

## پیش‌بینی پتانسیل تورمی خاک‌های مارنی حوضه دریاچه نمک

علیرضا مجیدی<sup>۱</sup>، غلامرضا لشکری‌پور<sup>۲\*</sup> و ضیاء‌الدین شعاعی<sup>۳</sup>

<sup>۱</sup> دانشجوی دکتری زمین‌شناسی مهندسی، دانشکده علوم، دانشگاه فردوسی مشهد، <sup>۲</sup> استاد، دانشکده علوم، دانشگاه فردوسی مشهد، <sup>۳</sup> دانشیار، پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ پذیرش: ۱۳۹۴/۱۱/۱۸

تاریخ دریافت: ۱۳۹۴/۰۸/۱۴

### چکیده

پتانسیل تورمی خاک‌های ریزدانه از جمله عوامل موثر بر فرسایش و رفتار مکانیکی آن‌ها و همچنین از داده‌های ضروری در مراحل مطالعه، طراحی، اجرای و انتخاب مصالح اغلب سازه‌های مهندسی به خصوص سازه‌های هیدرولیکی هستند. در این پژوهش به منظور پیش‌بینی پتانسیل تورمی خاک‌های ریزدانه مارنی از مدل شبکه عصبی مصنوعی پرسپترون چند لایه و الگوریتم آموزش لونیگ-مارکواریت استفاده شده است. به منظور مشخص نمودن بهترین مدل پیش‌بینی پتانسیل تورمی خاک‌های مارنی، چند عامل مختلف از جمله ساختار شبکه و ترکیب پارامترهای ورودی، به طور هم‌زمان و در ارتباط با یکدیگر به روش سعی و خطا مورد بررسی و ارزیابی قرار گرفت. در این تحقیق از نتایج آزمایش‌های فیزیکی شیمیایی و مکانیکی انجام شده بر روی ۶۰ نمونه خاک ریزدانه مارنی با سنگ مادری مارن‌های نئوژن، سازندهای قم و قرمز بالایی که از حوضه دریاچه نمک و در نواحی تهران، قم و ساوه برداشت شده، استفاده شده است. در این تحقیق از پارامتر شیمیایی قابلیت هدایت الکتریکی اشباع خاک EC، به عنوان یک پارامتر جدید همراه با پارامترهای شاخص و فیزیکی نظیر، حدود اتربرگ، دانه‌بندی، عدد فعالیت خاک، درصد پوکی و دانسیته اولیه خاک در پیش‌بینی پتانسیل تورمی خاک استفاده شد. مقادیر معیارهای ارزیابی  $R^2$ ، RMSE و ضریب کارایی مدل MCE مربوط به بهترین مدل با پارامترهای فیزیکی  $Y_{d0}$ ، C، M، A، PI و LL به ترتیب برابر ۰/۸۹، ۲/۳ و ۰/۸۴ و برای بهترین مدل با پارامترهای فیزیکی  $Y_{d0}$ ، C، M، PI، LL به همراه پارامتر EC به ترتیب برابر ۰/۹۲، ۱/۷ و ۰/۹۱ می‌باشد. به این ترتیب نتایج معیارهای ارزیابی مدل‌های شبکه عصبی نشان داد که استفاده از پارامتر هدایت الکتریکی اشباع خاک به همراه دیگر پارامترهای خاک، باعث افزایش دقت و کارایی مدل شبکه عصبی در پیش‌بینی پتانسیل تورمی خاک‌های ریزدانه مارنی می‌شود.

**واژه‌های کلیدی:** خاک‌های ریزدانه مارنی، شبکه عصبی مصنوعی، نئوژن، هدایت الکتریکی اشباع خاک

### مقدمه

متورم می‌شود و در اثر از دست دادن رطوبت کاهش حجم داده و منقبض می‌شود. درجه تورم این خاک‌ها، علاوه بر وابستگی به درصد و نوع و فعالیت کانی‌های رسی به دیگر پارامترهای شیمیایی و فیزیکی از جمله املاح، تراکم و ساختمان خاک نیز وابسته است

تغییر درصد رطوبت ناشی از وضعیت آب و هوای فصلی و یا عوامل مصنوعی، باعث تغییر ویژگی‌های مکانیکی خاک‌های ریزدانه می‌شود. خاک متورم شونده خاکی است که با افزایش رطوبت، افزایش حجمی بیش از ۱۵ درصد حجم اولیه پیدا کرده و

\* مسئول مکاتبات: lashkaripour@um.ac.ir

برآورد سریع و آسان پتانسیل تورمی خاک به صورت غیرمستقیم و با استفاده از پارامترهای سهل‌الوصول انجام شده، هنوز هم مورد توجه محققان قرار دارد. اولین تحقیقات انجام شده در این زمینه بر مبنای بررسی‌های آماری بوده که طی آن افراد زیادی تلاش کرده‌اند با استفاده از مدل‌های رگرسیونی بین ویژگی‌های شاخص خاک‌های ریزدانه و پارامترهای تورمی آن‌ها در مناطق مختلف، رابطه معنی‌داری برقرار کنند و بر مبنای آن، مدل آماری برای پیش‌بینی و تخمین پارامترهای تورمی ارائه نمایند (Seed و همکاران، ۱۹۶۲؛ Sneath، ۱۹۸۴؛ Chen، ۱۹۸۸؛ Prakash و Sridharan، ۲۰۰۰؛ Yilmaz، ۲۰۰۶).

در دو دهه اخیر روش‌های مبتنی بر هوش مصنوعی مانند شبکه عصبی مصنوعی<sup>۲</sup> (ANN) و الگوریتم ژنتیک توجه محققان را به سمت خود جلب کرده است. شبکه عصبی مصنوعی به دلیل بهره‌گیری از هوش محاسباتی مبتنی بر آموزش، توانایی شناخت روابط پیچیده غیرخطی بین متغیرها را دارد. لذا، برای پیش‌بینی رفتار و تخمین پارامترهای خاک و سنگ بسیار مناسب و بر اساس همین توانایی جایگاه خاصی در تحقیقات علوم خاک و ژئوتکنیک پیدا کرده است (Shahin و همکاران، ۲۰۰۱؛ Ashayeri و Yasrebi، ۲۰۰۹). عده‌ای از محققان از این مدل برای پیش‌بینی پارامترهای تورمی خاک استفاده کرده‌اند.

پژوهشگران، در تحقیقی از دو مدل تجربی بر مبنای، شبکه عصبی مصنوعی و شبکه عصبی با منطق فازی (ANFIS) در برآورد درصد تورم خاک استفاده و نتایج را با روش سنتی آماری رگرسیون چند متغیره، مورد مقایسه و ارزیابی قرار دادند. در این پژوهش از پارامترهایی نظیر حد روانی، درصد ماسه، عدد فعالیت و ظرفیت تبادل کاتیونی خاک در برآورد پارامتر مورد نظر استفاده شد. نتایج مشخص کرد که تفاوت چندانی بین شبکه عصبی و شبکه عصبی به همراه منطق فازی وجود ندارد. اما دقت و صحت و کارایی شبکه‌های عصبی (روش‌های محاسبات نرم) در برآورد پارامتر تورمی از روش رگرسیون بیشتر می‌باشد (Yilmaz و

Chen، ۱۹۸۸؛ Askari و Fakher، ۱۹۹۴؛ Sridharan و Prakash، ۲۰۰۰).

سازندهای مارنی در بیشتر نقاط جهان به خصوص در سطح خاورمیانه و ایران گسترش وسیعی دارند. با توجه به جنس سنگ مادر، خاک‌های مارنی از جمله خاک‌های ریزدانه بوده، عمدتاً از رس و سیلت و گاهی تا مقداری ماسه ریز تشکیل شده‌اند. این خاک‌ها عموماً دارای مقادیر مختلفی از املاح، مخصوصاً انواع کربنات‌ها، سولفات‌ها و کلورورها هستند و عمدتاً دارای فرسایش‌پذیری نسبتاً زیاد تا زیاد می‌باشند (Yong و همکاران، ۱۹۹۶؛ Peyrowan و همکاران، ۲۰۰۵؛ Peyrowan و Salmasi، ۲۰۰۹). این خاک‌ها از جمله خاک‌های مسئله‌دار و مشکل‌ساز در مسائل زیست-محیطی و ژئوتکنیکی نیز محسوب می‌شوند (Yong و همکاران، ۱۹۹۶؛ Lamas و همکاران، ۲۰۰۲؛ Ouhadi و Yong، ۲۰۰۳). خاک‌های مارنی به علت گسترش قابل ملاحظه، در برخی نواحی ایران به عنوان پی سازه و یا مصالح ساختمانی نیز مد نظر هستند. در خاک‌های ریزدانه، پارامتر پتانسیل تورم‌پذیری از پارامترهای ضروری در انتخاب مصالح مناسب و طراحی و اجرای سازه به خصوص سازه‌های هیدرولیکی و همچنین از پارامترهای مهم در مطالعات مربوط به فرسایش و رسوب و کنترل آن‌ها می‌باشد (Lamas و همکاران، ۲۰۰۲؛ Peyrowan و همکاران، ۲۰۰۵).

بررسی‌های آزمایشگاهی بهترین روش برای شناسایی دقیق خاک‌های متورم شونده می‌باشند. با توجه به تنوع آزمایش‌ها در تعیین پارامترهای تورمی خاک‌ها، محققان زیادی آزمایش ائدومتری<sup>۱</sup> را با وجود سختی اجرا و زمان بر بودن، سودمندترین و مطمئن‌ترین روش تعیین پارامترهای تورمی خاک‌های متورم شونده می‌دانند (Chen، ۱۹۸۸). اندازه‌گیری پتانسیل تورمی خاک‌های ریزدانه در آزمایشگاه فرایندی زمان‌بر است. نتایج حاصل از این آزمایش‌ها نیز به دلیل فرایند آماده‌سازی نمونه، روش آزمایش، بیشتر با خطا همراه هستند (Chen، ۱۹۸۸؛ ASTM، ۲۰۰۴). به همین دلیل تحقیقات گسترده‌ای در زمینه

<sup>2</sup> Artificial Neural Network

<sup>1</sup> Oedometer test

شیمیایی بر رفتار مهندسی خاک‌ها به خصوص بر رس‌ها، در ارائه مدل‌های تجربی به‌منظور برآورد پارامترهای تورمی خاک، کمتر به پارامترهای شیمیایی خاک توجه شده است.

