



"مقاله پژوهشی"

مقایسه و کاربرد شبکه عصبی مصنوعی، ماشین بردار پشتیبان و درخت تصمیم در پیش‌بینی هدایت هیدرولیکی اشباع خاک (مطالعه موردی: شهرستان هیرمند)

ایمان بیژن^۱، حلیمه پیری^۲، محمود طباطبایی^۳ و جمشید پیری^۴

۱- دانشجوی کارشناسی ارشد دانشگاه زابل
۲- استادیار دانشگاه زابل، (نویسنده مسوول: h_piri2880@uoz.ac.ir)
۳- استادیار دانشگاه زابل
۴- مربی دانشگاه زابل
تاریخ دریافت: ۱۳۹۹/۷/۲ تاریخ پذیرش: ۱۳۹۹/۹/۲۵
صفحه: ۷۴ تا ۸۵

چکیده مبسوط

مقدمه و هدف: اندازه‌گیری مستقیم هدایت هیدرولیکی خاک وقت‌گیر و پرهزینه بوده و گاهی اوقات به دلیل خطاهای آزمایشی و عدم یکنواختی خاک نتایج بدست آمده چندان قابل اعتماد نمی‌باشد. این پارامتر را می‌توان با استفاده از پارامترهای زود یافت خاک برآورد کرد. تحقیق حاضر به منظور پیش‌بینی هدایت هیدرولیکی اشباع خاک با استفاده از روش‌های درخت تصمیم، ماشین بردار پشتیبان و شبکه عصبی مصنوعی در شهرستان هیرمند انجام گرفت.
مواد و روش‌ها: برای این منظور، تعداد ۱۳۰ نمونه خاک از سطح (۳۰-۰ سانتی‌متری) جمع‌آوری و برای انجام آزمایش و آنالیزها، به آزمایشگاه انتقال داده شد. در آزمایشگاه پارامترهای هدایت هیدرولیکی اشباع خاک، درصد رس، شن و سیلت، ماده آلی، اسیدیته، هدایت الکتریکی و کرنات کلسیم اندازه‌گیری شد. سپس با استفاده از پارامترهای اندازه‌گیری شده و با استفاده از مدل‌های درخت تصمیم، شبکه عصبی مصنوعی و ماشین بردار پشتیبان هدایت هیدرولیکی اشباع برآورد شد. به منظور ارزیابی مدل‌ها از معیارهای ضریب تبیین، مجذور میانگین مربعات خطا و خطای مطلق میانگین استفاده شد.
یافته‌ها: نتایج نشان داد که مدل درخت تصمیم با دارا بودن بالاترین ضریب تبیین (۰/۸۳) و کمترین مقدار میانگین مربعات خطا و خطای مطلق میانگین (۰/۰۰۲۶ و ۰/۰۰۱۹) بهترین مدل برای پیش‌بینی هدایت هیدرولیکی اشباع خاک در منطقه هیرمند می‌باشد. همچنین نتایج آنالیز حساسیت داده‌ها با استفاده از مدل شبکه عصبی مصنوعی نشان داد که درصد شن، درصد آهک، درصد سیلت و اسیدیته به ترتیب مهمترین فاکتورهای موثر بر هدایت هیدرولیکی اشباع خاک در شهرستان هیرمند می‌باشند.

نتیجه‌گیری: نتایج حاصل بیانگر عملکرد بسیار مطلوب روش‌های هوش مصنوعی در پیش‌بینی هدایت هیدرولیکی اشباع خاک می‌باشد. در شرایطی که امکان اندازه‌گیری هدایت هیدرولیکی امکان‌پذیر نباشد، می‌توان با استفاده از پارامترهای زود یافت خاک و روش‌های هوش مصنوعی، هدایت هیدرولیکی را تخمین زد.

واژه‌های کلیدی: بار ثابت، ویژگی‌های زود یافت خاک، هوش مصنوعی

مقدمه

برخی از قوانین و پدیده‌های حاکم در محیط متخلخل خاک که در شاخه‌های مختلف علوم خاک مورد تحلیل و بررسی قرار می‌گیرد، به خصوصیات این محیط دینامیک و پویا باز می‌گردد. از مهم‌ترین خصوصیات خاک، می‌توان به هدایت هیدرولیکی اشباع اشاره نمود. اکثر مدل‌های شبیه‌ساز حرکت آب و انتقال املاح، این خصوصیات را به عنوان ورودی‌های مورد نیاز خود دریافت می‌نمایند. هدایت هیدرولیکی اشباع یکی از مهم‌ترین ویژگی‌های فیزیکی خاک است که در تعیین سرعت نفوذ، فواصل و طراحی زهکش‌ها، ارزیابی جریان آب زیرزمینی و دیگر فرآیندهای هیدرولوژیکی موثر است. همچنین تعیین هدایت هیدرولیکی خاک به منظور تعیین میزان رواناب خروجی از حوضه‌های آبخیز ضروری است. برای اندازه‌گیری هدایت هیدرولیکی اشباع، روش‌های مختلف آزمایشگاهی و مزرعه‌ای وجود دارند که روش‌های آزمایشگاهی برای پژوهش مناسب‌ترند و روش‌های مزرعه‌ای بیش‌تر برای پروژه‌های زهکشی به کار می‌روند. با وجود تلاش‌های فراوانی که برای اندازه‌گیری هدایت هیدرولیکی اشباع انجام می‌گیرد عواملی هستند که باعث ایجاد خطا در اندازه‌گیری این ویژگی می‌شوند (۲۶). اندازه‌گیری مستقیم هدایت هیدرولیکی اشباع به طور معمول با صرف زمان و

هزینه زیاد همراه است و از طرف دیگر این پارامتر دارای تغییرات زمانی و مکانی قابل توجهی بوده و به روش اندازه‌گیری نیز بستگی دارد. لذا بایستی برای تخمین دقیق این نوع ویژگی‌ها به دنبال راه‌حل‌های مناسب، ساده و کم هزینه بود. به همین منظور استفاده از روش‌های تخمین غیرمستقیم مورد توجه قرار گرفته است. روش غیرمستقیم به دست آوردن داده‌های دیر یافت خاک، استفاده از توابع انتقالی می‌باشد (۵). به دلیل این که توابع انتقالی خصوصیات دیر یافت خاک را با استفاده از خصوصیات زود یافت آن برآورد می‌کنند، باعث صرفه‌جویی در وقت و هزینه می‌شوند (۳۴). اکثر توابع انتقالی برای تخمین خصوصیات هیدرولیکی خاک، از داده‌های پایه‌ای خاک چون بافت خاک، جرم مخصوص ظاهری و یا میزان ماده آلی استفاده می‌کنند (۱۱). این توابع ویژگی‌های زود یافت را به ویژگی‌های دیر یافت مربوط می‌کنند (۱). اگرچه روش‌های آماری متعارف برای توسعه توابع انتقالی مانند روش‌های رگرسیونی وجود دارد، اما در سال‌های اخیر تکنیک‌های مدل‌سازی مبتنی بر هوش مصنوعی مانند شبکه‌های عصبی مصنوعی (ANN) به خاطر قابلیت بالای پیش‌بینی و ویژگی‌های غیرخطی محبوبیت زیادی را به عنوان یک ابزار آماری مناسب در مدل‌سازی مسائل متنوع زیست محیطی توسعه یافته‌اند. فرزاد مهر و همکاران (۷) برای


