J. Analysis of Structure and Earthquake
Volum 22, Issue 3, autumn 2025
Issn: 2821-0999
وبگاه مجله: www.civil-strj.maragheh.iau.ir
فصلنامه علمی آنالیز سازه - زلزله
دوره ۲۲، شماره ۳، پاییز ۱۴۰۴

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, S.T.C., Islamic Azad University, Tehran, Iran.
Ghodratollah Mohammadi
Department of Civil Engineering, S.T.C., Islamic Azad University, Tehran, Iran.
Amir Taban
Department of Civil Engineering ,Khorramabad Branch, Islamic Azad University, Khorramabad, Iran.
Mohammad Emami Kourandeh
Department of Civil Engineering, S.T.C., Islamic Azad University, Tehran, Iran.
sh.aghakasiri@iau.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
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 تهران‌جنوب، دانشگاه آزاد اسلامی، تهران، ایران
قدرت الله محمدی
گروه مهندسی عمران، واحد تهران‌جنوب، دانشگاه آزاد اسلامی، تهران، ایران
امیر تابان
گروه مهندسی عمران، واحد خرم‌آباد، دانشگاه آزاد اسلامی، خرم‌آباد، ایران.
محمد امامی کورنده
گروه مهندسی عمران، واحد تهران‌جنوب، دانشگاه آزاد اسلامی، تهران، ایران
sh.aghakasiri@iau.ir

تاریخ دریافت: ۱۱ خرداد ۱۴۰۴ تاریخ پذیرش: ۱۰ مهر 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 مورداستفاده 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 مورداستفاده قرار گیرد.

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

*نویسنده مسئول مکاتبات

۱- مقدمه

در هنگام ساخت طرح لرزه‌ای روانگرایی عامل مهمی است که موردتوجه قرار می‌گیرد. شکست پی ساختمان به دلیل کاهش مقاومت خاک رخ می‌دهد. هنگامی‌که خاک اشباع می‌شود مقاومت خاک کاهش می‌یابد. درنتیجه 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 قابل‌توجهی را به بار آورده‌اند. ریزش ساختمان‌ها درنتیجه روانگرایی و جابجایی قابل‌توجه خاک توسط زلزله سال ۱۹۶۴ توکیو در ژاپن آغاز شد. به‌این‌ترتیب، 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 دانشگاهیان 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 ایالات‌متحده 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 زمین لرزه اثرات بسیار منفی بر خطوط حیاتی، پل‌ها و ساختمان‌ها دارد[۵]. آسیب‌های ساختاری قابل‌توجهی 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 درزمینهٔ مهندسی ژئوتکنیک بوده است، همان‌طور که در شکل ۱ نشان داده‌شده 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 استفاده‌شده 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. براین اساس، تغییرشکل‌های زمین رخ می‌دهد که در هنگام زلزله آسیب شدیدی به خطوط حیاتی سازه‌های طراحی‌شده وارد می‌کند. رایج‌ترین نوع این خرابی‌ها، تغییر شکل، گسترش جانبی و نشست زمین است که در اثر روانگرایی ایجادشده است. تحت روانگرایی، خاک دانه‌ای سست متراکم می‌شود و درنتیجه به دلیل تغییر شکل عمودی ناشی از روانگرایی، نشست‌های افقی لایه‌های سطحی خاک ایجاد می‌شود[۹].

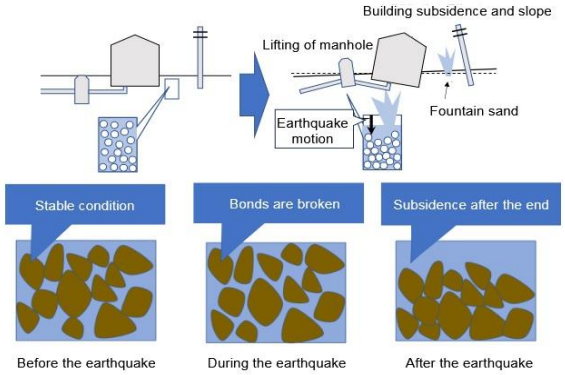

شکل ۱- مکانیزم روانگرایی: ذرات خاک به دلیل افزایش فشار آب منافذ شناور می‌شوند[۷]

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 درنتیجه باعث کاهش پایداری خاک می‌شود. هنگامی‌که 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 قابل‌توجهی شود، پیچیدگی تجزیه‌وتحلیل 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 آزمایش آزمایشگاهی روش‌های مختلفی هستند که برای محاسبه نشست‌های زمینی ناشی از روانگرایی، ازجمله 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 قابل‌توجهی مانند گسترش جانبی و روانگرایی ایجاد کند که به‌نوبه خود ممکن است به سازه‌ها و زیرساخت‌ها آسیب برساند. روش‌های مبتنی بر آزمون‌ها، مانند آزمون سرعت موج‌برشی(Vs) ، 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 به‌کاربرده‌اند، رویکردهای قطعی و احتمالی رویکردهای پرکاربرد با مزیت رویکردهای احتمالی هستند. رویکرد قطعی به‌طورکلی 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 رخداده است. به‌طورکلی، در مدل‌های قطعی، یک خط مرزی به‌عنوان خط جداکننده برای طبقه‌بندی خاک روانگرا از خاک غیر

