

پیش‌بینی رفتار تنش_کرنش مصالح شنی با استفاده از شبکه‌های عصبی مصنوعی

رضا مهین‌روستا^{۱*}، حامد فرخ بروجردی^۲

۱- استادیار دانشکده مهندسی، دانشگاه تربیت مدرس

۲- کارشناس ارشد مکانیک خاک و مهندسی پی

reza.mahinroosta@gmail.com

تاریخ پذیرش: ۱۳۸۹/۱۲/۱۱

تاریخ دریافت: ۱۳۸۸/۰۵/۰۷

چکیده- در این پژوهش رفتار مکانیکی مصالح درشت‌دانه شنی با استفاده از شبکه عصبی چندلایه پرسپترون، که از پرکاربردترین شبکه‌های عصبی مصنوعی در مسائل ژئوتکنیکی است، شبیه‌سازی شده است. ابتدا اطلاعات دقیقی از آزمون‌های منابع مختلف در سراسر کشور تهیه و عوامل مؤثر بر مقاومت برشی خاک‌های درشت‌دانه بررسی شده است. پس از حذف اطلاعات نادرست، روند یادگیری، آزمایش و پیش‌بینی شبکه طی شده است. در آموزش شبکه از الگوریتم یادگیری پس‌انتشار خطا استفاده شده است. پارامترهای استفاده شده در آموزش شبکه شامل خصوصیات دانه‌بندی، چگالی خشک، چگالی نسبی، درصد سایش لس‌آنجلس، فشار همه‌جانبه، کرنش و تنش انحرافی است. برای تعیین چگونگی و مقدار تأثیر ورودی‌ها بر خروجی مدل، تحلیل حساسیت روی آن‌ها انجام شده و نتایج به‌دست آمده با قوانین مکانیک خاک مقایسه شده است. بررسی مدل گویای این واقعیت است که شبکه ارائه شده، توانایی لازم برای پیش‌بینی رفتار تنش_کرنش خاک‌های درشت‌دانه را دارد.

کلیدواژه‌گان: خاک‌های شنی، منحنی تنش - کرنش، شبکه عصبی مصنوعی، پرسپترون چندلایه، تحلیل حساسیت.

۱- مقدمه

توانایی این مدل‌ها در پیچیدگی آن‌ها نهفته است؛ یعنی هرچه این مدل‌ها پیچیده‌تر باشند، انتظار جواب دقیق‌تری از آن‌ها می‌رود. اما به علت نداشتن اطمینان و تغییرپذیری رفتار خاک‌ها و همچنین مشخص نبودن همه‌ی عوامل مؤثر بر رفتار این مواد، این روابط نمی‌توانند کاملاً رفتار تنش_کرنش را در شرایط متفاوت پیش‌بینی کنند.

با توجه به این مطالب طی چند دهه اخیر، به استفاده از شبکه‌های عصبی مصنوعی در مدل‌سازی رفتار خاک‌ها، توجه بسیار شده است. نخستین بار الیس و همکاران

مطالعه رفتار تنش_کرنش خاک‌ها در حل مسائل مطرح شده در مهندسی ژئوتکنیک، اهمیت زیادی دارد. از این رو در طی دهه‌های گذشته، محققین بسیاری برای معرفی مدل‌های ریاضی، برای تخمین رفتار خاک‌های مختلف سعی کرده‌اند. این مدل‌ها بر پایه تئوری‌های متعدد مانند الاستیسیته و پلاستیسیته استوار است که با استفاده از پیش‌فرض‌ها و تعریف محدوده‌های شکست و تسلیم، رابطه‌ای برای خصوصیات تنش_کرنش خاک ارائه می‌دهد. به طور کلی

۲- گردآوری اطلاعات و مشخصات مصالح


مهم‌ترین اطلاعات مورد نیاز برای تعیین خصوصیات مکانیکی خاک‌های درشت‌دانه شامل نتایج آزمایش‌های مقاومت برشی سه‌محوری، دانه‌بندی، چگالی نسبی و سایش لس‌آنجلس است. برای شبیه‌سازی رفتار این مصالح، اطلاعات آزمایشگاهی از آزمایشگاه‌ها و شرکت‌های مهندسی مشاور داخل کشور، مانند شرکت مهندسی مشاور مه‌اب قدس [۱۰-۱۵] و شرکت مهندسی مشاور ارکان رهاب [۱۶] تهیه شده است. بانک اطلاعاتی جمع‌آوری شده شامل نتایج آزمایش روی نمونه‌های درشت‌دانه و سنگ حاصل از منابع قرصه سد مخزنی صفا، سد مخزنی منگل، سد مخزنی سیمینه‌رود، سد مخزنی سمیلان، سد خاکی مراش و سد آزاد است. شکل ۱، نمودار دانه‌بندی این مصالح را نشان می‌دهد. همان‌طور که مشاهده می‌شود مصالح از نظر طبقه‌بندی متحد^۱، در محدوده‌های GP، GW، SW و SP قرار می‌گیرند. بیشینه‌ی سایش مصالح بین ۱ تا ۲ اینچ بوده و کمتر از ۱۰ درصد وزنی مصالح بررسی شده، مصالح ریزدانه (زیر الک ۲۰۰) است.

