



دانشگاه گیلان، دانشکده علوم پایه

مجله پژوهش‌های حفاظت آب و خاک

جلد بیستم، شماره اول، ۱۳۹۲

<http://jwsc.gau.ac.ir>

## استفاده از آزمون گاما برای انتخاب ورودی‌های بهینه در مدل‌سازی مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی

\*علی اصغر بسالت‌پور<sup>۱</sup>، محمدعلی حاج‌عباسی<sup>۲</sup> و شمس‌الله ایوبی<sup>۳</sup>

<sup>۱</sup>دانشجوی دکتری گروه علوم خاک، دانشگاه صنعتی اصفهان، استاد گروه علوم خاک، دانشگاه صنعتی اصفهان،

<sup>۲</sup>دانشیار گروه علوم خاک، دانشگاه صنعتی اصفهان

تاریخ دریافت: ۸۹/۷/۲۷؛ تاریخ پذیرش: ۹۱/۱/۲۸

### چکیده

آزمون گاما ابزاری مناسب برای تعیین ترکیب بهینه ورودی‌ها و تعداد داده‌های مناسب برای رسیدن به کم‌ترین میانگین مربعات خطا در هر گونه مدل‌سازی غیرخطی پیوسته می‌باشد. در این پژوهش از فن‌آوری آزمون گاما برای انتخاب ورودی‌های بهینه از میان ۱۲ پارامتر ورودی (شامل ویژگی‌های خاک، توپوگرافی و پوشش گیاهی) مؤثر در برآورد مقاومت برشی خاک استفاده شد. سپس با استفاده از دو گروه داده‌های ورودی مختلف، دو مدل شبکه عصبی مصنوعی برای برآورد مقاومت برشی خاک طراحی شد (مدل‌های ۱ و ۲). در مدل ۱ از هر ۱۲ پارامتر اندازه‌گیری شده به‌عنوان ورودی و در مدل ۲ از ۵ پارامتر بهینه به‌دست آمده از مطالعات آزمون گاما برای مدل‌سازی استفاده شد. براساس نتایج آزمون گاما، پارامتر شن ریز دارای کم‌ترین مقدار گاما و میانگین وزنی قطر خاک‌دانه‌ها (MWD) دارای بیش‌ترین مقدار گاما و نسبت ۷ بودند. هم‌چنین شاخص پوشش گیاهی (NDVI)، درصد شن، شن خیلی ریز و جهت شیب، ۴ پارامتر دیگری بودند که دارای کم‌ترین مقدار گاما نسبت به سایر پارامترهای اندازه‌گیری شده بودند. مقدار گاما برای این پارامترها به‌ترتیب ۰/۲۱۷۷، ۰/۲۲۸۰، ۰/۲۳۱۳ و ۰/۲۳۱۸ بود. بنابراین براساس نتایج آزمون گاما ۵ پارامتر شن خیلی ریز، شن ریز، درصد شن، NDVI و جهت شیب به‌عنوان ورودی‌های بهینه برای مدل‌سازی مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی انتخاب شدند. مدل شبکه عصبی طراحی شده با استفاده از ۵ پارامتر ورودی بهینه به‌دست آمده از مطالعات آزمون گاما (مدل ۲)، دارای دقتی معادل با مدل شبکه

\*مسئول مکاتبه: [a\\_besaaltpour@yahoo.com](mailto:a_besaaltpour@yahoo.com)

عصبی طراحی شده با استفاده از ۱۲ پارامتر ورودی (مدل ۱) بود. مقادیر ضریب هم‌بستگی ( $r$ ) و ریشه میانگین مربعات خطا (RMSE) برای مدل ۲ به ترتیب ۰/۸۸۵ و ۰/۰۴۵ بود در حالی که مقدار این شاخص‌ها برای مدل ۱ به ترتیب برابر ۰/۸۹۱ و ۰/۰۵۸ بود. بنابراین به نظر می‌رسد که بتوان از آزمون گاما برای انتخاب ورودی‌های بهینه مؤثرتر بر برآورد مقاومت برشی خاک برای کاهش حجم محاسبه‌ها و صرفه‌جویی در وقت و هزینه‌ها استفاده نمود.

**واژه‌های کلیدی:** آزمون گاما، ویژگی‌های مکانیکی خاک، شبکه‌های عصبی مصنوعی، مدل‌سازی

### مقدمه

خاک به‌عنوان یک سیستم پویا، همواره تحت تأثیر نیروهای خارجی قرار داشته که این نیروها می‌توانند طبیعی (مانند قطرات باران، رواناب، انسان، گیاهان و جانوران) یا غیرطبیعی (مانند ادوات کشاورزی) باشند. توده خاک تا حد معینی در برابر نیروهای خارجی مقاومت نشان می‌دهد و بیش از آن حد، خاک گسیخته می‌شود. گسیختگی خاک معمولاً از نوع برشی بوده و به حداکثر مقاومتی که خاک در برابر گسیختگی و لغزش در امتداد هر صفحه دلخواه نشان دهد، مقاومت برشی خاک گویند (وفائیان، ۱۹۹۷). در بسیاری از مطالعات از مقاومت برشی سطح خاک به‌عنوان شاخصی مناسب برای بررسی فرسایش‌پذیری خاک نام‌برده شده است (فرانتی و همکاران، ۱۹۹۹؛ لئونارد و ریچارد، ۲۰۰۴؛ خلیل‌مقدم و همکاران، ۲۰۰۹). براساس این پژوهش‌ها، شرایط خاک زمانی که به‌وسیله جریان شیاری به حد آستانه فرسایش‌پذیری برسد به‌وسیله مقاومت برشی سطح خاک کنترل می‌گردد (رائوس و گاورز، ۱۹۸۸). هم‌چنین گزارش شده که فرایند جداسازی ذرات خاک به‌وسیله قطرات باران با مقاومت برشی سطح خاک مرتبط است (برنوری و همکاران، ۱۹۸۹).

روش‌های مختلفی برای اندازه‌گیری مقاومت برشی خاک وجود دارد. از جمله روش‌های آزمایشگاهی اندازه‌گیری مقاومت برشی خاک می‌توان به آزمایش برش مستقیم، آزمایش تک‌محوری غیرمحصور (فشاری غیرمحصور) و آزمایش فشردگی سه‌محوری اشاره نمود. برای اندازه‌گیری مقاومت برشی خاک در مزرعه نیز ممکن است از دستگاه‌هایی مانند رینگ برشی، پترومتر مخروطی، پترومتر جیبی و دستگاه برش وین استفاده شود (خلیل‌مقدم، ۲۰۰۹). با این وجود بسیاری از این روش‌ها به‌نسبت پیچیده و به‌طور عمده وقت‌گیر و هزینه‌بر بوده و استفاده از آن‌ها در مقیاس‌های بزرگ مانند حوزه‌های آب‌خیز با محدودیت‌های فراوان مواجه است. به همین سبب امروزه از روش‌های غیرمستقیم مانند توابع

انتقالی خاک<sup>۱</sup> و توابع پیش‌بینی فضایی خاک<sup>۲</sup> به منظور برآورد ویژگی‌های خاک استفاده می‌گردد. در این توابع با استفاده از داده‌های زودیافت برخی ویژگی‌های دیریافت خاک مانند خصوصیات فیزیکی و مکانیکی تخمین زده می‌شوند (خلیل مقدم و همکاران، ۲۰۰۹).

