

کاربرد شبکه عصبی مصنوعی در مهندسی ژئوتکنیک: مدلسازی، تحلیل، طراحی

میثم بنی مهد^۱، سید شهاب الدین یثربی^{۲*}

۱- فارغ التحصیل کارشناسی ارشد مهندسی عمران، دانشگاه تربیت مدرس

۲- استادیار بخش مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس

* تهران؛ صندوق پستی: ۱۵۹-۱۴۱۱۵

yasrobis@modares.ac.ir

(دریافت مقاله: اردیبهشت ۱۳۸۱، پذیرش مقاله: تیر ۱۳۸۲)

چکیده - پیش‌بینی الگوی رفتاری ساختارهای خاکی با توجه به مشاهدات قبلی و تجربیات گذشته از مسائل اصلی مهندسی ژئوتکنیک است. از این رو ارائه روشها و مدل‌های ریاضی و آماری برای تخمین روابط حاکم بر محیط، همواره مورد توجه محققان این علم بوده است. در این مقاله، شبکه عصبی مصنوعی در مدل سازی رفتار تنش - کرنش ماسه‌های سیلتی، تحلیل پایداری شیبهای کنار رودخانه ای و طراحی پوشش بتنی تونلهای آبی تحت فشار مورد استفاده قرار گرفته است. همچنین نحوه طراحی شبکه و عوامل مؤثر بر رفتار آن در مسائل مربوط، به طور خلاصه بررسی شده است. با توجه به اینکه موارد طرح شده در این تحقیق انواع مختلف مسائل مهندسی ژئوتکنیک (مدلسازی خواص خاک، تحلیل و طراحی سازه‌های خاکی) را در بر می‌گیرد و انطباق نتایج حاصل از شبکه‌های ارائه شده با نتایج تجربی و تحلیلی، می‌توان نتیجه گرفت که شبکه عصبی به عنوان روشی دقیق، سریع و آموزش پذیر، قابلیت خوبی در مهندسی ژئوتکنیک دارد.

کلید واژگان: شبکه عصبی، مهندسی ژئوتکنیک، تنش - کرنش، پایداری شیب، پوشش بتنی.

۱- مقدمه

اگرچه محققان بسیاری در زمینه خواص مکانیکی خاک مطالعه کرده‌اند، هنوز سازوکار رفتاری خاک کاملاً شناخته شده نیست. از این رو روشهای مرسوم، از جمله روابط تجربی و ریاضی، از فرضیات ساده کننده‌ای برای حل مسائل چند متغیره ژئوتکنیک استفاده می‌کنند. با مروری بر این روشها، آشکار می‌شود که این روشها نمی‌توانند رفتار پیچیده خاک را توصیف کنند. بنابراین نیاز به یک روش جایگزین - که توانایی در نظر گرفتن تمامی پارامترهای مؤثر را به طور همزمان داشته و قدرت تعمیم و یادگیری مستقیم


را از داده‌های تجربی (با در نظر گرفتن خطاها و نایقینهای موجود) داشته باشد - به طور فزاینده‌ای احساس می‌شود. شبکه عصبی به عنوان یک راه حل جایگزین، در سالهای اخیر با موفقیت، در حل بسیاری از مسائل مهندسی ژئوتکنیک استفاده شده است. زو^۱ و وو^۲ (۱۹۹۴) استفاده از نوعی شبکه عصبی چندلایه پرسپترون^۳ را در تحلیل نتایج آزمایشهای صحرایی شرح داده‌اند[۱]. آگراوال^۴ در همان سال با استفاده از شبکه عصبی، مقادیر مقاومت برشی مؤثر

1. Zhu
2. Wu
3. Multi-Layer Perceptron
4. Agrawal

در مراجع متعددی آمده است [۱۴-۱۶]. برای اینکه این مقاله به طور مستقل نیز قابل استفاده باشد، خصوصیت این شبکه‌ها، الگوریتم آموزشی و نحوه طراحی معماری آنها به طور خلاصه مورد بحث و بررسی قرار گرفته است.

۲- شبکه چندلایه پرسپترون

همانطور که گفته شد، شبکه عصبی از تعدادی واحد محاسباتی به نام نرون تشکیل شده است. این واحدهای محاسباتی با تعداد زیادی اتصال با یکدیگر ارتباط دارند که در واقع تمام دانش برگرفته از محیط در آن ذخیره شده است. اولین مدل نرون که به عنوان پایه شبکه‌های عصبی موجود شناخته می‌شود، توسط پیث^۱ و مک کولج^۲ (۱۹۴۳) معرفی شد (شکل ۱).



شکل ۱ یک واحد محاسباتی شبکه‌های عصبی (نرون)

در این شکل $x_i(k)$ ورودی i ام نرون k ، $x_1(k)$ بایاس نرون k ، w_i وزن مربوط، σ تابع فعالیت نرون k و $y(k)$ خروجی این نرون است. بر این مدل روابط ذیل حاکم است:

$$v(k) = \sum_{i=1}^n w_i x_i(k) \quad (1)$$

$$y(k) = \sigma(v(k)) \quad (2)$$

توانع فعالیت مختلفی برای شبکه‌های عصبی معرفی شده است. که تابع سیگموئید (SIG) و تانژانت هیپربولیک (TGH) پرکاربردترین آنها است [۱۵]. تاکنون انواع مختلفی

