

مقاله علمی-پژوهشی

ارزیابی مدل‌های هوشمند جهت برآورد هدایت هیدرولیکی اشباع در خاک‌های لومی

شادیه حیدری تاشه‌کبود^{۱*}، مجتبی خوش‌روش^۲

تاریخ دریافت: ۱۳۹۹/۸/۵ تاریخ پذیرش: ۱۳۹۹/۹/۲۷

چکیده

هدایت هیدرولیکی اشباع یکی از پارامترهای اصلی در مطالعات کشاورزی و محیط‌زیست است که برای پیش‌بینی و مدیریت آب و انتقال املاح در خاک ضروری است. در این تحقیق از ۱۲۰۰ سری داده مربوط به خاک‌های لومی جهت پیش‌بینی و مدل‌سازی هدایت هیدرولیکی اشباع با استفاده از خصوصیات فیزیکی خاک نظیر وزن مخصوص ظاهری خاک، ظرفیت آب در دسترس، محتوای کربن آلی و مقادیر رس، سیلت و ماسه استفاده شد. از این تعداد سری داده، ۹۰۰ سری برای استفاده در بخش آموزش مدل‌ها و ۳۰۰ سری برای آزمون مدل‌ها در سه سناریو طراحی شده تخصیص یافت. عملکرد مدل‌های SVM، MLP و M5 در برآورد هدایت هیدرولیکی اشباع خاک لومی مورد ارزیابی قرار گرفت. عملکرد مدل‌ها با استفاده از شاخص‌های آماری ضریب تبیین (R^2)، خطای مجذور میانگین مربعات (RMSE) و خطای بایاس میانگین (MBE) مقایسه شد. نتایج به‌دست‌آمده نشان داد هر سه مدل مورد استفاده از توانایی خوبی در مدل‌سازی هدایت هیدرولیکی اشباع برخوردارند، اما مدل M5 با ضریب تبیین بالای ۰/۹۵ در هر سه سناریو و RMSE پایین‌تر نسبت به سایر مدل‌ها به‌عنوان مدل برتر انتخاب شد. نتایج نشان داد که مدل‌های داده‌کاوی هوشمند تخمین مقادیر ناشناخته را بر اساس الگوهای موجود در یک پایگاه داده امکان‌پذیر می‌نمایند. بنابراین مدل‌های بکار گرفته‌شده می‌توانند در پیش‌بینی انتقال املاح در خاک و پارامترهای فیزیکی خاک استفاده شوند.

واژه‌های کلیدی: انتقال املاح، حرکت آب در خاک، درخت تصمیم، خصوصیات فیزیکی خاک، وزن مخصوص ظاهری

مقدمه

توسط رینولدز (Reynolds, 2010) دشوار، زمان‌گیر و هزینه‌بر است (Asadollahzadeh et al., 2014) و برای همین منظور غالباً از طریق روش‌های غیرمستقیم برآورد می‌شود. اکثر مدل‌های هیدرولیکی موجود خاک، نیروهای مویرگی را محاسبه می‌نمایند و روند جریان که در شرایط بسیار خشک رخ می‌دهد را نشان نمی‌دهند که این امر برای حفاظت آب و خاک، رشد گیاهان و فرایندهای بیولوژیکی بالأخص در مناطق خشک و نیمه‌خشک مهم هستند (Ryel et al., 2002; Wang et al., 2017). بر همین اساس در دهه‌های اخیر سعی بر آن بوده منحنی هدایت هیدرولیکی کامل خاک ارائه شود (Tuller and Or, 2001; Tokunaga, 2009; Wang et al., 2017; Wang et al., 2013). در حدود دو دهه است که استفاده از روش‌های هوشمند برای برآورد هدایت هیدرولیکی و پارامترهای مختلف آب و خاک به دلیل آسانی و کم‌هزینه بودن به‌وفور کاربرد داشته است.

سرمیدان و همکاران (۱۳۸۹) با استفاده از روش‌های نروفازی، شبکه عصبی و رگرسیون چندمتغیره، برخی از خصوصیات خاک شامل نقطه پژمردگی، ظرفیت زراعی، ظرفیت تبادل کاتیونی و وزن

آب در خاک می‌تواند به صورت جریان اشباع، غیراشباع و یا جریان بخار حرکت نماید. جریان اشباع زمانی صورت می‌پذیرد که منافذ خاک کاملاً از آب پر شده باشد. هدایت هیدرولیکی اشباع سرعت حرکت آب از طریق خاک اشباع را توصیف می‌نماید. همچنین هدایت هیدرولیکی خاک یکی از پارامترهای اساسی در مدل‌سازی آب‌های زیرزمینی، املاح شیمیایی در خاک و حرکت آب در خاک است (Nosrati, 2012; Koorevaar et al., 1983; Reynolds, 2008 and Topp). به منظور برآورد هدایت هیدرولیکی اشباع حل معادلات ارائه شده توسط فیلیپ (Philip, 1993) و اصلاح شده

۱- دانشجوی دکتری آبیاری و زهکشی، گروه علوم و مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ایران

۲- دانشیار گروه علوم و مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ایران.

* - نویسنده مسئول: (Email: shadiheidari1990@gmail.com)
DOR: 20.1001.1.20087942.1400.15.1.12.2

مصنوعی به‌خوبی و با دقت مناسب می‌تواند هدایت هیدرولیکی خاک را تخمین نماید و پارامترهای سیلت، رس، ماسه، وزن ظاهری و مواد آلی خاک مؤثرترین متغیرهای ورودی مدل هستند (Moosavi and Sepaskhah, 2012).

رضایی و همکاران در مطالعه‌ای از شبکه‌های عصبی MLP و مدل‌های رگرسیونی برای تخمین هدایت هیدرولیکی اشباع خاک استفاده کردند. نتایج نشان داد مدل MLP از دقت بهتری نسبت به مدل‌های رگرسیونی برخوردار است (Rezaie et al., 2012). همچنین امامزاده و همکاران با استفاده از مدل‌های MLP و RBF به تخمین هدایت هیدرولیکی اشباع خاک پرداختند و آنها نیز برتری مدل MLP را خاطر نشان کردند (Emamzadeh et al., 2014).

تایفور و همکاران با بهره‌گیری از چندین روش هوش مصنوعی، هدایت هیدرولیکی اشباع خاک را تخمین زدند. آنها نتیجه گرفتند که خروجی ناشی از ترکیب نتایج کل مدل‌ها به نسبت خروجی هرکدام از مدل‌های استفاده شده به‌صورت منفرد کارا تر است (Tayfur et al., 2014).

