

مقایسه‌ی روش‌های مختلف ارزیابی میزان اثرگذاری متغیرهای ورودی در شبکه‌های عصبی پیشخور با استفاده از داده‌های ژئوتکنیکی

علی شفایی (استادیار)

رژیمار قاطع (کوشناس ارشد)

پژوهشگاه بین‌المللی ژئوشناسی و مهندسی زلزله

شبکه‌های عصبی پیشخور به‌عنوان ابزاری مناسب در بسیاری از زمینه‌های مهندسی عمران کاربرد داشته‌اند. این شبکه‌ها به‌ویژه در بسیاری از مسائل مهندسی ژئوتکنیک کاربرد موفقیت‌آمیزی داشته‌اند. مروری بر مقالات منتشره در این زمینه، بیان‌گر این کاربرد موفقیت‌آمیز در زمینه‌هایی همچون پیش‌بینی ظرفیت شمع‌ها، مدل‌سازی رفتار خاک‌ها، روان‌گرایی و... است. با این حال، الگوریتم‌های آموزشی هیچ‌گونه اطلاعاتی درباره‌ی میزان اثرگذاری هر یک از پارامترهای ورودی در متغیرهای خروجی در اختیار کاربر قرار نمی‌دهند. به‌عبارت دیگر فهم سریع درجه‌ی اهمیت ورودی‌ها با استفاده از وزن‌ها و توابع تحریک ممکن نیست. در حقیقت شبکه‌های عصبی مصنوعی به‌عنوان یک جعبه‌سیاه به‌کاربر معرفی می‌شوند که فقط می‌تواند با پردازش بسیار پیچیده بر روی داده‌ها، خروجی‌های مشخصی تولید کند. برای حل این مشکل در طول ۱۵ سال اخیر روش‌های تفسیری متعددی به‌منظور تحلیل میزان اثرگذاری و اهمیت متغیرهای ورودی بر روی خروجی‌های شبکه پیشنهاد شده است. در این پژوهش ۶ روشی که پرکاربردترین روش‌های تفسیری‌اند با یکدیگر مقایسه شده‌اند. داده‌های مورد استفاده برای تربیت شبکه‌های عصبی براساس مجموعه آزمایشاتی است که برای تعیین پارامترهای دینامیکی رس‌های مخلوط انجام شدند. در نهایت، روشی که بهترین عملکرد تفسیری را نشان می‌دهد معرفی شده است.

shafieea@iiees.ac.ir
razmyar_gh@yahoo.com

واژگان کلیدی: تحلیل حساسیت، روش تولید وزن، رس مخلوط، مدل برشی، نسبت میرایی.

مقدمه


استفاده‌ی کامل از پتانسیل آن در کارهای عملی مهندسی شده است. به‌منظور رفع این مشکل مطالعات متعددی برای بررسی عملکرد شبکه و نیز درجه‌ی اهمیت و اثرگذاری متغیرهای ورودی انجام شده است. در این تحقیق سعی بر آن است تا براساس دو مدل شبکه‌ی عصبی ساخته شده، روش‌هایی که تاکنون برای سنجش اهمیت متغیرهای ورودی پیشنهاد شده‌اند مقایسه شوند. در نهایت، روشی که بیش از سایر روش‌ها در تحلیل حساسیت مدل ژئوتکنیکی معرفی شده موفق باشد برگزیده خواهد شد.

یکی از مشکلات بزرگ مدل‌هایی که براساس شبکه‌های عصبی ساخته می‌شوند، عملکرد آنها همانند یک جعبه‌سیاه^[۱] است. این بدان معناست که پس از ساختن یک مدل شبکه‌ی عصبی امکان فهم و درک رابطه‌ی پیچیده‌ی بین ورودی‌ها، خروجی‌ها، وزن‌ها و بردارهای بایاس برای طراح شبکه مقدور نیست و شبکه هیچ‌گونه توضیحی درباره‌ی نحوه‌ی تأثیر متغیرهای ورودی بر روی خروجی‌ها نمی‌دهد. اگرچه شبکه‌های عصبی مصنوعی ابزاری قوی برای یادگیری رابطه‌ی ناشناخته و پیچیده‌ی یک فضای ورودی و فضای خروجی‌اند، برخلاف مدل‌های ریاضی به‌خودی خود اثر پارامترهای ورودی بر پارامترهای خروجی و نحوه‌ی به دست آمدن خروجی مدل را توضیح نمی‌دهند. به‌عبارت دیگر پیش‌بینی شبکه‌ی عصبی مبتنی بر یک رابطه‌ی کور برای داده‌های جدید با استفاده از تجزیه و تحلیل داده‌های آموزشی بدون هیچ توضیحی در مورد اثر متغیرهای ورودی بر متغیرهای خروجی است.^[۱] به‌همین دلیل، از آنجا که اعتبار شبکه‌های عصبی مصنوعی بستگی کامل به توضیح و تفسیر نتایج به دست آمده دارد، عدم توانایی شبکه در توضیح رابطه‌ی حاکم، مانع از