در این تحقیق، کاربرد شبکه عصبی مصنوعی در برآورد پتانسیل تورمی خاک‌های ماری، با تاکید بر نقش پارامتر هدایت الکتریکی اشباع خاک<sup>۱</sup> (EC) به‌عنوان یک پارامتر شیمیایی سهل‌الوصول بر دقت و کارایی مدل، مورد بررسی قرار می‌گیرد. تفاوت این تحقیق با تحقیقات قبلی در استفاده از پارامتر EC در کنار دیگر پارامترهای متداول و شاخص خاک برای برآورد پارامتر پتانسیل تورم‌پذیری خاک‌های ماری است.

### مواد و روش‌ها

**منطقه مورد پژوهش:** منطقه مورد مطالعه حوضه دریاچه نمک از حوضه‌های مرکزی ایران است. مساحت این حوضه بالغ بر ۹۲۴۶۳ کیلومتر مربع و در محدوده ۵۶° ۳۲' تا ۳۵° ۳۶' عرض جغرافیایی شمالی و ۴۸° تا ۳۱° ۵۲' طول جغرافیایی شرقی قرار می‌گیرد. موقعیت این حوضه در کشور ایران و رخنمون دو سازند ماری قم و قرمز بالایی و همچنین موقعیت محدوده‌های نمونه‌برداری در سطح حوضه، در نقشه شکل ۱ مشاهده می‌شود. سطح رخنمون دو سازند ماری قم و قرمز بالایی در سطح این حوضه از مساحت و شرایط خوبی برخوردار بوده، بیشتر ممبرها و واحدهای این دو سازند در سطح این حوضه مشاهده می‌شوند. شرایط توپوگرافی و پوشش گیاهی در سطح قابل ملاحظه‌ای از دشت‌های این حوضه با شرایط در نظر گرفته شده برای نمونه‌برداری در این تحقیق (شیب کم، بارش کم تا متوسط و پوشش کم) از هم‌خوانی خوبی برخوردار می‌باشد.

در تقسیمات ایالت‌های زمین‌شناسی و پهنه‌های ساختاری-رسوبی، حوضه دریاچه نمک، بخشی از قلمروی ساختاری ایران مرکزی است. مورفولوژی حاکم بر این حوضه شامل مجموعه‌ای از رشته کوه‌ها، تپه ماهورها و دشت‌هایی است که محور آن‌ها تقریباً با

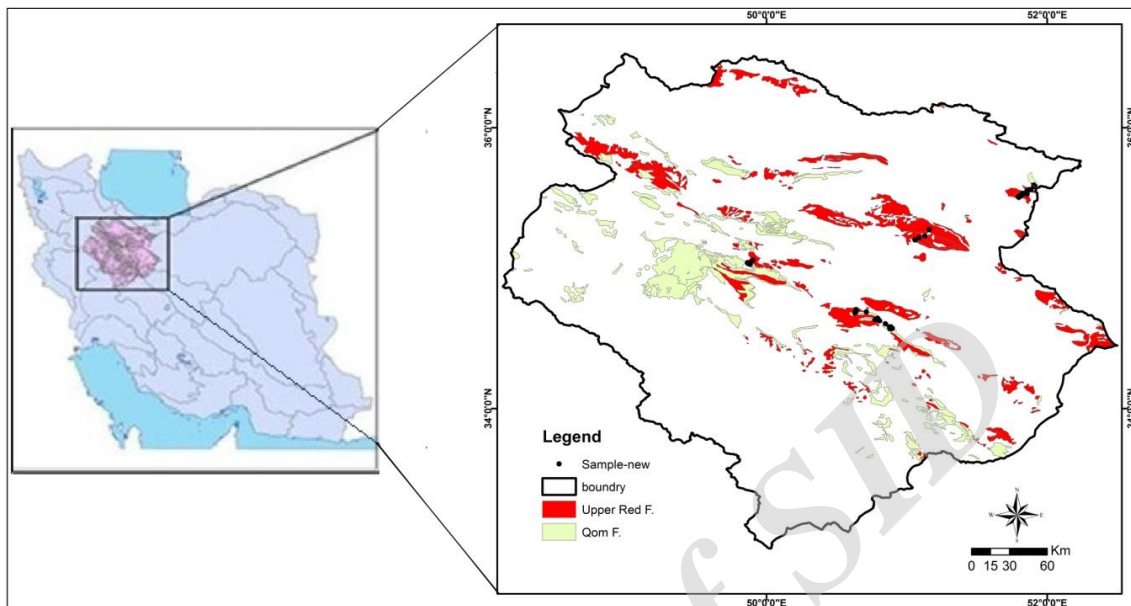
Kaynar, (۲۰۱۱). Komakpanah و همکاران (۲۰۱۰) با استفاده از شبکه عصبی مصنوعی از نوع پرسپترون چند لایه و پارامترهای رطوبت، اندیس خمیری، حد روانی، حد خمیری، دانسیته خشک و درصد ریزدانه خاک، مدل‌های تجربی به‌منظور برآورد پارامترهای تورمی (فشار تورمی و درصد تورم آزاد) ارائه نمودند. این محققان با استفاده از معیارهای متداول آماری اثبات نمودند که شبکه عصبی قابلیت پیش‌بینی رفتار تورمی انواع خاک‌های رسی را دارا می‌باشد، در تحقیقاتی دیگر عملکرد معادلات تجربی که به‌طور گسترده مورد استفاده قرار می‌گیرند با استفاده از یک پایگاه داده متشکل از نتایج به‌دست آمده از آزمون‌های تورم و تحکیم بر روی ۴۲ نمونه، مورد بررسی قرار داده شد. همچنین یک مدل تجربی با استفاده از شبکه عصبی مصنوعی (ANN) از نوع پرسپترون چند لایه پیش‌بینی با دو متغیر ورودی (پارامترهای پیش‌بینی)، یک لایه پنهان و هشت گره یا نرون در لایه پنهان به‌منظور برآورد شاخص تورم نیز ارائه شد. در پژوهش اخیر با ارزیابی و مقایسه‌ای که انجام شد، نتایج نشان دادند که عملکرد ANN در برآورد شاخص تورمی بهتر از معادلات تجربی می‌باشد (Isik, ۲۰۰۹).

تحقیقات انجام شده نشان می‌دهند که پارامترهای تورمی خاک‌ها بیشتر متأثر از پارامترهایی نظیر توزیع اندازه دانه‌ها، حدود آتربرگ و دانسیته هستند. در بیشتر مدل‌های قبلی به‌طور معمول از ویژگی‌هایی مانند دانه‌بندی، حدود آتربرگ، رطوبت، عدد فعالیت خاک و دانسیته اولیه خاک که تمامی آن‌ها یا پارامترهایی فیزیکی و یا وابسته به میزان رطوبت خاک هستند، استفاده شده است. باوجود این موضوع، نتایج بسیاری از تحقیقات نشان دهنده نقش پارامترهای شیمیایی در کنترل ویژگی‌ها و رفتار خاک، مخصوصاً خاک‌های ریزدانه و رس‌ها هستند. پارامترهای شیمیایی مانند مقدار املاح محلول تاثیر مستقیم بر رفتار رس‌ها، قابلیت جذب رطوبت، رمبندگی، تراکم‌پذیری و واگرایی و پدیده سیمان‌شدگی در خاک‌های ریزدانه می‌گذارد (Yukselen-Aksoy و همکاران، ۲۰۰۸؛ Chik و Islam، ۲۰۱۱؛ Majidi و همکاران، ۲۰۱۴). لذا، با توجه به تأثیر پارامترهای

<sup>1</sup> Electrical conductivity

مرکزی از زون‌های بسیار پیچیده و متنوع زمین‌شناسی ایران است.

روندی شمال غربی-جنوب شرقی که روند غالب ساختمانی این زون است، هم‌روند هستند. حدود نیمی از سطح حوضه را دشت‌ها تشکیل می‌دهند. زون ایران



شکل ۱- موقعیت حوضه دریاچه نمک در کشور ایران و رخنمون‌های دو سازند قم و قرمز بالایی و موقعیت نمونه‌ها در سطح حوضه

**متغیرهای ورودی:** به‌منظور تعیین پارامترها یا متغیرهای ورودی، از تجربیات محققان گذشته بهره گرفته شده است. در مرور منابع و بر اساس پیشینه تحقیق مشخص شد که در بیشتر مدل‌های تجربی ارائه شده برای پیش‌بینی پارامترهای تورمی خاک، خواص شاخص مشترکی که بیشتر از خصوصیات و پارامترهای فیزیکی خاک نظیر دانه‌بندی، حدود اتربرگ، تخلخل، رطوبت و دانسیته هستند، استفاده شده است. در این تحقیق در کنار پارامترهای متداول و شاخص خاک از پارامتر شیمیایی هدایت الکتریکی اشباع خاک (EC) نیز به‌عنوان یکی از متغیرهای ورودی برای ایجاد مدل پیش‌بینی پتانسیل تورمی خاک‌های مارنی مورد استفاده قرار گرفته است. پارامتر EC، پارامتری است جامع که نشان دهنده مجموع کاتیون‌ها و آنیون‌های محلول (املاح محلول) در خاک و در عین حال اندازه‌گیری آن نیز نسبتاً سریع و آسان و سهل‌الوصول است. در این پژوهش، تاثیر پارامتر هدایت الکتریکی اشباع خاک به‌عنوان یک ویژگی شیمیایی، بر دقت و کارایی مدل در کنار دیگر

**داده‌های مورد استفاده:** خصوصیات و پارامترهای فیزیکوشیمیایی و مکانیکی مربوط به ۶۰ نمونه خاک ریزدانه مارنی با سازند مادری مارن‌های نئوژن (سازند قم و قرمز بالایی) داده‌های مورد استفاده در این پژوهش است. این نمونه‌ها از سطح حوضه دریاچه نمک (نواحی تهران، قم و ساوه) و به‌صورت دست‌خورده و از عمق ۰/۵ تا یک متری برداشت شده‌اند. در شکل ۱ موقعیت نمونه‌های برداشت شده در سطح حوضه مورد مطالعه، قابل مشاهده است.