البیسی با استفاده از ماشین بردار پشتیبان هدایت هیدرولیکی اشباع را در خاک‌های شنی بر اساس ویژگی‌های شوری و قلیایی خاک پیش‌بینی کردند. در این تحقیق عملکرد سه تابع خطی، پایه شعاعی و سیگموئید بر عملکرد ماشین بردار پشتیبان با استفاده از داده‌های میدانی مورد بررسی قرار گرفت. مدل پایه شعاعی با ضریب همبستگی ۰/۹۷۶ در پیش‌بینی هدایت هیدرولیکی اشباع خاک عملکرد خوبی از خود به‌جای گذاشت (Elbisi, 2015).

یانو و همکاران با کمک شبکه عصبی مصنوعی مقدار هدایت هیدرولیکی اشباع خاک را در زمین‌های کشاورزی ساحلی و شور جیانگسوی شمالی در کشور چین تخمین زدند و شوری خاک را یکی از تأثیرگذارترین فاکتورها در مقدار این پارامتر برشمردند که بایستی همواره به‌عنوان یکی از داده‌های ورودی خاک مورد استفاده قرار گیرد (Yao et al., 2015).

سیهاگ و همکاران هدایت هیدرولیکی غیراشباع خاک را با استفاده از سیستم استنتاج تطبیقی عصبی فازی، رگرسیون خطی و شبکه عصبی مصنوعی پیش‌بینی کردند. نتایج حاکی از عملکرد تابع عضویت گاوسی نسبت به تابع عضویت مثلثی و بل در سیستم استنتاج تطبیقی عصبی فازی است. همچنین این مدل در حالت کلی عملکرد بهتری در تخمین هدایت هیدرولیکی غیراشباع خاک نسبت به شبکه عصبی مصنوعی و رگرسیون خطی داشت (Sihag et al., 2017). همچنین سیهاگ برای برآورد هدایت هیدرولیکی غیراشباع خاک مدلی بر پایه منطق فازی و شبکه عصبی مصنوعی توسعه داد. پیش‌بینی با رویکرد شبکه عصبی با ضریب همبستگی ۰/۸۶۶ و مجذور مربع خطای ۴/۵۶۱ کارایی خوبی داشت (Sihag, 2018).

الدوساری و همکاران هدایت هیدرولیکی غیراشباع خاک‌های لوم

مخصوصاً ظاهری را تخمین زدند. نتایج کار آنها نشان‌دهنده کارایی بالای مدل نروفازی و شبکه عصبی مصنوعی نسبت به معادلات رگرسیونی بود.

پوررضا بیلندی و خاشعی سیوکی (۱۳۹۴) به تحلیل عدم قطعیت خروجی شبکه عصبی در شبیه‌سازی هدایت هیدرولیکی اشباع خاک در ۱۵۱ نمونه از خاک‌های زراعی اطراف شهرستان بجنورد پرداختند. نتایج تحلیل عدم قطعیت به‌دست‌آمده با کمک نمونه‌گیر مونت‌کارلو جهت استفاده در دوره‌های آموزش و آزمون شبکه عصبی پروسپترون بررسی و ارزیابی شد. بر اساس نتایج فقط تابع کاهش گرادیان دارای زمان اجرا بیشتر و مقدار NUE پایین‌تر به نسبت بقیه بوده، لذا بیشترین عدم قطعیت را در بین مقادیر هدایت هیدرولیکی خروجی شبیه‌سازی شده داشت.

مارسل و همکاران از شبکه عصبی برای پیش‌بینی ظرفیت نگهداری رطوبت خاک و هدایت هیدرولیکی اشباع با بهره‌گیری از ویژگی‌های پایه خاک نظیر مقادیر شن، سیلت و رس، وزن مخصوص ظاهری، تخلخل و مقادیر گراول استفاده نمودند و نتایج حاصل نشان از افزایش دقت پیش‌بینی ظرفیت نگهداری رطوبت و هدایت هیدرولیکی اشباع با افزایش تعداد داده‌ها داشت و روش مذکور به دلیل دقت و میزان بالای انعطاف‌پذیری مورد توجه واقع شد (Marcel et al., 1998).

جرج با ترکیب آزمایش‌های صحرایی و روش مسئله معکوس، به بررسی و تحقیق در مورد تغییرات زمانی و مکانی خصوصیات هیدرولیکی غیراشباع پرداخت. در تحقیق وی، نیمرخ رطوبتی خاک در ابتدا و انتهای دوره مطالعاتی و همچنین مقادیر نفوذ، تبخیر و بار فشاری در پشت جبهه رطوبتی خاک به‌طور پیوسته اندازه‌گیری شد. نتایج حاصل از مطالعات نشان داد که روش معکوس مقادیر معقولی از درصد حجمی رطوبت اشباع را در یک لایه خاک رسی پیش‌بینی نماید (Greg, 2003).

نوایان و همکاران برآورد سریع هدایت آبی اشباع را ارزیابی کردند و نشان دادند شبکه‌های عصبی مصنوعی عملکرد نسبتاً بهتری در مقایسه با روابط رگرسیونی دارند (Navabian et al., 2004).

آمر و همکاران معادله‌ای را برای پیش‌بینی هدایت هیدرولیکی خاک بر اساس ویسکوزیته آب، شتاب ثقل، چگالی آب، نسبت حجم کل منافذ و شعاع اندازه منافذ استوانه‌ای پیشنهاد دادند (Amer et al., 2009). نشاط و فرهاد بر اساس محاسبات هدایت هیدرولیکی غیراشباع خاک را تخمین زدند، تا بر اساس آن رابطه‌ای بین هدایت هیدرولیکی غیراشباع و خصوصیات فیزیکی آن حاصل شود (Neshat and Farhad, 2012). همچنین موسوی و سپاس‌خواه از یک مدل شبکه عصبی مصنوعی با پارامترهای ورودی ماسه، سیلت، رس، وزن ظاهری، مواد آلی و محتوای آب اشباع حجمی به پیش‌بینی هدایت هیدرولیکی پرداختند. نتایج تحقیق آنها نشان داد که شبکه عصبی

فاصله ممکن را از نزدیک‌ترین نمونه‌ها به هر دو طرف ابر صفحه ایجاد می‌کند. در برآورد رگرسیونی به نقطه‌های ایجادکننده مرز ماکزیمم بردار پشتیبان گفته می‌شود. در واقع این بردارها همان تابع تقریب زده شده است که از داده‌های آموزشی حاصل شده است. در این مدل علاوه بر کمینه‌سازی از خطای تجربی از یک عامل هموارساز استفاده می‌شود.

