



تخمین ضریب فشار جانبی ماسه‌ها با استفاده از آزمایش نفوذ مخروط در محفظه کالیبراسیون و شبکه عصبی مصنوعی

محمد مهدی احمدی^{*}، نوید بشارت

دانشکده مهندسی عمران، دانشگاه صنعتی شریف، تهران، ایران

تاریخچه داوری:

دریافت: ۶ شهریور ۱۳۹۲

بازنگری: ۱۳ آبان ۱۳۹۴

پذیرش: ۲۷ اردیبهشت ۱۳۹۵

ارائه آنلاین: ۳۰ آذر ۱۳۹۵

کلمات کلیدی:

ضریب فشار جانبی ماسه در حالت سکون
آزمایش نفوذ مخروط
محفظة کالیبراسیون
شبکه عصبی خودسازمانده
شبکه عصبی احتمالاتی
شبکه عصبی چندلایه پس‌انتشار

چکیده: تعیین دقیق و مناسب مؤلفه‌های خاک، همواره در طراحی‌های ژئوتکنیکی مورد توجه بوده است. پیش‌بینی دقیق مؤلفه‌های تأثیرگذار ماسه از آزمایش‌های برجا نظیر نفوذ مخروط (CPT)، یکی از چالشی‌ترین مسائل در مهندسی ژئوتکنیک است. در این تحقیق، مؤلفه ضریب فشار جانبی ماسه در حالت سکون (K_0) برای انواع مختلف ماسه‌های موجود جمع‌آوری شده در پایگاه داده با استفاده از نتایج آزمایش کالیبراسیون نفوذ مخروط (که در دانشگاه‌ها و مؤسسات معتبر انجام شده‌اند) و همچنین سامانه‌ای متشکل از سه‌نوع شبکه عصبی مصنوعی، به طور نسبتاً دقیقی پیش‌بینی شده است. در این سامانه، مجموعه‌ای از شبکه‌های عصبی به صورت سری، وظایفی را انجام می‌دهند و در نهایت، سامانه با ترکیب مناسب این شبکه‌ها قادر خواهد بود تا مؤلفه K_0 را با دقت مناسب برای خاک‌های ماسه‌ای مورد بررسی در پایگاه داده، پیش‌بینی کند. در این روش، از شبکه عصبی خودسازمانده (SOM) برای خوشه‌بندی مناسب داده‌ها، از شبکه عصبی احتمالاتی (PNN) برای کلاسه‌بندی ماسه و در نهایت از شبکه عصبی چندلایه با الگوریتم پس‌انتشار (BP) برای مدل نهایی استفاده می‌شود. جزئیات ایجاد و بکارگیری چنین سامانه‌ای در این پژوهش شرح داده شده و در پایان نیز نتایج بدست‌آمده از این سامانه با نتایج سایر محققین مقایسه گردیده است.

۱- مقدمه

در سده‌های گذشته، روابط گوناگونی برای پیش‌بینی ضریب فشار جانبی ماسه در حالت سکون (K_0) با استفاده از داده‌های آزمایش (CPT) در محفظه کالیبراسیون و روش‌های رگرسیون آماری^۱ پیشنهاد شده است. زیرا از یک طرف تولید نمونه دست‌نخورده در خاک‌های غیرچسبیده بسیار سخت بوده و در پروژه‌های حقیقی با بودجه محدود عملاً غیرممکن است و از طرفی دیگر، داده‌های حاصل از نتایج آزمایش در محفظه کالیبراسیون بیش از گذشته و با دقت بیشتری در دسترس قرار دارند. در این محفظه‌ها، مشخصات و ویژگی‌های اولیه خاک و شرایط مرزی محفظه کالیبراسیون به طور دقیق مشخص است و با استفاده از نتایج آزمایش می‌توان روابطی را بین مشخصات خاک و نتایج آزمایش به روش‌های گوناگون برقرار نمود [۱، ۲]. روشی که محققان غالباً برای ایجاد رابطه از آن استفاده نموده‌اند، رگرسیون آماری بوده است. این روش در برخی از مواقع قادر به ایجاد رابطه‌ای با دقت مطلوب نبوده است. بدون تردید با وجود پیشرفت‌های حاصل در روش‌های تحلیل داده، ایجاد روابطی با دقت بیشتر همچنان مورد علاقه مهندسی ژئوتکنیک خواهد بود.

شبکه‌های عصبی مصنوعی^۲ (ANN) یا به طور خلاصه شبکه‌های عصبی، قادر هستند تا مجموعه‌ای از ورودی و خروجی‌ها را بدون داشتن دانش قبلی در ارتباط با ریاضی نهفته بین آن‌ها، به یکدیگر مرتبط سازند [۳]. بکارگیری شبکه عصبی مصنوعی در مهندسی ژئوتکنیک برای تعیین روابط ورودی خروجی (یا همان علت تأثیر) در سال‌های اخیر و در کارهای افرادی نظیر قابوسی و همکاران (۱۹۹۱) [۴]، میر و ریکس (۱۹۹۴) [۵]، آگراوال و همکاران (۱۹۹۵) [۶]، نجار و همکاران (۱۹۹۶) [۷]، نی و همکاران (۱۹۹۶) [۸]، جوانگ و چن (۱۹۹۹) [۹] و جوانگ و همکاران (۱۹۹۹) [۱۰، ۱۱] گزارش شده است.

در این مطالعه، داده‌های محفظه کالیبراسیون نفوذ مخروط که با دقتی بالا ثبت شده‌اند، به منظور ایجاد سامانه‌ای برای پیش‌بینی K_0 ماسه‌ها مورد استفاده قرار گرفته است. در این سامانه، مجموعه‌ای از شبکه‌های عصبی به صورت سری وظایفی را انجام می‌دهند و در نهایت نیز سامانه با ترکیب مناسب این شبکه‌ها، قادر خواهد بود تا مؤلفه K_0 را با دقت مناسبی برای خاک‌های ماسه‌ای در حالت طبیعی، پیش‌بینی کند. در این روش، از شبکه عصبی خودسازمانده برای خوشه‌بندی مناسب داده‌ها، از شبکه عصبی احتمالاتی برای کلاسه‌بندی ماسه و در نهایت نیز از شبکه عصبی چندلایه با الگوریتم پس‌انتشار برای مدل نهایی استفاده می‌شود. جزئیات ایجاد و

^۱ Statistical Regression Methods

* نویسنده عهده‌دار مکاتبات: mmahmadi@sharif.edu

^۲ Artificial Neural Network

بکارگیری چنین سامانه‌ای در ادامه شرح داده شده و در پایان نیز نتایج بدست‌آمده از این سامانه با سایر روش‌های تجربی موجود مقایسه می‌شود.

۲- روابط تجربی موجود

یکی از مؤلفه‌های مهم در طراحی‌های ژئوتکنیکی، تنش افقی برجا است و دانستن آن برای یافتن مقاومت جداره شمع‌ها، فشار پشت دیوارها، ارزیابی شکست سدها، ارزیابی پایداری گمانه‌ها و تفسیر نتایج سایر آزمایش‌های برجا بسیار ضروری است. بنابراین، هدف از تخمین ضریب فشار جانبی خاک، بدست‌آوردن تنش افقی برجا است. روابط گوناگونی برای محاسبه تنش افقی برجا با توجه به مؤلفه‌های مؤثر وجود دارد که در ادامه، نمونه‌هایی از مشهورترین آن‌ها ارائه می‌شود.

شواهد تجربی نشان می‌دهند که نفوذ مخروط، شرایط پیشین تنش و کرنش ماسه را تقریباً به طور کلی تغییر می‌دهد. علاوه بر این، مقاومت نفوذ مخروط (q_c) نیز به طور عمده تحت تأثیر مقدار تنش مؤثر افقی (σ'_{h0}) است [۱۲]. بر این اساس، پارکین (۱۹۸۸) رابطه‌ای تجربی به صورت رابطه ۱ برای ماسه‌های نسبتاً سخت پیشنهاد کرده است [۱۳]:

$$\sigma'_{h0} = A q_c^2 \quad (1)$$

که در این رابطه، σ'_{h0} تنش مؤثر افقی خاک در حالت سکون، q_c مقاومت نوک مخروط و A ضریب تجربی بسته به میزان تراکم خاک است.

هولسی و هیچمن (۱۹۸۸) نیز رابطه ۲ را برای گستره مختلف دانسیته نسبی ارائه کرده‌اند [۱۴]:

$$\frac{q_c}{p_a} = A \left(\frac{\sigma'_h}{p_a} \right)^{0.6} \quad (2)$$

در این رابطه، σ'_h تنش مؤثر افقی خاک در حالت سکون و p_a ثابتی برابر با فشار اتمسفر و مساوی با ۱ کیلوگرم بر سانتی‌متر مربع و یا ۹۸/۱ کیلوپاسکال است. مقادیر A در رابطه ۲ نیز عبارتند از: ۵۰ برای ماسه شل، ۱۶۰ برای ماسه متوسط و ۲۳۰ برای ماسه متراکم. رابطه مذکور از این لحاظ که تراکم خاک را به صورت کلی (شل، متوسط و متراکم) در نظر گرفته است، بنابراین تا حدودی ضعیف و ساده‌شده به نظر می‌رسد.

