

بررسی رفتار مصالح شن‌دار در بارگذاری زه‌کشی نشده مونوتونیک با استفاده از شبکه‌های عصبی مصنوعی

عطا آقایی آرای؛ مرکز تحقیقات راه، مسکن و شهرسازی

پذیرش ۹۲/۴/۸

تاریخ: دریافت ۹۱/۸/۱

چکیده

امکان توسعه و به‌کارگیری شبکه‌های عصبی مصنوعی در مدل‌سازی نتایج آزمایش‌های مونوتونیک سه‌محوری قطر بزرگ روی انواع مصالح سنگ‌ریزه‌ای تیز گوشه، گرد گوشه و مصالح شنی با درصد‌های مختلف ریزدانه به‌کار رفته در بدنه سدهای مهم کشور در این مقاله ارائه می‌شود. در ابتدا قابلیت شبکه‌های عصبی مصنوعی (ANNs) در مدل‌سازی منحنی‌های رفتاری تنش-تفاضلی-اضافه فشار آب حفره‌ای- کرنش محوری بررسی شده است که دلالت بر قابلیت نسبتاً مناسب مدل در شبیه‌سازی رفتار مصالح شن‌دار دارد. بانک اطلاعات به‌کار رفته در شبکه، شامل ۵۲ گزینه مختلف آزمایش سه‌محوری کرنش-کنترل تحت شرایط زه‌کشی نشده است. برای مسئله مذکور، یک برنامه شبکه‌های عصبی مصنوعی پیش‌خوراند سه‌لایه پرسپترون (MLP) در محیط MATLAB7 نوشته شد و شبکه بهینه (تعداد لایه‌های مخفی، تابع تبدیل و نوع آموزش شبکه) به روش سعی و خطا، و با توجه به شاخص‌های خطا و تطابق با داده‌های آزمایشگاهی انتخاب شد. پارامترهای ورودی شبکه شامل تنش محدودکننده، دانسیته و درصد رطوبت بهینه، توزیع اندازه دانه‌ها و نرخ ایجاد کرنش است. نتایج نشان می‌دهد که ANN قابلیت بسیار مناسبی در تخمین منحنی‌های رفتاری یادشده در همه موارد بررسی شده دارد. در ادامه قابلیت شبکه‌های عصبی مصنوعی (ANNs) در به‌دست آوردن حداکثر زاویه اصطکاک داخلی و تناطی از منحنی‌های رفتاری شامل تنش‌های تفاضلی حداکثر و پسماند و اضافه فشارهای آب حفره‌ای در کرنش‌های نظیر بررسی شد. ضمناً از قابلیت تعمیم شبکه عصبی مصنوعی برای بررسی موارد آزمایش نشده مثل اثر تغییرات دانسیته و درصد کوچک‌تر از ۰/۲ mm هم بهره گرفته شد.

واژه‌ها کلیدی: مصالح سنگ‌ریزه‌ای، مونوتونیک، تحکیم‌یافته زه‌کشی نشده، سه‌محوری، ANN

* نویسنده مسئول aghaeiarai@bhrc.ac.ir

مقدمه

از مصالح شن‌دار به‌طور وسیع به‌عنوان مصالح ساخت در خاک‌ریزهای مهندسی و حتی برای حفاظت شالوده ساختمان در برابر رطوبت در مناطق با سطح آب زیرزمینی بالا (در مناطق شمالی کشور) استفاده می‌شود. از جمله مشکلات موجود در تحلیل رفتار مصالح شنی در کاربری‌های مذکور، عدم شناخت رفتار و هم‌چنین مشخص نبودن پارامترهای مقاومتی و تغییرشکلی مصالح با جنس‌های متفاوت، تحت بارگذاری مونوتونیک با توجه به محدودیت‌های هزینه زیاد انجام آزمایش‌ها، اندازه دانه‌ها برای وسایل آزمایش، تراکم و درصد ریزدانه است. پارامترهای مقاومتی و تغییرشکلی مصالح سنگ‌ریزه‌ای به عوامل مختلفی نظیر دانه‌بندی، درصد ریزدانه، سطح تنش شرایط زه‌کشی، سرعت بارگذاری و نسبت تخلخل اولیه بستگی دارد. از این رو، انجام آزمایش روی مصالح شنی و مدل‌سازی رفتار آن‌ها، پیش‌نیاز اساسی برای انجام تحلیل‌های واقعی و طراحی‌های اقتصادی سازه‌های خاک‌ریزه‌ای است. تعیین مقاومت برشی برجا کار مشکلی است، بنا بر این تأکید بر اندازه‌گیری مقاومت آزمایشگاهی نمونه‌هایی است که مجدداً بازسازی و متراکم شده‌است.

از طرفی پارامترهای مقاومتی و تغییرشکلی منظور شده در طراحی‌ها و آزمایش‌ها با آنچه که از نتایج کنترل کیفیت به‌دست می‌آید، تفاوت چشم‌گیری با یک‌دیگر دارند. به‌طوری‌که منحنی تنش- کرنش واقعی مصالح سنگ‌ریزه‌ای یا دانه‌ای (رفتار غیرخطی سخت و نرم کرنشی و زون برشی) با رفتار منظور شده در طراحی‌های معمولی (پلاستیک کامل، بدون در نظر گرفتن رفتار سخت‌شوندگی و نرم کرنشی) تفاوت‌های چشم‌گیری دارند. نکته بعدی تفاوت تنش تفاضلی حداکثر تحت شرایط تراکمی متفاوت است به‌طوری‌که مقادیر تفاضلی حداکثر با افزایش تراکم افزایش می‌یابد. با توجه به میزان تراکم، تغییرات زاویه اصطکاک متفاوت است. (به شرط عدم ایجاد زون برشی در نمونه، با افزایش میزان تراکم، مقادیر زاویه اصطکاک افزایش می‌یابد). بررسی‌های انجام شده روی رفتار ماسه Inagi تحت تنش محدودکننده ۵۰kPa در تراکم‌های مختلف تحت شرایط زه‌کشی نشده نشان داد که تفاوت‌های چشم‌گیری بین تنش تفاضلی حداکثر و پسماند تحت شرایط زه‌کشی شده و زه‌کشی نشده وجود دارد [۱۸]. در کل در تراکم بالا مقادیر تنش تفاضلی حداکثر در حالت زه‌کشی نشده، خیلی بیش‌تر

از مقادیر تنش تفاضلی پسماند در تراکم پایین است (شکل ۱). متأسفانه اطلاعات زیادی در مورد رفتارهای یاد شده برای مصالح شنی سنگ‌ریزه‌ای وجود ندارد.

عده‌ای از پژوهش‌گران سعی کرده‌اند تا پیش‌بینی رفتار مصالح برای حالت‌های واقعی انجام دهند [۲۱]، [۲۲]. مثلاً با انجام آزمایش سه‌محوری روی چندین نمونه با حداکثر اندازه دانه کوچک‌تر از حالت واقعی، منحنی تنش-کرنش نمونه با اندازه واقعی را به‌دست آوردند. روش‌های عددی مختلفی برای مدل‌سازی عددی رفتار مکانیکی نمونه‌های مصالح خاکی و سنگ‌ریزه‌ای به‌کار گرفته شده است [۵]، [۱۵]، [۱۹]، [۲۰]. هر یک از مدل‌های معرفی شده محدودیت‌هایی دارد و قادر به شبیه‌سازی کامل رفتار تنش-اضافه فشار آب حفره‌ای-کرنش محوری مصالح نیستند.

در همه روش‌های مدل‌سازی عددی (روش‌های تحلیلی، روش‌های عددی پایه، روش المان محدود، روش المان مرزی، روش المان مجزا، روش‌های هیبرید^۱، روش‌های عددی توسعه یافته و روش‌های تحلیل کاملاً توأم) سعی می‌شود مکانیزم ارتباط یک به یک در مدل بین نتایج ایجاد شود [۹]، [۱۰]. گاهی هدف یافتن رابطه مستقیم بین پارامترهای مدل، مکانیزم‌های فیزیکی و خواص معادل مصالح نیست، که در این مواقع روش‌های یاد شده در بالا چندان مفید نیستند. یافتن مکانیزم‌های ارتباط غیر یک به یک را می‌توان با استفاده از روش شبکه‌های عصبی مصنوعی انجام داد که در این روش، مکانیزم‌های تأثیرگذار، کاملاً به‌هم مرتبط نیستند. همچنین مدل‌های حاصل از شبکه‌های عصبی مصنوعی قابلیت‌های تخمین و تعمیم دارد و به‌همین دلیل در موضوعات مختلف خاک و پی در سال‌های اخیر به‌کار گرفته می‌شوند [۴]، [۱۴]. به‌طور کلی روش شبکه‌های عصبی مصنوعی روشی متفاوت اساسی برای مدل‌سازی رفتار خاک ارائه می‌دهد و برای ارائه منحنی‌های رفتاری ماسه‌ها [۳]، [۶]، [۱۲]، [۱۳] و شن‌ها [۱۳]، [۱۶] به‌کار گرفته شده‌است.

متأسفانه اطلاعات موجود در زمینه رفتار CU مصالح سنگ‌ریزه‌ای و شن‌دار حاصل از نمونه‌های سه‌محوری بزرگ مقیاس و مدل‌سازی آن‌ها بسیار اندک است. از این رو، برای داشتن روشی ساده و قابل اطمینان برای ارائه رفتار تنش تفاضلی-اضافه فشار آب حفره‌ای-کرنش محوری در آزمایش‌های سه‌محوری، روش ANNs بررسی می‌شود.