کلیه خصوصیات و پارامترهای فیزیکوشیمیایی و مکانیکی نمونه‌ها در آزمایشگاه و بر مبنای دستورالعمل‌های استاندارد ASTM و دستورالعمل‌های نشریه ۴۶۷ سازمان مدیریت و برنامه‌ریزی کشور، اندازه‌گیری شده است. طبقه‌بندی نمونه‌های خاک نیز بر اساس سامانه طبقه‌بندی متحد خاک صورت گرفته است. در این پژوهش، پتانسیل تورمی نمونه‌ها به روش تورم آزاد تک بعدی در اثر جذب آب در طی زمان و بر مبنای نسبت افزایش ارتفاع به ارتفاع اولیه در دستگاه ادنومتر با قالب کوچک و مطابق استاندارد ASTM D-4546 اندازه‌گیری شده است.

تورم‌پذیری نمونه‌ها بر حسب درصد که در آزمایش ادنومتري یک بعدی اندازه‌گیری شده، نشان داده شده است. بر اساس طبقه‌بندی که عسکری و فاخر در کتاب خود آورده‌اند و با توجه به فراوانی مقادیر درصد تورم نمونه‌ها در نمودار شکل ۳، تورم‌پذیری نمونه‌ها در رده زیاد تا متوسط قرار می‌گیرند (Askari و Fakher, ۱۹۹۴).

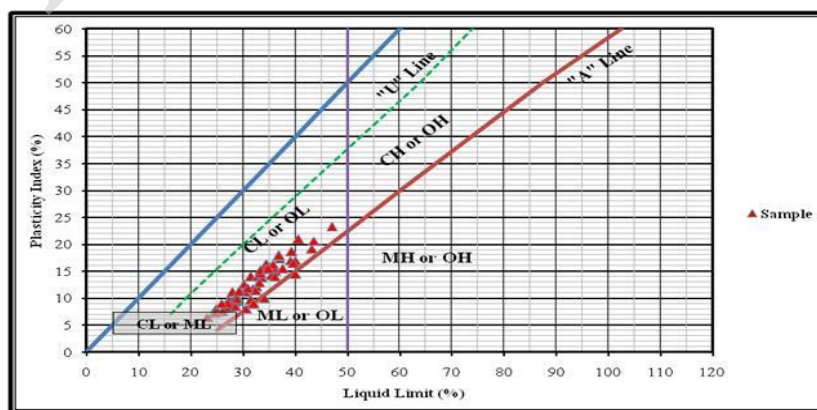
به‌منظور دست‌یابی به مناسب‌ترین پارامترهای ورودی شبکه و همچنین بررسی میزان حساسیت خروجی مدل به هرکدام از پارامترهای ورودی، ۱۹ ترکیب مختلف بر مبنای نتایج مرور منابع و نظر کارشناسی مطابق جدول ۲، از پارامترهای ورودی در گروه‌هایی با چهار تا نه پارامتر از پارامترهای انتخابی، ایجاد شد. به این ترتیب، با توجه به عدم حضور پارامتر EC در بعضی از گروه پارامترهای ورودی مدل‌ها، امکان بررسی تاثیر این پارامتر شیمیایی در ترکیب با دیگر پارامترها، بر دقت و کارایی شبکه فراهم می‌شود.

پارامترهای متداول و فیزیکی، مورد بررسی قرار گرفته است.


در مجموع نه پارامتر، حد روانی (LL)، حد خمیری (PL)، شاخص خمیری (PI)، درصد رس (C)، درصد سیلت (M)، عدد فعالیت (A)، یوکی (e<sub>0</sub>)، دانسیته اولیه (Y<sub>d0</sub>) و هدایت الکتریکی اشباع خاک (EC) به‌عنوان ورودی‌های مدل (متغیرهای پیش‌بینی‌کننده) انتخاب شدند. پارامتر بیشینه درصد تورم (H<sub>s</sub>) هم به‌عنوان متغیر هدف یا خروجی مدل می‌باشد. مشخصات آماری هر یک از پارامترهای ورودی و خروجی شبکه مربوط به داده‌های مورد استفاده (نمونه‌ها) در جدول ۱ ارائه شده است. شکل ۲ موقعیت نمونه‌ها را در نمودار پلاستیسیته (نمودار کاساگراند) نشان می‌دهد. مطابق با سامانه طبقه‌بندی متحد خاک USCS تمام نمونه‌ها در رده خاک‌های ریزدانه رسی با خمیریایی کم و در رده (CL) قرار می‌گیرند. در شکل ۳ نمودار هیستوگرام و فراوانی

جدول ۱- مقادیر ویژگی‌های آماری خصوصیات و پارامترهای اندازه‌گیری شده مورد استفاده به‌عنوان متغیرهای ورودی و خروجی مدل‌ها

EC	e <sub>0</sub>	Y <sub>d0</sub>	A	C	M	PI	LL	PL	H <sub>s</sub>	Statistical features
mS cm <sup>-1</sup>	%	gr cm <sup>-3</sup>		%	%	%	%	%	%	
۰/۶۶۷	۰/۴۳	۱/۶۱	۰/۲۴	۱۶	۳۸	۶/۴۵	۲۳/۱	۱۶/۶	۷/۲۵	Min.
۱۰۲	۰/۷۱	۱/۹۰	۰/۵۴	۵۴	۷۴	۲۳/۲	۴۷	۲۴	۲۴/۴۱	Max.
۱۱/۴۴	۰/۵۵	۱/۷۶	۰/۳۸	۳۴	۵۹	۱۲/۸	۳۲/۳	۱۹/۵	۱۸	Mean
۲۷۵/۱۷	۰/۰۰۳	۰/۰۰۳	۰/۰۰۶	۷۸	۵۶	۱۶	۲۷/۸	۳/۴	۲۲/۰۰	Var.
۱۶/۶	۰/۰۶	۰/۰۶	۰/۰۷۵	۱۱	۹	۴	۵/۳	۱/۸	۴/۷	SD
۴/۵	۰/۳۱	۰/۱۰	-۰/۱۷	۰/۳۶	۰/۳	۰/۴۷	۰/۵۶	۰/۷۳	-۰/۶۶	Skewness
۱۹/۰۵	۰/۴	۰/۲۰	۲۱/۲۳	۰/۸۸	۰/۱۲	-۰/۶۷	-۰/۲۲	-۰/۰۵	-۰/۶۳	Kurtines
۱۵،۷	۰/۵۶	۱/۷۷	۰/۲۳، ۰/۳۸	۳۴، ۲۲	۵۲، ۶۷	۱۵، ۹	۳۳، ۲۹	۲۱، ۱۸	۲۳، ۱۹	Mod



شکل ۲- موقعیت و محدوده نمونه‌ها در نمودار کاساگراند



شکل ۳- نمودار هیستوگرام و فراوانی درصد تورم‌پذیری نمونه‌ها

جدول ۲- ترکیب پارامترهای ورودی شبکه در گروه‌های نوزده‌گانه به‌منظور برآورد پارامتر پتانسیل تورمی خاک‌های مارنی (بر مبنای نظر کارشناسی)

EC	e <sub>o</sub>	Y <sub>do</sub>	C	M	A	PI	LL	PL	
dS m <sup>-1</sup>	%	gr cm <sup>-3</sup>	%	%	%	%	%	%	
X	X	X	X	X	X	X	X	X	Cat-1
X			X	X	X	X	X	X	Cat-2
			X	X		X	X		Cat-3
X			X			X	X		Cat-4
X			X	X	X		X	X	Cat-5
X		X	X	X		X	X		Cat-6
X	X		X	X		X	X		Cat-7
	X	X	X	X		X	X		Cat-8
X			X	X		X	X		Cat-9
	X		X	X	X	X	X		Cat-10
		X	X	X	X	X	X		Cat-11
	X	X	X			X	X		Cat-12
	X		X			X	X		Cat-13
		X	X			X	X		Cat-14
X	X	X	X		X	X	X		Cat-15
X	X		X		X	X	X		Cat-16
	X	X	X	X		X		X	Cat-17
X		X	X		X	X		X	Cat-18
X	X		X	X		X		X	Cat-19

داده‌های دسته دوم کنترل می‌شود تا بیش از حالت بهینه آموزش نبیند. پس از آموزش، شبکه به‌وسیله داده‌های دسته سوم که نقشی در آموزش و کنترل نداشته‌اند، مورد آزمون قرار می‌گیرد (Menhaj).

**پیش‌پردازش داده‌ها:** پارامترهای ورودی به شبکه قبل از ورود به‌صورت تصادفی به سه گروه (آموزش، اعتبارسنجی و آزمون شبکه) تقسیم می‌شوند. شبکه با داده‌های دسته اول آموزش می‌بیند و در عین حال با

مشخص می‌شود. در مرحله تقسیم داده‌ها، سعی شد تا ۷۵ درصد نمونه‌ها از تمام شاخه‌ها در دسته آموزش و ۱۰ و ۱۵ درصد باقی‌مانده به ترتیب در دو دسته اعتبارسنجی و آزمون قرار گیرند.