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی نوعی مدل‌های رایانه‌ی‌اند که با الهام از عملکرد مغز انسان ساخته می‌شوند. این شبکه‌ها پردازش‌گرهایی موازی، متشکل از واحدهای پردازش‌گر

مطالعات انجام شده حاکی از آن است که در بسیاری از موارد عملکرد شبکه‌های عصبی در مقایسه با روش‌های سنتی بهتر بوده است. ساده‌سازی‌های موجود در ساختن مدل‌های ریاضی (به علت عدم توانایی در درک مسئله) در شبکه‌های عصبی وجود ندارد؛ این در حالی است که شبکه‌های عصبی فقط براساس داده‌های موجود کار می‌کنند و هیچ‌گونه ساده‌سازی که سبب حذف پیچیدگی‌های طبیعت مسئله شود انجام نمی‌دهند. از سوی دیگر، شبکه‌های عصبی این قابلیت را دارند که با گذشت زمان و افزوده شدن نتایج و داده‌های جدید خود را نوسازی کرده و پاسخ‌های بهتری ارائه کنند حال آن‌که این خصوصیت در مدل‌های ریاضی وجود ندارد.



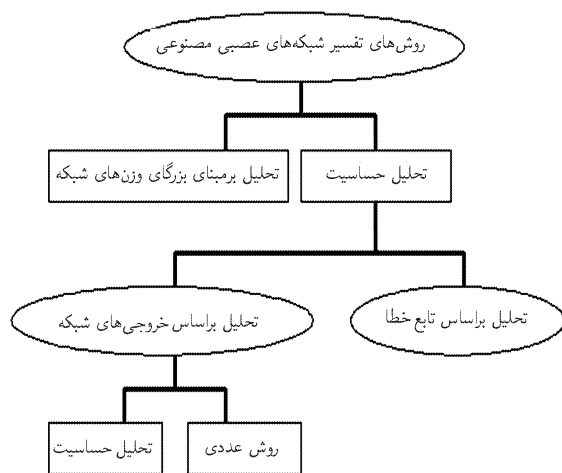
شکل ۱. نمونه‌یی از آرایش معماری شبکه‌های عصبی.

انواع روش‌های سنجش اهمیت متغیرهای ورودی

تا امروز بیشتر تحقیقاتی که در زمینه‌ی دانش شبکه‌های عصبی انجام شده است متمرکز بر توسعه‌ی روش‌های یادگیری جدید، کشف معماری‌های جدید شبکه و توسعه‌ی کاربردهای شبکه در علوم جدید بوده است. از سوی دیگر، متأسفانه توجه چندانی به ابداع و مطالعه‌ی روش‌های جدید برای درک ماهیت روابط پیچیده‌ی درون‌شبکه‌یی نشده است. در واقع شبکه‌ها عموماً به‌عنوان جعبه‌سیاهی معرفی می‌شوند که فقط قادر به تبدیل ورودی‌ها به خروجی‌های مورد نظرند. به‌بیان دیگر امکان درک سریع رابطه بین وزن‌ها یا توابع تحریک شبکه با مجموعه‌داده‌های تربیتی وجود ندارد. بنابراین برخلاف مدل‌های کلاسیک آماری، در شبکه‌های عصبی درک نحوه‌ی اثرگذاری متغیرهای ورودی بر روی متغیرهای خروجی چندان ساده نیست. تا پایان سال ۱۹۸۰ روش‌های متعددی برای تفسیر عملکرد شبکه‌های چندلایه‌ی پیش‌خور (MLP) ارائه شد^[۱] این روش‌ها به دو دسته‌ی کلی تقسیم می‌شوند (شکل ۲): تحلیل براساس بزرگی وزن‌های شبکه و آنالیز حساسیت.

۱. تحلیل براساس بزرگی وزن‌های شبکه

در این روش براساس مقادیر ذخیره‌شده در ماتریس وزن شبکه، تأثیر نسبی هر یک از متغیرهای ورودی بر روی خروجی‌ها تفسیر و ارزیابی می‌شود. تاکنون معادلات متنوعی براساس بزرگی وزن‌های شبکه ارائه شده‌اند. یکی از انواع این معادلات



شکل ۲. روش‌های موجود برای تفسیر عملکرد شبکه‌های عصبی.

کوچک‌اند و به ذخیره‌ی اطلاعات تجربی و آماده‌سازی آن برای استفاده تمایل دارند.^[۳] شبکه‌ی عصبی از دو جنبه‌ی کلی به مغز شباهت دارد:

۱. اطلاعات همانند مغز طی یک فرایند یادگیری از محیط کسب می‌شوند.
۲. وزن‌های سیناپتیک برای ذخیره‌ی اطلاعات به‌کار می‌روند.

