



برآورد مقاومت فروروی در خاک‌های زراعی دشت اردبیل با استفاده از توابع انتقالی رگرسیونی و شبکه عصبی مصنوعی

غلام رضا شیخ‌زاده^۱ - شکراله اصغری^{۲*} - ترحم مصری گندشمن^۳

تاریخ دریافت: ۱۳۹۳/۰۹/۱۹

تاریخ پذیرش: ۱۳۹۴/۰۵/۲۸

چکیده

مقاومت فروروی (PR) یکی از پویاترین ویژگی‌های مکانیکی خاک است که عملیات خاک‌ورزی، رشد گیاه و فعالیتهای بیولوژیکی خاک را تحت تاثیر قرار می‌دهد. اندازه‌گیری مستقیم این متغیر دشوار، زمان بر و پرهزینه است. هدف از تحقیق حاضر ارائه توابع انتقالی رگرسیونی و شبکه عصبی مصنوعی برای برآورد PR خاک بر پایه متغیرهای زودیافت شامل توزیع اندازه ذرات، کربن آلی، جرم مخصوص ظاهری و حقیقی، کربنات کلسیم معادل، تخلخل کل و رطوبت اولیه خاک مزروعه بود. به این منظور ۱۰۵ نمونه از عمق ۰ تا ۱۰ سانتی‌متر خاک‌های زراعی دشت اردبیل برداشته شد سپس برخی ویژگی‌های فیزیکی و شیمیایی آن‌ها تعیین گردید. داده‌ها به دو سری آموزشی (۷۸ نمونه) و آزمونی (۲۷ نمونه) تقسیم شدند. برای اشتراق توابع انتقالی رگرسیونی و شبکه عصبی به ترتیب از نرم افزارهای 18 SPSS و MATLAB استفاده گردید. نتایج توابع رگرسیونی و شبکه عصبی نشان داد که مناسب‌ترین متغیرها در برآورد PR خاک، رطوبت اولیه مزروعه، جرم مخصوص ظاهری و توزیع اندازه ذرات خاک بودند. مقادیر ضریب تبیین (R^2)، مجدور میانگین مربعات خطأ (RMSE) و معیار اطلاعات آکائیک (AIC) (برابر 0.055 MPa، 0.091 MPa و 0.076 MPa) به ترتیب برای مناسب‌ترین تابع رگرسیونی و شبکه عصبی به دست آمد. بنابراین دقت توابع شبکه عصبی در برآورد PR خاک منطقه مورد مطالعه بیشتر از توابع رگرسیونی بود.

واژه‌های کلیدی: تخمین، رطوبت اولیه، فشردنگی خاک، متغیر زودیافت

مقاومت زیاد خاک در برابر فروروی، رشد گیاه را محدود می‌سازد (۸)، هدایت هیدرولیکی و نفوذپذیری خاک را کاهش، روان آب و تلفات خاک را افزایش داده و اثر نامطلوبی بر کیفیت محیط زیست دارد (۱۷). مقاومت فروروی به متغیرهای زیادی مانند تراکم، تخلخل، بافت و ساختمان، عوامل سیمانی کننده، ماده آلی و رطوبت خاک بستگی دارد (۱۸) اما اغلب تحت تاثیر جرم مخصوص ظاهری و رطوبت خاک مزروعه می‌باشد (۳۵). البته برخی محققان رابطه قوی بین مقاومت فروروی و توزیع اندازه ذرات خاک را نیز گزارش کرده‌اند (۳۲).

اندازه‌گیری مستقیم PR خاک به علت خطای ابزاری، کاری وقت‌گیر و پرهزینه می‌باشد لذا محققان از مدل‌های مختلف رگرسیونی و شبکه عصبی مصنوعی برای تخمین این پارامتر از روی ویژگی‌های زود یافته خاک استفاده کرده‌اند که به آن‌ها توابع انتقالی خاک^۱ (PTFs) گفته می‌شود. شبکه‌های عصبی مصنوعی، یک ابزار

مقدمه

خصوصیات فیزیکی خاک نظریه مقاومت فروروی^۲ (PR) می‌تواند برای ناظارت و ارزیابی کیفیت خاک مورد استفاده قرار گیرد. مقاومت فروروی در رشد گیاه تأثیر می‌گذارد و آن می‌تواند به عنوان پارامتری برای ارزیابی اثر سیستم خاک‌ورزی بر محیط ریشه، آگاهی از سطح فشردنگی، تعیین نقش نیروهای لازم برای انجام فرایندهای مکانیکی و جلوگیری از موافع فیزیکی ظاهری که می‌تواند توسعه گیاهان را کاهش دهد مورد استفاده قرار گیرد (۹ و ۱۱). مقاومت فروروی یکی از پویاترین ویژگی‌های مکانیکی خاک است و اطلاع از آن برای شخم، رشد گیاه و فعالیتهای بیولوژیکی خاک مهم می‌باشد (۱۲).

۱ و ۲- دانشجوی سابق کارشناسی ارشد و دانشیار گروه علوم و مهندسی خاک، دانشکده

کشاورزی و منابع طبیعی، دانشگاه محقق اردبیل

(*)- نویسنده مسئول: shasghari@uma.ac.ir

۳- دانشیار گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق

اردبیلی

4- Penetration resistance

این مدل‌ها در برآورد PR با استفاده از محک‌های آماری مثل ضریب تبیین^۱ (R^2)، جذر میانگین مربعات خطأ^۲ (RMSE)، معیار اطلاعات آکائیک^۳ (AIC) و میانگین خطأ^۴ (ME) بود.

مواد و روش‌ها

نمونه‌های دستخورده به مقدار حدود ۳ کیلوگرم و نمونه‌های دستخورده با استفاده از استوانه‌های فولادی به قطر و ارتفاع ۵ سانتی متر از عمق ۰-۱۰ سانتی متری خاک در ۱۰۵ نقطه از زمین‌های زراعی دشت اردبیل واقع در ۱۵° و ۳۸° تا ۴۰° و ۳۸° عرض شمالی و ۱۶° و ۴۸° تا ۶۱° و ۴۸° طول شرقی به فواصل حدود ۳۰۰۰ متر و به طور تصادفی-منظمه در ماههای خرداد تا شهریور ۱۳۹۲ برداشته شد. موقعیت هر یک از نقاط نمونه‌برداری شده با استفاده از دستگاه موقعیت‌یاب جهانی^۵ (GPS) ثبت گردید (شکل ۱). کاربری اراضی منطقه، زراعی و محصول غالب کشت شده، سیب زمینی، گندم، چغندر قند و یونجه بود. نمونه‌های دستخورده در آزمایشگاه هوا خشک گردید و از الک ۲ میلی‌متری به منظور اندازه‌گیری مقادیر شن، سیلت، رس، جرم مخصوص حقیقی (D_p)، کربن آلی و کربنات کلسیم معادل عبور داده شد. جرم مخصوص ظاهری (D_b) به روش استوانه (۶) و رطوبت اشباع به روش وزنی (۱۴) در همان استوانه‌ها اندازه‌گیری شد. توزیع اندازه ذرات شن، سیلت و رس به روش هیدرومتری^۶ قراتبه (۱۵)، جرم مخصوص حقیقی به روش پیکنومتر (۷)، کربن آلی به روش والکلی و بلک (۳۷)، کربنات کلسیم معادل به روش تیتراسیون با اسید (۳۱) اندازه‌گیری شد. تخلخل کل (n) از رابطه $n = \frac{D_b}{D_p}$ محاسبه شد. پارامترهای میانگین هندسی قطر (d_g) و انحراف استاندارد هندسی (s_g) ذرات خاک از روی درصدهای شن، سیلت و رس محاسبه گردید (۱۰). مقاومت فروروی (PR) خاک به طور مستقیم در مزرعه با استفاده از دستگاه فرسنچ مخروطی مدل عقریه‌ای ساخت شرکت اکل کمپ کشور هلند در ۱۰ تکرار اندازه‌گیری شد. بر اساس تحقیقات قبلی انعام گرفته (۴، ۲۰ و ۳۶) رطوبت خاک مزرعه یکی از متغیرهای مستقل و موثر در برآورد PR می‌باشد لذا در تحقیق حاضر نیز رطوبت خاک مزرعه در حین اندازه‌گیری PR با استفاده از استوانه‌های خاک و پس از آون خشک کردن در دمای 105°C به روش وزنی تعیین گردید.

