

مقاله علمی-پژوهشی

## برآورد سرعت نفوذ نهایی آب در خاک و پارامترهای معادلات نفوذ به روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان

ندا ستار فیض آبادی<sup>۱</sup>، علی عباسپور<sup>۲</sup>، وجیهه درستکار<sup>۳\*</sup>، محمد هادی موحد نژاد<sup>۴</sup>، روزبه مؤذن زاده<sup>۵</sup>

تاریخ دریافت: ۱۳۹۹/۳/۵ تاریخ پذیرش: ۱۳۹۹/۶/۲۳

### چکیده

نفوذ آب به خاک یکی از مهمترین فرآیندهای هیدرولوژیک است. هدف از این تحقیق، بررسی امکان تخمین پارامترهای مدل‌های فیلپ و هورتون و سرعت نفوذ نهایی آب در خاک با استفاده از شبکه عصبی مصنوعی و ماشین بردار پشتیبان (SVM) بود. به این منظور نفوذپذیری خاک در عمق ۱۰۰-۳۰ سانتی‌متری سطح خاک نمونه برداری و ویژگی‌های خاک از جمله چگالی ظاهری، فراوانی نسبی ذرات، ماده آلی، نسبت جذب سدیم، تخلخل، میانگین هندسی قطر ذرات و انحراف معیار هندسی اندازه‌گیری شد. شبکه‌های عصبی پرسپترون چند لایه (MLP) با ۴ طراحی با ۳، ۵، ۷ و ۹ ورودی و ماشین بردار پشتیبان با ۹ ورودی برای برآورد سرعت نهایی نفوذ و پارامترهای مدل‌های نفوذ به کار گرفته شد. نتایج نشان داد که در برآورد پارامترهای مدل‌های فیلپ و هورتون، شبکه‌های طراحی شده با ۹ پارامتر ورودی بیشترین ضریب تبیین، کمترین خطا و بیشترین کارایی را نسبت به سایر شبکه‌های طراحی شده داشتند. همچنین مقایسه قدرت شبیه‌سازی شبکه عصبی برای پارامترهای دو مدل هورتون و فیلپ نشان داد که بیشترین کارایی در شبیه‌سازی پارامترهای نفوذ مربوط به پارامتر سرعت نهایی در مدل هورتون با ضریب تبیین ۰/۸۴ و معماری ۱-۵-۹ بوده است. نتایج آنالیز حساسیت نشان داد که حساسیت بهترین مدل MLP و SVM در شبیه‌سازی سرعت نفوذ نهایی به دو پارامتر نسبت جذب سدیم و ماده آلی بیشتر از ۷ فاکتور دیگر بوده است. همچنین مدل SVM با دقت بسیار زیاد توانایی تخمین و پیش بینی مقادیر نفوذپذیری نهایی خاک‌ها را بر اساس پارامترهای زود یافت خاک دارد و کارایی این شبکه بیش‌تر از شبکه MLP در تخمین سرعت نفوذ نهایی آب به خاک بود.

واژه‌های کلیدی: آنالیز حساسیت، شبکه پرسپترون چندلایه، مدل فیلپ، مدل هورتون

### مقدمه

ویژه‌ای برخوردار است (عباسی، ۱۳۹۱). آبی که در اثر بارندگی، آبیاری و یا سیلاب در سطح خاک قرار می‌گیرد، به داخل نفوذ می‌کند. این آب علاوه بر مرطوب کردن خاک و افزایش رطوبت اولیه تا رسیدن به رطوبت اشباع نسبی، در صورت مطلوب بودن وضعیت زهکشی وارد لایه‌های آبدار زیرین شده و ذخیره آب زیرزمینی را تشکیل می‌دهد (فرزانه و همکاران، ۱۳۸۶).

نفوذ آب به خاک یکی از فرآیندهای است که مورد توجه پژوهشگران بوده و نقش مهمی در چرخه آب در طبیعت ایفا می‌کند. وارد شدن آب به داخل خاک در نتیجه تأثیر هم‌زمان نیروهای ثقلی و موئینگی صورت می‌گیرد (علیزاده، ۱۳۹۴). دانستن سرعت نفوذ نهایی در تمامی طرح‌های آب و خاک الزامی می‌باشد. بنابراین ارائه یک روش مطمئن، سریع، ساده و کم هزینه جهت برآورد پارامتر نفوذ نهایی می‌تواند در این زمینه مفید باشد (ابراهیمی و نایب لویی،

نفوذپذیری یکی از مهمترین خصوصیات فیزیکی خاک می باشد، که اندازه‌گیری آن در مطالعات کاربردی روابط آب و خاک از اهمیت

- ۱- فارغ التحصیل کارشناسی ارشد گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران
  - ۲- دانشیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران
  - ۳- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران
  - ۴- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران
  - ۵- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران
- \*- نویسنده مسئول: (Email: vdorostkar@shahroodut.ac.ir)

چندسطحی مقایسه نمودند. نتایج حاکی از آن بود که روش بهینه‌سازی با دقت نسبتاً خوبی پارامترهای نفوذ را برآورد کرد.

زارع ایبانه و همکاران (۱۳۹۸) از مدل‌های کوستیاکف، کوستیاکف - لوئیس، فیلیپ، اورتون و هورتون براساس آزمایش استوانه‌های دوگانه در دو مزرعه گندم و لوبیا، با هدف تعیین بهترین مدل نفوذ در اراضی جهاد نصر خوزستان استفاده کردند. دقت مدل‌ها در مزارع گندم و لوبیا نشان داد که مدل‌های کوستیاکف- لوئیس و هورتون در برآورد سرعت نفوذ و کوستیاکف- لوئیس و فیلیپ در برآورد نفوذ تجمعی بیش‌ترین دقت را داشتند.

کمالی و همکاران (۱۳۹۴) از دو روش بهینه‌سازی چندسطحی و مدل IPARM برای تخمین پارامترهای نفوذ استفاده نمودند. براساس ضرایب تخمینی معادله نفوذ کوستیاکف- لوئیس، متوسط خطای نسبی برآورد حجم آب نفوذیافته مدل IPARM و بهینه‌سازی چندسطحی، به ترتیب ۸/۱ و ۸/۵ درصد به دست آمد.

سرمدیان و کشاورز برای بررسی کارایی توابع انتقالی و شبکه عصبی در برآورد میزان رطوبت خاک با استفاده از داده‌های مربوط به ۷۰ نمونه خاک از ۱۵ پروفیل در عمق‌های مختلف و با استفاده از پارامترهای قابل اندازه‌گیری در خاک مانند آهک، درصد سیلت، رس و کربن آلی پژوهشی انجام دادند. نتایج این پژوهش نشان داد که مدل شبکه عصبی با ۵ لایه مخفی عملکرد بهتری نسبت به رگرسیون چندمتغیره در پیش‌بینی میزان رطوبت خاک داشته است (Sarmadian and Keshavarzi, 2010).

موسی با استفاده از ماشین بردار پشتیبان و رگرسیون چندمتغیره به بررسی هدایت هیدرولیکی اشباع خاک‌های شنی پرداخت. در هر دو روش یاد شده خصوصیات از خاک مانند آهک، نسبت رس به سیلت که به راحتی قابل اندازه‌گیری می‌باشند، به عنوان ورودی مورد استفاده قرار گرفت. نتایج پژوهش نشان داد که مدل ماشین بردار پشتیبان عملکرد بهتری نسبت به رگرسیون چندمتغیره داشته است (Moussa, 2015).

نشاط و پاره‌کار (۱۳۸۶) عملکرد مدل‌های نفوذ کوستیاکف، گرین- امپت، فیلیپ، هورتون و سازمان حفاظت خاک آمریکا (SCS) در برآورد نفوذ تجمعی و سرعت نفوذ اندازه‌گیری شده به روش استوانه‌های مضاعف را مورد مقایسه و ارزیابی قرار دادند. به‌منظور مقایسه عملکرد مدل‌های نفوذ از آماره ضریب تبیین استفاده شد. نتایج این پژوهش حاکی از آن بود که مدل کوستیاکف مناسب‌ترین مدل برای برآورد نفوذ تجمعی و سرعت نفوذ می‌باشد.

