

برآورد میانگین وزنی قطر خاکدانه‌ها با استفاده از مدل‌های رگرسیونی و شبکه عصبی مصنوعی

حامد امیر عابدی*^۱، شکرالله اصغری^۲، ترحم مصری گندشمین^۳، ناصر بالنده^۴

(تاریخ دریافت: ۹۵/۰۱/۳۱ تاریخ پذیرش: ۹۵/۰۶/۰۵)

چکیده

اندازه‌گیری مستقیم برخی ویژگی‌های فیزیکی دیریافت خاک مثل پایداری خاکدانه وقت‌گیر، هزینه‌بر و گاهی اوقات به دلیل خطاهای آزمایشی و غیریکنواختی خاک غیرواقعی است. پایداری خاکدانه‌ها به عنوان یک ویژگی دیریافت می‌تواند از ویژگی‌های زودیافت خاک مانند بافت، جرم ویژه ظاهری، کربن آلی و کربنات کلسیم معادل با استفاده از توابع انتقالی رگرسیونی و شبکه عصبی مصنوعی برآورد شوند. هدف از این پژوهش ارائه مدل‌هایی برای برآورد میانگین وزنی قطر (MWD) خاکدانه از روی ویژگی‌های زودیافت با استفاده از مدل‌های رگرسیونی و شبکه عصبی مصنوعی و همچنین ارزیابی کارایی این مدل‌ها در برآورد با استفاده از معیارهای آماری مانند ضریب تبیین (R^2) و جذر میانگین مربعات خطا (RMSE) بود. برای این منظور، ۱۰۰ نمونه خاک از مناطق مختلف دشت اردبیل برداشت و تجزیه‌های فیزیکی و شیمیایی انجام شد. داده‌ها به دو سری داده‌های آموزشی (۸۰ درصد داده‌ها) و داده‌های آزمون (۲۰ درصد داده‌ها) تقسیم شدند. نتایج نشان داد که هر دو روش می‌توانند میانگین وزنی قطر خاکدانه را با دقت قابل قبولی برآورد کنند با این وجود شبکه عصبی مصنوعی از دقت بیش‌تر و خطای کمتری (R^2 و RMSE به ترتیب ۰/۸۸ و ۰/۰۴۲) در برآورد میانگین وزنی قطر خاکدانه نسبت به مدل‌های رگرسیونی (R^2 و RMSE به ترتیب ۰/۸۱ و ۰/۰۵۴) برخوردار بودند.

واژه‌های کلیدی: پایداری خاکدانه، توابع انتقالی، شبکه عصبی مصنوعی

۱- دانش آموخته کارشناسی ارشد مهندسی علوم خاک، دانشگاه محقق اردبیلی (مکاتبه کننده)
 ۲- دانشیار گروه علوم خاک، دانشگاه محقق اردبیلی
 ۳- استادیار گروه علوم خاک، دانشگاه محقق اردبیلی
 ۴- کارشناس ارشد آزمایشگاه گروه مهندسی علوم خاک، دانشگاه ارومیه
 * پست الکترونیک: amirabedihamed@yahoo.com

مقدمه

ثبات و پایداری خاکدانه یکی از مهم‌ترین ویژگی‌های فیزیکی خاک است که مقاومت خاک و حساسیت خاک را نسبت به فرسایش آبی و بادی تعیین می‌کند. ارشد و همکاران (Arshad *et al.*, 1992) اندازه و پایداری خاکدانه‌ها را به عنوان شاخصی از تغییر کیفیت خاک^۱ ناشی از مدیریت‌های متفاوت و در شرایط مشخص معروفی نمودند. کچسون (Ketcheson, 1980) گزارش کرد که اندازه و پایداری خاکدانه‌ها بیان‌کننده وضعیت حرکت آب و عناصر غذایی در خاک است و در تهویه و فعالیت میکروبی و عملیات خاک‌ورزی نقش زیادی دارد. خاکدانه‌سازی را می‌توان فرآیندی طبیعی محسوب نمود که طی آن مجموعه‌ای از ذرات خاک چنان در کنار هم قرار می‌گیرند که نیروهای نگه‌دارنده درونی آنها قوی‌تر از نیروهای میان خاکدانه‌های مجاور باشد. بیلر (Blair, 2000) فرآیندهای شیمیایی و زیستی را در پایداری خاکدانه‌ها موثر دانست. خاکدانه‌ها بر اساس اندازه به دو دسته اصلی، خاکدانه‌های درشت با قطر بزرگتر از ۲۵۰ میکرون و خاکدانه‌های ریز با قطر کوچکتر از ۲۵۰ میکرون تقسیم‌بندی می‌شوند. آمزکتا و همکاران (Amezketta *et al.*, 2003) گزارش کردند این واحدهای ساختاری به وسیله مکانیسم‌های مختلفی تشکیل شده‌اند و رفتار متفاوتی در مقابل استرس‌های خارجی از قبیل باران، باد، آبیاری و دیگر عملیات کشت و کار دارند. پایداری خاکدانه، سنجشی از میزان مقاومت خاک است. پایداری خاکدانه‌ها تاثیر بسزایی در نفوذ آب به خاک دارند. لادو و همکاران (Lado *et al.*, 2004) گزارش کردند که وجود خاکدانه‌های درشت و پایدار باعث افزایش ضریب آب‌گذری و شدت نفوذ آب به خاک می‌شود.

امرسون (Emerson, 1991) ساختمان آرمانی خاک را در اراضی مرتعی و خاک‌های جنگلی یافت، که در آب پایدار بوده و دارای جرم ویژه ظاهری کمی بود. چنو و

همکاران (Chenu *et al.*, 2000) بیان کردند، مواد آلی خاک باعث افزایش پایداری خاکدانه می‌گردد. مواد آلی به همراه رس توانست پایداری خاکدانه‌ها را بهبود دهد. شرستا و همکاران (Shrestha *et al.*, 2007) دریافتند که در اراضی تحت کشت، خاکدانه‌های کوچک فراوان است، حال آنکه در اراضی جنگلی، خاکدانه‌ها بزرگتر و پایدارتر هستند. خزابی و همکاران (Khazaei *et al.*, 2008) پایداری ساختمان خاک را به روش الک تر در ۲۱ سری از خاک‌های استان همدان بررسی کردند و گزارش کردند ماده آلی بیشترین نقش را در پایداری ساختمان خاک داشت.

آرینیری و سکوی (Aringhieri & Sequi, 1979) مقدار و نوع مواد آلی و نحوه پیوند آن با اجزای معدنی خاک را در پایداری خاکدانه موثر دانسته‌اند. چلیک (Celik, 2005) معتقد است که بر اثر کاهش مواد آلی، خاکدانه‌ها به آسانی شکسته شده و ذرات ریز خاک طی فرسایش آبی حمل خواهد شد. کوتیکا و همکاران (Koutikka *et al.*, 1997) نقش مواد آلی در پایداری خاکدانه‌ها را به صورت دوگانه توصیف کردند آنها بیان داشتند مواد آلی از سویی می‌توانند با افزایش بارهای سطحی منفی و کاهش تخلخل رس، مقدار پراکنش رس را افزایش داده و از سوی دیگر می‌تواند عامل پیوند دهنده بین ذرات خاک باشد. برزگر (Barzegar *et al.*, 1994) اثر مواد آلی در پایداری خاکدانه‌ها را به ویژگی‌های دیگر خاک مانند نوع و مقدار رس، درجه سدیمی بودن خاک، نوع مواد آلی و شدت عملیات مکانیکی ارتباط داد. در تحقیق انجام شده توسط تاجیک (Tajik, 2004) بر روی خاک‌های مناطق مختلف ایران، گزارش شده است که در مجموعه مناطق، تغییرات پایداری خاکدانه‌ها به طور عمده متاثر از مقدار مواد آلی ($R^2=0.72$) در مقایسه با سایر عوامل مثل رس و آهک بود.