1- Determination coefficient

2- Root mean square error

3- Akaike information criterion

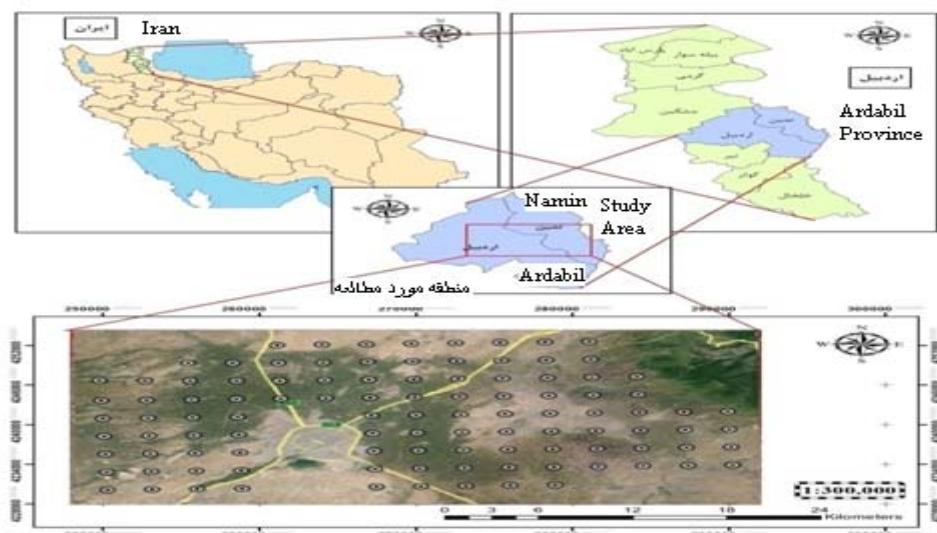
4- Mean error

5- Global positioning system

قدرتمند برای تجزیه و تحلیل داده‌ها و مدل‌سازی روابط غیرخطی به حساب می‌آیند که استفاده از آن‌ها طی سال‌های گذشته در مدل‌سازی فرآیندهای پیچیده گسترش یافته است. در واقع توابع شبکه عصبی مصنوعی با استفاده از توابع و پردازشگرهای ریاضی به شبیه سازی عملکرد مغز انسان می‌پردازند و قادرند روابط ناشناخته و به شدت غیرخطی را مدل‌سازی کنند. یکی از کاربردهای شبکه عصبی همانند رگرسیون برای تقریب توابع چند متغیره و یافتن ارتباط میان متغیرهای مستقل (زود یافت) ووابسته (دیرافت) می‌باشد. با این تفاوت که شبکه عصبی مصنوعی در مقایسه با روش‌های آماری پارامتریک هیچ پیش فرضی در مورد توزیع داده‌ها ندارد و از این نظر نسبت به تبیین متغیرهای وابسته از مزیت نسبی در مقایسه با روش‌های آماری برخوردارند (۲۵). شبکه عصبی مصنوعی یک سیستم غیرخطی است که بدون داشتن اطلاعات کامل از نحوه ارتباط پارامترها و قوانین حاکم بین آن‌ها، سیستم‌های مختلف را شبیه سازی می‌کند (۲۶ و ۲۲).

بیات و همکاران (۴) روش‌های شبکه عصبی مصنوعی و رگرسیون‌های خطی و غیرخطی را برای مدل‌سازی PR خاک با هم مقایسه کردند. آنها شبکه‌های عصبی مصنوعی را ابزار قدرتمندتری در مقایسه با رگرسیون برای تخمین شاخص مخروطی از روی رطوبت مزرعه، تخلخل کل و درجه اشباع نسبی (نسبت رطوبت اشباع به تخلخل کل) خاک گزارش نمودند. واژ و همکاران (۳۶) نشان دادند که بهترین نتیجه برای تخمین PR زمانی حاصل شد که از رطوبت مزرعه و جرم مخصوص ظاهری خاک به عنوان متغیرهای ورودی استفاده گردید. سانتوس و همکاران (۳۴) PR خاک را با استفاده از روش‌های رگرسیونی و شبکه عصبی مصنوعی برآورد کردند. آنها بیان کردند که PR با جرم مخصوص ظاهری و رطوبت مزرعه در ارتباط است و مقدار زیاد PR در مقادیر زیاد جرم مخصوص ظاهری و کم رطوبت مزرعه رخ می‌دهد. جره و همکاران (۲۰) گزارش کردند که افزودن پارامترهای فراکتالی، به ورودی‌های مرسوم برآورد کننده PR خاک (Germ مخصوص ظاهری و رطوبت مزرعه) باعث بهبود معنی‌دار معیارهای ارزیابی صحت مدل‌های رگرسیونی شد. همچنین بکارگیری پارامترهای کیفی ساختمان خاک به همراه پارامترهای فراکتالی توزیع اندازه ذرات باعث بهبود معنی‌دار پیش‌بینی PR شد.

اگرچه PTF‌های مختلفی برای برآورد PR خاک در داخل و خارج از کشور ارائه شده است ولی این PTF‌ها در دیگر نواحی همیشه با دقت قابل قبولی کاربرد ندارند. با توجه به اینکه استان اردبیل، قطب تولید سیب‌زمینی کشور می‌باشد اطلاع از PR که شاخصی از فشردگی خاک است به مدیریت تولید این محصول استراتژیک کمک می‌نماید. هدف از تحقیق حاضر ارائه مدل‌هایی برای برآورد مقاومت فروروی از روی متغیرهای زودیافت در خاک‌های زراعی دشت اردبیل با استفاده از روش‌های رگرسیونی و شبکه عصبی مصنوعی و نیز ارزیابی دقت



شکل ۱- موقعیت جغرافیایی و نقشه‌ی توزیع نقاط نمونه‌برداری در تصویر ماهواره‌ای منطقه مورد مطالعه
Figure1- Geographic position and distribution map of sampled points in satellite image of the studied area

رگرسیونی و شبکه‌های عصبی مصنوعی با استفاده از معادله ۱ به-
دست آمد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{i(p)} - Y_{i(m)})^2}{n}} \quad (1)$$

از لحاظ آماری حداقل مقدار RMSE برابر صفر بوده و زمانی است که مقادیر پیش بینی شده با مقادیر اندازه‌گیری شده PR برابر باشند. هر چقدر مقادیر این معیار کمتر باشد، برآوردهای انجام شده توسط تابع تخمین زننده دارای دقت بیشتری خواهد بود. همچنین برای بیان این که یک تابع از نظر تخمین، PR را بیشتر از مقدار واقعی یا کمتر از آن پیش بینی می‌کند از معیار ME (معادله ۲) استفاده شد. مقادیر مثبت این معیار نشان می‌دهد که تابع، PR را بیشتر از مقدار واقعی برآورد می‌کند و مقادیر منفی آن نشان می‌دهد که تابع، PR را کمتر از مقدار واقعی برآورد می‌کند.

$$ME = \frac{\sum_{i=1}^n Y_{i(p)} - Y_{i(m)}}{n} \quad (2)$$

در معادله‌های ۱ و ۲ و $Y_{i(p)}$ و $Y_{i(m)}$ به ترتیب مقادیر اندازه‌گیری و برآورد شده PR توسط تابع و n تعداد داده‌ها برای PR می‌باشد. به دلیل این که تعداد متغیرهای ورودی در PTF های برآورد کننده PR متفاوت بود از معیار AIC نیز برای ارزیابی دقت توابع استفاده گردید. این آماره طبق معادله ۳ محاسبه شد.

$$AIC = n \ln\left(\frac{ESS}{n}\right) + 2q \quad (3)$$

در رگرسیون خطی چندگانه، گام اول در تجزیه و تحلیل داده‌ها، آزمون نرمال بودن داده‌ها می‌باشد؛ ولی شبکه‌های عصبی مصنوعی، جزو روش‌های تحلیل ناپارامتری بوده و بر پیش‌فرض نرمال بودن توزیع داده‌ها استوار نیستند (۲۵). برای بررسی نرمال بودن داده‌ها از آزمون کولموگروف - اسمیرنوف^۱ استفاده شد. آزمون نرمال بودن داده‌ها نشان داد که توزیع همه متغیرهای به کار رفته در تحقیق به جز رطوبت مزرعه و مقاومت فرورویی نرمال بود لذا برای نرمال سازی متغیرهای مذکور از تبدیل لگاریتمی استفاده شد. اشتاقاق معادلات رگرسیونی خطی چندگانه به روش گام به گام در نرم‌افزار SPSS18 و MATLAB ایجاد مدل‌های شبکه عصبی مصنوعی با نرم‌افزار و الگوریتم لونبرگ- مارکوارت انجام گردید. همچنین از مومنتوم به منظور پرش از مینیمم‌های محلی استفاده شد. تابع فعال ساز تائزانت سیگموندی و ساختار پرسپترون سه لایه شامل ۱۱، ۸ و ۱۵ نرون در لایه پنهان به کار گرفته شد. بعد از آموزش شبکه با داده‌های سری آموزشی (۷۸ نمونه) و فریز نموند شبکه بعد از آزمون اعتبارسنجی آموزش، مابقی داده‌ها (شامل داده‌های آزمونی و اعتباری به تعداد ۲۷ نمونه) برای ارزیابی شبکه مورد تحلیل قرار گرفت.