عناصر اصلی تشکیل دهنده‌ی شبکه‌های عصبی نرون‌هایی هستند که به‌وسیله‌ی اتصالات درونی به یکدیگر متصل شده‌اند. نرون‌ها عموماً به سه دسته‌ی ورودی، میانی (پنهان) و خروجی تقسیم می‌شوند. (شکل ۱)

داده‌ها توسط لایه‌ی ورودی وارد شبکه، و خروجی‌ها نیز توسط لایه‌ی خروجی تولید می‌شوند. اتصالات میانی نیز وزن‌های سیناپتیک را در خود حفظ می‌کنند و در واقع حافظه‌ی شبکه‌اند. هر یک از واحدهای پردازش‌گر (نرون‌ها) یک تابع تحریک دارند. این توابع تحریک سیگنال ورودی را با بردار بایاس جمع، و خروجی مشخصی تولید می‌کنند. این خروجی در نقش سیگنال ورودی برای نرون‌های لایه‌ی بعدی است. تعداد نرون‌ها و آرایش معماری آنها با توجه به ماهیت مسائل مختلف متفاوت خواهد بود. تاکنون آرایش‌های معماری متفاوتی برای مدل‌های مبتنی بر شبکه‌های عصبی ارائه شده است که در بین آنها پرسپترون‌های چندلایه در رده‌ی کاربردی‌ترین این معماری‌ها شناخته شده‌اند. در این تحقیق نیز با توجه به کاربرد کلیدی این دسته از شبکه‌های عصبی در مسائل مهندسی، به سنجش اهمیت متغیرهای ورودی در آنها خواهیم پرداخت.

کاربرد شبکه‌های عصبی در شاخه‌های مختلف مهندسی ژئوتکنیک

شبکه‌های عصبی در شاخه‌های مختلف مهندسی ژئوتکنیک به کار رفته‌اند. مروری بر مقالاتی که تا امروز در این زمینه به چاپ رسیده‌اند گویای این حقیقت است که موفقیت‌های زیادی در حال شکل‌گیری است و افق‌های وسیع‌تری نیز نمایان است. شاخه‌های متنوعی که تا امروز در ارتباط با شبکه‌های عصبی به کار رفته‌اند عبارت‌اند از: پیش‌بینی ظرفیت شعاع‌ها، سازه‌های نگه‌دارنده‌ی خاک، نشست سازه‌ها، پایداری شیروانی، طراحی تونل‌ها و بازشوهای زیرزمینی، روان‌گرایی، متراکم‌سازی خاک، تورم خاک، طبقه‌بندی خاک‌ها، پیش‌بینی پروفیل خاک‌ها، مدل‌سازی رفتار خاک‌ها و تزریق در پی سدها.^[۴]

محاسبه‌ی تحلیلی در روش تحلیل حساسیت به دست می‌آید. با اعمال قاعده‌ی مشتق زنجیره‌یی به $\frac{\partial YK}{\partial X_i}$ داریم:

$$S_{ik} = \frac{\partial y_k}{\partial x_i} = f'(net_k) \sum_{j=1}^L v_{jk} f'(net_j) W_{ij} \quad (6)$$

که در آن S_{ik} بیان‌گر حساسیت خروجی (y_k) نسبت به تغییرات در متغیر ورودی (x_i) است و $f'(net_k)$ و $f'(net_j)$ مشتقات توابع تحریک نرون‌های لایه‌ی پنهان j و نرون‌های خروجی K هستند. محاسبه‌ی مشتقات جزئی در تعیین اهمیت ورودی سودمند است چرا که این مشتقات مقدار شیب لحظه‌یی بین هریک از زوج‌های ورودی و خروجی x_i و y_k را ارائه می‌کنند. برتری مشهود این روش نسبت به روش‌های وزنی در این است که برخلاف روش‌های وزنی که فقط بر مقادیر وزن ذخیره‌شده در سیناپس‌ها متکی‌اند، در اینجا مقادیر بردارهای ورودی و توابع تحریک به کار رفته در لایه‌های میانی نیز نقش مهمی در تعیین اهمیت نسبی متغیرهای ورودی دارند.

چنان‌که در شکل ۲ ملاحظه شده یکی دیگر از انواع روش‌های تحلیل حساسیت «تحلیل براساس تابع خطا»^[۳] است. در این روش، که در سال ۲۰۰۰ تحت عنوان «روش قیدگذاری» نیز معرفی شده است^[۴]، خطای تولیدشده توسط الگوهای اصلی با خطای تولیدشده هنگام محدودکردن ورودی‌های مورد نظر به اعدادی ثابت برای تمامی الگوها مقایسه می‌شود. در رابطه‌ی ۷ روش قیدگذاری نمایش داده شده است:

$$\xi(x_i) = 1 - \frac{g(x|_{x_i=\bar{x}_i})}{g(x)} \quad (7)$$

در این رابطه $g(x)$ نمایان‌گر تعمیم‌پذیری شبکه و $g(x|_{x_i=\bar{x}_i})$ بیان‌گر تعمیم‌پذیری مقید شبکه است که در آن x_i به مقدار ثابت \bar{x}_i مقید می‌شود. $\xi(x_i)$ نیز میزان نسبی اثرگذاری متغیر ورودی x است.