۳- شبکه عصبی مصنوعی

شبکه عصبی، پردازنده موازی گسترده‌ای است که از واحدهای پردازشگر ساده‌ای تشکیل شده و مهم‌ترین مزیت آن نسبت به سیستم‌های هوشمند دیگر، قدرت یادگیری شبکه از محیط و افزایش کارایی طی آموزش است. روشی که برای آموزش شبکه به کار می‌رود الگوریتم آموزش نامیده می‌شود و وظیفه آن اصلاح وزن نرون‌های شبکه است به گونه‌ای که ما را به سمت هدف از پیش تعیین شده راهنمایی کند.


(۱۹۹۵) یک مدل شبکه عصبی برای ماسه‌ها بر اساس دانه‌بندی و تاریخچه تنش توسعه دادند [۱]. در سال ۱۹۹۸ قابوسی و سیدارتا از شبکه‌های عصبی برای مدل‌سازی رفتار زهکشی شده و زهکشی نشده خاک‌های ماسه‌ای تحت آزمایش‌های فشاری سه‌محوری استفاده کردند [۲]. زو و همکاران (۱۹۹۸) از شبکه‌های عصبی برای مدل‌سازی رفتار برشی خاک‌های خوب دانه‌بندی شده و خاک‌های آتشفشانی هاوایی استفاده کردند [۳]. پنومادو و زو (۱۹۹۹) از شبکه‌های عصبی برای مدل‌سازی تنش_کرنش و رفتار تغییر حجم در شن و ماسه تحت آزمایش‌های فشاری سه‌محوری زهکشی شده استفاده کردند [۴]. حائری و مهین‌روستا (۱۳۸۰) رفتار زهکشی نشده خاک‌های رسی تحت آزمایش سه‌محوری را با استفاده از شبکه‌های عصبی مطالعه کردند [۵]. بنی‌مهد و همکارانش (۲۰۰۵) برای مدل کردن رفتار تنش_کرنش ماسه‌های سیلتی از شبکه‌های عصبی استفاده کردند [۶]. وُد و همکاران (۲۰۰۵) از یک شبکه عصبی مصنوعی برای پیش‌بینی خطا در آزمایش سه‌محوری با مرزهای انعطاف‌پذیر، استفاده کردند [۷]. نجار و هوآنگ (۲۰۰۷) رفتار تنش_کرنش خاک رسی جورجیا را به وسیله شبکه عصبی بازگشتی پیش‌بینی کردند [۸]. لی و می (۲۰۰۸) رفتار الاستیک غیرخطی خاک‌های تثبیت شده با آهک را در آزمایش‌های مقاومت برشی سه‌محوری با کمک شبکه‌های عصبی مدل‌سازی کردند [۹].

روند مدل‌سازی رفتار خاک‌های گوناگون به‌وسیله‌ی شبکه‌های عصبی مختلف در گوشه و کنار جهان ادامه دارد. با توجه به این‌که مطالعات بسیار کمی در ارتباط با پیش‌بینی رفتار مصالح درشت‌دانه انجام شده، هدف این مقاله، بررسی رفتار مکانیکی مصالح درشت‌دانه شنی با استفاده از شبکه عصبی مصنوعی است.




شکل (۱) منحنی دانه‌بندی مصالح منتخب برای آموزش شبکه عصبی

هر تابع غیرخطی با هر درجه پیچیدگی را دارند؛ [۱۷] از این رو در این پژوهش از شبکه عصبی سه‌لایه برای مدل‌سازی استفاده شده است. این شبکه‌ها در یک روش یادگیری با ناظر و به وسیله الگوریتم پس‌انتشار خطا^۲ تربیت می‌شوند و بر این اساس، تصحیح خطا را انجام می‌دهد. یادگیری به روش پس‌انتشار خطا از دو مسیر در میان لایه‌های مختلف تشکیل می‌شود: یک مسیر پیش‌خور و یک مسیر پس‌خور (شکل ۳).



شکل (۳) جهت‌های دو جریان سیگنال در یک پرسپترون چندلایه

شکل ۲، مدل یک گره که واحد پردازشگر اساسی در یک شبکه عصبی و رابطه ریاضی حاکم بر آن را نشان می‌دهد. x_{ij} ها، مقادیر ورودی گره j ، w_{ij} ، وزن‌های شبکه، f ، تابع تحریک، b_j ، مقدار بایاس و O_j ، خروجی گره j است.



شکل (۲) مدل ریاضی گره j

شبکه‌های پرسپترون چندلایه^۱ به گونه‌ای موفق برای حل مسائل پیچیده و متنوع به کار رفته است. این شبکه‌ها با سه لایه ورودی، خروجی و یک لایه میانی، با توابع فعالیت مشتق‌پذیر و تعداد کافی نرون در لایه میانی، تولنایی تخمین

نرم‌افزار است. این برنامه از روش‌های رگرسیون غیرخطی و توابع چندبعدي برای محاسبه خطا استفاده می‌کند. مهم‌ترین ویژگی این برنامه، خصوصیات منحصر به فرد گرافیکی آن است که کاربرد آن را بسیار آسان کرده است.

پارامترهایی که در مدل‌سازی رفتار مصالح درشت‌دانه‌ی شنی، تأثیرگذار بوده و به عنوان ورودی مدل در نظر گرفته شده عبارت است از:

قطر متوسط اندازه دانه‌ها (D50)، بزرگ‌ترین اندازه ذرات (Dmax)، ضریب خمیدگی (Cc)، ضریب یکنواختی (Cu)، چگالی نسبی (Dr)، درصد ریزدانه (PF)، چگالی خشک (γ_d)، درصد سایش لس‌آنجلس (LA)، فشار همه‌جانبه (σ_3) و کرنش محوری (ϵ).