بلدی و همکاران (۱۹۸۶) [۱۲] دانسیته‌ی نسبی (D_r) و تنش‌های مؤثر را از عوامل اصلی مؤثر در مقاومت نوک مخروط دانسته‌اند و پس از آن نیز عوامل تاریخچه تنش، نوع ماسه و شرایط مرزی را به ترتیب تأثیرگذار در این امر دانسته‌اند [۱۲].

آن‌ها رابطه‌ای به صورت رابطه ۳ را برای دانسیته‌ی نسبی ماسه‌های عادی تحکیم‌یافته ارائه کرده‌اند:

$$D_r = \left(\frac{1}{C_2} \right) \ln \left(\frac{q_c}{C_0 \sigma'_1 C_1} \right) \quad (3)$$

که در آن، σ'_1 تنش مؤثر قائم خاک و C_0 و C_1 و C_2 ثابت‌های تجربی هستند.

این رابطه، برای ماسه‌های بیش تحکیم‌یافته (OC) قابل استفاده نیست. دلیل این امر آن است که q_c به صورت کلی، تقریباً تحت تأثیر تنش مؤثر افقی (σ'_h) است و از آنجایی که این رابطه عامل تنش افقی را دربر ندارد، بنابراین بلدی و همکاران رابطه ۴ را برای ماسه‌های بیش تحکیم‌یافته ارائه کردند:

$$D_r = \left(\frac{1}{C_2} \right) \ln \left(\frac{q_c}{C_0 \sigma'_m C_1} \right) \quad (4)$$

که در آن، σ'_h تنش مؤثر افقی بوده و واضح است که نسبت σ'_h به σ'_v در شرایط اولیه، همان K_0 خواهد بود. از روابط بالا می‌توان نتیجه گرفت که q_c به σ'_v و D_r و K_0 وابسته است.

یملکوفسکی و همکاران (۱۹۸۵) رابطه‌ای تجربی را ارائه کرده‌اند که مشابه با روابط بلدی و همکاران (۱۹۸۶) بوده و برای ماسه‌های عادی تحکیم‌یافته و بدون در نظر گرفتن تأثیرهای سیمانی‌شدن و سن ماسه است و تفاوت آن با رابطه‌های بالا در این است که توان تنش یا همان C_1 در آن برابر با ۰/۵ در نظر گرفته شده است.

$$\sigma'_m = \frac{(\sigma'_v + 2\sigma'_h)}{3} = \left(\frac{1 + 2K_0}{3} \right) (\sigma'_v) \quad (5)$$

مین (۱۹۹۱) [۱۶] رابطه‌ای را بین OCR و K_0 ارائه داد که این امکان را فراهم می‌کند تا برای کنترل مجدد مؤلفه‌ها مورد استفاده قرار بگیرد.

$$K_0 = \frac{\left(\frac{Pa}{\sigma'_v} \right) \left(\frac{q_c}{Pa} \right)^{1.6}}{145 \exp \left[\left(\frac{\left(\frac{q_c}{Pa} \right)}{12.2 OCR^{0.18} \left(\frac{\sigma'_v}{Pa} \right)^{0.5}} \right)^{0.5} \right]} \quad (6)$$

به این معنی که در رابطه فوق با داشتن OCR می‌توان K_0 را تخمین زد و یا به طور برعکس، با داشتن K_0 می‌توان OCR را بدست آورد. در بسیاری از موارد، یک روند تکراری برای تخمین همزمان OCR و K_0 لازم خواهد بود [۱۶].

به عنوان یک رابطه دیگر، می‌توان به رابطه‌ای که توسط احمدی و کرمبخش (۲۰۱۰) با استفاده از داده‌های محفظه کالیبراسیون برای تعیین فشار جانبی خاک‌ها بدست آمده است، اشاره نمود [۱۷].

$$\sigma'_h = \frac{P_a}{9 \times 10^4 \times D_r^3} \left(\frac{q_c}{P_a} \right)^2 \quad (7)$$

توجه شود که استفاده از روابط بالا و به طور کلی تمام روابطی که در ارتباط با ماسه‌های بیش تحکیم‌یافته بوده، دانستن OCR یا D_r ضروری است. این مؤلفه‌ها از اندازه‌گیری‌های CPT به طور مستقیم بدست نمی‌آیند و این موضوع، ضعف ذاتی روابط ارائه‌شده را نشان می‌دهد.

جدول ۲: تعریف شرایط مرزی مورد استفاده در محفظه کالیبراسیون

Table 2. Definition of boundary conditions used in calibration chambers

نوع شرایط مرزی شرایط مرزی قائم شرایط مرزی جانبی تعداد آزمایش‌ها درصد (%)				
۶۶/۱	۴۱۷	$\sigma_h = \text{ثابت}$	$\sigma_v = \text{ثابت}$	BC1
۴/۳	۲۷	$\varepsilon_h = 0$	$\varepsilon_v = 0$	BC2
۲۲/۰	۱۳۹	$\sigma_h = 0$	$\sigma_v = \text{ثابت}$	BC3
۷/۶	۴۸	$\varepsilon_h = \text{ثابت}$	$\varepsilon_v = 0$	BC4

جدول ۳: تعداد و درصد انواع ماسه

Table 3. Sand Type number and percentage

درصد (%)	تعداد آزمایش‌ها	نوع ماسه
۵۳/۹	۳۴۰	Ticino
۱۶/۲	۱۰۲	Hokksund
۱۱/۳	۷۱	Toyoura
۹/۷	۶۱	Monterey
۹/۰	۵۷	Leighton Buzzard

گرفته و نامعینی‌هایی را مربوط به چگونگی نسبت‌دادن نتایج حاصل به نتایج اندازه‌گیری شده در صحرا ایجاد نماید. به عبارت دیگر، آزمایش نفوذ مخروط در یک محفظه کالیبراسیون (که اندازه نمونه آزمایشگاهی در آن محدود است)، سبب می‌شود تا مقاومت نوک q_c تحت تأثیر شرایط مرزی ناشی از محفظه قرار بگیرد و این موضوع سبب می‌گردد تا q_c بدست آمده در شرایط واقعی (صحرا) حتی هنگامی که تمام شرایط و ویژگی‌های نمونه با واقعیت تطابق دارد، با نتایج آزمایش یکسان نباشد [۲۰].

در مورد کاهش تأثیر شرایط مرزی، مطالعات فراوانی انجام شده است که از جمله آن، می‌توان به پارکین (۱۹۸۸) [۱۳]، بین و همکاران (۱۹۸۸) [۲۱]، ایواساکی و همکاران (۱۹۸۸) [۲۲]، یمیلکوفسکی و همکاران (۲۰۰۳) [۲۳]، احمدی و رابرتسون (۲۰۰۸) [۲۴] و پورنقی‌آذر (۲۰۱۲) [۲۵] اشاره نمود. احمدی و رابرتسون (۲۰۰۸) [۲۴] با مطالعه عددی بر روی تأثیر اندازه محفظه و شرایط مرزی بر مقاومت نوک ماسه‌های عادی تحکیم‌یافته، نشان دادند که هرچه اندازه ابعاد محفظه نسبت به قطر مخروط بزرگ‌تر باشد، تفاوت بین نتایج حاصل از CPT داخل محفظه و نتایج آزمایش در صحرا نیز کمتر خواهد بود [۲۴]؛ به گونه‌ای که اگر نسبت قطر محفظه به قطر مخروط برای ماسه‌های شل برابر با ۳۳ یا بیشتر باشد، شرایط مرزی تأثیری بر مقاومت نوک ندارند. اما این نسبت در مورد ماسه‌های خیلی متراکم باید حتی بیش از ۱۰۰ باشد. همچنین تأثیر شرایط مرزی علاوه بر دانسیته‌ی نسبی

جدول ۱: ضرایب رابطه‌های ۳ و ۴

Table 1. Coefficients in relations 3 & 4

شماره رابطه	C_2	C_1	C_0
رابطه (۳)	۲/۴۱	-۰/۵۵	۱۵۷
رابطه (۴)	۲/۶۱	-۰/۵۵	۱۸۱

هدف از ارائه این روابط، نشان دادن توجه محققین مختلف به ارائه روابط کاربردی برای تخمین مناسب تنش افقی برجا از نتایج آزمایش نفوذ مخروط است تا در ادامه و پس از ارائه مدل‌ها با استفاده از شبکه‌های عصبی، قدرت پیش‌بینی روش‌های نوین در مقایسه با روابط معمول نشان داده شود.

۳- داده‌های بکار رفته در ایجاد سامانه پیشنهادی

پایگاه داده شامل ۶۳۱ آزمایش (CPT) است که از مجموع چهار منبع مختلف آزمایش‌های محفظه کالیبراسیون استخراج شده‌اند [۱۲، ۱۴، ۱۸، ۱۹]. در این پایگاه داده، علاوه بر نتایج آزمایش در محفظه کالیبراسیون (شامل مقاومت نوک و مقاومت اصطکاک جداره)، اطلاعاتی از شرایط اولیه خاک نیز مانند وزن مخصوص خشک ماسه (γ_d)، دانسیته‌ی نسبی (D_r)، شرایط اولیه تنش به صورت تنش افقی (σ'_h) و قائم (σ'_v)، ضریب فشار جانبی خاک در حالت سکون (K_0)، نسبت بیش‌تحکیمی (OCR) و مدول محدود شده (M) نیز وجود دارد. همچنین نسبت قطر محفظه به قطر مخروط (R_D) نیز ثبت شده است.