آنگرس (Angers *et al.*, 1992)، اسمیل و همکاران (Ismail *et al.*, 1994) گزارشات گوناگونی در مورد اثرات مدیریتی مانند خاک‌ورزی بر روی پایداری خاکدانه‌ها و توزیع اندازه خاکدانه‌ها گزارش کرده‌اند. بیر و همکاران (Bear *et al.*, 1994) گزارش کردند باقی‌مانده‌های گیاهی در سیستم بی‌خاک‌ورزی باعث

1- Soil quality

شاپ و همکاران (Schaap *et al.*, 1998) نشان دادند که کیفیت پیش‌بینی توابع انتقالی توسط شبکه عصبی وابسته به مجموعه داده‌هایی است که برای آموزش آنها استفاده می‌شود زیرا دقت پیش‌بینی‌ها مستقیماً متأثر از کیفیت و نوع داده‌ها می‌باشد. همچنین در تکنیک شبکه عصبی مصنوعی، وسیع بودن محدوده داده‌های آموزش برای هر پارامتر مثل جرم ویژه‌ظاهری (مثلاً از ۰/۹۵ تا ۱/۶۵ گرم بر سانتی متر مکعب) نسبت به تعداد داده انتخابی (مثلاً ۱۰۰ داده تا ۱۵۰ داده) برای آن پارامتر اهمیت بیشتری دارد. امیرعابدی و همکاران (Amirabedi *et al.*, 2013) از مدل‌های رگرسیونی و شبکه عصبی مصنوعی برای پیش‌بینی ویژگی‌های هیدرولیکی خاک استفاده کردند و گزارش کردند شبکه‌های عصبی دارای عملکرد بالایی در مقایسه با مدل‌های رگرسیونی در برآورد ویژگی‌های هیدرولیکی خاک هستند. خاشعی و همکاران (Khashei *et al.*, 2014) هدایت هیدرولیکی اشباع خاک را با استفاده از روش‌های غیرپارامتریک نزدیکترین k-همسایه و شبکه عصبی مصنوعی برآورد کردند و بیان داشتند که روش‌های شبکه عصبی در صورت ارائه تمامی پارامترها از دقت بیشتری نسبت به سایر روش‌ها برخوردار هستند.

با توجه به اینکه اندازه‌گیری مستقیم میانگین وزنی قطر خاکدانه‌ها وقت‌گیر و هزینه‌بر بوده و همچنین در بسیاری از مطالعات مربوط به آبیاری، حفاظت آب و خاک اندازه‌گیری آن ضروری می‌باشد لذا هدف از این پژوهش ارائه مدل‌هایی برای برآورد پایداری خاکدانه در خاک‌های دشت اردبیل با استفاده از توابع انتقالی رگرسیونی و شبکه عصبی مصنوعی و همچنین بررسی کارایی هر یک از این مدل‌ها در برآورد پارامتر مورد نظر با استفاده از معیارهای آماری بود.

بهبود میزان پایداری خاکدانه‌ها می‌شود. از دیگر سو، واتز و دکستر (Watts & Dexter, 1997) گزارش کردند که در بسیاری موارد عملیات خاکورزی نامطلوب، مواد آلی خاک را کاهش داده و در نتیجه میزان پایداری خاکدانه کاهش و حساسیت خاک به فرسایش را افزایش می‌دهد. اطمینان و همکاران (Etminan *et al.*, 2011) نقش خصوصیات خاک با مواد مادری متفاوت را بر روی پایداری خاکدانه بررسی کردند و گزارش کردند که در سازند ژوراسیک درصد کربنات کلسیم، آهن و ظرفیت تبادل کاتیونی خاک، در سازند لسی درصد کربنات کلسیم و آهن و در سازند آبرفتی درصد مواد آلی و آهن مهم‌ترین عوامل تاثیرگذار بر پایداری خاکدانه است.

کالرو و همکاران (Calero *et al.*, 2008) شاخص‌های میانگین وزنی قطر خاکدانه^۱، رس قابل پراکنش^۲ و میانگین هندسی قطر خاکدانه^۳ را به عنوان شاخص‌های پایداری خاکدانه معرفی کردند. با این وجود اندازه‌گیری این شاخص‌ها به صورت مستقیم و در آزمایشگاه نسبتاً پیچیده، زمان‌بر و هزینه‌بر بوده و استفاده از آنها در مقیاس‌های بزرگ نظیر حوزه‌های آبخیز با محدودیت‌های فراوان روبرو است. به همین سبب امروزه از روش‌های غیر مستقیم نظیر توابع انتقالی خاکو توابع پیش‌بینی فضایی خاک^۴ به منظور برآورد این ویژگی‌ها استفاده می‌شود. خلیل مقدم و همکاران (Khalilmoghadam *et al.*, 2009) دریافتند در این توابع با استفاده از داده‌های زودیافت مانند توزیع اندازه ذرات خاک، کربنات کلسیم معادل، کربن آلی، جرم ویژه ظاهری و جرم ویژه حقیقی برخی ویژگی‌های مدیر یافت خاک نظیر ویژگی‌های فیزیکی و مکانیکی برآورد می‌شود. از جمله روش‌های رایج برای ایجاد توابع انتقالی و توابع پیش‌بینی فضایی خاک، شبکه‌های عصبی مصنوعی^۵ می‌باشد.

- 1-Mean weight diameter
- 2-Water dispersible clay
- 3-Geometric mean diameter
- 4-Soil spatial prediction function
- 5-Artificial neural network

مواد و روش‌ها

نمونه برداری خاک و تجزیه‌های آزمایشگاهی

نمونه‌های خاک دست خورده (با حداقل دست خوردگی و احتیاط کامل) به مقدار حدود ۳ کیلوگرمو نمونه‌های خاک دست نخورده با استفاده از استوانه-های فولادی به قطر ۵cm و ارتفاع ۵/۱cm از افق Ap خاک در ۱۰۰ نقطه از دشت اردبیل به طور تصادفی برداشته شد. نمونه‌های دست خورده در آزمایشگاه هوا خشک گردید و سپس بخشی از آن‌خرد و از الک ۲mm عبور داده شدند و مقادیر شن، سیلت، رس، جرم ویژه حقیقی، کربن آلی و کربنات کلسیم معادل خاک (CCE) اندازه‌گیری شدند. از بخش باقیمانده نمونه‌های دست خورده برای اندازه‌گیری میانگین وزنی قطر (MWD) خاکدانه‌ها استفاده شد. بافت خاک (درصد شن، سیلت و رس) به روش هیدرومتری، جرم ویژه حقیقی (D_p) به روش پیکنومتر، جرم ویژه ظاهری (D_b) به روش استوانه دست نخورده، میانگین وزنی قطر (MWD) در خاکدانه‌های کوچکتر از ۴/۷۵mm به روش الک تر (کمپر و روسو ۱۹۸۶)، کربن آلی (OC) به روش والکلی و بلک، کربنات کلسیم معادل به روش تیتراسیون با اسید مطابق دستورالعمل‌های ارائه شده (کلوت ۱۹۸۶، پیچ ۱۹۸۵) اندازه‌گیری شد. پارامترهای میانگین هندسی قطر (d_g) و انحراف استاندارد هندسی ذرات خاک از روی درصد‌های شن، سیلت و رس محاسبه شد (Campbell, 1985).

$$dg = \exp a \quad (1)$$

$$\sigma g = \exp b \quad (2)$$

$$a = 0.01 \sum_{i=1}^n f_i \ln(M_i) \quad (3)$$

$$b = 0.01 \sum_{i=1}^n f_i \ln^2(M_i) - a^2 \quad (4)$$

همراستایی چندگانه و آماده‌سازی داده‌ها

با استفاده از نرم‌افزار SPSS16 آزمون نرمال بودن توزیع داده‌ها انجام شد که همه متغیرهای به کار رفته در مدل، به جز میانگین هندسی قطر ذرات خاک (d_g) دارای توزیع نرمال بودند. برای ارزیابی همراستایی خطی چندگانه در مدل‌های رگرسیونی ایجاد شده از فاکتور تورم واریانس (VIF) استفاده شد (Khodaverdiloo *et al.*, 2011). داده‌ها در نرم-افزار Excel به صورت تصادفی به دو گروه ۸۰ تایی داده‌های آموزشی و ۲۰ تایی داده‌های آزمونی تقسیم شدند.

