



## برآورد نفوذپذیری خاک توسط شبکه عصبی مصنوعی و رگرسیون خطی در اراضی کشاورزی و بکر

حامد کاشی<sup>۱\*</sup>، صمد امامقلی‌زاده<sup>۲</sup>، هادی قربانی<sup>۳</sup>، سید علی اصغر هاشمی<sup>۴</sup>

۱- نویسنده مسئول: کارشناس ارشد خاکشناسی، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، h\_Kashi2010@yahoo.com

۲- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، s\_gholizadeh517@yahoo.com

۳- دانشیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، ghorbani1969@yahoo.com

۴- استادیار و عضو هیات علمی مرکز تحقیقات کشاورزی و منابع طبیعی استان سمنان، hashemiaa12@gmail.com

### چکیده

در سال‌های اخیر استفاده از روش‌های غیرمستقیم برای برآورد خصوصیات خاک مورد توجه قرار گرفته است. در روش‌های معمول، اندازه‌گیری نفوذپذیری نیاز به وقت و هزینه زیادی دارد از طرفی وجود عبارات غیرخطی در روابط نفوذپذیری، مدل‌سازی آنها را با مشکل همراه کرده است. امروزه روش شبکه عصبی مصنوعی با کارایی بالا در مدل‌سازی مسایل غیرخطی کاربرد روزافزون آن را سبب شده است. در این پژوهش ۲۰۰ نمونه خاک جمع‌آوری شده از منطقه قوشه واقع در استان سمنان مورد آزمایش قرار گرفت. نیمی از نمونه‌ها از اراضی بکر با کاربری مرتع دست نخورده و نیمی از اراضی کشاورزی منطقه جمع‌آوری شد. پارامترهای فیزیکی و شیمیایی خاک شامل هدایت الکتریکی، فراوانی نسبی ذرات، درصد آهک، نسبت جذب سدیم (SAR) و وزن مخصوص ظاهری به عنوان ویژگی‌های زودیافت و نفوذپذیری نهایی به عنوان پارامتر دیریافت مورد بررسی قرار گرفت. داده‌های جمع‌آوری شده به دو دسته آموزش و صحت‌سنجی تقسیم شدند و از آنها برای آموزش و ارزیابی مدل‌های شبکه عصبی شامل پرسپترون چند لایه (MLP) و توابع پایه شعاعی (RBF) و همچنین رگرسیون خطی استفاده شد. نتایج حاصل از این تحقیق کارایی بالاتر مدل شبکه عصبی مصنوعی را نسبت به روش رگرسیون خطی نشان می‌دهد. علاوه بر آن شبکه MLP دارای عملکرد بهتری نسبت به شبکه RBF در دو مرحله آموزش و صحت‌سنجی بوده است. همچنین به منظور تعیین همبستگی هر یک از پارامترهای ورودی مستقل با مقدار نفوذپذیری خاک از آنالیز حساسیت نیز استفاده گردید.

### واژه‌های کلیدی:

آنالیز حساسیت، خصوصیات فیزیکی و شیمیایی، شبکه عصبی مصنوعی، مدل‌سازی، نفوذپذیری خاک



Quarterly Journal of  
Environmental Erosion Researches  
No. 9, Spring 2013, pp: 19-34  
[www.magazine.hormozgan.ac.ir](http://www.magazine.hormozgan.ac.ir)

## Estimation of Soil Infiltration in Agricultural and Pasture lands Using Artificial Neural Networks and Multiple Regressions

Kashi. H<sup>1\*</sup>, Emamgholizadeh. S<sup>2</sup>, Ghorbani .H<sup>3</sup>, Asghar Hashemi. S.A<sup>4</sup>

- 1- \*Corresponding Author: M.Sc. Student, shahrood University of Technology
- 2- Assistant Professor, Faculty of Agriculture, Shahrood University of Technology
- 3- Professor, Faculty of Agriculture, Shahrood University of Technology
- 4- Assistant Professor, Agricultural and Natural Resources Research center, Semnan

### Abstract

Common methods to determine the soil infiltration would need lots of time as well as costs. On the other hand, the existence of non linear behaviors in soil infiltration would make it difficult to be modeled. Regard to the difficulties of direct measurement of soil infiltration, using indirect methods for estimation of this parameter, has received attention in recent years. In spite of the existence of various theoretic as well as experimental equations, some other indirect methods such as artificial neural networks are used to estimate this soil phenomenon. Now a day, artificial neural networks are shown high efficiency in modeling non linear equations. In the present study, 200 soil samples were collected from Ghoshe location in Semnan Province. Half of samples were collected from agricultural lands and the other half were collected from pastures nearby lands. Some soil chemical as well as physical properties such as electrical conductivity (EC), soil texture, lime percentage, sodium adsorption ration (SAR) and bulk density were considered as easy and fast obtainable features and soil permeability as difficult and time consuming feature. The collected data randomly divided in two categories of training and testing and they used for train and test of two artificial neural networks, multi-layer perception using back-propagation algorithm (MLP/BP) and Radial basis functions (RBF) and nonlinear regression model. Results of this research show high efficiency of artificial neural network compare with multiple regression and also MLP network was better than RBF network. Sensitive analysis was used to determine correlation between independent parameters and permeability.

### Keywords:

Artificial Neural Network, Modeling, Physical and Chemical Properties, Sensitivity Analysis, Soil Infiltration

## ۱- مقدمه

نفوذپذیری یکی از مشخصات فیزیکی خاک است که در مسایل آبیاری و زهکشی اهمیت خاصی دارد. دستیابی به مدیریت صحیح آبیاری، ذخیره رطوبتی مطلوب خاک در مناطق خشک، عملکرد زراعی قابل قبول و سامانه پایدار حفاظتی خاک به مدنظر قراردادن نفوذپذیری بستگی دارد (قربانی دشتکی و همکاران، ۱۳۸۱). به طور کلی عوامل زیادی در سرعت نفوذ آب به خاک موثر می‌باشند. از جمله این عوامل می‌توان به بافت، ساختمان، رطوبت اولیه، مواد آلی خاک و خصوصیات شیمیایی آب و خاک اشاره نمود. بافت خاک تعیین کننده فضای خالی خاک بوده و در تخلخل خاک موثر است، قطر خاکدانه‌های خاک هر قدر درشت‌تر باشد، فضای خالی بین ذرات بزرگتر بوده و قابلیت نفوذ آب در خاک بیشتر می‌باشد. ساختمان نیز یکی از مشخصه‌های مهم خاک بوده که در اثر تغییر شرایط محیطی، فعالیت موجودات زنده خاک و کشت و کار تغییر می‌کند. مقدار زیاد یون قابل تبادل سدیم باعث پراکندگی ذرات خاک شده و نفوذپذیری خاک را کاهش می‌دهد، لذا نفوذ آب به داخل خاک در لایه‌های رسی و سیلتی بسیار اندک است.

