

## Predicting the probability of liquefaction using Taguchi-optimized artificial neural network and comparing it with the results of different machine learning algorithms

Esmaeil Eksiri<sup>1</sup>, Mojtaba Karimaei Tabarestani<sup>2\*</sup>, Ali Nabizadeh<sup>3</sup>, Mostafa Adresi<sup>4</sup>

1- Graduated in Geotechnical Engineering, Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran

2- Associate Professor, Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran

3- Assistant Professor, Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran

4- Associate Professor, Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran

### ABSTRACT

Soil liquefaction is a phenomenon that occurs due to the loss of resistance of saturated soil mass during an earthquake. In this case, the structure built on this soil loses its static equilibrium and overturns. Therefore, predicting liquefaction is a very important issue in civil engineering. There are various methods for determining the potential of soil liquefaction, most of which are based on field tests and empirical equations, which can sometimes be accompanied by a large approximation. Today, the use of modern artificial intelligence methods is of great importance for solving complex engineering problems. Accordingly, in this paper, an attempt was made to predict the occurrence of liquefaction in a region by using an artificial neural network and optimizing it with the Taguchi design of experiments method. In the first step, by collecting existing data on the occurrence of liquefaction in different parts of the world, two datasets were created based on CPT and SPT tests. Next, using the Taguchi design of experiments method, the components of the artificial neural network, including the number of neurons in the middle layers and the activation function, were optimized, and the highest accuracy was obtained for the two datasets of CPT and SPT, equal to 0.89 and 0.73, respectively. Then, the evaluation of the obtained results with the results of 5 different machine learning models, including support vector machine, logistic fitting, k-nearest neighbor, decision tree, and random forest, showed that the optimized artificial neural network gives the best results. Finally, comparing the results of the present model with the experimental method of calculating the liquefaction coefficient shows the higher accuracy of the present model.

### ARTICLE INFO

Receive Date: 26 May 2025  
Revise Date: 01 September 2025  
Accept Date: 27 September 2025

### Keywords:

Liquefaction  
Artificial neural network  
Taguchi design of experiments  
Datasets  
Optimization

All rights reserved to Iranian Society of Structural Engineering.

doi: <https://doi.org/10.22065/jsce.2025.523786.3730>

\*Corresponding author: Mojtaba Karimaei Tabarestani  
Email address: Karimaei@sru.ac.ir

## پیش‌بینی احتمال وقوع روانگرایی با استفاده از شبکه عصبی مصنوعی بهینه‌شده با تاگوچی و مقایسه آن با نتایج الگوریتم‌های مختلف یادگیری ماشین

اسماعیل اکثیری<sup>۱</sup>، مجتبی کریمائی طبرستانی<sup>۲\*</sup>، علی نبی‌زاده<sup>۳</sup> و مصطفی آدرسی<sup>۴</sup>

۱- دانش‌آموخته مهندسی ژئوتکنیک، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجائی، تهران، ایران

۲- دانشیار، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجائی، تهران، ایران

۳- استادیار، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجائی، تهران، ایران

۴- دانشیار، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجائی، تهران، ایران

### چکیده

روانگرایی خاک پدیده‌ای است که به علت از بین رفتن مقاومت توده خاک‌های اشباع در هنگام وقوع زمین‌لرزه رخ می‌دهد. در این حالت، سازه ساخته شده بر روی این خاک، تعادل استاتیکی خود را از دست می‌دهد و واژگون می‌شود. به این ترتیب، پیش‌بینی روانگرایی از مسائل بسیار مهم در مهندسی عمران است. روش‌های مختلفی برای تعیین پتانسیل روانگرایی خاک وجود دارد که عمده آنها مبتنی بر آزمایشات میدانی و معادلات تجربی هستند که بعضاً می‌توانند با تقریب زیادی همراه شوند. امروزه استفاده از روش‌های نوین هوش مصنوعی برای حل مسائل پیچیده مهندسی از اهمیت زیادی برخوردار است. بر این اساس، در این مقاله سعی شد تا با استفاده از شبکه عصبی مصنوعی و بهینه‌سازی آن با روش طراحی آزمایش‌های تاگوچی اقدام به پیش‌بینی وقوع روانگرایی در یک منطقه شود. در اولین قدم با جمع‌آوری داده‌های موجود در زمینه وقوع روانگرایی در نقاط مختلف دنیا، اقدام به ایجاد دو پایگاه داده بر مبنای آزمایش‌های *CPT* و *SPT* شد. در ادامه با استفاده از روش طراحی آزمایش‌های تاگوچی، مؤلفه‌های شبکه عصبی مصنوعی شامل تعداد نرون‌های لایه‌های میانی و تابع فعال‌سازی بهینه شد و بیشترین دقت بدست آمده برای دو پایگاه داده مورد بررسی *CPT* و *SPT* به ترتیب با مقدار تابع صحت برابر ۰/۸۹ و ۰/۷۳ بدست آمد. سپس ارزیابی نتایج بدست آمده با نتایج حاصل از ۵ مدل مختلف یادگیری ماشین شامل ماشین بردار پشتیبان، برازش لجستیک، *k* نزدیک‌ترین همسایه، درخت تصمیم و جنگل تصادفی نشان داد که شبکه عصبی مصنوعی بهینه شده بهترین نتایج را بدست می‌دهد. در نهایت مقایسه نتایج مدل حاضر با روش تجربی محاسبه ضریب روانگرایی نشان‌دهنده دقت بالاتر مدل حاضر است.

کلمات کلیدی: روانگرایی، شبکه عصبی مصنوعی، طراحی آزمایش‌های تاگوچی، پایگاه داده، بهینه‌سازی

| سابقه مقاله:    |            | شناسه دیجیتال:         |               |            |                                                                                                             |
|-----------------|------------|------------------------|---------------|------------|-------------------------------------------------------------------------------------------------------------|
| دریافت          | بازنگری    | پذیرش                  | انتشار آنلاین | چاپ        | doi:                                                                                                        |
| ۱۴۰۴/۰۳/۰۵      | ۱۴۰۴/۰۶/۱۰ | ۱۴۰۴/۰۷/۰۵             | ۱۴۰۴/۰۷/۰۵    | ۱۴۰۵/۰۲/۳۱ | <a href="https://doi.org/10.22065/jsce.2025.523786.3730">https://doi.org/10.22065/jsce.2025.523786.3730</a> |
| *نویسنده مسئول: |            | مجتبی کریمائی طبرستانی |               |            |                                                                                                             |
| پست الکترونیکی: |            | karimaei@sru.ac.ir     |               |            |                                                                                                             |

## ۱- مقدمه

روانگرایی خاک پدیده‌ای است که در اثر از بین رفتن مقاومت توده خاک‌های اشباع در حین زلزله رخ می‌دهد و در صورت وجود سازه بر روی خاک در این شرایط، تعادل استاتیکی سازه بهم می‌خورد و دچار نشست و واژگونی می‌کند [۱]. طی این فرآیند، رفتار خاک از حالت جامد به حالت مایع تغییر می‌کند. از طرفی، افزایش جمعیت در شهرها و تاثیر مستقیم روانگرایی بر روی ایمنی سازه‌ها، اهمیت مطالعه بر روی این پدیده را در مهندسی عمران دوچندان می‌کند [۲ و ۳].

از میان موضوعات مختلف مطرح در بحث روانگرایی، بیشترین چیزی که توجه مهندسين را جلب کرده است ارزیابی پتانسیل زمین برای رخ دادن روانگرایی است [۴]. روانگرایی ارتباط بسیار نزدیکی با مشخصات زلزله دارد، دو زلزله بزرگ در شهر نیگاتای ژاپن و آلاسکای آمریکا، باعث ایجاد روانگرایی خاک در مقیاس‌های بسیار بزرگ شدند [۵]. اثرات مخرب روانگرایی‌های ناشی از این زلزله‌ها، پژوهشگران را به مطالعه بر روی فرایند رخ دادن روانگرایی واداشته است. بر اساس مطالعات صورت گرفته، منشا این پدیده به مفهوم تنش موثر ربط داده شد که دلیل تعادل ذرات خاک است [۵]. این تنش، بر اثر وزن و فشار ذرات جامد به وجود می‌آید و اجزای خاک را در کنار یکدیگر نگه می‌دارد. اگر تنش مؤثر از بین برود، دیگر نیرویی برای ثابت نگه داشتن ذرات خاک وجود ندارد. در شرایط روانگرایی به علت افزایش فشار آب حفره‌ای و کاهش تنش موثر، توده خاک همانند مایعات رفتار می‌کند که باعث تغییر شکل و جریان یافتن آن می‌شود. روانگرایی پدیده‌ای است که بیشترین آسیب را به ساختمان هنگام رخ دادن زلزله وارد می‌کند [۶].

در طول ۳۰ سال گذشته، بسیاری از محققان روش‌هایی را برای پیش‌بینی پتانسیل روان‌گرایی خاک پیشنهاد کردند. برای تعیین مقاومت روانگرایی خاکها از نتایج آزمایشات آزمایشگاهی و صحرایی استفاده می‌شود [۷]. برای انجام آزمایشات آزمایشگاهی اخذ نمونه‌های دست‌نخورده با کیفیت بالا نیاز است که این کار بسیار پرهزینه است. از روش‌های تجربی می‌توان به روش مبتنی بر تنش برش چرخه‌ای<sup>۱</sup>، روش مبتنی بر آزمایش‌های نفوذ مخروط CPT، روش مبتنی بر آزمایش نفوذ استاندارد SPT و روش مبتنی بر سرعت موج برشی VS اشاره کرد. اکثر این روش‌ها، ضریب ایمنی خاک FS را به عنوان مبنای ارزیابی پتانسیل روانگرایی در نظر می‌گیرند که به صورت تقسیم مقدار فراسنجه‌های نسبت مقاومت تناوبی CRR و نسبت تنش تناوبی CSR تعریف می‌شود. به عنوان نمونه روابط (۱) تا (۳) نحوه محاسبه FS را بر اساس نتایج آزمایش نفوذ استاندارد ارائه می‌دهند: [۳]

$$FS = \frac{CRR}{CSR} \quad (۱)$$

که در آن

$$CSR = 0.65 \frac{a_{\max}}{g} \frac{\sigma_v}{\sigma'_v} r_d \quad (۲)$$

و

$$CRR = \left( \frac{1}{34 - N_{1,60}} + \frac{N_{1,60}}{135} + \frac{50}{(10N_{1,60} + 45)^2} - \frac{1}{200} \right) \times MSF \quad (۳)$$

در روابط فوق

$a_{\max}$  اوج شتاب افقی در سطح زمین ناشی از زلزله،  $g$  شتاب ثقل،  $\sigma_v$  تنش عمودی کل،  $\sigma'_v$  تنش عمودی موثر،  $I_d$  ضریب کاهش تنش برشی با در نظر گرفتن پاسخ دینامیکی خاک در عمق مربوطه،  $N_{1,60}$  مقدار نرمال شده تعداد ضربه‌های چکش در آزمایش SPT برای

<sup>1</sup> Cyclic Stress Ratio (CSR)

فشار روباره ۱۰۰ کیلو پاسکال و نسبت انرژی چکش ۶۰ درصد و MSF فاکتور اصلاح شدت زلزله می باشد. جزئیات این روابط در تحقیقات مختلف نظیر [۳] موجود است.

با توجه به تعریف FS چنانچه مقدار این ضریب کمتر از یک باشد زمین مستعد وقوع روانگرایی است و اگر بیشتر از ۱ باشد روانگرایی رخ نمی دهد.