در این پژوهش از معادلات رگرسیونی و شبکه‌های عصبی مصنوعی برای برآورد میانگین وزنی قطر خاکدانه‌ها با استفاده از ویژگی‌های زودیافت خاک شامل توزیع اندازه ذرات، کربن آلی، آهک، جرم ویژه ظاهری، جرم ویژه حقیقی، میانگین هندسی قطر (d_g) و انحراف استاندارد هندسی ذرات (σ_g) خاک استفاده شد.

بر اساس نتایج ماتریس همبستگی بین MWD به عنوان متغیر وابسته و ویژگی‌های زودیافت به عنوان متغیرهای مستقل و بر اساس روش رگرسیونی گام-به-گام مهم‌ترین پارامترهای تاثیر گذار در هر مدل مشخص شدند. در صورتی که دو مدل در برآورد متغیر وابسته به یک اندازه کارآمد بود مدلی انتخاب گردید که دارای پارامترهای ورودی کمتری باشد. سپس متغیرهایی که در معادلات رگرسیونی به کار رفته بودند برای ایجاد شبکه‌های عصبی به عنوان ورودی مدل در نظر گرفته شدند.

اشتقاق توابع انتقالی رگرسیونی و شبکه عصبی

معادلات رگرسیونی خطی چندگانه به روش گام به گام در سطح احتمال ۵ درصد به کمک نرم افزار SPSS ایجاد شدند. سپس از متغیرهای ورودی مدل‌های رگرسیونی برای ایجاد شبکه‌های عصبی مصنوعی استفاده شد. از نرم‌افزار Neurosolution 5 برای ایجاد شبکه‌های عصبی مصنوعی استفاده گردید. داده‌ها

این آماره نشان می‌دهد که مدل پارامتر مورد نظر را بیش‌تر از مقدار واقعی برآورد می‌کند و مقادیر منفی آن نشان می‌دهد که مدل پارامتر را کمتر از مقدار واقعی برآورد می‌کند:

$$ME = \frac{\sum_{i=1}^n (Y_i(m) - Y_i(p))}{n} \quad (۶)$$

$$R^2 = 1 - \frac{SS_E}{SS_T} \quad (۷)$$

به دلیل اینکه تعداد پارامترهای ورودی مدل‌ها متفاوت بودند علاوه بر آماره‌های یاد شده از ضریب آکائیک^۲ (AIC) برای ارزیابی مدل‌ها در برآورد میانگین وزنی قطر خاکدانه‌ها استفاده شد (Ganbariyan & Liaghat, 2011).

$$AIC = n \ln\left(\frac{ESS}{n}\right) + 2q \quad (۸)$$

در این معادله n : تعداد داده‌ها، ESS : مجموع مربعات خطا و q : تعداد پارامترهای ورودی مدل می‌باشد. هر چه ضریب آکائیک کوچکتر باشد دقت مدل بیشتر خواهد بود.

نتایج و بحث

ویژگی‌های خاک و ارتباط آن با میانگین وزنی قطر خاکدانه (MWD)

آماره‌های توصیفی پارامترهای اندازه‌گیری شده برای توسعه و ارزیابی توابع انتقالی با استفاده از مدل‌های رگرسیونی و شبکه عصبی در جدول ۱ برای داده‌های آموزشی و آزمون خلاصه شده است. دامنه تغییرات مقادیر شن، سیلت، رس، جرم ویژه ظاهری، جرم ویژه حقیقی، کربنات کلسیم معادل، کربن آلی خاک و میانگین وزنی قطر خاکدانه برای داده‌های آموزش و آزمون در جدول (۱) آمده است. بین MWD با تمام متغیرهای زود یافت همبستگی بالایی وجود داشت (کربن آلی در سطح ۵ درصد و سایر متغیرهای مستقل

پیشاز برآورد توسط نرم‌افزار Neurosolution استاندارد شدند. شبکه پرسپترون سه لایه^۱ (MLP) با ۲ تا ۴ نرون در لایه ورودی، ۸ نرون با تابع فعال ساز تانژانت هایپربولیک و الگوریتم آموزشی مومنتم در لایه مخفی و یک نرون با تابع فعال ساز خطی در لایه خروجی ساختار شبکه عصبی این پژوهش را تشکیل می‌داد. بطور میانگین تعداد ۱۰۰۰ تکرار برای رسیدن به حداقل میزان خطا و حداکثر پایداری شبکه منظور گردید. برای برآورد خطا از الگوریتم پس انتشار خطا استفاده شد. قربانی دشتکی و همکاران (GhorbaniDashtaki *et al.*, 2009)، مصری و کریمی (Mesri & Karimi, 2009)، علیجانپور و همکاران (Alijanpuor *et al.*, 2011)، مردون و همکاران (Merdun *et al.*, 2006) از الگوریتم پس انتشار خطا برای برآورد خطا و از شبکه عصبی مصنوعی با ساختار پرسپترون سه لایه استفاده کرده‌اند.

معیارهای ارزیابی خطا و مقایسه کارایی روش-های مورد استفاده

به منظور مقایسه عملکرد توابع انتقالی رگرسیونی و شبکه MLP در برآورد میانگین وزنی قطر خاکدانه، از آماره‌های مجذور میانگین مربعات خطا (RMSE)، متوسط خطا (ME)، و ضریب تبیین (R^2) استفاده شد. مقادیر RMSE برای داده‌های مورد استفاده در آموزش و آزمون مدل‌های شبکه عصبی رگرسیونی با استفاده از معادله ۲ (Mesri *et al.*, 2009) محاسبه شد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i(m) - Y_i(p))^2}{n}} \quad (۵)$$

$Y_i(m)$: مقدار اندازه‌گیری شده پارامتر، $Y_i(p)$: مقدار برآورد شده پارامتر توسط مدل، n : تعداد داده وارد شده در مدل برای بیان این که یک مدل از نظر تخمین، پارامتر مورد نظر را بیشتر از حد واقعی یا کمتر از آن پیش‌بینی می‌کند از آماره میانگین خطا (ME) (معادله ۳) استفاده شد (Merdun *et al.*, 2006). مقادیر مثبت

2- Akaike information criterion

1-Multi-layer perceptron

صورت منفی با MWD داشت. همبستگی قوی بین رس و میانگین وزنی قطر خاکدانه نشان داد که تغییرات پایداری خاکدانه را می‌توان به خوبی از روی مقدار رس خاک برآورد نمود. این نتایج با یافته‌های اسکیدمور و لایتون (Skidmore & Layton, 1992) همخوانی دارد که اظهار داشتند پایداری خاکدانه‌های خشک را با استفاده از مقدار رس می‌توان با دقت بالا برآورد کرد. هیلل (Hillel, 2004) گزارش کرد رس یکی از عوامل سیمانی کننده قوی ذرات خاک به یکدیگر بوده و نقش کلیدی در پایداری خاکدانه‌ها دارد.

