

برآورد رطوبت‌های ظرفیت زراعی، پژمردگی دائم و قابل استفاده در خاک‌های دشت اردبیل با استفاده از مدل‌های رگرسیونی و شبکه عصبی مصنوعی

حامد امیرعابدی^۱، شکراله اصغری^{۲*}، ترحم مصری گندشمین^۳، فرشاد کیوان بهجو^۴

۱- دانشجوی کارشناسی ارشد، گروه علوم خاک، دانشگاه محقق اردبیلی

۲- استادیار، گروه علوم خاک، دانشگاه محقق اردبیلی

۳- استادیار، گروه مکانیک ماشین‌های کشاورزی، دانشگاه محقق اردبیلی

۴- استادیار، گروه مرتع و آبخیزداری، دانشگاه محقق اردبیلی

* نویسنده مسئول: Sh_asghari2005@yahoo.com

تاریخ دریافت: ۹۱/۰۸/۰۶ تاریخ پذیرش: ۹۱/۱۲/۲۲

چکیده

اندازه‌گیری مستقیم ویژگی‌های هیدرولیکی خاک وقت‌گیر، پرهزینه و گاهی اوقات به دلیل خطاهای آزمایشی و عدم یکنواختی خاک غیر واقعی است. در عوض، این ویژگی‌ها می‌توانند از روی ویژگی‌های زودپافت خاک مانند توزیع اندازه ذرات خاک، جرم ویژه ظاهری، کربن آلی و کربنات کلسیم معادل با استفاده از توابع انتقالی خاک برآورد شوند. هدف از این پژوهش، ارائه مدل‌های رگرسیونی و شبکه عصبی مصنوعی بر اساس ویژگی‌های زودپافت یاد شده برای برآورد ویژگی‌های دیرپافت شامل رطوبت‌های ظرفیت زراعی، پژمردگی دائم و قابل استفاده در شماری از خاک‌های دشت اردبیل بود. برای این منظور ۱۰۰ نمونه خاک برداشته شد سپس برخی ویژگی‌های فیزیکی و شیمیایی آنها اندازه‌گیری شد. داده‌ها به دو سری داده‌های آموزشی (۸۰ نمونه) و داده‌های آزمونی (۲۰ نمونه) تقسیم شدند. برای ایجاد مدل‌های شبکه عصبی از نرم‌افزار 5 Neurosolution و برای ایجاد مدل‌های رگرسیونی از نرم‌افزار SPSS استفاده شد. مقادیر ضریب تبیین (R^2) و مجذور میانگین مربعات خطا (RMSE) در تخمین پارامترهای دیرپافت شامل رطوبت‌های ظرفیت زراعی، پژمردگی دائم و قابل استفاده به ترتیب برابر ۰/۸۲ و ۰/۲۲۹، ۰/۸۲ و ۱/۳۸، ۰/۵۷ و ۱/۹۷ برای بهترین مدل رگرسیونی و به ترتیب برابر ۰/۸۷ و ۰/۹۰ و ۰/۷۳، ۱/۰۲ و ۱/۵۶ برای بهترین مدل شبکه عصبی مصنوعی بود. مقادیر R^2 و RMSE برای نتایج مدل‌های رگرسیونی و شبکه عصبی مصنوعی نشان داد که هر دو روش می‌توانند ضرایب رطوبتی خاک را با دقت مناسبی برآورد کنند. با این حال، مدل‌های رگرسیونی در برآورد رطوبت قابل استفاده کارایی لازم را نداشتند. دقت تخمین ضرایب رطوبتی توسط مدل‌های شبکه عصبی مصنوعی بیشتر از مدل‌های رگرسیونی بود.

واژه‌های کلیدی: توابع انتقالی خاک، رطوبت پژمردگی دائم، رطوبت ظرفیت زراعی، رگرسیون، شبکه عصبی مصنوعی

مقدمه

و مقدار آبی است که پس از خروج آب ثقلی در خاک نگه‌داری می‌شود. نقطه پژمردگی دائم حد پایین آب قابل استفاده است و اعتقاد بر این است که گیاه در آن به طور غیر قابل برگشت دچار تنش خشکی و پژمردگی می‌گردد. حد FC اغلب تنها به ویژگی‌های خاک بستگی دارد ولی حد PWP نه تنها به ویژگی‌های خاک بلکه به نوع گیاه، تراکم

برای زمان‌بندی مناسب آبیاری، اطلاع از میزان ذخیره رطوبت خاک بسیار ضروری است. آب قابل استفاده (AW) مقدار رطوبتی است که بین دو حد ظرفیت زراعی (FC) و نقطه پژمردگی دائم (PWP) قرار می‌گیرد. ظرفیت زراعی حد بالای آب قابل استفاده بوده

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 داده آموزش برای هر پارامتر مثل جرم ویژه ظاهری خاک (مثلاً از ۰/۹۵ تا ۱/۶۵ گرم بر سانتی متر مکعب) اهمیتی بیشتر از تعداد داده انتخابی (مثلاً ۱۰۰ یا ۱۵۰ داده) برای پارامتر مذکور به منظور تخمین ویژگی‌های دیرپافت خاک دارد. نوایبان و همکاران (۲۰۰۴) امکان برآورد سریع هدایت هیدرولیکی اشباع خاک توسط شبکه عصبی مصنوعی و رگرسیون را بررسی و نتیجه گرفتند که در این مورد شبکه‌های عصبی مصنوعی در مقایسه با روابط رگرسیونی دقت نسبتاً بهتری دارند. خداوردیلو و همکاران (۲۰۱۱) از توابع انتقالی رگرسیونی به منظور برآورد نگه‌داشت رطوبتی در مکش‌های مختلف و همچنین پارامترهای معادله وان‌گنوختن (۱۹۸۰) در خاک‌های آهکی استفاده کردند و نتایج حاصله را با نتایج مدل‌های رزتا مورد مقایسه قرار دادند و گزارش کردند که توابع انتقالی رگرسیونی دقت بیشتری در تخمین نگه‌داشت رطوبتی نسبت به مدل رزتا دارد و علت آن را کارایی پایین مدل‌های رزتا در خاک‌های آهکی ایران بیان داشتند. نتایج تحقیق مصدقی و محبوبی (۲۰۱۱) نشان داد که با استفاده از توابع انتقالی نقطه‌ای می‌توان نقاط مختلف منحنی رطوبتی را در خاک‌های منتخب از دشت همدان با استفاده از خصوصیات زودپافت شامل جرم ویژه ظاهری، توزیع اندازه ذرات، سنگریزه، کربنات کلسیم و ماده آلی با دقت قابل قبولی برآورد نمود. بر اساس اطلاعات موجود تاکنون مطالعه‌ای در زمینه تخمین ضرایب رطوبتی خاک‌های دشت اردبیل انجام نگرفته است. لذا این پژوهش با هدف امکان تخمین ضرایب رطوبتی FC، PWP و AW با استفاده از مدل‌های رگرسیونی و شبکه عصبی مصنوعی در خاک‌های دشت اردبیل و نیز مقایسه دقت این روش‌ها در برآورد این ویژگی‌ها صورت گرفت.

