

## ارزیابی مدل‌های رگرسیونی و شبکه عصبی مصنوعی در تخمین هدایت هیدرولیکی اشباع خاک در مازندران

زهرا نوروزیان عزیز، مهدی قاجار سپانلو<sup>1</sup>، سید مصطفی عمادی و فردین صادق زاده

دانشجوی سابق کارشناسی ارشد دانشگاه علوم کشاورزی و منابع طبیعی ساری؛ Zahra.norouzian.azizi@gmail.com

دانشیار دانشگاه علوم کشاورزی و منابع طبیعی ساری؛ Sepanlu@yahoo.com

استادیار دانشگاه علوم کشاورزی و منابع طبیعی ساری؛ Mostafaemadi@gmail.com

استادیار دانشگاه علوم کشاورزی و منابع طبیعی ساری؛ Fardin\_sadeqzade@gmail.com

دریافت: 94/8/20 و پذیرش: 95/12/2

### چکیده

هدایت هیدرولیکی اشباع یکی از خصوصیات مهم هیدرولیکی در علوم مرتبط با آب، خاک و کشاورزی می‌باشد که در مدلسازی حرکت املاح و آب در خاک بسیار اهمیت دارد. اندازه‌گیری آزمایشگاهی و صحرایی آن دشوار، وقت‌گیر و پرهزینه بوده و امکان شناسایی تغییرپذیری مکانی و زمانی آن در مقیاس وسیع عملاً وجود ندارد. امروزه با استفاده از روش‌های غیرمستقیم مانند توابع انتقالی می‌توان آن را با دقت بالایی برآورد نمود. پژوهش حاضر با هدف استفاده از روش‌های رگرسیونی و شبکه عصبی مصنوعی به عنوان دو روش کارآمد از توابع انتقالی، در برآورد هدایت هیدرولیکی اشباع انجام شد. در این مطالعه هدایت هیدرولیکی اشباع 80 نمونه خاک با سه تکرار به روش آزمایشگاهی بررسی شد. خصوصیات زودبافت خاک (بافت، میانگین هندسی قطر ذرات و انحراف معیار آن، جرم مخصوص ظاهری و حقیقی، هدایت الکتریکی، pH، ماده آلی و کربنات کلسیم) که به عنوان ورودی در توابع استفاده شد به دو دسته آموزش (80%) و آزمون (20%) تقسیم شدند. به منظور مدلسازی هدایت هیدرولیکی اشباع از مدل‌های رگرسیون چند متغیره خطی (MLR)، شبکه عصبی پرسپترون چندلایه (MLP) و شبکه عصبی تابع پایه شعاعی (RBF) استفاده شد. همچنین برای ارزیابی اعتبار توابع توسعه یافته از شاخص‌های ضریب تبیین ( $R^2$ )، میانگین مجذور مربعات خطا (RMSE) و ضریب همبستگی همگام (CCC) استفاده شد. نتایج نشان از برتری مدل پرسپترون شبکه عصبی با دو لایه مخفی با تابع فعال‌سازی سیکموئیدی با  $R^2$ ، RMSE و CCC به ترتیب معادل 0/871، 1/02 (cm/h) و 0/869 نسبت به سایر مدل‌ها در منطقه مورد مطالعه داشته است. با توجه به نتایج آنالیز حساسیت، مدل بهینه دارای بالاترین حساسیت نسبت به تغییرات پارامترهای جرم مخصوص ظاهری، pH و تخلخل دارد و در مقابل نسبت به پارامتر شوری کمترین حساسیت را نشان داد. به نظر می‌رسد که استفاده از شبکه عصبی پرسپترون با دو لایه مخفی روش کارآمدی برای تعیین هدایت هیدرولیکی اشباع در منطقه باشد و بتواند با صرفه جویی در زمان و هزینه، هدایت هیدرولیکی اشباع خاک را برآورد کند. نتایج این تحقیق به علت کمبود تعداد نمونه‌ها اعتبار کافی را نداشته، لذا می‌تواند به عنوان شروعی برای انجام تحقیقات بعدی استفاده شود.

واژه‌های کلیدی: توابع انتقالی، پرسپترون چندلایه، تابع پایه شعاعی، آنالیز حساسیت

<sup>1</sup> نویسنده مسئول، آدرس: ساری، دانشگاه علوم کشاورزی و منابع طبیعی، گروه علوم خاک

## مقدمه

عوامل هیدرولوژیکی خاک برای بیشتر مدل‌هایی که در علوم مرتبط با آب، خاک و کشاورزی تهیه شده و توسعه یافته‌اند، جزو نمایه‌های ورودی مهم و مورد نیاز می‌باشد (دوناتولی و اکوتیس، 2001). هدایت هیدرولیکی اشباع خاک (Ks) به عنوان یکی از خصوصیات مهم هیدرولوژیکی خاک جهت تخمین مدل‌های هیدرولوژیکی و همچنین به عنوان اساسی‌ترین ورودی برای مدل‌سازی رواناب، طرح‌های زهکشی و حرکت املاح در خاک می‌باشد که تغییرات مکانی آن اغلب مورد نیاز است (براد و همکاران 1995، مالانتز و همکاران 1997). تعیین هدایت هیدرولیکی اشباع به طور مستقیم از طریق روش‌های آزمایشگاهی و صحرایی انجام می‌گیرد (کلوت و دیرکسن 1986).

چندین روش آزمایشگاهی (کلوت و دیرکسن 1986) و مزرعه‌ای (الریک و رینولدز 1992) برای اندازه‌گیری این خاصیت هیدرولیکی خاک ارائه شده است. هر دو روش مزرعه‌ای و آزمایشگاهی دشوار، دست و پا گیر، وقت گیر و پرهزینه است. علاوه بر این، ممکن است نتایج آن با توجه به تغییرات زمانی و مکانی در خواص فیزیکی و هیدرولیکی خاک دقیق نباشد. این امر منجر به توسعه و استفاده گسترده از روش‌های غیرمستقیم شده است. سه دسته از روش‌های غیر مستقیم جهت برآورد خواص هیدرولیکی خاک وجود دارد که عبارتند از: 1. مدل‌های توزیع اندازه ذرات 2. مدل معکوس و 3. توابع انتقالی خاک (شاپ و همکاران، 2001). در میان این سه روش غیرمستقیم، توابع انتقالی خاک<sup>1</sup> (PTFs) به طور فزاینده‌ای جهت برآورد خصوصیات هیدرولیکی خاک محبوبیت یافته‌اند (وستن و همکاران 1995). استفاده از توابع انتقالی خاک برای اولین بار توسط بوما برای توصیف روابط کمی بین برخی خصوصیات زودیافت و دیریافت خاک بکار برده شد (بوما 1989).

اکثرتوابع انتقالی برای تخمین خصوصیات هیدرولیکی خاک، از داده‌های پایه‌ای خاک چون بافت خاک، جرم مخصوص ظاهری و یا میزان ماده آلی استفاده می‌کنند (هاورکامپ و همکاران 2005). این توابع ویژگی‌های زودیافت را به ویژگی‌های دیریافت مربوط می‌کنند (آگیار و همکاران، 2007). اگرچه روش‌های آماری متعارف برای توسعه توابع انتقالی مانند روش‌های رگرسیونی وجود دارد، اما در سال‌های اخیر تکنیک‌های مدل‌سازی مبتنی بر هوش مصنوعی مانند شبکه-

