



شماره ۱۱۰، بهار ۱۳۹۵

روش‌های آبخیزداری

(پژوهش و سازندگی)

مقایسه مدل‌های شبکه‌های عصبی مصنوعی و رگرسیون آماری برای پیش‌بینی هدایت هیدرولیکی اشباع خاک در مقیاس حوزه آبخیز

• حمیدرضا متقیان

دانشجوی دکتری، گروه خاکشناسی، دانشکده کشاورزی دانشگاه شهرکرد (نویسنده مسئول)

• جهانگرد محمدی

دانشیار گروه خاکشناسی، دانشکده کشاورزی دانشگاه شهرکرد

• احمد کریمی

استادیار گروه خاکشناسی، دانشکده کشاورزی دانشگاه شهرکرد

تاریخ دریافت: بهمن ماه ۱۳۹۱ تاریخ پذیرش: تیر ماه ۱۳۹۲

Email: hrm_61@yahoo.com

چکیده

هدایت هیدرولیکی اشباع خاک (Ks) از جمله مهمترین خصوصیات فیزیکی و هیدرولیکی مورد نیاز در مدل‌سازی‌های آب-خاک است. به علت وقت‌گیر و پرهزینه بودن ذاتی اندازه‌گیری Ks، برآورد آن از خصوصیات فیزیکی و شیمیایی اولیه، ارزان و سهل‌الوصول اندازه‌گیری شده خاک اهمیت بسیار زیادی دارد. در دو دهه اخیر، گسترش روش‌های برآورد تحت عنوان توابع انتقالی، که از متغیرهای کمکی سهل‌الوصول بهره می‌گیرند، نقطه عطفی در مطالعات خاک بوده است. تحقیق حاضر جهت (۱) بسط و توسعه توابع انتقالی مختلف و (۲) ارزیابی و مقایسه مدل‌های توابع انتقالی براساس رگرسیون آماری و شبکه عصبی مصنوعی در برآورد Ks در زیرحوزه رودخانه زاینده‌رود واقع در استان چهارمحال و بختیاری انجام شد. کل داده‌ها به دو زیرمجموعه، شامل داده‌های مدل‌سازی (n=۸۶) و ارزیابی (n=۲۵) تقسیم شدند. ریشه میانگین مربعات خطا (RMSE)، میانگین خطا (ME) و درصد بهبود نسبی (RI) به عنوان شاخص‌های ارزیابی مورد استفاده قرار گرفتند. مدل‌های توابع انتقالی براساس شبکه عصبی مصنوعی تخمین قابل اطمینان‌تری نسبت به توابع انتقالی براساس رگرسیون آماری ارائه دادند.

کلمات کلیدی: توابع انتقالی، شاخص‌های ارزیابی، متغیرهای کمکی.

Comparison of artificial neural network and regression pedotransfer functions for prediction of soil saturated hydraulic conductivity

By: H. R. Motaghian: PhD Student, Faculty of Agriculture, Shahrekord University (Corresponding Author). J. Mohammadi: Associate Professor, Faculty of Agriculture, Shahrekord University. A. Karimi: Assistant Professor of Soil Science, Faculty of Agriculture, Shahrekord University.

Soil saturated hydraulic conductivity (Ks) is among the most important soil hydraulic-physical properties that required for soil-water modeling. Due to high cost and time-consuming nature of Ks measurement, estimating Ks from basic, inexpensive and easily measured physical and chemical soil properties is becoming increasingly important. In the last two decades, the development of estimation methods called pedotransfer functions that use cheap auxiliary variables has been a sharpening focus of soil research. This study was conducted (i) to develop different pedotransfer functions and (ii) to evaluate and compare statistical regression and neural network based pedotransfer functions for estimating Ks in a sub-catchment of Zayanderood River, located in Chaharmahal-va-Backtiari province. The data set was divided in to subsets for modeling (n=86) and validation (n=25). Root-mean-square error (RMSE), mean error (ME) and percentage of relative improvement (RI) were used as the validation indices. The artificial neural network-based models provided more reliable estimation than the statistical regression-based pedotransfer functions.

Keywords: Auxiliary variables, Pedotransfer functions, Validation indices.

ذرات، جرم مخصوص ظاهری و کربن آلی خاک به عنوان متغیر توضیحی رگرسیون استفاده می‌شوند. توابع انتقالی خاک را می‌توان توسط دو تکنیک رگرسیون آماری و شبکه عصبی مصنوعی بدست آورد. شبکه عصبی مصنوعی یکی از روش‌های هوشمند پردازش داده‌ها هستند که به دلیل روش تحلیل اطلاعات مشابه با مغز انسان، داشتن قدرت تعمیم، عدم نیاز به یک مدل ریاضی از پیش تعیین شده، عدم نیاز به هم‌راستایی و نرمال بودن داده‌ها و توانایی آموزش و یادگیری می‌توانند در بسط توابع انتقالی خاک مورد استفاده قرار گیرند (Mohammadi ۲۰۰۲; Givi, Prasher, and Patel, ۲۰۰۴; Amini et al ۲۰۰۵). در مقابل، روش‌های رگرسیون آماری، علیرغم حساسیت به هم‌راستایی و نرمال بودن داده‌ها، در مجموع راحت‌تر و در برخی موارد سریع‌تر هستند و به این دلیل بعضی از محققین در صورتبندی توابع انتقالی از این تکنیک بهره می‌گیرند. در تحقیقات متعددی از ویژگی‌های مختلف خاک از جمله برآورد هدایت هیدرولیکی اشباع از رگرسیون خطی چندگانه در کنار سایر روش‌های مدل‌سازی استفاده شده است (Tamari, Wosten, Merdun, Meral, and Apan ۱۹۹۶; Ruz-suarez, Pachepsky, Timilin, and Varallyay ۲۰۰۶).