در این مطالعه هدف از آموزش مدل پیدا کردن تابع $f(x)$ به‌عنوان تقریبی از مقدار $y(x)$ با حداقل خطا و بر اساس داده‌های مستقل از یکدیگر می‌باشد.

$$(X_1, y_1), \dots, (X_m, y_m) \subseteq (X \subseteq R^n \times Y \subseteq R) \quad (1)$$

$$R_{reg} = R_{emp}(f) + \lambda \Omega(f) \quad (2)$$

در رابطه بالا R_{reg} و $R_{emp}(f)$ به ترتیب خطای ساختاری و خطای تجربی است و λ پارامتر هموارسازی است؛ که مشخص‌کننده تعادل بین دقت تخمین تابع f و نرمی آن است. همچنین $\Omega(f)$ از رابطه زیر به دست می‌آید:

$$\Omega(f) = \frac{w^T w}{2} \quad (3)$$

وینیک برای توسعه ماشین‌های بردار پشتیبان از تابع خطای جدید استفاده نمود که تابع خطای ϵ -insensitive خوانده می‌شود و جهت توصیف $L(x, f(x, \alpha))$ استفاده می‌شود که به‌صورت زیر تعریف می‌شود:

$$L(y, f(x, \alpha)) = |y - f(x, \alpha)|_{\epsilon} = \begin{cases} 0 & \text{if } |y - f(x, \alpha)| \leq \epsilon \\ |y - f(x, \alpha)| - \epsilon & \text{otherwise} \end{cases} \quad (4)$$

شکل ۱ تخمین شماتیکی از رابطه بین داده‌های موجود (دایره‌های سیاه و سفید) که در یک فضای یک‌بعدی توسط تابع خطی f انجام پذیرفته نشان می‌دهد. همان‌طور که در شکل قابل‌ملاحظه است استفاده از تابع خطای مذکور باعث شده تا اختلاف بین مقادیر تخمینی توسط تابع و مقادیر اندازه‌گیری شده y که کمتر از مقدار ϵ با مقادیر تخمینی دارند، (دایره‌های سیاه‌رنگ) مطابق تابع خطای ذکرشده، $\xi_i = |y_i - f(x_i, \alpha)| - \epsilon$ به‌عنوان خطا در نظر گرفته شود.

برای بررسی الگوریتم رگرسیون در ابتدای تخمین یک تابع خطی بررسی می‌شود. با توجه به این که کلیه توابع خطی به شکل زیر است:

ماسه‌ای را با استفاده از مدل‌های پرسپترون چندلایه، رگرسیون خطی چندگانه و رگرسیون فرایند گاوسی مدل‌سازی کردند که مقادیر RMSE برای مدل‌ها به ترتیب $10^{-4} * 1/87$ ، $10^{-4} * 2/22$ و $10^{-4} * 1/16$ به دست آمد. در این مطالعه مقایسه مدل‌ها نشان داد مدل رگرسیون فرایند گاوسی نسبت به مدل‌های پرسپترون چندلایه و رگرسیون خطی چندگانه عملکرد بهتری در مدل‌سازی هدایت هیدرولیکی غیراشباع داشت (Al-Dosari et al., 2019).

بر اساس موارد گفته‌شده و اهمیت مطالعه در زمینه هدایت هیدرولیکی خاک در علوم و مهندسی آب و خاک، هدف از این تحقیق ارزیابی روش‌های هوشمند SVM^1 ، MLP^2 و $M5$ در برآورد هدایت هیدرولیکی اشباع در خاک لومی است. در این راستا از اطلاعات خصوصیات فیزیکی خاک نظیر ظرفیت آب در دسترس، وزن ظاهری خاک و درصد رس، سیلت و ماسه جهت استفاده به‌عنوان ورودی مدل‌ها استفاده خواهد شد. نتایج به‌دست‌آمده از این تحقیق می‌تواند جهت دسترسی سریع به مقادیر هدایت هیدرولیکی در اختیار محققین قرار گیرد.


مواد و روش‌ها

در این تحقیق از اطلاعات خاک‌های پایگاه داده نرم‌افزار SWAT^۳ تحت عنوان usersoil برای استفاده در مدل‌های مورد ارزیابی بهره گرفته شد. بر این اساس ۱۲۰۰ سری داده خاک مربوط به خاک‌های لومی از آن استخراج و جهت پیش‌بینی هدایت هیدرولیکی اشباع مورد استفاده قرار گرفت. از این تعداد داده ۹۰۰ داده برای بخش آموزش و ۳۰۰ داده برای بخش آزمون مدل‌ها اختصاص یافت.

مدل ماشین بردار پشتیبان

ماشین بردار پشتیبان به‌عنوان ابزاری برای رگرسیون اولین بار توسط وینیک^۴ و همکاران معرفی شد (Vapnik et al., 1995). این مدل که از روش‌های یادگیری با نظارت^۵ است؛ بر اصل استقرایی کمینه‌سازی خطای ساختاری استوار است. یادگیری تحت نظارت یک روش عمومی در یادگیری ماشین است که در آن به سامانه، مجموعه جفت‌های ورودی و خروجی داده می‌شود و با توجه به داده‌ها مدل تلاش می‌کند تا تابعی از ورودی به خروجی فراگیرد. در این مدل سعی بر آن است که یک سطح چندبعدی در فضای داده‌های اصلی با جداسازی یک مجموعه داده‌های آموزشی صحیح دارد و بیشترین

- 1- Super Vector Machine
- 2- Multilayer perceptron
- 3- Soil and Water Assessment Tool
- 4- Vapnik
- 5- Supervisor



شکل ۱- تابع خطای ϵ غیر حساس

پیش‌بینی هستند که در دهه‌های اخیر در زمینه‌های مختلف علوم و مهندسی آب مورد استفاده قرار گرفته‌اند. این شبکه‌ها شامل مجموعه-ای از واحدهای حسی (نرون‌های پایه) می‌باشند که متشکل از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشند. سیگنال ورودی در خلال شبکه و در مسیری روبه‌جلو به‌صورت لایه به لایه منتشر می‌شود. این نوع شبکه‌ها معمولاً با عنوان پرسپترون چندلایه (MLP) نامیده می‌شوند (Haykin, 1999).

قاعده فراگیری پرسپترون چندلایه را «قاعده کلی دلتا» یا «قاعده پس انتشار» می‌گویند. نحوه عمل پرسپترون چندلایه‌ای مشابه پرسپترون تک لایه‌ای است. به این صورت که الگویی به شبکه عرضه می‌شود و خروجی آن محاسبه می‌گردد، مقایسه خروجی واقعی و خروجی مطلوب باعث می‌گردد که ضرایب وزنی شبکه تغییر یابد به طوری که در مراحل بعد خروجی صحیح‌تری حاصل شود. وقتی به شبکه آموزش ندیده‌ای الگویی را عرضه شود، خروجی‌های تصادفی تولید می‌کند. ابتدا باید تابع خطایی تعریف شود که تفاوت خروجی واقعی و خروجی مطلوب را نشان دهد. از آنجایی که خروجی مطلوب دانسته می‌شود، این نوع فراگیری را «فراگیری با سرپرستی» می‌نامند. برای موفقیت در آموزش شبکه باید خروجی آن را به تدریج به خروجی مطلوب نزدیک کرد. به عبارت دیگر باید میزان خطا را کاهش داد. برای رسیدن به این هدف از قانون دلتا استفاده می‌شود (حسینی، ۱۳۸۸). در پژوهش حاضر، برای مدل‌سازی با استفاده از شبکه‌های MLP از یک شبکه سه لایه‌ای پیشخور استفاده شد. شکل ۲ ساختار یک شبکه عصبی MLP را نشان می‌دهد.

