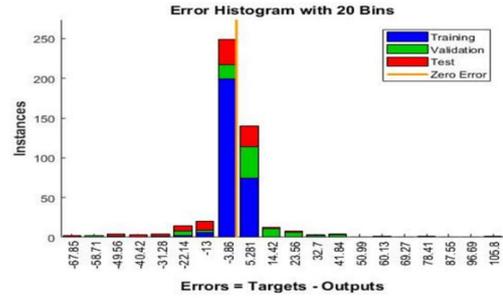
#### ۳-۴- روش یادگیری عمیق

مدل‌سازی و پیاده‌سازی روش یادگیری عمیق دارای چند مرحله است که پس از پیش‌پردازش داده‌ها و ارزیابی نتایج مطالعات ژئوتکنیک انجام می‌گردد. روش کاربرد مدل یادگیری عمیق بسیار به تعداد داده‌های موجود و دقت داده‌های مورد استفاده بستگی دارد. برای این منظور ابتدا بانک اطلاعاتی و پارامترهای ورودی و خروجی تعیین شده‌اند. همان‌طور که قبلاً ذکر شده در انتخاب پارامترهای ورودی سعی شده است تا پارامترهایی انتخاب گردند که از معمول‌ترین آزمون‌های مطالعات ژئوتکنیک حاصل شوند. باتوجه به حدود ۱۰۰ داده موجود در محدوده استان‌های شمالی کشور که از نتایج مطالعات ژئوتکنیک و همچنین تحلیل و ارزیابی محاسبات پتانسیل روانگرایی حاصل شده‌اند، پارامترهای ورودی و خروجی مطابق جدول (۱) انتخاب شده‌اند. مطابق جدول مذکور پارامترهای ورودی شامل: جنس خاک (Soil Type (SP))، سطح آب زیرزمینی (GWL)، درصد ریزدانه رسی (Fine Percent (FP))، عدد آزمایش نفوذ استاندارد ( $N_{spt}$ )، عمق خاک روانگرا (D) در نظر گرفته شده‌اند. همچنین دو پارامتر خروجی بر اساس اهمیت خطر روانگرایی شامل: پتانسیل روانگرایی (Liquefaction Potential (LP)) و نشست تخمینی (Settlement (SD)) مشخص شده است. پس از جمع‌آوری داده‌ها در پیش‌بینی خطر روانگرایی، داده‌ها در نرم‌افزار اکسل پردازش شده و مراحل پردازش آن‌ها جهت ارائه به کد یادگیری عمیق به دقت انجام شده است. در زمینه پارامترهای ورودی مانند جنس خاک برای قابل بررسی بودن توسط روش یادگیری عمیق کدگذاری انجام شده است و از خاک سنی بد دانه‌بندی شده ( $GP=1$ ) تا ماسه رس دار ( $S_c=12$ ) نوع خاک از کد ۱ تا ۱۲ به مدل معرفی شده است.

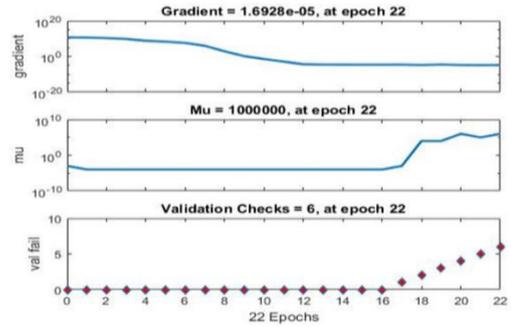
جدول ۳- نمونه‌ای از داده‌های بانک اطلاعاتی روش یادگیری عمیق

Output Parameter	Input Parameters					
	SD (mm)	LP	SP	GWL (m)	FP (%)	Nspt
41	1.20	5	8	18	6	5
18	1.11	3	5	13	7	4
21	1.23	5	3	25	5	8
12	1.08	5	10	26	9	10
11	1.03	4	2	21	12	6
26	1.25	6	2.5	18	11	7
23	1.13	6	4	15	16	4
13	0.98	7	3.6	17	25	11
16	0.95	4	3.2	15	33	12
14	0.98	2	6	16	20	5
31	1.12	4	4.6	10	25	6
10	0.88	3	2.8	8	35	7
33	1.20	6	3.2	11	11	4
32	1.21	5	3.5	18	10	5
26	1.13	8	4.1	20	16	8
15	1.05	10	7.5	23	20	10
18	1.06	9	5.3	5	23	16
11	0.92	12	6.3	8	33	10
16	1.01	11	2.6	6	15	8
13	1.03	10	3.7	9	18	6