در سطح یک درصد) به همین دلیل این متغیرها به عنوان ورودی مدل‌های رگرسیونی استفاده شدند (جدول ۲). معادلات رگرسیونی اشتقاق یافته به منظور برآورد MWD نمونه‌های آموزشی و آزمونی داده‌ها در جدول ۳ ارائه شده است. مدل‌های ارائه شده نشان می‌دهند که بین مقادیر جرم ویژه ظاهری، سیلت و شن با شاخص پایداری خاکدانه (MWD) رابطه منفی و بین مقادیر رس، آهک و کربن آلی خاک با میزان MWD رابطه مثبت وجود دارد. شکل ۱ نشان می‌دهد که در بین متغیرهای زود یافت، بیشترین میزان همبستگی مثبت MWD با رس ($R^2=0.755$) وجود داشت. بعد از رس، شن بیشترین همبستگی را به

جدول ۱- آماره‌های توصیفی پارامترهای اندازه‌گیری شده برای داده‌های آموزشی و آزمونی در خاک‌های دشت اردبیل

Table 1- Descriptive statistics of the measured parameters for training and test data in Ardabil Plain soils.

داده‌های آزمون				داده‌های آموزشی				
Test data		Training data						
حداقل	حداکثر	میانگین	انحراف استاندارد	حداقل	حداکثر	میانگین	انحراف استاندارد	پارامترها
Minimum	Maximum	Average	standard deviation	Minimum	Maximum	Average	standard deviation	parameter
3.8	42.2	19.18	9.03	4.4	42.9	20.61	9.3	Clay (%)
28.3	49.9	36.41	10.96	24.4	57.6	37.93	7.75	Silt (%)
28.3	65	44.4	8.42	24.4	68	41.45	8.3	Sand (%)
0.37	1.09	0.69	0.2	0.31	1.52	0.85	0.25	OC (%)
6.25	21.25	14.4	3.67	3.75	37.5	14.92	5.3	CaCO ₃ (%)
2.53	2.7	2.6	0.05	2.5	2.7	2.58	0.04	D _p (g cm ⁻³)
1.15	1.6	1.38	0.15	1.04	1.7	1.35	0.14	D _b (g cm ⁻³)
0.27	0.72	0.49	0.12	0.21	0.8	0.512	0.126	MWD (mm)

D_p: particle density; CaCO₃: calcium carbonate equivalent; MWD: mean weight diameter of aggregates; d_g: geometric mean diameter of particles; σ_g: geometric standard deviation of soil particles diameter.

جدول ۲ - ضریب همبستگی پیرسون بین متغیرهای مستقل با میانگین وزنی قطر خاکدانه (MWD)

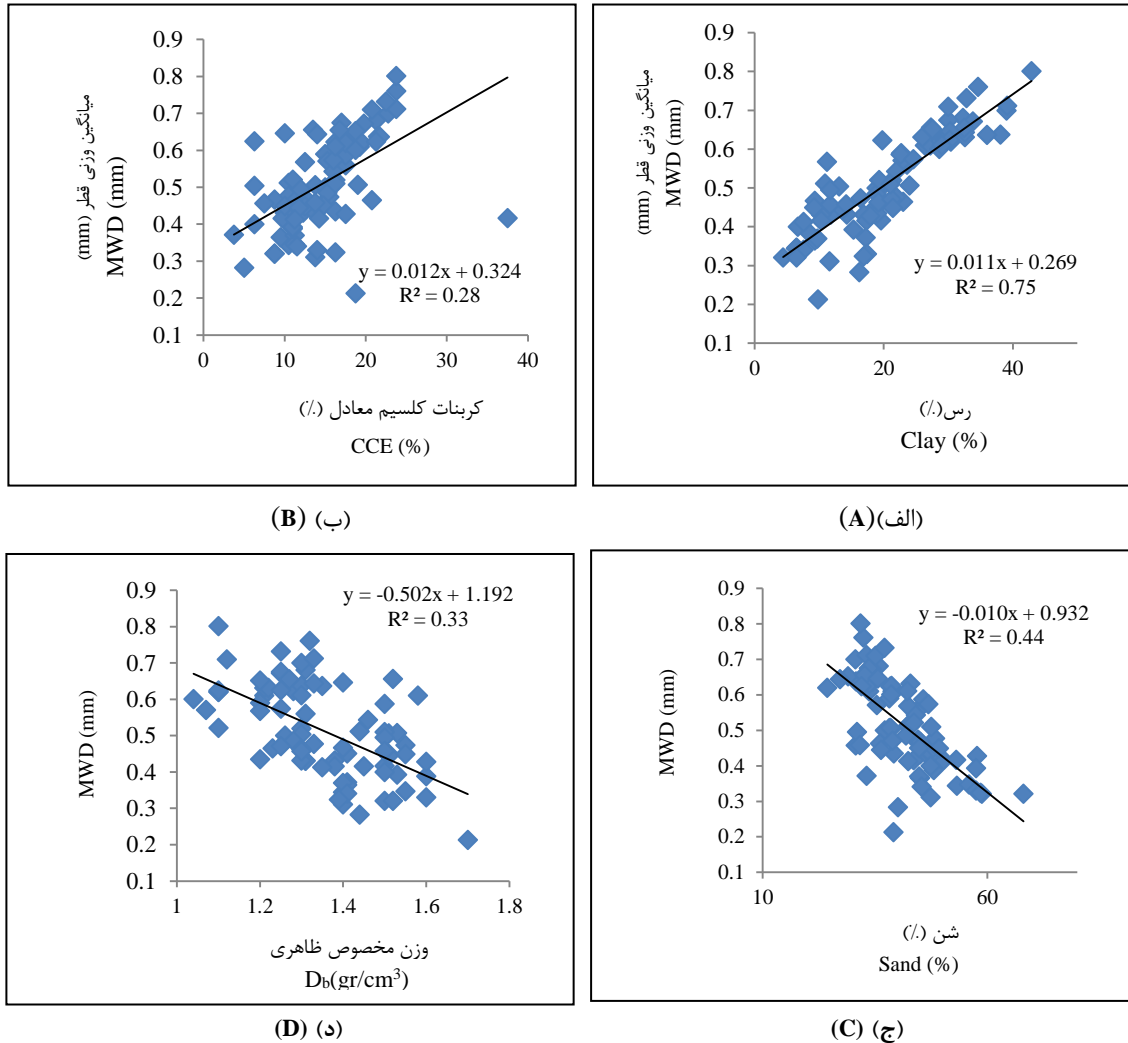
Table 2- Pearson correlation coefficient between independent variables and mean weight diameter

(MWD) of aggregates

D _b	D _p	CaCO ₃	OC	silt	sand	clay	MWD	parameter
-0.579**	-0.41**	0.538**	0.239*	-0.329**	0.667**	0.869**	1	MWD
-0.504**	-0.53**	0.648**	0.037	-0.538**	-0.618**	1		clay
0.457**	0.348**	-0.253*	-0.241*	-0.329**	1			sand
0.116	0.263*	-0.507**	0.214	1				silt
-0.258*	0.199	-0.021	1					OC
-0.246*	-0.297*	1						CaCO ₃
0.326**	1							D _p
1								D _b

** and * indicate significant at 0.01 and 0.05, respectively

** معنی‌دار در حد ۰/۰۱، * معنی‌دار در حد ۰/۰۵



شکل ۱- رابطه بین میانگین وزنی قطر (MWD) خاکدانه با درصد رس (الف)، درصد کربنات کلسیم معادل (CCE) (ب)، درصد شن (ج) و جرم ویژه ظاهری (د)

Figure 1- Relation between mean weight diameter (MWD) of aggregate with clay percentage (A), - Relation between calcium carbonate equivalent (CCE) percentage (B), Relation between sand percentage (C) and bulk density (D_b) (D)