به منظور یکسان‌سازی دامنه و بی‌بُعد نمودن داده‌های ورودی و هدف، همه داده‌ها با استفاده از رابطه (۱)، استانداردسازی و نرمال شدند. در این رابطه  $X_{nor}$ ،  $X_i$ ،  $X_{min}$ ،  $X_{max}$  به ترتیب مقادیر نرمال شده، مقادیر حقیقی و مقادیر کمینه و بیشینه داده‌ها هستند. با استفاده از این روش استانداردسازی، تمام داده‌ها در بازه  $-1$  تا  $+1$  قرار می‌گیرند. حذف اثر دامنه و حذف بعد داده‌های مورد استفاده در شبکه، باعث افزایش سرعت و دقت در مرحله آموزش و خروجی مدل می‌شود (Menhaj، ۲۰۰۰). در انتها، پس از پایان کار شبکه، خروجی‌های مدل به همان روش، دنرملایز می‌شوند یا به حالت طبیعی برگشته و در اختیار کاربر قرار می‌گیرد.

$$x_{nor} = \frac{2(x_i - x_{min})}{x_{max} - x_{min}} - 1 \quad (1)$$

**شبکه عصبی مصنوعی:** به دلیل عدم شناخت از روابط بین پارامترها و با عنایت به پیچیدگی و غیرخطی بودن برخی روابط در خاک‌ها به خصوص در خاک‌های ریزدانه و با توجه به قابلیت‌های مدل‌های شبکه عصبی مصنوعی در کشف روابط غیرخطی و پیچیده مبتنی بر هوش مصنوعی و آموزش، در این تحقیق تصمیم گرفته شد تا از شبکه عصبی مصنوعی برای ارائه مدل تجربی در پیش‌بینی پتانسیل تورمی خاک‌های ماری استفاده شود. مرور منابع نشان می‌دهد که در بیشتر موارد، محققان برای حل مسائل و پیش‌بینی پارامترهای مربوط به خاک و مسائل ژئوتکنیک از شبکه عصبی پرسپترون چند لایه پیشرو<sup>۵</sup> MLP-FF با الگوریتم آموزش لونیبرگ-مارکوارت LM<sup>۶</sup> و روش پس‌انتشار خطا<sup>۷</sup> BP استفاده کرده‌اند (Isik و Ozden، ۲۰۱۳؛ Shahin و همکاران، ۲۰۰۱). بنابراین، در این پژوهش نیز از شبکه MLP-FF و الگوریتم آموزش LM استفاده شد. با توجه به ماهیت و دامنه

(۲۰۰۰). نتایج بررسی بعضی از محققان نشان می‌دهد که نحوه تقسیم داده‌ها در این سه دسته می‌تواند در کارایی مدل موثر باشد. در حقیقت برای تعمیم‌پذیری<sup>۱</sup> بودن شبکه، داده‌های مورد استفاده در دو دسته آموزش و اعتبارسنجی باید طوری انتخاب شوند که معرف تمام جامعه آماری باشند و مقادیر کمینه و بیشینه در آن‌ها موجود باشد، تا شبکه در حین آموزش همه موارد ممکن را تجربه کرده، در نظر بگیرد. بنابراین، اگر تقسیم داده‌ها بین سه دسته به صورت کاملاً تصادفی انجام شود، ممکن است، به طور مناسب توزیع نشده و مقادیر کمینه یا بیشینه در یک دسته جمع شده و عملکرد شبکه را تحت تأثیر قرار دهند. لذا، بهتر است که داده‌ها به صورت تصادفی و همگن شده وارد دسته‌های ورودی شبکه عصبی شوند (Shahin و همکاران، ۲۰۰۴؛ Isik و Ozden، ۲۰۱۳).

در این پژوهش، به منظور همگن‌سازی داده‌های ورودی و خروجی با هدف افزایش دقت و تعمیم‌پذیری مدل، ابتدا نمونه‌ها (۶۰ نمونه) بر اساس تمام متغیرها یا پارامترهای ورودی و هدف با دو روش سلسله مراتبی<sup>۲</sup> و کی مینز<sup>۳</sup> خوشه‌بندی شده و خوشه‌های ایجاد شده به روش تحلیل ممیزی<sup>۴</sup> صحت‌سنجی و بهینه شدند. در روش خوشه‌بندی سلسله مراتبی برای تشکیل خوشه‌ها، از متد یا روش ارتباط بین گروهی و برای اندازه‌گیری فاصله‌ها، از مجذور فاصله اقلیدوسی استفاده شده است. در این پژوهش تعداد خوشه بهینه به وسیله نمودار دندوگرام حاصل از خوشه‌بندی سلسله مراتبی و بر مبنای تعداد نمونه‌ها و فاصله اقلیدوسی تعیین شده است. سپس در زمان تقسیم داده‌ها، به هر یک از سه گروه (آموزش، اعتبارسنجی و آزمون) اجازه داده شد تا به مقدار سهم خود از هر شاخه به صورت تصادفی داده بردارد. به این ترتیب داده‌ها به صورت تصادفی و نسبتاً همگن توزیع می‌شوند. به این صورت، با مقایسه عملکرد شبکه‌های مختلف ایجاد شده و به روش سعی و خطا بهترین روش خوشه‌بندی و مناسب‌ترین تعداد شاخه در همگن‌سازی داده‌ها و افزایش دقت مدل برای برآورد پتانسیل تورمی خاک،

<sup>1</sup> Generalizability

<sup>2</sup> Hierarchical

<sup>3</sup> K-means

<sup>4</sup> Discriminante

<sup>5</sup> Feed-forward Multi-layer Perceptron

<sup>6</sup> LevenbergMarquart

<sup>7</sup> Back Propagation

بنابراین، در این پژوهش علاوه بر ضریب همبستگی از معیارهای دیگری نظیر میانگین مجموع مربعات خطا<sup>۳</sup> (MSE)، مجذور میانگین مجموع مربعات خطا<sup>۴</sup> (RMSE)، ضریب تعیین<sup>۵</sup> ( $R^2$ )، میانگین انحراف خطا<sup>۶</sup> (MBE)، میانگین نسبی خطای مطلق<sup>۷</sup> (MARE)، خطای نسبی (RE) و ضریب کارایی مدل<sup>۸</sup> (MCE) یا همان ضریب Nash-Sutcliffe هم استفاده شد. روابط مورد نیاز برای محاسبه شاخص‌های فوق در ذیل ارائه شده است (روابط ۲ تا ۸). در این روابط n تعداد نمونه‌ها و  $O_i$ ،  $P_i$  و  $\bar{O}$ ،  $\bar{P}$  به ترتیب مقادیر مشاهده‌ای و پیش‌بینی شده و مقادیر میانگین آن‌ها می‌باشند.

در فرایند ارزیابی، هر چه مقادیر مربوط به معیارهای RE، MSE، RMSE، MBE، MARE به صفر و مقادیر R و  $R^2$  به یک نزدیک‌تر باشند دقت مدل بیشتر و هرچه مقدار MCE مثبت و به یک نزدیک‌تر باشد، کارایی مدل بهتر است. در بین معیارهای فوق مقادیر مثبت MBE نشان دهنده برآورد دست بالا و مقادیر منفی آن نشان دهنده برآورد دست پایین پارامترهای مورد نظر به وسیله مدل است (Farshadfar, ۲۰۰۵).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (۲)$$

$$MSE = \frac{\sum_{i=1}^n (O_i - P_i)^2}{n} \quad (۳)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i) \quad (۴)$$

$$MARE = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - P_i}{O_i} \right| \quad (۵)$$

$$MEC = \frac{\sum_{i=1}^n (O_i - \bar{O})^2 - \sum_{i=1}^n (P_i - \bar{P})^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۶)$$

تغییرات داده‌ها، تابع سیگموئیدی تانژانت هیپربولیک<sup>۱</sup> نیز به‌عنوان تابع تحریک انتخاب شده است.

**ساختار شبکه:** تعیین ساختار بهینه برای شبکه عصبی مصنوعی، مرحله‌ای دشوار و بیشتر مبتنی بر سعی و خطا است (Menhaj, ۲۰۰۰). به‌منظور بررسی و ارزیابی تأثیر ساختارهای مختلف شبکه بر دقت و کارایی مدل و انتخاب بهترین ساختار در برآورد پارامتر هدف، شبکه‌های مختلفی با یک تا سه لایه میانی و هرکدام متشکل از چهار تا ۲۲ نرون ایجاد شد. با توجه به تعداد پارامترهای ورودی و به‌منظور جلوگیری از پیچیدگی مدل، تعداد لایه‌های میانی و نرون‌ها، بیش از این در نظر گرفته نشد. بنابراین، در مجموع ۱۰۰۰ شبکه عصبی مصنوعی با ساختارهای مختلف ایجاد شد. در این شبکه‌ها تعداد نرون‌ها در لایه ورودی و خروجی برابر تعداد متغیرهای ورودی و خروجی مدل است. شبکه‌های عصبی در این مطالعه با استفاده از برنامه‌نویسی در محیط نرم‌افزاری متلب<sup>۲</sup> نسخه ۱۰ ایجاد و اجرا شده است.

هر یک از ۱۹ ترکیب مختلف از نه پارامتر مورد نظر به‌عنوان ورودی‌های شبکه، مطابق جدول ۲، که قبل از مرحله تقسیم به‌وسیله دو روش متداول خوشه‌بندی سلسله مراتبی و کی مینز خوشه‌بندی شده‌اند، با تمام ساختارهای شبکه عصبی ایجاد شده، اجرا شده‌اند. در نامگذاری شبکه یا مدل‌ها از اختصار Hs-iK و Hs-iH که نشان دهنده بهترین مدل برای تخمین پارامتر پتانسیل تورم‌پذیری (Hs) و مربوط به داده‌های ورودی گروه ام (با توجه به جدول ۲) که ورودی‌ها با روش سلسله مراتبی (H) و یا با روش کی مینز (K) خوشه‌بندی (همگن‌سازی) شده‌اند، استفاده شده است.

**معیارهای ارزیابی:** برای ارزیابی مدل‌ها از نظر دقت و کارایی و همچنین مقایسه آن‌ها با یکدیگر معیارهای مختلفی ارائه شده است. ضریب همبستگی بین مقادیر واقعی و برآورد شده به‌وسیله مدل، رایج‌ترین شاخص مقایسه است، با این وجود این شاخص یک معیار کلی است و نمی‌تواند به تنهایی ملاک سنجش مناسبی برای عملکرد مدل در پیش‌بینی یا برآورد قرار گیرد.

<sup>3</sup> Mean Square Error

<sup>4</sup> Root Mean Square Error

<sup>5</sup> Coefficient of determination

<sup>6</sup> Mean Bias Error

<sup>7</sup> Mean Absolute Relative Error

<sup>8</sup> Model Efficiency Coefficient (Nash-Sutcliffe model efficiency coefficient)

<sup>1</sup> Tangsig

<sup>2</sup> Matlab



یک از ترکیب پارامترهای ورودی که با استفاده از یکی از دو روش خوشه‌بندی همگن‌سازی شده‌اند، شبکه بهینه بر اساس کمترین میانگین مجموع مربعات خطا (MSE)، مشخص شد. اطلاعات مربوط به هریک از این شبکه‌های بهینه، نظیر ترکیب پارامترهای ورودی، ساختار شبکه، روش خوشه‌بندی داده‌ها و تعداد خوشه بهینه، در جداول ۴ و ۵ مشاهده می‌شود.