گزیده‌ای از داده‌های ورودی شبکه در جدول ۱ مشاهده می‌شود. در جدول ۲، مقادیر میانگین، انحراف از معیار و ضریب تغییرات مشاهده می‌شود. همان‌طور که دیده می‌شود پارامترهای چگالی و ضریب یکنواختی به ترتیب کمترین و بیشترین پراکندگی را بین داده‌های جمع‌آوری شده دارند. با توجه به ضریب تغییرات بالا در مجموعه داده‌های جمع‌آوری شده، می‌توان دریافت که نتایج حاصل از آموزش شبکه، طیف گسترده‌ای از مصالح شنی را پوشش می‌دهد و تنها برای استفاده در یک پروژه خاص نیست.

رفتار نسبتاً واقعی مصالح در برابر تنش‌های اعمال شده معمولاً از آزمایش مقاومت برشی سه‌محوری به‌دست می‌آید (که در این جا با توجه به ماهیت مصالح، آزمایش زهکشی شده مورد توجه است)؛ به‌طوری‌که در این نوع آزمایش، هم رفتار مقاومتی و هم رفتار تغییر شکل‌پذیری مصالح به گونه‌ای مناسب برآورد می‌شود. پارامتر خروجی که شبیه‌سازی می‌شود، تنش‌های انحرافی است که از آزمایش مقاومت برشی سه‌محوری به‌دست آمده که برخی از آن‌ها در منحنی‌های

در مسیر پیش‌خور که به صورت بردارهای پیوسته نشان داده شده، یک بردار ورودی به گره‌های ورودی شبکه اعمال شده و در اثر آن به صورت لایه به لایه در شبکه انتشار می‌یابد. سرانجام مجموعه‌ای از خروجی‌ها به عنوان پاسخ حقیقی شبکه گزارش می‌شود. در مسیر رو به جلو، همه‌ی وزن‌های شبکه ثابت می‌مانند؛ از سوی دیگر در مسیر برگشت، وزن‌های شبکه با توجه به قانون تصحیح خطا اصلاح می‌شوند. به طور مشخص، پاسخ حقیقی شبکه از پاسخ مطلوب، کم می‌شود تا سیگنال خطا تولید شود؛ سپس این سیگنال خطا به صورت برگشتی در شبکه انتشار می‌یابد. وزن‌های شبکه برای رساندن پاسخ حقیقی به پاسخ مطلوب تصحیح و تنظیم می‌شوند. رابطه (۱) تصحیح Δw_{ji} اعمال‌شده به وزن‌هایی که گره i را به گره j متصل می‌کند، نشان می‌دهد [۱۸]:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) + \alpha \Delta w_{ji}(n-1) \quad (1)$$

$\Delta w_{ji}(n)$ ، تصحیح وزن برای ورودی‌های گره j ، η ، نرخ یادگیری، $y_i(n)$ ، سیگنال ورودی گره i و α ، مقداری مثبت به نام ثابت مومنتوم است، همچنین $\delta_j(n)$ برابر مشتق O_j در سیگنال خطای مرتبط با نرون j است

۴- معماری شبکه انتخاب‌شده

در این پژوهش برای پیش‌بینی رفتار تنش_کرنش مصالح درشت‌دانه شنی با استفاده از شبکه پرسپترون چندلایه، از نرم‌افزار NeuralWorks استفاده شده است [۱۹].

NeuralWorks، برنامه‌ای قدرتمند و پویا برای ایجاد سیستم‌های مختلف شبکه عصبی مصنوعی است. با این برنامه می‌توان مسائل گوناگون را طراحی و خلق کرد؛ همچنین آموزش و آزمایش داده‌ها و توسعه شبکه‌های متنوع برای حل مسائل ترکیبی و پیچیده از ویژگی‌های دیگر این

شبیه سازی شده ارائه خواهند شد. لازم به یادآوری است که با توجه به محدوده آزمایش ها، در این پژوهش پیش بینی رفتار تنش_ کرنش خاک های درشت دانه تا کرنش ۱۵ درصد انجام شده است.

قبل از آموزش شبکه، نیاز است تا داده های جمع آوری شده برای ارائه به شبکه پردازش شوند. از این رو ابتدا تمام منحنی های تنش انحرافی_ کرنش محوری و خصوصیات نمونه ها به صورت جدول ورودی_ خروجی تنظیم می شود. سپس ورودی ها و خروجی ها با روش های آماری، به بازه ۰/۱ تا ۰/۹ محدود می شوند. زیرا در صورتی که ورودی های

بزرگی به شبکه ارائه شود، حتی با وجود وزن های کوچک در شبکه، جمع ورودی های وزن دار به نرون لایه بعد، بزرگ خواهد شد و در آموزش داده ها مشکل به وجود می آید؛ بدین ترتیب با مقیاس بالا، همه ی داده های ورودی در بازه ۰/۱ تا ۰/۹ قرار گرفته که منجر به کاهش خطای مدل سازی شبکه می شود [۲۰].