این مجموعه آزمایش‌ها در دانشگاه‌ها و مؤسسات مختلفی انجام شده‌اند. ۶۱ داده از دانشگاه برکلی (امریکا)، ۱۶۲ داده از مؤسسه ENEL CRIS (ایتالیا)، ۲۴۷ داده از مؤسسه ISMES (ایتالیا)، ۲۶ داده از مؤسسه NGI (نروژ)، ۶۰ داده از دانشگاه ساوتهمپتون (انگلستان)، ۱۸ داده از دانشگاه توکیو (ژاپن) و ۵۷ داده از دانشگاه آکسفورد (انگلستان) وجود دارد.

آزمایش‌ها در چهار نوع شرایط مرزی مختلف برای محفظه کالیبراسیون انجام شده‌اند که در جدول ۲ ارائه شده و تعداد و درصد آزمایش‌ها در دو ستون آخر این جدول داده شده است. همچنین پایگاه داده از پنج نوع ماسه با تعداد و درصد نام‌برده شده در جدول ۳ تشکیل شده است.

در این پژوهش، تأثیر جنس این پنج نوع ماسه بر نتایج آزمایش نادیده گرفته شده است و به عبارتی دیگر، فرض شده است که انواع ماسه‌های مختلف موجود در پایگاه داده به طور مستقیم بر نتایج آزمایش تأثیر گذار نبوده و با شاخص‌های دیگری (که در این مقاله مورد نظر قرار می‌گیرند)، تفاوت جنس به نحوی پوشش داده شده است.

۳-۱- کاهش تأثیر ابعاد محفظه کالیبراسیون

آزمایش نفوذ مخروط در ماسه‌ها که در محفظه‌های کالیبراسیون کوچک انجام می‌شود، ممکن است تحت تأثیر اندازه محفظه و شرایط مرزی قرار

جدول ۴: ضرایب اصلاح تأثیر شرایط مرزی (استخراج از نمودار احمدی و رابرتسون (۲۰۰۸))

Table 4. Correction coefficients for modification of the effect of boundary conditions (extracted from Ahmadi & Robertson, 2008)

$D_r=70-100\%$				
R_D				شرایط مرزی
۸۰-۱۰۰	۶۰-۸۰	۴۰-۶۰	۲۰-۴۰	
۱	۱/۰۲	۱/۰۴۲	۱/۲۶۵	BC1
۰/۹۵	۰/۹۴	۰/۹	۰/۷۸	BC2
۱	۱	۰/۹۲	۰/۹۲	BC3
۱	۱/۰۲	۱/۰۴۲	۱/۱۶۵	BC4
$D_r=50-70\%$				
R_D				شرایط مرزی
۸۰-۱۰۰	۶۰-۸۰	۴۰-۶۰	۲۰-۴۰	
۱	۱/۰۲	۱/۰۴۱	۱/۲	BC1
۱	۰/۹۷	۰/۹۵	۰/۸۶	BC2
۱	۱	۰/۹۶	۰/۹۴۵	BC3
۱	۱/۰۱	۱/۰۲	۱/۱۳	BC4
$D_r=30-50\%$				
R_D				شرایط مرزی
۸۰-۱۰۰	۶۰-۸۰	۴۰-۶۰	۲۰-۴۰	
۱	۱/۰۲	۱/۰۴	۱/۱۲	BC1
۱	۱	۱	۰/۹۴	BC2
۱	۱	۱	۰/۹۷	BC3
۱	۱	۱	۱/۰۹۲	BC4

ماسه، به سطح تنش نیز وابسته است. علاوه بر این، با افزایش نسبت قطر محفظه به قطر مخروط برای یک نوع خاک، مقدار مقاومت نوک مخروط (در این جا مقاومت نوک پیش‌بینی شده) در شرایط مرزی مختلف به سمت یک عدد خاص همگرا می‌شود. می‌توان این‌طور فرض نمود که مقدار همگرایی، در واقع میزان مقاومت نوک مخروطی است که در زمین طبیعی با این شرایط تنش و غیره اندازه‌گیری می‌شود [۲۴]. در این مطالعه، با استفاده از این فرض و همچنین نمودارهای نتایج مدل عددی احمدی و رابرتسون (۲۰۰۸) [۲۴]، ضریبی با توجه به دانسیته‌ی نسبی، شرایط مرزی و نسبت قطر محفظه به قطر مخروط استخراج شده و در q_c حاصل از آزمایش ضرب شد تا به این ترتیب، اثر شرایط مرزی بر روی q_c حذف شود. این ضرایب، در جدول ۴ ارائه شده‌اند.

۴- ایجاد سامانه پیشنهادی

سامانه پیشنهادی شامل مجموعه‌ای از سه نوع شبکه عصبی است که در ترکیبی ساختاریافته، توانایی پیش‌بینی مطلوب مؤلفه ضریب فشار جانبی ماسه را خواهد داشت. در این پژوهش، فرض اساسی بر آن است که انواع ماسه‌های موجود در پایگاه داده، تأثیر مستقیمی از نظر نوع و جنس بر نتایج حاصله نداشته و به عبارتی دیگر، نیازی به در نظرگیری جداگانه تأثیر جنس ماسه در ساخت مدل‌ها نبوده و مؤلفه‌های انتخابی نوع ماسه را نیز نمایندگی می‌کنند.

در این بخش، در ابتدا به نحوه تقسیم‌بندی مؤلفه‌ها به دسته‌های آموزش، آزمایش و اعتبارسنجی پرداخته می‌شود که برای این موضوع، شبکه‌های عصبی خودسازمانده معرفی می‌شوند. سپس مدل‌هایی با مؤلفه‌های ورودی مختلف برای تخمین ضریب فشار جانبی ماسه ایجاد می‌گردند تا مؤلفه‌های اصلی برای ایجاد مدل نهایی انتخاب شوند. به منظور بهبود مدل نهایی، از فرضیاتی برای کلاسه‌بندی ماسه استفاده می‌شود که در این قسمت، به بیان این فرضیات و همچنین معرفی شبکه عصبی احتمالاتی به عنوان ابزار کلاسه‌بندی پرداخته خواهد شد. در پایان، مؤلفه‌های مورد نیاز برای هر نوع شبکه عصبی به تفکیک هر مدل بیان خواهد شد.

۴-۱- تقسیم بندی داده‌ها به دسته‌های آموزش، آزمایش و اعتبارسنجی

مطالعات اخیر نشان داده است که روشی که داده‌ها به کمک آن به دسته‌های آموزش، آزمایش و اعتبارسنجی تقسیم‌بندی می‌شوند، می‌تواند تأثیر مشخصی بر نتایج حاصله داشته باشد [۲۶]. مجموعه آموزشی برای تنظیم وزن اتصال‌ها و مجموعه اعتبارسنجی نیز برای کنترل عملکرد شبکه در مراحل مختلف آموزش استفاده می‌شوند و هنگامی که خطا در مجموعه اعتبارسنجی رو به افزایش باشد، آموزش متوقف می‌شود. مجموعه آزمایشی برای ارزیابی عملکرد در مدل در هنگامی که آموزش به اتمام رسیده است، بکار می‌رود.

شاهین و همکاران (۲۰۰۲) پیشنهاد کردند که داده‌ها به گونه‌ای

تقسیم‌بندی شوند تا مؤلفه‌های آماری مانند میانگین، انحراف استاندارد، مقدار کمینه و بیشینه مؤلفه‌های ورودی در هر سه دسته از نظر آماری همسان^۱ باشند [۲۷]. به این ترتیب، سرعت و دقت آموزش بالاتر رفته و عملکرد مدل نیز بهتر خواهد بود.

در این راستا، شاهین (۲۰۰۲) روشی را برای تقسیم‌بندی بهتر داده‌ها بر مبنای شبکه عصبی خود سازمانده^۲ (SOM) که یک مدل الگوریتم شبکه عصبی بدون سرپرست است، پیشنهاد می‌دهد که در این مقاله، مورد استفاده

¹ consistent

² self-organizing map

قرار گرفته است [۲۷].

به آن پرداخته خواهد شد [۲۸].

۴-۱-۱- شبکه عصبی خودسازمانده


این دسته از شبکه‌های عصبی، در واقع یک سامانه طبقه‌بندی‌کننده بدون سرپرست هستند. در این سامانه، الگوهای ورودی با توجه به شباهتشان به بردارهای وزن شبکه دسته‌بندی می‌شوند. این فرآیند را خوشه‌بندی می‌نامند که در آن، هر خوشه توسط یک نرون معرفی می‌شود. اگر C_i بیانگر خوشه مربوط به نرون نام باشد، در این صورت هنگامی بردار ورودی در خوشه C_i قرار می‌گیرد که بردار وزن مرکز خوشه بیشترین شباهت (نزدیکترین فاصله) را به بردار ورودی داشته باشد. معیار شباهت را نیز می‌توان همان فاصله اقلیدسی تعریف نمود [۳].

ساختار عمومی این نوع شبکه شامل دو لایه است: لایه ورودی و لایه کوهن (شکل ۱). عناصر پردازشگر در لایه کوهن در یک یا دو آرایه چیده شده‌اند. ورودی از هر گره در لایه ورودی (x_i به ازای $i=1,2,\dots,n$) به طور کامل از طریق وزن‌های ارتباطی به لایه کوهن مرتبط هستند (W_{ji} به ازای $j=1,2,\dots,m$).