معیارهای ارزیابی توابع انتقالی
به منظور مقایسه دقت توابع انتقالی پیش بینی کننده PR، از معیارهای AIC , ME , $RMSE$, R^2 و AIC استفاده گردید (۴ و ۳۴). مقادیر RMSE برای داده‌های مورد استفاده در آموزش و آزمون توابع

۱ آورده شده است. با توجه به این جدول، متغیرهای مورد استفاده دارای پراکندگی مناسبی هستند. براساس توزیع اندازه ذرات شن، سیلت و رس (جدول ۱)، خاک‌های مورد مطالعه دارای کلاس بافت شن‌لومی (۸ نمونه)، لوم‌شنبی (۲۰ نمونه)، لوم (۶ نمونه) و لوم سیلتی (۲۱ نمونه) بودند (شکل ۲). بنابراین خاک منطقه مورد مطالعه دارای بافت درشت تا متوسط بود.

باتوجه به جدول ۱ مشاهده می‌شود که در خاک‌های زراعی دشت اردبیل همانند سایر خاک‌های مناطق خشک و نیمه‌خشک ایران، میانگین کربن آلی کم و در حدود یک درصد است. ناچیز بودن مقدار کربن آلی و نیز بالا بودن مقدار سیلت (حدود ۳۹ درصد) در این خاک‌ها، باعث گردیده است به علت نایابی‌داری ساختمان خاک، میزان مقاومت فروروی (PR) زیاد و به طور میانگین برابر حدود ۲/۷۵ مگاپاسکال در شرایط رطوبت مزرعه با متوسط مقدار ۱۱ درصد وزنی باشد.

n تعداد داده‌ها، ESS مجموع مربعات خطأ و q تعداد متغیرهای ورودی هر PTF می‌باشد. هرچه AIC کوچکتر باشد، دقیق‌تر آن PTF بیشتر خواهد بود.

از میان PTF‌های اشتراق یافته برای برآورد PR، مناسب‌ترین PTF رگرسیونی و شبکه عصبی با ترکیب متغیرهای ورودی در داده‌های آموزشی تعیین گردید. آزمون توابع در تشخیص دقیق مدل به ازای داده‌هایی که در آموزش مدل استفاده نشده‌اند به کار می‌رود و الزاماً بهترین تابع در داده‌های آموزشی، نمی‌تواند بهترین تابع در داده‌های آزمونی نیز باشد (۳ و ۲).

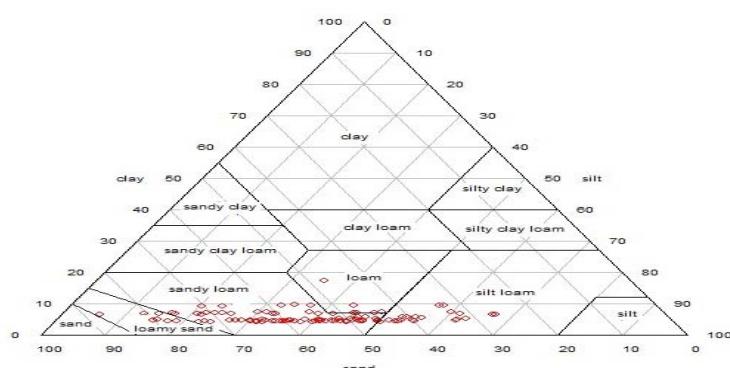
نتایج و بحث

آماره‌های توصیفی متغیرهای اندازه‌گیری شده در خاک‌های زراعی دشت اردبیل برای داده‌های آموزشی و آزمونی به کار رفته در توسعه و ارزیابی توابع انتقالی رگرسیونی و شبکه‌های عصبی در جدول

جدول ۱- آماره‌های توصیفی متغیرهای اندازه‌گیری شده.
Table 1- Descriptive statistics of the measured variables.

متغیر Variable	آموزش Training				آزمون Testing			
	Min.	Max.	Mean	Sd.	Min.	Max.	Mean	Sd.
$\theta_f (\% \text{ g g}^{-1})$	4.79	31.34	10.68	5.15	4.56	33.18	11.96	6.55
$D_b (\text{g cm}^{-3})$	1.02	1.63	1.27	0.11	1.03	1.44	1.24	0.11
$\theta_s (\% \text{ g g}^{-1})$	25.23	73.67	50.01	9.07	32.83	71.57	52.26	9.71
Clay (%)	3.99	17.34	5.8	2.02	4.07	9.1	5.32	1.45
Silt (%)	5.99	66.8	39.24	13.1	15.21	67.18	38.31	14.49
Sand (%)	26.87	87.43	54.96	13.2	26.26	80.22	56.37	14.21
$d_g (\text{mm})$	0.05	0.56	0.2	0.1	0.07	0.48	0.21	0.11
$\sigma_g (-)$	4.69	12.15	6.83	0.95	4.86	8.11	6.55	0.8
OC (%)	0.3	2.41	1.09	0.41	0.47	1.82	1.14	0.37
CaCO_3 (%)	3.45	26.99	12.77	5.17	5.31	15.76	10.58	3
$D_p (\text{g cm}^{-3})$	2	2.57	2.27	0.13	2.04	2.46	2.27	0.11
n (%)	26.12	55.62	44	175	37.22	56.78	45.46	5.16
PR (MPa)	1.1	6.6	2.86	1.4	1.23	2.07	2.7	1.33

روطیت مزرعه (θ_f : field water content), جرم مخصوص ظاهری (D_b : bulk density)، جرم مخصوص اشباع (θ_s : saturated water content)، اندماج میانگین هندسی قطر ذرات (d_g : geometric mean diameter)، اندماج اسیانداره هندسی ذرات (D_p : geometric standard deviation)، کربن آلی (OC)، کربن کلسیم معادل (CaCO_3 : total porosity)، حداکثر تخلخل کل (PR)، مقدار فروروی خاک (n)، حداکثر مخصوص حقیقی (Mean)، حداکثر مخصوص اندماج (Max)، اندماج اسیانداره (Sd)، میانگین (Min)، حداکثر (Max).



شکل ۲- توزیع کلاس بافت در خاک‌های مورد مطالعه.

Figure 2- Distribution of textural class in the studied soils.

جدول ۲- ضریب همبستگی پیرسون (r) بین متغیرهای مستقل (زویده‌یافت) خاک
Table 2- Pearson correlation (r) between independent variables

متغیر Variable	n	D _p	CaCO ₃	OC	σ_g	dg	sand	silt	clay	θ_s	D _b
θ_f	0.33**	-0.21*	0.17	0.39**	-0.13	0.03	-0.03	0.03	-0.02	0.32**	-0.42**
D _b	-0.81**	0.22*	-0.14	-0.46**	0.18	-0.01	-0.01	-0.01	0.13	-0.68**	1
θ_s	0.44**	-0.34**	0.16	0.32**	-0.13	-0.04	-0.07	-0.08	-0.12	1	
clay	-0.18	-0.09	0.01	-0.01	0.76**	-0.11	-0.05	-0.05	-0.09	1	
silt	-0.13	-0.24*	0.36**	-0.06	0.19	-0.92**	-0.99**	1			
sand	0.16	0.25*	-0.37**	0.06	-0.30**	0.94**	1				
dg	0.19*	0.32**	0.36**	0.02	-0.50**	1					
σ_g	-0.29*	-0.19*	0.10	-0.01	1						
OC	0.32**	-0.19*	-0.05	1							
CaCO ₃	-0.01	-0.23*	1								
D _p	0.38**	1									

* و **: به ترتیب معنی دار در سطح احتمال ۱ و ۵ درصد. توصیف متغیرها در زیر جدول ۱ آورده شده است.

Variables description is available under Table 1. *: **: Significant at P < 0.05 and P < 0.01, respectively.