ضریب رگرسیون در فضای محاسبات نرم یکی از پرکاربردترین شاخص‌های ارزیابی عملکرد روش به کاررفته است. شکل‌های ۱۶ و ۱۷ به ارائه همین شاخص پرداخته و مقادیر حاصل شده نشان می‌دهد که بر اساس معیارهای مختلف پذیرش کارایی مدل، قابل است. مقادیر بیش از ۹۰ درصد نشان‌دهنده کارایی مناسب مدل پیاده‌سازی شده دارد.

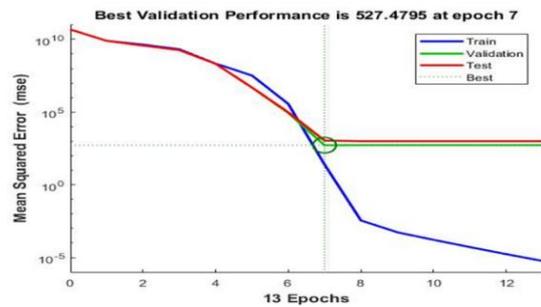


شکل ۱۲- دیاگرام آزمایش یادگیری عمیق (خروجی ۱)

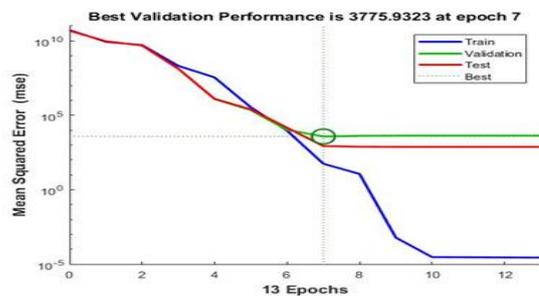


شکل ۱۳- دیاگرام آزمایش یادگیری عمیق (خروجی ۲)

بر اساس شکل‌های ۱۰ تا ۱۳ مشاهده می‌شود که در هر دو خروجی موردبررسی کارایی مدل ترکیبی یادگیری عمیق مناسب بود است. همچنین مطابق نتایج شکل‌های ۱۴ و ۱۵ مقادیر شاخص خطای زیر ۱ را برای مدل ترکیبی در هر دو خروجی نشان داده که نشان از قابلیت بسیار بالای روش ترکیبی مورد استفاده دارد.



شکل ۱۴- منحنی عملکرد کد ترکیبی یادگیری عمیق



شکل ۱۵- منحنی آموزش کد ترکیبی یادگیری عمیق

- ۱- داده‌ها فقط از SPT یا CPT استفاده می‌کنند و سایر عوامل مثل سطح آب، نوع خاک و تاریخچه زمین‌شناسی نادیده گرفته می‌شود.
- ۲- روابط بر اساس تجارب گذشته هستند و ممکن است برای مناطق با شرایط ژئوتکنیکی متفاوت معتبر نباشند.
- ۳- مرز روانگرایی و عدم روانگرایی به صورت قطعی ( $FS=1$ ) تعریف می‌شود، درحالی‌که پدیده روانگرایی ذاتاً احتمالاتی و غیرخطی است.