برای مقایسه ساختارهای مختلف، نیاز به شاخص هایی است که بتواند کارکرد مدل ارائه شده را در کل مجموعه داده ها و در مقایسه با نتایج تجربی، بررسی و قضاوت کند.

جدول (۱) نمونه ای از ورودی های شبکه

سد	No.	D50 (mm)	D max (mm)	Cc	Cu	Dr(%)	PF(%)	γ_d (gr/cm ³)	LA (%)	σ_3 (kg/cm ²)
آزاد	A1-4	۶	۲۵/۴	۳۵/۳۲	۳/۰۲	۵۸/۲۷	۶/۲۵	۱/۹۴	۱۸/۴	۸ و ۶ و ۲
	A5-8	۶/۴	۳۸/۱	۵۵/۴۹	۳/۳	۶۱/۸۵	۷/۰۸	۱/۹۴	۲۰/۵	۸ و ۶ و ۲
منگل ۱	MN7-9	۱۶/۸	۲۵/۴	۸/۴۵	۸۰	۸۹/۴۴	۵	۲/۱	۲۵	۸ و ۱
	MN13-15	۱۴	۲۵/۴	۱/۷۱	۱۹۹	۸۰/۸۹	۹	۲/۰۴	۱۹	۸ و ۱
منگل ۲	MO1-3	۵	۲۵/۴	۰/۶۲۶	۴۴/۴۴	۸۵/۶۸	۵/۴	۲/۳۱	۱۶/۶	۱۰ و ۵ و ۲
	MO7-9	۴	۲۵/۴	۰/۵۲۲	۴۹/۲۸	۸۵/۶۹	۶/۵	۲/۳	۱۸/۳	۱۰ و ۵ و ۲
مراش	MR1-3	۷	۳۵	۱۸/۳۴	۱/۰۵۸	۶۴/۹۷	۰/۶۲	۱/۹۷	۳۵/۲	۷ و ۲
	MR19-21	۶/۰۶	۳۵	۳۳/۰۲	۰/۵۹۵	۶۰/۵۴	۱/۱۶	۱/۹۳	۳۰/۲	۷ و ۲
صفا	Sa1-3	۷	۳۰	۶/۸۱۵	۳۵/۹۵	۵۸/۹۱	۱/۲	۲	۲۰	۸ و ۱
	Sa4-6	۵/۹	۳۰	۱/۴۲۱	۳۷	۶۹/۹۲	۴/۵	۲	۲۲	۸ و ۱
سمیلان	Se10-12	۲/۸۳	۲۵/۴	۱/۸۸	۴۸/۹	۷۹/۳۳	۱۰	۲/۱۴	۲۵/۴۳	۶ و ۳ و ۱
سیمینه رود	Si1-3	۳/۲	۲۵/۴	۱/۴۷۴	۱۶	۸۵/۴۳	۳/۱	۱/۹۹	۳۵	۸ و ۱
	Si19-21	۴	۲۵/۴	۱/۰۷	۱۲/۸	۸۵/۷۲	۱/۴۵	۱/۹۵	۳۵	۸ و ۱

جدول (۲) میانگین و انحراف معیار ورودی های شبکه


	D50 (mm)	D max (mm)	Cc	Cu	Dr(%)	PF(%)	γ_d (gr/cm ³)	LA (%)	σ_3 (kg/cm ²)
میانگین	۶/۵۸	۲۹/۹۹	۱۰/۵۵	۳۲/۲۴	۷۴/۸۸	۳/۸۸	۲/۰۵	۲۵/۰۱	۴/۵۴
انحراف معیار استاندارد	۳/۱۳	۷/۲۳	۹/۳۵	۳۲	۱۱/۲۷	۲/۷۵	۰/۱۲	۶/۴۷	۲/۶۵
ضریب تغییرات (%)	۴۷/۵۷	۲۴/۱۱	۸۸/۶۲	۹۹/۲۵	۱۵/۰۵	۷۰/۸۷	۵/۸۵	۲۵/۸۷	۵۸/۳۷

در این پژوهش از دو شاخص جذر میانگین مربعات خطا (RMS) و ضریب همبستگی (R)، برای ارزیابی مدل استفاده شده است. برای بالا بردن قدرت تعمیم شبکه از روش Cross-Validation برای توقف آموزش استفاده شده است [۲۱]. در این روش، بانک داده‌ها به سه مجموعه آموزشی، ارزیابی و آزمایشی تقسیم می‌شود برای پیدا کردن بهترین پارامترها برای مدل، مجموعه ارزیابی به عنوان بخشی از داده‌های تجربه‌نشده در کنترل فرایند آموزشی استفاده می‌شود. در ابتدا کارکرد شبکه آموزش‌دیده در مقابل این داده‌ها، با توجه به شاخص‌های خطا ارزیابی شده است؛ سپس شبکه‌هایی که در مقابل داده‌های ارزیابی، عملکرد خوبی نشان دادند، در مقابل مجموعه آزمایشی نیز مطالعه می‌شوند و سرانجام هر پارامتری که شبکه به وسیله آن بهترین کارایی را در شبیه‌سازی و پیش‌بینی از خود نشان دهد، به عنوان پارامتر بهینه انتخاب می‌شود. از کل اطلاعات، ۹۵ آزمایش سه‌محوری به عنوان داده‌های آموزشی، نتایج ۲۰ آزمایش به عنوان مجموعه ارزیابی و نتایج ۲۳ آزمایش به عنوان مجموعه آزمایشی، استفاده شده است.

