



دوره ۳۵، شماره ۴، شماره ۱۳۷، زمستان ۱۴۰۱، صفحه‌های ۱۱۶-۱۰۴
شناسه‌ی دیجیتال: 10.22092/wmrj.2022.358213.1461

مقاله‌ی پژوهشی



پژوهش‌های آبخیزداری

مدل‌سازی نفوذپذیری در رده‌های گوناگون بافت خاک با الگوریتم‌های یادگیری در آبخیز کشکان، استان لرستان

لیلی سلیمانی

دانشجوی دکترا، گروه مهندسی مرتع و آبخیزداری، دانشکده‌ی کشاورزی و منابع طبیعی، دانشگاه لرستان

بهرام میردربکوند

دکتری گروه مهندسی مرتع و آبخیزداری، دانشکده‌ی کشاورزی و منابع طبیعی، دانشگاه لرستان

علیرضا سپه‌وند

(نویسنده‌ی مسئول)* استادیار گروه مهندسی مرتع و آبخیزداری، دانشکده‌ی کشاورزی و منابع طبیعی، دانشگاه لرستان

*رایانامه‌ی نویسنده‌ی مسئول: sepahvand.a@lu.ac.ir

تاریخ دریافت: ۱۰ فروردین ۱۴۰۱ تاریخ پذیرش: ۳۱ خرداد ۱۴۰۱

چکیده

نفوذپذیری یکی از مهم‌ترین اجزای چرخه‌ی آب‌شناسی است که نقش مهمی در جریان رودخانه‌یی، تغذیه‌ی آب‌های زیرزمینی، جریان‌های زیرسطحی و سطحی، و کمیت و کیفیت آب‌های زیرزمینی دارد. هدف این پژوهش بررسی تغییرات نفوذپذیری و مدل‌سازی سرعت آن در بافت‌های گوناگون خاک در آبخیز کشکان استان لرستان بود. استوانه‌های دوگانه برای اندازه‌گیری نفوذ به کار برده شد. برای مدل‌سازی از الگوریتم‌های یادگیری GP و SVM (با دو هسته‌ی PUK و RBF)، MLF و RF بهره برده شد. مقایسه‌ی نتیجه‌ی مدل‌های گوناگون و انتخاب بهترین مدل با معیارهای سنجش خطای ریشه‌ی میانگین مربع‌های خطا، ضریب همبستگی و ضریب نش-ساتکلیف انجام شد. نتیجه‌ی ارزیابی نشان داد که بیش‌ترین ضریب کارایی نش-ساتکلیف (۰/۹۸۶۲۲) و کم‌ترین اندازه‌ی خطا (۰/۰۱۷۷) در مدل RF با ضریب همبستگی ۰/۹۹۵۳ بود، که دقت زیادی است. تحلیل حساسیت ویژگی‌های ورودی مدل RF نشان داد که زمان مهم‌ترین ویژگی ورودی در پیش‌بینی سرعت نفوذ خاک برای این مجموعه از داده‌های به‌کاررفته در پژوهش است. نتیجه‌ی این پژوهش نشان داد که نفوذپذیری در بافت‌های گوناگون خاک تغییرپذیر است، و برای مدیریت کردن بهتر تغذیه‌ی سفره‌های آب زیرزمینی باید این سنجه را در نظر گرفت.

واژگان کلیدی: آبخیز کشکان، فرآیند گوسی، لرستان، مدل جنگل تصادفی، مدل‌سازی نفوذپذیری

مقدمه

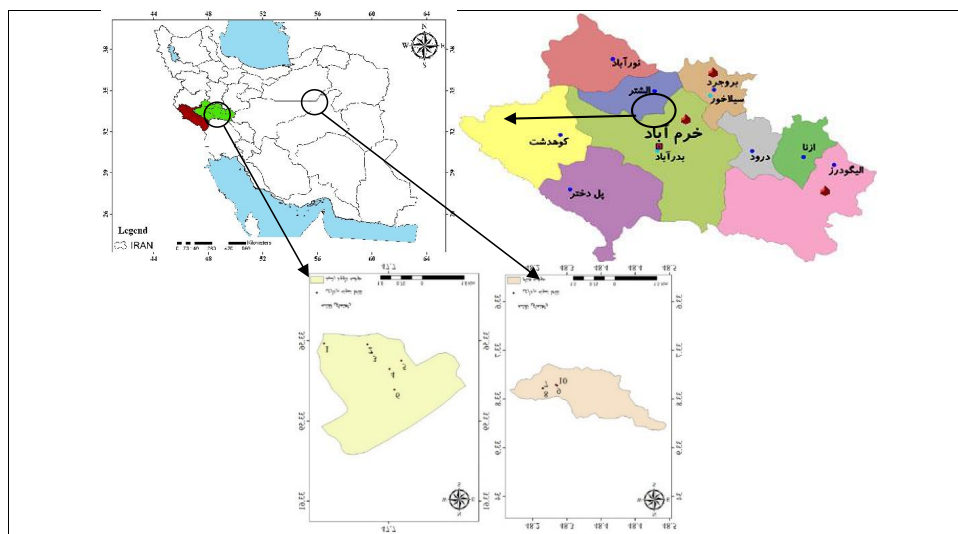
زمان‌بر و پرهزینه است، مدل‌های نفوذپذیری نقش مهمی در مدیریت‌کردن منابع آب دارند، بنابراین نوع‌های گوناگونی از این مدل‌ها با درجه‌های گوناگونی از پیچیدگی برای رسیدن به این هدف ساخته شده‌است (سلیمانی و همکاران ۲۰۱۶). در دهه‌های گذشته وایازی فرآیند گوسی، برنامه‌نویسی بیان ژن، شبکه‌ی عصبی تعمیم‌یافته، ماشین بردار پشتیبان، منطق فازی، سامانه‌ی استنتاج فازی عصبی تطبیقی، و شبکه‌ی عصبی مصنوعی ابزار غالب در حل مشکلات منابع آب بوده‌است. لاله‌ما و همکاران (۲۰۰۵) نشان دادند که پیش‌بینی الگوریتم MLP با کم‌ترین یاخته‌ی عصبی^۱ میانی در ارزیابی سطح آب زیرزمینی بهترین است. نتیجه‌ی شافعی و همکاران (۲۰۱۱) نشان داد که مدل شبکه‌های عصبی مصنوعی بارش اسکندریه مصر را مناسب‌تر و دقیق‌تر از مدل وایازی چندمتغیره پیش‌بینی کرد. سپه‌هاگ و همکاران (۲۰۱۹) در مدل‌سازی اندازه‌ی نفوذ با روش‌های هوش مصنوعی در منطقه‌های نیمه‌خشک غرب ایران نشان دادند که از میان مدل‌های استنتاج عصبی فازی تطبیقی، ماشین بردار پشتیبان، و جنگل تصادفی، ماشین بردار پشتیبان برای مدل‌سازی نفوذ در منطقه مناسب‌ترین است. نتیجه‌ی سپه‌وند و همکاران (۲۰۱۸) در مقایسه‌ی مدل‌های وایازی چندخطی، ماشین بردار پشتیبان، و فرآیند گوسی با دو هسته (پیرسون VII و شعاعی) نشان داد که کارایی ماشین بردار پشتیبان برپایه‌ی پیرسون VII در مدل‌سازی نفوذپذیری بهتر از روش‌های دیگر است. به‌دلیل این نتیجه‌های متفاوت در کارایی روش‌های گوناگون الگوریتم‌های یادگیری، هدف از این پژوهش مدل‌سازی نفوذپذیری در رده‌های گوناگون بافت خاک با الگوریتم‌های یادگیری، در دو زیرآبخیز هنام و داودرشید در آبخیز کشکان استان لرستان بود.