در بسیاری از مطالعات از برخی ویژگی‌های خاک (مانند توزیع اندازه ذرات خاک، ماده آلی و آهک)، خواص توپوگرافی (مانند درصد شیب، جهت شیب، ارتفاع) و پوشش گیاهی (مانند درصد پوشش گیاهی و شاخص‌های مرتبط با آن) به عنوان عواملی که به صورت مستقیم یا غیرمستقیم بر مقاومت برشی خاک مؤثرند یاد شده است (هرن و همکاران، ۲۰۰۵؛ مصدقی و همکاران، ۲۰۰۶؛ خلیل مقدم و همکاران، ۲۰۰۹). برای مثال هرن و همکاران (۲۰۰۵) گزارش کردند که تغییرات در مقاومت برشی خاک به شکل و توزیع اندازه ذرات خاک وابسته بوده و همچنین خاک‌های با میزان آهک بیش‌تر دارای ساختار خاک‌دانه‌ای قوی‌تر و بنابراین حساسیت کم‌تری نسبت به تراکم دارند. ویژگی‌های توپوگرافی نیز از طریق اثر بر رطوبت خاک، توسعه ریشه، پایداری خاک در شیب، نفوذ آب به خاک، فرسایش خاک و... بر میزان مقاومت برشی خاک مؤثرند (فن و سو، ۲۰۰۸؛ خلیل مقدم و همکاران، ۲۰۰۹). پوشش گیاهی هم به صورت مستقیم (از طریق توسعه سیستم ریشه‌ای) و هم به صورت غیرمستقیم (با اثر بر میزان ماده آلی خاک، نگهداری ذرات خاک و افزایش پایداری خاک‌دانه‌ها) بر میزان مقاومت برشی خاک اثرگذار است (لئونارد و ریچارد، ۲۰۰۴). توابع انتقالی خاک و توابع پیش‌بینی فضایی خاک می‌توانند این روابط را تشخیص داده و بنابراین به نظر می‌رسد که بتوان از این توابع برای برآورد خصوصیات دیریافت خاک (مانند مقاومت برشی خاک) استفاده نمود (گوکتپ و همکاران، ۲۰۰۸؛ خلیل مقدم و همکاران، ۲۰۰۹).

از جمله روش‌های نوین برای ایجاد توابع انتقالی و توابع پیش‌بینی فضایی خاک، شبکه‌های عصبی مصنوعی<sup>۳</sup> می‌باشند. شبکه‌های عصبی مصنوعی سیستم‌های یادگیرنده‌ای هستند که در صورت دارا بودن پیچیدگی لازم و نیز نمونه و زمان کافی برای آموزش، می‌توانند هر تابع غیرتصادفی از هر درجه‌ای را مدل کنند. اجزای سازنده شبکه‌های عصبی مصنوعی به عنوان یک مدل از سیستم عصبی موجودات زنده، نرون‌ها هستند. وظیفه هر نرون، انجام نوعی پردازش بر روی سیگنال‌های ورودی و تولید یک خروجی واحد مطلوب است. قبل از ورود هر سیگنال به نرون، سیگنال از فضایی موسوم به

1- Pedotransfer Functions, PTFs

2- Soil Spatial Prediction Functions, SSPFs

3- Artificial Neural Networks, ANNs

فضای سیناپسی عبور می‌کند که در آن عملیات تقویت و یا تضعیف سیگنال صورت می‌گیرد. این فضا در واقع محل ارتباط یک نرون با نرون دیگر است. وظیفه شبکه‌های عصبی این است که طی یک دوره آموزشی، بیاموزند که به‌ازای هر ورودی، خروجی مطلوب را تولید نمایند. از جمله مهم‌ترین برتری‌های شبکه‌های عصبی مصنوعی نسبت به رگرسیون‌های چندمتغیره در ایجاد توابع انتقالی و توابع پیش‌بینی فضایی خاک آن است که نیاز به یک معادله اولیه برای تعیین ارتباط بین ورودی‌ها و خروجی مطلوب نمی‌باشد (منهاج، ۲۰۰۱).

یکی از مهم‌ترین مراحل مدل‌سازی با شبکه‌های عصبی مصنوعی، انتخاب پارامترهای ورودی بهینه به‌منظور افزایش دقت و کارایی مدل و کاهش هزینه‌ها و زمان مصرفی در مدل‌سازی است. از جمله روش‌هایی که می‌توان برای شناسایی پارامترهای ورودی بهینه و مؤثر در مدل‌سازی یک خروجی هدف استفاده نمود، فن‌آوری آزمون گاما می‌باشد. آزمون گاما ابزاری برای تجزیه و تحلیل و مدل‌سازی غیرخطی بوده که با در نظر گرفتن کم‌ترین مقدار قابل محاسبه میانگین مربعات خطا<sup>۱</sup> مناسب‌ترین رابطه بین ورودی‌ها و خروجی یا خروجی‌ها در یک مجموعه داده‌های عددی را ارائه می‌کند. در واقع با استفاده از آزمون گاما می‌توان بهینه‌ترین ترکیب ورودی‌ها و مناسب‌ترین تعداد داده‌ها که منجر به کم‌ترین میانگین مربعات خطا در هر گونه مدل‌سازی غیرخطی پیوسته می‌شود را تعیین نمود. به بیان دیگر طی فرایند آزمون گاما، احتمال  $m$  ورودی مطابق با خروجی  $l$  در داده‌های پایه که ترتیبی مناسب برای مدلی بهینه از  $l$  را ارائه می‌کند، مورد ارزیابی قرار می‌گیرد. با بررسی خطا در هر ترتیب ورودی‌ها، یک معیار مناسب برای قضاوت در مورد آن‌ها فراهم می‌شود و در نهایت ترتیبی از داده‌ها که دارای کم‌ترین مقدار خطا برای مدل‌سازی بهینه خروجی  $l$  است، به‌عنوان ترتیب بهینه ورودی‌ها مورد استفاده قرار می‌گیرد (مقدم‌نیا و همکاران، ۲۰۰۹).

از آن‌جا که محاسبه گاما شکل ساده‌ای از انحراف خطا است در نتیجه گاما مقداری کلی است که می‌تواند در بسیاری از توجیحات آماری و در هر موردی که روش‌های آماری سنتی به‌کار می‌روند، استفاده شود. در این پژوهش نیز امکان استفاده از آزمون گاما برای تعیین ورودی‌های بهینه برای مدل‌سازی مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی مورد بررسی قرار گرفت. بررسی کارایی و قابلیت استفاده از شبکه‌های عصبی مصنوعی در برآورد ویژگی‌های مکانیکی خاک مانند مقاومت برشی نیز از دیگر اهداف این پژوهش بود.