مقدمه

اندازه‌گیری هدایت هیدرولیکی اشباع خاک (Ks) با توجه به نقش آن در فرآیندهای تصمیم‌گیری و مدیریت حوزه آبخیز از اهمیت بسیار زیادی برخوردار است. به دلیل تغییرات مکانی زیاد هدایت هیدرولیکی اشباع خاک، استفاده از یک مقدار عددی واحد مانند میانگین هدایت هیدرولیکی اشباع برای محدوده وسیع در مقیاس حوزه آبخیز منطقی به نظر نمی‌آید. بنابراین، یا باید نمونه‌برداری بیشتری در کل منطقه انجام گیرد و یا اینکه برای موقعیت‌هایی که فاقد اطلاعات در مورد Ks هستیم با استفاده از اطلاعات کمکی و ثانویه اقدام به تخمین این ویژگی خاک نماییم. از آنجایی که اندازه‌گیری این خصوصیت متضمن صرف زمان و هزینه قابل توجهی است، لذا رویکرد دوم بیشتر مورد توجه می‌باشد. توابع انتقالی از روش‌های غیرمستقیم بوده است که می‌توان با کمک آنها ویژگی‌های دیرپافت خاک را از ویژگی‌های زودپافت آن برآورد نمود. دو نوع توابع انتقالی کلاسی و پیوسته ارائه شده است، توابع انتقالی کلاسی که در آن از افق مشخصه یا نوع خاک به عنوان متغیر توضیحی رگرسیون استفاده می‌شود و توابع انتقالی پیوسته که در آن خصوصیات مختلف خاک مانند فراوانی نسبی

برداشت شده از سه عمق خاک از سطح ۶۷۵ کیلومترمربع با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی چندگانه برای برخی خصوصیات هیدرولیکی خاک از جمله هدایت هیدرولیکی اشباع مدل‌سازی کردند و نتیجه گرفتند که بر عکس سایر خصوصیات هیدرولیکی اندازه‌گیری شده، مدل رگرسیون خطی چندگانه علیرغم ضریب تبیین (R^2) پایین، با خطای کمتری نسبت به شبکه عصبی مصنوعی هدایت هیدرولیکی اشباع را برآورد می‌کند. این تحقیق با هدف مدل‌سازی با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی چندگانه برای برآورد هدایت هیدرولیکی اشباع و مقایسه بین مدل‌های ایجاد شده در مقیاس یک حوزه آبخیز انجام شد.

مواد و روش‌ها

۱-۲- منطقه مورد مطالعه

تحقیق حاضر در حوزه مرغملک از زیرحوزه‌های رودخانه زاینده‌رود، به مساحت ۹۷ کیلومترمربع در ۵۵ کیلومتری شمال غربی شهرستان شهرکرد (مرکز استان چهارمحال و بختیاری) انجام شد. فلات، تراس فوقانی و دشت‌های آبرفتی مهمترین اشکال اراضی در منطقه هستند. تراس‌های فوقانی دارای شیب بیش از ۵ درصد، فرسایش متوسط، سنگ و سنگریزه (۱۵-۳٪) و با مواد آبرفتی ریز پوشانیده شده‌اند و دشت‌های آبرفتی دارای شیب ملایم هستند. کلاس بافت خاک در منطقه عمدتاً silty clay loam و clay loam است و عمق خاک در فلات زیادتر است. اگرچه فعالیت‌های کشاورزی به صورت گسترده توسعه نیافته‌اند، با این حال کاربری اراضی عمده در منطقه شامل، مراتع طبیعی و دیم‌کاری است. بیشتر بخش‌های مراتع و دیم‌کاری‌ها، زمین‌هایی هستند که تحت تأثیر چرای شدید و شخم غیرحفاظتی قرار گرفته‌اند. بارش متوسط سالیانه ۴۰۰ میلی‌متر که بیشتر در زمستان و بهار اتفاق می‌افتد.

ابتدا سطح منطقه مطالعاتی با استفاده از شبکه‌بندی منظم با فواصل ۱ کیلومتری تقسیم‌بندی شد، ولی شرایط توپوگرافی و عدم امکان دسترسی به برخی از نقاط تعیین شده باعث شد که در نهایت نمونه‌برداری به صورت شبه‌منظم انجام شود. شکل ۱ موقعیت منطقه مورد مطالعه و نقاط نمونه‌برداری را نشان می‌دهد. در مجموع ۱۱۱ نقطه از خاک سطحی برای نمونه دست‌نخورده و دست‌خورده تعیین شد. پس از هوا خشک کردن نمونه‌ها و عبور از الک ۲ میلی‌متری، درصد شن، سیلت و رس به روش هیدرومتر (Gee and Bauder, ۱۹۸۶) و درصد ماده‌آلی به روش والکی-بلاک (Nelson et al, ۱۹۸۶) تعیین گردیدند. نمونه‌های دست‌نخورده از لایه سطحی با استفاده از سیلندر فلزی به حجم 100 cm^3 برای تعیین جرم مخصوص ظاهری () و نیز نمونه‌های دست‌نخورده دیگری با استفاده از استوانه‌ای به قطر ۵/۰۸ سانتی‌متر و ارتفاع ۱۰ سانتی‌متر جهت اندازه‌گیری هدایت هیدرولیکی اشباع خاک برداشته شد. هدایت هیدرولیکی اشباع خاک با استفاده از روش بار افتان (Klute and Dirksen, ۱۹۸۶) در آزمایشگاه اندازه‌گیری شد.