مواد و روش‌ها

ویژگی منطقه‌ی مورد مطالعه

آبخیز رود کشکان یکی از زیرحوزه‌های مهم آبخیز کرخه، در محدوده‌ی ۱۲° ۴۷' تا ۵۹' ۴۸° طول شرقی و ۳۳° ۸' تا ۲' ۳۴° عرض شمالی، در بخش میانی رشته‌کوه زاگرس است (شکل ۱). بر پایه‌ی روش آمبرژه، آبخیز کشکان در اقلیم نیمه مرطوب سرد است (مهدی‌نسب و همکاران ۲۰۱۵).

وضعیت نفوذپذیری خاک نشان‌دهنده‌ی چگونگی عمل‌کرد خاک در برابر آب رسیده به سطح خاک است. این پدیده تعیین‌کننده‌ی سرنوشت آب رسیده به سطح خاک است و اندازه‌ی هدررفت بارش را نیز مشخص می‌کند. نفوذ برای آبیاری کشاورزی، تغذیه‌ی آب زیرزمینی و جریان زیرسطحی، و کیفیت و کمیت آب سطحی و زیرسطحی پایه‌ی است (سینگ و همکاران ۲۰۲۱). دانش نفوذ برای هر پژوهش بادوام و سودمند ارزیابی آب‌شناسی ضروری است (شیری و همکاران ۲۰۱۷). نفوذ در فرآیند آب‌شناسی آب را به دو بخش جریان سطحی و جریان آب زیرزمینی جدا می‌کند. اندازه‌ی نفوذ به ویژگی‌های گوناگونی مانند اندازه‌ی رطوبت، بافت خاک، تراکم، و عمل‌کرد خاک بستگی دارد (آنجلاک و همکاران ۲۰۱۳). رابطه‌های نفوذ را می‌توان به دو دسته‌ی کلی رابطه‌های تجربی و رابطه‌های نظری برپایه‌ی فیزیک نفوذ تقسیم کرد. از جمله رابطه‌های نظری رابطه‌ی فیلپ (۱۹۵۷)، و گرین آمیت (۱۹۱۱)، و از رابطه‌های تجربی رابطه‌های کوستیاکف (۱۹۳۲)، و هورتون (۱۹۴۰) است، که هر یک برتری‌ها و کاستی‌های خاص خود دارد. به‌دلیل وابستگی ضریب‌های معادله‌های نفوذ به نوع خاک و شرایط سطحی زمین، آزمایش‌های میدانی برای اندازه‌گیری اندازه‌ی نفوذ، تعیین مدلی مناسب برای بیان کمی آن، و تعیین ضریب‌های آن در شرایط ویژه‌ی هر منطقه ضروری است. بارش با نفوذ به جریان‌های سطحی و زیرسطحی تقسیم می‌شود. عمل نفوذ از راه خاک از عامل‌های گوناگونی مانند رطوبت پیشین خاک، بافت و نوع خاک، تراکم خاک، هدایت آبی و بارش، و ویژگی‌های آب‌شناسی تأثیر می‌گیرد (سینگ و همکاران ۲۰۱۸؛ آنجلاک و همکاران ۲۰۱۸). آب بارشی زمانی به سیلاب تبدیل می‌شود که شدت بارش از شدت نفوذ بیش‌تر باشد. بنابراین ویژگی نفوذپذیری خاک در کنار سنجه‌هایی مانند نوع پوشش گیاهی و کاربری زمین یکی از مهم‌ترین عامل‌های ایجاد سیلاب در هر حوزه است. پیش‌بینی سیل‌خیزی، فرسایش خاک و جابه‌جایی آلاینده‌ها همگی به اندازه‌ی روان‌آب ایجادشده بستگی دارد، که خود مستقیمانه به نفوذ آب در خاک وابسته است. از آن‌جا که نفوذ آب به خاک یکی از مهم‌ترین اجزای چرخه‌ی آب‌شناسی است و از سوی دیگر، اندازه‌گیری آن دشوار،



شکل ۱- موقعیت جغرافیایی زیرحوزه های هنام و داودرشید روی نقشه ای ایران و استان لرستان.

شود اطلاعات سودمندی از اندازه گیری نفوذ می دهد (وارد و تریمبل ۲۰۰۴). برای افزایش دقت، نفوذپذیری در هر بافت خاک در اندازه های نفوذپذیری، درصد رطوبت خاک به روش وزنی، و جرم مخصوص ظاهری نمونه های خاک به روش استوانه در آزمایشگاه اندازه گیری شد.

روش تحقیق

محل اندازه گیری نفوذ با پیمایش صحرائی و در شرایط مکانی مناسب شناسایی شد. در میان نمونه ها ۴ رده ای خاک رسی، لومی، لای (سیلتی)-لومی^۲، و لای-رسی برای اندازه گیری نفوذ انتخاب شد (جدول ۱). استوانه های دوگانه به کار برده شد (شکل ۲) که شیوهی معمول است، و اگر به درستی به کار برده



شکل ۲- استوانه های نصب شده در محل اندازه گیری.

جدول ۱- بافت خاک و موقعیت جغرافیایی ایستگاه های اندازه گیری.

شماره ای جاها	منطقه	طول جغرافیایی	عرض جغرافیایی	بافت خاک
۱	داودرشید	۴۷° ۴۰' ۵۰/۵"	۳۳° ۳۳' ۴۸/۱"	لومی
۲	داودرشید	۴۷° ۴۱' ۴۰/۵"	۳۳° ۳۳' ۴۹/۱"	لومی
۳	داودرشید	۴۷° ۴۱' ۴۵/۹"	۳۳° ۳۳' ۵۸/۹"	لومی
۴	داودرشید	۴۷° ۴۲' ۶/۵"	۳۳° ۳۴' ۱۷/۶"	لای-لومی
۵	داودرشید	۴۷° ۴۲' ۲۰/۶"	۳۳° ۳۴' ۸/۰۷"	لای-لومی
۶	داودرشید	۴۷° ۴۲' ۱۲/۱۹"	۳۳° ۳۴' ۴۱/۹"	لای-لومی
۷	هنام	۴۷° ۱۵' ۵۵/۸"	۳۳° ۴۷' ۲۵/۳"	رسی
۸	هنام	۴۷° ۱۵' ۵۴/۲"	۳۳° ۴۷' ۵۴/۲"	رسی
۹	هنام	۴۷° ۱۷' ۱۵/۲"	۳۳° ۴۷' ۴۱/۲"	لای-رسی
۱۰	هنام	۴۷° ۱۷' ۲۳/۷"	۳۳° ۴۷' ۶/۸"	لای-رسی

^۲لای-سیلتی

زمان ثابت شدن سرعت نفوذ در بافت‌های گوناگون، پایه‌ی زمانی ۷۰ دقیقه انتخاب شد. نمودارهای نرخ تغییرات سرعت نفوذ نسبت به زمان در هر بافت خاک ترسیم شد. نمودار مرحله‌های انجام پژوهش در شکل ۳ نشان داده شده است.

