

# مدل سازی آزمایش پرسیمتری (فشارسنجی) با استفاده از شبکه‌ی عصبی مصنوعی

محمد امامی (دانشجوی دکتری)

سیدشهاب‌الدین ینیری (دانشیار)

دانشکده‌ی فنی و مهندسی، دانشگاه تربیت مدرس

آزمایش پرسیمتری (فشارسنجی)، یکی از مهم‌ترین آزمایش‌های برجای مهندسی ژئوتکنیک است. این آزمایش قادر به تخمین بسیار مناسبی از پارامترهای تغییر شکلی خاک است. در این تحقیق از سه نوع شبکه‌ی عصبی مصنوعی (ANN) به منظور مدل سازی آزمایش پرسیمتری (فشارسنجی) استفاده شده است. برای این منظور ابتدا از پرسپترون چندلایه - یکی از پرکاربردترین شبکه‌های عصبی - استفاده شد و در ادامه، با استفاده از شبکه‌ی نوروفازی که ترکیبی از شبکه‌های عصبی - فازی و نیز با بهره‌گیری از شبکه‌ی عصبی تابع مبنای شعاعی که شبکه‌ی موفق در مسائل غیرخطی است به این مهم پرداخته شد. در تمامی این مدل‌ها از خواص فیزیکی و تراکمی خاک استفاده شده است. مدل‌ها از دو ساختار کلی دارای ۶ ورودی، و دارای ۵ ورودی و یک خروجی تشکیل شده‌اند. از مجموعه‌ی بزرگی از آزمایش‌های پرسیمتری انجام شده روی محدوده‌ی وسیعی از خاک‌های ریزدانه و درشت‌دانه، به‌عنوان بانک اطلاعاتی استفاده شده است. شبکه‌های مورد استفاده نیز موفقیت قابل قبولی از خود نشان داده‌اند. در نهایت مدل‌های مختلف شبکه‌های عصبی با یکدیگر مقایسه، و شبکه‌ی که بهترین عملکرد را داشته مشخص شده است. برای ارزیابی شبکه نمودارهای فشار- تغییرحجم حاصل از شبیه‌سازی ساختارهای بهینه‌ی هر مدل با نتایج تجربی حاصل مقایسه شده است. مدل‌های مبتنی بر شبکه‌های عصبی، برخلاف مدل‌های رفتاری مرسوم توضیحی درمورد چگونگی اثر پارامترهای ورودی بر خروجی نمی‌دهند. در این تحقیق با انجام تحلیل حساسیت روی ساختار بهینه‌ی مدل معرفی شده سعی شده است تا حدودی به این سؤال پاسخ داده شود.


واژگان کلیدی: آزمایش پرسیمتری، شبکه‌ی عصبی مصنوعی، پرسپترون چندلایه، نوروفازی، تابع مبنای شعاعی، تحلیل حساسیت.

## ۱. مقدمه

رفتار خاک را مستقیماً از نتایج آزمایش‌های آزمایشگاهی و تجربی می‌آموزند. حتی خطاهای موجود در آزمایش‌های آزمایشگاهی و همچنین داده‌های تجربی خلل چندانی در آموزش شبکه‌ها وارد نمی‌کنند. شبکه‌های عصبی در صورت آموزش درست از طریق تعداد مناسب داده‌ها، با دقت قابل قبولی قادر به پیش‌بینی رفتار خاک‌ها هستند. با توجه به پیچیدگی نحوه‌ی انجام آزمایش پرسیمتری، زمان بر بودن و هزینه‌ی بالای انجام این آزمایش، ایجاد مدلی برای پیش‌بینی رفتار خاک‌ها تحت این آزمایش ضرورت می‌یابد. طی سالیان اخیر استفاده از شبکه‌های عصبی مصنوعی در بسیاری از رشته‌های مهندسی، به‌ویژه در بسیاری از مسائل ژئوتکنیکی، افزایش یافت و تاحدی موفقیت‌آمیز نیز بود. نگاهی اجمالی به مقالات انتشار یافته آشکار می‌سازد که شبکه‌های عصبی مصنوعی در پیش‌بینی ظرفیت باربری شمع‌ها، مدل سازی رفتار خاک، خصوصیات محل، سازه‌های نگهبان خاکی، نشست سازه‌ها، پایداری شیب‌ها، طراحی تونل‌ها و فضاهای زیرزمینی، روان‌گرایی، نفوذپذیری و هدایت هیدرولیکی

آزمایش‌های برجای نقش بسیار مهمی در مطالعات مهندسی ژئوتکنیک دارند. آزمایش پرسیمتری نیز یکی از مهم‌ترین آزمایش‌های برجای مهندسی ژئوتکنیک است که در مقایسه با سایر آزمایش‌ها، واقعی‌ترین تصور از رفتار تغییر شکلی خاک‌ها را ارائه می‌دهد. از این‌رو تلاش زیادی در زمینه‌ی مدل‌سازی این آزمایش و پیش‌بینی رفتار تغییر شکلی خاک‌ها انجام شده است. این مدل‌ها بر پایه‌ی نظریه‌های متعدد کشسانی و خمیرسانی استوارند و با استفاده از پیش‌فرض‌ها و تعریف محدوده‌های شکست و تسلیم، بین خصوصیات تنش - تغییر شکل خاک‌ها رابطه‌ی ارائه می‌کنند. برای سهولت هرچه بیشتر در پیش‌بینی رفتار خاک‌ها، استفاده از شبکه‌های عصبی مصنوعی بیشتر مورد توجه قرار گرفت. شبکه‌های عصبی مصنوعی نیازی به تعریف پیش‌فرض‌ها، ثوابت و نظریه‌های کشسانی و خمیرسانی ندارند. این شبکه‌ها

تاریخ: دریافت ۱۹/۱۳۸۸، اصلاحیه ۲۵/۷/۱۳۸۸، پذیرش ۳/۵/۱۳۸۹.



شکل ۱. نمونه‌یی از نمودار حاصل از آزمایش پرسیمتری. [۱۷]

منحنی‌ها هستند. شکل ۱ نمونه‌یی از منحنی فشار - حجم حاصل از آزمایش پرسیمتری را نشان می‌دهد. [۱۷]

دستگاه پرسیمتری مورد استفاده از نوع پرسیمتری پیش‌حفری شده است. برای قراردادن این پرسیمترها در داخل زمین، حفر و آماده‌کردن گمانه مورد نیاز است. این پرسیمترها فراگیرترین نوع پرسیمتر در مطالعات ژئوتکنیک‌اند. در این تحقیق از دستگاه پرسیمتری منارد استفاده شده، و روش انجام آزمایش پرسیمتری نیز مبتنی بر استاندارد ASTM D ۴۷۱۹ است.

### ۳. انواع شبکه‌ی عصبی مورد استفاده

سه نوع شبکه‌ی عصبی مورد استفاده قرار گرفته‌اند. این سه نوع عبارت‌اند از: شبکه‌های چندلایه‌ی پرسپترون، شبکه‌ی نوروفازی و شبکه‌ی تابع مبنای شعاعی.

#### ۱.۳. پرسپترون چندلایه (MLP)

پرکاربردترین معماری شبکه‌های عصبی، شبکه‌های چندلایه‌ی پیش‌خور<sup>۲</sup> است که به اختصار آنها را پرسپترون چندلایه (MLP) می‌نامند.

#### ۱.۱.۳. الگوریتم یادگیری پس‌انتشار

یک شبکه‌ی پس‌انتشار از نوع MLP مشتمل است بر: لایه‌یی ورودی از گره‌ها به‌عنوان متغیرهای ورودی به مسئله، لایه‌یی خروجی از گره‌ها که متغیرهای وابسته را نمایش می‌دهند، و یک یا چند لایه‌ی نهان متشکل از گره‌ها برای یافتن خاصیت غیرخطی در داده‌ها. هنگامی که یک ورودی آموزشی به شبکه عرضه می‌شود خروجی هر نورون محاسبه می‌شود و سپس این خروجی‌ها در طول شبکه به جلو پیش می‌روند و در نهایت خروجی شبکه محاسبه می‌شود. اگر اختلافی بین خروجی شبکه و خروجی مطلوب وجود داشته باشد آنگاه روند اصلاح وزن‌ها از لایه‌ی خروجی شروع شده و به سمت لایه‌های ورودی پیش می‌رود (عبارت پس‌انتشار). الگوریتم این روش عبارت است از:

$$e_j = t_j(n) - y_j(n) \quad (1)$$

$t_j(n)$  نشان‌گر مقدار هدف، و  $y_j(n)$  نشان‌گر مقدار خروجی شبکه برای نورون  $j$  در تکرار  $n$ ام است. مقدار انرژی خطا برای نورون  $j$  به صورت  $\frac{1}{2}e_j^2(n)$  تعریف می‌شود،

خاک، تراکم خاک، تورم خاک و طبقه‌بندی خاک‌ها به‌طور موفقیت‌آمیزی مورد استفاده قرار گرفته است. البته در زمینه‌ی آزمایش‌های برجای مهندسی ژئوتکنیک، استفاده از شبکه‌ی عصبی توسعه‌ی چندانی نداشته است. در سال ۲۰۰۱ از شبکه‌ی عصبی برای تعیین ظرفیت باربری جانبی شمع‌ها استفاده شد. [۱] پیش‌تر نیز در سال ۲۰۰۳، برای تخمین نمونه‌نهایی چسبندگی ظاهری ( $C_{max}$ ) خاک‌های غیراشباع روشی با استفاده از شبکه‌ی عصبی پیشنهاد شده بود. [۲] از شبکه‌های عصبی برای پیش‌بینی نشست شالوده‌های سطحی واقع بر خاک‌های غیرچسبیده استفاده شده و رفتار تنش - کرنش خاک‌های ماسه‌یی با استفاده از شبکه‌های عصبی مصنوعی مدل‌سازی شده است. [۳] محققین طبیعت احتمالی رفتار ترمی دوره‌یی گل‌سنگ و وابستگی داخلی آن به تعداد زیادی از پارامترها را با استفاده از شبکه‌های عصبی مدل کرده‌اند. [۴]

عادل اچ. هانا و درین اورال در سال ۲۰۰۶، از مدل شبکه‌ی عصبی برای ارزیابی پتانسیل روان‌گرایی خاک‌های رسوبی با استفاده از داده‌های زلزله‌های ترکیه و تایوان بهره بردند و برای این منظور یک مدل شبکه‌ی عصبی پیشنهاد دادند. [۱] بیناردوس و کالیمپاکوس (۲۰۰۴) نیز نرخ پیشروی تونل‌سازی در شرایط ژئوتکنیکی و زمین‌شناسی را مدل‌سازی کردند. در سال ۲۰۰۴ نیز مدل شبکه‌ی عصبی برای نشست سطح زمین ناشی از گودبرداری عمیق استفاده شد [۵] و از شبکه‌ی عصبی برای پیش‌بینی نشست‌های سطح زمین بر اثر تونل‌سازی استفاده کردند. [۶] بر مبنای نتایج حاصل از مطالعات مختلف، شبکه‌های عصبی مصنوعی بهتر از روش‌های معمول مدل‌سازی عمل می‌کنند. در بسیاری از مواقع، در مهندسی ژئوتکنیک با انواعی از مسائل بسیار پیچیده و غیرقابل فهم مواجه هستیم. از بسیاری از روش‌های ریاضی برای حل این مسائل پیچیده استفاده شده است؛ کمبود فهم فیزیکی معمولاً با ساده‌سازی و انجام چند فرض در این مدل‌ها تکمیل می‌شود. [۱۱-۷] شبکه‌های عصبی مصنوعی، علی‌رغم عملکرد خوبشان در بسیاری از موقعیت‌ها از نقایصی نیز رنج می‌برند که مهم‌ترین آنها عبارت است از: کمبود نظریه برای کمک به توسعه‌ی این شبکه‌ها، نبود تضمین برای موفقیت در یافتن راه‌حل بهینه، و نیز تشریح نشدن چگونگی رسیدن از اطلاعات ورودی به راه‌حل مورد نظر. در بسیاری از تحقیق‌های انجام‌شده تشریح کامل چگونگی رسیدن به پیش‌بینی شبکه‌های عصبی مصنوعی یک ضرورت است. [۱۳، ۱۲]