۲-۲- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی از سه لایه ورودی، پنهان و خروجی تشکیل

برخی محققین فقط از رگرسیون آماری در برآورد هدایت هیدرولیکی اشباع استفاده کرده‌اند (نوابیان و همکاران، ۱۳۸۲؛ Woston, Finke, and Jansen, ۱۹۹۵)، بعضی دیگر از محققین از شبکه عصبی مصنوعی به تنهایی در برآورد هدایت هیدرولیکی اشباع سود جست‌ه‌اند (Minansy et al, ۲۰۰۲؛ Parasuraman, Elshorbagy, and Bing-Chenge, ۲۰۰۶). مقایسه بین دو روش مدل‌سازی (شبکه‌های عصبی مصنوعی و رگرسیون آماری) در برآورد خصوصیات خاک از جمله هدایت هیدرولیکی اشباع، توسط محققین متعدد انجام شده است و در اغلب موارد برآوردهای شبکه عصبی مصنوعی از دقت بالاتری برخوردار بوده است (Minansy, Merdun, Meral, and McBatney, and Bistow, ۲۰۰۶). نوابیان و همکاران (۱۳۸۲) و وستن و همکاران (۱۹۹۵) با استفاده از توابع انتقالی رگرسیون خطی چندگانه و بر اساس خصوصیات نظیر جرم مخصوص ظاهری و فراوانی نسبی ذرات خاک اقدام به مدل‌سازی هدایت هیدرولیکی اشباع نمودند. آهوجا و همکاران (۱۹۸۹) با استفاده از پارامترهای زودیافتی همچون فراوانی نسبی ذرات خاک و جرم مخصوص ظاهری به برآورد هدایت هیدرولیکی اشباع اقدام نمودند. رومانو و پالادینو (۲۰۰۲) خصوصیات هیدرولیکی خاک را در طول دو ترانسکت و بر اساس خصوصیات فیزیکی و اطلاعات زمینی بررسی کردند. پاراسورامن و همکاران (۲۰۰۶) در ترانسکتی به طول ۳۸۴ متر از ۱۲۶ نقطه جهت مقایسه روش‌های مختلف شبکه عصبی مصنوعی نمونه‌برداری کرده و در مجموع شبکه عصبی مصنوعی را مناسب برای برآورد خصوصیات هیدرولیکی از جمله هدایت هیدرولیکی اشباع دانستند. آنها از پارامترهای ورودی، فراوانی نسبی ذرات و جرم مخصوص ظاهری خاک را در مدل‌سازی استفاده کردند. دعایی و همکاران (۱۳۸۴) با استفاده از شبکه عصبی مصنوعی با ساختار یک لایه پنهان متشکل از ۶ نرون اقدام به برآورد هدایت هیدرولیکی اشباع کردند. متغیرهای ورودی شامل جرم مخصوص ظاهری، درصد رس و کربن‌آلی بود. آنها ضریب تبیین برابر با ۰/۹۷ و ریشه میانگین مربعات خطای برابر با ۰/۱۶ را برای مدل حاصل گزارش کردند. تاماری و همکاران (۱۹۹۶) از ۶۰۰ نمونه خاک در مدل‌سازی با شبکه‌های عصبی مصنوعی برای برآورد هدایت هیدرولیکی خاک استفاده نمودند و نتیجه گرفتند که این مدل‌ها تخمین دقیق‌تری نسبت به سایر روش‌های مدل‌سازی ارائه می‌کنند. اسخاپ و لیچ (۱۹۹۸) گزارش کردند که شبکه‌های عصبی مصنوعی به دلیل ریشه میانگین مربعات خطای (RMSE) کمتر، روش قابل قبولی برای مدل‌سازی هدایت هیدرولیکی اشباع و منحنی رطوبتی هستند. آنها در تحقیق خود از ۳۱۵ نمونه هدایت هیدرولیکی اشباع استفاده کردند. نتایج مشابهی توسط بوما (۱۹۸۹) گزارش شده است. پاچپسکی و همکاران (۱۹۹۶) با بررسی شبکه عصبی و مدل‌های رگرسیونی بر روی ۲۳۰ نمونه خاک گزارش کردند که این مدل‌ها قادر به پیش‌بینی ظرفیت نگهداری آب در خاک می‌باشند. مع‌الوصف، مدل‌های برگرفته از شبکه عصبی مصنوعی دارای دقت بهتر و خطای کمتری در تخمین مقادیر خصوصیات هیدرولیکی هستند. مردون و همکاران (۲۰۰۶) بر اساس ۲۷۶ نمونه

که X_j متغیرهای ورودی، W_{jk} وزن و S_K مجموع ضرب متغیرهای ورودی در وزن‌ها هستند. سپس خروجی S_K از یک تابع سیگموئیدی به شکل رابطه زیر عبور می‌کند:

$$H_K = \frac{1}{1 + \exp^{-S_K}} \quad (2)$$

که S_K مجموع ضرب متغیرهای ورودی در وزن‌ها و H_K خروجی تابع سیگموئیدی هستند. نرون‌های لایه خروجی (L) نیز مانند نرون‌های لایه پنهان عمل کرده و مقادیر H_K را در W_{KL} ضرب می‌کنند (معادله ۳) و از تابع سیگموئیدی عبور می‌دهند و در نهایت خروجی Y به دست می‌آید که در حقیقت مقدار تخمین زده شده پارامتر خروجی است و روابط ریاضی آن به شکل زیر می‌باشد:

$$Z_L = \sum_{K=0}^K (W_{KL} \times H_K) \quad (3)$$

$$Y = \frac{1}{1 + \exp^{-Z_L}} \quad (4)$$

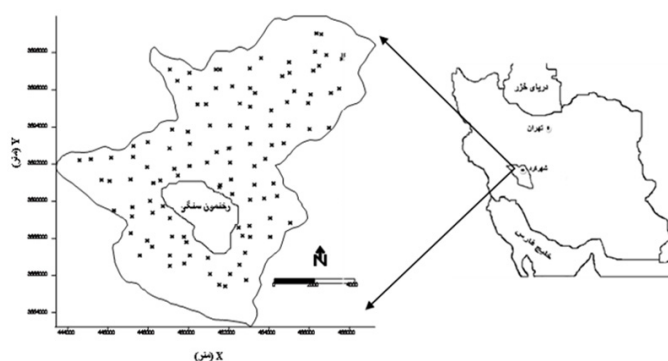
پس از تقسیم تصادفی داده‌ها، ۸۶ داده به عنوان داده‌های آموزشی و ۲۵ داده به عنوان داده‌های ارزیابی مورد استفاده قرار گرفتند. مدل‌سازی شبکه‌های عصبی مصنوعی توسط نرم‌افزار Professional II/Plus Neural Works صورت گرفت. با استفاده از روش آزمون و خطا تعداد لایه‌های پنهان شبکه و تعداد نرون‌های این لایه‌ها تعیین گردید. تابع فعال شبکه عصبی به صورت سیگموئیدی، قانون آموزش دلتا و الگوریتم آموزشی پس انتشار خطا همراه با تعداد نرون‌های لایه ورودی و خروجی شبکه برابر با تعداد پارامترهای ورودی و خروجی در نظر گرفته شد. در این تحقیق از چهار مدل شبکه عصبی مصنوعی شامل (الف) مدل ANN1 که در آن متغیرهای ورودی عبارت از شن، سیلت و رس است، (ب) مدل ANN2 با متغیرهای ورودی شامل شن، رس و جرم مخصوص ظاهری، (ج) مدل ANN3 که متغیرهای ورودی آن شامل شن، رس و ماده آلی و (د) مدل ANN4 با متغیرهای ورودی شن، رس، ماده آلی و جرم مخصوص ظاهری مورد استفاده قرار گرفتند.

۲-۳- رگرسیون خطی چندگانه


قبل از ورود پارامترهای فراوانی نسبی ذرات و جرم مخصوص ظاهری خاک به عنوان ورودی‌ها (متغیرهای مستقل) و هدایت هیدرولیکی اشباع به عنوان خروجی (متغیر وابسته) در مدل، همه آنها تحت آزمون نرمال بودن قرار گرفتند. این کار با استفاده از آزمون کولموگروف-اسمیرنوف انجام گرفت. در بین متغیرها، مقادیر هدایت هیدرولیکی اشباع انحراف از حالت نرمال داشته و لذا با استفاده از تبدیل لگاریتم پایه طبیعی به توزیع نزدیک به نرمال تبدیل شدند. مدل‌سازی رگرسیون آماری چندگانه به روش گام به گام پیش‌رونده و با استفاده از نرم‌افزار Statistica، 6.0 انجام شد.

۲-۴- ارزیابی کارایی مدل‌ها

شده است که اصطلاحاً به آن شبکه عصبی پروسپترون گفته می‌شود. ساختار شبکه عصبی مصنوعی پروسپترون با یک لایه پنهان، چهار ورودی، یک خروجی و چهار نرون در لایه پنهان در شکل ۲ نشان داده شده است. هر یک از لایه‌ها می‌توانند از تعدادی نرون تشکیل شده باشند که هر نرون به کلیه نرون‌های لایه دیگر متصل است (Leij and ۱۹۹۸, ۲۰۰۰). نرون‌های لایه ورودی مکان قرار گرفتن پارامترهای ورودی هستند. تعداد نرون‌های لایه ورودی و خروجی برابر با تعداد پارامترهای ورودی و خروجی مدل است. نرون‌های لایه پنهان نیز با توجه به پیچیدگی مدل و پارامترهای خروجی، توسط طراح انتخاب می‌شود (Persson, Sivakumar, Berndtsson, Jacobsen, and Schjonning, ۲۰۰۲).



شکل (۱) موقعیت محل مورد مطالعه و نقاط نمونه‌برداری



شکل (۲) ساختار شبکه عصبی مصنوعی پروسپترون برای چهار متغیر ورودی، یک خروجی و چهار نرون در لایه پنهان

نحوه عمل شبکه عصبی پروسپترون به این صورت است که ابتدا هر یک از نرون‌های لایه ورودی (j) با متغیرهای ورودی x_1, x_2, \dots, x_j به وسیله اتصالات سازگار شونده (W_{jk}) که به آن وزن می‌گویند به کلیه نرون‌های لایه پنهان (K) متصل می‌شوند. در نرون‌های لایه پنهان متغیرهای ورودی و وزن‌ها در هم ضرب شده و با یکدیگر جمع می‌شوند:

$$S_K = \sum_{j=0}^j (W_{jK} \times x_j) \quad (1)$$

که RMSEa ریشه میانگین مربعات خطای مدلی که برای بررسی بهبود دقت سایر مدل‌ها نسبت به آن در نظر گرفته شده است و RMSEb ریشه میانگین مربعات خطای سایر مدل‌ها می‌باشند.

۳- نتایج و بحث

خلاصه آماری کل داده‌ها در جدول ۱ ارائه شده است. همانگونه که ملاحظه می‌گردد، متغیرهای فیزیکی خاک دارای دامنه نسبتاً وسیعی هستند. هدایت هیدرولیکی اشباع در منطقه مورد مطالعه دارای حداقل ۰/۱۲، حداکثر ۲/۳۵ و میانگین ۰/۷۲ cmh⁻¹ می‌باشد. هدایت هیدرولیکی اشباع تغییرپذیری زیادی (۶۹٪) در منطقه مورد مطالعه دارد.

