

## چکیده

تاکنون روش‌های تجربی و هوشمند مختلفی برای ارزیابی پتانسیل روانگرایی ارائه شده که روش شبکه عصبی مصنوعی از قدرتمندترین این روش‌ها می‌باشد. این روش، با آموزش داده‌های به‌دست آمده از زلزله‌های گذشته، روانگرایی را ارزیابی می‌کند. با وجود این، به دلیل پیچیدگی رفتار خاک این روش هم با عدم قطعیت همراه است. در این مقاله روش جدیدی با عنوان روش مرکب خوشه‌بندی فازی-شبکه عصبی (FCM-ANN) برای بهبود عملکرد روش شبکه عصبی مصنوعی معرفی و نحوه عملکرد آن تشریح شده است. روش خوشه‌بندی میانگین مرکزی فازی الگوهای مورد استفاده برای آموزش شبکه را پالایش و از ورود الگوهای نامناسب به مجموعه آموزش جلوگیری می‌نماید. برای به دست آوردن نتایج قابل اعتمادتر در روش‌های هوشمند پارامترهای متعددی از خاک، برای به کارگیری در روش مرکب خوشه‌بندی فازی-شبکه عصبی و شبکه عصبی مورد استفاده قرار می‌گیرند که از مهم‌ترین آنها می‌توان به عدد نفوذ استاندارد و نسبت تنش تناوبی اشاره کرد. در این مقاله از پایگاه داده‌های معتبری شامل مطالعات میدانی وقوع و عدم وقوع روانگرایی در زلزله‌های معروف در نقاط مختلف دنیا، استفاده شده است. همچنین سامانه نرم‌افزاری برای تحلیل روش‌های هوشمند شبکه عصبی و روش مرکب خوشه‌بندی فازی-شبکه عصبی در محیط Visual Studio، به زبان #C با پایگاه SQL Server و با نام PILA (Professional Intelligent Liquefaction Assessment) توسط نویسندگان طراحی شده است.

**کلمات کلیدی:** پتانسیل روانگرایی، خوشه‌بندی فازی، شبکه عصبی، خوشه‌بندی میانگین مرکزی فازی، عدد نفوذ استاندارد

## برآورد پتانسیل وقوع روانگرایی خاک با روش مرکب خوشه‌بندی میانگین مرکزی فازی و شبکه عصبی مصنوعی (FCM-ANN)

### روح اله فاطمی کیا

فارغ‌التحصیل کارشناسی ارشد مهندسی زلزله، دانشگاه رازی

### ایمان عشایری (نویسنده مسؤول)

استادیار دانشکده فنی، دانشگاه رازی

E-mail: [lashayeri@razi.ac.ir](mailto:lashayeri@razi.ac.ir)

### مهنوش بیگلری

استادیار دانشکده فنی، دانشگاه رازی

## 1- مقدمه

توضیح پدیده روانگرایی به شمار می‌رود. با بررسی متون فنی می‌توان گفت کاساگرند [3] در سال 1936 اولین محققی باشد که این پدیده را مطالعه کرده است. عبارت «روانگرایی خود به خودی (spontaneous liquefaction)» نخستین بار توسط ترزاقی و پک [4] در سال 1984 برای نشان دادن تغییرات ناگهانی در نهشته‌های سست ماسه‌ای اشباع به جریان‌هایی شبیه سیال لزج به واسطه‌ی اغتشاش جزئی مورد استفاده قرار گرفت. در زمینه پیش‌بینی وقوع روانگرایی به منظور پیشگیری از خسارات احتمالی ناشی از این پدیده، روش‌های مختلفی توسط محققان ارائه شده است که از جمله آنها می‌توان به روش‌های تنش تناوبی [5]، کرنش تناوبی [6] و انرژی [7] اشاره کرد. همچنین با پیشرفت فناوری‌های رایانه‌ای، استفاده از روش‌های هوشمند مانند شبکه

تغییر شکل‌های حاصل از روانگرایی در زلزله‌های گذشته و خرابی‌های وسیع ناشی از آن، این پدیده را به یکی از مهم‌ترین پیچیده‌ترین و بحث‌انگیزترین موضوعات در مهندسی ژئوتکنیک لرزه‌ای تبدیل کرده است. در سال 1964 در زلزله‌های گود فراییدی (Good Friday) در آلاسکا و نیگاتا در ژاپن روانگرایی خرابی‌های زیادی نظیر شکست شیروانی‌ها، گسیختگی‌های پی ساختمان‌ها و پل‌ها و شناوری سازه‌های مدفون به وجود آورد. آشنایی با این پدیده به سال 1920 باز می‌گردد؛ زمانی که هانزن [1] واژه‌ی مایع‌شدگی (liquefying) را برای توصیف گسیختگی جریان‌ی خاک ریز سد کالاوراس استفاده کرد. در سال 1925، ترزاقی [2] نظریه‌ی تنش مؤثر را مطرح نمود که برای محققان پس از او گامی مهم در شرح و



عصبی مصنوعی [8] و فازی - عصبی [9] نیز گسترش یافته است. یکی از پرکاربردترین روش‌های هوشمند مورد استفاده برای ارزیابی پتانسیل روانگرایی، که در سال‌های گذشته توسط محققان زیادی به کار گرفته شده است، روش شبکه‌های عصبی مصنوعی (Artificial Neural Network (ANN)) است. این شبکه با تقلید از ساختار مغز انسان و با استفاده از داده‌های آزمایشگاهی و صحرایی پتانسیل روانگرایی خاک در نقاط مختلف را ارزیابی می‌کند [10-13]. اخیراً فاطمی کیا و همکاران [14] نیز از روش خوشه‌بندی میانگین مرکزی برای ارزیابی پتانسیل روانگرایی استفاده کرده‌اند. روش‌های شبکه عصبی مصنوعی با روش فازی، هر کدام نقاط ضعف و قوتی دارند که با ترکیب این دو روش می‌توان هم نقاط ضعف هر دو روش را پوشش داد و هم به‌طور همزمان از نقاط قوت آنها استفاده نمود. شبکه عصبی مصنوعی توانایی یادگیری روابط بین نمونه‌های ورودی و خروجی خود را دارد. به عبارت دیگر، یادگیری در این سیستم به صورت توزیع شده است و تعیین محل مفهوم یادگیری در آن امکان‌پذیر نیست؛ بنابراین، یکی از مشکلات این سامانه‌ها ذخیره دانش به صورت وزن‌های نامشخص بین نرون‌هایی است که تفسیر کلامی آنها امکان‌پذیر نیست. از سوی دیگر، منطق فازی توانایی استنتاج روی مجموعه‌های نادقیق کلامی را داراست. با این حال، یک سیستم فازی توانایی یادگیری و یا حتی استخراج قوانین مورد نیاز خود را ندارد. با افزایش پیچیدگی سامانه‌های فازی، متعاقباً توسعه قوانین فازی و توابع عضویت مشکل می‌شود. همچنین شبکه‌های عصبی امکان بیان مفاهیم زبانی را ندارند. ترکیب این دو سیستم ایجاد یک سیستم ترکیبی قدرتمند نموده که از توانایی‌های هر دو سیستم استفاده می‌نماید. در این مقاله روش خوشه‌بندی میانگین مرکزی فازی برای پالایش الگوهای مورد استفاده در آموزش شبکه (network training) به کار گرفته شده است. با به کارگیری این روش، الگوهای مورد استفاده برای آموزش شبکه عصبی مصنوعی بیشترین شباهت را به نمونه مورد سؤال دارند. روش مرکب خوشه‌بندی فازی - شبکه عصبی پتانسیل روانگرایی را در دو مرحله پالایش داده‌ها با استفاده از روش فازی و پتانسیل روانگرایی با استفاده از روش شبکه عصبی مصنوعی