### ۲-۵- روش محاسبات نرم (CNN-MVO)

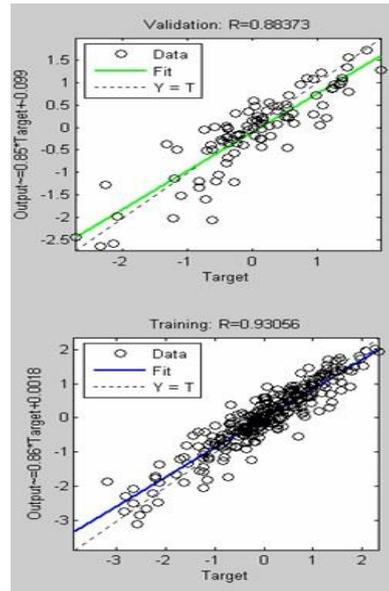
- روش محاسبات نرم از داده‌های چند منبعی (SPT، درصد ریزدانه، عمق، سطح آب زیرزمینی و نوع خاک) استفاده می‌کند.
- شبکه عصبی CNN قادر است روابط غیرخطی پیچیده میان پارامترها و وقوع روانگرایی را شناسایی کند.
- الگوریتم MVO باعث می‌شود مدل در بهینه‌سازی وزن‌ها گیر نکند و به بهترین جواب جهانی برسد.
- بر اساس نتایج این پژوهش، روش CNN-MVO توانست به:

$$R \approx 90.00 \quad MSE < 0.5 \quad (4)$$

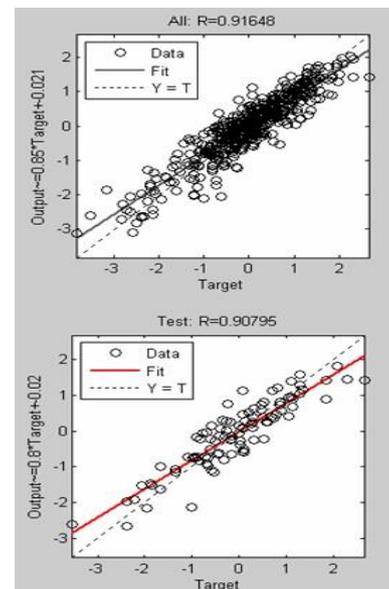
- این روش علاوه بر تشخیص روانگرایی، قابلیت برآورد نشست (Settlement) را هم دارد، درحالی‌که روش تجربی صرفاً وقوع یا عدم وقوع روانگرایی را مشخص می‌کند.

### ۳-۵- جمع‌بندی

- روش‌های تجربی برای تخمین سریع و اولیه مفید هستند، اما وابسته به منطقه و ساده‌سازی بیش از حد هستند.
- در مقابل، روش محاسبات نرم با استفاده از یادگیری الگوهای پیچیده و داده‌محور دقت بالاتری دارد و می‌تواند عدم قطعیت‌ها را بهتر مدیریت کند.
- بنابراین، استفاده از روش CNN-MVO به‌عنوان مکمل و ارتقادهنده روش‌های تجربی توصیه می‌شود، خصوصاً در پروژه‌های حساس ژئوتکنیک
- در جدول ۴ مقایسه روش تجربی و محاسبات نرم آمده است:



شکل ۱۶- ضریب رگرسیون کد ترکیبی یادگیری عمیق (خروجی ۲)



شکل ۱۷- ضریب رگرسیون کد ترکیبی یادگیری عمیق (خروجی ۱)

### ۵- مقایسه روش تجربی و روش محاسبات نرم

#### ۱-۵- روش تجربی (SPT-based)

- روش‌های تجربی سنتی مثل سید و ادريس [۳۴] ۱۹۸۳، بر مبنای روابط نیمه تجربی بین عدد SPT، درصد ریزدانه و تنش مؤثر عمقی توسعه یافته‌اند.
- این روش‌ها یک ضریب ایمنی ( $FS = CRR/CSR$ ) محاسبه می‌کنند که اگر  $FS < 1$  باشد خاک روانگرا محسوب می‌شود.
- مزیت اصلی این روش‌ها سادگی و کاربرد وسیع است. اما محدودیت‌های زیادی دارند:

جدول ۴- زیر مقایسه روش تجربی و محاسبات نرم

ویژگی‌ها	روش تجربی (SPT-based)	روش محاسبات نرم (CNN-MVO)
مبنای محاسبات	روابط نیمه‌تجربی (سید و ادیس ۱۹۸۳) بین SPT، درصد ریزدانه و عمق	یادگیری ماشین با ترکیب شبکه عصبی کانولوشن (CNN) و الگوریتم بهینه‌سازی (MVO)
نوع داده‌ها	محدود به نتایج SPT	داده‌های چند منبعی SPT، درصد ریزدانه، سطح آب، نوع خاک، عمق
ماهیت مدل	$FS < 1$ روانگرا، $FS > 1$ غیر روانگرا	احتمالاتی و غیرخطی (پیش‌بینی با دقت آماری)
قابلیت پیش‌بینی	روانگرایی یا عدم روانگرایی	وقوع روانگرایی + برآورد نشست
دقت نتایج	وابسته به منطقه و شرایط زمین‌شناسی، در برخی موارد خطای زیاد	دقت بالاتر و تعمیم‌پذیری بیشتر
مزایا	سادگی، سرعت، کاربرد گسترده	دقت بالا، توانایی مدل‌سازی روابط پیچیده، قابلیت تعمیم به شرایط جدید
محدودیت‌ها	نادیده‌گرفتن بسیاری از عوامل مؤثر، وابستگی به داده‌های گذشته	نیاز به پایگاه‌داده نسبتاً بزرگ و پردازش رایانه‌ای

## ۶- صحت‌سنجی

- مقایسه با روش تجربی: به منظور ارزیابی بیشتر، نتایج مدل ترکیبی CNN-MVO با روش تجربی مبتنی بر SPT مقایسه شد. نتایج نشان داد که روش محاسبات نرم دقت بالاتری در پیش‌بینی وقوع روانگرایی و نشست ناشی از آن دارد.

- تحلیل نموداری: نمودارهای رگرسیون و هیستوگرام خطا برای داده‌های آموزش، آزمون و کل داده‌ها ترسیم شد. این نمودارها نشان دادند که خطاها عمدتاً نزدیک به صفر بوده و مدل از همگرایی مناسبی برخوردار است.

- صحت‌سنجی میدانی: داده‌ها از پروژه‌های واقعی ژئوتکنیکی در استان های شمالی کشور جمع‌آوری شده و با گزارش‌های آزمایشگاهی معتبر و داده‌های منتشرشده در مقالات علمی مقایسه گردید. این امر اطمینان بیشتری نسبت به صحت نتایج مدل ایجاد کرد.

برای اطمینان از درستی مدل توسعه‌یافته، مراحل صحت‌سنجی زیر انجام شد:

- تقسیم داده‌ها: مجموعه داده‌های مورداستفاده به سه بخش تقسیم گردید: ۷۰ درصد برای آموزش (Training)، ۱۵ درصد برای اعتبارسنجی (Validation) و ۱۵ درصد برای آزمون (Testing) این تقسیم‌بندی باهدف جلوگیری از بیش‌برازش (Overfitting) و بررسی عملکرد مدل بر روی داده‌های جدید انجام شد.

- شاخص‌های ارزیابی: دو معیار اصلی برای سنجش دقت مدل به کار گرفته شد: ضریب رگرسیون (R) نشان‌دهنده میزان انطباق مدل با داده‌های واقعی در این مطالعه  $R \approx 0.90$  به دست آمد. میانگین مربعات خطا (MSE) شاخصی برای اندازه‌گیری خطای پیش‌بینی در این مطالعه MSE کمتر از 0.5 گزارش شد.

## ۷- نتیجه گیری

مسئله اصلی مقاله حاضر بررسی یکی از مهم‌ترین مخاطرات ژئوتکنیک و زمین‌شناسی مهندسی با روش‌های مبتنی بر محاسبات نرم و هوش مصنوعی است. پدیده‌ای خطرناک به نام روانگرایی خاک، در خاک‌های ماسه‌ای ذرات ماسه به‌وسیله اتصال بین ذرات نگهداری می‌شوند و نیرو می‌تواند از طریق این اتصالات منتقل گردد، این امر سبب ایجاد مقاومت برشی شده و باعث می‌شود ماسه‌های که بر روی سطح زمین قرار گرفته، به‌وسیله خاک تحمل شود. زمانی که خاک ماسه‌ای در اثر تنش برشی ناشی از ارتعاش تغییر شکل می‌دهد، اتصال بین ذرات کم می‌شود، در نتیجه نیرویی که عموماً در جهت قائم و از میان نقاط اتصال تحمل می‌شود تبدیل به فشار آب حفره‌ای می‌گردد که این حالت مربوط به پدیده روانگرایی هست.