### ۲. آزمایش پرسیمتری (فشارسنجی)

کلیدیه‌ی آزمایش‌های لازم برای این تحقیق براساس استاندارد ASTM انجام شده است. آزمایش پرسیمتری یکی از مهم‌ترین آزمایش‌های برجای مهندسی ژئوتکنیک است که در مقایسه با سایر آزمایش‌ها شکل‌دهنده‌ی واقعی‌ترین تصور نسبت به رفتار تغییر شکلی خاک است. [۱۴]

لوئیس منارد در سال ۱۹۵۵ دستگاه پرسیمتر را طراحی کرد و این نام را برای آن برگزید. برخی پرسیمتر را ابزاری استوانه‌یی معرفی می‌کنند که برای اعمال فشار یکنواخت از طریق پوسته‌ی انعطاف‌پذیر به دیواره‌ی گمانه به‌کار می‌رود. این تعریف متعاقباً توسط انجمن بین‌المللی مکانیک خاک و مهندسی پی به‌عنوان تعریف بین‌المللی پرسیمتر شناخته شد. [۱۵، ۱۶]

در آزمایش پرسیمتری، ابتدا سوند در داخل زمین و در عمق مورد نظر جای داده می‌شود و سپس توسط فشارگار، آب یا روغن منبسط می‌شود. منحنی فشار - جابه‌جایی (حجم) رسم شده و متغیرهای مهندسی خاک محصول ثانوی این

بنابراین مقدار کل انرژی خطا برابر است با:

$$\varepsilon(n) = \frac{1}{P} \sum_{j=1}^S e_j^r(n) \quad (2)$$

که در آن  $S$  تعداد نوروںهای خروجی است. متوسط مربعات خطا چنین تعریف می‌شود:

$$MSE = \frac{1}{N} \sum_{P=1}^P \sum_{j=1}^S e_j^r \quad (3)$$

در این رابطه،  $P$  تعداد کل الگوهای آموزشی است و  $N = P.S$ . تابع  $MSE$  که در واقع تابعی از تمام پارامترهای آزاد شبکه از قبیل وزن‌ها و مقدار بردار بایاس است، به‌عنوان تابع هزینه و تخمینی از کارایی شبکه به کار می‌رود. اصلاح وزن به‌وسیله قانون دلتا و براساس رابطه‌ی ۴ تعیین می‌شود:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (4)$$

که در آن  $\eta$  پارامتر سرعت یادگیری الگوریتم پس‌انتشار خطاست. علامت منفی در رابطه‌ی ۴ به‌دلیل در نظر گرفتن شیب گرادیان در فضای وزن‌ها (جهتی برای تغییر وزن که مقدار  $\varepsilon(n)$  را کاهش می‌دهد) لحاظ شده است.

در روش پس‌انتشار استاندارد هرچه پارامتر سرعت یادگیری  $\eta$  کوچک‌تر در نظر گرفته شود، مقدار تغییرات وزن‌ها کم‌تر و در نتیجه سیستم پایدارتر است. از طرف دیگر افزایش  $\eta$  موجب افزایش سرعت یادگیری می‌شود اما ممکن است شبکه ناپایدار شود. برای بهبود روش پس‌انتشار استاندارد، می‌توان از سیستم‌های بهینه‌سازی عددی بهره‌جست. یکی از این روش‌ها بهینه‌سازی مجموع مربعات توابع غیرخطی با روش لوبنبرگ - مارکوآرت (ML) است. [۱۹] براساس این روش کلی که تقریبی از روش نیوتن است، الگوریتم آموزشی پس‌انتشار ML در سال ۱۹۹۴ برای آموزش پرسپترون چندلایه پیشنهاد شد. [۱۷]

### ۲.۱.۳. توقف آموزش

شاخصی که از آن برای توقف الگوریتم پس‌انتشار استفاده شده عبارت است از: میانگین مربعات خطا ( $MSE$ ) در هر دوره کم‌تر از مقدار از پیش تعیین شده باشد، یا این که تغییرات در پارامترهای شبکه پس از هر دوره خیلی کوچک باشد. به‌منظور بالا بردن قابلیت تعمیم شبکه از روش توقف دیگری موسوم به «اعتبارسنجی ۳» استفاده می‌شود. طی این روش که برای متوقف کردن آموزش در انتهای مرحله اول مورد استفاده قرار می‌گیرد، بانک اطلاعاتی مورد استفاده به سه زیرمجموعه‌ی آموزشی، آزمایشی و ارزیابی تقسیم می‌شود. [۹]

### ۲.۲.۳. شبکه‌ی عصبی نوروفازی

شبکه‌ی نوروفازی با استفاده از محیط گرافیکی نرم‌افزار MATLAB (ANFIS) مدل شده است. در این سیستم، مشابه شبکه‌ی عصبی ورودی‌ها وارد توابع عضویت ورودی می‌شوند و پس از عبور از توابع عضویت خروجی به تولید خروجی شبکه می‌انجامند. پارامترهای توابع عضویت در حین فرایند یادگیری تنظیم می‌شوند. انواع توابع عضویت در لایه‌ی ورودی و خروجی مورد استفاده قرار می‌گیرند. [۲۰-۲۲]

### ۱.۲.۳. سیستم یادگیری پس‌انتشار نوروفازی (FBP)

طی این فرایند، از طریق ورودی‌های ارائه شده به شبکه‌ی عصبی رسیدن به خروجی‌های مطلوب میسر می‌شود. این عمل با تنظیم وزن‌ها در قانون یادگیری و بهینه‌سازی

خطای خروجی انجام می‌گیرد. مجموع مربعات خطا به‌عنوان شاخصی برای ارزیابی فرایند یادگیری در نظر گرفته می‌شود. با توجه به در نظر گرفتن ورودی و خروجی یک نوروں فازی (FN) به‌صورت  $(k) = 1, 2, 3, \dots, N$  داریم:

$$E(k) = \frac{1}{P} \sum_{j=1}^m [y_j^d(k) - y(k)] = \frac{1}{P} \sum_{j=1}^m e_j^r(k) \quad (5)$$

که در آن  $e_j$  مقدار خطای بین خروجی مطلوب شبکه و  $y_j^d$  خروجی شبکه‌ی  $y_j$  است. تنظیم وزن‌ها مطابق روابط ۶ تا ۹ انجام می‌گیرد:

$$w_{il}^{(1)}(k+1) = \text{Sat}(w_{il}^{(1)}(k) + \Delta w_{il}^{(1)}(k)) \quad (6)$$

$$i = 0, 1, 2, \dots, p; \quad l = 1, 2, \dots, n$$

$$w_{jq}^{(r)}(k+1) = \text{Sat}(w_{jq}^{(r)}(k) + \Delta w_{jq}^{(r)}(k)) \quad (7)$$

$$j = 0, 1, 2, \dots, p; \quad q = 1, 2, \dots, n$$

$$\Delta w_{il}^{(1)}(k) = -\eta \frac{\partial E}{\partial w_{il}^{(1)}} \quad (8)$$

$$\Delta w_{jq}^{(r)}(k) = -\eta \frac{\partial E}{\partial w_{jq}^{(r)}} \quad (9)$$

در این روابط  $\eta_1$  و  $\eta_2$  نرخ یادگیری به ترتیب در لایه‌ی ورودی و خروجی است. [۱۳]

### ۳.۳. شبکه‌ی عصبی تابع مبنای شعاعی

تابع مبنای شعاعی از جمله توابع دارای تقارن محوری است. یعنی در این تابع هر واحد خروجی متناظر با ورودی مورد نظر و با یک فاصله‌ی شعاعی معین تولید می‌شود. [۷] این بدان معناست که تابع مبنای شعاعی برای تمام  $x$ هایی که در دایره‌ی بی مرکز  $C_i$  قرار دارند، خروجی یکسان تولید می‌کند. [۲۰] این شبکه‌ها دو لایه دارند و حالت خاصی از شبکه‌های پس‌انتشارند. هر واحد در لایه‌ی پنهان از یک تابع مبنای شعاعی مانند یک هسته‌ی گاوسی، به‌عنوان تابع فعال‌سازی بهره می‌برد در حالی که واحدهای خروجی از تابع همانی به‌عنوان تابع فعال‌سازی استفاده می‌کنند. مرکز این تابع مبنای شعاعی (یا تابع هسته) با بردار وزن هر واحد مشخص می‌شود؛ موقعیت و عرض این هسته‌ها باید از الگوهای آموزشی یاد گرفته شود.

در این شبکه سیگنال‌های ورودی مستقیماً وارد سلول‌های لایه‌ی مخفی می‌شوند. برخلاف شبکه‌های چندلایه‌ی پرسپترون که دارای توابع فعالیت عمومی هستند، توابع فعالیت در این شبکه‌ها محلی‌اند. تعداد سلول‌های لایه‌ی مخفی از روش سعی و خطا به دست می‌آید. تعداد سلول‌های لایه‌ی خروجی نیز برابر است با تعداد خروجی‌ها. در تعلیم این شبکه، علاوه بر تنظیم وزن‌ها، تنظیم مرکز توابع فعالیت نیز ضرورت دارد. وزن‌ها از روش گرادیان نزولی بر طبق کم‌ترین مجموع مربعات خطا، و مرکز توابع فعالیت نیز به همین روش تنظیم می‌شود. [۲۳] تابع مبنای شعاعی به‌طور کلی به‌صورت رابطه‌ی ۱۰ نوشته می‌شود:

$$y \cong f(x) = \sum_{i=1}^n w_i \varphi(\|x - c_i\|) \quad (10)$$

که در آن  $\varphi(\|x - c_i\|)$ ،  $i = 1, 2, \dots, N$  مجموعه‌ی  $N$  تابع غیرخطی به‌نام «تابع مبنای شعاعی» است.  $\|\bullet\|$  بیان‌گر نرم برداری است که معمولاً به‌صورت فاصله‌ی اقلیدسی در نظر گرفته می‌شود. [۲۳]  $x_i \in R^p$ ،  $i = 1, 2, \dots, N$  مرکز توابع فعالیت هستند. در این تحقیق توابع فعالیت،  $\varphi$ ، برای شبکه‌ی تابع مبنای شعاعی

از نوع گوسی به صورت رابطه‌ی ۱۱ در نظر گرفته شده‌اند. همان‌طور که پیش‌تر نیز ذکر شد، این توابع از نوع توابع محلی‌اند.


$$\varphi(r) = \exp\left(-\left(\frac{r}{c}\right)^2\right) \quad (11)$$

الگوریتم یادگیری در این شبکه‌ها دارای سه مرحله است: مرحله‌ی ورودی، مرحله‌ی میانی یا تولید مراکز توابع گوسی، و مرحله‌ی خروجی. الگوریتم‌های یادگیری مختلفی برای شبکه‌ی تابع مینای شعاعی (RBF) وجود دارد. در این شیوه‌ی ساده‌ی یادگیری، ترکیبی به کار می‌رود که در آن تخمین در باره‌ی موقعیت و عرض هسته با استفاده از الگوریتم خوشه‌بندی بدون نظارت انجام می‌گیرد و سپس با استفاده از روش کمینه مجذور متوسط (LMS) با نظارت برای تعیین وزن‌های اتصال بین لایه‌های نهان و لایه‌های خروجی انجام می‌دهد. این الگوریتم یادگیری ترکیبی برای آموزش شبکه‌های RBF بسیار سریع‌تر از الگوریتم پس‌انتشار برای پرسپترون چندلایه هم‌گرا می‌شود.