روابط نفوذ را می‌توان به دو دسته کلی روابط تجربی و روابط تئوری تقسیم نمود. از جمله روابط تئوری می‌توان به رابطه فیلیپ 1957 و Philip, 1957 و از روابط تجربی نیز به روابط Kostiakov, 1932 و Horton, 1940 اشاره نمود. دانستن سرعت نفوذ پایه در تمامی طرح‌های آب و خاک الزامی است. بنابراین یک روش مطمئن، سریع، نسبتاً ساده و کم هزینه جهت برآورد پارامتر نفوذ نهایی دارای اهمیت است. با توجه به وابستگی میزان نفوذپذیری به پارامترهای فیزیکی و شیمیایی خاک در این روش با استفاده از پارامترهای مذکور به تخمین نفوذپذیری پرداخته شد. با انجام این روش محدودیت‌های روش تجربی و تئوری متداول در اندازه‌گیری نفوذپذیری مرتفع گردیده، همچنین لزوم انجام آزمایشات زمان بر و پرهزینه صحرائی به حداقل رسیده است. به طور کلی در زمینه استفاده از شبکه‌های عصبی مصنوعی و روش‌های مشابه هیدروانفورماتیک در ارتباط با علوم آب و خاک تاکنون تحقیقات مختلفی صورت گرفته است.

Marcel et al, 1998 از شبکه عصبی برای پیش‌بینی ظرفیت نگهداری رطوبت و هدایت هیدرولیکی در حالت اشباع با استفاده از خصوصیات پایه خاک شامل مقادیر شن، سیلت و رس، وزن مخصوص ظاهری، تخلخل و مقادیر گراول استفاده کردند و نتیجه گرفتند که به طور کلی با افزایش تعداد داده‌ها پیش‌بینی ظرفیت نگهداری رطوبت و هدایت هیدرولیکی در حالت اشباع بهبود می‌یابد و استفاده از این روش به دلیل دقت و میزان انعطاف‌پذیری زیاد مورد توجه قرار گرفت. گروهی از محققین امکان برآورد سریع هدایت آبی اشباع خاک توسط شبکه عصبی مصنوعی را بررسی و نتیجه گرفتند که در این مورد شبکه‌های عصبی مصنوعی در مقایسه با روابط رگرسیونی عملکرد نسبتاً بهتری دارند (نوابیان و همکاران، ۱۳۸۳). ابراهیمی و نایب لوتی (۱۳۸۸) در بررسی ۴۰ نمونه در سه تکرار با پیش‌بینی مقادیر نفوذپذیری خاک‌ها با استفاده از چند فاکتور فیزیکی و شیمیایی شامل اسیدیته، وزن مخصوص ظاهری، وزن مخصوص حقیقی، سدیم، تخلخل، ماده آلی، هدایت الکتریکی و مجموع کلسیم و منیزیم به این نتیجه رسیدند که مدل شبکه عصبی مصنوعی حتی در شرایط تعداد کم داده‌ها نیز قابلیت بالایی در تخمین نفوذپذیری دارد. سرمیدان و همکاران (۱۳۸۸)، با مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چند متغیره به پیش‌بینی برخی از خصوصیات خاک شامل نقطه پژمردگی، ظرفیت زراعی، ظرفیت تبادل کاتیونی و وزن مخصوص ظاهری پرداختند که نتایج آنها کارایی بالایی مدل نروفازی و شبکه عصبی مصنوعی را نسبت به معادلات رگرسیونی نشان داد. Jain & Kumar, 2006 ارزیابی روش شبکه‌های عصبی مصنوعی در تعیین پارامترهای مدل نفوذپذیری را انجام دادند و بر اساس نتایج به دست آمده به این نکته نیز اشاره شده است که برای مقایسه ارجحیت هر یک از روش مدل‌های آماری و یا شبکه عصبی مصنوعی اتکا به پارامتر حدافل میانگین مربعات خطا کافی نبوده و مطالعات گسترده‌تر آماری پیشنهاد شده است. از میان پژوهش‌های انجام شده که کارایی دو شبکه MLP و RBF را در تحقیقات آب و خاک بررسی کرده‌اند، Lallahema et al, 2005 نشان دادند که الگوریتم MLP با حدافل نرون میانی بهترین پیش‌بینی را برای ارزیابی سطح آب زیرزمینی دارند. Mutlu et al, 2008 به ارزیابی خصوصیات هیدرولوژیکی با شبکه عصبی مصنوعی پرداختند نتیجه نشان دهنده کارایی بالاتر شبکه MLP نسبت به RBF بوده است. Rub et al, 2009 از شبکه‌های MLP و RBF برای برآورد شاخص‌های ناهمگنی


خاک استفاده کردند که طبق بررسی‌های آنها، شبکه MLP از کارایی بالاتری برخوردار بود. ارشد و همکاران (۱۳۸۸) برای پیش‌بینی سرعت نفوذ نهایی آب به خاک از شبکه‌های MLP و RBF استفاده کردند که در آن شبکه‌های RBF از قابلیت بالاتری برخوردار بودند. در پژوهشی به پیش‌بینی پتانسیل آماس خاک‌های رسی با روش‌های رگرسیون خطی، شبکه‌های RBF و MLP و مدل نروفازی، پرداختند که طبق نتایج آنها شبکه RBF از بالاترین کارایی برخوردار بوده است (Yilmaz & Kaynar, 2011).

با توجه به سابقه تحقیق و ارائه نتایج متفاوت در زمینه کارایی روش‌های مختلف شبکه عصبی، هدف از این تحقیق تخمین نفوذپذیری خاک در منطقه قوشه سمنان با استفاده از روش‌های مختلف شبکه عصبی مصنوعی و رگرسیون خطی است.