شبکه عصبی مصنوعی پرسپترون چند لایه و به کمک بافت خاک هدایت هیدرولیکی اشباع خاک را برآورد کردند. نتیجه مطالعه نشان داد مدل منطق فازی توانایی بالاتری برای پیش بینی دارد. نجیب زاده و همکاران (۲۰) از روش های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی در مدل سازی بارش رواناب حوزه آبریز سد صفارود استفاده کردند. نتایج حاکی از عملکرد مناسب شبکه عصبی مصنوعی و بردار پشتیبان در مدل سازی بارش رواناب در حوزه مطالعاتی بود. حسینی صومعه و همکاران (۱۳) از هوش مصنوعی برای مدل سازی سطح آب زیرزمینی دشت زاوه ترتب حیدریه استفاده کردند. نتیجه مطالعه آن ها نشان داد شبکه عصبی مصنوعی توانایی بالایی در پیش بینی تراز سطح آب زیرزمینی دارد. آخونی پور حسینی و دربندی (۳) رواناب رودخانه صوفی چای از ماشین بردار پشتیبان و شبکه عصبی مصنوعی استفاده کردند و نتیجه گرفتند ماشین برار پشتیبان کارایی بالاتری نسبت به شبکه عصبی مصنوعی دارد.

همان طور که ملاحظه شد در تحقیقات انجام شده از روش های مختلف هوش مصنوعی برای پیش بینی هدایت هیدرولیکی اشباع خاک استفاده شد. بیشتر تحقیقات انجام شده برآورد را با بافت خاک و چگالی ظاهری انجام داده اند و از روش درخت تصمیم و یا رگرسیون جهت برآورد استفاده کردند. در این تحقیق هدف برآورد هدایت هیدرولیکی اشباع خاک با استفاده از روش های درخت تصمیم، شبکه عصبی مصنوعی و ماشین بردار پشتیبان و به کمک داده های زود یافت خاک همچون بافت خاک، درصد مواد آلی، هدایت الکتریکی و اسیدیته خاک می باشد.

مواد و روش ها

منطقه مورد مطالعه شهرستان هیرمند واقع در شمال استان سیستان و بلوچستان در جنوب شرقی ایران به مختصات طول جغرافیایی ۶۱ درجه و ۴۵ دقیقه تا ۶۱ درجه و ۳۰ دقیقه طول شرقی و ۳۱ درجه تا ۳۱ درجه و سی دقیقه عرض شمالی قرار دارد. منطقه مطالعاتی دارای اقلیم گرم و خشک بوده، میزان بارندگی آن در سال کمتر از ۶۰ میلی متر و ارتفاع آن از سطح دریا ۴۸۰ متر می باشد. برای انجام کار تعداد ۱۳۰ نمونه خاک از عمق ۳۰-۰ سانتی متری خاک بر اساس شبکه بندی منظم با ابعاد ۱۵۰۰×۱۵۰۰ متر برداشت شد. شکل (۱) موقعیت منطقه مورد مطالعه و نقاط نمونه برداری شده را نشان می دهد.

پیش بینی هدایت هیدرولیکی اشباع خاک از مدل های درخت تصمیم و یادگیری بر پایه نمونه استفاده کردند. آن ها برای تعیین مهم ترین پارامترها در پیش بینی و مدل سازی هدایت هیدرولیکی اشباع، از آزمون گاما استفاده کردند. ترکیب بهینه ای که از آزمون گاما به دست آمد، برای مدل سازی هر دو روش استفاده شد. این ترکیب شامل پارامترهای درصد شن، سیلت، رس، درصد مواد خنثی شونده، هدایت الکتریکی و جرم مخصوص ظاهری خاک بود. مدل درخت تصمیم پارامتر جرم مخصوص ظاهری خاک را به عنوان مهم ترین متغیر دسته بندی کننده انتخاب کرد و سه رابطه خطی برای برآورد هدایت هیدرولیکی اشباع با توجه به مقدار جرم مخصوص ظاهری ایجاد کرد. نوروزیان عزیز و همکاران (۲۴) از مدل رگرسیون و شبکه عصبی مصنوعی برای برآورد هدایت هیدرولیکی اشباع خاک های مازندران استفاده کردند. نتایج مطالعه آن ها نشان داد شبکه عصبی پرسپترون با دو لایه مخفی روش کارآمدی برای تعیین هدایت هیدرولیکی اشباع در منطقه می باشد. خاشعی سیوکی و همکاران با استفاده از داده های زود یافت خاک و سیستم های شبکه عصبی مصنوعی هدایت هیدرولیکی اشباع خاک را پیش بینی کردند و بیان داشتند سیستم توانایی خوبی در پیش بینی هدایت هیدرولیکی اشباع خاک دارد (۱۶). مونکادا و همکاران (۱۹) مدل های درخت تصمیم را برای ارزیابی کیفیت خاک و تخمین هدایت هیدرولیکی اشباع در دو خاک گرمسیری و معتدل استفاده کردند. آن ها از خصوصیات مورفولوژیکی خاک علاوه بر خصوصیات شیمیایی و فیزیکی آن استفاده کردند و مشاهده کردند که کاربرد خصوصیات مورفولوژیکی در کنار سایر خصوصیات خاک باعث بهبود تخمین هدایت هیدرولیکی اشباع می شود و درختی با یک ساختار ساده تر ایجاد می شود. احمدی و همکاران (۲) از مدل های برنامه ریزی بیان ژن و رگرسیون ریج برای پیش بینی هدایت هیدرولیکی اشباع خاک های آذربایجان شرقی استفاده کردند. نتایج مطالعه آن ها نشان داد که تابع انتقالی ارائه شده با روش برنامه ریزی بیان ژنی از دقت و صحت بیشتری نسبت به مدل رگرسیونی برخوردار می باشد. نوروزی قوش بلاغ و همکاران (۲۵) قابلیت انتقال آبخوان دشت ملکان را با استفاده از شبکه عصبی مصنوعی، منطق فازی و جنگل تصادفی برآورد کردند. بر اساس نتایج آن ها از بین مدل های بررسی شده، مدل جنگل تصادفی دقت و توانایی بیشتری در شبیه سازی داشته است. حسینی و صدقی (۱۲) با استفاده از دو مدل منطق فازی و



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه در کشور، استان و شهرستان و نقاط نمونه‌برداری
Figure 1. Geographical location of the study area in the country, province and city and sampling points

خروجی‌های مشاهده‌ای، استفاده می‌گردد. از داده‌های صحت‌سنجی به‌منظور کنترل و نظارت بر یادگیری صحیح شبکه استفاده می‌شود و از داده‌های آزمون برای ارزیابی عملکرد شبکه پیشنهادی استفاده می‌شود. در این پژوهش برای مدل شبکه عصبی (ANN) و مدل درخت تصمیم (M5) 60، 20 و 20 درصد کل داده‌ها، به‌ترتیب برای آموزش، اعتبارسنجی و آزمون مدل و برای مدل ماشین بردار پشتیبان (SVM) 60 و 40 درصد کل داده‌ها به‌ترتیب برای آموزش و آزمون مدل اختصاص یافت.

شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی به‌منظور طراحی و آموزش نیازمند یک سری داده‌های ورودی و خروجی می‌باشند تا با تجزیه و تحلیل منطقی که بین این داده‌ها به‌عنوان نمونه صورت می‌گیرد، بتواند روابط غیرخطی آن‌ها را استخراج نموده و کار شبیه‌سازی را برای موارد احتمالی مشابه انجام دهد. در این تحقیق پارامترهای زود یافت خاک شامل (بافت، pH، EC، درصد آهک و ماده آلی) به‌عنوان ورودی‌های مدل و هدایت هیدرولیکی اشباع خاک به‌عنوان خروجی در نظر گرفته شدند. به‌منظور آموزش شبکه‌ی عصبی، شبکه پرسپترون چند لایه مورد استفاده قرار گرفت. فرایند آموزش که شامل تغییر وزن‌ها بین لایه‌های مختلف در طول زمان آموزش است، انجام گردید تا جایی که تفاوت بین داده‌های واقعی (برای داده‌های آزمون) و داده‌های پیش‌بینی شده به حداقل برسد. الگوریتم آموزشی لوبزبرگ-مارکوات و تابع سیگموئید تانژانتی هیپربولیک^۲ در لایه پنهان و تابع خطی^۳ در لایه خروجی برای فرایند آموزش به‌کار گرفته شدند. تعداد نرون‌ها در لایه پنهان به‌روش سعی و خطا تعیین شد و در نهایت بهترین ساختارهای شبکه برای برآورد هدایت هیدرولیکی اشباع خاک بر اساس بیشترین R^2 و کمترین RMSE انتخاب گردید.

درخت تصمیم

نمونه‌های برداشت شده به آزمایشگاه منتقل گردید. در آزمایشگاه نمونه‌ها هواخشک و سپس از الک ۲ میلی‌متری عبور داده شدند. در آزمایشگاه بافت خاک به روش هیدرومتری (۹)، مواد آلی به روش والکی-بلک (۲۰)، کربنات کلسیم به روش تیتراسیون با اسید (نلسون، ۱۹۸۶)، هدایت الکتریکی با استفاده از دستگاه هدایت الکتریکی سنج (۲۶)، pH خاک با pH متر (۲۹) و هدایت هیدرولیکی اشباع به روش بار ثابت اندازه‌گیری شد.

استانداردسازی داده‌ها

معمولاً وارد کردن داده‌ها به‌صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای اجتناب از چنین شرایطی و همچنین به‌منظور یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی، داده‌های ورودی به آن بایستی استاندارد شوند. این کار مانع کوچک شدن بیش از حد وزن‌ها می‌گردد (۳۰) و در عین حال با تنظیم داده‌های ورودی در یک محدوده خاص می‌توان نرون‌ها را در محدوده مطلوب قرار داده و از اشباع زود هنگام نرون‌ها جلوگیری نمود. همچنین این کار به این علت صورت می‌گیرد که داده‌ها به اعدادی بین ۰ و ۱ تبدیل گردند، زیرا خروجی اکثر توابع آستانه اعدادی ما بین ۰ و ۱ می‌باشند و شکل داده‌های ورودی به آن نقش مهمی در یادگیری شبکه ایفا می‌کند. برای استاندارد کردن داده‌ها از رابطه زیر استفاده شد (۴).

$$X_n = \frac{X - X_{\text{mean}}}{X_{\text{max}} - X_{\text{min}}} \quad (1)$$

X_n : معرف داده نرمال شده، X : معرف داده‌ی مشاهده‌ای، X_{max} و X_{min} : به‌ترتیب معرف داده‌های مشاهده‌ای میانگین، حداقل و حداکثر می‌باشند.

تقسیم‌بندی داده‌ها

مدل‌های شبکه عصبی مصنوعی جهت طراحی نیازمند سه دسته داده آموزشی، اعتبارسنجی و آزمون می‌باشند. از داده‌های آموزشی به‌منظور پیدا کردن رابطه بین ورودی‌ها و

حاشیه ابر صفحه را حاصل می‌کند، به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان گفته می‌شود و تنها از این بردارها برای مشخص کردن مرز بین طبقات استفاده می‌شود. در یک مدل رگرسیونی SVM لازم است وابستگی تابع متغیر وابسته (y) به مجموعه‌ای از متغیرهای مستقل (x) تخمین زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین f به علاوه یک مقدار اضافی نویز مشخص می‌شود:

$$y = f(x) + \text{noise} \quad (4)$$

بنابراین موضوع اصلی پیدا کردن فرم اصلی تابع f است که بتواند به صورت صحیح، موارد جدیدی را که SVM تاکنون تجربه نکرده است، پیش‌بینی کند. در روش SVM - ϵ از توابع هسته‌ای (کرنل) به منظور جداسازی صفحات و بهینه‌سازی فواصل موجود بین داده‌های مشاهداتی و تخمینی استفاده می‌شود اما در مدل V-SVM از روش برنامه‌ریزی غیرخطی برای کاهش خطای پیش‌بینی استفاده می‌شود. در این مطالعه مدل SVM - ϵ به دلیل کاربرد گسترده آن در مسائل رگرسیونی استفاده گردید. برای این مدل، تابع خطا به صورت زیر تعریف می‌شود:

$$C \sum_{i=1}^n \epsilon_i^* + C \sum_{i=1}^n \epsilon_i + \frac{1}{2} W^T W \quad (5)$$

تابع خطای مذکور لازم است که با توجه به محدودیت‌های زیر حداقل گردد:

$$W^T \phi(x_i) + b - y_i \leq \epsilon + \epsilon_i \quad (6)$$

$$y_i - W^T \phi(x_i) + b \leq \epsilon + \epsilon_i \quad (7)$$

$$\epsilon_i \times \epsilon^* \geq 0 \quad (8)$$

در این روابط C : ثابت گنجایش، W : بردار ضریب، W^T : ترانزاده بردار ضریب، ϵ^* و ϵ_i : ضرایب کمبود، b : ضریب ثابت، ϕ : الگوی آموزش مدل و ϕ : تابع کرنل است.

ماشین‌های بردار پشتیبان برای حل مسائل غیرخطی، ابعاد مسئله را از طریق توابع کرنل تغییر می‌دهند. انتخاب کرنل برای SVM به حجم داده‌های آموزشی و ابعاد بردار ویژگی بستگی دارد. به عبارت دیگر، باید با توجه به این پارامترها تابع کرنلی را انتخاب نمود که توانایی آموزش برای ورودی‌های مسئله را داشته باشد. در عمل کرنل خطی به کار برده می‌شود. (۳۱)

محاسبات مربوط به شبکه عصبی مصنوعی، درخت تصمیم و ماشین بردار پشتیبان با استفاده از نرم‌افزار Matlab 7.9 انجام شد.