---

1- Mean Square Error, MSE

## مواد و روش ها

منطقه مورد مطالعه: منطقه مورد مطالعه بخشی از حوزه آبخیز بازفت (۴۹ درجه و ۳۴ دقیقه تا ۵۰ درجه و ۳۲ دقیقه طول شرقی و ۳۱ درجه و ۳۷ دقیقه تا ۳۲ درجه و ۳۹ دقیقه عرض شمالی) یکی از ۶ زیرحوزه اصلی حوزه آبخیز کارون شمالی بود. نام بازفت برای این حوزه برگرفته از نام رودخانه دایمی آب بازفت با طول تقریبی ۱۴۶ کیلومتر می باشد که از بخش شمال غربی حوزه به سمت جنوب شرقی آن جریان دارد. بخش اعظم این حوزه (حدود ۵۰ درصد) کوهستانی بوده که مرتفع ترین نقطه آن زردکوه با ارتفاع ۴۲۲۱ متر و ارتفاع متوسط حوزه حدود ۲۲۰۰ متر می باشد. شیب متوسط حوزه متغیر و بیشترین آن مربوط به کلاس شیب ۷۰-۴۰ درصد است. حدود ۵۶ درصد از وسعت کل حوزه دارای پوشش مرتعی (به طور عمده دافنه و گون) و بقیه منطقه دارای پوشش جنگلی (به طور عمده بلوط ایرانی) یا عاری از پوشش می باشد. میانگین سالانه درجه حرارت در ارتفاعهای شمال شرقی حوزه (ارتفاعهای زردکوه) به کم تر از ۸ درجه سانتی گراد و در قسمت های جنوبی حوزه به ۲۰ درجه سانتی گراد می رسد. میانگین بارش سالانه در حوزه نیز از ۱۴۰۰ میلی متر در ارتفاعهای شمال شرقی تا ۵۰۰ میلی متر در بخش های جنوبی حوزه متغیر می باشد (صفامنش، ۱۹۹۶).

**نمونه برداری و اندازه گیری ویژگی های خاک:** منطقه مورد مطالعه ابتدا براساس خواص توپوگرافی، زمین شناسی و پوشش گیاهی به واحدهای کاری همسان تقسیم گردید. سپس نمونه برداری خاک از عمق سطحی (۵-۰ سانتی متر) به صورت تصادفی نظارت شده انجام و در کل ۱۶۰ نمونه با در نظر گرفتن سطح هر واحد کاری برداشت گردید. نمونه خاکها پس از انتقال به آزمایشگاه هواخشک و برای انجام آزمایش های خاک شناسی از سرنند ۲ میلی متری عبور داده شدند. ماده آلی خاک به روش واکلی و بلاک (نلسون و سامرز، ۱۹۸۶)، آهک خاک به روش خشتی کردن مواد خشتی شونده با اسید کلریدریک و تیتراسیون با سود (نلسون، ۱۹۸۲) تعیین شد. درصد ذرات رس، سیلت و شن به روش پیپت و درصد ذرات شن ریز و شن خیلی ریز با عبور سوسپانسیون آب و خاک به ترتیب از سرندهای با شماره مش ۱۸۰ و ۲۷۰ تعیین شد (جی و بادر، ۱۹۸۶). روش ون باول (۱۹۵۰) اصلاح شده توسط کمپر و روزنو (۱۹۸۶) برای تعیین میانگین وزنی قطر خاک دانه ها<sup>۱</sup> به عنوان شاخصی از پایداری خاک دانه ها استفاده شد. برای اندازه گیری مقاومت برشی سطح خاک نیز از دستگاه توروین (مدل BS۱۳۷۷-۹) استفاده شد. برای این منظور دستگاه تا جایی که پره ها کاملاً در داخل خاک قرار گیرند وارد خاک شد. سپس وین در جهت

1- Mean Weight Diameter, MWD

عقره‌های ساعت تا برش (گسیختگی) کامل خاک که در حدود ۱۰-۵ ثانیه طول می‌کشد، دوران داده شد. بیشینه تنش وارده برای برش خاک بر روی صفحه درجه‌بندی شده بالای دستگاه، ثبت و قرائت گردید. این دستگاه قادر به اندازه‌گیری تنش‌های بین ۱۰۰-۰ کیلوپاسکال می‌باشد.

**تعیین ویژگی‌های توپوگرافی و پوشش گیاهی:** برخی خواص توپوگرافی نقاط نمونه‌برداری مانند درصد شیب، جهت شیب و ارتفاع با استفاده از نقشه مدل رقومی ارتفاعی<sup>۱</sup> با اندازه ابعاد سلولی ۲۰×۲۰ متر در محیط نرم‌افزار ایلویس تعیین شد. شاخص نرمال شده تفاوت پوشش گیاهی<sup>۲</sup> نیز به‌عنوان معیاری از وضعیت پوشش گیاهی نقاط مورد مطالعه استفاده شد. این شاخص از تصویر ماهواره‌ای IRS ۲۰۰۸ با وضوح ۲۴×۲۴ متر و در محیط نرم‌افزار ایلویس استخراج گردید.

**تجزیه و تحلیل آماری داده‌ها:** پس از اندازه‌گیری و تعیین ویژگی‌های خاک، توپوگرافی و پوشش گیاهی نقاط مورد مطالعه، برخی خصوصیات آماری داده‌ها مانند بیشینه، کمینه، میانگین، واریانس و انحراف معیار با استفاده از نرم‌افزار SPSS تعیین شد. سپس به‌منظور یکسان نمودن ارزش داده‌ها پیش از استفاده در آزمون گاما و مدل‌سازی با شبکه‌های عصبی، داده‌ها با استفاده از رابطه ۱ استاندارد شدند:

$$X_n = \left[ \left( \frac{X_i - \bar{X}}{X_{\max} - X_{\min}} \right) \times 0.5 \right] + 0.5 \quad (1)$$

که در آن،  $X_n$ : داده‌های استاندارد شده،  $X_i$ : داده‌های مشاهده‌ای،  $X_{\max}$  و  $X_{\min}$ : به‌ترتیب بیشینه و کمینه داده‌های مشاهده‌ای و  $\bar{X}$ : میانگین داده‌های مشاهده‌ای می‌باشد. این رابطه، داده‌ها را در بازه [۰ و ۱] تبدیل می‌کند.