مستقل (زویده‌یافت) نشان داد که بین هر یک از متغیرهای جرم مخصوص ظاهری با تخلخل کل و رطوبت اشیاع، رس با انحراف استاندارد هندسی (σ_g)، سیلت با شن و میانگین هندسی قطر ذرات (dg) همبستگی خطی قوی ($r > 0.60$) وجود دارد، لذا برای اجتناب از هم راستایی چندگانه^۱ از این متغیرها به همراه یکدیگر برای ایجاد PTF های رگرسیونی به منظور تخمین PR در یکتابع استفاده^۲ نگردید. همچنین نتایج آنالیز هم خطی حداکثر فاکتور تورم واریانس (VIF) PTF های مربوطه (جدول ۴) مقادیر کمتر از ۵ را نشان دادند که مقدار حداکثر آن در تحقیق حاضر $1/95$ بدست آمد. اگر این آماره برای یک متغیر کمتر از ۵ یا ۱۰ باشد آن متغیر در مدل وارد می‌گردد

خاک‌هایی که مقدار مواد آلی زیادی دارند، سخت نمی‌شوند، ولی خاک‌هایی که مقدار مواد آلی آنها کمتر از ۲ درصد باشد، در برابر تنش‌های ناشی از مرتبط شدن سریع، ناپایدارند (۸). اگر PR خاک از ۲ فراتر رود به علت کاهش تخلخل تهیه‌ای خاک به زیر ۱۰ MPa درصد، در جوانه زنی و رشد اکثر گیاهان محدودیت ایجاد می‌شود (۱۲ و ۳۸). متوسط کربنات کلسیم معادل در خاک‌های مورد مطالعه حدود ۱۱ درصد است (جدول ۱). لذا این خاک‌ها آهکی بوده و انتظار می‌رود قابلیت جذب عناصر مثل فسفر، آهن، روی و منگنز در آن‌ها پایین باشد. مقدار زیاد PR خاک‌های مورد مطالعه می‌تواند ناشی از بالا بودن کربنات کلسیم نیز باشد؛ زیرا ذرات ریز کربنات کلسیم در خاک، می‌توانند مانند ذرات رس در افزایش مقاومت فروروی نقش ایفا کنند (۲۷ و ۲۸).

مقادیر ضریب همبستگی پیرسون (جدول ۲) بین متغیرهای

1- Multicollinearity

2- Variance inflation factor

ذرات خاک هستند لذا با افزایش آنها در خاک می‌توان انتظار داشت که PR نیز افزایش یابد.

به طور کلی ۱۵ تابع رگرسیونی برای برآورد PR خاک با استفاده از متغیرهای زودیافت تشكیل شد (جدول ۴). در جدول ۵ نیز مقادیر آماره‌های RMSE² و AIC برای ارزیابی این توابع از نظر دقت برآورد PR ارائه گردیده است. لازم به ذکر است چون R^2 در ارزیابی اعتبار توابع می‌تواند فریب دهنده باشد و R^2 نزدیک به ۱ الزاماً دلالت بر انطباق مقادیر اندازه‌گیری شده با پیش‌بینی شده متغیر نیست یعنی بالا بودن R^2 دلیلی بر کمتر بودن خطای نیست (۸ و ۱۸) لذا در تحقیق حاضر رتبه‌بندی توابع بر مبنای پایین بودن RMSE و AIC انجام گرفت. بر اساس میارهای RMSE و AIC داده‌های آموزشی، تابع شماره ۱۰ (جدول ۵) با متغیرهای ورودی رطوبت مزرعه (θ_f) و تخلخل کل (n) از نظر برآورد PR دارای دقت بالاتری در مقایسه با سایر توابع بود. مقادیر R^2 AIC و RMSE ME این تابع برای داده‌های آموزشی به ترتیب برای ۰/۵۵، ۰/۸۹ و ۰/۱۶ و ۰/۱۶-۰/۰۵ و برای داده‌های آزمونی برابر ۰/۴۱، ۰/۴۱ و ۰/۱۷ بود (جدول ۵). مقادیر مثبت ME برای داده‌های آموزشی و آزمونی بیان گر برآورد بیشتر از مقدار واقعی PR خاک توسط تابع شماره ۱۰ می‌باشد. همچنین معادله رگرسیونی این تابع (جدول ۴) نشان می‌دهد که تاثیر متغیر θ_f به علت داشتن ضریب رگرسیونی بالاتر در تخمین PR به مراتب بیشتر از متغیر n است. در رتبه بعدی، تابع ۱۱ با متغیرهای ورودی θ_f , n و میانگین هندسی قطر ذرات (d_g) و تابع ۹ با متغیرهای ورودی θ_f , n , انحراف استاندار هندسی ذرات (۵g) و کربن آلی (OC) دارای دقت بیشتری در برآورد PR بودند (جدول ۵).

متغیرهای ورودی بهترین توابع رگرسیونی در جدول ۵ نشان می‌دهد که در منطقه مورد مطالعه، رطوبت اولیه مزرعه، تخلخل کل، میانگین هندسی قطر و انحراف استاندار هندسی ذرات خاک، مهم‌ترین متغیرهای زودیافت در برآورد مقاومت فروروی بودند. لاپوسکی و همکاران (۲۳) نشان دادند که با افزایش رطوبت خاک مقدار مقاومت فروروی خاک کاهش می‌یابد و جرم مخصوص ظاهری مهم‌ترین متغیر در برآورد مقاومت فروروی خاک می‌باشد.

و در غیر این صورت، باید از مدل حذف گردد.

نتایج توابع رگرسیونی برای برآورد مقاومت فروروی خاک

مقادیر ضریب همبستگی پیرسون بین مقاومت فروروی (PR) با متغیرهای مستقل یا زودیافت خاک در جدول ۳ نشان داده شده است. بیش‌ترین همبستگی مثبت و معنی‌دار (-0.655^{**}) بین D_b PR با پیدا شد. مقاومت فروروی و جرم مخصوص ظاهری هر دو شاخصی از فشردگی خاک هستند لذا رابطه مستقیم بین آنها وجود دارد. به عبارت دیگر با افزایش جرم مخصوص ظاهری به دلیل کاهش حجم منفذ خاک، فشردگی خاک و درنتیجه مقاومت در برابر نفوذ فرسنجه مخروطی افزایش یافته است. بین PR با رطوبت اولیه مزرعه (-0.465^{**})، تخلخل کل (-0.455^{**}) و کربن آلی (-0.43^{**}) همبستگی منفی و معنی‌دار یافت شد. با افزایش رطوبت، تخلخل و کربن آلی به علت ایجاد ساختمان نرم در خاک از مقاومت فروروی آن کاسته می‌شود. افزودن مواد آلی به خاک به علت ایجاد حالت پوکی می‌تواند PR خاک را کاهش دهد (۱۹). اوهیو و همکاران (۳۰) گزارش کردند که کاربرد مواد آلی سبب کاهش جرم مخصوص ظاهری، مقاومت فروروی و برشی خاک شد و به طور کلی تراکم پذیری خاک با افزودن مواد آلی، به طور معنی‌دار کاهش یافت؛ این تأثیر بهخصوص در خاک‌های سنگین بافت (رسی) که عملیات کشاورزی در آنها در رطوبت‌های بالا و پایین مشکل است باعث سهولت مدیریت خاک گردید. بیان و همکاران (۴) نیز بین PR خاک با رطوبت مزرعه، همبستگی منفی و معنی‌دار و با جرم مخصوص ظاهری گرفتند که جرم مخصوص ظاهری مؤثرترین پارامتر در بین متغیرهای خاک برای برآورد مقاومت فروروی می‌باشد. همچنین جدول ۳ نشان می‌دهد که همبستگی PR با سیلت، رس، جرم مخصوص حقیقی و کربنات کلسیم معادل مثبت و با شن منفی و معنی‌دار گردید. در یک رطوبت و جرم مخصوص ظاهری ثابت، PR با کاهش اندازه ذرات خاک تمايل به افزایش دارد (۲۴). دلیل این افزایش بالا بودن تنش مؤثر در نتیجه پایین بودن پتانسیل ماتریک در خاکی با بافت رسی باشد (۲۹). رس و آهک از عوامل سیمانی کننده

جدول ۳- ضریب همبستگی پیرسون (r) بین متغیرهای مستقل (زودیافت) با مقاومت فروروی (PR) خاک

Table 3- Pearson correlation (r) between penetration resistance and independent variables

Variable	متغیر	n	D_p	$CaCO_3$	OC	sand	silt	clay	θ_s	D_b	f
PR		-0.589**	0.266*	0.290**	-0.465**	-0.505**	0.447**	0.330**	-0.048	0.655**	-0.63**

* و **: به ترتیب معنی‌دار در سطح احتمال ۱ و ۵ درصد. توصیف متغیرها در زیر جدول ۱ آورده شده است.