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 جمع‌آوری‌شده متنوع‌تر باشند، تصمیمات اتخاذشده 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 زمین‌بر 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]. یوآن 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 خاکSM-SP،MI-ML-SC،CL-MHوCH-CI 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 براین، بر اساس توزیع زمین‌شناسی نشان داده‌شده است که این منطقه دارای ترکیب آبرفتی کواترنری زیادی است، که نوعی خاک کاملاً مستعد روانگرایی است[۱۹]. همچنین در طی سال های 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 ارائه‌شده است. ازجمله 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] هست. زمانی که زلزله بزرگ ژاپن در سال ۲۰۱۱ رخ داد، خسارات ناشی از روانگرایی تا ۵۰۰ کیلومتری از توکیو تا توهوکو مشاهده شد. این امر باعث جوشش ماسه، بیرون‌زدگی منهول، خرابی داکت ها و تأسیسات، واژگون شدن خانه‌های مسکونی و خرابی جاده‌ها شد. اثرات آسیب‌دیدگی روانگرایی و نشست ساختمان‌ها در بسیاری از زمین‌لرزه‌ها مشاهده‌شده است که شامل گسیختگی ظرفیت باربری ساختمان‌ها در زلزله ۱۹۶۴ نیگاتا، زلزله‌های ژاپن و بیشتر در زلزله ۲۰۱۲ مائول، چیل ، ۲۰۱۱ توهوکو 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 ارائه‌شده است. ازجمله 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] هست. زمانی که زلزله بزرگ ژاپن در سال ۲۰۱۱ رخ داد، خسارات ناشی از روانگرایی تا ۵۰۰ کیلومتری از توکیو تا توهوکو مشاهده شد. این امر باعث جوشش ماسه، بیرون‌زدگی منهول، خرابی داکت ها و تأسیسات، واژگون شدن خانه‌های مسکونی و خرابی جاده‌ها شد. اثرات آسیب‌دیدگی روانگرایی و نشست ساختمان‌ها در بسیاری از زمین‌لرزه‌ها مشاهده‌شده است که شامل گسیختگی ظرفیت باربری ساختمان‌ها در زلزله ۱۹۶۴ نیگاتا، زلزله‌های ژاپن و بیشتر در زلزله ۲۰۱۲ مائول، چیل ، ۲۰۱۱ توهوکو 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 به‌منظور ارزیابی و پیش‌بینی پتانسیل روانگرایی در خاک‌های ماسه‌ای شمال ایران طراحی‌شده است. چارچوب کلی پژوهش شامل مراحل زیر است:

- جمع‌آوری داده‌ها:

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

پایگاه‌داده شامل ۱۵۰ گمانه حفاری‌شده 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.

– پیش‌پردازش داده‌ها:
داده‌های خام پالایش و داده‌های پرت (Outliers) حذف شدند.
متغیرهای کیفی مانند نوع خاک به‌صورت کدگذاری عددی (از GP=1 تا SC=12) وارد مدل شدند.
مجموعه‌داده‌ها به‌صورت 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 ادریس ۱۹۸۳) مقایسه شد تا قابلیت اعتماد آن بررسی گردد.
– شرایط ژئوتکنیکی و لرزه‌ای موردمطالعه:
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 مبنای طراحی a_{max}=0.3g و بزرگای زلزله Mw = 7 در نظر گرفته شد.
شرایط مرزی و زهکشی خاک در تحلیل‌ها به‌صورت 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 جمع‌آوری‌شده
در ادامه هرکدام از مراحل روش تحقیق حاضر به تشریح ارائه می‌گردد.

۳-۱- نوع خاک و ضریب زلزله

خاک موردمطالعه باتوجه‌به اطلاعات به‌دست‌آمده در رده IV قرار دارد و بر همین اساس و باتوجه‌به میانگین عدد نفوذ استاندارد به‌دست‌آمده که ۱۲ است خاک در رده‌بندی ریزدانه سفت و درشت‌دانه تراکم متوسط قرار دارد. همچنین شتاب مبنای زلزله بر روی سطح زمین یا آبرفت، a_{max}= 0.3g در نظر گرفته‌شده است. عوامل زمین‌شناسی متعددی در میزان آب‌گونه شدن خاک‌دارند 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 براثر وزن رسوب یا زمین‌لرزه‌های قدیمی است. بیشترین استعداد آب‌گونگی 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 به‌واسطهٔ 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 کم‌شدن یا حتی ازبین‌رفتن 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 به‌صورت سیلان و جوشش ماسه ظاهر می‌شوند. باتوجه‌به وجود لایه‌های ماسه‌ای و سیلتی اشباع باضخامت قابل‌توجه در اعماق مختلف و همچنین اعداد SPT، امکان بروز پدیده روانگرایی مورد بررسی قرار گرفته است.
شاخص پتانسیل روانگرایی (LPI) به‌عنوان یک معیار کمی برای ارزیابی احتمال و شدت روانگرایی خاک در یک منطقه خاص ایجادشده است[۳۲]. برای ارائه یک ارزیابی کامل از خطر روانگرایی، LPI متغیرهای مختلفی مانند ویژگی‌های لرزه‌ای، شرایط آب زیرزمینی و کیفیت خاک را دربرمی گیرد .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 مورداستفاده در ارزیابی پتانسیل روانگرایی درگذشته 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 Cyclic (CSR) Stress Ratio با استفاده از تحلیل پاسخ لایه‌های خاک تحت ارتعاش زلزله و یا به‌وسیله روش ساده ارائه‌شده توسط سید و ادریس (۱۹۸۳) از رابطه زیر محاسبه می‌گردد[۳۴]:

$$CSR = (\tau_{av}/\sigma_0') = 0.65(\frac{a_{max}}{g})(\frac{\sigma_v}{\sigma_v'})r_d \qquad (۱)$$

که در آن a_{max} شتاب افقی حداکثر ناشی از زلزله در سطح زمین، g شتاب ثقل، تنش کل عمودی، σ_v تنش مؤثر عمودی و r_d ضریب کاهش تنش برحسب 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 داده‌شده است.

مقاومت برشی تناوبی یا به‌عبارت‌دیگر 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 اصلاح‌شده، درصد ریزدانه و بعضاً خواص خمیری خاک ارائه‌شده است. سید و همکاران (۱۹۸۳) نمودار نشان داده‌شده در شکل (۳) را جهت محاسبه نسبت مقاومت برشی تناوبی (τ_{av} / σ'_0) ارائه نموده‌اند[۳۴].

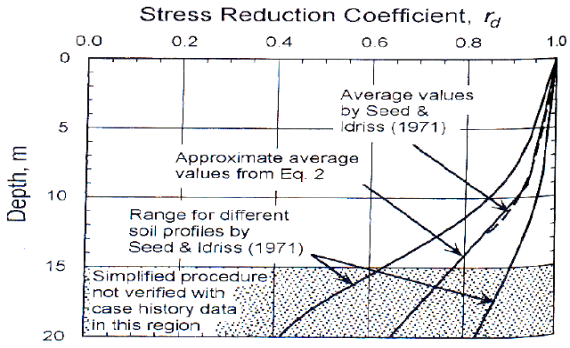

شکل ۲- ضریب r_d درروش سید و همکاران [۳۴]

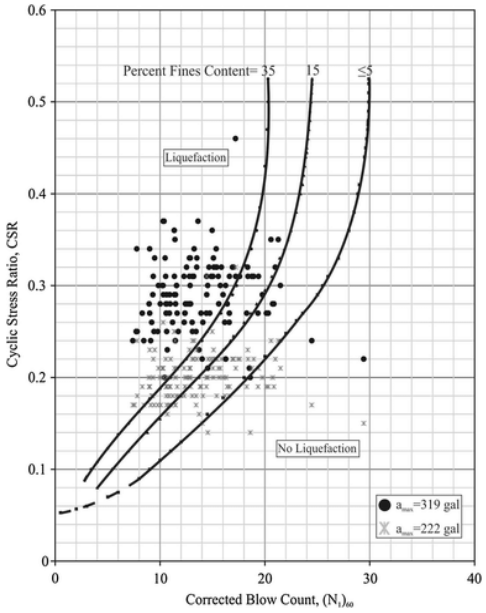

شکل ۳- نمودار محاسبه نسبت مقاومت برشی تناوبی برحسب عدد SPT (سید و همکاران (۱۹۸۳)[۳۴]

ضریب اطمینان در مقابل روانگرایی به‌صورت حاصل تقسیم نسبت مقاومت برشی تناوبی بر نسبت تنش برشی تناوبی تعریف می‌شود و درصورتی‌که ضریب اطمینان کمتر از یک باشد پدیده روانگرایی اتفاق خواهد افتاد. تحلیل روانگرایی به روش مذکور با استفاده از نرم‌افزار LiqufyPro (ویرایش 4.5D شرکت CivilTech) بر روی گمانه¬هایی که خاک آن‌ها دارای شرایط روانگرایی بوده تحلیل‌شده و نتایج حاصله تحلیل و بررسی‌شده است. تحلیل‌ها با فرض وقوع زلزله‌هایی با شتاب و بزرگی $M_w=7$, $a_{max}= 0.3g$ بر اساس شرایط لرزه‌خیزی استان‌های شمالی انجام‌شده است. شکل (۴) نمونه محاسبات و شبیه‌سازی‌ها به کمک نرم‌افزار مذکور را نشان می‌دهد.