توصیف آماری سری داده‌های آموزش و سری داده‌های ارزیابی در جدول ۲ نشان داده شده‌اند. در سری داده‌های آموزش و ارزیابی مشابه با کل داده‌ها، خصوصیات فیزیکی خاک و هدایت هیدرولیکی اشباع از دامنه نسبتاً وسیعی برخوردارند و معرف کل داده‌ها در منطقه مورد مطالعه هستند.

جدول ۳ همبستگی بین متغیرهای شن، سیلت، رس، ماده‌آلی و جرم مخصوص ظاهری با هدایت هیدرولیکی اشباع را نشان می‌دهد. همانطور که در این جدول ملاحظه می‌گردد، همبستگی بین متغیرهای شن، سیلت، رس، ماده‌آلی و جرم مخصوص ظاهری با هدایت هیدرولیکی اشباع خیلی قوی نیست. هدایت هیدرولیکی اشباع با شن و جرم مخصوص ظاهری رابطه مستقیم و با رس و ماده‌آلی رابطه معکوس دارد. قویترین همبستگی، بین هدایت هیدرولیکی اشباع با جرم مخصوص ظاهری به مقدار ۰/۴۱ است. نتایج مشابهی توسط پاراسورامن و همکاران (۲۰۰۶) گزارش شده است.

برای ارزیابی مدل‌های مختلف از سری داده‌های مستقل تحت عنوان داده‌های ارزیابی (n=۲۵) و علاوه بر ضریب تبیین (R²) از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE) و میانگین خطا (ME) استفاده شد:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)^2} \quad (5)$$

$$ME = \frac{1}{n} \sum_{i=1}^n (y_i - y_i^*) \quad (6)$$

که n تعداد مشاهدات، y_i و y_i^{*} به ترتیب مقادیر هدایت هیدرولیکی اشباع اندازه‌گیری شده و محاسبه شده در نقطه i می‌باشد. هر یک از این آماره‌ها اطلاعات متفاوتی از کارایی مدل‌ها در اختیار قرار می‌دهند. شاخص R² نشان می‌دهند که مدل چقدر از تغییرات هدایت هیدرولیکی اشباع را توجیه می‌کند. شاخص RMSE نشان‌دهنده دقت مدل برای پیش‌بینی نزدیک به واقعیت است. این آماره وزن بیشتری برای مقادیر هدایت هیدرولیکی اشباع بزرگ‌تر اختصاص می‌دهد چرا که مجذور تفاوت بین مقادیر مشاهدات و تخمین است. آماره ME میزان اختلاف مقادیر تخمین را از واقعیت تعیین می‌کند. هرگاه این آماره منفی شود نشانه بیش‌برآوردی و هرگاه مثبت شود کم‌برآوردی را نشان می‌دهد (Woston, Pachepsky, Timilin, ۱۹۹۵; Pachepsky, and Rawls and Varallyay, ۱۹۹۶). علاوه بر شاخص‌های فوق، از درصد بهبود نسبی مدل (RI) براساس ریشه میانگین مربعات خطای مدلی که برای بررسی بهبود دقت سایر مدل‌ها نسبت به آن در نظر گرفته شده است (اندیس a) نسبت به ریشه میانگین مربعات خطای سایر مدل‌ها (اندیس b) استفاده شد:

$$R = \frac{RMSE_a - RMSE_b}{RMSE_a} \times 100 \quad (7)$$

جدول (۱) توصیف آماری توزیع اندازه‌ای ذرات، جرم مخصوص ظاهری (ρ_b) و هدایت هیدرولیکی اشباع (K_s)

متغیر	میانگین	میانه	حداقل	حداکثر	انحراف استاندارد	ضریب تغییرات (%)
شن (%)	۱۹	۱۹	۲	۳۶	۸۰	۴۲
سیلت (%)	۴۴	۴۴	۲۸	۵۶	۶/۳	۱۴
رس (%)	۳۷	۳۷	۲۵	۵۱	۵/۱	۱۳
ماده‌آلی (%)	۱/۱۰	۱/۱۱	-۰/۵۶	۲/۱۳	۰/۳	۲۷
ρ _b (gcm ⁻³)	۱/۱۸	۱/۱۸	-۰/۹۹	۱/۴۱	۰/۱	۸
K _s (cmh ⁻¹)	۰/۷۲	۰/۵۹	-۰/۱۲	۲/۳۵	۰/۵	۶۹

جدول (۲) خلاصه آماری توزیع اندازه‌ای ذرات، ماده‌آلی، جرم مخصوص ظاهری (ρ_b) و هدایت هیدرولیکی اشباع (K_s) در سری داده‌های آموزش و ارزیابی

داده‌های ارزیابی (n=۲۵)				داده‌های آموزش (n=۸۶)				متغیر
ضریب تغییرات (%)	میانگین	حداکثر	حداقل	ضریب تغییرات (%)	میانگین	حداکثر	حداقل	
۴۹	۱۹	۳۴	۶	۴۰	۱۹	۳۶	۲	شن (%)
۱۶	۴۴	۵۶	۲۸	۱۴	۴۴	۵۵	۳۰	سیلت (%)
۱۴	۳۷	۴۵	۲۵	۱۴	۳۷	۵۱	۲۵	رس (%)
۲۷	۱/۱۰	۱/۸۲	۰/۵۹	۲۹	۱/۰۶	۲/۱۳	۰/۵۶	ماده‌آلی (%)
۹	۱/۱۵	۱/۳۷	۰/۹۹	۷	۱/۱۸	۱/۴۱	۱/۰۰	ρ_b (gcm ⁻³)
۶۲	۰/۶۷۵	۲/۱۲	۰/۱۷	۷۰	۰/۷۴	۲/۳۵	۰/۱۲	K_s (cmh ⁻¹)