های عصبی مصنوعی<sup>2</sup> (ANN) به خاطر قابلیت بالای پیش‌بینی و ویژگی‌های غیرخطی محبوبیت زیادی را به عنوان یک ابزار آماری مناسب در مدل‌سازی مسائل متنوع زیست محیطی توسعه یافته‌اند (ایلماز و کاینار 2011). در این زمینه تلاش‌های بسیاری در رابطه با مدل‌سازی پارامترهای فیزیکوشیمیایی مختلف خاک از طریق روش‌های مختلف مدل‌سازی مبتنی بر هوش مصنوعی مانند برآورد توانایی سله‌بندی خاکدانه (تکین و آکباس 2011)، تعیین پنخشدگی رس (زورلوتر و همکاران 2010)، پیش‌بینی پتانسیل تورم خاک‌های رسی (ایلماز و کاینار 2011)، مدل‌سازی جذب سرب (II) از محلول آبی (دمیرل و یتیلیمزوسی 2008)، برآورد فرسایش خاک و غلظت مواد مغذی در رواناب (کیم و گیلی 2008)، مدل‌سازی ظرفیت تبادل کاتیونی خاک (تنگ و همکاران، 2009)، پیش‌بینی مقدار آب خاک (بوتولا و همکاران 2012) و تعیین مقدار آب اشباع و آب ظرفیت زراعی (زیانگشن و همکاران 2013) را می‌توان نام برد. مدل‌سازی هدایت هیدرولیکی اشباع با استفاده از توابع انتقالی نیز در پژوهش‌های بسیاری به چشم می‌خورد. در این راستا می‌توان به پژوهش‌های قنبریان علویچه و همکاران (2010)، رسول زاده (2011)، حق وردی و همکاران (2012)، کیان پور و همکاران (2012)، روجیرز و همکاران (2012) اشاره کرد.

با توجه به نتایج غیر یکسان در مطالعات گذشته، می‌توان بیان داشت تمامی زوایای آن به طور کامل شناخته نشده است و یا حداقل برای هر منطقه باید جداگانه توسعه یابد. در این راستا مطالعات مربوط به برآورد هدایت هیدرولیکی اشباع خاک، که بیانگر بسیاری از خصوصیات خاک می‌باشد در استان مازندران، که مشکلات زیادی در مسئله زهکشی دارد انجام نشده است. بنابراین هدف اصلی این پژوهش امکان استفاده از توابع انتقالی از قبیل روش‌های رگرسیونی، شبکه عصبی پرسپترون چندلایه (MLP) و شبکه عصبی تابع پایه شعاعی (RBF) و ارزیابی دقت آنها در برآورد هدایت هیدرولیکی اشباع خاک‌های بخشی از استان مازندران و بررسی آنالیز حساسیت هر یک از پارامترهای زودیافت اندازه‌گیری شده در برآورد هدایت هیدرولیکی اشباع می‌باشد.

<sup>2</sup> Artificial Neural Network

<sup>1</sup> Pedotransfer functions

## مواد و روش‌ها

## نمونه‌برداری و جمع‌آوری اطلاعات

نمونه‌برداری از مناطق مختلف استان مازندران از کاربری‌های شالیزاری، باغی، جنگلی، زراعی، مرتعی و نواحی ساحلی صورت گرفت. منطقه نمونه‌برداری شده دارای رژیم حرارتی یکسان (ترمیک) بوده‌اند. سعی گردید نقاط نمونه‌برداری به گونه‌ای انتخاب شوند که متغیرهای اصلی مؤثر در نمونه‌های تهیه شده، دارای دامنه تغییرات نسبتاً زیادی باشند. 80 محل انتخاب و از عمق 0 تا 30 سانتیمتری با سه تکرار به صورت دست نخورده با رینگ بزرگ (ارتفاع 12/5 سانتیمتر و قطر 10 سانتیمتر) نمونه‌های دست نخورده برداشته شد. محل نمونه‌برداری در شکل 1 نشان داده شده است. جهت اندازه‌گیری هدایت هیدرولیکی اشباع از روش آزمایشگاهی بار افتان (خاک-های سنگین) و ثابت (خاک‌های سبک) استفاده شد (کلوت و دیرکسن، 1986). پارامترهای زودپافت شامل درصد فراوانی ذرات با روش هیدرومتری (وستمن 1990)، جرم مخصوص ظاهری به روش استوانه (بلیک و هاتیچ 1986)، جرم مخصوص حقیقی خاک به روش پیکنومتری (کلوت 1986)، تخلخل (کلوت 1986)، میانگین هندسی قطر ذرات و انحراف معیار آن از روابط ارائه شده توسط شیرازی و بورسما (شیرازی و بورسما 1984)، ماده آلی به روش والکلی و بلک (والکلی و بلک 1934)، کربنات کلسیم معادل به روش تیتراسیون (پیچ و همکاران، 1982)، pH و هدایت الکتریکی (EC<sup>1</sup>) به ترتیب با pH متر و EC متر (نلسون و سامرز 1986) اندازه‌گیری شدند. به منظور بررسی وجود همراستایی چندگانه از فاکتور تورم واریانس (VIF<sup>2</sup>) استفاده شد.

## نرمال سازی داده‌ها

در آزمون‌های آماری نخستین گام در تجزیه و تحلیل داده‌ها نرمال کردن داده‌هاست. نرمال نبودن داده‌ها نتایج و تجزیه و تحلیل‌ها را نامعتبر می‌سازد (قربانی دشتکی و همکاران 2010). اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای اجتناب از چنین شرایطی و همچنین به منظور یکسان نمودن ارزش داده‌ها، ابتدا بررسی نرمال بودن داده با آزمون کولموگروف-اسمیرنوف در نرم‌افزار SPSS انجام شد. از 3 تکرار در محل‌های نمونه‌برداری میانگین‌گیری و به عنوان یک نمونه در پردازش داده‌ها استفاده شد.

## توسعه توابع انتقالی

روش‌های مورد استفاده در این پژوهش شامل رگرسیون چند متغیره خطی، شبکه عصبی MLP با 1 و 2 لایه مخفی و شبکه عصبی RBF بود. 20% از داده‌ها به منظور آزمون مدل (ارزیابی اعتبار) و 80% باقیمانده برای آموزش مدل انتخاب شد. تقسیم داده‌ها به صورت تصادفی در نرم افزار اکسل انجام شد. از نرم افزار SPSS 18 برای انجام توسعه مدل رگرسیونی و شبکه عصبی استفاده شد.

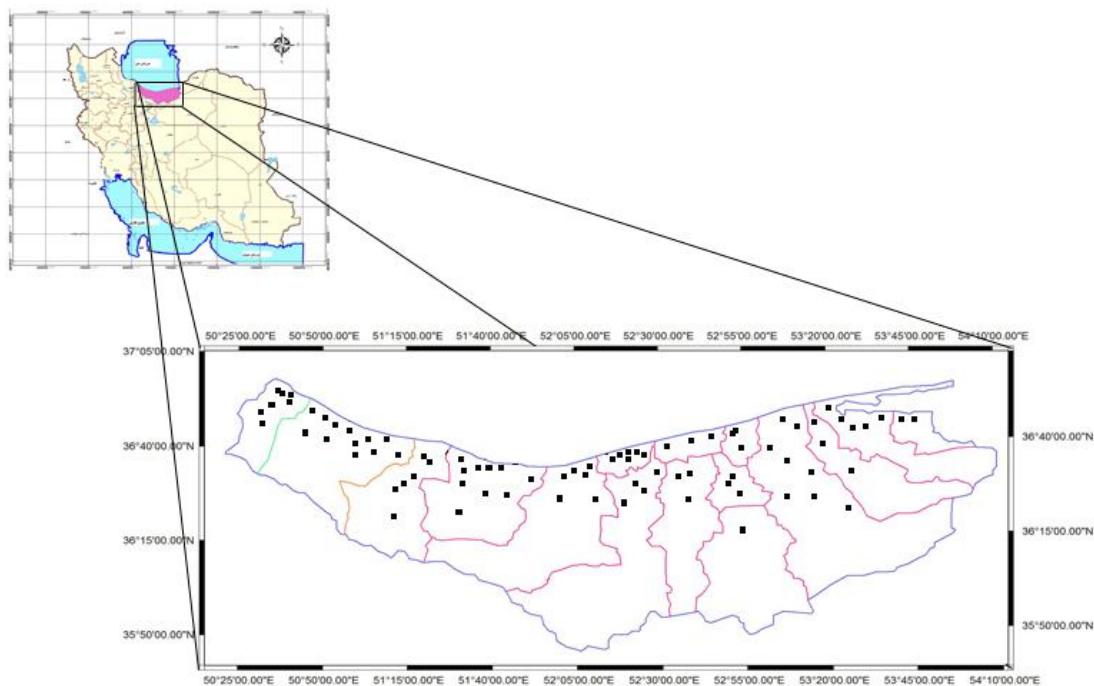
## رگرسیون چند متغیره خطی

در این تحقیق جهت توسعه مدل رگرسیونی چند متغیره خطی برای تخمین هدایت هیدرولیکی اشباع خاک با استفاده از خصوصیات زودپافت خاک از 3 روش گام به گام (Stepwise)، پیش رونده (Forward) و پس رونده (Backward) استفاده شد.

