

برآورد هدایت هیدرولیکی اشباع خاک‌های منتخب از دشت اردبیل با استفاده از مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی

حامد امیرعابدی^{۱*}، شکراله اصغری^۲، ترحم مصری گندشمین^۳، ناصر بالنده^۴ و ابراهیم جوهری^۵

تاریخ پذیرش: ۱۳۹۷/۰۹/۱۷

تاریخ دریافت: ۱۳۹۶/۱۰/۲۲

چکیده

هدایت هیدرولیکی اشباع به‌عنوان یک ویژگی دیرپافت می‌تواند از ویژگی‌های زودپافت خاک شامل جرم ویژه ظاهری، بافت خاک، کربن آلی، کربنات کلسیم معادل با استفاده از توابع انتقالی رگرسیونی و شبکه‌های عصبی مصنوعی برآورد شود. هدایت هیدرولیکی اشباع خاک به روش بار افتان در ۱۰۰ نمونه خاک جمع‌آوری شده از دشت اردبیل تعیین شد. بعد از انجام تجزیه‌های شیمیایی و فیزیکی روی نمونه‌های خاک، داده‌ها به دو سری داده‌های آموزشی (۸۰ نمونه) و داده‌های اعتبارسنجی (۲۰ نمونه) تقسیم شدند. مدل‌های رگرسیونی توسط نرم‌افزار SPSS و به روش گام‌به‌گام و مدل‌های شبکه عصبی توسط نرم‌افزار Neurosolution شکل گرفتند. برای انجام تجزیه‌های آماری از ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE) و ضریب آکائیک (AIC) استفاده شد. بهترین مدل رگرسیونی دارای متغیرهای شن، سیلت و جرم مخصوص ظاهری بود و بهترین مدل شبکه عصبی از متغیرهای ورودی میانگین هندسی قطر ذرات خاک، انحراف معیار هندسی قطر ذرات خاک و جرم مخصوص ظاهری به‌دست آمد. مقادیر R^2 ، RMSE (cm min^{-1}) در فاز آموزش و اعتبارسنجی برای بهترین مدل رگرسیونی به ترتیب برابر (۰/۵۳، ۰/۷۴ و ۰/۵۱) و برای بهترین مدل شبکه عصبی به ترتیب برابر (۰/۸۴، ۰/۷۳ و ۰/۰۶) بود. در این پژوهش به‌صورت جداگانه از تمامی پارامترهای مستقل شامل جرم مخصوص ظاهری، جرم مخصوص حقیقی، درصد آهک، میانگین هندسی قطر و انحراف معیار هندسی قطر ذرات خاک به‌عنوان ورودی در تکنیک شبکه عصبی استفاده شد. مقادیر R^2 و RMSE (cm min^{-1}) در مرحله آموزش و آزمون به ترتیب برابر (۰/۸۷، ۰/۳۶ و ۰/۵۸) و (۰/۷۶) بود. نتایج تحقیق در این مورد نشان داد شبکه‌های عصبی با داده‌های ورودی یکسان هدایت هیدرولیکی اشباع خاک را با دقت بیشتری ($R^2=0/84$) نسبت به مدل‌های رگرسیونی ($R^2=0/53$) برآورد می‌کنند. همچنین مشاهده شد زمانی که تعداد داده‌های ورودی در روش شبکه عصبی افزایش می‌یابد دقت برآورد در داده‌های آموزشی بیشتر می‌شود.

واژه‌های کلیدی: بار افتان، پارامترهای مستقل، توابع انتقالی، رگرسیون گام به گام

امیرعابدی ح، اصغری ش، مصری گندشمین ت، بالنده ن، جوهری ا. ۱۳۹۸. برآورد هدایت هیدرولیکی اشباع خاک‌های منتخب از دشت اردبیل با استفاده از مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی. تحقیقات کاربردی خاک. جلد ۷، شماره ۴. صفحه: ۱۳۶-۱۲۴.

۱- دانش آموخته کارشناسی ارشد، گروه علوم و مهندسی خاک، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی (مکانبه کننده)

۲- دانشیار گروه علوم و مهندسی خاک، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی

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

۴- کارشناس ارشد، گروه مهندسی علوم خاک، دانشکده کشاورزی و منابع طبیعی، دانشگاه ارومیه

۵- دانش آموخته کارشناسی ارشد گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه ارومیه

*پست الکترونیک: Amirabedihamed@yahoo.com

مقدمه

هیدرولیکی اشباع خاک ایجاد شده است (Brakensiek *et al.*, 1984; Campbell, 1985; Ghanbarian, 2009; Jabro, 1992; Saxton *et al.*, 1986; Wösten *et al.*, 2001). کلیشادی و همکاران (Kelishadi *et al.*, 2013) هدایت هیدرولیکی اشباع خاک را با توابع PTFs موجود در منابع و PTFs ایجاد شده در منطقه ارزیابی کردند. آن‌ها گزارش کردند که PTFs موجود در منابع قادر به برآورد دقیقی از هدایت هیدرولیکی اشباع نیست. زرین‌فر و همکاران (Zarinfar *et al.*, 2011) گزارش کرد که توابع انتقالی مرسوم قادر به برآورد دقیق از هدایت هیدرولیکی اشباع خاک‌های سنگریزه‌ای نمی‌باشد. آن‌ها مدل با متغیرهای ورودی انحراف معیار هندسی قطر ذرات خاک، میانگین هندسی قطر ذرات خاک و میانه قطر کل ذرات را در مرحله ارزیابی به‌عنوان بهترین مدل معرفی کردند. سالار شایری و سیوسمردی (Salarashayeri & Siosemarde, 2012) با استفاده از توزیع اندازه ذرات خاک هدایت هیدرولیکی اشباع را برآورد کردند و ضریب تبیین 0/52 را برای مدل رگرسیونی ایجاد شده گزارش کردند. نصرتی و همکاران (Nosrati *et al.*, 2012) هدایت هیدرولیکی اشباع خاک را با استفاده از شبکه‌های عصبی برآورد کردند آن‌ها گزارش کردند بهترین مدل از متغیرهای ورودی لگاریتم میانگین هندسی قطر ذرات خاک، تخلل کل، درصد شن و رس حاصل می‌شود. امیرعابدی و همکاران (Amirabedi *et al.*, 2013) عملکرد توابع انتقالی رگرسیونی و شبکه‌های عصبی مصنوعی را در برآورد ویژگی‌های هیدرولیکی خاک مورد مقایسه قرار دادند. آن‌ها گزارش کردند که هر دو روش کارایی مناسبی در برآورد ویژگی‌های هیدرولیکی خاک دارد، با این حال عملکرد شبکه‌های عصبی مصنوعی را نسبت به مدل‌های رگرسیونی بیشتر دانستند. خاشعی و همکاران (Khashei *et al.*, 2015) 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.