## ۲- مواد و روش‌ها

### منطقه مورد مطالعه

ایستگاه پخش سیلاب قوشه در ۷۵ کیلومتری شرق سمنان با مساحتی حدود ۱۲۰ هکتار واقع شده است. بخشی از اراضی این حوزه که کشت و کار نشده و نیز سیل‌گیری نشده و سیلاب باعث تغییر خصوصیات فیزیکی و شیمیایی خاک آن نشده بود به عنوان اراضی بکر انتخاب گردید. برای زمین‌های کشاورزی از زمین‌های مجاور این حوزه که چندین سال متوالی تحت کشت و کار قرار گرفته بودند، استفاده شد (شکل ۱).



شکل ۱- شماتیک ایستگاه پخش سیلاب قوشه و زمین‌های زراعی مجاور

### تجزیه‌های فیزیکی و شیمیایی نمونه‌های خاک

تعداد ۱۰۰ نمونه از ۱۰۰ هکتار از اراضی بکر و تعداد ۱۰۰ نمونه از ۱۰۰ هکتار از اراضی کشاورزی از عمق ۰-۳۰ سانتی‌متری خاک، جمع‌آوری شد و پس از انتقال به آزمایشگاه، هوا خشک شده، کوبیده شده و از الک دو میلی‌متری عبور داده شدند. نفوذپذیری نهایی خاک‌ها در هر دو منطقه با روش استوانه مضاعف و در سه تکرار برای هر نقطه اندازه‌گیری شدند. تعیین بافت خاک به روش هیدرومتری بایکاس، وزن مخصوص ظاهری ( $P_b$ ) با روش کلوخه، درصد آهک با روش حجم‌سنجی (Sparks et al, 1996)، نسبت جذب سدیم (SAR) با استفاده از رابطه سدیم و مجموع کلسیم و منیزیم و هدایت الکتریکی نیز با دستگاه

هدایت سنج اندازه گیری شدند (Gee & Bauder, 1986). علاوه بر پارامترهای فوق میزان تخلخل با استفاده از مقادیر وزن مخصوص ظاهری و حقیقی و ماده آلی با روش والکلی بلک نیز اندازه گیری شدند (Sparks et al, 1996)، که در طی تحقیق پس از رسم آنالیز حساسیت به علت همبستگی پایین با میزان نفوذپذیری حذف شدند. پس از آنالیز خاک‌های منطقه به علت شور و آهکی بودن بالای خاک‌ها چند نمونه از آب آبیاری زمین‌های کشاورزی مورد آزمایش قرار گرفت که متوسط مقادیر اندازه گیری شده آنها در جدول (۱) آمده است. بر اساس نتایج حاصل، یکی از دلایل اصلی شوری خاک‌های منطقه می‌تواند آب آبیاری باشد که مقادیر املاح در آنها بیش از حد مجاز است. پس از انجام آنالیزهای خاک لزوم استفاده از پارامترهای هدایت الکتریکی و درصد آهک خاک، احساس شد. در مقابل ماده آلی کم در خاک‌های منطقه و تاثیر اندک آن بر نفوذپذیری، همبستگی پایین آن را با میزان نفوذپذیری توجیه و در نتیجه امکان حذف آن را فراهم شد.

جدول ۱- آنالیز آب چاه آبیاری زمین‌های کشاورزی منطقه مورد مطالعه

اسیدیته	هدایت الکتریکی (EC*10 <sup>6</sup> )	کربنات (meq/l)	بیکربنات (meq/l)	کلر (meq/l)	سولفات (meq/l)	مجموع آنیونها (meq/l)	کلسیم (meq/l)	منیزیم (meq/l)
۷/۶۹	۲۵۵۰	۰/۱	۲/۶	۱۵/۷	۳/۶	۲۲	۵/۸	۴/۲
سدیم (meq/l)	مجموع کانیونها (meq/l)	درصد سدیم محلول	نسبت جذب سدیم	سختی کل (ppm)	سختی موقت (ppm)	سختی دائم (ppm)	مجموع مواد معلق (mg/l)	مجموع املاح محلول (mg/l)
۱۲/۵	۲۲/۵	۵۵/۵	۵/۶	۴۰۵	۴۹	۳۵۶	۳۸۸	۱۳۳۲

#### رگرسیون خطی چندگانه

تخمین پارامترهای دیرپافت خاک با استفاده از اطلاعات موجود، که به وسیله معادلات رگرسیونی صورت می‌گیرد، توابع انتقالی خاک نامیده می‌شود. قبل از ورود عوامل ورودی (متغیرهای مستقل) و نفوذپذیری به عنوان خروجی (متغیر وابسته)، همه آنها تحت آزمون هم راستایی و نرمال بودن قرار گرفتند. با استفاده از آزمون کولموگروف-اسمیرنوف، نرمال بودن داده‌ها مورد بررسی قرار گرفت. پس از برازش چندین رابطه رگرسیونی، بهترین رابطه انتخاب و با نتایج حاصل از مدل‌های شبکه عصبی مصنوعی مورد مقایسه قرار گرفت. از آنجایی که فراوانی نسبی ذرات رس، شن و سیلت هم راستا بودند، برای جلوگیری از هم راستایی در توابع به دست آمده از مقدار نسبت رس به سیلت استفاده شده است (Merdun et al, 2006).

#### شبکه عصبی مصنوعی


شبکه عصبی مصنوعی یک روش شبیه‌سازی می‌باشد که از مطالعه سیستم شبکه عصبی موجودات زنده الهام گرفته است. یکی از متداول‌ترین شبکه‌های عصبی مورد استفاده، شبکه عصبی پرسپترون چند لایه می‌باشد. این شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه بین آنها که مستقیماً به داده‌های ورودی و نتایج خروجی متصل نیستند، تشکیل یافته‌اند. واحدهای لایه ورودی وظیفه توزیع مقادیر ورودی‌ها به لایه بعد و لایه خروجی نیز پاسخ سیگنال‌های خروجی را ارائه می‌دهد. در این دو لایه، تعداد نرون‌ها برابر با تعداد ورودی‌ها و خروجی‌ها می‌باشد و لایه یا لایه‌های پنهان وظیفه ارتباط لایه‌های