نتایج تحقیق به دو شیوه‌ی ترسیم نمودار و مقایسه میان اندازه‌های واقعی و تخمینی به دست آمده از مدل‌های گوناگون نفوذ تهیه شد. برای بررسی نموداری نتیجه‌ها ابتدا با تهیه‌ی بانک اطلاعاتی در نرم‌افزار EXCEL 2019 پایه‌ی زمانی مشترکی برای همه‌ی آزمایش‌ها تهیه شد، که به دلیل



شکل ۳- نمودار مرحله‌های انجام پژوهش.

سال ۲۰۰۱ با مدل‌سازی بارش روان آب بود (تسوجانتاریدیس و همکاران ۲۰۰۴)، روشی فراگیر برای حل کردن دشواری‌های رده‌بندی، پیش‌بینی، و وایز است (کورتس و واپنیک ۱۹۹۵). در این مدل از اصل استقرای کمینه‌سازی خطای ساختاری بهره‌گیری، و به پاسخ بهینه‌ی کلی منجر می‌شود (قربانی و دهقانی ۲۰۱۶). برای حل کردن معادله‌ها برنامه‌ریزی دوگانه به کار برده می‌شود. بنابراین، حل کردن مسئله در اندازه‌های بزرگ با این مدل هزینه‌ی محاسبه را به شدت افزایش می‌دهد. هدف اصلی آن کاربرد ابر صفحه‌ی تفکیک‌کننده‌ی خطی است، که فاصله‌ی میان دو رده را برای ایجاد دسته‌بندی بیشینه می‌کند. برای ماشین بردار پشتیبان خطی، داده‌های آموزشی متشکل از N جفت $((x_1, y_1), (x_2, y_2), \dots)$ است که $x_i \in \mathcal{X}$

و $y_i \in \{-1, 1\}, i = 1, \dots, n$ است (رابطه‌ی ۱).

$$\min_{\omega, b, \varepsilon} \frac{1}{2} w^T w + c \sum_{i=1}^n \varepsilon_i \text{ subject } \rightarrow$$

$$y_i (w^T \phi(x_i) + b) \geq 1 - \varepsilon_i, \varepsilon_i \geq 1, \dots, n$$

برای مدل‌سازی نفوذپذیری با الگوریتم‌های یادگیری و تعیین بهترین آن‌ها، مدل‌های فرآیند گوسی^۳ (GP)، شبکه‌ی عصبی پرسپترون چندلایه^۴ (MLP)، ماشین بردار پشتیبان^۵ (SVM)، و جنگل تصادفی^۶ (RF) به کار برده شد. در اجرای مدل‌های GP و SVM دو هسته‌ی Puk و FBF به کار برده شد. داده‌های ورودی برای مرحله‌ی آموزش و آزمایش مدل داده‌های زمان، درصد رطوبت وزنی، درصد رس، درصد لای، درصد شن، و جرم مخصوص ظاهری به کار برده شد و اندازه‌ی سرعت نفوذپذیری، داده‌ی خروجی گرفته شد. در هر یک از ده ایستگاه اندازه‌گیری، ۱۵ داده (در مجموع ۱۵۰ داده) برداشته شد، که بر پایه‌ی زمان اندازه‌گیری ۷۰٪ آن برای مرحله‌ی آموزش و ۳۰٪ آن برای مرحله‌ی آزمایش مدل‌سازی به کار برده شد.

مدل‌های یادگیری

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان که نخستین کاربرد آن در مسائل آب در

از یادگیرنده های قوی تشکیل می دهند. روش جنگل تصادفی با تحلیل حساسیت، اهمیت متغیرها در مدل سازی را نیز نشان می دهد. این روش با کاربرد میانگین کاهش کمینه، می تواند اهمیت متغیرهای به کار رفته در فرآیند مدل سازی را نشان دهد. در روش میانگین کاهش کمینه اندازه های درست متغیرها با اندازه هایی که به طور تصادفی برای هر درخت تولید شد، جایگزین می شود. اگر این جایگزینی اثری بر خطای اندازه گیری نداشته باشد اهمیت آن کم است، و اگر اندازه خطای اندازه گیری افزایش یابد، آن متغیر مهم است (بریمان و کوتلر ۲۰۰۴).

شبکه ی عصبی پرسپترون چند لایه (MLP)

در دهه ی گذشته تمایل به کاربرد شبکه های عصبی مصنوعی در میان آب شناس ها به شدت افزایش یافته است (از جمله هسو و همکاران ۲۰۰۲، توکار و ماکوس ۲۰۰۰، و بسیاری دیگر). همه ی این محققان قدرتمند بودن این روش را برای مدل سازی پدیده های گوناگون به ویژه پدیده های ناخطی ثابت کرده اند. از جمله ساختارهای مهم شبکه های عصبی، پرسپترون چند لایه (MLP) با الگوریتم پس انتشار خطا است. این الگوریتم به خوبی می تواند تابع های دل خواه را تقریب کند (گومز و همکاران ۲۰۰۲). مبانی نظری این الگوریتم همان مبانی نظری روش های معمول بر پایه ی مشتق های جزئی گوس-نیوتون و نیتون-رافسون است. در این شبکه یک لایه ی ورودی برای به کار بستن ورودی های مسئله، یک لایه ی پنهان، و یک لایه ی خروجی که سرانجام پاسخ های مسئله را می دهد، به کار برده می شود. برای کار با شبکه ی عصبی مصنوعی ابتدا باید ویژگی های تاثیر گزار بر خروجی، در جایگاه لایه های ورودی و ورودی به شبکه داده شود، و سپس تعدادی جاهای آموزشی به شبکه داده شود تا شبکه با آن-ها اندازه ی تاثیر هر لایه ی ورودی را مشخص کند (دیاز و همکاران ۲۰۱۸) (شکل ۴).


$\omega \in m$ وزن نمونه های آموزشی است، b ثابت است، C ویژگی هزینه ی ارزش گذاری شده ی واقعی، و \hat{y}_i ویژگی کمکی است. اگر $\varphi(x_i) = x_i$ باشد، ماشین بردار پشتیبان ابر صفحه ی تفکیک خطی با حاشیه ی بیشینه پیدا می کند. در حالتی که ماشین بردار پشتیبان نقشه ی φ و x_i را بر فضای بعدی بالاتر می گزارد، ناخطی می شود.