کاربرد زیاد و غیر کنترل شده کودها و سموم شیمیایی به‌منظور افزایش تولیدات کشاورزی از طریق آلودگی آب‌های سطحی و زیرزمینی منجر به مسائل جدی زیست محیطی شده است. معادله ریچاردز¹ و معادله انتقال- انتشار (CDE)² به‌ترتیب برای مدل‌سازی جریان آب و انتقال املاح در ناحیه غیر اشباع خاک استفاده می‌شوند (Mesri Gundoshmian, 2009). کاربرد هر دو رابطه به درک ویژگی‌های هیدرولیکی خاک در حالت اشباع و غیر اشباع نیاز دارد. به‌دلیل طبیعت پیچیدگی خاک و تغییرات زمانی و مکانی هدایت هیدرولیکی، روش‌های اندازه‌گیری مستقیم آن، در حالت اشباع که شامل روش استوانه مضاعف³، روش بار ثابت⁴ و روش بار افتان⁵ و در حالت غیر اشباع نظیر روش جذب⁶، نفوذسنج صفحه‌ای⁷ و پروفیل لحظه‌ای⁸ بسیار دشوار بوده و به‌دست آوردن نتایج رضایت‌بخش مستلزم تکرارهای بسیار زیاد می‌باشد (Barzegar, 2008). امروزه پژوهشگران از روش‌های غیر مستقیم مانند توابع انتقالی رگرسیونی، شبکه‌های عصبی مصنوعی، روش نزدیکترین همسایه و مدل‌های مختلف که اساس آن‌ها توزیع اندازه ذرات خاک (PSD) است برای برآورد ویژگی‌های هیدرولیکی خاک استفاده می‌کنند (Campbell, 1985; Boadu, 2000; Mualem, 1976; Van Genuchten, 1980). گام معمول در اشتقاق توابع انتقالی خاک ارائه روابط تجربی میان ویژگی‌های پایه‌ای خاک و عواملی است که پیش‌بینی شوند. روش‌های رگرسیونی (Hassan Shah *et al.*, 199; Jabro, 1992) و شبکه‌های عصبی مصنوعی (Mesri Gundoshmian T. 2009; Minasny & Mcbartney, 2002; Pachepsky, *et al.*, 1996; Schaap & Bouten, 1996) دو ابزار پرکاربرد برای تهیه توابع انتقالی می‌باشند. در تمام این روش‌ها ویژگی‌های پایه‌ای و سهل‌الوصول خاک نظیر توزیع اندازه ذرات خاک، درصد ماده آلی، کربنات کلسیم، جرم ویژه ظاهری به ویژگی‌های دیر یافت خاک نظیر نقاط نگه‌داشت رطوبتی، هدایت هیدرولیکی اشباع و غیر اشباع خاک و غیره مرتبط داده می‌شوند (Wösten *et al.*, 1999). تاکنون توابع انتقالی زیادی برای برآورد هدایت

5. Falling head method-
6. Sorptivity method
7. Disk permeameter
8. Instantaneous profile

1. Richards equation
2. Convection-dispersion equation
3. Double ring method
4. Constant head method

اردبیل بود. با توجه به اینکه تاکنون بررسی جامع و دقیقی در دشت اردبیل برای مطالعه هدایت هیدرولیکی اشباع صورت نگرفته است. همچنین ذکر این نکته ضروری است بسیاری از پژوهشگرانی که در زمینه ایجاد توابع انتقالی کار کردند توصیه می‌کنند از توابع انتقالی منطقه‌ای استفاده شود چرا که هر منطقه‌ای دارای ویژگی‌های آب و هوایی و خاکی خاص بوده و استفاده از توابع انتقالی سایر مناطق برای یک منطقه خاص می‌تواند خطاهای زیادی را در برآورد پارامتر وابسته داشته باشد. با توجه به موارد فوق ایجاد مدل‌هایی که با استفاده از آن بتوان با صرف وقت و هزینه کم هدایت هیدرولیکی اشباع خاک را در دشت اردبیل با دقت مناسبی برآورد کرد، ضروری بود.

مواد و روش‌ها

نمونه‌های خاک دست خورده (با حداقل دست خوردگی و احتیاط کامل) به مقدار حدود ۳ کیلوگرم و نمونه‌های خاک دست نخورده با استفاده از استوانه‌های فولادی به قطر ۵cm و ارتفاع ۵/۱cm از افق A_p خاک در ۱۰۰ نقطه از دشت اردبیل به طور تصادفی برداشته شد. نمونه‌های دست خورده در آزمایشگاه هوا خشک گردید و سپس بخشی از آن را خرد نموده 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. 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، کربن آلی (OC) به روش والکلی و بلک (Walkley & Black, 1934)، کربنات کلسیم معادل به روش تیتراسیون با اسید مطابق دستورالعمل‌های ارائه شده (Klut & Direksen, 1986) اندازه‌گیری شد. پارامترهای میانگین هندسی قطر (d_g) و انحراف استاندارد هندسی (σ_g) ذرات خاک از روی درصدهای شن، سیلت و رس محاسبه شد (Campbell, 1985). هدایت هیدرولیکی اشباع (K_s) به روش بار افتان (Klute, 1986) اندازه‌گیری شد.

سرمدیان و همکاران (Sarmadian *et al.*, 2011) روش‌های نروفازی^۱، شبکه عصبی مصنوعی و رگرسیون چندمتغیره را در تخمین برخی ویژگی‌های خاک ارزیابی کردند. بدین منظور، ۱۴۰ نمونه خاک از منطقه گرگان جمع‌آوری کردند. فراوانی نسبی ذرات خاک، کربن آلی، درصد رطوبت اشباع و آهک به‌عنوان ویژگی‌های زودیافت و رطوبت نقطه پژمردگی، ظرفیت زراعی، ظرفیت تبادل کاتیونی و جرم ویژه ظاهری به‌عنوان ویژگی‌های دیریافت اندازه‌گیری شدند. کل داده‌ها به دو سری داده، شامل سری آموزش (۸۰٪ داده‌ها) و سری ارزیابی (۲۰٪ داده‌ها) تقسیم شدند. نتایج ارزیابی مدل‌ها بر اساس شاخص ریشه مربعات خطا (RMSE) و ضریب تبیین (R²) نشان داد که مدل نروفازی دارای بالاترین دقت در تخمین ویژگی‌های خاک بود.