جدول (۳) همبستگی (r) هدایت هیدرولیکی اشباع (K_s) با جرم مخصوص ظاهری (ρ_b)، توزیع اندازه‌ای ذرات و ماده‌آلی

متغیر	ρ_b (gcm ⁻³)	رس (%)	سیلت (%)	شن (%)	ماده‌آلی (%)
K_s (cmh ⁻¹)	۰/۴۱**	-۰/۳۲**	۰/۰۲	۰/۲۱*	-۰/۲۰*
ρ_b (gcm ⁻³)	۱	-۰/۴۲**	-۰/۲۸**	۰/۴۹**	-۰/۳۲**
رس (%)	۱	۱	-۰/۰۴	-۰/۶۱**	۰/۱۳
سیلت (%)	۱	۱	۱	-۰/۷۷**	۰/۰۱
شن (%)	۱	۱	۱	۱	-۰/۱۳
ماده‌آلی (%)	۱	۱	۱	۱	۱

رگرسیون آماری هدایت هیدرولیکی اشباع گزارش کردند و علت پایین بودن آن را تغییرپذیری مکانی زیاد هدایت هیدرولیکی اشباع و خطای ناشی از آن در مدل‌سازی دانستند. مردون و همکاران (۲۰۰۶) مدل رگرسیون آماری با ضریب تبیین ۰/۵۱ برای تخمین هدایت هیدرولیکی اشباع بدست آوردند.

نتیجه آنالیز رگرسیون خطی چندگانه در جدول ۴ نشان داده شده است. مقدار R2 نسبتاً پایین این مدل را می‌توان به مقدار همبستگی پایین متغیرهای مستقل با هدایت هیدرولیکی اشباع و همچنین تغییرپذیری مکانی زیاد این خصوصیت هیدرولیکی خاک ارتباط داد. وستن و همکاران (۲۰۰۱) مقدار ضریب تبیین ۰/۱۹ برای مدل

جدول (۴) ضریب متغیرها و مقدار ضریب تبیین (R2) در مدل رگرسیون خطی چندگانه


مدل	ضرایب	R ²
$\ln K_s (\ln \text{cmh}^{-1}) = a_1 + a_2 \rho_b (\text{gcm}^{-3})$	$a_1 = -۲/۹۴**$ $a_2 = ۲/۴۲**$	۰/۴۱۶

** معنی‌دار در سطح ۱٪، $\ln K_s$ لگاریتم پایه طبیعی هدایت هیدرولیکی اشباع و ρ_b جرم مخصوص ظاهری هستند.

تعداد نرون‌ها در لایه پنهان هر مدل با سعی و خطا تعیین شد. مقادیر خطای پیش‌بینی در مقابل تعداد نرون‌ها در لایه پنهان برای هر مدل در شکل ۳ نشان داده شده است. بر این اساس در مدل ANN1 ۳ نرون، مدل ANN2 ۴ نرون، مدل ANN3 ۵ نرون و در مدل ANN4 ۴ نرون در نظر گرفته شد. همانگونه که شکل نشان می‌دهد وارد کردن متغیرهای ورودی شن، رس، ماده‌آلی و جرم مخصوص ظاهری در مدل چهارم (ANN4) باعث کاهش خطا در مدل‌سازی با شبکه عصبی مصنوعی شد.

نتایج حاصل از محاسبه شاخص‌های ارزیابی هر دو روش رگرسیون

تعداد نرون‌ها در لایه پنهان هر مدل با سعی و خطا تعیین شد. مقادیر خطای پیش‌بینی در مقابل تعداد نرون‌ها در لایه پنهان برای هر مدل در شکل ۳ نشان داده شده است. بر این اساس در مدل ANN1 ۳ نرون، مدل ANN2 ۴ نرون، مدل ANN3 ۵ نرون و در مدل ANN4 ۴ نرون در نظر گرفته شد. همانگونه که شکل نشان می‌دهد وارد کردن متغیرهای ورودی شن، رس، ماده‌آلی و جرم مخصوص ظاهری در مدل چهارم (ANN4) باعث کاهش خطا در مدل‌سازی با شبکه عصبی مصنوعی شد.



شکل (۳) مقادیر ریشه میانگین مربعات خطا در مقابل تعداد نرون‌ها در چهار مدل شبکه عصبی مصنوعی

شده و حفرات مربوط به جانوران خاک مقادیر بزرگ‌تری در مقایسه با خاک‌های متراکم دارد. در عمل نیز نفوذ آب در خاک به دلیل وجود هوای حبس شده با مشکل مواجه می‌شود (Hillel ۱۹۹۸). تاماری و همکاران (۱۹۹۶) مقادیر هدایت هیدرولیکی را در مکش‌های ۱۰- و ۲۵- کیلوپاسکال با دو روش شبکه عصبی و رگرسیون برآورد کردند، آنها برآوردهای مناسبی به دست نیاوردند و پیشنهاد کردند که بهتر است نمونه‌ها از خاک‌هایی که براساس بافت به سه دسته درشت، متوسط و ریز طبقه‌بندی شده‌اند، تهیه گردد. بنابراین، مشکلات در اندازه‌گیری هدایت هیدرولیکی اشباع خاک بخصوص در خاک‌های ناهمگن منجر به برآوردهای نامناسب در تحقیقات شده است. شاید بتوان با استفاده از فاکتورهای ورودی بیشتر برآوردهای بهتری به دست آورد (Tamari, Wosten, and Ruz-suarez ۱۹۹۶; Merdun, Meral, and Apan ۲۰۰۶).