قربانی دشتکی و همکاران (۱۳۸۷) برای بررسی امکان تخمین پارامترهای مدل فیلیپ، کوستیاکف، کوستیاکف-لوئیس و هورتون از شبکه عصبی مصنوعی استفاده کردند. اعتبارسنجی مدل‌های نفوذ نشان داد که شبکه‌های ایجاد شده برای پارامترهای مدل فیلیپ با میانگین ریشه مربعات خطا معادل ۶/۶۶۴، دارای بهترین عملکرد در

(۱۳۸۸). روابط نفوذ ارائه شده را می‌توان به دو دسته روابط تجربی و تحلیلی تقسیم‌بندی نمود (عباسی، ۱۳۹۱). از جمله روابط تجربی می‌توان به رابطه هورتون و روابط تئوری به رابطه فیلیپ اشاره نمود (Horton, 1940; Philip, 1957).

از آنجایی که نفوذ آب به خاک دارای تغییرپذیری زیادی است (عباسی، ۱۳۹۱)، برای شبیه‌سازی شرایط واقعی سطح خاک، اندازه‌گیری‌های زیادی لازم است. علاوه بر این اندازه‌گیری نفوذ آب به خاک وقت‌گیر، هزینه‌بر و مشکل می‌باشد. به نظر می‌رسد استفاده از روش‌هایی که بتوانند مقدار نفوذ آب در خاک و پارامترهای مرتبط با مدل‌های مختلف نفوذ را با استفاده از پارامترهای زودیافت خاک نظیر بافت، جرم مخصوص ظاهری، تخلخل و ماده آلی با دقت مناسب تخمین بزنند، در این زمینه مفید باشد. استفاده از توابع انتقالی یکی از روش‌های غیرمستقیم بوده که می‌توان با استفاده از آن‌ها و به کمک ویژگی‌های زودیافت خاک، ویژگی‌های دیريافت خاک را تخمین زد. یکی از روش‌های غیرمستقیم مورد استفاده برای برآورد ویژگی‌های هیدرولیک خاک استفاده از شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان است (Minasny and McBratney, 2002).

پاراسورامن و همکاران برای برآورد هدایت آبی اشباع در مقیاس مزرعه‌ای، دو گروه شبکه عصبی طراحی نمودند. در گروه اول از مقدار رس، سیلت و شن به‌عنوان ورودی‌های شبکه استفاده گردید و در گروه دوم علاوه بر سه ویژگی یاد شده، چگالی ظاهری نیز به‌عنوان ورودی مدل مورد استفاده قرار گرفت. نتایج این پژوهش نشان داد که شبکه‌های عصبی طراحی شده عملکردی بهتر در برآورد هدایت آبی اشباع در مقیاسه با شبکه عصبی Rosetta داشته‌اند (Parasuraman et al., 2006).

ناصری و همکاران نیز در پژوهشی به بررسی عوامل تأثیرگذار بر نفوذ آب به داخل خاک پرداختند و نشان دادند که تأثیر عمق جریان، رطوبت اولیه خاک، محیط خیس شده جریان بر نفوذ به ترتیب ۰/۳۷، ۰/۳۵ و ۰/۳۴ بوده است (Nasseri et al., 2008).

مینسنی و مکبرتنی برای برآورد پارامترهای مدل ونگنختن در خاک‌های استرالیا از شبکه‌های عصبی مصنوعی استفاده نمودند. این پژوهشگران در طراحی شبکه عصبی مصنوعی تابع هدف جدیدی ارائه نمودند. در این پژوهش به‌جای این که تابع هدف مورد نظر را با استفاده از پارامترهای ونگنختن تعیین کنند، از مقدار رطوبت برآورد شده از مدل ونگنختن استفاده نمودند. نتایج این پژوهش نشان داد که تابع هدف ارائه شده اثری قابل قبول در بهبود عملکرد شبکه داشته است (Minasny and McBratney, 2002).

جنوبی و همکاران (۱۳۹۵) به‌منظور برآورد پارامترهای نفوذ معادله کوستیاکف-لوئیس در سامانه‌های آبیاری نواری انتهایی، از روش بهینه‌سازی بر اساس معادله بیلان حجمی استفاده نمودند. برای اعتبارسنجی، نتایج تجربی را با روش‌های دونقطه‌ای و بهینه‌سازی

در عرض جغرافیایی ۳۰ درجه و ۴۵ دقیقه تا ۳۱ درجه و ۱۵ دقیقه شمالی و در طول ۵۳ درجه و ۲۵ دقیقه تا ۵۴ درجه و ۱ دقیقه شرقی قرار گرفته است. ارتفاع آن از سطح دریا ۱۴۴۱ متر و مساحت آن ۱۵۹۰ کیلومتر مربع است (گلدان ساز و همکاران، ۱۳۹۰). برای انجام این پژوهش ۱۰۰ نقطه در فضای سبز شهری انتخاب شد. پراکنش نقاط مورد مطالعه در شکل ۱ نشان داده شده است.

در تمامی نقاط مورد مطالعه آزمایش نفوذ به روش استوانه مضاعف انجام شد. از دو استوانه فلزی به ارتفاع ۵۰ سانتی متر و قطر ۳۰ سانتی متر انجام پذیرفت. در روش استوانه مضاعف اندازه گیری نفوذ تا زمانی که سرعت نفوذ به مقدار ثابتی برسد ادامه یافت. همچنین در نقاط مورد مطالعه خاک از عمق ۰-۳۰ سانتی متری سطح خاک جمع آوری و پس از هوا خشک شدن از الک ۲ میلی متری عبور داده شد. مدل سازی نفوذ در خاک به کمک معادلات کوستیاکف، کوستیاکف-لوئیس، هورتون و فیلپ انجام شد و در نهایت از دو رابطه فیلپ و هورتون و پارامترهای وابسته به آن‌ها مطابق جدول ۱ برای تخمین سرعت نهایی و پارامترهای نفوذ به کمک شبکه عصبی و ماشین بردار پشتیبان استفاده شد.

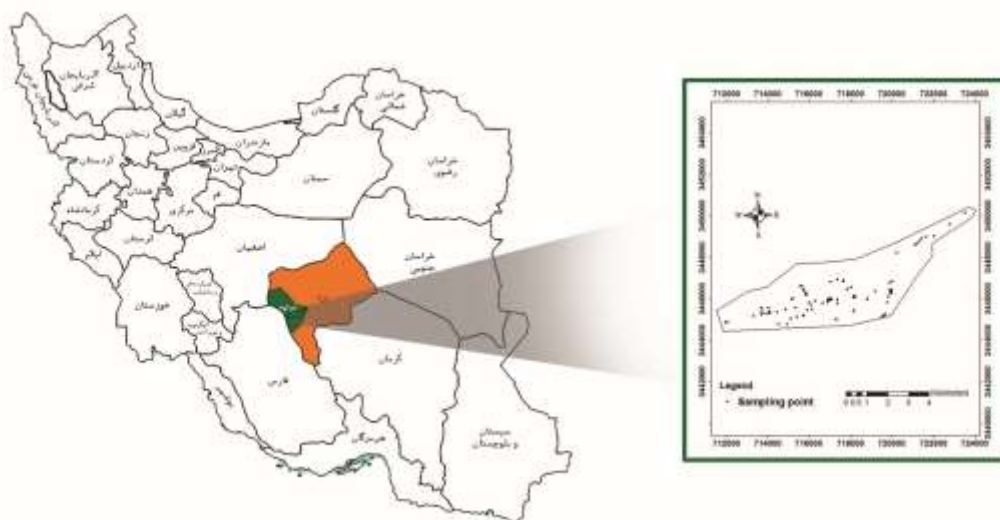
تخمین نفوذ تجمعی آب به خاک بوده و شبکه‌های پی‌ریزی شده برای مدل‌های هورتون، کوستیاکف-لوئیس و کوستیاکف به ترتیب در رتبه‌های دوم و چهارم قرار گرفتند.

