

پیش‌بینی پارامترهای مقاومت برشی خاک‌های بندرعباس با استفاده از شبکه عصبی مصنوعی

حبیب رحیمی منبر^۱، محمد فتح‌اللهی^{۲*}، غلامرضا شعاعی^۳

۱. دانشجوی دکتری زمین‌شناسی مهندسی، زمین‌شناسی مهندسی، علوم پایه، دانشگاه تربیت مدرس، تهران، ایران

۲. دکتری زمین‌شناسی مهندسی، علوم زمین، علوم پایه، دانشگاه کردستان، سنندج، ایران

۳. دکتری زمین‌شناسی مهندسی، زمین‌شناسی مهندسی، علوم پایه، دانشگاه تربیت مدرس، تهران، ایران

تاریخ دریافت: ۱۴۰۱/۰۷/۰۱

تاریخ پذیرش: ۱۴۰۱/۰۹/۲۰

چکیده

پارامترهای مقاومت برشی، پارامترهای مهمی برای ارزیابی پایداری سازه‌های مهندسی هستند که محاسبه آن‌ها با روش‌های مرسوم نیازمند هزینه و زمان زیادی می‌باشد. در این پژوهش با استفاده از آزمایش‌های اولیه ژئوتکنیک مانند دانه‌بندی، حدود آتربرگ و آزمایش تک‌محوره و به کارگیری هوش مصنوعی، بدون انجام تست‌های پیچیده‌تر، زاویه اصطکاک داخلی و چسبندگی خاک محاسبه شد. به این منظور از نمونه‌های دست‌نخورده از ۱۴ گمانه در بندرعباس که بر روی آن‌ها آزمایش‌های اولیه ژئوتکنیک و برش مستقیم انجام گرفته بود، انتخاب و برای آموزش شبکه‌ی عصبی استفاده شدند. در این پژوهش تعداد ۱۹۵ شبکه در حالت‌های مختلف آموزش داده شد. به منظور دستیابی به بهترین عملکرد، شبکه‌های عصبی پیش‌خور ابتدا در حالت تک لایه و دو لایه با تعداد نورون‌های لایه میانی پایین آموزش داده شدند و تابع TRAIN BR به دلیل بالا بودن نسبت $R(=0/97)$ انتخاب و سپس با افزودن لایه‌های میانی به ۳، ۴ و ۵ لایه با تعداد نورون‌های لایه میانی (۵۰، ۴۰، ۳۰، ۲۰ و ۱۰) نورون شبکه‌های عصبی آموزش داده شدند. نتایج نشان داد شبکه‌ی MLP چهار لایه بهترین نتایج را نشان می‌دهد، برای این حالت R آموزش ۱، R تست ۰/۹۰ و R کل ۰/۹۸ می‌باشد. در نهایت به منظور صحت‌سنجی شبکه‌ی عصبی، تعداد ۱۵ نمونه انتخاب و پارامترهای ورودی شبکه در حالات بهینه ۲، ۳ و ۴ لایه آموزش داده و خروجی شبکه ارزیابی شد. برای پیش‌بینی چسبندگی، شبکه عصبی در حالت ۴ لایه ($R^2=0/99$) و برای زاویه اصطکاک، شبکه‌های ۲، ۳ و ۴ لایه ($R^2=0/99$) بهترین خروجی را داشتند.

کلید واژه‌ها: بندرعباس، پیش‌بینی پارامترهای ژئوتکنیکی، شبکه عصبی

مقدمه

به طور کلی مقاومت برشی اشیاع خاک، با معیار مور-کلمب بیان می‌شود و در پروژه‌های مختلف مهندسی مانند ظرفیت باربری پی‌ها، برآورد مقدار نشست خاک، ارزیابی ناپایداری شیب‌های خاکی، طراحی دیوارهای حائل و... بسیار حائز اهمیت است (Khaboushan et al., 2018) و همچنین، این پارامترها مهم‌ترین پارامتر برای ارزیابی فرسایش خاک هستند (Zhang

(et al., 2018). به‌طور کلی برای محاسبه‌ی مستقیم پارامترهای مقاومت برشی خاک در آزمایشگاه از آزمایش سه محوره (Mohammadi et al., 2022) و در صحرا از PMT یا SPT، استفاده می‌شود (Lee et al., 2003). انجام آزمایش‌های مستقیم برای تعیین ϕ و c خاک‌ها به مقدار کافی نمونه مناسب (دست خورده یا دست‌نخورده) نیاز دارد. همچنین آماده‌سازی و انتقال نمونه به آزمایشگاه پرهزینه و زمان‌بر بوده و به تجهیزات آزمایشگاهی خاصی نیاز دارد (Khaboushan et al., 2018). برای محاسبه‌ی پارامترهای مقاومت برشی روابط تجربی زیادی نیز با استفاده از آزمایش‌های صحرایی ارائه شده است. اما تمامی این روش‌ها نیازمند صرف زمان و هزینه‌ی بسیاری می‌باشند و عملاً برای خاک‌های منطقه‌ای خاص با ویژگی خاص قابل استفاده‌اند؛ بنابراین همواره محققان در تلاش برای پیش‌بینی این پارامترها از طرق مختلفی هستند مثلاً برخی از آن‌ها ϕ و c را با استفاده از آزمایش نفوذ استاندارد تخمین زده‌اند (Mahmoud, 2013). خانلری و همکاران در 2012، ϕ و c را با استفاده از هوش مصنوعی از شاخص خمیری و درصد عبوری از الک 200، 40 و 4 به دست آوردند. مدنی اصفهانی و حیدری (1389)، پارامترهای چسبندگی و زاویه اصطکاک داخلی خاک‌های رسی دربرگیرنده مسیر پیشنهادی مونوریل کرمانشاه را با استفاده از روش شبکه عصبی مصنوعی برآورد کردند. کیم و همکاران (Kim et al., 2021) با استفاده از پارامترهای شاخص خاک و شبکه‌ی عصبی مصنوعی، چسبندگی مؤثر خاک‌های برجای مرتبط با ناپایدارهای ناشی از بارندگی سنگاپور را به دست آوردند. خوبشان و همکاران (Khaboushan et al., 2018) پارامترهای برشی خاک را با استفاده از رگرسیون خطی چندگانه (MLR) از درصد رس، ماسه و سیلت، قطر متوسط و محتوای مواد آلی (OM) و کربنات کلسیم (CaCO_3) به دست آوردند. ژانگ و همکاران (Zhang et al., 2018) رابطه‌ی بین پارامترهای برشی خاک و برخی خواص خاک مانند مقدار گراول، رس، کربنات کلسیم، وزن مخصوص را در منطقه‌ی فرسایشی شمال چین مورد بررسی قرار دادند. محمدی و همکاران (2020) پارامترهای مقاومت برشی خاک را با استفاده از هوش مصنوعی و آزمایش الک، حدود آتربگ و وزن مخصوص خاک‌های اشیاع اصفهان ایران را به دست آوردند.

در سال‌های اخیر، استفاده از هوش محاسباتی در حل مسائلی که راه حل مشخصی ندارند یا قابل حل به روش‌های سنتی نیستند به شدت پیشرفت کرده است. چراکه در برخی از فرایندهای فیزیکی پارامترهای زیادی تأثیر دارند، علاوه بر آن، وجود روابط کاملاً غیرخطی بین این پارامترها بر پیچیدگی موضوع می‌افزاید. در واقع پایه و اساس روش‌های هوشمند، استفاده از دانش پنهان نهفته در داده‌ها، تلاش در راستای یافتن روابط ذاتی میان آن‌ها و تعمیم این روابط به موقعیت‌های دیگر است (Churchland, 1992). در این پژوهش سعی شده است تا با استفاده از آزمایش‌های اولیه‌ی ژئوتکنیک مانند دانه‌بندی، حدود آتربگ و آزمایش تک‌محوره و به کارگیری هوش مصنوعی در نرم‌افزار متلب، بدون انجام تست‌های پیچیده‌تر زاویه اصطکاک داخلی و چسبندگی خاک را با دقت قابل قبولی محاسبه کرد.

