

Assessment of Soil Liquefaction Potential Using a Hybrid Artificial Neural Network and Fuzzy Logic Approach (Case Study: Northern Iran)

Shima Aghakasiri *

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

Mohammad Emami Kourandeh

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

Sanaz Aghakasiri

Department of Civil Engineering, Babol Noshirvani University of Technology, Babol, Iran.

Saeed Farrokhi zadeh

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

sh.aghakasiri@iau.ir

Keywords:

liquefaction,

sandy soils,

Artificial neural network,

fuzzy,

cone penetration test.

Abstract

Soil liquefaction is one of the most destructive geotechnical phenomena in seismic-prone regions and can lead to severe damage to structures and infrastructure. In this study, the liquefaction potential of soils in northern Iran is evaluated using a hybrid approach based on artificial neural networks (ANN) and fuzzy logic analysis. For this purpose, a comprehensive dataset comprising geotechnical and seismic information including cone penetration test (CPT) results, in-situ soil properties, groundwater table level, and peak ground acceleration collected over recent years was compiled and analyzed. Initially, the liquefaction potential was assessed using conventional numerical methods, and the obtained results were subsequently employed as training data for the ANN and fuzzy models. The performance of the developed models was evaluated using appropriate statistical indicators. The results demonstrate that soft computing techniques provide higher prediction accuracy compared to classical numerical methods. The findings highlight the strong capability of intelligent approaches in modeling complex geotechnical phenomena and their effectiveness in assessing liquefaction hazards 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

ارزیابی پتانسیل روانگرایی خاک با استفاده از رویکرد ترکیبی شبکه‌های عصبی مصنوعی و منطق فازی (مطالعه موردی: شمال ایران)

شیما آقاکیتری*

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

محمد امامی کورنده

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

ساناز آقاکیتری

گروه مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، مازندران، ایران

سعید فرخی‌زاده

گروه مهندسی عمران، دانشگاه صنعتی نوشیروانی بابل، مازندران، ایران

sh.aghakasiri@iau.ir

تاریخ پذیرش: ۰۷ بهمن ۱۴۰۴

تاریخ دریافت: ۱۰ اردیبهشت ۱۴۰۴

چکیده

روانگرایی خاک یکی از پدیده‌های مخرب ژئوتکنیکی در مناطق لرزه‌خیز به شمار می‌رود که می‌تواند موجب خسارات گسترده به سازه‌ها و زیرساخت‌ها گردد. در این پژوهش، پتانسیل روانگرایی خاک در شمال ایران با استفاده از رویکرد ترکیبی شبکه‌های عصبی مصنوعی و تحلیل فازی مورد ارزیابی قرار گرفته است. بدین منظور، مجموعه‌ای از داده‌های ژئوتکنیکی و لرزه‌ای شامل نتایج آزمایش‌های CPT، مشخصات خاک در محل، سطح آب زیرزمینی و شتاب حداکثر زمین، مربوط به بازه زمانی سال‌های اخیر گردآوری و تحلیل شد. ابتدا ارزیابی پتانسیل روانگرایی با استفاده از روش‌های عددی متداول انجام گرفت و سپس نتایج حاصل به‌عنوان داده آموزشی برای مدل‌های شبکه عصبی و فازی مورد استفاده قرار گرفت. عملکرد مدل‌ها با معیارهای آماری مناسب مورد سنجش قرار گرفت و نتایج نشان داد که روش‌های محاسبات نرم، دقت بالاتری در پیش‌بینی پتانسیل روانگرایی نسبت به روش‌های عددی کلاسیک ارائه می‌دهند. نتایج این تحقیق بیانگر توانایی بالای رویکردهای هوشمند در تحلیل پدیده‌های پیچیده ژئوتکنیکی و کاربرد آن‌ها در ارزیابی خطر روانگرایی در مناطق لرزه‌خیز است.

کلیدواژه‌ها: روانگرایی، خاک ماسه‌ای، آزمایش مقاومت مخروط، شبکه ANN، شبکه عصبی فازی

*نویسنده مسئول مکاتبات

۱- مقدمه

روانگرایی یکی از مهم‌ترین موضوعات در مهندسی ژئوتکنیک لرزه‌ای است. در سال ۱۹۶۴، دو زلزله در آلاسکا و نیگاتا ژاپن رخ داد که هر دو نمونه‌های بارزی از خرابی‌های ناشی از زلزله مانند گسیختگی شیب‌ها، شالوده و پل‌ها، و شناوری سازه‌های مدفون به دلیل روان شدن خاک بستر را نشان دادند. همچنین، زلزله ۱۹۹۰ منجیل در ایران نیز خرابی‌های قابل‌توجهی ناشی از روانگرایی به‌جا گذاشت. پس‌ازاین زلزله‌ها، پدیده روانگرایی به‌طور گسترده توسط محققان موردبررسی قرار گرفت [۱]. زلزله نیگاتا ژاپن در سال ۱۹۶۴ نماد اولین رخدادی است که منجر به ویرانی زیرساخت‌های مدرن شد و بعدها به‌عنوان پدیده روانگرایی شناخته شد [۲]. هنگام وقوع زلزله، امواج لرزه‌ای از منبع به اطراف منتشر می‌شوند و با سرعت از میان پوسته زمین عبور می‌کنند. طبیعت و توزیع خرابی زلزله‌ها به‌شدت به پاسخ خاک نسبت به بارهای دینامیکی زلزله وابسته است و این پاسخ نیز تا حد زیادی توسط خصوصیات دینامیکی خاک ازجمله سختی، میرایی، نسبت پواسون و دانسیته خاک کنترل می‌شود [۳]. یکی از عوامل عمده که جنبش نیرومند زمین و خرابی سازه‌ها را در خلال زمین‌لرزه کنترل می‌کند، سرعت موج‌برشی رسوبات سطحی تا سنگ کف است [۴]. سرعت موج‌برشی نشان‌دهنده نوع مصالح و شرایط ساختاری خاک است و می‌تواند برای ارزیابی ساختار لایه‌ها، درجه تراکم یا تحکیم خاک نرم، و تشخیص پهنه‌های ضعیف ساختگاه به‌کاربرده شود [۵].

هوش مصنوعی (AI) و یادگیری عمیق همیشه با یادگیری ماشین مرتبط هستند و بسیاری از شرکت‌ها در اندونزی اغلب از فناوری هوش مصنوعی استفاده می‌کنند. استفاده از این فناوری می‌تواند وظایف را با موفقیت بیشتری انجام دهد زیرا هوش مصنوعی می‌تواند وظایف را با فرض ذهنیت انسانی انجام دهد. یک تکنیک یادگیری ماشینی به نام یادگیری عمیق برای تطبیق مداوم در سطح معینی طراحی شده است که در آن سطح مورد نظر انتزاع را می‌توان تغییر داد [۶]. چن و همکاران در سال ۲۰۱۶ به بررسی روش‌های تجربی موجود برای برآورد پتانسیل روانگرایی با استفاده از داده‌های مربوط به زلزله تایوان باهدف یافتن روشی مناسب برای پیش‌بینی روانگرایی در کشور تایوان پرداختند و در نتیجه برای عمق‌های مختلف خاک میزان درستی هر یک از روش‌ها بررسی شده است [۷]. در تحقیق دیگری استفاده از مدل رفتاری مناسب با نوع خاک و یا مسئله ژئوتکنیکی در دقت مدل‌سازی تأثیر بسزایی دارد. جواد و تان در سال ۲۰۰۹ از مدل رفتاری هوشمند با استفاده از شبکه عصبی در چهارچوب اجزا محدود استفاده کردند. روش پیشنهادی ترکیبی از شبکه عصبی و اجزا محدود به‌عنوان زیرمجموعه‌ای از مدل رفتاری مصالح است. شبکه عصبی با استفاده از داده‌های خام آموزش دید. سپس از شبکه عصبی جهت پیش‌بینی رفتار تنش-کرنش مصالح در تحلیل اجزا محدود استفاده شد [۸]. ژائو و همکاران در سال ۲۰۲۱ یک حالت ماشین یادگیری برای ارزیابی پتانسیل روانگرایی خاک با استفاده از آزمایش نفوذ مخروط (CPT) و پایگاه داده سرعت موج برشی (Vs) پیشنهاد کردند [۹]. ارزیابی پتانسیل روانگرایی در لایه‌های خاکی با کاربرد

نتایج آزمون مقاومت نفوذ مخروط (CPT) بر اساس منطق فازی تحقیقی است که توسط محققین در سال ۱۴۰۱ انجام شده است [۱۰]. ارزیابی بروز پدیده روانگرایی مبتنی بر انرژی کرنشی با استفاده از الگوریتم برنامه‌نویسی بیان ژنی تحقیق دیگری است که توسط طهماسب و جاودانیان در سال ۱۴۰۲ انجام شده است [۱۱]. در سال ۱۴۰۲ محققین به ارزیابی و پهنه‌بندی مخاطره روانگرایی با استفاده از مدل فازی ویکور، مطالعه موردی: مخروط افکنه لیلان شمال غرب ایران پرداختند [۱۲].

مروری بر مطالعات در زمینه تحقیق حاضر نشان می‌دهد که کاربرد روش‌های محاسبات نرم در خصوص پیش‌بینی پتانسیل روانگرایی خاک در سال‌های اخیر توسعه یافته است.

۲- مبانی نظری تحقیق

خاک‌ها به‌طور کلی پیچیده و مبهم هستند که منجر به ترکیب نامنسجم، عدم دقت در نمونه‌برداری از خاک، حفاری، مشخصه‌یابی، آزمایش میدانی، آزمایش آزمایشگاهی و عدم قطعیت می‌شود [۱۳]. در طول چند دهه گذشته، رویکردهای زیادی برای پیش‌بینی پتانسیل روانگرایی لرزه‌ای نهشته‌های خاک، ازجمله روش‌های میدانی (بر اساس سرعت موج برشی، مبتنی بر CPT و مبتنی بر SPT (Standard Penetration Test)، تحلیلی (تجربی یا نیمه تجربی) روش‌های سیستم اطلاعات جغرافیایی، روش‌های عددی، روش‌های آزمایشگاهی (مانند آزمایش سه محوری چرخه‌ای و مدل‌سازی سانتیفریوژ)، هوش مصنوعی و روش‌های مبتنی بر محاسبات نرم مورد بررسی قرار گرفته‌اند [۱۴].