**انتخاب ورودی‌های بهینه با استفاده از آزمون گاما:** آزمون گاما مقدار خطای برآورد شده (واریانس خطا) را با توجه به داده‌های مستقیم نشان می‌دهد. از این‌رو برآورد خطایی که به آن آزمون گاما اطلاق می‌گردد، می‌تواند معادل مجموع مربعات خطای غیرخطی در نظر گرفته شود. برای درکی بهتر از آزمون گاما چنانچه فرض شود که دو نقطه  $x$  و  $x'$  با هم‌دیگر در فضای ورودی متناظر با خروجی‌های  $y$  و  $y'$  به هم نزدیک شوند باید در فضای خروجی نیز این دو نقطه به هم نزدیک گردند در غیر این صورت، نزدیک نبودن این دو نقطه ناشی از اختلافی خواهد بود که از خطاها (نویزها) ایجاد می‌شوند. به‌عنوان مثال اگر مجموعه‌ای از داده‌های مستقیم به شکل رابطه ۲ را در نظر بگیریم:

1- Digital Elevation Model, DEM

2- Normalized Difference Vegetation Index, NDVI

$$\{(x_i, y_i), 1 \leq i \leq M\} \quad (2)$$

که در آن، بردار  $x_i \in R^m$  به عنوان ورودی و مطابق آن عدد  $y_i \in R$  به عنوان خروجی در نظر گرفته می شود. فرض شود که بردارهای  $x$  قابلیت پیش گویی فاکتورهای مؤثر و بهینه قابل استفاده در برآورد خروجی  $y$  را داشته باشند، در این صورت رابطه ۳ صادق خواهد بود:

$$y = f(x_1, \dots, x_M) + r \quad (3)$$

که در آن،  $f$ : یک تابع ساده<sup>۱</sup> و  $r$ : یک متغیر تصادفی است که نشان دهنده مقادیر نویز می باشد. به طور کلی و بدون کاهش تابع می توان دریافت که مقدار  $r$  برابر صفر بوده و بنابراین هر مقدار اریب<sup>۲</sup> ثابت، می تواند در تابع ناشناخته  $f$  استنتاج شود.

دامنه احتمال مدل به تابعی از مدل ساده محدود می شود و چون مشتق جزئی اول دارای محدودیت هایی است، آماره گاما ( $\Gamma$ ) از قسمتی از واریانس خروجی که نمی تواند برای یک مدل ساده محاسبه شود به دست می آید. اگر فرض شود که  $\{x_i, k\}$  مقدار  $k$  آمین نزدیک ترین همسایه در یک فاصله اقلیدسی برای  $(1 \leq k \leq p)$  و  $x_i (1 \leq i \leq M)$  باشد در این صورت معادله اصلی محاسبه گاما، نیازمند برآورد مقدار  $\Gamma$  از بردارهای ورودی است:

$$\delta_M(k) = \frac{1}{M} \sum_{i=1}^M |x_{N[i,k]} - x_i|, (1 \leq k \leq p) \quad (4)$$

که در آن،  $|\dots|$  فاصله اقلیدسی را مشخص می کند و تابع مربوطه گاما از مقادیر خروجی عبارت خواهد بود از:

$$\gamma_M(k) = \frac{1}{M} \sum_{i=1}^M |y_{N[i,k]} - y_i|, (1 \leq k \leq p) \quad (5)$$

که در آن،  $\gamma_m(k)$ : بیانگر مقادیر  $y$  برای  $k$  آمین نزدیک ترین همسایه  $x_i$  در رابطه ۴ می باشد. از این رو با محاسبه  $\Gamma$  می توان کم ترین مربعات خطا را برای نقاط  $p$   $[\delta_M(k), \gamma_M(k)]$  ایجاد کرد:

$$\gamma = A\delta + \Gamma \quad (6)$$

1- Smooth Function

2- Bios

اگر محور عمودی قطع شود ( $\delta=0$ )، مقدار  $\Gamma$  به صورت زیر نشان داده می‌شود:

$$\gamma_M(k) \rightarrow \text{Var}(r) \quad \text{as} \quad \delta_M(k) \rightarrow 0 \quad (7)$$

وقتی که مقدار گاما صفر باشد هیچ محدودیتی برای ساخت یک مدل خوب وجود نخواهد داشت، بنابراین از نقاطی که دارای مقدار گامای کم‌تر در مقایسه با دیگر متغیرها هستند برای مدل‌سازی استفاده خواهد شد (مقدم‌نیا و همکاران، ۲۰۰۹).

محاسبه شیب<sup>۱</sup> نیز می‌تواند اطلاعات مفیدی در زمینه ترکیب سیستم تحت کنترل ارائه کند. در واقع شیب یک مقدار بی‌بعد است که بیان‌کننده پیچیدگی‌های تابع می‌باشد. انحراف معیار<sup>۲</sup> نیز درستی رگرسیون خطی در آماره گاما را بیان می‌کند. اگر این مقدار به صفر نزدیک شود، اطمینان بیشتری از مقدار آماره گاما را نشان می‌دهد. نسبت  $\gamma$ <sup>۳</sup> بررسی شکلی را که وابسته به دامنه خروجی است را میسر می‌سازد و خروجی مناسب برای توابع ساده را مدل‌سازی می‌کند و به صورت رابطه ۸ نشان داده می‌شود:

$$\gamma = \frac{\Gamma}{\sigma^2(y)} \quad (8)$$

که در آن،  $\sigma^2(y)$ : واریانس خروجی  $y$  است. در آزمون گاما هرچه نسبت  $\gamma$  به صفر نزدیک‌تر شود، نمایان‌گر برآوردی مناسب‌تر از خروجی  $y$  خواهد بود. برای پارامترهای ورودی که مقدار این متغیر به ۱ نزدیک‌تر باشد، مقدار خطای تصادفی افزایش یافته و بنابراین مدل برازش‌یافته با استفاده از آن پارامترها، نامناسب‌تر خواهد بود (مقدم‌نیا و همکاران، ۲۰۰۹). در این پژوهش از نرم‌افزار WinGamma<sup>TM</sup> برای محاسبه‌های آزمون گاما برای انتخاب ۵ ورودی بهینه در برآورد مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی استفاده شد.

**مدل‌سازی با شبکه‌های عصبی مصنوعی:** در این پژوهش دو مدل مختلف شبکه عصبی با استفاده از ویژگی‌های خاک، توپوگرافی و پوشش گیاهی نقاط مورد مطالعه به‌عنوان ورودی برای برآورد مقاومت برشی خاک طراحی شد (جدول ۱). در مدل اول همه پارامترهای خاک، توپوگرافی و پوشش گیاهی اندازه‌گیری شده به‌عنوان ورودی در مدل‌سازی استفاده شد (مدل ۱). در مدل دوم ۵ پارامتر مؤثرتر بر برآورد مقاومت برشی خاک به‌دست آمده از مطالعات آزمون گاما به‌عنوان ورودی شبکه استفاده گردید (مدل ۲). در هر دو مدل شبکه عصبی طراحی شده، ۶۰ درصد داده‌ها (۹۶ داده) برای آموزش مدل،

1- Gradient

2- Standard Error

3- V-Ratio



۲۰ درصد برای فرایند اعتبارسنجی (۲۳ داده) و ۲۰ درصد باقی مانده به عنوان داده های تست مدل استفاده شد. فرایند آموزش مدل در محیط نرم افزار MatLab 7.6 و با استفاده از شبکه عصبی پرسپترون چندلایه<sup>۱</sup> و قاعده آموزش پس انتشار<sup>۲</sup> انجام شد. تعداد نرون ها در لایه پنهان و تعداد دور یا اپاک<sup>۳</sup> مناسب به منظور رسیدن به بهترین ساختار شبکه عصبی برای هر مدل با کمترین خطا به روش سعی و خطا تعیین شد. برای مدل ۱ تعداد ۱۷ نرون در لایه مخفی و ۱۵۰۰۰ اپاک و برای مدل ۲ تعداد ۸ نرون در لایه مخفی با ۱۰۰۰ اپاک، بهترین ساختار شبکه عصبی با کمترین خطای ممکن به دست آمد.