رسمهای سیلتی را بر اساس مقادیر رطوبت و تراکم نسبی پیش‌بینی کرد [۲]. همچنین این روش برای پیش‌بینی رفتار تنش- کرنش ماسه‌ها [۳]، شن‌ها [۴]، رس‌ها [۶ و ۵]، خاک‌های غیراشباع [۷] ظرفیت باربری شمع‌ها [۸] پتانسیل روانگرایی [۹] ضریب نفوذ پذیری خاک‌های ریزدانه [۱۰]، نشست پی‌های سطحی بر روی خاک‌های دانه‌ای [۱۱] و نشست سدهای سنگریزه‌ای [۱۲] استفاده شده است. شبکه عصبی مصنوعی مجموعه‌ای از عناصر ساده محاسباتی متصل به هم به نام نرون است که قابلیت یادگیری منحصر به فرد آن، به این سیستم توانایی می‌دهد تا روابط پیچیده غیرخطی را بیاموزد. این یادگیری، به استفاده کننده اجازه می‌دهد تا شبکه را مستقیماً با داده‌های تجربی آموزش داده، نتیجه آموزش را در وزنه‌های بین نرون‌ها ذخیره کند. بنابراین پس از مرحله آموزش، شبکه عصبی می‌تواند با سرعت بالا و دقت مناسب، رابطه بین متغیرهای مستقل (ورودی) و وابسته (خروجی) را مدل‌سازی و پیش‌بینی کند.

به طور کلی در مهندسی ژئوتکنیک با سه گونه مسأله مواجه هستیم. در گروه اول با استفاده از خصوصیات پایه‌ای حاصل از آزمایشها، رفتار خاک در شرایط مشخص مدل می‌شود (مدلسازی)، در گروه دوم با در نظر گرفتن این خصوصیات رفتاری، سازه خاکی مورد نظر تحلیل می‌شود (تحلیل) و در گروه سوم با توجه به نتایج تحلیل، طراحی صورت می‌گیرد (طراحی). در این مقاله، با استفاده از شبکه چند لایه پرسپترون (MLP) به عنوان نوعی تقریب زن فراگیر^۱ [۱۳]، و یکی از پر کاربردترین انواع شبکه عصبی، راه حلی برای نمونه‌ای از هر سه نوع مسأله، مدلسازی رفتار تنش-کرنش خاک‌های ماسه سیلتی، تحلیل شیبهای کنار رودخانه‌ای و طراحی پوشش بتنی تونلهای آب تحت فشار، ارائه شده است.

علاوه بر این اگرچه نظریه شبکه‌های عصبی مصنوعی

2. Piths

3. McCulloch

1. Universal Approximator

۲-۱- تعیین تعداد نرونهای ورودی و خروجی

با توجه به شرایط حاکم بر مسأله، بانک اطلاعاتی موجود و عوامل موثر، متغیرهای ورودی و خروجی انتخاب می‌شود. معمولاً این متغیرها محدوده تغییر وسیعی دارند که با توجه به کارکرد شبکه باید به بازه [۱ و ۰] یا [۱ و -۱] انتقال داده شود. مهمترین هدف از این انتقال، اصلاح توزیع متغیرهای ورودی و خروجی به نحوی است که خطای مدلسازی شبکه کم شود [۱۷]. از این رو، در این تحقیق، متغیرهای ورودی و خروجی را نسبت به مقادیر حداکثر و حداقل آنها نرمالیزه شده اند.

۲-۲- تعیین تعداد نرونهای میانی

نرونهای لایه میانی در شبکه چندلایه به عنوان یک تشخیص دهنده الگو عمل می‌کند [۱۵]. بنابراین تعداد نرونها در لایه پنهان نقش عمده‌ای در قدرت شبکه دارد. اگر تعداد نرونها کم باشد، شبکه عصبی نمی‌تواند نگاشت غیرخطی بین ورودی و خروجی را با دقت لازم منعکس کند. از طرف دیگر اگر تعداد لایه میانی بیشتر از حد لزوم باشد شبکه نگاشت غیرخطی پیچیده‌ای تولید می‌کند که داده‌های آموزشی را بخوبی یاد می‌گیرد (حفظ می‌کند) اما در مقابل داده‌های جدید عملکرد مناسبی ندارد و در واقع شبکه قدرت تعمیم خود را از دست می‌دهد [۱۵]. برای غلبه بر این مشکلات یا باید تعداد نرونها به نحوی انتخاب شود که شبکه قدرت کافی و نه بیش از حد برای تولید نگاشت ناخطی داشته باشد یا آموزش در مرحله‌ای که شبکه شروع به حفظ کردن (نه یادگیری) داده‌های آموزشی می‌کند قطع شود [۱۵].


۲-۳- آموزش و آزمایش شبکه

منظور از آموزش در شبکه MLP، تنظیم پارامترهای آزاد شبکه (وزنها) برای دریافت پاسخ مطلوب از آن است. از این رو در فرایند آموزش، ورودیهای مربوط به بخشی از