## پرسپترون چندلایه

برای آموزش شبکه عصبی MLP و به منظور توسعه مدل‌های شبکه‌های عصبی از 12 نرون در لایه ورودی (تعداد متغیرهای مستقل)، 1 نرون در لایه خروجی (متغیر وابسته) و تعدادی نرون در لایه میانی (به روش سعی و خطا) استفاده شد. شبکه عصبی مصنوعی پیشخور با الگوریتم پس انتشار خطا به منظور برآورد مدل بهینه مورد استفاده قرار گرفت. شبکه عصبی پرسپترون به عنوان رایج‌ترین ساختار شبکه عصبی در مدل‌سازی محیط زیست و علوم خاک (آگیار و همکاران، 2007) می‌باشد. جهت توسعه معماری مناسب شبکه ابتدا سعی شد تا با استفاده از یک شبکه با یک لایه مخفی و تعداد 3 الی 20 نرون، شبکه مناسبی برای تخمین هدایت هیدرولیکی اشباع فراهم آورد. در شبکه پرسپترون از لایه ورودی به لایه پنهان از تابع فعال سازی سیگموئید<sup>3</sup> برای استاندارد نمودن متغیرهای ورودی و خروجی و در لایه خروجی از تابع فعالیت خطی (pureline) استفاده شد. برای به دست آوردن مدلی با کارایی بالاتر، شبکه توسعه داده شد و یک لایه مخفی دیگر نیز اضافه گردید. تعداد نرون‌های لایه دوم نیز با روش سعی و خطا (تجربی) و با در نظر گرفتن 3 تا 20 نرون مشخص شد. تابع انتقال سیگموئیدی نیز برای لایه دوم منظور گردید. در این شبکه با فرض ثابت بودن تعداد نرون یک لایه، تعداد نرون‌های لایه دوم تغییر کرده و با روش سعی و خطا بهترین معماری لایه پنهان دوم مشخص شد.

<sup>1</sup> Electrical Conductivity<sup>2</sup> Variance Inflation Factor<sup>3</sup> Sigmoid



شکل 1- محل نمونه برداری داده‌ها در استان مازندران

#### شبکه عصبی تابع پایه شعاعی

در مطالعه حاضر از شبکه عصبی RBF نیز جهت تخمین داده‌های هدایت هیدرولیکی اشباع خاک استفاده گردید. این نوع شبکه عصبی دارای پایه ریاضی بسیار قوی بر مبنای فرضیه منظم سازی و به نام شبکه عصبی آماری معروف است. به طور کلی این شبکه تقریباً از سه لایه شامل ورودی، مخفی و خروجی تشکیل شده است. در لایه مخفی، تابع انتقال گوسی استفاده می‌شود و در لایه خروجی تابع انتقال خطی است. در واقع نرون روش RBF یک تابع گوسی است. ورودی این تابع، فاصله اقلیدسی بین هر ورودی به نرون با بردار مشخص شده‌ی هم اندازه‌ی بردار ورودی است. فرم کلی ریاضی نرون‌های خروجی در شبکه‌ی RBF به شکل معادله زیر می‌باشد:

$$C_j(x) = \sum_{i=1}^k w_{ji} \phi(\|x - \mu_i\|; \sigma_i) \quad (1)$$

که در آن  $C_j(x)$  تابع وابسته به  $j$  امین واحد خروجی و ترکیب خطی از  $k$  تابع پایه شعاعی  $\phi(\cdot)$  با مرکز  $\mu_i$  و پهنای باند  $\sigma_i$  و همچنین وزن وابسته به  $j$  امین کلاس و  $i$  امین کلاس و  $i$  امین مرکز میباشد. تابع  $\phi(\|x - \mu_i\|)$  تابع پایه شعاعی نامیده می‌شود و  $\|\cdot\|$  به معنی فاصله اقلیدسی می‌باشد. یکی از تفاوت‌های  $RBF$  و  $MLP$  در این است که

در روش  $MLP$ ، مجموع وزندهار نرون‌های رسیده به نرون لایه میانی به عنوان ورودی توابع تحریک در نظر گرفته می‌شود ولی در شبکه  $RBF$  فاصله هر الگو با بردار مرکز هر نرون در لایه میانی به عنوان ورودی تابع تحریک شعاعی محاسبه می‌شود.

#### معیارهای ارزیابی

در این تحقیق برای ارزیابی و کارایی عملکرد مدل‌ها از شاخص‌های کمی مانند ضریب تبیین ( $R^2$ )، مجذور میانگین مربعات خطا<sup>1</sup> (RMSE) و ضریب همبستگی همگام<sup>2</sup> (CCC) استفاده شد. ضریب تبیین ( $R^2$ ) یکی از آماره‌هایی است که در مقالات شبکه‌های عصبی به فراوانی از آن استفاده شده است. فاکتور مجذور میانگین مربعات خطا (RMSE) دقت و اعتبار بین مقادیر داده‌های آموزشی و آزمونی را نشان می‌دهد (شاپ و لیچ، 1998). هرچه مقدار مجذور میانگین مربعات خطا به صفر نزدیک‌تر باشد نتیجه بدست آمده مطلوب‌تر است. ضریب همبستگی همگام (CCC) نیز چگونگی قرارگیری یک نقطه پیش بینی شده را نسبت به خط 45 درجه را نشان

<sup>1</sup> Root-mean-square error (RMSE)

<sup>2</sup> Concordance correlation coefficient (CCC)

## نتایج

با توجه به جدول 1، خاک‌های نمونه‌برداری شده دامنه گسترده‌ای از خصوصیات فیزیکی و شیمیایی خاک با توجه به گستردگی خاک‌های مختلف در استان مازندران را دارا هستند. خلاصه آماری خصوصیات مورد مطالعه داده‌ها در جدول 1 ارائه شد. ضریب تغییرات ماده آلی خاک بالا و پس از شوری دارای بیشترین ضریب تغییرات است. میانگین کربنات کلسیم معادل خاک‌های مورد مطالعه 16/66 درصد بدست آمد که نشان از آهکی بودن عمده خاک‌ها در استان مازندران دارد. حداکثر (8/73) و حداقل (4/71) مقدار pH نشان از تنوع خاک-های مورد مطالعه از قلیا تا اسیدی را دارد. به طور کلی هرچه به سمت ارتفاعات و پوشش جنگلی پیش می‌رویم، pH خاک‌ها کمتر، ماده آلی بیشتر و هدایت هیدرولیکی اشباع در عمده موارد بیشتر می‌شد. نمونه‌هایی با ماده آلی بیشتر و pH و کربنات کلسیم کمتر مربوط به خاک‌های جنگلی و دشت‌های استان عمدتاً کربنات کلسیم بیشتر و بافت ریزتری داشته‌اند. اوسبورن (2010) در پژوهش خود بیان داشت داده‌های که کشیدگی آن‌ها در حدود  $\pm 0/8$  باشد، دارای توزیع نرمال می‌باشند. در این پژوهش بررسی نرمال بودن توزیع پارامتر وابسته (هدایت هیدرولیکی اشباع خاک) و پارامترهای مستقل (ماده آلی، کربنات کلسیم معادل، جرم مخصوص ظاهری و حقیقی، تخلخل، اسیدیته، شوری، فراوانی نسبی ذرات خاک، میانگین هندسی قطر ذرات و انحراف معیار آن‌ها) با استفاده از آزمون کولموگروف اسمیرنوف انجام شد.