مردون و همکاران (Merdun *et al.*, 2006) توانایی شبکه‌های عصبی مصنوعی و توابع انتقالی رگرسیونی را در تخمین نگه‌داشت آب خاک و هدایت هیدرولیکی اشباع مقایسه کردند. آن‌ها از توابع انتقالی نقطه‌ای و پارامتریک برای تخمین پارامترهای هیدرولیکی از ویژگی‌های اصلی خاک مانند توزیع اندازه ذرات خاک، جرم ویژه ظاهری و سه منفذ با اندازه مختلف با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون خطی چندگانه استفاده کردند. برای این منظور نامبردگان از ۱۹۵ نمونه خاک که شامل ۱۳۰ نمونه برای توسعه و ۶۵ نمونه برای اعتبارسنجی توابع انتقالی بود، استفاده کردند. با این وجود اختلاف میان دو روش اهمیت آماری نداشت و تخمین نقطه‌ای و پارامتریک رگرسیون برای پارامترهای مختلف هیدرولیکی بهتر از شبکه‌های عصبی مصنوعی بود. آن‌ها همچنین گزارش کردند که هر دو روش اعتبار کمی در تخمین پارامتریک نسبت به تخمین نقطه‌ای داشتند. با توجه به اینکه هدایت هیدرولیکی اشباع خاک از ویژگی‌های اساسی در مطالعات مربوط به زهکشی، آبیاری، آلودگی منابع خاک می‌باشد و نظر به اینکه اندازه‌گیری مستقیم آن وقت‌گیر، هزینه‌بر بوده و دارای تغییرات زیاد مکانی و زمانی می‌باشد، بنابراین هدف از تحقیق حاضر ارائه مدل‌های رگرسیونی و شبکه عصبی مصنوعی در برآورد هدایت هیدرولیکی اشباع در دشت

$$K_s = \frac{aL}{At} \ln \frac{H_1}{H_2} \quad (1)$$

روش تشکیل شدند. در روش اول برای انتخاب متغیرهای مستقل از رگرسیون گام به گام در سطح احتمال ۵ درصد استفاده شد و در روش دوم همه متغیرهای مستقل با حضور d_g و σ_g نرون‌های لایه ورودی را تشکیل دادند. شبکه ابتدا با داده‌های فاز آموزش و به روش پس‌انتشار خطا تحت آموزش قرار گرفتند و پارامترهای آن تنظیم شدند. مدل عصبی توسعه داده شده مشتمل بر یک لایه نهان بود که تعداد بهینه نرون‌های لایه نهان ۷ تا ۱۰ نرون برای مدل‌سازی هدایت هیدرولیکی اشباع به روش آزمون و خطا تعیین شدند. بعد از اینکه آموزش شبکه به اتمام رسید کلیه وزن‌های مربوط به نرون‌ها فریزر شده و داده‌های مربوط به آزمون و داده‌های مربوط به مرحله آموزش به شبکه اعمال گردیدند تا خروجی مدل عصبی مورد محاسبه شود. برازش مدل‌ها توسط نرم‌افزار Neurosolution 5 انجام شد. در تحقیقات انجام شده توسط قربانی دشتکی و همکاران (Ghorbani Dashtaki *et al.*, 2009)، علی جانپور و همکاران (Alijanpour *et al.*, 2011)، مردون و همکاران (Merdun *et al.*, 2006)، امیرعابدی و همکاران (Amirabedi *et al.*, 2013) از الگوریتم پس‌انتشار خطا برای برآورد خطا و از شبکه عصبی مصنوعی با ساختار پرسپترون سه لایه استفاده شده است.

معیارهای ارزیابی

برای ارزیابی عملکرد توابع انتقالی رگرسیونی و شبکه عصبی مصنوعی در برآورد هدایت هیدرولیکی اشباع از آماره‌های مجذور میانگین مربعات خطا (RMSE)، ضریب تبیین (R^2)، متوسط خطا (ME) و ضریب آکائیک (AIC) استفاده شد. دلیل استفاده از ضریب آکائیک متفاوت بودن تعداد پارامترهای ورودی مدل بود (Amirabedi *et al.*, 2013). هرچه این ضریب کوچکتر باشد دقت مدل در برآورد بیشتر است. محاسبه شاخص‌های آماری و همچنین رسم نمودارها در نرم‌افزار Excel انجام شدند.

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

همراستایی چندگانه و آماده‌سازی داده‌ها

برای ارزیابی همراستایی خطی چندگانه در مدل‌های رگرسیونی ایجاد شده از فاکتور تورم واریانس (VIF^1) استفاده شد (Khodaverdilo *et al.*, 2011). داده‌ها در نرم‌افزار Excel به صورت تصادفی به دو گروه داده‌های آموزشی ۸۰ تایی و داده‌های آزمونی ۲۰ تایی تقسیم شدند. در این پژوهش از روش‌های رگرسیونی و شبکه‌های عصبی مصنوعی برای ارائه توابع انتقالی جهت برآورد هدایت هیدرولیکی اشباع خاک با استفاده از ویژگی‌های زود یافت خاک شامل توزیع اندازه ذرات، کربن آلی، آهک، جرم ویژه ظاهری، جرم ویژه حقیقی، میانگین هندسی قطر (d_g) و انحراف استاندارد هندسی قطر (σ_g) ذرات خاک استفاده شد.

اشتقاق توابع انتقالی رگرسیونی

بر اساس نتایج ماتریس همبستگی بین K_s به عنوان متغیر وابسته و ویژگی‌های زود یافت 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 باشد، باید مدلی انتخاب گردد که دارای پارامترهای ورودی کمتری است. معادلات رگرسیونی خطی چندگانه به روش گام به گام در سطح احتمال ۵ درصد به کمک نرم‌افزار SPSS شکل گرفتند. سپس از متغیرهای ورودی مدل‌های رگرسیونی برای ایجاد شبکه‌های عصبی مصنوعی استفاده شد.

تعیین مدل شبکه عصبی

در این مطالعه از شبکه عصبی پرسپترون چند لایه (MLP^2) استفاده شد که متداول‌ترین شبکه برای برآورد معادلات چند متغیره است. در این شبکه متغیرهای مستقل به عنوان ورودی شبکه و متغیرهای وابسته به عنوان خروجی شبکه در نظر گرفته شدند. آموزش شبکه با استفاده از الگوریتم یادگیری پس‌انتشار خطا با جمله ممنتوم انجام شد (Amirabedi *et al.*, 2013) ساختارهایی متعددی برای شبکه بهینه مورد آزمون قرار گرفتند. در این ساختارها نرون‌های لایه ورودی به دو