مقادیر معیارهای ارزیابی و کارایی مربوط به مراحل آموزش، اعتبارسنجی و آزمون مدل‌های بهینه، محاسبه و اطلاعات مربوط به مدل‌های بهینه در برآورد پارامتر مورد نظر مربوط به هر یک از گروه پارامترهای ورودی، به ترتیب در جداول ۶ و ۷ آورده شده است. شکل ۵ نمودارهای ستونی تغییرات مقادیر  $R^2$  (a) و RMSE (b) برای مراحل آزمون و آموزش مدل‌های بهینه در برآورد درصد تورم را نشان می‌دهد. در این مرحله برای مشخص نمودن بهترین مدل از بین مدل‌های بهینه، سه معیار  $R^2$ ، RMSE و MCE مربوط به مرحله آزمون و آموزش، در اولویت قرار گرفته‌اند.


$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (7)$$

$$RE = \frac{\sum_{i=1}^n (O_i - P_i)}{O_i} \quad (8)$$

## نتایج و بحث

**نتایج خوشه‌بندی:** ابتدا کلیه نمونه‌ها (۶۰ نمونه) بر اساس تمام متغیرها یا پارامترهای ورودی و هدف، با روش خوشه‌بندی سلسله مراتبی و k-means خوشه‌بندی شده و خوشه‌های ایجاد شده به روش تحلیل ممیزی صحت‌سنجی و بهینه شده‌اند. نتایج خوشه‌بندی به روش سلسله مراتبی در نمودار دندوگرام شکل ۴ مشاهده می‌شود.

**نتایج مدل‌سازی:** مطابق جدول ۲، کلیه ساختارهای شبکه عصبی مصنوعی ایجاد شده، با هر یک از ۱۹ ترکیب مختلف پارامترهای ورودی (پیش‌بین) اجرا شده و مقادیر بیشینه خطا و MSE برای هر یک از این شبکه‌ها محاسبه و ذخیره شده است. در انتها، برای هر



شکل ۴- نمودار داریستی (دندوگرام) خوشه‌بندی سلسله مراتبی نمونه‌ها بر اساس پارامترهای ورودی و خروجی شبکه

جدول ۳- نتایج خوشه‌بندی نمونه‌ها به روش کی‌مینز بر اساس پارامترهای ورودی و خروجی شبکه

Dist.	Clus.	Samp.	Dist.	Clus.	Samp.	Dist.	Clus.	Samp.	Dist.	Clus.	Samp.
۳/۲۴	۲	UVM3-1-a	۸/۶۵	۴	US-2	۱۰/۶۰	۲	QS-1-a	۱۰/۳۰	۴	QV-4
۱۷/۴۲	۲	UVM3-2-a	۵/۴۷	۲	UVM3-1	۷/۴۴	۴	QB-1-a	۱۰/۷۱	۲	QS-1
۲/۲۰	۱	UQM3-3-a	۱۵/۷۱	۲	UVM3-2	۹/۵۳	۳	QB-2-a	۷/۸۷		QB-1
۴/۴۸	۲	UQM2-1-a	۲/۲۰	۱	UQM3-3	۴/۵۷	۳	QC-1-a	۶/۹۵	۴	QB-2
۶/۲۹	۲	UQM2-2-a	۶/۷۱	۲	UQM2-1	۱۱/۰۶	۳	QC-2-a	۹/۴۱	۳	QC-1
۵/۶۴	۲	UQM2-3-a	۴/۰۸	۲	UQM2-2	۷/۸۹	۴	QC-3-a	۱۴/۰۵	۳	QC-2
۱۲/۸۲	۴	UQM2-4-a	۱۱/۴۶	۴	UQM2-3	۱۶/۷۵	۳	QC-4-a	۹/۷۲	۴	QC-3
۷/۵۸	۲	UVM2-5-a	۴/۸۸	۲	UVM2-4	۷/۲۳	۴	QC-5-a	۱۵/۳۳	۴	QC-4
۹/۳۵	۲	UVM2-6-a	۵/۹۰	۲	UVM2-5	۹/۶۰	۳	QE-2-a	۱۰/۴۰	۴	QC-5
۴/۷۷	۲	UVM2-7-a	۷/۷۷	۲	UQM1-1	۷/۶۱	۳	QE-3-a	۸/۶۵	۴	QE-2
۸/۱۶	۲	UQM1-1-a	۵/۵۶	۲	UVM1-2	۶/۹۷	۳	QE-4-a	۳/۴۰	۳	QE-3
۷/۷۷	۲	UQM1-2-a	۱۲/۴۲	۴	UVM1-3	۹/۶۰	۳	QE-5-a	۶/۱۲	۳	QE-4
۷/۲۰	۲	UVM1-3-a	۱۰/۲۰	۴	US-1-a	۷/۱۲	۴	QE-7-a	۵/۵۰	۳	QE-5
۸/۲۱	۲	UVM1-4-a	۹/۹۵	۴	US-2-a	۱۳/۲۸	۴	QE-8-a	۴/۱۱	۴	QE-7
۱۳/۶۱	۲	UVM1-5-a	۱۰/۸۲	۲	US-3-a	۱۱/۲۸	۴	US-1	۸/۰۲	۴	QE-8
									۶/۳۶	۴	QV4-a

۰/۹۳ و ۰/۴۷ مربوط به مرحله آموزش می‌باشد. به این ترتیب، نتایج معیارهای ارزیابی مدل‌های شبکه عصبی نشان داد که استفاده از پارامتر هدایت الکتریکی اشباع خاک به همراه دیگر پارامترهای خاک، باعث افزایش دقت و کارایی مدل شبکه عصبی مصنوعی در پیش‌بینی پتانسیل تورمی خاک‌های ریزدانه مارنی می‌شود.

همچنین نتایج مشخص می‌نماید که خوشه‌بندی به روش کی‌مینز بهتر از روش سلسله مراتبی توانسته با همگن‌سازی داده‌های ورودی و خروجی، کارایی برآورد شبکه را برای پارامتر هدف افزایش دهد. همچنین، دقت مدل‌های ارائه شده با مقایسه مقادیر واقعی و برآورد شده برای پارامتر پتانسیل تورمی خاک مارنی در مرحله آموزش و آزمون داده‌ها نیز تایید شد. خطاهای نسبی با استفاده از رابطه (۸) محاسبه شد. شکل ۶، نمودارهای مقایسه‌ای مربوط به مقادیر مشاهده‌ای و برآوردی به‌وسیله مدل HS-6K را نشان می‌دهد. خطا نسبی به‌طور متوسط برای برآورد پتانسیل تورمی خاک‌های مارنی به‌وسیله این مدل، برابر شش درصد و بیشینه و کمینه خطا ۲۰ و ۰/۱ درصد و مقدار RSME نیز برابر ۱/۷ درصد به‌دست آمد.

بر اساس مقادیر مربوط به این سه معیار و با توجه به جداول ۶ و ۷، بهترین مدل برای پیش‌بینی پارامتر پتانسیل تورمی خاک‌های مارنی منطقه (کمترین RMSE و بیشترین  $R^2$  و MCE)، مربوط به مدل (HS-6K) متعلق به ترکیب پارامترهای گروه ششم (Cat-6) است. در این مدل از پارامترهای حد روانی (LL)، شاخص خمیری (PI)، درصد سیلت (M)، درصد رس (C)، دانسیته خشک اولیه ( $Y_{d0}$ ) و هدایت الکتریکی یا شوری خاک (EC) برای برآورد پتانسیل تورمی استفاده شده است. در این مدل، ورودی‌ها با روش کی‌مینز برای همگن‌سازی به چهار دسته، خوشه‌بندی شده‌اند. ساختار شبکه مربوط به این مدل دارای دو لایه میانی است که تعداد نرون‌های لایه اول آن چهار و لایه دوم آن ۱۶ عدد است. مطابق با جدول ۷، مقادیر  $R^2$ ، RMSE، MCE و MARE (معیارهای ارزیابی) مربوط به مدل (HS-6K)، به‌ترتیب برابر ۰/۹۲، ۰/۱۷، ۰/۹۱ و ۰/۱۱ برای مرحله آزمون و ۰/۹۲، ۰/۳۵، ۰/۹۲ و ۰/۴۸ مربوط به مرحله آموزش می‌باشد. بهترین مدل با پارامترهای فیزیکی بدون حضور پارامتر EC، مربوط به مدل (Hs-11k) است که مقادیر معیارهای فوق‌الذکر نیز برای آن مطابق با جدول ۷ به‌ترتیب برابر ۰/۸۹، ۰/۲۳، ۰/۸۴ و ۰/۱۵ مربوط به مرحله آزمون و ۰/۹۴، ۰/۲۵،

**جدول ۴- مشخصات بهترین شبکه‌ها مربوط به هر یک از گروه متغیرهای ورودی در برآورد درصد تورم، به همراه تعداد خوشه بهینه (روش همگن‌سازی داده‌ها، خوشه‌بندی سلسله مراتبی)**

Model	Input Parameter Group	Optimum Structural Network				Optimum clusters (Hierarchical method)
		No. of mid. Layers	No. of neurons			
			Layer 1	Layer 2	Layer 3	
Hs-1H	Cat_1	۲	۱۰	۴	۶	۲
Hs-2H	Cat_2	۳	۱۴	۴	۴	۳
Hs-3H	Cat_3	۳	۱۰	۱۲	۶	۴
Hs-4H	Cat_4	۳	۱۶	۱۲	۶	۳
Hs-5H	Cat_5	۲	۶	۱۴	۰	۳
Hs-6H	Cat_6	۳	۱۴	۱۲	۸	۲
Hs-7H	Cat_7	۳	۸	۱۰	۶	۴
Hs-8H	Cat_8	۳	۱۶	۶	۸	۴
Hs-9H	Cat_9	۲	۱۲	۱۲	۰	۳
Hs-10H	Cat_10	۳	۱۰	۴	۸	۴
Hs-11H	Cat_11	۲	۴	۱۶	۰	۲
Hs-12H	Cat_12	۱	۱۲	۰	۰	۴
Hs-13H	Cat_13	۲	۴	۸	۰	۴
Hs-14H	Cat_14	۲	۶	۶	۰	۲
Hs-15H	Cat_15	۳	۱۴	۶	۸	۴
Hs-16H	Cat_16	۳	۸	۸	۶	۴
Hs-17H	Cat_17	۲	۱۰	۴	۰	۳
Hs-18H	Cat_18	۲	۸	۸	۰	۳
Hs-19H	Cat_19	۲	۱۶	۲۰	۰	۴