مقادیر ME نشان می‌دهد که کلیه مدل‌ها، هدایت هیدرولیکی اشباع را نسبت به مقدار واقعی، بیشتر برآورد کرده‌اند. مدل ANN4 در بین همه مدل‌ها حداقل بیش‌برآوردی را دارد. بیشترین تفاوت بین مقادیر مشاهدات و برآوردی در بین مدل‌ها متعلق به رگرسیون خطی چندگانه

خطی چندگانه و شبکه عصبی مصنوعی در جدول ۵ نشان داده شده است. همانطور که در جدول ملاحظه می‌گردد، هر چهار مدل شبکه عصبی مصنوعی دارای شاخص R^2 بالاتری نسبت به مدل رگرسیون خطی چندگانه هستند. مقایسه مدل‌های شبکه عصبی مصنوعی نشان داد، مدل ANN4 که از ورودی‌های شن، رس، ماده‌آلی و جرم مخصوص ظاهری در برآورد هدایت هیدرولیکی اشباع استفاده شده است، دارای مقدار R^2 بالاتری (۰/۶۴۲) می‌باشد و بعد از آن مدل ANN2 که از ورودی‌های شن، رس و جرم مخصوص ظاهری در برآورد هدایت هیدرولیکی اشباع استفاده شده است، قرار دارد. نتایج مشابهی توسط دعایی و همکاران (۱۳۸۴) گزارش شده است. مردون و همکاران (۲۰۰۶) نیز ضریب تبیین ۰/۵۱ را برای مدل‌سازی هدایت هیدرولیکی اشباع با استفاده از شبکه عصبی مصنوعی گزارش کردند. دلیل اینکه این مدل‌ها ۳۰-۴۰ درصد تغییرات هدایت هیدرولیکی اشباع در منطقه مورد مطالعه را توجیه نمی‌کنند، می‌تواند به علت تغییرات مکانی زیاد هدایت هیدرولیکی اشباع و تأثیرپذیری شدید این خصوصیت هیدرولیکی از بافت و ساختمان خاک باشد. این خصوصیت در برخی مناطق دارای درز و ترک، کانال‌های نفوذ ریشه‌های پوسیده

وزن‌دهی به کل داده‌های ورودی، مدل‌سازی انجام می‌گیرد. تقریباً نزدیک به مقدار RMSE به‌دست آمده در تحقیق حاضر توسط پاراسورامن و همکاران (۲۰۰۶) گزارش شده است. آنها در دو منطقه جداگانه، در مدل‌سازی شده با شبکه عصبی مصنوعی مقدار RMSE ۰/۱۹ به دست آوردند.

محاسبه درصد بهبود نسبی مدل‌های شبکه عصبی مصنوعی نسبت به مدل رگرسیونی خطی چندگانه نشان می‌دهد که مدل ANN4 درصد بهبود نسبی بیشتری در مقایسه با سایر مدل‌ها نسبت به مدل رگرسیونی داشته است. نمودار پراکنش داده‌های پیش‌بینی در مقابل مشاهدات برای بهترین مدل در این تحقیق در شکل ۴ نشان داده شده است.


است. مردون و همکاران (۲۰۰۶) به نتیجه مشابه با تحقیق حاضر رسیدند. آنها گزارش کردند که در مدل‌سازی با شبکه عصبی مصنوعی و رگرسیون خطی چندگانه بیش‌برآوردی با مقادیر به ترتیب، ۰/۲۳- و ۰/۱۲- وجود دارد. پاراسورامن و همکاران (۲۰۰۶) در مدل‌سازی با شبکه عصبی مصنوعی مشابه با نتایج تحقیق حاضر و بر اساس آماره ME با مقدار ۰/۰۷- به بیش‌برآوردی در مدل‌سازی دست یافتند. کمترین RMSE در بین همه مدل‌ها متعلق به مدل ANN4 است و بعد از آن مدل ANN2 قرار دارد. مقدار RMSE مدل رگرسیونی (۰/۵۵) تقریباً دو برابر مدل‌سازی با شبکه عصبی مصنوعی است. دلیل آن را می‌توان اینگونه توجیه نمودند که در آنالیز رگرسیونی خصوصیات خروجی به صورت یک به یک با استفاده از داده‌های ورودی به‌دست می‌آیند در حالی که در شبکه عصبی مصنوعی بر اساس

جدول (۵) شاخص‌های ارزیابی مدل‌ها شامل ضریب تبیین (R^2)، میانگین خطا (ME)، ریشه میانگین مربعات خطا (RMSE) و درصد بهبود نسبی مدل (RI%)

مدل	R^2	ME	RMSE	RI%
ANN ₁	۰/۵۸۹	-۰/۱۱۵	۰/۲۵	۵۴
ANN ₂	۰/۶۱۰	-۰/۰۷۶	۰/۲۲	۵۹
ANN ₃	۰/۶۰۱	-۰/۱۰۶	۰/۲۳	۵۷
ANN ₄	۰/۶۴۲	-۰/۰۴۳	۰/۲۰	۶۳
رگرسیون آماری	۰/۴۱۶	۰/۲۹۵	۰/۵۵	۰

۴- نتیجه گیری

در این تحقیق به ارزیابی توابع انتقالی برای تخمین هدایت هیدرولیکی اشباع در مقیاس حوزه آبخیز پرداخته شد. در بین مدل‌ها، مدل شبکه عصبی مصنوعی با متغیرهای ورودی شن، رس، جرم مخصوص ظاهری و ماده آلی (ANN4) با ۴ نرون در لایه پنهان توانست هدایت هیدرولیکی اشباع را بهتر از سایر مدل‌ها برآورد کند. بهبود نسبی این مدل نسبت به مدل رگرسیونی ۶۳٪ است. بطور کلی، مدل‌های شبکه عصبی مصنوعی دارای قابلیت تشخیص روابط غیرخطی بین متغیرها بوده و به نظر می‌آید که بخش زیادی از موفقیت‌های مدل‌های شبکه عصبی مصنوعی در این تحقیق ناشی از همین قابلیت و توانایی باشد. با توجه به نتایج حاصله و بررسی‌های قبلی علیرغم سادگی کار با مدل‌های رگرسیون آماری، مدل‌های شبکه عصبی مصنوعی، هدایت هیدرولیکی اشباع خاک را با دقت بیشتری نسبت به مدل‌های



شکل (۴) مقادیر اندازه‌گیری در برابر مقادیر برآورد شده هدایت هیدرولیکی اشباع توسط مدل شبکه عصبی مصنوعی ANN4

retention curve. *Geoderma*, 253-93:225.