روانگرایی لرزه‌ای خاک به دلیل پتانسیل ایجاد آسیب شدید سازه‌ای، تغییر شکل زمین و از دست دادن ظرفیت باربری، نگرانی عمده‌ای در مهندسی زلزله ژئوتکنیک است. روش‌های ارزیابی تجربی و نیمه‌تجربی سنتی مبتنی بر آزمایش نفوذ مخروط (CPT) به دلیل کاربردی بودن، تکرارپذیری و همبستگی قوی با رفتار خاک درجا، به‌طور گسترده در عمل مورد استفاده قرار گرفته‌اند. با این حال، این روش‌ها اغلب به منحنی‌های مرزی ساده‌شده و ضرایب اصلاحی متکی هستند که ممکن است به‌طور کامل غیرخطی بودن ذاتی، تغییرپذیری مکانی و عدم قطعیت مرتبط با بافت خاک و بارگذاری لرزه‌ای را در بر نگیرند [۱۵، ۱۶]. یک چارچوب پیش‌بینی روانگرایی خاک مبتنی بر مجموعه را با استفاده از ویژگی‌های CPT توسط محققین ارزیابی شد و نشان دادند که ترکیب مجموعه، استحکام را افزایش داده و قابلیت اطمینان پیش‌بینی را در شرایط عدم تعادل داده‌ها بهبود می‌بخشد [۱۷]. به‌طور مشابه، در تحقیق دیگری یک طبقه‌بندی‌کننده‌ی گروهی رأی‌دهنده استفاده شد که بهبودهای قابل توجهی را در پیش‌بینی حساسیت به روانگرایی و کاهش بیش‌برازش نسبت به طبقه‌بندی‌کننده‌های یادگیری ماشین مستقل نشان می‌دهد [۱۸]. یک روش ترکیبی عددی-احتمالاتی برای پیش‌بینی نشست ناشی از روانگرایی با استفاده از پارامترهای ورودی CPT توسط محققین ارائه شد آنها تأیید کردند که گنجاندن اصلاحات مدل‌سازی مکانیکی در ML، دقت پیش‌بینی نشست پیوسته را بهبود

در سال ۲۰۲۴، ارزیابی روانگرایی خاک با داده‌های CPT و سرعت موج برشی (VS) و خوشه‌بندی فازی پیشنهاد شد. این کار به بررسی کارایی رویکردهای ترکیبی ANN و روش‌های داده‌محور در پیش‌بینی روانگرایی پرداخته است. [۳۲]. و در سال ۲۰۱۹، طبقه‌بندی‌کننده ماشین بردار پشتیبان فازی با استفاده از الگوریتم‌های بهینه‌سازی برای مسئله پیش‌بینی روان‌گرایی بهبود یافته و ادعا شد که به ۱۰۰٪ دقت طبقه‌بندی دست یافته‌اند. [۳۰]. مدل‌های مبتنی بر شبکه‌های عصبی مصنوعی (ANN) نشان دادند که می‌توانند الگوهای رفتاری پیچیده خاک را ثبت کنند، اما به حساسیت به مجموعه داده‌های آموزشی و کاهش تعمیم‌پذیری به دلیل قابلیت تفسیر محدود اشاره شده است. [۳۳]. رویکرد پیش‌بینی مبتنی بر ANN برای پیش‌بینی پتانسیل روانگرایی برای طیف خاصی از خواص خاک پیشنهاد شده است. با توجه به اینکه ANN ابزار قابل‌اعتمادی برای پیش‌بینی پاسخ است، استفاده از این روش هوشمند چالش‌برانگیز است و به آن پرداخته شده است. هدف اصلی ارائه‌شده، استفاده از چند تکنیک هوشمند جهت غلبه بر مسائل مرتبط با روانگرایی است. [۳۴]. از شبکه‌های عصبی مصنوعی با الگوریتم انتشار پشت‌سرانه برای تعیین وقوع روانگرایی در سایت‌های مختلف بر اساس نتایج CPT استفاده شده است. [۳۵]. یک مدل شبکه عصبی فازی برای ارزیابی پتانسیل روانگرایی خاک‌ها با پایگاه داده میدان CPT که شامل سوابق روانگرایی واقعی از بیش از ۱۱ زلزله بزرگ بین سال‌های ۱۹۶۴ و ۱۹۹۹ است ایجاد شده است. [۲۳]. سه مدل ANN برای ارزیابی پتانسیل روانگرایی خاک بر اساس داده‌های CPT پیشنهاد شده‌اند. [۳۶].

۳- روش تحقیق

در این مقاله، روش تحقیق به‌گونه‌ای طراحی شده است که به پاسخ‌های سؤالات اصلی و فرعی تحقیق دست یابد. همچنین هدف از این تحقیق، شناسایی بهترین مدل برای به‌کارگیری در تمام خاک‌های ماسه‌ای مستعد خطر روانگرایی با داده‌های ژئوتکنیکی مشابه است. فرایند و متدولوژی اجرای این تحقیق شامل چندین مرحله است که در برخی موارد به‌صورت هم‌زمان پیش می‌روند. این مراحل به شرح زیر است:

- ۱- شناسایی کامل خطر روانگرایی و محاسبات پتانسیل روانگرایی
- ۲- تحلیل و ارزیابی پتانسیل روانگرایی باتوجه‌به آزمون CPT و اثر زلزله احتمالی در پروژه‌های استان‌های شمالی کشور
- ۳- جمع‌آوری اطلاعات لازم جهت آموزش شبکه عصبی مصنوعی و روش یادگیری عمیق
- ۴- تجزیه و تحلیل بانک اطلاعاتی جمع‌آوری‌شده و حذف داده‌های خارج از محدوده
- ۵- تعیین پارامترهای ورودی و خروجی در روش‌های محاسباتی
- ۶- کدنویسی روش یادگیری عمیق با ترکیب روش شبکه عصبی ANN و شبکه عصبی فازی
- ۷- پیاده‌سازی روش‌های یادگیری عمیق بر روی بانک اطلاعاتی

می‌بخشد [۱۹]. در تحقیقی دیگر یک ترکیب مقایسه‌ای از معماری‌های عصبی گروهی و عمیق ارائه دادند که بهبودهای قابل توجه عملکرد را برجسته می‌کند، اما بر نیاز به تفسیرپذیری قوی‌تر و اعتبارسنجی استاندارد تأکید دارد [۲۰].


ارزیابی پتانسیل روانگرایی زمین‌لرزه‌ای به دلیل پیچیدگی و عدم قطعیت موجود در پارامترهای زلزله و خاک و شرایط مکان، یک موضوع احتمالی است تا قطعی. روش‌های قطعی قبلی پتانسیل روانگرایی لرزه‌ای خاک هیچ بینشی در مورد احتمال روانگرایی نشان نمی‌دهند و تنها ارائه می‌دهند که آیا روانگرایی زمین‌لرزه‌ای رخ می‌دهد یا خیر. روش‌های احتمالی در حال حاضر می‌توانند نیازهای مهندسی تحلیل ریسک لرزه‌ای را بهتر برآورده کنند. در چند دهه اخیر، با افزایش انباشت داده‌های درجا، روش‌های محاسباتی نرم، مانند شبکه عصبی مصنوعی (ANN) [۲۱].

تأثیر پارامترهای مؤثر بر روانگرایی خاک کاملاً متغیر است. ازجمله این روش‌ها برای تعیین پتانسیل روانگرایی خاک، استفاده از مدل‌سازی احتمالی یا پیچیده‌تر دینامیکی است. همچنین علاوه بر این روش‌ها، اخیراً از روش‌های محاسباتی نرم مانند هوش مصنوعی، منطق فازی، الگوریتم ژنتیک یا ترکیبی برای تخمین ریسک روانگرایی خاک استفاده شده است. روانگرایی محاسباتی خاک در سال ۲۰۱۲ با استفاده از رویکرد عصبی-فازی، با سایر روش‌های مرسوم مقایسه شد [۲۲]. در سال ۲۰۰۸، ترکیب نظریه فازی با الگوریتم‌های ژنتیک برای ارزیابی پتانسیل روانگرایی ناشی از زلزله و تخمین ریسک روانگرایی خاک بر اساس منطق فازی با استفاده از شبکه عصبی فازی انجام شد [۲۳].

اخیراً روش‌های محاسباتی نرم، به‌ویژه شبکه‌های عصبی مصنوعی ANN، در راه‌حل‌های عملی مسائل مهندسی ژئوتکنیک مانند ظرفیت باربری پی‌های کم‌عمق و شمع، پایداری شیب، رفتار نشست و پارامترهای تراکم‌پذیری خاک‌ها رایج شده‌اند [۲۴]. علاوه بر این، پتانسیل روانگرایی خاک با استفاده از کاربردهای مختلف هوش مصنوعی در ۲۰ سال گذشته سعی شده است، پیش‌بینی شود [۲۵]. در سال‌های ۱۹۹۴، ۱۹۹۶ و ۲۰۰۲، مدل‌های مختلف شبکه‌های عصبی مصنوعی (ANN) برای پیش‌بینی پتانسیل روانگرایی خاک‌ها پیشنهاد شدند. این مدل‌ها بر پایه داده‌های میدان واقعی با استفاده از شاخص‌های SPT، CPT و سرعت موج‌برشی انجام شدند. [۲۶-۲۸] در سال ۱۹۹۹ مقاومت روانگرایی خاک‌های ماسه‌ای با مدل‌های مختلف ANN ارزیابی شد که از پایگاه داده تاریخی شامل اندازه‌گیری‌های CPT نیز استفاده می‌کرد. این بررسی نشان می‌دهد که ترکیب داده‌های CPT با ANN می‌تواند به بهبود پیش‌بینی کمک کند. [۲۹]. در سال ۲۰۱۹ به بررسی بهبود پیش‌بینی روانگرایی خاک با استفاده از الگوریتم‌های بهینه‌سازی ترکیبی و ماشین پشتیبان برداری فازی پرداختند. [۳۰]. در سال ۲۰۲۱ به تحلیل عدم قطعیت گسترش جانبی ناشی از روانگرایی پرداخته شد و از متغیرهای فازی همراه با الگوریتم ژنتیک برای مدلسازی و کاهش عدم قطعیت استفاده کردند. [۳۱].

جمع‌آوری شده

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



شکل ۱- نمودار شماتیک روند کلی پژوهش برای ارزیابی پتانسیل روانگرایی خاک

این شکل روند کلی انجام پژوهش را از مرحله گردآوری داده‌های ژئوتکنیکی تا پیش‌بینی نهایی وقوع یا عدم وقوع روانگرایی نشان می‌دهد. در گام نخست، داده‌های حاصل از آزمایش نفوذ مخروط (CPT) شامل پارامترهای مؤثر بر رفتار لرزه‌ای خاک گردآوری و پیش‌پردازش شدند. سپس ارزیابی پتانسیل روانگرایی به صورت موازی با استفاده از روش عددی مبتنی بر CPT و مدل‌های محاسبات نرم شامل شبکه عصبی مصنوعی و منطق فازی انجام گرفت. در ادامه، نتایج مدل‌ها مورد مقایسه و اعتبارسنجی قرار گرفته و در نهایت، وضعیت روانگرایی خاک به صورت دودویی (روانگرا / غیرروانگرا) تعیین شد.