۱. Hybrid

برنامه آزمایش‌های مونوتونیک و مشخصات مصالح بررسی شده

بخشی از مشخصات مصالح بررسی شده در این تحقیق در جدول ۱ ارائه شده است. منحنی دانه‌بندی برای مصالح آزمایش شده در دستگاه سه‌محوری بزرگ مقیاس در شکل ۲ ارائه شده است. با توجه به اثرات چشم‌گیر درصد نمونه گذشته از الک $0/2\text{mm}$ بر رفتار نمونه خصوصاً در زمانی که از ۲۲٪ بیش‌تر می‌شود، نتایج همه آزمایش‌های مونوتونیک روی نمونه‌های شن‌دار آزمایش شده در بخش ژئوتکنیک و هم‌چنین نتایج آزمایش روی مصالح هسته سد مسجدسلیمان تحت دو سرعت بارگذاری ارائه شده است که در مجموع نتایج ۵۵ آزمایش مونوتونیک تحت شرایط زه‌کشی نشده ارائه می‌شود. آزمایش‌ها طبق استاندارد $ASTM D4767 [2]$ انجام شده است. محدوده تنش‌های محدودکننده در آزمایش‌ها، بر اساس محدوده‌های تنش فرضی در سدها انتخاب شده است. این نمونه‌ها با قطر ۲۰ یا ۳۰ سانتی‌متر و با ارتفاع ۴۰ یا ۶۰ سانتی‌متر تهیه و آزمایش شدند. جزئیات ساخت، اشیاع کردن ($B\text{-Value} \geq 95\%$) و تحکیم، روش آزمایش نمونه‌ها و دستگاه سه‌محوری قطر بزرگ در مقاله آقای آرای و همکاران [۱] ارائه شده است.

استفاده از شبکه عصبی مصنوعی برای تخمین نتایج آزمایش‌های مونوتونیک CU

نیاز به مدلی با قابلیت تعمیم و تخمین و عدم کارآرایی مناسب مدل‌های موجود در مدل‌سازی منحنی‌های تنش تفاضلی-اضافه فشار آب حفره‌ای در برابر کرنش محوری در حالت CU سبب شد که شبکه‌های عصبی مصنوعی برای مسئله مورد نظر برای تخمین منحنی‌های رفتاری و هم‌چنین نقاط مهم این منحنی‌ها شامل زاویه اصطکاک داخلی حداکثر، تنش تفاضلی حداکثر و تنش تفاضلی پسماند و اضافه‌فشار آب حفره‌ای در کرنش‌های محوری نظیر بررسی شود.

هم‌چنین از قابلیت تعمیم و تخمین شبکه عصبی مصنوعی برای بررسی رفتار مصالح با دانسیته‌های مختلف و اثر توزیع اندازه دانه‌ها بهره گرفته شد.

شبکه به کار رفته و بانک اطلاعاتی مدل

تعداد ۵۲ آزمایش مختلف سه محوری کرنش-کنترل مونوتونیک تحت شرایط زهکشی نشده (به غیر از مصالح ۲۰-C.MES) به عنوان بانک اطلاعات در نظر گرفته شد. در ابتدا مقادیر تنش تفاضلی-کرنش محوری و اضافه فشار آب حفره ای-کرنش محوری تا کرنش مرحله حالت پایدار با تغییرات جزء کرنش 0.3% پردازش و به کار رفته اند. در این پژوهش برای شرایط CU یک مجموعه فراگیر از نتایج نقاطی از منحنی های تنش تفاضلی- اضافه فشار آب حفره ای-کرنش محوری، مشتمل بر ۲۷۵۵ سطر اعداد برای آموزش (0.85%)، ارزیابی (0.10%) و آزمایش (0.05%) شبکه استفاده شده است. بررسی های آزمایشگاهی نشان داد که مشخصات تغییرشکلی مصالح شن دار متأثر از تنش محدودکننده مؤثر اولیه، دانسیته، درصد رطوبت بهینه، توزیع اندازه دانه ها، سرعت بارگذاری است. از بانک اطلاعاتی ارائه شده در جدول ۲ که شامل پارامترهای ورودی و خروجی مدل ها است استفاده شد. در این بررسی، تنش محدودکننده مؤثر σ'_3 ، جزء کرنش در مرحله n ($\Delta \epsilon_n$)، کرنش محوری (ϵ_{1n})، دانسیته (γ_d)، درصد رطوبت (w)، درصد گذشته از الک های 0.075 ، 0.25 ، 0.425 ، 0.75 و 2.0 میلی متر، سرعت بارگذاری، مقدار فعلی تنش تفاضلی-کرنش محوری (q_n) و مقدار فعلی اضافه فشار آب حفره ای-کرنش محوری (u_n) به عنوان پارامترهای ورودی در نظر گرفته شد. مدل به کار رفته در این مقاله شامل دو خروجی ساده MLPs است. خروجی های MLPs حالت های بعدی تنش تفاضلی-کرنش محوری (q_{n+1}) و اضافه فشار آب حفره ای-کرنش محوری (u_{n+1}) هستند. شبکه برای تخمین منحنی های رفتاری تنش تفاضلی-کرنش محوری و اضافه فشار آب حفره ای-کرنش محوری به ترتیب $netq$ و $netu$ نامیده می شوند. مرزهای ورودی ها و خروجی ها برای $netu$ و $netq$ در جدول ۳ ارائه شده است.

یک مدل شبکه عصبی مصنوعی پیش خوراند سه لایه پرسپترون با توابع تحریک تانژانت زیگموئید^۱ برای لایه میانی و خطی^۲ برای لایه خروجی با تعدادی مناسبی نرون در لایه مخفی که طبق بررسی های هورنیک^۳ و همکاران [۸] برای تقریب سازی هر رابطه غیرخطی مناسب است برای تخمین مقادیر تنش تفاضلی- اضافه فشار آب حفره ای-کرنش محوری نظیر مصالح مختلف نوشته و توسعه داده شد. در نتیجه یک لایه مخفی در این بخش از بررسی های به کار

۱. Tansig ۲. Pureline ۳. Hornik

گرفته شد. از برنامه نوشته شده در محیط متلب^۱ برای پیاده کردن، آموزش و آزمایش شبکه استفاده شد.

آموزش شبکه به روش الگوریتم (LM)^۲ انجام گرفت. برای به‌کارگیری این الگوریتم، روش آموزش استاتیکی مورد توجه قرار گرفت. مثلاً مقادیر حالت تنش آزمایشگاهی واقعی به شبکه برای تولید حالت‌های تنش بعدی خورانده شدند. در نوشتن برنامه از تکنیک‌های مخلوط کردن تصادفی داده‌ها و نرمال کردن داده‌های ورودی و خروجی، یعنی تقسیم همه اعداد یک سطر یا ستون را بر حداکثر آن سطر یا ستون و تولید اعدادی بین صفر و یک، برای جلوگیری از آموزش‌های غیرمعمول و وزن‌دهی نامناسب استفاده شده است. میزان یادگیری شبکه ۰/۰۱ در نظر گرفته شده است.

MLPs آموزش داده شده، منحنی‌های تنش کرنش را تا سطح کرنش حداکثر ۲۰٪ تولید می‌کند. این عمل به‌آسانی با شروع حالت آزاد تنش-کرنش ($\epsilon_{1(0)} = 0$ ، $q_0 = 0$ و $u_0 = 0$) و به‌کارگیری MLPs برای تخمین حالت تنش مرحله بعد انجام می‌شود. سپس این حالت به شبکه برای تولید دیگر حالت‌های تنشی و اضافه فشار آب حفره‌ای که ورودی‌هایی برای تقریب حالت‌های جدید تنش و اضافه فشار آب حفره‌ای هستند، پس‌خور می‌شوند.

برای تخمین نقاط مهم منحنی‌های رفتاری چون تنش تفاضلی حداکثر و پسماند و اضافه فشارهای آب حفره‌ای نظیر، از نتایج ۵۲ آزمایش CU مختلف برای آموزش (۸۵٪)، ارزیابی (۱۰٪) و آزمایش (۵٪) و از شبکه‌ای با نام netCU استفاده شده است. مدل به‌کار رفته در این مقاله شامل شش ورودی و شش خروجی ساده MLPs است. از بانک اطلاعاتی ارائه شده در جدول‌های ۴ و ۵ استفاده شده است که به‌ترتیب شامل پارامترهای ورودی و خروجی‌های مدل است.

پارامترهای ورودی مدل شامل تنش محدودکننده مؤثر، دانسیته، رطوبت بهینه و درصد گذشته از الک‌های ۲۵/۴، ۴/۷۵ و ۰/۲ میلی‌متر است. خروجی‌های MLPs شامل q_{max} ، زاویه اصطکاک داخلی/اضافه فشار آب حفره‌ای در کرنش محوری نظیر، $q_{residual}$ و اضافه فشار آب حفره‌ای نظیر هستند. مرزهای ورودی‌ها و خروجی‌ها در انتهای جدول‌های ۴ و ۵ ارائه شده است. مشخصات شبکه عصبی و روش آموزش مشابه حالت قبل است.