مواد و روش‌ها

نمونه‌های خاک دست خورده به مقدار حدود ۳ کیلوگرم و نمونه‌های خاک دست نخورده با استفاده از استوانه‌های فولادی به قطر و ارتفاع ۵ cm از افق Ap خاک در ۱۰۰ نقطه از دشت اردبیل به طور تصادفی با فواصل حدود ۳۰۰۰ متر از یکدیگر برداشته شد. نمونه‌های دست

سیستم ریشه‌ای و وضعیت اقلیمی نیز بستگی دارد (Klute, 1986). اگر همه این عوامل در نظر گرفته شود اندازه‌گیری PWP بسیار مشکل و وقت‌گیر خواهد بود. اگر ناحیه مورد مطالعه نسبتاً کوچک باشد و یا اینکه به اندازه کافی از لحاظ ویژگی‌های فیزیکی خاک همگن باشد، می‌توان با انجام تعداد قابل قبولی از آزمایش‌های مزرعه‌ای تخمین‌های خوبی از میزان رطوبت‌های FC، PWP و AW به عمل آورد. اما اگر ناحیه مورد مطالعه نسبتاً وسیع باشد به طوری که تغییرات مکانی قابل توجهی در ویژگی‌های هیدرولیکی خاک مشاهده گردد تقریباً غیر ممکن است بتوان تعداد آزمایش‌ها را به گونه‌ای تنظیم کرد که علاوه بر تخمین دقیق رطوبت در نقاط یاد شده، محدودیت‌های هزینه‌ای و زمانی پروژه را نیز رعایت کرد (Schaap *et al.*, 2001). روش‌های غیرمستقیم در حقیقت به عنوان راه حلی برای مشکلات فوق به دنبال پیش‌بینی ویژگی‌های هیدرولیکی خاک با استفاده از پارامترهای زودپافت اندازه‌گیری شده می‌باشد. مفهوم توابع انتقالی خاک^۱ نخستین بار توسط بوما (۱۹۸۹) مطرح شد. توابع انتقالی ویژگی‌های خاصی از خاک را (عمدتاً ویژگی‌های هیدرولیکی) با استفاده از ویژگی‌های پایه خاک برآورد می‌کنند (McBratney *et al.*, 2002). گام معمول در اشتقاق توابع انتقالی ارائه روابط تجربی میان ویژگی‌های پایه خاک و عواملی است که باید پیش‌بینی شوند. روش‌های رگرسیونی (Schaap & Bouten, 1996) و شبکه عصبی مصنوعی (Merdun *et al.*, 2006; Minasny *et al.*, 1999; Pachepsky *et al.*, 1996) دو ابزار پرکاربرد برای تهیه توابع انتقالی خاک می‌باشد. شبکه عصبی مصنوعی حاصل تلاش موازی و مرتبط چندین رشته علمی از جمله ریاضیات، فیزیک، عصب شناسی و کامپیوتر می‌باشد. تقریباً نتیجه تمامی پژوهش‌های پیشین نشان می‌دهد که شبکه‌های عصبی حداقل به اندازه مابقی روش‌های مورد استفاده برای اشتقاق توابع انتقالی خاک خوب عمل می‌کنند. اسخاپ و همکاران (۱۹۹۸) نشان دادند که کیفیت پیش‌بینی توابع انتقالی خاک توسط شبکه عصبی وابسته به

1 - Pedotransfer functions

نخواهد آورد (Mesri, 2009). در تحقیق حاضر آزمون نرمال بودن داده‌ها با استفاده از نرم‌افزار SPSS صورت گرفت. نتایج آزمون نرمال بودن داده‌ها نشان داد که توزیع همه متغیرهای به کار رفته در مدل، به جز میانگین هندسی قطر ذرات خاک (d_g) نرمال بود. تبدیل زیر برای نرمال کردن (d_g) صورت گرفت.

$$d_{gn} = (d_g)^{0.5} \quad (5)$$

به منظور تعیین میزان همبستگی بین متغیرهای مستقل، از نرم افزار SPSS16 استفاده شد. برای ارزیابی همراستایی خطی چندگانه در مدل‌های رگرسیونی ایجاد شده از فاکتور تورم واریانس^۲ (VIF) استفاده شد (Khodaverdiloo *et al.*, 2011). داده‌ها در نرم‌افزار Excel به صورت تصادفی به دو گروه ۸۰ تایی داده‌های آموزشی و ۲۰ تایی داده‌های آزمونی تقسیم شدند. در این پژوهش FC، PWP و AW ویژگی‌های دیرپافت خاک را شامل می‌شدند که با استفاده از شبکه‌های عصبی مصنوعی و مدل‌های رگرسیونی با ویژگی‌های زودپافت خاک مانند توزیع اندازه ذرات، کربن آلی، کربنات کلسیم معادل، جرم ویژه ظاهری، جرم ویژه حقیقی، (d_g) و (σ_g) ذرات خاک مرتبط شدند.

اشتقاق توابع انتقالی رگرسیونی و شبکه‌های عصبی مصنوعی

برای اشتقاق معادلات رگرسیونی خطی چندگانه از نرم افزار SPSS16 و روش گام به گام و برای ایجاد شبکه‌های عصبی مصنوعی از نرم افزار Neuro solution 5 استفاده شد. برای انتخاب متغیرهای ورودی معادلات رگرسیونی و شبکه عصبی از رگرسیون گام به گام در سطح ۵ درصد استفاده شد. به این ترتیب که ابتدا معادلات رگرسیونی در سطح ۵ درصد ایجاد شدند سپس از متغیرهای ورودی معادلات رگرسیونی برای ایجاد مدل‌های شبکه عصبی استفاده شد. تمام مدل‌های شبکه‌های عصبی از ۲ تا ۴ ویژگی زودپافت در لایه ورودی، ۱ تا ۱۶ نرون با تابع فعال ساز تانژانت هایپربولیک^۳ و الگوریتم^۴ آموزشی مومنتم^۵ در لایه مخفی و

خورده در آزمایشگاه هوا خشک و از الک ۲ mm عبور داده شد. درصدهای شن، سیلت و رس به روش هیدرومتری ۴ قرائته، جرم ویژه حقیقی (D_p) به روش پیکنومتر، جرم ویژه ظاهری (D_b) به روش استوانه دست نخورده، کربن آلی (OC) به روش اکسیداسیون تر، کربنات کلسیم معادل به روش تیتراسیون با اسید مطابق دستورالعمل‌های استاندارد ارائه شده در منابع کلت میانگین هندسی قطر (d_g) و انحراف استاندارد هندسی قطر (σ_g) ذرات خاک از روی درصدهای شن، سیلت و رس محاسبه گردید (Shirazi & Boersma, 1984).

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

$$\sigma_g = \exp b \quad (2)$$

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

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

اندازه‌گیری رطوبت خاک در فشارهای ۰/۱ بار (معادل رطوبت FC در خاک‌های شنی) و ۰/۳ بار (معادل رطوبت FC در خاک‌های رسی) با دستگاه صفحات فشاری در نمونه‌های خاک دست نخورده (استوانه‌ها) و به روش وزنی انجام گرفت. اندازه‌گیری رطوبت خاک در فشار ۱۵ بار (معادل رطوبت PWP در همه خاک‌ها) در نمونه‌های خاک دست خورده ($< 2\text{mm}$) با استفاده از دستگاه صفحات فشاری و به روش وزنی انجام شد (Gardner, 1986). مقدار آب قابل استفاده (AW) از اختلاف رطوبت‌های FC و PWP محاسبه گردید (Baur & Black, 1992).

همراستایی چندگانه و نرمال کردن داده‌ها

در رگرسیون خطی چندگانه، گام اول در تجزیه و تحلیل داده‌ها، نرمال کردن داده‌ها است، زیرا آمار پارامتریک بر پایه فرض نرمال بودن داده‌ها استوار است. شبکه‌های عصبی مصنوعی، جزو روش‌های تحلیل ناپارامتری هستند و بر پیش‌فرض نرمال بودن توزیع داده‌ها استوار نیستند لذا اگر توزیع داده‌ها نرمال نباشد، تحلیل داده‌ها به روش شبکه عصبی مشکلی را به وجود

²- Variation inflation factor

³- Hyperbolic

⁴- Algorithm

⁵- Momentom

دهد که مدل پارامتر را کمتر از مقدار واقعی برآورد می‌کند:

$$ME = \frac{\sum_{i=1}^n (Y_i(m) - Y_i(p))}{n} \quad (7)$$

به دلیل اینکه که تعداد پارامترهای ورودی در مدل‌ها متفاوت بود علاوه بر آماره‌های یاد شده از ضریب آکائیک^۷ (AIC) برای ارزیابی روش‌های رگرسیون و شبکه عصبی در پیش‌بینی ضرایب رطوبتی استفاده گردید (Ganbarian et al., 2004; Minasny & McBratney., 2002) استفاده شد.