۰/۰۵۴، ۰/۸۱، ۰/۰۰۴- برای مدل شماره ۳ و برابر ۰/۰۵۵، ۰/۸۱، ۰/۰۱۳ برای مدل شماره ۴ و برای داده‌های آزمون به ترتیب برابر، ۰/۰۳۹، ۰/۰۹، ۰/۰۰۸، در مدل شماره ۳ و برابر ۰/۰۵۱، ۰/۰۸۷، ۰/۰۲۸ در مدل شماره ۴ بود (جدول ۵). در مدل‌های رگرسیونی از لحاظ آماره AIC مدل شماره ۸ ($AIC = -463/8$) با متغیرهای ورودی شن، سیلت و کربن آلی دارای عملکرد بهتری نسبت به مدل شماره ۴ ($AIC = -461/8$) در برآورد میانگین وزنی قطر خاکدانه بود که دلیل آن تعداد پارامتر ورودی بیشتر در مدل شماره ۴

نتایج مدل‌های آماری رگرسیونی و شبکه‌عصبی مصنوعی برای برآورد MWD

بهترین مدل‌های آماری برای برآورد میانگین وزنی قطر خاکدانه از لحاظ آماره‌های RMSE و R^2 در داده‌های آموزشی مدل شماره ۳ شامل متغیرهای رس، کربن آلی خاک و جرم ویژه ظاهری و مدل شماره ۴ شامل متغیرهای شن، سیلت، کربن آلی و جرم ویژه ظاهری است (جدول ۴)، که مقادیر RMSE، R^2 و ME این مدل‌ها در داده‌های آموزشی به ترتیب برابر

نشان می‌دهد مدل‌ها پایداری خاکدانه را کمتر از مقدار واقعی برآورد می‌کنند. به طور متوسط مقادیر ME چه در مرحله آموزش و چه در مرحله آزمون برای توابع اشتقاق یافته از مدل‌های رگرسیونی منفی بود.

نسبت به مدل شماره ۸ است. مقادیر مثبت ME در مرحله آزمون در جدول ۵ نشان می‌دهد که هر سه این مدل‌ها، پایداری خاکدانه را بیش‌تر از مقدار واقعی برآورد می‌کنند در صورتی که در مرحله آموزش (جدول ۴) برای مدل ۳ و ۸ میزان ME منفی بود که

جدول ۳- معادلات رگرسیونی اشتقاق یافته برای برآورد میانگین وزنی قطر خاکدانه (MWD)

Table 3- Derived regression equation for estimation mean weight diameter of aggregates

معادلات خطی رگرسیونی Linear regression eqs.	متغیرهای مستقل Independent variables	شماره مدل Model No.
$MWD=0.519+0.01Clay-0.164D_b$	Clay- D_b	1
$MWD=1.124+0.047OC-0.481D_b$	OC- D_b	2
$MWD=0.373+0.011Clay+0.086OC-0.115D_b$	OC-Clay- D_b	3
$MWD=1.448-0.012Sand-0.01Silt+0.074OC-0.1D_b$	Sand-Silt-OC- D_b	4
$MWD=0.009CaCO_3 -0.009Sand+1.012$	Sand- $CaCO_3$	5
$MWD=0.008CaCO_3 -0.252D_b -0.007Sand+1.012$	D_b -Sand- $CaCO_3$	6
$MWD=1.441-0.013Sand-0.01Silt$	Sand-Silt	7
$MWD=0.085OC-0.01Silt-0.013Sand+1.363$	OC-Silt-Sand	8
$MWD=0.092OC-0.822D_p -0.373D_b +3.067$	D_p -OC- D_b	9
$MWD=-0.301D_b -0.008Sand+1.24$	D_b -Sand	10
$MWD=0.995-3.882d_g -0.226D_b$	D_b - d_g	11
$MWD=0.842-3.273d_g -0.219D_b +0.006CaCO_3$	$CaCO_3$ - D_b - d_g	12
$MWD=0.032\sigma_g +0.151OC-0.057$	OC- σ_g	13
$MWD=0.305+0.028\sigma_g +0.117OC-0.202D_b$	D_b -OC- σ_g	14

OC: organic carbon; D_b : bulk density; D_p : particle density; $CaCO_3$: calcium carbonate equivalent; MWD: mean weight diameter of aggregates; d_g : geometric mean diameter of particles; σ_g : geometric standard deviation of soil particles diameter.

در مدل شماره ۳ و برابر ۰/۰۵۱، ۰/۰۸۷، ۰/۰۲۸ در مدل شماره ۴ بود (جدول ۵). در مدل‌های رگرسیونی از لحاظ آماره AIC مدل شماره ۸ (AIC= -۴۶۳/۸) با متغیرهای ورودی شن، سیلت و کربن آلی دارای عملکرد بهتری نسبت به مدل شماره ۴ (AIC= -۴۶۱/۸) در برآورد میانگین وزنی قطر خاکدانه بود که دلیل آن تعداد پارامتر ورودی بیشتر در مدل شماره ۴ نسبت به مدل شماره ۸ است. مقادیر مثبت ME در مرحله آزمون در جدول ۵ نشان می‌دهد که هر سه این مدل‌ها، پایداری خاکدانه را بیش‌تر از مقدار واقعی برآورد می‌کنند در صورتی که در مرحله آموزش (جدول ۴) برای مدل ۳ و ۸ میزان ME منفی بود که

نتایج مدل‌های آماری رگرسیونی و شبکه عصبی مصنوعی برای برآورد MWD

بهترین مدل‌های آماری برای برآورد میانگین وزنی قطر خاکدانه از لحاظ آماره‌های RMSE و R^2 در داده‌های آموزشی مدل شماره ۳ شامل متغیرهای رس، کربن آلی خاک و جرم ویژه ظاهری و مدل شماره ۴ شامل متغیرهای شن، سیلت، کربن آلی و جرم ویژه ظاهری است (جدول ۴)، که مقادیر R^2 ، RMSE و ME این مدل‌ها در داده‌های آموزشی به ترتیب برابر ۰/۰۵۴، ۰/۰۸۱، ۰/۰۰۴- برای مدل شماره ۳ و برابر ۰/۰۵۵، ۰/۰۸۱، ۰/۰۱۳- برای مدل شماره ۴ و برای داده‌های آزمون به ترتیب برابر، ۰/۰۳۹، ۰/۰۹، ۰/۰۰۸-،

نشان می‌دهد مدل‌ها پایداری خاکدانه را کمتر از مقدار واقعی برآورد می‌کنند. به طور متوسط مقادیر ME چه در مرحله آموزش و چه در مرحله آزمون برای توابع اشتقاق یافته از مدل‌های رگرسیونی منفی بود. از متغیرهای ورودی مدل‌های ۳، ۴ و ۸ که پایداری خاکدانه را به طور قابل قبولی ($R^2=0.81$) و $R^2=0.8$ بیان می‌کنند می‌توان استنباط نمود که در دشت اردبیل مهمترین ویژگی‌های تاثیر گذار در پایداری خاکدانه مقادیر رس، شن، سیلت، کربن آلی و جرم ویژه ظاهری می‌باشد. با این وجود تاثیر سیلت و مواد آلی کمتر از رس، شن و جرم ویژه ظاهری بود (جدول ۲).