۱. MATLAB7

۲. Levenberg-Marquardt

ارزیابی مدل

برای مقایسه عمل‌کرد شبکه‌ها با نرون‌های میانی متفاوت، از ۵ شاخص خطا: میانگین قدرمطلق خطا (MAE)، میانگین خطا (MBE)، مربع میانگین خطا (MSE)، مربع مجذور میانگین خطا (RMSE) و ضریب هم‌بستگی (IOA) استفاده شده است. انتخاب تابع تحریک و ساختار شبکه‌ها و تعداد تکرار با سعی و خطا تعیین شد. در قدم اول خطای شبکه‌ها با تعداد نرون‌های میانی متفاوت در مقابل مجموعه ارزیابی، برآورد شد که به‌عنوان نمونه در شکل ۳ الف و ب، به‌ترتیب شاخص‌های خطا MSE و IOA در برابر تعداد لایه‌های مخفی میانی برای netCU ارائه شده است. دیده می‌شود که netCU با ۷ نرون میانی، کم‌ترین میزان خطا را دارد. شکل ۴ کاهش خطا با افزایش تعداد سبکل netCU در محیط MATLAB را نشان می‌دهد. در برنامه نوشته شده netCU تعداد تکرار مناسب ۲۰۰ بار به‌دست آمد. برای انتخاب دقیق‌تر شبکه سایر شاخص‌ها کنترل خطا برای داده‌های آموزشی و آزمایشی نیز ارزیابی شده است. با توجه به عمل‌کرد شبکه مورد نظر در برابر داده‌های آموزشی، آزمایشی و ارزیابی، در نهایت شبکه با ۷ نرون میانی به‌علت داشتن قدرت پیش‌بینی بهتر و میزان خطای کم‌تر به‌عنوان مدل نهایی netCU انتخاب شده است. جدول ۶ مقادیر MAE، MSE، MBE، RMSE و IOA برای شبکه netCU با ۷ نرون میانی را نشان می‌دهد. تعداد ۱۱ و ۱۳ مقادیر بهینه نرون در لایه مخفی به‌ترتیب برای شبکه‌های netu و netq بر اساس شاخص‌های خطا است و تعداد تکرار برای آموزش شبکه‌ها ۴۰۰۰ بار به‌دست آمد. جدول ۷، اندازه‌گیری خطای مدل‌های netu و netq را برای مقادیر بهینه نرون ارائه می‌دهد. مقادیر IOA برای هر سه مجموعه برای شبکه‌ها بیش از ۰/۸ است که طبق توضیحات اسمیت [۱۷]، برای IOA بیش از ۰/۸، مدل ارائه شده قابلیت تخمین بسیار مناسب نتایج را در محدوده داده‌های موجود در کاتولوک دارد.

شکل ۵ به‌صورت نمونه مقایسه مقادیر حاصل از آزمایش‌ها با مقادیر حاصل از ANN برای تنش تفاضلی (q) را نشان می‌دهد که انطباق نسبتاً خوبی بین نتایج وجود دارد. شکل ۶ و جدول ۸ مقایسه نتایج آزمایش‌ها با نتایج تحلیل‌ها با شبکه‌های عصبی netq و netu مصالح ADBS1 در تنش محدودکننده ۴۰۰ kPa، مصالح C.K در تنش محدودکننده ۶۰۰ kPa و شده شبکه عصبی از قابلیت نسبت مناسبی در تخمین منحنی‌های تنش تفاضلی/اضافه فشار

آب حفره‌ای در برابر کرنش محوری برخوردار است. شکل ۷ مقادیر پارامترهای محاسبه شده آزمایش‌های سه محوری را با نتایج حاصل از شبکه عصبی مصنوعی را نشان می‌دهد که انطباق بسیار خوبی بین نتایج وجود دارد. از این رو، پس از تربیت شبکه با دادن تعدادی پارامتر به مدل، مقادیر تنش تفاضلی حداکثر و پسماند و اضافه فشار آب حفره‌ای نظیر به آسانی محاسبه می‌شود. ضمناً می‌توان از قابلیت تعمیم شبکه عصبی در پیش بینی موارد بررسی نشده هم بهره گرفت.

وزن هر یک از نرون‌های مخفی، وزن پارامترهای خروجی و توارش (Bias) آن‌ها در جدول ۹ به صورت نمونه برای شبکه netq ارائه شده است که از این طریق می‌توان فرمولی برای محاسبه نقاطی از منحنی‌های تنش تفاضلی-اضافه فشار آب حفره‌ای-کرنش محوری در شرایط CU، ارائه کرد. برای مسئله مورد نظر رابطه بین خروجی و سایر پارامترهای ورودی بدین صورت به دست می‌آید:

$$\text{Output} = \text{pureline}(w_2(\text{tansig}(w_1 * \text{TestDataIn}) + b_1) + b_2) \quad (1)$$

w_1 و w_2 ماتریس‌های وزن به ترتیب برای نرون‌های مخفی لایه میانی و خروجی، b_1 و b_2 ماتریس‌های وزن به ترتیب برای لایه مخفی میانی و توارش (Bias) لایه خروجی است. باید ذکر شود که فرمول بالا تابعی تقریب برای محاسبه مقادیر منحنی‌های تنش تفاضلی-فشار آب حفره‌ای-کرنش محوری در نقاط بررسی شده است.

نتایج تحلیل حساسیت

چنان‌که ذکر شد با وجود عمل‌کرد مناسب روی داده‌های موجود، مدل‌های شبکه عصبی مصنوعی هیچ‌گونه اطلاعاتی راجع به نحوه اثر ورودی‌ها بر روی خروجی‌ها ارائه نمی‌دهند. از این رو آن‌ها را به عنوان مدل‌های دسته جعبه سیاه نام می‌برند. به همین سبب، برای تأیید عمل‌کرد چنین مدل‌هایی به علاوه دقت اندازه‌گیری مدل شبکه عصبی بر اساس داده‌های موجود، حساسیت ورودی بر مبنای مشتق جزئی مرتبه اول بین متغیر خروجی شبکه عصبی مصنوعی و پارامترهای ورودی با عبارت ریاضی (مشابه تحلیل رگرسیون) تعریف می‌شود [۳]، [۷]، [۱۱]. به همین سبب، در تحلیلی حساسیت میزان درستی قابلیت تخمین مدل شبکه عصبی مصنوعی برای استخراج قوانین حاکم از مدل پیشنهادی برای تأیید دانش ذخیره شده امتحان

می‌شود. با توجه به اثرات چشم‌گیر دانسیته و درصد دانه کوچک‌تر از $0/2\text{mm}$ بر رفتار مصالح و عدم بررسی آزمایشگاهی آن‌ها، این دو پارامتر در ادامه بررسی می‌شود.

اثر تغییرات دانسیته

با توجه به محدوده داده‌های موجود، تحلیل حساسیت روی نتایج آزمایش‌های CU روی مصالح با درصد‌های مختلف ریزدانه و تنش‌های محدود کننده مختلف از جمله BAA1 در تنش محدود کننده $300, 100$ و 700 kPa صورت گرفته است. در شکل ۸ نتایج تحلیل حساسیت اثر دانسیته بر زاویه اصطکاک داخلی حداکثر، تنش تفاضلی-اضافه فشار آب حفره‌ای در کرنش محوری نظیر تنش تفاضلی حداکثر و مقاومت پسماند و هم‌چنین زاویه اصطکاک داخلی حداکثر و مقایسه آن‌ها با نتایج آزمایش‌ها نشان داده شده است. این نتایج نشان می‌دهد که مدل شبکه عصبی مصنوعی در تخمین نتایج قابلیت مناسبی دارد. راست آزمایی این نتایج، نیاز به انجام آزمایش و داده‌های بیش‌تر دارد.

در شکل ۹ به صورت نمونه روند کلی تغییرات تنش تفاضلی اندازه‌گیری شده در کرنش محوری نظیر تنش تفاضلی حداکثر و مقاومت پسماند در برابر دانسیته در تنش‌های محدودکننده مختلف برای همه مصالح بررسی شده ارائه شده است. به‌طورکلی روند تغییرات تخمین زده شده تنش تفاضلی با دانسیته (شکل ۹) با روند تغییرات اندازه‌گیری شده آن‌ها به‌وسیله شبکه‌های عصبی (شکل ۸) هم‌خوانی دارد.

اثر تغییرات درصد کوچک‌تر از $0/2\text{ mm}$

با توجه به محدوده داده‌های موجود، تحلیل حساسیت روی نتایج آزمایش‌های CU روی مصالح BAA1 در تنش محدود کننده 100 و 700 kPa با تمرکز بر تغییرات درصد کوچک‌تر از $0/2\text{ mm}$ صورت گرفته است که در شکل ۱۰ نتایج تحلیل حساسیت اثر درصد کوچک‌تر از $0/2\text{ mm}$ بر تنش تفاضلی-اضافه فشار آب حفره‌ای در کرنش محوری نظیر تنش تفاضلی حداکثر و مقاومت پسماند و هم‌چنین زاویه اصطکاک داخلی حداکثر و مقایسه آن‌ها با نتایج آزمایش‌ها نشان داده شده است. علت محدود کردن درصد کوچک‌تر از $0/2\text{ mm}$ به 37 درصد رعایت نظم حاکم بر دانه‌بندی است. زیرا حداکثر درصد گذشته از الک

بزرگ‌تر از آن یعنی $6/75 \text{ mm}$ برابر با ۳۷ درصد است. این نتایج نشان می‌دهد که مدل شبکه عصبی مصنوعی قابلیت مناسبی در تخمین نتایج دارد.

