

کاربرد شبکه عصبی مصنوعی در تفسیر نتایج آزمایش پرسیومتری

محمد امامی^۱ و سید شهاب الدین یثربی^{۲*}

۱- دانش آموخته دکتری مهندسی ژئوتکنیک - دانشگاه تربیت مدرس

۲- دانشیار دانشکده فنی و مهندسی - دانشگاه تربیت مدرس

yasrobis@modares.ac.ir

تاریخ پذیرش: [۱۳۹۲/۳/۲]

تاریخ دریافت: [۱۳۹۱/۲/۱۹]

چکیده- آزمایش پرسیومتری، یکی از مهم ترین آزمایش های برجای مهندسی ژئوتکنیک است. در این مقاله از سه نوع شبکه عصبی مصنوعی (ANN) به منظور تفسیر نتایج آزمایش پرسیومتری استفاده شده است. در ابتدا از شبکه عصبی چند لایه پرسپترون، در ادامه از شبکه نروفازی بهره گرفته شده و در پایان از شبکه عصبی تابع مینای شعاعی استفاده شده است. مدل ها از ساختار کلی دارای ۵ ورودی و یک خروجی تشکیل شده اند. در پایان مدل های مختلف شبکه های عصبی با یکدیگر مقایسه شده و شبکه ای که بهترین عملکرد را داشته مشخص شده است. برای ارزیابی قدرت تعمیم مدل، عملکرد شبکه مورد نظر در مقابل داده های تجربه نشده با نتایج تجربی مورد مقایسه قرار گرفت. مدل های مبتنی بر شبکه های عصبی توضیحی در مورد چگونگی اثر پارامترهای ورودی بر خروجی نمی دهند. در این پژوهش با انجام آنالیز حساسیت بر روی ساختار بهینه مدل معرفی شده سعی شده است تا حدودی به این سوال پاسخ داده شود.


واژگان کلیدی: تفسیر آزمایش پرسیومتری، شبکه عصبی مصنوعی، چند لایه پرسپترون، نروفازی، تابع مینای شعاعی، آنالیز حساسیت.

۱- مقدمه

پیش بینی از خود نشان می دهند. در سالیان اخیر استفاده از شبکه های عصبی مصنوعی در بسیاری از رشته های مهندسی افزایش یافت. به خصوص، شبکه های عصبی مصنوعی در بسیاری از مسایل ژئوتکنیکی به کار برده شدند و تاحدی موفقیت آمیز بودند. شبکه های عصبی مصنوعی به طور موفقیت آمیزی در پیش بینی ظرفیت باربری شمع ها، مدلسازی رفتار خاک، خصوصیات محل، سازه های نگهبان خاکی، نشست سازه ها، پایداری شیب ها، طراحی تونل ها و فضاهای زیرزمینی، روانگرایی، نفوذ پذیری و هدایت هیدرولیکی خاک، تراکم خاک، تورم خاک و طبقه بندی خاک ها استفاده شد. البته در زمینه آزمایش های برجای مهندسی ژئوتکنیک استفاده از شبکه عصبی توسعه چندانی نداشته است. تعداد زیادی از کاربردهای

آزمایش های برجای، نقش بسیار مهمی در مطالعات مهندسی ژئوتکنیک دارند. آزمایش پرسیومتری نیز یکی از مهم ترین آزمایش های برجای مهندسی ژئوتکنیک است که واقعی ترین تصور را نسبت به رفتار تغییرشکلی خاک ها نسبت به سایر آزمایش ها، نتیجه می دهد. از این رو تلاش زیادی در زمینه مدلسازی و پیش بینی رفتار تغییرشکلی خاک ها انجام شده است. این مدل ها بر اساس تئوری های متعدد الاستیسیته و پلاستیسیته استوار هستند با استفاده از پیش فرض ها و تعریف محدوده های شکست و تسلیم، رابطه ای بین خصوصیات تنش-تغییرشکل خاک ها ارائه می کنند. ولی باتوجه به روابط بسیار پیچیده حاکم بر رفتار خاک ها که بستگی به شرایطی که در آن قرار دارند، حتی رفتار غیر قابل

پرسیومتر را ابزار آسانی استوانه‌ای شکل معرفی می‌کنند که برای اعمال فشار یکنواخت از طریق پوسته‌ی انعطاف‌پذیر به دیواره‌ی گمانه به کار می‌رود؛ که این تعریف بعدها به وسیله‌ی انجمن بین‌المللی مکانیک خاک و مهندسی پی به عنوان تعریف بین‌المللی پرسیومتر شناخته شد [۳۲]. شکل (۱) نمونه‌ای از منحنی فشار-حجم حاصل از آزمایش پرسیومتری را نشان می‌دهد [۳۲].



شکل ۱- نمونه‌ای از نمودار حاصل از آزمایش پرسیومتری [۳۲]

دستگاه پرسیومتری استفاده شده از نوع پرسیومتری پیش حفاری شده است. این پرسیومترها فراگیرترین نوع پرسیومتر در مطالعه ژئوتکنیک است. روش انجام آزمایش پرسیومتری براساس استاندارد ASTM D ۴۷۱۹ انجام می‌شود. مهمترین قسمت آزمایش پرسیومتری آماده‌سازی گمانه است [۳۲]. مراحل تحلیل نتایج آزمایش پرسیومتری به طور کامل در مرجع [۳۲] ذکر شده است.

۳- انواع شبکه عصبی مورد استفاده

سه نوع شبکه عصبی استفاده شده است. این سه نوع عبارتند از: شبکه‌های چند لایه پرسپترون، شبکه نروفازی و شبکه تابع مبنای شعاعی.

۳-۱- شبکه عصبی پرسپترون چندلایه (MLP)

پرکاربردترین معماری شبکه‌های عصبی، شبکه‌های چند لایه پیشخور (Feed Forward) است که شبکه‌های چند لایه‌ای پرسپترون به‌طور اختصار MLP (Multi Layer Perceptron) می‌گویند.

شبکه عصبی مصنوعی در زمینه مهندسی ژئوتکنیک در مرجع [۱۴] گفته شده است. رأو و کومار (۲۰۰۶) از شبکه عصبی برای تعیین ظرفیت باربری جانبی شمعها استفاده کردند. لی و لی (۲۰۰۳) یک روش برای تخمین نمو نهایی چسبندگی ظاهری (C_{max}) خاک‌های غیراشباع با استفاده از شبکه عصبی پیشنهاد کردند. شاهین (۲۰۰۰) از شبکه‌های عصبی برای پیش‌بینی نشست‌های شالوده‌های سطحی واقع بر خاک‌های غیرچسبنده استفاده کرده است. مدلسازی رفتار تنش-کرنش خاک‌های ماسه‌ای با استفاده از شبکه‌های عصبی مصنوعی [۷]. موسوی و یزدانپناه (۲۰۰۶) طبیعت احتمالی رفتار تورمی سیکلی گلسنگ و وابستگی داخلی آن به تعداد زیادی از پارامترها را با استفاده از شبکه‌های عصبی تأخیر زمانی مدل کرده‌اند.

در بسیاری از مواقع در مهندسی ژئوتکنیک، با انواعی از مسایل بسیار پیچیده و غیرقابل فهم برخورد می‌شود. بسیاری از روش‌های ریاضیاتی برای حل این مسایل پیچیده تلاش کرده‌اند. بسیاری از روش‌های ریاضیاتی در مدلسازی رفتار پیچیده بسیاری از مسایل ژئوتکنیکی با شکست برخورد می‌کنند. در مقابل، شبکه‌های عصبی مصنوعی که فقط بر مبنای داده‌هایی که برای آموزش و آزمایش شبکه برای تعیین ساختمان و پارامترهای مدل به کار می‌روند، قرار دارد. در این مورد، هیچ نیازی به ساده‌سازی و یا انجام فرض‌های مختلف نیست. علاوه بر این، شبکه‌های عصبی مصنوعی می‌توانند همیشه با ارایه داده‌ها از مثال‌های جدیدتر برای نتایج دقیق‌تر ارتقا یابند [۱، ۲، ۳، ۴ و ۱۴].