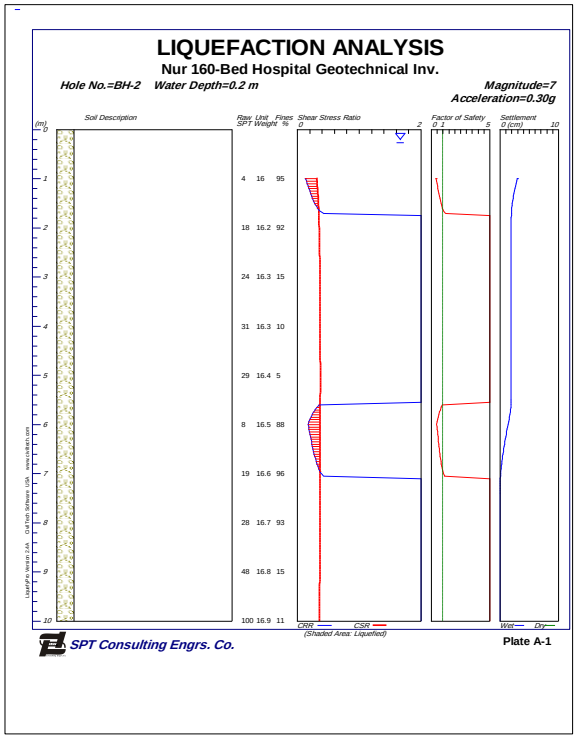

شکل ۴- نمونه‌ای از نتایج نرم‌افزار LiqufyPro در پیش‌بینی پتانسیل روانگرایی

محاسبات و مدل‌سازی مذکور در این بخش برای بیش از ۱۵۰ گمانه حفاری‌شده در پروژه‌های مطالعات ژئوتکنیک واقع در استان‌های شمالی کشور انجام‌شده است تا در تکمیل بانک اطلاعاتی تحقیق حاضر مورداستفاده 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 انجام‌شده ارزیابی‌شده و پارامترهای مهم آن‌ها استخراج‌شده‌اند. 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 موردنظر تحقیق انجام‌شده است.

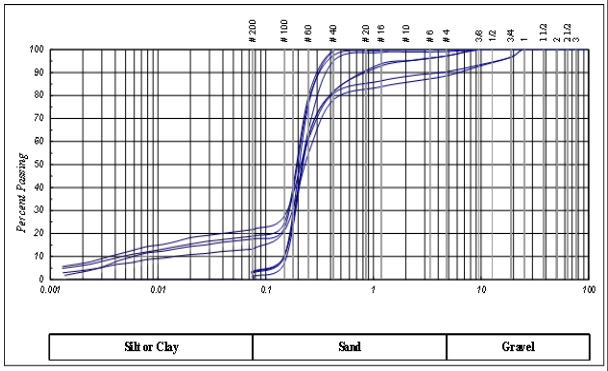

شکل ۵- پوش منحنی دانه‌بندی خاک‌های ماسه‌ای

بانک اطلاعاتی تحقیق حاضر نیز بر اساس پارامترهای مهم در محاسبات پتانسیل روانگرایی تکمیل‌شده است. پارامترهای ورودی و خروجی نیز بر همین اساس انتخاب‌شده‌اند.

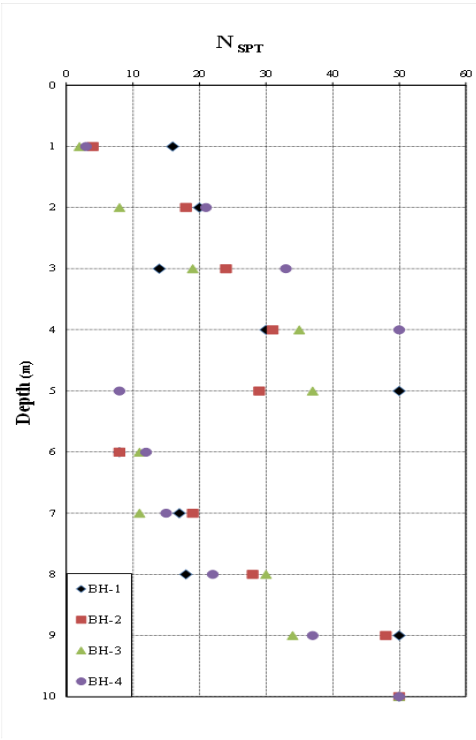

شکل ۶- نتایج آزمون‌های SPT دریکی از پروژه‌ها

جهت بررسی استعداد روانگرایی خاک‌های ریزدانه از معیارهای بولانگر و ادریس (۲۰۰۵) [۳۵]و بری و سانکیو (۲۰۰۶)[۳۶] استفاده‌شده 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 به۱/۰نزدیک باشد خاک ریزدانه رفتار ماسه‌ای و هرچه به۰/۰نزدیک باشد، خاک دارای رفتار رسی است. این معیارها در ذیل ارائه‌شده است:

$$S_{BI} = \left[1 + \left(\frac{\ln PI}{1.938}\right)^{6.676}\right]^{-2.0} \qquad (۲)$$

$$S_{BS} = \left[1 + \left(\frac{\ln PI}{2.778}\right)^{33.077}\right]^{-2.0}\left[1 + \left(\frac{4.401}{\ln\left(w_c/LL\right)}\right)^{360.471}\right]^{-2.0} \qquad (۳)$$

چنانچه متوسط این دو شاخص کوچک‌تر از ۰/۵باشد، لایه مقاوم در برابر روانگرایی است و اگر این شاخص بیشتر از۰/۵باشد، 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 ارائه‌شده است. همچنین ضرایب اطمینان در برابر روانگرایی در جدول ۲ ارائه‌شده 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 نشان‌داده‌شده است.