بهترین مدل شبکه عصبی در داده‌های آموزشی در برآورد MWD بر اساس شاخص R^2 و RMSE و AIC مدل ۳ با متغیرهای ورودی رس، جرم ویژه ظاهری و کربن آلی خاک بدست آمد. مقادیر R^2 ، RMSE، ME در مرحله آموزش به ترتیب برابر 0.88 ، 0.042 ، 0.0006 (جدول ۴) و در مرحله آزمون به ترتیب برابر 0.89 ، 0.042 ، 0.057 (جدول ۵). مقدار مثبت ME در مرحله آزمون و مقدار منفی آن در مرحله آموزش به ترتیب نشان دهنده مقدار برآورد شده بیشتر و کمتر از مقدار واقعی است. مقادیر منفی ME در اکثر مدل‌های شبکه‌های عصبی در مرحله آموزش و مقادیر مثبت در مرحله آزمون نشان داد که در کل شبکه‌های عصبی مصنوعی مقدار MWD را در مرحله آموزش کمتر از مقدار واقعی و در مرحله آزمون بیش‌تر از مقدار واقعی برآورد می‌کنند (شکل ۲). در طول آزمون مدل‌های رگرسیونی عملکردی مشابه با شبکه‌های عصبی داشتند و در برخی موارد عملکرد مدل‌های رگرسیونی بهتر از مدل‌های شبکه‌های عصبی بود، در تعیین بهترین مدل از داده‌های آزمونی استفاده نشد، چون آزمون مدل‌ها در تشخیص روابط بین داده‌هایی که قبلاً مشاهده نشده است به کار می‌رود و الزاماً بهترین مدل در داده‌های آموزشی نمی‌تواند بهترین مدل در داده‌های آزمونی باشد (Mesri 2009). رضائی و سلطانی (Rezai & Soltani, 1998)، علیجانپور و همکاران (Alijanpour et al., 2001) در تعیین بهترین مدل رگرسیونی از داده‌های آموزشی

استفاده کردند. متوسط مقدار RMSE برای شبکه‌های عصبی مصنوعی اشتقاق یافته از داده‌های آموزشی برابر 0.061 و برای مدل‌های رگرسیونی برابر 0.086 بدست آمد. حداقل مقدار RMSE برای بهترین مدل‌های شبکه‌های عصبی و رگرسیونی در مرحله آموزش به ترتیب برابر با 0.042 و 0.054 بدست آمد. مقایسه شبکه‌های عصبی مصنوعی و توابع انتقالی رگرسیونی در برآورد MWD نشان داد که همه مدل‌های شبکه عصبی دارای R^2 بالاتر و RMSE پایین‌تر نسبت به مدل‌های رگرسیونی هستند. این نتایج با یافته‌های سایر محققان همخوانی دارد. امیرعابدی و همکاران (Amirabedi et al., 2013) برای پی‌ریزی شبکه‌های عصبی از متغیرهای ورودی مدل‌های رگرسیونی به روش گام به گام استفاده کردند. آن‌ها با این روش رطوبت در نقاط اشباع، ظرفیت زراعی، پژمردگی دائم و قابل استفاده را برآورد کردند و گزارش کردند که شبکه‌های عصبی در تمامی موارد دارای عملکردی بهتر در برآورد نقاط رطوبتی می‌باشد. سرمردیان و همکاران (Sarmadian et al., 2011) با استفاده از مدل‌های رگرسیونی و شبکه عصبی مصنوعی بعد فرکتال سطح داخلی خلل و فرج خاک را برآورد کردند و بیان داشتند شبکه‌های عصبی با ۷ نرون در لایه مخفی با دقت بالاتری نسبت به سایر مدل‌های ارائه شده بعد فرکتال سطح داخلی خلل و فرج را از پارامترهای زود یافت برآورد می‌کنند. شاپ و همکاران (Schaap et al., 1998) در طراحی شبکه‌های عصبی نوع خاصی از معادلات لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسبی دست پیدا کرد و به علت وجود روابط غیرخطی میان متغیرهای وابسته و پیش‌بینی شونده شبکه عصبی عملکرد بهتری نسبت به مدل‌های رگرسیونی داشته است. میناسنی و همکاران (Minasni et al., 2002) علت برآورد دقیق‌تر شبکه‌های عصبی مصنوعی نسبت به توابع انتقالی رگرسیونی را در نحوه عملکرد شبکه پرسپترون سه لایه دانسته‌اند، عملکرد این شبکه به این صورت است که ابتدا الگویی به شبکه عرضه می‌شود و خروجی آن محاسبه می‌شود، سپس شبکه این خروجی را با مقادیر

رگرسیونی می‌باشد این محققین گزارش کردند که بهترین مدل شبکه عصبی در برآورد پایداری خاکدانه مدلی با متغیرهای ورودی مقاومت مکانیکی خاک، درصد سیلت، جرم ویژه حقیقی و pH خاک بود. خزایی و همکاران (Khazaee *et al.*, 2008) با استفاده از متغیرهای ورودی رس، کربن آلی و آهک بهترین مدل رگرسیونی را در برآورد میانگین وزنی قطر خاکدانه‌ها بدست آوردند. تاماری و همکاران (Tamari *et al.*, 1996) گزارش کردند زمانی که ناپایداری داده‌ها بالا باشد نتایج مدل‌های شبکه‌های عصبی مصنوعی بهتر از مدل‌های رگرسیونی نخواهد بود اما زمانی که داده‌هایی با دقت بالا به کار برده شوند کارایی شبکه‌های عصبی بیشتر خواهد بود.

خلیل مقدم و افیونی (Khalilmoghadam *et al.*, 2009) کاربرد روش‌های رگرسیونی و شبکه‌های عصبی در تشکیل توابع انتقالی خاک به منظور برآورد هدایت هیدرولیکی اشباع منطقه زاگرس مرکزی را ارزیابی کردند. هدف آنها از این تحقیق، بررسی امکان استفاده از ویژگی‌های توپوگرافی و پوشش گیاهی به همراه ویژگی‌های خاک به عنوان ویژگی‌های زودپافت برای برآورد هدایت هیدرولیکی اشباع خاک بود و گزارش کردند که شبکه‌های عصبی دارای کارایی بهتری از رگرسیون چندمتغیره خطی در برآورد هدایت هیدرولیکی اشباع خاک بود.

اندازه‌گیری شده متغیر یا متغیرهای خروجی مقایسه می‌کند و ضرایب وزنی شبکه را نوعی تغییر می‌دهد که کمترین اختلاف بین مقادیر پیش‌بینی شده و اندازه‌گیری شده باشد. پاچپسکی و همکاران (Pachepsky, *et al.*, 1996) با استفاده از آماره‌های ضریب همبستگی و ریشه میانگین مربعات خطا به بررسی شبکه‌های عصبی مصنوعی و آنالیز رگرسیون پرداختند. آنها نتیجه گرفتند شبکه‌های عصبی برآورد بهتر و با خطای کمتری، بر اساس داده‌های زودپافت خاک دارد. مصری و همکاران (Mesri, 2009) علت برآورد دقیق‌تر شبکه‌های عصبی نسبت به توابع انتقالی رگرسیونی را حساسیت کمتر شبکه‌های عصبی به همراستایی موجود در بین داده‌ها عنوان کردند و بیان داشتند این عوامل تاثیر کمتری در قدرت برآورد آنها می‌گذارد. یلماز و یوکسک (Yilmaz, & Yuksek, 2009) گزارش کردند مدل‌های رگرسیونی خطی تنها قادر به تشخیص روابط خطی بین متغیرهای وابسته و مستقل هستند و چنانچه روابط غیرخطی بین متغیرهای وابسته و مستقل وجود داشته باشد، کارایی این مدل‌ها به حد قابل ملاحظه کاهش می‌یابد. علی جانپور و همکاران (Alijanpour *et al.*, 2011) پایداری خاکدانه را در خاک‌های جنگلی استان گیلان با استفاده از مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی برآورد کردند و گزارش کردند که کارایی شبکه‌های عصبی مصنوعی در برآورد پایداری خاکدانه به طور قابل ملاحظه‌ای بیش‌تر از مدل‌های



شکل ۲- مقادیر اندازه‌گیری و برآورد شده میانگین وزنی قطر خاکدانه (MWD) با استفاده از بهترین مدل رگرسیونی (REG) و شبکه عصبی مصنوعی (ANN)

Figure 2- Measured versus predicted values (1:1) of Mean Weight Diameter of Aggregate, using the best regression model and artificial neural network

جدول ۴- آماره‌های ارزیابی مدل‌های مختلف رگرسیونی و شبکه عصبی مصنوعی (ANN) برای داده‌های آموزشی در برآورد میانگین وزنی قطر خاکدانه (MWD)

Table 4- Evaluating statistics for different regression and artificial neural network (ANN) models for training data in estimating Mean Weight Diameter Aggregates.