در شروع روند خودسازماندهی، وزن‌ها به طور تصادفی مقداردهی می‌شوند. در هر گره در لایه کوهن، ورودی (x_i) بدون حضور خروجی مطلوب ارائه می‌شود و مقدار تطابق محاسبه می‌شود. همان‌طور که پیش‌تر نیز اشاره شد، این مقدار عموماً فاصله اقلیدسی بین وزن‌های هر گره و مقدار ورودی متناظر در نظر گرفته می‌شود.

در این تحقیق، با استفاده از نرم‌افزار متلب^۱ (نسخه ۷،۱۱،۰) و ابزار خوشه‌بندی به کمک شبکه‌های خودسازمانده، داده‌ها به دسته‌های آموزش، آزمایش و اعتبارسنجی (به گونه‌ای که از لحاظ آماری به یکدیگر شبیه باشند) دسته‌بندی شدند. به منظور خوشه‌بندی داده‌ها، ورودی‌ها و خروجی متناظر با آن‌ها در شبکه عصبی اصلی به عنوان ورودی در شبکه عصبی خودسازمانده در نظر گرفته می‌شوند. مؤلفه‌های مورد نیاز نرم‌افزار برای ابعاد شبکه، اندازه همسایگی و تعداد تکرارها، با توجه به مدل تنظیم شدند که در بخش ۴-۳-۱

^۱ MATLAB



شکل ۱: شبکه خودسازمانده (کوهن)

Fig. 1. Self-Organizing Map (Kohonen)

هر سلول شبکه، در حقیقت یک گره در لایه کوهن را نمایش می‌دهد. هیچ قاعده علمی برای تخمین اندازه بهینه لایه کوهن و هندسه‌ی آن وجود ندارد. بنابراین، ابعاد شبکه به اندازه‌ای بزرگ در نظر گرفته می‌شود که تعداد بیشتری خوشه از داده‌ها ایجاد گردد [۲۹].

پس از اتمام خوشه‌بندی، سده‌ده از هر خوشه انتخاب می‌شود و به هر یک از دسته‌های آموزش، آزمایش و اعتبارسنجی تعلق می‌گیرد. اگر در خوشه‌ای یک داده قرار داشته باشد، به دسته آموزش و اگر دو داده وجود داشته باشد، به آموزش و آزمایش تعلق می‌گیرد. به این ترتیب، داده‌ها به یکدیگر شبیه بوده و هیچ داده‌ای وجود نخواهد داشت؛ مگر آن‌که مشابه با آن در دسته آموزش وجود داشته باشد. اما در نوع دیگری از دسته‌بندی داده‌ها پس از خوشه‌بندی، تمام داده‌های باقی‌مانده بعد از انتخاب دسته‌های آزمایش و اعتبارسنجی در دسته آموزش قرار می‌گیرد.

به نظر می‌رسد که استفاده از تمامی داده‌ها (روش دوم) نتایج بهتری داشته است [۲۷]. در این مطالعه نیز از روش دوم برای خوشه‌بندی داده‌ها استفاده می‌شود.

همان‌طور که پیش‌تر نیز اشاره شد، هیچ قانون مشخصی برای تعیین ابعاد شبکه وجود ندارد. بنابراین، شبکه‌هایی با ابعاد مختلف آموزش داده می‌شود و در نهایت، شبکه‌ای که از بیشترین تعداد خوشه‌ها از داده‌های آموزش تشکیل شده باشد، به عنوان شبکه مورد نظر انتخاب می‌گردد [۲۹]. در جدول ۹ از بخش ۴-۳-۳، تعداد داده‌های اختصاص‌یافته با این روش به هر یک از دسته‌های آموزش، آزمایش و اعتبارسنجی دیده می‌شوند.

۴-۲- انتخاب مؤلفه‌های مؤثر برای مدلسازی

با انجام هر آزمایش نفوذ مخروط در محفظه کالیبراسیون، تعدادی از مؤلفه‌ها به عنوان شرایط اولیه خاک و محفظه هستند که مشخص خواهند بود و نتیجه آزمایش که همان مقاومت نوک مخروط (q_c) و اصطکاک جداره (f_s) است، بدست خواهد آمد.

از میان مؤلفه‌های اولیه، باید تعدادی به همراه مقاومت نوک مخروط و اصطکاک جداره به عنوان ورودی مدل انتخاب شوند و هدف یا مؤلفه خروجی، همان ضریب فشار جانبی ماسه در حالت سکون (K_0) خواهد بود. در علوم آماری اثبات شده که برخی مؤلفه‌ها ممکن است به تنهایی تأثیر مشخصی بر روی نتایج نداشته باشند. اما در ترکیب با دیگر مؤلفه‌ها سبب بهتر شدن نتایج شده و وجودشان مهم شود. بنابراین، همواره چندین مدل شبکه عصبی با حضور مؤلفه‌های گوناگون ایجاد می‌شود تا مدلی با تعداد مؤلفه‌های بهینه و نتایجی با خطای کمتر انتخاب شود. از این‌رو با توجه به روابط تجربی موجود و تأثیرهای مؤلفه‌های مختلف، مدل‌های متنوعی ایجاد و آموزش داده شد تا مؤلفه‌های تأثیرگذار مشخص شوند. در واقع، هدف ایجاد مدلی است که با داده‌های قابل اندازه‌گیری ماسه‌ها در صحرا، قادر باشد تا ضریب فشار جانبی خاک (K_0) را تعیین کند. در جدول ۵، این

جدول ۵: مدل‌های پیشنهادی برای تخمین (K_0)

Table 5. Proposed models for estimating (K_0)

نام مدل	مؤلفه‌های استفاده شده
مدل (۱)	$\gamma_D, \sigma'_v, q_c, f_s$
مدل (۲)	$\gamma_D, \sigma'_v, f_s, D_r, q_c$
مدل (۳)	$\gamma_D, \sigma'_v, f_s, M, q_c$
مدل (۴)	$\gamma_D, \sigma'_v, f_s, OCR, q_c$
مدل (۵)	$\gamma_D, \sigma'_v, f_s, M_c, q_c$

کلاس مدول محدودشده (M_c) انجام گرفته است. کلاس مدول محدودشده بر مبنای این ایده حاصل شده است که حاصل لگاریتم مدول محدودشده واقعی در پایگاه داده موجود بر حسب مگاپاسکال در مبنای ۱۰ در بازه‌ای بین ۱ تا ۲/۵ قرار می‌گیرد. بنابراین، با تقسیم این بازه به عنوان نمونه به ۸ زیربخش و به کمک چهار مؤلفه اصلی و شبکه عصبی احتمالاتی^۱ (PNN)، باید بتوان ماسه را کلاسه‌بندی نمود و کلاس صحیح ماسه را از بین ۸ کلاس موجود نیز با دقت کافی تشخیص داد.

فرض دوم این است که با بدست آوردن کلاس مشخص برای M_c و استفاده از ۱۰ به توان مرکز دسته به جای استفاده از خود مدول محدودشده (M) (که از نتایج آزمایش بدست نمی‌آید)، قابلیت پیش‌بینی سامانه با اضافه کردن مؤلفه‌ای قابل تولید ارتقاء می‌یابد. به این ترتیب با کلاس مدول محدودشده، مؤلفه‌ای به مجموعه مؤلفه‌ها اضافه می‌شود که بتواند به صورت اثر مدول محدودشده و نسبت بیش‌تحکیمی (که اثر مثبتی بر بهبود پیش‌بینی مدل‌ها دارند) را بدون استفاده مستقیم از این مؤلفه‌ها نمایندگی کند. این فرض‌ها هر دو در ادامه و با ایجاد مدل، بررسی و تأیید خواهند شد.

۴-۲-۱- شبکه عصبی احتمالاتی (PNN)

شبکه عصبی احتمالاتی، حالت خاصی از شبکه عصبی شبکه‌ی تابع پایه شعاعی^۲ (RBF) بوده که تغییراتی به منظور افزایش سرعت آموزش در آن ایجاد شده است و اغلب برای طبقه‌بندی از آن استفاده می‌شود. شبکه عصبی احتمالاتی، یک روش عمومی برای حل مسائل طبقه‌بندی الگو است که از داده‌های آموزش برای ایجاد تابع توزیع استفاده می‌کند که بعد از آن، برای تخمین احتمال تعلق یک ورودی (بردار ورودی) به یک طبقه خاص استفاده می‌شود [۳]. شکل ۲ معماری یک شبکه PNN را نمایش می‌دهد که شامل یک لایه ورودی، یک لایه‌ی پایه شعاعی^۳ و یک لایه

مدل‌ها و مؤلفه‌های آن مشاهده می‌شود. در انتخاب مؤلفه‌های ورودی برای مدل‌ها، سعی بر انتخاب مؤلفه‌های مؤثر و همچنین کشف میزان اهمیت و تأثیر آن‌ها بر بهبود پیش‌بینی مدل بوده است تا بتواند مبنای مناسبی برای ایجاد سامانه مورد نظر باشد.