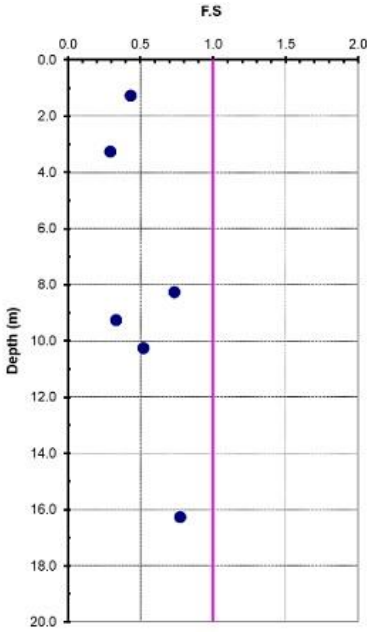

شکل ۷- ضرایب اطمینان متوسط در برابر روانگرایی در اعماق مستعد روانگرایی با استفاده از روش‌های بولانگر و ادریس [۹] و مرکز بین‌المللی تحقیقات زلزله

جدول ۱- شاخص استعداد روانگرایی در سایت موردمطالعه گمانهBH1

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

جدول ۲- ضرایب اطمینان در برابر روانگرایی با استفاده از روش‌های بولانگر و ادریس (۲۰۰۴) و مرکز بین‌المللی تحقیقات زلزله گمانهBH1

عمق (متر)	مرکز بین‌المللی تحقیقات زلزله				بولانگر و ادریس (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

یادگیری ماشین، شاخه‌ای از هوش مصنوعی، بر ایجاد الگوریتم‌ها و مدل‌هایی تأکید دارد که رایانه‌ها را قادر می‌سازد تا وظایف را به‌طور 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 به‌عنوان ابزاری برای پیش‌بینی نتایج و تجزیه‌وتحلیل داده‌های پیچیده در طیف وسیعی از صنایع، ازجمله 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 به‌گونه‌ای طراحی‌شده‌اند 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 معرفی‌شده‌اند. این شبکه‌ها نوع تخصصی از شبکه‌های عصبی مصنوعی هستند که از یک عملیات ریاضی به نام کانولوشن به‌جای ضرب ماتریس عمومی حداقل در یکی از لایه‌های خود استفاده می‌کنند. یک شبکه عصبی CNN از یک‌لایه ورودی، لایه‌های پنهان و یک‌لایه خروجی تشکیل‌شده 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 موردنظر را انجام می‌دهند. معمولاً شامل یک‌لایه است که حاصل‌ضرب 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 به‌صورت دستی مهندسی‌شده‌اند، شبکه عصبی پیچشی (ConvNets)، با آموزش‌دیدن به‌اندازه کافی، توانایی فراگیری این فیلترها/مشخصات را کسب می‌کند. معماری ConvNet مشابه با الگوی اتصال «نورون‌ها» (Neurons) در مغز انسان است و از سازمان‌دهی «قشر بصری» (Visual Cortex) در مغز الهام گرفته‌شده است. هر نورون به محرک‌ها تنها در منطقه محدودی از میدان بصری که تحت عنوان «میدان تأثیر» (Receptive Field) شناخته‌شده است پاسخ می‌دهد. یک مجموعه از این میدان‌ها برای پوشش‌دادن کل ناحیه بصری با یکدیگر هم‌پوشانی دارند.

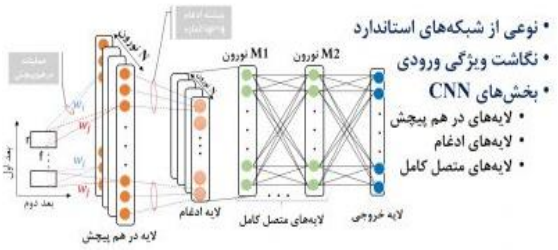

شکل ۸- شبکه عصبی CNN و نحوه عملکرد آن [۲۱]

۳-۲-۲ الگوریتم چند متغیره (MVO)

الگوریتم MVO یک الگوریتم متاهیورستیک 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 به‌جای تکرار استفاده‌شده، زیرا این یک اصطلاح رایج در نظریه و کیهان‌شناسی چند نظمی است[۴۰].