در این راستا جهت نرمال سازی توزیع داده‌های غیر نرمال از تبدیل لگاریتمی استفاده شد. جرم مخصوص ظاهری هم از 0/73 (برای نمونه‌ای با میزان 7 درصد کربن آلی در پوشش انبوه جنگلی) تا 1/6 (در خاک اراضی شالیزار) تغییرات داشته است. هدایت هیدرولیکی اشباع، هدایت الکتریکی، اسیدیته (pH) و میانگین هندسی قطر ذرات نرمال نبودند (جدول 1) و با روش‌های مختلف نرمال‌سازی مورد تبدیل قرار گرفتند و در نهایت روش لگاریتمی در پایه عدد طبیعی (Ln) برای نرمال سازی استفاده شد. بر این اساس کلیه داده‌های ورودی دارای توزیع نرمال بودند. همبستگی بین هدایت هیدرولیکی اشباع و خصوصیات خاک نیز در جدول 2 آمده است.

می‌دهد که خود بیانگر ضریب همبستگی همگام است و هرچه به 1 نزدیک‌تر باشد مقدار پیش‌بینی شده به مقدار واقعی نزدیک‌تر است (لین 1989). در زیر معادلات و اجزای آن‌ها نشان داده می‌شود.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$CCC = \frac{2\rho\sigma_x\sigma_y}{\sigma_x^2 + \sigma_y^2 + (\mu_x - \mu_y)^2} \quad (4)$$

که در آن‌ها:  $n$  تعداد داده‌های پارامتر اندازه‌گیری شده یا تخمینی است.  $y_i$  و  $\hat{y}_i$  ترتیب مقادیر پارامتر اندازه‌گیری شده و تخمینی هدایت هیدرولیکی،  $\hat{y}_i$  میانگین هدایت هیدرولیکی اندازه‌گیری شده،  $\rho$  ضریب همبستگی پیرسون بین دو پارامتر اندازه‌گیری شده و تخمین زده شده،  $\sigma_x^2$  و  $\sigma_y^2$  به ترتیب واریانس پارامتر اندازه‌گیری شده و تخمینی،  $\sigma_x$  و  $\sigma_y$  به ترتیب انحراف معیار پارامتر اندازه‌گیری شده و تخمینی و  $\mu_x$  و  $\mu_y$  میانگین پارامتر اندازه‌گیری شده و تخمینی است.

## آنالیز حساسیت

آنالیز حساسیت مدل، مشخص می‌کند که خروجی مدل تا چه اندازه تحت تأثیر هر کدام از ورودی‌های مدل بوده و به ازای تغییر یک واحد در هر کدام از ورودی‌ها، خروجی مدل چه مقدار تغییر خواهد کرد (مورگان 2005). در نتیجه در صورتی که نیاز به ایجاد تعداد ورودی کمتر باشد، پارامترهایی که دارای حساسیت کمی هستند صرف نظر می‌شوند (نوروزیان 1393). برای انجام آنالیز حساسیت برای داده‌های هر شبکه که دارای مقادیر ورودی مربوط به خودش است، مقادیر مشتق نسبی خروجی نسبت به هر یک از ورودی‌ها به طور جداگانه محاسبه و در پایان از روش آماری مقادیر حساسیت نسبی که بوسیله لو و همکاران (2011) بیان شد استفاده گردید. روابط مربوطه و معادلات مشتق خروجی شبکه عصبی مصنوعی توسط امامی و یثربی (1393) نیز مورد استفاده و بررسی قرار گرفت.

جدول 1- خلاصه آماری داده‌های مورد مطالعه

مقدار $p$ در آزمون KS الف	ضریب کشیدگی	ضریب تغییرات	میانگین	کمینه	بیشینه	خصوصیات خاک
0/009	3/23	204/88	7/32	0/04	72/95	بار ثابت (cm/h)
0/006	4/97	328/84	9/40	0/01	212/79	بار افتان (cm/h)
0/25	0/77	62/13	2/48	0/24	6/39	ماده آلی (%)
0/214	0/11	61/63	16/66	0/52	40/17	کربنات کلسیم معادل (%)
0/095	0/20	16/94	1/15	0/73	1/60	جرم مخصوص ظاهری ( $g/cm^3$ )
0/110	-0/79	7/05	2/48	1/82	2/75	جرم مخصوص حقیقی ( $g/cm^3$ )
0/124	-0/76	16/35	53	23	69	تخلخل
0/001	10/20	6/89	7/45	4/71	8/73	pH
0/005	4/50	189/27	2/43	0/20	28/30	(dS/m)EC
0/14	0/70	53/38	30/38	4/50	72/00	رس (%)
0/13	-0/50	41/69	37/15	0/50	63/50	سیلت (%)
0/15	0/76	69/10	32/47	3/00	89/50	شن (%)
0/036	2/60	151/320	0/072	0/003	0/520	میانگین هندسی قطر ذرات (mm)
0/168	0/26	44/61	14/76	3/14	29/43	انحراف معیار هندسی ذرات

الف: مقادیر  $p$  در آزمون کلموگروف اسمیرنوف (مقادیر کوچکتر از 0/05 نشان دهنده نرمال نبودن داده ها می باشد)

جدول 2- همبستگی بین هدایت هیدرولیکی اشباع خاکها (Ks) و خصوصیات خاک

$\sigma_g$	dg	CCE (%)	شن (%)	سیلت (%)	رس (%)	LnKs
-0/49*	-0/46**	0/22*	0/34*	0/27*	-0/56**	
EC (dS m <sup>-1</sup> )	pH	N (%)	PD (gr cm <sup>-3</sup> )	BD (gr cm <sup>-3</sup> )	OM (%)	
0/18*	-0/41*	0/29*	-0/12*	-0/39*	0/38*	

CCE: کربنات کلسیم معادل; dg: میانگین هندسی قطر ذرات;  $\sigma_g$ : انحراف معیار هندسی ذرات; OM: ماده آلی; BD: وزن مخصوص ظاهری; PD: وزن مخصوص حقیقی; N: تخلخل

## توسعه تابع انتقالی رگرسیون خطی

بدست آمده نشان می‌دهد که تابع شماره 1 با دارا بودن 2 متغیر مستقل در داده‌های آموزشی از دقت بالاتری نسبت به سایر مدل‌ها برخوردار است. در این مدل رگرسیونی برای تخمین هدایت هیدرولیکی اشباع خاک از درصد رس و لگاریتم میانگین هندسی قطر ذرات استفاده شد.

تابع رگرسیونی شماره 1 با  $R^2$  برابر 0/73 بالاترین ضریب تبیین را برای داده‌های آزمون نشان داد (جدول 4). در این تابع مقادیر CCC و RMSE نیز به ترتیب 0/65 و 1/48 (cm/h) بدست آمد. در این معادله میانگین هندسی قطر ذرات تأثیر و ضریب بالایی بر تخمین هدایت هیدرولیکی اشباع داشت. در خاک‌های انتخاب شده به دلیل تنوع بافتی تأثیر این تفاوت به وضوح دیده می‌شود.