با وجود مطالعات انجام شده در زمینه استفاده از شبکه‌های عصبی در پیش‌بینی ویژگی‌های هیدرولیکی خاک، به ویژه برآورد مقدار رطوبت و هدایت هیدرولیکی غیر اشباع خاک، پژوهش‌های اندکی در زمینه برآورد نفوذ نهایی و به ویژه پارامترهای معادلات نفوذ صورت گرفته است. همچنین، پژوهش‌های اندکی در زمینه استفاده از مدل ماشین بردار پشتیبان در برآورد نفوذ نهایی آب در خاک صورت گرفته است. بنابراین، این پژوهش با هدف بررسی کارایی شبکه عصبی و ماشین بردار پشتیبان در تخمین ویژگی‌های نفوذ آب در خاک انجام شد.

## مواد و روش‌ها

### جمع‌آوری داده‌های مورد استفاده

این پژوهش در خاک‌های فضای سبز شهرستان ابرکوه در استان یزد انجام گردید. ابرکوه از نظر مکانی در شرق استان یزد قرار دارد که



شکل ۱- پراکنش نقاط نمونه برداری

جدول ۱- خلاصه‌ای از مدل‌های فیلپ و هورتون و پارامترهای مربوطه

| معادله   | پارامترها  | نام مدل |
|--|--|---------|
| $I = st^{1/2} + k_s t$                                 | $I$ (نفوذ تجمعی)، $t$ (زمان)، $s$ ( $Lt^{1/2}$ ) ضریب جذبی خاک (تابع مکش خاک)، و $K_s$ ( $Lt^{-1}$ ) ضریبی است که بیانگر هدایت هیدرولیکی منطقه انتقال بوده و مقدار آن کوچکتر و یا مساوی هدایت هیدرولیکی اشباع خاک است. | فیلپ    |
| $I = i_f t + (i_0 - i_f) / \beta * (1 - e^{-\beta t})$ | $I$ (نفوذ تجمعی)، $i_0$ ( $Lt^{-1}$ ) سرعت نفوذ اولیه، $i_f$ ( $Lt^{-1}$ ) سرعت نفوذ نهایی، $t$ (زمان نفوذ)، $\beta$ ( $T^{-1}$ )  | هورتون  |

مرز بین طبقات استفاده می‌شود. اگر داده‌ها به صورت خطی قابل جداسازی باشند، از ماشین‌های خطی برای تولید یک سطح بهینه که داده‌ها را بدون خطا و با حداکثر فاصله‌ی میان صفحه و نزدیک‌ترین نقاط آموزشی (بردارهای پشتیبان) تفکیک می‌نماید، استفاده می‌شود. به منظور مفهوم‌سازی چگونگی عملکرد ماشین‌های بردار پشتیبان، نقاط آموزشی به صورت رابطه ۶ در نظر گرفته شدند.

$$D = \{(x_i, y_i)\}_{i=1}^n \quad (6)$$

که در این رابطه  $x_i$  بردار ورودی بوده که  $x_i \in X$  و  $y_i$  مقدار مطلوب می‌باشد که  $y_i \in R$  است و  $n$  تعداد کل الگوهای داده‌ای می‌باشد. معادله قواعد تصمیم‌گیری به کمک یک صفحه‌ی بهینه برای تفکیک طبقات تصمیم‌گیری یابری، در صورت امکان تفکیک داده‌ها به شکل خطی به صورت معادله ۷ می‌باشد:

$$y = \text{sign}\left(\sum_{i=1}^n y_i a_i(X, X_i) + b\right) \quad (7)$$

در این رابطه  $y$  خروجی معادله،  $y_i$  ارزش طبقه‌ی نمونه آموزشی، بردار  $X$  نشان‌دهنده‌ی یک داده‌ی ورودی، بردارهای  $X_i$  بردارهای پشتیبان و پارامترهای  $b$  و  $a_i$  تعیین‌کننده ابر صفحه هستند. اما در صورتی که داده‌ها به صورت خطی قابل تفکیک نباشند، معادله ۸ به شکل زیر تغییر می‌یابد:

$$y = \text{sign}\left(\sum_{i=1}^n y_i a_i K(X, X_i) + b\right) \quad (8)$$

در این رابطه  $K(X, X_i)$  تابع کرنل بوده که برای ایجاد ماشین‌های با انواع مختلف از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها، ضرب‌های داخلی تولید می‌نماید (Wang et al., 2009).

### پیریزی مدل‌های مورد استفاده

اولین گام در طراحی شبکه‌های عصبی مصنوعی، انتخاب داده‌های ورودی است. در این پژوهش از ویژگی‌های زودیافت خاک شامل درصد شن، سیلت، رس، ماده آلی، نسبت جذب سدیم، چگالی ظاهری، تخلخل، میانگین هندسی قطر ذرات و انحراف معیار هندسی به عنوان داده‌های لایه ورودی استفاده شد. یکی از مهمترین مراحل در ایجاد شبکه‌های عصبی مصنوعی پیش پردازش داده‌ها است. این پیش پردازش شامل انتخاب متغیرهای مؤثر و استاندارد کردن داده‌ها می‌شود. برای استاندارد کردن داده‌ها از رابطه زیر استفاده شد (قربانی دشتکی و همکاران، ۱۳۸۷).

$$X_n = 0.1 + 0.8 \left[ \frac{X - X_{\min}}{X_{\max} - X_{\min}} \right] \quad (9)$$

که  $X_n$  داده نرمال شده،  $X$  داده‌های اندازه‌گیری شده و  $X_{\max}$  و  $X_{\min}$  به ترتیب شامل داده با بیشینه مقدار و داده با کمینه مقدار می‌باشند. پس از استاندارد کردن، داده‌ها به صورت تصادفی مخلوط

فراوانی نسبی ذرات به روش هیدرومتر، چگالی ظاهری خاک به روش سیلندر، چگالی حقیقی به روش پیکنومتر، ماده آلی به روش سوزاندن تر و تخلخل کل به کمک رابطه ۱ اندازه‌گیری شد (Burt, 2004).

$$f = (1 - \rho_b / \rho_s) \quad (1)$$

در این رابطه  $f$  تخلخل خاک،  $\rho_b$  چگالی ظاهری و  $\rho_s$  چگالی حقیقی خاک است. همچنین میانگین هندسی قطر ذرات ( $d_g$ ) و انحراف معیار هندسی ذرات خاک ( $\sigma_g$ ) با استفاده از روابط شیرازی و بورسما و به کمک روابط ۲ تا ۵ محاسبه شدند (Shirazi and Boersma, 1984):

$$a = 0.01 \sum_{i=1}^n f_i \ln M_i \quad (2)$$

$$d_g = \exp a \quad (3)$$

$$b = (0.01) \sum_{i=1}^n f_i \ln^2 M_i - a^2 \quad (4)$$

$$\sigma_g = \exp b \quad (5)$$

$f_i$  درصد جرمی ذرات خاک با میانگین قطر  $\mu_i$  و  $n$  تعداد گروه ذرات خاک است. همچنین میزان کلسیم و منیزیم در عصاره اشباع خاک به روش تیتراسیون با EDTA و سدیم خاک در عصاره اشباع به روش شعله‌سنجی اندازه‌گیری شد (Burt, 2004).

### شبکه‌های مورد استفاده

شبکه‌های عصبی ابزار محاسباتی قوی و توانمندی بوده که در سازماندهی و ایجاد رابطه بین اطلاعات گوناگون از قابلیت بسیار خوبی برخوردار هستند. تئوری شبکه عصبی مصنوعی برگرفته از مدل سلول‌های عصبی مغز انسان است. مغز از تعداد زیادی سلول عصبی یا نرون تشکیل شده است. یکی از معروف‌ترین انواع شبکه‌های عصبی مصنوعی، شبکه پرسپترون چند لایه (MLP) می‌باشد. این شبکه شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است (محمودآبادی و همکاران، ۱۳۹۶).