محدودیت روش آزمایشگاهی اتکای آنها به روش های نمونه برداری و انجام آزمایش است که می تواند پرهزینه و غیر قابل اعتماد باشند. ایراد اصلی روش های آماری مرسوم هم به دقت ناکافی آنها به علت تقریب های موجود در مدل و فراسنجه ها بر می گردد [۷]. با توسعه هوش مصنوعی و علم داده محققان در سال های اخیر به حل این مشکل پرداختند.

جوانگ و همکاران در سال ۲۰۰۳ از شبکه عصبی مصنوعی<sup>۱</sup> برای پیش بینی روانگرایی خاک استفاده نمودند. ایشان از ۲۲۶ نمونه داده آزمایش CPT برای پیاده سازی مدل استفاده نمودند که مدل آنها توانست با مقدار تابع صحت<sup>۲</sup> ۰/۹۱ داده های روانگرایی را پیش بینی کند [۷]. مقدار تابع صحت شامل نسبت تعداد پیش بینی های صحیح بر تعداد کل پیش بینی ها است و هر چه مقدار این تابع به عدد ۱ نزدیکتر باشد دقت الگوریتم استفاده شده بیشتر است. در تحقیق دیگری پال در سال ۲۰۰۶ از ماشین بردار پشتیبان برای پیش بینی داده های روانگرایی حاصل از آزمایش های CPT و SPT استفاده کردند و توانستند به مقدار تابع صحت برابر با ۰/۹۶ دست یابند [۸]. در سال ۲۰۰۷ هانا و همکارانش مدل شبکه عصبی برازش تعمیم یافته را بر روی داده هایی روانگرایی برداشت شده از زلزله سال ۱۹۹۹ تایوان و ترکیه، پیاده کردند. ایشان همچنین نتیجه گرفتند که سرعت موج برشی تأثیر چندانی در پیش بینی روانگرایی در مدل ندارد. همچنین مؤلفه مقاومت در برابر نفوذ به عنوان مؤلفه مؤثر شناخته شد [۹]. سامویی و سیتهارام در سال ۲۰۱۱، دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان<sup>۳</sup> را بر روی یک پایگاه داده مبتنی بر آزمایش SPT پیاده کردند. نتایج آنها نشان داد که ماشین بردار پشتیبان مدل بهتری برای پیش بینی احتمال رخ دادن روانگرایی در خاک نسبت به شبکه عصبی مصنوعی است [۱۰]. علوی و گندمی در سال ۲۰۱۱ از سه مدل برنامه نویسی ژنتیک<sup>۴</sup>، برنامه نویسی ژنتیکی خطی<sup>۵</sup> و برنامه نویسی چندبیینی<sup>۶</sup> برای ارزیابی رخداد روانگرایی استفاده کردند. در این تحقیق مدل برنامه ژنتیک ضعیف ترین عملکرد را نسب به بقیه مدل ها داشت [۱۱]. سامویی و سنتر در سال ۲۰۱۲ ماشین بردار پشتیبان حداقل مربعات<sup>۷</sup> و شبکه عصبی مصنوعی را بر روی داده های حاصل از آزمایش های CPT بررسی کردند. نتایج آنها نشان داد شتاب زلزله موثرترین فراسنجه در وقوع روانگرایی است [۱۱]. ژویی و یانگ در سال ۲۰۱۳ از سامانه استنتاج عصبی فازی تطبیقی<sup>۸</sup> برای پیش بینی احتمال وقوع روانگرایی استفاده کردند و توانستند به مقدار تابع صحت برابر با ۰/۷۸ برسند [۱۲]. ون کاتش و همکارانش در سال ۲۰۱۳ دقت شبکه عصبی مصنوعی و سامانه استنتاج عصبی فازی تطبیقی را برای پیش بینی روانگرایی مورد مقایسه قرار دادند و نتیجه گرفتند که شبکه عصبی مصنوعی نتایج بهتری داشت [۱۳]. مادالی و همکارانش در سال ۲۰۱۴ از برنامه نویسی ژنتیک چندلایه<sup>۹</sup> برای پیش بینی روانگرایی استفاده کردند و توانستند به مقدار تابع صحت برابر با ۰/۹۵ دست یابند [۱۴]. کوهستانی و همکارانش در سال ۲۰۱۵ از سامانه جنگل تصادفی<sup>۱۰</sup> برای پیش بینی احتمال وقوع روانگرایی استفاده کردند. آنها نتایج کار خود را با مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقایسه کردند و نتیجه گرفتند که مدل جنگل تصادفی دقت بالاتری دارد [۱۵]. عباس زاده در سال ۲۰۱۶ با استفاده از شبکه عصبی مصنوعی مدلی را با استفاده از داده هایی مکانیکی و ژئوتکنیکی و مدل دیگری را با استفاده از داده های زلزله برای پیش بینی احتمال وقوع روانگرایی توسعه داد و نتیجه گرفت که دقت مدل حاصل از داده های زلزله کمتر است [۱۶]. هو و همکارانش در سال ۲۰۱۶ از شبکه بییزی<sup>۱۱</sup> برای پیش بینی احتمال وقوع

<sup>1</sup> Artificial Neural Network (ANN)

<sup>2</sup> Accuracy score

<sup>3</sup> Support Vector Machine (SVM)

<sup>4</sup> Genetic Programming (GP)

<sup>5</sup> Regression Genetic Programming (RGP)

<sup>6</sup> Multi-statement Programming (MSP)

<sup>7</sup> Least squares support vector machines (LSSVM)

<sup>8</sup> Adaptive neuro-fuzzy Inference System (ANFIS)

<sup>9</sup> Multi Layer Genetic Programming (MLGP)

<sup>10</sup> Random Forest (RF)

<sup>11</sup> Bayesian network (BN)

روانگرایی استفاده کردند. ایشان نتایج مدل خود را با نتایج مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقایسه کردند و نتیجه گرفتند که مدل شبکه باور نتایج بهتری به دست می‌دهد [۱۷]. ژو و لیو در سال ۲۰۱۷ از مدل‌های سامانه ازدحام ذرات<sup>۱</sup> و برنامه ژنتیک برای بهینه‌کردن شبکه عصبی مصنوعی پس‌انتشار استفاده کردند و نتایج آن‌ها نشان داد که این دو مدل در بهینه‌سازی موثرند [۱۸]. در سال ۲۰۱۸ هوانگ و بویی از مدل جدیدی برای پیش‌بینی وقوع روانگرایی استفاده کردند. این مدل تحلیل تشخیصی کرنل فشر<sup>۲</sup> را با ماشین بردار پشتیبان حداقل مربعات ترکیب می‌کرد. به‌طور ساده آن‌ها با استفاده از معرفی یک ویژگی اضافه برای رکوردها و با استفاده از ماشین بردار پشتیبان حداقل مربعات داده‌ها را مرزبندی کردند و مدلی برای پیش‌بینی احتمال وقوع روانگرایی توسعه دادند [۱۹]. در ادامه جی‌لی و هایوبی در سال ۲۰۱۹ برای پیش‌بینی روانگرایی خاک از مدل شبکه باور بر روی پایگاه داده‌های آزمایش CPT و داده‌های مبتنی بر سرعت موج برشی استفاده کردند [۲۰]. ژائو و همکاران (۲۰۱۹) از مدل تقویت گرادیان تصادفی<sup>۳</sup> برای پیش‌بینی وقوع روانگرایی استفاده کردند. با وجود اینکه این مدل در مقایسه با مدل‌های یادگیری آماری مرسوم در چندین کاربرد مهندسی، قدرت پیش‌بینی بالایی را نشان داده بود ولی مقدار تابع صحت آن در پیش‌بینی روانگرایی برابر با ۰/۸۸ بدست آمد [۲۱]. نجوک و همکاران در سال ۲۰۲۰ از الگوریتم شبکه عصبی تکاملی<sup>۴</sup> همراه با روش کاهش ابعاد برای پیش‌بینی روانگرایی استفاده کردند. مدل شبکه عصبی تکاملی دارای تلاقی روش تکامل دیفرانسیل و الگوریتم بهینه‌سازی شیب تصادفی<sup>۵</sup> است. همچنین از روش کاهش ابعاد برای تجسم مجموعه داده‌های آموزش، آزمون و عملکرد مدل شبکه عصبی تکاملی جدید استفاده شد. نتایج ایشان در این مدل راضی‌کننده بود [۲۲]. کامورا و همکاران در سال ۲۰۲۱ مدلی را با استفاده از سوابق لرزه‌ای زمین و شبکه عصبی مصنوعی ارائه دادند. این مدل درجه افزایش فشار آب منفذی اضافی را به عنوان خروجی بر اساس رکوردهای لرزه‌ای بدست‌آمده از آزمایش میز لرزه سه‌بعدی پیش‌بینی می‌کرد. این محققین مدل خود را با سه سری داده زلزله واقعی ارزیابی کردند و نتایج قابل قبولی رسیدند [۲۳]. در نهایت جیان و همکارانش در سال ۲۰۲۱ عملکرد مدل‌های ترکیبی را برای پیش‌بینی پتانسیل روان‌گرایی خاک ارزیابی کردند. آن‌ها برای پیش‌بینی روانگرایی دو مدل ماشین بردار پشتیبان را پیشنهاد کردند که با الگوریتم ژنتیک و الگوریتم گرگ خاکستری<sup>۶</sup> بهینه‌سازی شده بودند [۲۴].

بررسی مراجع نشان می‌دهد که در تحقیقات گذشتگان ضعف‌هایی از جمله دقت کم مدل توسعه داده شده، نبود یک پایگاه جامع داده از سراسر جهان و پیچیدگی استفاده از معادلات و مدل‌های ارائه شده، دیده می‌شود. بر این اساس در تحقیق حاضر سعی شد با تکیه بر پایگاه داده‌ای جامع و جهان شمول و روش‌های مختلف معمول علم داده بخصوص شبکه عصبی مصنوعی اقدام به پیش‌بینی روانگرایی شود. برای این منظور از دو پایگاه داده مبتنی بر آزمایش‌های CPT و SPT استفاده شد. همچنین برای بهینه‌سازی شبکه عصبی، روش طراحی آزمایشات تاگوچی به کار گرفته شد. در نهایت دقت حاصل از این روش در پیش‌بینی داده‌ها با دیگر روش‌های معمول یادگیری ماشین و همچنین معادلات تجربی مورد مقایسه قرار گرفت.

## ۲- مواد و روش‌ها

در این بخش شرح مختصری از پایگاه‌های داده و ویژگی‌های آنها به همراه روش‌های یادگیری ماشین مورد استفاده در تحقیق حاضر ارائه می‌شود:

### ۲-۱-۲- شرح پایگاه داده‌ها

#### ۲-۱-۱-۲- پایگاه داده ۱: داده‌های مبتنی بر آزمایش CPT

<sup>1</sup> Particle Swarm (PS)

<sup>2</sup> Kernel Fisher Discriminant Analysis (KFDA)

<sup>3</sup> Stochastic Gradient Boosting (SGB)

<sup>4</sup> Evolutionary Neural Network (ENN)

<sup>5</sup> Stochastic Gradient Descent (SGD)

<sup>6</sup> Gray Wolf Algorithm (GWA)

در تحقیق حاضر، ۹۵۸ سری داده از مقالات یانگ و همکاران [۷]، ماهش و همکاران [۸]، ژویی و همکاران [۱۲]، [۱۸]، اریک و موس [۲۵] و گاه و گاه [۲۶] به عنوان پایگاه داده ۱ مربوط به پدیده روانگرایی خاک جمع آوری شدند. این داده‌ها از نقاط مختلف کره زمین شامل ایالت‌های سن فرانسیسکو، کالیفرنیا و آیداهو، شهرهای چوبو و نیگاتا ژاپن، اجکو نیوزیلند، تایوان، هایچنگ و تانگشان چین، ورنچا رومانی، مکزیک، برداشت شده‌اند. به طور کلی روش کار در آزمایش CPT به این گونه است که در مرحله اول مخروط استاندارد به درون گمانه فرو برده می‌شود و مقاومت نوک و جداره مخروط محاسبه می‌شود. با داشتن این مقاومت‌ها می‌توان ویژگی‌های خاک را به دست آورد. بر اساس استاندارد این آزمایش لازم است مخروطی به قطر ۳/۵۷ سانتی‌متر که دارای زاویه راس ۶۰ درجه است با سرعت ۲ سانتی‌متر در ثانیه به داخل زمین فرو برده شود. این کار توسط جک هیدرولیکی انجام می‌شود و با هر میزان نفوذ مقاومت نوک و مقاومت جداره به‌طور پیوسته ثبت می‌شوند.