#### ۴. بانک اطلاعاتی

در این تحقیق از نتایج به‌دست آمده از حدود ۱۰۰ آزمایش پرسیمتری انجام شده توسط شرکت عمران پژوهش راهوار (۱۳۸۵ تا ۱۳۸۶) استفاده شده است. این آزمایش‌های پرسیمتری روی خاک‌های مناطق شمال غرب ایران (تیریز) انجام شده، و دستگاه پرسیمتری مورد استفاده از نوع پرسیمتر پیش‌حفاری شده‌ی منارد است. آزمایش‌های انجام شده از دقت قابل قبولی برخوردارند و مطابق استاندارد ASTM-D4719 انجام شده‌اند.

حفاری گمانه‌ها به روش دورانی با مغزه‌گیری ممتد انجام شده است. در همه‌ی گمانه‌های مورد استفاده برای آزمایش پرسیمتری و نیز به‌منظور بررسی وضعیت لایه‌ها و مقاومت زمین، آزمایش‌های ضربه و نفوذ استاندارد (SPT) انجام شده است. در حین حفاری نمونه‌های دست‌خورده و دست‌خورده‌ی مورد نیاز اخذ، و برای انجام آزمایش‌های مختلف فیزیکی، مکانیکی و شیمیایی به آزمایشگاه منتقل شده‌اند. پارامترهای ورودی شبکه‌ی عصبی از نتایج آزمایش‌های فیزیکی و تراکمی خاک به دست آمده‌اند. نمونه‌ی از خصوصیات فیزیکی و تراکمی خاک‌های مورد آزمایش در جدول ۱ ارائه شده است. تعدادی از نمودارهای فشار - تغییر حجم آزمایش‌های پرسیمتری نیز در شکل ۲ ارائه شده است.



شکل ۲. تعدادی از نمودارهای آزمایش‌های پرسیمتری.

جدول ۱. خصوصیات فیزیکی و تراکمی خاک‌های مورد مطالعه.

$N_{SPT}$	اندازه بیشینه دانه ( $D_{max}$ )	وزن مخصوص طبیعی ( $gr/cm^3$ )	درصد رطوبت (%)	عمق (cm)
۱۲	۰٫۹۵	۱٫۸۲	۱۸	۶۷۵
۳۲	۰٫۴۲۵	۱٫۷۷	۱۴٫۵	۷۷۵
۳۳	۲٫۴۵	۱٫۸۱	۱۵٫۶	۸۷۵
۲۸	۳٫۸۱	۱٫۸۵	۱۴٫۲	۹۲۵
۳۶	۲٫۴۵	۱٫۷۸	۱۸٫۵	۱۰۷۵
۲۳	۰٫۴۷۵	۱٫۷	۲۳٫۲	۱۱۷۵
۴۹	۰٫۳۳۵	۱٫۶	۲۱٫۳	۱۳۲۵
۳۰	۲٫۴۵	۱٫۷۵	۱۸٫۱	۱۴۷۵
۵۰	۰٫۹۵	۱٫۸۲	۱۶٫۲	۱۵۷۵
۳۴	۰٫۲۰	۱٫۸۲	۱۸٫۶	۱۶۲۵
۵۰	۰٫۴۲۵	۱٫۸۳	۱۶٫۶	۱۷۷۵
۴۷	۰٫۴۷۵	۱٫۷۹	۱۷٫۶	۱۹۲۵
۴۰	۰٫۹۵	۱٫۸۴	۲۱٫۵	۲۱۲۵
۵۰	۰٫۳۳۵	۱٫۷۸	۲۱٫۸	۲۲۷۵
۳۵	۰٫۰۱۸	۱٫۸۶	۱۶٫۵	۲۳۲۵
۵۰	۰٫۰۸۵	۱٫۸	۲۵	۲۴۷۵

#### ۵. پیاده‌سازی مدل‌های شبکه‌ی عصبی

در این بخش پیاده‌سازی مدل‌های شبکه‌ی عصبی مورد استفاده طرح و بررسی می‌شود.

##### ۱.۵. پارامترهای ورودی

با توجه به عوامل تأثیرگذار بر آزمایش پرسیمتری و همچنین داده‌های به‌دست آمده از آزمایش‌های آزمایشگاهی و صحرایی انجام شده در گمانه‌هایی که در آن آزمایش پرسیمتری انجام شده بود، پارامترهای ورودی انتخاب شدند. البته کسب پارامترهای ورودی از آزمایش‌های معمول مهندسی ژئوتکنیک نکته‌ی است که در انتخاب پارامترهای ورودی نقش به‌سزایی دارد. در این مدل‌ها به ترتیب از شبکه‌هایی با ۶ و ۵ پارامتر ورودی استفاده شد.

پارامترهای ورودی از خواص فیزیکی و تراکمی خاک به دست می‌آیند. این پارامترها از آزمایش‌های آزمایشگاهی دانه‌بندی، تعیین وزن مخصوص، تعیین درصد رطوبت، آزمایش صحرایی عدد نفوذ استاندارد و همچنین عمق آزمایش و فشار وارده حاصل می‌شوند. پارامترهای مورد نظر عبارت‌اند از:

- پارامترهای فیزیکی: پارامترهای فیزیکی به‌عنوان شاخص‌های اولیه ارائه‌دهنده‌ی نگرش کلی نسبت به وضعیت لایه‌های زیرسطحی هستند. وزن مخصوص طبیعی ( $\gamma_m$ ) و درصد رطوبت ( $w$ ) مهم‌ترین این پارامترها هستند. پارامتر فیزیکی دیگری که به‌عنوان نشان‌دهنده‌ی وضعیت دانه‌بندی خاک‌ها مورد استفاده قرار گرفته است، اندازه‌ی بیشینه دانه‌ها ( $D_{max}$ ) است.

- شبکه‌ی نوروفازی: شبکه‌های نوروفازی از پرکاربردترین شبکه‌های عصبی هستند که توانایی بسیار بالایی در مسائل غیرخطی دارند. در این تحقیق از دو نوع شبکه‌ی نوروفازی -- NF<sub>1</sub> و NF<sub>2</sub> -- استفاده شده است. تفاوت این دو نوع شبکه مانند شبکه‌های چندلایه‌ی پرسپترون، در تعداد پارامترهای ورودی آنهاست و هر دو شبکه یک خروجی دارند.

- شبکه‌ی تابع مینای شعاعی: شبکه‌های تابع مینای شعاعی حالت خاصی از شبکه‌های پس‌انتشار هستند.<sup>[۲۲]</sup> در این تحقیق از دو نوع شبکه‌ی تابع مینای شعاعی -- RBF<sub>1</sub> و RBF<sub>2</sub> -- استفاده شده است. تفاوت این دو نوع شبکه مانند شبکه‌های چندلایه‌ی پرسپترون، در تعداد پارامترهای ورودی آنهاست و هر دو شبکه یک خروجی دارند. جزئیات تمامی مدل‌های مورد استفاده در جدول ۳ ارائه شده است.

#### ۴.۵. شاخص‌های ارزیابی مدل‌های شبکه‌ی عصبی

برای ارزیابی کارایی مدل‌های شبکه‌ی عصبی مورد استفاده شاخص‌هایی برای داوری درخصوص کارکرد مدل‌ها در مقایسه با مجموعه داده‌ها و همچنین نتایج تجربی حاصله مورد نیاز است. بنابراین، شاخص‌های مورد استفاده برای ارزیابی مدل‌ها و در نهایت مقایسه‌ی کارایی آنها نسبت به هم عبارت‌اند از:

- ضریب همبستگی ( $R$ ): درجه‌ی ارتباط بین دو متغیر به‌وسیله‌ی این پارامتر نشان داده می‌شود. ضریب همبستگی بین دو متغیر  $x$  و  $y$  مطابق رابطه‌ی ۱۲ بیان می‌شود:<sup>[۲۴]</sup>

$$R = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} \quad (12)$$

- میانگین قدرمطلق خطا ( $MAE$ ): نشان‌دهنده‌ی مقدار متوسط خطا در مجموعه‌ی مورد نظر است. این شاخص با رابطه‌ی ۱۳ بیان می‌شود.

$$MAE = \frac{1}{N} \sum_{i=1}^N |E_i| \quad (13)$$

جدول ۲. حدود تغییرات پارامترهای ورودی و خروجی.

خروجی	ورودی‌ها						حدود
	$\Delta V$ (cm <sup>۲</sup> )	P (kg/cm <sup>۲</sup> )	$D_{max}$ (mm)	H(cm)	W(%)	$\gamma_m$ (kg/cm <sup>۳</sup> )	
۱۰	۱	۰٫۲۵	۳۰۰	۱۰	۱٫۵۳	۱۰	کمینه
۱۲۰	۳۰	۳٫۸۱	۳۰۰۰	۲۶	۱٫۸۸	۵۰	بیشینه

جدول ۳. جزئیات ساختاری مدل‌های شبکه‌ی عصبی مورد استفاده.

خروجی‌ها	ورودی‌ها	شبکه‌ها
$\Delta V$ (cm <sup>۲</sup> )	$N_{SPT}, \gamma_m$ (gr/cm <sup>۳</sup> ), W(%), $D_{max}$ , H(cm), P(kg/cm <sup>۲</sup> )	MLP <sub>1</sub>
$\Delta V$ (cm <sup>۲</sup> )	$N_{SPT}, \gamma_m$ (gr/cm <sup>۳</sup> ), W(%), $D_{max}$ , H(cm)	MLP <sub>2</sub>
$\Delta V$ (cm <sup>۲</sup> )	$N_{SPT}, \gamma_m$ (gr/cm <sup>۳</sup> ), W(%), $D_{max}$ , H(cm), P(kg/cm <sup>۲</sup> )	NF <sub>1</sub>
$\Delta V$ (cm <sup>۲</sup> )	$N_{SPT}, \gamma_m$ (gr/cm <sup>۳</sup> ), W(%), $D_{max}$ , H(cm)	NF <sub>2</sub>
$\Delta V$ (cm <sup>۲</sup> )	$N_{SPT}, \gamma_m$ (gr/cm <sup>۳</sup> ), W(%), $D_{max}$ , H(cm), P(kg/cm <sup>۲</sup> )	RBF <sub>1</sub>
$\Delta V$ (cm <sup>۲</sup> )	$N_{SPT}, \gamma_m$ (gr/cm <sup>۳</sup> ), W(%), $D_{max}$ , H(cm)	RBF <sub>2</sub>

- پارامتر تراکمی: آزمایش نفوذ استاندارد (SPT) از رایج‌ترین آزمایش‌های درجا جهت تعیین خصوصیات فیزیکی و مکانیکی لایه‌های خاک است. با توجه به این نکته که این آزمایش در بیشتر گمانه‌های مطالعات ژئوتکنیک انجام می‌شود، در دسترس‌ترین داده‌ی حاصل از آزمایشات برجا است.