در شکل ۱۱ روند کلی تنش تفاضلی اندازه‌گیری شده در کرنش محوری نظیر تنش تفاضلی حداکثر و مقاومت پسماند در برابر درصد کوچک‌تر از $0/2 \text{ mm}$ در تنش محدود کننده مختلف برای مصالح مورد بررسی ارائه شده است. به‌طور کلی با افزایش درصد گذشته از اندازه $0/2 \text{ mm}$ روند کلی تغییرات تنش تفاضلی کاهش یافته است. روند تغییرات پارامترهای تخمین زده شده به‌وسیله شبکه‌های عصبی برای پارامترهای مختلف (شکل ۱۰) با روند تغییرات اندازه‌گیری شده آن‌ها (شکل ۱۱) هم‌خوانی دارد.

شکل ۱۲ نتایج تحلیل حساسیت اثر درصد کوچک‌تر از $0/2 \text{ mm}$ اضافه فشار آب حفره‌ای در کرنش محوری نظیر تنش تفاضلی حداکثر مصالح BAA1 در تنش محدود کننده 100 و 700 kPa و مقایسه آن‌ها با نتایج آزمایش‌ها در تنش‌های محدودکننده 200 – 100 و 700 – 600 kPa مصالح مختلف را نشان می‌دهد.

به‌نظر می‌رسد روند اضافه فشار آب حفره‌ای اندازه‌گیری شده تا حدی از درصد کوچک‌تر از $0/2 \text{ mm}$ کاهش یافته و سپس افزایش یافته است. از این رو، برای بررسی تغییرات اضافه فشار آب حفره‌ای به دانسیته نمونه هم باید توجه داشت.

جمع‌بندی و نتیجه‌گیری

بررسی ادبیات فنی نشان می‌دهد که نتایج موجود در مورد رفتار زه‌کشی نشده مصالح شن‌دار با توجه به تغییرات درصد ریزدانه و میزان تراکم، بسیار اندک است. مهم‌ترین نتایج مدل‌سازی آزمایش‌های CU با استفاده شبکه‌های عصبی مصنوعی بدین شرح است:

- مدل شبکه عصبی مصنوعی پیش‌خوراند سه لایه پرسپترون با توابع تحریک تاوانت زیگموئید برای لایه میانی و خطی برای لایه خروجی با تعدادی مناسبی نرون در لایه مخفی برای تخمین مقادیر تنش تفاضلی- اضافه فشار حفره‌ای- کرنش محوری نظیر مصالح شن‌دار مناسب است.
- براساس نتایج ارائه شده، روش ANNs در شبیه‌سازی و تخمین منحنی‌های تنش تفاضلی- اضافه فشار آب حفره‌ای- کرنش محوری مصالح قابلیت مناسبی دارد. هم‌چنین

نقاط مهم این منحنی‌ها شامل تنش تفاضلی حداکثر و پسماند و اضافه فشارهای آب حفره‌ای در کرنش نظیر مورد دارد.

- مطابق نتایج مدل‌سازی با ANN روند مقادیر تنش تفاضلی حداکثر و اضافه فشار آب حفره‌ای با افزایش دانسیته در مصالح مختلف متفاوت است. مثلاً در مصالح با درصد ریزدانه کم، افزایش دانسیته سبب افزایش تنش تفاضلی حداکثر و کاهش اضافه فشار آب حفره‌ای می‌شود که با نتایج آزمایش‌های موجود در این پژوهش هم‌خوانی دارد.
- براساس نتایج تحلیل حساسیت با ANN، اثر افزایش درصد گذشته از الک $0/2 \text{ mm}$ سبب کاهش تنش تفاضلی و افزایش اضافه فشار آب حفره‌ای در مصالح شن دار می‌شود.
- نتایج نشان داد که مدل شبکه‌های عصبی در شرایط CU قابلیت تعمیم و تخمین خوبی دارد. ضمناً می‌توان از قابلیت تعمیم شبکه عصبی مصنوعی برای موارد بررسی نشده هم بهره گرفت. ضمناً با توجه به تعداد اندک داده‌ها، قابلیت تعمیم و تخمین ارائه شده در خارج از محدوده داده‌های کاتالوگ نیاز به راست آزمایی دارد.

قدردانی

از بخش ژئوتکنیک مرکز تحقیقات راه، مسکن و شهرسازی که داده‌های پایه این تحقیق از آن‌جا فراهم شد تقدیر و تشکر می‌گردد.

منابع


1. Aghaei Araei. A., Soroush A., Hashemi Tabatabaei S., Ghalandarzadeh A., "Consolidated Undrained Behavior of Gravelly Materials", Scientia Iranica, under press (2012).
2. ASTM D4767, "Standard test method for consolidated undrained triaxial compression test for cohesive soils" (2004).
3. Banimahd M., Yasrobi S. S., Woodward P.K., "Artificial Neural Network for Stress-strain Behavior of Soils: Knowledge based verification", Computers and Geotechnics, ELSEVIER, 32 (2005) 377-386.

4. Baziar M. H., Jafarian Y., "Assessment of Liquefaction Triggering using Strain Energy Concept and ANN Model: Capacity Energy, Soil Dynamics and Earthquake Engineering", Vol. 27 (2007) 1056-1072.
5. Duncan J. M., Chang C. Y., "Nonlinear Analysis of Stress and Strain in Soils", Journal of the Soil Mechanics and Foundation Division, ASCE, 96, SM5, Proceedings, Paper 7513, (1970) 1629-1653.
6. Ellis G. W., Yao C., Zhao R., Penumadu D., "Stress-strain Modeling of Sands using Artificial Neural Networks", ASCE J Geotech Eng., Vol.121 (5) (1995) 429-35.
7. Hashem S. "Sensitivity Analysis for Feedforward Artificial Neural Networks with Differentiable Activity Functions", International conference on neural network, Baltimore: IEEE, Vol. 1 (1993) 419-429.
8. Hornik K. M., Stinchcombe M., White H., "Multi-layer Feedforward Networks are Universal Approximator", Neural Networks, Vol. 2(5) (1994) 359-366.
9. Jing L., Hudson J. A., "Numerical Methods in Rock Mechanics", Int. J. Rock Mech. Mining Sci., 39 (2002) 409-427.
10. Jing L., "A Review of Techniques, Advances and Outstanding Issues in Numerical Modeling for Rock Mechanics and Rock Engineering", Int. J. Rock Mech. Mining Sci., 40 (2003) 283-353.
11. Lu M., AbouRizk S. M., Hermann U. H., "Sensitivity Analysis of Neural Networks in Spool Fabrication Productivity Studies", ASCE J Comp Civil Eng, Vol.15(4) (2001) 299-308.
12. Najjar Y., Zhang X. C., "Characterizing the 3D Stress-Strain Behavior of Sandy Soils: a Neuro Mechanistic Approach", In: Filz GM, Griffiths DV, editors, Numerical methods in geotechnical engineering; Geotechnical Special Publications, No. 96, ASCE (2000) 43-57.


13. Penumadu D., Zhao R., "Triaxial Compression Behavior of Sand and Gravel using Artificial Neural Networks (ANN)", *Comput Geotech.*, 24 (1999) 207-230.
14. Sakellariou M. G., Ferentinou, M. D., "A Study of Slope Stability Prediction using Neural Networks", *Geotechnical and Geological Engineering*, 23 (2005) 419-445.
15. Salim W., Indraratna B., "A new Elastoplastic Constitutive Model for Coarse Granular Aggregates Incorporating Particle Breakage", *Can. Geotech. J.*, 41 (2004) 657-671.
16. Shahin M. A., Indraratna B., "Modeling the Mechanical Behavior of Railway Ballast using Artificial Neural Networks", *Can. Geotech. J.*, 43 (2006) 1144-1152.
17. Smith G. N., "Probability and statistics in civil engineering", London: Collins (1986).
18. Tatsouka F., "Importance of High Backfill Compaction for Better Performance of Soil Structure", TC29 meeting, ISSMGE, 7th October (2009) Alexandria, Egypt.
19. Varadarajan A., Sharama K. G., Venkatachalam K., Gupta A. K., "Testing and Modeling two Rockfill Materials", *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, March (2003) 206-218.
20. Varadarajan A., Sharma K. G., Abbas S. M., Dhawan A. K., "Constitutive Model for Rockfill Materials and Determination of Material Constants", *International journal of Geomechanics*, ASCE / July/August (2006) 226-237.
21. Varadarajan A., Sharma K. G., Abbas S.M., Dhawan A. K., "The Role of Nature of Particles on the Behavior of Rockfill Materials, Vol. 46 (5) (2006) 569-584.

22. Venkatachalam K., "Prediction of Mechanical Behavior of Rockfill Materials", PhD thesis, Indian Institute of Technology, Delhi, India (1993).