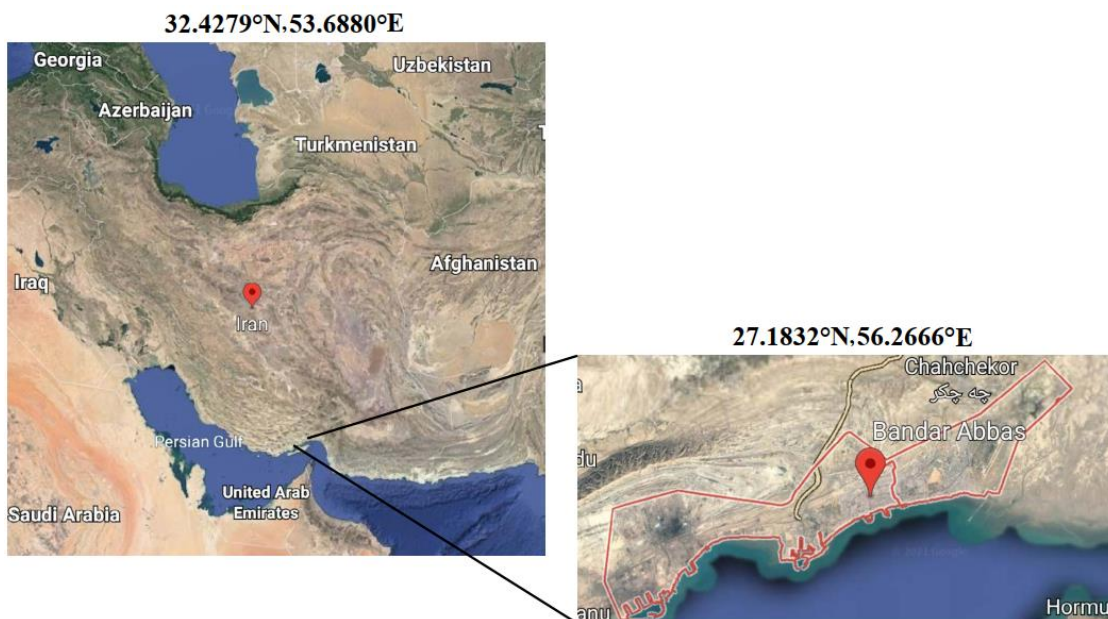
شبکه‌ی عصبی مصنوعی (ANN) در بسیاری از مطالعات پیشین ژئوتکنیک استفاده شده است. بسیاری از محققین از ANN برای محاسبه‌ی ظرفیت باربری پی‌های عمیق و سطحی استفاده نموده‌اند (Kalinli et al., 2011; Goh, 1995). نشست پی‌های سطحی کم‌عمق نیز با استفاده از مدل‌های ANN استنباط شده است (Sivakugan et al., 1998). پایداری دامنه‌ها با ترکیب نظریه مجموعه‌های فازی با شبکه‌های عصبی مورد بررسی قرار گرفته است (Ni et al., 1996). زمین‌لغزش‌ها نیز با استفاده از هوش مصنوعی مدل شده‌اند (Choi et al., 2012). الیس و همکاران (Ellis et al., 1995) یک مدل ANN را

برای پیش‌بینی توزیع اندازه‌ی دانه و تاریخچه‌ی تنش ماسه پیشنهاد کردند. Cal یک مدل ANN را برای ایجاد طبقه‌بندی کمی خاک از ویژگی‌های شاخص خاک مانند شاخص خمیری، حد روانی و درصد رس توسعه داد. رومرو و پاموکچو (Romero and Pamukcu, 1996) یک مدل ANN را برای مشخص کردن مدول برشی و مواد گرانول ارائه کردند. از ANN با درجات مختلف موفقیت برای پیش‌بینی ظرفیت باربری محوری و جانبی پی‌های شمعی، از جمله پی‌های شمعی کوبیده شده، در تراکم و بالا آمدن (uplift)، استفاده شده است (e.g., Chan et al., 1995; Lee and Lee, 1996; Teh et al., 1997; Abu-Kiefa, 2005; Das and Basudhar, 2006; Shahin and Jaksa, 2006). شریفی و همکاران (۱۳۹۴) و مرنندی و همکاران (۱۳۹۴) پتانسیل رمبندگی خاک‌های رمبنده را از طریق شبکه‌های عصبی مصنوعی، پیش‌بینی کرده‌اند. کمک‌پناه و همکاران در سال ۱۳۹۴ با استفاده از شبکه‌ی عصبی مصنوعی، رفتار تورمی خاک‌های رسی را پیش‌بینی کرده‌اند.

مواد و روش‌ها

منطقه و بانک اطلاعات پژوهش

داده‌های این پژوهش از مطالعات ژئوتکنیکی صورت گرفته برای پروژه‌ی آب‌شیرین‌کن ساقی کوثر بندرعباس که توسط شرکت ژئوتکنیک تهران انجام گردیده جمع‌آوری شده است. بندرعباس مرکز استان هرمزگان و یکی از کلان‌شهرهای ایران می‌باشد که در جنوب ایران قرار گرفته است. بانک اطلاعاتی پژوهش شامل داده‌های مطالعات ۱۰۰ آزمایش ژئوتکنیک انجام شده در ۱۴ گمانه در شهر بندرعباس می‌باشد. در این پژوهش از داده‌های آزمایش‌های دانه‌بندی، حدود آتبرگ (ASTM-D 4318 87)، تعیین وزن مخصوص دانه‌های جامد (Gs) (ASTM-D 854-14)، آزمایش تک‌محوری (ASTM-D2166)، آزمایش تعیین درصد رطوبت (ASTM-D851) و آزمایش SPT (برای داده‌های ورودی) و آزمایش برش مستقیم (برای داده‌های خروجی) استفاده شده است تا با استفاده از هوش مصنوعی پارامترهای مقاومت برشی خاک را محاسبه کنیم. شکل ۱ منطقه‌ی مورد مطالعه را نشان می‌دهد. همان‌طور که مشاهده می‌شود، آزمایش‌های مورد استفاده برای داده‌های ورودی این پژوهش، از آزمایش‌های ژئوتکنیک رایج در پروژه‌های ژئوتکنیک می‌باشند که نسبت به سایر آزمایش‌ها سریع‌تر بوده، هزینه‌ی کمتری دارند و دسترسی به نتایج آن‌ها راحت‌تر است. در جدول ۱، تجزیه و تحلیل آماری بانک داده‌ها انجام شده است. نمونه‌های مورد مطالعه از گمانه‌هایی به عمق ۱ تا ۷۰ متر استخراج شده است. نمونه‌ها، خاک ریزدانه عمدتاً از رس با خاصیت خمیری بالا تا سیلت با خاصیت خمیری پایین می‌باشد. در این جدول، N_{spt} عدد آزمایش نفوذ استاندارد، C_u چسبندگی به دست آمده از آزمایش تک‌محوری، γ_d وزن واحد حجم خشک، q_u مقاومت فشاری تک محوری، ω درصد رطوبت، G_s وزن مخصوص دانه‌های جامد، C درصد رس، M درصد سیلت، S درصد ماسه، G درصد گراول، LL حد روانی، PL حد خمیری، PI شاخص خمیری، C_u ضریب یکنواختی، CC ضریب انحنای، C چسبندگی و ϕ زاویه اصطکاک داخلی را تشکیل می‌دهند.



شکل ۱. موقعیت منطقه مورد مطالعه
 Fig. 1. The location of study area

جدول ۱. تجزیه و تحلیل آماری مجموعه داده‌ها

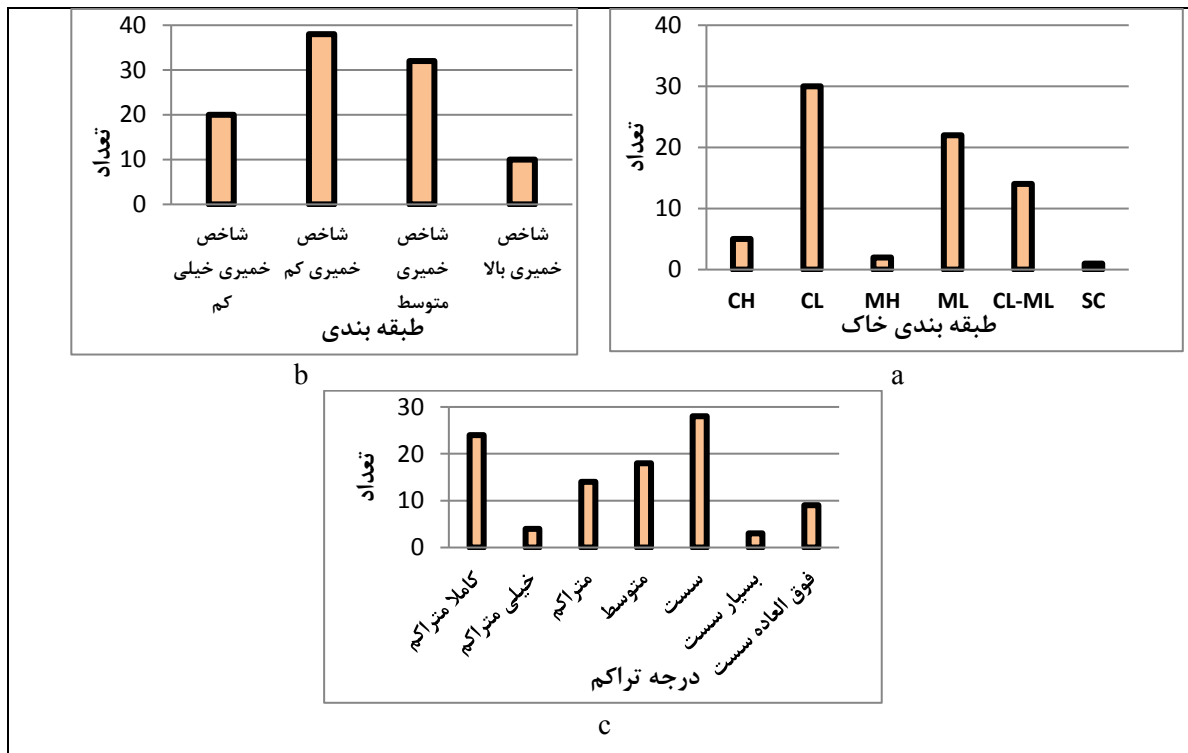
Table 1. Statistical analysis of results