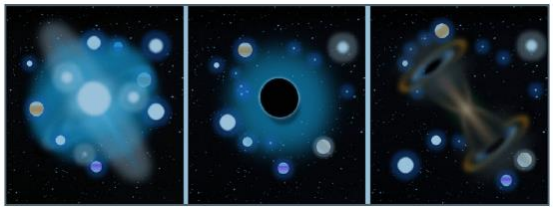

شکل ۹- شماتیک عملکرد الگوریتم (MVO) [۴۰]

۳-۳- مطالعات ژئوتکنیک

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

مطالعات ژئوتکنیک انجام‌شده در پروژه‌های شمالی کشور تکمیل‌شده است. لازم به ذکر است تمامی داده‌های مورداستفاده از داده‌های آزمایشگاهی به‌دست‌آمده 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 دربند قبل توضیح داده شد، طیف گسترده‌ای از داده‌ها از منابع معتبر، ازجمله مقالات معتبری جمع‌آوری شد. پایگاه‌داده، متشکل از ۱۵۰ نمونه، بر اساس پارامترهای کلیدی ژئوتکنیکی مانند محدودهSPT ، 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 به‌صورت تصادفی انجام‌شده تا عدالت رعایت شود و از سوگیری در فرایند یادگیری مدل جلوگیری شود.

۳-٤- 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 مورداستفاده بستگی دارد. برای این منظور ابتدا بانک اطلاعاتی و پارامترهای ورودی و خروجی تعیین‌شده‌اند. همان‌طور که قبلاً ذکرشده در انتخاب پارامترهای ورودی سعی شده است تا پارامترهایی انتخاب گردند که از معمول‌ترین آزمون‌های مطالعات ژئوتکنیک حاصل شوند. باتوجه‌به حدود ۱۰۰ داده موجود در محدوده استان‌های شمالی کشور که از نتایج مطالعات ژئوتکنیک و همچنین تحلیل و ارزیابی محاسبات پتانسیل روانگرایی حاصل‌شده‌اند، پارامترهای ورودی و خروجی مطابق جدول (۱) انتخاب‌شده‌اند. 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 گرفته‌شده‌اند. همچنین دو پارامتر خروجی بر اساس اهمیت خطر روانگرایی شامل: پتانسیل روانگرایی ((Liquefaction Potential (LP)) و نشست تخمینی (Settlement ((SD)) مشخص‌شده است. پس از جمع‌آوری داده‌ها در پیش‌بینی خطر روانگرایی، داده‌ها در نرم‌افزار اکسل پردازش‌شده و مراحل پردازش آن‌ها جهت ارائه به کد یادگیری عمیق به‌دقت انجام‌شده است. درزمینه پارامترهای ورودی مانند جنس خاک برای قابل‌بررسی بودن توسط روش یادگیری عمیق کدگذاری انجام‌شده است و از خاک شنی بد دانه‌بندی شده (GP=1) تا ماسه رس دار (S_C=12) ۱۲ نوع خاک از کد ۱ تا ۱۲ به مدل معرفی‌شده است.

٤- پیاده‌سازی روش یادگیری عمیق

برای *پیاده‌سازی* کدنویسی مورداستفاده، آموزش و ارزیابی آن‌ها از نرم‌افزار MATLAB 9.5 (20018b) استفاده‌شده است. این نرم‌افزار باتوجه‌به توابع متعدد، قابلیت برنامه‌نویسی، الگوریتم‌های آموزشی و ساختارهای متعدد برای شبکه‌های عصبی و قدرت پردازش و تحلیل‌های آماری در حل مسائل مهندسی بسیار موردتوجه محققین بوده است. کدنویسی انجام‌شده در نرم‌افزار متلب قابل‌ارائه 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 استفاده‌شده است. ضریب رگرسیون (R) و شاخص خطا (MSE) که در شکل‌های ادامه ارائه‌شده‌اند. در شکل (۱۰) منحنی آموزشی برای کد نویسی انجام‌شده، نشان داده‌شده است. پس از پایان آموزش مقادیر وزن‌ها ذخیره‌شده و شبکه موردنظر آماده است. همچنین نمونه‌ای از داده‌های بانک اطلاعاتی روش یادگیری عمیق در جدول ۳ آمده است.

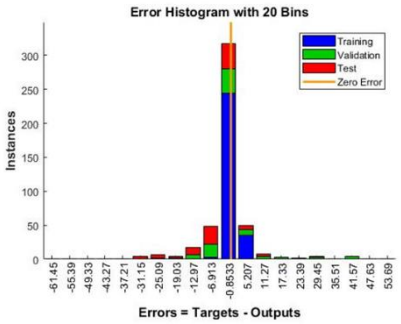

شکل ۱۰- دیاگرام آموزش یادگیری عمیق (خروجی ۱)