محاسبه شد:

$$AIC = n \ln\left(\frac{ESS}{n}\right) + 2q \quad (8)$$

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

دامنه تغییرات و ضریب همبستگی ویژگی‌های زود یافت و دیر یافت اندازه‌گیری شده

آماره‌های توصیفی پارامترهای اندازه‌گیری شده در خاک دشت اردبیل برای توسعه و ارزیابی توابع انتقالی با استفاده از مدل‌های رگرسیونی و شبکه‌های عصبی در جدول ۱ برای داده‌های آموزشی و آزمونی خلاصه شده است. دامنه تغییرات درصدهای شن، سیلت و رس به ترتیب ۶۸-۲۴/۴، ۵۷/۶-۴/۴ و ۴۲/۹-۴/۴ بود. دامنه تغییرات درصد کربنات کلسیم معادل و کربن آلی به ترتیب ۳۷/۵-۳/۷۵، ۳۱/۳-۰/۳۱ تا ۱/۵۲ بود. دامنه تغییرات جرم ویژه ظاهری از ۱/۰۴ تا ۱/۷ گرم بر سانتی متر مکعب، جرم ویژه حقیقی از ۲/۵ تا ۲/۷ گرم بر سانتی متر مکعب، رطوبت ظرفیت زراعی از ۱۳/۸ تا ۳۶/۳ درصد وزنی، رطوبت نقطه پژمردگی دائم از ۷ تا ۲۰ درصد وزنی و آب قابل استفاده از ۴/۲ و ۱۸/۳ درصد وزنی متغیر بود. با توجه به جدول ۱ مشاهده می‌شود که در خاک دشت اردبیل همانند سایر خاک‌های مناطق نیمه خشک ایران به طور میانگین دارای مقدار کربن آلی کمتر از یک درصد می‌باشد. ناچیز بودن کربن آلی در این خاک‌ها باعث

تابع فعال ساز خطی در لایه خروجی تشکیل شدند. تعداد تکرار برای رسیدن به حداقل میزان خطا و حداکثر پایداری شبکه به صورت میانگین برابر با ۱۰۰۰ منظور گردید. الگوریتم برآورد خطا با الگوریتم پس‌انتشار خطا^۶ صورت گرفت و از شبکه عصبی مصنوعی با ساختار پرسپترون سه لایه (Merdun et al., 2006; Navabian et al., 2004; Minasny & McBratney., 2002) استفاده شد.

معیارهای ارزیابی

به منظور مقایسه عملکرد توابع انتقالی رگرسیونی و شبکه‌های عصبی مصنوعی برای پیش‌بینی ویژگی‌های دیریافت خاک، از آماره‌های مجذور میانگین مربعات خطا (RMSE)، متوسط خطا (ME) و ضریب تبیین (R^2) استفاده گردید (Merdun et al., 2006). مقادیر RMSE برای داده‌های مورد استفاده در آموزش و آزمون مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی با استفاده از معادله (۶) (Merdun et al., 2006) بدست آمد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i(m) - Y_i(p))^2}{n}} \quad (6)$$

که در آن $Y_i(m)$ مقدار اندازه‌گیری شده پارامتر، $Y_i(p)$ مقدار برآورد شده پارامتر توسط مدل و n تعداد داده برای پارامتر، می‌باشد.

به لحاظ آماری حداقل مقدار RMSE برابر صفر بوده و زمانی است که مقادیر پیش‌بینی شده با مقادیر اندازه‌گیری شده پارامتر برابر باشند. هرچقدر مقادیر این آماره کمتر باشد، میزان خطای برآوردهای انجام شده توسط مدل تخمین زنده دارای دقت بیشتری خواهد بود. برای بیان تمایل مدل به بیش‌برآوردی یا کم‌برآوردی از آماره میانگین خطا (ME) (معادله ۷) استفاده شد (Merdun et al., 2006). مقادیر مثبت این آماره نشان می‌دهد که مدل پارامتر مورد نظر را بیشتر از مقدار واقعی برآورد می‌کند و مقادیر منفی آن نشان می‌-

گردیده است که میزان آب قابل استفاده در آن پایین بوده و به طور میانگین برابر با ۱۱/۸ درصد وزنی باشد.

جدول (۱) آماره‌های توصیفی پارامترهای اندازه‌گیری شده برای داده‌های آموزشی و آزمونی در خاک دشت اردبیل.
Table 1) Descriptive statistics of the measured parameters for training and testing data in Ardabil plain soils.

داده‌های آموزشی				داده‌های آزمونی				پارامتر
انحراف استاندارد	میانگین	حداکثر	حداقل	انحراف استاندارد	میانگین	حداکثر	حداقل	
9.03	19.18	42.2	3.8	9.3	20.61	42.9	4.4	Clay (%)
10.96	36.41	49.9	28.3	7.75	37.93	57.6	24.4	Silt (%)
8.42	44.4	65	28.3	8.3	41.45	68	24.4	Sand (%)
0.2	0.69	1.09	0.37	0.25	0.85	1.52	0.31	OC (%)
3.67	14.4	21.25	6.26	5.3	14.92	37.5	3.75	CaCO ₃ (%)
0.05	2.6	2.7	2.53	0.04	2.58	2.7	2.5	D _p (gr/cm ³)
0.15	1.38	1.6	1.15	0.14	1.35	1.7	1.04	D _b (gr/cm ³)
3.03	12.42	17.5	6.4	3.3	12.76	20	7	θ_{pwp} (% $\frac{w}{w}$)
7.26	24.24	41.1	16.02	5.48	24.56	36.3	13.8	θ_{FC} (% $\frac{w}{w}$)
4.82	11.82	23.6	3.62	3.04	11.79	18.3	4.2	AW (% $\frac{w}{w}$)

Clay، رس؛ Silt، سیلت؛ Sand، شن؛ OC، کربن آلی؛ D_b، جرم ویژه ظاهری؛ D_p، جرم ویژه حقیقی؛ d_g، میانگین هندسی قطر ذرات خاک؛ σ_g انحراف استاندارد هندسی قطر ذرات خاک؛ CaCO₃، کربنات کلسیم معادل؛ θ_{pwp} ، رطوبت نقطه پژمردگی دائم؛ θ_{FC} ، رطوبت ظرفیت زراعی؛ AW، رطوبت قابل استفاده.