معیارهای ارزیابی مدل

برای ارزیابی صحت و اعتبار مدل‌های مورد استفاده از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE)، ضریب تبیین (R^2)، و میانگین مطلق خطا (MAE) استفاده شد (روابط ۹ تا ۱۱).

$$R^2 = 1 - \sum_{i=1}^n \frac{(x_i - x_i^*)^2}{(x_i - \bar{x}_i)^2} \quad (9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x_i^*)^2} \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x_i^*| \quad (11)$$

مدل درختی زیر مجموعه‌ای از روش‌های یادگیری ماشینی و داده‌کاوی است. روش‌های یادگیری ماشینی و داده‌کاوی قابلیت کشف نیمه‌اتوماتیک الگوهای ارزشمندی از داده‌ها را دارند. در سال‌های اخیر مدل درختی تحول قابل توجهی در مسایل طبقه‌بندی و پیش‌بینی ایجاد نموده است. از جمله دلایل استفاده از مدل درختی می‌توان به این موارد اشاره کرد: (۱) مدل درختی به طور مستقیم با متغیرهای پیش‌بینی‌کننده مرتبط می‌باشد، بنابراین نتایج مدل برای فهم و شبیه‌سازی آسان هستند. (۲) درخت‌های تصمیم‌گیری غیرپارامتریک بوده و هیچ دخالتی از سوی کاربر بر روی آن‌ها صورت نمی‌گیرد. (۳) خروجی مدل از دقت بالایی برخوردار است که می‌توان آن را با سایر مدل‌ها مقایسه کرد. درخت تصمیم برای انجام پیش‌بینی، ساختاری مشابه درخت ایجاد می‌کند به این صورت که ابتدا کار خود را با استفاده از تمام نمونه‌های آموزشی شروع می‌کند و متغیری که بهترین دسته‌بندی را انجام می‌دهد، انتخاب می‌کند و زیرمجموعه‌هایی تشکیل می‌دهد. شاخه‌های درخت نتیجه آزمونی است که در هر مرحله توسط الگوریتم بر روی گره‌های میانی صورت می‌گیرد. پیش‌بینی‌ها نیز در برگ‌های درخت ظاهر می‌شود (۶). مدل درختی قابلیت پیش‌بینی متغیرهای پیوسته عددی از روی صفات عددی را دارد و نتایج پیش‌بینی شده به صورت مدل‌های رگرسیونی خطی چندمتغیره در برگ‌های درخت ظاهر می‌شود. معیار تقسیم در یک گره بر اساس انتخاب انحراف معیار مقادیر خروجی که به آن گره می‌رسند به عنوان معیار از خطا است. با آزمودن هر پارامتر در گره، کاهش مورد انتظار در خطا محاسبه می‌شود. خطای مدل عموماً با اندازه‌گیری دقت پیش‌بینی مقادیر هدف موارد دیده نشده، سنجش می‌شود (۳۳). فرمول محاسبه کاهش انحرافات (SDR) به صورت روابط زیر می‌باشد:

$$SDR = Sd(T) - \sum_{i=1}^N \frac{|Ti|}{|T|} Sd(Ti) \quad (2)$$

$$Sd(T) = \sqrt{\frac{1}{N} (\sum_{i=1}^N Yi^2 - \frac{1}{N} (\sum_{i=1}^N Yi)^2)} \quad (3)$$

در این روابط: SDR: کاهش انحراف معیار، T : مجموعه‌ای از نمونه‌ها است که به هر گره وارد می‌شود، Ti : نشان‌دهنده‌ی زیر مجموعه‌ای از نمونه‌ها است که i امین نتیجه تست پتانسیلی را دارند، Sd : بیانگر انحراف معیار، Yi : مقدار عددی ویژگی هدف نمونه i و N : شماره داده‌ها را نشان می‌دهد (۶)

ماشین بردار پشتیبان (SVM)

هدف ماشین‌های بردار پشتیبان، یافتن یک تابع پیوسته با مقدار حقیقی است که بتواند به ازای مقادیر ورودی، پیش‌بینی دقیقی از مقدار خروجی داشته باشد (۲۲). به طور کلی ماشین بردار پشتیبان نوعی سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که توسط وینیک ارائه شده است (۲۳). ماشین بردار پشتیبان روشی است که هم برای گروه‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها در مسائل رگرسیون به کار می‌رود. به طوری که کمترین خطا در گروه‌بندی داده‌ها با تابع برازش رخ می‌دهد. SVM الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر

نتایج و بحث

در این روابط x_i مقدار اندازه‌گیری شده، x_i^* مقادیر برآورد شده و n تعداد نمونه می‌باشد. برخی نمایه‌های آمار توصیفی پارامترهای فیزیکی و شیمیایی خاک مورد مطالعه در جدول ۱ آورده شده است.

جدول ۱- توصیف آماری خصوصیات فیزیکی و شیمیایی نمونه های خاک

Table 1. Statistical description of physical and chemical properties of soil samples

خصوصیات خاک	واحد	حداقل	حداکثر	میانگین	میان	انحراف معیار	ضریب تغییرات	چولگی
کربنات کلسیم	درصد	۸	۳۷/۵	۲۱/۲۹	۲۰	۵/۷۷	۲۷/۰۱	-۰/۶۸
هدایت الکتریکی	ds/m	۲/۴۲	۶۴	۱۵/۱۵	۹/۸۲	۱۴/۲۸	۹۴/۲۴	۱/۷۹
اسیدیته خاک	(-log[H+])	۶/۷۰	۱۰/۲۲	۷/۹۶	۸	-۰/۵۳	۶/۷۲	-۰/۲۳
رس	درصد	۰/۰۰	۱۷/۵	۴/۶۵	۳/۵	۳/۴۳	۷۳/۸۷	-۰/۹۹
شن	درصد	۷۳	۹۶	۸۲/۸۹	۸۲	۵/۸۶	۷/۰۷	-۰/۴۱
سیلت	درصد	۱	۲۱	۱۲/۴۴	۱۲/۵	۴/۶۳	۳۷/۲۶	-۰/۱۹
کربن آلی	درصد	۰/۱۱	۱/۲۴	۰/۴۴	-۰/۴۱	۰/۲۱	۴۷/۸۳	۱/۰۷
هدایت هیدرولیکی اشباع	m/day	۰/۰۲۵	۰/۰۵۷	۰/۰۴	۰/۰۴۱	۰/۰۷۲	۱۷/۸۷	-۰/۱۳