طراحی پارامترهای شبکه به صورت سیستماتیک، با


هدف کاهش جذر میانگین مربعات خطا (RMS) و افزایش ضریب همبستگی (R) بین داده‌های واقعی و پیش‌بینی، انجام شده است. به این صورت، شبکه بهینه ۱۹ گره در لایه میانی داشت و ضرایب یادگیری در لایه میانی و لایه خروجی به ترتیب $0/8$ و $0/3$ و ضریب مومنتوم $0/2$ به دست آمد. همچنین تابع انتقال تانژانت هیپربولیک برای لایه میانی و تابع سیگموئید برای لایه خروجی، کمترین شاخص خطا و بیشترین مقدار همبستگی را در

شبکه ایجاد کردند. سرانجام، معماری شبکه به شکل $19 \times 10 \times 1$ یعنی شبکه‌ای با ۱۰ ورودی، ۱۹ گره میانی و یک خروجی درآمد. شکل ۴، نمایی از این شبکه را نشان می‌دهد. شبکه پس از آموزش در نهایت به جذر میانگین مربعات خطای $0/0375$ برای مجموعه ارزیابی، $0/0368$ برای مجموعه آزمایشی و $0/0262$ برای مجموعه آموزشی می‌رسد. لازم به ذکر است که ورودی این شبکه علاوه بر اطلاعات جدول ۱، پارامتر کرنش محوری هم دارد که در شکل با ϵ نمایش داده شده است. خروجی شبکه نیز مقدار تنش انحرافی ($\Delta\sigma$) متناظر با کرنش، معرفی شده است.




شکل (۴) نمایی از شبکه عصبی استفاده شده در مدل‌سازی

در شکل‌های ۷، ۸ و ۹، نمونه‌هایی از منحنی‌های تنش انحرافی_کرنش محوری، به دست آمده از مدل شبکه عصبی مصنوعی برای مجموعه‌های آموزشی، ارزیابی و آزمایشی در مقایسه با نتایج آزمایشگاهی ارائه شده است. همان‌گونه که مشاهده می‌شود تطابق خوبی بین منحنی‌های شبیه‌سازی و پیش‌بینی با منحنی‌های حاصل از نتایج آزمایشگاهی وجود دارد. در برخی منحنی‌ها، اندکی اختلاف وجود دارد ولی در کل هم در مرحله آموزش و ارزیابی و هم در مرحله آزمایش، پیش‌بینی‌ها به واقعیت نزدیک است.




(الف)



(ب)

شکل (۶) مقایسه نتایج آزمایشگاهی با (الف) نتایج مجموعه آموزشی، (ب) نتایج مجموعه‌های ارزیابی و آزمایشی

برای آموزش شبکه، فایل داده‌های آموزشی به برنامه ارائه می‌شود. این فایل به وسیله برنامه خط به خط خوانده می‌شود و با توجه به داده‌های آموزشی، وزن‌های شبکه تغییر می‌کند؛ به عبارت دیگر، شبکه، آموزش می‌گیرد. هنگامی که برنامه به آخرین خط داده‌ها می‌رسد، دوباره به ابتدای فایل بازگشته و این روند تکرار می‌شود. همان‌طور که در شکل ۴ مشاهده می‌شود بعد از خواندن ۷۰۰۰۰ خط از فایل داده‌ها، آموزش متوقف می‌شود زیرا خطای داده‌های ارزیابی به کمترین مقدار می‌رسد. اگر آموزش بیش از این مقدار ادامه یابد، ممکن است شبکه به ازیرکردن داده‌ها بپردازد. هنگامی که شبکه دچار یادگیری بیش از اندازه شود، توانایی تعمیم خود را از دست می‌دهد. این اتفاق زمانی رخ می‌دهد که خطای شبکه برای داده‌های ارزیابی شروع به افزایش می‌کند.



شکل (۵) نمودار تعیین یادگیری بهینه


۵- مقایسه نتایج شبیه‌سازی و پیش‌بینی با نتایج آزمایشگاهی

شکل ۶، مقایسه آماری نتایج شبکه با نتایج آزمایشگاهی را نشان می‌دهد. مشاهده می‌شود که نتایج شبیه‌سازی بسیار نزدیک به نتایج حاصل از آزمایشگاه است. در واقع خط رگرسیون با درجه بالایی به خطی با شیب یک به یک نزدیک است. البته مطابق انتظار، درجه نزدیکی در داده‌های آموزشی بسیار بیشتر از داده‌های ارزیابی و آزمایشی است.

۶- حساسیت‌سنجی مدل


مدل‌های مبتنی بر شبکه‌های عصبی، هیچ‌گونه توضیحی درباره‌ی نحوه اثر پارامترهای ورودی بر خروجی و به عبارتی دانش حاکم بر محیط آن نمی‌دهد؛ بنابراین برای تعیین چگونگی و مقدار تأثیر ورودی‌ها بر خروجی مدل،

تحلیل حساسیت روی آن‌ها انجام گرفته است. این امر با دو هدف انجام می‌شود؛ یکی آن‌که می‌توان به شناسایی پارامترهایی پرداخت که بیشترین تأثیر را بر خروجی مدل داشته باشد و دوم آن‌که می‌توان ارتباطات مهندسی بین ورودی و خروجی را یافت.