فرآیند گوسی (GP)

فرآیند گوسی روش یادگیری ماشینی ناسنجه ی قوی برای ایجاد مدل های احتمال گرایانه ی جامع از مسائل دنیای واقعی است. فرآیند گوسی تصادفی است، و متشکل از اندازه های تصادفی در هر نقطه در دامنه ی زمانی یا مکانی است، به طوری که پراکندگی هر متغیر تصادفی بهنجار است. به علاوه، پراکندگی هر مجموعه ی محدود از این متغیرهای تصادفی بهنجار چندمتغیره است. فرآیندهای گوسی پراکندگی های گوسی چندمتغیره را به مقیاس نامحدود گسترش می دهد. فرآیند گوسی داده هایی تولید می کند که در طول این طیف است، به طوری که هر زیرمجموعه ی متناهی دامنه ی توزیع گوسی چندمتغیره یی را دنبال می کند (اسدی و همکاران ۲۰۱۷).

مدل جنگل تصادفی (RF)

مدل جنگل تصادفی روش یادگیرنده ی فعال است (بریمان ۲۰۰۱) و گسترش یافته ی مدل رده بندی و وایازی درختی (CART) است، که برای به دست آوردن ارتباط میان متغیر پاسخ و متغیرهای مستقل و تخمین زدن، داده ها را به شیوه ی تکراری جداسازی می کند. در این روش یادگیری که گروهی است، برخلاف دیگر روش های درختی که تنها چند درخت ترسیم می کنند، صدها یا هزاران درخت رده بندی تولید می شود (بریمان و کوتلر ۲۰۰۴). پایه ی روش های یادگیرنده ی گروهی این است که گروهی از یادگیرنده های ضعیف، مجموعه هایی




شکل ۴- شبکه ی عصبی پرسپترون چند لایه (MLP).

و وزن میان لایه‌ی میانی و خروجی با روش‌های کاهش شیب و واپازی خطی تعیین می‌شود. یکی از تفاوت‌های شبکه‌ی پرسپترون چندلایه و تابع‌های پایه‌ی شعاعی این است که در شبکه‌ی پرسپترون چندلایه، مجموع وزن‌دار یاخته‌های عصبی رسیده به یاخته‌ی عصبی لایه‌ی میانی ورودی تابع‌های تحریک گرفته می‌شود، ولی در شبکه‌های تابع‌های پایه‌ی شعاعی فاصله‌ی هر الگو با بردار مرکز هر یاخته‌ی عصبی در لایه‌ی میانی ورودی تابع تحریک شعاعی است (شکل ۵)

شبکه‌های تابع پایه‌ی شعاعی (RBF)

شبکه‌های تابع پایه‌ی شعاعی از نوع شبکه‌های پیش‌رو همراه با یک لایه‌ی میانی است که در آن اغلب تابع جابه‌جایی در لایه‌ی میانی و تابع گوسین در لایه‌ی خروجی تابع خطی است (دبیاک و همکاران ۱۹۹۹). آموزش آن به دو بخش تقسیم می‌شود. بخش اول یادگیری بی نظارت است که در آن سنجه‌های تابع‌های پایه به روش‌های خوشه‌بندی با اطلاعات ورودی تعیین می‌شود. بخش دوم یادگیری با نظارت است،



شکل ۵- ساختار شبکه‌ی عصبی تابع‌های پایه‌ی شعاعی (RBF).

F اندازه‌ی برآوردشده، H اندازه‌ی مشاهده‌شده، میانگین اندازه‌های مشاهده‌شده، و n تعداد داده‌های اندازه‌گیری نفوذ است.

نتایج

با داده‌های اندازه‌گیری‌شده و برپایه‌ی اثر رطوبت پیشین بر ویژگی‌های گوناگون نفوذپذیری، ویژگی‌هایی مانند نفوذ تجمعی، بیشینه‌ی سرعت نفوذ، سرعت نفوذ نهایی و زمان تا لحظه‌ی تثبیت نفوذپذیری محاسبه شد. شکل ۶ روند تغییرات سرعت نفوذ در بافت‌های گوناگون خاک، و جدول ۲ نتیجه‌ی شناسایی بافت خاک، درصد رطوبت، وزن مخصوص، و اندازه‌ی نفوذ اولیه و نهایی را در ایستگاه‌های گوناگون نمونه‌برداری نشان می‌دهد. بیش‌ترین و کم‌ترین نفوذ تجمعی ۸/۵۳ و ۲/۶۸ در بافت‌های لای-رسی و لای-لومی بود. بیشینه‌ی سرعت نفوذ در بافت لای-رسی (۹۱/۲ سانتی‌متر در ساعت)، و کمینه‌ی آن در خاک لومی (۲۴ سانتی‌متر در ساعت) بود. زمان تا لحظه‌ی تثبیت نفوذ در خاک لومی، لای-لومی، رس، و لای-رسی به ترتیب ۰/۵، ۰/۵۸، ۰/۴۲ و ۰/۴۲ ساعت بود.

معیارهای سنجش خطا


برای ارزیابی دقت مدل‌های نفوذ ریشه‌ی میانگین مربع‌های خطا، ضریب ناش-ساتکلیف، و ضریب همبستگی به کار برده شد. مدلی که ضریب همبستگی آن بیش‌تر، ریشه‌ی میانگین مربع‌های خطای آن نزدیک به صفر، و ضریب ناش-ساتکلیف آن بیش‌تر باشد مدل مناسب‌تری برای آگاهی از اندازه‌ی نفوذپذیری در رده‌های گوناگون بافت خاک است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (H - F)^2} \quad (2)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (H - F)^2}{\sum_{i=1}^n (H - \bar{H})^2} \quad (3)$$

$$CC = \frac{n \sum HF - (\sum H)(\sum F)}{\sqrt{n(\sum H^2) - (\sum H)^2} \sqrt{n(\sum F^2) - (\sum F)^2}} \quad (4)$$

مدل سازی نفوذپذیری در رده های گوناگون بافت خاک با الگوریتم های...



شکل ۶- آهنگ تغییرات سرعت نفوذ در شرایط گوناگون بافت خاک.

جدول ۲- نفوذ اولیه و نهایی اندازه گیری شده به همراه ویژگی های خاک.