Variables description is available under Table 1. * , **: Significant at $P < 0.05$ and $P < 0.01$, respectively.

جدول ۴- توابع رگرسیونی اشتراق یافته برای برآورد مقاومت فروروی (PR) خاک

Table 4- Derived regression PTFs for estimating soil penetration resistance

شماره تابع PTF number	توابع رگرسیونی Regression PTFs	VIF حداکثر Max VIF
1	PR=-0.572 +0.974D _b - 0.005sand	1.14
2	PR=0.675D _b - 0.004sand - 0.302θ _f	1.86
3	PR=0.588D _b - 0.003sand - 0.309 θ _f + 0.033σ _g	1.95
4	PR= -1.023 + 0.997D _b + 0.004silt	1.13
5	PR=0.695D _b - 0.004silt - 0.305θ _f	1.87
6	PR=0.585D _b - 0.003silt -0.307θ _f + 0.039σ _g	1.95
7	PR=1.066 - 0.541θ _f - 0.608d _g	1.20
8	PR=0.725 - 0.527θ _f - 0.404d _g + 0.042σ _g	1.65
9	PR= 0.718 - 0.428θ _f - 0.404d _g + 0.042σ _g - 0.085OC	1.75
10	PR=1.521 - 0.476θ _f - 0.014n	1.34
11	PR=1.429 - 0.407θ _f - 0.012n - 0.459d _g	1.44
12	PR=1.477 - 0.018n - 0.005sand	1.17
13	PR=0.705 - 0.019n -0.004sand +0.346D _p	1.25
14	PR=0.929 - 0.006sand - 0.176OC	1.1
15	PR=0.785 - 0.006sand -0.162OC + 0.018clay	1.13

توصیف متغیرها در زیر جدول ۱ آورده شده است

Variables description is available under Table 1

جدول ۵- معیارهای ارزیابی توابع انتقالی رگرسیونی برای برآورد مقاومت فروروی (PR) خاک

Table 5. Evaluation criteria for regression PTFs in estimating penetration resistance (PR)

شماره تابع PTF number	Input variables	Testing set			Training		
		R ²	RMSE (MPa)	ME (MPa)	AIC	R ²	RMSE (MPa)
1	D _b , sand	0.53	1.16	0.40	12.240.51	0.96	0.66
2	D _b , sand, θ _f	0.50	1.33	0.69	21.220.58	1.03	1.48
3	D _b , sand, θ _f , σ _g	0.50	1.18	-0.29	16.860.61	1.00	-1.50
4	D _b , silt	0.53	1.19	0.49	13.510.50	1.01	0.97
5	D _b , silt, θ _f	0.50	3.34	-2.80	71.070.57	3.15	-8.34
6	D _b , silt, θ _f , σ _g	0.50	4.40	-3.89	87.950.61	4.43	-11.94
7	θ _f , d _g	0.39	1.29	0.34	17.730.52	0.95	0.31
8	θ _f , d _g , σ _g	0.40	1.28	0.39	19.310.56	0.91	0.28
9	θ _f , d _g , σ _g , OC	0.43	1.22	0.35	18.790.57	0.89	0.33
10	θ _f , n	0.41	1.16	0.17	12.160.55	0.89	0.05
11	θ _f , n, d _g	0.49	1.16	0.34	13.840.58	0.88	0.35
12	n, sand	0.49	1.16	0.35	12.000.44	1.01	0.33
13	n, sand, D _p	0.52	1.16	0.11	14.020.48	0.97	-0.10
14	sand, OC	0.39	1.25	0.30	15.880.36	1.11	0.44
15	sand, OC, clay	0.34	1.34	0.49	21.840.42	1.08	0.79

AIC : معیار اطلاعات آکائیک، RMSE : مجدد میانگین مربعات خطأ، ME: میانگین خطأ، R² : ضریب تبیین. توصیف متغیرها در زیر جدول ۱ آورده شده استR²: coefficient of determination; RMSE: root mean square error; ME: mean error; AIC: Akaike information criterion. Variables description is available under Table 1

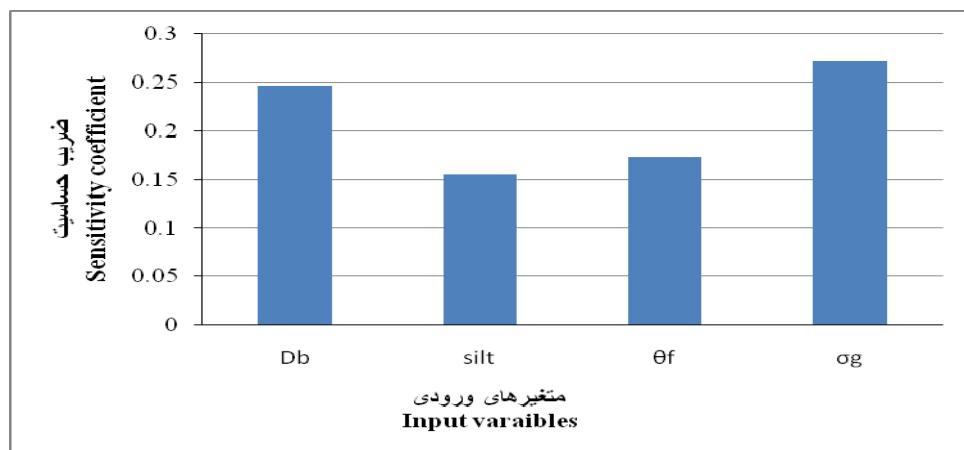
متغیرهای تخلخل کل و درجه اشباع نسبی باعث افزایش دقت توابع رگرسیونی با دو متغیر ورودی جرم مخصوص ظاهری و رطوبت خاک مزرعه گردید.

گرونوالد و همکاران (۱۸) بیان کردند که جرم مخصوص ظاهری مؤثرترین متغیر در تخمین مقاومت فروروی خاک می‌باشد. واژ و همکاران (۳۶) گزارش نمودند توابع رگرسیونی که در آن PR تابعی از رطوبت و جرم مخصوص ظاهری خاک هستند دارای بیشترین R² و کمترین RMSE بودند. بیات و همکاران (۴) بیان کردند افزودن

تغییرات در مقدار آن (میانگین \pm انحراف معیار) و ثابت نگهداشتن بقیه متغیرهای ورودی تخمین زده شد. یک مثالی از آنالیز حساسیت متغیرهای ورودی برای تخمین PR در بهترین مدل شبکه عصبی مصنوعی (تابع ۶ در جدول ۶) در شکل ۳ آورده شده است. هرچه متغیر ورودی در تخمین متغیر خروجی اهمیت بیشتری داشته باشد ضریب حساسیت برای آن متغیر ورودی دارای مقدار بیشتری خواهد بود. بر اساس شکل ۳، متغیرهای انحراف استاندارد هندسی و جرم مخصوص ظاهری بیشترین اهمیت و رطوبت مزرعه و سیلت کمترین اهمیت را در برآورد PR داشتند. بیات و همکاران^(۴) با استفاده از روش شبکه عصبی مصنوعی، مقاومت فروروی خاک را از روی متغیرهای زودیافت رطوبت مزرعه، جرم مخصوص ظاهری، تخلخل کل و درجه اشباع نسبی برآورد کردند. آن‌ها نشان دادند که استفاده از درجه اشباع نسبی در روش شبکه عصبی مصنوعی موجب بهبود برآورد PR گردید و R^2 را از ۰/۷۵۱ به ۰/۸۰۰ بود. افزایش و RMSE را نیز به میزان ۸/۶۵ درصد بهبود بخشید. عباسپور گیلاند و شایگانی سلطان پور^(۱) طی پژوهشی در مزرعه تحقیقاتی دانشکده کشاورزی دانشگاه محقق اردبیلی نشان دادند که شبکه عصبی مصنوعی با متغیرهای ورودی جرم مخصوص ظاهری و رطوبت مزرعه، مقاومت فروروی خاک را با دقت زیادی ($R^2 = 0/885$) برآورد نمود. سانتوس و همکاران^(۳) گزارش دادند که شبکه عصبی مصنوعی قادر است مقاومت فروروی خاک را با دقت زیادی ($0/98$ و $R^2 = 0/084$) از روی جرم مخصوص ظاهری و رطوبت اولیه مزرعه برآورد نماید.