مثبت متغیرهای مستقل بر روی رطوبت ظرفیت زراعی تماماً در سطح یک درصد (به جزء اثر سیلت) معنی‌دار شد. با افزایش میزان شن و سیلت در خاک به علت افزایش منافذ درشت، میزان آب ثقیلی افزایش و θ_{FC} کاهش می‌یابد (Warrick, 2002). با توجه به جدول ۳ همگی متغیرهای مستقل (به جزء کربن آلی) همبستگی معنی‌داری با رطوبت پژمردگی دائم (θ_{pwp}) نشان دادند لکن رس در بین سایر پارامترها بیشترین تأثیر را بر θ_{pwp} داشت ($r=0.78^{**}$). همبستگی منفی و معنی‌دار بین شن با θ_{pwp} به دلیل تأثیر منفی آن بر سطح ویژه ذرات خاک به دست آمد ($r=-0.63^{**}$). از بین متغیرهای مستقل، کربن آلی کمترین تأثیر را بر θ_{pwp} داشت که احتمالاً به این دلیل باشد چون در خاک‌های دشت اردبیل مقدار کربن آلی و دامنه تغییرات آن نسبت به متغیرهای مستقل دیگر کم بود باعث گردید تا اثر آن در تخمین پارامتر θ_{pwp} کمتر باشد. جدول ۳ نشان می‌دهد مقادیر ضرایب همبستگی برای رطوبت قابل استفاده (θ_{AW}) احتمالاً به دلیل محاسبه‌ای بودن این پارامتر به مراتب پایین‌تر از

مقادیر ضریب همبستگی بین متغیرهای مستقل نشان داد (جدول ۲) که بین هر یک از متغیرهای رس با سیلت و رس با شن و همچنین بین رس با آهک همبستگی بالایی وجود دارد و به همین علت نمی‌توان از رس و سیلت، رس و شن، رس و آهک به همراه یکدیگر در یک مدل استفاده کرد. جدول ۳ ضریب همبستگی بین متغیرهای مستقل با ضرایب رطوبتی را نشان می‌دهد. بیشترین میزان همبستگی مثبت و معنی‌دار رطوبت ظرفیت زراعی (θ_{FC}) با رس پیدا شد ($r=0.78^{**}$). با افزایش مقدار رس در خاک به علت بالا رفتن منافذ میکرو، میزان آب ثقیلی کاهش و در نتیجه θ_{FC} افزایش می‌یابد (Hillel, 2004). بعد از رس، جرم ویژه ظاهری بیشترین همبستگی منفی و معنی‌دار را با رطوبت ظرفیت زراعی داشت. به عبارت دیگر با افزایش جرم ویژه ظاهری به علت کاهش تخلخل کل، θ_{FC} کاهش می‌یابد (Warrick, 2002). همچنین جدول ۳ نشان می‌دهد که همبستگی بین آهک و کربن آلی با رطوبت ظرفیت زراعی مثبت و بین شن و سیلت با رطوبت ظرفیت زراعی منفی است. تأثیر منفی و

ضرایب همبستگی مشابه برای رطوبت ظرفیت زراعی و پژمردگی دائم است. همچنین مشاهده می‌شود که بیشترین همبستگی منفی آب قابل استفاده با جرم ویژه ظاهری بود ($r = -0.587^{**}$).

جدول ۲) ضریب همبستگی پیرسون بین متغیرهای مستقل

Table 2) Pearson correlation coefficient between independent variables

پارامتر	Clay	sand	silt	OC	CaCO ₃	D _p	D _b
Clay	1						
sand	0.618	1					
Silt	0.618	0.618	1				
OC	0.618	0.618	0.618	1			
CaCO ₃	0.618	0.618	0.618	0.618	1		
D _p	0.618	0.618	0.618	0.618	0.618	1	
D _b	0.618	0.618	0.618	0.618	0.618	0.618	1

Clay: رس، Silt: سیلت، Sand: شن، OC: کربن آلی، D_b: جرم مخصوص ظاهری، D_p: جرم مخصوص حقیقی، CaCO₃: کربنات کلسیم معادل.

جدول ۳) ضریب همبستگی پیرسون بین متغیرهای مستقل با رطوبت ظرفیت زراعی (θ_{FC})، پژمردگی دائم (θ_{PWP}) و قابل استفاده (θ_{AW}).

Table 3) Pearson correlation coefficient between independent variables and field capacity (θ_{FC}), permanent wilting point (θ_{PWP}) and available water (θ_{AW}) contents.

پارامتر	Clay	Sand	Silt	OC	CaCO ₃	D _p	D _b
θ_{FC}	0.787**	-0.623**	-0.277**	0.425**	0.457**	-0.389**	-0.67**
θ_{pwp}	0.886**	0.63**	0.389**	0.119	0.575**	0.51**	0.57**
AW	0.555*	-0.438**	0.077	0.45**	0.119	-0.147	-0.587**

Clay: رس، Silt: سیلت، Sand: شن، OC: کربن آلی، D_b: جرم ویژه ظاهری، D_p: جرم ویژه حقیقی، CaCO₃: کربنات کلسیم معادل، **: رابطه معنی‌دار در سطح یک درصد؛ *: رابطه معنی‌دار در سطح ۵ درصد.

نتایج مدل‌های رگرسیونی برای تخمین ضرایب رطوبتی خاک

روابط رگرسیونی در داده‌های آموزشی برای پارامترهای مورد مطالعه به روش گام به گام تعیین شدند که در جدول ۴ نشان داده شده است. به طور کلی ۸ معادله رگرسیونی برای برآورد θ_{FC} ، ۵ معادله رگرسیونی برای برآورد θ_{PWP} ، ۶ معادله رگرسیونی برای برآورد θ_{AW} با استفاده از متغیرهای زودیاقت تشکیل شد (جدول ۴). مقدار ضریب آکائیک (AIC) برای بهترین مدل‌ها در شکل ۱ نشان داده شده است. از بین مدل‌هایی که دارای ضریب تبیین یکسانی بودند، مدلی که AIC و RMSE کمتری داشت به عنوان بهترین مدل معرفی شد.

جدول ۵ آماره‌های ارزیابی مدل‌های رگرسیونی برای برآورد رطوبت ظرفیت زراعی (θ_{FC}) را نشان می‌دهد. بهترین مدل رگرسیونی برای برآورد رطوبت ظرفیت زراعی، مدل شماره ۶ است که دارای ۴ متغیر مستقل می‌باشد. در این مدل از متغیرهای کربن آلی، جرم ویژه ظاهری، شن و سیلت برای تخمین رطوبت ظرفیت زراعی

استفاده گردید. مقادیر ضریب تبیین (R^2)، مجذور میانگین مربعات خطا (RMSE) و میانگین خطا (ME) در این مدل به ترتیب برابر با ۰/۸۲، ۲/۲۹ و ۰/۰۱ در مرحله آموزش و ۰/۹۳، ۳ و ۱/۷۱ در مرحله آزمون بود. بعد از مدل ۶، مدل ۳ با دقتی مشابه مدل ۶، θ_{FC} را برآورد کرد. در این مدل از متغیرهای میانگین هندسی قطر ذرات خاک (d_g)، انحراف معیار هندسی قطر ذرات خاک (σ_g)، کربن آلی و جرم ویژه ظاهری برای تخمین رطوبت ظرفیت زراعی استفاده شد.

مقادیر R^2 ، RMSE و ME مدل ۳ به ترتیب برابر با ۰/۸۲، ۲/۳ و ۰/۰۱- در مرحله آموزش و ۳/۸، ۰/۸۱ و ۲/۰۵ در مرحله آزمون بدست آمد. شیرانی و رفیع نژاد (۲۰۱۰) یک مدل رگرسیونی با روش گام به گام برای تخمین رطوبت ظرفیت زراعی ایجاد کردند و مهمترین متغیرهای تأثیرگذار را پارامترهای رس، شن و گچ دانستند همچنین آنها بیان داشتند که مقدار رس بیشترین تأثیر را بر رطوبت ظرفیت زراعی داشت.

جدول ۴) معادلات رگرسیونی اشتقاق یافته برای برآورد رطوبت‌های ظرفیت زراعی (θ_{FC})، پژمردگی دائم (θ_{PWP}) و قابل استفاده (θ_{AW}).
Table 4. Derived regression equation for estimation field capacity (θ_{FC}), permanent wilting (θ_{PWP}) and available water (θ_{AW}) contents.