مؤلفه‌های پایگاه داده ۱ شامل مقاومت مخروط ( $q_c$ )، تنش عمودی کل ( $\sigma_v$ )، تنش عمودی موثر ( $\sigma'_v$ )، اوج شتاب افقی نرمال شده ( $a_{max}$ )، بزرگی زلزله ( $M_w$ ) و وقوع یا عدم وقوع روانگرایی (Liquified) هستند. در جدول ۱ مشخصات این پایگاه داده نشان داده شده است.

جدول ۱: مشخصات داده‌ها در پایگاه داده ۱

| مؤلفه‌ها                | تعداد | بیشینه | کمینه | میانگین | انحراف معیار استاندارد |
|-------------------------|-------|--------|-------|---------|------------------------|
| مقاومت مخروط            | ۹۵۸   | ۳۱/۴   | ۰/۳۸  | ۵/۸۱    | ۴/۳۵                   |
| تنش عمودی کل            | ۹۵۸   | ۲۹۶/۳  | ۱۶/۷  | ۹۴/۵۸   | ۵۳/۷۸                  |
| تنش عمودی موثر          | ۹۵۸   | ۲۷۴    | ۱۴/۱  | ۷۵/۸    | ۴۱/۹۶                  |
| اوج شتاب افقی نرمال شده | ۹۵۸   | ۰/۸    | ۰/۰۸  | ۰/۲۸    | ۰/۱۴                   |
| بزرگی زلزله             | ۹۵۸   | ۸      | ۶     | ۷/۱     | ۰/۵۳                   |

## ۲-۱-۲ پایگاه داده ۲: داده‌های مبتنی بر آزمایش SPT

مجموع داده‌های مربوط به این پایگاه داده که از مقالات پال [۸]، هانا و همکارانش [۹] و اریک و موس [۲۵] برداشت شده‌اند، ۸۸۶ سری داده می‌شود. این داده‌ها مربوط به وقوع پدیده روانگرایی از نقاط مختلف کره زمین شامل ایالت‌های سن‌فرانسیسکو، کالیفرنیا و آلاسکا در آمریکا، شهرهای چوبو، کوشوریکه، نیگاتا، تونانکانی، فوکو، توکاجیوکی و میاگینوکی ژاپن، هایچنگ و تانگشان چین، لوزون فیلیپین، گویاتمالا، آرژانتین، تایوان و ترکیه جمع‌آوری شده‌اند. به طور کلی روش کار آزمایش نفوذ SPT به این گونه است که در مرحله اول گمانه‌ای با قطر ۲/۵ تا ۱۸ اینچ تا عمق مورد نظر، حفر می‌گردد. سپس میله از سر مته حفاری در عمق مورد نظر جدا شده و نمونه‌گیر که از یک استوانه توخالی تشکیل شده است و می‌تواند در امتداد طول خود به دو نیم تقسیم شود، متصل می‌گردد. در مرحله بعد استوانه توسط چکش ۶۳/۵ کیلوگرمی از ارتفاع ۷۵ سانتی‌متری با استفاده از مکانیزم اتومکانیک و یا با مکانیزم قرقره و طناب به درون زمین رانده می‌شود. عدد آزمایش نفوذ استاندارد از تعداد ضربات لازم برای نفوذ ۱۵ سانتی‌متر اول، دوم و سوم بدست می‌آید. نتایج آزمایش بدست‌آمده برای ۱۵ سانتی‌متر اول ممکن است به دو دلیل دست‌خورده شدن خاک محدوده مذکور در عملیات حفاری و ریزش جدار گمانه، مورد اعتماد و اعتبار نباشد. به همین خاطر معمولاً از نتایج ۱۵ سانتی‌متر دوم و سوم استفاده می‌شود. در انتهای آزمایش نمونه‌گیر از میله حفاری جدا می‌شود و خاک درون نمونه‌گیر به عنوان نمونه دست‌نخورده به آزمایشگاه برای انجام آزمایش‌های بیشتر ارسال می‌شود.

مؤلفه‌های مربوط به این پایگاه داده شامل عدد آزمون نفوذ استاندارد ( $N$ )، تنش عمودی کل ( $\sigma_v$ )، تنش عمودی موثر ( $\sigma'_v$ )، اوج شتاب افقی نرمال شده ( $a_{max}$ )، بزرگی زلزله ( $M_w$ ) و وقوع یا عدم وقوع روانگرایی (liquified) هستند. با توجه به اختلاف مؤلفه‌های این پایگاه داده، با پایگاه داده ۱، امکان ادغام این پایگاه‌های داده وجود نداشت. درواقع در رویکرد مربوط به پایگاه داده ۱، از مقاومت مخروط برای پیش‌بینی وقوع روانگرایی استفاده شده است، درحالی‌که در رویکرد پایگاه داده ۲ از عدد آزمون نفوذ استاندارد استفاده شده است. در جدول ۲ مشخصات این پایگاه داده نشان داده شده است.

جدول ۲: مشخصات داده‌ها در پایگاه داده ۲


| مؤلفه‌ها                 | تعداد | بیشینه | کمینه | میانگین | انحراف معیار استاندارد |
|--------------------------|-------|--------|-------|---------|------------------------|
| عدد آزمون نفوذ استاندارد | ۸۸۶   | ۶۳     | ۱     | ۱۴/۵۱   | ۱۱                     |
| تنش عمودی کل             | ۸۸۶   | ۶۸۶/۶  | ۱۲/۱  | ۱۳۱/۰۳  | ۸۹/۵۵                  |
| تنش عمودی موثر           | ۸۸۶   | ۲۳۳/۷  | ۷/۵   | ۷۶/۸۹   | ۴۶/۹۹                  |
| اوج شتاب افقی نرمال شده  | ۸۸۶   | ۰/۸۴   | ۰/۰۵  | ۰/۳۵    | ۰/۱۵                   |
| بزرگی زلزله              | ۸۸۶   | ۸/۳    | ۵/۵   | ۷/۳۹    | ۰/۳۴                   |

## ۲-۲- روش‌های یادگیری ماشین

در ادامه توضیحات مختصری از روش‌های مختلف یادگیری ماشین که در تحقیق حاضر مورد استفاده قرار گرفته‌اند، ارائه می‌شود.

### ۲-۲-۱- شبکه عصبی مصنوعی

اصطلاح شبکه عصبی مصنوعی از شبکه‌های عصبی طبیعی گرفته شده است که ساختار مغز انسان را توسعه می‌دهند. مشابه مغز انسان که دارای نورون‌های متصل به یکدیگر است، شبکه‌های عصبی مصنوعی نیز دارای نورون‌هایی هستند که در لایه‌های مختلف شبکه به یکدیگر متصل هستند. این نورون‌ها به عنوان گره شناخته می‌شوند. یک شبکه عصبی مصنوعی تلاش می‌کند شبکه‌ای از نورون‌ها که مغز انسان را می‌سازند تقلید کند، تا رایانه‌ها گزینه‌ای برای درک موضوعات و تصمیم‌گیری به شیوه‌ای شبیه به انسان داشته باشند. به منظور درک شبکه عصبی باید نگاهی به ساختار شبکه و اجزای تشکیل‌دهنده آن داشت. همان‌طور که در شکل ۱ نمایش داده شده است شبکه عصبی از چندین لایه تشکیل می‌شود که حداقل تعداد این لایه‌ها، ۳ لایه است هر لایه شبکه عصبی شامل مجموعه‌ای از گره‌ها است که عملکردی مشابه با نورون‌های مغز انسان دارند [۲۷].




شکل ۱: انواع لایه‌ها در یک شبکه عصبی مصنوعی [۲۷]

لایه ورودی، داده‌های ورودی به مسئله را دریافت می‌کند و در ادامه به منظور اعمال محاسبات مختلف بر روی داده‌ها، آن‌ها را به لایه بعدی می‌فرستد. لایه یا لایه‌هایی که در میان لایه ورودی و لایه خروجی قرار می‌گیرند، لایه پنهان یا لایه میانی نامیده می‌شوند. حداقل تعداد لایه‌های میانی شبکه عصبی، یک لایه است و بر اساس پیچیدگی و نوع مسئله می‌توان به تعداد لایه‌های میانی شبکه اضافه کرد. در نهایت آخرین لایه شبکه عصبی، لایه خروجی نام دارد که مقادیر خروجی شبکه عصبی را محاسبه می‌کند. به عبارتی، لایه خروجی، با دریافت ورودی خود از لایه قبلی (لایه پنهان)، محاسباتی بر روی آن‌ها انجام داده و در نهایت خروجی شبکه را تولید می‌کند [۲۷].

در لایه نخست شبکه عصبی، ورودی گره‌ها در قالب بردارهای عددی با طول یکسان هستند. به عنوان مثال، در مسئله تشخیص اشیاء، ورودی گره‌های لایه نخست، لیستی از مقادیر پیکسل‌های تصاویر است. ورودی گره‌ها در لایه‌های پنهان و لایه خروجی، مقادیر خروجی حاصل از لایه‌های قبلی آن‌هاست. وزن‌ها میزان اهمیت ورودی‌های گره‌ها را مشخص می‌کنند. به عبارتی، با اعمال ضرب داخلی مقدار ورودی گره و ماتریس وزن، به علاوه بایاس، ورودی تابع فعال‌سازی آماده می‌شود و تابع فعال‌سازی گره مشخص می‌کند که ورودی وارد شده مهم است یا خیر؟ در واقع تابع فعال‌سازی باید خروجی را از مقادیر ورودی استخراج کند تا به لایه پنهان بعدی یا خروجی انتقال داده شود. همه لایه‌های پنهان معمولاً از یک تابع فعال‌سازی استفاده می‌کنند در حالی که، لایه خروجی معمولاً از یک تابع فعال‌سازی متفاوت از لایه‌های

پنهان استفاده می‌کند. انتخاب نوع تابع بستگی به هدف یا نوع پیش‌بینی انجام شده توسط مدل دارد. در شکل ۲ عملیات‌های گفته‌شده نمایش داده شده است [۲۷].



شکل ۲: مراحل پیش‌بینی خروجی در شبکه عصبی مصنوعی [۲۷]

از مهمترین توابع فعال‌سازی می‌توان به توابع زیر اشاره کرد.