ANN				PTF				متغیرهای مستقل Independent variables	شماره مدل Model Number
AIC	RMSE	R ²	ME	AIC	RMSE	R ²	ME		
-495.3	0.045	0.86	-0.001	-453	0.059	0.78	0.0096	Clay-D _b	1
-371.3	0.098	0.38	-0.00007	-366.4	0.1	0.34	0.00005	OC- D _b	2
-505.7	0.042	0.88	-0.00006	-464.2	0.054	0.81	-0.0047	OC-Clay- D _b	3
-488.8	0.046	0.86	-0.00006	-461.8	0.055	0.81	0.013	Sand-Silt-OC-D _b	4
-415.1	0.075	0.64	0.0004	-206.3	0.2	0.58	-0.26	Sand-CaCO ₃	5
-450.8	0.059	0.77	-0.0006	-413.6	0.075	0.64	0.01	D _b -Sand-CaCO ₃	6
-469.8	0.053	0.81	-0.00002	-453.3	0.059	0.78	-0.01	Sand-Silt	7
-491.3	0.046	0.86	-0.0002	-463.8	0.055	0.8	-0.004	OC-Silt-Sand	8
-421.5	0.071	0.67	-0.0005	-374.5	0.095	0.42	0.0007	D _p -OC- D _b	9
-402.7	0.081	0.58	-0.0002	-393.5	0.085	0.63	0.011	D _b -Sand	10
-451.8	0.059	0.77	-0.00004	-394.2	0.085	0.63	-0.039	D _b -d _g	11
-469	0.053	0.82	-0.0001	-420.9	0.071	0.67	-0.006	CaCO ₃ - D _b -d _g	12
-440.3	0.064	0.73	-0.0004	-419	0.073	0.65	0.002	OC- σ _g	13
-472.3	0.052	0.83	-0.0005	-427.1	0.068	0.69	-0.0018	D _b -OC-σ _g	14

OC: organic carbon; D_b: bulk density; D_p: particle density; CaCO₃: calcium carbonate equivalent; MWD: mean weight diameter of aggregates; d_g: geometric mean diameter of particles; σ_g: geometric standard deviation of soil particles diameter.

جدول ۵- آماره‌های ارزیابی مدل‌های مختلف رگرسیونی و شبکه عصبی مصنوعی (ANN) برای داده‌های آزمونی در برآورد میانگین وزنی قطر خاکدانه (MWD)

Table 5- Evaluating statistics for different regression and artificial neural network (ANN) models for testing data in estimating mean weight diameter of aggregates

ANN			PTF			متغیرهای مستقل Independent variables	شماره مدل Model Number
RMSE	R ²	ME	RMSE	R ²	ME		
0.1	0.87	-0.09	0.048	0.85	-0.015	Clay-D _b	1
0.065	0.74	-0.006	0.081	0.55	0.003	OC- D _b	2
0.057	0.89	0.042	0.039	0.9	0.008	OC-Clay- D _b	3
0.053	0.84	0.023	0.051	0.87	0.028	Sand-Silt-OC-D _b	4
0.077	0.61	0.007	0.26	0.55	-0.24	Sand-CaCO ₃	5
0.065	0.72	0.008	0.077	0.66	0.022	D _b -Sand-CaCO ₃	6
0.062	0.74	0.013	0.053	0.8	-0.007	Sand-Silt	7
0.052	0.85	0.023	0.046	0.86	0.011	OC-Silt-Sand	8
0.089	0.71	0.039	0.076	0.63	0.022	D _p -OC- D _b	9
0.076	0.62	0.0047	0.087	0.55	0.025	D _b -Sand	10
0.062	0.75	0.01	0.081	0.64	-0.022	D _b -d _g	11
0.061	0.75	0.008	0.071	0.7	0.007	CaCO ₃ - D _b -d _g	12
0.068	0.71	0.019	0.064	0.74	0.018	OC- σ _g	13
0.058	0.77	0.012	0.056	0.79	0.013	D _b -OC-σ _g	14

OC: organic carbon; D_b: bulk density; D_p: particle density; CaCO₃: calcium carbonate equivalent; MWD: mean weight diameter of aggregates; d_g: geometric mean diameter of particles; σ_g: geometric standard deviation of soil particles diameter.

نتیجه‌گیری کلی

شبکه‌های عصبی در برآورد میانگین وزنی قطر خاکدانه نسبت به مدل‌های رگرسیونی بیشتر است. هر دو روش بهترین عملکرد را با متغیرهای ورودی جرم ویژه ظاهری، کربن آلی و رس داشتند همچنین نتایج نشان داد از هر دو روش در منطقه مورد مطالعه با دقت قابل قبولی در برآورد پارامتر مورد نظر می‌توان استفاده کرد.

در این پژوهش از مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی در برآورد میانگین وزنی قطر خاکدانه‌ها استفاده شد. مقادیر R²، RMSE و AIC برای بهترین مدل رگرسیونی و شبکه عصبی به ترتیب برابر ۰/۸۱، ۰/۰۵۴ و ۴۶۴/۲- برای مدل رگرسیونی و ۰/۸۸، ۰/۰۴۲ و ۵۰۵/۷- برای مدل شبکه عصبی بود. این مقادیر نشان دادند دقت

References

- Alijanpour Shalmani A., Shabanpour M., Asadi H., and Bagheri F. 2011. Estimation of soil aggregate stability in forest's soils of Guilan province by artificial neural networks and regression pedotransfer functions. *Journal of Soil and Water*, 21 (3):153-162. (In Persian)
- Amezketta E., Arguós R., Carranza R., and Urgel B. 2003. Macro and microaggregate stability of soils determined by a combination of wet sieving and laser-ray diffraction. *Spanish Journal of Agriculture Research*, 4 (1): 83-94.
- Amirabedi H., Asghari Sh., Mesri T., and Keivanbehjo F. 2013. Estimating of field capacity, permanent wilting point and available water content in Ardabil plain using regression and artificial neural network models. *Applied Soil Research*, 1(1):60-72.
- Angers D.A., Peasant A., and Vigneus J. 1992. Early cropping included changes in soil aggregation, organic carbon, and microbial biomass. *Soil Science Society of American Journal*, 56: 115-119.
- Aringhieri R. and Sequi P. 1979. The arrangement of organic matter in a soil crumb. In: Emerson WW (Eds.), *Modification of Soil Structure*. John Wiley and Sons, Chichester, pp. 145-150.
- Arshad M.A., and Coen G.M. 1992. Characterization of soil quality: physical and chemical criteria. *America Journal of Alternative Agriculture*, 7:25-31.
- Barzegar A.R., Oades J.M., Rengasamy P., and Giles L. 1994. Effect of sodicity and salinity on disaggregation and tensile strength of an Alfisol under different cropping systems. *Soil and Tillage Research*, 32: 329- 345.
- Basalatpour A., Haj Abbasi M., and Ayyoubi Sh. 2011. Estimation of some physical and mechanical characteristics of the soil using artificial neural networks. *Sixth National Congress of Civil Engineering, 26-27 April, Semnan*. (In Persian)
- Bear M.H., Hendrix P.F., and Coleman D.C. 1994. Water stable aggregates and organic carbon fractions in conventional and no tillage soils. *Soil Science Society of American Journal*, 58: 777-786.
- Blair N. 2000. Impact of cultivation and sugarcane green trash management on carbon fractions and aggregate stability for a cromaticluvisol Queensland, Australia. *Soil and Tillage Research*, 55: 183-191.
- Boix-Fayos C., Calvo-Cases A., Imeson, A.C., and Soriano-Soto, MD. 2001. Influence of soil properties on the aggregation of some Mediterranean soils and the use of aggregate size and stability as land degradation indicators. *Catena*, 44: 47-67.
- Calero N., Barron V. and Torrent J. 2008. Water dispersible clay in calcareous soil south western in Spain. *Catena*, 74: 22-30.
- Campbell G.S. 1985. *Soil Physics with Basic: Transport Models for Soil-Plant System*. Elsevier, New York.
- Celik I. 2005. Land-use effects on organic matter and physical properties of soil in a southern Mediterranean highland of Turkey. *Soil and Tillage Research*, 83: 270-277.
- Chan K.Y., and Heenan D.P. 1996. The influence of crop rotation on soil structure and soil physical properties under conventional tillage. *Soil and Tillage Research*, 37: 113- 125.
- Chenu C., LeBissonnias Y., and Arrouays D. 2000. Organic matter influence on clay wettability and soil aggregate stability. *Soil Science Society of America Journal*, 64: 1479-1486.
- Emerson, W.W. 1991. Structural decline of soils, assessment and prevention. *Australian Journal of Soil Research*, 24: 905-921.
- Etminan S., Kiani F., and Habashi H. 2011. Effect of soil properties with different parent materials on aggregate stability in Shastkola watershed, Golestan province. *Journal of Soil Management and Sustainable Production*, 1(2): 39-60. (In Persian)