از شبکه‌های عصبی مصنوعی معرفی شده که هر یک کاربرد خاص خود را دارد. یکی از متداولترین آنها شبکه چندلایه پرسپترون یا به اختصار شبکه MLP است. در این شبکه که برای اولین بار توسط ویدرو^۱ و روزنبلات^۲ مطرح شد هر نرون در هر لایه، به تمامی نرونهای لایه قبل و بعد متصل است و هیچ‌گونه اتصال برگشتی در شبکه وجود ندارد [۱۴]. این شبکه یک لایه ورودی، خروجی و تعدادی لایه پنهان دارد که موجب می‌شود تا شبکه بخوبی نگاشتهای غیرخطی پیچیده را بیاموزد. شبکه عصبی MLP با یک لایه پنهان (شکل ۲) می‌تواند هر رابطه غیرخطی بین الگوی ورودی و خروجی را توصیف کند [۱۳]. بنابراین در این تحقیق، از شبکه عصبی با یک لایه پنهان استفاده شده که به طور فشرده با رابطه زیر بیان می‌شود:

$$\{V_{1..no}\} = MLP_{(nh)}\{U_{1..ni}\} \quad (3)$$

no تعداد مؤلفه‌های بردار خروجی، nh تعداد نرونهای لایه پنهان و ni تعداد مؤلفه‌های بردار ورودی است. به طور کلی طراحی شبکه عصبی MLP، چهار بخش مهم را شامل می‌شود که در ادامه به آن می‌پردازیم.



شکل ۲ شبکه MLP با یک لایه میانی

1. Widrow
2. Rosenblatt

بانک اطلاعاتی (مجموعه آموزشی) به شبکه ارائه می‌شود، مقادیر خروجی محاسبه شده و با مقادیر هدف مقایسه شده و با توجه به مقدار خطا، وزن‌ها اصلاح می‌شود. هر بار ارائه ورودیها و تنظیم وزن‌ها را یک سیکل آموزشی گویند [۱۶]. سیکلهای آموزشی تا جایی ادامه می‌یابد که خطا به حد قابل قبولی برسد. پس از پایان آموزش، مقادیر وزن‌ها ذخیره شده و شبکه برای بخش دیگری از داده‌ها - که در فرایند آموزش استفاده نمی‌شود (مجموعه آموزشی) - آزمایش می‌شود. در این مقاله از روش پس‌انتشار خطای استاندارد با ممتوم استفاده شده است که ضمن بالا بردن سرعت آموزش، از ناپایداری شبکه جلوگیری می‌کند [۱۶].

۳- مدلسازی رفتار تنش - کرنش ماسه‌های

سیلتی

۳-۱- بیان مسأله

برای تحلیل ساختارهای خاکی به مطالعه سازوکار رفتار خاک در مقابل بارگذاریهای متفاوت نیاز است. در این راستا، در چهار دهه گذشته، مدل‌های ریاضی متفاوتی برای مدلسازی رفتار تنش - کرنش خاک معرفی شده است. اصول کلی زیر در این مدل‌ها رعایت شده است [۱۸]:

- در نظر گرفتن فرضیات ساده کننده؛
- تعیین محدوده شکست و تسلیم؛
- بیان ریاضی مدل، طوری که دو اصل بالا را ارضا کند؛
- تعیین پارامترهای مدل با تحلیل برگشتی از روی نتایج آزمایشگاهی.

شبکه عصبی مصنوعی با توجه به قابلیت یادگیری می‌تواند رفتار خاک را از داده‌های تجربی بیاموزد. بنابراین در این روش، در نظر گرفتن فرضیات ساده‌کننده، یافتن پارامترها و تعیین محدوده شکست ضروری نیست. از طرف دیگر، مهمترین خصوصیت شبکه عصبی، انعطاف و تطبیق‌پذیری آن است که در مدلسازی رفتار خاک نقش

مهمی دارد. در خاکها به علت رفتار پیچیده، همواره بعضی داده‌های تجربی جدید وجود دارد که مدل‌های ریاضی موجود توانایی توصیف آنها را ندارند. در این حالت نیاز به معرفی مدل جدید وجود دارد تا بتواند داده‌های جدید را پوشش دهد؛ در حالی که در صورت استفاده از شبکه عصبی، شبکه می‌تواند با این اطلاعات آموزش بیشتری ببیند و اطلاعات بیشتری را در باره رفتار خاک - برای پیش‌بینی داده‌های جدید - در خود ذخیره کند و در عین حال که داده‌های جدید را پوشش خواهد داد، هیچ تغییری در ساختار شبکه حاصل نمی‌شود. در این بخش، مدلسازی رفتار تنش-کرنش ماسه‌های سیلتی با استفاده از شبکه عصبی MLP بررسی و نتایج به دست آمده از مدل با نتایج تجربی مقایسه شده است.

۳-۲- بانک اطلاعاتی

مطالعات انجام شده در سالهای اخیر نشان داده است که بافت ریزدانه، نقش عمده‌ای در رفتار برشی خاکهای ماسه سیلتی دارد. از آن جمله دیده شد که برای نسبت تخلخل ثابت، با افزایش درصد ریزدانه تا ۳۰٪، مقاومت حالت پایدار زهکشی نشده کاهش می‌یابد و پس از ۳۰٪، بعکس این مقاومت افزایش خواهد یافت [۱۹ و ۲۰]. یثربی (۱۳۷۶) آزمایشهای سه محوره زهکشی نشده متعددی را روی ماسه توپورا (ماسه استاندارد ژاپن) و ترکیب آن با درصد‌های متفاوتی (۰ تا ۳۰٪) از ریزدانه‌های تیز گوشه و گرد و ماسه سیلتی آستانه، به روش کنترل کرنش انجام داده و تأثیر درصد ریزدانه و شکل ریزدانه را بر رفتار این خاکها بررسی کرد. او سه رفتار متفاوت نرم شونده کرنشی، سخت شونده کرنشی و نرم شونده محدود کرنشی را برای خاکهای ماسه‌ای گزارش کرد [۲۱]. در این بخش از نتایج این آزمایشها (۱۳۰ عدد، ۸۲ آزمایش روی نمونه‌های ماسه توپورا و ترکیب آن با ریزدانه و ۴۸ عدد روی ماسه سیلتی آستانه) شامل منحنی‌های تنش انحرافی-کرنش و فشار آب