مکانیزم اساسی روانگرایی در لایه‌های ماسه‌ای اشباع و سست، افزایش تدریجی فشار منفذی در اثر اعمال تنش‌های سیکی حاصل از انتشار موج برشی زلزله هست، یک المان خاک در زمین مسطح در شرایط طبیعی تحت تنش‌های جانبی حاصل از وزن لایه‌های بالا قرار می‌گیرد. در هنگام اعمال تنش‌های سیکی به یک المان ماسه سست، تمایل به تراکم و در نتیجه کاهش حجم در آن المان وجود دارد. اگر زمان بارگذاری بسیار کمتر از زمان لازم برای زهکشی و خروج آب باشد، امکان کاهش حجم در زمان کوتاه ایجاد نشده و در نتیجه در وضعیت تنش سیستم تغییراتی ایجاد می‌شود، این تغییرات شامل کاهش تنش مؤثر بین ذرات و افزایش فشار منفذی هست؛ بنابراین مقدار فشار منفذی ایجادشده به وضعیت فشردگی، خصوصیات کاهش حجم المان در اثر بارگذاری، شدت و دوام بارگذاری بستگی پیدا می‌کند. فرایند و متدولوژی اجرای تحقیق حاضر شامل چندین مرحله است که در اغلب موارد به‌موازات یکدیگر قرار دارند.

مدل‌سازی و پیاده‌سازی روش یادگیری عمیق دارای چند مرحله است که پس از پیش‌پردازش داده‌ها و ارزیابی نتایج مطالعات ژئوتکنیک انجام می‌گردد. روش کاربرد مدل یادگیری عمیق بسیار به تعداد داده‌های موجود و دقت داده‌های مورد استفاده بستگی دارد. برای این منظور ابتدا بانک اطلاعاتی و پارامترهای ورودی و خروجی تعیین شده‌اند. همان‌طور که قبلاً ذکر شده در انتخاب پارامترهای ورودی سعی شده است تا پارامترهایی انتخاب گردند که از معمول‌ترین آزمون‌های مطالعات ژئوتکنیک حاصل شوند. باتوجه به حدود ۱۰۰ داده موجود در محدوده استان‌های شمالی کشور که از نتایج مطالعات ژئوتکنیک و همچنین تحلیل و ارزیابی

محاسبات پتانسیل روانگرایی حاصل شده‌اند، پارامترهای ورودی و خروجی مطابق جدول (۱) انتخاب شده‌اند.

برای پیاده‌سازی کدنویسی مورد استفاده، آموزش و ارزیابی آن‌ها از نرم‌افزار (MATLAB 9.5 (2018b) استفاده شده است. این نرم‌افزار باتوجه به توابع متعدد، قابلیت برنامه‌نویسی، الگوریتم‌های آموزشی و ساختارهای متعدد برای شبکه‌های عصبی و قدرت پردازش و تحلیل‌های آماری در حل مسائل مهندسی بسیار مورد توجه محققین بوده است. کدنویسی انجام شده در نرم‌افزار متلب قابل ارائه بوده و مطابق شرایط مقاله در این قسمت ارائه نشده است. همچنین جهت ارزیابی کارایی روش یادگیری عمیق از دو شاخص ارزیابی استفاده شده است. ضریب رگرسیون (R) و شاخص خطا (MSE) که در شکل‌های ادامه ارائه شده‌اند. روش‌های یادگیری عمیق و الگوریتم‌های یادگیری ماشین بسیار کاربرد بوده و در صورت وجود داده‌های قابل اطمینان و مناسب از لحاظ تعداد داده، عملکرد موفقی خواهند داشت.

نتایج تحقیق حاضر عبارت‌اند از:

- ضریب رگرسیون (R) برابر ۹۰ درصد در این مدل‌ها نشان‌دهنده کارایی مناسب روش یادگیری عمیق در مدل‌سازی طرح مخلوط حاضر است.
- روش یادگیری عمیق به‌کاررفته بهترین کارایی را بر اساس ضریب رگرسیون در سه مجموعه یادگیری، آزمایشی و ارزیابی از خود نشان داده است.
- شاخص خطا نیز در نتایج گزارش شده و در این شاخص نیز مشاهده می‌گردد که روش ترکیبی معرفی شده با شاخص خطای زیر ۰/۵ عملکرد مناسبی داشته است.