ارزیابی می‌کند. به این ترتیب برای هر کدام از نمونه‌های مورد سؤال، پایگاه داده مختص به آن نمونه انتخاب و از ورود داده‌های نامناسب به داخل پایگاه داده آموزش جلوگیری می‌شود. نتایج این پژوهش نشان داد که درصد موفقیت در پیش‌بینی روانگرایی نسبت به روش شبکه عصبی مصنوعی افزایش و خطای شبکه نیز به مقدار محسوسی کاهش خواهد یافت. با وجود این، برای روش‌های هوشمند شبکه عصبی مصنوعی، روش فازی و روش مرکب خوشه‌بندی فازی - شبکه عصبی به دلیل حجم زیاد عملیات محاسباتی، تحلیل دستی امکان‌پذیر نیست به همین علت باید از نرم‌افزارهای کامپیوتری برای تحلیل این روش‌ها استفاده نمود.

تاکنون محققان برای تحلیل این روش‌ها از ماژول‌های (modules) خاصی در نرم‌افزارهایی مانند MATLAB استفاده کرده‌اند. به منظور فراهم آوردن امکانات لازم برای استفاده دیگر کاربران از این روش‌ها، سامانه نرم‌افزاری پیشرفته‌ای در محیط ویژوال استودیو (Visual Studio) و به زبان سی شارپ C# و با پایگاه داده اس کیوال سرور (SQL Server) و با نام Professional Intelligent Liquefaction Assessment توسط نویسندگان طراحی شده است [15].

در بخش بعد ضمن معرفی مشخصات مدل شبکه عصبی استفاده شده در این تحقیق، مدل‌های شبکه عصبی مهم ارائه شده در برآورد پتانسیل روانگرایی، بررسی شده است. سپس، با معرفی جزئیات روش طبقه‌بندی میانگین مرکزی فازی الگوریتم روش مرکب فازی - عصبی ارائه و در انتها نتایج به دست آمده از تحلیل‌های مختلف مورد بررسی قرار گرفته است.

## 2- روش شبکه عصبی مصنوعی (ANN)

در زمینه ارزیابی پتانسیل روانگرایی به روش شبکه عصبی مصنوعی مطالعات بسیاری انجام شده است که نتایج مهم‌ترین این مطالعات در ادامه بررسی شده است.

جو [8] از مدل پس انتشار خطا استفاده نموده است. در این تحقیق از 85 الگو با درصد ریزدانه کمتر از 35 درصد استفاده شده است. 52 نمونه از این داده‌ها به عنوان پایگاه داده و

به عقب (back propagation training) است. ساختار شبکه عصبی مورد استفاده در این مقاله شامل سه لایه مختلف است. این سه لایه عبارتند از:

الف. لایه ورودی: در این لایه 8 نرون قرار دارد که به‌عنوان داده‌های ورودی شامل عمق، تنش کلی خاک ( $\sigma_v$ , (kpa), (total stress "σv", (kpa)), تنش مؤثر خاک ( $\sigma'_v$ , (kpa), (effective stress "σ'v", (kpa)), نسبت تنش تناوبی (cyclic stress ratio "CSR"), بزرگای زلزله (magnitude "Mw"), عدد نفوذ استاندارد اصلاح‌شده (standard penetration test "SPT" (N1)60), درصد ریزدانه (fine content "Fc") و شتاب بیشینه افقی در سطح زمین (peak horizontal acceleration at ground surface "amax") می‌باشند. در این مقاله ویژگی‌های خاک به‌صورت کاملی پوشش داده شده تا نتایج به‌دست‌آمده بر پایه‌ی ورودی‌های جامع‌تری استوار باشند.

ب. لایه دوم: لایه دوم پنهان می‌باشد. در این لایه 7 نرون قرار دارد.

پ. لایه سوم: در لایه سوم که لایه خروجی نام دارد 1 نرون وجود دارد که نتیجه روانگرایی را مشخص خواهد نمود.

تعداد رویکردهای (سعی و خطا) مورد استفاده در این مدل 30000 بار در نظر گرفته شده است. همچنین تابع انتقال به کار رفته در این مدل تابع تانژانت هیپربولیک است. نرخ یادگیری برای تمام لایه‌ها 0/01 در نظر گرفته شده است. در جدول (1)، مدل M1 که در این مقاله برای ارزیابی پتانسیل روانگرایی به روش شبکه عصبی مصنوعی به کار رفته از میان مدل‌های مختلفی که توسط برنامه PILA تحلیل شده‌اند استخراج شده و در تحلیل‌ها بهترین نتایج را به دست داده است. پایگاه داده مورد استفاده این مقاله، از 671 نمونه تشکیل شده است که برای مدل M1، 600 الگو به‌صورت تصادفی برای آموزش شبکه عصبی مصنوعی و تعیین وزن نرون‌ها در لایه‌های مختلف شبکه عصبی مصنوعی به کار رفته‌اند. همچنین 71 مورد باقیمانده نیز در مرحله راستی‌آزمایی شبکه، برای ارزیابی پتانسیل روانگرایی مورد استفاده قرار گرفته‌اند.

26 مورد بقیه برای راستی‌آزمایی عملکرد شبکه عصبی مصنوعی استفاده شده است. پایگاه داده این تحقیق از زلزله 1923 کانتو، 1891 مینواواری، 1944 توهانکای، 1948 فوکویی، 1964 نیگاتا، 1968 توکاجی اوکی، 1979 امپریال ولی، 1978 میاگیکن اوکی، 1957 سن‌فرانسیسکو، 1971 سن‌فرناندو، 1976 گواتمالا، 1980 جی باکن چو بوگرفته شده است. این تحقیق از هشت مدل با ساختارهای مختلف برای ارزیابی پتانسیل روانگرایی به روش شبکه عصبی مصنوعی استفاده کرده که در بهترین مدل پیشنهادی، شبکه به‌طور کلی به 95 درصد نگاهت‌ها پاسخ درست داده است. در این تحقیق به استفاده از نرم‌افزار خاصی برای تحلیل شبکه عصبی اشاره نشده است.