نتایج اندازه‌گیری آزمایشگاهی ————— نتایج شبکه عصبی

شکل (۷) نمونه‌ای از منحنی‌های تنش انحرافی-کرنش محوری برای مجموعه آموزشی



نتایج اندازه‌گیری آزمایشگاهی ————— نتایج شبکه عصبی

شکل (۸) نمونه‌ای از منحنی‌های تنش انحرافی-کرنش محوری برای مجموعه ارزیابی



شکل (۹) نمونه‌ای از منحنی‌های تنش انحرافی_کرنش محوری برای مجموعه آزمایشی
نتایج اندازه‌گیری آزمایشگاهی ————— نتایج شبکه عصبی

سطح تنش را می‌رساند که در مصالح ژئوتکنیکی به طور ذاتی وجود دارد. شکل ۱۰-ب، نشان می‌دهد که هرچه درصد سایش افزایش یابد، مقاومت نهایی مصالح دانه‌ای افزایش می‌یابد که البته این تغییرات در محدوده آزمایش‌ها بسیار کم است. این امر می‌تواند به این دلیل باشد که دانه‌هایی که درصد سایش بیشتری دارد، زودتر خرد شده و بین دانه‌های بزرگ‌تر قرار می‌گیرد؛ در نتیجه قفل و بست بین دانه‌ای و درگیری آن‌ها افزایش یافته و باعث افزایش مقاومت برشی می‌شود. شکل ۱۰-ج، نشان می‌دهد که هرچه درصد مصالح ریزدانه افزایش یابد، تنش گسیختگی کاهش می‌یابد؛ این کاهش با توجه به محدوده مصالح، چشم‌گیر نیست.

شکل ۱۰-د، نمایانگر آن است که مصالح با چگالی نسبی بالا، مقاومت برشی بیشتری دارند. اثر بزرگ‌ترین اندازه دانه (D_{max})، در شکل ۱۰-ه نیز بدین گونه است که باعث افزایش در مقاومت برشی مصالح می‌شود؛ در حالی که این تأثیر تا حدود اندازه دانه ۳۵ میلی‌متر تقریباً تأثیری در مقدار تنش گسیختگی ندارد. این موضوع با تحقیقات انجام شده به وسیله‌ی داگلاس (۲۰۰۱) هم‌خوانی دارد [۲۲].

در شکل ۱۰-و، مشاهده می‌شود که هر چه مصالح دانه‌بندی گسترده‌تری داشته باشند، تنش انحرافی، بیشتر


ابتدا مقادیر متوسط پارامترهای ورودی تعیین شده، سپس با توجه به انحراف معیار آن (sd)، تغییرات ($\pm sd$) و ($\pm sd / 2$) روی هر پارامتر، به‌طور جداگانه اعمال می‌شود به گونه‌ای که دیگر پارامترهای شبکه، ثابت نگه‌داشته شود؛ بنابراین داده‌های دیگری به عنوان ورودی شبکه عصبی ارائه می‌شوند که در محدوده متوسط کل داده‌ها تغییر کرده است.

متوسط داده‌ها در جدول ۲ مشاهده می‌شود که خود یکی از دسته‌داده‌های ورودی شبکه عصبی است. برای نمونه مثال برای بررسی تحلیل حساسیت روی تنش همه‌جانبه، ۵ دسته داده به شبکه عصبی معرفی می‌شود که تمام اطلاعات ورودی آن‌ها همان میانگین داده‌ها است ولی مقدار تنش همه‌جانبه آن‌ها به ترتیب، $1/9$ ، $3/2$ ، $4/5$ ، $5/9$ و $7/2$ است. باتوجه به این روش حساسیت‌سنجی، مهم‌ترین نتایج به دست آمده در شکل ۱۰ نشان داده شده است. در این شکل، روند تغییرات تنش انحرافی با پارامترهای ورودی به صورت خطی برازش داده شده است تا روند کلی، بهتر مشاهده شود.


همان‌طور که مشاهده می‌شود با افزایش تنش همه‌جانبه، تنش انحرافی‌ای که باعث گسیختگی در نمونه‌ها می‌شود نیز افزایش می‌یابد. این موضوع تابعیت مقاومت برشی از

دارند؛ زیرا مصالح ریزتر در بین مصالح درشت‌تر جای گرفته و باعث افزایش مقاومت برشی می‌شوند.


به‌دست می‌آید؛ یعنی هرچه Cu افزایش یابد، تنش گسیختگی افزایش می‌یابد. این موضوع نشان می‌دهد که مصالح با دانه‌بندی غیریکنواخت، مقاومت برشی بالاتری




ب




الف




د



ج



و



ه

شکل (۱۰) حساسیت تنش گسیختگی نسبت به پارامترهای ورودی

به روش زیر عمل کرد:


ابتدا آزمایش‌های دانه‌بندی، سایش لس‌آنجلس و تراکم روی مصالح مورد نظر انجام می‌شود. در صورتی که پارامترهای به دست آمده در محدوده اطلاعات ورودی شبکه عصبی این مقاله باشند، می‌توانند در ورودی شبکه عصبی شوند؛ البته برای تعیین منحنی تنش- کرنش واقعی و همچنین مشاهده میزان خطا در پیش‌بینی، لازم است آزمایش‌های دقیق روی مصالح، انجام و برای تکمیل مطالعات انجام شده در این پژوهش، گام برداشته شود.