پیوست‌ها و ضمائم:



شکل ۱. تغییرات تنش تفاضلی حداکثر و پسماند با میزان تراکم ماسه Inagi IV تحت تنش محدودکننده 50 kPa در تراکم‌های مختلف تحت شرایط زه‌کشی نشده (اصلاح شده [۱۸])



شکل ۲. دانه‌بندی مصالح آزمایش شده در آزمایش‌های سه محوری قطر بزرگ




(ب)

(الف)


شکل ۳. شاخص‌های خطا در برابر تعداد لایه‌های مخفی میانی برای netCU (الف) MSE، (ب)

IOA

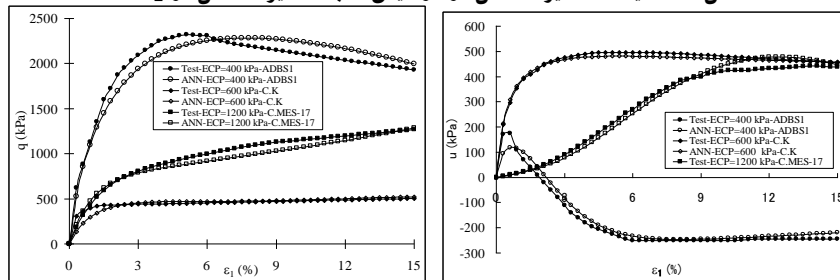


شکل ۴. کاهش خطا با افزایش تعداد سیکل برای مدل نوشته شده با استفاده از ANN در محیط

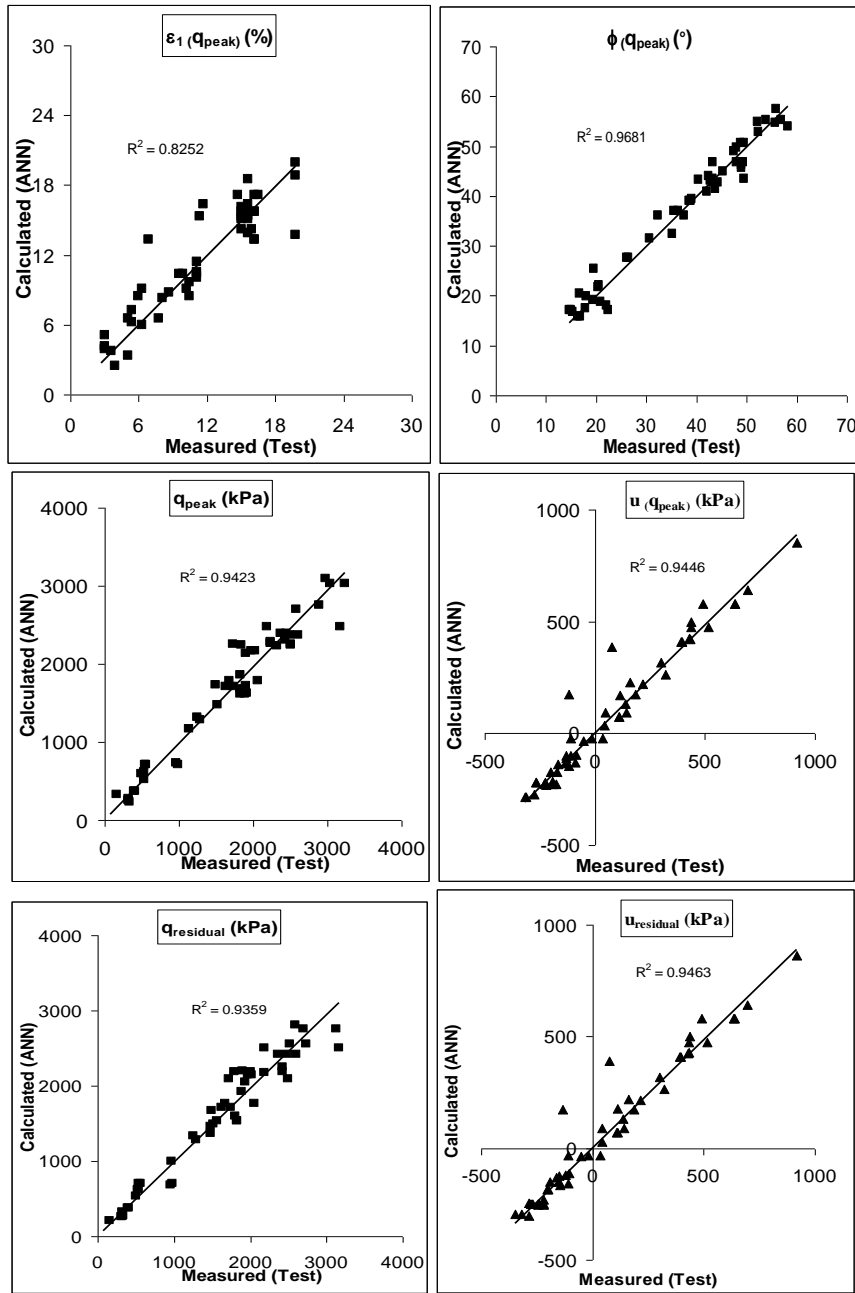
netCU برای MATLAB



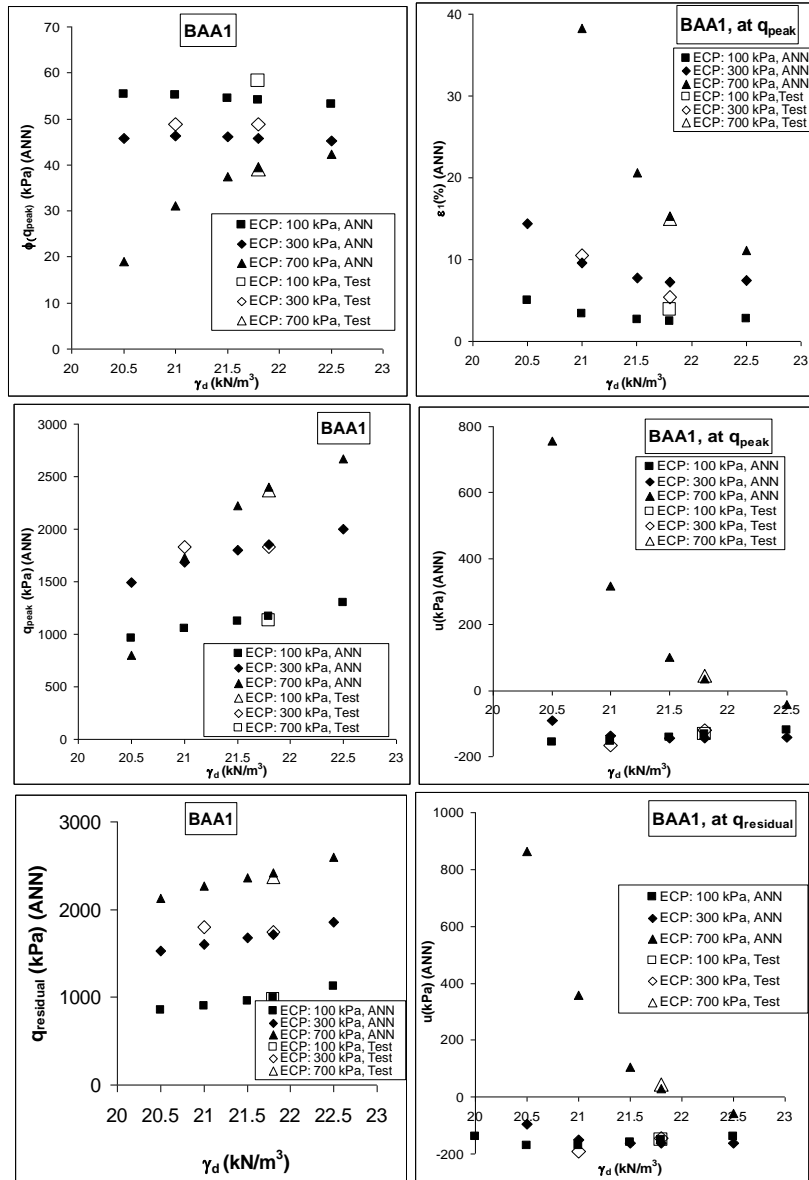
شکل ۵. مقایسه مقادیر حاصل از آزمایش‌ها با مقادیر حاصل از netq




شکل ۶. مقایسه نتایج آزمایش‌ها با نتایج تحلیل‌ها با شبکه‌های عصبی netq و netu مصالح ADBS1 در تنش محدود کننده ۴۰۰ kPa، مصالح C.K در تنش محدود کننده ۶۰۰ kPa و مصالح C.MES-17 در تنش محدود کننده ۱۲۰۰ kPa



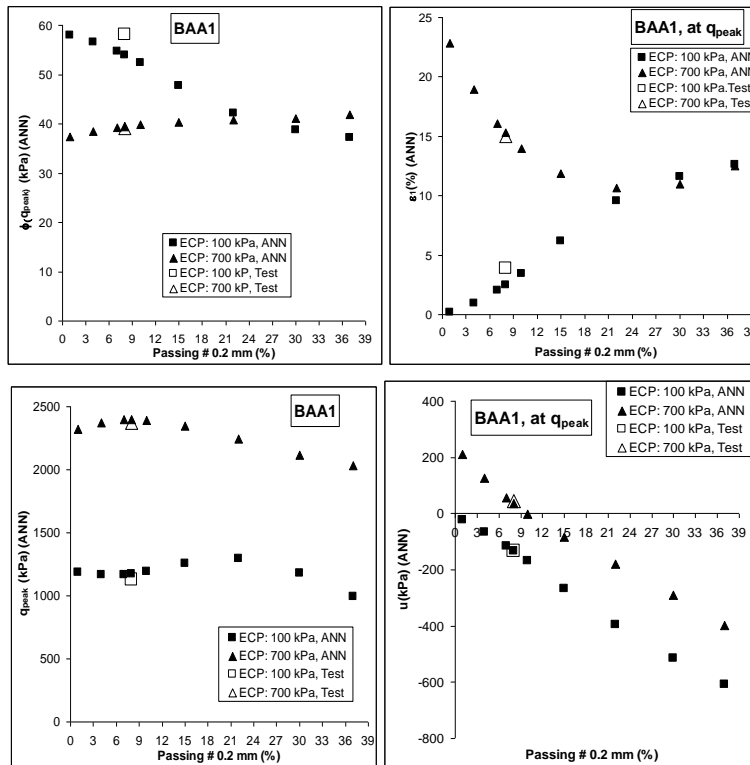
شکل ۷. مقایسه مقادیر حاصل از آزمایش‌ها با مقادیر حاصل از netCU