به طوری که: $w, x \in X, b \in R$

$$f(x) = \langle w, x \rangle + b \quad (5)$$

به طوری که در آن $\langle \cdot, \cdot \rangle$ مشخص‌کننده ضرب داخلی دو بردار در فضای هیلبرت^۱ (فضایی که به نام فضای ضرب داخلی یا نقطه‌ای نیز خوانده می‌شود. و در آن ضرب داخلی دو بردار عددی حقیقی شود) می‌باشد و w بردار وزن مربوط به بردار ورودی است.

برای یافتن تابع f باید به کمینه‌سازی تابع خطای هموار شده R_{reg} بر اساس تابع خطای ϵ -insensitive پرداخت. R_{reg} را می‌توان بر اساس شکل باز شده R_{emp}^ϵ بازنویسی شود.

$$R_{reg}[f] = \frac{1}{2} \|w\|^2 + \frac{C}{m} \sum |y_i - f(x_i)|_\epsilon \quad \text{بنابراین}$$

$$R_{emp}^\epsilon[f] = \frac{1}{m} \sum_{i=1}^m |y_i - f(x_i)|_\epsilon \quad (6)$$

خطای آموزش را در قالب تابع خطای ϵ -insensitive محاسبه می‌شود. ضریب ثابت C بیانگر سازشی است که میان پیچیدگی تابع f ($\|w\|^2$) و بالاترین مقداری از انحرافات بیشتر از ϵ که قابل تحمل خواهند بود. به طور مختصر کمینه‌سازی رابطه (۴) نشان‌دهنده ایده اصلی تئوری یادگیری آماری است و بیان‌کننده این است که برای دستیابی به کم‌ترین خطای واقعی، کنترل پیچیدگی مدل و همچنین خطای مربوط به داده‌های آموزش ضروری است. به عبارت دیگر طبق گفته وپنیک عمومیت‌پذیری با استفاده از داده‌های محدود امکان‌پذیر است، اگر و تنها اگر پیچیدگی تابع تخمین کنترل شود.

مدل MLP

شبکه‌های چندلایه پیشخور^۲، یکی از متداول‌ترین مدل‌های


3- Delta rule

4- Backpropagation

5- Supervised learning

1- Hilbert

2- Multi-layer perceptron



شکل ۲- ساختار شبکه MLP (حسینی، ۱۳۸۸)

مدل‌های چندتکه‌ای خطی دانست که هرکدام برای یک محدوده خاصی از داده‌های ورودی مناسب هستند (شکل ۴).

سنجش دقت مدل‌ها

برای بررسی دقت تخمین هر یک از مدل‌ها با استفاده از جذر میانگین مجموع مربع خطاها (RMSE) و متوسط خطای سوءگیری (MBE) و ضریب همبستگی (R^2) واسنجی انجام گرفت. معادلات مربوط به RMSE، MBE و R^2 به صورت زیر می‌باشد:

$$RMSE = \sqrt{\frac{1}{t} \sum_{i=1}^t (P_i - O_i)^2} \quad (۸)$$

$$MBE = \frac{\sum_{i=1}^t (P_i - O_i)}{t} \quad (۹)$$

$$R^2 = 1 - \frac{\sum_{i=1}^t (P_i - O_i)^2}{\sum_{i=1}^t (O_i - \bar{O}_i)^2} \quad (۱۰)$$

که در روابط فوق P_i و O_i مقادیر مشاهداتی و تخمینی در زمان i و t تعداد داده‌ها هستند. مقدار RMSE بیانگر متوسط مربع خطا بین مقادیر مشاهداتی و پیش‌بینی شده است و هر چه مقدار آن کمتر باشد نشان‌دهنده دقت بیشتر تخمین مدل است. مقدار MBE نشان‌دهنده مثبت یا منفی بودن خطای محاسباتی بوده و در صورت مثبت یا منفی بودن نمایانگر این مطلب است که مقادیر پیش‌بینی شده به ترتیب بیشتر یا کمتر از مقادیر مشاهداتی هستند. مقدار R^2 نیز همیشه بین صفر و یک تغییر می‌کند. هر چه به یک نزدیک‌تر باشد، نشان‌دهنده تطابق بهتر مقادیر تخمینی و مقادیر اندازه‌گیری شده می‌باشد.

مدل درختی M5

کوبین لان اولین بار این الگوریتم را در سال ۱۹۹۲ مطرح کرد. الگوریتم M5 از معمول‌ترین درختان تصمیم‌گیری برای دسته‌بندی است. مزیت مدل درختی M5 نسبت به رگرسیون درختی، مؤثر بودن در داده‌های بزرگ و دارا بودن دقت بیشتر است (Pal and Deswal, 2009). این دقت معادل دقت شبکه عصبی و دقتی بیش از درختان تصمیمی همانند کارت^۱ می‌باشد. اساس این مدل بر پایه تصمیم و غلبه کردن استوار است و هدف در آن، کار با رگرسیون خطی و تشکیل مقادیر پیش‌بینی شده نهایی در برگ‌هاست. گره‌های این درخت بر اساس حداقل خطای انحراف معیار تعیین می‌شوند (شکل ۳).

مدل رگرسیون‌گیری درختی دو مرحله را شامل می‌شود:


الف) استفاده از یک معیار دسته‌بندی برای ایجاد درخت تصمیم. این معیار بر اساس عملکرد انحراف استاندارد به ازای هر کلاس که در هر گره به دست آمده است، تعیین می‌شود.