- پارامترهای حاصل از نحوه‌ی انجام آزمایش: با توجه به اثر قابل ملاحظه‌ی عمق انجام آزمایش بر نتایج حاصل از آزمایش پرسپومتري، این پارامتر به‌عنوان ورودی در نظر گرفته شد. در شبکه‌های ۶ ورودی از گام‌های فشار وارده در آزمایش پرسپومتري نیز به‌عنوان ورودی مدل استفاده شده است.

#### ۲.۵. پارامترهای خروجی

مقدار تغییر حجم حاصل از هر گام افزایش فشار ( $\Delta V$ )، بدون در نظر گرفتن زمان، به‌عنوان خروجی مدل در مدل‌سازی در نظر گرفته شد. حدود تغییرات پارامترهای ورودی و خروجی در جدول ۲ ارائه شده است.

#### ۳.۵. ساختار مدل‌های شبکه‌ی عصبی

در این بخش به تشریح معماری شبکه‌های عصبی مورد استفاده می‌پردازیم. با توجه به استفاده از سه نوع پرسپترون چندلایه، نوروفازی و تابع مینای شعاعی برای پیش‌بینی نمودار فشار-تغییرحجم حاصله از آزمایش پرسپومتري، ابتدا مدل شبکه‌ی چندلایه‌ی پرسپترون توضیح داده می‌شود و به‌ترتیب شبکه‌ی نوروفازی و شبکه‌ی تابع مینای شعاعی ارائه می‌شود.

- شبکه‌ی چندلایه‌ی پرسپترون: این شبکه به‌طور کلی از سه لایه‌ی ورود پنهان و خروجی تشکیل شده است. در این تحقیق از دو نوع شبکه‌ی چندلایه پرسپترون -- MLP<sub>1</sub> و MLP<sub>2</sub> -- استفاده شده است. تفاوت این دو نوع شبکه در تعداد پارامتر ورودی آنهاست. در مدل اول از ۶ ورودی و در مدل دوم از ۵ ورودی استفاده شده است. هر دو مدل یک خروجی دارند. ساختار به‌ترتیب با یک لایه‌ی پنهان و دو لایه‌ی پنهان برای هر دو مدل ارائه شده است.

جدول ۴. نمونه‌یی از پردازش داده‌ها قبل از ارائه به شبکه‌ی عصبی.

ورودی‌ها						خروجی‌ها
$N_{SPT}$	$\gamma_m$ ( $gr/cm^3$ )	W (%)	H (cm)	$D_{max}$	P ( $kg/cm^2$ )	$\Delta V$ ( $cm^3$ )
۱۲	۱٫۸۲	۱۸	۶۷۵	۰٫۹۵	۳٫۴۷۵	۵۸
۱۲	۱٫۸۲	۱۸	۶۷۵	۰٫۹۵	۵٫۰۷۵	۵۷
۱۲	۱٫۸۲	۱۸	۶۷۵	۰٫۹۵	۶٫۶۷۵	۴۰
۱۲	۱٫۸۲	۱۸	۶۷۵	۰٫۹۵	۸٫۴۷۵	۱۰۰
۴۰	۱٫۸۶	۱۷	۱۵۲۵	۰٫۴۷	۴٫۴۲۵	۴۵
۴۰	۱٫۸۶	۱۷	۱۵۲۵	۰٫۴۷	۷٫۹۲۵	۸۳
۴۰	۱٫۸۶	۱۷	۱۵۲۵	۰٫۴۷	۱۱٫۵۲	۹۵
۴۰	۱٫۸۶	۱۷	۱۵۲۵	۰٫۴۷	۱۵٫۲۲	۲۷
۴۰	۱٫۸۶	۱۷	۱۵۲۵	۰٫۴۷	۱۹٫۰۲	۲۰
۴۰	۱٫۸۶	۱۷	۱۵۲۵	۰٫۴۷	۲۳٫۰۲	۳۵
۴۰	۱٫۸۶	۱۷	۱۵۲۵	۰٫۴۷	۲۷٫۰۲	۷۵
۲۸	۱٫۸	۱۸٫۱	۸۷۵	۱٫۹	۳٫۵	۲۲
۲۸	۱٫۸	۱۸٫۱	۸۷۵	۱٫۹	۷٫۲	۱۶
۲۸	۱٫۸	۱۸٫۱	۸۷۵	۱٫۹	۱۱	۱۴
۲۸	۱٫۸	۱۸٫۱	۸۷۵	۱٫۹	۱۴٫۹	۲۰
۲	۱٫۸	۱۸٫۱	۸۷۵	۱٫۹	۱۸٫۸	۲۶
۲۸	۱٫۸	۱۸٫۱	۸۷۵	۱٫۹	۲۲٫۷	۴۴

جذر متوسط مربعات خطا ( $RMSE$ ): این شاخص نیز بیان‌گر متوسط مقدار خطا -- تفاوت مقدار به دست آمده از آزمایش‌ها و مدل‌ها -- است، با این تفاوت که بر خطاهای بزرگ‌تر تمرکز بیشتری دارد. [۱۱] رابطه‌ی ۱۴ نشان‌دهنده‌ی این شاخص است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_i)^2} \quad (14)$$

بیشینه مقدار قدر مطلق خطا ( $MAXAE$ ): این شاخص نشان‌دهنده‌ی بیشترین خطایی است که در مجموعه‌ی مورد نظر اتفاق می‌افتد. براین اساس:

$$MAXAE = Max(|E_i|) \quad (15)$$

مجموع مربعات خطا: این شاخص نشان‌دهنده‌ی مجموع مربعات خطای مجموعه‌ی مورد نظر است (رابطه‌ی ۱۶).

$$SSE = \sum_{i=1}^N (E_i)^2 \quad (16)$$


انحراف استاندارد قدر مطلق خطا ( $SDAE$ ): این شاخص نشان‌دهنده‌ی درجه پراکندگی قدر مطلق خطا حول MAE است.

### ۵.۵. پردازش داده‌های شبکه‌ی عصبی

داده‌های مورد نیاز برای آموزش شبکه از آزمایش‌های آزمایشگاهی و صحرایی به دست آمده‌اند. در این تحقیق از آزمایش‌های پرسیمتری با مدول پرسیمتری بین ۱۰۰ تا ۴۰۰ کیلوگرم بر سانتی‌متر مربع استفاده شده است. با توجه به حفاری گمانه‌هایی که آزمایش پرسیمتری در آنها انجام شده، داده‌های ورودی از نزدیک‌ترین عمق مورد نظر در صورت عدم وجود داده در همان عمق انتخاب شده‌اند. تعداد داده‌های مورد استفاده در مرحله‌ی پیش‌بینی با توجه به نمودارهای حاصله از آزمایش پرسیمتری برابر ۵۰ داده در نظر گرفته شد. نمونه‌یی از ورودی‌های و خروجی‌های ارائه شده به شبکه‌ی عصبی در جدول ۴ ارائه شده است.

### ۶.۵. پیاده‌سازی شبکه‌های عصبی

برای پیاده‌سازی، آموزش و ارزیابی شبکه‌های عصبی مورد استفاده، از جعبه‌ابزار شبکه‌ی عصبی MATLAB ۷٫۶ (۲۰۰۸) استفاده شده است. پرسیمتری چندلایه؛ آموزش و توقف آموزش: چنان‌که گفته شد، از شبکه‌های دو سه‌لایه‌ی پرسپترون با تعداد ورودی متفاوت برای پیش‌بینی استفاده شده است. با توجه به مزیت‌های روش ML که شرح داده شد، این روش مورد استفاده قرار گرفته است. در این تحقیق ضرایب روش ML،  $\mu$  و  $\beta$  با توجه به مقادیر پیش‌فرض MATLAB به ترتیب معادل ۰٫۰۰۱ و ۰٫۰۱ در نظر گرفته شده است. [۱۲] در همین راستا بانک اطلاعاتی به سه مجموعه‌ی آموزشی، ارزیابی و آزمایشی تقسیم شده است. از تمام شاخص‌های ارزیابی برای سنجش کارایی و دقت شبکه‌های چندلایه‌ی پرسپترون استفاده شده است. تعداد ۳۵ داده برای آموزش، ۷۰ داده برای مجموعه‌ی ارزیابی و تعداد ۸۰ داده برای مجموعه‌ی آزمایشی استفاده شده است. در شکل ۳ منحنی آموزشی برای شبکه‌ی MLP با یک لایه‌ی پنهان نشان داده شده است. در هر دو مدل پرسپترون چندلایه (MLP۱ و MLP۲) از تعداد یک و دو لایه‌ی پنهان استفاده شده است. به‌عنوان توابع فعالیت در لایه‌های پنهان از تابع تانژانت



شکل ۳. منحنی آموزش شبکه‌ی MLP با یک لایه‌ی پنهان ۱۱ نورونی.

هیپربولیک و برای لایه‌ی خروجی از تابع خطی استفاده شده است. از آنجا که تعداد نورون‌های لایه‌ی پنهان در رفتار این شبکه‌ها نقش عمده دارد، مطالعه‌ی عملکرد این شبکه‌ها با تعداد نورون‌های متفاوت بدین ترتیب انجام شده است: پس از انتخاب تعداد نورون‌های بهینه برای هر دو ساختار ۶ ورودی و ۵ ورودی، این دو ساختار نیز با استفاده از شاخص‌های خطا با هم مقایسه شده و ساختار مناسب هر مدل

پنهان مختلف در جدول ۵ ارائه شده است. مشاهده می‌شود که مدل MLP۱ با دو لایه‌ی پنهان و با ۲۰ نورون در لایه‌های پنهان بهترین عملکرد را در شبکه‌های مدل MLP۱ (با ۶ پارامتر ورودی) از خود نشان می‌دهد. همچنین این ساختار دارای بالاترین ضریب همبستگی و پایین‌ترین شاخص‌های خطاست.

مدل MLP۲ با ۵ پارامتر ورودی در این بخش ارائه شده است. ابتدا مدل MLP۲ با یک لایه‌ی پنهان به همراه تعداد نورون‌های مختلف در برابر دو دسته شاخص‌های ارزیابی قرار گرفته است. ولی در مجموع ساختار این مدل با ۱۵ نورون در لایه‌ی پنهان نسبت به دیگر ساختارهای این مدل ضریب همبستگی بالاتر و همچنین شاخص‌های خطای کم‌تری از خود نشان می‌دهد.

شاخص‌های خطای شبکه در مقابل مجموعه‌ی ارزیابی، آموزشی و آزمایشی برای شبکه‌ی MLP۲ با دو لایه‌ی پنهان با تعداد نورون‌های متفاوت نیز محاسبه شده است. دو ساختار به ترتیب با ۱۵ و ۲۰ نورون در لایه‌ی پنهان عملکرد بسیار مناسبی از خود نشان داده‌اند.

ساختارهای بهینه مدل MLP۲ با پنج پارامتر ورودی با تعداد لایه‌ها و نورون‌های پنهان مختلف در جدول ۶ ارائه شده‌اند. مشاهده می‌شود که مدل MLP۲ با یک لایه پنهان با ۱۵ نورون در لایه پنهان بهترین عملکرد را در شبکه‌های مدل MLP۲ با پنج پارامتر ورودی از خود نشان می‌دهد. همچنین این ساختار دارای بالاترین ضریب همبستگی و پایین‌ترین شاخص‌های خطاست. لازم به ذکر است که این ساختار در ضریب همبستگی و RMSE در مجموعه‌ی آموزشی و ارزیابی شبکه با دو لایه‌ی پنهان ۲۰ نورونی تقریباً برابر است. بنابراین شبکه‌ی مذکور عملکرد قابل قبولی در مرحله‌ی پیش‌بینی از خود نشان داده است.