parameter	unit	Max	Min	mean	SD	skewness	kurtosis
Nspt	N	100	1	33.72	27.92	-1.24	0.72
Cu	Kg/cm ²	1.17	0.09	0.43	0.23	-0.83	-0.35
γd	Kg/cm ³	2.1	1.45	1.68	0.09	-1.18	0.20
qu	Kg/cm ²	2.34	0.18	0.87	0.47	-0.83	-0.35
ω	-	31.4	7.96	20.05	3.71	-1.33	0.48
Gs	-	2.86	2.52	2.70	0.04	-0.11	4.47
%C	-	56.3	0	28.46	12.87	-1.18	0.75
%M	-	94.8	8.1	45.85	17.98	1.09	-0.21
%S	-	87.9	0	24.70	24.73	-0.68	-0.20
%G	-	26.5	0	1.17	3.93	-3.26	11.63
LL	-	72	10	27.51	10.69	-1.58	1.97
PL	-	40	1	17.57	6.46	-1.32	0.77
PI	-	32	1	9.94	6.62	-1.27	0.95
Cu	-	252	0	5.49	26.66	-5.36	30.06
CC	-	1187	0	71.24	143.10	-2.66	6.67
C	Kg/cm ²	1.24	0	0.22	0.21	-2.03	4.20

parameter	unit	Max	Min	mean	SD	skewness	kurtosis
ϕ	degree	42	10	25.49	6.92	-0.60	-0.75

نتایج آزمایش‌های ژئوتکنیک

در شکل ۲ a، نمونه‌های خاک طبق سیستم یونیفاید (USCS) طبقه‌بندی شده‌اند. نمونه‌ها از رس با خاصیت خمیری زیاد (CH)، رس با خاصیت خمیری کم (CL)، لای با خاصیت خمیری کم (ML)، رس با خاصیت خمیری پایین یا لای با خاصیت خمیری پایین (CL-ML) و ماسه با ریزدانه‌ی رسی (SC) تشکیل شده‌اند. در این میان رس با خاصیت خمیری کم بیشترین فراوانی را دارد. طبق طبقه‌بندی برمیستر (Burmister, 1994) نمونه‌ها به ۴ دسته‌ی شاخص خمیری خیلی کم، شاخص خمیری کم، شاخص خمیری متوسط و شاخص خمیری بالا تقسیم‌بندی شدند. با توجه به شکل ۲ b، شاخص خمیری کم بیشترین فراوانی را دارد. طبق طبقه‌بندی اسکمپتون (Skempton, 1986) با استفاده از عدد SPT، تراکم نسبی (Dr) نمونه‌ها تخمین زده شد و نمونه‌ها به کاملاً متراکم، خیلی متراکم، متوسط، سست، بسیار سست و فوق‌العاده سست تقسیم شدند. شکل ۲ c، نمودار این طبقه‌بندی را نشان می‌دهد. در این بین خاک‌های سست بیشترین فراوانی را دارند.




شکل ۲. a) هیستوگرام فراوانی و طبقه‌بندی یونیفاید خاک، b) هیستوگرام فراوانی و طبقه‌بندی شاخص خمیری و c) هیستوگرام فراوانی و طبقه‌بندی تراکم نسبی خاک با استفاده از عدد SPT

Fig. 2a. Soil class in unified classification system, b: plasticity index of soil, c: Relative density of soil using SPT

شبکه‌ی عصبی مصنوعی (ANN)

شبکه‌ی عصبی مصنوعی، یک روش محاسباتی و مدل‌سازی عددی می‌باشد که با الهام گرفتن از عملکرد مغز انسان و سیستم عصبی که در لایه‌های شبکه قرار می‌گیرند، گسترش یافته است. با توجه به کاربرد شبکه‌های عصبی مصنوعی، هر لایه دارای مقدار کافی نورون است و هر اتصال وزن خاصی دارد. فلسفه‌ی این روش همانند بسیاری از روش‌های آماری ساده، یافتن ارتباط بین ورودی‌های مدل با خروجی‌های متناظر آن می‌باشد. این روش به عنوان ابزاری قدرتمند برای مدل‌سازی شناخته می‌شود که می‌تواند داده‌های ناکافی را دسته‌بندی کرده و روابط پیچیده و غیرخطی میان متغیرهای یک سیستم ایجاد کند (Rumelhart et al., 1985). به‌طور کلی شبکه‌های عصبی به سه دسته‌ی پیش‌خور، پس‌خور و رقابتی تقسیم شده‌اند (Hagan, 1995). در این پژوهش از شبکه‌ی عصبی پیش‌خور استفاده شده است. ساختار مرسوم یک شبکه‌ی عصبی پیش‌خور در شکل ۳ نشان داده شده است.



شکل ۳. ساختار مرسوم یک شبکه عصبی پیش‌خور

Fig. 3. Structure of a feed forward neural network

در یک شبکه‌ی عصبی، نورون‌ها در لایه‌های مختلف طبقه‌بندی می‌شوند. لایه‌ی ورودی شامل نورون‌هایی است که ورودی را از محیط خارج دریافت می‌کنند. لایه خروجی نیز شامل نورون‌هایی است که خروجی سیستم را به محیط خارجی یا کاربر و یا طراح سیستم ارائه می‌دهد. معمولاً علاوه بر لایه‌های ورودی و خروجی ممکن است یک یا چند لایه‌ی نهان (میانی، Hidden Layer) نیز بین این دو لایه موجود باشد که تعداد این لایه‌ها به ساختار شبکه، ساختار داده‌ها و طراحی شبکه توسط طراح بر می‌گردد. هنگامی که لایه ورودی، ورودی را دریافت می‌کند، نورون‌های آن لایه، خروجی را تولید کرده که همین خروجی، ورودی لایه بعدی است. این مراحل به همین ترتیب ادامه پیدا می‌کند تا اینکه شرط معین و مورد نظر (پایان فرایند یادگیری) برقرار گردد، سپس لایه خروجی، خروجی شبکه را ارائه می‌دهد و فرایند به اتمام می‌رسد. تعیین تعداد نورون‌های لایه‌های نهان شبکه برای طراحی شبکه الزامی است و تعداد آن بستگی به بهینه کردن شبکه دارد، یعنی در حقیقت آنقدر نورون به لایه‌ی نهان افزوده می‌شود تا کارایی شبکه بهینه گردد. البته باید در نظر داشت که افزایش بی‌رویه‌ی تعداد نورون‌های لایه‌ی نهان ممکن است باعث بیش‌برازش شبکه گردد.


در این پژوهش از شبکه عصبی پرسپترون (MLP) استفاده شده است که اولین شبکه‌ی کاربردی در تاریخ شبکه عصبی مصنوعی است و نماد شبکه‌های عصبی پیش‌خور می‌باشد. الگوریتم یادگیری پرسپترون، الگوریتمی ساده ولی مفهومی است.