رابطه زیر جهت محاسبه کاهش انحراف استاندارد ارائه شده است:

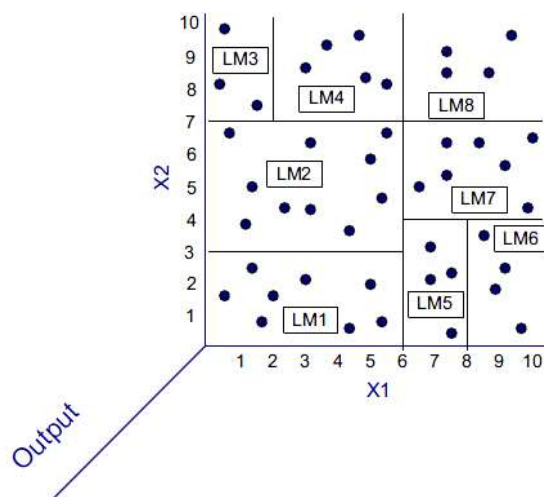
$$SDR = sd(T) - \sum \frac{T_1}{T_2} sd(T_1) \quad (۷)$$

که در رابطه فوق T نشان‌دهنده مجموعه‌ای از نمونه‌ها که به هر گره وارد شده‌اند و sd انحراف استاندارد داده‌های ورودی است. گره‌های فرزند به علت انحراف معیار کمتر دارای دقت بیشتری نسبت به گره‌های والد هستند.

ب) هرس درخت کاملاً رشد یافته: پس از انجام دسته‌بندی‌ها، مدل حداقل خطای مورد انتظار به‌عنوان گزینه برتر ارائه می‌شود. بدین منظور ساختار بزرگ درختی ایجاد شده باید هرس شود، تا مدل با پیچیدگی تحلیل مواجه نشود. از جمله راه‌حل‌های هرس، جایگزینی زیرشاخه‌ها با برگ‌هاست. پس یک مدل درختی را می‌توان ترکیبی از



شکل ۳- ساختار سلسله مراتبی مدل درختی M5



شکل ۴- تقسیم‌بندی فضای نمونه‌ها توسط الگوریتم مدل درختی M5

هیدرولیکی اشباع^۴ خاک (میلی‌متر بر ساعت) استفاده شد. ورودی‌های سناریوهای طراحی‌شده برای مدل‌سازی در جدول ۲ ارائه شده است.

نتایج مدل SVM

بر اساس نتایج به‌دست‌آمده از مدل SVM برای سه سناریوی طراحی‌شده، این مدل در بخش آموزش و آزمون به لحاظ خطای MBE و RMSE مقادیر قابل قبولی داشت، مقادیر ضریب تبیین در بخش آموزش و آزمون باهم اختلاف قابل‌توجهی ندارند (جدول ۳). شاخص‌های آماری نشان‌دهنده برتری سناریوی سوم مدل SVM در بخش آموزش و آزمون هستند. شکل ۵ پراکنش داده‌های مشاهداتی در مقابل داده‌های برآوردی را برای بخش آزمون سناریوی برتر

نتایج و بحث

برای شبیه‌سازی مقادیر هدایت هیدرولیکی اشباع با استفاده از مدل‌های هوشمند SVM، MLP و M5 استفاده شد. مشخصات آماری داده‌های بکار رفته در مراحل آموزش و آزمون مدل‌ها در جدول ۱ آمده است. از سه سناریو با استفاده از داده‌های وزن مخصوص ظاهری^۱ خاک (گرم بر سانتی‌متر مکعب)، ظرفیت آب در دسترس^۲ (میلی‌متر آب بر میلی‌متر خاک)، محتوای کربن آلی^۳ (درصد وزنی خاک) و مقادیر رس، سیلت و ماسه (درصد) برای مدل‌سازی هدایت

- 1- Bulk density
- 2- Available water capacity
- 3- Organic carbon content

4- Saturated hydraulic conductivity

و سوم نتایج به هم نزدیک بود. مقادیر ضریب تبیین در بخش آموزش و آزمون باهم نزدیک بود و در سناریوی دوم و سوم هم نزدیک به هم به دست آمد (جدول ۴). گرچه شاخص‌های آماری نشان‌دهنده برتری سناریوی سوم مدل MLP در بخش آموزش و آزمون هست، اما سناریوی دوم نیز اختلاف چندانی با آن ندارد. شکل ۶ پراکنش داده‌های مشاهداتی در مقابل داده‌های برآوردی را برای بخش آزمون سناریوی دوم و شکل ۷ نیز برای سناریوی برتر (سناریوی سوم) نشان می‌دهد. امامزاده و همکاران و کروک و همکاران در تخمین هدایت هیدرولیکی اشباع با مدل MLP به نتایج مشابهی دست‌یافته‌اند (Emamzadeh et al., 2017; Kruk et al., 2017).

(سناریوی سوم) نشان می‌دهد. نتایج به‌دست‌آمده از مدل SVM در این تحقیق با نتایج کار تیواراکاوی و همکاران، الیسی، مادی و شین همخوانی داشت. همچنین در تحقیق مادی و شین ترکیب ورودی‌ها با این تحقیق مشابه بوده است (Twarakavi et al., 2009; Elbisy, 2015; Mady and Shein, 2018).

نتایج مدل MLP

بر اساس نتایج به‌دست‌آمده از مدل MLP هر سه سناریوی طراحی‌شده، عملکرد خوبی در بخش آموزش و آزمون داشتند. مقادیر خطای MBE و RMSE مقادیر قابل‌قبول بوده و در سناریوهای دوم

جدول ۱- مشخصات آماری داده‌های بکار رفته در مدل‌ها


شاخص‌های آماری				متغیرها	مجموعه داده‌ها
انحراف معیار	کمینه	بیشینه	میانگین		
۰/۱۸	۰/۱	۱/۹	۱/۳۳	وزن مخصوص ظاهری	آموزش
۰/۰۴۵	۰	۰/۱۷۵	۰/۱۲۵	ظرفیت آب در دسترس	
۳/۷۱	۰/۲	۴۷/۳	۱/۹۳	محتوای کربن آلی	
۲/۶۷	۱۰	۲۸	۳۲/۴۱	مقدار رس (%)	
۴/۸۵	۲۸	۴۹	۳۶/۲۳	مقدار سیلت (%)	
۵/۳۱	۲۶	۵۱	۴۱/۴۳	مقدار ماسه (%)	
۸/۴۵	۰/۹۵	۳۹/۴۱	۱۰/۲۶	هدایت هیدرولیکی اشباع	
۰/۱	۱	۱/۵	۱/۲۱	وزن مخصوص ظاهری	آزمون
۰/۰۰۳	۰/۱۷۵	۰/۲	۰/۱۷۶	ظرفیت آب در دسترس	
۲/۵۳	۰/۴	۱۵/۸	۲/۵۴	محتوای کربن آلی	
۳	۱۲	۲۷	۲۱/۷۲	مقدار رس (%)	
۵/۴۸	۲۸	۴۹	۳۶/۵۳	مقدار سیلت (%)	
۵/۷۴	۲۶	۵۱	۴۱/۷۸	مقدار ماسه (%)	
۸/۴۷	۷/۵۵	۳۹/۰۱	۱۶/۷۵	هدایت هیدرولیکی اشباع	