- Ghorbani-Dashtaki Sh., Homae M., and Mahdian M. 2009. Estimating soil water infiltration parameters using Artificial Neural Networks. *Journal of Water and Soil*, 23(1):185-198. (In Persian)
- Hillel D. 2004. Introduction to Environmental Soil Physics. Elsevier, Academic Press, Amsterdam, 494p.
- Ismail I., Blevins R.L., and Frye W.W. 1994. Long-term no-tillage effects on soil properties and continuous corn yields. *Soil Science Society of America Journal*, 58:193-198.
- Kemper A., and Rosenau R.C. 1986. Aggregate stability and size distribution. In: Klute A. (Eds.), *Methods of Soil Analysis. Part 1, America Society of Agronomy and Soil Science Society of America*, Madison, WI.
- Ketcheson J. 1980. Long range effects of intensive cultivation and monoculture on the quality of southern Ontario soils. *Canadian Journal Soil Science*, 60: 403-410.
- Khalilmoghadam B., Afyuni M., Abbaspour K.C., Jalalian A., Dehgani 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.
- Khashei Siuki A., Jalali Moakhar V., Nofaresti A., and Ramazani Y. 2015. Comparing nonparametric k-nearest neighbor technique with ANN models for predicting soil saturated hydraulic conductivity. *Journal of Soil Management and Sustainable Production*, 5(3): 81-95. (In Persian)
- Khazae A., Mosaddeghi M.R., and Mahboubi A.A. 2008. Structural stability assessment using wet sieving method and its relations with some intrinsic properties in 21 soil series from Hamadan province. *Agricultural Research*, 8(1):171-181.
- Klute A. 1986. *Methods of Soil Analysis. Part 1. Physical and Mineralogical Methods*. 2nd edition. *American Society of Agronomy and Soil Science Society of America*, Madison, WI.
- Koutikka L.S., Bartoli F., Andreux C.C., Cerri G., Burtin T.C., and Philippy R. 1997. Organic matter dynamics and aggregation in soils under rain forest and pastures of increasing age in the eastern Amazon basin. *Geoderma*, 76: 87-112.
- Lado M., Paz A., and Ben-Hur M. 2004. Organic matter and aggregate size interactions in infiltration, seal formation and soil loss. *Soil Science Society of America Journal*, 68: 935-942.
- Merdun H., Cinar O., Meral R. and Apan M. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research*, 90: 108-116.
- Mesri Gundoshmian T. 2009. The use of intelligent systems to optimize drop combine. PhDthesis, *Engineering of Agriculture Machinery and Mechanization Department*, University of Tabriz. (In Persian)
- Minasny B., and Mcbartney A.B. 2002. The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*, 66: 352-361.
- Pachepsky Y.A., Timlin D.J., and Varallyay G. 1996. Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Science Society of America Journal*, 60: 727-773.
- Rezai A., and Soltani A. 1998. Introduction to Applied Regression Analysis. Isfahan University Press. (In Persian)
- Sarmadian F., GhanbarianAlavijeh B., Taghizadeh Mehrjardi R., and Keshavarzi A. 2011. Comparison of linear and nonlinear pedotransfer functions with artificial neural networks in prediction of surface fractal dimension. *Journal of Range and Watershed Management*, 64(1): 53-64.
- Schaap M.G., Leij F.J., and Van Genuchten M.T. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Science Society of America Journal*, 62:847-855.

- Seta A., and Karathanasis A. 1996. Water dispersible colloids and factors influencing their dispersibility from soil aggregates. *Geoderma*, 74: 255-266.
- Shrestha B.M., Singh B.K., Sitaula R.L., and Barjacharya R.M. 2007. Soil aggregate and particle associated organic carbon under different land use in Nepal. *Soil Science Society of America Journal*, 71: 1194- 1203.
- Skidmore C.A., and Layton J.B. 1992. Dry- soil aggregate stability as influenced by selected soil properties. *Soil Science Society of America Journal*, 75: 557-561.
- Skidmore E.L., and Layton J.B. 1992. Dry-soil aggregate stability as influenced by selected soil properties. *Soil Science Society of America Journal*, 56(2): 557-561.
- Tajik F., Pazira A., and Rahimi A. 1998. The effect of organic matter on soil physical and mechanical properties. *Articles Collections specialized scientific and technical research Agricultural Engineering*, 3(10): 1-20. (In Persian)
- Tajik F. 2004. Evaluation of aggregates stability in the some parts of Iran. *Water and Soil Science*, 8(1): 134-125. (In Persian)
- Tamari S., Wosten J.H., and Ruiz-Suarez JC. 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Science Society of America Journal*, 60: 1732–1741.
- Watts C.W., and Dexter, A.R. 1997. The influence of organic matter in reducing the destabilization of soil bay simulated tillage. *Soil and Tillage Research*, 42: 253-275.
- Yilmaz I., and Yuksek G. 2009. Prediction of the strength and elasticity modulus gypsum using multiple regression, ANN, and ANFIS models. *International Journal of Rock Mechanics and Mining Sciences*, 46: 803-810.

Prediction of Mean Weight Diameter of Aggregates using Artificial Neural Network and Regression Models

Hamed Amir Abedi^{1*}, Shokr Allah Asghari², Tarahom Mesri Ghandomshin³,
Naser Balandeh⁴

(Received: April 2016 Accepted: August 2016)

Abstract

Direct measurement of soil physical properties is time consuming, costly and sometimes unreliable because of soil heterogeneity and experimental errors. Stability of aggregates could be estimated from surrogate data such as soil texture, bulk density, organic carbon and CaCO_3 using pedotransfer function (PTF). The objective of this research was to present regression PTFs and artificial neural network models to predict mean weight diameter (MWD) of aggregate from limited sets of soil properties and to assess the efficiency of the presented models to predict the MWD with the statistical criteria including the coefficient of determination (R^2) and root mean square deviation (RMSE). In total, 100 soil sample were collected from Ardabil plain and analyzed for their physicals and chemicals properties. Soil samples were divided into two groups, so that, 80 samples were used for the development and remaining 20 samples for the validation of PTFs. The values of R^2 and RMSE for regression PTFs and artificial neural networks were, respectively, 0.88, 0.42 for neural networks and 0.81, 0.054 for regression PTF. Results showed that two methods could be applied to predict the MWD in Ardabil plain. However, artificial neural networks performed better than regression model in this study.

Keywords: Aggregate stability, Neural networks, Pedotransfer function

1-MSc. Graduate, Department of Soil Science, University of Mohaghegh Ardebili

2-Associate Professor, Department of Soil Science, University of Mohaghegh Ardebili

3-Assistant Professor, Department of Soil Science, University of Mohaghegh Ardebili

4-MSc. Department of Soil Science, Urmia University

* Corresponding author Email: amirabedihamed@yahoo.com