### ماشین بردار پشتیبان (SVM)

ماشین‌های بردار پشتیبان از جمله روش‌های یادگیری نظارت‌شونده می‌باشند که از آن‌ها برای طبقه‌بندی و رگرسیون استفاده می‌شود (Vapnik, 1998). الگوریتم SVM نوع خاصی از مدل‌های خطی را می‌یابد که حاشیه‌ی ابر صفحه بیشینه شود. بیشینه کردن حاشیه‌ی ابر صفحه، منجر به حداکثر شدن تفکیک بین طبقات می‌شود. در واقع، نزدیکترین نقاط آموزشی به حداکثر حاشیه‌ی ابر صفحه را بردارهای پشتیبان می‌نامند که از آن‌ها برای مشخص کردن

کامل استفاده شد. برای ارزیابی و مقایسه عملکرد مدل‌های مختلف، ضریب تبیین ( $R^2$ ) (رابطه ۱۱) و جذر میانگین مربعات خطا (RMSE) (رابطه ۱۲) به کمک داده‌های اندازه‌گیری شده و پیش‌بینی شده محاسبه شد.

$$R^2 = \frac{\sum(X - \bar{X})}{\sqrt{\sum(X - \bar{X})^2}} \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - X_p)^2} \quad (12)$$

در روابط فوق،  $X_i$  مقدار مشاهده شده،  $X_p$  مقدار برآورده شده،  $\bar{X}$  میانگین مقادیر مشاهده شده و  $X$  مقادیر اندازه‌گیری شده و  $n$  تعداد داده‌های اندازه‌گیری نفوذ است.

## نتایج و بحث

جدول ۲ نتایج تجزیه آماری برخی خصوصیات فیزیکی و شیمیایی خاک‌های مورد مطالعه را نشان می‌دهد. نتایج نشان داد که خاک‌ها از نظر توزیع اندازه ذرات اولیه (بافت) دارای تنوع مطلوبی بوده است. به طوری که دامنه تغییرات شن، سیلت و رس به ترتیب ۱۷ تا ۹۱، ۶ تا ۵۹ و ۱ تا ۳۴ درصد بود. از این رو کلاس‌های مختلف بافت خاک را شامل شده است. حداقل و حداکثر مقدار ماده آلی در منطقه مورد مطالعه ۰/۲۸ و ۳/۸۷ درصد و با میانگین ۱/۶۳ درصد بوده است. این نشان می‌دهد ورودی مواد آلی در مناطق مختلف مورد مطالعه یکسان نبوده که می‌تواند ویژگی‌های فیزیکی خاک از جمله نفوذ آب به خاک را تحت تأثیر قرار دهد. حداقل و حداکثر مقدار چگالی ظاهری خاک در منطقه مورد مطالعه ۰/۹۴ و ۱/۴۶ گرم بر سانتی‌متر مکعب و با میانگین ۱/۰۵ گرم بر سانتی‌متر مکعب بوده است. مشاهده مقادیر بسیار کم چگالی ظاهری خاک در برخی نقاط به دلیل استفاده تازه از کودهای دامی می‌باشد. حداقل و حداکثر مقدار تخلخل خاک در منطقه مورد مطالعه ۰/۲۰ و ۰/۶۸ و با میانگین ۰/۵۷ بوده است. حداقل و حداکثر مقدار نسبت جذب سدیم در منطقه ۰/۲۴ و ۹۰/۵۳ و با میانگین ۱/۳۵ بوده است. این تغییرات نسبت جذب سدیم در مناطق مختلف میزان نفوذ آب به خاک را به شدت تحت تأثیر قرار می‌دهد.

### شبکه عصبی

به منظور برآورد هر کدام از پارامترهای مدل‌های یاد شده نفوذ، ۴ نوع شبکه با تعداد گره‌های مختلف طراحی گردید. با توجه به تعداد گره‌های استفاده شده در لایه میانی هر شبکه از ۳ تا ۱۵ گره تشکیل شده است. عملکرد شبکه‌های طراحی شده در بخش آموزش و آزمون، با استفاده از آماره ضریب تبیین ( $R^2$ ) مورد بررسی قرار گرفت. سپس

شده و الگوهای آموزش، اعتبارسنجی و آزمون به ترتیب به نسبت ۷۰، ۱۵ و ۱۵ درصد انتخاب شدند.

در طراحی شبکه عصبی مصنوعی از روش سلسله‌ای استفاده شد. به این صورت که در شبکه اول (ANN1) تنها از ویژگی‌های فراوانی نسبی ذرات خاک به عنوان متغیرهای ورودی استفاده گردید. در شبکه دوم (ANN2) چگالی ظاهری خاک و تخلخل کل به ورودی‌های شبکه ANN1 اضافه گردید و شبکه ANN2 را ایجاد نمود. به همین ترتیب برای ایجاد شبکه سوم (ANN3) ماده آلی و نسبت جذب سدیم به ورودی‌های قبلی اضافه شد و در نهایت برای ایجاد شبکه چهارم (ANN4) میانگین هندسی قطر ذرات و انحراف معیار هندسی به شبکه افزوده شد.

یک شبکه عصبی پرسپترون پیش‌خور سه لایه قادر است روابط موجود بین لایه ورودی و خروجی را تشخیص دهد و مدل کند. باتوجه به قابلیت این شبکه در این پژوهش از آن برای برآورد میزان نفوذ آب در خاک و پارامترهای مدل‌های نفوذ به کمک الگوریتم آموزشی لوبنرگ-مارکوارت استفاده شد. برای اجرا، آموزش و آزمون شبکه از نرم افزار MATLAB2016a استفاده شد. به منظور بهینه‌سازی شبکه عصبی مورد استفاده از آزمون و خطا استفاده شد و تعداد نرون‌های لایه پنهان و نوع تابع آستانه مشخص و بهینه شد. به همین منظور، برای پیش‌بینی سرعت نفوذ نهایی و هرکدام از پارامترهای دو مدل هورتون و فیلیپ، شبکه‌هایی با ۲ تا ۱۵ نرون و در ترکیب با دو تابع آستانه  $\text{tansig}$  و  $\text{logsig}$  در لایه مخفی طراحی و مورد آزمون قرار گرفت.

همچنین برای پیش‌بینی میزان نفوذ نهایی با استفاده از ۹ پارامتر ورودی مورد اندازه‌گیری شامل درصد شن، سیلت، رس، ماده آلی، نسبت جذب سدیم، چگالی ظاهری، تخلخل، میانگین هندسی قطر ذرات و انحراف معیار هندسی از مدل ماشین بردار پشتیبان نیز استفاده شد. مدلسازی ماشین بردار پشتیبان به کمک نرم افزار Clementine 12 انجام شد.

در مطالعه حاضر برای برآورد سرعت نفوذ نهایی آب در خاک با استفاده از روش ماشین بردار پشتیبان ۷۰ درصد داده‌ها برای ساخت و آموزش مدل، ۱۵ درصد اعتبارسنجی و ۱۵ درصد باقی مانده برای آزمون کارایی مدل استفاده شد. در مرحله بعد مقادیر بهینه مشخصه‌های مدل SVM شامل  $\epsilon$  و  $c$  با آزمون و خطا تعیین گردید. همچنین در این مطالعه تابع کرنل مورده استفاده، تابع RBF انتخاب شد چرا که در اکثر مطالعات از دقت بیشتری برخوردار بود.

$$K(X, X_i) = \exp(-\|X - X_i\|^2 / \sigma^2) \quad (10)$$

در این رابطه  $\sigma$  پهنای باند کرنل می‌باشد (Baofeng, et al., 2008).

همچنین برای انجام آنالیز حساسیت مدل از محاسبه درصد خطا در زمان حذف هر یک از پارامترهای ورودی مدل در مقایسه با مدل

نهایی را نشان می‌دهد. مقدار  $R^2$  بخش آزمون شبکه‌ها همواره کمتر از مقدار آن در بخش آموزش بوده است. در واقع می‌توان گفت مقدار خطای بخش آزمون از بخش آموزش بیش‌تر بوده است.