**تابع سیگموید<sup>۱</sup>** - تابع سیگموید یک تابع ریاضی با منحنی  $S$  شکل یا منحنی سیگموید است. این تابع، هر مقدار  $x$  در دامنه تابع  $f(x)$  را به عددی بین ۰ و ۱ تبدیل می‌کند. از لحاظ ریاضی این تابع به صورت رابطه (۴) تعریف می‌شود: [۲۷]

$$f(x) = \frac{e^{-x}}{1 + e^{-x}} \quad (4)$$

**تابع فعال‌سازی خطی اصلاح‌شده<sup>۲</sup>** - این تابع رایج‌ترین تابع فعال‌سازی در مدل‌های یادگیری عمیق است. تابع اگر ورودی منفی دریافت کند صفر را برمی‌گرداند، اما برای هر مقدار مثبت  $x$  همان مقدار را بر می‌گرداند. از لحاظ ریاضی این تابع به صورت رابطه (۵) تعریف می‌شود:

$$f(x) = \text{Max}[0, x] \quad (5)$$

**تابع سوییش<sup>۳</sup>** - این تابع فعال‌سازی توسط محققان گوگل توسعه‌یافته است و در شبکه‌های عمیق اعمال‌شده در حوزه‌های مختلف چالش‌برانگیز مانند طبقه‌بندی تصویر، ترجمه ماشینی و غیره کاربرد دارد. از لحاظ ریاضی این تابع به صورت زیر تعریف می‌شود:

$$f(x) = x \cdot \text{Sigmoid}(x) \quad (6)$$

**تابع واحد خطی نمایی<sup>۴</sup>** - یک جایگزین قوی برای تابع فعال‌سازی خطی اصلاح‌شده است زیرا به آرامی مسطح می‌شود. این تابع به جای صفر کردن مقادیر منفی آن‌ها را به مقادیر کوچکتری تبدیل می‌کند. این به شبکه کمک می‌کند تا وزن‌ها و سوگیری‌ها را در جهت درست هدایت کند. مقدار ثابت  $\alpha$  به صورت پیش‌فرض برابر با ۱ قرار داده می‌شود. فرم کلی تابع به صورت زیر است:

$$f(x) = \begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases} \quad (7)$$

<sup>1</sup> Sigmoid

<sup>2</sup> Rectified Linear Activation Function (RELU)

<sup>3</sup> SWISH

<sup>4</sup> Exponential Linear Unit (ELU)



تابع واحد خطی خطای گاوسی<sup>۱</sup> - این تابع نسبت به تابع فعال سازی خطی اصلاح شده نرمتر عمل می کند. فرم کلی تابع به صورت زیر است:

$$f(x) = 0.5x \left( 1 + \tanh \left[ \frac{\sqrt{2}}{\pi} (x + 0.044715x^3) \right] \right) \quad (8)$$

تابع واحد خطی نمایی مقیاس شده<sup>۲</sup> - فرم کلی این تابع به صورت زیر است:

$$f(\alpha, x) = \lambda \begin{cases} \alpha(e^x - 1) & x < 0 \\ x & x \geq 0 \end{cases} \quad (9)$$

که در آن مقادیر  $\lambda$  و  $\alpha$  به ترتیب  $1/0.507$  و  $1/6732$  تعیین شده اند.

## ۲-۲-۲- ماشین بردار پشتیبان

ماشین بردار پشتیبان یکی از محبوب ترین الگوریتم های یادگیری نظارتی است که برای مسائل طبقه بندی و همچنین خطی استفاده می شود. با این حال، در درجه اول، برای مسائل طبقه بندی در یادگیری ماشین استفاده می شود. هدف از ماشین بردار پشتیبان ایجاد بهترین خط یا مرز تصمیم است که بتواند فضای  $n$  بعدی را به دسته هایی تفکیک کند تا بتوان به راحتی نقطه داده جدید را در دسته بندی صحیح قرار داد. این مرز یا بهترین تصمیم، ابرصفحه نامیده می شود. ماشین بردار پشتیبان نقطه هایی را انتخاب می کند که به ایجاد ابرصفحه کمک می کند. این نقطه ها به عنوان بردارهای پشتیبان نامیده می شوند و از این رو، این الگوریتم را ماشین بردار پشتیبان می نامند [۲۸].

## ۲-۲-۳- برازش لجستیک

برازش لجستیک یکی از محبوب ترین الگوریتم های یادگیری ماشینی است که تحت روش یادگیری نظارتی قرار می گیرد. در این روش برای پیش بینی متغیر وابسته طبقه بندی با استفاده از مجموعه معینی از متغیرهای مستقل استفاده می شود. برازش لجستیک خروجی یک متغیر وابسته مقوله ای را پیش بینی می کند. بنابراین نتیجه باید یک مقدار مقوله ای یا گسسته باشد. می تواند بله یا خیر، صفر یا یک، درست یا نادرست و غیره باشد [۲۹]. برازش لجستیک بسیار شبیه به برازش خطی است به جز نحوه استفاده از آن. برازش خطی برای حل مسائل برازش استفاده می شود، در حالی که برازش لجستیک برای حل مسائل طبقه بندی استفاده می شود. در برازش لجستیک، به جای ایجاد یک خط برازش، یک تابع لجستیک به شکل  $S$  قرار داده می شود که دو مقدار حداکثر ۰ یا ۱ را پیش بینی می کند.

## ۲-۲-۴- درخت تصمیم

درخت تصمیم یک روش یادگیری تحت نظارت است که می تواند هم برای مسائل طبقه بندی و هم برای برازش استفاده شود، اما بیشتر برای حل مسائل طبقه بندی ترجیح داده می شود. ساختار این الگوریتم درختی است که در آن گره های داخلی ویژگی های یک مجموعه داده، شاخه ها قوانین تصمیم گیری و هر برگ نشان دهنده نتیجه است [۳۰].

## ۲-۲-۵- جنگل تصادفی

جنگل تصادفی یک الگوریتم یادگیری ماشینی محبوب است که به روش یادگیری نظارت شده تعلق دارد. می توان از آن برای مسائل طبقه بندی و برازش استفاده کرد. همان طور که از نام آن پیداست، جنگل تصادفی یک الگوریتم است که شامل تعدادی درخت تصمیم در زیر مجموعه های مختلف پایگاه داده است جنگل تصادفی به جای تکیه بر یک درخت تصمیم، پیش بینی را از هر درخت و بر اساس اکثریت آرا بر

<sup>1</sup> Gaussian Error Linear Unit (GELU)

<sup>2</sup> Scaled Exponential Linear Unit (SELU)

روی پیش‌بینی‌ها می‌گیرد و خروجی نهایی را پیش‌بینی می‌کند. تعداد بیشتر درختان در جنگل منجر به دقت بالاتر و جلوگیری از مشکل بیش از حد برازش می‌شود [۱۵].

## ۲-۶-۲ k نزدیک‌ترین همسایه

الگوریتم k نزدیک‌ترین همسایه را می‌توان برای برازش و همچنین برای طبقه‌بندی استفاده کرد ولی بیشتر برای مسائل طبقه‌بندی استفاده می‌شود. این الگوریتم بدون مؤلفه است، به این معنی که هیچ فرضی در مورد داده‌های آموزش ایجاد نمی‌کند. به این الگوریتم یادگیرنده تنبل نیز گفته می‌شود، زیرا بلافاصله از مجموعه آموزشی یاد نمی‌گیرد، در عوض مجموعه داده را ذخیره می‌کند و در زمان طبقه‌بندی که داده‌های جدیدی را دریافت می‌کند، آن داده‌ها را در دسته‌ای طبقه‌بندی می‌کند که بسیار شبیه به داده‌های جدید است [۳۱]، [۳۲].

## ۲-۳- فراسنجه تعیین دقت مدل‌ها

روش‌های مختلفی برای بررسی دقت نتایج حاصل از تحلیل‌ها وجود دارد. در تحقیق حاضر به دلیل دوتایی بودن نتایج (وقوع روانگرایی یا عدم وقوع روانگرایی) نیاز به استفاده از توابع خاصی است. مشابه با تحقیقات گذشته در عمده مقایسه‌های حاضر از تابع صحت در زبان برنامه نویسی پایتون استفاده شد. همچنین برای ارزیابی کامل‌تر نتایج از توابع امتیاز اف یک<sup>۱</sup>، بازیابی<sup>۲</sup> و دقت<sup>۳</sup> نیز استفاده شد. به طور مثال چنانچه مدل دو حالت پیش‌بینی یعنی مثبت و منفی داشته باشد، تابع دقت به صورت نسبت پیش‌بینی‌های مثبت درست به کل پیش‌بینی‌های مثبت تعریف می‌شود. همچنین تابع بازیابی نسبت پیش‌بینی‌های مثبت درست را به مجموع پیش‌بینی‌های مثبت درست و پیش‌بینی‌های منفی نادرست را محاسبه می‌کند. در نهایت تابع امتیاز اف یک مقدارهای دو تابع دقت و بازیابی را با هم ترکیب می‌کند و میانگین هارمونیک آن‌ها را به دست می‌دهد. [۳۳]

## ۲-۴- طراحی آزمایش‌های تاکوچی

تئوری تاکوچی توسط Genichi Taguchi از اوایل ۱۹۵۰ در راستای اصلاح سامانه خطوط تلفن در یک شرکت مخابراتی شکل گرفت و در طی دهه ۱۹۸۰ تکامل یافت و از آن به بعد در اکثر شرکت‌های دنیا مورد استفاده قرار گرفت [۳۴]، [۳۵]. در این پژوهش از روش طراحی آزمایشات تاکوچی برای تعیین ساختار شبکه عصبی و یا پیدا کردن مولفه‌های بهینه آن استفاده می‌شود. بر خلاف روش‌های دیگری مانند جستجوی شبکه‌ای<sup>۴</sup> و جستجوی تصادفی<sup>۵</sup>، استفاده از روش طراحی آزمایشات تاکوچی ساده‌تر و سریع‌تر است.

تاکوچی به جای استفاده از ترکیبات فاکتوریلی کامل (همه حالات ممکن) از ترکیبات فاکتوریلی جزئی استفاده می‌کند در این روش برای ترکیب سطوح از جدول‌های خاصی تحت عنوان آرایه‌های متعامد استفاده می‌شود. این آرایه‌ها نوعی ماتریس هستند که متغیرها را با اثرات متقابل آن‌ها مقایسه می‌کنند. تاکوچی در جدولی ۱۸ آرایه متعامد تحت عنوان آرایه‌های متعامد استاندارد ارائه نمود. به عنوان مثال چنانچه برای بدست آوردن هدفی ۵ فاکتور مهم وجود داشته باشد که هر یک از این فاکتورها دارای ۵ سطح باشند برای پیدا کردن سطح‌های بهینه در هر مؤلفه طبق روش معمولی باید ۳۱۲۵ آزمایش انجام شود. در حالیکه با استفاده از انتخاب آرایه متعامد مناسب در روش تاکوچی، این روش تعدادی آزمایش محدود (با توجه به آرایه انتخاب شده) به ما پیشنهاد می‌کند. با تحلیل نتایج این آزمایش‌ها می‌توان سطح‌های بهینه در فاکتورها را پیدا کرد.

در روش تاکوچی انتخاب آرایه متعامد مناسب بسیار مهم است. معمولاً این روش تاکوچی با استفاده از نرم‌افزار Minitab انجام می‌شود و خود نرم‌افزار آرایه متعامد مناسب را با توجه به فاکتورها و سطح‌ها پیشنهاد می‌دهد.

<sup>1</sup> F1 Score

<sup>2</sup> Recall

<sup>3</sup> Precision

<sup>4</sup> Grid search

<sup>5</sup> Random search

این روش را می توان در گام های زیر خلاصه کرد.