توابع رگرسیون خطی اشتقاق یافته در جدول 3 نشان داده شده است. در جدول 3، تنها توابعی که دقت معقولی در هریک از روش‌های رگرسیون چند متغیره خطی مورد بررسی بدست آمدند، آورده شدند. از خصوصیات فیزیکوشیمیایی داده‌های آموزشی در ایجاد مدل‌های رگرسیونی استفاده گردید و در ادامه بهترین مدل رگرسیونی براساس پارامترهای آماری انتخاب شد. آزمون VIF (فاکتور تورم واریانس) برای هر یک از مدل‌های رگرسیونی انجام و با توجه به کمتر بودن آن از 5 برای تمام مدل‌ها، عدم هم خطی متغیرهای وارد شده در مدل بررسی شد. جدول 4 نیز نتایج سنجش عملکرد مدل‌های رگرسیونی ایجاد شده را نشان می‌دهد. نتایج

جدول 3- معادلات رگرسیون خطی اشتقاق یافته

تابع	حداکثر VIF	نوع رگرسیون	تابع
$\ln Ks = 0.686 - 0.114 \text{ Clay} - 0.858 \ln dg$	1/02	گام به گام	تابع 1
$\ln ks = -36.059 + 0.272 OM + 0.023 CaCO_3 - 14.675 Bd - 6.753 Pd + 32.859 n - 2.210 \ln pH + 0.024 \ln EC - 0.016 \text{ Clay} + 0.083 \text{ Silt} - 0.176 \ln \sigma g$	3/25	برگشتی	تابع 2
$\ln Ks = 1.753 - 0.053 \text{ Clay}$	2/4	پیش رونده	تابع 3

VIF: فاکتور تورم واریانس

جدول 4- نتایج معیارهای سنجش عملکرد مربوط به مدل‌های رگرسیونی اشتقاق یافته در مرحله آموزش و آزمون

داده آزمون			داده آموزش			
R <sup>2</sup>	RMSE	CCC	R <sup>2</sup>	RMSE	CCC	
0/73**	1/48	0/650	0/54*	1/53	0/480	تابع 1
0/54*	0/89	0/052	0/67**	1/44	0/628	تابع 2
0/64**	1/65	0/026	0/47**	1/61	0/019	تابع 3

### شبکه عصبی پرسپترون

یکی از بهترین خروجی‌ها مربوط به شبکه پرسپترون با یک لایه مخفی با تابع تبدیل تانژانت سیگموئیدی با تعداد 3 و 4 نرون در لایه میانی برای داده‌های آموزش بود. جدول 5 نتایج معیارهای سنجش عملکرد این شبکه را نشان می‌دهد. ارزیابی نتیجه داده‌های آموزشی و آزمون برای شبکه پرسپترون با دو لایه مخفی (جدول 6) بیانگر کارایی بسیار بالای شبکه پرسپترون با 7 نرون در لایه میانی اول و 19 نرون در لایه میانی دوم در داده‌های آموزشی نسبت به سایر معماری‌های مربوطه به شبکه پرسپترون دو لایه می‌باشد.

### شبکه عصبی RBF

نتایج سنجش عملکرد مربوط به شبکه عصبی RBF نیز در جدول 5 قابل مشاهده است. نتایج نشان می‌دهد مدل شبکه عصبی RBF نیز تا حد زیادی قادر به برآورد هدایت هیدرولیکی اشباع در منطقه مورد نظر می‌باشد، بطوری که ضریب تبیین داده‌های برآوردی با داده‌های واقعی معادل با 0/783 می‌باشد. همچنین مقدار RMSE نیز برابر 1/34 (cm/h) برآورد شده است. در تحلیل رابطه‌ی هدایت هیدرولیکی اشباع خاک با پارامتر

های موجود در مدل رگرسیونی آیمرون و آمین (2009) بهترین مدل رگرسیونی برای پیش‌بینی هدایت هیدرولیکی اشباع در اراضی شالیزاری را مدل گام به گام معرفی کردند، که نتایج مدل رگرسیونی این تحقیق نیز این مسئله را تأیید می‌کند. همچنین قابل ذکر است، که با کاهش رس خاک و میانگین هندسی قطر ذرات هدایت هیدرولیکی اشباع خاک افزایش می‌یابد.

### بحث و نتیجه‌گیری

مقایسه روش رگرسیونی با شبکه عصبی مصنوعی و انتخاب مدل بهینه

به منظور ارزیابی کارایی مدل‌ها و همچنین مقایسه مدل‌های شبکه عصبی و توابع انتقالی رگرسیونی از داده‌های آزمون که در محاسبه این توابع دخالت نداشتند برای برآورد هدایت هیدرولیکی اشباع استفاده گردید. نتایج این مقایسه در جدول 7 نشان داده شده است. نتایج بدست آمده از تحقیق نشان داد که در صورت استفاده از پارامترهای فیزیکوشیمیایی به عنوان داده‌های ورودی به شبکه و لگاریتم هدایت هیدرولیکی به عنوان داده خروجی از شبکه و استفاده از تابع انتقال سیگموئیدی در لایه مخفی، شبکه عصبی پرسپترون تخمین مورد اطمینان و قابل قبولی از مقدار هدایت هیدرولیکی اشباع به دست می‌دهد.

جدول 5- نتایج معیارهای سنجش عملکرد مربوط به شبکه پرسپترون با یک لایه مخفی و شبکه عصبی تابع پایه شعاعی

داده آزمون			داده آموزشی			ANN
CCC	RMSE	R <sup>2</sup>	CCC	RMSE	R <sup>2</sup>	
0/824	1/09	0/853**	0/625	1/46	0/643**	MLP با 3 نرون در لایه مخفی
0/749	1/24	0/820**	0/630	1/43	0/658**	MLP با 4 نرون در لایه مخفی
0/673	1/34	0/783**	0/498	1/54	0/550**	RBF

جدول 6- نتایج معیارهای سنجش عملکرد مربوط به شبکه پرسپترون با 2 لایه مخفی

داده آزمون			داده آموزشی			نرون لایه دوم	نرون لایه اول
CCC	RMSE	R <sup>2</sup>	CCC	RMSE	R <sup>2</sup>		
0/869	1/02	0/871**	0/808	1/10	0/815**	19	7

ضریب تبیین و ضریب همبستگی همگام و کمترین مقدار میانگین مربعات خطا را با داده‌های واقعی دارد به عنوان مدل بهینه در برآورد هدایت هیدرولیکی اشباع در منطقه مورد مطالعه شناخته شد. مقادیر زیاد ضریب تبیین و خطای پایین در مراحل آموزش و آزمون شبکه، مؤید این است که مدل به خوبی توانسته است هدایت هیدرولیکی اشباع خاک را با استفاده از ویژگی‌های زودیافت خاک تخمین بزند. پژوهشگرانی مانند پاچپسکی و همکاران (1996)، مارسل و همکاران (1998)، شاپ و همکاران (1998) با بررسی شبکه‌های عصبی و مدل‌های رگرسیونی گزارش کردند که عملکرد شبکه‌های عصبی مصنوعی بهتر از سایر توابع انتقالی منتشر شده است. فریت و همکاران (2003) از شبکه‌های عصبی مصنوعی با ساختار پرسپترون چندلایه با دو لایه پنهان و تابع عملگر سیگموئید به منظور برآورد رطوبت خاک استفاده کردند و گزارش کردند که شبکه‌های عصبی که از چنین ساختاری بهره می‌برند ابزار مناسبی برای تخمین رطوبت خاک هستند. کارایی بهتر شبکه‌های عصبی را می‌توان به این دلیل دانست که این مدل‌ها نیاز به یک مدل پیش فرض برای پیش‌بینی هدایت هیدرولیکی ندارند (آگیار و همکاران، 2007).