ورودی به لایه های خروجی و به دست آوردن روابط خطی و غیرخطی را بر عهده دارند. ساختار پرسپترون چند لایه به توابع غیرخطی نیاز دارد که به طور پیوسته مشتق پذیر باشد به عبارت دیگر هموار باشد (نصیری صالح و منتظر، ۱۳۸۰). اغلب اوقات این تابع به شکل تابع باینری، سیگموئید، تانژانت هیپربولیک خطی یا گوسی و سکانت هیپربولیک در نظر می گیرند (شکل ۲). ساده ترین و معمول ترین نوع شبکه عصبی مصنوعی که در بسیاری از علوم مهندسی و از جمله پژوهش حاضر استفاده می گردد شبکه های عصبی چند لایه پیشخور همراه با ناظر است که از روش پس انتشار خطا برای آموزش کمک می گیرد. مسئله اصلی در این شبکه ها تعیین تعداد لایه های پنهان و تعداد نرون های آنها می باشد که در این رابطه نظرات متفاوتی وجود دارد. در این مورد ثابت شده است که در شبکه های عصبی با یک لایه مخفی با تابع سیگموئید (معادله ۱) در لایه میانی و تابع خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهد بود مشروط به این که به اندازه کافی نرون در لایه مخفی وجود داشته باشد (Nielsen, 1987)، این قضیه به تقریب ساز جهانی معروف می باشد (منهاج، ۱۳۸۸). در این تحقیق شبکه ها با یک لایه مخفی که دارای تابع فعال سازی سیگموئید، تانژانت هیپربولیک، گوسی و سکانت هیپربولیک در لایه مخفی و تابع فعال سازی خطی در لایه خروجی بوده و تعداد نرون های آنها از یک تا هفت نرون متغیر بوده و بهترین تعداد نرون به صورت سعی و خطا تعیین گردید، مورد بررسی قرار گرفتند. رابطه (۱) تابع سیگموئید را نشان می دهد.


در معادله (۱)،  $O$  خروجی و  $net$  ورودی تابع خواهد بود.

$$O = \frac{1}{1 + e^{-net}} \quad (1)$$

شبکه های تابع پایه شعاعی از نوع شبکه های پیشرو همراه با یک لایه میانی هستند که برای اولین بار در سال ۱۹۸۸ معرفی شدند. در این روش اغلب تابع انتقال در لایه میانی و تابع گوسین در لایه خروجی تابع خطی است (Dibike et al, 1999) (شکل ۳). عموماً آموزش شبکه RBF به دو بخش تقسیم می شود. بخش اول یادگیری بدون نظارت است که با استفاده از روش های خوشه بندی، پارامترهای توابع پایه با استفاده از اطلاعات ورودی تعیین می شود. بخش دوم که یادگیری با نظارت است و وزن بین لایه میانی و خروجی با استفاده از روش های کاهش شیب و رگرسیون خطی تعیین می شود. یکی از تفاوت های شبکه پرسپترون چند لایه و توابع پایه شعاعی این است که در شبکه پرسپترون چند لایه، مجموع وزن دار نرون های رسیده به نرون لایه میانی به عنوان ورودی توابع تحریک در نظر گرفته می شود، ولی در شبکه های توابع پایه شعاعی فاصله هر الگو با بردار مرکز هر نرون در لایه میانی به عنوان ورودی تابع تحریک شعاعی محاسبه می شود.



شکل ۳- ساختار شبکه عصبی توابع پایه شعاعی (RBF)



شکل ۲- ساختار شبکه عصبی مصنوعی پرسپترون چند لایه (MLP)

ارزیابی مدل‌ها

به منظور مقایسه عملکرد الگوریتم‌های شبکه عصبی و رگرسیون چند متغیره از پارامترهای آماری مانند ضریب تبیین ( $R^2$ ) (رابطه ۲)، میانگین خطای مطلق (MAE) (رابطه ۳)، خطای استاندارد نسبی (RSE) (رابطه ۴)، مجذور میانگین مربعات خطا (RMSE) (رابطه ۵) که از روابط زیر قابل محاسبه می‌باشند، استفاده گردید.

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (۳) \quad R^2 = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 \sum(y-\bar{y})^2}} \quad (۲)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_0 - Z_p)^2} \quad (۵) \quad RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z_0 - Z_p)^2}}{Z_{ave}} \quad (۴)$$

که در آنها:  $Z_0$  و  $\hat{Y}_j$  مقادیر پیش‌بینی شده،  $Z_p$  و  $Y_i$  مقادیر مشاهداتی،  $Z_{ave}$  متوسط مقادیر مشاهداتی و  $n$  تعداد داده‌ها می‌باشد همچنین  $Y$  و  $\bar{Y}$  به ترتیب مقدار مطلق و متوسط مقادیر خروجی شبکه عصبی و  $X$  و  $\bar{X}$  به ترتیب برابر مقادیر مطلق و متوسط نفوذپذیری اندازه‌گیری شده است.

که در آنها:  $Z_0$  و  $\hat{Y}_j$  مقادیر پیش‌بینی شده،  $Z_p$  و  $Y_i$  مقادیر مشاهداتی،  $Z_{ave}$  متوسط مقادیر مشاهداتی و  $n$  تعداد داده‌ها می‌باشد همچنین  $Y$  و  $\bar{Y}$  به ترتیب مقدار مطلق و متوسط مقادیر خروجی شبکه عصبی و  $X$  و  $\bar{X}$  به ترتیب برابر مقادیر مطلق و متوسط نفوذپذیری اندازه‌گیری شده است.

### ۳- نتایج

برای نیل به اهداف تعریف شده، ابتدا داده‌ها را به دو دسته تقسیم کرده به طوریکه ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای صحت‌سنجی اختصاص داده شد (منهاج، ۱۳۸۸؛ امینی و همکاران، ۲۰۰۵). همچنین تفاوت معنی‌دار نبودن در سطح پنج درصد برای هر دو گروه صورت گرفت. تعدادی از محققین برای انتخاب داده‌های آزمون و تست از تی تست استفاده کردند و بیان داشتند که اگر بین داده‌های تست و آموزش تفاوت معنی‌داری وجود نداشته باشد، می‌توان انتظار نتایج بهتری را از مدل داشت (تامسلا و همکاران، ۲۰۰۰). در جداول (۲) و (۳) معیارهای آماری مربوط به داده‌های تست و آموزش در خاک‌های کشاورزی و بکر ارائه شده است.