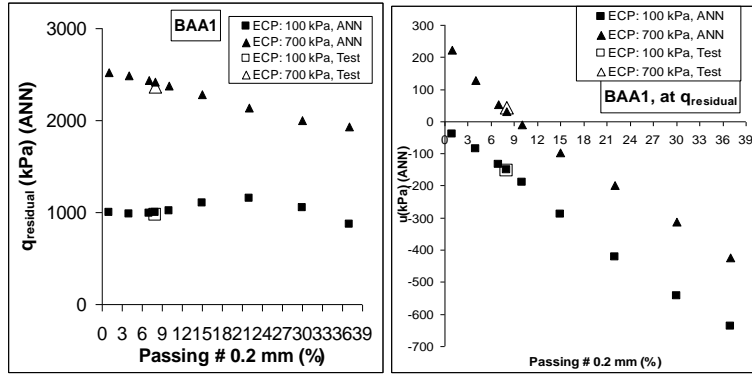


شکل ۸. نتایج تحلیل حساسیت اثر دانسیته بر زاویه اصطکاک داخلی حداکثر، تنش تفاضلی-اضافه فشار آب حفره ای در کرنش محوری نظیر تنش تفاضلی حداکثر و مقاومت پسماند مصالح BAA1 در تنش محدود کننده ۱۰۰،۳۰۰ و ۷۰۰ kPa حاصل از netCU و مقایسه آنها با نتایج آزمایش ها

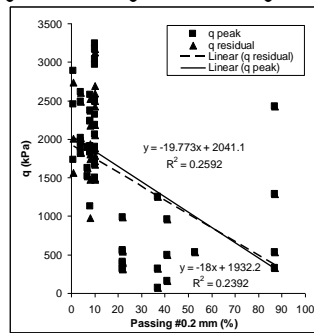


شکل ۹. تغییرات تنش تفاضلی اندازه‌گیری شده در کرنش محوری نظیر تنش تفاضلی حداکثر و مقاومت پسماند در برابر دانسیته در تنش‌های محدودکننده مختلف برای همه مصالح بررسی شده



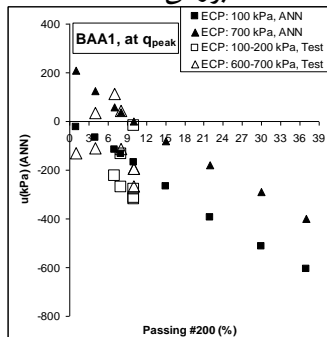


شکل ۱۰. نتایج تحلیل حساسیت اثر درصد کوچک‌تر از ۰/۲ mm بر زاویه اصطکاک حداکثر، تنش تفاضلی-اضافه فشار آب حفره‌ای در کرنش محوری نظیر تنش تفاضلی حداکثر و مقاومت پسماند مصالح BAA1 در تنش محدود کننده ۱۰۰ و ۷۰۰ kPa و مقایسه آن‌ها با نتایج آزمایش‌ها



شکل ۱۱. تغییرات تنش تفاضلی اندازه‌گیری شده در کرنش محوری نظیر تنش تفاضلی حداکثر و مقاومت پسماند در برابر درصد کوچک‌تر از ۰/۲ mm در تنش محدود کننده مختلف برای مصالح

بررسی شده



شکل ۱۲. نتایج تحلیل حساسیت اثر درصد کوچک‌تر از ۰/۲ mm بر اضافه فشار آب حفره‌ای در کرنش محوری نظیر تنش تفاضلی حداکثر مصالح BAA1 در تنش محدود کننده ۱۰۰ و ۷۰۰ kPa و مقایسه آن‌ها با نتایج آزمایش‌ها در تنش‌های محدود کننده ۱۰۰-۲۰۰ و ۶۰۰-۷۰۰ kPa

جدول ۱. مشخصات مصالح به کار رفته برای انجام آزمایش‌های CU

Material	Dam		Passing	Passing	Passing	Passing	γ_d (۹۵%)	W_{opt} (%)	Rate of	Symbol	
			۳۹/۲ mm	۴۵/۴ mm	۴۷/۵ mm	۵۰/۶ mm	(kN/m ^۳)		loading		
Blasting	Andesibasalt	Sabalan	۹۵	۷۲	۳۷	۴	۲۱/۱	۴/۵	۰/۵	BABS	
	Andesite	Aydoghmosh-G ^۱	۹۶	۸۴	۳۷	۸	*۲۱/۸	۶/۵	۰/۵	BAA ^۱	
Alluvium	Andesi-Dacite	Yamchi	G ^۱	۹۷/۵	۹۱	۶۱	۱۰	۲۰/۵	۰/۵	۰/۵	AADY ^۲
			G ^۲	۸۰	۷۰	۳۵	۷	۲۰/۵	۰/۵	۰/۵	AADY ^۱
	Alluvium-river bed	Shahr Chi	۹۴	۸۳	۵۹	۱۰	۲۱/۹	۵/۸	۰/۵	ASSC	
	Andesite-Basalt	Sattar Khan	۹۵	۸۵	۵۳	۲۲	۲۰	۹	۰/۵	AASK	
	Deurite-Basit	Sahand- G ^۱	۹۷	۹۱	۶۲	۱۰	۲۰/۵	۹	۰/۵	ADBS ^۱	
	Deurite-Basalt	Sahand- G ^۲	۹۶	۸۴	۳۷	۸			۰/۵	ADBS ^۲	
	Andesite	Aydoghmosh-G ^۲	۸۲	۷۳	۲۵	۱	۲۲/۳	۷/۴	۰/۵	AAA	
	Core	Masjed-e-Soleyman(LL=۴۱, PI=۲۳)		۱۰۰	۹۷/۵	۹۳/۵	۸۷	۱۷	۲۰	۰/۲	C.MES-۱۷
							۰/۰۴	C.MES-۲۰			
Karkheh(LL=۶۰, PI=۳۰)		۱۰۰	۹۰	۶۹	۵۳	۱۸/۳	۱۳/۵	۰/۰۷	C.K		
Shahr Chi (LL=۲۸/۷, PI=۱۳/۵)		۹۱	۸۶	۶۳	۴۱	۲۰/۳	۱۰/۱	۰/۲	C.SC		
High Weathered Sandstone	Vanyar(PI=۸۶)	۱۰۰	۹۲	۵۹	۳۷	۲۰/۸	۹/۵	۰/۱	C.SV		

$kPa^{۳۰۰} \text{ kN/cm}^3$ for Effective Confining Pressure (ECP)= $۲۱\gamma_d =$

جدول ۲. ورودی‌ها و خروجی‌های MLPs تشکیل دهنده مدل $netu$ و $netq$

Networks	Inputs										Outputs	
	σ'_r (kPa)	$\Delta\varepsilon_n$	ε_{vn}	γ_d (kN/m ^۳)	w (%)	Passing ۳۹/۲ mm	Passing ۴۵/۴ mm	Passing ۴۷/۵ mm	Passing ۵۰/۶ mm	Rate of loading (mm/s)	q_n	$q_{n+۱}$
$netq$											u_n	$u_{n+۱}$

جدول ۳. مرزهای ورودی‌ها و خروجی‌های MLPs برای $netu$ و $netq$

Limits	Inputs										Outputs	
	σ'_r (kPa)	$\Delta\varepsilon_n$	ε_{vn}	γ_d (kN/m ^۳)	w (%)	Passing ۳۹/۲ mm	Passing ۴۵/۴ mm	Passing ۴۷/۵ mm	Passing ۵۰/۶ mm	Rate of loading (mm/s)	$q_{n+۱}$	$u_{n+۱}$
Min.	۱۰۰	۰/۳	۰/۰	۱۷/۰	۴/۵	۸۰/۰	۷۰/۰	۲۵/۰	۱/۰	۰/۰۷	۰	۳۴۸/۴
Max.	۲۴۰۰	۰/۳	۱۹/۸	۲۲/۳	۲۰/۰	۱۰۰/۰	۹۷/۵	۹۳/۵	۸۷/۰	۰/۵	۳۲۴۰	۹۱۸