گام اول: اولین قدم تعیین تابع هدف است یا به عبارت دیگر تعریف کردن یک مقدار برای عملکرد فرآیند. هدف یک فرآیند می تواند به حداقل یا حداکثر رساندن مقداری باشد مثل به حداکثر رساندن نرخ جریان خروجی یا به حداقل رساندن خطای سیستم.

گام دوم: متغیرهای مؤثر بر فرآیند تعیین شوند. همچنین تعداد سطوحی که متغیرها باید در آن ها تغییر کنند نیز مشخص می شود. با افزایش تعداد سطوح، تعداد آزمایش افزایش می یابد.

گام سوم: آرایه متعامد مناسب انتخاب می شود. این آرایه ها تعداد آزمایش ها و نحوه انجام آن ها را مشخص می کند.

گام چهارم: آزمایش ها انجام شده و خروجی ها مشخص می شود.

گام پنجم: نتایج تحلیل می شود تا ترکیب بهینه از متغیرها مشخص شود.

## ۲-۴-۱- انواع تحلیل ها در روش تاگوچی

### الف) روش استاندارد با استفاده از تحلیل میانگین

روش استاندارد یا روش انحراف از میانگین که در آن بهینه سازی نتایج با استفاده از تحلیل میانگین و تنها حاصل از یک بار انجام آزمایش ها است. با استفاده از رابطه زیر میانگین هر فاکتور در هر سطح حساب می شود. سپس با استفاده از نمودارهای پاسخ، سطح های بهینه بدست می آیند [۳۵].

$$M_{Factor=m}^{Level=1} = \frac{1}{n_{Lm}} \sum_{i=1}^{n_{Lm}} (f_x)_{Factor=m}^{Level=1} \quad (11)$$

در این رابطه  $n_{Lm}$  تعداد دفعات ظهور فاکتور  $m$  در سطح  $L$  است و  $f_x$  داده های مشاهداتی آزمایشگاهی بر اساس الگوی پیشنهاداتی تاگوچی است.

### ب) استفاده از نسبت سیگنال به نویز

مقدار نسبت سیگنال به نویز یا  $S/N$  میزان پراکندگی را حول یک مقدار مشخص بیان می کند یا به بیان دیگر اینکه جواب های مسئله در بین چند آزمایش انجام شده چگونه تغییر کرده اند. برای بدست آوردن این که کدام مقدار بهتر است از سه رابطه استفاده می شود. در روش تاگوچی از یک تابع زیان برای محاسبه تغییرات موجود بین نتایج و مقدار مورد نظر استفاده می شود و این تابع با توجه به شرایط مسئله دارای حالت های مختلف زیر است [۳۵]:

۱- مقدار کوچکتر بهترین است.

$$SB = \frac{1}{n} \sum y_i^2 \quad (12)$$

۲- مقدار بزرگترین بهترین است.

$$SB = \frac{1}{n} \sum \left( \frac{1}{y_i} \right)^2 \quad (13)$$

۳- اندازه اسمی بهترین است.

$$SB = \frac{1}{n} \sum (y_i - y_o)^2 \quad (14)$$

در این رابطه‌ها  $n$  تعداد تکرارها و  $y_i$  خروجی‌های اندازه‌گیری شده است. رابطه ۹ زمانی کاربرد دارد که خروجی هر چقدر کمتر باشد، بهتر است نظیر سایش. رابطه ۱۰ برعکس است نظیر مقاومت و رابطه ۱۱ برای شرایطی است که یک ویژگی یا مقدار مشخص بررسی شود. در نهایت مقدار  $S/N$  از رابطه زیر بدست می‌آید.

$$S/N = -10 \log SB \quad (15)$$

هر چه مقدار  $S/N$  در فاکتور ورودی بیشتر باشد یعنی تاثیر آن بر خروجی بیشتر است.

## ۲-۵- مؤلفه‌های بهینه در مدل‌ها

در تحقیق حاضر، مؤلفه‌های بهینه شبکه عصبی مصنوعی با استفاده از روش طراحی آزمایشات تاگوچی انتخاب شدند که در قسمت نتایج به آن پرداخته می‌شود. از طرفی برازش لجستیک تابع ساده‌ای است و مؤلفه خاصی ندارد. برای الگوریتم  $k$  نزدیک‌ترین همسایه نیز مقدار  $k$  که همان تعداد همسایه است با استفاده از تابع نرخ خطا<sup>۱</sup> در پایتون، برابر با عدد ۱ انتخاب شد. در الگوریتم درخت تصمیم برای جلوگیری از بیش برازش<sup>۲</sup>، مؤلفه بیشینه عمق<sup>۳</sup> عدد ۵ در نظر گرفته شد. در الگوریتم جنگل تصادفی نیز مؤلفه بیشینه عمق عدد ۵ و تعداد درختان در هر جنگل<sup>۴</sup> ۱۰۰۴ در نظر گرفته شد. در نهایت در روش ماشین بردار پشتیبان با استفاده از تابع جستجوی شبکه‌ای مؤلفه  $C$  و مؤلفه گاما<sup>۵</sup> که وظیفه کنترل حاشیه‌ها بین دسته‌ها و اندازه آن‌ها را دارند به ترتیب ۱۰۰۰ و ۰/۰۰۱ انتخاب شدند. با توجه به حجم زیاد تحلیل‌های انجام شده در تحقیق حاضر و همچنین لزوم بهینه‌سازی مؤلفه‌های شبکه عصبی مصنوعی، تحلیل بیشتری بر روی مقدار فراسنجه‌های مدل‌های دیگر انجام نشد و از مقدار معمول آنها استفاده گردید.

## ۳- نتایج و بحث

### ۳-۱- بهینه‌سازی شبکه عصبی مصنوعی با استفاده از تحلیل تاگوچی

در تحقیق حاضر، تعداد لایه میانی شبکه عصبی ۲ در نظر گرفته شد چرا که با افزایش این تعداد، نتایج ضعیف‌تری حاصل می‌شد. بنابراین تمرکز تحقیق حاضر بر بهینه‌کردن فاکتورهای دیگر گذاشته شد. مراحل بهینه‌سازی مؤلفه‌های شبکه عصبی مصنوعی در نرم‌افزار Minitab انجام شد. سه فاکتور تابع فعال‌سازی لایه‌های میانی، تعداد نورون‌های لایه میانی اول و تعداد نورون‌های لایه میانی دوم انتخاب شدند و برای هر فاکتور ۵ سطح برگزیده شد. در جدول (۳) نوع فاکتورها و مقادیر یا مشخصات سطوح هر یک از آنها نشان داده شده است. در ادامه برای بهینه‌سازی شبکه عصبی و پیدا کردن سطح‌های بهینه در هر فاکتور، جدول L25 تاگوچی انتخاب شد. به این ترتیب ۲۵ آزمایش روی شبکه‌های عصبی مصنوعی انجام شد و مؤلفه‌های بهینه با استفاده از تحلیل  $S/N$  تاگوچی انتخاب شدند. در ادامه نتایج بدست آمده برای پایگاه داده ۱ و ۲ ارائه می‌شود:

<sup>1</sup> Error rate

<sup>2</sup> Overfitting

<sup>3</sup> Maxdepth

<sup>4</sup> Number of estimators

<sup>5</sup> Gamma

جدول ۳: فاکتورها و سطوح های مورد استفاده برای بهینه سازی شبکه عصبی

| سطح ها |     |       |      |      | فاکتورها                         |
|--------|-----|-------|------|------|----------------------------------|
| SELU   | ELU | SWISH | GELU | RELU | تابع فعال سازی لایه های میانی    |
| ۱۲     | ۱۱  | ۱۰    | ۹    | ۸    | تعداد نورون ها در لایه میانی اول |
| ۱۲     | ۱۱  | ۱۰    | ۹    | ۸    | تعداد نورون ها در لایه میانی دوم |

## ۳-۱-۱- پایگاه داده ۱


در جدول ۴ تابع صحت مدل های بدست آمده (۲۵ مدل) با توجه به مؤلفه های پیشنهادی تاکوچی آورده شده است. همان گونه که در این جدول مشخص است محدوده تابع صحت مدل مابین ۰/۸۶۱ و ۰/۸۸۸ است. بر این اساس، بیشترین مقدار مربوط به مدل های ۱ و ۴ با ۰/۸۸۸ است و کمترین مقدار مربوط به مدل شماره ۱۴ است.

جدول ۴: دقت مدل ها با مؤلفه های پیشنهادی تاکوچی در پایگاه داده شماره ۱

| تابع صحت بدست آمده | تعداد نورون در لایه میانی دوم | تعداد نورون در لایه میانی اول | تابع فعال سازی | شماره ی مدل |
|--------------------|-------------------------------|-------------------------------|----------------|-------------|
| ۰/۸۸۸              | ۸                             | ۸                             | Relu           | ۱           |
| ۰/۸۸۱              | ۹                             | ۹                             | Relu           | ۲           |
| ۰/۸۸۵              | ۱۰                            | ۱۰                            | Relu           | ۳           |
| ۰/۸۸۸              | ۱۱                            | ۱۱                            | Relu           | ۴           |
| ۰/۸۷۱              | ۱۲                            | ۱۲                            | Relu           | ۵           |
| ۰/۸۸۱              | ۹                             | ۸                             | Gelu           | ۶           |
| ۰/۸۶۸              | ۱۰                            | ۹                             | Gelu           | ۷           |
| ۰/۸۷۸              | ۱۱                            | ۱۰                            | Gelu           | ۸           |
| ۰/۸۷۸              | ۱۲                            | ۱۱                            | Gelu           | ۹           |
| ۰/۸۶۴              | ۸                             | ۱۲                            | Gelu           | ۱۰          |
| ۰/۸۷۱              | ۱۰                            | ۷                             | Swish          | ۱۱          |
| ۰/۸۶۴              | ۱۱                            | ۹                             | Swish          | ۱۲          |
| ۰/۸۸۱              | ۱۲                            | ۱۰                            | Swish          | ۱۳          |
| ۰/۸۶۱              | ۸                             | ۱۱                            | Swish          | ۱۴          |
| ۰/۸۸۵              | ۹                             | ۱۲                            | Swish          | ۱۵          |
| ۰/۸۶۸              | ۱۱                            | ۸                             | Elu            | ۱۶          |
| ۰/۸۸۱              | ۱۲                            | ۹                             | Elu            | ۱۷          |
| ۰/۸۷۸              | ۸                             | ۱۰                            | Elu            | ۱۸          |
| ۰/۸۸۱              | ۹                             | ۱۱                            | Elu            | ۱۹          |
| ۰/۸۸۱              | ۱۰                            | ۱۲                            | Elu            | ۲۰          |
| ۰/۸۶۸              | ۱۲                            | ۸                             | Selu           | ۲۱          |
| ۰/۸۸۲              | ۸                             | ۹                             | Selu           | ۲۲          |
| ۰/۸۸۱              | ۹                             | ۱۰                            | Selu           | ۲۳          |
| ۰/۸۷۱              | ۱۰                            | ۱۱                            | Selu           | ۲۴          |
| ۰/۸۷۸              | ۱۱                            | ۱۲                            | Selu           | ۲۵          |

با توجه به نتایج این ۲۵ آزمایش و با کمک تحلیل S/N سطوح های بهینه در هر فاکتور انتخاب می شود. همان گونه که در شکل ۳ مشخص است تحلیل S/N برای سطح بهینه تابع فعال سازی شماره ۱ یعنی RELU، تعداد نورون ها در لایه میانی اول برابر با ۱۰ و تعداد نورون ها در لایه میانی دوم برابر با ۹ را انتخاب نموده است. به این ترتیب با در نظر گرفتن مؤلفه های فوق برای معماری شبکه عصبی، مدل بهینه ساخته و اجرا شد. تابع صحت داده های آموزش ۰/۹۰۵ و داده های آزمون ۰/۸۹۲ بدست آمد. همچنین مقدار این تابع برای داده های

آزمون از همه‌ی مقدارهای بدست آمده در ۲۵ مدل ساخته شده تاگوچی بیشتر است. به عبارت دیگر از مجموع ۲۸۸ داده آزمون و ۱۰۸ مورد عدم رخداد روانگرایی، مدل ۸۵ مورد را درست و ۲۳ مورد را نادرست پیش‌بینی کرده است. همچنین از ۱۸۰ مورد رخداد روانگرایی، ۱۷۲ مورد را درست و ۸ مورد را نادرست پیش‌بینی کرده است که در مجموع تابع صحت مدل برابر با ۰/۸۹۲ حساب شد. همچنین مقدار تابع دقت برای عدم رخداد روانگرایی ۰/۷۸ و برای رخداد روانگرایی ۰/۹۵ و در ادامه مقدار تابع بازیابی برای عدم رخداد روانگرایی ۰/۹۱ و برای رخداد روانگرایی ۰/۸۸ بدست آمدند. در نهایت مقدار تابع امتیاز اف یک برای عدم رخداد روانگرایی ۰/۸۴ و برای رخداد روانگرایی ۰/۹۱ محاسبه شد.