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

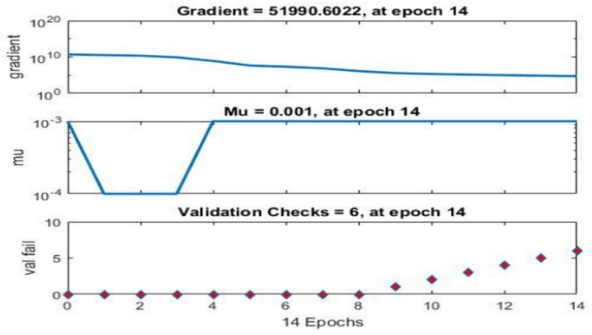

شکل ۱۱- دیاگرام آموزش یادگیری عمیق (خروجی ۲)

جدول ۳- نمونه‌ای از داده‌های بانک اطلاعاتی روش یادگیری عمیق

Output Parameter		Input Parameters				
SD (mm)	LP	SP	GWL (m)	FP (%)	Nspt	D (m)
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 به‌کاررفته است. شکل‌های ۱۶ و ۱۷ به ارائه همین شاخص پرداخته و مقادیر حاصل‌شده نشان می‌دهد که بر اساس معیارهای مختلف پذیرش کارایی مدل، قابل است. مقادیر بیش از ۹۰ درصد نشان‌دهنده کارایی مناسب مدل پیاده‌سازی شده دارد.

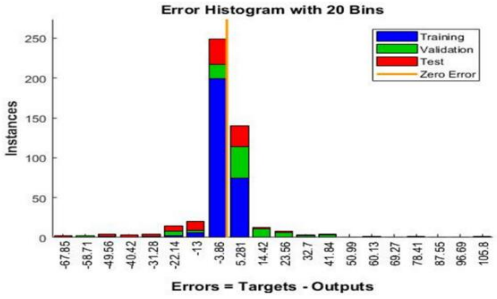

شکل ۱۲- دیاگرام آزمایش یادگیری عمیق (خروجی ۱)

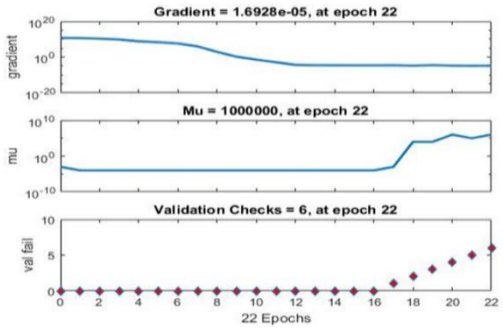

شکل ۱۳- دیاگرام آزمایش یادگیری عمیق (خروجی ۲)

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 مورداستفاده دارد.

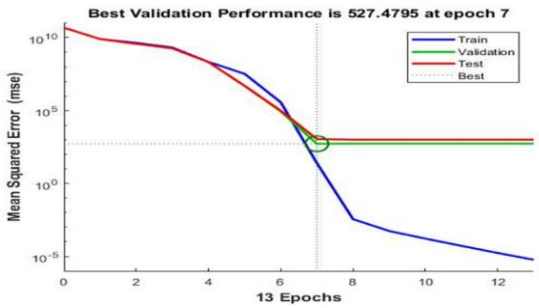

شکل ۱۴- منحنی عملکرد کد ترکیبی یادگیری عمیق

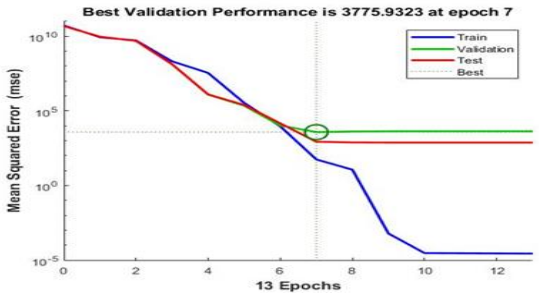

شکل ۱۵- منحنی آموزش کد ترکیبی یادگیری عمیق

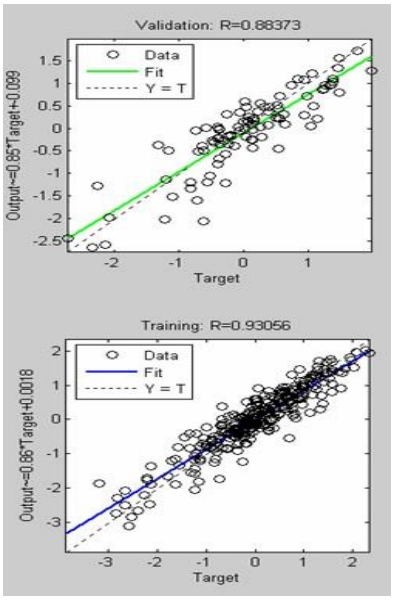

شکل ۱۶- ضریب رگرسیون کد ترکیبی یادگیری عمیق (خروجی۲)