1. Variation inflation factor

2. Multi-layer perceptron

آزمون نرمال کردن داده‌ها نشان داد که توزیع همه متغیرهای به کار رفته در مدل، به جز میانگین هندسی قطر ذرات خاک (d_g) و هدایت هیدرولیکی اشباع خاک (K_s) نرمال است. شکل ۲ توزیع هدایت هیدرولیکی اشباع در دو حالت نرمال شده و غیر نرمال را نشان می‌دهد. از تبدیل لگاریتمی برای نرمال کردن توزیع هدایت هیدرولیکی اشباع استفاده شد. وستن و همکاران (Wösten *et al.*, 2001) بیان داشتند که هدایت هیدرولیکی اشباع توزیع لگاریتمی دارد. جدول ۲ ضریب همبستگی پیرسون بین K_s با ویژگی‌های زود یافت خاک را نشان می‌دهد. با توجه به این جدول مشاهده می‌گردد در خاک‌های دشت اردبیل بین هدایت هیدرولیکی اشباع با مقادیر جرم ویژه حقیقی، جرم ویژه ظاهری، سیلت، شن و رس همبستگی معنی‌دار وجود دارد (جرم ویژه ظاهری در سطح پنج درصد و سایر متغیرهای مستقل در سطح یک درصد). همبستگی بین جرم ویژه ظاهری و هدایت هیدرولیکی اشباع منفی بود. جابرو (Jabro, 1992) گزارش کردند در خاک‌هایی که در کلاس‌های بافتی نزدیک هم قرار دارند، با کاهش جرم ویژه ظاهری تخلخل خاک افزایش می‌یابد و با افزایش تخلخل احتمالاً میزان درشت موئینه‌ها افزایش و در نتیجه هدایت هیدرولیکی اشباع نیز افزایش می‌یابد. این موضوع با مفهوم فیزیکی هدایت هیدرولیکی اشباع مطابقت دارد. وستن و همکاران (Wösten *et al.*, 2001) نشان دادند که با کاهش جرم ویژه ظاهری هدایت هیدرولیکی اشباع افزایش یافت. بین هدایت هیدرولیکی اشباع و رس همبستگی منفی و معنی‌دار ($P=0/01$) بود. کادو و همکاران (Kadu *et al.*, 2003) در مطالعات خودشان نشان دادند که رابطه منفی بین درصد رس و هدایت هیدرولیکی اشباع وجود دارد. افزایش مقدار رس خاک به علت افزایش سهم منافذ ریز نسبت به منافذ درشت در خاک، باعث کاهش K_s در خاک می‌گردد (Warrick, 2002).

$$ME = \frac{\sum_{i=1}^n (Y_i(m) - Y_i(p))}{n} \quad (3)$$

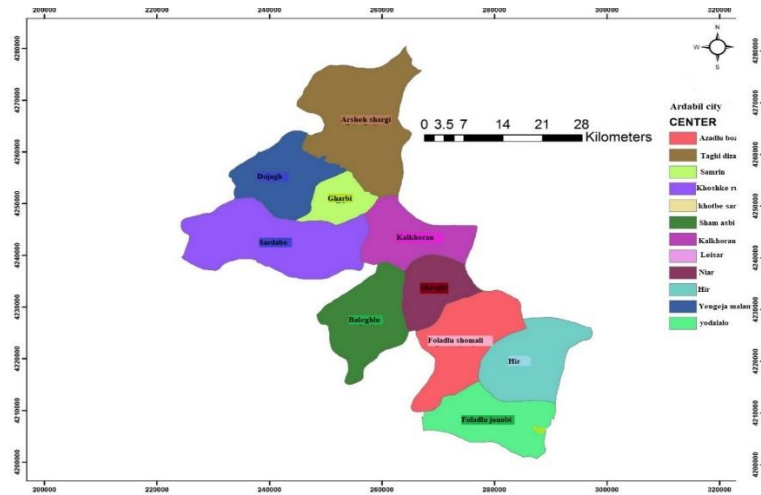
$$R^2 = 1 - \frac{SS_E}{SS_T} \quad (4)$$

$$AIC = nLn\left(\frac{ESS}{n}\right) + 2q \quad (5)$$

$Y_i(m)$: مقدار اندازه‌گیری شده پارامتر، $Y_i(p)$: مقدار برآورد شده پارامتر توسط مدل، n : تعداد داده، SSE: مجموع مربعات خطا و q : تعداد پارامترهای ورودی مدل می‌باشد.

نتایج و بحث

شکل ۱ موقعیت منطقه مورد مطالعه را نشان می‌دهد. مساحت منطقه نمونه برداری حدود ۲۲۰۰ کیلومتر مربع بود. نمونه برداری برحسب سامانه تصویر جهانی UTM و بیضوی مبنا WGS84 از طول ۲۳۰۰۰۰ کیلومتر تا ۲۹۰۰۰۰ کیلومتر و عرض ۴۲۰۰۰۰ کیلومتر تا ۴۲۷۰۰۰۰ کیلومتر صورت گرفت. آماره‌های توصیفی پارامترهای اندازه‌گیری شده برای توسعه و ارزیابی توابع انتقالی با استفاده از مدل‌های رگرسیونی و شبکه عصبی در جدول ۱ برای داده‌های آموزش و آزمون خلاصه شده است. دامنه تغییرات مقادیر شن، سیلت، رس، جرم ویژه ظاهری، جرم ویژه حقیقی، کرنات کلاسیم معادل، کرن آلی خاک و هدایت هیدرولیکی اشباع برای داده‌های آموزش و آزمون در جدول (۱) آمده است. خاک‌های مورد مطالعه دارای بافت رسی، لوم رسی، لوم، لوم رسی شنی، لوم شنی و لوم سیلتی بودند. دامنه تغییرات هدایت هیدرولیکی اشباع از ۰/۰۲ تا ۰/۴۷ سانتی‌متر بر دقیقه بود (جدول ۱) که طیف نسبتاً وسیعی را شامل می‌شود. بیشترین میزان هدایت هیدرولیکی اشباع در خاک لوم شنی مشاهده شد که تاثیر توزیع اندازه ذرات خاک بر هدایت هیدرولیکی اشباع را نشان می‌دهد. نتایج




شکل ۱- موقعیت منطقه مورد مطالعه
Figure 1. location of study region


جدول ۱- آماره‌های توصیفی پارامترهای اندازه‌گیری شده برای داده‌های آموزش و آزمون در خاک‌های دشت اردبیل

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

Parameter	Training data				Test data			
	Standard deviation	Average	Maximum	Minimum	Standard deviation	Average	Maximum	Minimum
Clay (%)	9.3	20.61	42.9	4.4	9.03	19.18	42.2	3.8
Silt (%)	7.75	37.93	57.6	24.4	10.96	36.41	49.9	28.3
Sand (%)	8.3	41.45	68	24.4	8.42	44.4	65	28.3
OC (%)	0.25	0.85	1.52	0.31	0.2	0.69	1.09	0.37
CaCO ₃ (%)	5.3	14.92	37.5	3.75	3.67	14.4	21.25	6.25
Dp(gr cm ⁻³)	0.04	2.58	2.7	2.5	0.05	2.6	2.7	2.53
Db(gr cm ⁻³)	0.14	1.35	1.7	1.04	0.15	1.38	1.6	1.15
Ks(cm min ⁻¹)	0.103	0.11	0.47	0.02	0.07	0.12	0.33	0.03



(الف) (a)



(ب) (b)

شکل ۲- توزیع هدایت هیدرولیکی اشباع - نرمال نشده (الف) و نرمال شده (ب)

Figure 2. Normalized (a) and normalized(b) saturated hydraulic conductivity distribution

جدول ۲ - ضریب همبستگی پیرسون بین متغیرهای مستقل با هدایت هیدرولیکی اشباع (K_s)