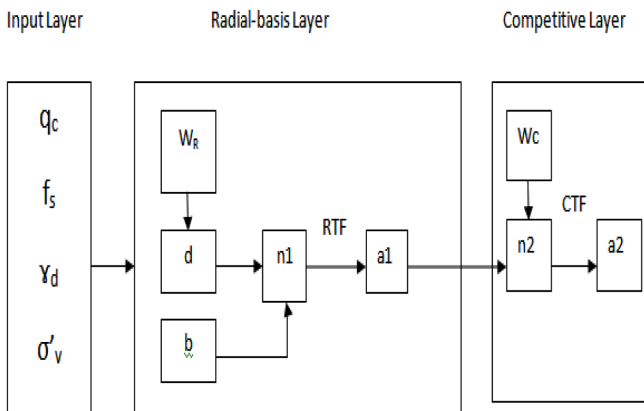
در این پژوهش، مدل‌های مختلف با این رویکرد ایجاد شده و مشخص شد که در کنار چهار مؤلفه اصلی وزن مخصوص خشک نمونه (γ_D)، تنش قائم (σ'_v)، مقاومت نوک مخروط (q_c) و اصطکاک جداره (f_s)، نیاز است تا مؤلفه دیگری وجود داشته باشد. بهترین مؤلفه‌ها بر طبق نتایج ثبت شده در بخش ۳-۳-۴، به ترتیب مؤلفه‌های نسبت بیش‌تحکیمی (OCR)، مدول محدودشده (M) و دانسیته‌ی نسبی (D_r) است. اما از آن‌جایی که این مؤلفه‌ها هیچ‌یک به طور مستقیم از نتایج آزمایش (CPT) بدست نمی‌آید، بنابراین باید مؤلفه‌ای با تأثیری نزدیک به این مؤلفه‌ها تعریف کرد تا بتوان قابلیت پیش‌بینی مدل را ارتقاء داد.

برای این منظور، روشی غیرمستقیم بر پایه دو فرض بنا شد. فرض اول این است که با کمک چهار مؤلفه اصلی می‌توان ماسه‌ها را به کلاس‌های مختلفی تقسیم‌بندی نمود. این کلاسه‌بندی بر مبنای تعریف مؤلفه‌ای به نام

جدول ۶: کلاسه‌بندی ماسه بر حسب M_c

Table 6. Classifying sands based on (M_c)

شماره کلاس	بازه تعریف شده	مرکز دسته
۱	$M_c > 1$	۱
۲	$1 < M_c < 1/25$	۱/۲۵
۳	$1/25 < M_c < 1/5$	۱/۳۷۵
۴	$1/5 < M_c < 1/75$	۱/۶۲۵
۵	$1/75 < M_c < 2$	۱/۸۷۵
۶	$2 < M_c < 2/25$	۲/۱۲۵
۷	$2/25 < M_c < 2/5$	۲/۳۷۵
۸	$2/5 < M_c$	۲/۵



شکل ۲: معماری شبکه احتمالاتی

Fig. 2. Architecture of Probabilistic network

جدول ۷: مؤلفه‌های شبکه SOM

Table 7. Required Parameters for SOM

نام مدل	ابعاد شبکه	اندازه همسایگی	تعداد تکرار
مدل (۱)	۱۰×۱۰	۵	۱۰۰۰۰
مدل (۲)	۱۰×۱۰	۵	۱۰۰۰۰
مدل (۳)	۸×۸	۵	۱۰۰۰۰
مدل (۴)	۱۱×۱۱	۵	۱۰۰۰۰
مدل (۵)	۹×۹	۵	۱۰۰۰۰

۳-۲-۴- مؤلفه‌های شبکه عصبی احتمالاتی (PNN)

در این مطالعه، شبکه عصبی احتمالاتی برای کلاسه‌بندی ماسه با استفاده از مؤلفه‌های اصلی بکار گرفته شد. بخش ورودی از داده‌های آموزش برای ایجاد ماتریس W_R و بخش خروجی نیز برای ایجاد ماتریس W_C بکار می‌رود. مقدار بایاس (b) و تعداد الگوهای آموزش تنها مؤلفه‌هایی هستند که باید با استفاده از جعبه ابزار شبکه عصبی نرم‌افزار متلب اختیار شوند [۲۸]. بایاس در شبکه عصبی احتمالاتی با استفاده از مؤلفه‌ای به نام Spread طبق رابطه ۸ بیان می‌شود:

$$b = \left(\frac{0.8326}{S} \right) \quad (8)$$

لازم به ذکر است که مقدار S با سعی و خطا بدست می‌آید. S با استفاده از حلقه تکرار در این مطالعه، از ۱ تا ۱۰۰۰ با گام یک و از ۱ تا ۰/۰۰۱ با گام n^{-1} قرار داده شده و شبکه با بهترین عملکرد مورد استفاده قرار گرفته است. برای انتخاب تعداد الگوهای آموزش به جای استفاده از روند سعی و خطا، باز هم از شبکه عصبی خودسازمانده بهره برده شد و داده‌ها به دو بخش آموزش و بخش آزمایش و صحت‌سنجی تقسیم‌بندی شدند. در جدول ۸، مقدار انتخابی برای مؤلفه S و مؤلفه‌های شبکه عصبی خودسازمانده بکار رفته، دیده می‌شود.

جدول ۸: مؤلفه‌های شبکه عصبی احتمالاتی (PNN)

Table 8. Probability Neural network (PNN) Parameters

نام مدل	مؤلفه (S)	ابعاد شبکه	اندازه همسایگی	تعداد تکرار
مدل (۱)	۳	۹×۹	۵	۱۰۰۰۰

رقابتی^۱ است [۱۱].

اولین قدم در لایه‌ی پایه شعاعی در هنگامی که بردار ورودی به شبکه اعمال می‌شود، محاسبه فاصله بردار ورودی تا هر یک از بردارهای آموزش است. به این ترتیب، برداری که نشان‌دهنده میزان نزدیکی بردار ورودی به هر یک از بردارهای آموزش است، تولید می‌شود. بردارهای آموزش در این لایه، به شکل ماتریس وزن W_R ذخیره می‌شوند. قدم بعدی در این لایه، تنظیم فاصله‌های محاسبه‌شده با بایاس^۲ و سپس ورود این فاصله‌های تنظیم‌شده به تابع انتقال است. استفاده از بایاس به شبکه‌ی پایه شعاعی اجازه می‌دهد تا حساسیت خودش را تنظیم نماید [۳].

تابع انتقال در لایه‌ی پایه شعاعی عموماً تابع زنگوله‌ای شکل است که در ورودی با مقدار صفر، مقدار بیشینه یک را دارا خواهد بود. خروجی این لایه، بردار a_1 است. توجه شود که هر عضو از بردار حاصله a_1 الزاماً اندازه‌ای از میزان شباهت بین بردار ورودی و هر یک از بردارهای آموزش ذخیره‌شده در W_R است.

قدم بعدی، اضافه‌کردن توزیع تمام داده‌های آموزش برای هر کلاس خروجی است. این کار با تغذیه بردار a_1 به لایه رقابتی با ماتریس وزن W_C و محاسبه n_2 صورت می‌پذیرد. ماتریس وزن W_C با ذخیره بخش خروجی‌های داده‌های آموزش تشکیل می‌شود. هر عضو از ماتریس حاصله n_2 یک احتمال نسبی است که احتمال تعلق یک ورودی به هر یک از γ کلاس خروجی را نشان می‌دهد.

قدم آخر برای طبقه‌بندی در لایه رقابتی، تفسیر n_2 از طریق تابع انتقال^۳ (CTF) است که در آن، هر عضو n_2 مقدار یک خواهد گرفت؛ اگر و تنها اگر بیشترین احتمال در بین γ کلاس دیگر را داشته باشد. در غیر این صورت، مقدار صفر خواهد گرفت. به این ترتیب، خروجی نهایی یک بردار ستونی خواهد بود که فقط مقدار یک دارد که نمایانگر کلاس نهایی است.

۳-۴- هندسه و الگوریتم آموزش شبکه‌ها

سه‌نوع شبکه عصبی مصنوعی بکار رفته در این مطالعه، برای حصول نتایج بهتر نیاز به تنظیم مؤلفه‌های مخصوص به خود دارند که در این بخش، مقادیر استفاده‌شده برای این مؤلفه‌ها بیان می‌شود.

۳-۴-۱- مؤلفه‌های شبکه عصبی خودسازمانده (SOM)

در این شبکه، مؤلفه‌های ابعاد شبکه، اندازه همسایگی و تعداد تکرارها باید تنظیم شود. همان‌طور که پیش‌تر نیز اشاره شد، هیچ قانون مشخصی برای تعیین ابعاد شبکه وجود ندارد. بنابراین، شبکه‌هایی با ابعاد مختلف آموزش داده می‌شود و در نهایت، شبکه‌ای که در آن بیشترین تعداد خوشه‌ها از داده‌های آموزش تشکیل شده باشد، به عنوان شبکه مورد نظر انتخاب می‌شود [۲۷]. در جدول ۷، مقادیر بکار رفته برای هر مؤلفه مشاهده می‌شود.

¹ competitive layer

² bias

³ contrast transfer function

یا دارای کمینه خطا به عنوان مدل اصلی انتخاب شد. در جدول ۹، مشخصات و مؤلفه‌های شبکه عصبی بکار رفته مشاهده می‌شود.