جدول ۲- سناریوهای در نظر گرفته‌شده جهت مدل‌سازی

سناریو	متغیرهای ورودی	پارامتر شبیه‌سازی
سناریوی اول	وزن مخصوص ظاهری، محتوای کربن آلی	هدایت هیدرولیکی اشباع
سناریوی دوم	وزن مخصوص ظاهری، محتوای کربن آلی، مقدار ماسه	هدایت هیدرولیکی اشباع
سناریوی سوم	وزن مخصوص ظاهری، ظرفیت آب در دسترس، محتوای کربن آلی، مقدار رس و سیلت و ماسه	هدایت هیدرولیکی اشباع

جدول ۳- ارزیابی شاخص‌های آماری سناریوهای مدل SVM


شاخص‌های آماری			سناریو	مجموعه داده‌ها
RMSE	MBE	R ²		
۵/۴۶۵	-۰/۹۱۶	۰/۷۷۲	سناریوی اول	آموزش
۵/۳۵۳	-۱/۰۶۹	۰/۷۸۴	سناریوی دوم	
۵/۱۸۵	-۱/۰۴۵	۰/۷۹۹	سناریوی سوم	
۵/۶۹۷	-۲/۵۶۶	۰/۹۱۳	سناریوی اول	آزمون
۶/۰۳۵	-۳/۰۵	۰/۹۳	سناریوی دوم	
۵/۳۸۱	-۲/۳۴۲	۰/۹۵۶	سناریوی سوم	




شکل ۵- پراکنش داده‌های مشاهده‌ای و برآوردی برای هدایت هیدرولیکی اشباع خاک در سناریوی برتر SVM

جدول ۴- ارزیابی شاخص‌های آماری سناریوهای مدل MLP

شاخص‌های آماری			سناریو	مجموعه داده‌ها
RMSE	MBE	R ²		
۳/۰۷۴	-۰/۴۴۹	۰/۹۳۷	سناریوی اول	آموزش
۱/۸۸۹	-۰/۴۳۸	۰/۹۸۴	سناریوی دوم	
۰/۶۸۳	۰/۳۱۹	۰/۹۹۸	سناریوی سوم	
۳/۴۷۳	-۰/۳۸۴	۰/۹۱۴	سناریوی اول	آزمون
۲/۷۱	۰/۹۰۶	۰/۹۶	سناریوی دوم	
۱/۱۸۸	۰/۲۴۸	۰/۹۹۱	سناریوی سوم	



شکل ۶- پراکنش داده‌های مشاهده‌ای و برآوردی برای هدایت هیدرولیکی اشباع خاک در سناریوی دوم MLP



شکل ۷- پراکنش داده‌های مشاهده‌ای و برآوردی برای هدایت هیدرولیکی اشباع خاک در سناریوی برتر MLP

نتایج مدل M5



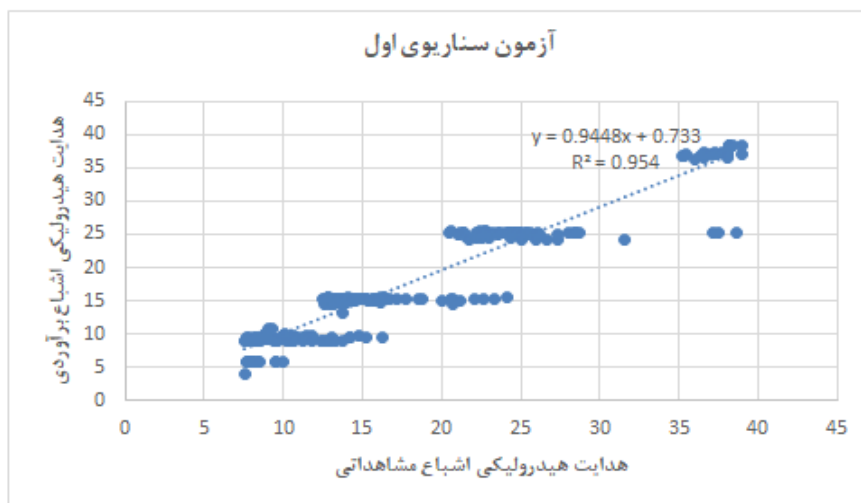
بر اساس نتایج به‌دست‌آمده از مدل MLP هر سه سناریوی طراحی‌شده، عملکرد خوبی در بخش آموزش و آزمون داشتند. مقادیر خطای MBE و RMSE مقادیر قابل قبول بوده و نتایج به‌دست‌آمده در سناریوها به هم نزدیک است. مقادیر ضریب تبیین هم در بخش آموزش و آزمون باهم نزدیک هستند (جدول ۵). گرچه شاخص‌های آماری نشان‌دهنده برتری سناریوی سوم مدل MLP در بخش آموزش و آزمون هست، اما سناریوی اول و دوم نیز اختلاف چندانی با آن ندارند. شکل ۸ پراکنش داده‌های مشاهده‌ای در مقابل داده‌های برآوردی را برای بخش آزمون سناریوهای مدل M5 نشان می‌دهد. بر اساس شکل ۸ پراکنش داده‌ها نشان‌دهنده برتری نسبی سناریوی سوم بر سناریوی اول و دوم است. تحقیقات سپهاگ و همکاران نیز مؤید نتایج به‌دست‌آمده از مدل M5 در پیش‌بینی هدایت هیدرولیکی خاک می‌باشد (Sihag et al., 2019).

نتیجه‌گیری

هدایت هیدرولیکی اشباع خاک یک پارامتر ورودی کلیدی موردنیاز در اکثر مدل‌سازی‌های هیدرولوژیکی است. با توجه به محدودیت روش‌های مستقیم در اندازه‌گیری خصوصیات هیدرولیکی خاک، از جمله تغییرپذیری زیاد مکانی و زمانی، آزمایش وقت‌گیر، خطاهای بهره‌برداری و هزینه‌های بالای اندازه‌گیری، روش‌های تخمین غیرمستقیم از خصوصیات هیدرولیکی در سال‌های اخیر موردتوجه بسیاری قرار گرفته است. این تحقیق به‌صورت مشخص برای ارزیابی مدل‌های هوشمند در پیش‌بینی هدایت هیدرولیکی اشباع خاک‌های لومی بر اساس خصوصیات فیزیکی خاک انجام شده است. به‌طور خاص الگوریتم‌های داده‌کاوی SVM، MLP و M5 به‌صورت جداگانه مورد ارزیابی و آزمایش قرار گرفتند.