در سال ۲۰۰۳ روش دیگری به نام «تحلیل حساسیت عددی»^[۴] پیشنهاد شد.^[۱] این روش بر مبنای محاسبه‌ی شیب‌هایی است که بین ورودی‌ها و خروجی‌ها شکل می‌گیرد. به علت کاربرد این روش در مورد الگوهای یادگیری خاص از ارائه‌ی آن صرف‌نظر شده است.

معرفی مدل‌های شبکه‌ی عصبی و بانک اطلاعاتی

برای پیش‌بینی رفتار تغییر شکل تناوبی (شامل مدول برشی و نسبت میرایی) مخلوط‌های رس - سنگ‌دانه (که در هسته‌ی سدهای خاکی کاربرد دارند) دو مدل شبکه‌ی عصبی طراحی شده‌اند.^[۱] این مدل‌ها بر مبنای مطالعات انجام‌شده بر روی رس‌های مخلوط ساخته شدند.^[۱] شبکه‌هایی که عموماً در مسائل مهندسی ژئوتکنیک به کار می‌روند از نوع پرسپترون چندلایه (MLP) هستند. دلیل اصلی این انتخاب آن است که در مسائل مهندسی ژئوتکنیک همواره مقادیر هدف معین و در نتیجه یادگیری از نوع معلم‌دار است. (به صورت مفهومی معلم مجموعه‌یی است که درباره محیط اطلاعات و آگاهی دارد و اطلاعاتش را به صورت مجموعه‌یی از داده‌های ورودی - خروجی عرضه می‌کند. به عبارت دیگر فرایند آموزش شبکه به وسیله مجموعه‌یی موجود از داده‌ها صورت می‌پذیرد.) در این تحقیق شبکه‌ی مورد استفاده نیز از نوع MLP است و برای آموزش شبکه‌ها از نرم‌افزار MATLAB6.12 استفاده شده است. در این نرم‌افزار الگوریتم‌های آموزشی مختلفی برای تربیت شبکه‌های MLP وجود دارد. براساس توصیه‌های موجود در راهنمای این نرم‌افزار^[۱] در مسائل

$$Q_{ik} = \frac{\sum_{j=1}^L \left(\frac{|W_{ij}|}{\sum_{i=1}^N |W_{ij}|} \cdot |v_{jk}| \right)}{\sum_{i=1}^N \left(\sum_{j=1}^L \left(\frac{|W_{ij}|}{\sum_{i=1}^N |W_{ij}|} \cdot |v_{jk}| \right) \right)} \quad (8)$$

که در آن N تعداد متغیرهای ورودی، L تعداد نرون‌های لایه‌ی پنهان، W_{ij} وزن سیناپس‌های بین لایه‌ی ورودی و لایه‌ی میانی، و v_{jk} وزن سیناپس‌های بین لایه‌ی میانی و لایه‌ی خروجی است. عبارت $\sum_{j=1}^L W_{ij}$ بیان‌گر مجموع وزن‌های بین متغیرهای ورودی و نرون j است. Q_{ik} نیز نشان‌گر درصد تأثیر متغیر ورودی (x_i) بر متغیر خروجی (y_k) است.

محققین رابطه‌ی دیگری براساس وزن‌ها ارائه داده‌اند که «تولید وزن»^[۲] نام دارد.^[۱] در این رابطه نسبت مقادیر متغیر ورودی (x_i) و مقادیر خروجی (y_k) به وزن‌های شبکه توسط رابطه‌ی ۲ ارتباط داده می‌شود:

$$WP_{ik} = \frac{x_i}{y_k} \sum_{j=1}^L W_{ij} v_{jk} \quad (2)$$

که در آن WP_{ik} بیان‌گر تأثیر متغیر ورودی (x_i) بر متغیر خروجی (y_k) است. در سال ۱۹۹۵ به منظور اصلاح روش گارسن رابطه‌ی ۳ ارائه شد.^[۱] در رابطه‌ی ۳ مشکل روش گارسن که در مورد وزن‌های با علامت منفی در پارامتری اوقات نتایج غلطی ارائه می‌داده حل شده است. در این رابطه برای غلبه بر این مشکل از قدرمطلق وزن‌ها استفاده شده است.

$$Q_{ik} = \frac{\sum_{j=1}^{hidden} \frac{W_{jk}}{\sum_{i=1}^{maxinputs} |W_{ji}|} \cdot W_{oj}}{\sum_{k=1}^{inputs} \left(\sum_{j=1}^{hidden} \left| \frac{W_{jk}}{\sum_{i=1}^{maxinputs} |W_{ji}|} \cdot W_{oj} \right| \right)} \quad (3)$$