انتخاب می‌شود. در مرحله‌ی بعد نیز مدل‌ها با توجه به ساختار بهینه‌ی هر مدل با هم مقایسه می‌شوند. برای قضاوت در مورد عملکرد و کارایی مدل‌ها از دو دسته شاخص استفاده شده است: ضریب همبستگی (R) و شاخص‌های مقدار خطا (SDAE, MSE, MAXAE, MAE, SSE). در مجموعه‌ی مورد نظر شبکه و مدلی دارای کارایی بهتر است که دارای ضریب همبستگی و شاخص‌های خطای مناسب‌تر باشد. برای قضاوت درباره‌ی ضریب همبستگی، از محدوده‌ی اسمیت (۱۹۸۶) استفاده شده است.<sup>[۲۴]</sup> به عنوان مثال اگر برای هر یک از مجموعه‌های سه‌گانه‌ی آموزشی، ارزیابی و آزمایشی  $R \leq 0.8$  به دست آید، شبکه کارایی خوبی در آن مجموعه داده ندارد. در مدل اول، شاخص‌های خطای شبکه در مقابل مجموعه‌ی ارزیابی، آموزشی و آزمایشی برای شبکه‌ی MLP۱ با یک لایه‌ی پنهان مورد مقایسه قرار گرفت شبکه با ۱۵ نورون در لایه‌ی پنهان با شاخص‌های همبستگی و مقدار خطای بهتر در مجموعه‌ی آموزشی به عنوان بهترین ساختار مدل MLP۱ با یک لایه‌ی پنهان انتخاب شده است.

همچنین شاخص‌های خطای شبکه در مقابل مجموعه‌ی ارزیابی، آموزشی و آزمایشی برای شبکه‌ی MLP۱ با دو لایه‌ی پنهان و تعداد نورون‌های متفاوت بررسی شد. در این ساختارها دو ساختار به ترتیب با ۲۰ و ۲۵ نورون در لایه‌ی پنهان عملکرد بسیار مناسبی از خود نشان داده‌اند. در این میان شبکه با ۲۰ نورون در هر دو لایه‌ی پنهان با ضریب همبستگی بالا در مجموعه‌های آموزشی، ارزیابی و آزمایشی و همچنین شاخص‌های خطای پایین‌تر در مقایسه با ساختارهای دیگر مدل، عملکرد بسیار مناسبی از خود نشان داده است. ساختارهای بهینه‌ی مدل MLP۱ با ۶ پارامتر ورودی، با تعداد لایه‌ها و نورون‌های

جدول ۵. مقایسه‌ی بین ساختارهای بهینه‌ی شبکه‌های MLP۱.

مجموعه ارزیابی								
SSE	SDAE	MAXAE	MAE	RMSE	R	تعداد نورون‌ها		شبکه‌ها
۰٫۹۹	۰٫۰۴۹	۰٫۲۰	۰٫۰۵۰	۰٫۰۶۷	۰٫۹۳	۱۵		MLP۱ - ۱
۱٫۱	۰٫۰۴۵	۰٫۳۱	۰٫۰۵۵	۰٫۰۷۲	۰٫۹۲	۲۰		
۱٫۴	۰٫۰۵۸	۰٫۴۶	۰٫۰۵۵	۰٫۰۸۰	۰٫۸۹	۳۰		
۰٫۷۵	۰٫۰۵۶	۰٫۳۷	۰٫۰۳۳	۰٫۰۶۱	۰٫۹۴	۲۰	۲۰	MLP۱ - ۲
۰٫۴۴	۰٫۰۵۶	۰٫۱۶	۰٫۰۳۲	۰٫۰۴۶	۰٫۹۷	۲۵	۲۵	
مجموعه آموزشی								
۳٫۱	۰٫۰۴۵	۰٫۳۸	۰٫۰۳۹	۰٫۰۵۶	۰٫۹۷	۱۵		MLP۱ - ۱
۳٫۱	۰٫۰۴۳	۰٫۳۶	۰٫۰۳۶	۰٫۰۵۵	۰٫۹۶	۲۰		
۳٫۲	۰٫۰۵۱	۰٫۳۵	۰٫۰۳۷	۰٫۰۵۶	۰٫۹۵	۳۰		
۰٫۴۸	۰٫۰۲۱	۰٫۲۷	۰٫۰۰۷	۰٫۰۲۲	۰٫۹۹	۲۰	۲۰	MLP۱ - ۲
۰٫۸۲	۰٫۰۲۴	۰٫۳۴	۰٫۰۱۰	۰٫۰۲۹	۰٫۹۹	۲۵	۲۵	
مجموعه آزمایشی								
۱٫۳	۰٫۰۵۶	۰٫۲۲	۰٫۰۵۵	۰٫۰۷۹	۰٫۹۱	۱۵		MLP۱ - ۱
۱٫۳۵	۰٫۰۵۷	۰٫۳۰	۰٫۰۵۷	۰٫۰۸۰	۰٫۹۰	۲۰		
۱٫۴	۰٫۰۵۹	۰٫۲۷	۰٫۰۶۰	۰٫۰۸۱	۰٫۸۷	۳۰		
۰٫۶۴	۰٫۰۴۵	۰٫۲۱	۰٫۰۳۳	۰٫۰۵۵	۰٫۹۶	۲۰	۲۰	MLP۱ - ۲
۰٫۸۵	۰٫۰۵۵	۰٫۲۷	۰٫۰۳۹	۰٫۰۶۳	۰٫۹۵	۲۵	۲۵	

جدول ۶. مقایسه‌ی ساختارهای بهینه‌ی شبکه‌های MLP۲.

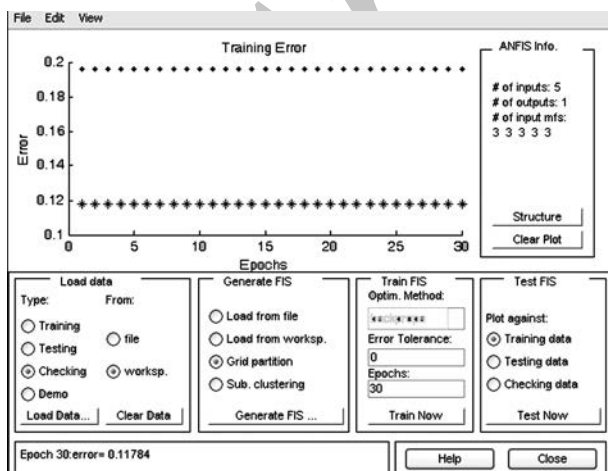
مجموعه ارزیابی							
SSE	SDAE	MAXAE	MAE	RMSE	R	تعداد نورون‌ها	
۱٫۳	۰٫۲۸	۰٫۳۲	۰٫۱۸	۰٫۳۷	۰٫۹۸	۱۵	
۱٫۶	۰٫۶۸	۰٫۳۴	۰٫۶۶	۰٫۸۹	۰٫۹۰	۲۰	
۰٫۹۵	۰٫۴۸	۰٫۲۰	۰٫۴۶	۰٫۶۸	۰٫۹۴	۲۵	
۱٫۱	۰٫۵۸	۰٫۳۳	۰٫۴۹	۰٫۷۰	۰٫۹۳	۳۰	
۰٫۶۵	۰٫۴۱	۰٫۲۶	۰٫۳۹	۰٫۵۳	۰٫۹۳	۲۰	۲۰
۰٫۷۵	۰٫۵۰	۰٫۳۲	۰٫۴۱	۰٫۶۲	۰٫۹۴	۲۵	۲۵
مجموعه آموزشی							
۱٫۳	۰٫۲۸	۰٫۳۲	۰٫۱۸	۰٫۳۷	۰٫۹۸	۱۵	
۳٫۶	۰٫۴۲	۰٫۴۱	۰٫۴۱	۰٫۶۱	۰٫۹۵	۲۰	
۱٫۶	۰٫۴۵	۰٫۳۳	۰٫۲۷	۰٫۴۰	۰٫۹۸	۲۵	
۲٫۶	۰٫۴۸	۰٫۴۹	۰٫۳۳	۰٫۵۱	۰٫۹۶	۳۰	
۱٫۸	۰٫۲۰	۰٫۳۱	۰٫۲۰	۰٫۳۶	۰٫۹۹	۲۰	۲۰
۱٫۶	۰٫۳۸	۰٫۳۳	۰٫۲۴	۰٫۴۱	۰٫۹۸	۲۵	۲۵
مجموعه آزمایشی							
۰٫۶۱	۰٫۵۱	۰٫۳۳	۰٫۳۶	۰٫۶۲	۰٫۹۴	۱۵	
۱٫۷	۰٫۶۳	۰٫۳۳	۰٫۶۴	۰٫۹۱	۰٫۸۴	۲۰	
۱٫۵	۰٫۶۸	۰٫۳۲	۰٫۴۹	۰٫۸۳	۰٫۹۱	۲۵	
۱٫۷	۰٫۷۲	۰٫۴۴	۰٫۶۲	۰٫۸۹	۰٫۸۵	۳۰	
۱٫۵	۰٫۶۳	۰٫۴۷	۰٫۴۷	۰٫۸۵	۰٫۹۰	۲۰	۲۰
۱٫۱	۰٫۵۸	۰٫۳۳	۰٫۴۸	۰٫۷۲	۰٫۹۰	۲۵	۲۵

گرفته شده‌اند. شاخص‌های ارزیابی در این مدل همانند مدل چندلایه‌ی پرسپترون است. دو مدل شبکه‌ی نوروفازی (NF۱ و NF۲) به‌منظور پیش‌بینی مورد استفاده قرار گرفته است. در شکل ۵ منحنی آموزشی برای شبکه‌ی NF۱ نشان داده شده است. در مدل اول، شاخص‌های خطای شبکه در مقابل مجموعه‌های آموزشی و آزمایشی برای شبکه‌ی NF۱ مورد ارزیابی قرار گرفته است. در انتها، شبکه با ۳


الگوریتم یادگیری در شبکه‌ی نوروفازی: مدل‌کردن شبکه‌ی نوروفازی با استفاده از محیط گرافیکی نرم‌افزار MATLAB (ANFIS) انجام شده است. انواع توابع عضویت در لایه‌ی ورودی و خروجی مورد استفاده قرار گرفته‌اند. بهترین کاربرد در استفاده از تابع عضویت مثلثی براساس رابطه‌ی ۱۷ در لایه‌ی ورودی مشاهده شده است. در شکل ۴ نیز شمایی از این تابع عضویت نشان داده است.<sup>[۹]</sup>

$$\mu(x, a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right), \quad a \neq b, b \neq c \quad (17)$$


بانک اطلاعاتی مورد استفاده به دو دسته داده‌ی آموزشی و آزمایشی تقسیم شده است. تعداد ۴۰۰ داده در مرحله‌ی آموزش و ۱۰۰ داده برای آزمایش در نظر



شکل ۵. منحنی آموزش شبکه‌ی NF۱ با تابع عضویت مثلثی.

شکل ۴. شمایی از تابع عضویت مثلثی.<sup>[۹]</sup>





شکل ۶. منحنی آموزش شبکه RBF۱.

RBF۲ با ۵ پارامتر ورودی بررسی شده است. در این مدل بیشتر ساختارها در مقایسه با مدل اول از کارایی بهتری برخوردارند. ولی در بین این ساختارها، ساختار دارای نصف بیشینه نورون‌های پیش فرض بهترین عملکرد را دارد.