معادلات رگرسیونی	پارامترها	شماره مدل
$\theta_{FC} = 50.359 - 136.844d_g - 15.473D_b$	D_b, d_g	1
$\theta_{FC} = 41.499 - 138.588d_g - 12.628D_b + 5.935OC$	D_b, d_g, OC	2
$\theta_{FC} = 22.416 - 69.386d_g - 9.625D_b + 7.853OC + 0.799\sigma_g$	D_b, d_g, OC, σ_g	3
$\theta_{FC} = 60.363 - 18.322D_b - 0.265Sand$	$D_b, Sand$	4
$\theta_{FC} = 70.449 - 12.743D_b - 0.405Sand - 0.312Silt$	$Sand, Silt, D_b$	5
$\theta_{FC} = 61.77 - 9.493D_b - 0.396Sand - 0.365Silt + 6.912OC$	$Sand, Silt, OC, D_b$	6
$\theta_{FC} = 8.001 + 0.455Clay + 8.409OC$	$OC, Clay$	7
$\theta_{FC} = 23.86 + 0.38Clay + 7.079OC - 9.732D_b$	$OC, Clay, D_b$	8

$\theta_{PWP} = 4.509 + 0.313Clay + 2.125OC$	$OC, Clay$	1
$\theta_{PWP} = 9.012 + 0.291Clay + 1.752OC - 2.763D_b$	$OC, Clay, D_b$	2
$\theta_{PWP} = 7.51 + 0.559\sigma_g - 67.912d_g$	d_g, σ_g	3
$\theta_{PWP} = 3.954 + 0.625\sigma_g + 2.693OC - 57.733d_g$	d_g, OC, σ_g	4
$\theta_{PWP} = 8.708 + 0.591\sigma_g + 2.273OC - 50.53d_g - 3.089D_b$	D_b, d_g, OC, σ_g	5

$\theta_{AW} = 21.01 - 9.968D_b + 5.026OC$	OC, D_b	1
$\theta_{AW} = 14.848 - 6.968D_b + 5.345OC + 0.089Clay$	$OC, Clay, D_b$	2
$\theta_{AW} = 11.99 + 5.553OC - 0.119Sand$	$Sand, OC$	3
$\theta_{AW} = 28.909 - 10.219D_b - 0.079Sand$	$D_b, Sand$	4
$\theta_{AW} = 18.675 - 7.317D_b + 5.08OC - 36.867d_g$	D_b, d_g, OC	5
$\theta_{AW} = 12.827 - 7.186D_b + 5.73OC + 0.279\sigma_g$	D_b, OC, σ_g	6

Clay: رس؛ Silt: سیلت؛ Sand: شن، OC: کربن آلی؛ D_b : جرم ویژه ظاهری؛ σ_g : انحراف استاندارد هندسی قطر ذرات خاک.

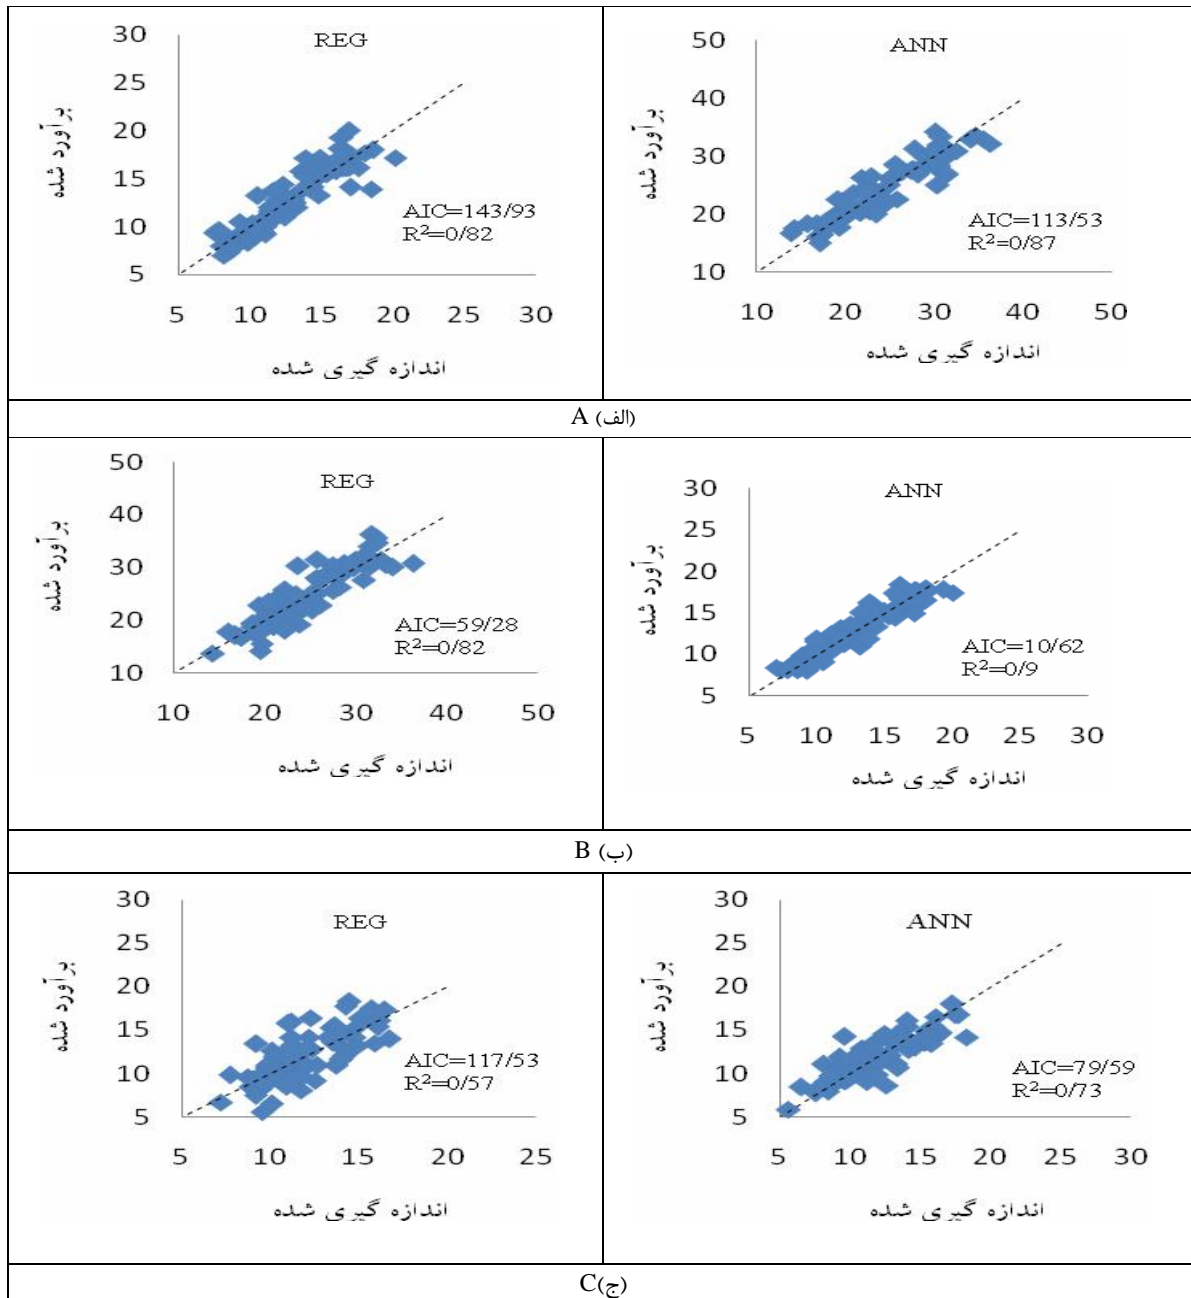
و جرم ویژه ظاهری خاک بدست آمد (جدول ۵). مقادیر R^2 ، RMSE و ME این مدل برابر ۰/۵۷، ۱/۹۷ و ۰/۰۵ در مرحله آموزش و برابر ۰/۶۸، ۳/۲۹ و ۱/۲۶ در مرحله آزمون بود. مقدار منفی ME در مرحله آموزش برای مدل ۶ و مقدار مثبت آن در مرحله آزمون برای همین مدل نشان داد که مقادیر برآوردی به ترتیب کمتر و بیشتر از مقادیر واقعی است. به طور کلی نتایج جدول ۵ نشان داد که توابع انتقالی رگرسیونی دارای دقت کمتر در تخمین رطوبت قابل استفاده (θ_{AW}) نسبت به رطوبت ظرفیت زراعی (θ_{FC}) و پژمردگی دائم (θ_{PWP}) هستند که دلیل آن به محاسبه‌ای بودن θ_{AW} (معادله ۵) برمی‌گردد در حالیکه θ_{FC} و θ_{PWP} مستقیماً از طریق اندازه‌گیری بدست آمدند. رضانی و همکاران (۲۰۱۱) مهم‌ترین متغیرهای تاثیر

بر اساس جدول ۵ بهترین مدل برای تخمین رطوبت پژمردگی دائم (θ_{PWP})، مدل ۲ با متغیرهای ورودی جرم ویژه ظاهری، کربن آلی و رس بدست آمد. این مدل دارای بیشترین ضریب تبیین و کمترین خطا نسبت به مدل‌های دیگر در مرحله آموزش و آزمون بود.