در سال ۲۰۰۳ شکل ساده‌شده‌ی روش گارسن به صورت رابطه‌های ۴ و ۵ ارائه شد.^[۱]

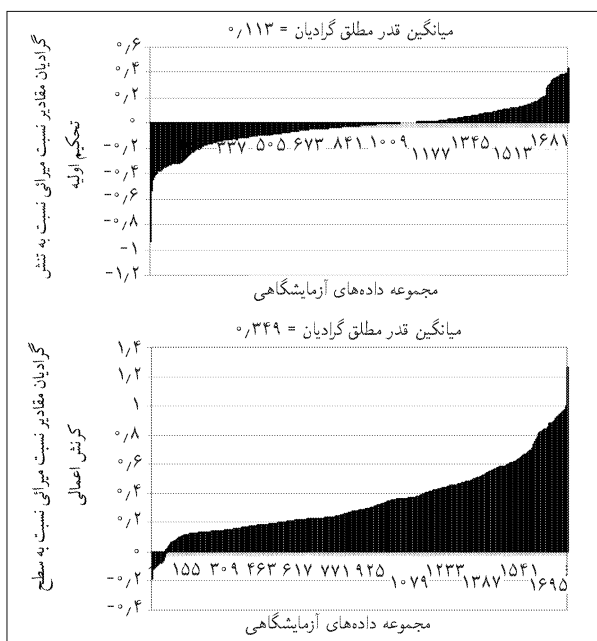
$$Q_{ih} = \frac{|W_{ih}|}{\sum_{i=1}^{n_i} |W_{ih}|} \quad (4)$$

$$RI(I)_i = \frac{\sum_{h=1}^{n_h} Q_{ih}}{\sum_{h=1}^{n_h} \sum_{i=1}^{n_i} Q_{ih}} \times 100 \quad (5)$$

در روابط فوق $RI(I)_i$ بیان‌گر اهمیت نسبی متغیرهای ورودی است.

۲. تحلیل حساسیت

تحلیل حساسیت بر مبنای اندازه‌گیری تأثیری است که تغییرات ورودی (x_i) در خروجی (y_k) به وجود می‌آورد. بنابراین هرچه اثر مشاهده‌شده در خروجی بیشتر باشد حساسیت ورودی نیز بیشتر خواهد بود. با محاسبه‌ی مشتقات جزئی خروجی (y_k) نسبت به ورودی (x_i) و به دست آوردن ماتریس ژاکوبین نحوی



شکل ۳. نمودار فراوانی - گزاردیان برای ورودی‌های تنش تحکیمی اولیه و سطح کرنش اعمالی و خروجی نسبت میرایی.

جدول ۱. نتایج نهایی تحلیل حساسیت بر روی داده‌های آزمایشگاهی.

شبکه	اهمیت نسبی پارامترها				
	شماره سیکل	درصد ریس	تنش تحکیم اولیه	قطر سنگدانه	سطح کرنش اعمالی
$M_1 - D$ نسبت میرایی	٪۲۱	٪۳۲	٪۱۰	٪۶	٪۳۱
$M_2 - G$ مدول برشی	٪۴۷	٪۱۳	٪۲۰	٪۲	٪۱۸

عصبی به‌کار می‌روند. برای تحلیل حساسیت کافی است شیب (گزاردیان) متغیرهای خروجی نسبت به هر یک از متغیرهای ورودی در کل فضای داده‌های آزمایشگاهی محاسبه شود. پس از آن با استفاده از یک شاخص آماری (مانند میانگین قدر مطلق فراوانی)، فراوانی نسبی گزاردیان‌ها محاسبه شده و به‌عنوان نماینده‌ی آن از درجه اهمیت متغیر ورودی ارائه شود. در شکل ۳ نمودار فراوانی - گزاردیان (مشتق لحظه‌ی خروجی به ورودی) برای ورودی‌های تنش تحکیمی اولیه و سطح کرنش اعمالی و خروجی نسبت میرایی ارائه شده است.

در جدول ۱ نتایج نهایی حاصل از تحلیل حساسیت ارائه شده است. همان‌گونه که پیش‌تر ذکر شد هرچه نتایج حاصل از تحلیل شبکه‌های عصبی براساس روش‌های مختلف به نتایج این جدول نزدیک‌تر باشد بیان‌گر عملکرد صحیح‌تر آن است.