نتایج توابع شبکه عصبی مصنوعی برای برآورد مقاومت فروروی خاک

جدول ۶ معیارهای ارزیابی توابع شبکه عصبی مصنوعی ارائه شده برای برآورد مقاومت فروروی (PR) خاک را نشان می‌دهد. رتبه‌بندی این توابع نیز همانند توابع رگرسیونی (جدول ۵)، بر اساس معیارهای مذکور در بودن RMSE و AIC صورت گرفت. براساس معیارهای مذکور در داده‌های آموزشی (جدول ۶)، بهترین تابع شبکه عصبی مصنوعی برای برآورد PR خاک، تابع شماره ۶ با متغیرهای ورودی جرم مخصوص ظاهری (Θ_f)، سیلت، رطوبت مزرعه (Θ_f) و انحراف استاندارد هندسی ذرات (σ_g) تعیین گردید. مقادیر R^2 و AIC این تابع به ترتیب برابر $0/91$ ، $0/37$ ، $0/64$ و $0/206$ و $-0/0026$ برای داده‌های آموزشی و $0/41$ ، $0/40$ ، $0/37$ و $0/26$ برای داده‌های آزمونی بود. مقادیر منفی ME برای داده‌های آزمونی و آزمونی در تابع ۶ نشان می‌دهد که این تابع، PR را کمتر از مقدار واقعی برآورد می‌کند. در رتبه‌های بعدی، تابع ۱۱ با متغیرهای ورودی رطوبت مزرعه (Θ_f)، تخلخل کل (n)، میانگین هندسی قطر ذرات (d_g) و تابع ۱۰ با متغیرهای ورودی رطوبت مزرعه (Θ_f)، تخلخل کل (n) دارای بیشترین دقت در برآورد PR خاک بودند (جدول ۶). بهترین تابع شبکه‌های عصبی مصنوعی نیز بیان گر اهمیت زیاد متغیرهای انحراف استاندارد هندسی ذرات، جرم مخصوص ظاهری، رطوبت مزرعه و سیلت در برآورد PR می‌باشند. آنالیز حساسیت برای تعیین موثرترین پارامترهای ورودی در نرم افزار MATLAB اجرا گردید. حساسیت متغیر خروجی (PR) به یک متغیر ورودی با ایجاد



شکل ۳- آنالیز حساسیت متغیرهای ورودی استفاده شده در بهترین تابع شبکه عصبی (تابع ۶) برای برآورد مقاومت فروروی. توصیف متغیرها در زیر جدول ۱ آورده شده است

Figure 3- Sensitivity analysis of the input variables used to develop the best ANN PTF (PTF 6) for prediction of PR. Variables description is available under Table 1

جدول ۶- معیارهای ارزیابی توابع شبکه عصبی مصنوعی برای برآورد مقاومت فروروی (PR) خاک

Table 6- Evaluation criteria for ANN PTFs in estimating penetration resistance (PR)

شماره تابع PTF number	Input variables	متغیرهای ورودی	آزمون Testing set			آموزش Training		
			R ²	RMSE (MPa)	ME (MPa)	AIC	R ²	RMSE (MPa)
1	D _b , sand		0.52	1.22	0.229	14.74	0.50	0.86
2	D _b , sand, θ _f		0.41	1.34	0.209	21.65	0.73	0.65
3	D _b , sand, θ _f , σ _g		0.47	1.32	0.205	23.12	0.81	0.55
4	D _b , silt		0.50	1.31	0.316	18.71	0.60	0.79
5	D _b , silt, θ _f		0.45	1.33	0.332	21.29	0.69	0.70
6	D _b , silt, θ _f , σ _g		0.41	1.40	-0.206	26.18	0.91	0.37
7	θ _f , d _g		0.46	1.30	0.288	18.17	0.61	0.79
8	θ _f , d _g , σ _g		0.47	1.31	0.390	20.73	0.76	0.61
9	θ _f , d _g , σ _g , OC		0.45	1.31	0.300	18.72	0.67	0.72
10	θ _f , n		0.38	1.39	0.232	23.97	0.81	0.55
11	θ _f , n, d _g		0.45	1.32	0.107	20.83	0.84	0.50
12	n, sand		0.54	1.20	0.278	13.95	0.51	0.88
13	n, sand, D _p		0.46	1.30	0.288	20.16	0.69	0.70
14	sand, OC		0.42	1.40	0.399	22.10	0.61	0.78
15	sand, OC, clay		0.51	1.23	0.193	17.02	0.65	0.75

AIC: معیار اطلاعات آکایک، RMSE: مجدد میانگین مربعات خطأ، ME: میانگین خطأ، R²: ضریب تبیین. توصیف متغیرها در زیر جدول ۱ آورده شده است

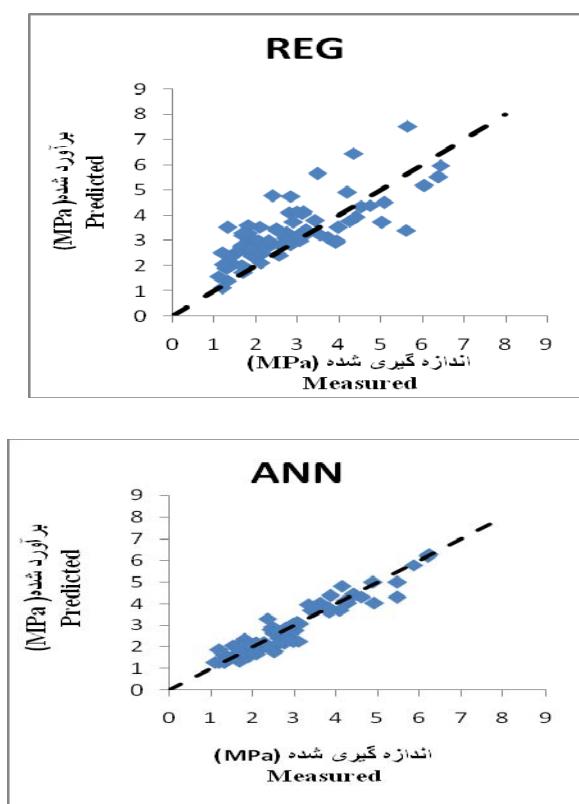
R²: coefficient of determination; RMSE: root mean square error; ME: mean error; AIC: Akaike information criterion. Variables description is available under Table 1

برآورد PR در خاک‌های منطقه مورد مطالعه می‌باشد به عبارت دیگر دقت مدل شبکه عصبی مصنوعی در تخمین PR به مراتب بیشتر از مدل رگرسیونی بوده است. بیات و همکاران (۴) گزارش کردند که شبکه عصبی مصنوعی (R²=۰/۸۲) نسبت به تابع رگرسیونی خطی (R²=۰/۷۲) در برآورد PR از روی جرم مخصوص ظاهری، رطوبت وزنی مزرعه، تخلخل کل و درجه اشباع نسبی دقیق‌تر عمل نمود. سانتوس و همکاران (۳۴) نشان دادند تابع شبکه عصبی مصنوعی سانتوس و همکاران (۳۴) نسبت به تابع رگرسیونی (R²=۰/۹۸) (RMSE=۰/۰۸۴) دقت بیشتری در برآورد مقاومت فروروی (RMSE=۰/۰۹۸) داشتند. شکل ۴ نیز نمودار ۱:۱ مقادیر اندازه‌گیری و برآورد شده مقاومت فروروی خاک را با استفاده از بهترین تابع رگرسیونی (تابع شماره ۱۰ در جدول ۵) و شبکه عصبی مصنوعی (تابع شماره ۱۰ در جدول ۶) برای داده‌های آموزشی نشان می‌دهد. با توجه به این شکل مشاهده می‌شود که پراکندگی داده‌ها حول محور ۱:۱ در بهترین تابع رگرسیونی بیشتر از بهترین تابع شبکه عصبی استقاق یافته برای

مقایسه دقت تابع رگرسیونی و شبکه عصبی مصنوعی در برآورد مقاومت فروروی خاک

مقادیر R², RMSE و AIC و ME تابع انتقالی رگرسیونی (جدول ۵) و شبکه عصبی مصنوعی (جدول ۶) ارائه شده برای برآورد PR در داده‌های آموزشی نشان می‌دهد که شبکه‌های عصبی مصنوعی به علت داشتن R² بیشتر (از ۰/۵۰ تا ۰/۹۱) و RMSE کمتر (از ۰/۳۷ تا ۰/۸۸) در مقایسه با تابع رگرسیونی (R² از ۰/۰۶۱ تا ۰/۰۸۸) از رگرسیونی (۴/۴۳) دارای دقت بالاتری و خطای کمتری در برآورد PR بودند. شکل ۴ نیز نمودار ۱:۱ مقادیر اندازه‌گیری و برآورد شده مقاومت فروروی خاک را با استفاده از بهترین تابع رگرسیونی (تابع شماره ۱۰ در جدول ۵) و شبکه عصبی مصنوعی (تابع شماره ۱۰ در جدول ۶) برای داده‌های آموزشی نشان می‌دهد. با توجه به این شکل مشاهده می‌شود که پراکندگی داده‌ها حول محور ۱:۱ در بهترین تابع رگرسیونی بیشتر از بهترین تابع شبکه عصبی استقاق یافته برای

گردد.