شماره ایستگاه ها	شن (%)	رس (%)	لای (سیلت) (%)	رطوبت (%)	جرم مخصوص (g/cm^3)	نفوذ نهایی (cm/min)	نفوذ اولیه (cm/min)	بافت خاک	میانگین نفوذ تجمعی* (cm)	زمان تا لحظه ی تثبیت نفوذ (hr)
۱	۳۰	۲۶	۴۴	۲/۴۳	۱/۳۶	۰/۲۸	۰/۶۴	لومی	۴/۱۹	۰/۵
۲	۲۶	۲۵	۴۹	۲/۳۷	۱/۴۴۸	۰/۲	۰/۵۶			
۳	۳۳	۱۶	۵۱	۲/۴۸	۱/۴	۰/۲	۰/۶			
۴	۲۰	۱۸	۶۲	۲/۴۸	۱/۰۸	۰/۰۸	۰/۱۲	لای** لومی	۲/۶۸	۰/۵۸
۵	۱۷	۲۸	۵۵	۲/۸۴	۱/۳	۰/۲۴	۰/۱۸			
۶	۱۹	۱۶	۶۵	۲/۲۴	۱/۲۷	۰/۱	۰/۴۴	رسی	۶/۰۸	۰/۴۲
۷	۱۱	۵۲	۳۷	۲/۴۲	۱/۵۶	۰/۶	۰/۹			
۸	۹	۵۷	۳۴	۲/۳۸	۱/۵۹	۰/۱۲	۰/۳۶			
۹	۶	۵۰	۴۴	۲/۳	۱/۴۶	۰/۳۸	۱/۴۸	لای-رسی	۸/۵۳	۰/۴۲
۱۰	۲۱	۴۲	۳۷	۲/۳	۱/۴۸	۰/۳۸	۱/۵۶			

* در ۷۰ دقیقه
** لای-سیلتی

ویژگی ورودی زمان، درصد رطوبت، درصد رس، درصد لای، درصد شن، و جرم مخصوص ظاهری به کار برده شد، و خروجی مدل ها سرعت نفوذپذیری گرفته شد (جدول ۳).

برای مدل سازی و تخمین اندازه ی نفوذپذیری بافت های گوناگون خاک با الگوریتم های یادگیری GP-PUK، GP، SVM-PUK، SVM-RBF، MLP، RBF، RF و شش

جدول ۳- ویژگی های آماری داده های مرحله ی آموزش و آزمایش.

آموزش								ویژگی
سرعت نفوذ (cm/min)	جرم مخصوص ظاهری (gr/cm^3)	رطوبت (%)	لای (سیلت) (%)	رس (%)	شن (%)	زمان (min)		
۰/۱	۱/۱	۲/۲	۳۴	۱۶	۶	۲/۵	کمینه	
۱/۶	۱/۶	۳/۸	۶۵	۵۷	۳۳	۴۵	بیشینه	
۰/۴	۱/۴	۲/۵	۴۷/۸	۳۳	۱۹/۲	۲۲/۸	میانگین	
۰/۳	۰/۱	۰/۴	۱۰/۱	۱۵/۱	۸/۵	۱۴/۱	انحراف معیار	
آزمایش								
سرعت نفوذ (cm/min)	جرم مخصوص ظاهری (gr/cm^3)	رطوبت (%)	لای (سیلت) (%)	رس (%)	شن (%)	زمان (min)		
۰/۱	۱/۱	۲/۲	۳۴	۱۶	۶	۵۰	کمینه	
۰/۶	۱/۶	۳/۸	۶۵	۵۷	۳۳	۷۰	بیشینه	
۰/۳	۱/۴	۲/۵	۴۷/۸	۳۳	۱۹/۲	۶۰	میانگین	
۰/۲	۰/۱	۰/۴	۱۰/۲	۱۵/۱	۸/۵	۷/۱	انحراف معیار	

نتیجه‌ی ضریب‌های بهینه‌ی مدل‌ها در جدول ۴ نشان داده شده‌است، که با روش آزمون‌وخطا تعیین شد، و نتیجه‌ی نهایی مدل‌سازی و تخمین نفوذپذیری بر پایه‌ی این ویژگی‌ها انجام شد.

جدول ۴- ضریب‌های بهینه‌ی مدل‌ها.

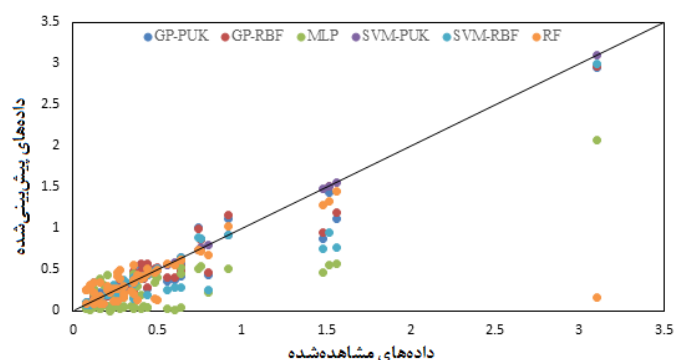
ضریب‌های بهینه	مدل
Gaussian noise = 0.1, $\omega=2$, $\sigma=1$	GP-PUK
Gaussian noise = 0.03, $\Upsilon=3$	GP-RBF
Lr=0.3, M=0.2	MLP
C=2, $\omega=0.08$, $\sigma=1$	SVM-PUK
C=8, $\Upsilon=2$	SVM-RBF
K=0, M=1	RF

و بیش‌ترین اندازه‌ی میانگین مربع‌های خطا ضعیف‌ترین مدل بود (جدول ۵). شکل‌های ۷ و ۸ نمودار تغییرات داده‌های مشاهده‌شده و پیش‌بینی شده‌ی مدل‌های GP، SVM، MLP، RF را در مرحله‌ی آموزش و آزمایش برای بافت‌های گوناگون خاک نشان می‌دهد.

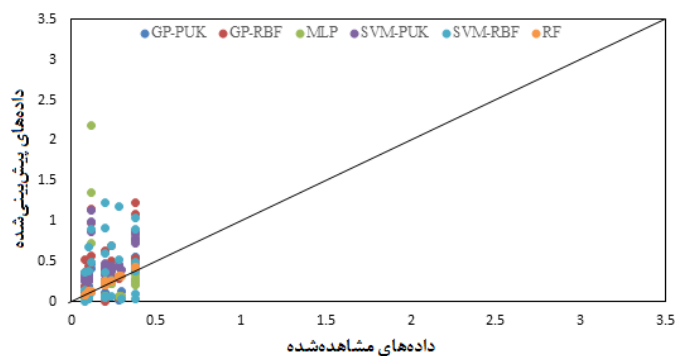
ابتدا مدل RF با ضریب همبستگی ۰/۹۹۱۲، ناش-ساتکلیف (۰/۹۸۶۲) و کم‌ترین ریشه‌ی میانگین مربع‌های خطا (۰/۱۰۱۷۷)، و پس از آن MLP با ضریب کارآیی ۰/۹۵۶۱ و ریشه‌ی میانگین مربع‌های خطای ۰/۵۵۸۶ بهترین عمل کرد در تخمین‌زدن اندازه‌ی نفوذپذیری خاک داشت (جدول ۵). مدل SVM با هسته‌ی PUK با کم‌ترین ضریب همبستگی

جدول ۵- نتیجه‌ی ارزیابی عمل‌کرد مدل‌های GP، SVM، MLP، RF.