مطالعه‌ی شبکه‌ها براساس روش‌های مختلف تحلیل حساسیت

مدل‌های $M_1 - D$ (برای پیش‌بینی نسبت میرایی) و $M_2 - G$ (برای پیش‌بینی مدول برشی) براساس شش روش متداول تحلیل حساسیت مورد بررسی قرار گرفتند. در این بین چهار روش براساس بزرگی وزن‌ها، یک روش براساس تحلیل تابع خطا

«تخمین تابع ۵» (که در این تحقیق نیز با همین مسئله روبه‌رو هستیم) دو الگوریتم «لونبرگ - مرکورت ۶» (LM) و «شیب مزدوج اندازه‌گیری شده ۷» (SCG) بهترین عملکرد را دارند. در بین این دو الگوریتم نیز الگوریتم LM در شبکه‌هایی با ابعاد متوسط (تا چندصد پارامتر آزاد) سریع‌ترین و بهترین نوع هم‌گرایی را دارد و با توجه به همین موضوع، LM به‌عنوان الگوریتم تربیتی برگزیده شد.

دو مدل M_1 و M_2 با دو ساختار متفاوت برای پیش‌بینی پارامترهای نسبت میرایی و مدول برشی ارائه شدند. ورودی‌های مدل اول (M_1) که در پیش‌بینی نسبت میرایی (D) کاربرد داشت عبارت‌اند از شماره‌ی دوره‌ی آزمایش (N)، درصد رس، قطر درشت‌دانه، تنش تحکیمی همه‌جانبه‌ی اولیه، و دامنه‌ی کرنش برشی اعمال شده. در مدل اول (M_1) تنها شرایط اولیه‌ی نمونه مورد توجه واقع شدند. یکی از عوامل مؤثر در مدل‌سازی رفتار خاک، تاریخچه‌ی بارگذاری نمونه است. در طول آزمایش با انجام بارگذاری و باربرداری‌های متوالی فشار آب منفذی دچار تغییرات شده و این تغییرات تأثیر زیادی در روند رفتار خاک دارد. با توجه به این موضوع در مدل دوم فشار آب منفذی نیز به‌عنوان یک ورودی در نظر گرفته شد. لحاظ کردن فشار آب منفذی در ورودی مدل می‌تواند تا حدودی اثرات تاریخچه‌ی بارگذاری نمونه‌ی خاک را منعکس، و خروجی‌های صحیح‌تری تولید کند. ورودی‌های مدل دوم (M_2) که برای پیش‌بینی مدول برشی (G) به کار می‌رود با مدل اول یکسان است با این تفاوت که ورودی فشار آب منفذی (U) نیز به آن اضافه می‌شود. برای اطمینان از تعمیم‌پذیری شبکه‌ها از روش توقف زودهنگام (Cross validation) استفاده شد. در این روش داده‌های آموزشی باید به ۳ دسته تقسیم شوند: داده‌های آموزشی ۱، داده‌های ارزیابی ۱، و داده‌های آزمایشی ۱.

کل آزمایشات انجام‌شده در این تحقیق ۵۶ عدد بوده و قاعده‌ی تقسیم‌بندی نیز بدین ترتیب است که ۷ نمونه آزمایش به‌عنوان داده‌های آزمایشی، ۷ نمونه آزمایش به‌عنوان داده‌های ارزیابی، و ۴۲ نمونه آزمایش به‌عنوان داده‌های آموزشی در نظر گرفته شدند. ۳۱ بنا براین با توجه به انجام هر یک از آزمایشات در ۵ دوره، تعداد کل داده‌های آموزشی ۲۱۰۰ زوج و تعداد کل داده‌های آزمایشی و ارزیابی هر یک ۳۵۰ زوج است. شبکه‌های مختلف با تعداد لایه‌های میانی متفاوت، توابع تحریک مختلف، تعداد نرون‌های میانی متفاوت و ورودی‌های مختلف مورد آزمایش و ارزیابی قرار گرفتند. پس از بررسی و مقایسه‌ی شاخصه‌های آماری با یکدیگر، در نهایت شبکه‌ی $M_1 - D$ با یک لایه‌ی پنهان و متشکل از ۱۸ نرون میانی که دارای توابع تحریک تانژانت سیگموئید (tansiy) بودند به‌عنوان مدل نهایی در پیش‌بینی نسبت میرایی رس‌های مخلوط برگزیده شد. همچنین شبکه‌ی $M_2 - G$ با یک لایه‌ی پنهان متشکل از ۵ نرون میانی که دارای توابع تحریک تانژانت سیگموئید بودند نیز به‌عنوان بهترین شبکه برای پیش‌بینی مدول برشی رس‌های مخلوط برگزیده شد.

تحلیل حساسیت بر روی نسبت میرایی و مدول برشی با

استفاده از داده‌های آزمایشگاهی

نسبت میرایی و مدول برشی در واقع تابعی از شماره‌ی دوره‌ی آزمایش، درصد رس، قطر درشت‌دانه، تنش تحکیم همه‌جانبه‌ی اولیه، دامنه‌ی کرنش برشی اعمال شده و فشار آب منفذی هستند. با استفاده از داده‌های آزمایشگاهی موجود و انجام تحلیل حساسیت بر روی آنها می‌توان درجه‌ی تأثیر و اهمیت هر یک از پارامترهای اولیه‌ی خاک را بر روی نسبت میرایی و مدول برشی تعیین کرد. نتایج این تحلیل به‌عنوان معیاری برای سنجش صحت عملکرد روش‌های مختلف تحلیل حساسیت شبکه‌های

جدول ۳. درصد خطای کل و انحراف از معیار برای روش‌های مختلف.