۳-۱- محاسبه خطر روانگرایی

تعیین مقاومت روانگرایی خاک بر اساس نتایج تجزیه و تحلیل مستلزم محاسبه یا برآورد دو متغیر است. پارامتر اول نسبت تنش چرخه‌ای (CSR) است که نشان‌دهنده سطح بارگذاری چرخه‌ای است که می‌تواند توسط زلزله ایجاد شود و پارامتر دوم میزان مقاومت چرخه‌ای (CRR) است که نشان‌دهنده مقاومت خاک در برابر روانگرایی است. نسبت تنش چرخه‌ای ایجاد شده در طول زلزله (CSR) توسط سید و ادريس (۱۹۷۱) مطابق معادله تعریف شده است [۳۷]:

$$CSR = 0.65 * \frac{a_{max}}{g} * \frac{\sigma_v}{\sigma_v'} * r_d \quad (1)$$

a_{max} ، اوج شتاب افقی در سطح زمین در هنگام زلزله است. g ، شتاب گرانشی σ_v و σ_v' تنش کلی و مؤثر؛ r_d ضریب کاهش تنش. مقادیر متوسط برای r_d بسته به عمق توسط لیاثو و ویتمن در سال ۱۹۸۶ در کاربردهای مهندسی استفاده می‌شود، تعریف شده است [۳۸]:

$$r_d = \begin{cases} 1.0 - 0.00765z, & z \leq 9.15m \\ 1.174 - 0.0267z, & 9.15 < z \leq 23m \end{cases} \quad (2)$$

(z) عمق (برحسب متر) است. نرخ مقاومت چرخه‌ای (CRR) نیز توسط رابرتسون و راید در سال ۱۹۹۸ [۳۹] به صورت زیر تعریف شده است. در این روش، لازم است در هنگام تعیین مقاومت روانگرایی در استفاده از مقاومت نوک نفوذ مخروط اصلاح شده برای تنش روباره (q_{c1N}) تنظیماتی انجام شود. پارامتر q_{c1} همان طور که در معادلات زیر نشان داده شده است با استفاده از ضریب اصلاح بار لایه بالایی (C_Q) نرمال می‌شود:

$$q_{c1N} = \left(\frac{q_c}{P_{a2}} \right) C_Q = \left(\frac{q_{c1}}{P_{a2}} \right) \quad (3)$$

$$C_Q = \left(\frac{P_a}{\sigma_{vo}'} \right)^n \quad (4)$$

درجایی که q_c اندازه‌گیری مقاومت در برابر نفوذ نوک مخروط است C_Q ضریب اصلاح بار لایه بالایی برای مقاومت در برابر نفوذ مخروط است، P_a فشار مرجع در واحدهای مشابه σ_{vo}' است (یعنی $P_a = 100$ کیلو پاسکال اگر σ_{vo}' برحسب کیلو پاسکال است و P_{a2} یک فشار مرجع در همان واحدهای q_c است. به عنوان مثال، P_{a2} مساوی 0.1 مگا پاسکال اگر q_c برحسب مگاپاسکال باشد، n ضریب آن با نوع خاک متفاوت است و معمولاً برابر با 0.5 است. حداکثر مقدار $C_Q = 2$ به طور کلی برای داده‌های CPT در اعماق کم اعمال می‌شود. مقاومت نرمال شده در برابر نفوذ مخروط، q_{c1N} بدون بعد است. رابرتسون و راید (۱۹۹۸) مشخص کردند [۳۹]، نسبت اصطکاک CPT با افزایش ریزدانه و انعطاف‌پذیری خاک افزایش می‌یابد. ویژگی‌های دانه خاک‌های شنی را می‌توان به طور مستقیم از داده‌های CPT با استفاده از هر یک از این نمودارهای رفتار خاک که در شکل ۲ نشان داده شده است تخمین زد [۴۰]. همچنین؛ با استفاده از نمودار CPT توسط رابرتسون در سال ۱۹۹۰، شاخص نوع رفتار خاک، I_c ، را می‌توان به صورت زیر تعریف کرد [۴۰]:

$$I_c = [(3.47 + Q)^2 + (\log F + 1.22)^2]^{0.5} \quad (5)$$

$$Q = \left(\frac{q_c - \sigma_{vo}}{P_{a2}} \right) \left(\frac{P_a}{\sigma_{vo}'} \right)^n \quad (6)$$

$$F = \left[\frac{f_s}{q_c - \sigma_{vo}} \right] \quad (7)$$

که در آن Q مقاومت نوک نرمال شده، F نسبت اصطکاک نرمال شده، توان n معمولاً برابر با $1/0$ است، σ_{vo}' و σ_{vo} به ترتیب تنش‌های کل و مؤثر روباره هستند. مرزهای نوع رفتار خاک برحسب شاخص I_c در جدول ۱ نشان داده شده است. معادله پیشنهادی برای به دست آوردن معادل مقاومت در برابر نفوذ CPT نرمال شده با شن تمیز، $(q_{c1N})_{CS}$ ، تابعی از مقاومت نفوذ اندازه‌گیری شده، q_{c1N} و ویژگی‌های دانه خاک، به شرح زیر است:

$$(q_{c1N})_{CS} = K_c q_{c1N} \quad (8)$$

مستقیم از داده‌های CPT اندازه‌گیری شده ترکیب کرد. سپس، با استفاده از معادل مقاومت نفوذ نرمال شده شن تمیز $(q_{c1N})_{CS}$ ، CRR برای $(M=7.5)$ را می‌توان با استفاده از معادله ساده‌شده زیر تخمین زد:

$$\text{IF } 50 \leq (q_{c1N})_{CS} < 160, \quad (11)$$

$$\text{CRR} = 93 \left[\frac{(q_{c1N})_{CS}}{1000} \right]^3 + 0.08$$

$$\text{IF } (q_{c1N})_{CS} < 50, \quad \text{CRR} = 0.833 \left[\frac{(q_{c1N})_{CS}}{1000} \right]^3 + 0.05 \quad (12)$$

۳-۲- ارزیابی پتانسیل روانگرایی به روش عددی

در گام نخست، پتانسیل روانگرایی خاک با استفاده از روش‌های عددی و تجربی مبتنی بر CPT ارزیابی شد. ضریب اطمینان در برابر روانگرایی به صورت زیر تعریف گردید:


$$\text{FS} = \frac{\text{CRR}}{\text{CSR}} \quad (13)$$

که در آن:


CRR: نسبت مقاومت سیکلی خاک

CSR: نسبت تنش سیکلی ناشی از زلزله

پارامتر CSR با استفاده از شتاب حداکثر سطح زمین (PGA)، تنش مؤثر قائم، عمق و ضریب کاهش تنش محاسبه شد. اگرچه مقدار PGA برابر 0.3g در نظر گرفته شده است، اما به دلیل سطح بالای آب زیرزمینی و خاک‌های سست دانه‌ای، احتمال وقوع روانگرایی همچنان قابل توجه است [۳۷، ۴۱].



شکل ۳- تغییرات ضریب اطمینان در برابر روانگرایی در لایه‌های مختلف خاک



شکل ۲. نمودار نوع رفتار خاک CPT نرمال شده، که توسط رابرتسون در سال ۱۹۹۰ پیشنهاد شده است [۴۰].

جدول ۱- مرزهای نوع رفتار خاک [۴۰]

نوع رفتار خاک (شکل ۱)	طبقه‌بندی
شن و ماسه به ماسه متراکم	۷
ماسه: ماسه تمیز تا ماسه سیلتی	۶
مخلوط ماسه: ماسه سیلتی به ماسه لای دار	۵
مخلوط‌های سیلت: رس لای دار تا خاک رس سیلتی	۴
خاک رس: خاک رس سیلتی تا خاک رس	۳
خاک‌های آلی	۲

در اینجا (K_c) ضریب تصحیح است که ساختار دانه‌ای خاک را بیان می‌کند و با استفاده از معادله ۹ و ۱۰ به شرح زیر تعیین می‌شود:

$$\text{If } I_c \leq 1.64, \quad K_c = 1 \quad (9)$$

$$K_c = -0.403 I_c^4 + 5.581. \quad (10)$$

$$I_c^3 - 21.63. \quad I_c^2 + 33.75. \quad I_c - 17.88.$$

اگر $I_c > 2.6$ باشد، داده‌ها باید مستقیماً در نمودار رابرتسون رسم

شوند و $q_{c1N} = Q$ را فرض کرد.

اگر $I_c \leq 2.6$ باشد، توان برای محاسبه Q باید به $n = 0.5$ تغییر

کند (یعنی اساساً q_{c1N} را با استفاده از معادله (۳) محاسبه کنید، زیرا $q_c < \sigma_{vo}$ و I_c باید بر اساس q_{c1N} و F دوباره محاسبه شوند. اگر I_c محاسبه شده مجدد کمتر از $2/6$ باقی می‌ماند، داده‌ها باید در نمودار رابرتسون با استفاده از q_{c1N} بر اساس $n = 0.5$ رسم شوند.

بالین حال، اگر I_c بالاتر و کمتر از مقدار $2/6$ تکرار شود، بسته به اینکه کدام مقدار از n استفاده می‌شود، مقدار $n = 0.75$ باید برای محاسبه q_{c1N} انتخاب شود. معادلات ۵، ۸ و ۹ را می‌توان برای تخمین معادل مقاومت نفوذ نرمال شده شن تمیز، $(q_{c1N})_{CS}$ ، به‌طور

برای بررسی روانگرایی خاک‌های ریزدانه از معیارهای بولانگر و ادریس (۲۰۰۵) [۴۲] و بری و سانکیو (۲۰۰۶) [۴۳] استفاده شده است. این معیارها بر اساس نسبت درصد رطوبت خاک به حد روانی آن و خواص خمیری خاک، شاخص روانگرایی را معین می‌کنند. هر چه این ضریب به ۰ نزدیک باشد خاک دارای رفتار رسی و هر چه به ۱ نزدیک باشد، خاک ریزدانه رفتار ماسه‌ای می‌باشد. 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 روانگرایی است. برای خاک‌های ریزدانه دارای استعداد روانگرایی می‌توان از معیارهای یاد شده برای خاک‌های ماسه‌ای بهره گرفت. نمونه‌ای از تغییرات ضریب اطمینان در برابر روانگرایی در لایه‌های مختلف خاک در شکل ۳ نشان داده شده است.