جدول ۱- متغیرهای ورودی مورد استفاده برای مدل های مختلف شبکه عصبی.

مدل	ورودی
مدل ۱	رس، سیلت، شن، شن ریز، شن خیلی ریز، ماده آلی، آهک، NDVI، MWD، درصد شیب، جهت شیب و ارتفاع
مدل ۲	شن، شن ریز، شن خیلی ریز، NDVI و جهت شیب

MWD: میانگین وزنی قطر خاک دانه ها و NDVI: شاخص پوشش گیاهی.

**شاخص های ارزیابی مدل ها:** به منظور بررسی کارایی و دقت دو مدل شبکه عصبی طراحی شده برای برآورد مقاومت برشی خاک در این پژوهش از برخی شاخص های آماری مانند ضریب هم بستگی ( $r$ )، ریشه میانگین مربعات خطا<sup>۴</sup> و میانگین خطای تخمین<sup>۵</sup> استفاده شد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [S(x_i) - M(x_i)]^2} \quad (9)$$

$$MEE = \frac{1}{n} \sum_{i=1}^n [S(x_i) - M(x_i)] \quad (10)$$

که در آن ها،  $M(x_i)$  و  $S(x_i)$ : به ترتیب مقادیر مشاهده ای و برآورد شده و  $n$ : تعداد کل مشاهده ها می باشد.

- 1- Multilayer Perceptron, MLP
- 2- Back Propagation
- 3- Epoch
- 4- Root Mean Square Error, RMSE
- 5- Mean Estimation Error, MEE

## نتایج و بحث

ویژگی‌های خاک، توپوگرافی و پوشش گیاهی: جدول ۲ توصیف آماری ویژگی‌های خاک، توپوگرافی و پوشش گیاهی نقاط مورد مطالعه، استفاده شده برای برآورد مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی را نشان می‌دهد. براساس توزیع اندازه ذرات خاک، بافت غالب خاک در منطقه شامل لومی رسی سیلتی، لومی سیلتی، لومی و رسی سیلتی بود. ماده آلی خاک بین ۶/۳۳-۰/۲۲ درصد و آهک خاک به ترتیب دارای مقادیر کمینه، بیشینه، میانگین و انحراف معیار ۱/۰۰، ۸۰/۶۵، ۲۵/۳۲ و ۲۱/۱۲ درصد بود. مقادیر زیاد آهک خاک در منطقه مورد مطالعه به دلیل وجود مواد مادری مارن غنی از گچ و آهک و وجود افق کلسیک می‌باشد که دارای مقدار زیادی از کربنات‌ها است. پایداری خاک‌دانه‌ها در منطقه از ۱/۴۷-۰/۰۳ میلی‌متر متغیر بود. تخریب جنگل‌ها و مراتع، تغییر کاربری اراضی به دیم و شخم و شیار اراضی، چرای بی‌رویه و ورود زودهنگام دام به مراتع، قطع درختان و سوزاندن بوته‌ها، شیب زیاد و فرسایش خاک در منطقه به‌طور مستقیم و غیرمستقیم سبب تخریب خاک‌دانه‌ها و بنابراین مقادیر کم MWD در برخی از نقاط مورد مطالعه شده است (صفامنش، ۱۹۹۶).

جدول ۲- توصیف آماری پارامترهای مورد استفاده برای مدل‌سازی مقاومت برشی خاک.

شاخص آماری					پارامتر
انحراف معیار	واریانس	بیشینه	کمینه	میانگین	
۸/۴۲	۷۰/۹۶	۵۳/۶۰	۸/۰۰	۳۱/۰۸	رس (درصد)
۹/۲۸	۸۶/۱۹	۸۱/۶۰	۲۱/۶۰	۴۸/۴۰	سیلت (درصد)
۱۲/۸۱	۱۶۴/۰۹	۶۵/۶۰	۳/۲۰	۲۰/۵۳	شن (درصد)
۵/۴۵	۲۹/۶۶	۲۸/۰۴	۰/۷۰	۶/۶۵	شن خیلی ریز (درصد)
۳/۳۸	۱۱/۴۳	۱۶/۰۲	۰/۱۸	۴/۱۳	شن ریز (درصد)
۱/۲۹	۱/۶۷	۶/۳۳	۰/۲۲	۲/۵۸	ماده آلی (درصد)
۲۱/۱۲	۴۴۵/۹۰	۸۰/۶۵	۱/۰۰	۲۵/۳۲	آهک (درصد)
۰/۲۹	۰/۰۸	۱/۴۷	۰/۰۳	۰/۳۷	MWD (میلی‌متر)
۰/۰۸	۰/۰۰۶	۰/۴۷	-۰/۳۱	۰/۱۳	NDVI
۱۵/۴۲	۲۳۷/۸۸	۸۰/۶۱	۳/۱۰	۲۸/۳۱	درصد شیب
۱۰۰/۸۱	۱۰۱۶۲/۸۳	۳۶۵/۸۵	۸/۸۷	۱۷۱/۸۲	جهت شیب (رادیان)
۲۹۷/۶۴	۸۸۴۸۴/۴۵	۲۶۳۹/۰۰	۹۰۷/۰۰	۱۷۱۴/۵۳	ارتفاع (متر)
۱/۱۷	۱/۳۶	۹/۷۰	۳/۳۳	۶/۳۴	مقاومت برشی (کیلوپاسگال)

MWD: میانگین وزنی قطر خاک‌دانه‌ها و NDVI: شاخص پوشش گیاهی.

شاخص NDVI در نقاط نمونه برداری از ۰/۳۱- تا ۰/۴۷ متغیر بوده و دارای میانگین و انحراف معیار به ترتیب ۰/۱۳ و ۰/۰۸ بود. شاخص NDVI بیان کننده سبزینه گیاهی است که در ارتباط با درصد تابش های جذب شده فتوسنتزی بوده و نمایانگر فعالیت کلروفیل در گیاهان است. این شاخص بین ۱- تا ۱ متغیر بوده که افزایش میزان عددی آن بیانگر افزایش درصد پوشش گیاهی سبز سالم می باشد و بنابراین سطوح بدون پوشش گیاهی، دارای مقادیر منفی NDVI هستند (خلیل مقدم، ۲۰۰۹). درصد شیب در نقاط نمونه برداری بین ۸۰/۶۱- تا ۳/۱۰ درصد با میانگین ۲۸/۳۱ درصد متفاوت بود که نمایانگر توپوگرافی شدید در منطقه مورد مطالعه است. برای شیب دارای میانگین ۱۷۱/۸۲ رادیان و ارتفاع نقاط نمونه برداری به ترتیب دارای مقادیر کمینه، بیشینه و میانگین ۹۰۷/۰۰، ۲۶۳۹/۰۰ و ۱۷۱۴/۵۳ متر بود.