اساس یادگیری پرسپترون که مبنای بسیاری از الگوریتم‌های پیشرفته‌تر شبکه عصبی با ناظر است، این است که رفتار خوب تشویق می‌شود و رفتار بد مورد سرزنش قرار می‌گیرد. بنابراین در این شبکه به نورون اجازه داده می‌شود که از اشتباهات قبلی خود یاد بگیرد که در آینده چگونه رفتار کند. اگر جواب شبکه با خطا همراه باشد، احتمال این خطا را در آینده کم می‌کنیم و اگر جواب درست باشد وضع موجود را تغییر نمی‌دهیم (Rosenblatt, 1958). توابع محرک (Activation Function) نقش تابع ربط را در لایه‌های مختلف شبکه‌ی عصبی ایفا می‌کنند. تابع محرک می‌تواند خطی یا غیرخطی باشد. یک تابع محرک بر اساس نیاز خاص حل مسئله انتخاب می‌شود. در عمل، تعداد محدودی از توابع محرک مورد استفاده قرار می‌گیرند که از بین آن‌ها می‌توان به تابع آستانه‌ای دو مقدره متقارن، تابع آستانه‌ای دو مقدره، تابع همانی، تابع خطی مثبت، تابع سیگموئیدی و تابع تانژانت هایپربولیک اشاره کرد (Hagan, 1995). در این پژوهش از تابع محرک تانژانت هایپربولیک استفاده شده است. تابع انتقال راه مناسبی برای نشان دادن سیستم خطی و زمان ثابت رابطه‌ی ورودی-خروجی است. این تابع با تبدیل لاپلاس به معادلات دیفرانسیل توصیف کننده پویایی سیستم، با فرض صفر بودن شرایط اولیه بدست می‌آید (MATLAB help center). فرایند یادگیری در واقع مشخص کردن ارتباط بین ورودی و خروجی در طول زمان با تکرار فرایند است (Dayhoff, 1994). در این پژوهش از تابع یادگیری تطبیقی و تابع یادگیری عملگر استفاده شده است. انتخاب تابع آموزشی شبکه عصبی چندلایه به عوامل زیادی بستگی دارد، که شامل: پیچیدگی مسئله، تعداد نقاط داده در مجموعه‌ی آموزش، تعداد وزن‌ها و جهت‌گیری‌ها در شبکه، هدف خطا و این که آیا شبکه برای تشخیص الگو استفاده می‌شود (تجزیه و تحلیل تشخیصی) یا تقریب تابع (رگرسیون) می‌باشند. پس در این بخش لازم است الگوریتم‌های مختلف آموزشی را مقایسه کرد (MATLAB help center).

داده‌های ورودی و خروجی

ورودی‌های پژوهش ۱۵ پارامتر می‌باشند، شامل: درصد رس، درصد سیلت، درصد ماسه، درصد گراول، ضریب انحنای (Cc)، ضریب یکنواختی (Cu)، حد روانی، حد خمیری، شاخص خمیری، وزن مخصوص دانه‌های جامد (Gs)، درصد رطوبت، وزن مخصوص خشک ذرات خاک (γ_d)، مقاومت تک‌محوری، چسبندگی و عدد SPT می‌شود. این پژوهش دو خروجی دارد که زاویه اصطکاک داخلی و چسبندگی را شامل می‌شوند.

شکل ۴، نمایی از ورودی‌ها و خروجی‌های شبکه‌ی عصبی را نشان می‌دهد.



شکل ۴. نمایی از ورودی‌ها و خروجی‌های شبکه عصبی

Fig. 4. Input and output of neural network

نرم افزار مورد استفاده

برای پیاده‌سازی طرح

شکل ۴ در شبکه عصبی مصنوعی از نرم‌افزار MATLAB R2021a v9.9.0 و جعبه ابزار شبکه‌ی عصبی آن استفاده شده است. جعبه‌ابزار این نسخه از نرم‌افزار، نسبت به نسخه‌های قبلی کارتر بوده و سرعت آموزش و آنالیز داده‌ها نیز در این نسخه بالاتر از نسخه‌های پیشین است.


ساختار شبکه‌ی عصبی برای مسئله‌ی مورد نظر

در این پژوهش از شبکه‌ی عصبی پیش‌خور (FF) و پرسپترون چندلایه (MLP) برای آنالیز داده‌ها استفاده شده است. تعداد گره‌های لایه‌ی پنهان و همچنین تعداد لایه‌های پنهان از طریق سعی و خطا به دست آمده‌اند. در حقیقت تعداد مناسب نورون‌ها و لایه‌های پنهان، وقتی به دست می‌آید که شبکه بهترین جواب را ارائه دهد (Rosenblatt, 2004). به همین خاطر شبکه‌های عصبی یک‌لایه، دو‌لایه و سه‌لایه، چهار لایه و پنج لایه و تعداد نورون‌های ۱۰، ۲۰، ۳۰، ۴۰، ۵۰ برای آنالیز داده‌های این پژوهش استفاده شده است.


در این پژوهش، ۱۹۵ شبکه پردازش شده است که از این تعداد ۸۴ شبکه تک لایه، ۸۴ شبکه دو‌لایه، ۷ شبکه سه لایه، ۱۰ شبکه چهار لایه و ۱۰ شبکه پنج لایه بوده‌اند (جدول ۱ و شکل ۵ و ۶).

جدول ۲. تعداد شبکه‌های عصبی پردازش شده با تعداد لایه‌های مختلف
 Table 2. Number of processed neural network with different layers

تعداد شبکه	تعداد لایه
۸۴	تک لایه
۸۴	دو لایه
۷	سه لایه
۱۰	چهار لایه
۱۰	پنج لایه
۱۹۵	مجموع



شکل ۵. نمایش فراوانی شبکه‌های عصبی پردازش شده با تعداد لایه‌های مختلف
 Fig. 5. Show the frequency of processed neural network with different layers




شکل ۶. نمایی از شبکه‌های عصبی یک لایه، دو لایه، سه لایه، و پنج لایه

Fig6. A view of one – layer, two- layer, three-layer, four- layer and five- layer neural networks

به منظور دست‌یابی به بهترین عملکرد، شبکه ابتدا در حالت تک لایه و دو لایه با تعداد نورون‌های لایه میانی 10 نورون پردازش شد. سپس بهترین نتایج مرحله‌ی قبل با 3، 4 و 5 لایه و با تعداد نورون‌های لایه میانی 20، 30، 40، 50 و 10 مورد پردازش قرار گرفتند.

فرآیند آموزش

در این مطالعه از ۱۴ تابع آموزشی مختلف استفاده شده است که تعداد و فراوانی شبکه‌های عصبی پردازش شده با هر یک از این توابع در شکل ۷ و جدول ۳ قابل مشاهده می‌باشد.



شکل ۷. نمایش فراوانی شبکه‌های عصبی پردازش شده با توابع آموزشی مختلف
 Fig. 7. Presentation of the frequency of neural networks processed with training function


جدول ۳. تعداد شبکه‌های عصبی پردازش شده با تعداد توابع آموزشی مختلف

Table 3. The number of processed neural networks with the number of different training function

ردیف	تابع آموزشی	تعداد
۱	Train BFG	۱۴
۲	Train BR	۳۱
۳	Train CGB	۱۳
۴	Train CGF	۱۲
۵	Train CGP	۱۲
۶	Train GD	۱۲
۷	Train GDM	۱۲
۸	Train GDA	۱۲
۹	Train GDX	۱۲
۱۰	Train LM	۱۳
۱۱	Train OSS	۱۲
۱۲	Train NR	۱۲
۱۳	Train NRP	۱۴
۱۴	Train SCG	۱۴
	مجموع	۱۹۵

فرآیند یادگیری

در این مطالعه در ابتدا ۱۵ داده اعم از ورودی و خروجی شبکه عصبی را جدا و برای صحت‌سنجی نتایج نهایی کنار گذاشته شد (داده‌های مربوط به جدول ۸ و ۹) از بقیه داده‌ها برای آموزش شبکه عصبی و آزمون خود شبکه عصبی با این ترتیب که ۷۰ درصد داده‌ها برای آموزش شبکه عصبی و ۳۰ درصد داده‌ها برای آزمون شبکه عصبی ساخته شده استفاده شد، در نتیجه حدود ۷۷ شبکه با تابع یادگیری عملگرای MSE، ۵۹ شبکه با تابع یادگیری عملگرای MSE REG و ۵۹ شبکه با تابع یادگیری عملگرای SEE پردازش شدند (شکل ۱ و جدول ۴). در این پژوهش از تابع یادگیری تطبیقی و تابع یادگیری عملگرای استفاده شده است. همانطور که در شکل ۹ و جدول ۵ مشاهده می‌کنید، در این پژوهش ۹۰ شبکه با تابع یادگیری تطبیقی GD و ۱۰۵ شبکه با تابع یادگیری تطبیقی GDM پردازش شده‌اند.