از بین شبکه‌های طراحی شده برای هر  $ANN_i$ ، شبکه‌ای که دارای بهترین عملکرد بود، انتخاب شد. جدول ۳ شبکه‌های عصبی گزینش شده برای برآورد سرعت نفوذ

جدول ۲- نتایج بررسی آماری برخی ویژگی‌های فیزیکی و شیمیایی خاک‌های مورد مطالعه

| پارامتر       | واحد                  | حداقل | حداکثر | میانگین | انحراف معیار | چولگی |
|---------------|-----------------------|-------|--------|---------|--------------|-------|
| شن            | درصد                  | ۱۷    | ۹۱     | ۶۳/۸۳   | ۱۷/۴۰        | ۰/۴۲  |
| سیلت          | درصد                  | ۶     | ۵۹     | ۲۴/۶۹   | ۱۰/۲۴        | ۰/۹۷  |
| رس            | درصد                  | ۱     | ۳۴     | ۱۱/۴۷   | ۸/۶۷         | -۰/۲۸ |
| چگالی ظاهری   | گرم بر سانتی‌متر مکعب | ۰/۹۴  | ۱/۴۶   | ۱/۰۵    | ۰/۰۷         | ۰/۱۷  |
| تخلخل خاک     | -                     | ۰/۲۰  | ۰/۶۸   | ۰/۵۷    | ۰/۱۰         | ۰/۵۰  |
| نسبت جذب سدیم | -                     | ۰/۲۴  | ۹۰/۵۳  | ۱/۳۵    | ۱/۲۸         | ۱۵/۸۰ |
| ماده آلی      | درصد                  | ۰/۲۸  | ۳/۸۷   | ۱/۶۳    | ۰/۸۴         | -۰/۴۱ |

جدول ۳- بهترین شبکه‌های عصبی گزینش شده در برآورد سرعت نفوذ نهایی

| نوع شبکه         | معماری انتخابی | توابع آستانه | ضریب تبیین آموزش | ضریب تبیین آزمون | ضریب تبیین اعتبارسنجی | ضریب تبیین شبیه‌سازی | خطای شبیه‌سازی |
|------------------|----------------|--------------|------------------|------------------|-----------------------|----------------------|----------------|
| ANN <sub>1</sub> | ۳-۶-۱          | tansig       | ۰/۹۵۱۷           | ۰/۶۲۱۳           | ۰/۵۴۳۲                | ۰/۷۹۸۸               | ۰/۰۴۲۱         |
|                  | ۳-۳-۱          | logsig       | ۰/۷۰۸۹           | ۰/۵۹۳۵           | ۰/۴۸۵۲                | ۰/۷۵۷۷               | ۰/۰۴۶۲         |
| ANN <sub>2</sub> | ۵-۸-۱          | tansig       | ۰/۸۹۶۵           | ۰/۴۳۱۵           | ۰/۲۷۲۷                | ۰/۷۰۸۹               | ۰/۰۵۰۷         |
|                  | ۵-۱۵-۱         | logsig       | ۰/۹۲۰۹           | ۰/۷۱۶۵           | ۰/۵۵۶۵                | ۰/۶۲۶۴               | ۰/۰۵۷۴         |
| ANN <sub>3</sub> | ۷-۱۲-۱         | tansig       | ۰/۹۶۵۰           | ۰/۷۶۶۲           | ۰/۶۴۰۳                | ۰/۸۵۰۶               | ۰/۰۳۶۳         |
|                  | ۷-۶-۱          | logsig       | ۰/۹۵۲۱           | ۰/۴۸۸۵           | ۰/۷۱۸۹                | ۰/۸۷۹۳               | ۰/۰۳۲۶         |
| ANN <sub>4</sub> | ۹-۴-۱          | tansig       | ۰/۹۴۹۱           | ۰/۷۳۴۲           | ۰/۷۵۲۷                | ۰/۸۷۸۴               | ۰/۰۳۲۸         |
|                  | ۹-۶-۱          | logsig       | ۰/۹۳۸۷           | ۰/۵۸۶۶           | ۰/۶۶۶۰                | ۰/۸۵۸۳               | ۰/۰۳۵۴         |

جدول ۴- نتایج بهترین شبکه‌های پی‌ریزی شده از بین ۴ نوع شبکه مورد مطالعه با معماری‌های مختلف برای برآورده پارامترهای مدل‌های فیلپ و هورتون

| مدل            | پارامتر | معماری         | توابع آستانه | ضریب تبیین آموزش | ضریب تبیین آزمون | ضریب تبیین اعتبارسنجی | ضریب تبیین شبیه‌سازی | خطای شبیه‌سازی |
|----------------|---------|----------------|--------------|------------------|------------------|-----------------------|----------------------|----------------|
| فیلپ           | A       | ۹-۱۳-۱         | tansig       | ۰/۹۸۸۹           | ۰/۴۲۶۴           | ۰/۸۶۴۴                | ۰/۸۴۲۵               | ۰/۰۶۱۴         |
|                | S       | ۹-۱۱-۱         | logsig       | ۰/۹۱۹۶           | ۰/۷۶۲۱           | ۰/۹۷۶۳                | ۰/۸۱۲۹               | ۰/۰۶۶۹         |
|                |         | ۹-۷-۱          | tansig       | ۰/۹۴۲۱           | ۰/۳۶۱۵           | ۰/۴۵۰۷                | ۰/۶۳۸۹               | ۰/۰۸۶۸         |
|                | هورتون  | I <sub>0</sub> | ۹-۱۱-۱       | tansig           | ۰/۹۷۲۵           | ۰/۶۲۱۷                | ۰/۵۶۲۳               | ۰/۷۵۷۱         |
| i <sub>c</sub> |         | ۷-۱۱-۱         | logsig       | ۰/۹۷۷۰           | ۰/۲۲۲۸           | ۰/۶۴۷۳                | ۰/۶۳۵۹               | ۰/۰۸۳۸         |
|                |         | ۹-۹-۱          | tansig       | ۰/۹۳۳۳           | ۰/۴۹۶۷           | ۰/۷۶۳۴                | ۰/۸۲۰۹               | ۰/۰۴۲۵         |
| K              |         | ۹-۵-۱          | logsig       | ۰/۹۴۴۷           | ۰/۳۵۷۳           | ۰/۹۱۲۷                | ۰/۸۴۷۵               | ۰/۰۳۹۲         |
| K              | ۵-۹-۱   | tansig         | ۰/۹۴۸۶       | ۰/۵۸۱۵           | ۰/۶۰۶۹           | ۰/۷۱۱۶                | ۰/۰۶۰۹               |                |
|                | ۹-۲-۱   | logsig         | ۰/۸۷۳۰       | ۰/۶۱۴۳           | ۰/۵۴۱۶           | ۰/۶۲۵۵                | ۰/۰۶۹۴               |                |

بهترین شبکه طراحی شده برای برآورد سرعت نفوذ، شبکه طراحی شده با ۹ متغییر ورودی شامل فراوانی نسبی ذرات خاک، چگالی ظاهری خاک، تخلخل کل، ماده آلی، نسبت جذب سدیم، میانگین هندسی قطر ذرات و انحراف معیار هندسی ( $ANN_4$ ) بوده است. معماری بهترین شبکه به صورت ۹-۴-۱ و با تابع آستانه tansig بوده است. در این معماری ضریب تبیین به ترتیب برای