مقاومت برشی سطح خاک در منطقه مورد مطالعه تحت تأثیر فعالیت هایی هم چون چرای بی رویه و زود هنگام دام، شخم و شیار در جهت شیب، قطع درختان و بوته ها و سله سطحی خاک قرار داشته و مقدار اندازه گیری شده آن از ۹/۷۰-۳/۳۳ کیلو پاسکال متغیر بود. تخریب خاک دانه ها (به سبب تردد زیاد دام و شخم و شیار)، و حذف ریشه گیاهان (به سبب چرای بی رویه دام و سوزاندن بوته ها) از جمله عوامل اصلی کم بودن مقاومت برشی سطح خاک در برخی از نقاط مورد مطالعه بود. وجود پوشش گیاهی و تحت اشکوب متراکم، تجمع سنگ ریزه در سطح خاک به سبب از دست رفتن خاک در مناطق بالادست و تشکیل سله در مناطق پایین دست نیز از عوامل بالا بودن مقاومت برشی سطح خاک در برخی نقاط مورد مطالعه بودند.

در بسیاری از مطالعات برخی از ویژگی های خاک مانند توزیع اندازه ذرات خاک، ماده آلی و آهک و نیز برخی از خصوصیات توپوگرافی و پوشش گیاهی مانند درصد و جهت شیب، ارتفاع و پوشش گیاهی به عنوان پارامترهای اثرگذار بر مقاومت برشی خاک نام برده شده است (هرن و همکاران، ۲۰۰۵؛ لئونارد و ریچارد، ۲۰۰۴؛ مصدقی و همکاران، ۲۰۰۶). برای مثال مصدقی و همکاران (۲۰۰۶) گزارش کردند که میزان آهک خاک پارامتری مهم و مؤثر بر مقاومت برشی خاک مناطق خشک می باشد. هرن و همکاران (۲۰۰۵) بیان نمودند که مقاومت برشی خاک های بدون پوشش به شکل و اندازه ذرات شن خاک وابسته بود. لئونارد و ریچارد (۲۰۰۴) دریافتند که حضور شبکه ای از ریشه گیاهان که نقشی مؤثر در پایداری خاک دانه ها دارد بر مقاومت برشی خاک نیز تأثیر فراوان داشت. خلیل مقدم و همکاران (۲۰۰۹) گزارش نمودند که با توجه به تأثیر غیرمستقیم توزیع اندازه ذرات خاک، مواد آلی و آهک خاک و ویژگی های توپوگرافی و پوشش گیاهی بر مقاومت برشی سطح خاک، می توان از این پارامترها برای برآورد مقاومت برشی خاک با استفاده از توابع انتقالی و پیش بینی فضایی خاک استفاده نمود.

انتخاب ورودی‌های بهینه با استفاده از آزمون گاما: شکل ۱ نشان‌دهنده نتایج مقدار گاما در نزدیک‌ترین همسایه‌ها می‌باشد. چنانچه اولین مقدار کاهش گاما را به‌عنوان نویز در نظر بگیریم، دومین مقدار کاهش گاما در نهمین همسایه اتفاق افتاده و بنابراین به‌نظر می‌رسد که تعداد داده‌ها در این پژوهش برای مدل‌سازی و توسعه یک مدل خوب با خطای کم مناسب بوده است. نتایج آزمون گاما به‌منظور انتخاب ورودی‌های بهینه برای مدل‌سازی مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی نیز در جدول ۳ آمده است. براساس مقادیر گاما، شیب، خطای استاندارد و نسبت ۷، پارامترهای شن، شن ریز، شن خیلی‌ریز، NDVI و جهت شیب دارای بیش‌ترین قابلیت استفاده در مدل‌سازی برآورد مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی بودند. از میان ویژگی‌های خاک، توپوگرافی و پوشش گیاهی اندازه‌گیری شده، پارامتر شن ریز دارای کم‌ترین مقدار گاما بود و بنابراین به‌نظر می‌رسد تأثیر بیش‌تری در مدل‌سازی مقاومت برشی خاک نسبت به سایر پارامترها داشته باشد (جدول ۳). این در حالی است که MWD دارای بیش‌ترین مقدار گاما و نسبت ۷ و بنابراین کم‌ترین نقش در برآورد مقاومت برشی خاک بود. مقدار گاما برای پارامترهای NDVI، شن، شن خیلی‌ریز و جهت شیب نیز به‌ترتیب ۰/۲۱۷۷، ۰/۲۲۸۰، ۰/۲۳۱۳ و ۰/۲۳۱۸ بود (جدول ۳). بنابراین براساس نتایج آزمون گاما، ۵ پارامتر درصد شن، شن ریز، شن خیلی‌ریز، NDVI و جهت شیب به‌عنوان ورودی‌های بهینه برای مدل‌سازی مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی انتخاب شدند. در پژوهشی مشابه مقدم‌نیا و همکاران (۲۰۰۹) به قابلیت بالای آزمون گاما برای انتخاب پارامترهای بهینه در مدل‌سازی تبخیر آب به‌منظور کاهش زمان و هزینه‌ها در مدل‌سازی اشاره کردند.



شکل ۱- مقدار گاما در نزدیک‌ترین همسایه‌ها.

جدول ۳- نتایج آزمون گاما برای انتخاب ورودی‌های بهینه برای مدل‌سازی مقاومت برشی خاک.

نسبت $\nu$	پارامتر			ورودی
	انحراف معیار	شیب	گاما	
۰/۹۵۲۳	۰/۰۰۹۲	-۰/۰۰۱۶	۰/۲۳۸۱	رس (درصد)
۰/۹۹۲۵	۰/۰۱۳۵	-۰/۱۱۰۶	۰/۲۴۸۱	سیلت (درصد)
۰/۹۱۱۹	۰/۰۰۸۵	۰/۰۸۶۱	۰/۲۲۸۰	شن (درصد)
۰/۹۲۵۱	۰/۰۲۴۹	-۱/۰۰۳۴	۰/۲۳۱۳	شن خیلی ریز (درصد)
۰/۸۰۵۲	۰/۰۱۹۵	۰/۴۵۳۸	۰/۲۰۱۳	شن ریز (درصد)
۰/۹۳۲۷	۰/۰۱۴۳	۱/۰۲۶۲	۰/۲۳۳۲	ماده آلی (درصد)
۰/۹۸۶۸	۰/۰۲۳۷	-۲/۰۹۶۱	۰/۲۴۶۷	آهک (درصد)
۱/۰۸۲۰	۰/۰۳۶۲	-۱/۳۸۱۱	۰/۲۷۰۵	MWD (میلی متر)
۰/۸۷۰۷	۰/۰۱۵۳	۰/۱۰۲۲	۰/۲۱۷۷	NDVI
۱/۰۶۶۳	۰/۰۲۲۶	-۳/۲۵۵۰	۰/۲۶۶۶	درصد شیب
۰/۹۲۷۱	۰/۰۱۳۶	۲/۸۹۴۳	۰/۲۳۱۸	جهت شیب
۰/۹۵۴۸	۰/۰۳۳۷	-۰/۸۶۷۳	۰/۲۳۸۷	ارتفاع (متر)

MWD: میانگین وزنی قطر خاک‌دانه‌ها و NDVI: شاخص پوشش گیاهی.