هانا و همکاران [16] نیز از شبکه‌های عصبی مصنوعی برای ارزیابی پتانسیل روانگرایی استفاده کرده‌اند. در این تحقیق، محققان به ارزیابی غیرخطی پتانسیل روانگرایی با استفاده از روش شبکه‌های عصبی مصنوعی و با مدل GRNN (General Regression Neural Network) پرداخته‌اند. برای سیستم‌هایی که داده‌های پراکنده و نوفه در آنها استفاده می‌شود، قابلیت ویژه‌ای دارد. مدل GRRN نیازی به تنظیمات اولیه برای پارامترهای یادگیری ندارد؛ ولی به جای آن در این روش باید عامل تسطیح را برای تمام پارامترهای مورد نیاز محاسبه نمود. به همین دلیل GRRN، زمان به نسبت کمتری برای آموزش نیاز دارد. نتایج آزمایش‌های صحرایی از زلزله‌های 1999 کوکایی و چی‌چی، گردآوری شده است. پایگاه داده شامل 620 نگاهت است که 330 نگاهت مربوط به زلزله کوکایی و 290 نگاهت مربوط به زلزله چی‌چی است. در این تحقیق از نرم‌افزار Neuro Shell 2 برای تحلیل مراحل چندگانه آموزش، آزمایش و راستی‌آزمایی و از مدل GRNN استفاده شده است. این مدل به 98 درصد نمونه‌ها پاسخ درست داده است. قابل ذکر است که نحوه ارزیابی عملکرد در این مقالات و همچنین این تحقیق با یکدیگر متفاوت است.

مدل عمومی به کار رفته در این مقاله برای شبکه عصبی مصنوعی، شبکه جلو رونده (feed forward) با روال تعلیم انتشار



جدول (1): مدل‌های به کار رفته در مقاله برای مقایسه دو روش شبکه عصبی مصنوعی با مرکب خوشه‌بندی فازی - شبکه عصبی

مدل	پارامترهای ورودی	تعداد پارامترهای ورودی	تعداد نرون‌های لایه پنهان	تعداد رویکردها	نرخ یادگیری	تابع انتقال	معیار شباهت	تعداد کلاسترها
M1	ANN	8	7	30000	0/01	tgh(x)	-	-
M100	FCM-ANN	8	7	30000	0/01	tgh(x)	90	40
M10		8	7	30000	0/01	tgh(x)	80	40
M11		8	7	30000	0/01	tgh(x)	70	40
M12		8	7	30000	0/01	tgh(x)	60	40

$$d_{ik}^2 = \|y_k - v_i\|_A^2 = (y_k - v_i)^T A (y_k - v_i) \quad (4)$$

$m =$  توان وزنی  $1 \ll m < \infty$

$v = (v_1, v_2, \dots, v_c)$  مراکز بردار

$v_i = (v_{i1}, v_{i2}, \dots, v_{in})$  خوشه مرکز  $i$  ام

$\| \cdot \|_A$  نرم هندسی اقلیدسی

$A = n \times n$  ماتریس وزنی مثبت معین

2- محاسبه تمایل به روانگرایی مراکز هر کدام از خوشه‌ها  $(LT_{ci})$  که با رابطه (5) به دست می‌آید:

$$LT_{ci} = \frac{\sum_{k=1}^n (\hat{u}_{ik}) L_{pk}}{\sum_{k=1}^n (\hat{u}_{ik})} \quad i = 1, 2, \dots, c \quad (5)$$

3- محاسبه روانگرایی هر کدام از نمونه‌های روانگرایی (liquefaction sample ( $L_s$ )) با استفاده از مراکز خوشه‌ها و با رابطه (6) قابل محاسبه است:

$$L_s_j = \sum_{i=1}^c LT_{ci} \times \hat{u}_{ij} \quad i = 1, 2, \dots, c; j = \text{No Samples} \quad (6)$$

لازم به ذکر است که نمونه‌های مورد سؤال به صورت تک‌به‌تک با پایگاه داده ترکیب می‌شوند و روش فازی به ازای هر کدام از آنها یک‌بار اجرا می‌شود. به این صورت، در هر دور اجرای روش فازی مراکز خوشه مخصوص به مورد سؤال و درجه عضویت این مورد سؤال به هر کدام از خوشه‌ها به دست می‌آیند. با رابطه (5) ابتدا تمایل به روانگرایی خوشه‌ها  $(LT_{ci})$  و سپس تمایل به روانگرایی هر نمونه با استفاده از رابطه (6) محاسبه می‌شود.

### 3- روش مرکب خوشه‌بندی فازی - شبکه عصبی (Fuzzy C-Means Clustering - (FCM-ANN) Artificial Neural Network)

روش مرکب خوشه‌بندی فازی - شبکه عصبی از روش فازی برای پالایش الگوهای مورد استفاده برای آموزش شبکه عصبی مصنوعی استفاده می‌کند تا مجموعه‌ای که تحت آموزش قرار می‌گیرد بیشترین شباهت را به نمونه مورد سؤال داشته باشد و به دنبال آن عملکرد شبکه عصبی مصنوعی بهبود یابد. اجرای روش مرکب خوشه‌بندی فازی - شبکه عصبی شامل مراحل زیر است.

#### 3-1- روش خوشه‌بندی میانگین مرکزی فازی

روش خوشه‌بندی میانگین مرکزی فازی در سه مرحله اجرا می‌شود که عبارتند از:

1- محاسبه ماتریس عضویت  $(u_{ik})$  و تعیین مراکز خوشه‌ها  $(v_i)$  که از کمینه کردن تابع هدف (روابط 1 تا 4) به دست می‌آیند:

$$J_m(C, v) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m \|y_k - v_i\|_A^2 \quad (1)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left( \frac{d_{ik}}{d_{ij}} \right)^{\frac{2}{m-1}}} \quad (2)$$

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m y_k}{\sum_{k=1}^n u_{ik}^m} \quad (3)$$

### 3-2- پالایش الگوهای آموزش شبکه عصبی مصنوعی

با دانستن تمایل به روانگرایی هر کدام از نمونه‌های مورد سؤال و با استفاده از معیار شباهت ("Tolerance" semblance)، از الگوریتم نشان داده‌شده در روابط (7)، (8) و (9)، مجموعه‌ای که بیشترین شباهت را به نمونه مورد نظر دارد، شناسایی شده و اکنون آموزش شبکه عصبی مصنوعی بر روی مجموعه مختص به نمونه مورد سؤال انجام می‌گیرد:

$$L_{\max} = L_{s_j} + Tole \quad (7)$$

$$L_{\min} = L_{s_j} - Tole \quad (8)$$

If  $L_{\min} < L_{sp} < L_{\max}$   
 {choose this pattern} (9)  
 else  
 {delete this pattern}