بهترین شبکه طراحی شده برای برآورد سرعت نفوذ، شبکه طراحی شده با ۹ متغییر ورودی شامل فراوانی نسبی ذرات خاک، چگالی ظاهری خاک، تخلخل کل، ماده آلی، نسبت جذب سدیم، میانگین هندسی قطر ذرات و انحراف معیار هندسی ( $ANN_4$ ) بوده است. معماری بهترین شبکه به صورت ۹-۴-۱ و با تابع آستانه tansig بوده است. در این معماری ضریب تبیین به ترتیب برای

logsig به ترتیب شبکه‌های با معماری ۱-۱۱-۹ و ۱-۱۱-۷ دارای کم‌ترین خطای شبیه‌سازی (به ترتیب ۰/۰۶۸ و ۰/۰۸۳) و بیش‌ترین ضریب تبیین (به ترتیب ۰/۷۵ و ۰/۶۳) بوده است. در برآورد پارامتر  $i_c$  نیز با دو تابع محرک  $tansig$  و  $logsig$  به ترتیب شبکه‌های با معماری ۱-۹-۱ و ۱-۵-۹ دارای کم‌ترین خطای شبیه‌سازی (به ترتیب ۰/۰۴۲ و ۰/۰۳۹) و بیش‌ترین ضریب تبیین (به ترتیب ۰/۸۴) بود. همچنین در برآورد پارامتر  $k$  با توابع محرک  $tansig$  و  $logsig$  به ترتیب شبکه‌های با معماری ۱-۹-۵ و ۱-۲-۹ دارای کم‌ترین خطای شبیه‌سازی (به ترتیب ۰/۰۶۰ و ۰/۰۷) و بیش‌ترین ضریب تبیین (به ترتیب ۰/۷۱ و ۰/۶۲) بوده است. برای هر سه پارامتر موفقیت نسبی شبکه‌های مذکور بوده است. شکل ۲-D، ۲-E و ۲-F نیز بیان‌کننده پراکنش مناسب داده‌های اندازه‌گیری شده و شبیه‌سازی شده توسط شبکه‌های مذکور به ترتیب برای برآورد پارامتر  $i_c$ ،  $I_0$  و  $k$  بوده که بر کارایی مناسب شبکه طراحی شده در پیش‌بینی این پارامترها تأکید می‌نماید.

#### ماشین بردار پشتیبان

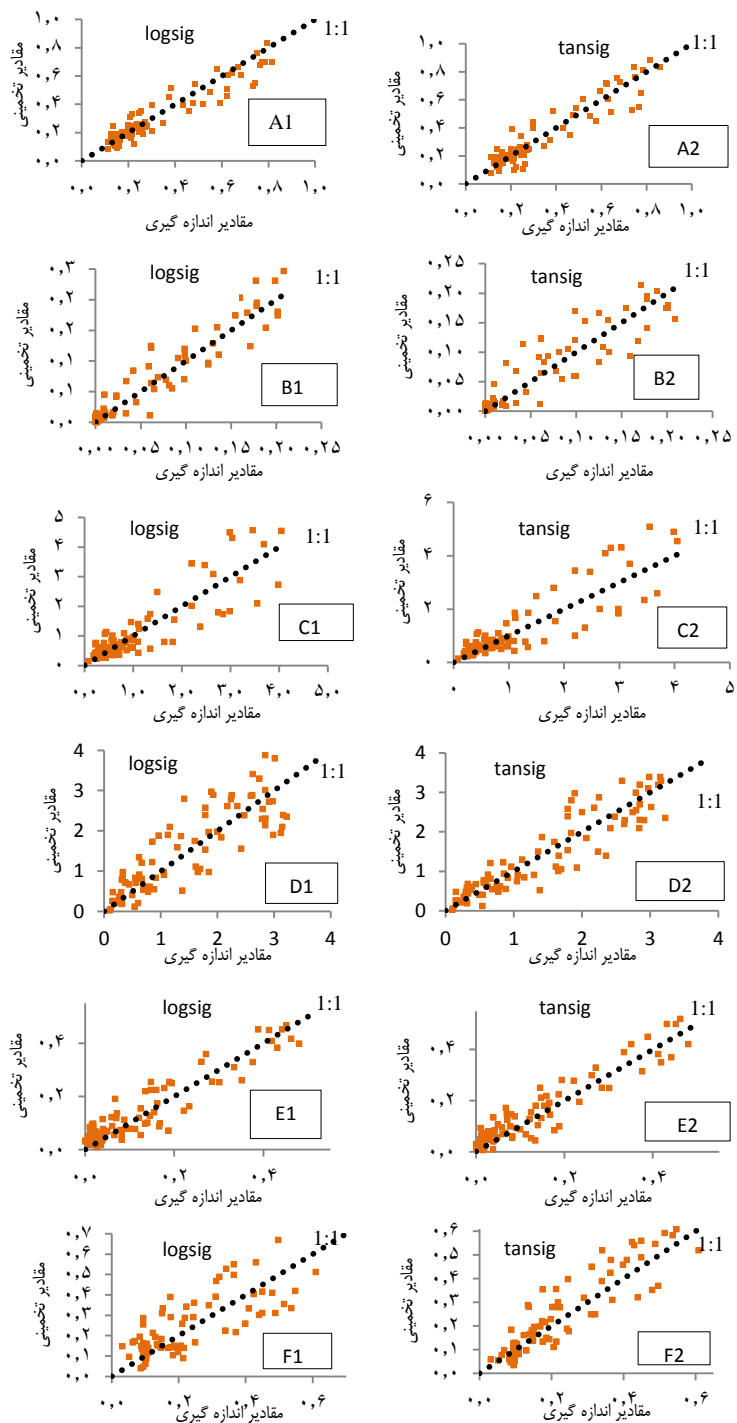
در این تحقیق برای برآورد سرعت نفوذ نهایی آب در خاک به کمک مدل ماشین بردار پشتیبان از همان ۹ ورودی شبکه عصبی مصنوعی استفاده شد. برای هر الگوی ورودی با تغییر  $\epsilon$ ،  $C$  و  $\sigma$  به صورت آزمون و خطا، شبکه‌های مختلفی ساخته و آموزش داده شد و در نهایت ساختاری که دارای کمترین خطا و بیشترین دقت بود به عنوان مناسب‌ترین الگو انتخاب شد. جدول ۵ شاخص‌های آماری مربوط به نتایج حاصل از کاربرد مدل SVM را برای برآورد سرعت نفوذ نهایی آب در خاک نشان می‌دهد. عملکرد SVM در برآورد سرعت نفوذ نهایی آب در خاک در هر سه مرحله آموزش، آزمون و شبیه‌سازی مناسب بوده است. خطای شبیه‌سازی در مدل مذکور ۰/۰۵ و ضریب تبیین ۰/۹۲ بوده است (جدول ۵). شکل ۳ نمودار پراکندگی مقادیر اندازه‌گیری و شبیه‌سازی توسط بهترین حالت مدل SVM نشان می‌دهد.

مراحل آموزش، آزمون و اعتبارسنجی ۰/۹۴، ۰/۷۳ و ۰/۷۵ می‌باشد. همچنین در مرحله شبیه‌سازی نیز این شبکه با معماری اشاره شده توانسته به خوبی به شبیه‌سازی سرعت نفوذ پرداخته و ضریب تبیین و ریشه میانگین مربعات خطا در این مرحله به ترتیب ۰/۸۷ و ۰/۰۳۲ می‌باشد (جدول ۳). شکل ۲-A نیز بیان‌کننده پراکنش مناسب داده‌های اندازه‌گیری شده و شبیه‌سازی شده توسط این شبکه بوده که بر کارایی مناسب شبکه طراحی شده در پیش‌بینی سرعت نفوذ تأکید می‌نماید. همچنین در بین ۴ شبکه مطالعه شده با معماری‌های مختلف، شبکه دارای ۷ ورودی شامل فراوانی نسبی ذرات خاک، چگالی ظاهری خاک، تخلخل کل، ماده آلی و نسبت جذب سدیم ( $ANN_3$ ) با ساختار ۱-۶-۷ و تابع آستانه  $logsig$  نیز با ضریب تبیین ۰/۸۷ و خطای شبیه‌سازی ۰/۰۳۲۶ توانسته تا حد قابل قبولی به شبیه‌سازی سرعت نفوذ بپردازد. با این وجود ضریب تبیین این ساختار نسبت به معماری ۱-۴-۹ در مراحل آزمون و اعتبارسنجی کمتر بوده است (جدول ۳). کارایی شبکه عصبی برای برآورد پارامترهای نفوذ مورد مطالعه، در مدل فیلیپ برای پارامتر  $A$  و در مدل هورتون برای پارامتر  $i_c$  بیش‌تر بود (جدول ۴). در برآورد پارامترهای مدل فیلیپ، شبکه‌های با ۹ پارامتر ورودی بهترین عملکرد را داشته‌اند. در برآورد پارامتر  $A$  با توابع محرک  $tansig$  و  $logsig$  به ترتیب شبکه‌های با معماری ۱-۱۳-۹ و ۱-۱۱-۹ دارای کم‌ترین خطای شبیه‌سازی (به ترتیب ۰/۰۶ و ۰/۰۶) و بیش‌ترین ضریب تبیین (به ترتیب ۰/۸۴ و ۰/۸۱) بوده است. در برآورد پارامتر  $S$  نیز با دو تابع محرک  $tansig$  و  $logsig$  به ترتیب شبکه‌های با معماری ۱-۷-۹ و ۱-۲-۹ دارای کم‌ترین خطای شبیه‌سازی (به ترتیب ۰/۰۸ و ۰/۰۸) و بیش‌ترین ضریب تبیین (به ترتیب ۰/۶۳ و ۰/۶۶) بوده است. برای هر دو پارامتر  $A$  و  $S$  ضرایب تبیین برای مراحل آموزش و آزمون نشان‌دهنده موفقیت نسبی شبکه‌های مذکور بوده است. شکل ۲-B و ۲-C نیز بیان‌کننده پراکنش مناسب داده‌های اندازه‌گیری شده و شبیه‌سازی شده توسط شبکه‌های مذکور به ترتیب برای برآورد پارامتر  $A$  و  $S$  بوده که بر کارایی مناسب شبکه طراحی شده در پیش‌بینی این پارامترها تأکید می‌نماید.