## منابع

- [1]. Luque, R. and J.D. Bray, *Dynamic soil-structure interaction analyses of two important structures affected by liquefaction during the Canterbury earthquake sequence*. Soil Dynamics and Earthquake Engineering, 2020. 133: p. 106026. <https://doi.org/10.1016/j.soildyn.2019.106026>
- [2]. Zhou, J., et al., *Feasibility of stochastic gradient boosting approach for evaluating seismic liquefaction potential based on SPT and CPT case*

- Sustainability, 2020. **12**(10): p. 4001. <https://doi.org/10.3390/su12104001>
- [١٠]. Tang, X.-W., J.-L. Hu, and J.-N. Qiu, *Identifying significant influence factors of seismic soil liquefaction and analyzing their structural relationship*. KSCE Journal of Civil Engineering, 2016. **20**: p. 2655-2663. <https://doi.org/10.1007/s12205-016-0339-2>
- [١١]. Cetin, K. and H. Bilge, *Recent advances in seismic soil liquefaction engineering*. The Evolution of Geotech-25 Years of Innovation, 2021: p. 18-42.
- [١٢]. Fang, Y., I. Jairi, and N. Pirhadi, *Neural transfer learning for soil liquefaction tests*. Computers & Geosciences, 2023. **171**: p. 105282. <https://doi.org/10.1016/j.cageo.2022.105282>
- [١٣]. Hong, Y. and J. Kim, *Art painting detection and identification based on deep learning and image local features*. Multimedia Tools and Applications, 2019. **78**: p. 6513-6528. <https://doi.org/10.1007/s11042-018-6387-5>
- [١٤]. Nurhikmat, T., *Implementasi deep learning untuk image classification menggunakan algoritma Convolutional Neural Network (CNN) pada citra wayang golek*. 2018. <https://dspace.uin.ac.id/handle/123456789/7843>
- [١٥]. Purwanto, A., *Utilization of Deep Learning for Mapping Land Use Change Base on Geographic Information System: A Case Study of Liquefaction*. Jurnal Penelitian Pendidikan IPA, 2023. **9**(10): p. 8059-8064. <https://doi.org/10.29303/jppipa.v9i10.5032>
- [١٦]. Fadhillah, M.F., et al., *Integrating SAR and Optical Imagery Analysis for Liquefaction Phenomenon Identification of Post-Pohang Earthquake 2017, South Korea, Utilizing a Hybrid Deep-Learning Approach*. IEEE Transactions on Geoscience and Remote Sensing, 2025. [10.1109/TGRS.2025.3550554](https://doi.org/10.1109/TGRS.2025.3550554)
- histories*. Journal of Performance of Constructed Facilities, 2019. **33**(3): p. 04019024. [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0001292](https://doi.org/10.1061/(ASCE)CF.1943-5509.0001292)
- [3]. Kokusho, T., *Innovative earthquake soil dynamics*. 2017: CRC Press.
- [4]. Ahmad, M., et al., *A hybrid approach for evaluating CPT-based seismic soil liquefaction potential using Bayesian belief networks*. J. Cent. South Univ, 2020. **27**: p. 500-516. <https://doi.org/10.1007/s11771-020-4312-3>
- [5]. Zhou, J., et al. *Classification of seismic-liquefaction potential using Friedman's stochastic gradient boosting based on the cone penetration test data*. in *Transportation and Geotechniques: Materials, Sustainability and Climate: Proceedings of the 5th GeoChina International Conference 2018–Civil Infrastructures Confronting Severe Weathers and Climate Changes: From Failure to Sustainability, held on July 23 to 25, 2018 in HangZhou, China*. 2019. Springer. [https://doi.org/10.1007/978-3-319-95768-5\\_7](https://doi.org/10.1007/978-3-319-95768-5_7)
- [6]. Nakao, K., et al., *Numerical simulation of the liquefaction phenomenon by MPSM-DEM coupled CAES*. Sustainability, 2022. **14**(12): p. 7517. <https://doi.org/10.3390/su14127517>
- [7]. Cong, Y., et al., *Machine learning predictive analysis of liquefaction resistance for sandy soils enhanced by chemical injection*. Machine Learning and Knowledge Extraction, 2024. **6**(1): p. 402-419. <https://doi.org/10.3390/make6010020>
- [٨]. Cavus, U.S., et al., *Fuzzy logic based assessment of seismic soil liquefaction potential and its application to foundations of bridge piers*. Journal of Intelligent & Fuzzy Systems, 2019. **36**(6): p. 6001-6011. <https://doi.org/10.3233/JIFS-181795>
- [٩]. Park, S.-S., et al., *A simple and sustainable prediction method of liquefaction-induced settlement at Pohang using an artificial neural network*.