مدل‌سازی با شبکه‌های عصبی مصنوعی: مقادیر شاخص‌های آماری مورد استفاده برای ارزیابی کارایی مدل‌های شبکه عصبی طراحی شده برای برآورد مقاومت برشی خاک با استفاده از پارامترهای ورودی مختلف (مدل‌های ۱ و ۲) در جدول ۴ آمده است. نتایج نمایانگر آن بود که مدل شبکه عصبی طراحی شده با استفاده از ۵ پارامتر ورودی بهینه به دست آمده از مطالعات آزمون گاما (مدل ۲)، دارای دقتی معادل با مدل شبکه عصبی طراحی شده با استفاده از ۱۲ پارامتر ورودی (مدل ۱) می‌باشد. مقادیر  $RMSE$  و  $MEE$  برای مدل ۲ به ترتیب برابر ۰/۸۸۵، ۰/۰۴۵ و -۰/۰۰۰۲ بود در حالی که مقدار این شاخص‌ها برای مدل ۱ به ترتیب برابر ۰/۸۹۱، ۰/۰۵۸ و -۰/۰۰۵ بود. بنابراین به نظر می‌رسد که براساس مقادیر نزدیک شاخص‌های آماری ارزیابی مدل مورد استفاده در این پژوهش برای هر دو مدل ۱ و ۲، بتوان از فن‌آوری آزمون گاما برای انتخاب ورودی‌های بهینه مؤثرتر بر برآورد و مدل‌سازی مقاومت برشی خاک در منطقه مورد مطالعه برای کاهش حجم محاسبه‌ها، صرفه‌جویی در وقت و هزینه‌ها استفاده نمود.

جدول ۴- شاخص‌های آماری مورد استفاده برای ارزیابی کارایی مدل‌های مختلف شبکه عصبی.

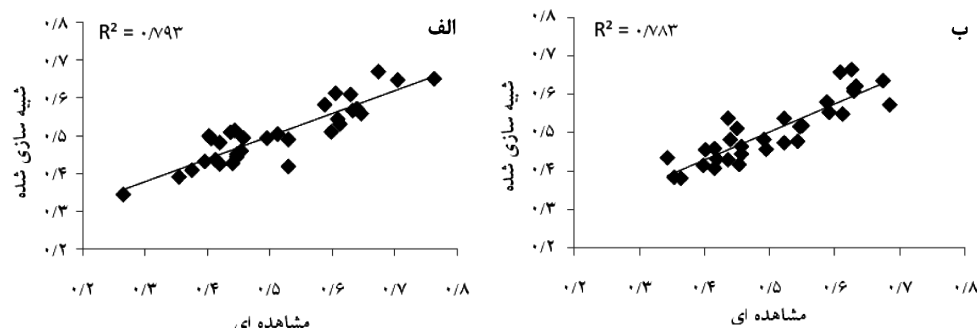
شاخص آماری			مدل
MEE	RMSE	r	
-۰/۰۰۵	۰/۰۵۸	۰/۸۹۱**	مدل ۱
-۰/۰۰۰۲	۰/۰۴۵	۰/۸۸۵**	مدل ۲

۲: ضریب هم‌بستگی، MEE: میانگین خطای تخمین، RMSE: ریشه میانگین مربعات خطا و \* معنی‌دار در سطح ۱ درصد.

مقادیر مشاهده‌ای و شبیه‌سازی شده مقاومت برشی خاک برای داده‌های تست در مدل‌های مختلف شبکه عصبی در شکل ۲ مقایسه شده‌اند. با توجه به این شکل مشخص است که در هر دو مدل در برخی از نقاط به صورت غیریکنواخت بیش برآوردی از مقاومت برشی خاک صورت گرفته و در برخی دیگر، مقاومت برشی خاک کم‌تر از مقدار مشاهده‌ای آن تخمین زده شده است. با این وجود با توجه به ضریب هم‌بستگی ( $R^2$ ) به نسبت مناسب بین مقادیر مشاهده‌ای و شبیه‌سازی شده مقاومت برشی خاک برای داده‌های تست دو مدل شبکه عصبی طراحی شده در این پژوهش (شکل ۳)، به نظر می‌رسد که بتوان از شبکه‌های عصبی مصنوعی برای مدل‌سازی و تخمین مقاومت برشی سطح خاک در منطقه استفاده نمود. در پژوهش‌هایی مشابه، گوکتپ و همکاران (۲۰۰۸) نیز گزارش نمودند که از شبکه‌های عصبی مصنوعی می‌توان به عنوان ابزاری مناسب برای برآورد مقاومت برشی خاک استفاده نمود. خلیل‌مقدم و همکاران (۲۰۰۹) از پارامترهای مختلف خاک و توپوگرافی برای برآورد مقاومت برشی خاک در منطقه زاگرس مرکزی به عنوان ورودی مدل‌های مختلف شبکه عصبی با ساختارهای متفاوت استفاده نمودند و بیشینه ضریب هم‌بستگی (۲) برابر ۰/۶۷ را گزارش نمودند.



شکل ۲- مقایسه مقادیر مشاهده‌ای و شبیه‌سازی شده مقاومت برشی خاک برای داده‌های تست مدل‌های مختلف شبکه عصبی (الف: مدل ۱ و ب: مدل ۲).



شکل ۳- همبستگی بین مقادیر مشاهده‌ای و شبیه‌سازی شده مقاومت برشی خاک برای داده‌های تست مدل‌های شبکه عصبی (الف: مدل ۱ و ب: مدل ۲).

### نتیجه‌گیری

نتایج این پژوهش نمایانگر آن بود که براساس نتایج آزمون گاما ۵ پارامتر درصد شن، شن ریز، شن خیلی ریز، NDVI و جهت شیب به‌عنوان ورودی‌های بهینه، بیش‌ترین قابلیت را در میان سایر پارامترهای اندازه‌گیری شده برای مدل‌سازی مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی داشتند. مدل شبکه عصبی طراحی شده با استفاده از این ورودی‌های بهینه، دقتی معادل با مدل شبکه عصبی طراحی شده با استفاده از همه پارامترهای ورودی داشت. بنابراین به‌نظر می‌رسد که از فن‌آوری آزمون گاما بتوان به‌عنوان روشی نوین برای تعیین بهینه‌ترین ترکیب ورودی‌ها برای رسیدن به بیش‌ترین دقت با صرف کم‌ترین هزینه و وقت در برآورد مقاومت برشی خاک با استفاده از شبکه‌های عصبی مصنوعی بهره برد. از سوی دیگر با توجه به همبستگی به‌نسبت مناسب بین مقادیر مشاهده‌ای و شبیه‌سازی شده مقاومت برشی خاک برای داده‌های تست دو مدل شبکه عصبی طراحی شده در این پژوهش، به‌نظر می‌رسد که شبکه‌های عصبی مصنوعی نیز توانایی به‌نسبت قابل‌قبولی در مدل‌سازی و تخمین مقاومت برشی سطح خاک در منطقه مورد مطالعه داشته باشند. با این وجود مطالعه امکان استفاده از سایر فن‌آوری‌های انتخاب ورودی‌های بهینه مانند الگوریتم‌های تکاملی<sup>۱</sup> (هم‌چون الگوریتم ژنتیک<sup>۲</sup>) و مقایسه نتایج به‌دست آمده از این فن‌آوری‌ها با آزمون گاما و نیز استفاده از دیگر ابزارهای مدل‌سازی در برآورد مقاومت برشی خاک مانند سیستم‌های نروفازی<sup>۳</sup> در پژوهش‌های آینده پیشنهاد می‌گردد.