### 4- پایگاه داده

در این تحقیق از 600 الگو استفاده شده است که 273 نگاهت از زلزله 1999 کو کاپلی، 248 نگاهت از زلزله 1999 چی چی، 6 نگاهت از زلزله 1923 کانتو، 5 نگاهت از زلزله 1891 مینوآواری، 4 نگاهت از زلزله 1944 توهانکای، 6 نگاهت از زلزله 1948 فوکویی، 10 نگاهت از زلزله 1964 نیگاتا، 3 نگاهت از زلزله 1968 توکاجی اوکی، 1 نگاهت از زلزله 1979 امپریال ولی، 38 نگاهت از زلزله 1978 میاگیکن اوکی، 1 نگاهت از زلزله 1957 سان فرانسیسکو، 1 نگاهت از زلزله 1971 سن فرناندو، 2 نگاهت از زلزله 1976 گواتمالا و 2 نگاهت از زلزله 1980 جی‌باکن چویو است. نمونه‌های مورد سؤال نیز از 71 نگاهت، 41 نگاهت از زلزله 1999 کو کاپلی، 2 نگاهت از زلزله 1999 چی چی، 1 نگاهت از زلزله 1944 توهانکای می‌باشند. تمام الگوهای پایگاه داده از مقالات جو [8] و هانا [5] اقتباس گردیده است. از میان 600 داده‌ای که برای آموزش شبکه مورد استفاده قرار گرفته است، 274 مورد روانگرا می‌شود و 326 مورد روانگرایی در آنها رخ نمی‌دهد. همچنین در میان 71 مورد داده‌ای که برای ارزیابی کارایی شبکه مورد استفاده قرار گرفته‌اند، 50 مورد روانگرا شده و 21 مورد روانگرا نشده است. برای به دست آوردن نتایج دقیق‌تر، به علت پیچیدگی زیاد

رفتار خاک باید پارامترهای به کار رفته در تحلیل بیشترین خصوصیات خاک را پوشش دهند. پارامترهای موجود در هر کدام از الگوها و یا نمونه‌های مورد سؤال در این مقاله برای روش شبکه عصبی مصنوعی در جدول (1) ارائه شده‌اند. همچنین پارامترهای به کار برده شده برای روش فازی شامل عدد نفوذ استاندارد اصلاح شده برای اصلاح درصد ریزدانه ماسه تمیز ( $60_{cs}(MI)$ ) و نسبت تنش سیکلی معادل ( $CSReq$ ) برای معادل کردن آن با بزرگ‌گای مختلف از روش کارگروه انسیر استفاده شده است [17]. الگوها و نمونه‌های مورد سؤال بر اساس عدد نفوذ استاندارد و نسبت تنش تناوبی سیکلی در شکل (1) نشان داده شده است.

پایگاه داده‌های مورد استفاده در این تحقیق ممکن است دارای عدم قطعیت‌هایی باشند که بر نتایج نهایی تأثیر داشته باشند. عدم قطعیت موجود در این داده‌ها به علت استفاده از آزمایش‌های صحرائی است که وجود خطا در این آزمایش‌ها اجتناب‌ناپذیر است. به همین دلیل، نتایج به دست آمده در این تحقیق هم عدم قطعیت‌هایی دارد. برخی از محققان [18] به پالایش این داده‌ها اقدام نموده‌اند.

### 5- تحلیل نتایج


برای مقایسه دو روش شبکه عصبی مصنوعی با خوشه‌بندی فازی - شبکه عصبی، پارامترهای مورد استفاده، یکسان در نظر گرفته شده است. مدل‌های به کار رفته در این مقاله برای مقایسه دو روش شبکه عصبی مصنوعی با مرکب خوشه‌بندی فازی - شبکه عصبی در جدول (1) آورده شده است. برای روش شبکه عصبی مصنوعی از مدل M1 و برای ارزیابی به روش مرکب خوشه‌بندی فازی - شبکه عصبی از مدل‌های M100 تا M12 استفاده شده است. تمام مدل‌ها در این دو روش مشابه یکدیگرند. تنها در روش مرکب خوشه‌بندی فازی - شبکه عصبی مقادیر معیار، مشابه و تعداد خوشه‌ها متغیرند.

نتایج به دست آمده از مدل‌های بررسی شده در جدول (2) آورده شده است. ستون‌هایی که با عنوان liq در این جدول مشخص شده‌اند نشان‌دهنده‌ی نتیجه‌ی پیش‌بینی پتانسیل



به نتایج روانگرایی الگوهای به کار رفته در آموزش شبکه عصبی مصنوعی نشان‌دهنده وقوع یا عدم وقوع روانگرایی‌اند. هرچه دامنه گرد کردن اعداد کوچک‌تر باشد نشان‌دهنده دقت زیاد شبکه عصبی در ارزیابی توان روانگرایی است.

روانگرایی بر اساس مدل‌های مختلف است. در مقالات مختلف که در این تحقیق به آنها اشاره شد به منظور ارائه شفاف‌تر نتایج، مقادیر به‌دست‌آمده از روش شبکه عصبی به اعداد صفر و یک گرد می‌شوند که این اعداد با توجه



شکل (1): داده‌های آموزش و راستی‌آزمایی بر اساس عدد نفوذ استاندارد اصلاح‌شده به ریزدانه و نسبت تنش تناوبی سیکلی

جدول (2): نتایج ارزیابی پتانسیل روانگرایی برای مدل‌های مختلف همراه با خطای شبکه به‌دست‌آمده برای هر کدام از نمونه‌های مورد سؤال