frequency images. *Soil Dynamics and Earthquake Engineering*, 2023. **166**: p. 107788.

<https://doi.org/10.1016/j.soildyn.2023.107788>

[25]. Idriss, I. and R.W. Boulanger, *SPT-based liquefaction triggering procedures*. Rep. UCD/CGM-10, 2010. **2**: p. 4-13.

[26]. Kohestani, V., M. Hassanlourad, and A. Ardakani, *Evaluation of liquefaction potential based on CPT data using random forest*. *Natural Hazards*, 2015. **79**(2): p. 1079-1089.

<https://doi.org/10.1007/s11069-015-1893-5>

[27]. Kayen, R., et al., *Shear-wave velocity-based probabilistic and deterministic assessment of seismic soil liquefaction potential*. *Journal of Geotechnical and Geoenvironmental Engineering*, 2013. **139**(3): p. 407-419.

[https://doi.org/10.1061/\(ASCE\)GT.1943-5606.0000743](https://doi.org/10.1061/(ASCE)GT.1943-5606.0000743)

[28]. Filali, K. and B. Sbartai, *A comparative study between simplified and nonlinear dynamic methods for estimating liquefaction potential*. *Journal of Rock Mechanics and Geotechnical Engineering*, 2017. **9**(5): p. 955-966.

<https://doi.org/10.1016/j.jrmge.2017.05.008>

[29]. Kokusho, T., *Major advances in liquefaction research by laboratory tests compared with in situ behavior*. *Soil Dynamics and Earthquake Engineering*, 2016. **91**: p. 3-22.

<https://doi.org/10.1016/j.soildyn.2016.07.024>

[30]. Toprak, S. and T.L. Holzer, *Liquefaction potential index: Field assessment*. *Journal of Geotechnical and Geoenvironmental Engineering*, 2003. **129**(4): p. 315-322.

[https://doi.org/10.1061/\(ASCE\)1090-0241\(2003\)129:4\(315\)](https://doi.org/10.1061/(ASCE)1090-0241(2003)129:4(315))

[31]. Bhattacharya, S., et al., *Liquefaction of soil in the Tokyo Bay area from the 2011 Tohoku (Japan) earthquake*. *Soil Dynamics and Earthquake Engineering*, 2011. **31**(11): p. 1618-1628.

[17]. Yuan, Y., et al., *A Hybrid SSA-CNN-SVM Model for Seismic-Induced Sand Liquefaction Discrimination*. 2025. <https://doi.org/10.21203/rs.3.rs-7188692/v1>

[18]. Ghani, S., et al., *Soil categorization and liquefaction prediction using deep learning and ensemble learning algorithms*. *Transportation Infrastructure Geotechnology*, 2025. **12**(1): p. 22. <https://doi.org/10.1007/s40515-024-00474-8>

[19]. Fadhillah, M.F., et al., *Liquefaction Phenomenon Identification from post-Pohang Earthquake 2017, South Korea based Integrated SAR and optical imagery data using a machine-learning approach*. 2024. <https://doi.org/10.21203/rs.3.rs-3849294/v1>

[20]. Bai, R., et al., *The Analysis of the Correlation between SPT and CPT Based on CNN-GA and Liquefaction Discrimination Research*. *CMES-Computer Modeling in Engineering & Sciences*, 2024. **138**(2). (<https://doi.org/10.2604/cmcs.2023.029562>)