مقادیر R^2 ، RMSE و ME مدل ۲ در جدول ۴ برابر ۰/۸۲، ۱/۳۸ و ۰/۰۴ در مرحله آموزش و در مرحله آزمون به ترتیب برابر ۰/۸۷، ۱/۱۳ و ۰/۴ بود. مقادیر مثبت ME چه در مرحله آموزش و چه در مرحله آزمون برای مدل ۲ نشان داد که این مدل رطوبت پژمردگی دائم را بیشتر از مقدار واقعی برآورد می‌کند. بهترین مدل برای تخمین رطوبت قابل استفاده (θ_{AW})، مدل ۶ با متغیرهای کربن آلی، انحراف استاندارد هندسی قطر ذرات خاک (σ_g)

رگرسیون را برای تخمین رطوبت در نقاط ظرفیت زراعی و پژمردگی دائم به ترتیب با حداکثر R^2 برابر ۰/۹۲ و ۰/۹۷ را گزارش کردند.

گذار را در بیان میزان رطوبت در نقطه ظرفیت زراعی، جرم ویژه ظاهری و نسبت جذبی سدیم و در نقطه پژمردگی دائم، میزان هدایت الکتریکی، رس و جرم ویژه ظاهری دانستند. مردون و همکاران (۲۰۰۶) توابع انتقالی



شکل ۱) نمودار ۱:۱ مقادیر اندازه‌گیری و برآورد شده رطوبت‌های ظرفیت زراعی (الف)، پژمردگی دائم (ب) و قابل استفاده (ج) با استفاده از بهترین مدل رگرسیونی (REG) و شبکه عصبی مصنوعی (ANN).

Figure 1) Measured and estimated diagram (1:1) of field capacity (A), permanent wilting (B) and available water (C) contents, using the best model of regression and artificial neural network.

نتایج مدل‌های شبکه عصبی مصنوعی برای تخمین ضرایب رطوبتی خاک

بهترین مدل شبکه عصبی برای تخمین رطوبت ظرفیت زراعی مدل شماره ۳، با مقادیر R^2 ، RMSE و ME برابر ۰/۸۷، ۱/۹ و ۰/۰۲- در مرحله آموزش و ۰/۸۸، ۳/۱۹ و ۱/۸ در مرحله آزمون بدست آمد (جدول ۵). مقادیر متوسط منفی ME در مرحله آموزش و مقادیر مثبت آن در مرحله آزمون نشان داد که در کل شبکه‌های عصبی، رطوبت ظرفیت زراعی را به ترتیب کمتر و بیشتر از مقدار واقعی برآورد می‌کنند. تخمین رطوبت در نقطه ظرفیت زراعی از روی ویژگی‌های زودیافت خاک با استفاده از مدل‌های شبکه عصبی مصنوعی توسط محققان زیادی گزارش شده است (Merdun et al., 2006; Sarmadian et al., 2010) این محققان بر توانایی شبکه عصبی در تخمین θ_{FC} تأکید داشتند.

شیرانی و رفیع‌نژاد (۲۰۱۲) از شبکه عصبی برای تخمین θ_{FC} استفاده کردند و گزارش کردند بهترین نتیجه زمانی بدست می‌آید که از همه پارامترهای ورودی شامل شن، سیلت، رس، ماده آلی، گچ، کربنات کلسیم معادل و جرم ویژه ظاهری به همراه یکدیگر در یک مدل برای تخمین θ_{FC} استفاده شود. حق وردی و همکاران (۲۰۱۰) از پارامترهای شن، سیلت، رس، جرم ویژه ظاهری، رطوبت اشباع و هدایت هیدرولیکی اشباع برای تخمین رطوبت در نقاط ظرفیت زراعی و پژمردگی دائم استفاده کردند و گزارش نمودند زمانی که پارامترهای رطوبت اشباع و هدایت هیدرولیکی اشباع به مدل‌ها اضافه گردید، دقت شبکه عصبی در تخمین θ_{FC} و θ_{PWP} افزایش پیدا کرد. بعد از مدل شماره ۳، مدل‌های شماره ۶ و ۸ دارای دقت مناسب در تخمین θ_{FC} بودند. مقادیر R^2 و RMSE برابر ۰/۸۵ و ۲/۰۵ برای مدل‌های ۶ و ۸ در مرحله آموزش بود (جدول ۵).

جدول ۵) آماره‌های ارزیابی مدل‌های مختلف رگرسیونی و شبکه عصبی مصنوعی (ANN)

Table 5) Evaluating statistic for different regression and artificial neural network (ANN) models

شماره مدل	رگرسیون			ANN			رگرسیون			ANN		
	RMSE	R^2	ME	RMSE	R^2	ME	داده‌های آموزشی	داده‌های آزمون	داده‌های آموزشی	داده‌های آزمون	داده‌های آموزشی	داده‌های آزمون
ظرفیت زراعی	3.25	0.64	0.0006	2.8	0.72	-0.006	3.86	0.74	1.2	3.25	0.64	0.0006
	2.9	0.71	0.0007	2.45	0.79	0.003	3.9	0.77	2.06	2.9	0.71	0.0007
	2.3	0.82	-0.001	1.9	0.87	-0.02	3.8	0.1	2.05	2.3	0.82	-0.001
	3.5	0.57	0.007	2.39	0.61	0.01	3.6	0.79	1.06	3.5	0.57	0.007
	2.8	0.73	0.003	2.39	0.80	-0.008	2.9	0.89	0.81	2.8	0.73	0.003
	2.29	0.82	0.01	2.05	0.85	-0.009	3	0.93	1.71	2.29	0.82	0.01
	2.57	0.77	0.006	2.34	0.81	-0.01	3.57	0.87	1.67	2.57	0.77	0.006
	2.29	0.82	0.01	2.05	0.85	-0.02	3.04	0.29	1.67	2.29	0.82	0.01
پژمردگی دائم	1.42	0.81	-0.007	1.16	0.87	0.002	1.14	0.87	0.40	1.42	0.81	-0.007
	1.38	0.82	0.004	1.02	0.90	0.001	1.13	0.87	0.40	1.38	0.82	0.004
	1.71	0.72	0.005	1.26	0.85	0.01	1.43	0.79	0.38	1.71	0.72	0.005
	1.58	0.76	0.008	1.2	0.86	0.05	1.39	0.85	0.75	1.58	0.76	0.008
	1.53	0.78	-0.0008	1.07	0.89	0.026	1.29	0.87	0.71	1.53	0.78	-0.0008
قابل استفاده	2.11	0.51	0.005	2.07	0.53	-0.001	3.24	0.71	1.14	2.11	0.51	0.005
	1.98	0.56	-0.008	1.73	0.67	-0.01	3.07	0.77	1.21	1.98	0.56	-0.008
	2.34	0.40	-0.0003	2.18	0.48	-0.003	3.66	0.62	1.25	2.34	0.40	-0.0003
	2.38	0.38	0.007	2.1	0.51	-0.005	3.08	0.76	0.59	2.38	0.38	0.007
	2.00	0.56	-0.0001	1.65	0.70	-0.004	3.22	0.70	1.34	2.00	0.56	-0.0001
	1.97	0.57	-0.005	1.56	0.73	0.01	3.29	0.68	1.26	1.97	0.57	-0.005