در برآورد پارامتر  $I_0$  مدل هورتون با توابع محرک  $tansig$  و


جدول ۵- نتایج مدل ماشین بردار پشتیبان در پیش‌بینی سرعت نفوذ نهایی آب در خاک

| پارامتر   | $\epsilon$ | $C$   | $\sigma$ | RMSE  | $R^2$ |
|-----------|------------|-------|----------|-------|-------|
| I (آزمون) | ۵          | ۰/۰۵۰ | ۴/۳۱۰    | ۰/۰۴۱ | ۰/۹۶۱ |
| I (تست)   | ۴          | ۰/۰۶۰ | ۲/۲۱۰    | ۰/۰۵۴ | ۰/۹۳۴ |
| I         | ۴          | ۰/۰۶۰ | ۲/۲۱۰    | ۰/۰۵۷ | ۰/۹۲۵ |



شکل ۲- پراکندگی مقادیر اندازه گیری و تخمینی مربوط به برآورد سرعت نفوذ نهایی (شکل A)، پارامترهای A (شکل B) و S (شکل C) از مدل فیلیپ و همچنین پارامترهای  $I_0$  (شکل D)،  $I_c$  (شکل E) و K (شکل F) از مدل هورتون توسط بهترین شبکه های عصبی مصنوعی مورد مطالعه






شکل ۳- پراکندگی مقادیر اندازه گیری و تخمینی سرعت نفوذ نهایی در بهترین حالت مدل SVM

فاکتور دیگر در شبیه سازی سرعت نفوذ بوده است. در شبیه سازی فاکتور  $I_c$  در مدل هورتون، بیشترین حساسیت مدل نسبت به دو پارامتر نسبت جذب سدیم و ماده آلی و در درجه دوم نسبت به چگالی ظاهری و تخلخل بوده است. همچنین در شبیه سازی پارامتر  $I_0$  و  $K$  در مدل هورتون نیز بیشترین حساسیت به پارامترهای تخلخل و ماده آلی خاک بوده است (شکل ۴). در شبیه سازی پارامترهای نفوذ در مدل فیلپ نیز، بیشترین حساسیت مدل نسبت به فراوانی نسبی ذرات خاک و در درجه دوم نسبت به چگالی ظاهری و تخلخل خاک بوده است (شکل ۴).


مقایسه دو مدل شبکه عصبی و ماشین بردار پشتیبان در برآورد سرعت نفوذ نهایی نشان داد که مدل SVM با خطای شبیه سازی ۰/۰۵ و ضریب تبیین ۰/۹۲ نسبت به بهترین مدل شبکه عصبی با معماری ۱-۴-۹ و تابع محرک tansig با ضریب تبیین ۰/۸۸ عملکرد بهتری داشته است.

#### آنالیز حساسیت مدل های مورد مطالعه

نتایج آنالیز حساسیت نشان می دهد که حساسیت بهترین مدل شبکه عصبی نسبت به نسبت جذب سدیم و ماده آلی بیشتر از ۷



شکل ۴- آنالیز حساسیت مدل شبکه عصبی



شکل ۵- آنالیز حساسیت مدل SVM

قرار گیرد.

## منابع

ابراهیمی، ک. و نایب لویی، ف. ۱۳۸۸. تخمین نفوذپذیری نهایی خاک‌ها با استفاده از مدل شبکه عصبی مصنوعی، پژوهش‌های حفاظت آب و خاک (علوم کشاورزی و منابع طبیعی). ۱۶: ۵۷-۳۷.

جنوبی، ر.، رضاوودی نژاد، و. و عباسی، ف. ۱۳۹۵. ارائه مدل بهینه‌سازی برآورد پارامترهای نفوذ و ضریب زبری آبیاری نواری با استفاده از داده‌های پیشروی و رواناب. مدیریت آب و آبیاری. ۱: ۲۹-۴۵.

زارع ایبانه، ح. ر.، خسرایبی، ا.، ابراهیمی پاک، ن. ع.، تافته، آ. و جوزی م. ۱۳۹۸. انتخاب مدل بهینه نفوذ آب در خاک (مطالعه موردی: اراضی جهاد نصر استان خوزستان). مدیریت آب و آبیاری. ۲: ۲۹۱-۳۰۴.

عباسی، ف. ۱۳۹۱. اصول جریان در آبیاری سطحی. کمیته ملی آبیاری و زهکشی ایران. ۲۳۲ صفحه.

علیزاده، ا. ۱۳۹۴. فیزیک خاک. انتشارات دانشگاه فردوسی مشهد. ۴۴۰ صفحه.

فرزانه، ح.، مهدیان، م. ح. و گزنچیان، ع. ۱۳۸۶. بررسی پخش سیلاب و تأثیر آن بر روند میزان نفوذپذیری عرصه پخش سیلاب آبخوان سبزوار - داورزن، نهمین سمینار سراسری آبیاری و کاهش تبخیر. بهمن ماه، دانشگاه شهید باهنر، انجمن مهندسی آبیاری و آب.

قربانی دشتکی، ش.، همایی، م. و مهدیان، م. ح. ۱۳۸۷. برآورد پارامترهای نفوذ با استفاده از شبکه عصبی مصنوعی. مجله آب و خاک (علوم و صنایع کشاورزی). ۲۳: ۱۹۸-۱۸۵.

قیومی محمدی، ا. م.، قربانی دشتکی، ش.، رئیسی، ف. و طهماسبی، پ. ۱۳۹۲. اثر رهاسازی اراضی بر تغییرات نفوذ آب به خاک. نشریه حفاظت منابع آب و خاک. ۲: ۴: ۴۱-۵۱.

کمالی، پ.، ابراهیمیان، ح. و وردی نژاد، و. ر. ۱۳۹۴. ارزیابی و مقایسه روش بهینه سازی چندسطحی و مدل IPARM در تخمین پارامترهای نفوذ در آبیاری جویچه ای. مدیریت آب و آبیاری. ۱: ۵۴-۴۳.

گلدان‌ساز، س. م.، سلطانی گرد فرامرزی، م.، رضایی، م. ب. و زارع چاهوکی، م. ع. ۱۳۹۰. معرفی و بررسی شکل زیستی، خواص و

همچنین نتایج آنالیز حساسیت مدل SVM نیز نشان می‌دهد که حساسیت این مدل به نسبت جذب سدیم و ماده آلی و تخلخل بیشتر از ۶ فاکتور دیگر در شبیه‌سازی سرعت نفوذ نهایی بوده است (شکل ۵).