شکل ۴- مقایسه مقادیر اندازه‌گیری و برآورد شده مقاومت فرروروی (PR) خاک با استفاده از بهترین تابع رگرسیونی (REG) و شبکه عصبی مصنوعی (ANN) بر اساس داده‌های آموزشی. اطلاعات مربوط به توابع و متغیرهای ورودی در جداول ۵ و ۶ آورده شده است. خطچین بیانگر نمودار ۱:۱ است.

Figure 4- Comparisons of predicted and measured values of penetration resistance (PR) for the training data set based on the best regression and ANN PTFs. Tables 5 and 6 provide detailed information about each PTF and input variables. The dashed lines indicate the 1:1 diagonals.

داده‌های پیش‌بینی شده به داده‌های واقعی) را برای مقایسه دقت توابع رگرسیونی و شبکه عصبی مصنوعی در برآورد PR استفاده کردند. نتایج نشان داد که تابع شبکه عصبی مصنوعی درصد ۸۶/۴۹ (PA=۷۹/۶۳) دقت بیشتری نسبت به تابع رگرسیونی (PA=۷۹/۷۹۵) دارد. بسالت پور و همکاران (۵) معیارهای R^2 ، میانگین مربعات خطای (MSE)^۱ و میانگین خطای تخمین (MEE)^۲ قابلیت شبکه عصبی مصنوعی برای مدل سازی ویژگی‌های فیزیکی و مکانیکی خاک را با رگرسیون خطی چند متغیره مقایسه کردند. آن‌ها گزارش کردند که توابع شبکه عصبی طراحی شده برای تخمین متغیرهای مورد مطالعه دارای کارایی بسیار بالاتری نسبت به روش‌های رگرسیونی مرسوم بودند. علت برآورد دقیق تر شبکه‌های عصبی مصنوعی نسبت به توابع انتقالی رگرسیونی را می‌توان در نحوه عمل شبکه پرسپترون ۳ لایه دانست. عملکرد این شبکه به این صورت است که ابتدا الگویی به شبکه عصبی عرضه می‌شود و خروجی آن محاسبه می‌شود سپس شبکه این خروجی را با مقادیر اندازه‌گیری شده متغیر یا متغیرهای خروجی مقایسه می‌کند و ضرایب وزنی شبکه را به نوعی تغییر می‌دهد که کمترین اختلاف بین مقادیر پیش‌بینی شده و اندازه‌گیری شده باشد (۲۶).

نتیجه‌گیری کلی

در پژوهش حاضر روش‌های رگرسیونی و شبکه عصبی مصنوعی به منظور برآورد مقاومت فرروروی (PR) با استفاده از ویژگی‌های زودیافت خاک در اراضی زراعی دشت اردبیل مورد استفاده قرار گرفتند. نتایج توابع بدست آمده نشان داد در برآورد PR خاک، مهم‌ترین متغیرهای زودیافت شامل رطوبت اولیه مزرعه، جرم مخصوص ظاهری و توزیع اندازه ذرات خاک بودند. مقایسه نتایج نشان داد شبکه‌های عصبی مصنوعی به علت داشتن R^2 بالاتر و AIC و RMSE پایین‌تر دارای دقت بالاتر و خطای کمتری در برآورد PR خاک نسبت به توابع رگرسیونی بودند. توصیه می‌شود در تحقیقات بعدی تأثیر پارامترهای فراکتالی توزیع اندازه ذرات و خاکدانه‌ها نیز در برآورد PR خاک در منطقه مورد مطالعه بررسی

منابع

- Abbaspour Gilandeh Y., and Shaygani Soltanpour A.R. 2014. Soil cone index prediction using artificial neural networks model and its comparison with regression models. Journal of Soil Management and Sustainable Production. 187-204. (in Persian)
- Alijanpour Shalmani A., Shabani M., Asadi, H., and Bagheri F. 2011. Estimation of soil aggregate stability in forest soils of Guilan Province by artificial neural networks and regression pedotransfer functions. Water and soil Science. 21:152-163. (in Persian)

1- Mean square error

2- Mean estimation error

- 3- Bachmann J., Contreras K., Hartage K. H. and MacDonald R. 2005. Comparison of soil strength data obtained in situ with penetrometer and with vane shear test. *Soil & Tillage Research*. 89:86-102.
- 4- Bayat H., Neyshabouri M.R. and Hajabbasi M. 2008. Comparing neural networks, linear and nonlinear regression techniques to model penetration resistance. *Turkish Journal of Agriculture and Forestry*. 32: 425-433.
- 5- Besalatpour A.A., Hajabbasi M.A., and Ayoubi S. 2010. Estimation of some physical and mechanical properties of soils using artificial neural network. Sixth National Congress on Civil Engineering. Semnan, Iran.
- 6- Blake G.R. and Hartge K.H. 1986. Bulk density, p. 363-375. In: Klute, A. (ed). *Methods of Soil Analysis*. Part 1. 2nd ed. Agronomy. Monograph. 9. ASA, Madison, WI.
- 7- Blake G.R., and Hartge K.H. 1986. Particle Density. p. 377-382. In: Klute, A. (ed). *Methods of Soil Analysis*. Part 1. 2nd ed. Agronomy. Monograph. 9. ASA, Madison, WI
- 8- Busscher W.J. and Bauer P.J. 2003. Soil strength cotton growth and lint yield in a southeastern USA coastal loamy sand. *Soil & Tillage Research*. 56: 197-204.
- 9- Campanharo W.A., Sperandio H.V., Cecilio R.A., Hollanda M.P. and Guariz H.R. 2009. Variabilidade espacial da resistência a penetração do solo a penetração em áreas sob cultivos puros e consorciados de café e eucalipto. *Revista Brasileira de Agroecologia*. 2: 2721-2724.
- 10- Campbell G.S. 1985. *Soil Physics with Basic: Transport Models for Soil–Plant System*. Elsevier. New York. 150 p.
- 11- Cunha J.P.A.R., Vieira L.B. and Magalhaes A.C. 2002. Resistência mecânica do solo à penetração sob diferentes densidades e teores de água.. *Engenharia na Agricultura*. 1:1-7.
- 12- Emami H., Lakzian A., and Mohagerpour M. 2010. Study of the relationship between slope of retention curve and some physical properties of soil quality. *Journal of Water and Soil*. 24: 1027-1035. (In Persian)
- 13- Farahani E., Mosaddeghi M.R., and Mahboubi. A.A. 2012. Measuring the mechanical strength and hardsetting phenomenon in selected soils of Hamadan province. *Journal of Science and Technology of Agriculture and Natural Resources, Water and Soil Science*. 16: 181-194. (in Persian)
- 14- Gardner W.H. 1986. Water Content. p. 493-544. In: Klute, A. (ed). *Methods of Soil Analysis*. Part 1. 2nd ed. Agronomy. Monograph. 9. ASA, Madison, WI
- 15- Gee G.W. and Bauder J.W. 1986. Particle-size analysis. p. 383–411. In: Klute, A. (ed). *Methods of Soil Analysis*. Part 1. 2nd ed. Agronomy. Monograph. 9. ASA, Madison, WI
- 16- Ghaboussi J., Garrett J.H., and Wu X. 1991. Knowledge-based modeling of material behavior with neural networks. *Journal of Engineering Mechanics*. 117: 132-153.
- 17- Gomez J.A., Giraldez J.V., Pastor M., and Fereres E. 1999. Effects of tillage method on soil physical properties, infiltration, and yield in an olive orchard. *Soil & Tillage Research*. 52:167-175.
- 18- Grunwald S., Rooney D.J., McSweeney K., and Lowery B. 2001. Development of pedotransfer functions for a profile cone penetrometer. *Geoderma*. 100: 25-47.
- 19- Gupta S.C., Schneider E.C., Larson W.E. and Hadas A. 1987. Influence of corn residue on compression and compaction behavior of soils. *Soil Science Society of America Journal*. 51: 207-212.
- 20- Jorreh M., Bayat h., Safari Sinejani A.A., and Davatgar N. 2012. Estimation of soil penetration resistance using fractal parameters of particle and aggregate size distributions. *Journal of Water and Soil*. 23: 13-27. (in Persian)
- 21- Kozak E., Pachepsky Y.A., Sokolowski S., Sokolowska Z. and Stepniewski W. 1996. A modified number-based method for estimating fragmentation fractal dimensions of soils. *Soil Science Society of America Journal*. 60: 1291- 1297.
- 22- Kushwaha P.L., and Zhang Z.X. 1998. Evaluation of factors and current approaches related to computerized design of tillage tools: a review. *Journal of Terramechanics*. 35:69-86.
- 23- Laboski C.A.M., Dowdy R.H., Allmaras R.P., and Lamb J.A. 1998. Soil strength and water content influence on corn root distribution in a sandy soil. *Plant and Soil*. 203: 239-247.
- 24- Marshall T.J., Holmes J.W., and Rose C.W. 1996. *Soil Physics*. 3rd ed. Cambridge, Cambridge University Press.
- 25- Mesri Gundoshmian T., Ghasemzadeh H.R., Abdollahpour S.H., Navid H., and Sahraeian H., 2009. Determining appropriate neural network model for predicting quantitative grain loss of combine harvester lexion 510. *Agriculture Science*. 20: 211-220. (in Persian)
- 26- Minasny B., Hopman J.W., Harter T.X., Eching T., Toli A. and Denton M.A. 2004. Neural networks prediction of soil hydraulic functions for alluvial soils using multi step outflow data. *Soil Science Society of America Journal*. 68: 417- 429.
- 27- 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.
- 28- Mosaddeghi M.R., Hemmat M.A. Hajabbasi M.A. Vafaeian M. and Alexandrou A. 2006. Plate Sink age versus confined compression tests for in situ soil compressibility studies. *Biosystem Engineering*. 93: 325–334.
- 29- Mullins CE., Young I.M., Bengough A.G., and Ley G.J. 1987. Hard-setting soils. *Soil Use Managment*. 3:79–83.
- 30- Ohu J.O., Ekwue E. and Folorunse O.A. 1994. The effect of addition of organic matter on the compaction of a vertisol from Northern Nigeria. *Soil Technology*. 7: 155-162
- 31- Page A.L. (ed.).1985. *Methods of Soil Analysis*. Part 2. Chemical and Microbiological Methods. Agronomy No. 9.