1- Evolutionary Algorithms

2- Genetic Algorithm

3- Adaptive Neuro-Fuzzy Inference Systems, ANFIS

## منابع

1. Brunori, F., Penzo, M.C., and Torri, D. 1989. Soil shear strength: its measurement and soil detachability. *Catena*, 16: 59-71.
2. Franti, T.G., Laflen, J.M., and Watson, D.A. 1999. Predicting soil detachment from high discharge concentrated flow. *Trans. ASAE*, 42: 329-335.
3. Gee, G.W., and Bauder, J.W. 1986. Particle size analysis, P 383-411. In: Klute, A. (Ed.), *Methods of Soil Analysis: Part 1. Agronomy Handbook No 9*. American Society of Agronomy and Soil Science Society of America, Madison, WI.
4. Goktepe, A.B., Altun, S., Altintas, G., and Tan, O. 2008. Shear strength estimation of plastic clays with statistical and neural approaches. *Build. Environ.* 43: 849-860.
5. Horn, R., Fleige, H., Richter, F.H., Czyz, E.A., Dexter, A., Diaz-Pereira, E., Dumitru, E., Enarache, R., Mayol, F., Rajkai, K., De la Rosa, D., and Simota, C. 2005. SIDASS project, Part 5: Prediction of mechanical strength of arable soils and its effects on physical properties at various map scales. *Soil Till. Res.* 82: 47-56.
6. Kemper, W.D., and Rosenau, K. 1986. Size distribution of aggregates, P 425-442. In: Klute, A. (Ed.), *Methods of Soil Analysis: Part 1: Physical and Mineralogical Methods*, American Society of Agronomy, Madison, WI.
7. Khalilmoghadam, B. 2009. Estimation of shear strength, hydraulic conductivity, and soil infiltration rate using pedotransfer functions (artificial neural networks). Ph.D. Thesis, Department of Soil Science, Collage of Agriculture, Isfahan University of Technology, Isfahan, Iran, 169p. (In Persian)
8. Khalilmoghadam, B., Afyuni, M., Abbaspour, K.C., Jalalian, A., Dehghani, A.A., and Schulin, R. 2009. Estimation of surface shear strength in Zagros region of Iran-A comparison of artificial neural networks and multiple-linear regression models. *Geoderma*, 153: 29-36.
9. Leonard, J., and Richard, G. 2004. Estimation of runoff critical shear stress for soil erosion from soil shear strength. *Catena*, 57: 233-249.
10. Menhaj, M. 2001. Acquaintanceship with artificial neural networks. Sharif Univ. Press, Tehran, Iran, 137p. (In Persian)
11. Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S., and Han, D. 2009. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advance. Water Res.* 32: 88-97.
12. Mosaddeghi, M.R., Hajabbasi, M.A., and Khademi, H. 2006. Tensile strength of sand, palygorskite, and calcium carbonate mixtures and interpretation with the effective stress theory. *Geoderma*, 134: 160-170.
13. Nelson, D.W., and Sommers, L.P. 1986. Total carbon, organic carbon and organic matter, P 539-579. In: Page, A.L. (Ed.), *Methods of Soil Analysis: Part 2: Agronomy Handbook No 9*, American Society of Agronomy and Soil Science Society of America, Madison, WI.



14. Nelson, R.E. 1982. Carbonate and gypsum, P 181-197. In: Page, A.L. (Ed.), Methods of Soil Analysis: Part I: Agronomy Handbook No 9, American Society of Agronomy and Soil Science Society of America, Madison, WI.
15. Rauws, G., and Govers, G. 1988. Hydraulic and soil mechanical aspects of till generation on agricultural soils. J. Soil Sci. 39: 111-124.
16. Safamanesh, R. 1996. Comprehensive studies of Bazoft watershed, Chaharmahal Bakhtiary province. Part 7: Soil erosion and sediment, 153p. (In Persian)
17. Vafaieyan, M. 1997. Soil engineering properties. Nashr Arkan Press, Isfahan, Iran. (In Persian)
18. Van Bavel, C.H.M. 1950. Mean-weight diameter of soil aggregates as a statistical index of aggregation. Soil Sci. Soc. Am. Proc. 14: 20-23.



Gorgan University of Agricultural  
Sciences and Natural Resources

*J. of Water and Soil Conservation, Vol. 20(1), 2013*  
<http://jwsc.gau.ac.ir>

## **Use of Gamma test technique for choosing the optimum input variables in modeling of soil shear strength using artificial neural networks**

**\*A.A. Besalatpour<sup>1</sup>, M.A. Hajabbasi<sup>2</sup> and Sh. Ayoubi<sup>3</sup>**

<sup>1</sup>Ph.D. Student, Dept. of Soil Science, Isfahan University of Technology,

<sup>2</sup>Professor, Dept. of Soil Science, Isfahan University of Technology,

<sup>3</sup>Associate Prof., Dept. of Soil Science, Isfahan University of Technology

Received: 10/19/2010; Accepted: 04/16/2012

### **Abstract**

Gamma test is an appropriate tool for determining the optimum input combination and suitable number of data to achieve minimum mean square error in any continuous nonlinear modeling approaches. In this study, at first Gamma test technique was used to determine the optimum input variables from measured input parameters (including soil properties, topographic and vegetation attributes) affecting soil shear strength (SSS) prediction. Two different artificial neural network (ANN) models were then constructed using different input data (Models 1 and 2) to predict SSS. In Model 1, all of the measured parameters (12 parameters) were used as input variables of the model and Model 2 was constructed using only the optimum 5 parameters resulted from the Gamma test trails. According to the Gamma test trail results, fine sand and mean weight diameter (MWD) parameters had the lowest and highest Gamma and  $\nu$ -ratio values among the other parameters, respectively. Furthermore, the vegetation index (NDVI), sand, very fine sand, and aspect parameters had a Gamma values of 0.2177, 0.2280, 0.2313, and 0.2318 in comparison with the other investigated parameters, respectively. Therefore, sand, fine sand, very fine sand, NDVI, and aspect parameters were selected as the optimum 5 input variables for modeling of SSS using ANNs. The proposed ANN model using the optimum 5 input variables, selected from the Gamma test trails (Model 2), had a similar accuracy with the proposed ANN model using all of the 12 input variables (Model 1). The correlation coefficient ( $r$ ) and root mean square error (RMSE) values for Model 2 were 0.885 and 0.045, respectively, while these indices for Model 1 were 0.891 and 0.058, respectively. Therefore, it appears that the Gamma test technique can be used for choosing optimum input variables affecting SSS prediction to reduce experimental expenses and to save a great amount of time and effort in modeling approaches.

**Keywords:** Gamma test, Soil mechanical properties, Artificial neural networks, Modeling

---

\* Corresponding Author; Email: [a\\_besaaltpour@yahoo.com](mailto:a_besaaltpour@yahoo.com)