جدول ۲- مهمترین مشخصات آماری داده‌های استفاده شده در مدل شبکه عصبی و رگرسیون چند متغیره در خاک‌های کشاورزی مورد مطالعه

وزن مخصوص ظاهری (gr/cm <sup>3</sup> )	نسبت جذب سدیم	آهک (درصد)	شن (درصد)	سیلت (درصد)	رس (درصد)	هدایت الکتریکی (dS/m)	نفوذپذیری (cm/hr)	
۱/۴۲	۳/۱۱	۵	۱۴/۸	۶/۲	۱۱	۲	۰/۰۶	کمترین
۱/۶۵	۱۰/۹۷	۲۹	۷۸/۹	۵۸/۷	۴۹	۶۰	۴/۹	بیشترین
۱/۵	۵/۶۸	۱۸/۵۳	۴۳/۱	۳۰/۶۴	۲۷/۲۸	۲۹/۹	۲/۰۲	میانگین
۰/۰۶	۱/۷۴	۴/۷۹	۱۶/۹۲	۱۱/۴۹	۱۰/۵۷	۱۵/۸۳	۱/۵۷	انحراف معیار
۱/۸۴	-۰/۴۱	-۰/۹۱	۰/۰۳	-۰/۷۱	۱/۱۴	۲۰/۶	-۱/۷۳	کشیدگی
۱/۴۴	۳/۸۹	۱۵	۲۵/۲۵	۲۱	۱۹	۱۳	۱	کمترین
۱/۶۲	۶/۵۲	۲۳	۶۰	۴۷/۸	۴۰	۵۰	۲/۸۹	بیشترین
۱/۴۹	۵/۲۹	۱۸/۷۳	۴۱/۳۳	۳۰/۸۶	۲۸/۹۷	۲۴/۵	۱/۵۶	میانگین
۰/۰۵	۰/۸	۲/۴۳	۹/۹	۸/۸۷	۷/۰۴	۱۲/۶۹	۰/۴۸	انحراف معیار
۲/۷۳	-۰/۵۷	-۰/۱۹	۰/۵۵	۰/۱۴	-۰/۹	۱/۵۵	۰/۳	کشیدگی

جدول ۳- مهمترین مشخصات داده‌های استفاده شده در مدل شبکه عصبی و رگرسیون چند متغیره در خاک‌های بکر مورد مطالعه

وزن مخصوص ظاهری (gr/cm <sup>3</sup> )	نسبت جذب سدیم	آهک (درصد)	شن (درصد)	سیلت (درصد)	رس (درصد)	هدایت الکتریکی (dS/m)	نفوذپذیری (cm/hr)	
۱/۷۵	۴/۰۲	۵	۵۳/۱	۱/۶۷	۴/۸	۰/۴۳	۱/۲۶	کمترین
۱/۹	۹/۹۴	۳۵	۹۲/۵	۲۶/۵	۳۲/۹	۱۰	۱۰/۸۸	بیشترین
۱/۸۵	۶/۰۹	۱۹/۵	۷۵/۳	۸/۷	۱۵/۹۶	۱/۳۶	۷/۵۵	میانگین
۰/۰۳	۱/۴۶	۷/۱۷	۸/۵	۴/۷۱	۶/۹۳	۱/۷۳	۲/۴۵	انحراف معیار
۰/۹۹	۰/۵۱	-۰/۴۸	۰/۳۲	۴/۵۵	۰/۴۷	۲۰/۰۵	-۰/۹۹	کشیدگی
۱/۷۷	۴/۷۷	۹	۶۰/۱	۲/۱۴	۸	۰/۷	۳/۰۴	کمترین
۱/۸۹	۶/۶۲	۲۱	۸۸	۱۵	۲۷/۸	۱/۵	۸/۸۲	بیشترین
۱/۸۱	۵/۶۴	۱۴/۴۵	۷۳/۲۹	۷/۴۲	۱۹/۳۷	۱/۰۷	۶/۸۱	میانگین
۰/۰۳	۰/۶۴	۳/۲۵	۹/۸۳	۵/۰۶	۶/۹۱	۰/۲۲	۱/۳۴	انحراف معیار
۰/۶۲	-۱/۱	۱/۳	-۱/۴۹	-۱/۱۹	-۱/۳۲	۰/۵	۰/۷۳	کشیدگی

### رگرسیون چند متغیره خطی

برای تعیین رگرسیون چند متغیره پارامترهای مورد مطالعه، رابطه رگرسیونی مربوطه را با استفاده از داده‌های آموزش تعیین کرده که به صورت رابطه (۶) برای اراضی کشاورزی و رابطه (۷) برای اراضی بکر می‌باشد.



(۶)

$$\text{Infiltration (cm/hr)} = -0.913 + 0.111(P_b) + 0.111(\text{SAR}) + 0.04(\text{CaCO}_3) + 0.005(\text{Sand}) + 0.396(\text{Clay/Silt}) - 0.33(\text{EC}) \quad R^2 = 0.63 \quad (p < 0.05)$$

(۷)


$$\text{Infiltration (cm/hr)} = -0.4418 + 0.2797(P_b) - 0.381(\text{SAR}) + 0.035(\text{CaCO}_3) + 0.014(\text{Sand}) + 0.19(\text{Clay/Silt}) - 0.33(\text{EC}) \quad R^2 = 0.68 \quad (p < 0.05)$$

شبکه عصبی مصنوعی


پس از تعیین مجموع داده‌های تست و آموزش، داده‌های ورودی به شبکه را باید استانداردسازی کرد. در صورتی که داده‌ها به صورت خام وارد شبکه شود، به علت تغییرات زیاد داده‌ها، تاثیر متفاوتی بر روی شبکه گذاشته، به صورتی که برخی از نرون‌ها خیلی زود به حد آتش رسیده، درحالی که برخی دیگر از نرون‌ها حتی به آستانه فعالیت نیز نرسیده‌اند (منهاج، ۱۳۸۸). لذا ابتدا، داده‌ها با استفاده از رابطه (۸) استاندارد شده، یعنی بین یک دامنه عددی که معمولا (۰/۱ و ۰/۹) می‌باشد، قرار می‌گیرند.

$$y = 0.8 \times \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} + 0.1 \quad (8)$$