شکل ۳: نتایج تحلیل S/N برای بدست آوردن بهترین سطح‌ها در پایگاه داده ۱

### ۳-۱-۲- پایگاه داده ۲

در جدول ۵ مقدار تابع صحت مدل‌های بدست آمده (مدل) با توجه به مؤلفه‌های پیشنهادی تاگوچی برای پایگاه داده ۲ آورده شده است. همان‌گونه که در این جدول مشخص است محدوده مقدارهای بدست آمده مابین ۰/۶۱ و ۰/۷۲ است به گونه‌ای که بیشترین مقدار مربوط به مدل شماره ۸ یعنی ۰/۷۲ و کمترین آن مربوط به مدل شماره ۱۶ با مقدار ۰/۶۱ است.


با توجه به نتایج این ۲۵ آزمایش و با کمک تحلیل S/N سطح‌های بهینه در هر فاکتور انتخاب می‌شود. بر این اساس، سطح بهینه تابع فعال‌سازی را شماره ۵ یعنی SELU، تعداد نورون‌ها در لایه میانی اول برابر با ۱۰ و تعداد نورون‌ها در لایه میانی دوم برابر با ۸ انتخاب نموده است (شکل ۴). در این حالت، مقدار تابع صحت برای داده‌های آموزش ۰/۷۶ و برای داده‌های آزمون ۰/۷۳ بدست آمد. به عبارت دیگر در شبکه عصبی مصنوعی بهینه‌شده با تاگوچی از مجموع ۲۶۶ داده مورد استفاده برای آزمون و ۱۲۳ رخداد روانگرایی، ۸۸ مورد را درست و ۳۵ مورد را غلط پیش‌بینی کرده است و از ۱۴۳ مورد عدم رخداد روانگرایی ۱۰۷ مورد را درست و ۳۶ مورد را غلط پیش‌بینی کرده است که در کل مقدار تابع صحت مدل برابر با ۰/۷۳۳ حساب شده است. همچنین در این حالت مقدار تابع دقت برای رخداد روانگرایی ۰/۷۱ و برای عدم رخداد روانگرایی ۰/۷۴ بدست آمد. در ادامه مقدار تابع بازیابی برای رخداد روانگرایی ۰/۷۰ و برای عدم رخداد روانگرایی ۰/۷۵ محاسبه شد. در نهایت مقدار تابع امتیاز اف یک نیز برای رخداد روانگرایی ۰/۷۰ و برای عدم رخداد روانگرایی ۰/۷۴ بدست آمد.

## ۳-۲- مقایسه نتایج حاصل از الگوریتم‌های یادگیری ماشین مختلف

در جدول ۶ دقت مدل‌های مختلف یادگیری ماشین در برآورد روانگرایی خاک بر اساس آزمون CPT (پایگاه داده ۱) ارائه شده است. همان‌طور که در این جدول مشخص است در داده‌های آزمون بیشترین مقدار تابع صحت برای شبکه عصبی مصنوعی بهینه‌شده با تاگوچی یعنی ۰/۸۹ است و رتبه‌های بعدی به جنگل تصادفی با مقدار ۰/۸۸، درخت تصمیم با مقدار ۰/۸۷، سیستم بردار پشتیبان با مقدار ۰/۸۳، برازش لجستیک با مقدار ۰/۷۹ و k نزدیکترین همسایه با مقدار ۰/۷۶ می‌رسد.

جدول ۵: دقت مدل‌ها با مؤلفه‌های پیشنهادی تاگوچی در پایگاه داده ۲

| مقدار تابع صحت بدست‌آمده | تعداد نرون در لایه میانی دوم | تعداد نرون در لایه میانی اول | تابع فعال‌سازی | شماره‌ی آزمایش |
|--------------------------|------------------------------|------------------------------|----------------|----------------|
| ۰/۶۹                     | ۸                            | ۸                            | Relu           | ۱              |
| ۰/۷۰                     | ۹                            | ۹                            | Relu           | ۲              |
| ۰/۶۷                     | ۱۰                           | ۱۰                           | Relu           | ۳              |
| ۰/۶۸                     | ۱۱                           | ۱۱                           | Relu           | ۴              |
| ۰/۷۰                     | ۱۲                           | ۱۲                           | Relu           | ۵              |
| ۰/۶۸                     | ۹                            | ۸                            | Gelu           | ۶              |
| ۰/۶۷                     | ۱۰                           | ۹                            | Gelu           | ۷              |
| ۰/۷۲                     | ۱۱                           | ۱۰                           | Gelu           | ۸              |
| ۰/۶۸                     | ۱۲                           | ۱۱                           | Gelu           | ۹              |
| ۰/۶۹                     | ۸                            | ۱۲                           | Gelu           | ۱۰             |
| ۰/۶۶                     | ۱۰                           | ۷                            | Swish          | ۱۱             |
| ۰/۶۴                     | ۱۱                           | ۹                            | Swish          | ۱۲             |
| ۰/۶۳                     | ۱۲                           | ۱۰                           | Swish          | ۱۳             |
| ۰/۶۵                     | ۸                            | ۱۱                           | Swish          | ۱۴             |
| ۰/۶۶                     | ۹                            | ۱۲                           | Swish          | ۱۵             |
| ۰/۶۱                     | ۱۱                           | ۸                            | Elu            | ۱۶             |
| ۰/۶۵                     | ۱۲                           | ۹                            | Elu            | ۱۷             |
| ۰/۷۱                     | ۸                            | ۱۰                           | Elu            | ۱۸             |
| ۰/۶۸                     | ۹                            | ۱۱                           | Elu            | ۱۹             |
| ۰/۶۷                     | ۱۰                           | ۱۲                           | Elu            | ۲۰             |
| ۰/۷۰                     | ۱۲                           | ۸                            | Selu           | ۲۱             |
| ۰/۶۸                     | ۸                            | ۹                            | Selu           | ۲۲             |
| ۰/۶۹                     | ۹                            | ۱۰                           | Selu           | ۲۳             |
| ۰/۷۱                     | ۱۰                           | ۱۱                           | Selu           | ۲۴             |
| ۰/۶۹                     | ۱۱                           | ۱۲                           | Selu           | ۲۵             |



شکل ۴: نتایج تحلیل S/N برای بدست آوردن بهترین سطح‌ها در پایگاه داده ۲

جدول ۶: دقت الگوریتم‌های مختلف در برآورد داده‌های آزمون و آموزش پایگاه داده ۱

| الگوریتم استفاده شده      | صحت داده‌های آموزش | صحت داده‌های آزمون |
|---------------------------|--------------------|--------------------|
| شبکه عصبی مصنوعی (ANN)    | ۰/۹۰               | ۰/۸۹               |
| درخت تصمیم (DT)           | ۰/۸۹               | ۰/۸۷               |
| جنگل تصادفی (RF)          | ۰/۹۳               | ۰/۸۸               |
| برازش لجستیک (LR)         | ۰/۸۳               | ۰/۷۹               |
| سیستم بردار پشتیبان (SVM) | ۰/۹۲               | ۰/۸۳               |
| k نزدیکترین همسایه (KNN)  | ۰/۸۴               | ۰/۷۶               |

در ادامه جدول ۷ دقت مدل‌های یادگیری ماشین در برآورد روانگرایی خاک بر اساس آزمون SPT (پایگاه داده ۲) را نشان می‌دهد. بر اساس نتایج ارائه شده در این جدول، بیشترین مقدار تابع صحت در داده‌های آزمون برای شبکه عصبی مصنوعی بهینه‌شده با تاگوچی با مقدار ۰/۷۳ است. و رتبه‌های بعدی به جنگل تصادفی با مقدار ۰/۷۰۳، درخت تصمیم با مقدار ۰/۶۹۵، برازش لجستیک با مقدار ۰/۶۶۱، k نزدیکترین همسایه با مقدار ۰/۶۶۱ و ماشین بردار پشتیبان با مقدار ۰/۶۴ می‌رسد.

جدول ۷: دقت الگوریتم‌های مختلف در برآورد داده‌های آزمون و آموزش پایگاه داده ۲


| الگوریتم استفاده شده      | صحت داده‌های آموزش | صحت داده‌های آزمون |
|---------------------------|--------------------|--------------------|
| شبکه عصبی مصنوعی (ANN)    | ۰/۷۶               | ۰/۷۳               |
| درخت تصمیم (DT)           | ۰/۸۳               | ۰/۶۹۵              |
| جنگل تصادفی (RF)          | ۰/۹۲               | ۰/۷۰۳              |
| برازش لجستیک (LR)         | ۰/۶۴               | ۰/۶۶۱              |
| سیستم بردار پشتیبان (SVM) | ۰/۷۴               | ۰/۶۴۲              |
| k نزدیکترین همسایه (KNN)  | ۰/۷                | ۰/۶۶۱              |

به طور کلی همانگونه که در شکل ۵ مشخص است بررسی دقت‌های بدست آمده نشان می‌دهد که مدل‌های یادگیری ماشین، دقیق‌تر (حدود ۲۰ درصد) می‌توانند روانگرایی خاک را بر اساس آزمون CPT (پایگاه داده ۱) نسبت به SPT (پایگاه داده ۲) پیش‌بینی کنند. به این ترتیب می‌توان نتیجه گرفت که پیش‌بینی روانگرایی با استفاده از داده‌های مبتنی بر آزمون نفوذ مخروط CPT بهتر از آزمون نفوذ استاندارد SPT است. دلیل این موضوع را می‌توان به خطای انسانی در جمع‌آوری داده‌ها و همچنین پراکندگی بیشتر داده‌های آزمایش SPT



نسبت به CPT مربوط دانست. همانگونه که در جدول های ۱ و ۲ مشخص است انحراف از معیار داده های CPT برابر با ۴/۳۵ است که این مقدار بسیار کمتر از انحراف از معیار داده های SPT یعنی ۱۱ است. همچنین دقت برآورد داده های آموزش بیشتر از آزمون بدست آمده است.