ساختار انتخاب شدند. بنابراین در هر نوع رفتار، شبکه‌های مورد استفاده را به صورت زیر خلاصه کرد:

$$q_i - u_i = MLP_{(10)} \{D_r, e, \varepsilon_i, \sigma_3', F_c, F_s\} \quad (4)$$

۳-۴- آزمایش شبکه‌ها

پس از آموزش شبکه‌ها، کارایی آنها در مقابل داده‌های آموزشی (قدرت شیب‌سازی) و آزمایشی (قدرت پیش‌بینی) مورد ارزیابی قرار گرفت. نمونه‌ای از خروجی شبکه‌ها در مقایسه با نتایج تجربی در شکل‌های ۳ تا ۸ دیده می‌شود. نتایج کامل حاصل از شبکه‌ها در مرجع [۲۲] آورده شده است. بر طبق نتایج حاصل مشخص است که شبکه بخوبی مقادیر تنش انحرافی و فشار آب منفذی را در کرنشهای مختلف و روند رفتاری این خاکها را بخوبی آموخته است. مدل مبتنی بر شبکه عصبی به خودی خود توضیحی درباره رابطه بین ورودی و خروجی به دست نمی‌دهد که این مسأله از گستره کاربرد از این مدلها می‌کاهد [۲۳]. از این رو باید تحلیل حساسیتی بر روی مدل‌های مبتنی بر شبکه‌های عصبی انجام شود تا نحوه اثر ورودیها بر خروجی مدل مشخص شود. به عنوان نمونه اثر شکل ریزدانه بر مقادیر تنش انحرافی و فشار آب منفذی حاصل از مدل در شرایط تراکمی، تحکیمی و درصد ریزدانه یکسان در شکل ۹ دیده می‌شود. با گرد گوشه‌تر شدن ریزدانه، اصطکاک بین ریزدانه و درشت دانه کاهش یافته و در نتیجه مقاومت برشی این خاکها کاهش می‌یابد. همچنین مقدار فشار آب منفذی کاهش می‌یابد [۲۲]. چنین روندی در مدل نیز دیده می‌شود که نشان‌دهنده عملکرد مطلوب آن است.

۴- تحلیل پایداری شیبهای کنار رودخانه‌ای

۴-۱- بیان مسأله

پایداری شیب معمولاً با تحلیل تعادل حدی با استفاده از روش تفاضل محدود یا المان محدود یا به روش قطعات بررسی می‌شود. این روشها علاوه بر فرضهای ساده کننده،

منفذی-کرنش استفاده شده است. نتایج ۶۵ آزمایش بر روی نمونه‌های ماسه تویورا و ترکیب آن با ریزدانه به عنوان مجموعه آموزشی و بقیه به عنوان مجموعه آزمایشی در نظر گرفته شده است [۲۲].

۳-۳- پیاده سازی شبکه‌ها و آموزش آنها

با توجه به وجود سه رفتار متفاوت در ماسه سیلتی، برای هر رفتار، شبکه‌های عصبی جداگانه‌ای جهت پیش‌بینی مقدار تنش انحرافی و فشار آب منفذی معرفی شده است. با توجه به پارامترهای مؤثر بر رفتار این خاکها، ورودیهای این شبکه‌ها عبارتند از: چگالی نسبی اولیه (D_r)، نسبت تخلخل اولیه (e)، تنش تحکیم مؤثر (σ_3')، درصد ریزدانه (F_c)، شکل ریزدانه (تیز گوشه (۰) یا گرد گوشه (۱) - F_s)، کرنش در قدم i (ε_i) و خروجی شبکه‌ها عبارتند از: تنش انحرافی در قدم i (q_i) یا فشار منفذی در قدم i (u_i).


خصوصیات شبکه‌های مورد استفاده در جدول (۱) ارائه شده است.

جدول ۱ خصوصیات شبکه‌های مورد استفاده


نام شبکه	خروجی	رفتار خاک
SSNET-1	q	نرم شونده
SSNET-2	u	
QSNET-1	q	نرم شونده محدود
QSNET-2	u	
SHNET-1	q	سخت شونده
SHNET-2	u	

برای آماده‌سازی زوج داده‌های آموزشی و آزمایشی در کرنشهای ۱۲٪، ۸٪، ۵٪، ۳٪، ۲٪، ۱٪، ۰/۵٪، ۰/۲۵٪، ۱۵٪ و ۱۸٪، مقادیر u و q ثبت شده است. برای انتخاب تعداد نرونها میانی، کارایی شبکه‌ها با تعداد متفاوت نرونها میانی در مقابل داده‌های آموزشی و آزمایشی مورد مطالعه قرار گرفت و شبکه‌های با ۱۰ نرون میانی با مقدار میانگین مربعات خطای 10^{-5} ($1/3 \times 10^{-5}$) به عنوان بهترین


I. Mean Square Error(MSE)




شکل ۳ قدرت شبیه‌سازی SSNET-1,2




شکل ۴ قدرت شبیه‌سازی SSNET-1,2




شکل ۵ قدرت شبیه‌سازی SHNET-1,2




شکل ۶ قدرت پیش‌بینی SSNET-1,2



شکل ۷ قدرت پیش‌بینی QSNET-1,2



شکل ۸ قدرت پیش‌بینی SHNET-1,2



شکل ۹ اثر شکل ریزدانه بر رفتار خاکهای ماسه سیلتی

۲-۴- باتک اطلاعاتی

داده‌های مورد استفاده در آموزش و آزمایش شبکه از تحلیل شیب‌ها در شرایط ژئوتکنیکی و هندسی مختلف، به روش تفاضل محدود با نرم لفتوار CA2 آماده شده است. تعداد کل زوج داده‌ها برابر ۱۰۰۰ بوده که ۸۰۰ عدد از آنها برای آموزش و ۲۰۰ عدد برای آزمایش شبکه استفاده شده است. حدود تغییر پارامترهای مؤثر با توجه به شکل (۱۰) در جدول (۲) آمده است.