### ۷.۵. مقایسه‌ی کارایی مدل‌های شبکه‌ی عصبی

در این بخش کارایی ساختارهای بهینه‌ی سه مدل شبکه‌ی عصبی مورد استفاده مقایسه شده است. در جدول ۷ شاخص‌های خطا برای سه مدل مربوطه -- برای مجموعه‌های آموزشی، آزمایشی و ارزیابی -- نشان داده شده است. چنان‌که مشاهده می‌شود شبکه‌ی MLP۲ با یک لایه‌ی پنهان ۱۵ نورونی بهترین عملکرد را نسبت به سه مدل دیگر از خود نشان می‌دهد. البته در مجموعه‌ی آموزشی، شبکه‌ی MLP۱ با دو لایه‌ی پنهان ۲۰ نورونی بهترین عملکرد را دارد ولی در سایر شاخص‌های خطا شبکه‌ی MLP۲ مقادیر پایین‌تری را به خود اختصاص داده است. بنابراین شبکه‌ی

تابع عضویت با MAE و RMSE بهتر در مجموعه‌های آموزشی و آزمایشی، و با وجود بیشینه خطای بیشتر در مجموعه‌ی ارزیابی به‌عنوان بهترین ساختار مدل NF۱ با ۶ پارامتر ورودی انتخاب شده است.

شاخص‌های خطای شبکه در مقابل مجموعه‌ی آموزشی و آزمایشی برای شبکه‌ی NF۲ با ۵ پارامتر ورودی نیز بررسی شده است. بدین ترتیب شبکه با ۳ تابع عضویت با شاخص‌های خطای پایین‌تر، در مقایسه با ساختارهای دیگر مدل، عملکرد قابل قبولی از خود نشان داده است. در مجموع شبکه NF۱ با ۳ تابع عضویت ورودی و خروجی بهترین کارایی را در میان این دو مدل از خود نشان می‌دهد.

شبکه‌ی تابع مبنای شعاعی: در این شبکه‌ها هر واحد در لایه‌ی پنهان، یک تابع مبنای شعاعی مانند یک هسته‌ی گاوسی را به‌عنوان تابع فعال‌سازی به کار می‌برد، در حالی‌که واحدهای خروجی تابع همانی را به‌عنوان تابع فعال‌سازی به کار می‌برند. در پیاده‌سازی شبکه‌ی تابع مبنای شعاعی از جعبه‌ابزار MATLAB بهره گرفته شده است. برای تشکیل ساختار شبکه‌ی عصبی تابع مبنای شعاعی در محیط نرم‌افزار و با استفاده از جعبه‌ابزار شبکه‌ی عصبی از دستور newrb استفاده می‌شود.

در این نوشتار از دو نوع شبکه‌ی تابع مبنای شعاعی (RBF۱ و RBF۲) استفاده شده است. شاخص‌های ارزیابی برای مدل‌های تابع مبنای شعاعی مانند شبکه‌های قبلی مورد محاسبه قرار گرفته‌اند. بانک اطلاعاتی مورد استفاده به دو دسته داده‌ی آموزشی و آزمایشی تقسیم شده‌اند. تعداد ۴۰۰ داده در مرحله‌ی آموزش و تعداد ۱۰۰ داده برای آزمایش در نظر گرفته شده‌اند. در شکل ۶ منحنی آموزشی برای شبکه‌ی RBF۱ نشان داده شده است.

شاخص‌های خطای شبکه در مقابل مجموعه‌های آموزشی و آزمایشی برای شبکه‌ی RBF۱ به‌دست آمده است. براین اساس تمام شبکه‌ها عملکرد نسبتاً قابل قبولی از خود نشان می‌دهند. به‌این ترتیب در میان مدل‌های ارائه شده، مدل شبکه‌ی RBF۱ با برخورداری از نصف بیشینه نورون‌های پیش فرض بهترین عملکرد را دارد.

شاخص‌های خطای شبکه در مقابل مجموعه‌ی آموزشی و آزمایشی برای شبکه‌ی

جدول ۷. مقایسه‌ی ساختارهای بهینه‌ی مدل‌ها براساس شاخص‌های خطا.

مجموعه ارزیابی								
SSE	SDAE	MAXAE	MAE	RMSE	R	تعداد نورون‌ها		شبکه‌ها
۰٫۷۵	۰٫۰۵۶	۰٫۳۷	۰٫۰۳۳	۰٫۰۶۱	۰٫۹۴۴	۲۰	۲۰	MLP۱ - ۲
۰٫۷۳	۰٫۰۴۸	۰٫۳۰	۰٫۰۳۶	۰٫۰۵۹	۰٫۹۵	۱۵		MLP۲ - ۱
مجموعه‌ی آموزشی								
۰٫۴۸	۰٫۰۲۱	۰٫۲۷	۰٫۰۰۷	۰٫۰۲۲	۰٫۹۹	۲۰	۲۰	MLP۱ - ۲
۱٫۳	۰٫۰۲۸	۰٫۳۲	۰٫۰۱۸	۰٫۰۳۷	۰٫۹۸	۱۵		MLP۲ - ۱
۲٫۵	۰٫۰۵۵	۰٫۵۵	۰٫۰۴۲	۰٫۰۵۰	۰٫۹۴	۳		NF۱
۱٫۱	۰٫۰۲۷	۰٫۳۲	۰٫۰۱۸	۰٫۰۳۳	۰٫۹۸	۲۵۰		RBF۲
مجموعه‌ی آزمایشی								
۱٫۳۵	۰٫۰۴۵	۰٫۳۰	۰٫۰۵۷	۰٫۰۸۰	۰٫۹۰	۲۰	۲۰	MLP۱ - ۲
۰٫۶۱	۰٫۰۵۱	۰٫۳۳	۰٫۰۳۶	۰٫۰۶۲	۰٫۹۴	۱۵		MLP۲ - ۱
۳٫۷	۰٫۰۶۵	۰٫۵۰	۰٫۰۶۵	۰٫۰۸۰	۰٫۹۰	۳		NF۱
۱٫۸	۰٫۰۵۳	۰٫۴۶	۰٫۰۴۲	۰٫۰۷۲	۰٫۹۲	۲۵۰		RBF۲


بر هریک از نورون های میانی و خروجی با توجه به وزن ها و توابع فعالیت هر کدام از آنها<sup>[25]</sup> و همچنین استفاده از منطق فازی با شبکه های عصبی برای توضیح قوانین حاکم بر شبکه های عصبی آموزش دیده<sup>[26]</sup> نام برد. بررسی این روش ها نشان داده که اثر هر پارامتر ورودی بر متغیرهای خروجی از نظر مقدار و جهت را نمی توان با این روش در کل فضای ورودی تعیین کرد.<sup>[25]</sup> از این رو، با روشی مبتنی بر تحلیل آماری مشتق خروجی شبکه نسبت به ورودی (حساسیت خروجی به ورودی)، تحلیل حساسیت روی مسئله بهره وری در تولید لوله های انتقال انجام شده و چنین نتیجه گرفته شده که مطالعه روابط درون شبکه های عصبی در کاربران آن اطمینان بیشتری به قدرت پیش بینی شبکه ایجاد می کند و استفاده از این مدل ها را در کارهای علمی و مهندسی تسهیل می کند.<sup>[26]</sup> با این هدف در این بخش، ابتدا رابطه مشتق خروجی نسبت به ورودی برای ساختارهای بهینه ای ارائه شده در هر مرحله تعیین شده است. سپس اثر پنج متغیر اصلی ورودی شامل: وزن مخصوص طبیعی، درصد رطوبت، عمق انجام آزمایش، عدد آزمایش نفوذ استاندارد و بیشترین اندازه دانه ها مورد مطالعه قرار گرفته است. این مطالعه مبتنی بر تحلیل آماری مشتق نسبی خروجی های مدل نسبت به ورودی های مورد نظر در ۲۰۰ نقطه ای واقع در فضای پنج بعدی ورودی های مورد بحث است. این نقاط با تابع توزیع نرمال انتخاب شده اند.

#### ۱.۶. حساسیت خروجی نسبت به ورودی در مدل رفتاری مبتنی بر


##### شبکه ی MLP

در این بخش رابطه مشتق نسبی خروجی ها در این مدل ها نسبت به ورودی های مستقل ارائه شده است. در این ارتباط، مشتق نسبی خروجی یک شبکه نسبت به ورودی های آن -- که تماماً مستقل از خروجی بودند -- محاسبه شد.<sup>[25]</sup> با این وجود با توجه به این که در مدل های رفتاری مبتنی بر شبکه های عصبی دست کم یکی از ورودی های شبکه به مثابه خروجی مدل در لحظه های قبل است، این رابطه مستقیماً قابل استفاده نیست و باید اصلاح شود. در شکل ۹ نورون های لایه های ورودی، پنهان و خروجی و نیز اتصال بین آنها در یک شبکه ی MLP که به عنوان مدل رفتاری خاک ها استفاده می شود به طور شماتیک نشان داده شده است. مطالعه ی چگونگی انتساب عدم قطعیت ها در خروجی مدل به منابع مختلف عدم قطعیت در ورودی مدل را «تحلیل حساسیت» می نامند. موضوع مرتبط با این امر تحلیل عدم قطعیت است که بر آشکار ساختن کمیت این عدم قطعیت ها تمرکز دارد.


برای تحلیل حساسیت و عدم قطعیت، می توان هر چیزی را که در خروجی مدل تغییر ایجاد می کند، به عنوان ورودی در نظر گرفت. وقتی که بین ورودی و خروجی ها



شکل ۹. شمایی از شبکه ی MLP مورد استفاده.



شکل ۷. نمودارهای حاصل از مدل های شبکه ی عصبی.



شکل ۸. نمودارهای حاصل از مدل های شبکه ی عصبی.

مذکور به عنوان موفق ترین مدل در پیش بینی نتایج حاصل از آزمایش پرسیمتری انتخاب می شود.

پیش بینی نمودار فشار - تغییر حجم حاصل از آزمایش پرسیمتری در شکل های ۷ و ۸ برای ساختارهای بهینه ی شبکه ی پرسپترون، نوروفازی و تابع میانی شعاعی نشان داده شده است. این نمودارها در مقایسه با نمودار تجربی حاصله رسم شده اند. چنان که مشاهده می شود نمودارهای حاصله رفتار خاک را در آزمایش پرسیمتری با دقت قابل قبولی تخمین می زنند.

#### ۶. تحلیل حساسیت

در این بخش، ساختار نهایی مدل های متشکل از شبکه ی عصبی پیشخور دارای یک لایه پنهان با ۱۵ نورون و یک لایه ی خروجی با یک نورون مورد ارزیابی قرار گرفته است. در این راستا تحلیل نامعینی و تحلیل حساسیت روی مدل شبکه ی عصبی مورد نظر صورت گرفته تا کارایی و اهمیت پارامترها مورد بررسی قرار گیرند. در بخش قبل عملکرد، ساختار بهینه ی شبکه ی عصبی در مقایسه با نتایج تجربی مورد بررسی قرار گرفت. چنان که پیش تر گفته شد، این شبکه ها هیچ گونه توضیحی در مورد نحوه ی اثر پارامترهای ورودی بر خروجی و به عبارتی دانش حاکم بر محیط ارائه نمی دهند. در این راستا روش های متفاوتی برای استخراج و توضیح روابط حاکم ارائه شده است. از جمله این روش ها می توان به استخراج روابط حاکم

بدیهی است با توجه به علائم فوق خواهیم داشت:  $h_i^j = f(net_i^j)$  که در آن  $f()$  تابع فعالیت نورون لایه ی  $j$ ام است. اگر تعداد لایه ی پنهان شبکه و تعداد نورون در لایه ی خروجی برابر ۱ در نظر گرفته شود و نیز تعداد نورون در لایه ی پنهان  $m$  و  $n$  تعداد ورودی باشد، رابطه ی مشتق خروجی نسبت به ورودی  $x_i$  را می توان با استفاده از روابط زیر به دست آورد.