ME: میانگین خطا؛ R^2 : ضریب تبیین؛ RMSE: مجذور میانگین مربعات خطا

بدست آمد. کلیه مقادیر ME برای θ_{PWP} در مدل‌های اشتقاق یافته از شبکه‌های عصبی در مرحله آزمون و آموزش مثبت بود که نشان می‌دهد شبکه‌های عصبی هم در مرحله

بهترین مدل برای تخمین رطوبت پژمردگی دائم (θ_{PWP})، مدل شماره ۲ با سه متغیر مستقل ورودی شامل جرم ویژه ظاهری، رس و کربن آلی (جدول ۴)

عصبی ایجاد شده در تخمین رطوبت‌های ظرفیت زراعی، پژمردگی دائم و قابل استفاده در داده‌های آموزشی به ترتیب برابر 0.82 ، $2/3$ و 0.82 ، $1/38$ و 0.57 و $1/97$ برای رگرسیون و به ترتیب برابر 0.87 و $1/9$ ، $1/9$ و 0.73 و $1/56$ برای شبکه عصبی بود (جدول ۵). همچنین مقادیر AIC (شکل ۱) برای بهترین مدل رگرسیون و شبکه عصبی ایجاد شده در تخمین رطوبت‌های ظرفیت زراعی، پژمردگی دائم و قابل استفاده در داده‌های آموزشی به ترتیب برابر $143/93$ و $113/53$ ، $59/28$ و $10/62$ ، $117/53$ و $79/59$ به دست آمد. این نتایج با یافته‌های سایر محققان (Pachepsky *et al.*, 1996; Tamari *et al.*, 1996; Schaap *et al.*, 1998; Sarmadian *et al.*, 2010; Shirani & Rafienejad, 2012) مطابقت دارد. مصدقی و محبوبی (۲۰۱۱) بیان داشتند که بر اساس ضریب AIC وارد نمودن رطوبت اشباع لزوماً باعث بالا رفتن دقت توابع انتقالی برای برآورد نقاط منحنی رطوبتی از روی خصوصیات زود یافت خاک نگردید. طبق نظر اسخاپ و همکاران (۱۹۹۸) در طراحی شبکه‌های عصبی نوع خاصی از معادلات لازم نیست و با ایجاد روابط مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسبی دست پیدا کرد و به علت وجود روابط غیر خطی میان متغیرهای وابسته و پیش‌بینی شونده شبکه عصبی عملکرد بهتری نسبت به مدل‌های رگرسیونی داشته است. میناسنی و همکاران (۲۰۰۲) 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 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. با این وجود مردون و همکاران (۲۰۰۶) گزارش کردند که مدل‌های رگرسیونی دارای دقت بالا و خطای کمتری در تخمین ویژگی‌های هیدرولیکی شامل رطوبت‌های ظرفیت زراعی، پژمردگی دائم و قابل استفاده نسبت به شبکه‌های عصبی مصنوعی است. مقادیر متوسط RMSE مراحل آموزش و آزمون در تحقیق حاضر نشان داد که خطای توابع انتقالی رگرسیونی و شبکه عصبی در مکش‌های ماتریک بالا (معادل θ_{PWP}) که بیشتر تابعی از توزیع اندازه ذرات خاک بوده

آموزش و هم در مرحله آزمون رطوبت پژمردگی دائم را بیشتر از مقدار واقعی برآورد می‌کنند. مقادیر R^2 ، RMSE برای مدل ۲ به ترتیب برابر 0.9 و $1/02$ در مرحله آموزش و در مرحله آزمون برابر 0.88 و $1/1$ بود. تمام مدل‌های شبکه عصبی دارای دقت مناسب و نزدیک به هم در تخمین رطوبت پژمردگی دائم بودند. مردون و همکاران (۲۰۰۶) از مدل شبکه عصبی برای تخمین رطوبت پژمردگی دائم از روی ویژگی‌های زود یافت خاک استفاده کردند و $R^2=0.95$ را بدست آوردند. شیرانی و رفیع‌نژاد (۲۰۱۲) از پارامترهای رس، شن، سیلت، جرم ویژه ظاهری، گچ، کربنات کلسیم معادل و ماده آلی برای تخمین θ_{PWP} استفاده کردند و ضریب تبیین 0.93 را گزارش کردند.

نتایج مدل‌های شبکه عصبی در جدول ۵ نشان می‌دهد که در کل دقت شبکه عصبی در تخمین رطوبت قابل استفاده (θ_{AW}) نسبت به رطوبت ظرفیت زراعی و پژمردگی دائم پایین بود. این نتایج با یافته‌های مردون و همکاران (۲۰۰۶) مطابقت دارد. بهترین مدل شبکه عصبی که دارای خطای کمتری نسبت به سایر مدل‌ها بود، مدل شماره ۶ با ۳ متغیر ورودی شامل کربن آلی، انحراف استاندارد هندسی قطر ذرات خاک (σ_g) و جرم ویژه ظاهری بود. مقادیر R^2 ، RMSE و ME مدل ۶ در جدول ۵ در مرحله آموزش برابر 0.73 ، $1/56$ و 0.01 و در مرحله آزمون برابر 0.7 ، $3/26$ و $1/58$ بود. مقادیر مثبت ME در مرحله آموزش و آزمون نشان داد که مقادیر برآوردی در هر دو مرحله بیشتر از مقادیر واقعی است. تمام مقادیر ME در مرحله آزمون مثبت و در مرحله آموزش منفی (به جزء مدل ۶) بود که نشان می‌دهد شبکه‌های عصبی رطوبت قابل استفاده را در مرحله آموزش کمتر از مقدار واقعی و در مرحله آزمون بیش‌تر از مقدار واقعی برآورد کردند.

مقایسه نتایج مدل‌های رگرسیونی و شبکه عصبی

مصنوعی در برآورد ضرایب رطوبتی خاک

نمودار ۱:۱ مقادیر اندازه‌گیری و برآورد شده رطوبت‌های ظرفیت زراعی، پژمردگی دائم و قابل استفاده با استفاده از مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی در شکل ۱ نشان داده شده است. مقادیر R^2 و RMSE برای بهترین مدل رگرسیون و شبکه

ویژگی زودیافت خاک مورد مقایسه قرار گرفتند مقایسه نتایج نشان داد که شبکه‌های عصبی مصنوعی در این پژوهش به علت داشتن R^2 بالاتر و RMSE و AIC پایین‌تر دارای دقت بالاتر و خطای کمتر در تخمین ضرایب رطوبتی خاک نسبت به توابع انتقالی رگرسیونی بودند. با این وجود، دقت مدل‌های رگرسیونی و شبکه عصبی در برآورد آب قابل استفاده کمی پایین بود که دلیل آن محاسبه‌ای بودن پارامتر مورد نظر از روی داده‌های منحنی رطوبتی بود. توصیه می‌شود در تحقیقات بعدی از ویژگی‌های مینرالوژی رس، حدود پایایی، میانگین وزنی قطر خاکدانه‌ها، سطح ویژه ذرات خاک و خصوصیات شیمیایی خاک نیز در ایجاد توابع انتقالی برای خاک‌های منطقه مورد مطالعه استفاده گردد.

نسبت به مکش ماتریک کم (معادل θ_{FC}) که بیشتر تابعی از توزیع اندازه منافذ خاک است، به طور قابل ملاحظه‌ای کمتر می‌باشد.