۷- نتیجه‌گیری

خاک‌های درشت دانه به گونه وسیعی در ساخت سدهای خاکی و خاکریزهای بزرگ استفاده شده و در بسیاری از پروژه‌های اجرایی در پی سازه قرار گرفته و از ظرفیت آن استفاده می‌گردد؛ بنابراین بررسی مقاومت برشی و مدل‌سازی مصالح شنی و سنگریزه‌ای، اهمیت ویژه‌ای دارد.

در شکل ۱۰ مشاهده می‌شود که در محدوده اطلاعات استفاده شده، اثر تنش همه‌جانبه روی تنش انحرافی بیشینه، بیشترین مقدار است. برای بررسی و انتخاب مهم‌ترین پارامترهای مؤثر بر خروجی شبکه، لازم است منحنی‌های حساسیت‌سنجی به گونه‌ای دیگری تهیه شوند؛ پس همه‌ی منحنی‌های شکل ۱۰، بجز منحنی اثر تنش همه‌جانبه، بر اساس مقدار نرمال شده آن‌ها در شکل ۱۱ رسم شد. همان‌طور که در این شکل مشاهده می‌شود، ضریب یکنواختی مصالح، بیشترین تأثیر را بر خروجی داشته و بعد از آن چگالی مصالح، درصد ریزدانه (تقریباً در یک سطح با تمایل متضاد)، مقدار بزرگ‌ترین اندازه دانه و سرانجام، فرسایش در آزمایش لوس‌آنجلس، قرار دارد. در محدوده داده‌های بررسی شده می‌توان گفت بعد از تنش همه‌جانبه، یکنواختی مصالح و درصد فرسایش، بیشترین و کمترین اثر را بر میزان تنش انحرافی هنگام گسیختگی دارد.

سرانجام، برای استفاده کاربردی از شبکه عصبی تهیه شده برای تخمین منحنی تنش-کرنش مصالح می‌توان



شکل (۱۱) حساسیت نسبی تنش گسیختگی نسبت به برخی پارامترهای ورودی

Geotechnics, 1999, pp207-230

- [5] مهین‌روستا، رضا؛ "پیش‌بینی رفتار تنش_کرنش خاک‌های رسی با استفاده از شبکه عصبی مصنوعی"؛ پایان‌نامه کارشناسی ارشد؛ دانشگاه صنعتی شریف؛ ۱۳۷۷

- [6] Banimahda M., Yasrobib S.S, Woodward P.K.; "Artificial neural network for stress-strain behavior of sandy soils: Knowledge based verification", *Computers and Geotechnics*; Volume 32, Issue 5, 2005, pp377-386.
- [7] Wood D.M., Dihoru L., Sadek T., Lings M.; "A neural network for error prediction in a true triaxial apparatus with flexible boundaries", *Computers and Geotechnics*; Volume 32, Issue 2, 2005, pp59-71.
- [8] Najjar Y.M., Huang C.; 2007, "Simulating the stress-strain behavior of Georgia kaolin via recurrent neuronet approach", *Computers and Geotechnics*; Volume 34, Issue 5, 2007, pp346-361.
- [9] He S., Li J.; "Modeling nonlinear elastic behavior of reinforced soil using artificial neural networks", *Applied Soft Computing*; 2008.

- [۱۰] شرکت مهندسی مشاور مهتاب قدس؛ "نتایج گزارشات آزمایشگاهی منابع قرضه سد منگل"؛ ۱۳۸۶.

- [۱۱] شرکت مهندسی مشاور مهتاب قدس؛ گزارشات آزمایش‌های فیزیکی و مکانیکی مصالح منابع قرضه سد منگل؛ ۱۳۷۷.

- [۱۲] شرکت مهندسی مشاور مهتاب قدس؛ "نتایج آزمایش‌های مصالح منابع قرضه سد صفا"؛ ۱۳۸۲.

- [۱۳] شرکت مهندسی مشاور مهتاب قدس؛ "نتایج آزمایش‌های مصالح ساختمانی تونل و نیروگاه سد آزاد"؛ ۱۳۸۶.

- [۱۴] شرکت مهندسی مشاور مهتاب قدس؛ "نتایج گزارشات آزمایشگاهی منابع قرضه سد سیمینه‌رود"؛ ۱۳۸۶.

در این مقاله پارامترهای مختلف فیزیکی و مکانیکی از مناطق مختلف کشور تهیه و پس از بررسی‌های لازم، شبکه عصبی مصنوعی با [معماری ۱*۱۹*۱۰ با ضرایب یادگیری ۰/۸ و ۰/۳ و ضریب مومنتوم ۰/۲] برای شبیه‌سازی آن‌ها استفاده شد. نتایج شبیه‌سازی، نشانگر آن است که شبکه عصبی پیشنهادی، قابلیت تعیین رفتار تنش_کرنش مصالح درشت‌دانه را دارد؛ همچنین حساسیت‌سنجی‌های انجام‌شده نیز نمایانگر مطابقت بسیار خوب رفتار شبکه با قوانین و اصول مکانیک خاک است. در نهایت می‌توان گفت شبکه عصبی ارائه‌شده، توانایی مدل‌سازی منحنی‌های تنش_کرنش مصالح شنی را با استفاده از پارامترهای ساده که معمولاً در مراحل اولیه اکتشافات انجام می‌شود، دارد.