۲- آزمایش پرسیومتری

همه‌ی آزمایش‌های لازم برای این پژوهش بر اساس استاندارد ASTM انجام شده‌اند. آزمایش‌های برجاء، نقش بسیار مهمی در مطالعات مهندسی ژئوتکنیک دارند. آزمایش پرسیومتری نیز یکی از مهم‌ترین آزمایش‌های برجای مهندسی ژئوتکنیک است که واقعی‌ترین تصور را نسبت به رفتار تغییرشکلی خاک‌ها نسبت به سایر آزمایش‌ها، نتیجه می‌دهد [۳۲]. لوئیس منارد در سال ۱۹۵۵ دستگاه پرسیومتر را طراحی کرد و این نام را برای آن برگزید. برخی

۳-۱-۱- الگوریتم یادگیری پس انتشار

یک شبکه پس انتشار از نوع MLP و شامل: یک لایه ورودی، یک لایه خروجی و یک یا چند لایه نهان متشکل از گره‌ها برای یافتن خاصیت غیرخطی در داده‌ها است. هنگامی که یک ورودی آموزشی به شبکه عرضه می‌شود خروجی هر نورون محاسبه شده و این خروجی‌ها در طول شبکه به جلو پیش می‌روند و در پایان خروجی شبکه محاسبه می‌شود، اگر اختلافی بین خروجی شبکه و خروجی مطلوب وجود داشته باشد آنگاه روند اصلاح وزنها از لایه خروجی شروع شده و به سمت لایه‌های

ورودی پیش می‌رود (عبارت پس انتشار). الگوریتم این روش به طور کامل در مرجع [۳۲] ذکر شده است. در روش پس انتشار استاندارد هر چه پارامتر سرعت یادگیری η کوچکتر در نظر گرفته شود، مقدار تغییرات وزنها کمتر است و شیب تغییرات ملایمتر، در نتیجه سیستم پایدارتر است. از طرف دیگر افزایش η موجب افزایش سرعت یادگیری شده ولی در عوض شبکه ممکن است ناپایدار شود. یک روش برای بهبود الگوریتم پس انتشار استفاده از سیستم‌های بهینه‌سازی عددی است [۳]. یکی از این روش‌ها بهینه کردن مجموع مربعات توابع غیرخطی با روش لوبنبرگ-مارکوارت یا به اختصار ML است [۵]. براساس این روش کلی که تقریبی از متد نیوتن است، الگوریتم پس انتشار ML در سال ۱۹۹۴ برای آموزش شبکه عصبی چند لایه پرسپترون پیشنهاد شد [۳].

برای توقف تکرار الگوریتم پس انتشار از شاخص زیر استفاده شده است: میانگین مربعات خطا (MSE) در هر دوره کمتر از مقدار از پیش تعیین شده‌ای باشد و یا اینکه تغییرات در پارامترهای شبکه پس از هر دوره خیلی کوچک باشد. برای بالا بردن قابلیت تعمیم شبکه از روش توقف دیگری موسوم به Cross Validation استفاده می‌شود، که این روش برای متوقف کردن آموزش در انتهای مرحله اول است [۱].

۳-۲- شبکه عصبی نروفازی

مدل شبکه نروفازی با استفاده از محیط گرافیکی نرم افزار (ANFIS) (MATLAB) استفاده شده است.

این مدل از یک سیستم فازی با استفاده از فرایند یادگیری پس انتشار خطا استفاده می‌کند. پارامترهای توابع عضویت در حین فرایند یادگیری تنظیم می‌شوند. انواع توابع عضویت در لایه ورودی و خروجی استفاده می‌شود [۶]. فرایند یادگیری در شبکه‌های عصبی رسیدن به خروجی‌های مطلوب از ورودی‌های آرایه شده به شبکه عصبی است. این عمل با تنظیم وزن‌های در قانون یادگیری و بهینه‌سازی خطای خروجی انجام می‌شود. مجموع مربعات خطا به عنوان یک شاخص ارزیابی در فرایند یادگیری در نظر گرفته می‌شود.


۳-۳- شبکه عصبی تابع مبنای شعاعی

مفهوم تابع پایه شعاعی از آنجا ناشی می‌شود که این توابع دارای تقارن محوری است. یعنی هر واحد خروجی خود را متناظر با ورودی مورد نظر و با یک فاصله شعاعی معین تولید می‌کند [۶]. این به آن معنی است که یک تابع پایه شعاعی برای تمام x هایی که در یک دایره به مرکز C_i قرار دارند، خروجی یکسان تولید می‌کند [۶].

الگوریتم یادگیری در این شبکه‌ها دارای سه مرحله است: مرحله ورودی، مرحله میانی یا تولید مراکز توابع گوسی و مرحله خروجی. الگوریتم‌های یادگیری مختلفی برای شبکه RBF وجود دارد. یک راه ساده یادگیری ترکیبی را به کار می‌برد، که تخمین درباره موقعیت و عرض هسته را با استفاده از الگوریتم خوشه‌بندی بدون نظارت انجام می‌دهد؛ سپس با استفاده از مجذور متوسط کمترین (LMS) با نظارت برای تعیین وزن‌های اتصال بین لایه‌های نهان و لایه‌های خروجی انجام می‌دهد.

۴- بانک اطلاعاتی

در این پژوهش از نتایج ۴۰۰ آزمایش پرسیمتری انجام شده به وسیله شرکت عمران پژوهش راهوار (۱۳۸۵ تا ۱۳۸۶) استفاده شده است. به دلیل عدم دقت کافی و همچنین تغییر زیاد در محدوده ضریب پرسیمتری این تعداد آزمایش پس از حذف به ۴۰۰ عدد تقلیل یافت. آزمایش‌های روی



شکل ۲- تعدادی از نمودارهای آزمایش‌های پرسیومتری

۵- پیاده‌سازی مدل‌های شبکه عصبی

در این بخش به پیاده‌سازی مدل‌های شبکه عصبی استفاده شده پرداخته می‌شود:

۵-۱- پارامترهای ورودی-خروجی

۵-۱- پارامترهای ورودی

باتوجه به عوامل تأثیرگذار بر آزمایش پرسیومتری و همچنین داده‌های موجود از آزمایش‌های آزمایشگاهی و صحرایی انجام شده در گمانه‌هایی که آزمایش پرسیومتری انجام شده بود، پارامترهای ورودی انتخاب شدند. البته این نکته که پارامترهایی ورودی از آزمایش‌های معمول مهندسی ژئوتکنیک به دست آیند نیز در انتخاب پارامترهای ورودی نقش زیادی 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 و آزمایش صحرایی عدد نفوذ استاندارد و همچنین عمق آزمایش و فشار وارده حاصل می‌شوند. پارامترهای مورد نظر عبارتند از:

- پارامترهای فیزیکی: پارامترهای فیزیکی به عنوان شاخص‌های اولیه می‌توانند دید کلی نسبت به وضعیت لایه‌های زیرسطحی ارایه نمایند. مهم‌ترین این پارامترها، وزن مخصوص طبیعی (γ_m)، درصد رطوبت (w) است. پارامتر فیزیکی دیگری که به عنوان نشان‌دهنده وضعیت دانه‌بندی خاک‌ها استفاده

خاک‌های مناطق شمال غرب ایران (تبریز)، جنوب ایران (جزیره خارگ) و شمال شرق ایران (مشهد) انجام شد. دستگاه پرسیومتری استفاده شده از نوع پرسیومتر پیش حفاری شده منارد است. آزمایش‌های انجام شده از دقت قابل قبولی برخوردار بوده و مطابق با استاندارد ASTM- D4719 انجام شده‌اند. حفاری گمانه‌ها به روش دورانی با مغزه‌گیری ممتد انجام شده است. در همه گمانه‌های استفاده شده برای آزمایش پرسیومتری به منظور بررسی وضعیت لایه‌ها و مقاومت زمین، آزمایش‌های ضربه و نفوذ استاندارد (SPT) انجام شده است. نمونه‌ای از خصوصیات فیزیکی و تراکمی خاک‌های آزمایش شده در جدول (۱) ارایه شده است. تعدادی از نمودارهای فشار- تغییر حجم آزمایش‌های پرسیومتری در شکل (۲) ارایه شده است.