بالای هدایت الکتریکی در خاک ممکن است به دلیل بالا بودن سطح آب زیرزمینی و حرکت موئینگی آب به سمت بالا و تجمع املاح در بعضی از افق‌های سطحی خاک باشد. ضریب همبستگی پیرسون بین پارامترهای مورد مطالعه در جدول ۲ آورده شده است. همان‌طور که مشاهده می‌شود، هدایت هیدرولیکی اشباع خاک با درصد شن رابطه مثبت معنی‌دار، با درصد سیلت، درصد رس و مواد آلی رابطه منفی معنی‌دار و با درصد کربنات کلسیم رابطه مثبت و با اسیدیته خاک و هدایت الکتریکی رابطه منفی ضعیفی دارد. این نتایج با یافته‌های جارویس و همکاران (۱۴) و احمدی و همکاران (۲) همخوانی دارد. ایشان بیان داشتند هدایت الکتریکی از عوامل تأثیرگذار در پایداری خاک می‌باشد. هدایت هیدرولیکی اشباع خاک در خاک به شدت تحت تأثیر بافت و ساختمان خاک است. هدایت هیدرولیکی اشباع در خاک‌های درشت بافت بیشتر از خاک‌های ریز بافت می‌باشد. زیرا جریان اشباع آب در خاک بیشتر از طریق منافذ درشت خاک صورت می‌گیرد. بنابراین هدایت هیدرولیکی اشباع در خاک‌های شنی بیشتر از خاک‌های رسی می‌باشد. نتایج به دست آمده از تحقیق نیز نشان داد بیشترین همبستگی مثبت (۰/۸۶۸) بین هدایت هیدرولیکی اشباع خاک و ویژگی زودبافت خاک (شن) وجود دارد.

ضریب تغییرات (پراکندگی) شاخصی است که برای اندازه‌گیری توزیع پراکندگی داده‌های آماری و همچنین مقایسه پراکندگی دو یا چند متغیر به کار می‌رود. در این مطالعه کمترین مقدار ضریب تغییرات (۶/۷۲ درصد) برای اسیدیته خاک و بیشترین مقدار آن (۹۴/۲۴ درصد) برای هدایت الکتریکی خاک می‌باشد. غلامی و همکاران (۱۰) کمترین ضریب تغییرات را برای اسیدیته خاک گزارش کرده‌اند. فروغی‌فر و همکاران (۸) بیان داشته‌اند که ضریب تغییرات کم برای اسیدیته متأثر از عوامل ذاتی همچون مواد مادری در رفتار این ویژگی است. در حالی که ضریب تغییرات زیاد می‌تواند ناشی از اثر متقابل عوامل مدیریتی، مانند مصرف کود و عوامل ذاتی مانند وضعیت زهکشی در خاک‌ها باشد. ضریب تغییرات بالای هدایت الکتریکی (۹۴/۲۴) در منطقه مورد مطالعه می‌تواند ناشی از بالا بودن سطح آب‌های زیرزمینی و شدت بالای تبخیر ۴۵۰۰ تا ۵۰۰۰ میلی‌متر در سال و همچنین ناشی از کنده شدن و به جا ماندن رسوبات بادرفنی سطح دریاچه هامون باشد که در سال‌های اخیر خشک شده و باعث به جا ماندن نمک‌های محلول در سطح خاک منطقه مورد مطالعه گردیده است. تغییرپذیری در ویژگی‌های خاک نتیجه تغییر در محیط‌های رسوب‌گذاری و یا اختلاف در مراحل خاک‌سازی یا هیدرولوژیکی در شکل‌های اراضی مختلف می‌باشد. ممتاز و همکاران (۱۸) بیان داشتند تغییرات

جدول ۲- ضریب همبستگی پیرسون پارامترهای اندازه‌گیری شده خاک


Table 2. Pearson correlation coefficient of measured soil parameters

هدایت هیدرولیکی	مواد آلی	کربنات کلسیم	هدایت الکتریکی	pH	رس	سیلت	شن
۱							
مواد آلی	۱						
کربنات کلسیم	-۰/۹۰۶	۱					
هدایت الکتریکی	-۰/۱۱۸	-۰/۰۲۳	۱				
pH	-۰/۱۶۴	-۰/۰۵۹	-۰/۰۰۵	۱			
رس	-۰/۷۵۹**	۰/۰۳۶**	۰/۰۷۷	۰/۰۸۷	۱		
سیلت	-۰/۵۴۴**	۰/۲۸۶**	۰/۰۳۹	۰/۱۰۲	-۰/۰۴۲	۱	
شن	۰/۸۶۸**	-۰/۴۰۵**	۰/۰۶۹	-۰/۱۱۱	-۰/۵۹۸**	-۰/۷۹۸**	۱

** همبستگی در سطح معنی‌داری یک درصد

مدل‌ها انتخاب شدند (۲۰). این پارامترها عبارت بودند از: چهار پارامتر درصد شن، آهک، درصد سیلت و pH.

به منظور دست‌یابی به مدل بهینه جهت پیش‌بینی هدایت هیدرولیکی اشباع خاک با توجه به ارتباط کامل (فاصله ضریب همبستگی) بین متغیرها (شکل ۲)، پارامترهای ورودی به



شکل ۲- نمودار همبستگی بین متغیرها
Figure 2. Correlation diagram between variables

نمونه) داده‌ها برای آزمون قرار گرفت. تعداد نرون لایه پنهان برای پیش‌بینی هدایت هیدرولیکی اشباع خاک ۱۰ به‌دست آمد. تکرار بهینه در ساختارهای به‌دست آمده ۱۰۰۰ و کارآترین تابع انتقال در لایه میانی تانژانت هاپربولیک و در لایه خروجی خطی بود. نتایج دقت آزمایی شبکه عصبی در برآورد هدایت هیدرولیکی اشباع خاک برای سری داده‌های آموزش، صحت‌سنجی و آزمون در جدول ۳ آورده شده است.

نتایج مدل‌سازی شبکه عصبی (ANN)

در این تحقیق از شبکه پرسپترون چندلایه به‌منظور پیش‌بینی هدایت هیدرولیکی اشباع خاک استفاده گردید و توابع انتقال، تعداد لایه پنهان، تعداد نرون در لایه پنهان و تعداد بهینه‌ی تکرار برای هر شبکه مورد آزمایش قرار گرفت و بهترین ساختار شبکه‌ها با روش سعی و خطا به‌دست آمد. از مجموع ۱۳۰ نمونه، ۶۰ درصد (۸۰ نمونه) داده‌ها برای آموزش، ۲۰ درصد (۲۵ نمونه) داده‌ها برای صحت‌سنجی و ۲۰ درصد (۲۵)


جدول ۳- نتایج معیارها برای مرحله آموزش، صحت‌سنجی و آزمون

Table 3. Results of criteria for training, validation and testing

MAE	RMSE	R ²	آماره خطا
۰/۰۰۲۵	۰/۰۰۳۱	۰/۷۷	آموزش
۰/۰۰۲۶	۰/۰۰۳۴	۰/۶۵	صحت سنجی
۰/۰۰۱۹	۰/۰۰۲۶	۰/۸۱	آزمون

زیر این خط مرجع قرار گرفته اند، نشان‌دهنده این هستند که مدل مقدار آن‌ها را کمتر از مقدار واقعی تخمین زده است و نقاط بالاتر از این خط نشان می‌دهند که مدل مقدار آن‌ها را بیش‌تر تخمین زده است. معیار R^2 به تنهایی برای برآورد دقت مدل نمی‌تواند مناسب باشد. بنابراین از آماره خطای RMSE و MAE نیز استفاده شد. این دو آماره معیار ارزیابی کیفیت مدل بر اساس بررسی میزان خطای پیش‌بینی هستند. هرچه مقدار این دو آماره کمتر و نزدیک به صفر باشد، نشان‌دهنده برآورد خوب مدل می‌باشد. همان‌طور که از جدول ۳ مشاهده می‌شود در هر سه مرحله آموزش، صحت‌سنجی و آزمون مقادیر این دو آماره کم و نزدیک به صفر می‌باشد.