۳-۳-۳- انجام آزمایش CPT و صحت‌سنجی داده‌ها

آزمایش نفوذ مخروط (CPT) مطابق با استاندارد ASTM D5778 انجام شده است. در این آزمایش، مقاومت نوک مخروط (q_c)، اصطکاک جانبی (f_s) و در برخی موارد فشار آب منفذی اندازه‌گیری شده است. آزمایش‌ها به صورت پیوسته در عمق انجام شده و اطلاعات دقیقی از رفتار لایه‌های خاک فراهم نموده‌اند.

برای اطمینان از صحت داده‌ها:

- دستگاه‌ها پیش از انجام آزمایش کالیبره شده‌اند؛
- داده‌های غیرمنطقی و پرت حذف شده‌اند؛
- نتایج CPT با لاگ گمانه‌ها و طبقه‌بندی آزمایشگاهی خاک تطبیق داده شده است.

۳-۴- تحلیل لرزه ای

باتوجه به شواهد مستند از زمین‌لرزه‌های مخرب گذشته، وقوع پدیده روانگرایی عمدتاً در زلزله‌هایی با شتاب حداکثر زمین بیش از 0.25g تا 0.3g گزارش شده است. در زلزله نیگاتا ژاپن (۱۹۶۴) و زلزله کوبه (۱۹۹۵)، مقادیر شتاب حداکثر زمین ثبت شده در ایستگاه‌های مجاور مناطق دچار روانگرایی به طور گسترده در بازه 0.3g تا 0.6g گزارش شده است. به طور مشابه، در زلزله کریستچرچ نیوزیلند (۲۰۱۱) و زلزله لوما پریتا آمریکا (۱۹۸۹)، وقوع روانگرایی گسترده عمدتاً در مناطقی مشاهده شده که شتاب حداکثر زمین از حدود 0.3g فراتر رفته است [۴۴، ۴۵].

براین اساس، در پژوهش حاضر مقدار $a_{max} = 0.3g$ به عنوان یک سطح شتاب نماینده و محافظه کارانه برای ارزیابی پتانسیل روانگرایی انتخاب شده است. این مقدار نه تنها با داده‌های ثبت شده زلزله‌های واقعی سازگار است، بلکه مطابق با توصیه‌های ارائه شده در مطالعات کلاسیک و آیین‌نامه‌های روانگرایی می‌باشد. انتخاب این سطح شتاب امکان بررسی رفتار خاک‌های مستعد روانگرایی تحت تحریک لرزه‌ای متوسط تا نسبتاً شدید را فراهم کرده و موجب افزایش قابلیت تعمیم نتایج پژوهش برای کاربردهای مهندسی می‌شود.

۳-۵- شبکه‌های عصبی مورد استفاده در مقاله

در این مقاله، از الگوریتم‌های شبکه عصبی ANN و شبکه فازی برای پیش‌بینی پتانسیل روانگرایی استفاده شده است و نتایج به دست آمده با هم مقایسه شده است.

۳-۵-۱- شبکه عصبی ANN


ایده‌ای برای پردازش اطلاعات است که از سیستم عصبی بیولوژیکی الهام گرفته شده و اطلاعات مشابه مغز را پردازش می‌کند. یک عنصر کلیدی این ایده ساختار جدید سیستم پردازش اطلاعات است که از تعداد زیادی عناصر پردازشی بسیار به هم پیوسته به نام نورون‌ها تشکیل شده است که برای حل یک مشکل با هم کار می‌کنند. مشابه انسان‌ها، شبکه‌های عصبی مصنوعی با مثال یاد می‌گیرند و یک شبکه عصبی برای انجام وظایف خاص، مانند شناسایی الگوها و دسته‌بندی اطلاعات، در طول یک فرایند یادگیری راه‌اندازی می‌شود. در سیستم‌های بیولوژیکی، یادگیری با تنظیماتی در ارتباطات سیناپسی بین اعصاب همراه است. این روش در شبکه‌های عصبی نیز کاربرد دارد. ANN ها دانش یا قانون پشت داده‌ها را با پردازش داده‌های تجربی به ساختار شبکه منتقل می‌کنند که به آن یادگیری می‌گویند. توانایی یادگیری اساساً مهم‌ترین ویژگی یک سیستم هوشمند است. سیستمی که قادر به یادگیری باشد، انعطاف‌پذیرتر است، برنامه‌ریزی آن آسان‌تر است و می‌تواند بهتر به مسائل و معادلات جدید پاسخ دهد. ساختار شبکه عصبی انسان مدت‌هاست که برای درک یو فیزیولوژی مغز جستجو می‌شود. درواقع همیشه برای انسان جالب بوده که باهوش باشد، توانایی تعمیم، خلاقیت، انعطاف‌پذیری و پردازش موازی در مغز داشته باشد و از این قابلیت‌ها در ماشین‌ها به خوبی استفاده کند. روش‌های الگوریتمی برای پیاده‌سازی این ویژگی‌ها در ماشین‌ها مناسب نیستند و بنابراین روش‌ها باید بر اساس همان مدل‌های بیولوژیکی ابداع شوند. به عبارت دیگر، شبکه عصبی یک سیستم پردازش داده است که از مغز انسان سرچشمه می‌گیرد و پردازش داده‌ها را به چندین پردازنده بزرگ می‌سپارد که به صورت شبکه‌ای و موازی برای حل یک مشکل کار می‌کنند. با استفاده از دانش برنامه‌نویسی در این شبکه‌ها، ساختار داده‌ای طراحی شده است که می‌تواند به عنوان یک نورون به نام گره عمل کند. در این ساختار، شبکه از طریق ایجاد شبکه بین این گره‌ها و اعمال الگوریتم آموزشی در داخل آموزش داده می‌شود. در این حافظه یا شبکه عصبی، گره‌ها دارای دو حالت فعال (روشن) و غیرفعال (خاموش) هستند و هر لبه (سیناپس یا پیوند بین گره‌ها) دارای وزنی است. لبه‌های با وزن مثبت گره غیرفعال بعدی را تحریک یا فعال می‌کنند و یال‌های با وزن منفی گره متصل بعدی را غیرفعال یا مهار می‌کنند (در صورت فعال بودن). پیکربندی کلی نورون‌ها در شکل ۴ نشان داده شده است [۳۴].

مشخصات خاک در محل، عمق لایه‌ها، سطح آب زیرزمینی و پارامترهای لرزه‌ای بوده و پس از پالایش و کنترل کیفی، در تحلیل‌های عددی و مدل‌های محاسبات نرم به کار گرفته شدند.

داده‌های اطلاعاتی در دقت محاسبات روش‌های عمیق بسیار تأثیرگذار هستند. روش‌های ذکرشده از لحاظ تعداد داده‌ها و همچنین از لحاظ دقت داده، بسیار به داده‌های اطلاعاتی وابسته‌اند. در این تحقیق داده‌های اطلاعاتی از مطالعات ژئوتکنیک انجام‌شده در پروژه‌های شمالی کشور استخراج شده است. محدوده مورد مطالعه در این پژوهش، پهنه شمالی ایران شامل استان‌های ساحلی دریای خزر است که به دلیل سطح بالای آب زیرزمینی، رسوبات آبرفتی جوان و فعالیت لرزه‌ای، از مناطق مستعد وقوع روانگرایی به شمار می‌رود در شکل ۵ نشان داده شده است. اطلاعات مورد استفاده شامل نتایج آزمایش‌های برجا نظیر آزمایش نفوذ استاندارد (SPT) و آزمایش نفوذ مخروط (CPT)، مشخصات لایه‌بندی خاک، عمق آب زیرزمینی و اطلاعات لرزه‌ای منطقه است. کلیه داده‌ها از گزارش‌های ژئوتکنیکی معتبر پروژه‌ها استخراج شده و تنها داده‌های واقعی میدانی در تحلیل‌ها مورد استفاده قرار گرفته‌اند. لازم به ذکر است؛ بر روی نمونه‌های برداشت‌شده از گمانه‌ها، آزمایش‌های دانه‌بندی، هیدرومتری، طبقه‌بندی خاک، تعیین رطوبت، حدود اتر برگ، وزن مخصوص، چگالی دانه‌ها و... انجام شده است. باتوجه به عوامل مؤثر بر محاسبات پتانسیل روانگرایی، پارامترهای مهم در محاسبات گزارش نتایج مطالعات ژئوتکنیک توسط محققین مورد ارزیابی و تجزیه و تحلیل قرار گرفته است.

همان‌طور که در بخش دوم ذکر شد، از مهم‌ترین پارامترهای مؤثر در ارزیابی خطر روانگرایی می‌توان به: ۱- نوع خاک، ۲- متراکم بودن خاک، ۳- تراز آب زیرزمینی، ۴- درصد ریزدانه و ۵- شرایط لرزه‌خیزی محدوده طرح اشاره کرد. بر همین اساس، مطالعات ژئوتکنیک انجام‌شده، ارزیابی‌شده‌اند و پارامترهای مهم آن‌ها استخراج شده است. این ارزیابی برای بیش از ۳۰ پروژه در محدوده مورد نظر تحقیق انجام گردیده است.

داده‌های مورد استفاده در این تحقیق، بر اساس پارامترهای مهم در محاسبات پتانسیل روانگرایی استفاده شده است.




شکل ۴- پیکربندی کلی نورون‌ها [۳۴]

۳-۵-۲- شبکه فازی

مفهوم منطق فازی، ابر مجموعه‌ای از منطق بولی که برای رسیدگی به عدم قطعیت در داده‌ها بسط داده شد، توسط زاده در سال ۱۹۶۵ تصور شد [۴۶]. منطق فازی شامل یک رویکرد ساده و مبتنی بر قانون $IF\ X\ THEN\ Y\ AND\ Z$ برای حل یک مسئله کنترلی به‌جای مدل‌سازی ریاضی یک سیستم است. مدل منطق فازی مبتنی بر تجربی است و به تجربه اپراتورها متکی است تا درک فنی آن‌ها از سیستم. منطق فازی معمولاً شامل فازی سازی، کاربرد قاعده برای داده‌های فازی، استنتاج نتایج فازی و فازی زدایی از مراحل نتایج فازی است. فازی سازی رویه‌ای است که داده‌های مشاهده‌شده (واقعی) را با استفاده از تابع عضویت که ویژگی‌های مسئله را توصیف می‌کند، به شکل فازی تبدیل می‌کند. پایه قانون روابط بین توابع عضویت را توصیف می‌کند و تابع عضویت حاصل را تشکیل می‌دهد. فازی سازی مقدار واقعی (تخمین مدل) را از تابع عضویت حاصل می‌سازد [۴۷].