جدول ۱- تعدادی از خصوصیات فیزیکی و تراکمی خاک‌های مطالعه شده

NSPT	Dmax	$m\gamma$ (gr/cm^3)	w(%)	Depth (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

به عنوان تنها پارامتر خروجی در نظر گرفته شد. این پارامتر به عنوان مهم‌ترین خروجی آزمایش پرسپترون به شمار می‌آید. حدود تغییرات پارامترهای ورودی و خروجی در جدول (۲) ارائه شده است.

۵-۳- ساختار مدل‌های شبکه عصبی

در این بخش معماری شبکه‌های عصبی استفاده شده توضیح داده می‌شود. باتوجه به استفاده از سه نوع شبکه عصبی چندلایه پرسپترون، نروفازی و تابع مبنای شعاعی برای تفسیر نتایج آزمایش پرسپترون، ابتدا مدل شبکه چندلایه پرسپترون توضیح داده می‌شود و به ترتیب شبکه نروفازی و شبکه تابع مبنای شعاعی ارائه می‌شود. جزییات تمامی مدل‌های مورد استفاده در جدول (۳) ارائه شده است.

شده است، اندازه بیشینه دانه‌ها (D_{max}) است. پارامتر تراکمی: آزمایش نفوذ استاندارد (SPT) از رایج‌ترین آزمایش‌های درجا برای تعیین خصوصیات فیزیکی و مکانیکی لایه‌های خاک است. باتوجه به این نکته که این آزمایش در بیشتر گمانه‌های مطالعات ژئوتکنیک انجام می‌شود، در دسترس‌ترین داده حاصل از آزمایشات برجا است. پارامترهای حاصل از چگونگی انجام آزمایش: باتوجه به اثر قابل ملاحظه عمق انجام آزمایش بر نتایج حاصل از آزمایش پرسپترون، این پارامتر به عنوان ورودی در نظر گرفته شد. در شبکه‌های ۶ ورودی از گام‌های فشار وارده نیز به عنوان ورودی مدل استفاده شده است.

۵-۲- پارامترهای خروجی

مقدار ضریب پرسپترون (E_p) در مرحله تفسیر

جدول ۲- حدود تغییرات پارامترهای ورودی و خروجی

Limits	Inputs					Output
	N_{SPT}	γ_m (gr/cm ^۳)	(%) W	H (cm)	D_{max}	E_m (kg/cm ^۲)
Min.	۱۰	۱,۵۳	۱۰	۳۰۰	۰,۰۲۵	۱۰۰
Max.	۵۰	۱,۸۸	۲۶	۳۰۰۰	۳,۸۱	۴۰۰

جدول ۳- جزییات ساختاری مدل‌های شبکه عصبی مورد استفاده

Networks	Inputs	Output
MLP	N_{SPT} , γ_m (gr/cm ^۳), W (%), D_{max} , H (cm)	E_m (kg/cm ^۲)
ANFIS	N_{SPT} , γ_m (gr/cm ^۳), W (%), D_{max} , H (cm)	E_m (kg/cm ^۲)
RBF	N_{SPT} , γ_m (gr/cm ^۳), W (%), D_{max} , H (cm)	E_m (kg/cm ^۲)

– انحراف استاندارد قدرمطلق خطا (SDAE): این شاخص نشاندهنده درجه پراکندگی قدرمطلق خطا حول MAE است.

۵-۵- پردازش داده‌های شبکه عصبی

داده‌های مورد نیاز برای آموزش شبکه از آزمایش‌های آزمایشگاهی و صحرایی به دست آمده‌اند. در این پژوهشی از آزمایش‌های پرسیومتری با مدول پرسیومتری بین ۱۰۰ تا ۴۰۰ کیلوگرم بر سانتی متر مربع استفاده شده است. با توجه به حفاری گمانه‌هایی که آزمایش پرسیومتری در آنها انجام می‌شود، داده‌های ورودی از نزدیکترین عمق مورد نظر در صورت عدم وجود داده در همان عمق انتخاب شده‌اند. تعداد داده‌های مورد استفاده در مرحله پیش‌بینی با توجه به نمودارهای به دست آمده از آزمایش پرسیومتری برابر ۴۰۰ داده در نظر گرفته شد. نمونه‌ای از ورودی‌ها و خروجی‌های ارایه شده به شبکه عصبی در جدول (۴) ارایه شده است.

جدول ۴- نمونه‌ای از پردازش داده‌ها قبل از ارایه به شبکه عصبی

Inputs					Output
N_{SPT}	γ_m (gr/ cm ³)	W (%)	H (cm)	D_{max}	E_m (kg/ cm ²)
۱۲	۱,۸۲	۱۸	۶۷۵	۰,۹۵	۱۱۰
۴۰	۱,۸۶	۱۷	۱۵۲۵	۰,۴۷۵	۱۳۵
۲۸	۱,۸	۱۸,۱	۶۷۵	۱,۹	۱۲۵
۴۳	۱,۸۱	۱۶,۴	۱۵۰۰	۰,۲	۲۲۵
۲۳	۱,۷۳	۲۱,۲	۶۷۵	۰,۲	۱۵۰
۴۳	۱,۸۵	۱۹	۱۵۲۵	۰,۹۵	۲۷۵
۳۹	۱,۸۴	۱۷,۸	۶۷۵	۰,۰۸۵	۱۴۵
۵۰	۱,۸۳	۱۶,۶	۱۷۷۵	۰,۰۴۲۵	۲۸۰
۲۵	۱,۷۳	۱۸,۹	۶۷۵	۰,۰۴۲۵	۱۷۵
۵۰	۱,۸۳	۱۴,۳	۱۴۷۵	۲,۴۵	۳۱۰
۳۳	۱,۷۴	۱۷,۵	۸۷۵	۱,۹	۱۱۵
۵۰	۱,۸	۱۷	۱۴۷۵	۰,۹۵	۲۳۵
۳۳	۱,۸۱	۱۵,۶	۸۷۵	۲,۴۵	۱۸۵
۱۸	۱,۷۱	۱۸,۶	۷۷۵	۰,۴۷۵	۱۱۵
۳۵	۱,۶۹	۱۷,۶	۷۷۵	۰,۴۷۵	۱۴۰

۵-۴- شاخص‌های ارزیابی مدل‌های شبکه عصبی

برای ارزیابی کارایی مدل‌های شبکه عصبی مورد استفاده نیاز به شاخص‌های است که بتوان کارکرد مدل‌ها را در مقایسه با مجموعه داده‌ها و همچنین نتایج تجربی مورد قضاوت قرار داد. از اینرو از شاخص‌های زیر برای ارزیابی مدل‌ها و در نهایت مقایسه کارایی آنها نسبت به یکدیگر استفاده شده است:

– ضریب همبستگی (R): درجه ارتباط بین دو متغیر بوسیله این پارامتر نشان داده می‌شود. ضریب همبستگی بین دو متغیر x و y به صورت زیر تعریف می‌شود [۱۲]:

$$R = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} \quad (1)$$

– میانگین قدرمطلق خطا (MAE): نشان‌دهنده مقدار متوسط خطا در مجموعه مورد نظر است. این شاخص با رابطه زیر بیان می‌شود.

$$MAE = \frac{1}{N} \sum_{i=1}^N |E_i| \quad (2)$$

– جذر متوسط مربعات خطا (RMSE): این شاخص نیز بیانگر متوسط مقدار خطا، تفاوت مقدار به دست آمده از آزمایش‌ها و مدل‌ها است [۶]. رابطه (۳) نشان‌دهنده این شاخص است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_i)^2} \quad (3)$$

– بیشینه مقدار قدرمطلق خطا (MAXAE): این شاخص نشان‌دهنده بیشینه خطایی که در مجموعه مورد نظر اتفاق می‌افتد. رابطه این شاخص در ادامه آورده شده است.

$$MAXAE = \max(|E_i|) \quad (4)$$

– مجموع مربعات خطا این شاخص نشان‌دهنده مجموع مربعات خطای مجموعه مورد نظر است. رابطه این شاخص عبارتست از:

$$SSE = \sum_{i=1}^N (E_i)^2 \quad (5)$$


۵-۶- پیاده‌سازی شبکه‌های عصبی

برای پیاده‌سازی شبکه‌های عصبی استفاده شده، آموزش و ارزیابی آنها از جعبه ابزار شبکه عصبی MATLAB ۷,۶ (۲۰۰۸a) استفاده شده است. این نرم‌افزار با توجه به توابع متعدد، قابلیت برنامه‌نویسی، الگوریتم‌های آموزشی و ساختارهای متعدد برای شبکه‌های عصبی و قدرت پردازش و تحلیل‌های آماری در حل مسایل مهندسی بسیار مورد توجه پژوهشی بوده است.

- شبکه عصبی پرسپترون چندلایه- آموزش و توقف آموزش: همان‌گونه که گفته شد، از شبکه‌های سه و چهار لایه پرسپترون با تعداد ورودی متفاوت برای تفسیر نتایج آزمایش پرسپوتری استفاده شده است. با توجه به مزیت‌های روش ML که شرح داده شد، این روش مورد استفاده قرار گرفته است. در این پژوهش ضرایب روش μ ، ML، و β با توجه به مقادیر پیش‌فرض MATLAB به ترتیب $0/001$ و $0/01$ در نظر گرفته شده است [۷]. همچنین برای بالا بردن قدرت تعمیم شبکه از روش Cross-Validation برای توقف آموزش استفاده شده است. در همین راستا بانک اطلاعاتی به سه مجموعه آموزشی، ارزیابی و آزمایشی تقسیم شده است. تمام شاخصهای ارزیابی جهت ارزیابی کارایی و دقت شبکه‌های چندلایه پرسپترون استفاده شده است. تعداد ۲۵۰ داده برای آموزش، ۷۰ داده برای مجموعه ارزیابی و تعداد ۸۰ داده برای مجموعه آزمایشی استفاده شده است. در شکل (۳) منحنی آموزشی برای شبکه‌های MLP۱ با یک لایه پنهان نشان داده شده است.

به عنوان توابع فعالیت در لایه‌های پنهان از تابع تانژانت هیپربولیک و برای لایه خروجی از تابع خطی استفاده شده است. پس از انتخاب تعداد نرون‌های بهینه با استفاده از شاخصهای خطا ساختار مناسب هر مدل انتخاب می‌شود. در مرحله بعد نیز مدلها با توجه به ساختار بهینه هر مدل با هم مقایسه می‌شوند. در قضاوت در مورد عملکرد و کارایی مدلها از دو دسته شاخص استفاده شده است: ضریب همبستگی (R) و شاخصهای مقدار خطا (SSE، SDAE، MSE، MAXAE، MAE). شبکه و مدلی دارای کارایی بهتر در مجموعه مورد نظر است که دارای ضریب

همبستگی و شاخصهای خطای مناسبتری باشد.



شکل ۳- منحنی آموزش شبکه MLP۱ با یک لایه پنهان ۱۱ نرونی

برای قضاوت درباره ضریب همبستگی، از محدوده اسمیت (۱۹۸۶) استفاده شده است. شاخصهای خطای شبکه در مقابل مجموعه ارزیابی، آموزشی و آزمایشی برای شبکه MLP۱ با یک لایه پنهان محاسبه شده است. در انتها شبکه با ۱۵ نرون در لایه پنهان با شاخصهای همبستگی و مقدار خطای بهتر در مجموعه آموزشی، ضریب همبستگی بهتر در مجموعه ارزیابی و آموزشی، MAE و RMSE بهتر در مجموعه‌های ارزیابی و آزمایشی و با وجود مقدار بیشینه خطای بیشتر در مجموعه ارزیابی در مجموع به عنوان بهترین ساختار مدل MLP۱ با یک لایه پنهان انتخاب شده است. شاخصهای خطای شبکه در مقابل مجموعه ارزیابی، آموزشی و آزمایشی برای شبکه MLP۲ با دو لایه پنهان نیز به دست آمده‌اند. در این میان شبکه با ۱۱ نرون در هر دو لایه 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 بهینه مدل MLP۱ و MLP۲ با تعداد لایه‌ها و نرون‌های پنهان مختلف در جدول (۵) ارائه شده‌اند. مشاهده می‌شود که مدل MLP۱ با یک لایه پنهان با ۱۵ نرون در لایه‌های پنهان بهترین عملکرد را در شبکه‌های مدل MLP از خود نشان می‌دهد. همچنین این ساختار بالاترین ضریب همبستگی و پایین‌ترین شاخصهای خطا را داراست.

جدول ۵- مقایسه بین ساختارهای بهینه شبکه‌های MLP

Validation Subset								
Networks	Num. of neurons		R	RMSE	MAE	MAXAE	SDAE	SSE
MLP۱	۱۱		۰٫۸۷	۰٫۰۸۳	۰٫۰۵۱	۰٫۳۵	۰٫۰۵۸	۰٫۸۲
	۱۵		۰٫۹۶	۰٫۰۶۰	۰٫۰۴۲	۰٫۲۶	۰٫۰۳۷	۰٫۴۳
MLP۲	۱۱	۱۱	۰٫۹۴	۰٫۰۶۲	۰٫۰۵۲	۰٫۱۸	۰٫۰۵۱	۰٫۴۵
	۱۵	۱۵	۰٫۹۱	۰٫۰۷۵	۰٫۰۶۱	۰٫۱۹	۰٫۰۶۷	۰٫۶۸
Training Subset								
MLP۱	۱۱		۰٫۹۵	۰٫۰۷۴	۰٫۰۵۳	۰٫۲۶	۰٫۰۴۵	۳٫۱
	۱۵		۰٫۹۶	۰٫۰۷۳	۰٫۰۵۱	۰٫۱۶	۰٫۰۴۱	۲٫۰
MLP۲	۱۱	۱۱	۰٫۹۶	۰٫۰۶۸	۰٫۰۵۲	۰٫۲۱	۰٫۰۴۳	۲٫۴
	۱۵	۱۵	۰٫۹۵	۰٫۰۷۶	۰٫۰۵۹	۰٫۲۵	۰٫۰۵۳	۳٫۲
Testing Subset								
MLP۱	۱۱		۰٫۹۴	۰٫۰۶۹	۰٫۰۵۵	۰٫۱۸	۰٫۰۴۶	۰٫۶۶
	۱۵		۰٫۹۵	۰٫۰۶۴	۰٫۰۵۳	۰٫۱۶	۰٫۰۴۴	۰٫۵۶
MLP۲	۱۱	۱۱	۰٫۹۶	۰٫۰۶۸	۰٫۰۵۱	۰٫۱۹	۰٫۰۵۲	۰٫۵۵
	۱۵	۱۵	۰٫۹۴	۰٫۰۷۶	۰٫۰۶۲	۰٫۲۰	۰٫۰۶۴	۰٫۶۹