جدول ۵- ارزیابی شاخص‌های آماری سناریوهای مدل M5

شاخص‌های آماری			سناریو	مجموعه داده‌ها
RMSE	MBE	R ²		
۱/۶۵۱	۰/۱۲۵	۰/۹۸۱	سناریوی اول	آموزش
۱/۳۰۷	۰/۱۷	۰/۹۸۸	سناریوی دوم	
۰/۷۶۳	۰/۲۴۴	۰/۹۹۷	سناریوی سوم	
۲/۵۶۲	-۰/۱۹۲	۰/۹۵۴	سناریوی اول	آزمون
۲/۲۴۸	-۰/۰۶۶	۰/۹۶۴	سناریوی دوم	
۰/۹۳۵	۰/۳۸۴	۰/۹۹۵	سناریوی سوم	



شکل ۸- پراکنش داده‌های مشاهده‌ای و برآوردی برای هدایت هیدرولیکی اشباع خاک در سناریوی برتر M5

- در پیش‌بینی برخی خصوصیات خاک (مطالعه موردی: استان گلستان)، مجله تحقیقات آب و خاک، (۴۱): ۲۱۱-۲۲۰.
- عزیزپور، س.، فتحی، پ. و نوبخت و کیلی، ک. ۱۳۹۱. برآورد توأم هدایت هیدرولیکی اشباع خاک و تخلخل مؤثر با استفاده از رویکرد مسأله معکوس هوشمند، مجله علوم و فنون کشاورزی و منابع طبیعی. ۱۶ (۶-): ۱۳-۲۲.
- Al-Dosary, N.M., Al-Sulaiman, M.A. and Aboukarima, A.M. 2019. Modelling the unsaturated hydraulic conductivity of a sandy loam soil using Gaussian process regression, *Water SA*. 45 (1): 121-130.
- Amer, A.M., Logsdon, S.D., and Davis, D. 2009. Prediction of hydraulic conductivity in unsaturated soils. *Soil Science*. 174 (9): 508-515.
- Asadollahzadeh, T., Mashal, M. and Karimzadgan, S. 2014. Investigating the Precision of Hydraulic Conductivity and Sorptive Number Estimation in Cased Boreholes by Reynolds Analysis: The Cased of Pakdasht Region, *Journal of Water and Soil*. 28(4):708-716.
- Elbisy, M.S. 2015. Support Vector Machine and regression analysis to predict the field hydraulic conductivity of sandy soil. *KSCE Journal Civil Engineering*. 19 (7): 2307-2316.
- Emamzadeh, S., Soltani, A. S. J., Mashal, M., and Kalanaki, M. 2014. Comparison of RBF and MLP neural network performance to estimate the saturated hydraulic conductivity. *Second National Conference on Sustainable Agriculture and Natural Resources*.
- Emamzadeh, E.S., Soltani, J., Mashal, M., Kalanaki, M. and Asadolahzadeh, T. 2017. Performance evaluation of MLP and RBF neural networks to estimate the soil saturated hydraulic conductivity, *Modern Applied Science*. 11(3):1-12.
- Greg, A. 2003. Temporal and spatial (down profile) variability of unsaturated soil hydraulic properties determined from a combination of repeated field experiments and inverse modeling. *Journal of Hydrology*. 281: 23-35.
- Haykin, S. 1999. *Neural Networks: A Comprehensive Foundation*. Prentice-Hall Inc., NJ.
- Koorevaar, P., Menelik, G. and Dirksen, C. 1983. *Elements of soil physics*. Elsevier, New York, 228 p.
- Kruk, E., Malec, M., Klatka, S., Brodzińska-Cygan, A. and Kołodziej, J. 2017. Pedotransfer function for determining saturated hydraulic conductivity using Artificial Neural Network, *Acta Scientiarum Polonorum Formatio Circumiectus*. 16(4): 115-126.
- Mady, A.Y. and Shein, E.V. 2018. Support Vector Machine and Nonlinear Regression Methods for

در ارزیابی مدل‌ها، در مدل SVM سناریو سوم دارای ضریب تبیین ۰/۹۵۶ و RMSE برابر با ۵/۳۸۱ بهترین سناریوی مدل مذکور شد. در مدل MLP نیز سناریوی سوم با ضریب تبیین ۰/۹۹۱ و RMSE برابر با ۱/۱۸۸ بهترین سناریوی مدل شناخته شد. هرچند نتایج تحلیلی نشان از عملکرد خوب همه مدل‌های مورد آزمایش دارند و می‌تواند دقت پیش‌بینی خوبی داشته باشند اما ارزیابی سناریوی سوم مدل M5 نشان داد این مدل با ضریب تبیین ۰/۹۹۵ و RMSE برابر با ۰/۹۳۵ به‌عنوان بهترین مدل به لحاظ پیش‌بینی هدایت هیدرولیک اشباع است. بر اساس تحقیق موسوی و سپاسخواه پارامترهای سیلت، رس، ماسه، وزن ظاهری و مواد آلی خاک مؤثرترین متغیرهای ورودی مدل بوده‌اند (Moosavi and Sepaskhah, 2012)، اما بر اساس تحقیق حاضر مؤثرترین پارامترهای ورودی وزن ظاهری و مواد آلی خاک بوده است که سناریوها بر اساس مؤثرترین ورودی‌ها طراحی شده‌اند. هرچند دو پارامتر ورودی در هر دو تحقیق مشترک هستند اما ترتیب آنها یکسان نیست. نتایج حاصل از این تحقیق در تمامی مدل‌ها نشان داد که سناریوی سوم که ورودی آن تمامی پارامترهاست نتیجه بهتری در آن مدل به دست می‌آورد که این موضوع مؤید تحقیقات تایفور و همکاران است (Tayfur et al., 2014). الدوساری و همکاران در استفاده از شبکه MLP برای پیش‌بینی هدایت هیدرولیکی خاک نتایج مشابهی برای آن مدل گرفتند (Al-Dosary et al., 2019). پس از مقایسه مطالعه حاضر با نتایج تحقیقات انجام شده در این رابطه، با وجود ظرفیت نشان داده‌شده از استفاده از مدل‌های داده‌کاوی هوشمند برای پیش‌بینی هدایت هیدرولیکی اشباع در خاک لومی، تحقیقات آینده می‌تواند این رویکرد را برای مطالعه سایر متغیرها در زمینه مدیریت آب و انتقال املاح در خاک‌هایی که امکان اندازه‌گیری آسان وجود ندارد، اتخاذ نماید.