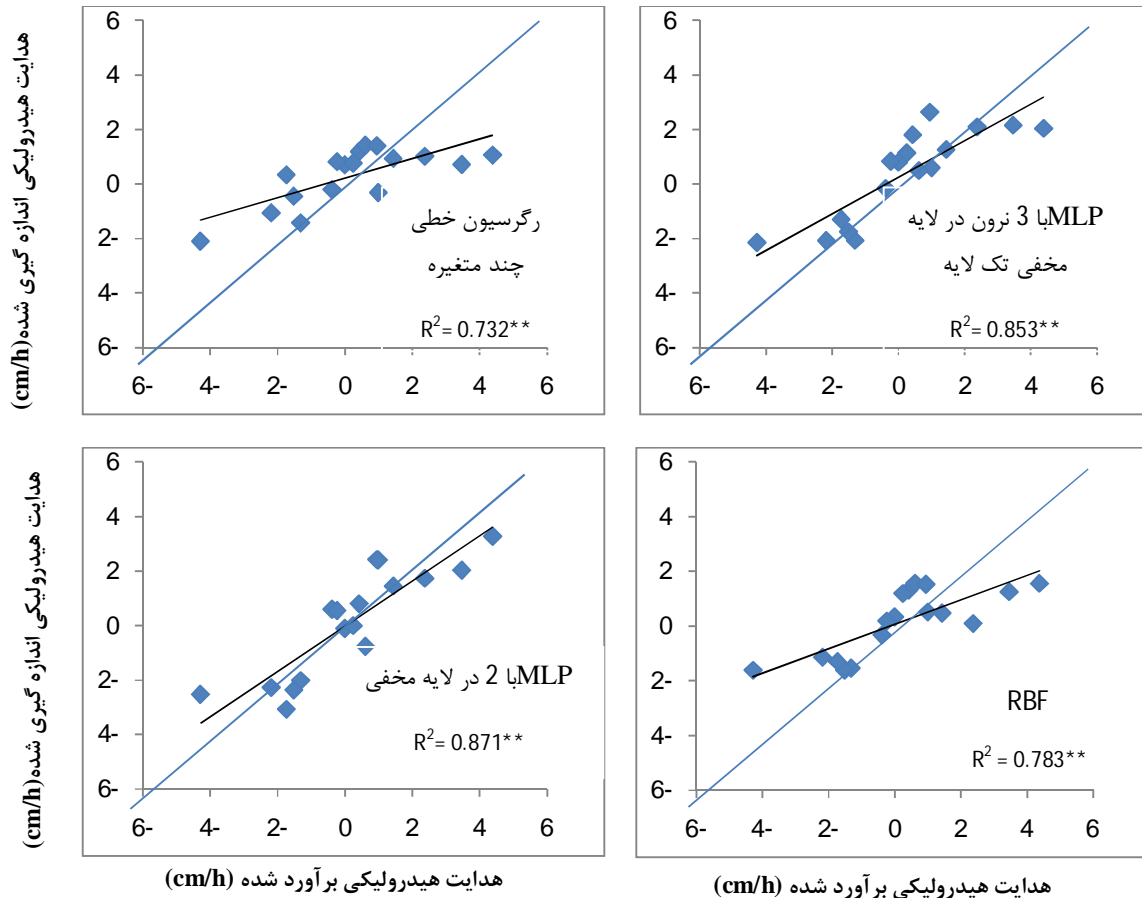
برای نشان دادن دقت برآوردها، مقادیر هدایت هیدرولیکی اشباع پیش‌بینی شده در مقابل مقادیر اندازه-گیری شده نسبت به خط 1:1 برای داده‌های آزمون در هر 4 مدل (رگرسیون خطی، شبکه عصبی پرسپترون با 1 لایه مخفی، شبکه عصبی پرسپترون با 2 لایه مخفی و شبکه عصبی تابع پایه شعاعی ترسیم شد (شکل 2). شکل 2 از لحاظ ظاهری معرف دقت مدل پیشنهادی است. همچنین بالا بودن ضرایب همبستگی نیز نشان دهنده وابستگی بسیار نزدیک مقادیر مشاهداتی و برآوردی دارد. آنچه از نتایج به دست آمده پیدا و مسلم است، توانایی بالای شبکه عصبی پرسپترون با دو لایه مخفی در برآورد مقدار هدایت هیدرولیکی اشباع، نسبت به سایر مدل‌ها است. بهینه بودن شبکه عصبی نسبت به توابع رگرسیونی از سوی وستن و همکاران (2001) نیز گزارش شده است. آن‌ها اشاره کردند که هنگامی که بیش از سه ورودی در شبکه وجود داشته باشد معمولاً شبکه‌های عصبی مصنوعی بهتر از روش‌های رگرسیونی عمل می‌کنند.

نتایج آماری سنجش عملکرد مدل‌های برآورد هدایت هیدرولیکی اشباع خاک نیز نشان داد که مدل رگرسیون خطی دارای کمترین دقت تخمینی است. لذا شبکه عصبی پرسپترون با 2 لایه مخفی که بالاترین

جدول 7- مقایسه معیارهای سنجش عملکرد مدل‌های برآورد هدایت هیدرولیکی اشباع خاک در مرحله آزمون

CCC	RMSE	R <sup>2</sup>	روش تخمینی
0/650	1/48	0/732**	مدل رگرسیون خطی گام به گام (مدل 1)
0/824	1/09	0/853**	مدل پرسپترون با یک لایه مخفی (با 3 نرون)
0/869	1/02	0/871**	مدل پرسپترون با دو لایه مخفی (با 7 نرون در لایه اول و 19 نرون در لایه دوم)
0/673	1/34	0/783**	شبکه عصبی تابع پایه شعاعی





شکل 2- رابطه بین مقادیر هدایت هیدرولیکی اشیاع برآورد شده با مقادیر اندازه‌گیری شده (LnKs (cm/h) (خط آبی نشان دهنده خط 1:1 یا 45 درجه محور مختصات می‌باشد)

باشد، آن پارامتر جزو پارامترهای حساس مدل محسوب می‌شود. براساس نتایج آنالیز حساسیت، پارامترهای حساس و مهم در مدل‌ها شناسایی شدند. تغییر در پارامترهای حساس روش‌های مختلف مورد بررسی به ماهیت روش‌ها و مدل‌ها وابسته است. در برآورد هدایت هیدرولیکی اشیاع به تناسب مدل و ضرایب داده شده به متغیرهای ورودی، حساسیت هر یک تعیین گردید. در مدل رگرسیونی پارامترهای رس و میانگین هندسی قطر ذرات و در شبکه عصبی پرسپترون با یک لایه مخفی پارامترهای رس، سیلت و pH، در مدل شبکه عصبی RBF نیز پارامترهای رس، pH، انحراف معیار میانگین هندسی ذرات و سیلت جز پارامترهای حساس بر خروجی مدل معرفی شده‌اند. در مدل بهینه با تابع فعال‌سازی سیگموئیدی پارامتر ورودی جرم مخصوص ظاهری بیشترین تأثیر را بر خروجی‌های مدل دارد و اسیدیته خاک به عنوان دومین پارامتر مهم و مؤثر بر خروجی‌های مدل

آنالیز حساسیت مدل رگرسیونی و شبکه عصبی مصنوعی در اکثر توابع انتقالی خصوصیتی از خاک استفاده می‌شوند که برداشت و ثبت آن‌ها در معرض خطاهای انسانی و سیستماتیک قرار دارد. لذا بررسی تأثیر تغییرات این عوامل و تعیین مؤثرترین متغیرهای مستقل در تخمین هدایت هیدرولیکی اشیاع توسط تابع انتقالی، ضروری به نظر می‌رسد. بر این اساس حساسیت توابع انتقالی ارائه شده در این تحقیق در اثر تغییرات پارامترهای ورودی در برآورد هدایت هیدرولیکی اشیاع مورد ارزیابی قرار گرفت. نتایج آنالیز حساسیت روش رگرسیونی و شبکه عصبی مصنوعی در جدول 8 نشان داده شد. در این جدول رتبه 1 برای پارامتری است که بیشترین حساسیت و رتبه 12 برای پارامتری است که کمترین حساسیت را بر هدایت هیدرولیکی اشیاع دارا می‌باشد. هیل (1998) در پژوهش‌های خود بیان می‌کند که اگر مقدار ضریب حساسیت پارامتری از 0/1 بیشتر

مخصوص ظاهری و pH بدست آمد. باتوجه به این که اندازه‌گیری ورودی‌های بیشتر، مستلزم صرف وقت و هزینه بیشتر است، استفاده از ورودی‌های غیر حساس یا با حساسیت پایین برای تخمین منطقی به نظر نمی‌رسد.