جدول ۴. پارامترهای ورودی netCU

	σ'_3 (kPa)	γ_d (kN/m ³)	W_{opt} (%)	Passing ۲۵/۴ mm (%)	Passing ۴۷/۵ mm (%)	Passing ۰/۲ mm (%)
BABS	۳۰۰	۲۱/۱	۴/۵	۷۲	۳۷	۴
	۶۰۰	۲۱/۱	۴/۵	۷۲	۳۷	۴
	۹۰۰	۲۱/۱	۴/۵	۷۲	۳۷	۴
BABS-re	۳۰۰	۲۱/۱	۴/۵	۷۲	۳۷	۴
	۶۰۰	۲۱/۱	۴/۵	۷۲	۳۷	۴
	۹۰۰	۲۱/۱	۴/۵	۷۲	۳۷	۴
BAA1	۱۰۰	۲۱/۸	۶/۵	۸۴	۳۷	۸
	۳۰۰	۲۱/۸	۶/۵	۸۴	۳۷	۸
	۵۰۰	۲۱/۸	۶/۵	۸۴	۳۷	۸
	۷۰۰	۲۱/۸	۶/۵	۸۴	۳۷	۸
BAA1-re	۳۰۰	۲۱	۶/۵	۸۴	۳۷	۸
AADY 2	۲۰۰	۲۰/۵	۹	۷۰	۳۵	۷
	۴۰۰	۲۰/۵	۹	۷۰	۳۵	۷
	۷۰۰	۲۰/۵	۹	۷۰	۳۵	۷
AADY 1	۲۰۰	۲۰/۵	۹	۹۱	۶۱	۱۰
	۴۰۰	۲۰/۵	۹	۹۱	۶۱	۱۰
	۷۰۰	۲۰/۵	۹	۹۱	۶۱	۱۰
AADY 1-re	۲۰۰	۲۰/۵	۹	۹۱	۶۱	۱۰
	۴۰۰	۲۰/۵	۹	۹۱	۶۱	۱۰
	۷۰۰	۲۰/۵	۹	۹۱	۶۱	۱۰
S.SC	۲۰۰	۲۱/۹	۵/۸	۸۳	۵۹	۱۰
	۵۰۰	۲۱/۹	۵/۸	۸۳	۵۹	۱۰
	۸۰۰	۲۱/۹	۵/۸	۸۳	۵۹	۱۰
S.SC-re	۵۰۰	۲۱/۹	۵/۸	۸۳	۵۹	۱۰
	۸۰۰	۲۱/۹	۵/۸	۸۳	۵۹	۱۰
ADBS1	۲۰۰	۲۰/۵	۹	۹۱	۶۲	۱۰

	σ'_3 (kPa)	γ_d (kN/m ³)	W_{opt} (%)	Passing ۲۵/۴ mm (%)	Passing ۴۷/۵ mm (%)	Passing ۷۵/۲ mm (%)
	۴۰۰	۲۰/۵	۹	۹۱	۶۲	۱۰
	۷۰۰	۲۰/۵	۹	۹۱	۶۲	۱۰
ADBS2	۲۰۰	۲۰/۵	۹	۸۴	۳۷	۸
	۴۰۰	۲۰/۵	۹	۸۴	۳۷	۸
	۷۰۰	۲۰/۵	۹	۸۴	۳۷	۸
AAA	۳۰۰	۲۲/۳	۷,۴	۷۳	۲۵	۱
	۵۰۰	۲۲/۳	۷,۴	۷۳	۲۵	۱
	۷۰۰	۲۲/۳	۷,۴	۷۳	۲۵	۱
AASK	۲۰۰	۲۰	۹	۸۵	۵۳	۲۲
	۵۰۰	۲۰	۹	۸۵	۵۳	۲۲
	۸۰۰	۲۰	۹	۸۵	۵۳	۲۲
AASK-re	۲۰۰	۲۰	۹	۸۵	۵۳	۲۲
	۵۰۰	۲۰	۹	۸۵	۵۳	۲۲
	۸۰۰	۲۰	۹	۸۵	۵۳	۲۲
	۸۰۰	۲۰	۹	۸۵	۵۳	۲۲
C.MES-17	۳۰۰	۱۷	۲۰	۹۷/۵	۹۳/۵	۸۷
	۶۰۰	۱۷	۲۰	۹۷/۵	۹۳/۵	۸۷
	۱۲۰۰	۱۷	۲۰	۹۷/۵	۹۳/۵	۸۷
	۲۴۰۰	۱۷	۲۰	۹۷/۵	۹۳/۵	۸۷
C.K	۶۰۰	۱۸,۳	۱۳/۵	۹۰	۶۹	۵۳
C.SC	۲۰۰	۲۰/۳	۱۰/۱	۸۶	۶۳	۴۱
	۵۰۰	۲۰/۳	۱۰/۱	۸۶	۶۳	۴۱
	۸۰۰	۲۰/۳	۱۰/۱	۸۶	۶۳	۴۱
C.SV	۱۰۰	۲۰/۸	۹/۵	۹۲	۵۹	۳۷
	۳۰۰	۲۰/۸	۹/۵	۹۲	۵۹	۳۷
	۶۰۰	۲۰/۸	۹/۵	۹۲	۵۹	۳۷
min	۱۰۰	۱۷	۴/۵	۷۰	۲۵	۱
max	۲۴۰۰	۲۲/۳	۲۰	۹۷,۵	۹۳,۵	۸۷

جدول ۵. پارامترهای خروجی netCU

	$\varepsilon_1(q_{\max})$ (%)	q_{\max} (kPa)	σ_{\max}°	$u(q_{\max})$ (kPa)	q_{residual} (kPa)	$u(q_{\text{residual}})$ (kPa)
BABS	۶,۳۰	۱۸۹۴	۴۹,۴۰	۱۷۱-	۱۸۳۰	-۲۰,۴
	۱۵,۶۰	۲۰۲۰	۳۸,۹۰	۱۱۰-	۲۰۲۰	-۱۱۰
	۱۵,۶۰	۲۴۸۸	۳۵,۵۰	۱۸۵	۲۴۸۸	۱۸۵
BABS-re	۱۰,۲۰	۱۸۲۲	۴۸,۸۰	۲۰۰-	۱۸۲۲	-۲۰۰
	۱۵,۶۰	۱۹۷۵	۳۸,۵۰	۳۳,۴	۱۹۷۵	۳۳,۴
	۱۱,۷۰	۲۶۰۸	۳۶,۳۰	۱۱۹,۱-	۲۶۰۰	-۱۳۳,۷
BAA1	۳,۹۰	۱۱۳۰	۵۸,۲۰	-۱۳۲	۹۷۳	-۱۵۲
	۵,۴۰	۱۸۳۰	۴۸,۹۰	-۱۲۰	۱۷۴۰	-۱۴۶
	۱۱,۱۰	۲۲۴۰	۴۳,۷۰	-۸۶,۵	۲۱۸۰	-۱۰,۴
	۱۵,۰۰	۲۳۷۰	۳۹,۰۰	۴۴	۲۳۷۰	۴۴
BAA1-re	۱۰,۵۰	۱۸۳۰	۴۸,۹۰	-۱۶۷	۱۸۰۰	-۱۹۲
AADY2	۱۵,۶۰	۱۵۲۲	۵۲,۴۰	-۲۲۲	۱۵۲۲	-۲۲۲
	۱۵,۶۰	۱۶۲۵	۴۲,۱۰	-۵۲	۱۶۲۵	-۵۲
	۱۵,۶۰	۱۹۰۰	۳۵,۲۰	۱۱۳	۱۹۰۰	۱۱۳
AADY1	۱۵,۶۰	۱۶۷۳	۵۳,۸۰	-۳۱۸	۱۶۷۳	-۳۱۸
	۱۱,۱۰	۱۷۳۲	۴۳,۲۰	-۲۲۹	۱۷۱۶	-۲۴۲
	۵,۱۰	۳۰۳۸	۴۳,۲۰	-۲۶۷	۲۶۹۵	-۲۷۸
AADY1-re	۱۱,۴۰	۲۰۶۵	۵۶,۹۰	-۳۱۲	۲۰۵۰	-۳۴۸,۴
	۹,۹۰	۲۵۰۰	۴۹,۳۰	-۱۷۸	۲۵۰۰	-۲۴۵
	۷,۸۰	۳۲۴۰	۴۴,۳۰	-۱۹۵	۳۱۳۰	-۲۷۰
S.SC	۸,۷۰	۱۴۹۷	۵۲,۱۰	-۱۷	۱۴۹۰	-۲۱
	۱۵,۶۰	۲۱۸۳	۴۳,۳۰	۱۴۱,۴	۲۱۸۳	۱۴۱,۴
	۶,۰۰	۲۵۰۲	۳۷,۶۰	۴۳۶	۲۴۲۵	۴۳۱
S.SC-re	۱۵,۰۰	۳۱۷۰	۴۹,۵۰	۴۵,۹	۳۱۷۰	۴۲,۷
	۱۰,۵۰	۱۸۳۵	۳۲,۳۰	۵۱۵	۱۷۸۸	۵۱۵
ADBS1	۳,۰۰	۱۹۰۴	۵۵,۷۰	-۲۷۷	۱۴۷۵	-۲۸۷
	۵,۱۰	۲۳۲۰	۴۸,۰۰	-۲۲۵	۱۸۸۵	-۲۴۵
	۵,۴۰	۲۹۷۰	۴۲,۸۰	-۱۹۵	۲۵۹۴	-۲۲۰
ADBS2	۲,۷۰	۱۹۱۰	۵۵,۸۰	-۲۷۰	۱۴۷۵	-۲۸۸
	۳,۶۰	۲۲۳۰	۴۷,۴۰	-۱۹۰	۱۹۳۵	-۲۲۰