۳-۶- مطالعات ژئوتکنیک

منطقه مورد مطالعه شامل بخش‌هایی از شمال ایران است که به دلیل شرایط زمین‌شناسی، سطح بالای آب زیرزمینی و فعالیت لرزه‌ای، مستعد بروز پدیده روانگرایی هستند. داده‌های مورد استفاده در این پژوهش از نتایج آزمایش‌های صحرایی CPT، مطالعات ژئوتکنیکی انجام‌شده در پروژه‌های عمرانی و گزارش‌های فنی موجود طی سال‌های ۱۳۹۰ تا ۱۴۰۴ استخراج شده‌اند. این داده‌ها شامل



شکل ۵- موقعیت جغرافیایی محدوده مورد مطالعه و نقشه گسل ها در شمال ایران

۴- روش یادگیری عمیق

همان طور که قبلاً ذکر شده در انتخاب پارامترهای ورودی سعی شده است تا پارامترهایی انتخاب گردند که از معمول ترین آزمون های مطالعات ژئوتکنیک حاصل شوند. باتوجه به حدود ۱۲۰ داده موجود در محدوده استان های شمالی کشور که از نتایج مطالعات ژئوتکنیک و همچنین تحلیل و ارزیابی محاسبات پتانسیل روانگرایی حاصل شده اند، پارامترهای ورودی و خروجی مطابق جدول (۲) انتخاب شده اند.

جدول ۲. نمونه‌ای از داده‌های بانک اطلاعاتی روش یادگیری عمیق

M	σ	σ'	$a_{\max}$	q_c	τ/σ'	D50	Actual Liquefied
7.8	103	213	0.3	2.73	0.23	0.67	1
7.8	35	53	0.3	4.4	0.2	0.16	1
7.8	59.8	38.2	0.3	2.94	0.2	0.16	1
7.8	52	34.3	0.3	4.3	0.2	0.16	1
7.8	31.4	25.5	0.3	12.81	0.16	0.17	0
7.8	78	89	0.3	1.65	0.41	0.17	1
7.8	74.5	46.1	0.3	2.85	0.21	0.18	1
7.8	214.8	104.6	0.3	1.75	0.23	0.067	1
7.8	51	59	0.3	2.73	0.15	0.16	1
7.8	57	72	0.3	2.94	0.16	0.21	1
7.8	118.7	55.3	0.3	1.54	0.25	0.062	1
7.8	56	114	0.3	1.57	0.25	0.062	1
7.8	68.6	46.1	0.3	2.2	0.19	0.14	1
7.8	75	99	0.3	17.76	0.17	0.14	0
7.8	153	79.4	0.3	8.83	0.23	0.08	1
7.8	22.6	21.6	0.3	12.98	0.14	0.17	0
7.8	122	249	0.3	5.79	0.22	0.067	0
7.8	58	114	0.3	8.47	0.24	0.062	0
7.8	61	63	0.3	9.12	0.13	0.26	0



مطابق جدول مذکور پارامترهای ورودی شامل: بزرگای زلزله M ، شتاب حداکثر زلزله، σ_v و σ'_v تنش کلی و مؤثر، q_c مقاومت نفوذ مخروط، T_{av} تنش برشی متوسط ایجادشده بر اثر وقوع زمین‌لرزه در عمق، D50 اندازه‌ای که ۵۰ درصد ذرات خاک از آن عبور می‌کنند و ایجاد پتانسیل روانگرایی (Actual Liquefied) در نظر گرفته شده‌اند. همچنین یک پارامتر خروجی بر اساس اهمیت خطر روانگرایی شامل: ایجاد پتانسیل روانگرایی (Liquefaction Potential (LP)) مشخص شده است. پس از جمع‌آوری داده‌ها در پیش‌بینی خطر روانگرایی، داده‌های ورودی در نرم‌افزار اکسل پردازش شده است و در مرحله بعد به‌صورت کد به ماشین دقیق وارد شده است.

۴-۱- تعریف متغیرهای ورودی و خروجی مدل‌ها

در این پژوهش، به‌منظور پیش‌بینی پتانسیل روانگرایی خاک، متغیرهای ورودی مدل‌های محاسبات نرم (شبکه عصبی مصنوعی و منطق فازی) بر اساس داده‌های آزمایش نفوذ

جدول ۳- معرفی پارامترهای ورودی و خروجی مورد استفاده در پیش‌بینی روانگرایی خاک

توضیح ژئوتکنیکی	واحد	نماد	نام پارامتر	نوع متغیر
شاخص اصلی مقاومت خاک در برابر نفوذ، مرتبط با تراکم و مقاومت برشی	Mpa	q_c	مقاومت نوک مخروط	ورودی
مقاومت اصلاح شده با در نظر گیری تنش مؤثر قائم	-	q_{c1N}	مقاومت نوک نرمال شده	ورودی
بیانگر نوع خاک و درصد ریزدانه‌ها	%	R_f	نسبت اصطکاک	ورودی
شاخص پاسخ هیدرولیکی خاک در حین نفوذ	Kpa	u	فشار آب منفذی اضافی	ورودی
کنترل کننده اصلی رفتار روانگرایی	Kpa	σ'_v	تنش مؤثر قائم	ورودی
مؤثر در تغییرات تنش و شرایط زهکشی	m	Z	عمق نمونه برداری	ورودی
تعیین کننده اشباع خاک و پتانسیل تولید فشار آب منفذی	m	GWL	سطح آب زیرزمینی	ورودی
۱: وقوع روانگرایی ۰: عدم وقوع روانگرایی	۱/۰	LP	وضعیت روانگرایی	خروجی

۴-۲- روند مدل‌سازی

ساختار شبکه شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. فرآیند آموزش شبکه با الگوریتم پس‌انتشار خطا انجام شد.

داده‌ها به دو بخش آموزش و آزمون تقسیم شدند و از معیارهایی نظیر ضریب همبستگی (R) و خطای میانگین مربعات (RMSE) برای ارزیابی عملکرد مدل استفاده گردید.

مخروط (CPT) و پارامترهای ژئوتکنیکی مؤثر بر رفتار لرزه‌ای خاک انتخاب شدند. این پارامترها از جمله متغیرهایی هستند که در مطالعات کلاسیک و نوین روانگرایی، نقش تعیین‌کننده‌ای در آغاز و گسترش پدیده روانگرایی دارند که در جدول ۳ نشان داده شده است.


آزمایش CPT به دلیل پیوستگی داده‌ها، دقت بالا و قابلیت تکرارپذیری، یکی از معتبرترین روش‌ها برای ارزیابی روانگرایی خاک در محل محسوب می‌شود. متغیرهای استخراج‌شده از این آزمایش، نمایانگر مقاومت برشی، وضعیت تنش مؤثر، ویژگی‌های دانه‌بندی و شرایط هیدروژئولوژیکی خاک می‌باشند. متغیر خروجی مدل‌ها به‌صورت یک متغیر دودویی تعریف شده است که نشان‌دهنده وقوع یا عدم وقوع روانگرایی در هر نقطه مورد بررسی می‌باشد.

۴-۳- نتایج ارزیابی پتانسیل روانگرایی با روش عددی

مبتنی بر CPT

نتایج حاصل از تحلیل عددی مبتنی بر داده‌های آزمایش نفوذ مخروط (CPT) نشان می‌دهد که بخش قابل‌توجهی از لایه‌های ماسه‌ای سست در محدوده مورد مطالعه دارای ضریب اطمینان کمتر از یک در برابر روانگرایی می‌باشند. این وضعیت عمدتاً در عمق‌های کم تا متوسط و در مجاورت سطح آب زیرزمینی مشاهده شده است.

این ویژگی نشان می‌دهد که منطق فازی در شرایطی که داده‌ها دارای پراکندگی و عدم قطعیت هستند، ابزار مناسبی برای تحلیل پدیده روانگرایی محسوب می‌شود.



شکل ۷- نمودار شماتیک سیستم استنتاج فازی برای ارزیابی پتانسیل روانگرایی خاک

این شکل ساختار کلی سیستم منطق فازی مورد استفاده در پژوهش حاضر را نمایش می‌دهد. در این سیستم، پارامترهای ژئوتکنیکی ورودی ابتدا از طریق توابع عضویت فازی‌سازی شده و سپس بر اساس مجموعه‌ای از قوانین فازی استخراج شده از دانش مهندسی ژئوتکنیک، مورد پردازش قرار می‌گیرند. در نهایت، با انجام فرآیند غیرفازی‌سازی، خروجی سیستم به صورت وقوع یا عدم وقوع روانگرایی تعیین می‌شود. استفاده از منطق فازی امکان تحلیل رفتار خاک در شرایط عدم قطعیت و مرزی را فراهم می‌سازد.


۴-۶- مقایسه نتایج روش عددی و محاسبات نرم

- مقایسه نتایج سه رویکرد مورد استفاده در این پژوهش نشان داد که: روش عددی مبتنی بر CPT عملکرد مناسبی در شرایط ساده و یکنواخت دارد؛
- شبکه عصبی مصنوعی دقت بالاتری در مدل‌سازی رفتار غیرخطی خاک ارائه می‌دهد؛
- مدل فازی در تفسیر شرایط مرزی و خاک‌های ناهمگن عملکرد مطلوب‌تری دارد.

با وجود در نظر گرفتن شتاب حداکثر سطح زمین برابر با $0.3g$ ، ترکیب شرایط ژئوتکنیکی شامل دانه‌بندی ریز، تراکم کم و سطح بالای آب زیرزمینی منجر به کاهش تنش مؤثر و افزایش احتمال روانگرایی شده است. نتایج به‌دست‌آمده از این تحلیل با مطالعات پیشین در مناطق ساحلی و آبرفتی تطابق مناسبی دارد [۳۷].

۴-۴- نتایج مدل‌سازی با شبکه عصبی مصنوعی

عملکرد شبکه عصبی مصنوعی در پیش‌بینی پتانسیل روانگرایی نشان داد که این مدل قادر است روابط غیرخطی بین پارامترهای ژئوتکنیکی را با دقت مناسبی شناسایی کند. مقدار ضریب همبستگی بین مقادیر پیش‌بینی‌شده و داده‌های واقعی در مجموعه آزمون نشان‌دهنده همخوانی قابل قبول مدل با رفتار واقعی خاک است. شبکه عصبی توانست اثر همزمان پارامترهایی نظیر q_c ، سطح آب زیرزمینی، عمق و درصد ریزدانه را در تعیین وقوع روانگرایی لحاظ نماید، در حالی که روش‌های عددی کلاسیک معمولاً این پارامترها را به‌صورت مجزا بررسی می‌کنند.