شاخصه‌های						
مدل $M_1 - G$ برای پیش بینی مدول برشی (G)						
آماره‌های روش‌ها	گارسن	میلر	جوری	تولید وزن	قیدگذاری	تحلیل حساسیت
درصد خطای کل	٪۳۸	٪۷۶	٪۳۵	٪۴۳	٪۱۳۲	٪۳۶
انحراف از معیار	۱۱٫۵	۱۶٫۹	۱۲٫۲	۱۵٫۳	۹٫۹	۱۱٫۵
شاخصه‌های						
مدل $M_2 - D$ برای پیش بینی نسبت میرایی (D)						
آماره‌های روش‌ها	گارسن	میلر	جوری	تولید وزن	قیدگذاری	تحلیل حساسیت
درصد خطای کل	٪۲۶	٪۵۲	٪۲۶	٪۷۸	٪۷۱	٪۴۴
انحراف از معیار	۱۰٫۲	۱۴٫۳	۱۰٫۲	۹٫۱	۹٫۱	۱۳

شده بر روی داده‌های آزمایشگاهی مقایسه شود. برای این مقایسه از ۲ پارامتر «درصد خطای کل» و «انحراف از معیار» استفاده شده است. این مقایسه در جدول ۳ ارائه شده است. همچنین در شکل ۴ درصد خطای کل و انحراف از معیار که در هر یک از روش‌ها به دست آمده نمایش داده شده است.

نتیجه‌گیری

در این تحقیق دو مدل شبکه‌ی عصبی با استفاده از یک مجموعه‌ی جامع آزمایشگاهی تربیت شدند. سپس هر یک از دو مدل با استفاده از ۶ روش تحلیل حساسیت مورد ارزیابی قرار گرفتند. با توجه به اطلاعات ارائه شده در جدول ۳ و شکل ۴، خلاصه‌ی نتایج حاصل از این تحلیل به شرح زیر است:

۱. به‌طور کلی روش‌های تحلیل حساسیت گارسن و جوری، نسبت به سایر روش‌ها، نتایج بهتری ارائه می‌دهند. با توجه به این که روش جوری ارائه‌ی دیگری از روش گارسن است می‌توان دو روش «تحلیل حساسیت» و «گارسن» را به‌عنوان روش‌های برگزیده انتخاب کرد.

۲. در شبکه‌های با تعداد نرون میانی زیاد (مانند شبکه‌ی $M_1 - D$ با ۱۸ نرون میانی) نتایج روش تحلیل حساسیت نسبت به روش گارسن بهتر است.

جدول ۲. خلاصه نتایج حاصل از تحلیل دو مدل شبکه عصبی براساس ۶ روش تحلیل حساسیت.


اهمیت نسبی پارامترهای ورودی برای پیش‌بینی مدول برشی (G)						
روش به‌کار رفته در تحلیل حساسیت	شماره‌ی دوره	درصد رس	تنش تحکیم اولیه	قطر سنگ‌دانه	سطح کرنش عملی	فشار آب منفذی
گارسن	٪۳	٪۲۷٫۹	٪۱۴٫۳	٪۱٫۸	٪۲۴٫۱	٪۲۹
میلر	٪۵٫۳	٪۲۳٫۴	٪۱۱٫۳	٪۱٫۵	٪۵۸٫۳	٪۵٫۲
جوری	٪۳٫۳	٪۳۰٫۸	٪۱۵٫۸	٪۲	٪۲۶٫۶	٪۳۲
تولید وزن	٪۱٫۶	٪۱۵٫۲	٪۲۱	٪۲٫۸	٪۵۳٫۲	٪۶٫۲
قیدگذاری	٪۵	٪۲۲	٪۱۹٫۸	٪۱۸٫۷	٪۲۴	٪۱۵٫۵
تحلیل حساسیت	٪۴٫۵	٪۱۱٫۸	٪۱۹٫۸	٪۷	٪۱۸٫۶	٪۳۸٫۳