شکل ۸. نمایش فراوانی شبکه‌های عصبی پردازش شده با توابع یادگیری عملگرای

Fig. 8. Presentation of the frequency of neural networks processed with operant learning function

جدول ۴. تعداد شبکه‌های عصبی پردازش شده با توابع یادگیری عملگرای مختلف

Table 4. Number of neural networks processed with different operant learning function

تعداد	تابع یادگیری عملگرای	ردیف
۷۷	MSE	۱
۵۹	MSE REG	۲
۵۹	SEE	۳
۱۹۵	مجموع	



شکل ۹. نمایش فراوانی شبکه‌های عصبی پردازش شده با تابع یادگیری تطبیقی مختلف

Fig. 9. Frequency display of neural networks processed with different adaptive learning function

جدول ۵. تعداد شبکه‌های عصبی پردازش شده با توابع یادگیری تطبیقی مختلف

Table 5. The number of processed neural networks with different adaptive learning functions

تعداد شبکه	تابع یادگیری تطبیقی	ردیف
۹۰	Learn GD	۱
۱۰۵	Learn GDM	۲
۱۹۵	مجموع	

تفسیر نتایج حاصل از شبکه

در جدول ۶ از بهترین نتایج شبکه‌های عصبی تک لایه و دو لایه را مشاهده می‌شود که از a تا m نام‌گذاری شده‌اند. همانطور که مشاهده می‌شود، در بین بهترین نتایج به دست آمده، تابع آموزشی BR بیشترین فراوانی را در میان توابع آموزشی داشته است و ۶ مورد از توابع یادگیری عملگرا را تابع MSE تشکیل می‌دهد. در میان توابع یادگیری تطبیقی، تابع GD بیشترین فراوانی را دارد. بنابراین تابع BR، تابع MSE و تابع GD به ترتیب بهترین توابع آموزشی، یادگیری عملگرا و یادگیری تطبیقی برای این مسئله هستند. سپس با تغییر دادن تعداد نورون‌های لایه‌های میانی، و با استفاده از بهترین توابع آموزشی، یادگیری تطبیقی و یادگیری عملگرا در حالت سه لایه، و پنج لایه بهترین نتایج بدست آمد.

جدول ۶. نتایج شبکه‌های عصبی یک‌لایه و دو لایه
Table 6. The results of one-layer and two-layer neural networks


نام	تابع آموزش	تابع یادگیری تطبیقی	تابع یادگیری عملگرا	تعداد لایه	تابع انتقال	R آموزش	R صحت آموزش	R تست	R کل
a	Train BFG	Learn GD	SEE	2	TAN SIG	0.96	0.97	0.96	0.97
b	Train BFG	Learn GDM	MSE	2	TAN SIG	0.97	0.95	0.96	0.97
c	Train BR	Learn GD	SEE	1	TAN SIG	0.95	-	0.95	0.97
d	Train BR	Learn GDM	MSE	1	TAN SIG	0.95	-	0.95	0.97
e	Train BR	Learn GD	MSE	2	TAN SIG	0.99	-	0.84	0.97
f	Train BR	Learn GD	SEE	2	TAN SIG	0.99	-	0.82	0.97
g	Train BR	Learn GDM	MSE	2	TAN SIG	1	-	0.83	0.97
h	Train BR	Learn GDM	MSE REG	2	TAN SIG	0.97	-	0.95	0.97
i	Train CGB	Learn GD	MSE	2	TAN SIG	0.96	0.98	0.97	0.97
j	Train LM	Learn GDM	MSE	2	TAN SIG	0.97	0.95	0.96	0.97
k	Train NRP	Learn GDM	MSE REG	2	TAN SIG	0.96	0.98	0.97	0.97
l	Train SCG	Learn GD	MSE	2	TAN SIG	0.97	0.93	0.99	0.97
m	Train SCG	Learn GDM	MSE	2	TAN SIG	0.96	0.97	0.96	0.97

جدول ۷، پنج مورد از بهترین نتایج را با استفاده از بهترین توابع نشان می‌دهد که از n تا r نام‌گذاری شده‌اند. نمودارهای این شبکه‌ها در شکل ۱۰ تا شکل ۱۳ نشان داده شده است.

جدول ۷. بهترین نتایج شبکه‌های عصبی یک‌لایه، دو لایه، سه لایه، چهار لایه و پنج لایه با استفاده از بهترین توابع


Table 7. The best results of one-layer, one-layer, three-layer, four-layer and five-layer neural networks using the best functions

نام	تابع آموزش	تابع یادگیری عملگرا	تابع یادگیری تطبیقی	تعداد لایه	تابع انتقال	R آموزش	R تست	R کل
n	TRAIN BR	Learn GDM	MSE	1	TAN SIG	0.96	0.97	0.97
o	TRAIN BR	Learn GDM	MSE	2	TAN SIG	1	0.74	0.95
p	TRAIN BR	Learn GDM	MSE	3	TAN SIG	1	0.87	0.98
q	TRAIN BR	Learn GDM	MSE	4	TAN SIG	1	0.90	0.98
r	TRAIN BR	Learn GDM	MSE	5	TAN SIG	0.99	0.81	0.97




شکل ۱۰. نمودارهای شبکه‌ی عصبی O


Fig.10. Neural network diagrams O



شکل ۱۱. نمودارهای شبکه‌ی عصبی P
Fig. 11. Neural network diagrams p



شکل ۱۲. نمودارهای شبکه‌ی عصبی q
Fig. 12. Neural network diagrams q



شکل ۱۳. نمودارهای شبکه‌ی عصبی Γ
Fig. 13. Neural network diagrams r

صحت‌سنجی نتایج به دست آمده از شبکه عصبی مصنوعی

به منظور صحت‌سنجی نتایج حاصل از شبکه‌های عصبی، مقادیر به دست آمده برای زاویه اصطکاک داخلی و مقادیر واقعی اندازه‌گیری شده برای همان مقادیر در جدول ۸ نشان داده شده است. همچنین نتایج حاصل از شبکه‌های عصبی به دست آمده برای چسبندگی و مقادیر واقعی اندازه‌گیری شده برای همان مقادیر در جدول ۹ نشان داده شده است. سپس رگرسیون بین مقادیر به دست آمده از آزمایش‌ها و مقادیر به دست آمده از شبکه‌ی عصبی برای حالت‌های دولایه، سه لایه، چهارلایه و پنج لایه برای هر دو خروجی به دست آمده است (شکل ۱۴ و ۱۵).

همان‌طور که از

جدول ۱۰ و شکل ۱۵ پیداست، شبکه‌ی عصبی برای چسبندگی، در حالت چهار لایه در بهترین حالت قرار دارد و رگرسیون $0/99$ را داده است. بعد از حالت ۴ لایه، حالت سه لایه با رگرسیون $0/98$ بهترین نتایج را داده است. با بررسی جدول ۹ و شکل ۱۴ مشاهده می‌شود که برای زاویه اصطکاک داخلی تمام حالت‌های دولایه و سه لایه رگرسیون $0/99$ را داده است. با توجه به جدول ۸ بهترین نتایج مربوط به شبکه‌ی q می‌باشد، در این حالت R آموزش ۱، R تست $0/90$ و R کل $0/98$ به دست آمده است.

جدول ۸. برخی از داده‌های ورودی واقعی به دست آمده در آزمایشگاه که برای ارزیابی عملکرد شبکه‌ها استفاده شده‌اند

Table 8. Some of the real input data obtained in the laboratory that have been used to evaluate the performance of networks