مقابل مجموعه‌های آموزشی و آزمایشی برای شبکه NFI بررسی شده است. به این ترتیب دو شبکه با تعداد ۲ و ۳ تابع عضویت ورودی و خروجی عملکرد بهتری دارند. این دو شبکه در مقابل مجموعه آموزشی و آزمایشی مورد ارزیابی شده و در پایان شبکه با ۳ تابع عضویت با MAE و RMSE بهتر در مجموعه‌های آموزشی و آزمایشی و با وجود مقدار بیشینه خطای کمتر در مجموعه ارزیابی در مجموع نسبت به شبکه دیگر به عنوان بهترین ساختار مدل NFI انتخاب شده است.

شبکه تابع مبنای شعاعی: در این شبکه‌ها هر واحد در لایه پنهان یک تابع پایه شعاعی مانند یک هسته گاوسی را به عنوان تابع فعال‌سازی به کار می‌برد در حالی که واحدهای خروجی تابع همانی را به عنوان تابع فعال‌سازی به کار می‌برند در پیاده‌سازی شبکه تابع مبنای شعاعی از جعبه ابزار MATLAB بهره گرفته

شبکه نروفازی: مدل شبکه نروفازی با استفاده از محیط گرافیکی نرم‌افزار (ANFIS) (MATLAB) استفاده شده است. انواع توابع عضویت در لایه ورودی و خروجی استفاده شده است. بهترین کاربرد در استفاده از تابع عضویت مثلثی با رابطه (۶) در لایه ورودی مشاهده شده است [۹].

(۶)

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


بانک اطلاعاتی استفاده شده به دو دسته داده آموزشی و آزمایشی تقسیم شده‌اند. تعداد ۳۰۰ داده در مرحله آموزش و تعداد ۱۰۰ داده برای آزمایش در نظر گرفته شده‌اند. شاخص‌های ارزیابی در این مدل مانند مدل چندلایه پرسپترون است. پس از پایان آموزش مقادیر وزن‌ها ذخیره شده و این شبکه آماده است. شاخص‌های خطای شبکه در

شاخص‌های خطای شبکه در مقابل مجموعه‌های آموزشی و آزمایشی برای شبکه RBF محاسبه شده است. مدل شبکه RBF با تعداد بیشینه نرون‌های پیش‌فرض بهترین عملکرد را دارد.

۵-۷- مقایسه کارایی مدل‌های شبکه عصبی

در این بخش به مقایسه عملکرد ساختارهای بهینه سه مدل شبکه عصبی استفاده شده پرداخته است. در جدول (۶) شاخص‌های خطا برای سه مدل مربوطه برای مجموعه‌های آموزشی، آزمایشی و ارزیابی نشان داده شده است. همان‌گونه که مشاهده می‌شود شبکه MLP_۱ با یک لایه پنهان ۱۵ نرونی بهترین عملکرد را نسبت به سه مدل دیگر از خود نشان می‌دهد. البته در مجموعه آموزشی شبکه RBF از بهترین عمل کرد برخوردار است. ولی در سایر شاخص‌های خطا شبکه MLP_۱ مقادیر پایین‌تری را به خود اختصاص داده است. بنابراین این شبکه به عنوان موفق‌ترین مدل در مرحله تفسیر نتایج حاصل از آزمایش پرسیمتری انتخاب می‌شود.

شده است. بانک اطلاعاتی استفاده شده به دو دسته داده آموزشی و آزمایشی تقسیم شده‌اند. تعداد ۳۰۰ داده در مرحله آموزش و تعداد ۱۰۰ داده برای آزمایش در نظر گرفته شده‌اند. در شکل (۴) منحنی آموزشی برای شبکه RBF نشان داده شده است.



شکل ۴- منحنی آموزش شبکه RBF

جدول ۶- مقایسه ساختارهای بهینه مدل‌ها براساس شاخص‌های خطا


Validation Subset								
Networks	Num. of neurons or MFs		R	RMSE	MAE	MAXAE	SDAE	SSE
MLP-I ₁	۱۵		۰,۹۶	۰,۰۶۰	۰,۰۴۲	۰,۲۶	۰,۰۳۷	۰,۴۳
MLP-I _۲	۱۱	۱۱	۰,۹۴	۰,۰۶۲	۰,۰۵۲	۰,۱۸	۰,۰۵۱	۰,۴۵
Training Subset								
MLP-I ₁	۱۵		۰,۹۶	۰,۰۷۳	۰,۰۵۱	۰,۱۶	۰,۰۴۱	۲,۰
MLP-I _۲	۱۱	۱۱	۰,۹۶	۰,۰۶۸	۰,۰۵۲	۰,۲۱	۰,۰۴۳	۲,۴
NFI	۳		۰,۹۶	۰,۰۶۱	۰,۰۵۰	۰,۱۸	۰,۰۵۰	۲,۲
RBF	۴۰۰		۰,۹۸	۰,۰۳۵	۰,۰۲۲	۰,۱۹	۰,۰۲۵	۰,۸۲
Testing Subset								
MLP-I ₁	۱۵		۰,۹۵	۰,۰۶۴	۰,۰۵۳	۰,۱۶	۰,۰۴۴	۰,۵۶
MLP-I _۲	۱۱	۱۱	۰,۹۶	۰,۰۶۸	۰,۰۵۱	۰,۱۹	۰,۰۵۲	۰,۵۵
NFI	۳		۰,۹۲	۰,۰۸۸	۰,۰۶۸	۰,۲۹	۰,۰۶۳	۱,۵
RBF	۴۰۰		۰,۸۷	۰,۱۰	۰,۰۸۵	۰,۳۸	۰,۰۷۲	۳,۳

این شبکه‌ها هیچگونه توضیحی در مورد چگونگی اثر پارامترهای ورودی بر خروجی و به عبارتی دانش حاکم بر محیط ارایه نمی‌دهند. لو و همکاران با بررسی این روش‌ها به این نتیجه رسیدند که اثر هر پارامتر ورودی بر روی متغیرهای خروجی از نظر مقدار و جهت با این روش در کل فضای ورودی قابل تعیین نیست [۳۰].

۶-۱- حساسیت خروجی نسبت به ورودی در

مدل رفتاری مبتنی بر شبکه MLP

در این بخش رابطه مشتق نسبی خروجی‌ها نسبت به ورودی‌های مستقل ارایه شده است. لو و همکاران (۲۰۰۱) مشتق نسبی خروجی یک شبکه را نسبت به ورودی‌های آن که مستقل از خروجی بودند، محاسبه کردند [۳۰]. با این وجود با توجه به اینکه در مدل‌های رفتاری مبتنی بر شبکه‌های عصبی کمینه یکی از ورودی‌های شبکه، در واقع خروجی مدل در لحظه‌های قبل است این رابطه قابل استفاده نیست و باید اصلاح شود. شکل (۶) به طور شماتیک نرون‌های لایه‌های ورودی، پنهان و خروجی و اتصال بین آنها را در یک شبکه MLP که به عنوان مدل رفتاری خاک‌ها استفاده می‌شود را نشان می‌دهد.