که در رابطه (۸)،  $X_{\min}$  کوچکترین داده و  $X_{\max}$  بزرگترین داده از داده‌های ورودی می‌باشد. با استفاده از این رابطه، داده‌های ورودی بین ۰/۱ و ۰/۹ قرار می‌گیرد. در مرحله بعد مدل‌های مختلف شبکه عصبی با یک لایه مخفی که تعداد نرون‌های آن بین دو تا هفت نرون می‌باشد، ساخته و ساختار بهینه شبکه با استفاده از معیار RMSE تعیین گردید. با توجه به شکل‌های (۴) و (۵) ملاحظه می‌شود که حداقل مقدار RMSE در نفوذپذیری مربوط به شبکه با سه نرون در لایه مخفی می‌باشد. همان طور که در شکل‌ها نشان داده شده است تغییرات RMSE دارای روند مشخصی نمی‌باشد چون در شبکه عصبی وزن‌ها به طور تصادفی انتخاب می‌شوند و نمی‌توان روند موجود را به طور کامل توضیح داد و باید با سعی و خطا بهترین ساختار را به دست آورد. اما باید توجه کرد که پیچیده کردن بیش از حد مدل سبب عدم برازش مناسب بین داده‌ها می‌شود. مقادیر RMSE برای پارامتر نفوذپذیری در اراضی کشاورزی و بکر به ترتیب در بهترین حالت ۰/۸۳ و ۱/۰۴ به دست آمده است که با افزایش تعداد نرون‌ها عملکرد مدل‌ها بدتر شده است.



شکل ۵- مقادیر RMSE نرون‌های متفاوت برای نفوذپذیری خاکهای بکر



شکل ۴- مقادیر RMSE نرون‌های متفاوت برای نفوذپذیری خاکهای کشاورزی



## ارزیابی مدل‌ها

نتایج مربوط به الگوریتم‌های شبکه عصبی و رگرسیون چند متغیره مربوط به پارامترهای مورد اندازه گیری در جدول (۴) آورده شده است. با توجه به این جدول ملاحظه می‌شود در کل بهترین عملکرد مربوط به شبکه عصبی مربوط به شبکه MLP و بعد از آن برای شبکه RBF و در مرتبه پایین تر رگرسیون چند متغیره می‌باشد. مقدار پایین RMSE، پایین بودن خطا و دقت بالای مدل‌های برازش شده را نشان می‌دهد. همان طور که در جدول (۴) نشان داده شده است. مدل شبکه عصبی توانسته تخمین ضریب تبیین اراضی کشاورزی و بکر را نسبت به رگرسیون چند متغیره افزایش دهد. همچنین شبکه MLP باعث افزایش ضریب تبیین نسبت به شبکه RBF شده است. قابل ذکر است که بهترین تابع برای پیش‌بینی نفوذپذیری در اراضی کشاورزی و بکر تابع تانژانت سیگموئید (TANSIG) بوده است.

جدول ۴- مقایسه نتایج به دست آمده از مدل‌های شبکه عصبی (MLP و RBF) و رگرسیون چند متغیره

خصوصیات خاک	مدل	مرحله محاسباتی	R <sup>2</sup>	RMSE	RSE	MAE
	MLP	آموزش	۰/۸۷	۰/۹۸	۰/۴۸	۰/۸۳
		صحت‌سنجی	۰/۸۰	۰/۸۳	۰/۵۳	۰/۶۹
نفوذپذیری اراضی کشاورزی	RBF	آموزش	۰/۸۱	۱/۲۳	۰/۶	۱/۱۶
		صحت‌سنجی	۰/۷۸	۱/۱۷	۰/۷۵	۱/۱۳
		رگرسیون چند متغیره	۰/۷۱	۱/۵۶	۰/۸۲	۱/۴۶
	MLP	آموزش	۰/۸۹	۱/۱۴	۰/۱۵	۰/۹۶
		صحت‌سنجی	۰/۹۰	۱/۰۴	۰/۱۵	۰/۹۳
نفوذپذیری اراضی بکر	RBF	آموزش	۰/۸۱	۱/۴۹	۰/۱۹	۱/۴
		صحت‌سنجی	۰/۷۵	۱/۲۱	۰/۱۷	۱/۱۸
		رگرسیون چند متغیره	۰/۶۸	۱/۶۷	۰/۲۲	۱/۵۸



در شکل‌های (۶) و (۷) منحنی مقادیر خطا در هر سه حالت بررسی شده، ترسیم شده است که در این اشکال کارایی بالای شبکه MLP نسبت به شبکه RBF و مدل رگرسیونی قابل مشاهده است.



شکل ۷- منحنی مقادیر خطا ۳ مدل در خاک‌های بکر

شکل ۶- منحنی مقادیر خطا ۳ مدل در خاک‌های کشاورزی



در شکل‌های (۸) و (۹) منحنی ضریب تبیین سه روش به کار رفته، ترسیم شده است که در آنجا نیز کارایی بهتر شبکه MLP مشاهده می‌شود.



شکل ۹- منحنی مقادیر ضریب تبیین ۳ مدل در اراضی بکر


شکل ۸- منحنی مقادیر ضریب تبیین ۳ مدل در اراضی کشاورزی

در شکل‌های (۱۰) تا (۱۵) پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای شبکه‌های MLP و RBF (مرحله صحت‌یابی) و روش رگرسیون خطی آورده شده است.




شکل ۱۱- دیاگرام پراکنش شبکه MLP برای نفوذپذیری اراضی


شکل ۱۰- دیاگرام پراکنش شبکه MLP برای نفوذپذیری اراضی




شکل ۱۳- دیاگرام پراکنش شبکه RBF برای نفوذپذیری



شکل ۱۲- دیاگرام پراکنش شبکه RBF برای نفوذپذیری اراضی



شکل ۱۵- دیاگرام پراکنش رگرسیون خطی برای نفوذپذیری اراضی




شکل ۱۴- دیاگرام پراکنش رگرسیون خطی برای نفوذپذیری اراضی

طبق شکل‌های فوق و نتایج حاصل از جدول (۴) بیشترین همبستگی و کمترین میزان خطا در شبکه MLP مشاهده می‌شود که از طریق کم‌ترین میزان پراکنندگی نسبت به خط کشیده شده از مبدا با زاویه ۴۵ درجه، قابل تشخیص است. بعد از شبکه MLP، شبکه RBF و رگرسیون خطی قرار دارند که همبستگی کمتر و خطای بیشتری را نسبت به شبکه MLP نشان می‌دهند.