شکل ۶- ساختار شماتیک شبکه عصبی مصنوعی مورد استفاده در پیش‌بینی روانگرایی خاک

شکل ۶ ساختار کلی شبکه عصبی مصنوعی به‌کاررفته در این پژوهش را نشان می‌دهد. لایه ورودی شامل پارامترهای ژئوتکنیکی استخراج‌شده از داده‌های CPT است که هر یک بیانگر ویژگی‌های مکانیکی و هیدرولیکی خاک می‌باشند. لایه‌های پنهان وظیفه استخراج روابط غیرخطی و پیچیده میان متغیرهای ورودی و پدیده روانگرایی را بر عهده دارند. در نهایت، لایه خروجی وضعیت وقوع یا عدم وقوع روانگرایی را پیش‌بینی می‌کند. این ساختار امکان مدل‌سازی رفتار غیرخطی خاک تحت بارگذاری لرزه‌ای را فراهم می‌سازد.

۴-۵- نتایج مدل فازی

مدل فازی توسعه‌یافته توانست رفتار خاک را تحت شرایط عدم قطعیت به‌خوبی شبیه‌سازی کند. خروجی‌های مدل فازی به‌ویژه در محدوده‌های مرزی (نزدیک به آستانه روانگرایی) نتایج منطقی‌تری نسبت به روش عددی ارائه دادند.

جدول ۴- مقایسه عملکرد روش عددی، شبکه عصبی مصنوعی و مدل منطق فازی در ارزیابی پتانسیل روانگرایی

محدودیت‌ها	مزایا	عملکرد در شرایط عدم قطعیت	قابلیت تفسیر مهندسی	دقت پیش‌بینی	نوع داده ورودی	روش تحلیل
حساس به فروض اولیه و ساده‌سازی‌ها	مبتنی بر روابط کلاسیک ژئوتکنیکی، قابل فهم برای مهندسان	پایین	بالا	متوسط	σ_v' , CSR, q_c , fs	روش عددی مبتنی بر CPT
نیازمند داده کافی و کالیبراسیون	توانایی مدل‌سازی روابط غیرخطی پیچیده، دقت بالاتر نسبت به روش عددی	متوسط	متوسط	بالا	پارامترهای CPT و شرایط هیدروژئولوژیکی	شبکه عصبی مصنوعی ANN
وابستگی به تعریف توابع	مناسب برای داده‌های نامعین و مرزی، تفسیرپذیری مناسب	بالا	بالا	متوسط تا بالا	پارامترهای CPT به همراه قواعد فازی	منطق فازی
پیچیدگی ساده‌سازی	افزایش دقت همراه با تفسیرپذیری مهندسی	بالا	بالا	بالا	تحلیل عددی+ CPT	رویکرد تلفیقی (عددی + محاسبات نرم)

اصول مکانیک خاک و روابط کلاسیک CPT-based liquefaction assessment همخوانی کامل دارد.

پس از q_c ، تنش مؤثر قائم (σ_v') و سطح آب زیرزمینی (GWL) بیشترین نقش را در تغییر رفتار روانگرایی ایفا می‌کنند. افزایش سطح آب زیرزمینی موجب کاهش تنش مؤثر و افزایش فشار آب حفره‌ای شده و در نتیجه احتمال وقوع روانگرایی را افزایش می‌دهد. از سوی دیگر، افزایش تنش مؤثر قائم منجر به افزایش مقاومت در برابر روانگرایی می‌شود.

نسبت اصطکاک (R_f) به عنوان شاخصی از نوع خاک، تأثیر متوسطی بر نتایج مدل نشان داد. مقادیر بالاتر R_f که بیانگر حضور ریزدانه‌ها و خاک‌های سیلتی است، در بسیاری از موارد موجب کاهش تمایل به روانگرایی شده‌اند، هرچند این تأثیر وابسته به شرایط تنش و سطح آب زیرزمینی بوده است.

عمق لایه مستعد روانگرایی (D) نیز دارای تأثیر منفی بر وقوع روانگرایی بوده، به گونه‌ای که افزایش عمق لایه موجب افزایش تنش مؤثر و کاهش احتمال روانگرایی شده است.

به طور کلی، نتایج تحلیل حساسیت مبتنی بر CPT نشان می‌دهد که پارامترهای مقاومت و شرایط تنش مؤثر خاک نقش غالبی در کنترل روانگرایی دارند و استفاده از داده‌های CPT می‌تواند چارچوبی دقیق و قابل اعتماد برای تحلیل حساسیت و پیش‌بینی رفتار خاک فراهم آورد.

همان‌گونه که در جدول ۴ مشاهده می‌شود، روش عددی مبتنی بر داده‌های CPT دارای قابلیت تفسیر مهندسی بالایی است، اما به دلیل فروض ساده‌ساز، دقت محدودی در شرایط پیچیده خاک دارد. در مقابل، شبکه عصبی مصنوعی با بهره‌گیری از روابط غیرخطی، دقت بالاتری در پیش‌بینی روانگرایی ارائه می‌دهد، هرچند نیازمند داده‌های کافی و تنظیم پارامترهاست.

منطق فازی عملکرد مناسبی در شرایط عدم قطعیت و داده‌های مرزی نشان داده و امکان تحلیل رفتار خاک‌های ناهمگن را فراهم می‌کند. ترکیب این روش‌ها منجر به افزایش دقت پیش‌بینی همراه با حفظ قابلیت تفسیر مهندسی نتایج شده است.

۴-۷- نتایج تحلیل حساسیت

در این پژوهش، تحلیل حساسیت با هدف بررسی میزان تأثیر پارامترهای ورودی مبتنی بر آزمایش نفوذ مخروط (CPT) بر وقوع روانگرایی انجام شد. به منظور حذف هرگونه وابستگی به داده‌های SPT، کلیه تحلیل‌ها صرفاً بر اساس متغیرهای استخراج شده از CPT شامل مقاومت نوک مخروط (q_c)، نسبت اصطکاک (R_f)، تنش مؤثر قائم (σ_v') ، عمق لایه مستعد روانگرایی (D) و سطح آب زیرزمینی (GWL) انجام گرفت.

نتایج تحلیل حساسیت نشان داد که مقاومت نوک مخروط q_c بیشترین تأثیر را بر وقوع یا عدم وقوع روانگرایی دارد. افزایش مقدار q_c بیانگر افزایش تراکم نسبی و مقاومت برشی خاک بوده و به طور معناداری احتمال روانگرایی را کاهش می‌دهد. این نتیجه با

جدول ۵ نتایج تحلیل حساسیت پارامترهای CPT بر وقوع روانگرایی

تفسیر ژئوتکنیکی	میزان تاثیر	نوع اثر	نماد	CPT پارامتر ورودی
افزایش q_c ، باعث افزایش تراکم و مقاومت خاک می شود.	بسیار زیاد	منفی	q_c	مقاومت نوک مخروط
افزایش تنش موثر باعث کاهش احتمال روانگرایی می شود.	زیاد	منفی	σ'_v	تنش موثر قائم
افزایش GWL، باعث کاهش σ'_v و افزایش خطر می شود.	زیاد	مثبت	GWL	سطح آب زیرزمینی
خاک های ریزدانه تر تمایل کمتری به روانگرایی دارند.	متوسط	منفی / وابسته	R_f	نسبت اصطکاک
افزایش تنش موثر باعث افزایش عمق موثر می شود.	متوسط	منفی	D	عمق لایه روانگرا

۵- پیاده سازی روش یادگیری عمیق

جدول ۷- نرخ موفقیت مدل شبکه فازی برای تعداد مختلف لایه های پنهان با ۸۰-۲۰ درصد مجموعه تست آموزشی


معیار ترکیبی	فراخوانی مجدد	صحت	دقت	تعداد لایه های پنهان
۰,۷۸۱	۰,۹۲۵	۰,۸۶	۰,۹۲۵	TRAIN
۰,۸۸۳	۰,۷۱۴	۱	۰,۹۳۹	TEST
۰,۸	۰,۹۰۹	۰,۷۱۴	۰,۸۸۷	ALL

باتوجه به دقت های به دست آمده از هر دو مدل، مشخص گردید مدل ANN در مقایسه با شبکه فازی عملکرد بهتری دارد که در نمودار شکل ۸ این مقایسه نشان داده شده است.


برای مدل سازی کدها به روش آموزش - یادگیری از نرم افزار MATLAB (20016a) استفاده شده است. به طور کلی بیان می شود که دقت طبقه بندی با طبقه بندی کننده به دست آمده در نتیجه ترکیب بهتر از استفاده از هر طبقه بندی به تنهایی است. زیرا تنوع طبقه بندی کننده ها معمولاً اشتباهات یک طبقه بندی را جبران می کند که در صورت استفاده منفرد، می تواند خطای تست بالاتری داشته باشد؛ بنابراین، خطای تست کمتری با ترکیب طبقه بندی کننده ها به دست می آید. نرخ موفقیت به دست آمده با مدل ANN برای ۸۰-۲۰ درصد مجموعه تست آموزش در جدول ۶ آورده شده است و نرخ موفقیت به دست آمده با مدل شبکه فازی برای ۸۰-۲۰ درصد مجموعه تست آموزش در جدول ۷ آورده شده است.

جدول ۶- نرخ موفقیت مدل ANN برای تعداد مختلف لایه های پنهان با ۸۰-۲۰ درصد مجموعه تست آموزشی

معیار ترکیبی	فراخوانی مجدد	صحت	دقت	تعداد لایه های پنهان
۰,۸۶۹	۰,۸۸۲	۰,۸۵۷	۰,۹۱۵	TRAIN
۰,۹۳۳	۰,۸۷۵	۱	۰,۹۶۲	TEST
۰,۸۸۰	۰,۸۸۰	۰,۸۸۰	۰,۹۳۲	ALL




شکل ۸- نمودار مقایسه دقت های به دست آمده از شبکه عصبی مصنوعی ANN و شبکه عصبی فازی




شکل ۱۰- ماتریس درهم‌ریختگی کل مدل شبکه فازی برای ۸۰-۲۰ درصد داده‌های آزمون آموزشی

همچنین برای درک بهتر این مطلب نمودارهای ROC مربوط به مدل ANN و شبکه عصبی نیز به ترتیب در شکل ۱۱ و ۱۲ قرار گرفته‌اند. این نمودار بیان می‌کند هرچه تقعر نمودار به عدد ۱ نزدیک تر باشد از جهت انتخاب بهترین روش گزینه مناسبی می‌باشد. با توجه به این توضیحات می‌توان مشاهده کرد در نمودار ROC مربوط شبکه عصبی مصنوعی ANN در هر دو کلاس به عدد ۱ نزدیک است.