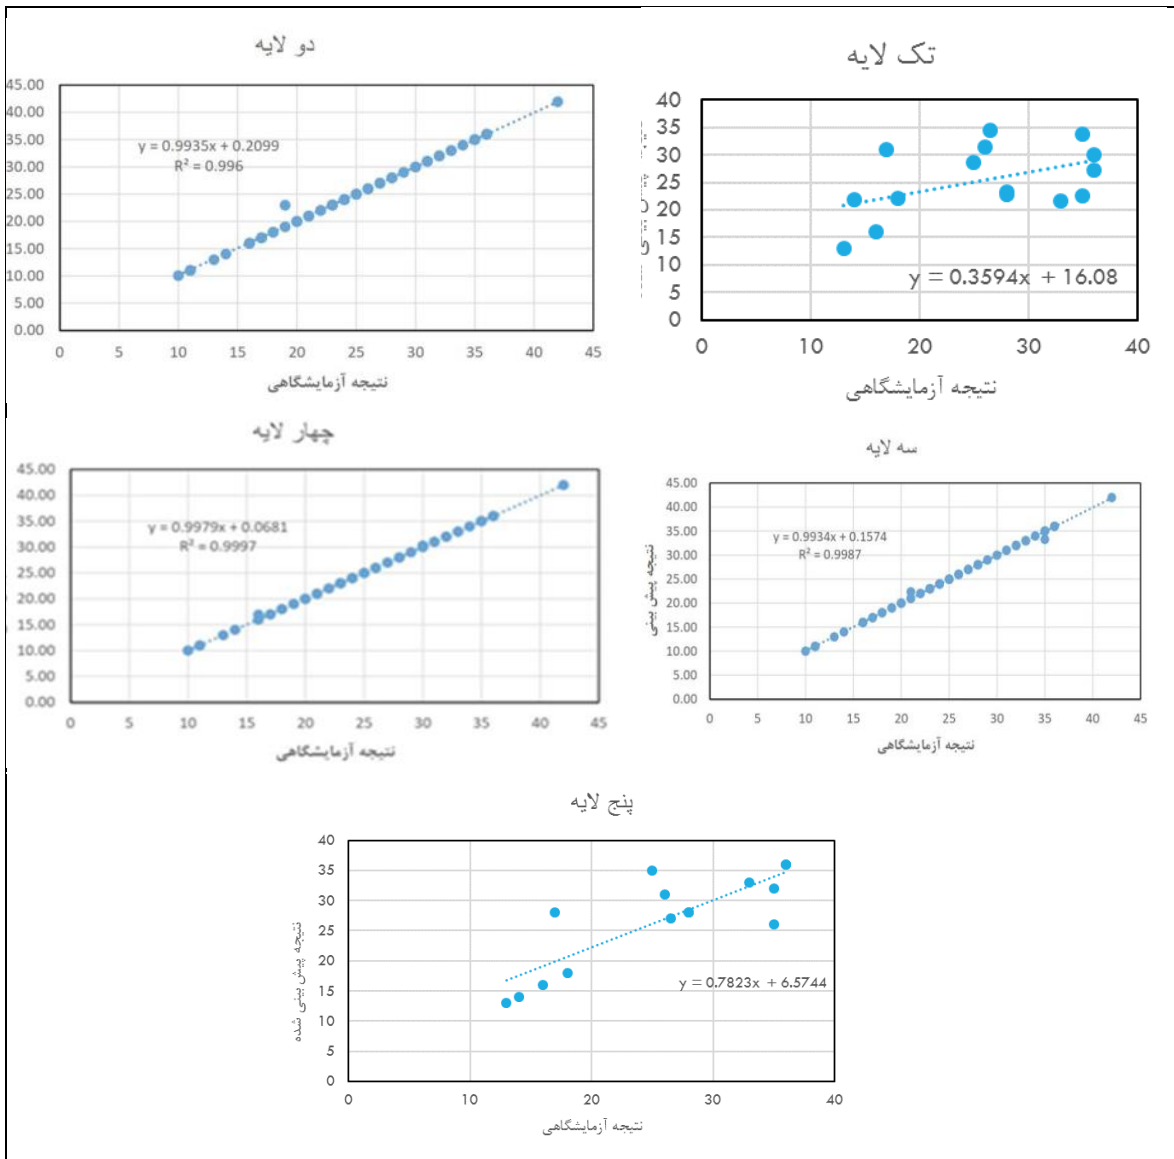
Nspt	C _u	q _u	γ _d	ω	G _s	%C	%M	%S	%G	LL	PL	PI	C _u	C _c
3	0.815	1.67	1.63	17.52	2.71	43.6	43.8	12.6	0	61	30	31	0.167	6
5	0.79	1.63	1.58	19.25	2.7	37.4	62.2	0.4	0	72	40	32	0.111	9
11	0.805	1.65	1.61	18.29	2.74	30.6	67.6	1.8	0	32	2	30	0.211	19
40	0.905	1.65	1.81	26.2	2.74	41.2	58.3	0.5	0	38	23	15	0.125	8
40	1.17	1.6	2.34	27.4	2.75	43.4	54.9	1.7	0	45	24	21	0.143	7
32	0.44	1.7	0.88	22.2	2.73	38.1	45.9	16	0	36	20	16	0.091	11
17	0.92	1.65	1.84	23.79	2.71	12.5	46.5	41	0	20	1	19	10.316	76
22	0.33	1.58	0.66	26.83	2.73	27.2	72	0.8	0	25	22	3	1.19	21
28	0.475	1.69	0.95	24.3	2.81	33.1	93.9	26.9	0.1	23	15	8	0.062	16
15	0.615	1.72	1.23	19.2	2.71	46.7	51.3	2	0	14	18	8	0.143	7
15	0.51	1.75	1.02	18.55	2.69	24.6	51.3	24.1	0	20	21	2	0.533	30
100	0.32	1.78	0.64	14.5	2.67	9.9	14.1	71.8	0.2	18	13	1	23.194	311.5
95	0.3	1.75	0.6	13.5	2.68	0	31.1	42.4	17	19	13	7	0.437	0
12	0.1	1.73	0.65	14.36	2.69	18	25.5	52.8	0.9	30	9	3	0.714	231
17	0.21	1.64	0.2	19.2	2.67	20.4	52.3	27.3	0	28	17	10	0.25	42

جدول ۹. مقادیر زاویه اصطکاک داخلی به دست آمده از آزمایش‌ها و مقایسه‌ی آن‌ها با پیش‌بینی‌های شبکه‌ی عصبی برای حالت‌های دو لایه، سه لایه، چهار لایه و پنج لایه

Table 9. Friction angle values obtained from experiments and their comparison with neural network predictions for two-layer, three-layer, four-layer and five-layer states

φ حاصل از آزمایش					φ حاصل از پیش‌بینی شبکه‌های عصبی	
-	تک‌لایه	دولایه	سه لایه	چهار لایه	پنج لایه	
16.00	16.15	16.00	16.00	16.00	16.00	
13.00	13.08	13.00	13.00	13.00	12.99	
36.00	30.04	36.00	36.00	36.00	36.00	
18.00	22.17	18.00	18.00	18.00	17.99	
14.00	21.80	14.00	14.00	14.00	13.98	
28.00	23.33	28.00	28.00	28.00	28.00	
26.50	34.46	27.00	27.00	27.00	27.00	
33.00	21.70	33.00	33.00	33.00	33.00	

36.00	36.00	36.00	36.00	27.21	36.00
28.00	28.00	28.00	28.00	22.82	28.00
32.01	35.00	35.00	32.00	33.70	35.00
31.00	26.00	26.00	31.00	31.51	26.00
28.00	17.00	17.00	28.00	30.93	17.00
34.99	25.00	25.00	35.00	28.67	25.00
26.00	35.00	35.00	26.00	22.55	35.00




شکل ۱۴. رگرسیون حاصل از زاویه اصطکاک داخلی به دست آمده از آزمایش‌های آزمایشگاهی و پیش‌بینی شبکه‌ی عصبی

Fig. 14. Regression of friction angle obtained from laboratory experiments and neural network prediction

جدول ۱۰. مقادیر چسبندگی به دست آمده از آزمایش‌ها و مقایسه‌ی آن‌ها با پیش‌بینی‌های شبکه‌ی عصبی برای حالت‌های دولایه، سه لایه، چهارلایه و پنج لایه

Table 10. Cohesion values obtained from experiments and their comparison with neural network predictions for two-layer, three-layer, four-layer and five-layer states

C حاصل از آزمایش						C حاصل از پیش‌بینی شبکه‌های عصبی					
						پنج لایه					
						چهار لایه					
						سه لایه					
						دو لایه					
						تکلایه					
						-					
						0.31	0.44	0.44	0.40	0.54	0.44
						0.28	0.22	0.21	0.23	0.50	0.22
						0.21	0.15	0.15	0.03	0.51	0.15
						0.18	0.13	0.13	0.17	0.47	0.13
						0.21	0.29	0.43	0.28	0.50	0.29
						0.21	0.19	0.18	0.12	0.49	0.19
						0.18	0.24	0.22	0.17	0.48	0.24
						0.17	0.17	0.17	0.07	0.48	0.17
						0.18	0.19	0.18	0.20	0.47	0.19
						0.19	0.29	0.30	0.27	0.50	0.29
						0.21	0.36	0.23	0.23	0.53	0.23
						0.22	0.21	0.20	0.20	0.46	0.21
						0.27	0.22	0.21	0.17	0.47	0.22
						0.30	0.24	0.21	0.17	0.50	0.24
						0.23	0.28	0.25	0.19	0.53	0.28



شکل ۱۵. رگرسیون حاصل از چسبندگی به دست آمده از آزمایش‌های آزمایشگاهی و پیش‌بینی شبکه‌ی عصبی