#### آنالیز حساسیت

برای تعیین همبستگی هر یک از پارامترها با مقدار نفوذپذیری تخمین زده شده، از آنالیز حساسیت مدل MLP شبکه عصبی که بالاترین دقت را در تخمین نفوذپذیری خاک داشته است استفاده شده است. با انجام این روش می‌توان نقش هر یک از پارامترها را لحاظ کرده و قدرت آنها را محاسبه کرد. تعیین تاثیرگذارترین پارامترها در نفوذپذیری تخمین زده شده نیز با انجام این محاسبه امکان پذیر می‌شود. نتایج آنالیز حساسیت اراضی کشاورزی و بکر به ترتیب در شکل‌های (۱۶) و (۱۷) نشان داده شده است. بر اساس نتایج حاصل، درصد رس و جرم مخصوص ظاهری به ترتیب در اراضی کشاورزی و بکر بیشترین همبستگی را با نفوذپذیری داشتند در حالی که کمترین همبستگی مربوط به درصد سیلت برای اراضی کشاورزی و بکر بود. با افزایش درصد رس مقادیر خلل و فرج ریز خاک (میکروپورها) که نقش مهمی در کاهش نفوذپذیری خاک دارند، افزایش می‌دهند.

یابد که این نقش در اراضی کشاورزی به دلیل وجود درصد بیشتر رس، واضح تر است و نسبت به شن همبستگی بیشتری را با نفوذپذیری اراضی کشاورزی و بکر نشان می دهد. جرم مخصوص ظاهری نیز با اثرپذیری از بافت و میزان ماده آلی خاک نقش مهمی در نفوذپذیری بخصوص در اراضی بکر داشته است. وجود مقادیر بالای آهک سبب سیمانی شدن خاک و تشکیل سخت لایه ها و در نتیجه کاهش نفوذپذیری خاک می شود. نسبت جذب سدیم (SAR) هرچقدر بالاتر باشد تورم و پراکندگی ذرات خاک و تخریب ساختمان بیشتر است که به دلیل وجود مقادیر مشابه SAR در هر دو خاک، تاثیرگذاری آن نیز در هر دو خاک مشابه است. هدایت الکتریکی که به میزان کاتیون های محلول در خاک اشاره دارد نیز تاثیر قابل ملاحظه ای بر میزان نفوذپذیری اراضی کشاورزی و بکر نداشته است.



شکل ۱۶- آنالیز حساسیت پارامترهای خاک نسبت به نفوذپذیری اراضی کشاورزی



شکل ۱۷- آنالیز حساسیت پارامترهای خاک نسبت به نفوذپذیری اراضی بکر

#### ۴- بحث و نتیجه گیری

در این تحقیق با استفاده از دو شبکه MLP و RBF و رگرسیون چند متغیره، مقادیر نفوذپذیری اراضی کشاورزی و بکر، برآورد گردید. برای انجام رگرسیون چند متغیره از نرم افزار آماری SPSS 19 کمک گرفته شده است. در اکثر کارهای صورت

گرفته برای برآورد خصوصیات هیدرولیکی خاک، از اجزا بافت و ماده آلی به عنوان پارامترهای مستقل نام برده شده است (سرمدیان و همکاران، ۱۳۸۸؛ ابراهیمی و نایب لویی، ۱۳۸۸) ولی در این تحقیق به دلیل همبستگی پایین ماده آلی با نفوذپذیری از این فاکتور صرف نظر شده است. پس از تعیین ساختار بهینه هر یک از مدل‌ها با استفاده از معیارهای آماری  $R^2$ ، RMSE، RSE و MAE اقدام به پیش‌بینی خصوصیات خاک با استفاده از مدل مربوطه گردید. نتایج این بررسی نشان داد که در این تحقیق، شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی کارایی بهتری داشته زیرا احتمالاً از یک طرف کارایی توابع انتقالی به دست آمده در مناطق مختلف با هم متفاوتند و از طرف دیگر بر طبق نظریه‌ای در طراحی شبکه‌های عصبی نوعی خاص از معادلات لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد (Schaap et al, 1998) و به علت وجود روابط غیرخطی میان متغیرهای وابسته و پیش‌بینی شونده، شبکه عصبی عملکرد بهتری نسبت به مدل‌های رگرسیون داشته است. همچنین نتایج نشان می‌دهد که شبکه‌های MLP که متداول‌ترین نوع شبکه‌های عصبی در مدل‌سازی سیستم‌های مختلف می‌باشند در مدل‌سازی نفوذپذیری نسبت به شبکه‌های RBF از عملکرد بهتری برخوردارند و تنها مزیت شبکه‌های RBF نسبت به MLP، زمان کوتاه‌تر مورد نیاز برای آموزش می‌باشد (Haykin, 1999). نتایج این بررسی از نتایج به دست آمده توسط برخی از محققین که به کارایی بالاتر شبکه MLP در برابر شبکه RBF رسیده بودند، پیروی می‌کند (Mutlu et al, 2008; Rub et al, 2009). ولی با نتایج عده‌ای از محققین که به نتایج بهتری در شبکه RBF رسیده بودند، در تناقض است (ارشد و همکاران، ۱۳۸۸، Yilmaz & Kaynar, 2011)؛ همین‌طور که از نتایج این تحقیق و سایر پژوهش‌ها، مشاهده می‌کنید، در یک سری از پژوهش‌ها شبکه MLP و در تعدادی از آنها شبکه RBF از قابلیت بالاتری برای تخمین پارامترهای خام برخوردار بوده است و نتیجه‌گیری قطعی در مورد کارایی بهتر هر یک از شبکه‌ها وجود ندارد. آنالیز حساسیت خاک‌ها نیز نشان دهنده تاثیر پارامترهای مختلف به خصوص درصد رس و مقادیر جرم مخصوص ظاهری در تخمین نفوذپذیری اراضی کشاورزی و بکر است. همچنین یکی از تاثیرگذارترین پارامترها بر میزان نفوذپذیری خاک‌ها، درصد آهک تعیین گردید و این خود نقش مهم درصد آهک را بر میزان نفوذپذیری خاک‌ها که در مقادیر اندک سبب افزایش همآوری ذرات و در نتیجه افزایش نفوذپذیری و در مقادیر زیاد سبب تشکیل سخت لایه‌ها و کاهش نفوذپذیری می‌گردد، نشان داد.