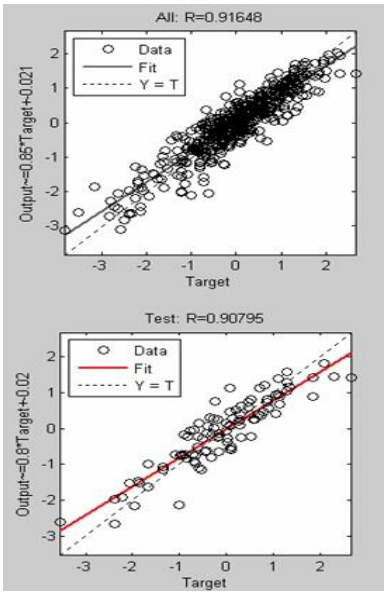

شکل ۱۷- ضریب رگرسیون کد ترکیبی یادگیری عمیق (خروجی ۱)

۵- مقایسه روش تجربی و روش محاسبات نرم

۵-۱- روش تجربی(SPT-based)

• روش‌های تجربی سنتی مثل سید و ادریس ۱۹۸۳ [۳۴] ، برمبنای روابط نیمه تجربی بین عدد SPT، درصد ریزدانه و تنش مؤثر عمقی توسعه‌یافته‌اند .

• 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:

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 به‌صورت قطعی (FS=1) تعریف می‌شود، درحالی‌که پدیده روانگرایی ذاتاً احتمالاتی و غیرخطی است.

۵-۲- 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:

$$R \approx 90.00 \qquad MSE < 0.5 \qquad (۴)$$

- 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.

۵-۳- 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:

جدول ۴- زیر مقایسه روش تجربی و محاسبات نرم

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

٦- صحت سنجی

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

- تقسیم داده‌ها: مجموعه‌داده‌های 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 بیش برازش (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 داده های واقعی در این مطالعه $R \approx 0.90$ به دست آمد.
میانگین مربعات خطا :(MSE) شاخصی برای اندازه‌گیری خطای پیش بینی در این مطالعه MSE کمتر از 0.5 گزارش شد.
- مقایسه با روش تجربی: به‌منظور 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.

۷- نتیجه‌گیری

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 سازه‌ای 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، درنتیجه 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 سیکلی حاصل از انتشار موج‌برشی 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 سیکلی به یک المان ماسه سست، تمایل به تراکم و درنتیجه 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 درنتیجه 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 مورداستفاده بستگی دارد. برای این منظور ابتدا بانک اطلاعاتی و پارامترهای ورودی و خروجی تعیین‌شده‌اند. همان‌طور که قبلاً ذکرشده در انتخاب پارامترهای ورودی سعی شده است تا پارامترهایی انتخاب گردند که از معمول‌ترین آزمون‌های مطالعات ژئوتکنیک حاصل شوند. باتوجه‌به حدود ۱۰۰ داده موجود در محدوده استان‌های شمالی کشور که از نتایج مطالعات ژئوتکنیک و همچنین تحلیل و ارزیابی محاسبات پتانسیل روانگرایی حاصل‌شده‌اند، پارامترهای ورودی و خروجی مطابق جدول (۱) انتخاب‌شده‌اند.

برای پیاده‌سازی کدنویسی مورداستفاده، آموزش و ارزیابی آن‌ها از نرم‌افزار MATLAB 9.5 (20018b) استفاده‌شده است. این نرم‌افزار باتوجه‌به توابع متعدد، قابلیت برنامه‌نویسی، الگوریتم‌های آموزشی و ساختارهای متعدد برای شبکه‌های عصبی و قدرت پردازش و تحلیل‌های آماری در حل مسائل مهندسی بسیار موردتوجه محققین بوده است. کدنویسی انجام‌شده در نرم‌افزار متلب قابل‌ارائه بوده و مطابق شرایط مقاله در این قسمت ارائه نشده است. همچنین جهت ارزیابی کارایی روش یادگیری عمیق از دو شاخص ارزیابی استفاده‌شده است. ضریب رگرسیون (R) و شاخص خطا (MSE) که در شکل‌های ادامه ارائه‌شده‌اند. روش‌های یادگیری عمیق و الگوریتم‌های یادگیری ماشین بسیار پرکاربرد بوده و در صورت وجود داده‌های قابل‌اطمینان و مناسب ازلحاظ 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 گزارش‌شده و در این شاخص نیز مشاهده می‌گردد که روش ترکیبی معرفی‌شده 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

[۱۰]. 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

[۱۱]. Cetin, K. and H. Bilge, *Recent advances in seismic soil liquefaction engineering.* The Evolution of Geotech-25 Years of Innovation, 2021: p. 18-42.

[۱۲]. 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

[13]. 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

[14]. Nurhikmat, T., *Implementasi deep learning untuk image classification menggunakan algoritma Convolutional Neural Network (CNN) pada citra wayang golek.* 2018. https://dspace.uii.ac.id/handle/123456789/7843

[15]. 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

[16]. 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

histories. Journal of Performance of Constructed Facilities, 2019. **33**(3): p. 04019024. 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

[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

[۸]. 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

[۹]. 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

[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)

[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. rg/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/cmes.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

[۲۳]. 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

[۳۹]. 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 artifitial 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

[۳۲]. 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

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

[۳۴]. 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)

.

[۳۵]. 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.

[۳۶]. 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)

[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.