ضریب تبیین مهم‌ترین معیاری است که به‌کمک آن می‌توان رابطه بین دو متغیر را توضیح داد و مقدار آن بین صفر و یک می‌باشد. هر چه این معیار به یک نزدیک‌تر باشد، نشان‌دهنده برآورد خوب می‌باشد. مقدار این آماره برای مرحله آزمون به‌دست آمد که نشان می‌دهد شبکه عصبی به‌خوبی توانسته است هدایت‌هیدرولیکی اشباع خاک را برآورد کند. برای دستیابی به اطلاعات بیش‌تر، نمودار پراکنش نقاط و بهترین خط برازنده به این نقاط رسم شد (شکل ۳). با توجه به نمودار پراکنش ارتباط مستقیم خطی بین داده‌های اندازه‌گیری شده و پیش‌بینی شده مشاهده می‌شود. بیش‌تر نقاط حول خط رگرسیونی و نزدیک به آن هستند. نقاطی که



شکل ۳- مقادیر پیش‌بینی و مشاهده‌ای هدایت هیدرولیکی اشباع خاک با مدل شبکه عصبی (ANN)

Figure 3. Predictive and observational values of soil saturation hydraulic conductivity with neural network model (ANN)

درصد داده‌ها (۸۰ نمونه) برای مرحله آموزش و ۴۰ درصد داده‌ها (۵۰ نمونه) برای مرحله آزمون استفاده شد. جدول ۴ نتایج ارزیابی مرحله آموزش و آزمون را نشان می‌دهد. تقریباً نتایج ارزیابی مشابه‌ای و با کمترین اختلاف در هر دو مرحله به‌دست آمد و این بدین معنی است که ماشین بردار پشتیبان در برآورد Ks از دقت پیش‌بینی خوبی برخوردار است. همچنین نتایج حاکی از کمترین مجذور میانگین مربعات خطا (RMSE) به ترتیب برابر با مرحله آزمون، آموزش و صحت‌سنجی می‌باشد.

رضایی‌ارشد و همکاران (۲۸) و خلیلی‌مقدم و همکاران (۱۵) هم به نتایج مشابه در تحقیقات خود رسیدند و از بین رگرسیون و شبکه عصبی بیان کردند، شبکه عصبی قدرت بالاتری جهت پیش‌بینی هدایت هیدرولیکی اشباع خاک داشت.

نتایج مدل ماشین بردار پشتیبان (SVR)

در این مدل بر خلاف مدل شبکه عصبی (ANN) که از سه مرحله آموزش، صحت‌سنجی و آزمون استفاده شد، از دو مرحله آموزش و آزمون استفاده می‌شود. از ۱۳۰ نمونه، ۶۰


جدول ۴- نتایج معیارها برای مرحله آموزش و آزمون

Table 4. Results of criteria for the training and test phase

آماره خطا	R ²	RMSE	MAE
آموزش	۰/۷۹	۰/۰۰۳۱	۰/۰۰۲۳
آزمون	۰/۸	۰/۰۰۳۱	۰/۰۰۲۳

نیم‌ساز پراکنده شده و این امر دلالت بر برابری مقادیر مشاهداتی و محاسباتی بر اساس خط $(y=x)$ می‌کند.

در شکل (۴) پراکنش بین مقادیر مشاهده‌ای و برآوردی Ks را نشان می‌دهد. همان‌طور که از این نمودار مشخص است مقادیر برآورد شده و مشاهداتی به‌غیر از چند نقطه روی خط



شکل ۴- مقادیر پیش بینی و مشاهده‌ای هدایت هیدرولیکی اشباع خاک با مدل ماشین بردار پشتیبان (SVR)
Figure 4. Predictive values and observations of soil saturation hydraulic conductivity with support vector machine model (SVR)

همان‌طور که از شکل ۴ مشاهده می‌شود مدل ماشین بردار پشتیبان قابلیت بالایی در شبیه‌سازی هدایت هیدرولیکی اشباع خاک دارد. توار اکاوی و همکاران (۳۳) ضمن مقایسه روش SVM با ANN برای برآورد پارامترهای هدایت هیدرولیکی خاک، دریافتند که ماشین‌های بردار پشتیبان دارای توانایی بالاتری در تعیین مقادیر بهینه پارامترهای هدایت هیدرولیکی خاک هستند. لامورسکی و همکاران (۱۷) نیز امکان استفاده از SVM برای تخمین هدایت هیدرولیکی خاک با استفاده از داده‌های زود یافت خاک را مورد بررسی قرار دادند و دقت بالای این روش برای برآورد هدایت هیدرولیکی خاک را گزارش دادند.

نتایج مدل درخت تصمیم

نتایج مدل‌سازی با درخت تصمیم همانند مدل شبکه عصبی (ANN) از سه مرحله آموزش، صحت‌سنجی و آزمون برای


جدول ۵- نتایج معیارها برای مرحله آموزش، صحت‌سنجی و آزمون

Table 5. Results of criteria for training, validation and testing

آماره خطا	R^2	RMSE	MAE
آموزش	۰/۸۶	۰/۰۰۲۵	۰/۰۰۱۷
صحت‌سنجی	۰/۴۰	۰/۰۰۳۲	۰/۰۰۲۵
آزمون	۰/۶۴	۰/۰۰۳۲	۰/۰۰۲۵

فرزاد مهر و همکاران (۷) و مونکادا و همکاران (۱۹) همچنین به نتایج مشابه در تحقیقات خود رسیدند و از بین مدل‌های درخت تصمیم و یادگیری بر پایه نمونه بیان کردند، درخت تصمیم مدل مناسب‌تری جهت پیش‌بینی هدایت هیدرولیکی اشباع خاک است.

شکل ۵ پراکنش میان مقادیر مشاهده‌ای و برآوردی K_s را نشان می‌دهد. همان‌طور که از این نمودار مشخص است مقادیر برآورد شده و مشاهداتی به غیر از چند نقطه روی خط نیم‌ساز پراکنده شده و این امر دلالت بر برابری مقادیر مشاهداتی و محاسباتی بر اساس خط $(y=x)$ می‌کند.



شکل ۵- مقادیر پیش‌بینی و مشاهده‌ای هدایت هیدرولیکی اشباع با مدل درخت تصمیم (M5)

Figure 5. Predictive and observational values of saturated hydraulic conductivity with decision tree model (M5)

درخت تصمیم با بالاترین R^2 (۰/۸۳) و کمترین مقدار RMSE و MAE (۰/۰۰۲۶ و ۰/۰۰۱۹) بهترین مدل برای پیش‌بینی هدایت هیدرولیکی اشباع خاک در منطقه هیرمند انتخاب شد.