خروجی لایه ی دوم، یعنی لایه ی خروجی با یک نورون و با تابع انتقال خطی به صورت زیر نمایش داده می شود:

$$O_1 = f(net_1) = net_1 = b_1 + \sum_{j=1}^m w_{j1} h_j = b_1 + \sum_{j=1}^m w_{j1} f(net_j) = b_1 + \sum_{j=1}^m w_{j1} f(b_j + \sum_{i=1}^n w_{ij} x_i) \quad (21)$$

از آنجا که تابع انتقال نورون های لایه ی پنهان، تانژانت هیپربولیک ( $\tan sig$ ) است، رابطه ی ۲۱ چنین نوشته خواهد شد:

$$O_1 = b_1 + \sum_{j=1}^m \{w_{j1} \cdot \tan sig(b_j + \sum_{i=1}^n w_{ij} x_i)\} \quad (22)$$

حال می توان با استفاده از رابطه ی زنجیره یی، مشتق تنها خروجی شبکه ( $O_1$ ) را نسبت به هر کدام از ورودی های ( $x_i$ ) به دست آورد.

$$\frac{\partial O_1}{\partial x_i} = \frac{\partial O_1}{\partial h_j} \frac{\partial h_j}{\partial net_j} \frac{\partial net_j}{\partial x_i} \quad (23)$$

$$\frac{\partial O_1}{\partial h_j} = w_{j1} \quad (24)$$

$$\frac{\partial h_j}{\partial net_j} = \frac{\partial \tan sig(net_j)}{\partial net_j} = 1 - (h_j)^2 \quad (25)$$

$$\frac{\partial net_j}{\partial x_i} = w_{ij} \quad (26)$$

### ۳.۶. روش به کار رفته

در این مطالعه تحلیل حساسیت روی پنج ورودی شامل وزن مخصوص طبیعی، درصد رطوبت، عمق انجام آزمایش، عدد آزمایش نفوذ استاندارد و بیشترین اندازه ی دانه ها انجام شده است. در این تحلیل تعداد ۲۰۰ نقطه داده در فضای پنج بعدی پارامترهای ورودی متناظر با تابع توزیع نرمال توسط نرم افزار Simlab انتخاب شده است.

در هر یک از این نقاط که مقادیر ورودی مربوط به خودش را دارد، مقادیر مشتق نسبی تغییر حجم برای ساختار بهینه محاسبه شده است. خصوصیات آماری این مقادیر در جدول ۸ ارائه شده است. چنان که انتظار می رود مشتق نسبی هر خروجی نسبت به هر ورودی در نقاط فضای ورودی مقادیر متفاوتی دارد. برای تحلیل و توضیح این تغییر اگر توزیع مقادیر مشتق در حالت واقعی در دسترس باشد، می توان این توزیع را با توزیع واقعی مقایسه، و بدین وسیله مدل را ارزیابی کرد. اما در واقعیت با توجه به پیچیدگی مسائل مهندسی، عامل های درگیر این توزیع در دسترس نیست. علاوه بر این، علت اول استفاده از شبکه ی عصبی در حل این مسائل به جای مدل های ریاضی مرسوم همین مشخص نبودن تأثیر پارامترهای ورودی در شرایط مختلف روی پارامترهای خروجی است.<sup>[۲۵]</sup>

در میان پارامترهای دیگر، مقدار میانگین حساسیت ها نیز می تواند به عنوان برآیند اثر ورودی بر خروجی مد نظر قرار گیرد. در واقع تغییرات در مقادیر خروجی برابر

رابطه برقرار شد، می توان تحلیل نامعینی و حساسیت را روی آن انجام داد. یکی از روش های قابل استفاده برای انجام تحلیل، روش مونت کارلو است که در آن به توابع توزیع پارامترهای ورودی و خروجی های شبکه توجه می شود. برای مثال مراحل انجام تحلیل مونت کارلو را می توان چنین در نظر گرفت:

۱. توزیعی مانند توزیع نرمال برای هر کدام از پارامترهای ورودی ( $x_1, x_2, \dots$ ) تهیه می شود.

نکته: طبق تعریف، متغیر تصادفی  $x$  با میانگین  $\mu$  و انحراف معیار  $\sigma$  دارای توزیع نرمال است مشروط بر آن که تابع چگالی آن به صورت رابطه ی ۱۸ باشد:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right] \quad (18)$$

که به صورت  $x \sim N(\mu, \sigma)$  نشان داده می شود.

۲. پارامترها مستقل از یکدیگر فرض می شوند.

۳. برای هر پارامتر ورودی نمونه یی از توزیع ایجاد شده، با روش خاص نمونه گیری، مانند روش نمونه گیری تصادفی، در نظر گرفته می شود. این عمل منجر به ساخت ماتریسی می شود که تعداد سطرها ی آن برابر با تعداد نمونه، و ستون هایش به تعداد پارامترهای ورودی است.

$$\begin{bmatrix} x_1^1 & x_1^2 & \dots \\ x_2^1 & x_2^2 & \dots \\ \vdots & \vdots & \dots \\ x_n^1 & x_n^2 & \dots \end{bmatrix} \quad (19)$$

۴. پس از آن، داده های بیرون کشیده شده به مدل اعمال می شوند تا ماتریس خروجی به صورت زیر به دست آید:

$$\begin{bmatrix} y^1 \\ y^2 \\ \vdots \\ y^N \end{bmatrix} \quad (20)$$

موارد گفته شده مراحل انجام تحلیل نامعینی را تشکیل می دهند. از نتیجه ی حاصله می توان میانگین، انحراف استاندارد، چارک ها، مرزهای اطمینان و غیره را برای خروجی به دست آورد. پس از انجام تحلیل نامعینی می توان با انجام تحلیل حساسیت روی مدل، مشخص کرد که کدام پارامتر ورودی در تولید نامعینی در خروجی شبکه از اهمیت بیشتری برخوردار است.

### ۲.۶. مشتق خروجی پرسپترون چندلایه نسبت به ورودی

پیش از ارائه ی روابط مورد نیاز برای محاسبه ی مشتق نسبی خروجی نسبت به ورودی ها، ابتدا علائم به کار رفته در روابط تشریح می شوند:

$O_k$ : خروجی  $k$ امین نورون در لایه ی خروجی؛

$x_i$ :  $i$ امین ورودی به شبکه؛

$w_{ik}^j$ : وزن اتصالات بین  $i$ امین نورون در لایه ی  $j$ ام و  $k$ امین نورون در لایه ی  $j+1$ ام؛

$b_j^k$ : بایاس  $i$ امین نورون در لایه ی  $j$ ام؛

$net_i^j$ : جمع وزنی ورودی به  $i$ امین نورون در لایه ی  $j$ ام؛

$h_i^j$ : خروجی  $i$ امین نورون در لایه ی  $j$ ام.

جدول ۸. خصوصیات آماری حساسیت مطلق خروجی نسبت به ورودی‌ها.

ورودی	بیشینه	کمینه	میانگین	انحراف معیار
$\gamma$	۴,۰۴۵	۰,۳۶۱	۰,۹۵۰	۰,۵۳۵
W	۳,۲۰۱	-۱,۲۱۸	۱,۴۸۲	۰,۹۸۴
H	۲,۰۶۸	-۱۱,۷۸	-۱,۵۹۳	۱,۱۸۸
$N_{SPT}$	۶,۴۲۲	-۱۷,۳۴	-۱,۴۲۷	۱,۳۸۷
$D_{max}$	۲,۵۸۴	-۱,۹۲۵	-۰,۶۵۹	۰,۶۲۰

جدول ۹. مقادیر میانگین حساسیت نسبی خروجی نسبت به ورودی‌ها.

خروجی	$\Delta V$			
	$D_{max}$	$N_{SPT}$	H	W
میانگین نسبی	-۱,۰۱۵	-۱,۱۶۵	-۲,۹۲۰	۰,۲۴۶
$\gamma$	-۰,۹۲۸			

مقادیر درصدی آماری می‌توان درجه‌ی تأثیر هر متغیر را روی خروجی بررسی، و اثر آنها را با هم سنجید.

چنان که پیش‌تر توضیح داده شد، برای مقایسه‌ی درجه‌ی تأثیر متغیرهای ورودی به‌جای استفاده از مقادیر حساسیت مطلق بهتر است از حساسیت نسبی استفاده شود. در جدول ۹ مقادیر میانگین حساسیت‌های نسبی تغییر حجم نسبت به ورودی‌های مورد بحث ارائه شده است.

#### ۴.۶. تحلیل نتایج و تحلیل حساسیت


در این بخش مقادیر درصدی آماری مربوط به حساسیت‌های نسبی مقادیر تغییر حجم در مقابل هر پنج ورودی برای شبکه‌ی MLP۲ با ۱۵ نورون در لایه‌ی پنهان ارائه شده است (شکل ۱۰). چنان که مشاهده می‌شود، بیش از ۷۵٪ مقادیر حساسیت نسبی برای وزن مخصوص طبیعی ( $\gamma_m$ ) منفی است. این امر نشان‌دهنده‌ی کاهش مقادیر تغییر حجم بر اثر افزایش وزن مخصوص طبیعی ( $\gamma_m$ ) است.

در مورد پارامتر ورودی دیگر، یعنی درصد رطوبت (W)، مشخص است که مقادیر بیشتری از حساسیت نسبی در این پارامتر در حول محور صفر است ولی مقادیر مثبت درصد بیشتری را به خود اختصاص می‌دهند که نشان‌دهنده‌ی افزایش مقدار تغییر حجم بر اثر افزایش مقدار درصد رطوبت است.

بیشترین مقادیر منفی در حساسیت نسبی متعلق به عمق انجام آزمایش است. بیشترین تأثیر کاهش در تغییر حجم نیز بر اثر افزایش عمق اتفاق می‌افتد.

چنان که در شکل ۱۰ مشاهده می‌شود، دو پارامتر ورودی دیگر شامل عدد آزمایش نفوذ استاندارد و بیشترین اندازه‌ی دانه‌ها، دارای مقادیر حساسیت نسبی منفی هستند و این نشان‌دهنده‌ی اثرکاهشی این دو پارامتر روی تغییر حجم حاصل از آزمایش پرسوتمتری است. البته تأثیر این دو پارامتر کم‌تر از عمق انجام آزمایش است.

در مقایسه‌ی اثر این پنج پارامتر ورودی بر تغییر حجم حاصله می‌توان گفت که با توجه به فاصله‌ی دسته‌های آماری از خط پایه، مقادیر درصدی (شکل ۱۰)، و مقادیر میانگین نسبی (جدول ۹)، عمق انجام آزمایش (H) بیشترین تأثیر را دارد.



شکل ۱۰. تحلیل حساسیت شبکه‌ی عصبی.