Fig. 15. Regression from cohesion obtained from laboratory experiments and prediction of neural network

جمع‌بندی و نتیجه‌گیری

در این پژوهش، از آزمایش‌های آزمایشگاهی و صحرایی برای تعیین خواص فیزیکی و مکانیکی خاک استفاده شد و نتایج آن برای ورود به شبکه آماده شد. در مراحل بعد، ۱۹۵ شبکه با ۱۵ ورودی و ۲ خروجی ساخته شد که هر یک ویژگی‌های متفاوتی داشتند (جدول ۳، ۴، ۵ و ۶). در این مطالعه ابتدا از شبکه پرسپترون پیش‌خور تک‌لایه و دو لایه با ۱۰ نورون برای مدل‌سازی استفاده شده است. سپس شبکه‌های ساخته شده پردازش و نتایج به دست آمده برای یافتن بهترین نتایج با یکدیگر مقایسه شدند. سپس بهترین توابع آموزشی، یادگیری عملگرا و یادگیری تطبیقی انتخاب و با استفاده از آن‌ها مدل سه لایه، چهار لایه و پنج لایه و تعداد نورون ۱۰، ۲۰، ۴۰، ۳۰، ۵۰ مدل شدند. برخی از داده‌های ورودی واقعی به دست آمده در آزمایشگاه برای ارزیابی عملکرد شبکه‌ها استفاده شدند. طبق نتایج به دست آمده، شبکه‌ی عصبی برای چسبندگی، در حالت چهار لایه در بهترین حالت قرار دارد و رگرسیون ۰/۹۹ را داده است. بعد از حالت ۴ لایه، حالت سه لایه با رگرسیون ۰/۹۸ بهترین نتایج را داده است، در نتیجه می‌توان گفت شبکه‌ی عصبی توانسته است رابطه‌ای خوبی بین داده‌های تجربی و عددی برقرار کند و

پیش‌بینی مناسبی انجام دهد. در بین بهترین نتایج به دست آمده، تابع آموزشی BR بیشترین فراوانی را در میان توابع آموزشی داشته است و ۶ مورد از توابع یادگیری عملگرا را تابع MSE تشکیل می‌دهد. در میان توابع یادگیری تطبیقی، تابع GD بیشترین فراوانی را دارد. بنابراین تابع BR، تابع MSE و تابع GD به ترتیب بهترین توابع آموزشی، یادگیری عملگرا و یادگیری تطبیقی برای این مسئله هستند.

قدردانی

نویسندگان قدردانی خود را از شرکت ژئوتکنیک تهران برای حمایت در انجام این پژوهش ابراز می‌دارند.

منابع

- شریفی، ج.، خامه چیان م.، غفوری م.، ۱۳۹۴. پیش‌بینی پتانسیل رمبندگی خاک‌های رمبنده از طریق شبکه‌های عصبی مصنوعی. مهندسی عمران مدرس. ۱۵(۱):۱۶۵-۱۵۵.
- کمک‌پناه ح.، یثربی، س.ش.، گلشنی، ع.ا.، ۱۳۹۴. کاربرد شبکه عصبی مصنوعی در پیش‌بینی رفتار تورمی خاک‌های رسی. مهندسی عمران مدرس. ۱۵: ۱۸۱-۱۹۰.
- مدنی اصفهانی، ن.، حیدری، ب.، ۱۳۸۹. برآورد پارامترهای چسبندگی و زاویه اصطکاک داخلی خاک‌های رسی دربرگیرنده مسیر پیشنهادی مونوریل کرمانشاه با استفاده از روش شبکه عصبی مصنوعی، پنجمین همایش ملی زمین‌شناسی و محیط‌زیست اسلامشهر، <https://civilica.com/doc/102033>
- مردی، س.م.، گنجعلیخان حاکمی، ف.، ۱۳۹۴. مدل‌سازی پتانسیل رمبندگی خاک با استفاده از شبکه عصبی مصنوعی مطالعه موردی خاک‌های منطقه غرب کرمان، کنفرانس ملی مهندسی عمران و محیط زیست، قزوین، <https://civilica.com/doc/410860>
- Abu-Farsakh, M.Y., 2004. Evaluation of consolidation characteristics of cohesive soils from piezocone penetration tests (No. FHWA/LA. 03/386). Louisiana Transportation Research Center.
- Abu-Farsakh, M.Y. and Titi, H.H., 2004. Assessment of direct cone penetration test methods for predicting the ultimate capacity of friction driven piles. *Journal of Geotechnical and geoenvironmental Engineering*, 130(9), pp.935-944.
- Baziar, M.H., Ghorbani, A., 2005. Evaluation of lateral spreading using artificial neural networks. *Soil Dynamics and Earthquake Engineering*, 25(1), pp.1-9.
- Cal, Y., 1995. Soil classification by neural network. *Advances in Engineering software*, 22(2), pp.95-97.
- Chan, W.T., Chow, Y.K., Liu, L.F., 1995. Neural network: an alternative to pile driving formulas. *Computers and geotechnics*, 17(2), pp.135-156.
- Choi, J., Oh, H.J., Lee, H.J., Lee, C. and Lee, S., 2012. Combining landslide susceptibility maps obtained from frequency ratio, logistic regression, and artificial neural network models using ASTER images and GIS. *Engineering geology*, 124, pp.12-23.
- Churchland, P. S., 1992. *The computational brain*, Cambridge, MA: MIT press.
- Das, M., Dey, A.K., 2018. Prediction of bearing capacity of stone columns placed in soft clay using ANN model. *Geotechnical and Geological Engineering*, 36, pp.1845-1861.
- Das, S.K., Basudhar, P.K., 2006. Undrained lateral load capacity of piles in clay using artificial neural network. *Computers and Geotechnics*, 33(8), pp.454-459.
- Dayhoff, J., 1994. *Neural network architectures: An introduction* VNR, USA.
- Ellis, G.W., Yao, C., Zhao, R., Penumadu, D., 1995. Stress-strain modeling of sands using artificial neural networks. *J. Geotech. Eng. ASCE* 121 (5), 429-435.
- Goh, A.T.C., 1995. Empirical design in geotechnics using neural networks. *Geotechnique*, 45(4), pp.709-714.

- Hagan M. T., 1995. Neural network design, PWS, USA.
- Kalinli, A., Acar, M.C., Gündüz, Z., 2011. New approaches to determine the ultimate bearing capacity of shallow foundations based on artificial neural networks and ant colony optimization. *Engineering Geology*, 117(1-2), pp.29-38.
- Kiefa, M.A., 1998. General regression neural networks for driven piles in cohesionless soils. *Journal of Geotechnical and Geoenvironmental Engineering*, 124(12), pp.1177-1185.
- Khaboushan, E.A., Emami, H., Mosaddeghi, M.R., and Astaraei, A.R., 2018. Estimation of unsaturated shear strength parameters using easily-available soil properties. *Soil and Tillage Research*, 184, pp.118-127.
- Khanlari, G.R., Heidari, M., Momeni, A.A., Abdilor, Y., 2012. Prediction of shear strength parameters of soils using artificial neural networks and multivariate regression methods. *Engineering Geology*, 131, pp.11-18.
- Lee, I.M., Lee, J.H., 1996. Prediction of pile bearing capacity using artificial neural networks. *Computers and geotechnics*, 18(3), pp.189-200.
- Lee, S.J., Lee, S.R., Kim, Y.S., 2003. An approach to estimate unsaturated shear strength using artificial neural network and hyperbolic formulation. *Computers and Geotechnics*, 30(6), pp.489-503.
- Mahmoud, M.A.A.N., 2013. Reliability of using standard penetration test (SPT) in predicting properties of silty clay with sand soil. *International Journal of Civil & Structural Engineering*, 3(3), pp.545-556.
- MATLAB help center, <https://ch.mathworks.com/>
- Shahin, M.A., Maier, H.R., Jaksa, M.B., 2004. Data division for developing neural networks applied to geotechnical engineering. *Journal of Computing in Civil Engineering*, 18(2), pp.105-114.
- Mohammadi, M., Fatemi Aghda, S.M., Talkhablou, M., Cheshomi, A., 2022. Prediction of the shear strength parameters from easily-available soil properties by means of multivariate regression and artificial neural network methods. *Geomechanics and Geoengineering*, 17(2), pp.442-454.
- Ni, S.H., Lu, P.C., Juang, C.H., 1996. A fuzzy neural network approach to evaluation of slope failure potential. *Computer-Aided Civil and Infrastructure Engineering*, 11(1), pp.59-66.
- Romero, S., Pamukcu, S., 1996. Characterization of granular material by low strain dynamic excitation and ANN. In *Uncertainty in the Geologic Environment: from Theory to Practice* (pp. 1134-1148). ASCE.
- Rosenblatt, F., 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), p.386.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1985. Learning internal representations by error propagation.
- Shahin, M.A. and Jaksa, M.B., 2006. Pullout capacity of small ground anchors by direct cone penetration test methods and neural networks. *Canadian Geotechnical Journal*, 43(6), pp.626-637.
- Sivakugan, N., Eckersley, J., Li, H., 1998. Settlement predictions using neural networks. *Australian Civil Engineering Transactions*, 40, pp.49-52.
- Teh, C.I., Wong, K.S., Goh, A.T.C., Jaritngam, S., 1997. Prediction of pile capacity using neural networks. *Journal of computing in civil engineering*, 11(2), pp.129-138.
- Kim, Y., Satyanaga, A., Rahardjo, H., Park, H., Sham, A.W.L., 2021. Estimation of effective cohesion using artificial neural networks based on index soil properties: A Singapore case. *Engineering Geology*, 289, p.106163.
- Zhang, C., Wang, X., Zou, X., Tian, J., Liu, B., Li, J., Kang, L., Chen, H., Wu, Y., 2018. Estimation of surface shear strength of undisturbed soils in the eastern part of northern China's wind erosion area. *Soil and Tillage Research*, 178, pp.1-10.
- Zhang, C., Wang, X., Zou, X., Tian, J., Liu, B., Li, J., Kang, L., Chen, H., Wu, Y., 2018. Estimation of surface shear strength of undisturbed soils in the eastern part of northern China's wind erosion area. *Soil and Tillage Research*, 178, pp.1-10.