جدول ۲ خصوصیات هندسی و ژئوتکنیکی شیبهای مورد مطالعه


حدود	H (m)	H1 (m)	m	C' (kg/cm ²)
حداقل	۴	۰	۰/۳	۵۰۰
حداکثر	۱۳	2H-1	۱/۵	۲۵۰۰
حدود	φ' (Deg.)	γ _{sat} (kg/cm ²)	γ _t (kg/cm ²)	
حداقل	۱۰	۱۷۰۰	۱۵۰۰	
حداکثر	۲۴	۲۰۰۰	۱۸۰۰	

۳-۴- پیاده سازی شبکه و آموزش آن

مدل شبکه عصبی بکار رفته عبارتست از:

$$\{R, X, Y, F_s\} = MLP_{(1)} \{H, m, H_1, \gamma_t, \gamma_{sat}, C', \phi'\} \quad (4)$$

زمان زیادی را برای تحلیل شیب صرف می‌کنند. در مورد شیبهای کنار رودخانه‌ای، به علت هندسه پیچیده‌تر و حضور آب، همچنین در مسائلی که به تحلیل پی در پی سازه نیاز است (مانند مسائل بهینه‌سازی)، زمان تحلیل نقش عمده‌ای بازی می‌کند. به عنوان یک روش جایگزین از شبکه MLP می‌توان استفاده کرد این شبکه می‌تواند با توجه به ساختار موازی، کوچکتر بودن ماتریسهای ذخیره شده و قدرت یادگیری، در زمان بسیار کم و با دقت کافی، به تحلیل شیب مورد نظر بپردازد. در شکل ۱۰ خصوصیات هندسی و ژئوتکنیکی مسأله به طور شماتیک نشان داده شده است.




شکل ۱۰ خصوصیات هندسی و ژئوتکنیکی شیبهای مورد مطالعه

جدول ۳ نمونه‌ای از نتایج حاصل از شبکه

مدل	CA2	STABLE	MLP	CA2	STABLE	MLP	CA2	STABLE	MLP
H	۷/۵	۷/۵	۷/۵	۷/۵	۷/۵	۷/۵	۷/۵	۷/۵	۷/۵
H1	۰/۴	۱/۴۵	۱/۴۵	۱/۴۵	۱/۴۵	۱/۴۵	۱/۴۵	۱/۴۵	۱/۴۵
m	۱/۵	۵/۵	۵/۵	۵/۵	۵/۵	۵/۵	۵/۵	۵/۵	۵/۵
γ_t	۱۵۵۰	۱۸۱۰	۱۸۱۰	۱۸۱۰	۱۸۱۰	۱۸۱۰	۱۸۱۰	۱۸۱۰	۱۸۱۰
γ_{sat}	۱۶۵۰	۲۰۰۰	۲۰۰۰	۲۰۰۰	۲۰۰۰	۲۰۰۰	۲۰۰۰	۲۰۰۰	۲۰۰۰
C'	۲۱۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰
ϕ'	۱۵	۲۴	۲۴	۲۴	۲۴	۲۴	۲۴	۲۴	۲۴
R	۱۳/۳	۱۵	۱۲	۱۴	۱۴/۱	۱۳/۳	۱۴	۱۴	۱۴/۵
X	۱۱	۹/۵	۱۱/۷	۱۷/۵	۷/۸	۱۵/۵	۲۰/۵	۲۱/۲	۲۰/۹
Y	۲۰/۵	۲۱/۱	۱۸/۴	۲۲	۲۱/۲	۱۹/۹	۲۲	۲۱/۳	۲۱/۴
F _s	۱/۳	۱/۳	۱/۴	۱/۷	۱/۵	۱/۶	۱/۱	۱/۶	۱/۶

سه تحلیل تطابق خوبی با یکدیگر دارند. علاوه بر این سرعت محاسباتی شبکه MLP بسیار بیشتر از CA2 و STABLE در شرایط یکسان است؛ از این رو در جایی که زمان تحلیل نقش مهمی دارد یا فقط تخمین ضریب اطمینان و سطوح لغزشی بحرانی مورد نظر است، استفاده از شبکه عصبی مناسبتر از روشهای مبتنی بر تفاضل محدود یا روش قطعات است. در قدم بعدی تحلیل حساسیتی بر روی شبکه انجام شده است که نمونه ای از آن در اشکال ۱۲ و ۱۳ دیده می‌شود. با افزایش ضریب چسبندگی و اصطکاک، ضریب اطمینان افزایش ضریب افزایش می‌یابد. این روند کاملاً منطبق به روند قابل انتظار و حاصل از دو روش دیگر است. بنابراین با توجه به نتایج به دست آمده از تحلیل حساسیت دیده می‌شود که شبکه MLP مورد نظر اثر تغییرات پارامترها را بر خروجی بخوبی توصیف می‌کند.