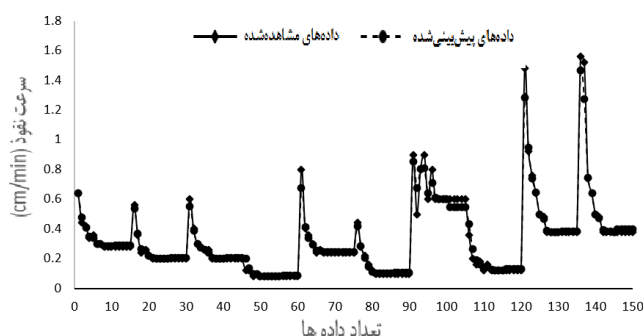
آزمایش			آموزش			
NSE	RMSE	C.C	NSE	RMSE	C.C	
۰/۸۸۱۷	۱/۱۷۴۴	۰/۵۷۸۰۲	۰/۹۸۸۳	۰/۱۴۷۲	۰/۹۷۵۴	GP-PUK
۰/۹۵۱۲	۰/۶۹۱۲	۰/۸۵۳۸	۰/۹۹۱۴	۰/۱۲۳۴	۰/۹۸۲۷	GP-RBF
۰/۹۵۶۱	۰/۵۵۸۶	۰/۹۰۴۵	۰/۹۴۷۸	۰/۴۱۲۲	۰/۸۰۷۱	MLP
۰/۶۱۵۲	۱/۶۴۴	۰/۱۷۲۵	۰/۹۹۹۹	۰/۰۰۵۲	۰/۹۹۹۹	SVM-PUK
۰/۸۱۷۴	۱/۵۲	۰/۲۹۲۳	۰/۹۷۵۸	۰/۲۲۶۷	۰/۹۴۱	SVM-RBF
۰/۹۸۶۲	۰/۰۱۷۷	۰/۹۹۵۳	۰/۹۹۲۹	۰/۰۴۵۱	۰/۹۹۱۲	RF



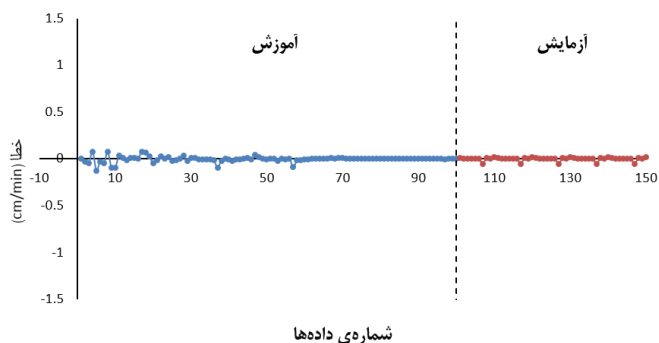
شکل ۷- نمودار تغییرات داده‌های مشاهده‌شده و پیش‌بینی شده‌ی مدل‌های GP، SVM، MLP، RF و ReepTree در مرحله‌ی آموزش.



شکل ۸- نمودار تغییرات داده‌های مشاهده‌شده و پیش‌بینی‌شده‌ی مدل‌های GP، SVM، MLP، RF در مرحله‌ی آزمایش.



شکل ۹- نمودار کارآیی مدل RF در مرحله‌ی آموزش و آزمایش.



شکل ۱۰- نمودار تغییرات خطا در مرحله‌ی آموزش و آزمایش.

پایه‌ی ویژگی‌های باقی‌مانده اجرا می‌شود، و سرانجام برای هر مرحله معیارهای سنجش خطای CC ، $RMSE$ و NSE تعیین می‌شود. مشخص شد که زمان نقش مهمی در پیش‌بینی/تخمین اندازه‌ی نفوذپذیری بافت‌های گوناگون خاک در مقایسه با دیگر ویژگی‌های ورودی دارد (جدول ۶).

تحلیل حساسیت برای یافتن ویژگی‌های ورودی مهم در تخمین سرعت نفوذپذیری در بافت‌های گوناگون خاک انجام شد. مدل RF با بهترین عمل‌کرد با این مجموعه‌ی داده بود. برای تحلیل حساسیت مدل روش حذفی به کار برده‌شد. ویژگی‌های ورودی یکی‌یکی حذف می‌شود، مدل بر

جدول ۶- تحلیل حساسیت مدل RF.

RMSE	NSE	C.C	ویژگی حذف شده	تحلیل حساسیت
۰/۰۱۷۷	۰/۹۸۶۲۲	۰/۹۹۵۳	-	T, C, Si, Sa, B, W
۰/۱۶۲۲	۰/۹۹۱۹۵	۰/۹۹۶۲	t	C, Si, Sa, B, W
۰/۱۰۵۷	۰/۹۹۶۵۸	۰/۹۹۹	c	T, Si, Sa, B, W
۰/۱۱۰۱	۰/۹۹۶۳	۰/۹۹۸۵	si	T, C, Sa, B, W
۰/۰۹۴۱	۰/۹۹۷۲۹	۰/۹۹۹۳	sa	T, C, Si, B, W
۰/۰۸۲	۰/۹۹۷۹۴	۰/۹۹۹۶	B	T, C, Si, Sa, W
۰/۱۱۴۱	۰/۹۹۶۰۲	۰/۹۹۸۷	W	T, C, Si, Sa, B

T: زمان، W: درصد رطوبت، C: درصد رس، Si: درصد لای، Sa: درصد شن، B: جرم مخصوص ظاهری
* لای= سیلت

بحث و نتیجه‌گیری

نفوذ آب به خاک فرآیند اولیه‌ی ورود آب از سطح خاک به درون ناحیه‌ی اشباع‌نشده‌ی خاک، و یکی از اجزای اصلی چرخه‌ی آب‌شناسی است. کمی کردن نفوذ آب به خاک در مدیریت حوزه‌های آبخیز اهمیت بسیار زیادی دارد، زیرا نفوذ مهم‌ترین ویژگی خاک از دیدگاه ذخیره‌ی بارش‌ها و کشاورزی است. بنابراین پیش‌بینی اندازه‌ی نفوذپذیری خاک در طراحی‌های آب-شناسی، آبخیزداری، آبیاری و پژوهش‌های کشاورزی ضروری است. نفوذ آب به خاک مهم‌ترین منبع تامین‌کننده‌ی آب برای زندگی گیاهان است و نقشی پایه‌ی در مهار آب‌های سطحی و زیرزمینی دارد. بنابراین دست‌یابی به مدل بهینه‌ی که بتواند با دقت پذیرفتنی، اندازه‌ی نفوذپذیری خاک را تخمین بزند، اهمیت ویژه‌ی دارد، و ابزاری برای ارزیابی دشواری‌های محیطی و کشاورزی است. بر این پایه، هدف از انجام این تحقیق مدل‌سازی اندازه‌ی نفوذپذیری در بافت‌های گوناگون خاک در دو زیرحوزه‌ی هنام و داودرشد در استان لرستان بود. نتایج نشان داد که بیش‌ترین و کم‌ترین نفوذ تجمعی ۸/۵۳ و ۲/۶۸ در بافت‌های سیلتی-رسی و سیلتی-لومی بود. بیشینه‌ی سرعت نفوذ در بافت سیلتی-رسی (۹۱/۲ سانتی‌متر در ساعت)، و کمینه‌ی آن در خاک لومی (۲۴ سانتی‌متر در ساعت) بود. زمان تا لحظه‌ی تثبیت نفوذ در خاک لومی، لای-لومی، رس، و لای-رسی به ترتیب ۰/۵، ۰/۵۸، ۰/۴۲ و ۰/۴۲ ساعت بود. به نظر می‌رسد مقدار رسی که در این خاک‌ها دیده شد نامستقیم عامل مهمی در نفوذپذیری آن‌ها باشد، و از آن‌جا که رس کلویید مهمی در تشکیل شدن خاک‌دانه‌ها و شکل‌دهی ساختمان خاک است، به نظر می‌رسد به‌مانند عاملی اصلاح‌کننده در بافت لای-رسی کار کرده، و باعث تشکیل شدن ساختمان خاک مناسب‌تری شده است، و در نتیجه باعث شده است که نفوذپذیری افزایش یابد. محققان نشان داده‌اند که بافت خاک به‌ندرت به‌تنهایی نفوذ آب به خاک را تنظیم می‌کند، و هدایت آبی خاک بیش‌تر وابسته به ویژگی‌های ساختمانی آن است (یمر و همکاران ۲۰۰۸؛ اوسوجی و همکاران ۲۰۱۰؛