Table 2. Pearson correlation coefficient between independent variables and saturated hydraulic conductivity

parameter	$K_s(\text{cm min}^{-1})$	Clay	Sand	Silt	OC	CaCO_3	D_p	D_b
$K_s(\text{cm min}^{-1})$	1	-0.784**	0.513**	0.329**	-0.063	-0.502**	0.46**	-0.201*
Clay (%)		1	-0.618**	-0.538**	0.037	0.648**	-0.53**	-0.504**
Sand (%)			1	-0.329**	-0.241*	-0.253*	0.348**	0.457**
Silt (%)				1	0.214	-0.507**	0.263*	0.116
OC (%)					1	-0.021	0.199	-0.258*
$\text{CaCO}_3(\%)$						1	-0.297*	-0.246*
$D_p(\text{gr cm}^{-3})$							1	0.326**
$D_b(\text{gr cm}^{-3})$								1

* رابطه معنی دار در سطح احتمال ۵ درصد، ** رابطه معنی دار در سطح احتمال یک درصد

به‌طور کلی ۵ رابطه رگرسیونی برای برآورد هدایت هیدرولیکی اشباع به روش رگرسیون گام به گام توسعه یافت (جدول ۳). از بین متغیرهای زود یافت فقط از کربن آلی به‌عنوان ورودی مدل‌های رگرسیونی استفاده نشد به این دلیل که همبستگی کربن آلی با هدایت هیدرولیکی اشباع معنی‌دار نبود (جدول ۲).

جدول ۳ - معادلات رگرسیونی ارائه شده برای برآورد هدایت هیدرولیکی اشباع (K_s) خاک

Table 3. Derived regression equation for estimation saturated hydraulic conductivity

Model Number	Independent variables	Linear regression equation
1	Silt(%)-Sand(%)	$\text{Log}(K_s) = 0.025\text{Silt} + 0.027\text{Sand} - 3.108$
2	Sand(%)-Silt(%)- $D_b(\text{g cm}^{-3})$	$\text{Log}(K_s) = 0.033\text{Sand} + 0.028\text{Silt} - 0.598D_b - 2.667$
3	Clay(%)- $D_b(\text{g cm}^{-3})$	$\text{Log}(K_s) = -0.552D_b - 0.03\text{Clay} + 0.323$
4	$D_p(\text{g cm}^{-3})$ -Sand(%)- $\text{CaCO}_3(\%)$ -	$\text{Log}(K_s) = 1.555D_p + 0.013\text{Sand} - 0.02\text{CaCO}_3 - 5.307$
5	$d_g(\text{mm})$ - σ_g - $D_b(\text{g cm}^{-3})$	$\text{Log}(K_s) = 0.202 + 6.574d_g - 0.056\sigma_g - 0.534D_b$

Clay: رس، Silt: سیلت، Sand: شن، D_b : جرم مخصوص ظاهری، D_p : جرم مخصوص حقیقی، d_g : میانگین هندسی قطر ذرات خاک، σ_g : انحراف استاندارد هندسی قطر ذرات خاک، CaCO_3 : کربنات کلسیم معادل و K_s : هدایت هیدرولیکی اشباع خاک

مرحله آزمون برابر ۰/۳۸، ۰/۰۵۹ و ۴/۳۲۶ بود. مقادیر R^2 ، RMSE و AIC مدل ۲ در مرحله آموزش برابر ۰/۵۳، ۰/۰۷ و ۶/۴۴۷ و در مرحله آزمون برابر ۰/۵۱، ۰/۰۵۲ و ۶/۲۲۷ بود. مدل ۲ در مرحله آموزش دارای R^2 و RMSE (۰/۵۳ و ۰/۰۷) مشابه مدل ۳ بود ولی تعداد پارامتر ورودی بیشتر باعث بزرگتر شدن ضریب آکائیک در مدل ۲ ($\text{AIC} = ۶/۴۴۷$) شده بود. با در نظر گرفتن ضریب آکائیک باید مدل ۳ به‌عنوان بهترین مدل آماری انتخاب شود (Amirabedi, 2011). ولی چون مدل ۳ در مرحله آزمون عملکرد پایین داشت به‌عنوان بهترین مدل آماری انتخاب نشد. بنابراین در مدل‌های رگرسیونی با در نظر گرفتن مقادیر R^2 و RMSE در داده‌های آزمون و آموزشی مدل ۲ با متغیرهای ورودی درصد شن، سیلت و جرم ویژه ظاهری به‌عنوان بهترین مدل آماری معرفی شد. بهترین مدل در برآورد متغیر وابسته مدلی است که هم در مرحله آموزش و هم در مرحله آزمون عملکرد مناسبی داشته باشد (Merdun

نتایج رابطه‌های رگرسیونی و شبکه عصبی برای برآورد هدایت هیدرولیکی اشباع برای داده‌های آموزش و آزمون نشان داده شده است (جدول ۴ و ۵). مقادیر ME برای اکثر مدل‌های رگرسیونی در مرحله آموزش و آزمون منفی بود. بنابراین این مدل‌ها هدایت هیدرولیکی اشباع را در مرحله آموزش و آزمون کمتر از مقدار واقعی برآورد می‌کنند. برای مدل‌های شبکه عصبی مقادیر ME در مرحله آموزش مثبت و مقادیر متوسط آن در مرحله آزمون منفی بود که نشان می‌دهد شبکه‌های عصبی هدایت هیدرولیکی اشباع را در مرحله آموزش بیشتر از مقدار واقعی و در مرحله آزمون کمتر از مقدار واقعی نشان می‌دهند. مدل‌های رگرسیونی که در مرحله آموزش عملکرد مناسبی در برآورد هدایت هیدرولیکی اشباع داشتند شامل مدل ۳ با متغیرهای ورودی رس و جرم ویژه ظاهری و مدل ۲ با متغیرهای ورودی درصد شن، درصد سیلت و جرم ویژه ظاهری بودند. مقادیر R^2 ، RMSE و AIC مدل ۳ در مرحله آموزش برابر ۰/۵۳، ۰/۰۷۴ و ۴/۴۵ و در

هیدرولیکی خاک هم‌خوانی دارد (Doai, 2016; Amirabedi, 2006; Jain & Kumar, 2006; Mesri, 2009). مصری (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 (2009) (Yilmaz & Yuksek) 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. میناسنی و مک بارتنی (2002) (Mcbartney & Minasny) 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. خلیل‌مقدم و همکاران (2009) (Khalilmoghdam) کار برد روش‌های رگرسیونی و شبکه‌های عصبی در تشکیل توابع انتقالی خاک به‌منظور 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 به‌عنوان ویژگی‌های زود یافت 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.

در این پژوهش علاوه بر مقایسه نتایج مدل‌های رگرسیونی و شبکه عصبی با داده‌های ورودی یکسان در برآورد K_s ، ترکیبی از کل متغیرهای مستقل (به جزء کربن آلی) در ایجاد شبکه عصبی به کار گرفته شدند تا نتایج شبکه حاصل از تمام داده‌های ورودی با نتایج حاصل از داده‌های ورودی به کار گرفته شده حاصل از رگرسیون گام‌به‌گام مورد مقایسه قرار گیرد.