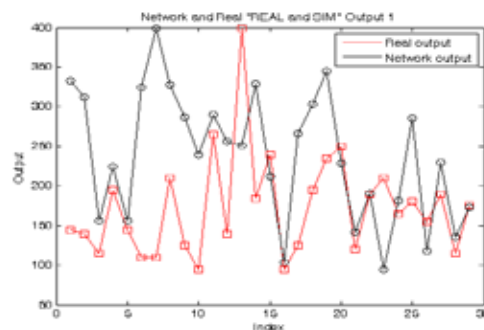


شکل ۶- شمایی از شبکه MLP مورد استفاده

زمانی که بین ورودی و خروجی‌ها مدلی برقرار شد، می‌توان آنالیز نامعینی و حساسیت را بر روی آن انجام داد. یک راه انجام آن، استفاده از تحلیل مونت کارلو است که در آن به توابع توزیع پارامترهای ورودی و

۵-۸- بررسی قدرت تعمیم مدل‌های شبکه عصبی

به منظور ارزیابی قدرت تعمیم شبکه، از نتایج شبکه در برابر داده‌های تجربه نشده استفاده شده است. آزمایش‌های پرسیومتر انجام شده در مرحله دوم مطالعات ژئوتکنیک خط ۲ قطار شهری تبریز برای این منظور به کار رفته است. با توجه به دسترس بودن تعداد ۳۰ آزمایش پرسیومتری، نتایج حاصل از شبیه‌سازی بهترین مدل شبکه عصبی با نتایج تجربی مقایسه شده است. مطابق بند قبلی مدل شبکه MLP با ۱۵ نرون در لایه پنهان به عنوان مناسب‌ترین مدل انتخاب شده است. نمودار حاصل از این مقایسه در شکل (۵) نشان داده شده است. همان‌گونه که مشاهده می‌شود، شبکه عملکرد قابل قبولی در شبیه‌سازی در برابر داده‌های تجربه نشده از خود نشان داده است. پیش‌بینی مدول پرسیومتری (EP) به عنوان مهم‌ترین خروجی آزمایش پرسیومتری در این شبکه عصبی با خطای قابل قبولی انجام شده است. بنابراین مدل شبکه عصبی موفقیت قابل قبولی در تفسیر آزمایش پرسیومتری دارا است.



شکل ۵- نتایج حاصل از مقایسه شبیه‌سازی شبکه با نتایج تجربی

۶- آنالیز حساسیت

در این بخش، ساختار نهایی مدل‌ها متشکل از شبکه عصبی پیشخور دارای یک لایه پنهان با ۱۵ نرون و یک لایه خروجی با یک نرون مورد ارزیابی قرار گرفته است. در این راستا آنالیز نامعینی و تحلیل حساسیت بر روی مدل شبکه عصبی مورد نظر صورت گرفته تا کارایی و اهمیت پارامترها بررسی شود.

خروجی‌های شبکه توجه می‌شود.

$$\frac{\partial o_1}{\partial x_i} = \frac{\partial o_1}{\partial h_j^1} \frac{\partial h_j^1}{\partial net_j^1} \frac{\partial net_j^1}{\partial x_i} \quad (9)$$

$$\frac{\partial o_1}{\partial h_j^1} = w_{j1}^1 \quad (10)$$

$$\frac{\partial h_j^1}{\partial net_j^1} = \frac{\partial \tan \text{sig}(net_j^1)}{\partial net_j^1} = 1 - (h_j^1)^2 \quad (11)$$

$$\frac{\partial net_j^1}{\partial x_i} = w_{j1}^0 \quad (12)$$

۶-۳- روش به کار رفته

در این مطالعه آنالیز حساسیت بر روی پنج ورودی شامل وزن مخصوص طبیعی، درصد رطوبت، عمق انجام آزمایش، عدد آزمایش نفوذ استاندارد و اندازه بیشینه دانه-ها انجام شده است. در این آنالیز تعداد ۲۰۰ نقطه داده در فضای پنج بعدی پارامترهای ورودی متناظر با تابع توزیع نرمال به وسیله نرم افزار Simlab ۳،۰ انتخاب شده است.

در هر کدام از این نقاط که دارای مقادیر ورودی مربوط به خودش است، مقادیر مشتق نسبی ضریب پرسیمتری برای ساختار بهینه محاسبه شده است. خصوصیات آماری این مقادیر در جدول (۷) ارائه شده است.

جدول ۷- خصوصیات آماری حساسیت مطلق خروجی نسبت به ورودی‌ها

Input	Max.	Min.	Mean.	Standard Deviation
γ	۰,۵۵۵	۰,۴۸۲-	۰,۵۰۲	۰,۲۵۷
W	۰,۱۶۶	۱,۲۹۴-	۰,۳۶۰-	۰,۳۳۷
H	۰,۴۵۲	۰,۲۴۶	۰,۳۸۴	۰,۰۵۷
N_{SPT}	۱,۷۹۵	۱,۱۰۴	۱,۵۸۵	۰,۱۶۰
D_{max}	۰,۲۵۶	۰,۴۱۶-	۰,۰۳۴-	۰,۲۰۰

به عنوان پارامترهای دیگر، مقدار میانگین

۶-۲- مشتق خروجی شبکه عصبی پرسپترون چندلایه نسبت به ورودی

پیش از ارائه روابط مورد نیاز برای محاسبه مشتق نسبی خروجی نسبت به ورودی‌ها، ابتدا علائم به کار رفته در روابط ارائه می‌شوند:

O_k : خروجی k امین نورون در لایه خروجی.
 X_i : i امین ورودی به شبکه.

w_{jk}^l : وزن اتصالات بین i امین نورون در لایه j ام و k امین نورون در لایه $j+1$ ام.

b_i^j : بایاس i امین نورون در لایه j ام.

net_i^j : جمع وزنی ورودی به i امین نورون در لایه j ام.

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

بدیهی است با توجه به علائم فوق، $h_i^j = f(net_i^j)$

که در آن $f()$ تابع فعالیت نورون لایه j ام است. اگر تعداد لایه پنهان شبکه و تعداد نورون در لایه خروجی برابر یک در نظر گرفته شوند و همچنین تعداد نورون در لایه پنهان m و تعداد ورودی n باشد، رابطه مشتق خروجی نسبت به ورودی x_i را می‌توان با استفاده از روابط زیر به دست آورد.

خروجی لایه دوم یعنی لایه خروجی با یک نورون و با تابع انتقال خطی به صورت زیر نمایش داده می‌شود:

$$O_1 = f(net_1^2) = net_1^2 = b_1^2 + \sum_{j=1}^m w_{j1}^1 h_j^1 \quad (7)$$

$$= b_1^2 + \sum_{j=1}^m w_{j1}^1 f(net_j^1) = b_1^2 + \sum_{j=1}^m w_{j1}^1 (b_j^1 + \sum_{i=1}^n w_{ji}^0 x_i)$$

از آنجا که تابع انتقال نورون‌های لایه پنهان، تانژانت هیپربولیک، tansig است () در نتیجه رابطه (۷) به صورت زیر نوشته خواهد شد:

$$(8)$$

$$O_1 = b_1^2 + \sum_{j=1}^m \{w_{j1}^1 \cdot \tan \text{sig}(b_j^1 + \sum_{i=1}^n w_{ji}^0 x_i)\}$$

حال می‌توان با استفاده از رابطه زنجیره‌ای، مشتق تنها خروجی شبکه، O_1 را نسبت به هر کدام از ورودی‌ها، x_i به دست آورد.

که احتمال اینکه مقدار حساسیت نسبی مثبت باشد، بالای ۹۰٪ است یا به عبارتی احتمال اینکه خروجی با افزایش ورودی مورد نظر اضافه شود بالای ۹۰٪ است.