یاد شده است و درصد تخلخل در مرتبه بعدی اهمیت قرار دارد. روش‌های مختلف بدست آمده براساس پتانسیل های متفاوت در تخمین و شیوه برآورد، حساسیت‌های مختلفی به پارامترهای سهل الوصول ورودی داشته‌اند. به طور کلی مهمترین پارامترها توزیع اندازه ذرات و جرم

جدول 8- مقایسه نتایج آنالیز حساسیت روش رگرسیونی و شبکه عصبی مصنوعی

رتبه	مدل 2 رگرسیونی	مدل پرسپترون با 1 لایه میانی	مدل پرسپترون با 2 لایه میانی	مدل شبکه عصبی RBF
1	Clay (/114)	Clay (/214)	Bd (/143)	Clay (/171)
2	dg (/858)	Silt (/174)	pH (/140)	pH (/112)
3		pH (/103)	n (/118)	$\sigma_g$ (/109)
4		$\sigma_g$ (/095)	Silt (/099)	Silt (/102)
5		dg (/076)	Pd (/094)	Bd (/087)
6		Bd (/074)	$\sigma$ /089g	OM (/078)
7		OM (/055)	OM (/066)	n (/074)
8		Sand (/053)	Sand (/056)	dg (/066)
9		EC (/053)	dg (/054)	Pd (/061)
10		Pd (/043)	Clay (/048)	CaCO <sub>3</sub> (/055)
11		n (/030)	CaCO <sub>3</sub> (/045)	EC (/051)
12		CaCO <sub>3</sub> (/026)	EC (/044)	Sand (/029)

اعداد داخل پرانتز ضریب حساسیت را نشان می‌دهند.

## نتیجه کلی

پنهان دوم در تخمین هدایت هیدرولیکی اشباع نسبت به مدل رگرسیون خطی و RBF داشت. نتایج آنالیز حساسیت نیز نشان داد که جرم مخصوص ظاهری مهم‌ترین پارامتر ورودی برای خاک‌های مورد مطالعه است. سهولت اندازه‌گیری پارامترهای ورودی حساس مدل بهینه (جرم مخصوص ظاهری، pH و تخلخل) در این مدل تخمینی بسیار حائز اهمیت می‌باشد. به گونه‌ای که می‌توان از آن در تخمین‌های اولیه معیارهای لازم برای طراحی پروژه‌های آبیاری، زهکشی و مهندسی منابع آب استفاده نمود. پیشنهاد می‌شود تحقیقات بعدی در استان مازندران برای مدلسازی هدایت هیدرولیکی اشباع خاک، با تعداد بیشتری نسبت به داده‌های این تحقیق انجام شود تا نتایج بدست آمده از اعتبار بیشتری برخوردار باشد.

هدایت هیدرولیکی اشباع به عنوان یکی از عوامل هیدرولوژیکی از خصوصیات بنیادین خاک است، لیکن اندازه‌گیری مستقیم آن پرهزینه و زمان‌بر می‌باشد. در این راستا مدل‌های رگرسیون خطی و شبکه عصبی مصنوعی جهت برآورد هدایت هیدرولیکی اشباع به وسیله خصوصیات زودیافت خاک در خاک‌های مورد مطالعه توسعه داده شدند و عملکرد مدل‌های شبکه عصبی مصنوعی و رگرسیون خطی مورد ارزیابی قرار گرفت. بالا بودن R<sup>2</sup> و CCC و همچنین کم بودن RMSE نشان دهنده وابستگی بسیار نزدیک مقادیر مشاهداتی و برآوردی توسط مدل معرفی شده می‌باشد. نتایج نشان از عملکرد مناسب مدل شبکه عصبی پرسپترون با دو لایه مخفی با هفت نرون در لایه پنهان اول و با نوزده نرون در لایه

## فهرست منابع:

1. نوروزیان ز. 1393. برآورد هدایت هیدرولیکی اشباع خاک با استفاده از روش‌های رگرسیونی و شبکه عصبی مصنوعی. پایان نامه کارشناسی ارشد دانشگاه علوم کشاورزی و منابع طبیعی ساری، دانشکده علوم زراعی، گروه علوم خاک.
2. Agyare, W.A., S.J. Park., and P.L.G. Vlek. 2007. Artificial neural network estimation of saturated hydraulic conductivity. *Vadose Zone J.* 6:423-431.

3. Aimrun, W., and S.M.Amin. 2009. Pedo-transfer functions for saturated hydraulic conductivity of lowland paddy soils. *Paddy Water Environ.* 7:217-225.
4. Blake, G.R., and K.H. Hartge. 1986. Bulk density. In: Klute, A. (Ed.). *Methods of Soil Analysis. Part 1, second ed.* Agron. Monogr. 9. ASA and SSSA, Madison, WI.
5. Bouma, J. 1989. Using soil survey data for quantitative land evaluation. *Adv Soil Sci.* 9:177-213.
6. Botulaa, Y.D., W.M. Cornelisa., G. Baertb., and E. Van Ranste. 2012. Evaluation of pedotransfer functions for predicting water retention of soils in Lower Congo. *Agric Water Manag.* 111:1-10.
7. Braud I, A., C.Dantas-Antonino.,And M. Vauclin. 1995. A stochastic approach to studying the influence of the spatial variability of soil hydraulic properties on surface fluxes. *J Hydrol.* 165: 283–310.
8. Donatelli, M., and M. Acutis. 2001. Soil par 2.00 beta-help. Research Institute for industrial Crops. Via corticella 133, 40128 Bbologna. Italy.
9. Elrick, D.E., and W.D. Reynolds. 1992. Infiltration from constant-head well permeameters and infiltrometers. In: Topp, G.C., Reynolds, W.D., Green, R.E. (Eds.), *Advances in Measurements of Soil Physical Properties: Bringing Theory into Practice.* SSSA Spec. Publ. 30. SSSA, Madison, WI.
10. Frate, F.D., P. Ferrazoli.,and G. Schiavon. 2003. Retrieving soil moisture and agricultural variables by microwave radiometry using neural network. *Remote Sens. Environ.* 84:174-183.
11. Haghverdi, A., H.S. Ozturk., S. Ghodsi., and T. Tuncay. 2012. Estimating saturated hydraulic conductivity using different wellknownpedotransfer function. *Instructions for Short Papers forThe 8th International Symposium Agro Environ, 2012 Conference, Wageningen, Ankara.*
12. Haverkamp, R., F.J. Leij., C. Fuentes., A. Sciortino., and P.J. Ross. 2005. Soil water retention: I. Introduction of a shape index. *Soil Sci. Soc. Am. J.* 69: 1881–1890.
13. Hill, M. 1998. *Methods and guidelines for effective model calibration.* U.S. Geological survey Water- Resources Investigations Report,Denver, Colorado.
14. Ghanbarian-Alavijeh, B., A.M. Liaghat., and S. Sohrabi. 2010. Estimating saturated hydraulic conductivity from soil physical properties using neural networks model. *World Acad. Science. Engin.Technol.* 62:131-136.
15. GhorbaniDashtaki, S.M., M. Homae., and H. Khodaverdiloo. 2010. Derivation and validation of pedotransferfunctions for estimating soil water retention curve using a variety of soil data. *Soil Use and Mange.* 26:68-74.
16. Lin, L.I.K. 1989. A concordance correlation coefficient to evaluate reproducibility. *Biometrics,* 45:255-268.
17. Lu, M., Abourizk, S.M. and Hermann, U.H.,Sensitivity Analysis of neural networks in spool fabrication productivity studies. *J. Comput. Civ. Eng.* 15:4(299), 299-308.
18. Kianpoor-kalkhajeh, U., R. Rezaie-Arshad., H. Amerikhah., and M. Sami. 2012. multiplelinear regression, artificial neural network and ANFIS modeling the saturated hydraulic conductivity. *InterJAgric Res Review.* 2(3):255-265.
19. Kim, M., and J.E. Gilley. 2008. Artificial Neural Network estimation of soil erosion and nutrient concentrations in runoff from land application areas. *Comput Electron Agric.* 64:268–275.
20. Klute, A. 1986. *Methods of Soil Analysis. Part 1, physical and mineralogical methods,* American Society of Agronomy, Agronomy Monographs 9(1), Madison, Wisconsin, USA.