شکل ۱۱- نمودار ROC مربوط به کلاس طبقه‌بندی روانگرا و غیر روانگرا بودن داده‌ها در مدل ANN

ماتریس درهم‌ریختگی برای ۸۰-۲۰ درصد مجموعه آزمون آموزشی برای مدل ANN در شکل ۹ آورده شده است که مشاهده شد میزان موفقیت ۹۶/۷٪ برای خروجی "۲" است (کلاس روانگرایی). به نظر می‌رسد همه ۱۲۰ نمونه آزمایش تا حد قابل قبولی درست هستند و به این شکل طبقه‌بندی شده‌اند. باین‌حال، از آنجایی که تعدادی از داده‌ها غیر روانگرا بودند در کلاس ۱ به‌طور مستقیم طبقه‌بندی شده‌اند، میزان موفقیت کلی مشاهده‌شده برای خروجی "۱" (کلاس غیر روانگرا) ۸۵٪ باشد.



شکل ۹- ماتریس درهم‌ریختگی کل مدل ANN برای ۸۰-۲۰ درصد داده‌های آزمون آموزشی

ماتریس درهم‌ریختگی برای ۸۰-۲۰ درصد مجموعه آزمون آموزشی برای مدل شبکه فازی در شکل ۱۰ آورده شده است که مشاهده شد میزان موفقیت ۸۸٪ برای خروجی "۲" است (کلاس روانگرایی). به نظر می‌رسد همه ۱۲۰ نمونه آزمایش تا حد قابل قبولی درست هستند و به این شکل طبقه‌بندی شده‌اند. باین‌حال، از آنجایی که تعدادی از داده‌ها غیر روانگرا بودند در کلاس ۱ به‌طور مستقیم طبقه‌بندی شده‌اند، میزان موفقیت کلی مشاهده‌شده برای خروجی "۱" (کلاس غیر روانگرا) ۹۰٪ باشد.

نتایج این پژوهش با یافته‌های مطالعات قبلی در حوزه روانگرایی خاک همخوانی دارد، اما استفاده همزمان از داده‌های واقعی میدانی و روش‌های محاسبات نرم باعث شده است که دقت و قابلیت تعمیم نتایج افزایش یابد. این موضوع ارزش افزوده پژوهش حاضر نسبت به مطالعات مشابه را نشان می‌دهد.

۷- نتیجه‌گیری

در این پژوهش، پتانسیل روانگرایی خاک در محدوده شمال ایران با استفاده از یک رویکرد تلفیقی شامل روش‌های عددی مبتنی بر داده‌های آزمایش نفوذ مخروط (CPT) و روش‌های محاسبات نرم شامل شبکه عصبی مصنوعی و منطق فازی مورد ارزیابی قرار گرفت. داده‌های مورد استفاده حاصل مطالعات ژئوتکنیکی میدانی انجام شده طی سال‌های ۱۳۹۰ تا ۱۴۰۴ بوده و بیانگر شرایط واقعی خاک‌های آبرفتی اشباع منطقه هستند.


نتایج تحلیل عددی مبتنی بر CPT نشان داد که در شرایط شتاب حداکثر سطح زمین برابر با 0.3g، برخی لایه‌های ماسه‌ای سست و اشباع در محدوده مورد مطالعه دارای پتانسیل بالای روانگرایی هستند. این یافته نشان می‌دهد که وقوع روانگرایی صرفاً تابع شدت زلزله نبوده و پارامترهای ژئوتکنیکی محلی نظیر مقاومت نوک مخروط، تنش مؤثر قائم، سطح آب زیرزمینی و ویژگی‌های دانه‌بندی خاک نقش تعیین‌کننده‌تری در آغاز این پدیده دارند.

مدل‌سازی انجام شده با شبکه عصبی مصنوعی مبتنی بر پارامترهای CPT نشان داد که این مدل قادر است روابط پیچیده و غیرخطی میان متغیرهای ورودی از جمله مقاومت نوک مخروط نرمال شده، نسبت اصطکاک، عمق لایه و سطح آب زیرزمینی را بادقت بالایی شناسایی نماید. مقایسه نتایج حاصل از مدل شبکه عصبی با روش عددی کلاسیک CPT-based بیانگر بهبود قابل توجه دقت پیش‌بینی و کاهش خطای مدل در برآورد وقوع روانگرایی است.

همچنین، مدل فازی توسعه یافته در این پژوهش عملکرد مناسبی در شرایط عدم قطعیت و تغییرپذیری پارامترهای ژئوتکنیکی از خود نشان داد. استفاده از منطق فازی امکان مدل‌سازی رفتار تدریجی و مرزی خاک را فراهم کرده و نتایج آن نشان داد که این رویکرد می‌تواند به عنوان یک ابزار مکمل قابل اعتماد در تحلیل روانگرایی خاک‌های ناهمگن مورد استفاده قرار گیرد.

نتایج تحلیل حساسیت مبتنی بر داده‌های CPT حاکی از آن است که مقاومت نوک مخروط نرمال شده و سطح آب زیرزمینی بیشترین تأثیر را بر وقوع روانگرایی دارند، به طوری که افزایش مقاومت مخروط منجر به کاهش احتمال روانگرایی شده و بالابودن سطح آب زیرزمینی خطر وقوع آن را به طور چشمگیری افزایش می‌دهد. این نتایج با مبانی فیزیکی رفتار خاک‌های اشباع و یافته‌های پژوهش‌های پیشین همخوانی کامل دارد.

در مجموع، نتایج این تحقیق نشان می‌دهد که به کارگیری همزمان روش‌های عددی CPT-based و مدل‌های محاسبات نرم می‌تواند دقت ارزیابی پتانسیل روانگرایی را به طور محسوسی افزایش داده و



شکل ۱۲- نمودار ROC مربوط به کلاس طبقه‌بندی روانگرا و غیر روانگرا بودن داده‌ها در مدل شبکه فازی

۶- بحث و تفسیر نتایج

۶-۱- تحلیل اثر شتاب زلزله در وقوع روانگرایی

انتخاب شتاب حداکثر زمین برابر با 0.3g در این مطالعه از نظر فیزیکی و مهندسی کاملاً توجیه‌پذیر است. مطالعات متعدد نشان داده‌اند که در خاک‌های ماسه‌ای اشباع و سست، حتی افزایش‌های نسبتاً محدود در شتاب لرزه‌ای می‌تواند منجر به افزایش فشار آب حفره‌ای و کاهش تنش مؤثر شود، به‌ویژه زمانی که مقدار شتاب از حدود 0.3g فراتر رود؛ بنابراین، نتایج حاصل از این پژوهش را می‌توان به عنوان سناریویی واقع‌بینانه برای تحلیل خطر روانگرایی در مناطق لرزه‌خیز شمال ایران در نظر گرفت، جایی که رخداد زلزله‌هایی با شدت متوسط تا شدید محتمل است.

۶-۲- برتری روش‌های محاسبات نرم نسبت به روش‌های کلاسیک

نتایج نشان داد که روش‌های محاسبات نرم، به‌ویژه شبکه‌های عصبی، قادر به شناسایی روابط پیچیده بین پارامترهای خاک هستند؛ روابطی که در روش‌های تجربی کلاسیک به صورت ساده‌سازی شده در نظر گرفته می‌شوند. این ویژگی موجب افزایش دقت پیش‌بینی و کاهش خطای مدل می‌شود.

۶-۳- تفسیر نتایج تحلیل حساسیت

نتایج تحلیل حساسیت تأیید می‌کند که پارامترهای مرتبط با تراکم خاک و شرایط هیدرولیکی بیشترین نقش را در کنترل پتانسیل روانگرایی دارند. این یافته از نظر فیزیکی نیز قابل توجیه است، زیرا کاهش تنش مؤثر و افزایش تخلخل خاک، مهم‌ترین مکانیسم‌های وقوع روانگرایی هستند.

۶-۴- مقایسه با مطالعات پیشین

به عنوان ابزاری کارآمد در مطالعات ژئوتکنیکی و طراحی لرزه‌ای پروژه‌های عمرانی مناطق لرزه‌خیز شمال کشور مورد استفاده قرار گیرد.

۸- نوآوری‌ها و سهم علمی پژوهش

نوآوری‌ها و دستاوردهای اصلی این پژوهش به صورت زیر قابل جمع‌بندی است:

- ۱- ارائه یک چارچوب تلفیقی نوین مبتنی بر داده‌های CPT و روش‌های محاسبات نرم (شبکه عصبی مصنوعی و منطق فازی) برای ارزیابی پتانسیل روانگرایی خاک، بدون اتکا به داده‌های SPT.
- ۲- استفاده از داده‌های واقعی ژئوتکنیکی میدانی شمال ایران در بازه زمانی ۱۳۹۰ تا ۱۴۰۴ که موجب افزایش اعتبار، واقع‌گرایی و قابلیت تعمیم نتایج شده است.

منابع

- ۳- تحلیل علمی وقوع روانگرایی در شتاب حداکثر سطح زمین برابر با 0.3g و تبیین نقش غالب شرایط ژئوتکنیکی محلی در بروز این پدیده
 - ۴- مقایسه جامع عملکرد روش عددی CPT-based، شبکه عصبی مصنوعی و مدل فازی و ارائه تحلیل کیفی و کمی از مزایا و محدودیت‌های هر یک در پیش‌بینی روانگرایی.
 - ۵- انجام تحلیل حساسیت مبتنی بر پارامترهای CPT و شناسایی مؤثرترین عوامل کنترل‌کننده روانگرایی، به‌ویژه مقاومت نوک مخروط و سطح آب زیرزمینی.
 - ۶- ارائه یک چارچوب کاربردی و قابل‌استفاده برای مهندسان ژئوتکنیک در مطالعات خطر روانگرایی و طراحی لرزه‌ای پروژه‌های عمرانی در مناطق مستعد شمال کشور
- 135-149.
<https://doi.org/10.1016/j.enggeo.2016.07.002>
- [8]. Javadi, A.A., T.P. Tan, and A. Elkassas, Intelligent finite element method and application to simulation of behavior of soils under cyclic loading. Foundations of Computational Intelligence Volume 5: Function Approximation and Classification, 2009: p. 317-338.
https://doi.org/10.1007/978-3-642-01536-6_12
- [9]. Zhao, Z., W. Duan, and G. Cai, A novel PSO-KELM based soil liquefaction potential evaluation system using CPT and Vs measurements. Soil Dynamics and Earthquake Engineering, 2021. 150: p. 106930.
<https://doi.org/10.1016/j.soildyn.2021.106930>
- [10]. Rafiei, A., M. Rahman, and M. Gabr, Response and instability of sloping seabed supporting small marine structures: wave-structure-soil interaction analysis. Journal of Offshore Mechanics and Arctic Engineering, 2022. 144(3): p. 032101.
<https://doi.org/10.1115/1.4052864>
- [۱۱]. طهماسب، ح. جاودانیان، ارزیابی بروز پدیده روانگرایی مبتنی بر انرژی کرنشی با استفاده از الگوریتم برنامه نویسی بیان ژنی، سیزدهمین کنگره بین المللی مهندسی عمران، ۱۴۰۲.
- [۱۲]. معزز، س.، د. مختاری، م. رضائی مقدم، ارزیابی و پهنه بندی مخاطره روانگرایی با استفاده از مدل فازی ویکور، مطالعه موردی: مخروط افکنه لیلان شمال غرب ایران، ۱۴۰۲.
- [13]. Juwaied, N.S., Applications of artificial intelligence in geotechnical engineering. ARPN J Eng Appl Sci, 2018. 13(8): p. 2764-2785.
- [14]. Kaveh, A., S. Hamze-Ziabari, and T. Bakhshpoori, Patient rule-induction method for liquefaction potential assessment based on CPT data. Bulletin of Engineering Geology and the