انتخاب مدل برتر از بین مدل‌های بررسی شده
جهت تعیین انتخاب مدل مناسب و بهتر برای پیش‌بینی هدایت هیدرولیکی اشباع خاک منطقه مورد مطالعه آماره‌های خطا برای هر سه مدل در حالت کلی در جدول ۶ آورده شده است. همان‌طور که از جدول (۶) مشاهده می‌گردد مدل

جدول ۶- نتایج معیارهای ارزیابی در حالت کلی برای هر سه مدل

Table 6. Results of evaluation criteria in general for all three models

MAE	RMSE	R^2	آماره خطا
۰/۰۰۲۵	۰/۰۰۳۲	۰/۷۶	شبکه عصبی ANN
۰/۰۰۲۳	۰/۰۰۳۱	۰/۸۰	ماشین بردار پشتیبان SVR
۰/۰۰۱۹	۰/۰۰۲۶	۰/۸۳	درخت تصمیم M5

عملکرد آن‌ها مورد ارزیابی قرار گرفت. نتایج نشان داد از بین پارامترهای زود یافت خاک (درصد شن، رس، سیلت، هدایت الکتریکی، کربنات کلسیم و pH) درصد شن با ۰/۸۶ درصد بالاترین همبستگی و هدایت الکتریکی با ۰/۰۶۳ کمترین همبستگی را با هدایت هیدرولیکی اشباع خاک داشتند. همچنین نتایج نشان داد مدل‌های مورد بررسی دقت قابل‌قبولی در پیش‌بینی هدایت هیدرولیکی اشباع خاک با استفاده از داده‌های زود یافت داشتند و از بین این مدل‌ها مدل درخت تصمیم به دلیل داشتن بالاترین ضریب تعیین و کمترین میزان آماره خطا به عنوان مدل برتر انتخاب شد.

تشکر و قدردانی

این پژوهش با حمایت مالی دانشگاه زابل انجام شده است. کد پژوهانه IR- UOZ-GR-1837

نتیجه‌گیری کلی

با توجه به شرایط آب و هوایی منطقه هیرمند، کاربری مختلف اراضی و قرار گرفتن این منطقه در زمره مناطق خشک و نیمه‌خشک و نیاز به اصلاح خاک‌های منطقه و انجام کارهای مدیریتی اطلاع از هدایت هیدرولیکی اشباع خاک به عنوان یکی از عوامل هیدرولوژیکی که از خصوصیات بنیادین خاک است، حائز اهمیت می‌باشد. لیکن اندازه‌گیری مستقیم آن پرهزینه و زمان بر می‌باشد. استفاده از روش‌های تخمین غیرمستقیم هدایت هیدرولیکی اشباع خاک راهی مناسب جهت کاهش هزینه و اتلاف زمان در به‌دست آوردن این خصوصیت مهم خاک می‌باشد. در این راستا مدل‌های هوش مصنوعی (شبکه عصبی، ماشین بردار پشتیبان و درخت تصمیم) برای برآورد هدایت هیدرولیکی اشباع به‌وسیله خصوصیات زود یافت خاک در خاک‌های منطقه هیرمند به کار گرفته شدند و

منابع

1. Agyare, W.A., S.J. Park and P.L.G. Vlek. 2007. Artificial neural network estimation of saturated hydraulic conductivity. *Vadose Zone Journal*, 6: 423-431.
2. Ahmadi, A., P. Palizwanzand and H. Palizwanzand. 2017. Estimation of hydraulic conductivity of soil saturation using gene expression programming and ridge regression (Case study in East Azarbaijan province). *Iranian Soil and Water Research*, 48(5): 1087-1095 (In Persian).
3. Akhoni poorhoseini, F. and S. Darbandi. 2018. Modeling Sufi Chai River runoff using support vector machine and artificial neural network. *Watershed management*, 9(17): 57-66 (In Persian).
4. Anon. 2008. MATLAB software help manual. Version 7.6.0.2008b. The Math Works, Inc.
5. Bouma, J. 1989. Using soil survey data for quantitative land evaluation. *Advances Soil Science*, 9: 177-213.
6. Debeljak, M. and S. Džeroski. 2011. Decision Trees in Ecological Modelling. In: Jopp, F., Reuter, H., Breckling, B. (eds), *Modelling Complex Ecological Dynamics*. (197-209). Springer, Berlin, Heidelberg.
7. Farzadmehr, M., M. Dastoorani and M. Khashei siooki. 2018. Compare M5 Moldel and RBF model in saturation hydraulic conductivity. *Water and Soil Conservation*, 25(5): 167-183 (In Persian).
8. Foroughifar H., A.A. Jafarzadah, H. Torabi Gelsefidi, N. Aliasgharzadah, N. Toomanian and N. Davatgar. 2010. Spatial variations of surface soil physical and chemical properties on different landforms of Tabriz plain, *Journal of Soil and Water Science*, 21(3):1-21 (In Persian).
9. Gee, G.W. and D. Or. 2002. Particle-size analysis. In: Warren, A.D. Eds. *Methods of Soil Analysis. Part 4. Physical Methods*. (pp.255-295). Soil Science Society of America Journal.
10. Gholami Sh., S.M. Hosseini J. Mohammadi and A.S. Mahini. 2011. Spatial variability of soil macrofauna biomass and soil properties in riparian forest of Karkhe river, *Journal of Water and Soil*, 25(2): 248-257 (In Persian).
11. Haverkamp, R., F.J. Leij, C. Fuentes, A. Sciortino and P.J. Ross. 2005. Soil water retention: I. Introduction of a shape index. *Soil Science Society of America Journal*, 69: 1881-1890.
12. Hoseini, Y. and R. Sedghi. 2015. Assesment and compar ANFIS system and MLP in Estimation Saturation hydraulic conductivity by texture soil. *Applied Research in Engineering of Irrigation and Drainage Structures*, 16(65): 54-27 (In Persian).
13. Hoseini Somee, M., A. Roshani and I. Zebah. 2020. Modeling Groundwater Level Changes Based on Artificial Intelligence Methods (Murray Study of Zaveh Plain). *Watershed management*, 11(21): 223-234 (In Persian).
14. Jarvis, N., J. Zavattaro, L.K. Reynolds, W.D. Olsen, P.A. McGechan, M. Mecke, M. Mohanty, B. Leeds-Harrison, P.B. and D. Jacques. 2002. Indirect estimation of near-saturated hydraulic conductivity from readily available soil information. *Geoderma*, 108: 1-17.
15. Khalili Moghadam, B., M. Afioni, A. Jalalian, K. Abbaspour and A. Dehghani. 2014. Application of regression methods and neural networks to estimate the saturated hydraulic conductivity of soil in Central Zagros region. *Journal of Agricultural Science and Technology and Natural Resources, Soil and Water Sciences*, 19(71): 217-227 (In Persian).
16. Khashei Siuki, A., V.R. Jalali Moakhar, A.M. Noferesti and Y. Ramazani. 2015. Comparing nonparametric k-nearest neighbor technique with ANN model for predicting soil saturated hydraulic conductivity. *Journal of Soil Management and Sustainable Production*, 5(3): 81-95 (In Persian).
17. Lamorski K., Y. Pachepsky, C. Slawinski and R.T. Walczak. 2008. Using support vector machines to develop pedotransfer functions for water retention of soils in Poland. *Soil Science Society American Journal*, 72: 1243-1247.
18. Momtaz, H.R., A.A. Jafarzadah, H. Torabi, Sh. Oustan, A. Samadi, N. Davatgar and R.J. Gilkes. 2009. An assessment of the variation in soil properties within and between Landforms in Amol region, Iran. *Geoderma*, 149: 10-18.
19. Moncada, M.P., D. Gabriels and W.M. Cornelis. 2014. Data-driven analysis of soil quality indicators using limited data. *Geoderma*, 235: 271-278.
20. Najibzadeh, N., K. Ghaderi and M.M. Ahmadi. 2019. Utilization of support vector regression methods and artificial neural network in runoff precipitation modeling (Case study: Saffarud Dam catchment). *Irrigation and Drainage of Iran*, 6(13):1709-1720 (In Persian).
21. Nelson, D.W. and L.E. Sommer. 1982. Total carbon, organic carbon, and organic matter. In: Sparks, D.L. Page, A.L. Helmke, P.A. Loeppert, R.H. Soltanpour, P.N. Tabatabai, M.A. Johnston, C.T. Sumner, M.E. Eds. *Methods of soil analysis: part 3. Chemical and microbiological properties*. American Society of Agronomy, 539-579 pp.
22. Nikbakht Shahbazi, A., B. Zahraei and M. Naseri. 2012. Seasonal forecast of meteorological drought using support vector machines. *Water and Wastewater*, 2(23): 73-85 (In Persian).
23. Nikpour, M.R., H. Thanikhani, S. Mahmoudi Babalan and A. Mohammadi. 2017. Application of SVM, ANN, WNN and GEP models in rainfall-runoff simulation of Khiavachai River. *Echo Hydrology*, 627-639 (In Persian).