۸- قدردانی

در پایان، نویسندگان مقاله از شرکت‌های مهندسی مشاور مهتاب قدس و مهندسی مشاور ارکان‌رهاب به خاطر همکاری‌هایی که در تهیه اطلاعات آزمایشگاهی داشتند، تشکر و قدردانی می‌کنند.

۹- مراجع

- [1] Ellis G.W., Yao C., Zhao R., Penumadu D.; "Stress-strain modeling of sands using artificial neural networks", *Geotechnical Engineering, ASCE*, 121(5), 1995, pp429-35.
- [2] Ghaboussi J., Sidarta D.E; "New nested adaptive neural networks (NANN) for constitutive modeling" *Computers and Geotechnics*; 22(1), 1998, pp29-52.
- [3] Zhu J.H., Zaman M.M., Anderson S.A.; "Modeling of shearing behavior of a residual soil with recurrent neural networks", *J. Num. Anal. Meth. Geomech.*, No. 22, 1998, pp671-687.
- [4] Penumadu D., Zhao R.; "Triaxial compression behavior of sand and gravel using artificial neural networks (ANN)", *Computers and*

- [18] Andina D., Pham D.T.; *Computational Intelligence for Engineering and Manufacturing*, Springer, 2007; pp. 67-92.
- [19] NeuralWorks Professional II/PLUS; Ver5.23; NeuralWare, Inc.; 1996.
- [۲۰] کاوه، ع؛ ثروتی، ه؛ "شبکه‌های عصبی مصنوعی در تحلیل و طراحی سازه‌ها"؛ مرکز تحقیقات ساختمان و مسکن؛ نشریه شماره ک-۳۲۰؛ چاپ سوم؛ ۱۳۸۴.
- [21] Haykin S.; *Neural Networks: A Comprehensive Foundation*, Prentice-Hall International; Inc.; New Jersey; 1999.
- [22] Douglas KJ; *The shear strength of rock masses*; Ph.D Thesis; The University of New South Wales, Sydney, Australia; 2002.
- [۱۵] شرکت مهندسی مشاور مه‌اب قدس؛ "گزارش مطالعات ژئوتکنیک مرحله اول سد مخزنی سمیلان (جلد چهارم)، نتایج آزمون‌های آزمایشگاهی منابع قرضه درشت‌دانه و سنگ"؛ ۱۳۸۶.
- [۱۶] شرکت مهندسی مشاور ارکان رهاب؛ "گزارش مطالعات منابع قرضه سد خاکی مراش"؛ ۱۳۸۶.
- [۱۷] منه‌اج، محمدباقر. "هوش محاسباتی (جلد اول)، مبانی شبکه‌های عصبی"؛ مرکز نشر دانشگاه صنعتی امیرکبیر؛ چاپ سوم؛ ۱۳۸۴.

Prediction of stress- strain behavior in gravelly material based on Artificial Neural Networks

R. Mahin Roosta^{1*}, H. Farrokh²

1- Assistant Professor, Engineering Faculty, Tarbiat Modares University, Tehran, Iran

2- M.Sc in Soil Mechanics and foundation engineering

reza.mahinroosta@gmail.com

Abstract:

Prediction of stress-strain behavior of geotechnical material is one of the major efforts of engineers and researchers in the field of geomechanics. Experimental tests like tri-axial shear strength tests are the most effective apparatus to prepare the mechanical characteristics of gravelly material; but due to difficulties in preparing test samples and costs of the tests, only several tests will be done in a new project. Artificial neural network is a kind of method, in which engineer could judge the results based on numerous data from other similar projects, which enable the engineer to have a good judgment on the material properties.

In this research, the behavior of gravelly material was simulated by use of multi-layer perceptron neural network, which is the most useful kind of artificial neural networks in the field of geotechnical engineering. For instance, first exact information was provided from laboratory tests of various barrow areas of embankment dams in the country and effective parameters on shear strength of coarse-grained material were studied. After omitting incorrect or weak data, 95, 20 and 23 sets of data were used for learning, testing and evaluating data, respectively. Input parameters for the model were as follows: particle-size distribution curve, dry density, relative density, Los-angles abrasion percent, confining pressure, axial strain; and outputs were selected as deviator stress. In order to reach a steady state in the model and force the model to behave homogenous to the all inputs, data was normalized to the value between .05 and 0.95. In the simulation, back-propagation algorithm was used for learning or error reduction. The aim of the simulations was defined to reduce error between real data and predicted values; for instance root mean square error (RMS) was used to be minimized through simulation and predicted versus real graphs were used to observe the global error of the model. After modeling the data based on some criteria, it was shown that curves of stress-strain from simulation tests were in good agreement with those from laboratory. These close coherencies were observed in all training, testing and evaluation data, in which the RMS errors were 0.038, 0.037 and 0.026, respectively. To reach this ultimate step, a 10*19*1 multilayer perceptron was used via trial and error. In order to determine quality and quantity of the effect of inputs on outputs, and prove that the results were in good agreement with soil mechanic principles, sensitivity analyses were done on the average data of the inputs. Results show that confine pressure, uniformity coefficient and relative density of the material were the most effective parameters on the stress-strain curves; thus the model has enough capability to predict the stress-strain behavior of gravelly soils.

Keywords: Gravelly soil, Stress-strain curve, Artificial neural network, Multi-layer perceptron, Sensitivity analysis