	$\varepsilon_1(q_{\max})$ (%)	q_{\max} (kPa)	\square_{\max}°	$u(q_{\max})$ (kPa)	q_{residual} (kPa)	$u(q_{\text{residual}})$ (kPa)
	۸,۱۰	۲۵۸۰	۴۰,۴۰	-۱۱۲	۲۵۲۰	-۱۲۰
AAA	۳,۰۰	۱۷۲۹	۴۷,۹۰	-۱۳۰	۱۵۶۰	-۱۶۲
	۳,۰۰	۲۴۴۸	۴۵,۲۰	-۹۰	۲۰۱۰	-۱۱۰
	۶,۳۰	۲۸۹۰	۴۲,۴۰	-۱۳۰	۲۷۳۵	-۱۵۲
AASK	۱۶,۲۰	۳۲۰	۲۶,۴۰	۱۰۹	۳۲۰	۱۰۹
	۱۶,۲۰	۳۹۳	۱۶,۴۰	۳۹۲	۳۹۳	۳۹۲
	۱۶,۲۰	۵۳۸	۱۴,۶۰	۶۳۶,۴	۵۳۸	۶۳۶,۴
AASK-re	۱۶,۵۰	۳۱۵	۲۶,۱۰	۱۱۱	۳۱۵	۱۱۱
	۱۶,۲۰	۴۰۵	۱۶,۸۰	۳۹۴	۴۰۵	۳۹۴
	۱۶,۲۰	۹۸۳	۲۲,۴۰	۴۹۲	۹۸۳	۴۹۲
	۶,۹۰	۵۵۷	۱۵,۰۰	۶۳۵	۵۵۷	۶۳۵
C.MES-17	۱۹,۸۰	۲۳۲	۲۰,۹	۱۳۹	۲۳۲	۱۳۹
	۱۴,۷۰	۵۳۷	۱۸,۰۰	۳۲۱	۵۳۷	۳۲۱
	۱۵,۹۰	۱۲۸۹	۲۰,۵۰	۴۳۵	۱۲۸۹	۴۳۵
	۱۹,۸۰	۲۴۲۶	۱۹,۶۰	۹۱۸	۲۴۲۶	۹۱۸
C.K	۱۹,۸۰	۵۳۰	۱۷,۸۰	۴۳۱	۵۳۰	۴۳۱
C.SC	۱۱,۱۰	۱۶۱	۱۶,۷۰	۱۶۰,۵	۱۶۱	۱۶۰,۵
	۱۱,۱۰	۴۹۷	۱۹,۴۰	۴۳۰	۴۹۷	۴۳۰
	۹,۶۰	۹۵۷	۲۲,۰۰	۶۹۵	۹۵۷	۶۹۵
C.SV	۱۵,۰۰	۷۲	۱۵,۳۰	۷۷	۷۲	۷۷
	۱۵,۰۰	۳۲۰	۲۰,۴۰	۳۰۰	۳۲۰	۳۰۰
	۱۵,۰۰	۱۲۵۰	۳۰,۷۰	۲۱۷	۱۲۵۰	۲۱۷
Min	۲,۷	۷۲	۱۴,۶	-۳۱۸	۷۲	-۳۴۸,۴
Max	۱۹,۸	۳۲۴۰	۵۸,۲	۹۱۸	۳۱۷۰	۹۱۸

جدول ۶. عمل کرد مدل نسبت به شاخص‌های خطا شبکه با ۷ نرون میانی برای netCU

Hidden layers	Training subset	Testing subset	Validation subset
Total Error IOA	۰/۹۷۰۱	۰/۸۹۸۶	۰/۸۹۱۲
Error IOA	۰/۹۸۶۷	۰/۹۶۶۶	۰/۸۵۱۰
Total Error MAE	۰/۰۰۰۲	۰/۳۱۵۸	۰/۲۶۵۵
Error MAE	۰/۰۰۰۲	۰/۲۲۰۲	۰/۲۴۶۴
Total Error MBE	۰/۰۰۰۲	-۰/۳۱۵۸	۰/۲۶۵۵
Error MBE	۰/۰۰۰۲	-۰/۲۲۰۲	۰/۲۴۶۴
Total Error MSE	۰/۳۰۵۷	۰/۲۸۸۲	۰/۱۲۰۶
Error MSE	۰/۱۶۸۷	۰/۰۴۱۳	۰/۰۲۰۳
Total Error RMSE	۰/۵۵۲۹	۰/۵۳۶۹	۰/۳۴۷۲
Error RMSE	۰/۴۱۰۷	۰/۲۰۳۲	۰/۱۴۲۶

جدول ۷. عمل کرد مدل‌ها نسبت به شاخص‌های خطا برای netu و netq

		Training subset	Validation subset	Testing subset
TotErrorIOA	netu	۰/۹۹۹۴۵	۰/۹۹۹۴۹	۰/۹۹۹۴۵
	netq	۰/۹۹۹۵۵	۰/۹۹۹۷۴	۰/۹۹۹۳۴
TotErrorMAE	netu	۰/۰۱۴۳۰۲	۰/۰۸۳۰۵۱	۰/۱۱۱۴۱
	netq	۰/۰۰۵۱۰۹	۰/۰۴۱۲۳۱	۰/۱۸۱۹۴
TotErrorMBE	netu	۰/۰۱۴۳۰۲	۰/۰۸۳۰۵۱	۰/۱۱۱۴۱
	netq	۰/۰۰۵۱۱	-۰/۰۴۱۲۳	-۰/۱۸۱۹۴
TotErrorMSE	netu	۰/۴۹۵۴۷	۰/۰۴۵۷۲	۰/۰۲۵۶۴۸
	netq	۰/۲۷۴۳۵	۰/۰۱۸۱۱۵	۰/۲۲۰۵۴
TotErrorRMSE	netu	۰/۷۰۳۹	۰/۲۱۳۸۲	۰/۱۶۰۱۵
	netq	۰/۵۲۳۷۹	۰/۱۳۴۵۹	۰/۱۴۸۵

جدول ۸. مقایسه نتایج آزمایش‌ها با نتایج تحلیل‌ها با netCU

		$\epsilon_s(q_{max})$	q_{max}	$u(q_{max})$	$q_{residual}$	$u(q_{residual})$
ADBS ₁ , $\sigma'_v=400$ kPa	Test	۵/۱	۲۳۲۰	-۲۲۵	۱۸۸۵	-۲۴۵
	netCU	۳/۳۲	۲۲۳۳	-۲۱۸	۱۹۲۴	-۲۵۱
C.K., $\sigma'_v=600$ kPa	Test	۱۹/۸	۵۳۰	۴۳۱	۵۳۰	۴۳۱
	netCU	۱۹/۹۱	۵۱۸/۵۸	۴۲۰	۶۲۱	۴۳۱
۱۷C.MES- $\sigma'_v=1200$ kPa	Test	۱۵/۹	۱۲۸۹	۴۳۵	۱۲۸۹	۴۳۵
	netCU	۱۴/۲۱	۱۲۸۶/۱	۴۹۸/۴	۱۲۷۹	۵۰۳

جدول ۹. مقادیر وزن‌ها و توارش برای netCU برای آزمایش‌های CU

$$w_1 = \text{netCU.iw}\{1,1\}$$

۷/۱۶۱	-۲۱/۰۰۶	-۱۱/۴۱۹	۳۸/۵۶۸	۲۸/۹۰۲	-۴/۸۰۹
۰/۱۳۴	-۱/۴۸۸	۴/۰۰۷	-۱۵/۱۹۱	۱۱/۸۲۰	۰/۵۳۵
-۰/۷۸۳	-۳/۵۳۴	-۴/۲۵۶	۱۶/۳۳۱	-۱۲/۵۱۴	-۱/۴۵۴
۱/۸۷۰	۱۲/۲۲۵	۴/۹۸۶	-۱۸/۰۴۹	۱۳/۹۲۵	۲/۴۶۷
۰/۵۷۵	-۸۳/۸۴۸	-۴/۹۶۷	-۸۴/۰۷۱	۵۹/۳۳۵	-۹/۴۸۰
۱۱/۴۳۹	۴/۳۵۰	-۱/۵۱۳	۱/۸۸۶	-۲/۵۵۵	۷/۳۳۵
-۰/۴۸۱	-۰/۳۵۸	-۰/۲۲۱	۰/۰۰۴	-۰/۳۲۴	۰/۴۰۷

$$w_2 = \text{netCU.lw}\{1,2\}$$

۵/۷۱۹	۵/۳۱۴	۳۴/۲۴۵	۱۳/۶۰۸	۹/۶۸۹	۰/۳۱۷	۲/۷۲۱
-۰/۹۴۴	۷/۷۸۰	۱۰/۳۷۷	۴/۶۲۲	-۱/۲۷۲	۰/۱۶۲	-۳/۷۶۸
-۰/۷۰۸	۴/۷۷۰	۶/۰۱۹	۲/۸۱۴	-۱/۰۱۹	-۰/۱۷۱	-۶۷۳
۱/۶۹۵	-۱۲/۱۸۵	-۱۴/۲۰۰	-۶/۰۱۸	۲/۵۹۷	-۰/۱۲۶	-۴/۶۵۶
-۰/۱۴۴	۸/۰۳۱	۱۴/۴۰۱	۶/۲۴۷	۰/۰۸۳	۰/۱۸۰	-۳/۷۰۶
۱/۹۴۴	-۱۲/۳۷۷	-۱۳/۴۳۳	-۵/۷۱۶	۳/۰۱۶	-۰/۱۲۸	-۴/۷۱۷

$$b_1 = \text{netCU.b}\{1,1\} \quad b_2 = \text{netCU.b}\{1,2\}$$

Bias hidden layer Bias Output layer

-۲۳/۷۵۵	۲/۳۹۶۸
۵/۸۲۱	-۲/۴۶۷۹
-۱/۲۶۵	۰/۱۹۸۶
-۶/۹۳۷	-۳/۱۷۹۷
۱۱۸/۴۶۲	-۲/۴۲۵۴
-۶/۰۰۱	-۳/۲۲۹۶
-۰/۳۵۹	