24. Noroozian Azizi, Z., M. Qajar Spanloo, M. Emadi and F. Sadeghzadeh. 2017. Evaluation of regression models and artificial neural network in estimating hydraulic conductivity of soil saturation in Mazandaran. *Soil Research (Soil and Water Sciences)*, 31(1): 76-88 (In Persian).
25. Norouzi Ghoshbalagh, H., A. Nadiri, A. Asghari Moghaddam and M. Qarakhani. 2018. Comparison of the efficiency of artificial neural networks, fuzzy logic and random forest in estimating the aquifer transfer capability of Malekan plain. *Echo Hydrology*, 5(3): 739-751 (In Persian).
26. Nosrati Karizak, F., S.A. Movahedi Naeni and A. Hezarjaribi. 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).
27. Page, A.L., R.H. Miller and D.R. Keeney. 1982. *Methods of Soil Analysis. Part 2. Chemical and Microbiological Properties*, second ed. Agronomy Monographs, 9. ASA-SSA, Madison.
28. Rezaei Arshad, R., A. Sayadi, M. Mazlum, M. Sharfa and A. Jafar Nejadi. 2012. Comparison of artificial neural network and regression methods to predict saturated hydraulic conductivity of soils in Khuzestan province. *Water and Soil Science-Agricultural Science and Technology and Natural Resources*, 16(60): 107-118 (In Persian).
29. Rhoads, J.D. 1986. Cation exchange capacity, In; A.C. Page (ed) *Methods of soil Analysis*, part 2, American Society of Agronomy, 9: 149-158.
30. Sajikumar, N. and B.S. Thandaveswara. 1999. A Nonlinear Rainfall-Runoff Model Using an Artificial Neural Network," *Journal of Hydrology*, 126(1): 32-55.
31. Siasar, H. and T. Honar. 2019. Application of support vector machine models, chad and random forest in estimating daily reference transpiration evaporation in northern Sistan and Baluchestan province. *Irrigation and Drainage of Iran*, 2(13): 378-388 (In Persian).
32. Twarakavi N.K.C., J. Simunek and M.G. Schaap. 2009. Development of pedotransfer functions for estimation of soil hydraulic parameters using support vector machines. *Soil Science Society of American Journal*, 73: 1443-1452.
33. Wang, Y. and I.H. Witten. 1997. Inducing model trees for continuous classes. In *Proceedings of the Ninth European Conference on Machine Learning*. 128-137 pp.
34. Wosten, J.H.M., Ya.A. Pachepsky and W.J. Rawls. 2001. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Journal of Hydrology*, 251: 123-150.

Comparison and Application of Artificial Neural Network, Support Vector Machine and Decision Trees in Predicting the Hydraulic Conductivity of Soil Saturation (Case Study: Hirmmand City)

Iman Bijan¹, Halimeh Piri², Mahmoud Tabatabai³ and Jamshid Piri⁴

1- M.Sc. Student, University of Zabol

2- Assistant Professor University of Zabol, (Corresponding author: h_piri2880@uoz.ac.ir)

3- Assistant Professor, University of Zabol

4-Instructor University of Zabol

Received: 23 September, 2020

Accepted: 15 December, 2020

Extended Abstract

Introduction and Objective: Direct measurement of soil hydraulic conductivity is time consuming and costly, and sometimes the results are unreliable due to trial and error. This parameter can be estimated using early soil parameters. The present study was conducted to predict the hydraulic conductivity of soil saturation using decision tree methods, support vector machine and artificial neural network in Helmand city.

Material and Methods: For this purpose, 130 soil samples were collected from the surface (0-30 cm) and transferred to the laboratory for testing and analysis. In the laboratory, the parameters of hydraulic conductivity of soil saturation, percentage of stress, sand and silt, organic matter, acidity, electrical conductivity and calcium carbonate were measured. It was then estimated using measurement parameters and using decision tree models, artificial neural network, and saturated hydraulic guidance support vector machine. In order to evaluate the models, the criteria of explanatory coefficient, square mean error and absolute mean error were used.

Results: The results showed that the decision tree model with the highest coefficient of explanation (0.83) and the lowest value of the mean square of error and absolute error of average (0.0026 and 0.0019) is the best model for predicting the hydraulic conductivity of soil saturation in Hirmmand region. Also, the results of data sensitivity analysis using artificial neural network model showed that sand percentage, lime percentage, silicate percentage and acidity are the most important factors affecting the hydraulic conductivity of soil saturation in Hirmmand city, respectively.

Conclusion: The results show the very good performance of artificial intelligence methods in predicting hydraulic conductivity of soil saturation. In cases where it is not possible to measure hydraulic conductivity, hydraulic conductivity can be estimated using early soil parameters and artificial intelligence methods.

Keywords: Artificial intelligence, Constant head, Early soil characteristics