21. Klute, A., and C. Dirksen. 1986. Hydraulic conductivity and diffusivity: Laboratory methods. In: *Methods of Soil Analysis Part 1: Physical and Mineralogical Methods*, A. Klute, Ed. Soil Science Society of America, Madison, WI.
22. Marcel, G.S., J.L. Feike., T. Martinus., and H. van Genuchten. 1998. Neural Network Analysis for Hierarchical Prediction of Soil Hydraulic Properties. *Soil SciSoc Am J.* 62: 847-855.
23. Mallants, D., D. Jaques.,P.H. Tseng., H. Van Genuchten., And J. Feyen. 1997. Comparison of three hydraulic property measurement methods. *J hydrol.* 199: 295-318.
24. Morgan, R.P.C. 2005. *Soil erosion & Conservation*. Third edition. Blackwell Publishing. United Kingdom.
25. Nelson, D.W., and L.P. Sommers. 1986. Total carbon, organic carbon and organic matter. In: page. A.L. Ed. *Methods of Analysis*. *Soil SciSoc Am J.* 2:539-579.
26. Osborne, J. 2010. Improving your data transformations: Applying the Box-Cox transformation. North Carolina State University, A peer-reviewed electronic journal. *Prac Assess, Res Eval.* 15(12):2.
27. Pachepsky, Ya., A.D. Timlin., And G. Varallyay. 1996. Artificial neural networks to estimate soil water retention from easily measurable data. *Soil SciSoc Am J.* 60:727-733.
28. Page, A., R. Miller., and D. Keeney. 1982. *Methods of Soil Analysis*. 2<sup>th</sup> ed. Part2: Chemical and biological properties. Soil SciSoc Am J. Inc. Publisher.
29. Rasoulzade, A. 2011. Estimating hydraulic conductivity using pedotransfer functions. *Hydraulic Conductivity – Issues, Determination and Applications*, Prof. Lakshmanan Elango (Ed.), ISBN: 978-953-307-288-3, InTech, Available from: <http://www.intechopen.com/books/hydraulic-conductivity-issues-determination-and-applications/estimating-hydraulic-conductivity-using-pedotransfer-functions>.
30. Rogiers, B., D. Mallants., O. Batelaan., M. Gedeon., M. Huysmans., and A. Dassargues. 2012. Estimation of hydraulic conductivity and its uncertainty from grain-size data using GLUE and artificial neural networks. *Inter Assoc Math Geosci.* 44:739-763.
31. Schaap, M.G., and F.J. Leij. 1998. Using neural networks to predict soil water retention and hydraulic conductivity. *Soil TillRes.* 47: 37-42.
32. Schaap, M.G., F.J. Leij., And H. Van Genuchten. 2001. Rosetta: a computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *J hydrol.* 251: 163-176.
33. Shirazi, M.A., and L. Boersma. 1984. A unifying quantitative analysis of soil texture. *Soil SciSoc Am J.* 48:142-147.
34. Tang, L., G. Zeng., F. Nourbakhsh., L. Guoli., And G.L. Shen. 2009. Artificial Neural Network Approach for Predicting Cation Exchange Capacity in Soil Based on Physico-Chemical Properties. *Environ Eng Sci.* 26(1): 137-146.
35. Tekin, E., and S.O. Akbas. 2011. Artificial neural networks approach for estimating the groutability of granular soils with cement-based grouts. *B EngGeol Environ.* 70:153–161.
36. Walkley, A., and I.A. Black. 1934. An examination of the degtjareff method for determining soil organic matter and a proposed modification of the chronic acid titration method. *Soil SciSoc Am J.* 37:29-39.
37. Westerman, R.E.L. 1990. *Soil testing and plant analysis*. Soil Society Science America Jurnal. Madison, Wisconsin. USA.
38. Wosten, J.H.M., P.A. Finke., And M.J.W. Jansen. 1995. Comparison of class and continuous pedotransfer functions to generate soil hydraulic characteristics. *Geoderma.* 66:227–237.
39. Wosten, J.H.M., Y.A. Pachepsky., and W.J. Rawls. 2001. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *JHydrol.* 251: 123-150.

40. Xiangsheng, Y., L. Guosheng., and Y. Yanyu. 2013. Comparison of three methods to develop pedotransfer functions for the saturated water content and field water capacity in permafrost region. *Cold RegSci Technol.* 88:10-16.
41. Yetilmezsoy, K., and S. Demirel. 2008. Artificial neural network (ANN) approach for modeling of Pb(II) adsorption from aqueous solution by Antep pistachio (*Pistacia Vera L.*) shells. *J Hazard Mater.* 153: 1288–1300.
42. Yilmaz, I., and O. Kaynar. 2011. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. *Expert Syst Appl.* 38: 5958–5966.
43. Zorluer, I., Y. Icaga., S. Yurtcu., and H. Tosun. 2010. Application of a fuzzy rule-based method for the determination of clay dispersibility. *Geoderma.* 160: 189–196.

## Evaluation of Regression and Artificial Neural Network Models to Estimate the Saturated Hydraulic Conductivity in Mazandaran Province

Z. Norouzian Azizi, M. Ghajar Sepanlou<sup>1</sup>, S. M. Emadi, and F. Sadeqzade

Former MSc student of Sari Agricultural Sciences and Natural Resources University;

E-mail: Zahra.norouzian.azizi@gmail.com

Associate Professor, Sari Agricultural Sciences and Natural Resources University;

E-mail:Sepanlu@yahoo.com

Assistant Professor, Sari Agricultural Sciences and Natural Resources University;

E-mail:Mostafaemadi@gmail.com

Assistant Professor, Sari University of Agricultural Sciences and Natural Resources;

E-mail:Fardin\_sadeqzade@gmail.com

**Received: November, 2015 & Accepted: February, 2016**

### Abstract

Soil saturated hydraulic conductivity (Ks) is one of the important factors involved in water, soil, and agricultural sciences. Ks measurement is important for solute and water movement modeling and, in turn, is costly and time consuming. It is also impractical to spatially and temporarily measure the Ks in large scale studies. Therefore, it would be wise to predict Ks using indirect methods such as pedotransfer functions (PTFs). The objective of this study was to use the regression and artificial neural networks methods as an alternative method to estimate the saturated hydraulic conductivity. Therefore, 80 undisturbed soil samples in three replications were collected in Mazandaran province, northern Iran, and analyzed by laboratory methods. Data was divided into two categories including the training (80%) and testing dataset (20%). In order to predict the soil saturated hydraulic conductivity, the multiple linear regression models (MLR), multilayer perceptron (MLP) and radial basis function (RBF) methods were used. To test the performance of the three methods, the correlation ( $R^2$ ), mean square error (RMSE) and consistent correlation coefficient (CCC) statistics between actual and predicted values were measured. The results showed that MLP with two hidden layers by sigmoid activation function was the best method for Ks estimation.  $R^2$ , RMSE and CCC statistics were 0.871, 1.02 cm/h and 0.869, respectively, for the best predicted method. The sensitivity analysis showed that the soil bulk density, pH and porosity had the highest impact on Ks, while soil salinity affected the Ks slightly. Therefore, use of MLP with two hidden layers efficiently can predict Ks in the study area and could be introduced as a promising method for Ks estimation. Considering the slightly low sampling data, this research can be considered as a starting step for future comprehensive studies with high intensive sampling sites that would enhance the reliability of these results.

**Keywords:** Pedotransfer functions, MLP, RBF, Sensitivity analysis

---

<sup>1</sup> Corresponding author: Sari Agricultural Sciences and Natural Resources University, Department of Soil Science