D۹۰: نشان‌دهنده مقداری برای حساسیت نسبی است که ۹۰٪ مقادیر از آن کمتر و ۱۰٪ مقادیر از آن بیشتر هستند. بنابراین اگر منفی شود نشان می‌دهد که به احتمال بالای ۹۰٪، خروجی با افزایش ورودی مورد نظر کاهش می‌یابد.

توضیحات D۲۵ و D۷۵ مانند D۱۰ و D۹۰ است.

D۵۰: اگر این مقدار بر روی خط پایه (حساسیت صفر) باشد نشان می‌دهد که احتمال اینکه با افزایش ورودی، خروجی افزایش یا کاهش پیدا کند ۵۰٪ است.

همان‌گونه که پیش‌تر توضیح داده شد، برای مقایسه درجه اثر متغیرهای ورودی به جای استفاده از مقادیر حساسیت مطلق بهتر است از حساسیت نسبی استفاده شود. در جدول (۸) مقادیر میانگین حساسیت‌های نسبی ضریب پرسیومتری نسبت به ورودیهای مورد بحث ارائه شده است.

جدول ۸: مقادیر میانگین حساسیت نسبی خروجی نسبت به ورودی‌ها

Output	Ep				
	γ	W	H	NSPT	Dmax
Relative Mean	۰,۰۹۵۷	-۰,۳۹۹	۰,۳۴۶	۰,۳۴۱	-۰,۰۲۵

۶-۴- تحلیل نتایج و آنالیز حساسیت

در این بخش مقادیر درصدهای آماری مربوط به حساسیت‌های نسبی مقادیر ضریب پرسیومتری در مقابل هر پنج ورودی برای شبکه MLPI با ۱۵ نورون در لایه پنهان در شکل (۷) ارائه شده است. همان‌گونه که در این شکل مشخص است حدود ۷۵٪ مقادیر حساسیت نسبی برای وزن مخصوص طبیعی (γ_m) مثبت است. این امر نشان‌دهنده افزایش مقادیر ضریب پرسیومتری در اثر افزایش مقادیر وزن مخصوص طبیعی (γ_m) است.

حساسیت‌ها نیز می‌تواند به عنوان برآیند اثر ورودی بر خروجی مد نظر قرار گیرد. در واقع تغییرات در مقادیر خروجی در اثر 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 مقایسه میانگین نیز به مانند 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 گمراه کننده باشد. به عنوان مثال برای یک متغیر ورودی در ۵۰٪ نقاط فضای ورودی مقادیر حساسیت مقادیر بزرگ مثبت و در ۵۰٪ بقیه مقادیر بزرگ منفی است، مقدار میانگین حساسیت تقریباً صفر شده و از این نتیجه گرفته می‌شود که این متغیر بر روی خروجی تأثیر چندانی ندارد. در حالی که ممکن است در بخشی از فضای ورودی متغیر تأثیر افزایشی زیاد و در بخشی دیگر تأثیر کاهش‌ی زیادی داشته باشد. بنابراین نمی‌توان به مقدار میانگین به عنوان شاخص اولیه نشان‌دهنده حساسیت خروجی نسبت به ورودی تکیه کرد. با توجه به مطالب گفته شده و متغیر بودن مقادیر حساسیت، برای تحلیل حساسیت نیاز به روشی است که پراکندگی و احتمال مقادیر مختلف حساسیت خروجی نسبت به یک ورودی را در فضای ورودی به طور هم‌زمان نشان دهد. با این هدف از روش آماری مقادیر حساسیت نسبی که به وسیله لو و همکاران (۲۰۰۱) به کار گرفته شد [۳۰] استفاده شده است. در این روش پنج درصد آماری (D۱۰، D۲۵، D۵۰، D۷۵ و D۹۰) مقادیر حساسیت نسبی خروجی‌ها نسبت به ورودی مورد نظر محاسبه می‌شود. به وسیله این روش می‌توان اثر افزایش و یا کاهش هر ورودی را به خروجی و روند کلی حاکم را در کل فضای ورودی براساس نمونه‌های تصادفی گرفته شده تعیین کرد. توضیح و تعریف نتایج بدست آمده از این روش به شرح ذیل است [۱]:

D۱۰: نشان‌دهنده مقداری برای حساسیت نسبی است که ۹۰٪ مقادیر از آن بیشتر و ۱۰٪ مقادیر از آن کمتر است. بنابراین اگر مثبت شود نشان می‌دهد

۷- نتایج

در این مقاله سه نوع شبکه عصبی متفاوت چندلایه پرسپترون، نروفازی و تابع مبنای شعاعی استفاده شده است. از ۵ پارامتر ورودی برای مدل‌های استفاده شده انتخاب شده است. خروجی مدل ضریب پرسپومتري است. در شبکه‌های چند لایه پرسپترون از یک و دو لایه پنهان با تعداد نرون‌های متفاوت استفاده شده و مناسب‌ترین مدل شبکه عصبی انتخاب شده است. شبکه‌های نروفازی با تابع‌های عضویت متفاوت استفاده شده و موفق‌ترین مدل ارائه شده است. در انتها عمل‌کرد ساختارهای بهینه هر نوع شبکه عصبی در مقابل شاخص‌های خطا با یکدیگر مقایسه شده و موفق‌ترین مدل شبکه عصبی در مجموع برای پیش‌بینی ضریب پرسپومتري مشخص شده است. با مقایسه عمل‌کرد مدل‌های مختلف، شبکه چندلایه پرسپترون به عنوان موفق‌ترین شبکه معرفی شد. سرانجام به منظور ارزیابی قدرت تعمیم شبکه، از نتایج شبکه در برابر داده‌های تجربه نشده استفاده شده است. باتوجه به اینکه شبکه‌های عصبی به خودی خود توضیحی درباره رابطه حاکم در فضای ورودی و خروجی یا به عبارتی نحوه تأثیر پارامترهای ورودی بر خروجی نمی‌دهند. ابتدا با انجام آنالیز نامعینی مقدار حساسیت مطلق خروجی‌های هر مرحله نسبت به پنج پارامتر ورودی به دست آمدند. به این وسیله تأثیر پنج پارامتر ورودی شامل وزن مخصوص طبیعی (m)، درصد رطوبت (W)، عمق انجام آزمایش (H)، عدد آزمایش نفوذ استاندارد (NSPT) و اندازه بیشینه دانه‌ها (Dmax) بر خروجی مورد نظر در هر مرحله مورد مطالعه قرار گرفت. سپس با توجه به اینکه حساسیت مطلق پارامتر مناسبی برای تحلیل اثر پارامترهای ورودی بر خروجی تشخیص داده نمی‌شود، حساسیت‌های نسبی هر خروجی نسبت به این ورودی‌ها بررسی شد. در پایان مؤثرترین پارامترهای ورودی معرفی می‌شود.

۸- تشکر و قدردانی

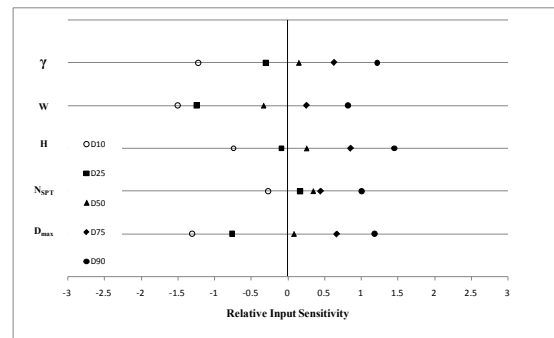
نویسندگان مقاله بر خود لازم می‌دانند از هیات داوری محترم به خاطر مطالعه و راهنمایی‌های

در مورد پارامتر ورودی دیگر یعنی درصد رطوبت (W) مشخص است که بیشتر از ۷۵٪ مقادیر حساسیت نسبی در این پارامتر منفی است که نشان‌دهنده کاهش مقدار ضریب پرسپومتري در اثر افزایش مقدار درصد رطوبت است.