ID	Actual Liq	Liq (M1)	Result (M1)	Error/net (M1)	Liq (M100)	Result (M100)	Error/net (M100)	Liq (M10)	Result (M10)	Error/net (M10)	Liq (M11)	Result (M11)	Error/net (M11)	Liq (M12)	Result (M12)	Error/net (M12)
1	0	-0.126	0	0.369	-0.16	0	0.135	-0.13	0	0.137	-0.1	0	0.2	-0.07	0	-0.145
2	0	0.3468	0	0.369	0.26	0	0.108	0.116	0	0.174	0.08	0	0.18	0.091	0	-0.175
3	0	-0.137	0	0.369	-0.245	0	0.156	-0.06	0	0.109	-0.1	0	0.21	-0.329	0	0.21
4	0	-0.146	0	0.369	-0.062	0	0.109	-0.41	0	0.176	-0.1	0	0.12	-0.240	0	0.1501
5	1	1.0875	1	0.369	0.934	1	0.133	0.783	1	0.178	1/1	1	0.12	0.9644	1	0.12591
6	0	0.2252	0	0.369	0.139	0	0.158	0.071	0	0.125	0.33	0	0.11	0.0213	0	0.14292
7	1	1/0.1	1	0.369	0.813	1	0.134	1/0.12	1	0.181	0.77	1	0.13	0.7333	0	0.17517
8	0	0.7022	0	0.369	0.549	0	0.175	0.684	0	0.11	0.64	0	0.15	0.6255	0	0.12076
9	1	1/1.05	1	0.369	0.625	0	0.109	0.599	0	0.108	0.65	0	0.15	0.7947	1	0.15614
10	1	0.7775	1	0.369	0.66	0	0.185	0.578	0	0.123	0.55	0	0.2	0.3445	0	0.10898
11	1	1/0.15	1	0.369	0.919	1	0.114	0.635	0	0.117	0.73	0	0.13	0.4988	0	0.10825
12	1	1/1.948	1	0.369	0.743	0	0.143	0.65	0	0.109	0.72	0	0.13	0.6447	0	0.10915
13	1	0.6539	0	0.369	0.664	0	0.139	0.646	0	0.137	0.66	0	0.13	0.7956	1	0.11576
14	1	0.7537	0	0.369	0.269	0	0.108	0.56	0	0.185	0.76	0	0.18	0.6541	0	0.17924
15	0	-0.057	0	0.369	-0.168	0	0.137	-0.1	0	0.153	-0.1	0	0.14	-0.050	0	0.17605
16	1	0.725	0	0.369	0.267	0	0.109	0.53	0	0.153	0.53	0	0.18	0.7049	0	0.12129
17	1	0.6968	0	0.369	0.609	0	0.175	0.462	0	0.109	0.92	1	0.13	0.7507	0	0.13079
18	1	0.97	1	0.369	0.692	0	0.169	0.774	1	0.136	0.92	1	0.11	0.7235	0	0.21251
19	1	0.5951	0	0.369	0.799	1	0.126	0.806	1	0.128	0.72	0	0.15	0.6642	0	0.15319

ادامه جدول (2)

ID	Actual Liq	Liq (M1)	Result (M1)	Error/net (M1)	Liq (M100)	Result (M100)	Error/net (M100)	Liq (M10)	Result (M10)	Error/net (M10)	Liq (M11)	Result (M11)	Error/net (M11)	Liq (M12)	Result (M12)	Error/net (M12)
20	1	1/1972	1	0/369	0/915	1	0/157	0/937	1	0/191	0/75	0	0/15	0/7725	1	0/16472
21	0	0/503	0	0/369	0/192	0	0/179	0/7	0	0/136	0/1	0	0/2	0/866	0	0/12631
22	0	0/4668	0	0/369	0/216	0	0/142	0/517	0	0/12	0/59	0	0/11	0/5674	0	0/11023
23	0	0/5248	0	0/369	0/702	0	0/1	0/543	0	0/146	0/47	0	0/15	0/5235	0	0/13483
24	0	0/1772	0	0/369	0/81	0	0/161	0/337	0	0/135	0/24	0	0/18	0/1881	0	0/15555
25	0	0/6303	0	0/369	0/666	0	0/11	0/562	0	0/171	0/63	0	0/14	0/597	0	0/12161
26	1	0/7806	1	0/369	0/585	0	0/181	0/688	0	0/133	0/62	0	0/15	0/6628	0	0/1469
27	0	0/206	0	0/369	0/306	0	0/164	0/05	0	0/137	0/1	0	0/14	0/206	0	0/17136
28	0	0/237	0	0/369	0/281	0	0/155	0/119	0	0/154	0/8	0	0/18	0/3836	0	0/10961
29	0	0/6772	0	0/369	0/364	0	0/171	0/495	0	0/165	0/71	0	0/13	0/5687	0	0/15082
30	0	0/424	0	0/369	0/65	0	0/135	0/22	0	0/193	0/1	0	0/14	0/443	0	0/13498
31	0	0/522	0	0/369	0/23	0	0/119	0/2	0	0/129	0/2	0	0/18	0/251	0	0/10744
32	0	0/7314	0	0/369	0/754	0	0/15	0/626	0	0/184	0/65	0	0/17	0/8317	1	0/14919
33	0	0/2281	0	0/369	0/153	0	0/161	0/205	0	0/148	0/17	0	0/18	0/177	0	0/21455
34	0	0/67	0	0/369	0/182	0	0/163	0/17	0	0/182	0/11	0	0/11	0/1028	0	0/16668
35	1	0/39	0	0/369	0/143	0	0/141	0/09	0	0/176	0/2	0	0/21	0/247	0	0/19797
36	0	0/3707	0	0/369	0/396	0	0/114	0/266	0	0/136	0/39	0	0/15	0/4229	0	0/11397
37	0	0/6924	0	0/369	0/754	0	0/128	0/631	0	0/188	0/71	0	0/14	0/5521	0	0/17859
38	0	0/3822	0	0/369	0/34	0	0/149	0/235	0	0/172	0/34	0	0/15	0/2413	0	0/17811
39	0	0/3183	0	0/369	0/267	0	0/132	0/196	0	0/157	0/22	0	0/16	0/2841	0	0/13842
40	0	0/8325	1	0/369	0/724	0	0/153	0/679	0	0/176	0/85	1	0/19	0/6929	0	0/16775
41	0	0/214	0	0/369	0/97	0	0/149	0/08	0	0/222	0/05	0	0/18	0/0186	0	0/17222
42	0	0/328	0	0/369	0/357	0	0/109	0/374	0	0/11	0/32	0	0/13	0/3227	0	0/1428
43	0	0/132	0	0/369	0/181	0	0/198	0/1	0	0/109	0/1	0	0/14	0/121	0	0/13742
44	0	0/215	0	0/369	0/17	0	0/152	0/2	0	0/195	0/3	0	0/13	0/162	0	0/12799
45	0	0/196	0	0/369	0/74	0	0/127	0/15	0	0/126	0/3	0	0/14	0/178	0	0/14922
46	0	0/205	0	0/369	0/09	0	0/124	0	0	0/96	0/2	0	0/13	0/306	0	0/14836
47	1	0/4768	0	0/369	0/449	0	0/109	0/265	0	0/197	0/37	0	0/15	0/2275	0	0/15866
48	0	0/12	0	0/369	0/14	0	0/137	0/3	0	0/162	0/2	0	0/14	0/133	0	0/15256
49	1	0/7034	0	0/369	0/645	0	0/152	0/568	0	0/183	0/91	1	0/12	0/8316	1	0/14062
50	1	0/5604	0	0/369	0/39	0	0/174	0/593	0	0/14	0/59	0	0/14	0/788	1	0/9834
51	1	0/5795	0	0/369	0/804	1	0/109	0/126	0	0/201	0/54	0	0/14	0/6233	0	0/13383
52	1	0/6413	0	0/369	0/691	0	0/122	0/65	0	0/136	0/73	0	0/13	0/6448	0	0/1377
53	0	0/091	0	0/369	0/92	0	0/137	0/29	0	0/137	0	0	0/11	0/220	0	0/1785
54	0	0/188	0	0/369	0/323	0	0/162	0/06	0	0/151	0/1	0	0/11	0/194	0	0/18125
55	0	0/2101	0	0/369	0/188	0	0/168	0/533	0	0/129	0/58	0	0/18	0/506	0	0/15498
56	0	0/036	0	0/369	0/346	0	0/179	0/37	0	0/137	0/04	0	0/17	0/223	0	0/14013
57	0	0/2247	0	0/369	0/497	0	0/109	0/497	0	0/109	0/07	0	0/17	0/246	0	0/14945
58	0	0/1301	0	0/369	0/152	0	0/137	0/24	0	0/214	0	0	0/11	0/049	0	0/17445
59	0	0/3247	0	0/369	0/148	0	0/109	0/159	0	0/159	0/43	0	0/13	0/2851	0	0/13955
60	0	0/3755	0	0/369	0/142	0	0/109	0/23	0	0/144	0/2	0	0/18	0/210	0	0/17429