**جدول ۵- مشخصات بهترین شبکه‌ها مربوط به هر یک از گروه متغیرهای ورودی در برآورد درصد تورم، به همراه تعداد خوشه بهینه (روش همگن‌سازی داده‌ها، خوشه‌بندی کی مینز)**

Model	Input Parameter Group	Optimum Structural Network				Optimum clusters (k-means method)
		No. of mid. Layers	No. of neurons			
			Layer 1	Layer 2	Layer 3	
Hs-1k	Cat_1	۲	۱۰	۴	۴	۲
Hs-2k	Cat_2	۳	۸	۶	۱۴	۲
Hs-3k	Cat_3	۳	۱۰	۶	۱۴	۲
Hs-4k	Cat_4	۲	۸	۸	۰	۲
Hs-5k	Cat_5	۲	۶	۱۲	۰	۲
Hs-6k	Cat_6	۲	۴	۱۶	۰	۴
Hs-7k	Cat_7	۳	۸	۱۴	۱۲	۲
Hs-8k	Cat_8	۳	۱۶	۱۴	۱۰	۳
Hs-9k	Cat_9	۳	۱۶	۱۰	۶	۲
Hs-10k	Cat_10	۲	۶	۱۸	۰	۴
Hs-11k	Cat_11	۳	۱۶	۱۰	۱۴	۳
Hs-12k	Cat_12	۳	۱۶	۶	۱۰	۳
Hs-13k	Cat_13	۲	۱۲	۱۴	۰	۳
Hs-14k	Cat_14	۳	۱۲	۱۲	۱۲	۲
Hs-15k	Cat_15	۳	۱۶	۶	۱۲	۳
Hs-16k	Cat_16	۳	۱۴	۸	۰	۳
Hs-17k	Cat_17	۲	۱۰	۴	۰	۲
Hs-18k	Cat_18	۲	۱۲	۸	۰	۴
Hs-19k	Cat_19	۲	۱۰	۸	۱۲	۲

جدول ۶- معیارهای ارزیابی و کارایی بهترین شبکه‌ها مربوط به هر یک از گروه متغیرهای ورودی در برآورد درصد تورم (روش همگن‌سازی داده‌ها، خوشه‌بندی سلسله مراتبی)


MEC	MARE			MBE			R <sup>2</sup>			R			RMSE			Input Group	Model		
	T	V	L	T	V	L	T	V	L	T	V	L	T	V	L				
۰/۲۳	-۰/۲۶	۰/۹۵	۰/۲۲	۰/۳۷	۰/۰۳	-۰/۹۴	-۲/۷۲	۰/۲۳	۰/۴۶	۰/۰۹	۰/۹۵	۰/۶۸	۰/۳۱	۰/۹۸	۳/۹۵	۶/۰۱	۱/۰۵	Cat_1	HS-1H
-۰/۹۵	-۱/۸۶	۰/۸۴	۰/۵۷	۰/۴۶	۰/۰۷	-۱/۹۰	۲/۱۳	۰/۵۰	۰/۱۱	-۰/۰۱	۰/۸۸	-۰/۳۳	۰/۰۸	۰/۹۴	۸/۰۹	۸/۱۴	۱/۷۹	Cat_2	Hs-2H
-۰/۲۰	-۴/۵۸	۰/۹۱	۰/۱۸	۰/۷۱	۰/۰۴	-۰/۱۸	-۱/۱۳	۰/۴۴	۰/۷۵	۰/۰۱	۰/۹۲	۰/۸۷	-۰/۱۱	۰/۹۶	۳/۸۱	۱۰/۶۶	۱/۴۳	Cat_3	Hs-3H
-۰/۳۶	-۲/۴۳	۰/۷۹	۰/۴۸	۰/۵۲	۰/۰۷	-۴/۲۷	۰/۲۷	-۰/۳۲	۰/۳۶	۰/۱۵	۰/۸۰	۰/۵۱	۰/۳۹	۰/۹۰	۶/۷۶	۸/۹۲	۲/۰۹	Cat_4	Hs-4H
-۰/۲۳	-۱/۲۷	۰/۸۰	۰/۴۸	۰/۴۳	۰/۰۹	-۴/۱۵	-۳/۱۳	-۰/۷۵	۰/۲۳	۰/۲۸	۰/۸۴	۰/۴۸	-۰/۵۳	۰/۹۱	۶/۶۷	۷/۲۵	۱/۰۳	Cat_5	Hs-5H
۰/۱۸	-۱/۳۲	۰/۹۱	۰/۲۲	۰/۳۲	۰/۰۶۴	-۲/۴۹	۱/۴۹	۰/۰۱	۰/۴۸	۰/۱۱	۰/۹۱	۰/۷۰	۰/۳۲	۰/۹۵	۴/۰۸	۸/۱۴	۱/۴۲	Cal_6	Hs-6 H
-۰/۷۶	-۰/۹۵	۰/۸۷	۰/۲۱	۰/۳۷	۰/۰۷	۲/۳۲	۱/۸۵	۰/۱۹	۰/۱۴	۰/۰۴	۰/۸۷	۰/۳۸	-۰/۲۰	۰/۹۳	۵/۶۴	۶/۳۰	۱/۷۸	Cat_7	Hs-7 H
۰/۵۵	-۰/۸۲۶	۰/۹۱	۰/۱۴	۰/۳۵	۰/۰۴	-۱/۴۸	-۳/۰۷	-۰/۱۷	۰/۶۷	۰/۱۸	۰/۹۲	۰/۸۲	۰/۴۳	۰/۹۶	۳/۰۱	۵/۹۹	۱/۴۱	Cat_8	Hs-8 H
-۰/۰۲	-۰/۸۷	۰/۷۶	۰/۴۲	۰/۳۸	۰/۱۱	-۳/۲۹	۰/۸۱	۰/۲۴	۰/۳۰	۰/۰۰	۰/۷۶	۰/۵۵	-۰/۰۵	۰/۸۷	۵/۸۵	۶/۵۸	۱/۲۳	Cat_9	Hs-9 H
-۵/۲۳	-۴/۵۸	۰/۹۴	۰/۴۸	۰/۷۱	۰/۰۵	-۵/۴۵	-۱/۱۳	-۰/۱۵	۰/۴۷	۰/۰۱	۰/۹۴	۰/۶۹	۰/۱۱	۰/۹۷	۱۰/۶۲	۱۰/۶۶	۱/۲۰	Cat_10	Hs-10 H
۰/۳۵	۰/۲۵	۰/۹۵	۰/۲۱	۰/۳۰	۰/۰۴	۰/۵۲	-۰/۸۲	۰/۰۱	۰/۶۴	۰/۵۳	۰/۹۵	۰/۸۰	۰/۷۳	۰/۹۸	۳/۶۱	۶/۶۳	۱/۰۳	Cat_11	Hs-11 H
۰/۲۹	۰/۷۹	۰/۸۷	۰/۱۵	۰/۴۰	۰/۷۰	۱/۶۴	-۱/۹۵	۰/۱۸	۰/۷۵	۰/۰۲	۰/۸۷	۰/۸۶	-۰/۱۳	۰/۹۳	۳/۵۸	۶/۰۳	۱/۷۴	Cat_12	Hs-12 H
۰/۰۱	-۱/۶۴	۰/۹۳	۰/۲۱	۰/۴۶	۰/۰۳	۲/۴۳	۰/۱۵	-۰/۰۶	۰/۷۸	۰/۰۲	۰/۹۳	۰/۸۸	۰/۱۴	۰/۹۷	۴/۲۲	۷/۳۳	۱/۲۵	Cat_13	Hs-13 H
۰/۳۱	-۰/۱۱	۰/۸۸	۰/۳۰	۰/۳۳	۰/۰۶	-۱/۲۷	-۴/۱۳	-۰/۱۴	۰/۴۹	۰/۶۸	۰/۹۱	۰/۷۰	۰/۸۳	۰/۹۶	۳/۷۶	۵/۰۲	۱/۶۴	Cat_14	Hs-14 H
-۱/۱۵	-۲/۰۵	۰/۹۱	۰/۳۹	۰/۵۲	۰/۰۴	-۰/۹۳	-۳/۴۵	-۰/۳۵	۰/۴۲	۰/۰۸	۰/۹۳	۰/۶۵	۰/۲۸	۰/۹۶	۶/۲۳	۷/۸۸	۱/۴۱	Cat_15	Hs-15 H
-۰/۷۳	-۰/۸۳	۰/۹۵	۰/۲۶	۰/۳۸	۰/۰۳	۴/۴۸	-۱/۸۴	-۰/۰۹	۰/۶۰	۰/۰۴	۰/۹۵	۰/۷۷	۰/۲۰	۰/۹۸	۵/۵۸	۶/۱۱	۱/۰۴	Cat_16	Hs-16 H
۰/۵۴	-۰/۲۰	۰/۸۷	۰/۱۵	۰/۳۴	۰/۰۴	۰/۸۶	-۳/۳۵	۰/۲۳	۰/۵۹	۰/۴۷	۰/۸۸	۰/۷۷	۰/۶۹	۰/۹۴	۳/۰۸	۵/۲۲	۱/۷۱	Cat_17	Hs-17H
۰/۳۳	۰/۳۶	۰/۹۳	۰/۱۷	۰/۲۵	۰/۰۶	۰/۵۲	-۲/۲۲	۰/۱۵	۰/۵۶	۰/۶۳	۰/۹۳	۰/۷۵	۰/۷۹	۰/۹۶	۳/۷۱	۳/۷۸	۱/۲۸	Cat_18	Hs-18 H
۰/۲۱	-۰/۶۷	۰/۹۱	۰/۱۵	۰/۲۸	۰/۰۴	۲/۵۲	۰/۶۱	۰/۴۴	۰/۶۶	۰/۰۰	۰/۹۲	۰/۸۱	۰/۰۱	۰/۹۶	۳/۷۸	۵/۸۴	۱/۴۳	Cat_19	Hs-19 H