۷۵٪ مقادیر حساسیت نسبی برای ضریب پرسپومتري در پارامتر ورودی عمق انجام آزمایش مثبت هستند. که این امر نشان‌دهنده افزایش مقادیر ضریب پرسپومتري در اثر افزایش مقادیر عمق انجام آزمایش است.

همچنین ۹۰٪ مقادیر حساسیت‌های نسبی ضریب پرسپومتري برای عدد آزمایش نفوذ استاندارد مثبت است. این امر نشان‌دهنده افزایش ضریب پرسپومتري در اثر افزایش عدد آزمایش نفوذ استاندارد است.

در مورد پارامتر ورودی دیگر یعنی اندازه بیشینه دانه‌ها (D_{max}) بیش از ۵۰٪ مقادیر حساسیت‌های نسبی ضریب پرسپومتري در برابر این پارامتر مثبت است.



شکل ۷- آنالیز حساسیت شبکه عصبی

در مقایسه اثر این پنج پارامتر ورودی بر روی ضریب پرسپومتري می‌توان گفت که با توجه به فاصله دسته‌های آماری از خط پایه، مقادیر درصدها (شکل ۷) و مقادیر میانگین نسبی (جدول ۸) می‌توان گفت که عمق انجام آزمایش (H) و عدد آزمایش نفوذ استاندارد (N_{SPT}) بیشترین تأثیر را دارا است. ولی باتوجه به مقادیر مثبت بالای ۹۰٪ عدد آزمایش استاندارد (N_{SPT}) در حساسیت نسبی این پارامتر به عنوان تأثیرگذارترین پارامتر ورودی بر روی ضریب پرسپومتري انتخاب می‌شود.

- [11] Gupta, M. M. (1994). «*Fuzzy Logic and Neural Networks*,» in Neuro Control, Gupta, M. M. and Rao, D. H. (eds.), IEEE Press, New York, pp. 403-416.
- [12] Hecht-Neilsen, R., Neurocomputing, Adisson Wesley Publishing Company, 1990
- [13] Demuth, H. & Beale, M., Neural Network tool-box user's guide, The math work, Inc., Natick, Mass., 1998
- [14] Mohamed A. Shahin, Mark B. Jaksa and Holger R. Maier, Department of Civil and Environmental Engineering, Adelaide University, «*ARTIFICIAL NEURAL NETWORK APPLICATIONS IN GEOTECHNICAL ENGINEERING*»
- [15] Mohamed A. Shahin, Holger R. Maier, and Mark B. Jaksa, «*Data Division for Developing Neural Networks Applied to Geotechnical Engineering*»
- [16] Basheer, I.A. and M.Hajmeer; «Artificial neural networks: fundamentals, computing, design and application»; Journal of Microbiological Methods; Vol.43; No.1;1 December 2000
- [17] S.J. Lee, S.R. Lee, Y.S. Kim, «*An approach to estimate unsaturated shear strength using artificial neural network and hyperbolic formulation*», Computers and Geotechnics 30 (2003) 489–503
- [18] M.A. Shahin, M.B. Jaksa, «*Neural network prediction of pullout capacity of marquee ground anchors*», Computers and Geotechnics 32 (2005) 153–163
- [19] Dayakar Penumadu, Rongda Zhao, «*Triaxial compression behavior of sand and gravel using artificial neural networks (ANN)*», Computers and Geotechnics 24 (1999) 207±230
- [20] Yong Lu, «*Underground blast induced ground shock and its modeling using artificial neural network*», Computers and Geotechnics 32 (2005) 164–178
- [21] Light, W. A. (1992). «*Some Aspects of Radial Basis Function Approximation*,» in Approximation Theory, Spline Functions and Applications, Singh, S.

ارزنده برای بهبود این مقاله تشکر نمایند. همچنین از مسئولین محترم شرکت پژوهش عمران راهوار که مساعدت بسیار خوبی در تهیه داده‌های مورد نیاز داشته‌اند، کمال تقدیر و تشکر را دارند.

۹- منابع

- [1] Banimahd M., 2004. Prediction of stress- strain behavior of sandy soils with neural network. Master of science thesis, Tarbiat Modares University. Tehran. Iran
- [2] Fausett, L. V. (1994). Fundamentals neural networks: Architecture, algorithms, and applications, Prentice-Hall, Inc., Englewood Cliffs, New Jersey.
- [3] Hagan, M. T. & Menhaj, M.B., Training feedforward networks with the marquardt algorithm., IEEE transactions on neural networks, Vol.5, No. 6, pp 989-992, 1994
- [4] Hagan, M. T., H. B. Demuth, and M. H. Beale, Neural Network Design, Boston, MA: PWS Publishing, 1996
- [5] Marquardt, D., an algorithm for least squares estimation of nonlinear parameters, Soc. Ind. Appl. pp 431-441
- [6] Madan M.Gupta, Liang Jin, and Noriyasu Homma, «*Static and Dynamic Neural Network*», A John Wiley & Sons, INC., Publication, Hobokon, New Jersey
- [7] M. Banimahd, S.S. Yasrobi, P.K. Woodward, «*Artificial neural network for stress–strain behavior of sandy soils: Knowledge based verification*», Computers and Geotechnics 32 (2005) 377–386
- [8] Kennedy, J. B. & Neville, A.D., Basic statistical methods for engineers and scientists, Happer International edition 1964
- [9] Smith, G.N., Probably and statistics in civil engineering, Collins, 1986
- [10] Buckley, J. J. and Hayashi, Y. (1994b). «*Fuzzy Neural Networks: A Survey*,» Fuzzy Sets Syst., Vol. 66, No. 1, pp. 1-13

- [27] Clarke, B.G. «*Pressuremeters in geotechnical design*», 1995, Blackie Academic & professional Pub. 364p.
- [28] American Society for Testing and Materials, «*Annual book of ASTM standards*», D04-08, ASTM International Pub.
- [29] Bowles, J., 1994, *Foundation analysis and design*, McGraw-Hill Book Company.
- [30] Lu, M., Abourizk, S.M. & Hermann, U.H., Sensitivity Analysis of neural networks in spool fabrication productivity studies, *J. Comp. in civil engineering*, Vol. 15, No.4, pp 299-308, 2001
- [31] Knowels, P., Predicting Labor productivity using neural networks, MSc thesis, University of Alberta, Edmonton, Canada
- [32] Emami M., 2009. Application of artificial neural networks in pressuremeter test results. Master of Science thesis, Tarbiat Modares University. Tehran. Iran.
- P. (ed.), Kluwer Academic, Boston, NATO ASI Series Vol. 256, pp. 163-190.
- [22] Sarat Kumar Das, Prabir Kumar Basu, «*Undrained lateral load capacity of piles in clay using artificial neural network*», *Computers and Geotechnics* 33 (2006) 454-459
- [23] Nabney, T. (1999). «*Efficient Training of RBF Networks for Classification*,» Proc. 9th, Vol. 1, pp. 210-215.
- [24] Adnan A. Basma and Nabil Kallas, «*Modeling soil collapse by artificial neural networks*», *Geotechnical and Geological Engineering* 22: 427-438, 2004
- [25] M. Moosavi, M.J. Yazdanpanah, R. Doostmohammadi, «*Modeling the cyclic swelling pressure of mudrock using artificial neural networks*», *Engineering Geology* 87 (2006) 178-194
- [26] D.P. Kanungo, M.K. Arora, S. Sarkar, R.P. Gupta, «*A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas*», *Engineering Geology* 85 (2006) 347-366