مظاهری و محمودآبادی ۲۰۱۲؛ فیشر و همکاران ۲۰۱۵). این حال بافت خاک اغلب بر ویژگی‌های ساختمانی خاک تاثیر می‌گذارد، و از این رو اثرهای نامستقیمی بر نفوذ آب به خاک دارد (کاردول ۲۰۱۷). یکی از مهم‌ترین ویژگی‌های خاک که با عامل‌های نفوذ زیادی مانند میانگین نفوذ، سرعت نهایی نفوذ، و بیشینه‌ی سرعت نفوذ رابطه‌ی قوی معنی‌دار و مثبت دارد تخلخل خاک است، که ممکن است نقش مهمی در نفوذ دادن آب به خاک داشته باشد (حسنوند و همکاران ۲۰۲۱).

نتیجه‌ی ارزیابی مدل‌سازی نفوذپذیری در بافت‌های گوناگون خاک با الگوریتم‌های یادگیری GP و SVM (با دو هسته‌ی PUK و RBF)، MLF و RF نشان داد که در مدل‌سازی نفوذپذیری توان مدل RF با ضریب کارایی نش ساتکلیف ۰/۹۸۶۲، بیش‌ترین اندازه‌ی ضریب همبستگی ۰/۹۹۵۳، و کم‌ترین ریشه‌ی میانگین مربع‌های خطای ۰/۰۱۷۷ برای مدل‌سازی نفوذپذیری در بافت‌های گوناگون خاک زیاد است، و دقت مدل SVM با هسته‌ی PUK با ضریب کارایی نش ساتکلیف ۰/۶۱۵۲، کم‌ترین ضریب همبستگی ۰/۱۷۲۵، و بیش‌ترین ریشه‌ی میانگین مربع‌های خطای ۱/۶۴۴ کم‌ترین است.

نتیجه‌ی تحلیل حساسیت سنج‌های ورودی مدل برتر RF نشان داد که زمان مهم‌ترین ویژگی ورودی برای پیش‌بینی سرعت نفوذ خاک برای این مجموعه از داده‌ها است، که با نتیجه‌ی سیهاگ و همکاران (۲۰۱۸) در مدل‌سازی نفوذپذیری در منطقه‌ی های داودرشد و هنام لرستان و کلات ایلام هم‌خوانی دارد، اما با نتیجه‌ی سیهاگ و همکاران (۲۰۱۹) که برای اندازه‌گیری نفوذ تجمعی و نفوذ در منطقه‌ی نیمه‌خشک ایران مدل استنتاج عصبی فازی تطبیقی (ANFIS)، ماشین بردار پشتیبان (SVM)، و جنگل تصادفی (RF) را به‌کار بردند، و به این نتیجه رسیدند که SVM برای مدل‌سازی نفوذ در منطقه مناسب‌ترین است، مغایرت دارد. نتیجه‌های این تحقیق با سپهوند و همکاران (۲۰۲۱) مغایرت دارد، زیرا آن‌ها به این نتیجه رسیدند که دقت مدل

ساختار ساده‌ی مدل‌سازی، برای کمی‌کردن مقدار نفوذ و تخمین‌زدن اندازه‌ی روان‌آب در بافت‌های گوناگون خاک توصیه می‌شود. برپایه‌ی نتیجه‌ی این تحقیق می‌توان این مدل‌ها را همراه با صرفه‌جویی در زمان و هزینه برای کمی‌سازی میزان نفوذپذیری و تراوایی خاک سرزمین‌های گوناگون به‌کار برد. برپایه‌ی نتیجه‌های به‌دست آمده می‌توان این سرزمین‌ها را برای اجرای کنش‌های سازه‌بی و زیستی آبخیزداری با هدف افزایش نفوذپذیری و کاهش سیل‌خیزی اولویت‌بندی کرد.

شبکه عصبی (NN)^۷ برای تخمین نفوذپذیری بیشترین است. علاوه بر این، سپهوند و همکاران (۲۰۲۱) در تحقیق خود نشان دادند که به‌کاربردن مدل‌های یادگیری برای تخمین‌زدن نفوذپذیری باعث صرفه‌جویی در زمان و هزینه‌ی اندازه‌گیری نفوذ در ایران و دیگر جاهای جهان است. جنگل تصادفی یکی از مدل‌هایی است که در کار مدل‌سازی در اندوخته‌های آب به‌کار برده می‌شود، و با نتیجه‌های این پژوهش که نشان‌دهنده‌ی دقت زیاد آن در تخمین‌زدن نفوذپذیری است، و با صرفه‌جویی دیده‌شده در زمان و

فهرست منابع

- Angelaki A, Sakellariou-Makrantonaki M, Tzimpoulous C. 2013. The oretical and experimental research of cumulative infiltration. *Transport in Porous Media*, 100(2): 247–257.
- Angelaki A, Singh Nain S, Singh V, Sihag P. 2018. Estimation of models for cumulative infiltration of soil using machine learning methods. *ISH Journal of Hydraulic Engineering*, pp. 1–8.
- Asadi M, Fatzhadeh A, Taghizadeh Mehrjerdi R. 2017. Optimization suspended load estimation models by using geo-morphometric parameters and attribute reduction technique. *Iranian Journal of Soil and Water Research*, 48(3):669–678. (In Persian).
- Breiman L, Cutler A. 2004. RF tools-for predicting and understanding data, *Interface* 04 Workshop. pp. 1–62.
- Breiman L. 2001. Random forests. *Machine Learning*, 45(1): 5–32.
- Cardwell A. 2017. The effect of land use on infiltration in Taita Hills, Kenya. Master's thesis in Geography, Faculty of Science, Department of Geosciences and Geography, university of Helsinki, 88 p.
- Cortes C, Vapnik V. 1995. Support-vector network. *Machine Learning*, 20(3): 273–297.
- Díaz-Álvarez A, Serradilla F, Naranjo JE, Anaya JJ, Jiménez F. 2014. Modeling the driving behavior of electric vehicles using smartphones and neural networks. *IEEE Intelligent Transportation Systems Magazine*, 6(3): 44–53.
- Dibike YB, Solomatine D, Abbott MB. 1999. The encapsulation of numerical hydraulic models in artificial neural network. *Journal of Hydraulic Research*, 37(2): 147–161.
- Fischer C, Tischer J, Roscher C, Eisenhauer N, Ravenek J, Gleixner G, Attinger S, Jensen B, Kroon H, Mommer L, Scheu S, Hildebrandt A. 2015. Plant species diversity affects infiltration capacity in an experimental grassland through changes in soil properties. *Plant Soil*, 397: 1–16.
- Ghorbani MA, Dehghani R. 2016. Application of bayesian neural networks, support vector machines and gene expression programming analysis of rainfall - runoff monthly. *Journal of Irrigation Sciences and Engineering*, 39(2): 125–138 (In Persian).
- Gomez H, Kavzoglu T, Mather P. 2002. Artificial neural network application in landslide hazard zonation in the Venezuelan Andes. *Abstracts of 15th International Conference on Geomorphology*, Tokyo, Japan, pp. 23–28.
- Hassanvand S, Sepahvand A, Tarnian F, Sihak P. 2021. Infiltration change assessment in different vegetation types (Case study: Aleshtar watershed, Lorestan province). *Range*, 15(3): 477–493.
- Hsu SM, NI CF, Hung PF. 2002. Assessment