Prediction of shear strength parameters of Bandar Abbas soils using artificial neural network

Habib Rahimi menbar¹, Mohammad Fathollahy^{2*}, Gholamreza Shoaie³

1. Phd. student, Department of Engineering geology, Faculty of science, Tarbiat modares University, Tehran, Iran
2. Assistant professor, Department of earth science, faculty of science, University of Kurdistan, Sanandaj, Iran
3. Assistant professor, Department of Engineering geology, Faculty of science, Tarbiat modares University, Tehran, Iran

Received: 23 Sep 2022

Accepted: 11 Dec 2022

Abstract

Shear strength parameters are important for assessing the stability of structures, and are costly to calculate using conventional methods. In this research, simple geotechnical techniques and artificial intelligence were used to calculate the angle of internal friction and soil cohesion without the need for more complex testing. To this end, intact samples from 14 boreholes in Bandar Abbas, which had undergone primary geotechnical testing and direct cutting, were selected and used to train neural networks. 195 networks were trained in in this research. To achieve the best performance, feedforward neural networks were first trained in single and double layer modes with a low number of neurons in the middle layer, and the TRAIN BR function was selected due to the high ratio of R (0.97). Then, by incorporating additional layers, the Median model was trained using configurations of 3, 4, and 5 layers, each with varying numbers of neurons in the intermediate layer (50, 40, 30, 20, and 10). The results show that the four-layer MLP network gives the best results, for this mode R training 1, the test R is 0.90 and the total R is 0.98. Finally, to validate the neural network, 15 samples were selected and the input parameters of the network were trained in the optimal states of 2, 3, and 4 layers, then the output of the network was evaluated. For cohesion prediction, the neural network in 4-layer mode ($R^2=0.99$) and 2, 3 and 4-layer networks ($R^2=0.99$) have the best output for the friction angle.

Keywords: Bandar Abbas, Geotechnical parameters prediction, Neural network.

Introduction

In general, for the direct calculation of soil shear strength parameters in the laboratory, the triaxial test (Mohammadi et al. 2022) and PMT or SPT in the field (Lee et al., 2003)) are used for direct calculation of soil shear parameters in the laboratory. Conducting direct tests to determine ϕ and c of soils requires a sufficient amount of suitable samples (damaged or intact). In addition, the preparation and transport of samples to the laboratory is costly and time consuming and requires specialized laboratory equipment (2018 Khaboushan, E.A., et al.). To calculate shear strength parameters, many experimental relationships have been presented using field tests. However, all these methods require

*Corresponding author: m.fathollahy@uok.ac.ir

DOI: <http://doi.org/10.22034/JEG.2022.16.3.1015261>

spending a lot of time and money and can be used practically used for specific regional soils with specific characteristics; therefore, researchers are always trying to predict these parameters in different ways, for example, some of them have estimated ϕ and c using the standard penetration test (Mahmoud, M.A.A.N., 2013).

In recent years, the use of computational intelligence has greatly advanced in solving problems that do not have a specific solution or cannot be solved by traditional methods. Because in some physical processes, many parameters have an effect, in addition, the existence of completely non-linear relationships between these parameters adds to the complexity of the issue.

Artificial Neural Network (ANN) has been used in many previous geotechnical studies. Many researchers have used ANN to calculate the bearing capacity of deep and shallow foundations.

Materials and Methods

The data of this research were collected from the geotechnical studies in Bandar Abbas in south of Iran. The research database includes the study data of 100 geotechnical tests conducted in 14 boreholes in Bandar Abbas city. In this research, the data of granulation tests, Atterberg limits (ASTM-D 4318 87), determination of specific gravity of solid grains (Gs) (ASTM-D 854-14), uniaxial test (ASTM-D2166), moisture percentage test (ASTM) -D851) and SPT test (for input data) and direct shear test (for output data) have been used to calculate soil shear strength parameters using artificial intelligence. The studied samples investigated were taken from boreholes ranging in depth from 1 to 70 meters. The samples were fine-grained soils mainly from clay with high pasty properties to silt with low pasty properties. Table 1 presents the statistical analysis of samples.

Table 1. Statistical analysis of results

parameter	unit	Max	Min	mean	SD	skewness	kurtosis
Nspt	N	100	1	33.72	27.92	-1.24	0.72
Cu	Kg/cm ²	1.17	0.09	0.43	0.23	-0.83	-0.35
γ_d	Kg/cm ³	2.1	1.45	1.68	0.09	-1.18	0.20
qu	Kg/cm ²	2.34	0.18	0.87	0.47	-0.83	-0.35
ω	-	31.4	7.96	20.05	3.71	-1.33	0.48
Gs	-	2.86	2.52	2.70	0.04	-0.11	4.47
%C	-	56.3	0	28.46	12.87	-1.18	0.75
%M	-	94.8	8.1	45.85	17.98	1.09	-0.21
%S	-	87.9	0	24.70	24.73	-0.68	-0.20
%G	-	26.5	0	1.17	3.93	-3.26	11.63
LL	-	72	10	27.51	10.69	-1.58	1.97
PL	-	40	1	17.57	6.46	-1.32	0.77
PI	-	32	1	9.94	6.62	-1.27	0.95
Cu	-	252	0	5.49	26.66	-5.36	30.06
CC	-	1187	0	71.24	143.10	-2.66	6.67

parameter	unit	Max	Min	mean	SD	skewness	kurtosis
C	Kg/cm ²	1.24	0	0.22	0.21	-2.03	4.20
φ	degree	42	10	25.49	6.92	-0.60	-0.75

Results and Discussion

In order to validate the results of neural networks, the values obtained for the internal friction angle and the actual values measured for the same values were checked. Also, the results obtained from the neural networks for adhesion and the actual values measured for the same values were obtained. Then, the regression between the values obtained from the experiments and the values obtained from the neural network for two-layer, three-layer, four-layer and five-layer states has been obtained for both outputs.

Results show, the neural network for cohesion is in the best state in the four-layer state and has given a regression of 0.99. After the 4-layer mode, the three-layer mode with a regression of 0.98 has given the best results. The results show that for the internal friction angle, all the two-layer and three-layer modes have a regression of 0.99.

Conclusions

In this research, laboratory and field tests were used to determine the physical and mechanical properties of the soil, and the results were prepared for input into the network. The next steps were to build 195 networks with 15 inputs and 2 outputs, each with different characteristics. In this study, single and double layer feedforward perceptron network with 10 neurons were used for modeling. Then the constructed networks were processed and the obtained results were compared with each other to find the best results. Then, the best educational functions, pragmatic learning and adaptive learning were selected and three-layer, four-layer and five-layer models were made using them and the number of neurons was 10, 20, 30, 40, 50. Some real input data obtained in the laboratory were used to evaluate the performance of the networks. According to the results obtained, the neural network was able to establish a good relationship between experimental and numerical data and to make a suitable prediction.