حساسیت مدل به پارامتر نسبت جذب سدیم به دلیل اثر سدیم بر پایداری خاکدانه‌های خاک و تخریب ساختمان خاک است. سدیم به دلیل نقش تخریبی در ساختمان خاک سبب افزایش سله سطحی شده که نفوذ آب به داخل خاک را کاهش می‌دهد. عماد نیز در پژوهش خود به بررسی کیفیت آب بر نفوذ آب به داخل خاک پرداخته و نشان داده است که تغییرات سدیم بر نفوذ آب به داخل خاک مؤثر می‌باشد (Emdad, 2007). همچنین ماده آلی خاک به عنوان یک پارامتر خاکدانه‌ساز باعث افزایش پایداری ساختمان خاک شده و با بهبود تخلخل، نفوذ آب به داخل خاک را افزایش می‌دهد و همین امر سبب حساسیت مدل‌های مورد استفاده در پیش‌بینی پارامترهای نفوذ به ماده آلی خاک شده است. قیومی محمدی و همکاران نیز نشان دادند که ماده آلی خاک به واسطه جرم ویژه پایین و توانایی در افزایش پایداری خاکدانه‌ها باعث بالا رفتن سرعت نفوذ آب در خاک می‌شود (قیومی محمدی و همکاران، ۱۳۹۲). اندازه ذرات خاک نیز از پارامترهای مهم و تأثیرگذار در جذب‌پذیری آب در خاک و هدایت هیدرولیکی آن می‌باشد. اثر منفی افزایش نسبت جذب سدیم و چگالی ظاهری و اثر مثبت ماده آلی و تخلخل در بهبود وضعیت ساختمانی خاک و در نتیجه بر نفوذ آب به داخل خاک را دارا می‌باشد.

## نتیجه‌گیری

اندازه‌گیری مستقیم ویژگی‌های هیدرولیکی مثل سرعت نفوذ آب به خاک بدلیل تغییرات مکانی و زمانی زیاد این خصوصیات اغلب مشکلاتی را به دنبال دارند. یکی از راه‌های چیرگی بر این مشکل استفاده از توابع انتقالی خاک می‌باشد. از مهمترین روش‌های برآورد توابع انتقالی خاک روش‌های شبکه‌های عصبی مصنوعی می‌باشد. در این تحقیق از شبکه‌های عصبی پرسپترون چند لایه و ماشین بردار پشتیبان استفاده شده است. نتایج نشان داد که ماشین بردار پشتیبان با ضریب تعیین ۰/۹۲۵ و خطای ۰/۰۵۷ دارای کارایی بیشتری نسبت به شبکه‌های عصبی پرسپترون چند لایه MLP است. با توجه به نتایج آنالیز حساسیت پیشنهاد می‌شود در شبیه‌سازی نفوذ آب به خاک در درجه اول بیش‌تر به پارامترهای نسبت جذب سدیم و ماده آلی و در درجه دوم به چگالی ظاهری و تخلخل خاک توجه شود. همچنین، پیشنهاد می‌شود با توجه به نتایج بهتر ماشین بردار پشتیبان نسبت به شبکه عصبی در برآورد سرعت نفوذ نهایی، پیش‌بینی پارامترهای مدل‌های نفوذ یاد شده توسط ماشین بردار پشتیبان نیز مورد مطالعه

- American Journal. 66: 352–361.
- Moussa, S.E. 2015. Support Vector Machine and Regression Analysis to Predict the Field Hydraulic Conductivity of Sandy Soil. *Journal of Civil Engineering*. 19: 2307–2316.
- Nasseri, A., Neyshabouri, M.R. and Abbasi, F. 2008. Effectual components on furrow infiltration. *Irrigation and Drainage*. 57: 481–489.
- Parasuraman, K., Elshorbagy, A. and Si, B.C. 2006. Estimating saturated hydraulic conductivity in spatially variable field using neural network ensembles. *Soil Science Society of American Journal*. 70: 1851–1859.
- Philip, J.R. 1957. The theory of infiltration, I. Infiltration equation and its solution. *Soil Science*. 83: 345–357.
- Sarmadian, F. and Keshavarzi, A. 2010. Developing pedotransfer functions for estimating some soil properties using artificial neural network and multivariate regression approaches. *World Academic Science Engineering Technology*. 48: 427–433.
- Shirazi, M.A. and Boersma, L. 1984. A unifying quantitative analysis of soil texture. *Soil Science Society of American Journal*. 48: 142–147.
- Vapnik, V.N. 1998. *Statistical Learning Theory*. New York: Wiley.
- Wang, W.C., Chau, K.W., Cheng, C.T. and Qiu, L. 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*. 374: 294–306.
- قسمت‌های مورد استفاده فلور دارویی کفه ابرکوه یزد. فصلنامه پژوهش‌های علوم گیاهی. ۳.۲۳: ۲۱–۱۶.
- محمودآبادی، ا.، کریمی، ع.ر.، حق‌نیا، غ. و سپهر، ع. ۱۳۹۶. ارزیابی عملکرد رگرسیون چندمتغیره، شبکه عصبی مصنوعی و برنامه ریزی بیان ژن در تخمین برخی خصوصیات خاک. پژوهش‌های حفاظت آب و خاک (علوم کشاورزی و منابع طبیعی). ۲.۲۴: ۴۴–۲۳.
- نشاط، ع. و پاره‌کار، م. ۱۳۸۶. مقایسه روش‌های تعیین سرعت نفوذ عمودی آب در خاک. علوم کشاورزی و منابع طبیعی. ۳.۱۴: ۱۹۵–۱۸۶.
- Baofeng, G., Gunn, S.R., Damper, R.I. and Nelson, J.D.B. 2008. Customizing Kernel Functions for SVM-Based Hyperspectral Image Classification. *IEEE Transactions on Image Processing*. 17: 622–629.
- Burt, R. 2004. *Soil survey laboratory methods manual: Soil survey investigations*, Version 4.0. Natural Resources Conservation Service, Nebraska, United States.
- Emdad, M.R. 2007. Effect of water quality on soil structure and infiltration under furrow irrigation. *Irrigation Science*. 23: 50–60.
- Horton, R.E. 1940. An approach toward to physical interpretation of infiltration capacity. *Soil Science Society of American Journal*. 5: 399–417.
- Minasny, B. and McBratney, A.B. 2002. The Neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Science Society of*

## Soil Water Infiltration Rate and Soil Infiltration Model Parameters Prediction Using Artificial Neural Network and Support Vector Machine

N. Satar Feizabadi<sup>1</sup>, A. Abbaspour<sup>2</sup>, V. Dorostkar<sup>3\*</sup>, M.H. Movahednejad<sup>4</sup>, R. Moazenzadeh<sup>5</sup>

Received: May.25, 2020

Accepted: Sep.13, 2020

### Abstract

Water infiltration into the soil is one of important hydrological parameters. This study was conducted for Phillip and Horton parameters and final water infiltration rate prediction using artificial neural network and support vector machine (SVM). The soil water infiltration was measured in 100 points of Abarkouh city landscape (Yazd province) with double ring method. The samples from 0-30 cm of soil surface were analyzed for bulk density, texture, organic matter, sodium adsorption ratio, porosity, geometric mean particle diameter and geometric standard deviation of soil particle. The multilayer perceptron neural network (MLP) with 4 different scenarios with 3, 5, 7 and 9 inputs and SVM with 9 inputs were analyzed for infiltration parameters and final water infiltration rate prediction. The results showed that the network with 9 inputs had the greatest  $R^2$  and the lowest error in Phillip and Horton parameters prediction. The study of prediction ability of ANN for Horton and Phillip parameters showed that the greatest capability was related to final infiltration rate to net design as 9-5-1 with  $R^2$  equal to 0.84. The sensitivity analysis showed that the designed nets had greater sensitivity to soil sodium adsorption ratio and the organic matter than other 7 parameters. The SVM model had good ability to water infiltration rate prediction based on basic soil properties. SVM model had better ability in soil water infiltration rate prediction compared to ANN model.

**Keywords:** Horton model, Multilayer perceptron neural network, Phillip model, Sensitivity analysis

1- M.S Graduated, Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran

2- Associate Professor, Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran

3- Assistant Professor, Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran

4- Assistant Professor, Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran

5- Assistant Professor, Water and Soil Department, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran

(\*- Corresponding Author Email: vdorostkar@shahroodut.ac.ir)