[21]. Kumar, D.R., et al., *Liquefaction susceptibility using machine learning based on SPT data*. *Intelligent Systems with Applications*, 2023. **20**: p. 200281. <https://doi.org/10.1016/j.iswa.2023.200281>

[22]. LONG ,X., R. SUN, and T. ZHENG, *Convolutional neural network-based liquefaction prediction model and interpretability analysis*. *Rock and Soil Mechanics*, 2025. **45**(9): p. 8. [10.16285/j.rsm.2023.6596](https://doi.org/10.16285/j.rsm.2023.6596)

[23]. Şehmusoğlu, E.H., T.F. Kurnaz, and C. Erden, *Estimation of soil liquefaction using artificial intelligence techniques: an extended comparison between machine and deep learning approaches*. *Environmental Earth Sciences*, 2025. **84**(5): p. 1-22 <https://doi.org/10.1007/s12665-025-12116-4>

[24]. Zhang, W., et al., *A deep learning approach for rapid detection of soil liquefaction using time-*



<https://doi.org/10.5194/soil-6-35-2020>

[3۹]. Hakim, W.L., et al., *Land subsidence and groundwater storage assessment using ICOPS, GRACE, and susceptibility mapping in Pekalongan, Indonesia*. IEEE Transactions on Geoscience and Remote Sensing, 2023. **61**: p. 1-25.

<https://doi.org/10.1109/TGRS.2023.3324043>

[۴۰]. Mirjalili, S., S.M. Mirjalili, and A. Hatamlou, *Multi-verse optimizer: a nature-inspired algorithm for global optimization*. Neural Computing and Applications, 2016. **27**: p. 495-513.

<https://doi.org/10.1007/s00521-015-1870-7>

[۴۱]. Emami ,M., *Application of artificial neural networks in pressuremeter test results*. Master of Science thesis, Tarbiat Modares University, Tehran, Iran, 2009.

<https://doi.org/10.1016/j.soildyn.2011.06.006>

[3۲]. Hossain, M.B., M. Roknuzzaman, and M.M. Rahman, *Liquefaction potential evaluation by deterministic and probabilistic approaches*. Civil Engineering Journal, 2022. **8**(7): p. 1459-1481.

<http://dx.doi.org/10.28991/CEJ-2022-08-07-010>

[3۳]. GASHAW, H., *ASSESSMENT AND EVALUATION OF EARTHQUAKE-INDUCED SOIL LIQUEFACTION POTENTIAL: A CASE STUDY IN HAWASSA TOWN*. ARCHITECTURAL ENGINEERING, 2020.

[3۴]. Seed, H.B., I.M. Idriss, and I. Arango, *Evaluation of liquefaction potential using field performance data*. Journal of geotechnical engineering, 1983. **109**(3): p. 458-482

[https://doi.org/10.1061/\(ASCE\)0733-9410\(1983\)109:3\(458\)](https://doi.org/10.1061/(ASCE)0733-9410(1983)109:3(458))

[3۵]. Boulanger, R. and I. Idriss. *Evaluating cyclic failure in silts and clays*. in *Proceedings, geotechnical earthquake engineering satellite conference on performance based design in earthquake geotechnical engineering: concepts and research*. Prepared by TC4 Committee of ICSMGE, Japanese Geotechnical Society, Tokyo. 2005.

[3۶]. Bray, J.D. and R.B. Sancio, *Assessment of the liquefaction susceptibility of fine-grained soils*. Journal of geotechnical and geoenvironmental engineering, 2006. **132**(9): p. 1165-1177.

[https://doi.org/10.1061/\(ASCE\)1090-0241\(2006\)132:9\(1165\)](https://doi.org/10.1061/(ASCE)1090-0241(2006)132:9(1165))

[37]. Abdul Mueed, M., *Machine learning algorithms-based evaluation of dynamic properties and liquefaction potential of soil*. 2024, NUST.

<http://10.250.8.41:8080/xmlui/handle/123456789/44698>

[38]. Padarian, J., B. Minasny, and A.B. McBratney, *Machine learning and soil sciences: A review aided by machine learning tools*. Soil, 2020. **6**(1): p. 35-52.