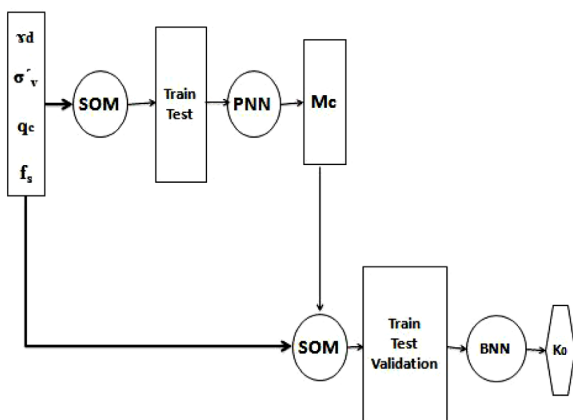
۵- نتایج مدل‌سازی و صحت‌سنجی

در این بخش، چگونگی بدست‌آوردن نتایج مطلوب تنها با استفاده از چهار مؤلفه اصلی قابل دسترس و سامانه پیشنهادی بیان خواهد شد. برای این منظور، شکل ۳ روندی که برای این منظور باید طی شود را به صورت یک گراف نمایش می‌دهد. مطابق با این شکل، در ابتدا داده‌ها شامل چهار مؤلفه اصلی به شبکه عصبی خودسازمانده داده شده و به کمک آن، به دسته‌های آموزش و آزمایش دسته‌بندی می‌شوند. سپس با استفاده از شبکه عصبی احتمالاتی و با تعریف کلاس مدول محدود شده، ماسه به ۸ کلاس مختلف تقسیم بندی می‌گردد. عدد ۱۰ به توان مرکز دسته محاسبه شده همراه با چهار مؤلفه اصلی پس از دسته‌بندی شدن توسط شبکه خودسازمانده، به شبکه عصبی سه‌لایه پس‌انتشار داده می‌شوند و خروجی نهایی (که همان ضریب فشار جانبی ماسه در حالت سکون است)، بدست می‌آید. در بخش‌های بعدی، نتایج هر یک از شبکه‌های عصبی بیان شده و مدل‌های مختلف ایجادشده با یکدیگر مقایسه می‌شوند. در پایان، سامانه پیشنهادی با روش‌های سایر محققین و به کمک نمودارهایی مقایسه خواهند شد.

۵-۱- نتایج مدل PNN

مطابق با فرض بیان شده، می‌توان ماسه‌ها را به کمک چهار مؤلفه اصلی کلاسه‌بندی کرد. داده‌ها با استفاده از شبکه عصبی خودسازمانده به دو دسته آموزش و دسته آزمایش و اعتبارسنجی تقسیم شدند. در جدول ۱۰ می‌توان نتیجه را مشاهده نمود. درصد موفقیت در این جدول، میزان پیش‌بینی درست برای کلاس ماسه در نظر گرفته شده است.

با توجه به نحوه نتایج حاصل از کلاسه‌بندی در جدول ۱۱ و با وجود



شکل ۳: ترکیب سامانه پیشنهادی برای تخمین K_0

Fig. 3. Schematic structure of proposed system for estimation of K_0

۴-۳-۳- شبکه عصبی چندلایه پس‌انتشار^۱

هدف از آموزش در شبکه عصبی چندلایه، تعیین وزن اتصال‌ها و بایاس‌ها با کمینه‌کردن خطای مربعی متوسط^۲ (MSE) است. در حالت نظری، یک خطای هدف قرار داده می‌شود و هنگامی که خطای شبکه در خلال آموزش کمتر از خطای هدف شود، آموزش متوقف می‌شود. سایر روش‌های توقف آموزش عبارتند از این‌که نرم‌گرادیان خطا از یک مقدار از پیش تعیین‌شده‌ای کوچکتر شود و یا این‌که داده‌های اعتبارسنجی در تعداد مشخصی سیکل^۳ بهبود پیدا نکرده و یا عملکرد بدتری را نشان دهند. در این مطالعه، تعداد سیکل مشخص برابر با ۶ در نظر گرفته شده است. خطای هدف در عمل اغلب به صورت اولیه انتخاب شده و سپس با توجه به نیازهای دامنه مسئله و نیز برای جلوگیری از سناریوی بیش‌آموزشی^۴ اصلاح می‌شود [۱۱]. در مطالعه حاضر، در نهایت با استفاده از نرم‌افزار متلب (نسخه ۰-۱۱-۷)، تمامی مدل‌ها به صورت یک شبکه عصبی سه‌لایه پیش‌خور^۵ با الگوریتم آموزش پس‌انتشار انتخاب شده‌اند که یک لایه ورودی، یک لایه مخفی و یک لایه خروجی دارند. برای آموزش نیز الگوریتم لونیگ-رکوردت^۶ (که پیش‌فرض نرم‌افزار است) بر دیگر الگوریتم‌های آموزش پس‌انتشار ترجیح داده شد.

مؤلفه‌های مورد نیاز الگوریتم شامل μ اولیه، عامل افزایش و کاهش μ و نیز مقدار بیشینه قابل قبول برای μ است. پس از بررسی مقادیر مختلف، همان مقادیر پیش‌فرض نرم‌افزار قرار داده شد [۲۸]. در هر شبکه عصبی چندلایه پس‌انتشار، تعداد نرون‌های لایه مخفی توسط یک روند سعی و خطا اختیار می‌شود. وزن‌های اولیه به صورت اعداد شبه‌تصادفی توسط نرم‌افزار متلب و به تعداد ۱۰۰۰ بار تولید شد و عمل آموزش در هر بار صورت گرفت. از بین این مدل‌ها با وزن‌های اولیه متفاوت، مدلی با بهترین عملکرد کلی^۷ و

¹ multilayer backpropagation neural network

² mean squared error

³ epoch

⁴ over-training

⁵ feed forward neural network

⁶ Levenberg Marquardt

⁷ performance

جدول ۹: شبکه عصبی چندلایه و مؤلفه‌های انتخابی آن

Table 9. Multi-layer Neural Network (MBPNN) and its selected parameters

نام مدل	تعداد نرون لایه مخفی	آموزش	آزمایش	اعتبارسنجی
مدل (۱)	۱۰	۲۵۲	۶۰	۴۹
مدل (۲)	۸	۲۳۹	۶۷	۵۵
مدل (۳)	۸	۱۸۴	۵۴	۴۵
مدل (۴)	۸	۲۳۷	۷۰	۵۴
مدل (۵)	۱۰	۱۸۶	۵۵	۴۲

جدول ۱۲: نتایج مدل شبکه عصبی MBPNN

Table 12. Results of neural network model multi-layer back propagation neural network (MBPNN)

نام مدل	عملکرد کلی	درصد موفقیت		
		آموزش	آزمایش	اعتبارسنجی
مدل (۱)	۰/۰۱۹	۸۲/۹۴	۷۶/۶۷	۷۹/۵۹
مدل (۲)	۰/۰۱۹۴	۸۶/۵۷	۷۴/۶۳	۷۸/۱۸
مدل (۳)	۰/۰۰۴۸۷	۹۷/۸۳	۹۰/۷۴	۸۸/۸۹
مدل (۴)	۰/۰۰۲۹۶	۹۸/۷۳	۹۵/۷۱	۹۸/۱۵
مدل (۵)	۰/۰۰۹۴۴	۹۱/۹۳	۹۰/۹۰	۸۵/۷۱

پنجم با اعمال کلاسه‌بندی و تعریف مؤلفه کلاس مدول محدود شده ارائه شد. همان‌طور که مشاهده می‌شود، پیش‌بینی مدل پنجم از مدل یک بهتر بوده و نسبت به مدل دوم (که مؤلفه دانسیته‌ی نسبی واقعی به آن داده شده است) عملکرد بهتری را دارد. همچنین نسبت به مدل سوم و چهارم دارای این مزیت است که نیازی به مؤلفه‌ای که در عمل قابل دسترسی نیست، نخواهد داشت. به این ترتیب، فرض دوم این مطالعه (که همان بهبود قابلیت پیش‌بینی مدل با اضافه کردن کلاس مدول محدود شده به جای خود مدول محدود شده است)، تأیید می‌شود. از طرفی دیگر، با توجه به نتایج نسبتاً مناسب مدل‌ها بدون لحاظ مؤلفه‌ای مشخص برای تعریف نوع ماسه در ورودی‌ها به طور مستقیم، فرض عدم تأثیر مستقیم جنس ماسه‌های موجود در پایگاه داده بر نتایج مدل‌سازی نیز تأیید می‌شود.

جدول ۱۰: نتایج شبکه عصبی PNN

Table 10. Neural network (MBPNN) results

درصد موفقیت		تعداد نمونه‌ها	
آموزش	آزمایش	آموزش	آزمایش
۹۳/۲	۷۳/۰۴	۹۲	۱۹۱

نتیجه نسبتاً ضعیف در آزمایش، مشاهده خواهد شد که بیشتر عدم تطبیق کلاس‌ها در یک و یا دو کلاس اختلاف رخ داده است و برای هدف مورد نظر می‌تواند قابل قبول باشد. به این ترتیب، فرض اول و قابلیت کلاسه‌بندی ماسه به کمک چهار مؤلفه به صورت نسبی تأیید می‌شود.

حال باید مؤلفه مدول محدود کلاسه‌بندی شده را با رابطه ۱۰ به توان مرکز دسته محاسبه کرده و به عنوان ورودی به شبکه عصبی اصلی وارد نمود.