که در آن X , Y مختصات مرکز دایره بحرانی، شعاع دایره و F.S ضریب اطمینان برای شیب بحرانی است. در مطالعات اولیه مربوط به این مسأله، شبکه با توابع فعالیت متفاوت آموزشی داده شد و با مقایسه کارایی آنها، توابع $TGH(0.5x)$ و $SIG(x)$ برای لایه میانی و خروجی انتخاب شده است. برای انتخاب تعداد نرونهای میانی مورد نیاز، مقادیر خطای متوسط شبکه با تعداد نرونهای میانی متفاوت، برای بانک اطلاعاتی مورد استفاده، مورد مقایسه قرار گرفته و ۱۱ نرون برای لایه میانی انتخاب شده است (شکل ۱۱).



شکل ۱۱ تأثیر تعداد نرونهای میانی بر خطای کل شبکه

۴-۴- تست شبکه

پس از پایان مرحله آموزشی، شبکه در مقابل داده‌های تجربه نشده، آزمایش شده است. به منظور مقایسه، این شیب‌ها با استفاده از CA2 و روش بیشاپ ساده شده با نرم افزار STABLE تحلیل شده است. جدول ۳ نمونه‌ای از نتایج به دست آمده را نشان می‌دهد. نتایج کامل در مرجع [24] آورده شده است. با مرور نتایج به دست آمده، آشکار است که شبکه عصبی بخوبی روش تفاضل محدود را در حل این مسأله خاص آموخته است. ضریب اطمینان حاصل از MLP حدود ۱۰٪ از ضریب اطمینان حاصل از CA2 بیشتر بوده و سطوح لغزش بحرانی به دست آمده حاصل از

۵-۲- بانک اطلاعاتی


عوامل موثر بر عملکرد پوشش بتنی عبارت است از: زاویه اصطکاک داخلی (ϕ)، وزن مخصوص طبیعی (γ)، ضریب عکس العمل خاک (ks)، قطر حفاری شده تونل (D)، مقاومت مشخصه بتن (f'_c) و اختلاف ارتفاع بین تراز حداکثر و محور تونلی (H) است. حدود تغییر این پارامترها بر طبق جدول ۴ است.

جدول ۴ حدود تغییر پارامترهای ورودی شبکه

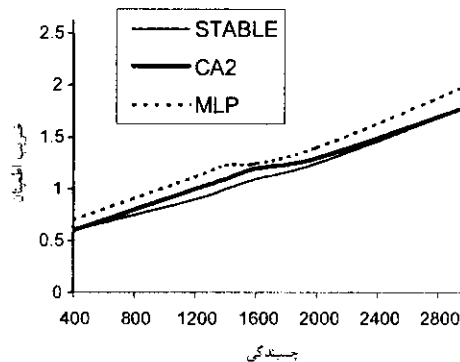
حدود	ϕ (Deg.)	γ (Ton/m ³)	K (Kg/cm ²)
حداقل	۲۷	۱/۶	۳
حداکثر	۵۵	۲/۶	۳۰۰
حدود	D (m)	f'_c (Kg/cm ²)	H (m)
حداقل	۳	۲۴۰	۳۰
حداکثر	۸	۳۰۰	۱۲۰

برای آماده‌سازی زوج داده‌های آموزشی و آزمایشی تونلها با شرایط هندسی و ژئوتکنیکی مختلف بر مبنای آیین‌نامه طراحی انستیتوی تحقیقاتی هیدروپراتیک مسکو، بارگذاری و تحلیل و طراحی شده است. بارهای وارد بر تونل به صورت ذیل است:

- بارهای دائمی: شامل فشار مصالح اطراف تونل، وزن پوشش؛
 - بارهای موقت طولانی‌مدت: شامل فشار داخلی آب در تونل، فشار آب زیرزمینی؛
 - بارهای موقت کوتاه‌مدت: شامل تأثیر زلزله، فشار داخلی آب در تونل به هنگام بالارفتن سریع سطح آب تا تراز حداکثر مخزن، تورم و خزش سنگها.
- پس از بارگذاری سازه با استفاده از مدل تحلیلی تیر و فنر یا وینکلر به صورت کرنش صفحه‌ای، با نرم‌افزار Sap90 تحلیل شده (شکل ۱۴) و در نهایت طراحی با توجه به دو حالت حدی مقاومت و عدم وجود ترک



شکل ۱۲ تأثیر تغییرات زاویه اصطکاک بر ضریب اطمینان بحرانی در یک شیب خاص



شکل ۱۳ تأثیر تغییرات ضریب چسبندگی بر ضریب اطمینان بحرانی در یک شیب خاص

۵- طراحی پوشش تونل‌های آب تحت فشار


۱-۵- بیان مسأله

تونل‌های آبی با رژیم تحت فشار یکی از سازه‌هایی است که کاربرد بسیاری در پروژه‌های آبرسانی و سدسازی دارد. در این تونلها، به منظور ایجاد خصوصیت هیدرولیکی مطلوب و همچنین ایجاد سیستم نگهدارنده دائمی از پوشش بتنی استفاده می‌شود. MLP می‌تواند با استفاده از نمونه‌های طراحی، روش طراحی را بیاموزد و با سرعت و دقت بالا، طراحی پوشش بتنی را که شامل ضخامت (t)، میزان آرماتور حلقوی (A_s) است، انجام دهد.