با توجه به معیارهای مورد استفاده جهت ارزیابی (RSE, MAE, RMSE,  $R^2$ )، نتایج بررسی نشان می‌دهد که در این تحقیق مدل شبکه عصبی در مقایسه با معادلات رگرسیونی در پیش‌بینی پارامترهای خاک کارایی بالاتری داشته است. بین دو شبکه MLP و RBF، شبکه پرسپترون چند لایه (MLP) قابلیت بالاتری نسبت به شبکه توابع پایه شعاعی (RBF) دارد.

## ۵- تشکر و قدردانی

مولفین مقاله از حمایت مرکز تحقیقات منابع طبیعی و امور دام استان سمنان جهت فراهم نمودن برخی امکانات و تجهیزات آزمایشگاهی و صحرایی تقدیر و تشکر خود را ابراز می‌نمایند.

## ۶- مراجع

- ۱- ارشد، ر.ا.، ج. صیاد، م. مظلوم، و آ.ر. جعفری نژاد، ۱۳۸۸. تخمین قابلیت نفوذ آب با استفاده از شبکه عصب، سومین کنفرانس آبیاری و مدیریت آب، اهواز، ایران
- ۲- ابراهیمی، ک.، و ف. نایبلویی، ۲۰۰۹. تخمین نرخ نفوذ نهایی خاک‌ها با استفاده از شبکه عصبی مصنوعی، مطالعه موردی: مزرعه پردیس ابوریحان، مجله حفاظت آب و خاک، ۱۶ (۱)
- ۳- قربانی دشتکی، ش. و م. همایی، ۱۳۸۱. برآورد پارامتریک توابع هیدرولیکی بخش غیراشباع خاک با استفاده از توابع انتقالی. مجله تحقیقات مهندسی کشاورزی، ۱۶-۱: ۳(۱۲).
- ۴- منهای، م.، ۱۳۸۸. اصول شبکه‌های عصبی، انتشارات امیرکبیر
- ۵- نصیری صالح، ف.، و ق. منتظر، ۱۳۸۰. استفاده از شبکه عصبی مصنوعی برای برآورد میزان آبشویی در پایین دست سدها، سومین کنفرانس هیدرولیک، دانشگاه تهران
- ۶- سرمدیان، ف.، ر.ا. تقی‌زاده، عسگری، ح.م.، و ا. اکبرزاده، ۱۳۸۹. مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چند متغیره در پیش‌بینی برخی خصوصیات خاک (مطالعه موردی: استان گلستان)، مجله تحقیقات آب و خاک، ۱ (۴۱): ۲۱۱-۲۲۰.
- 7- Amini, M., M. Afyuni., N. Fathianpourb., H. Khademi., and H. Fluchler., 2005. Continuous soil pollution mapping using fuzzy logic and spatial interpolation. *Geoderma*, 124: 223-233.
- 8- Dibike, Y.B., D. Solomatine., and M.B. Abbott., 1999. On the encapsulation of numerical hydraulic models in artificial neural network. *Journal of Hydraulic Research*, 37(2). 147-161.
- 9- Gee, G., and J.W. Bauder., 1986. Particle size distribution analysis. In: Klute, A. (Ed.), Method of soil analysis. Part 1, second ed. Agron. Monogr. 9. ASA and SSSA, Madison, WI. 383-411.
- 10- Green, W.H., and G.A. Ampt., 1911. Studies in soil physics: I. The flow of air and water through soils. *J. Agric. Science*, 4: 1-24.
- 11- Haykin, S., 1999. Neural networks: A Comprehensive Foundation, 2nd ed., Upper Saddle River, NJ: Prentice-Hall.
- 12- Horton, R.E., 1940. An approach toward to physical interpretation of infiltration capacity. *Soil. Sci. Soc. Am. J*, 5: 399-417.
- 13- Jain, A., and A. Kumar., 2006. An evaluation of artificial neural network technique for the determination of infiltration model parameters, *Applied Soft Computing*, 6: 272-282.
- 14- Kostiaikov, A.N., 1932. On the Dynamic of coefficient of water-percolation in soils and on the necessity for studying it from a dynamic point of view for purposes of amelioration. Trans sixth comm. *Intern. Soil. Sci. Soc. Russia*, 17-21.
- 15- Lallahema, S., J. Maniaa., A. Hania., and Y. Najjarb., 2005. On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*, 307: 92-111.
- 16- Marcel, G.S., J.L. Feike., T. Martinus., and H. van Genuchten., 1998. Neural Network Analysis for Hierarchical Prediction of Soil Hydraulic Properties, *Soil Science Society*, 62: 847-855.
- 17- Mason, J.C., R.K. Price., and A. Temme., 1996. A neural network model of rainfall-runoff using radial basis functions. *J. of Hydraulic Research*, 34: 537-548.
- 18- Merdun, H., O. Cinar., R. Meral., and M. Apan., 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity, *Soil and Tillage Research*, 90: 108-116.
- 19- Mutlu, E., I. Chaubey., H. Hexmoor., and S.G. Bajwa., 2008. Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed. *Hydrol. Process*. 22(26): 5097-5106.
- 20- Navabian, M., A.M. Liaghat., and M. Homayi., 2004. Prediction of lectrical conductivity with neural networks. International water and soil conference, Shiraz University, 203-211.



- 21- Nielsen, R., 1987. Kolmogrov's mapping neural network existence theorem. Proceedings of the 1st IEEE International Joint Conference on Neural Networks, San Diego.
- 22- Philip, J. R., 1957. The theory of infiltration, I. Infiltration equation and its solution. *Soil Sci.* 83: 345-357.
- 23- Rub, G., R. Kruse., M. Schneider., and P. Wagnr., 2009. Using advanced regression models for determining optimal soil heterogeneity indicators. *Studies in Classification, Data Analysis, and Knowledge Organization*, 463-471.
- 24- Schaap, M.G., F.J. Leij., and M.T. van Genuchten., 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *J. Soil Sci. Soc. Am*, 62: 847-855.
- 25- Sparks, D.L., A.L. Page., P.A. Helmke., R.H. Leoppert., P.N. Soltanpour., M.A. Tabatabai., G.T. Johnston., and M.E. Summer., 1996. *Methods of soil analysis*, SSSA, Madison, Wisconsin.
- 26- Tomasella, J., M.G. Hodnett., and L. Rossato., 2000. Pedotransfer functions for the estimation of soil water retention in Brazilian soils. *J. Soil Sci. Soc. Am*, 49: 1100-1105.
- 27- Yilmaz, I., and O. Kaynar., 2011. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. *Expert Systems with Applications*, 38: 5958-5966.