تغییرات ورودی، تحت تأثیر برآیند مقدار تغییرات خروجی نسبت به یک واحد متغیر در ورودی، یا به عبارتی حساسیت خروجی نسبت به ورودی در هر نقطه از مسیر تغییر ورودی (از یک مقدار اولیه به مقدار ثانویه) است. البته مقایسه‌ی میانگین نیز همانند مقادیر حساسیت باید نسبی در نظر گرفته شود تا قابل مقایسه با مقادیر میانگین ورودی‌های دیگر باشد. اما استفاده از مقادیر میانگین نیز می‌تواند در بعضی از موارد گمراه‌کننده باشد. به‌عنوان مثال، برای یک متغیر ورودی در ۵۰٪ نقاط فضای ورودی حساسیت مقادیر بزرگ مثبت و در ۵۰٪ بقیه مقادیر بزرگ منفی است، مقدار میانگین حساسیت تقریباً صفر شده و چنین نتیجه می‌شود که این متغیر تأثیر چندانی بر خروجی ندارد. در حالی که ممکن است در بخشی از فضای ورودی، متغیر تأثیر افزایشی زیاد و در بخشی دیگر تأثیرکاهشی زیادی داشته باشد. بنابراین نمی‌توان به مقدار میانگین به‌عنوان شاخص اولیه‌ی نشان‌دهنده‌ی حساسیت خروجی نسبت به ورودی تکیه کرد.

با توجه به مطالب گفته شده و متغیر بودن مقادیر حساسیت، برای تحلیل حساسیت نیازمند روشی هستیم که پراکندگی و احتمال مقادیر مختلف حساسیت خروجی نسبت به یک ورودی را در فضای ورودی به‌طور هم‌زمان نشان دهد. با این هدف، از روش آماری مقادیر حساسیت نسبی استفاده شده است. [۲۵] در این روش پنج درصد آماری ( $D_{10}$ ,  $D_{25}$ ,  $D_{50}$ ,  $D_{75}$  و  $D_{90}$ ) مقادیر حساسیت نسبی خروجی‌ها نسبت به ورودی مورد نظر محاسبه می‌شود. با استفاده از این روش می‌توان اثر افزایش یا کاهش هر ورودی را به خروجی، و نیز روند کلی حاکم بر کل فضای ورودی براساس نمونه‌های تصادفی گرفته شده را تعیین کرد. در توضیح و تعریف نتایج به دست آمده از این روش می‌توان گفت: [۲۶]

$D_{10}$ : نشان‌دهنده‌ی شاخصی برای حساسیت نسبی است که ۹۰٪ مقادیر از آن بیشتر و ۱۰٪ مقادیر از آن کم‌تر هستند. بنابراین اگر مثبت شود نشان می‌دهد که احتمال مثبت بودن حساسیت نسبی بالای ۹۰٪ است یا به عبارتی، احتمال افزایش خروجی بر اثر افزایش ورودی مورد نظر بالای ۹۰٪ است.

$D_{90}$ : نشان‌دهنده‌ی شاخصی برای حساسیت نسبی است که ۹۰٪ مقادیر از آن کم‌تر و ۱۰٪ مقادیر از آن بیشتر است. بنابراین اگر منفی شود نشان می‌دهد که کاهش خروجی بر اثر افزایش ورودی مورد نظر بالای ۹۰٪ است. توضیحات  $D_{25}$  و  $D_{75}$  مانند  $D_{10}$  و  $D_{90}$  هستند.

$D_{50}$ : اگر این مقدار بر روی خط پایه (حساسیت صفر) باشد نشان می‌دهد که احتمال افزایش یا کاهش خروجی بر اثر افزایش ورودی معادل ۵۰٪ است.

هر ورودی که دارای پخش مقادیر درصدی حساسیت نسبی حول خط پایه باشد، دارای اثر کم‌تری روی خروجی نسبت به ورودی است که دسته درصدی حساسیت نسبی آن دورتر از خط پایه است. بدین ترتیب با توجه به فاصله‌ی دسته و

## ۷. نتیجه‌گیری

صورت‌گرفته در پروژه‌های مختلف بوده و پارامترهای ورودی دیگر حاصل از نتایج آزمایش‌های آزمایشگاهی و صحرایی مورد نظر در عمق آزمایش پرسیمتری انتخاب شده‌اند. خطاهای حاصل از ساختارهای مختلف شبکه‌های چندلایه‌ی پرسپترون، نوروفازی و تابع مبنای شعاعی با یکدیگر مقایسه شده و ساختار بهینه براساس شاخص‌های خطای بهینه و همچنین ضریب همبستگی پیشینه معرفی شده است. باتوجه به این که شبکه‌های عصبی به خودی خود توضیحی درباره‌ی رابطه‌ی حاکم بر فضای ورودی و خروجی، یا به عبارتی نحوه‌ی تأثیر پارامترهای ورودی بر خروجی نمی‌دهند، ابتدا با انجام تحلیل نامعینی مقدار حساسیت مطلق خروجی‌های هر مرحله نسبت به پنج پارامتر ورودی به دست آمد. بدین‌وسیله تأثیر پنج پارامتر ورودی شامل وزن مخصوص طبیعی ( $\gamma_m$ )، درصد رطوبت ( $W$ )، عمق انجام آزمایش ( $H$ )، عدد آزمایش نفوذ استاندارد ( $N_{SPT}$ ) و بیشترین اندازه‌ی دانه‌ها ( $D_{max}$ ) بر خروجی مورد نظر در هر مرحله مورد مطالعه قرار گرفت. سپس با توجه به این که «حساسیت مطلق» پارامتر مناسبی برای تحلیل اثر پارامترهای ورودی بر خروجی تلقی نمی‌شود، حساسیت‌های نسبی هر خروجی نسبت به ورودی‌های مورد نظر مورد بررسی قرار گرفت و در نهایت مؤثرترین پارامترهای ورودی معرفی شد.

در این مطالعه، سه نوع شبکه‌ی عصبی متفاوت -- چندلایه‌ی پرسپترون، نوروفازی و تابع مبنای شعاعی -- استفاده شده است. ۵ و ۶ پارامتر ورودی برای مدل‌های مورد استفاده انتخاب شده است. خروجی مدل تغییر حجم حاصل از فشار وارده است. در مدل با ۶ ورودی، فشار وارده به‌عنوان ورودی به ۵ ورودی که شامل خواص فیزیکی و تراکمی خاک هستند، اضافه شده است. در شبکه‌های چندلایه‌ی پرسپترون از یک و دو لایه‌ی پنهان با تعداد نورون‌های متفاوت استفاده شده و مناسب‌ترین مدل شبکه‌ی عصبی انتخاب شده است. شبکه‌های نوروفازی با تابع‌های عضویت متفاوت استفاده شده و موفق‌ترین مدل ارائه شده است. در این مرحله همچنین از شبکه‌ی تابع مبنای شعاعی استفاده شده و بهترین عملکرد آن ارائه شده است. در نهایت نتایج حاصل از پیش‌بینی نمودار فشار - تغییر حجم به دست آمده از ساختارهای بهینه‌ی شبکه‌های عصبی با نتایج تجربی مقایسه شده است. شبکه‌های عصبی مورد استفاده به‌خوبی نمودار فشار - تغییر حجم حاصل از آزمایش پرسیمتری را تخمین می‌زنند. داده‌های مورد استفاده در مرحله‌ی ورودی حاصل از آزمایش‌های پرسیمتری

## پانویس

1. multy layer perceptron (MLP)
2. feed forward networks
3. cross validation

## منابع

1. Shahin, M.A; Jaksa, M.B. and Maier, H.R. "Artificial neural network application in geotechnical engineering", Department of Civil and Environmental Engineering, Adelaide University, Australian Geomechanics, (March 2001).
2. Lee, S.J.; Lee, S.R. and Kim, Y.S. "An approach to estimate unsaturated shear strength using artificial neural network and hyperbolic formulation", *Computers and Geotechnics*, **30**, pp. 489-503 (2003).
3. Banimahd, M.; Yasrobi, S.S. and Woodward, P.K. "Artificial neural network for stress-strain behavior of sandy soils: Knowledge based verification", *Computers and Geotechnics*, **32**, pp. 377-386 (2005).
4. Moosavi, M.; Yazdanpanah, M.J. and Doostmohammadi, R. "Modeling the cyclic swelling pressure of mudrock using artificial neural networks", *Engineering Geology*, **87**, pp. 178-194 (2006).
5. Lu, Y. "Underground blast induced ground shock and its modeling using artificial neural network", *Computers and Geotechnics*, **32**, pp. 164-178 (2005).
6. Kim, C.Y.; Bae, G.J.; Hong, S.W.; Park, C.H.; Moon, H.K. and Shin, H.S. "Neural network based prediction of ground surface settlements due to tunneling", *Computers and Geotechnics*, **28**, pp. 517-547 (2001).
7. Menhaj, M.B., *Artificial Intelligence*, Volume 1, Amir Kabir University (2004).
8. Menhaj, M.B. and Seifipour, N., *Artificial Intelligence in Control*, Volume 1, Amir Kabir University (1998).
9. Banimahd M., *Prediction of Stress-Strain Behavior of Sandy Soils with Neural Network*, Master of Science thesis, Tarbiat Modares University, Tehran, Iran (2004).
10. Fausett, L.V., *Fundamentals Neural Networks: Architecture, Algorithms, and Applications*, Prentice-Hall, Inc., Englewood Cliffs, New Jersey (1994).
11. Hagan, M.T. and Menhaj, M.B. "Training feedforward networks with the marquardt algorithm", *IEEE transactions on neural networks*, **5**(6), pp. 989-992 (1994).
12. Hagan, M.T.; Demuth, H.B. and Beale, M.H. *Neural Network Design*, Boston, MA: PWS Publishing (1996).
13. Emami, M., *Application of Artificial Neural Networks in Pressuremeter Test Results*, Master of Science thesis, Tarbiat Modares University, Tehran, Iran (2009).
14. "Pressuremeter test" Instruction for test and application for foundation design, Management and Planning Organization, No: 223, (2001/2002).
15. Pahlavan, M., *An Investigation to Deformation of Coarse Grained Alluvium of Tehran Using Pressuremeter*, A thesis for the degree of PHD, Tarbiat Modares University, Tehran, Iran (2003).
16. Clarke, B.G., *Pressuremeters in Geotechnical Design*, Blackie Academic & professional Pub., p. 364 (1995).

17. Asghari E. and Yasrobi S.S., *Investigation of Deformation Parameters of Marl with Pressuremeter Test*, (2006).
18. Gerivani, H.; Nikodel, M.R. and Pahlavan P., *An Investigation in Engineering Properties of Soft Rock in the Khark Island Using Menard Pressuremeter*, The 4th of engineering geology conference, Tarbiat Modares University, Tehran, Iran (2009).
19. Marquardt, D. "An algorithm for least squares estimation of nonlinear parameters", *J. Soc. Ind. Appl. Math.*, pp. 431-441 (2000).
20. Madan, M.G.; Liang, J. and Noriyasu, H., *Static and Dynamic Neural Network*, John Wiley & Sons, INC., Publication, Hobokon, New Jersey (1996).
21. Buckley, J.J. and Hayashi, Y. "Fuzzy genetic algorithm and applications", *Fuzzy Sets Syst.*, **61**, pp. 129-136 (1994a).
22. Gupta, M.M. "Fuzzy logic and neural networks", in *Neuro Control*, Gupta, M.M. and Rao, D.H. (eds.), IEEE, New York, pp. 403-416 (1994).
23. Shah Nazari, M. *Simulation of Sencron Engine and Design of Expremental Model*, Master of science thesis, Tehran. Iran (2002).
24. Smith, G.N., *Probability and statistics in civil engineering*, Collins, (1986).
25. Lu, M.; Abourizk, S.M. and Hermann, U.H. "Sensitivity analysis of neural networks in spool fabrication productivity studies", *J. Comp. in Civil Engineerings*, **15**(4), pp 299-308 (2001).
26. Knowels, P., *Predicting Labor Productivity Using Neural Networks*, MSc thesis, University of Alberta, Edmontn, Canada (2005).

Archive of SID