اهمیت نسبی پارامترهای ورودی برای پیش‌بینی مدول میرایی (D)					
روش به‌کار رفته در تحلیل حساسیت	شماره‌ی دوره	درصد رس	تنش تحکیم اولیه	قطر سنگ‌دانه	سطح کرنش عملی
گارسن	٪۱۶٫۳	٪۲۹٫۷	٪۱۲٫۸	٪۱۰٫۴	٪۳۰٫۹
میلر	٪۳۵٫۱	٪۳۲٫۸	٪۵٫۵	٪۵٫۴	٪۳۱٫۲
جوری	٪۱۶٫۳	٪۲۹٫۷	٪۱۲٫۸	٪۱۰٫۴	٪۳۰٫۹
تولید وزن	٪۶۳٫۴	٪۱۸٫۱	٪۱۰٫۳	٪۲٫۲	٪۵٫۹
قیدگذاری	٪۱۱	٪۲۵	٪۹۸	٪۱۸	٪۲۸
تحلیل حساسیت	٪۴۶	٪۱۵٫۵	٪۱۱	٪۶٫۵	٪۲۱

(روش قیدگذاری)، و یک روش براساس تحلیل گردیان خروجی نسبت به ورودی‌ها بود (این روش تحت عنوان عمومی تحلیل حساسیت شناخته می‌شود). در جدول ۲ خلاصه‌ی نتایج حاصل از این مطالعه آورده شده است. در این جدول درصد اهمیت نسبی هر یک از ورودی‌ها که با روش‌های مختلف محاسبه شده‌اند برای هر یک از مدل‌های $M_1 - D$ و $M_2 - G$ ارائه شده است.

مقایسه‌ی عملکرد روش‌های مختلف تحلیل حساسیت

چنان‌که پیش‌تر ذکر شد برای سنجش عملکرد هر یک از روش‌های تحلیل حساسیت باید نتایج حاصل از هر یک از روش‌ها با نتایج حاصل از تحلیل حساسیت انجام



شکل ۴. نمودار مربوط به درصد خطای کل و انحراف از معیار برای روش‌های مختلف.

۳. در شبکه‌های با تعداد نرون‌های میانی کم (مانند شبکه‌ی $M_2 - G$ با ۵ نرون میانی) عملکرد روش گارسن نسبت به سایر روش‌ها بهتر است.
۴. روش فیدگذاری که براساس تحلیل تابع خطا است در هیچ‌یک از موارد عملکرد خوبی ارائه نمی‌دهد؛ لذا استفاده از آن در مطالعات تحلیل حساسیت شبکه توصیه نمی‌شود.
۵. روش تولید وزن در شبکه‌های با تعداد نرون‌های میانی زیاد عملکرد مناسبی دارد، حال آن‌که با کاهش تعداد نرون‌های میانی عملکرد آن ضعیف می‌شود.
۶. در مواردی که تعداد نرون‌های میانی شبکه کم تا متوسط است، استفاده از روش گارسن برای تعیین اهمیت نسبی متغیرهای ورودی توصیه می‌شود. در صورت زیاد بودن تعداد نرون‌های میانی بهتر است که از روش تحلیل حساسیت استفاده شود.

پانویس

1. black box
2. weight product
3. analysis based on the error function
4. numeric sensitivity analysis
5. function approximation
6. levenberg-marquardt
7. Scaled Conjugate Gradient
8. training subset
9. validation subset
10. test subset

منابع

4. Shahin, M.A.; Jaksa, M.B.; and Maier, H.R. "Artificial neural network applications in geotechnical engineering", *J. Australian Geomechanics*, **36**(1), pp. 49-62 (2001).
5. Gevrey, M.; Dimopoulos, I. and Lek, S. "Review and comparison of methods to study the contribution of variables in artificial neural network models", *J. Ecol. Model*, **160**, pp. 249-264 (2003).
6. Tchaban, T.; Taylor, M.J. and Griffin, A. "Establishing impacts of the inputs in a feed forward network", *J. Neural Computing & Applications*, **7**, pp. 309-317 (1998).
7. Milne, K. "Feature selection using neural networks with contribution measures", In: Proceedings Australian Conference AI'95, IEEE West Australian Section, Sydney, pp. 124-136 (1995).
8. Wang, W., Jones, P., Partridge, D., "Assessing the impact of input features in a feedforward neural network", *J. Neural Comput & Applic*, **9**, pp. 101-112 (2000).
9. Ghateh, R. "ANN prediction of dynamic deformation properties of composite clays", MSc thesis, IIEES, Tehran, Iran (2006).
10. Shafiee, A. "Monotonic and cyclic behavior of composite clays with special view to pore pressure", PhD thesis, IIEES, Tehran, Iran (2002).
11. Demuth, Howard; Beale, Mark. "Neural network toolbox user's guide for use with MATLAB", Version 4, Release13 (2002).
1. Montano, J.; Palmer, A. "Numeric sensitivity analysis applied to feed forward neural networks", *J. Neural Compute & Applic*, **12**, pp. 119-125 (2003).
2. Lu, M., Abourizk, S.M. & Hermann, U.H. "Sensitivity analysis of neural networks in spool fabrication productivity studies", *J. Comp. in civil. Engrg*, **15**(4), pp. 299-308 (2001).
3. Haykin, S. "Neural networks: A comprehensive foundation, prentice-hall international", Inc. New Jersey (1999).