12) Minansy, B. and McBratney, A.B., (2002). The Neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci. Soc. Am. J.*, -352 :66 361.

13) Mohammadi, J. (2002). Testing an artificial neural network for predicting soil water retention characteristics from soil physical and chemical properties. 17th WCSS. Thailand. Paper No. 221.

14) Nelson, D.W. and Sommers, L.P. (1986). Total carbon, organic carbon and organic matter. *Methods of Soil Analysis*, part 2, pp. 579-539. *Agronomy Handbook No 9*, American Society of Agronomy and Soil Science Society of America, Madison, WI.

15) Pachepsky, Y.A., Timilin, D. and Varallyay, G. (1996). Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Sci. Soc. Am. J.*, 733-727 :60.

16) Parasuraman, K., Elshorbagy, A. and Bing-Chenge. (2006). Estimating saturated hydraulic conductivity in spatially variable field using neural network ensemble. *Soil sci. Soc. Am. J.*, 1859-1851 :70.

17) Persson, M., Sivakumar, B., Berndtsson, R., Jacobsen, O.H. and Schjonning, P. (2002). Predicting the di-electric constant-water content relationship using artificial neural network. *Soil Sci. Soc. Am. J.*, :66 1439-1427.

18) Romano, N. and Palladino, M. (2002). Prediction of soil water retention using soil physical data and terrain attributes. *J. Hydrology*, 75-265:56.

19) Schaap, M.G. and Leij, F.J. (1998). Using neural networks to predict soil water retention soil hydraulic conductivity. *Soil and Tillage Res.*, 42-37 :47.

20) Schaap, M.G. and Leij, F.J. (2000). Improved prediction of unsaturated hydraulic conductivity with the Mualem-Van Genuchten model. *Soil Sci. Soc. Am. J.*, 851-843 :64.

21) Tamari, S., W sten, J.H.M. and Ruz-suarez, J.C. (1996). Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Sci. Soc. Am. J.*, 1741-1732 :60.

22) W ston, J.H.M., Finke, P.A. and Jansen, M.J.W. (1995). Comparison of class and Continuous pedotransfer functions to generate soil hydraulic characteristics. *Geoderma*, 237-227 :66.

رگرسیون آماری برآورد می‌کنند.

۵- منابع مورد استفاده

۱) دعایی، م.، شعبانپور شهرستانی، م. و باقری، ف. (۱۳۸۴). مدل‌سازی ضریب آب‌گذری اشباع در خاک‌های رسی استان گیلان به وسیله شبکه عصبی مصنوعی. پژوهش‌نامه علوم کشاورزی. ج ۱، ش ۶. ص ۴۷-۴۱.

۲) نوابیان، م.، لیاقت، ع. و همایی، م. (۱۳۸۲). تعیین هدایت هیدرولیکی اشباع خاک با استفاده از توابع انتقالی. *مجله تحقیقات مهندسی کشاورزی*. ۴ (۱۶): ۱۲-۱.

3) Ahuja, L.R., Cassel, D.D., Bruce, R.R. and Barnes, B.B. (1989). Evaluation of spatial distribution of hydraulic conductivity using effective posing data. *Soil Sci.*, 411-404 :148.

4) Amini, M., Abbaspour, K.C., Khademi, H., Fathianpour, N., Afyuni, M. and Schulin R. (2005). Neural network models to predict cation exchange capacity in arid regions of Iran. *Eur. J. Soil Sci.*, -551 :56 559.

5) Bouma, J. (1989). Using soil survey data for quantitative land evaluation. *Advance Soil Sci.*, -177 9 213.

6) Gee, G.W. and Bauder, J.W. (1986). Particle size analysis. In: A. Klute (Ed.), *Methods of Soil Analysis. Part 2*. 1st edition. *Agron. Monogr. 9*. ASA and SSSA, Madison, WI. Pp. 407-404.

7) Givi, J., Prasher, S.O. and Patel, R.M. (2004). Evaluation of Pedotransfer functions in predicting the soil water contents at field capacity and wilting point. *Agricultural Water Management*, 96-83 :70.

8) Hillel, D. (1998). *Environmental soil physics*. Academic Press, New York. USA.

9) Klute, A., and Dirksen, C. (1986) Hydraulic conductivity and diffusivity: laboratory methods. In: A. Klute (Ed.), *Methods of Soil Analysis. Part 2*. 1st edition. *Agron. Monogr. 9*. ASA and SSSA, Madison, WI. Pp. 734-687.

10) Merdun, H., Meral, O.C. and Apan, R.M. (2006). Comparison of artificial neural network and regression Pedotransfer functions for predict of water retention and saturated hydraulic conductivity. *Soil and Tillage Res.*, 116-108 :90.

11) Minansy, B., McBatney, A.B. and Bistow, K.L. (1999). Comparison of different approaches to the development of Pedotransfer functions for water

between available basic soil data and missing soil hydraulic characteristics. J. Hydrology, 150-123 :251.

23) W ston, J.H.M., Pachepsky, Y.A. and Rawls, W.J. (2001). Pedotransfer functions: bridging the gap

■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■