(2006, *et al.*). جابرو (1992, Jabro) در رابطه رگرسیونی ایجاد شده از مقادیر سیلت، رس و جرم ویژه ظاهری برای برآورد هدایت هیدرولیکی اشباع استفاده کردند. زرین‌فر (Zarinfar, 2011, *et al.*) پارامترهای انحراف معیار هندسی قطر ذرات خاک، میانگین هندسی قطر ذرات خاک و میانه قطر کل ذرات خاک را به‌عنوان بهترین ورودی در مدل ایجاد شده معرفی کردند و $R^2 = 0/4$ را گزارش کردند. بهترین مدل شبکه عصبی، مدل 5 با آماره‌های R^2 ، RMSE و AIC برابر $0/84$ ، $0/04$ و $6/138$ در مرحله آموزش و $0/06$ ، $0/73$ و $6/089$ در مرحله آزمون بود که از مقادیر جرم ویژه ظاهری، میانگین هندسی قطر و انحراف معیار هندسی قطر ذرات خاک به عنوان ورودی مدل شبکه عصبی استفاده شده بود. این مطلب بیان‌گر آن است که میانگین هندسی قطر و انحراف معیار هندسی قطر ذرات خاک می‌توانند به‌عنوان ورودی مدل‌های شبکه عصبی در برآورد ویژگی‌های هیدرولیکی خاک با دقت مناسب به کار برده شوند. دعایی و همکاران (Doai *et al.*, 2005) برای برآورد K_s از مقادیر جرم ویژه ظاهری، کربن آلی و رس به عنوان پارامترهای زود یافت در ورودی مدل شبکه عصبی استفاده کردند و ضریب تبیین $0/97$ را گزارش کردند. مردون و همکاران (2006, Merdun *et al.*) از توزیع اندازه ذرات خاک، جرم ویژه ظاهری و سه منفذ با اندازه‌های مختلف به‌عنوان ورودی شبکه عصبی در برآورد هدایت هیدرولیکی اشباع استفاده کردند و حداکثر ضریب تبیین $0/52$ را گزارش کردند. نصرتی و همکاران (2012, Nosrati *et al.*) بهترین مدل شبکه عصبی را از پارامترهای ورودی میانگین هندسی قطر ذرات، تخلخل کل، درصد شن و رس به دست آوردند. برای مقایسه نتایج توابع انتقالی رگرسیونی با شبکه عصبی در برآورد هدایت هیدرولیکی اشباع ابتدا داده‌های نرمال شده به مقادیر واقعی تبدیل شدند. تمام مدل‌های رگرسیونی در مرحله آموزش دارای دقت کمتر و خطای بیشتری نسبت به مدل‌های شبکه عصبی در برآورد K_s بودند (جدول 4). در مرحله آزمون خطای برخی مدل‌های رگرسیونی نسبت به شبکه‌های عصبی در برآورد K_s پایین بود (جدول 5). شکل 2 پراکنش داده‌های K_s حول محور 1:1 در بهترین مدل رگرسیونی و شبکه عصبی را نشان می‌دهد. مقادیر متوسط RMSE، R^2 و AIC برای نتایج مدل‌های رگرسیونی و شبکه عصبی نشان داد که شبکه عصبی دارای خطای کمتر و دقت بیشتری در برآورد هدایت هیدرولیکی اشباع هستند. این یافته با نتایج برخی محققان دیگر در برآورد پارامترهای

جدول ۴- آماره‌های ارزیابی مدل‌های مختلف رگرسیونی و شبکه عصبی مصنوعی (ANN) برای داده‌های آموزش در برآورد هدایت هیدرولیکی اشباع (k_s)

Table 4. Evaluating statistics for different regression (Reg-PTF) and artificial neural network (ANN- PTF) models for training data in estimating saturated hydraulic conductivity.

Model Number	Independent variables	Reg- PTF				ANN-PTF			
		ME	R ²	RMSE (cm min ⁻¹)	AIC	ME	R ²	RMSE (cm min ⁻¹)	AIC
1	Silt(%)-Sand(%)	-0.009	0.45	0.078	4.5	0.001	0.65	0.06	4.3
2	Sand (%) -Silt (%) D _b (g cm ⁻³)	-0.012	0.53	0.07	6.447	0.003	0.83	0.042	6.145
3	Clay(%)- D _b (g cm ⁻³)	0.005	0.53	0.074	4.45	0.0001	0.62	0.06	4.326
4	D _p (g cm ⁻³)-Sand (%) CaCO ₃ (%)	-0.014	0.39	0.081	6.54	0.007	0.63	0.06	6.3
5	dg(mm)- σ _g -D _b (g cm ⁻³)	-0.011	0.47	0.076	6.479	0.006	0.84	0.04	6.138

Clay: رس، Silt: سیلت، Sand: شن، D_b: جرم مخصوص ظاهری، D_p: جرم مخصوص حقیقی، dg: میانگین هندسی قطر ذرات خاک، σ_g: انحراف استاندارد هندسی قطر ذرات خاک، CaCO₃: کربنات کلسیم معادل و K_s: هدایت هیدرولیکی اشباع خاک، AIC: ضریب آکائیک

جدول ۵- آماره‌های ارزیابی مدل‌های مختلف رگرسیونی و شبکه عصبی مصنوعی (ANN) برای داده‌های آزمون در برآورد هدایت هیدرولیکی اشباع (k_s)


Table 5. Evaluating statistics for different regression (Reg-PTF) and artificial neural network (ANN- PTF) models for testing data in estimating saturated hydraulic conductivity.

Model Number	Independent variables	PTF				ANN			
		ME	R ²	RMSE (cm min ⁻¹)	AIC	ME	R ²	RMSE (cm min ⁻¹)	AIC
1	Silt(%)-Sand(%)	-0.006	0.38	0.058	4.06	-0.03	0.63	0.09	4.170
2	Sand (%) -Silt (%) - D _b (gr cm ⁻³)	-0.009	0.51	0.052	6.227	-0.01	0.74	0.06	6.077
3	Clay (%) - D _b (gr cm ⁻³)	-0.0012	0.38	0.059	4.069	0.002	0.47	0.05	4.065
4	D _p (gr cm ⁻³)- Sand(%)- CaCO ₃ (%)	0.0048	0.49	0.056	6.06	-0.02	0.2	0.09	6.173
5	dg(mm)- σ _g - D _b (gr cm ⁻³)	0.0056	0.36	0.105	6.222	0.001	0.73	0.06	6.089

Clay: رس، Silt: سیلت، Sand: شن، D_b: جرم مخصوص ظاهری، D_p: جرم مخصوص حقیقی، dg: میانگین هندسی قطر ذرات خاک، σ_g: انحراف استاندارد هندسی قطر ذرات خاک، CaCO₃: کربنات کلسیم معادل و K_s: هدایت هیدرولیکی اشباع خاک، AIC: ضریب آکائیک.

شکل ۳ نمودار پراکنش داده‌ها حول محور یک به یک برای مقادیر برآورد شده و اندازه‌گیری شده K_s برای داده‌های آموزش و آزمون را نشان می‌دهد. نتایج نشان داد کاربرد تعداد داده‌ی ورودی بیشتر باعث کاهش خطا و افزایش ضریب تبیین در برآورد K_s در داده‌های آموزش شده است.