## ادامه جدول (2)

ID	Actual Liq	Liq (M1)	Result (M1)	Error/net (M1)	Liq (M100)	Result (M100)	Error/net (M100)	Liq (M10)	Result (M10)	Error/net (M10)	Liq (M11)	Result (M11)	Error/net (M11)	Liq (M12)	Result (M12)	Error/net (M12)
61	0	-0/22	0	0/369	-0/3	0	-0/114	-0/4	0	-0/146	-0/1	0	0/1	-0/222	0	0/14548
62	0	0/7022	0	0/369	0/711	0	0/154	0/688	0	-0/149	0/66	0	0/15	-0/497	0	0/15756
63	0	0/7276	0	0/369	0/759	0	-0/12	0/726	0	-0/176	0/69	0	0/13	0/6799	0	0/13886
64	0	0/7168	0	0/369	0/471	0	-0/164	0/421	0	-0/176	0/66	0	0/17	-0/4121	0	0/15717
65	0	0/7428	0	0/369	0/459	0	-0/168	0/552	0	-0/179	0/83	1	0/13	-0/5728	0	0/11487
66	0	0/6718	0	0/369	0/286	0	-0/168	0/673	0	-0/136	0/68	0	0/1	-0/4349	0	0/16509
67	0	0/7609	1	0/369	0/547	0	-0/141	0/444	0	-0/185	0/83	1	0/11	0/5895	0	0/1517
68	0	0/4279	0	0/369	0/458	0	-0/15	0/431	0	-0/173	0/4	0	0/16	0/426	0	0/13814
69	0	0/2217	0	0/369	-0/12	0	-0/109	0/329	0	-0/184	-0/16	0	0/14	-0/604	0	0/15159
70	0	-0/152	0	0/369	0/193	0	-0/187	-0/1	0	-0/147	-0/2	0	0/11	-0/347	0	0/19115
71	1	0/3199	0	0/369	0/53	0	-0/188	0/556	0	-0/157	0/43	0	0/12	0/4584	0	0/10729


جو [8] آمده، محاسبه می‌شود. در شکل (3) عملکرد مدل‌های مختلف در ارزیابی پتانسیل روانگرایی به صورت نمودار ستونی نشان داده شده است. این شکل نشان می‌دهد که مدل‌های M10 و M100 برای تمامی مواردی که وقوع روانگرایی پیش‌بینی شده موفق بوده‌اند و در واقعیت نیز آن موارد به روانگرایی منجر شده‌اند. این در حالی است که مدل M1 تقریباً 82% موفقیت در ارزیابی پتانسیل روانگرایی داشته است و بدین ترتیب 18% میزان موفقیت در ارزیابی پتانسیل روانگرایی با کاربرد این روش جدید افزایش یافته است. به عنوان مثال، شکل (4)، مجموعه انتخاب شده برای آموزش شبکه عصبی با مدل M12 را برای نمونه مورد سؤال شماره 1 (ID = 1) در جدول (3) نشان می‌دهد.

جدول (3): نتایج درصد موفقیت در ارزیابی توان روانگرایی برای مدل‌های مختلف و با نرخ‌های گرد کردن متفاوت

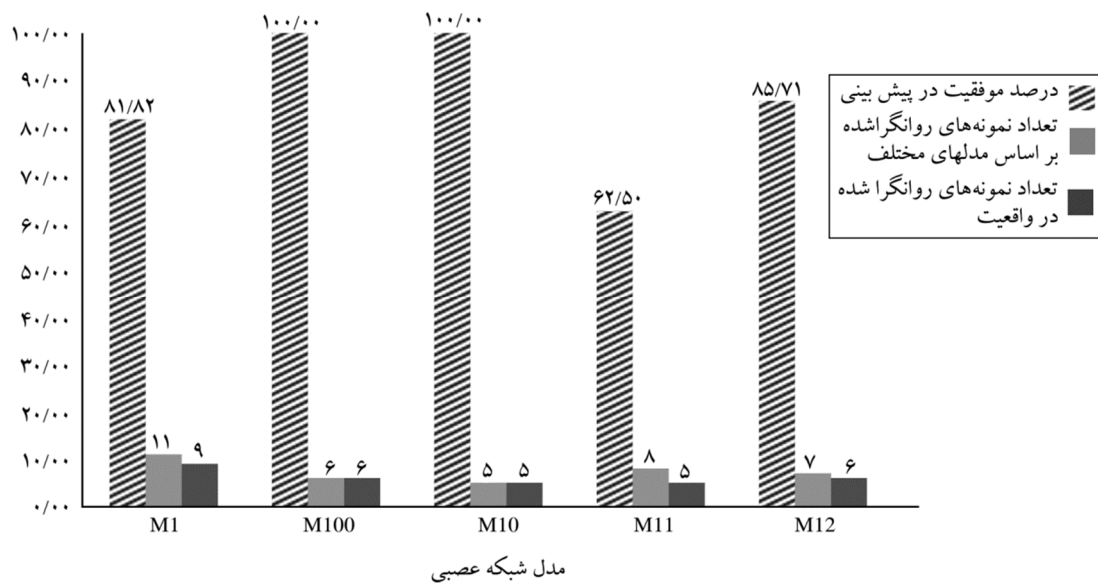
M12	M11	M10	M100	M1	نرخ گرد کردن
55/56	56/25	58/62	64	58/6	0/5
78/95	53/85	58/82	66/67	55/56	0/6
90/91	68/75	83/33	53/85	60	0/7
85/71	62/5	100	100	81/82	0/76
66/67	57/14	100	100	87/5	0/8
100	100	100	100	100	0/85