در ادامه مقدار تابع صحت حاصل از بهترین مدل این تحقیق یعنی شبکه عصبی مصنوعی با تحقیقات قبلی مورد مقایسه قرار می گیرد. همان گونه که در جدول ۸ مشخص است، نتایج تعدادی از مدل های قبلی بهتر از مدل حاضر شده است که دلیل اصلی این موضوع می تواند تعداد کمتر داده های مورد بررسی در تحقیقات قبلی (محدوده ۲۰۰ تا ۳۰۰ داده) باشد. برای اثبات این موضوع تعداد کمتری داده به صورت تصادفی از بین کل داده های جمع آوری شده انتخاب گردید و بر روی آنها شبکه عصبی مصنوعی اجرا شد که نتایج آن در ردیف های ۹ و ۱۰ جدول ۸ ارائه شد. همانگونه که مشخص است در این حالت نتایج مدل حاضر در محدوده نتایج تحقیقات قبلی قرار گرفت و در بعضی موارد نیز نتایج بهتری بدست آمده است.



شکل ۵: مقایسه دقت الگوریتم های مختلف یادگیری ماشین در پیش بینی روانگرایی خاک

جدول ۸: مقایسه نتایج بدست آمده از تحقیق حاضر با مقالات دیگر در زمینه روانگرایی

| ردیف | مرجع       | بهترین الگوریتم استفاده شده | تعداد و نوع داده | مقدار تابع صحت بدست آمده |
|------|------------|-----------------------------|------------------|--------------------------|
| ۱    | [۹]        | شبکه عصبی                   | SPT, ۵۲۵         | ۰/۹۲۹                    |
| ۲    | [۱۰]       | ماشین بردار پشتیبان         | SPT, ۲۸۸         | ۰/۹۵۳                    |
| ۳    | [۱۱]       | ماشین بردار پشتیبان         | SPT, ۲۸۸         | ۰/۹۰۷                    |
| ۴    | [۱۳]       | الگوریتم ژنتیک              | CPT, ۲۲۶         | ۰/۹۵                     |
| ۵    | [۱۵]       | جنگل تصادفی                 | CPT, ۲۲۶         | ۰/۹۸۹                    |
| ۶    | [۳۶]       | الگوریتم ژنتیک              | SPT, ۱۶۰         | ۰/۸۵۴                    |
| ۷    | [۲۴]       | ماشین بردار پشتیبان         | CPT, ۲۲۶         | ۰/۹۸۲                    |
| ۸    | تحقیق حاضر | شبکه عصبی                   | CPT, ۹۵۸         | ۰/۸۹۵                    |
|      |            |                             | SPT, ۸۸۶         | ۰/۷۳۳                    |
| ۹    | تحقیق حاضر | شبکه عصبی                   | CPT, ۲۳۰         | ۰/۹۸                     |
|      |            |                             | SPT, ۲۳۰         | ۰/۹۵                     |
| ۱۰   | تحقیق حاضر | شبکه عصبی                   | CPT, ۵۰۰         | ۰/۹۶                     |
|      |            |                             | SPT, ۵۰۰         | ۰/۹                      |

### ۳-۳- مقایسه نتایج حاصل از الگوریتم شبکه عصبی حاصل با روابط تجربی

در این بخش ۱۸۰ سری داده در مدل شبکه عصبی اجرا شد. همچنین ضریب ایمنی روانگرایی این سری داده‌ها از طریق رابطه ۱ حساب شد. اگر ضریب ایمنی کمتر از یک باشد زمین مستعد وقوع روانگرایی است و اگر ضریب ایمنی بیشتر از ۱ باشد روانگرایی رخ نمی‌دهد [۵]. بررسی و تحلیل نتایج نشان داد که مقدار تابع صحت رابطه تجربی ۱ در برآورد پتانسیل روانگرایی برابر با ۰/۸ است. در حالیکه این مقدار در حالت استفاده از شبکه عصبی برابر با ۰/۹ بدست آمد. این موضوع نشان دهنده دقت مناسب روش‌های یادگیری ماشین نسبت به روش‌های تجربی در برآورد پتانسیل روانگرایی خاک می‌باشد.

### ۴- مطالعه فراسنجه‌ای وقوع روانگرایی

در این قسمت وقوع روانگرایی نسبت به تغییرات فراسنجه‌های موثر مورد بررسی قرار می‌گیرد. به این منظور فراسنجه هدف تغییر یافته و فراسنجه‌های موثر دیگر برابر با مقدار میانگین ثابت در نظر گرفته می‌شوند. در ادامه نتایج این بررسی برای پایگاه داده ۱ و پایگاه داده ۲ به صورت جداگانه ارائه می‌شود.


#### ۴-۱- پایگاه داده ۱

در شکل ۶ مطالعه فراسنجه‌ای به ترتیب برای فراسنجه‌های مقاومت مخروط، تنش کل، تنش موثر، شتاب و در نهایت بزرگی زلزله به صورت جداگانه نشان داده شده است. در این شکل وقوع روانگرایی (محور عرضی) با عدد ۱ و عدم وقوع آن به عدد ۰ مشخص است. با توجه به شکل ۶-الف مشخص است که در شرایط ثابت بودن فراسنجه‌های موثر، چنانچه مقاومت مخروط از ۹ کیلوپاسکال کمتر باشد، روانگرایی رخ می‌دهد. به همین ترتیب بر اساس شکل ۶-ب روانگرایی خاک در شرایطی که مقدار تنش کل از ۲۲۰ کیلوپاسکال کمتر باشد رخ می‌دهد. همچنین بر اساس بقیه قسمت‌های شکل ۶، وقوع روانگرایی در حالتی است که تنش موثر کمتر از ۱۸۰ کیلوپاسکال، شتاب زلزله بیشتر از ۰/۱ شتاب ثقل و در نهایت بزرگای زلزله از ۶/۵ ریشتر بیشتر باشد.

#### ۴-۲- پایگاه داده ۲

شکل ۷ مطالعه فراسنجه‌ای به ترتیب برای فراسنجه‌های عدد نفوذ استاندارد، تنش کل، تنش موثر، شتاب و در نهایت بزرگی زلزله به صورت جداگانه نشان داده شده است. در این شکل نیز وقوع روانگرایی (محور عرضی) با عدد ۱ و عدم وقوع آن به عدد ۰ مشخص است. بر اساس این شکل وقوع روانگرایی در حالتی است که عدد نفوذ استاندارد کمتر از ۱۶، تنش کل کمتر از ۲۰۰، تنش موثر کمتر از ۱۵۰ کیلوپاسکال، شتاب زلزله بیشتر از ۰/۲ شتاب ثقل و در نهایت بزرگای زلزله از ۶ ریشتر بیشتر باشد.


مقایسه نتایج حاصل از این پایگاه داده با پایگاه داده ۱ نشان می‌دهد که نتایج فراسنجه‌های مشابه به غیر از شتاب زلزله، نزدیک به هم است. مقدار اختلاف برای فراسنجه تنش کل حدود ۱۰ درصد، تنش موثر حدود ۱۷ درصد، شتاب زلزله ۱۰۰ درصد و بزرگای زلزله حدود ۸ درصد می‌باشد.



شکل ۶: مطالعه فراسنجه‌ای مربوط به فراسنجه‌های مؤثر بر روانگرایی خاک در پایگاه داده ۱: (الف) تغییرات مقاومت مخروط، (ب) تغییرات تنش کل، (ج) تغییرات تنش مؤثر، (د) تغییرات شتاب و (ه) تغییرات بزرگی زلزله

## ۵- نتیجه‌گیری

روانگرایی یک پدیده مخرب ژئوتکنیک است که منجر به ناپایداری سازه‌ها و زیرساخت‌های عمرانی در زمان زلزله می‌شود. روش‌های مختلفی برای برآورد پتانسیل روانگرایی خاک در یک منطقه وجود دارد. در تحقیق حاضر بعد از جمع‌آوری داده‌های میدانی از نقاط مختلف دنیا و ساخت پایگاه‌های داده‌ای مبتنی بر آزمایش‌های CPT و SPT اقدام به پیش‌بینی روانگرایی با استفاده از روش‌های مختلف علم داده و یادگیری ماشین شامل ماشین بردار پشتیبان، برازش لجستیک، k نزدیک‌ترین همسایه، درخت تصمیم، جنگل تصادفی و شبکه عصبی مصنوعی شد. همچنین برای بهینه‌سازی شبکه عصبی از روش طراحی آزمایشات تاگوچی استفاده شد. در مجموع از ۹۵۸ سری داده مبتنی بر آزمایش CPT و ۸۸۶ سری داده مبتنی بر آزمایش SPT در تحقیق حاضر استفاده شد. مهمترین نتایج حاصل از این تحقیق به طور خلاصه عبارتند از:



شکل ۷: مطالعه فراسنجه‌ای مربوط به فراسنجه‌های مؤثر بر روانگرایی خاک در پایگاه داده ۲: (الف) تغییرات مقاومت مخروط، (ب) تغییرات تنش کل، (ج) تغییرات تنش مؤثر، (د) تغییرات شتاب و (ه) تغییرات بزرگی زلزله

۱- طراحی آزمایش‌های تاگوچی در بهینه‌کردن مؤلفه‌های شبکه عصبی برای پیش‌بینی روانگرایی بسیار مؤثر است. در پایگاه داده مبتنی بر آزمایش‌های CPT، مقدار تابع صحت شبکه عصبی مصنوعی برای پیش‌بینی رخ‌دادن روانگرایی در هنگام زلزله بعد از بهینه‌شدن با روش طراحی آزمایش‌های تاگوچی از ۰/۷۸ به ۰/۸۹ افزایش یافت. همچنین در پایگاه داده مبتنی بر آزمایش‌های SPT این مقدار از ۰/۶۱ به ۰/۷۳۳ افزایش یافت. به این ترتیب دقت مدل پیش‌بینی مبتنی بر داده‌های آزمایش‌های CPT بیشتر از داده‌های آزمایش‌های SPT است.

۲- در پیش‌بینی رخ‌دادن روانگرایی با استفاده از داده‌های مبتنی بر آزمایش‌های CPT، بالاترین مقدار تابع صحت برای شبکه عصبی مصنوعی بهینه‌شده با تاگوچی یعنی ۰/۸۹ بدست آمد و رتبه‌های بعدی به جنگل تصادفی با مقدار ۰/۸۸، درخت تصمیم با مقدار ۰/۸۷، سیستم بردار پشتیبان با مقدار ۰/۸۳، برازش لجستیک با مقدار ۰/۷۹ و  $k$  نزدیک‌ترین همسایه با مقدار ۰/۷۶ رسید. در ادامه با کاهش تعداد داده‌های ورودی، دقت شبکه عصبی مصنوعی افزایش یافت به گونه‌ای که مقدار تابع صحت برای ۲۳۰ داده برابر با ۰/۹۸ و برای ۵۰۰ داده ۰/۹۶ بدست آمد.

۳- در پیش‌بینی رخ‌دادن روانگرایی با استفاده از داده‌های مبتنی بر آزمایش‌های SPT، بالاترین مقدار تابع صحت برای شبکه عصبی مصنوعی بهینه‌شده با تاگوچی یعنی ۰/۷۳ بدست آمد و رتبه‌های بعدی به جنگل تصادفی با مقدار ۰/۷۰۳، درخت تصمیم با مقدار ۰/۶۹۵، برازش لجستیک با مقدار ۰/۶۶۱،  $k$  نزدیک‌ترین همسایه با مقدار ۰/۶۶۱ و ماشین بردار پشتیبان با مقدار ۰/۶۴ رسید. همچنین در این حالت کاهش تعداد داده‌های ورودی منجر به افزایش دقت شبکه عصبی مصنوعی شد به گونه‌ای که مقدار تابع صحت برای ۲۳۰ داده برابر با ۰/۹۵ و برای ۵۰۰ داده برابر با ۰/۹۰ بدست آمد.