مقادیر RMSE، R² و AIC برای مدل شبکه عصبی با داده‌های ورودی میانگین هندسی قطر (d_g) ذرات خاک، انحراف معیار هندسی قطر (σ_g) ذرات خاک، کربنات کلسیم، جرم ویژه ظاهری و جرم ویژه حقیقی در مرحله آموزش برابر ۰/۰۰۳۶، ۰/۸۷ و ۱۲/۱۰۸ و در مرحله آزمون برابر ۰/۰۷۶، ۰/۵۸ و ۱۲/۴۷۶ بود (جدول ۶).



شکل ۲- نمودار ۱:۱ مقادیر اندازه‌گیری شده و برآورد شده هدایت هیدرولیکی اشباع با استفاده از بهترین مدل رگرسیونی (Reg-PTF) و شبکه عصبی مصنوعی (ANN-PTF)

Figure 2. Measured and estimated diagram (1:1) of saturated hydraulic conductivity, using the best model of regression and artificial neural network


تمامی پارامترهای ورودی در برآورد K_s افزایش می‌یابد. نصرتی و همکاران (Nosrati *et al.*, 2012) گزارش کردند اضافه کردن پارامترهای ورودی در تکنیک شبکه عصبی باعث کاهش RMSE و افزایش R^2 در برآورد K_s می‌شود. آن‌ها بهترین مدل را از پارامترهای ورودی در صد شن، در صد رس، لگاریتم میانگین هندسی قطر، تخلخل کل و رطوبت در مکش ۰/۳ بار را به‌دست آوردند.

ولی به دلیل کاربرد تعداد داده‌ی ورودی بیشتر ضریب آکائیک (AIC) به مقدار قابل توجهی افزایش یافته است. با توجه به افزایش مقادیر R^2 و کاهش RMSE در صورت در دسترس بودن تمامی متغیرهای مستقل توصیه می‌شود از همه آن‌ها در یک لایه ورودی برای ایجاد مدل شبکه‌ی عصبی مصنوعی استفاده شود. خاشعی و همکاران (Khashei *et al.*, 2015) گزارش کردند که عملکرد شبکه‌های عصبی در صورت ارایه

جدول ۶- آماره‌های ارزیابی شبکه عصبی مصنوعی (ANN) برای داده‌های آموزش و آزمون در برآورد هدایت هیدرولیکی اشباع
Table 6. Evaluating statistics for artificial neural network (ANN) models for testing and training data in estimating saturated hydraulic conductivity.

Independent variables	Training			AIC	Testing			
	ME	R^2	RMSE (cm min ⁻¹)		ME	R^2	RMSE (cm min ⁻¹)	
$d_g(\text{mm})$ - σ_g - $D_b(\text{g cm}^{-3})$ - $\text{CaCO}_3(\%)$ - $D_p(\text{g cm}^{-3})$	0.0021	0.87	0.036	12.108	-0.014	0.58	0.076	12.476

Db: جرم ویژه ظاهری، D_p : جرم ویژه حقیقی، d_g : میانگین هندسی قطر ذرات خاک، σ_g : انحراف استاندارد هندسی قطر ذرات خاک، CaCO_3 : کربنات کلسیم معادل.



شکل ۳- نمودار ۱:۱ مقادیر اندازه‌گیری شده و برآورد شده هدایت هیدرولیکی اشباع با استفاده از شبکه عصبی مصنوعی (ANN) برای داده‌های آموزشی (Training) و آزمونی (Testing)

Figure 3. Measured and estimated diagram (1:1) of saturated hydraulic conductivity, using the artificial neural network for training and testing data set

نتیجه‌گیری کلی

هند سی (σ_g) و میانگین هند سی قطر (d_g) ذرات خاک با RMSE، R^2 و AIC برابر 0.04 ، 0.84 و $6/138$ بود. نتایج نشان داد که شبکه‌های عصبی دارای دقت بیشتر و خطای کمتر در برآورد هدایت هیدرولیکی اشباع نسبت به مدل‌های رگرسیونی هستند. در روش دیگر از تمام متغیرهای زودیافت (به جزء کربن آلی) به عنوان ورودی مدل شبکه عصبی استفاده شد (جدول ۶). مقادیر RMSE، R^2 و AIC (به ترتیب 0.036 ، 0.87 و $12/108$) نشان داد که دقت شبکه عصبی در صورت ارائه تمامی پارامترهای ورودی در برآورد K_s افزایش می‌یابد.

در این پژوهش هدف اصلی ارائه مدل‌هایی بود که بتوان هدایت هیدرولیکی اشباع (K_s) را با صرف هزینه و زمان کم با دقت قابل قبولی برآورد کرد. برای این منظور از دو روش رگرسیون و شبکه عصبی در مدل‌سازی‌ها استفاده شد. بر اساس معیارهای آماری بهترین مدل رگرسیون از پارامترهای ورودی شن، سیلت و جرم ویژه ظاهری با RMSE، R^2 و AIC برابر 0.07 ، 0.53 و $6/447$ به دست آمد. بهترین مدل شبکه عصبی دارای پارامترهای ورودی جرم ویژه ظاهری، انحراف معیار

Reference

- 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)
- Amirabedi H., Asghari Sh., Mesri T., and Balandeh N. 2016. Prediction of mean weight diameter of aggregates using artificial neural network and regression models. *Applied Soil Research*, 4(1): 39-53. (in Persian)
- Amirabedi H., Asghari Sh., Mesri T., and Keivan behjo 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. (in Persian).
- Barzegar A.R. 2008. Advanced Soil Physics. Shahid Chamran University Press. 309 pp.
- Boadu, F. K. 2000. Hydraulic conductivity of soils from grain-size distribution: new models. *Journal of Geotechnical and Geoenvironmental Engineering*. 126(8), 739-746.
- Brakensiek D.L., Rawls W.J., and Stephenson G.R. 1984. Modifying SCS hydrologic soil groups and curve numbers for rangeland soils. ASAE Paper (PNR-84203)
- Campbell G.S. 1985. Soil Physics with Basic: Transport Models for Soil-Plant System. Elsevier, New York. 150 pp.
- Doai M., Shabanpaour Shahrestani M., Bagheri F. 2005. Modelling of saturated hydraulic conductivity of Gilan province artificial neural networks. *The Agriculture Science Research Report*, 1(6): 41-48. (in Persian)
- Ghanbarian-Alavigeh B., Liaghat A., and Sohrabi S. 2009. Application of artificial neural networks in prediction of saturated hydraulic conductivity using soil physical parameters. *Journal of Agricultural Engineering Research*, 10(1):1. 97-112.
- 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)
- Hassan Shah A., Lone M., Stephen I., and Anderson H. 1997. Regression model to predict hydraulic conductivity from simple soil physical and chemical properties. 7th ICID international drainage workshop. Malaysia.
- Jabro J.A., 1992. Estimation of Saturated Hydraulic Conductivity of Soils from Particle Size Distribution and Bulk Density Data. *Trans ASAE*. 35:557-560.
- Jain A., and Kumar A. 2006. An evaluation of artificial neural network technique for the determination of infiltration model parameters. B.V. Amsterdam, Netherlands. Pp. 272-282..
- Kadu P.R., Vaidya P.H., Balpande S.S., Satyavathi P.L.A., and Pal D.K. 2003. Use of hydraulic conductivity to evaluate the suitability of vertisols for deep-rooted crops in semiarid parts of central india. *Soil Use and Management*, 19: 208-216.
- Kelishadi H., Mosaddeghi M.R., Hajabbasi M.A., and Ayoubi S. 2013. Evaluating and developing pedotransfer functions to predict soil saturated hydraulic conductivity at landscape scale in Central Zagros. *Applied Soil Research*, 1(2): 16-33.