در این تحقیق، به منظور رعایت این دامنه، اگر مقادیر بزرگ‌تر از 0/76 باشند به عنوان نمونه روانگرا در نظر گرفته می‌شود و اگر این نمونه در واقعیت نیز روانگرا شده باشد، نشان می‌دهد که پیش‌بینی مدل در ارزیابی پتانسیل روانگرایی درست بوده است (ستون Result=1). علت استفاده از مقدار 0/76 به دلیل نتایج به دست آمده از تحلیل‌های مختلف برای مقادیر مختلف نرخ گرد کردن است که در نتیجه این تحلیل، مقدار 0/76 بهترین نتیجه را برای مدل‌های مختلف به دست می‌دهد. در این تحقیق برای مقادیر مختلف نرخ گرد کردن 5/ تا 0/85 (مطابق جدول 3)، تحلیل انجام شده و مقدار 0/76 بهترین موفقیت را در ارزیابی پتانسیل روانگرایی نسبت به روش شبکه عصبی مصنوعی به دست داده است. در ستون Error/net جدول (2) نیز خطای شبکه برای هر کدام از نمونه‌های مورد سؤال آورده شده است و نشان می‌دهد که روش مرکب خوشه‌بندی فازی - شبکه عصبی به مقدار چشمگیری خطای شبکه عصبی مصنوعی را کاهش می‌دهد (شکل 2). شکل (2) مبین آن است که خطای شبکه برای هر کدام از نمونه‌های مورد سؤال مقداری متفاوت است؛ زیرا برای هر کدام از آنها شبکه عصبی با پایگاه داده مختص به همان نمونه آموزش می‌بیند. در نتیجه، هم خطای شبکه و هم اوزان نرون‌های لایه پنهان، مقادیر متفاوتی خواهند بود. خطای شبکه مطابق آنچه در مقاله






شکل (2): نتایج خطای شبکه برای نمونه‌های مورد سؤال در مدل‌های مختلف



شکل (3): نتایج عملکرد مدل‌های مختلف در ارزیابی پتانسیل روانگرایی



شکل (4): الگوهای مختص به نمونه مورد سؤال شماره 1 در مدل M12

## 6- نتیجه‌گیری

روش FCM-ANN ترکیبی از روش‌های خوشه‌بندی میانگین مرکزی فازی و شبکه عصبی مصنوعی است. این روش از بخش فازی برای پالایش الگوهای که برای آموزش شبکه عصبی مصنوعی به کار می‌رود، بهره‌برداری می‌کند و از روش شبکه عصبی مصنوعی برای ارزیابی پتانسیل روانگرایی استفاده می‌نماید. پالایش الگوهای شبکه آموزش به حذف داده‌های نامناسب و استفاده از الگوهای نزدیک‌تر به نمونه مورد سؤال منجر گردید. خطای شبکه آموزش نیز به مقدار چشمگیری کاهش یافت. هدف این تحقیق ارتقای عملکرد شبکه عصبی مصنوعی در موفقیت پیش‌بینی رخداد روانگرایی و به تبع آن کاهش خطاهای شبکه آموزش بوده است. به همین منظور، از مدل M1 برای شبکه عصبی مصنوعی و از مدل‌های M100 تا M12 برای روش ترکیبی خوشه‌بندی فازی-عصبی استفاده شد. همچنین مدل عمومی روش شبکه عصبی مصنوعی مدل پس انتشار خطا در نظر گرفته شده است. در این تحقیق نشان داده شد که روش خوشه‌بندی میانگین مرکزی فازی می‌تواند مکمل مناسبی برای روش شبکه عصبی مصنوعی باشد و با توجه به نتایج به‌دست آمده از روش مرکب خوشه‌بندی فازی-شبکه عصبی، ملاحظه می‌شود که استفاده از الگوهای مناسب باعث بهبود عملکرد روش شبکه عصبی در ارزیابی پتانسیل روانگرایی می‌شود. نتایج نهایی نشان می‌دهد که با معیار شباهت 80% در مدل M10 می‌توان به عملکرد بهتری دست یافت و اضافه نمودن تعداد الگوهای نامناسب برای تحلیل نمونه‌های مورد سؤال به کاهش عملکرد شبکه منجر شده است. عملکرد ترکیبی روش فازی با روش شبکه عصبی مصنوعی باعث بهبود 18 درصدی در مدل‌های بررسی شده در این تحقیق شد و تقریباً 50% خطای شبکه نسبت به روش شبکه عصبی کاهش یافت.

## مراجع

- Terzaghi, K. (1925) Modern conceptions concerning foundation engineering. *Journal of the Boston Society of Civil Engineers*, **12**(10), 397-439.
- Casagrande, A. (1940) *Characteristics of Cohesion Less Soils Affecting the Stability of Slopes and Earth Fills*. Contributions to Soils Mechanics, Boston: Boston Society of Civil Engineers.
- Terzaghi, K., Peck, R.B., and Mesri, G. (1996) *Soil Mechanics in Engineering Practice*. New York: John Wiley & Sons.
- Tokimatsu, K. and Yoshimi, Y. (1983) Empirical correlation of soil liquefaction based on spt N-value and fines content. *Soils and Foundations*, **23**(4), 56-74.
- Dobry, R., Ladd, R.S., Powell, D., Yokel, F.Y., and Chung, R.M. (1982) *Prediction of Pore Water Pressure Build Up and Liquefaction of Sands During Earthquakes by the Cyclic Strain Method*. NBS Building Science Series 138. Maryland. National Bureau of Standards.
- Law, K.T., Cao, Y.L., and He, G.N. (1990) An energy approach for assessing seismic liquefaction potential. *Canadian Geotechnical Journal*, **27**(3), 320-329.
- Goh, A.T. (1994) Seismic liquefaction potential assessed by neural networks. *Journal of Geotechnical Engineering*, **120**(9), 1467-1480.
- Lin, C.T. (1996) *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*. Boston: Prentice-Hall.
- Baziar, M.H., and Nilipour, N. (2003) Evaluation of liquefaction potential using neural-networks and CPT results. *Soil Dynamics and Earthquake Engineering*, **23**(7), 631-636.
- Goh, A.T. (1996) Neural-network modeling of CPT seismic liquefaction data. *Journal of Geotechnical Engineering*, **122**(1), 70-73.
- Goh, A.T. (2002) Probabilistic neural network for evaluating seismic liquefaction potential. *Canadian Geotechnical Journal*, **39**(1), 219-232.

- Yoshimine, M., Robertson, P.K., and Wride, C.E. (1999) Undrained shear strength of clean sands to trigger flow liquefaction. *Canadian Geotechnical Journal*, **36**(5), 891-906.