- of three infiltration formulas based on model fitting and Richards equation. *Journal of Hydrology Engineering*, 7(5): 373–379.
- Lallahema S, Maniaa J, Hania A, Najjarb Y. 2005. On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*, 307(1): 92–111.
- Mazaheri MR, Mahmoodabadi M. 2012. Study on infiltration rate based on primary particle size distribution data in arid and semiarid region soils. *Arabian Journal of Geoscience*, 5: 1039–1046.
- Mehdi Nasab M, tavousi T, tavousi T, Negaresh H. 2015. Modeling of rainfall – runoff Kaskan River Catchment based on statistical models, *Geography and Environmental Planning*, 26(2): 67–84.
- Osuji G, Okon M, Chukwuma M, Nwarie I. 2010. Infiltration characteristics of soils under selected land use practices in Owerri, Southeastern Nigeria. *World Journal of Agricultural Sciences*, 6: 322–326.
- Sepahvand A, Golkarian A, Billa L, Wang K, Rezaie F, Panahi S, Samadianfard S, Khosravi Kh. (2022). Evaluation of deep machine learning-based models of soil cumulative infiltration, *Earth Science Informatics*, 15, 1861–1877.
- Sepahvand A, Sihag P, Singh B, Zand M. 2018. Comparative evaluation of infiltration models. *Journal of Civil Engineering*, 22(2): 4173–4184.
- Sepahvand A, Singh B, Ghobadi M, Sihag P. 2021. Estimation of infiltration rate using data-driven models, *Arabian Journal of Geosciences*, 14(1): 1-11.
- Shafie Amr H, Mazoghi E, Hasan G, Shehata E, Taha A, Mohd R. 2011. Artificial neural network technique for rainfall forecasting applied to Alexandria. *Egypt, International Journal of the Physical Sciences*, 6(6): 1306–1316.
- Shiri J, Keshavarzi A, Kisi O, Iturran-Viveros U, Bagherzadeh A, Mousavi R, Karimi S. 2017. Modeling soil cation exchange capacity using soil parameters: Assessing the heuristic models. *Comput. Electron. Agric.*, 135(3): 242–251.
- Sihag P, Singh B, Sepahvand A, Mehdipour V. 2018. Modeling the infiltration process with soft computing techniques. *ISH Journal of Hydraulic Engineering*, 26(1): 1–15.
- Sihag P, Singh VP, Angelaki A, Kumar V, Sepahvand A, Golia E. 2019. Modelling of infiltration using artificial intelligence techniques in semi-arid Iran. *Hydrological Sciences Journal*, 64(13):1647–1658.
- Singh B, Sihag P, Singh K, Kumar S. 2021. Estimation of trapping efficiency of vortex tube silt ejector. *International Journal of River Basin Management*, 19(1): 1–38.
- Singh B, Sihag P, Singh K. 2018. Comparison of infiltration models in NIT Kurukshetra campus. *Applied Water Science*, 8(2): 63–70.
- Soleimani L, Haghizadeh A, Zeinivand H. 2016. The determination of the best models to estimate the infiltration in various land uses for optimum management of watersheds. *Journal of Watershed Management Research*, 7(13): 33–41 (In Persian).
- Tokar AS, Markus M. 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. *Journal of Hydrology Engineering*, 5(2): 156–161.
- Tsochantaridis I, Hofmann T, Joachims T, Altun Y. 2004. Support vector machine learning for interdependent and structured output spaces, *Proceedings of the Twenty-first International Conference on Machine learning*, 20: 1–8. DOI:10.1145/1015330.1015341.
- Yimer F, Messing I, Ledin S, Abdelkadir A. 2008. Effects of different land use types on infiltration capacity in a catchment in the highlands of Ethiopia. *Soil use and management*, 24: 344–349.



Watershed Management Research

VOL. 35, No.4, Ser. No: 137, Winter 2023, pp.104 -116

DOI: 10.22092/wmrj.2022.358213.1461

Research Paper



Modelling of Infiltration Rate in Different Soil Textures using Soft Computing Techniques in Kashkan Watershed, Lorestan Province

Leili Soleimani

Ph.D. Student, Department of Range and Watershed Management, Faculty of Agriculture and Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran

Bahram Mir Derikvand

Ph.D. Student, Department of Range and Watershed Management, Faculty of Agriculture and Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran

Alireza Sepahvand

(Corresponding Author)* Assistant professor, Department of Range and Watershed Management, Faculty of Agriculture and Natural Resources, Lorestan University, Khorramabad, Lorestan Province, Iran

*Corresponding Author Email: Sepahvand.a@lu.ac.ir

Received: 30 March 2022

Accepted: 21 June 2022

Abstract

Infiltration is one of the most parameters of hydrology that plays a fundamental role in streamflow, groundwater recharge, subsurface flow, and surface and subsurface water quality and quantity. According to the importance of the mentioned subject, the infiltration changes and modeling were investigated in the different soil textures in Kashkan watershed, Lorestan province. In this study, the double-ring infiltrometer was used to measure the infiltration in the different soil textures. Also, Support vector regression (SVM), Gaussian Process (GP), Multi-Layer Perceptron (MLP), and Random Forest (RF) were used to Modeling of infiltration rate in different soil textures. Three statistical comparison criteria including root mean square error (RMSE), coefficient of correlation (C.C), and Nash Sutcliffe (NSE) were used to determine the best-performing infiltration model. The results showed that Random Forest model better estimated infiltration rate (C.C= 0.9912, NSE= 0.98622, and RMSE = 0.0177) compared to the other models. Thus, RF was found to be the most suitable for modeling infiltration in the study area. Also, sensitivity analysis concludes that the parameter time is the most effective parameter for the estimation of infiltration rate. The results indicated that the infiltration varies in the different soil textures, which should be considered in the management of groundwater recharge.

■ **Keywords:** Gaussian process, infiltration modeling, Kashkan watershed, Lorestan province, random forest ■