T = test; V = validate; L = learning

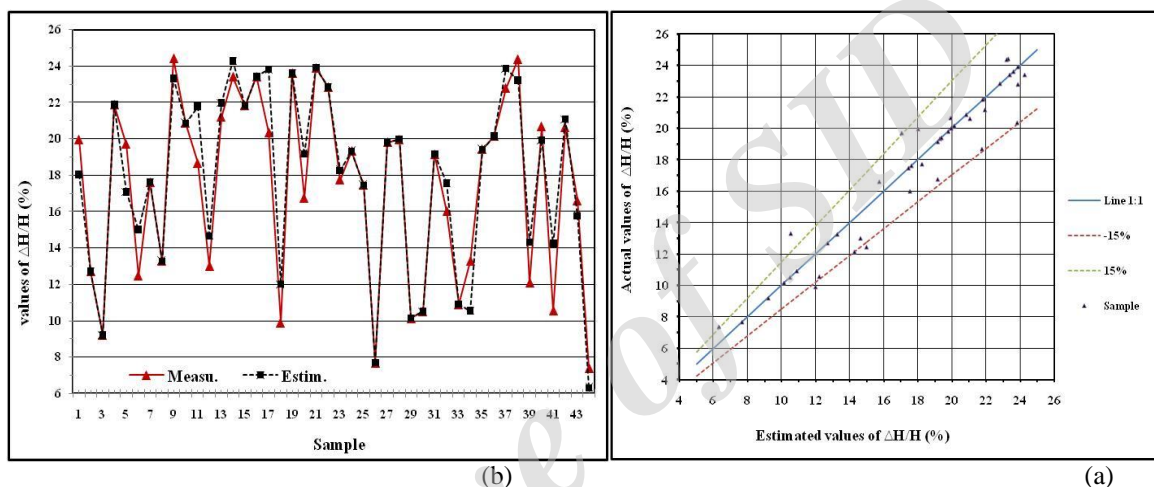
جدول ۷- معیارهای ارزیابی و کارایی بهترین شبکه‌ها مربوط به هر یک از گروه متغیرهای ورودی در برآورد درصد تورم (روش همگن‌سازی داده‌ها، خوشه‌بندی کی مینز)

Model	Input Group	RMSE			R			R <sup>2</sup>			MBE			MARE			MEC		
		T	V	L	T	V	L	T	V	L	T	V	L	T	V	L	T	V	
Hs-1K	Cat_1	۳/۹۶	۶/۰۱	۱/۰۵	۰/۹۸	۰/۳۱	۰/۶۸	۰/۹۵	۰/۰۹	۰/۴۶	۰/۲۳	-۲/۷۲	-۰/۹۴	۰/۰۳	۰/۳۷	۰/۲۲	۰/۹۵	-۰/۲۶	۰/۲۳
Hs-2K	Cat_2	۷/۱۱	۶/۲۸	۱/۸۲	۰/۹۲	-۰/۲۲	۰/۸۴	۰/۱۰	۰/۰۵	۰/۱۰	-۰/۳۵	-۰/۲۱	-۳/۱۹	۰/۰۸	۰/۳۲	۰/۴۴	۰/۸۳	-۰/۷۶	-۰/۶۵
Hs-3K	Cat_3	۵/۹۸	۶/۸۲	۱/۵۱	۰/۹۴	۰/۰۴	۰/۵۹	۰/۰۰	۰/۸۹	۰/۳۵	-۰/۰۱	-۰/۱۱	-۳/۵۹	۰/۰۷	۰/۳۶	۰/۴۲	۰/۸۸	-۱/۰۶	-۰/۱۶
Hs-4K	Cat_4	۴/۰۱	۴/۸۴	۲/۴۱	۰/۹۰	۰/۶۲	۰/۳۴	۰/۸۱	۰/۳۸	۰/۱۱	۱/۰۰	-۰/۹۷	-۲/۲۵	۰/۱۲	۰/۲۳	۰/۲۱	۰/۷۶	۰/۱۸	-۰/۶۵
Hs-5K	Cat_5	۳/۵۳	۳/۴۴	۱/۲۸	۰/۹۶	۰/۷۳	۰/۸۰	۰/۹۲	۰/۵۴	۰/۶۵	۰/۰۳	۱/۰۰	-۱/۳۶	۰/۵۳	۰/۱۴	۰/۲۶	۰/۹۲	۰/۴۷	۰/۵۹
Hs-6K	Cal_6	۱/۷۴	۱۰/۴۴	۱/۳۷	۰/۹۶	-۰/۱۷	۰/۹۶	۰/۹۲	۰/۰۳	۰/۹۲	-۰/۳۲	۴/۲۰	-۰/۴۲	۰/۴۸	۰/۳۵	۰/۱۱	۰/۹۲	-۲۸/۲۸	۰/۹۱
Hs-7K	Cat_7	۳/۴۸	۳/۷۷	۱/۵۱	۰/۹۶	۰/۷۸	۰/۴۰	۰/۹۱	۰/۶۰	۰/۱۶	۰/۳۹	-۱/۰۴	۱/۱۸	۰/۴۳	۰/۲۰	۰/۱۵	۰/۹۱	۰/۵۰	-۰/۲۵
Hs-8K	Cat_8	۶/۲۹	۶/۰۲	۱/۶۱	۰/۹۴	-۰/۲۱	۰/۴۸	۰/۲۳	۰/۰۵	۰/۸۹	۰/۱۴	-۰/۷۱	-۳/۱۷	۰/۰۴	۰/۲۴	۰/۴۵	۰/۸۹	-۸/۷۱	-۰/۱۶
Hs-9K	Cat_9	۶/۹۰	۷/۹۹	۱/۵۳	۰/۹۵	-۰/۲۹	۰/۱۳	۰/۹۰	۰/۰۹	۰/۰۲	۰/۵۷	۱/۴۸	-۱/۷۴	۰/۰۶	۰/۴۰	۰/۴۸	۰/۸۸	-۱/۸۴	-۰/۵۵
Hs-10K	Cat_10	۳/۶۲	۶/۱۳	۱/۶۰	۰/۹۵	۰/۱۰	۰/۷۴	۰/۹۱	۰/۰۱	۰/۵۵	-۰/۰۸	۱/۴۴	۱/۹۷	۰/۰۵	۰/۳۴	۰/۱۹	۰/۹۱	-۱/۳۶	-۰/۱۲
Hs-11K	Cat_11	۲/۳۲	۷/۸۹	۱/۲۵	۰/۹۷	-۰/۰۵	۰/۹۴	۰/۹۴	۰/۰۰	۰/۸۹	-۰/۲۴	۴/۴۷	-۰/۳۳	۰/۰۶	۰/۲۸	۰/۱۵	۰/۹۳	-۱۵/۷۰	۰/۸۴
Hs-12K	Cat_12	۴/۳۰	۴/۶۵	۱/۵۴	۰/۹۵	۰/۶۲	۰/۴۷	۰/۹۱	۰/۳۸	۰/۲۲	۰/۳۲	-۱/۸۴	-۲/۴۷	۰/۰۶	۰/۲۵	۰/۲۱	۰/۹۰	۰/۲۴	-۰/۹۰
Hs-13K	Cat_13	۳/۲۹	۵/۶۶	۱/۵۶	۰/۹۵	-۰/۳۷	۰/۸۳	۰/۹۰	۰/۱۴	۰/۶۹	-۰/۱۵	۱/۱۲	۰/۳۴	۰/۰۶	۰/۱۸	۰/۱۸	۰/۸۹	-۷/۵۸	۰/۶۸
Hs-14K	Cat_14	۴/۴۲	۵/۱۶	۱/۶۳	۰/۹۳	۰/۱۲	۰/۸۵	۰/۸۷	۰/۰۱	۰/۷۱	۰/۰۱	-۰/۱۴	-۰/۰۱	۰/۰۶	۰/۲۶	۰/۳۰	۰/۸۶	-۰/۱۵	۰/۳۶
Hs-15K	Cat_15	۴/۷۴	۵/۹۹	۱/۴۳	۰/۹۶	۰/۵۰	۰/۵۵	۰/۹۲	۰/۲۵	۰/۳۰	-۰/۱۳	۲/۸۹	-۱/۷۹	۰/۰۵	۰/۲۴	۰/۲۲	۰/۹۱	-۱/۸۷	۰/۳۰
Hs-16K	Cat_16	۳/۵۵	۶/۰۴	۱/۷۵	۰/۹۳	-۰/۱۰	۰/۵۵	۰/۸۷	۰/۰۱	۰/۳۰	۰/۰۹	۲/۴۹	-۰/۷۴	۰/۰۶	۰/۲۴	۰/۱۹	۰/۸۶	-۱/۹۲	۰/۲۷
Hs-17K	Cat_17	۲/۸۳	۳/۳۸	۱/۸۲	۰/۹۲	۰/۸۸	۰/۹۰	۰/۸۴	۰/۸۷	۰/۸۰	۰/۳۹	۱/۰۴	-۱/۱۲	۰/۰۸	۰/۱۸	۰/۰۸	۰/۸۳	۰/۵۰	۰/۷۴
Hs-18K	Cat_18	۵/۰۱	۶/۸۴	۱/۴۹	۰/۹۶	-۰/۴۱	۰/۴۲	۰/۹۲	۰/۱۷	۰/۱۸	۰/۱۷	۳/۷۳	۰/۱۹	۰/۰۵	۰/۲۴	۰/۲۶	۰/۹۱	۰/۸۱	۰/۵۳
Hs-19K	Cat_19	۵/۴۶	۷/۹۴	۱/۴۵	۰/۹۵	-۰/۲۸	۰/۵۸	۰/۹۰	۰/۰۸	۰/۳۴	-۰/۳۵	۱/۹۵	۰/۸۶	۰/۰۶	۰/۳۷	۰/۳۹	۰/۸۹	-۱/۷۴	۰/۰۳

T = test; V = validate; L = learning



شکل ۵- نمودار ستونی تغییرات مقادیر الف)  $R^2$  و ب) RMSE برای مراحل آزمون و آموزش مدل‌های بهینه در برآورد درصد تورم



شکل ۶- نمودارهای، (a) مقادیر اندازه‌گیری شده در مقابل مقادیر برآوردی، (b) تغییرات و اختلاف مقادیر اندازه‌گیری شده و مقادیر برآوردی درصد تورم خاک به‌وسیله مدل عصبی (Hs-6K)

### نتیجه‌گیری

نتایج نشان می‌دهد که مناسب‌ترین پارامترها برای پیش‌بینی پارامتر پتانسیل تورمی خاک مارنی، پارامترهای، حدود اتربرگ (حد روانی و شاخص خمیری)، دانه‌بندی (درصد رس و سیلت خاک)، دانسیته خشک اولیه و هدایت الکتریکی اشباع خاک EC می‌باشند. در این پژوهش EC به‌عنوان یک متغیر ورودی از نوع پارامتر شیمیایی، برای اولین بار در برآورد پارامتر پتانسیل تورمی خاک مارنی در ایران مورد استفاده قرار گرفته است.