۴- مقایسه دقت حاصل از نتایج مدل‌های حاضر با مدل‌های یادگیری ماشین ارائه شده توسط تحقیقات قبلی نشان داد که به علت تعداد کم داده‌های مورد بررسی در این تحقیقات (محدوده ۲۰۰ تا ۳۰۰ داده) نسبت به تحقیق حاضر، دقت تعدادی از آنها بیشتر از تحقیق حاضر است. همچنین با کاهش تعداد داده‌های مورد بررسی، دقت نتایج مدل‌های حاضر در محدوده نتایج مدل‌های قبلی قرار گرفت.

۵- مقایسه نتایج روش شبکه عصبی توسعه داده شده در تحقیق حاضر نسبت به روش تجربی برآورد ضریب ایمنی روانگرایی نشان داد که دقت روش شبکه عصبی بالاتر از دقت روش تجربی است.

۶- مطالعه فراسنجه‌ای پایگاه‌های داده‌ای مبتنی بر آزمایش CPT برای فراسنجه‌های مقاومت مخروط، تنش کل، تنش موثر، شتاب و در نهایت بزرگی زلزله به صورت جداگانه انجام شد و به عنوان نمونه نتایج نشان داد که در شرایطی که همه فراسنجه‌ها مقدار میانگین پایگاه داده را داشته باشند و مقاومت مخروط از ۹ کیلوپاسکال کمتر باشد، روانگرایی رخ می‌دهد.

۷- مطالعه فراسنجه‌ای پایگاه‌های داده‌ای مبتنی بر آزمایش SPT برای فراسنجه‌های عدد نفوذ استاندارد، تنش کل، تنش موثر، شتاب و در نهایت بزرگی زلزله به صورت جداگانه انجام شد و به عنوان مثال نتایج نشان داد که در شرایطی که همه فراسنجه‌ها مقدار میانگین پایگاه داده را داشته باشند و عدد نفوذ استاندارد کمتر از ۱۶ باشد، روانگرایی رخ می‌دهد.

در نهایت لازم است اشاره شود که محدودیت‌های این تحقیق را می‌توان شامل در نظر نگرفتن فراسنجه‌های دیگری نظیر اندازه دانه خاک و میزان ریزدانه و همچنین تعداد بیشتر نمونه‌های مربوط به عدم وقوع روانگرایی دانست.

## مراجع

- [1] Alavi, A.H. and Gandomi, A. H. (2011). Energy-based numerical models for assessment of soil liquefaction. *Geosci. Front.* 3(4), 541–555.
- [2] Farrokhzad, F., Choobasti, A. J. and Barari, A. (2012). Liquefaction microzonation of Babol city using artificial neural network, *J. King Saud Univ. – Sci.* 24(1), 89–100.
- [3] Youd et al. (2001). Liquefaction Resistance of Soils: Summary Report from the 1996 NCEER and 1998 NCEER/NSF Workshops on Evaluation of Liquefaction Resistance of Soils. *J. Geotech. & Geo-environ. Eng.* ASCE, 127(10), 817–833.
- [4] Hwang, J. H. and Yang, C. W. (2001). Verification of critical cyclic strength curve by Taiwan Chi-Chi earthquake data. *Soil Dyn. Earthq. Eng.*, 21(3), 237–257.
- [5] Cetin K. O. (2004). Standard Penetration Test-Based Probabilistic and Deterministic Assessment of Seismic Soil Liquefaction Potential. *J. Geotech. Geoenvironmental Eng.* 130(12), 1314–1340.
- [6] Muduli P. K. and Das, S. K. (2014). Evaluation of liquefaction potential of soil based on standard penetration test using multi-gene genetic programming model, *Acta Geophys.* 62(3), 529–543.
- [7] Juang, C. H. Yuan, H. Lee, D. H. and Lin, P.S. (2003). Simplified Cone Penetration Test-based Method for Evaluating Liquefaction Resistance of Soils. *J. Geotech. Geoenvironmental Eng.* 129(1), 66–80.
- [8] Pal, M. (2006). Support vector machines-based modelling of seismic liquefaction potential. *Int. J. Numer. Anal. Methods Geomech.* 30(10), 983–996.
- [9] Hanna, A. M. Ural, D. and Saygili, G. (2007). Neural network model for liquefaction potential in soil deposits using Turkey and Taiwan earthquake data. *Soil Dyn. Earthq. Eng.* 27(6), 521–540.
- [10] Samui P. and Sitharam, T. G. (2011). Machine learning modelling for predicting soil liquefaction susceptibility. *Nat. Hazards Earth Syst. Sci.* 11(1), 1–9.
- [11] Samui P. and Center, J. K. (2012). Directional response of a reconstituted fine-grained soil - Part II : Performance of different constitutive models. *Int. J. Numer. Anal. Methods Geomech.* 30(13), 1303–1336.

- [12] Xue X. and Yang, X. (2013). Application of the adaptive neuro-fuzzy inference system for prediction of soil liquefaction. *Nat. Hazards*, 67(2), 901–917.
- [13] Venkatesh, K., Kumar, V. and Tiwari, R. P. (2013). Appraisal of liquefaction potential using neural network and neuro fuzzy approach, *Appl. Artif. Intell.* 27(8), 700–720.
- [14] Muduli, P. K., Das, S. K. and Bhattacharya, S. (2014). CPT-based probabilistic evaluation of seismic soil liquefaction potential using multi-gene genetic programming. *Georisk*. 8(1), 14–28.
- [15] Kohestani, V. R., Hassanlourad, M. and Ardakani, A. (2015). Evaluation of liquefaction potential based on CPT data using random forest. *Nat. Hazards*. 79(2), 1079–1089.
- [16] Abbaszadeh Shahri, A. (2016). Assessment and Prediction of Liquefaction Potential Using Different Artificial Neural Network Models: A Case Study. *Geotech. Geol. Eng.* 34(3), 807–815.
- [17] Hu, J. L., Tang, X. W. and Qiu, J. N. (2016). Assessment of seismic liquefaction potential based on Bayesian network constructed from domain knowledge and history data. *Soil Dyn. Earthq. Eng.* 89, 49–60.
- [18] Xue X. and Liu, E. (2017). Seismic liquefaction potential assessed by neural networks. *Environ. Earth Sci.* 76(5).
- [19] Hoang N. D. and Bui, D. T. (2018). 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. *Bull. Eng. Geol. Environ.*, 77(1), 191–204.
- [20] Hu J. and Liu, H. (2019). Bayesian network models for probabilistic evaluation of earthquake-induced liquefaction based on CPT and Vs databases. *Eng. Geol.* 254, 76–88.
- [21] Zhou, J. Li, E. Wang, M. Chen, X. Shi, X. and Jiang, L. (2019). Feasibility of Stochastic Gradient Boosting Approach for Evaluating Seismic Liquefaction Potential Based on SPT and CPT Case Histories. *J. Perform. Constr. Facil.* 33(3), 1–10.
- [22] Atangana Njock, P. G. Shen, S. L. Zhou, A. and Lyu, H. M. (2019). Evaluation of soil liquefaction using AI technology incorporating a coupled ENN / t-SNE model. *Soil Dyn. Earthq. Eng.* 130, 105988.
- [23] Kamura A. *et al.*, (2021). Exploring the possibility of assessing the damage degree of liquefaction based only on seismic records by artificial neural networks. *Soils Found.* 61(3), 658–674.
- [24] Zhou, J. Huang, S. Wang, M. and Qiu, Y. (2021). Performance evaluation of hybrid GA – SVM and GWO – SVM models to predict earthquake - induced liquefaction potential of soil : a multi - dataset investigation. *Eng. Comput.* 38(3), 4197-4225.
- [25] Eric R. and Moss, S. (2003). Cpt-Based Probabilistic Assessment of. MASTER, UNIVERSITY OF CALIFORNIA, BERKELEY.
- [26] Goh, A. T. C and Goh, S. H. (2007). Support vector machines: Their use in geotechnical engineering as illustrated using seismic liquefaction data, *Comput. Geotech.* 34(5), 410–421.
- [27] Sharma, S. Activation functions in Neural Networks. 2022 [https://towardsdatascience.com.-activate-function-neural-networks-\(accessed Dec. 03, 2022\).](https://towardsdatascience.com.-activate-function-neural-networks-(accessed Dec. 03, 2022).)
- [28] Support Vector Machine Algorithm. [https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm\(accessed May. 07, 2022\).](https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm(accessed May. 07, 2022).)
- [29] Logistic Regression in Machine Learning. 2022. [https://www.javatpoint.com logistic-regression-in machine-learning\(accessed May. 06, 2022\).](https://www.javatpoint.com logistic-regression-in machine-learning(accessed May. 06, 2022).)
- [30] Decision Tree Classification Algorithm. 2022 [https://www.javatpoint.com.com/machine-learning-decision-tree-classification-algorithm\(accessed Apr. 03, 2022\).](https://www.javatpoint.com.com/machine-learning-decision-tree-classification-algorithm(accessed Apr. 03, 2022).)
- [31] K-Nearest Neighbor. 2021, [https://www.javatpoint.com/k-nearest-neighbor-algorithm-for-machine-learning\(accessed Feb. 04, 2022\).](https://www.javatpoint.com/k-nearest-neighbor-algorithm-for-machine-learning(accessed Feb. 04, 2022).)
- [32] Tavish Srivastava, (2023). A Complete Guide to K-Nearest Neighbors,”. [https://www.analyticsvidhya.com/blog/2018/03/introduction-k-neighbours-algorithm-clustering/\(accessed Mar. 02, 2023\).](https://www.analyticsvidhya.com/blog/2018/03/introduction-k-neighbours-algorithm-clustering/(accessed Mar. 02, 2023).)
- [33] Piyush Kashyap, (2024). Understanding Precision, Recall, and F1 Score Metrics,”. [https://medium.com/@piyushkashyap045/understanding-precision-recall-and-f1-score-metrics-ea219b908093/\(accessed Dec. 02, 2024\).](https://medium.com/@piyushkashyap045/understanding-precision-recall-and-f1-score-metrics-ea219b908093/(accessed Dec. 02, 2024).)
- [34] Esfandmaz, S., Feizi, A., Karimaei Tabarestani, M., and Rasi Nezami S. (2021) An artificial neural network and taguchi method integrated approach to predicting the local scour depth around the bridge pier during flood event. *J. Hydraul. Struct.* 7 (1), 98-113.
- [35] Fraley, S. Zalewski, J., Oom, M. and Terrien, B. (2022). Design of Experiments via Taguchi Methods. [https://eng.libretexts.org/Bookshelves/Industrial\\_and\\_Systems\\_Engineering/Chemical\\_Process\\_Dynamics\\_and\\_Controls\\_\(Woelf\). \(accessed JUN. 02, 2022\).](https://eng.libretexts.org/Bookshelves/Industrial_and_Systems_Engineering/Chemical_Process_Dynamics_and_Controls_(Woelf). (accessed JUN. 02, 2022).)
- [36] Goharzay, M. Noorzad, A. Ardakani, A. M. and Jalal, M. (2017). A worldwide SPT-based soil liquefaction triggering analysis utilizing gene expression programming and Bayesian probabilistic method. *J. Rock Mech. Geotech. Eng.* 9(4), 683–693.