13. Tung, A.T., Wang, Y.Y., and Wong, F.S. (1993) Assessment of liquefaction potential using neural networks. *Soil Dynamics and Earthquake Engineering*, **12**(6), 325-335.
14. فاطمی کیا، روح اله، عشایری، ایمان، بیگلری، مهنوش (1393) ارزیابی پتانسیل روانگرایی به روش خوشه‌بندی میانگین مرکزی فازی. دومین کنفرانس ملی ژئوتکنیک (صفحه 116). کرمانشاه.
15. فاطمی کیا، روح اله (1393) ارزیابی پتانسیل وقوع روانگرایی با استفاده از روش فازی-عصبی پیاده‌سازی در نرم‌افزار. پایان‌نامه کارشناسی ارشد، دانشگاه رازی.
16. 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 Dynamics and Earthquake Engineering*, **27**(6), 521-540.
17. Robertson, P.K. and Fear, C.E. (1997) *Cyclic Liquefaction and Its Evaluation Based on the SPT and CPT*. 97. California: US National Center for Earthquake Engineering Research (NCEER).
18. Cetin, K.O., Seed, R.B., Der Kiureghian, A., Tokimatsu, K., Harder Jr, L.F., Kayen, R.E., and Moss, R.E. (2004) Standard penetration test-based probabilistic and deterministic assessment of seismic soil liquefaction potential. *Journal of Geotechnical and Geoenvironmental Engineering*, **130**(12), 1314-134.

## Liquefaction Potential Assessment Using Fuzzy c-Means Clustering - Artificial Neural Network Hybrid Method (FCM-ANN)

Rouhollah Fatemikia<sup>1</sup>, Iman Ashayeri<sup>2</sup>, and Mahnoosh Biglari<sup>3</sup>

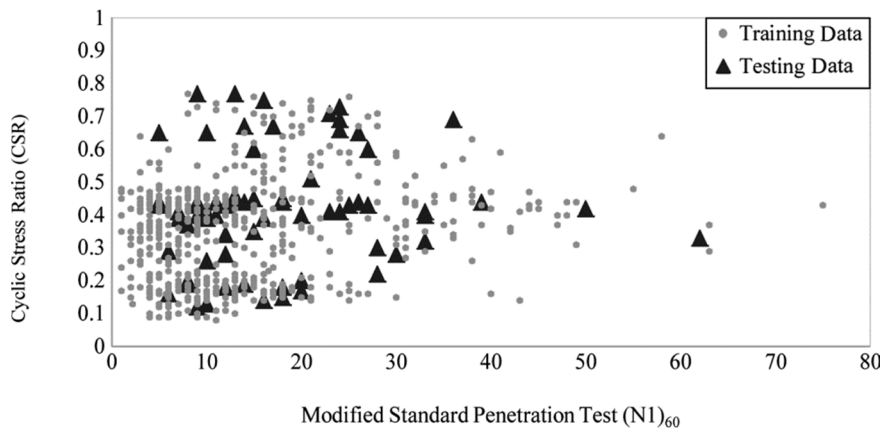
1. M.Sc. of Earthquake Engineering, Razi University

2. Assistant Professor, Razi University, Coresponding Author: [i.ashayeri@razi.ac.ir](mailto:i.ashayeri@razi.ac.ir)

3. Assistant Professor, Razi University

There are various empirical and intelligent methods to evaluate the liquefaction potential. Although the artificial neural network (ANN) method is one of the most powerful methods that is introduced in liquefaction assessment recently, a new hybrid intelligent system of fuzzy c-means clustering and artificial neural network (FCM-ANN) is examined in this article to overcome the complexity of soil behavior. Fuzzy c-means clustering method refines the patterns used for training neural network, and the entry of inappropriate patterns in training will be prevented. This clustering is performed on the standard penetration test measurements  $(N_1)_{60cs}$  and cyclic stress ratio (CSR). In this article, a database of 600 field studies of liquefaction in past earthquakes is used that contains 274 liquefied and 326 non-liquefied cases. The distribution of these 600 studies is presented in Figure (1).

In order to compare the two methods of ANN and FCM-ANN, one ANN and four FCM-ANN models are analyzed (Table 1). All models in these two methods are similar in configuration but different in tolerance semblance values and the number of clusters. Figure (2) presents the results of the various models to assess the



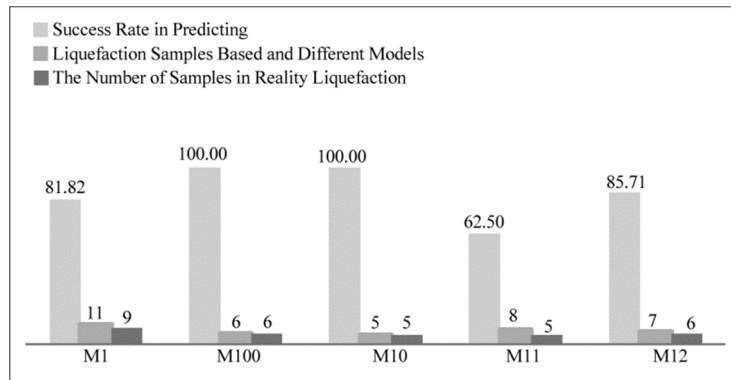
**Figure 1.** Training and testing data based on standard penetration test modified to fines and cyclic stress ratio.

**Table 1.** Models used in this article to compare the two methods of ANN and FCM-ANN

	Model	Input Parameters	Number of Input Parameters	Number of Hidden Neurons	Number of Epoch	Learning Rate	Transfer Function	Tolerance Semblance	Number of Clusters
ANN	M1	$z, \sigma'v, \sigma'v, CSR, mw, (N1)_{60}, FC, amax$	8	7	30000	0.01	tgh(x)	-	-
ANN-FCM	M100	$z, \sigma'v, \sigma'v, CSR, mw, (N1)_{60}, FC, amax$	8	7	30000	0.01	tgh(x)	90	40
	M10	$z, \sigma'v, \sigma'v, CSR, mw, (N1)_{60}, FC, amax$	8	7	30000	0.01	tgh(x)	80	40
	M11	$z, \sigma'v, \sigma'v, CSR, mw, (N1)_{60}, FC, amax$	8	7	30000	0.01	tgh(x)	70	40
	M12	$z, \sigma'v, \sigma'v, CSR, mw, (N1)_{60}, FC, amax$	8	7	30000	0.01	tgh(x)	60	40

## ABSTRACT

liquefaction potential in terms of successful liquefaction prediction. As seen in Figure (2), M100 and M10 models reached 100 percent successful prediction. This is while the M1 achieved about 82 percent. Thus an 18% improvement is observed by using new method to evaluate liquefaction potential.



**Figure 2.** The results of the different models in the evaluation of liquefaction potential.

Besides, an advanced software system for the analysis of ANN and FCM-ANN methods was designed by the authors in Language C# with Microsoft Visual Studio 2012 and the SQL Server 2012 database entitled PILA (Professional Intelligent Liquefaction Assessment).

**Keywords:** Liquefaction Potential; Fuzzy C-Means Clustering; Artificial Neural Network; Standard Penetration Test