نتایج معیارهای ارزیابی مدل‌ها نشان داد که استفاده از پارامتر هدایت الکتریکی اشباع خاک EC به همراه دیگر پارامترهای فیزیکی، باعث افزایش دقت و کارایی مدل شبکه عصبی مصنوعی در پیش‌بینی پتانسیل تورمی خاک‌های ریزدانه مارنی می‌شود.

ساختار بهینه شبکه‌های ANN در برآورد پتانسیل تورمی خاک، پیچیدگی روابط بین پارامترهای ورودی و پتانسیل تورمی را مشخص می‌سازد. علاوه بر مقادیر معیارهای ارزیابی مدل، تعداد لایه‌های میانی و نرون‌های هر لایه در مقایسه دو مدل (Hs-6k) و (Hs-11k) مشخص می‌نماید که قرارگیری پارامتر EC در کنار دیگر پارامترهای شاخص و فیزیکی، سبب کاهش پیچیدگی روابط بین این پارامترها با پتانسیل تورمی خاک‌های مارنی شده که این خود یکی از دلایلی می‌باشد که می‌توان برای نقش EC در افزایش دقت و کارایی مدل ارائه نمود.

همچنین، نتایج مشخص نمود که همگن‌سازی داده‌ها با استفاده از خوشه‌بندی آن‌ها به روش کی‌مینز بهتر از روش سلسله مراتبی توانسته با

می‌تواند برآورد مناسبی را قبل از انجام آزمایش‌ها و یا ارائه نتایج آن‌ها فراهم آورد.

### تشکر و قدردانی

نویسندگان از پژوهشکده حفاظت خاک و آبخیزداری به لحاظ حمایت مالی و مساعدت در انجام آزمایشات و نمونه‌برداری صحرائی، تشکر و قدردانی می‌نمایند.

افزایش قدرت تعمیم‌دهی مدل، دقت و کارایی برآورد شبکه را برای پارامتر هدف، افزایش دهد.

مدل پیشنهادی می‌تواند برای خاک‌های مارنی یا ریزدانه که داده‌های ورودی آن‌ها در محدوده جدول ۱ قرار دارند و پارامتر پتانسیل تورمی آن‌ها با روش ادئومتری یک بعدی اندازه‌گیری شده‌اند، مورد استفاده قرار گیرند. این مدل را می‌توان برای ارزیابی مراحل مقدماتی مطالعات و طراحی و انجام مطالعات امکان‌سنجی استفاده نمود. در حقیقت این مدل

### منابع مورد استفاده

1. ASTM International. 2004. Annual book of ASTM standards, construction-standard test method for soils and rocks. Section 04, Volume 04.08 and 04.09, West Conshohocken, United States.
2. Ashayeri, I. and S. Yasrebi. 2009. Free-swell and swelling pressure of unsaturated compacted clays, experiments and neural networks. *Geotechnical and Geological Engineering*, 27(1): 137-153.
3. Askari, F. and A. Fakher. 1994. Swelling and dispersion of soils in geotechnical engineering. Published by Institute of the Jihade Daneshgahi (MAJED), Tehran, 245 pages (in Persian).
4. Chen, F.H. 1988. Foundation on expansive soils. Elsevier, New York, 463 pages.
5. Chik, Z. and T. Islam. 2011. Study of chemical effects on soil compaction characterizations through electrical conductivity. *International Journal of Electrochemical Science*, 6: 6733-6740.
6. Farshadfar, A. 2005. Advanced principles and methods of statistic. Razi University of Kermanshah Press, 124 pages (in Persian).
7. Isik, F. and G. Ozden. 2013. Estimating compaction parameters of fine and coarse-grained soils by means of artificial neural networks. *Environmental Earth Sciences*, 69: 2287-2297.
8. Isik, N.S. 2009. Estimation of swell index of fine grained soils using regression equations and artificial neural networks. *Scientific Research and Essay*, 4(10): 1047-1056.
9. Komakpanah, H., S.S.H. Yasrebi and A. Gulshan. 2010. Application of artificial neural network in predicting the behavior of swelling clay soils. The 4th International Conference on Soil Mechanics and Geotechnical Engineering, Tehran, IRAN (in Persian).
10. Lamas, F., C. Irigaray and J. Chacón. 2002. Geotechnical characterization of carbonate marls for the construction of impermeable dam cores. *Engineering Geology Journal*, 66: 283-294.
11. Majidi, A., G. Lashgaripour, Z. Shoaie, M. Noruzi nashlaji and Y. Firouzei. 2014. Estimating compaction parameters of marl soils using multi-layer perceptron neural networks. *Journal of the Balkan Tribological Association*, 20(2): 170-198.
12. Menhaj, M. 2000. Fundamentals of neural networks. Amir Kabir University Press, 715 pages (in Persian).
13. Ouhadi, V.R. and R.N. Yong. 2003. The role of clay fractions of marly soils on their post stabilization failure. *Engineering Geology Journal*, 70: 365-375.
14. Peyrowan, H., A. Jafariardakani, J. Ghayomyan and M. Sharijafari. 2005. Improvement and stabilization of marl deposits to control erosion and runoff. The 4th Iranian Conference of Engineering Geology and Environment, Tehran, Tarbiat Modarres University (in Persian).
15. Planning and Strategic Supervision President. 2008. Guidelines for laboratory analysis of soil samples and water. Publication No. 467: 255 (in Persian).
16. Salmasi, R. and H. Peyrowan. 2009. Investigate the relationship between the physical and chemical characteristics of sensitive marl in the Talkherod River basin with various forms of erosion. The 6th Iranian Conference of Engineering Geology and Environment, Tarbiat Modarres University (in Persian).
17. Seed, H.B., R.J. Woodward and R. Lundgren. 1962. Prediction of swelling potential for compacted clays. *Journal of the Soil Mechanics and Foundation Division, ASCE*, 88(6): 107-131.
18. Shahin, M.A., M.B. Jaksa and H.R. Maier. 2001. Artificial neural network applications in geotechnical engineering. *Australian Geomechanics*, 36(1): 49-62.
19. Shahin, M.A., H.R. Maier and M.B. Jaksa. 2004. Data division for developing neural networks applied to geotechnical engineering. *Journal Computing in Civil Engineering*, 18(2): 105-114.

20. Snethen, D.R. 1984. Evaluation of expedient methods for identification and classification of potentially expansive soils. In: Proceedings of Fifth International Conference on Expansive Soils, Institution of Engineers, Adelaide: 22–26.
21. Sridharan, A. and K. Prakash. 2000. Classification procedures for expansive soils. Proceedings of the Institution of Civil Engineers-Geotechnical Engineering, 143(4): 235-240.
22. Yilmaz, I. 2006. Indirect estimation of the swelling percent and a new classification of soils depending on liquid limit and cation exchange capacity. Engineering Geology Journal, 85(3-4): 295–301.
23. Yilmaz, I. and O. Kaynar. 2011. Multiple regressions, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. Expert Systems with Applications, 38: 5958–5966.
24. Yong, R.N., V.R. Ouhadi and A.M.O. Mohamed. 1996. Physicochemical evaluation of failure of stabilized marl soil. The 49th Canadian Geotechnical Conference Frontiers in Geotechnology, 2: 769–776.
25. Yukselen-Aksoy, Y., A. Kaya and A.H. Ören. 2008. Seawater effect on consistency limits and compressibility characteristics of clays. Engineering Geology Journal, 102(1-2): 54-61.

Archive of SID



## Prediction of swelling potential of marl soils of Salt Lake watershed basin

Alireza Majidi<sup>1</sup>, Gholamreza Lashkaripour<sup>\*2</sup> and Ziaoddin Shoaie<sup>3</sup>

<sup>1</sup> PhD Student, Faculty of Science, Ferdowsi University of Mashhad, Iran <sup>2</sup> Professor, Faculty of Science, Ferdowsi University of Mashhad, Iran and <sup>3</sup> Associate Professor, Soil Conservation and Watershed Management Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

Received: 05 November 2015

Accepted: 07 February 2016

### Abstract

The swelling potential of fine-grained soils is one of effective parameters on soil mechanical behavior and erosion and fundamental data required for the design, construction and choosing construction materials. This paper presents a multi-layer perceptron (MLP) artificial neural network (ANN) model to prediction of the swelling potential of marl soils. Marl soil is a fine-grained soil. The Levenberg-Marquadt learning algorithm was used to train the networks. Existing models prediction of soil swelling potential based on physical and soil index parameters. The present study considers the effects of chemical factors on the behavior and characteristics of fine-grained soils along with the common soil index parameters. The model used physicochemical and mechanical test results from 60 marl soil samples taken from marl formations in the Neogene basin in central Iran (Tehran, Qom and Saveh regions). The models were designed to use different input data sets and structures to determine which soil properties and ANN structures correlate well with the swelling potential parameter. Electrical conductivity (EC) of saturated soil was a new input parameter used in addition to the physical and soil index parameters that include the atterberg limit, activity, content of the clay and silt, initial of porosity ratio and dry density. Values of RMSE, R2 and MCE (evaluation criteria) related to the best model with the physical parameters LL, PI, A, M, C and  $Y_{d0}$  are respectively 0.89, 2.3, 0.84, and for the best model with the physical parameters LL, PI, M, C,  $Y_{d0}$  and EC are respectively 0.92, 1.7, and 0.91. The results of the evaluation criteria models show that inclusion of EC improved the accuracy of the model. It was found that the accuracy of the generalizations and estimations of the ANN models was further increased by clustering data before the data division stage by k-means method to Compared with hierarchical method.

**Key words:** Artificial neural network, Electrical conductivity of saturated soil, Marl soil, Neogene, Swelling potential of soil

---

\* Corresponding Author: lashkaripour@um.ac.ir