- 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., Nofereesti 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*, 5(3): 81-95.
- Khodaverdiloo H., Homae M.Th., Van Genuchten M., and Ghorbani Dashtaki Sh. 2011. Deriving and validating pedotransfer functions for some calcareous soils. *Journal of Hydrology*, 399: 93-99.
- Klute A., and Dirksen C. 1986. Hydraulic conductivity of saturated soils. In methods of soil analysis. *Soil Science Society of America*, Madison, Wisconsin, USA. (pp. 694-700).
- Klute A., 1986. Methods of Soil Analysis. Part 1. Physical and Mineralogical Methods. 2 nd edition. Agron. Monog. 9. ASA and SSSA, Madison, WI.
- 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 & Tillage Research*, 90: 108–116.
- Mesri Gundoshmian T. 2009. The use of intelligent systems to optimize drop combine. PhD thesis, Engineering of Agriculture Machinery and Mechanization Department, University of Tabriz. 119 p. (in Persian)
- Minasny B., and Mcbartney A.B. 2002. The neuron method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*, 66: 352-361.
- Mualem Y., 1976. A new model for predicting the hydraulic conductivity of unsaturated porous media. *Water Resource Research*, 12, 593–622.
- Nosrati Karizak1 F., Movahedi Naeni S.A., Hezarjaribi A., Roshani Gh.A., and Deghani A.A. 2012. Using artificial neural networks to estimate saturated hydraulic conductivity from easily available soil properties. *Journal of Soil Management and Sustainable Production*, 2(1). 95-110. (in Persian)
- 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.
- Page A.L. (ed.).1985. Methods of Soil Analysis. Part 2. Chemical and Microbiological Methods. Agronomy No. 9. *American Society of Agronomy*, Madison, WI.
- Salarashayeri A.F., and Siosemarde M. 2012. Prediction of soil hydraulic conductivity from particle-size distribution. *International Journal of Environmental, Chemical, Ecological, Geological and Geophysical Engineering*, 6(1): 16-20.
- Sarmadian F., Ghanbarian Alavijeh 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.
- Saxton K. E., Rawls W. J., Romberger J.S., and Papendick R.I. 1986. Estimating generalized soil water characteristics from texture. *Soil Science Society of American Journal*, 50: 1031–1036.
- Schaap M.G., and Bouten W. 1996. Modeling water retention curves of sandy soils using neural networks. *Water Resource Research*, 32: 3033–3040.
- Van Genuchten M.Th., 1980. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. *Soil Science Society of American Journal*, 44: 892–898.
- Walkley A.J., and Black I.A. 1934. An examination of degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Science*, 37: 29–38.
- Warrick A.W. 2002. *Soil Physics Companion*. CRC Press. 389 p.
- Wösten J.H.M., Lilly A., Nemes A., and Le Bas C. 1999. Development and use of a database of hydraulic properties of European soils. *Geoderma*, 90: 169-185.
- Wösten J.H.M., Pachepsky Ya.A., and Rawls W.J. 2001. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Journal of Hydrology*, 251:123-150.
- 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.
- Zarinfar S., Ghahraman B., and Davary N. 2011. Development of some pedotransfer functions to predict the saturated hydraulic conductivity of gravel soils using partial least square regression method. *Journal of Water and Soil*, 25(3): 617-624.

Estimating the Soil Saturated Hydraulic Conductivity in Ardabil Plain Soils Using Artificial Neural Networks and Regression Models

Hamed Amirabedi^{1*}, Shokrollah Asghari², Tarahhom Mesri Gandoshmin³,
Naser Balandeh⁴, Ebrahim Johari⁵

(Received: January 2018 Accepted: December 2018)

Abstract

Soil saturated hydraulic conductivity (Ks) can be estimated from surrogate data such as soil texture, bulk density and organic carbon and CaCO₃ contents using regression (Reg-PTFs) and artificial neural networks (ANN-PTFs) pedotransfer function (PTF). Saturated hydraulic conductivity was measured by falling head method in 100 soil samples that obtained from Ardabil plain, Iran. After performing physical and chemical analysis on soil samples, the data were divided into two sets of training (80 samples) and validation data (20 samples). Regression models were created by SPSS software, stepwise method and neural networks models were created by Neurosolution software. Statistics criteria such as coefficient of determination (R²), root mean square deviation (RMSE) and Akaike information Criterion (AIC) were determined. Input variables in the best regression models were sand, silt and bulk density. The best neural network models were obtained from the input variables that include bulk density, geometric mean and standard deviation of soil particle size distribution. The values for R² and RMSE in training and testing data set for the Reg-PTF were 0.53, 0.074 and 0.51, 0.052 and for the ANN-PTF they were 0.84, 0.04 and 0.73, 0.06, respectively. In this research all independent variables such as bulk density, particle density, CaCO₃, geometric mean and standard deviation of the particle size distribution included as inputs for development of Reg-PTFs and ANN-PTFs. The amount of R² and RMSE for training and testing data set equal 0.87, 0.036 and 0.58, 0.076, respectively. Results showed that the ANN-PTF (R²= 0.84) performs better than the Reg-PTF (R²= 0.53) in this case. It was also found that when all independent variables were used as inputs in the neural ANN-PTF the values of R² and RMSE (0.87 and 0.036) have been improved in the training data set.

Keywords: Falling head, Independent Parameters, Pedotransfer function, Stepwise Regressions

Amirabedi H., Asghari Sh., Mesri Gandoshmin T., Balandeh N., Johari E. 2019. Estimating the soil saturated hydraulic conductivity in Ardabil Plain soils using artificial neural networks and regression models. *Applied Soil Research*. 7(4):124-136.

1. M.Sc. Graduate, Department of Soil Science and Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran.

2. Associate Professor, Department of Soil Science and Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran.

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

4. M.Sc. Department of Soil Science, Faculty of Agriculture and Natural Resources, Urmia University, Urmia, Iran.

5. M.Sc. Graduate, Department of Water Engineering, Faculty of Agriculture and Natural Resources, Urmia University, Urmia, Iran.

* Corresponding Author Email: amirabedihamed@yahoo.com