در جدول ۱۱، نتایج کلاسه‌بندی و نیز اختلاف بیشینه دو کلاسی برای پیش‌بینی، مشاهده می‌شود.

۵-۲ نتایج شبکه عصبی چندلایه پس‌انتشار


در جدول ۱۲، عملکرد کلی و با تفکیک دسته‌های آموزش، آزمایش و اعتبارسنجی برای هر یک از پنج مدل انتخابی مشاهده می‌شود.

درصد موفقیت در جدول ۱۲، نشان‌دهنده درصد پیش‌بینی‌های با خطای کمتر از ۳۰ درصد است. به این ترتیب، افزودن مؤلفه‌ای دیگر مانند نسبت بیش‌تحکیمی و یا مدول محدود شده واقعی به چهار مؤلفه اصلی، کمک فراوانی به بهبود پیش‌بینی کرده است. اما از آنجایی که دسترسی به مدول محدود شده واقعی به طور عملی در صحرا غیرممکن است، بنابراین مدل


جدول ۱۱: نتایج کلاسه‌بندی با کمک شبکه عصبی PNN

Table 11. Classification results of neural network (PNN)

کلاس واقعی	تعداد داده موجود در کلاس واقعی	تعداد داده موجود در کلاس پیش‌بینی شده توسط شبکه احتمالاتی							
		۱	۲	۳	۴	۵	۶	۷	۸
۱	صفر	صفر	صفر	صفر	صفر	صفر	صفر	صفر	صفر
۲	۳	صفر	۲	۱	صفر	صفر	صفر	صفر	صفر
۳	۸	صفر	صفر	۶	۱	۱	صفر	صفر	صفر
۴	۳۹	صفر	صفر	۱	۳۵	۲	۱	صفر	صفر
۵	۷۷	صفر	صفر	صفر	صفر	۷۳	۲	۱	صفر
۶	۱۱۲	صفر	صفر	صفر	صفر	۱۱	۹۶	۵	صفر
۷	۴۴	صفر	صفر	صفر	صفر	۳	۸	۳۴	صفر
۸	صفر	صفر	صفر	صفر	صفر	صفر	صفر	صفر	صفر



شکل ۵: رابطه احمدی کرمبخش (۲۰۱۰) مطابق با رابطه ۷
Fig. 5. The prediction results of relation 7 (Ahmadi & Karambakhsh, 2010)



شکل ۶: سامانه ارائه شده در این مطالعه
Fig. 6. The prediction results of proposed system

درست بودن پیش‌بینی این رابطه است. اما همان‌طور که در شکل ۷ دیده می‌شود، نسبت به پیش‌بینی‌های مدل چهارم (که در آن، OCR واقعی یکی از مؤلفه‌های ورودی آن نیز به شمار می‌رود)، نتایج ضعیف‌تر است که این موضوع، برتری کلی روش‌های شبکه عصبی را بر روش رگرسیون آماری نشان می‌دهد. توجه شود که داده‌های ورودی در شکل‌های ۴ تا ۷ یکسان

۵-۳- صحت‌سنجی سامانه با روابط موجود


در این بخش، به مقایسه نموداری روش‌های مین و همکاران (۱۹۹۱) [۱۶] و احمدی کرمبخش (۲۰۱۰) [۱۷] با سامانه پیشنهادی پرداخته خواهد شد. لازم به ذکر است که در ارتباط با سامانه پیشنهادی، تنها از داده‌های آزمایشی که در صحرا قابل حصول هستند (یعنی چهار مؤلفه اصلی σ'_v و γ_d و q_c و f_s) استفاده شده است.

در بسیاری از روابط تجربی موجود از جمله روابط ارائه‌شده در ابتدای این مقاله، نیاز به دانستن مؤلفه‌هایی از ماسه خواهد بود که یا به کلی قابل اندازه‌گیری نیستند و یا نیاز به نمونه‌گیری و انجام آزمایش‌های آزمایشگاهی و بعضاً گران‌قیمت دارند.

همان‌طور که در روش مین (۱۹۹۱) و مطابق با رابطه ۶ مشاهده می‌شود، مقدار K_0 با فرض دانستن مقدار دقیق OCR محاسبه شده است. همچنین در روش احمدی کرمبخش (۲۰۱۰) مطابق با رابطه ۷، σ'_v با فرض دانستن مقدار دقیق D_r محاسبه و سپس مقدار K_0 با این مقدار و دانستن σ'_v محاسبه شده است. از طرفی دیگر در هر دو رابطه مذکور، از مقاومت نوک بدست‌آمده از آزمایش کالیبراسیون به صورت مستقیم و بدون هیچ تصحیحی استفاده شده که به معنی تفاوت در داده‌های مورد نیاز و داده‌های قابل دسترس در صحرا است.

خط نشان داده‌شده در شکل‌های ۴ تا ۷، نیمساز محورهای مختصات بوده و هرچه داده‌ها به این خط نزدیک‌تر باشند، نشان‌دهنده پیش‌بینی دقیق‌تر مدل و یا رابطه ارائه‌شده است.

لازم به ذکر است که رابطه مین (۱۹۹۱) با داشتن OCR واقعی، جواب‌هایی نزدیک به نیمساز محورهای مختصات داده است که این به معنی



شکل ۴: رابطه مین (۱۹۹۱) مطابق با رابطه ۶
Fig. 4. The prediction results of relation 6 (Mayne, 1991)


می‌تواند تأثیر زیادی را بر نتیجه داشته باشد. بنابراین، بار دیگر اثبات می‌شود که استفاده از روابط رگرسیونی ساده (که در آن تنها تأثیر برخی عوامل قابل مشاهده است)، برای پیش‌بینی مؤلفه‌های چندمتغیره و وابسته به عوامل گوناگون نمی‌تواند عمومیت پیدا کند و در این موارد، استفاده از روش‌های پیچیده‌تر علت تأثیر مانند شبکه‌های عصبی می‌تواند مفیدتر باشد.

۶- جمع‌بندی و نتیجه‌گیری

در این پژوهش، سامانه پیشنهادی با استفاده از مؤلفه‌های اصلی و قابل حصول در صحرا (یعنی γ_d و σ'_v و q_c و f_s) و بر مبنای این فرض که ماسه‌ها با استفاده از همین مؤلفه‌ها به کلاس‌های مختلفی قابل تقسیم هستند، توانست مؤلفه K_0 را با دقت خوبی پیش‌بینی نماید. به این ترتیب، علاوه بر نشان دادن نقش شبکه‌های عصبی در پیش‌بینی مناسب‌تر مؤلفه‌های رفتاری مصالح مهندسی از جمله ضریب فشار سکون خاک نسبت به روابط سایر محققین، راهکاری عملی برای تخمین ضریب فشار جانبی خاک ماسه‌ای را تنها بر اساس نتایج حاصل از آزمایش برجای نفوذ مخروط ارائه شده است. سامانه پیشنهادی با استفاده از ترکیب ساختاریافته‌ای از سه‌نوع شبکه عصبی خودسازمانده، احتمالاتی و چندلایه پیشخور بدون نیاز به داده‌هایی که در عمل در ماسه‌ها و در صحرا قابل اندازه‌گیری نیستند، نتایج مطلوبی را با درصد پیش‌بینی نزدیک به ۹۰ درصد در تخمین K_0 ماسه‌های موجود در پایگاه داده بدست آورد.

سامانه پیشنهادی در عمل به این صورت خواهد بود که در ابتدا داده‌های آزمایش نفوذ مخروط انجام‌شده در صحرا شامل چهار مؤلفه اصلی (یعنی γ_d و σ'_v و q_c و f_s) به شبکه عصبی خودسازمانده داده شده و به کمک آن، به دسته‌های آموزش و آزمایش دسته‌بندی می‌شود. سپس ماسه با استفاده از شبکه عصبی احتمالاتی و با تعریف کلاس مدول محدودشده (M_c)، به ۸ کلاس مختلف تقسیم‌بندی می‌گردد. عدد ۱۰ به توان مرکز دسته محاسبه‌شده به همراه چهار مؤلفه اصلی پس از دسته‌بندی شدن توسط شبکه خودسازمانده، به شبکه عصبی سه‌لایه پس‌انتشار داده می‌شوند و خروجی نهایی (که همان ضریب فشار جانبی ماسه در حالت سکون است)، بدست می‌آید. به این ترتیب و پس از آموزش شبکه با داده‌های قابل اطمینان، سامانه‌ای ایجاد شده که قادر است تا با نتایج صحرائی حاصل از آزمایش نفوذ مخروط، ضریب فشار جانبی ماسه را در حالت سکون بدست آورد.

به طور یقین، تعداد داده‌های در دسترس و بکار رفته در ایجاد سامانه پیشنهادی محدود بوده است و بنابراین، استفاده از داده‌های بیشتر و به ویژه داده‌های صحرائی برای سنجش اعتبار سامانه لازم خواهد بود. زیرا با وجود اصلاح تأثیر شرایط مرزی و ابعاد محفظه کالیبراسیون، عوامل دیگری از قبیل سالخوردگی و سیمانتاسیون^۱، تأثیر انواع دیگری از ماسه‌ها به غیر از ماسه‌های بکار رفته در این مطالعه بر K_0 مؤثر هستند که در این مقاله به این عوامل به طور کلی پرداخته نشده است.