هاتسون و کاس (۱۹۸۶) نشان دادند که توابع انتقالی دقت بیشتری در تخمین رطوبت پژمردگی دائم نسبت به رطوبت ظرفیت زراعی دارد و علت این امر را ساختمان متغیر خاک (توزیع اندازه منافذ) در پژوهش خود گزارش کردند که این پارامتر تأثیر زیادی بر رطوبت ظرفیت زراعی دارد.

نتیجه‌گیری کلی

در پژوهش حاضر، روش‌های رگرسیونی و شبکه عصبی مصنوعی به منظور برآورد رطوبت‌های ظرفیت زراعی، پژمردگی دائم و قابل استفاده با استفاده از

References

- Bauer A and Black AL. 1992. Organic carbon effects on available water capacity of three soil textural groups. *Soil Sci. Soc. Am. J.* 56: 248-254.
- Bouma J. 1989. Using soil survey data for quantitative land evaluation. *Adv. Soil Sci.* 9:177-213.
- Campbell GS. 1985. *Soil Physics with Basics*, Elsevier press, Amsterdam.
- Ganbarian Alavijeh B and Liaghat A. 2011. Evaluation of pedotransfer functions and effect of organic matter in prediction of soil saturated water content. *J. Water Soil.* 25(5): 1016-1024. (in Farsi with English Summary)
- Gardner, WH. 1986. Water content. In: *Methods of soil analysis. Part1. Physical and mineralogical methods.* 2nd Ed. (ed. A. Klute). Madison, WI: Am. Soc. Agron. 493-544.
- Haghverdi A, Ghahraman B, Khoshnood Yazdi AA and Arabi Z. 2010. Estimating of water content in FC and PWP in north and north east of Iran's soil samples using k-nearest neighbor and artificial neural networks. *Journal of Water and Soil*, 24 (4): 804-814. (In Farsi with English Summary)
- Hillel D. 2004. *Introduction to environmental soil physics.* Elsevier Academic Press. 494 p.
- Hutson JL and Cass A. 1987. A retentivity function for use in soil-water simulation models. *J. Soil Sci.* 38: 105-113.
- Khodaverdiloo H, Homae M, Th. van Genuchten M and Ghorbani Dashtaki Sh. 2011. Deriving and validating pedotransfer functions for some calcareous soils. *J. Hydro.* 399: 93-99.
- Klute A. 1986. *Methods of soil analysis. Part 1. Physical and mineralogical methods.* 2nd Ed. Agron. Monog. 9. ASA and SSSA, Madison, WI.
- McBratney AB, Minasny B, Cattle SR and Vervoort RW. 2002. From pedotransfer function to soil inference system. *Geoderma*, 109: 41-73.
- 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 Till. Res.* 90: 108-116.
- Mesri Gundoshmian T. 2009. The use of intelligent systems to optimize drop Combine. PhD Thesis, Engineering of Agriculture Machinery Mechanization Department, University of Tabriz. (In Farsi with English Summary)
- Minasny B and Mcbratney AB. 2002. The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci. Soc. Am. J.* 66: 352-361.
- Minasny B, McBratney AB and Bristow KL. 1999. Comparison of different approaches to the development of pedotransfer functions for water retention curves. *Geoderma*, 93: 225-253.

- Mosaddeghi MR and Mahboubi AA. 2011. Point pedotransfer functions for prediction of water retention of selected soil series in a semi-irrigated region of western Iran. *Archives of Agronomy and Soil Science*. 57(4): 327-342.
- Navvabian M, Liaghat EM and Homaie M. 2004. Rapid estimation of hydraulic conductivity using neural networks. In: *Proceedings of the Second National Student conference on Water and soil Resources*. Shiraz Uni. Press, Pp: 203-211.
- Pachepsky YA, Timlin DJ and Varallyay G. 1996. Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Sci. Soc. Am. J.* 60: 727-773.
- Page AL (ed.).1985. *Methods of soil analysis. Part 2. Chemical and microbiological methods*. Agronomy No. 9. American Society of Agronomy, Madison, WI.
- Ramezani M, Ganbarian B, Liaghat AM and Salehi Khoshkroudi Sh. 2011. Developing pedotransfer functions for saline and saline- alkali soils. *J. Water and Irrigation Manag.* 1(1): 99-110. (In Farsi with English Summary)
- Sarmadian F, Taghizade R, Asghari H and Akbarzade A. 2010. Comparison neuro-fuzzy, neural network and regression stepwise methods in predicting some soil properties. *J. Water Soil Res.* 41 (1): 211-220. (In Farsi with English Summary)
- Schaap M G, Leij FJ and Van Genuchten MTh. 2001. Rosetta: a computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *J. Hydrol.* 251: 163-176.
- Schaap MG and Bouten W. 1996. Modeling water retention curves of sandy soils using neural networks. *Water Resour. Res.* 32: 3033-3040.
- Schaap MG, Leij FJ and Van Genuchten MTh. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Sci. Soc. Am. J.* 62:847-855.
- Shirani H and Rafienejad N. 2012. Estimating of some missing soil properties with regression pedotransfer functions and neural network in the Kerman. *J. Soil Res.* 25. (4): 349-359. (In Farsi with English Summary)
- Shirazi MA and Boersma L. 1984. A unifying quantitative analysis of soil texture. *SSSA. J.* 48: 142-147.
- Tamari, S, Woosten, JH M and Ruiz-Suarez JC. 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Sci. Soc. Am. J.* 60: 1732-1741.
- Van Genuchten, MTh. 1980. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. *Soil Sci. Soc. Am. J.* 44: 892-898.
- Warrick AW. 2002. *Soil physics companion*. CRC Press. 389 p.

Estimating of Field Capacity, Permanent Wilting and Available Water Content in Ardabil Plain Soils using Regression and Artificial Neural Network Models

Hamed Amir-Abedi¹, Shokrollah asghari^{2*}, Tarahhom Mesri Gandoshmin³, Farshad Keivan behjo⁴

1- MSc. Student of Soil Science, College of Agriculture, Mohaghegh Ardabili University

2- Assis. Prof. Department of Soil Science, Mohaghegh Ardabili University

3- Assis. Prof, Department of Mechanical Engineering, Mohaghegh Ardabili University

4- Assistant Professor, Faculty of Natural Resources, Mohaghegh Ardabili University

* Corresponding author: sh_asghari2005@yahoo.com

Received: 27.10.2012

Accepted: 12.03.2013

Abstract

Direct measurement of soil hydraulic properties is consuming, costly and sometimes unreliable because of soil heterogeneity and experimental errors. These properties can be estimated from surrogate data such as particle size distribution, bulk density, organic carbon and CaCO_3 using pedotransfer functions (PTFs). The objective of this research was presentation of regression and neural network models for estimation of missing soil properties including field capacity, permanent wilting and available water contents from above-cited surrogate soil properties in some soil of the Ardabil Plain. Total 100 soil samples were taken and then some physical and chemical properties of them measured. Soil samples were divided into two groups as 80 for the development and 20 for the validation of PTFs. Neural network and regression models were made using Neurosolution5 and SPSS softwares, respectively. The values of determination coefficient (R^2) and root mean square error (RMSE) for the estimation of field capacity, permanent wilting and available water contents were obtained 0.82 and 2.29, 0.82 and 1.38, 0.57 and 1.97 in the best regression models and 0.87 and 1.9, 0.90 and 1.02, 0.73 and 1.56 in the best neural network models, respectively. The values of R^2 and RMSE for the results of regression and artificial neural network PTFs showed that both models can be applied to predicting missing soil properties. Regression models hadn't any efficiency to predict available water content. Artificial neural networks were performed better than regression models in this case.

Keywords: artificial neural networks, field capacity water content, permanent wilting water content, regression, soil pedotransfer function.