[1]. Bahrainy, H. and A. Bakhtiar, Manjil Earthquake of June 20, 1990, The Lessons Learned, in Urban Design in Seismic-Prone Regions. 2022, Springer International Publishing: Cham. p. 49-95.
https://doi.org/10.1007/978-3-031-08321-1_3

[2]. Matsuoka, M., et al., Evaluation of liquefaction potential for large areas based on geomorphologic classification. Earthquake Spectra, 2015. 31(4): p. 2375-2395.
<https://doi.org/10.1193/072313EQS211M>

[3]. 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>

[4]. 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)

[5] Norini, G., et al., Assessment of liquefaction potential in the central Po plain from integrated geomorphological, stratigraphic and geotechnical analysis. Engineering Geology, 2021. 282: p. 105997 .
<https://doi.org/10.1016/j.enggeo.2021.105997>

[6]. Putra, J.W.G., Pengenalan konsep pembelajaran mesin dan deep learning. Tokyo. Jepang, 2019.

[7]. Chen, Q., C. Wang, and C.H. Juang, Probabilistic and spatial assessment of liquefaction-induced settlements through multiscale random field models. Engineering Geology, 2016. 211: p.

neural network. Journal of Marine Science and Technology, 2008. 16(2): p. 6.

[24]. Jamshidi Chenari, R., et al., The use of index parameters to predict soil geotechnical properties. Arabian Journal of Geosciences, 2015. 8: p. 4907-4919. <https://doi.org/10.1007/s12517-014-1538-0>

[25]. Hoang, N.-D. and D.T. Bui, Predicting earthquake-induced soil liquefaction based on a hybridization of kernel Fisher discriminant analysis and a least squares support vector machine: a multi-dataset study. Bulletin of Engineering Geology and the Environment, 2018. 77: p. 191-204. <https://doi.org/10.1007/s10064-016-0924-0>

[26]. Goh, A.T., Seismic liquefaction potential assessed by neural networks. Journal of Geotechnical engineering, 1994. 120(9): p. 1467-1480. [https://doi.org/10.1061/\(ASCE\)0733-9410\(1994\)120:9\(1467\)](https://doi.org/10.1061/(ASCE)0733-9410(1994)120:9(1467))

[27]. Goh, A.T., Neural-network modeling of CPT seismic liquefaction data. Journal of Geotechnical engineering, 1996. 122(1): p. 70-73. [https://doi.org/10.1061/\(ASCE\)0733-9410\(1996\)122:1\(70\)](https://doi.org/10.1061/(ASCE)0733-9410(1996)122:1(70))

[28]. Goh, A.T., Probabilistic neural network for evaluating seismic liquefaction potential. Canadian Geotechnical Journal, 2002. 39(1): p. 219-232. <https://doi.org/10.1139/t01-073>

[29]. Kurnaz, T.F. and Y. Kaya, A novel ensemble model based on GMDH-type neural network for the prediction of CPT-based soil liquefaction. Environmental Earth Sciences, 2019. 78(11): p. 339. <https://doi.org/10.1007/s12665-019-8344-7>

[30]. Rahbarzare, A. and M. Azadi, Improving prediction of soil liquefaction using hybrid optimization algorithms and a fuzzy support vector machine. Bulletin of Engineering Geology and the Environment, 2019. 78(7): p. 4977-4987. <https://doi.org/10.1007/s10064-018-01445-3>

[31]. Ghasemi Rozveh, S. and A. Derakhshani, Uncertainty analysis of liquefaction-induced lateral spreading using fuzzy variables and genetic algorithm. Bulletin of Engineering Geology and the Environment, 2021. 80: p. 9185-9200. <https://doi.org/10.1007/s10064-021-02385-1>

[32]. Mohammadikish, S., et al., Soil liquefaction assessment by CPT and VS data and incomplete-fuzzy C-means clustering. Geotechnical and

Environment, 2018. 77: p. 849-865. <https://doi.org/10.1007/s10064-016-0990-3>

[15]. Samui, P., Hybrid metaheuristic optimization of artificial neural networks for liquefaction probability prediction using various historical CPT data. Transportation Infrastructure Geotechnology, 2025. 12(1): p. 1-33. <https://doi.org/10.1007/s40515-024-00504-5>

[16]. Jas, K. and G. Dodagoudar, Liquefaction potential assessment of soils using machine learning techniques: a state-of-the-art review from 1994–2021. International Journal of Geomechanics, 2023. 23(7): p. 03123002. <https://doi.org/10.1061/IJGNALGMENG-7788>

[17]. Moayedi Far, A. and M. Zare, Ensemble-based soil liquefaction assessment: Leveraging CPT data for enhanced predictions. Civil Engineering Design, 2025. 7(1): p. 23-35. <https://doi.org/10.1002/cend.202400024>

[18]. Bherde, V., N. Gorantala, and U. Balunaini, Liquefaction susceptibility prediction using ML-based voting ensemble classifier. Natural Hazards, 2025. 121(4): p. 4359-4384. <https://doi.org/10.1007/s11069-024-06960-z>

[19]. Gupta, T., G. Ramana, and A. Elgamal, A hybrid numerical–probabilistic approach for machine learning-based prediction of liquefaction-induced settlement using CPT data. Arabian Journal of Geosciences, 2023. 16(6): p. 394. <https://doi.org/10.1007/s12517-023-11500-3>

[20]. Ranjan Kumar, D. and W. Wipulanusat, Advancements in predicting soil liquefaction susceptibility: a comprehensive analysis of ensemble and deep learning approaches. Scientific Reports, 2025. 15(1): p. 26453. <https://doi.org/10.1038/s41598-025-04280-1>

[21]. Hsein Juang, C., C.J. Chen, and Y.-M. Tien, Appraising cone penetration test based liquefaction resistance evaluation methods: artificial neural network approach. Canadian Geotechnical Journal, 1999. 36(3): p. 443-454. <https://doi.org/10.1139/t99-011>

[22]. Chen, Y.-R., H.-Y. Liang, and C.-K. Tsai, Applying fuzzy theory combined with genetic algorithms to evaluate earthquake-induced liquefaction potential. EJGE, 2012. 17: p. 1087-1114.

[23]. Chern, S.-G., C.-Y. Lee, and C.-C. Wang, CPT-based liquefaction assessment by using fuzzy-

<https://doi.org/10.1139/t90-014>

[41]. Kanagalingam, T. and S. Thevanayagam, Energy dissipation and liquefaction assessment in sands and silty soils, in GeoCongress 2006: Geotechnical Engineering in the Information Technology Age. 2006. p. 1-6.

[https://doi.org/10.1061/40803\(187\)198](https://doi.org/10.1061/40803(187)198)

[42]. 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.

[43]. 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))

[44]. Mijic, Z., J.D. Bray, and S. van Ballegooy, Liquefaction ejecta case histories for 2010-11 Canterbury earthquakes. International Journal of Geoengineering Case Histories, 2022. 6(3)

[45]. Cappellaro, C., R. Dhakal, and M. Cubrinovski, Liquefaction hazard of Wellington reclamations based on conventional analysis. Bulletin of the New Zealand Society for Earthquake Engineering, 2024. 57(2): p. 97-116. <https://doi.org/10.5459/bnzsee.1675>

[46]. Ashfaq, M., A Tribute to Father of Fuzzy Set Theory and Fuzzy Logic (Dr. Lotfi A. Zadeh). Int. J. Swarm Intell. Evol. Comput, 2018. 7: p. 2. <https://doi.org/10.4172/2090-4908.1000170>

[47]. Zorluer, I., et al., Application of a fuzzy rule-based method for the determination of clay dispersibility. Geoderma, 2010. 160(2): p. 189-196. <https://doi.org/10.1016/j.geoderma.2010.09.017>

Geological Engineering, 2024. 42(3): p. 2205-2220. <https://doi.org/10.1007/s10706-023-02669-1>

[33]. Kumar ,D.R., P. Samui, and A. Burman, Prediction of probability of liquefaction using soft computing techniques. Journal of The Institution of Engineers (India): Series A, 2022. 103(4): p. 1195-1208. <https://doi.org/10.1007/s40030-022-00683-9>

[34]. Alizadeh Mansouri, M. and R. Dabiri, Predicting the liquefaction potential of soil layers in Tabriz city via artificial neural network analysis. SN Applied Sciences, 2021. 3: p. 1-31 <https://doi.org/10.1007/s42452-021-04704-3>.

[35]. Baziar, M. and N. Nilipour, Evaluation of liquefaction potential using neural-networks and CPT results. Soil Dynamics and Earthquake Engineering, 2003. 23(7): p. 631-636. [https://doi.org/10.1016/S0267-7261\(03\)00068-X](https://doi.org/10.1016/S0267-7261(03)00068-X)

[36]. Mughieda, O., K. Bani-Hani, and B. Safieh, Liquefaction assessment by artificial neural networks based on CPT. International Journal of Geotechnical Engineering, 2009. 3(2): p. 289-302. <https://doi.org/10.3328/IJGE.2009.03.02.289-302>

[37]. Seed, H.B. and I.M. Idriss, Simplified procedure for evaluating soil liquefaction potential. Journal of the Soil Mechanics and Foundations division, 1971. 97(9): p. 1249-1273. <https://doi.org/10.1061/JSFEAQ.0001662>

[38]. Liao, S.S. and R.V. Whitman, Overburden correction factors for SPT in sand. Journal of geotechnical engineering, 1986. 112(3): p. 373-377. [https://doi.org/10.1061/\(ASCE\)0733-9410\(1986\)112:3\(373\)](https://doi.org/10.1061/(ASCE)0733-9410(1986)112:3(373))

[39]. Robertson, P.K. and C. Wride, Evaluating cyclic liquefaction potential using the cone penetration test. Canadian geotechnical journal, 1998. 35(3): p. 442-459. <https://doi.org/10.1139/t98-017>

[40]. Robertson, P.K., Soil classification using the cone penetration test. Canadian geotechnical journal, 1990. 27(1): p. 151-158.