- American Society of Agronomy, Madison, WI.
- 32- Puppala A.J., Acar Y.B. and Tumay M.T. 1995. Cone penetration in very weakly cemented sand. *Journal of Geotechnical and Geoenvironmental Engineering*. 121: 589-600.
- 33- Rezaei A., and Soltani A. 2008. *Introduction to Applied Regression Analysis*. Isfahan University Press. (in Persian)
- 34- Santos F.L., De Jesus V.A.M. and Valente D.S.M. 2012. Modeling of soil penetration resistance using statistical analyses and artificial neural networks. *Acta Scientiarum. Agronomy*. 34: 219-224.
- 35- Vaz C.M.P., Manieri J.M., de Maria I.C. and Tuller M. 2011. Modeling and correction of soil penetration resistance for varying soil water content. *Geoderma*. 166: 92-101.
- 36- Vaz, C.M.P., Luis H.B. and Hopmans J.W. 2001. Contribution of water content and bulk density to field soil penetration resistance as measured by a combined cone penetrometer-TDR probe. *Soil & Tillage Research*. 60: 35-42.
- 37- Walkley A.J. and Black I.A. 1934 Estimation of soil organic carbon by the chromic acid titration method. *Soil Science*. 37: 29-38.
- 38- Zareh haghi D., Neyshabouri M.R., Gorji M., Monirifar H., and Shorafa M. 2011. Determination of non-limiting water range for seedling growth of Pistachio at two levels of soil compaction. *Water and Soil Sience*. 22: 61-71. (in Persian)



Estimating Penetration Resistance in Agricultural Soils of Ardabil Plain Using Artificial Neural Network and Regression Methods

G.R. Sheykhzadeh¹ - Sh. Asghari^{2*} - T. Mesri Gundoshmian³

Received: 09-12-2014

Accepted: 18-08-2015

Introduction: Penetration resistance is one of the criteria for evaluating soil compaction. It correlates with several soil properties such as vehicle trafficability, resistance to root penetration, seedling emergence, and soil compaction by farm machinery. Direct measurement of penetration resistance is time consuming and difficult because of high temporal and spatial variability. Therefore, many different regressions and artificial neural network pedotransfer functions have been proposed to estimate penetration resistance from readily available soil variables such as particle size distribution, bulk density (D_b) and gravimetric water content (θ_m). The lands of Ardabil Province are one of the main production regions of potato in Iran, thus, obtaining the soil penetration resistance in these regions help with the management of potato production. The objective of this research was to derive pedotransfer functions by using regression and artificial neural network to predict penetration resistance from some soil variations in the agricultural soils of Ardabil plain and to compare the performance of artificial neural network with regression models.

Materials and methods: Disturbed and undisturbed soil samples ($n=105$) were systematically taken from 0-10 cm soil depth with nearly 3000 m distance in the agricultural lands of the Ardabil plain ((lat $38^{\circ}15'$ to $38^{\circ}40'$ N, long $48^{\circ}16'$ to $48^{\circ}61'$ E). The contents of sand, silt and clay (hydrometer method), CaCO_3 (titration method), bulk density (cylinder method), particle density (D_p) (pycnometer method), organic carbon (wet oxidation method), total porosity(calculating from D_b and D_p), saturated (θ_s) and field soil water (θ_f) using the gravimetric method were measured in the laboratory. Mean geometric diameter (d_g) and standard deviation (σ_g) of soil particles were computed using the percentages of sand, silt and clay. Penetration resistance was measured in situ using cone penetrometer (analog model) at 10 replicates. The data were divided into two series as 78 data for training and 27 data for testing. The SPSS 18 with stepwise method and MATLAB software were used to derive the regression and artificial neural network, respectively. A feed forward three-layer (8, 11 and 15 neurons in the hidden layer) perceptron network and the tangent sigmoid transfer function were used for the artificial neural network modeling. In estimating penetration resistance, The accuracy of artificial neural network and regression pedotransfer functions were evaluated by coefficient of determination (R^2), root mean square error (RMSE), mean error (ME) and Akaike information criterion (AIC) statistics.

Results and discussion: The textural classes of study soils were loamy sand ($n=8$), sandy loam ($n=70$), loam ($n=6$) and silt loam ($n=21$). The values of sand (26.26 to 87.43 %), clay (3.99 to 17.34 %), organic carbon (0.3 to 2.41 %), field moisture (4.56 to 33.18 mass percent), D_b (1.02 to 1.63 g cm⁻³) and penetration resistance (1.1 to 6.6 MPa) showed a large variations of study soils. There were found significant correlations between penetration resistance and sand ($r=-0.505^{**}$), silt ($r=0.447^{**}$), clay ($r=0.330^{**}$), organic carbon ($r=-0.465^{**}$), D_b ($r=0.655^{**}$), θ_f ($r=-0.63^{**}$), CaCO_3 ($r=0.290^{**}$), total porosity ($r=-0.589^{**}$) and D_p ($r=0.266^*$). Generally, 15 regression and artificial neural network pedotransfer functions were constructed to predict penetration resistance from measured readily available soil variables. The results of regression and artificial neural network pedotransfer functions showed that the most suitable variables to estimate penetration resistance were θ_f , D_b and particles size distribution. The input variables were n and θ_f for the best regression pedotransfer function and also D_b , silt, θ_f and σ_g for the best artificial neural network pedotransfer function. The values of R^2 , RMSE, ME and AIC were obtained equal to 0.55, 0.89 MPa, 0.05 MPa and -14.67 and 0.91, 0.37 MPa, -0.0026 MPa and -146.64 for the best regression and artificial neural network pedotransfer functions, respectively. The former researchers also reported that there is a positive correlation between penetration resistance with D_b and a negative correlation between penetration resistance with θ_f and organic carbon.

1, 2- Former M.Sc. Student and Associate Professor, Department of Soil Science and Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil

(*- Corresponding Author Email: shasghari@uma.ac.ir)

3- Associate Professor, Department of Biosystem Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil

Conclusion: The results showed that silt, standard deviation of soil particles (σ_g), bulk density (D_b), total porosity and field water content (θ_f) are the most suitable readily available soil variables to predict penetration resistance in the studied area. According to the RMSE and AIC criteria, the accuracy of artificial neural network in estimating soil penetration resistance was more than regression pedotransfer functions in this research.

Keywords: Estimation, Initial moisture, Readily available variable, Soil compaction