طراحی)، می‌تواند مستقیماً با توجه به پارامترهای مؤثر، به طراحی پوشش تونل بپردازد. در قدم بعدی، تحلیل حساسیتی روی شبکه انجام شد که نمونه‌ای از آن در شکل‌های ۱۵ و ۱۶ دیده می‌شود. بر طبق این شکل‌ها افزایش مقاومت بتن در مدل مبتنی بر شبکه، موجب افزایش میزان آرماتور مصرفی می‌شود اما ضخامت پوشش بتنی را کاهش می‌دهد. این روند منطبق بر تغییرات پیش‌بینی شده در آیین‌نامه است که در واقع نشان‌دهنده عملکرد رضایت بخش شبکه در منظور کردن اثر تغییرات مقاومت بتن است.

جدول ۵ نمونه‌ای از نتایج حاصل از شبکه

روش		Des.		MLP	
Des.	MLP	Des.	MLP	Des.	MLP
		۲۵	۲۷	۴۲	
		۲	۲/۴	۱/۹۵	
		۱۲۵	۲۰۸	۸۵	
		۵	۳/۵	۶	
		۲۶۵	۲۷۵	۲۹۰	
		۳۰	۶۸	۱۰۵	
T	۷۵	۲۵	۲۱	۱۰۰	۱۰۰/۸
A_s	۱۷/۲	۱۷/۴	۲۷/۴	۸/۵	۸/۶




شکل ۱۵ تأثیر تغییر F_c بر ضخامت پوشش

صورت گرفته است. ۸۸ زوج داده برای آموزش شبکه و ۳۰ داده برای آزمایش شبکه استفاده شده است.

۳-۵- پیاده سازی شبکه و آموزش آن

شبکه عصبی به کار رفته با معادله ذیل معرفی می‌شود:

$$\{t, A_s\} = MLP_{(7)} \{\phi, \gamma, K, D, f'_c, H\} \quad (5)$$



شکل ۱۴ مدل تحلیلی تونل مدور یکپارچه

توابع فعالیت به کار رفته در لایه میانی و لایه میانی و لایه خروجی، پس از بررسی‌های اولیه، به ترتیب $TGH(6x)$ و $SIG(2x)$ انتخاب شد و این شبکه پس از ۱۶۰۰۰ تکرار، به حداقل خطای متوسط ($2/71 \times 10^{-4}$) می‌رسد.

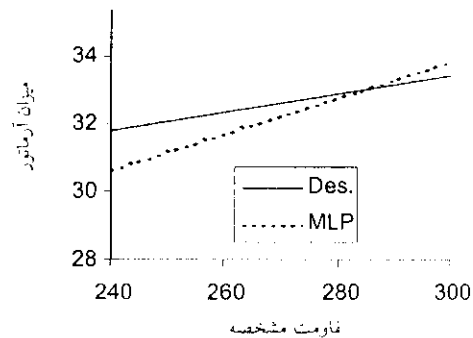
۴-۵- آزمایش شبکه

پس از پایان آموزش شبکه، شبکه در مقابل داده‌های آزمایشی تست شده اند. نمونه‌ای از نتایج حاصل از شبکه در مقایسه با روش مبتنی بر آیین‌نامه در جدول ۵ ارائه شده است. نتایج کامل حاصل از مدل در مرجع [۲۵] آورده شده است.

با توجه به نتایج حاصل می‌توان گفت که شبکه با خطای ۱٪ تا ۱۴٪ به خوبی روش طراحی را آموخته و به خلاف روش‌های مرسوم طراحی (بارگذاری، تحلیل و

"Data Analysis and Modeling Using an Artificial Neural Network;" Proc. 13th Conference of Int. Soc. Soil Mechanics and Foundation Engrg; Vol. 4, 1994; pp. 1441-1444.

- [3] Ellis, G.W.; Yao, C.; Zhao, R.; Penumadu, D.; "Stress Strain Modeling of Sands Using Artificial Neural Networks;" J. Geo. Engrg; Vol. 121, No. 5, 1995; pp. 429-435.
- [4] Penumadu, D.; Zhao, R.; "Modeling Drained Compression Behavior of Sand Using ANN, Numerical Method in Geotechnical Engineering;" Geotechnical Special Publication, ASCE, No.96, 2000; pp. 71-87.
- [5] Penumadu, D.; Jin-Nan, L.; Chameau J-L.; Arumugam, S.; "Rate Dependent Behavior of Clays Using Neural Networks;" Proc. 13th Conference of Int. Soc. Soil Mechanics and Foundation Engrg; Vol. 4, 1994; pp. 1445-1448
- [6] مهین روستا، رضا؛ "پیش بینی رفتار تنش-کرنش خاکهای رسی با استفاده از شبکه عصبی مصنوعی؛" پایان نامه کارشناسی ارشد، دانشگاه صنعتی شریف؛ ۱۳۷۷.
- [7] Habibagahi, G.; Katchbi, S.; Johari, A.; "A Neural Network Framework for Unsaturated Soils.;" Unsaturated soils for Asia, eds: Toll & Leong, Balkema, Rotterdam; 2000; pp. 107-111.
- [8] Abu Kiefa, M.A.; "General Regression Neural Networks for Driven Piles in Cohesionless Soils;" Geotechnic. & Geoenv. Engrg., ASCE; 124(12), 1998; pp. 1177-1185.
- [9] Goh, A.T.C.; "Seismic Liquefaction Potential Assessed by Neural Networks;" J. Geo. Eng.; Vol. 120, No. 9, pp. 1467-1480.
- [10] Najjar, Y. M.; Basheer, I.A.; "Utilizing Computational Neural Networks for Evaluating the Permeability of Compacted Clay Liners;" Geotechnical & geological