شکل ۷: پیش‌بینی مدل چهارم برای داده‌های آزمایش

Fig. 7. The prediction results of fourth model with test set data

بوده و همان داده‌های دسته آزمایش برای مدل پنجم هستند. روش احمدی کرمبخش (۲۰۱۰) به جز سه داده نشان‌داده‌شده در جدول ۱۳، در دیگر داده‌ها پیش‌بینی نسبتاً مناسبی داشته است. همان‌طور که در جدول ۱۳ مشاهده می‌شود، این سه داده دانسیته‌ی نسبی کمی دارند و احتمال می‌رود که همین کم‌بودن دانسیته‌ی نسبی سبب افزایش خطای آزمایش‌شده باشد. از طرفی دیگر، در رابطه ۷ اهمیت ویژه‌ای برای تأثیر دانسیته‌ی نسبی در نظر گرفته شده است که وجود اندکی خطا در اندازه‌گیری

جدول ۱۳: داده‌های با نتایج ضعیف در رابطه ۷

Table 13. Poor results in relation 7

ENEL CRIS	SU	ISMES	Test done by
۱۲۴	۴۴	۳۱	شماره آزمون
۱۴/۷۳۸	۱۴/۵۳۲	۱۴/۱۱۱	γ_d (کیلو نیوتون بر متر مکعب)
۴۱	۲۳/۹	۱۷/۲	D_r (درصد)
۳۰۵/۹	۴۰۳	۶۱/۸	σ'_v (کیلو پاسکال)
۰/۷۷۴	۰/۴۵	۰/۶۳۹	K_0
۲۳۶/۸	۱۸۱/۴	۳۹/۵	σ'_h (کیلو پاسکال)
۲/۹۳	۱	۱	OCR
۲۱/۹	۱۱/۹	۲/۸	q_c (مگا پاسکال)
۱۲۵/۵	۶۳/۷	۸/۸	f_s (کیلو پاسکال)
۱	۳	۱	BC
۱۸۷/۵	۴۷/۲	۱۴/۱	M (مگا پاسکال)

¹ Cementation

- 2nd Part: Drained Penetration of Sands, 4th International Conference on Field Instrumentation and In-situ Measurements, Singapore, pp. 143-156, 1986.
- [13] A. K., Parkin; The Calibration of Cone Penetrometers, *Proceedings of the 1st International Symposium on Penetration Testing (ISOPT)*, Vol. 1, pp. 221-243, 1988.
- [14] G. T., Houlsby; R. C., Hitchman; Calibration Tests of Cone Penetrometers in Sand, *Géotechnique*, Vol. 38, No. 1, pp. 39-44, 1988.
- [15] M., Jamiolkowski; G., Baldi; R., Bellotti; V., Ghionna; E., Pasqualini; Penetration Resistance and Liquefaction of Sands, *Proc. 11th Int. Conf. on Soil Mech. and Found. Eng.*, A. A. Balkema, Rotterdam, Netherlands, pp. 1891-186, 1985
- [16] P. W., Mayne; Tentative Method for Estimating σ_{h0} from q_c Data in Sands, *Proc. 1st Int. Symposium on Calibration Chamber Testing*, Potsdam, NY, Elsevier, Amsterdam, pp. 249-256, 1991.
- [17] M. M., Ahmadi; P., Karambakhsh; K_0 Determination of Sand Using CPT Calibration Chamber, 2nd Int. Symposium on CPT, Huntington Beach, California, Paper No. 2-14, 2010.
- [18] R., Salgado; Analysis of Penetration Resistance in Sands, *Ph.D. Thesis, Dept. of Civ. Engineering, University of California*, Berkeley, Calif., 1993.
- [19] T., Lunne; P. K., Robertson; J. M., Powell; Cone Penetration Testing in Geotechnical Practice, *Blackie Academic and Professional*, London, UK, 1997.
- [20] P. W., Mayne; F. H., Kulhawy; Calibration Chamber Data Base and Boundary Effects Correction for CPT Data, *Proceedings of the 1st International Symposium on Calibration Chamber Testing*, Potsdam, New York, pp. 257-264, 1991.
- [21] K., Been; J. H. A., Crooks; L. A., Rothenburg; Critical Appraisal of CPT Calibration Chamber Tests, *Proceeding of the 1st International Symposium on Penetration Testing (ISOPT)*, Vol. 2, pp. 651-660, 1988.
- [22] K., Iwasaki; F., Tanizawa; S., Zhou; F., Taksuoka; Cone Resistance and Liquefaction Strength of Sand, *Proc. 1st Int. Symp. on Penetration Testing*, Vol. 2, Rotterdam: Balkema, pp. 785-791, 1988.
- [23] M., Jamiolkowski; D. C. F., Lo-Presti; M., Manassero; Evaluation of Relative Density and Shear Strength of Sands from CPT and DMT, *Soil Behavior and Soft Ground Construction, ASCE Geotechnical Special Publication*, Vol. 119, pp. 201-238, 2003.
- [24] M. M., Ahmadi; P. K., Robertson; A Numerical Study of Chamber Size and Boundary Effects on CPT Tip Resistance in NC Sand, *Scientia Iranica*, Vol. 15, No. 5,
- [1] P., Karambakhsh, Determination of lateral pressure of sandy soil using results of calibration of cone penetration test, MSc thesis, Sharif University of Technology, Iran, 2008 (in Persian).
- [2] M. M., Ahmadi, P., Karambakhsh, A. A., Golestani, Horizontal Stress Estimation Using CPT: A Database Approach, *Sharif Journal-Civil Engineering*, 2010. (In Persian)
- [3] M. B., Menhaj, Computational Intelligence-Volume I: Fundamentals of Neural Networks, *Amirkabir university of technology Pub.*, 2009.
- [4] J., Ghaboussi; J. H., Garrett; X., Wu; Knowledge Based Modeling of Material Behavior with Neural Networks, *Journal of Engineering Mechanics, ASCE*, Vol. 117, No. 1, pp. 132-53, 1991.
- [5] R. W., Meier; G. J., Rix; Backcalculation of Flexible Pavement Moduli Using Artificial Neural Networks, *Transportation Research Record 1448, National Research Council*, Washington, D.C., pp. 75-82, 1994.
- [6] G., Agrawal; J. L., Chameau; P. L., Bourdeau; Assessing the Liquefaction Susceptibility at a Site Based on Information from Penetration Testing, *Artificial Neural Networks for Civil Engineers: Fundamentals and Applications, ASCE Monograph*, New York, pp. 185-214, 1995.
- [7] Y. M., Najjar; I. A., Basheer; R., McReynold; Neural Modelling of Kansas Soil Swelling, *Transportation Research Record 1526, National Research Council*, Washington, D.C., pp. 14-9, 1996.
- [8] S. H., Ni; P. C., Lu; C. H., Juang; A Fuzzy Neural Network Approach to Evaluation of Slope Failure Potential, *Microcomputers in Civil Engineering*, Vol. 11, pp. 59-66, 1996.
- [9] C. H., Juang; C. J., Chen; CPT-based Liquefaction Evaluation Using Artificial Neural Networks, *Journal of Computer-Aided Civil and Infrastructure Engineering*, Vol. 14, No. 2, pp. 221-229, 1999.
- [10] C. H., Juang; C. J., Chen; Y. M., Tien; Appraising CPT Based Liquefaction Resistance Evaluation Method Artificial Neural Network Approach, *Canadian Geotechnical Journal*, Vol. 36, pp. 443-54, 1999.
- [11] C. H., Juang; P. C., Lu; Predicting Geotechnical Parameters of Sands from CPT Measurements Using Neural Networks, *Computer-Aided Civil and Infrastructure Engineering*, Vol. 17, pp. 31-42, 2002.
- [12] G., Baldi; R., Bellotti; V., Ghionna; M., Jamiolkowski; E., Pasqualini; Interpretations of CPT's and CPTU's,

- Division for Developing Neural Networks Applied to Geotechnical Engineering, *Journal of Computing in Civil Engineering, ASCE*, Vol. 18, No. 2, pp. 105-114, 2004.
- [28] H., Demuth; M., Beale; Neural Network Toolbox, User's Guide, Version 3, *The Mathworks, Inc.*, Natick, MA, 1998.
- [29] G. J., Bowden; H. R., Maier; G. C., Dandy; Optimal Division of Data for Neural Network Models in Water Resources Applications, *Water Resource. Res.*, Vol. 2, pp. 1-11, 2002.
- pp. 541-553.
- [25] M., Pournaghiazar; A. R., Russel; N., Khalili; Linking Cone Penetration Resistances Measured in Calibration Chambers and the Field, *Geotechnique Letters*, Vol. 2, pp. 29-35, 2012.
- [26] M. A., Shahin; M. B., Jaksa; H. R., Maier; Artificial Neural Network Application in Geotechnical Engineering, *Australian Geomechanics*, Vol. 36, No. 1, pp. 49-62, 2001.
- [27] M. A., Shahin; M. B., Jaksa; H. R., Maier; Data

برای ارجاع به این مقاله از عبارت زیر استفاده کنید:

Please cite this article using:

M. M., Ahmadi, N., Besharat, "Determination of Coefficient of Lateral Earth Pressure at Rest for Sandy Soils Using Cone Penetration Test and Artificial Neural Network". *Amirkabir J. Civil Eng.*, 49(1) (2017) 67-79.

DOI: 10.22060/ceej.2016.8601.4417