منابع

- پوررضا بیلندی، م. و خاشعی سیوکی، ع. ۱۳۹۴. تحلیل عدم قطعیت خروجی شبکه عصبی در شبیه‌سازی هدایت هیدرولیکی اشباع خاک، نشریه آبیاری و زهکشی ایران. ۹ (۴): ۶۵۵-۶۶۴.
- حسینی، س.ا. ۱۳۸۸. برآورد و تحلیل دماهای حداکثر شهرستان اردبیل با استفاده از مدل تئوری شبکه‌های عصبی مصنوعی، پایان‌نامه کارشناسی ارشد جغرافیای طبیعی (اقلیم‌شناسی)، دانشگاه محقق اردبیلی.
- سرمدیان، ف.، تقی‌زاده، ر.ا.، عسگری، ح.م.، و اکبرزاده، ا. ۱۳۸۹. مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چندمتغیره

- Sihag, P. 2018. Prediction of unsaturated hydraulic conductivity using fuzzy logic and artificial neural network. *Model. Earth Syst. Environ.* 4 (1): 189–198.
- Sihag, P., Tiwari, N.K. and Ranjan, S. 2017. Prediction of unsaturated hydraulic conductivity using adaptive neuro-fuzzy inference system (ANFIS). *ISH J. Hydraul. Eng.* 1–11.
- Sihag, P., Mohsenzadeh Karimi, S. and Angelaki, A. 2019. Random forest, M5P and regression analysis to estimate the field unsaturated hydraulic conductivity, *Applied Water Science*. 9(129). <https://doi.org/10.1007/s13201-019-1007-8>.
- Tayfur, G., Nadiri, A.A., Moghaddam, A.A. 2014. Supervised intelligent committee machine method for hydraulic conductivity estimation. *Water Resources Management*. 28(4): 1173–1184.
- Tokunaga, T.K. 2009. Hydraulic properties of adsorbed water films in unsaturated porous media. *Water Resour. Res.* 45:W06415.
- Tuller, M., and D. Or. 2001. Hydraulic conductivity of variably saturated porous media: Film and corner flow in angular pore space. *Water Resour. Res.* 37:1257–1276.
- Twarakavi, N.K.C., Simunek, J. and Schaap, M.G. 2009. Development of Pedotransfer Functions for Estimation of Soil Hydraulic Parameters using Support Vector Machines, *Soil Physics*. 73(5): 1443–1452.
- Vapnik, V.N. 1998. *Statistical Learning Theory*, John Wiley, New York.
- Wang, Y., J. Ma, H. Guan, and G. Zhu. 2017. Determination of the saturated film conductivity to improve the EMFX model in describing the soil hydraulic properties over the entire moisture range. *J. Hydrol.* 549:38–49.
- Wang, Y., J. Ma, Y. Zhang, M. Zhao, and W.M. Edmunds. 2013. A new theoretical model accounting for film flow in unsaturated porous media. *Water Resour. Res.* 49:5021–5028.
- Yao, R.J., Yang, J.S., Wu, D.H., Li, F.R., Gao, P., Wang, X.P. 2015. Evaluation of pedotransfer functions for estimating saturated hydraulic conductivity in coastal salt-affected mud farmland. *Journal of Soils and Sediments*. 1–15.
- Estimating Saturated Hydraulic Conductivity, *Moscow University Soil Science Bulletin*. 73(3): 129–133.
- Marcel, G.S., J.L. Feike., T. Martinus., and H. van Genuchten., 1998. *Neural Network Analysis for Hierarchical Prediction of Soil Hydraulic Properties*, Soil Science Society. 62: 847–855.
- Moosavi, A.A. and Sepaskhah, A.R. 2012. Artificial neural networks for predicting unsaturated soil hydraulic characteristics at different applied tensions. *Arch. Agron. Soil Sci.* 58 (2): 125–153.
- Navabian, M., A.M. Liaghat., and M. Homayni., 2004. Prediction of electrical conductivity with neural networks. *International water and soil conference*, Shiraz University. 203–211.
- Neshat, A. and Farhad, M. 2012. A presentation of an experimental model for unsaturated hydraulic conductivity under affection of physical properties of Soil: A case-by-case study of Baghin Plain in Kerman, Iran. *Acad. J. Plant Sci.* 5 (3): 70–75.
- Nosrati, K.F., Movahedi, S.A., Naini, A. Hezar, J., Rishani, Gh. and Dehghani, A. 2012. Using artificial neural networks to estimate saturated hydraulic conductivity from easily available soil properties. *Electronic Journal of Soil Management and Sustainable Production*. 2(1): 95–110.
- Pal, M., Deswal, S. 2009. M5 model tree based modelling of reference evapotranspiration: *HYDROLOGICAL PROCESSES*. 23, P. 1437–1443.
- Reynolds, W. D. and Topp, G. C. 2008. Soil water analyses: Principles and parameters. In M.R. Carter, & E.G. Gregorich (Eds.), *Soil sampling and methods of analysis*. 2nd Ed. CRC Press, Boca Raton, FL. pp. 913–939.
- Rezaei, A. R., Sayad, G. A. Mazloom, M., Jafari N., & M. Shorafa, 2012, Comparison of artificial neural networks and regression pedotransfer functions for predicting saturated hydraulic conductivity in soils of Khuzestan province. *JWSS - Isfahan University of Technology*. 16(60): 107–118.
- Ryel, R.J., M.M. Caldwell, C.K. Yoder, D. Or, and A.J. Leffler. 2002. Hydraulic redistribution in a stand of *Artemisia tridentata*: Evaluation of benefits to transpiration assessed with a simulation model. *Oecologia*. 130:173–184.

Evaluation of Intelligent Models Due to Estimating Saturated Hydraulic Conductivity in Loamy Soils

S Heidari TashehKaboud*¹, M Khoshravesh²

Received: Oct.26, 2020

Accepted: Dec.17, 2020

Abstract

Saturated hydraulic conductivity is one of the main parameters in agricultural and environmental studies that is essential for the estimation and management of water and solute transport in soil. In this research, 1200 series of data related to loamy soils were used to prediction and modeling saturated hydraulic conductivity using soil physical properties such as bulk density, available water capacity, organic carbon content and percent of clay, silt and sand content. From studied data series, 900 series were allocated for use in training models and 300 series for testing models in three designed scenarios. The performance of SVM, MLP and M5 models was evaluated in estimating saturated hydraulic conductivity of loamy soils. The performance of the models was compared using the statistical indices such as coefficient of determination (R^2), root mean square error (RMSE) and mean bias error (MBE). The results showed that all three models used have good ability in saturated hydraulic conductivity modeling, but the M5 model with a high coefficient of determination over 0.95 in all three scenarios and a lower RMSE than other models was selected as the superior model. The results showed that intelligent data mining models make it possible to estimate unknown values based on ready patterns in a database. Therefore, the applied models can be used to predict solute transport in soil and soil physical parameters.

Keywords: Bulk density, Decision tree, Soil physical properties, Solute transport, Water flow in soil,

1- PhD Student in Irrigation and Drainage, Department of Water Science and Engineering, Sari University of Agricultural Sciences and Natural Resources, Iran

2- Associate Professor, Department of Water Science and Engineering, Sari University of Agricultural Sciences and Natural Resources, Iran

(* - Corresponding Author Email: shadiheidari1990@gmail.com)