شکل ۱۶ تاثیر تغییر f_c بر میزان آرماتور

۶- جمع بندی

در این مطالعه، شبکه عصبی MLP به عنوان روشی جایگزین برای حل انواع مسائل ژئوتکنیک مدلسازی (رفتار تنش - کرنش خاکهای ماسه سیلتی)، تحلیل (شیبهای کنار رودخانه‌ای) و طراحی (پوشش بتنی تونلهای آبی تحت فشار) استفاده شده است. با دقت در نتایج به دست آمده از شبکه در مسائل مطرح شده دیده می‌شود که با وجود متفاوت بودن این مسائل، شبکه عصبی با خطای حداقل، سرعت بالا و علاوه بر آن توانایی یادگیری، کارایی بسیار بالایی را در حل این مسائل از خود نشان داده است. همچنین تحلیل حساسیت انجام شده نشان‌دهنده آن است که منطق حاکم بر هر سه مسأله را شبکه عصبی مربوط به خوبی آموخته است. این موارد در واقع توانمندی شبکه عصبی را در حل انواع مسائل ژئوتکنیک نشان می‌دهد.

۷- منابع

- [1] Zhou, Y. X.; Whu, X. P.; "Use of neural Networks in the Analysis and Interpretation of Site Investigation Data;" Computer & Geotechnics, Vol. 16, No. 2, 1994; pp. 105-122.
- [2] Agrawal, G.; Frost, J.D.; Chameau, J.L.;

- Geoenvir. Engrg., ASCE, Vol. 124, No. 6, 1998; pp. 479-491.
- [20] Zlatovic, S.; Ishihara, K.; "On the Influence of Nonplastic Fines on Residual Strength;" Proc. IS Tokyo' 95, 1995; pp. 239-244.
- [۲۱] یثربی، سیدشهاب الدین؛ "بررسی اثر میزان و شکل ریزدانه ها بر رفتار حالت پایدار خاکهای ماسه ای اشباع به منظور ارزیابی پتانسیل روانگرایی در این خاکها؛" رساله دکترای مهندسی ژئوتکنیک، دانشگاه صنعتی شریف؛ ۱۳۷۶
- [۲۲] سبحانی، سعید؛ "مدل کردن رفتار تنش-کرنش زهکشی نشده ماسه های سیلتی با استفاده از شبکه عصبی مصنوعی؛" پایان نامه کارشناسی ارشد عمران، دانشگاه تربیت مدرس؛ ۱۳۷۸.
- [23] Widham, L. E.; Loparo, K. A.; "Artificial Intelligence, Simulation and Modeling: Critical Survey, Artificial Intelligence, Simulation and Modeling;" L.E. Widman; K.A. Loparo; N.R. Nielsen; eds.; Wiley, 1989; pp. 1-45.
- [۲۴] احمدی پیشکوهی، کاظم؛ "بررسی پایداری دیواره های رودخانه با استفاده از شبکه های عصبی مصنوعی؛" پایان نامه کارشناسی ارشد عمران - خاک و پی، دانشگاه تربیت مدرس؛ ۱۳۷۷.
- [۲۵] تقی پور میرزایی، محمد رسول؛ "استفاده از شبکه های عصبی مصنوعی در طراحی سیستم های نگهدارنده تونلها؛" پایان نامه کارشناسی ارشد عمران - سازه، دانشگاه آزاد اسلامی - واحد جنوب؛ ۱۳۷۷.
- Eng, Vol. 14, No. 3, pp. 193-212.
- [11] Shahin, M.A.; Maier, R.H.; Jaksa, M.B.; "Predicting Settlement of Shallow Foundations Using Neural Networks;" J. Geo & Geoenvir. Engrg, Vol. 128, No.9, 2002; pp. 785-793.
- [12] Habibagahi G.; "Post-Construction Settlement of Rockfill Dams Analyzed Via Adaptive Network-Based Fuzzy Inference Systems;" Computers and Geotechnics; 29, 2002; pp. 211-233.
- [13] Hornik, K.M.; Stinchcombe, M.; White, H.; "Multilayer Feedforward Networks are Universal Approximator;" Neural networks; Vol. 2, No. 5, 1989; pp. 359-366.
- [14] Haykin, S.; "Neural Networks, a Comprehensive foundation; Prentice Hall: 1999.
- [15] Smith, G.N.; "Probabilistic and Statistics in Civil Engineering;" Collins; 1986.
- [۱۶] منهاج، محمد باقر؛ هوش محاسباتی (جلد اول)، مبانی شبکه های عصبی مصنوعی، دانشگاه امیر کبیر، ۱۳۷۷.
- [17] Shi, J.J.; "Reducing Prediction Error by Transforming Input Data for Neural Networks;" J. of Computing in Civil Engrg., ASCE, 14, No. 2, 2000; pp. 109-116.
- [18] Ghaboosi, J.; J.H Garret Jr.; Wu, X; "Knowledge-based Modeling of Material Behavior with Neural Networks;" J. Engrg. Mech., ASCE, Vol.117, No.1., 1991; 132-153.
- [19] Thevanayagam, S.; "Effect of Fines and Confining Stress on Undrained Shear Strength of Silty Sands;" J. Geotech &