



شماره ۱۱۳، زمستان ۱۳۹۵

# پژوهش‌های آب‌نخرداری

(پژوهش و سازندگی)

## برآورد نقطه‌ای منحنی مشخصه‌ی رطوبتی خاک با استفاده از شبکه‌ی عصبی مصنوعی و بهینه‌سازی آن با الگوریتم ژنتیک در کشت و صنعت‌های نیشکر خوزستان

### • نبی جنادله

دانش‌آموخته گروه علوم خاک، دانشگاه کشاورزی و منابع طبیعی رامین خوزستان

### • حبیب‌الله نادیان

استاد گروه علوم خاک، دانشگاه کشاورزی و منابع طبیعی رامین خوزستان

### • بیژن خلیلی مقدم\*

(نویسنده‌ی مسئول) دانشیار گروه علوم خاک، دانشگاه کشاورزی و منابع طبیعی رامین خوزستان

### • شجاع قربانی دشتکی

استاد گروه علوم خاک، دانشگاه شهرکرد

تاریخ دریافت: بهمن ۱۳۹۱ تاریخ پذیرش: تیر ۱۳۹۲

\* Corresponding Email: khalilimoghadam@ramin.ac.ir

### چکیده

ویژگی‌های هیدرولیکی خاک در مدیریت اراضی تحت کشت نیشکر نقش به‌سزایی دارد. هدف از این تحقیق برآورد نقطه‌ای منحنی مشخصه‌ی رطوبتی خاک با استفاده شبکه‌ی عصبی مصنوعی و بهینه‌سازی آن با الگوریتم ژنتیک می‌باشد. به این منظور براساس ویژگی‌های مدیریت اراضی، درصد مواد آلی، بافت خاک، هدایت الکتریکی و درصد سدیم جذب سطحی شده، ۴ واحد کاری در کشت و صنعت‌های دعبل خزاعی، امیر کبیر، کارون و هفت‌تپه انتخاب شد. در مجموع تعداد ۳۱۰ نمونه خاک از دو عمق ۰-۴۰ و ۴۰-۸۰ سانتی‌متری نیمرخ خاک به طور تصادفی برداشت گردید. در این پژوهش پنج مدل به شکل سلسله مراتبی به وسیله‌ی شبکه‌ی عصبی مصنوعی برای برآورد نقطه‌ای منحنی مشخصه‌ی رطوبتی خاک مورد پی‌ریزی و ارزیابی قرار گرفت. جهت بررسی کارایی مدل‌ها از ضریب همبستگی اسپیرمن (R)، متوسط مربعات خطای نرمال شده (NMSE) و متوسط خطای مطلق (MAE) استفاده شد. از آن جا که انتخاب هر یک از پارامترهای متغیر شبکه‌ی عصبی مستلزم آزمون و خطاهای مکرر و در نتیجه آموزش تعداد زیادی شبکه با ساختار مختلف بود، از روش الگوریتم ژنتیک برای بهینه‌یابی این پارامترها استفاده شد و کارایی این روش در بهینه‌سازی شبکه‌ی عصبی بررسی گردید. نتایج نشان داد که شبکه‌ی عصبی در مدل‌سازی و برآورد نقطه‌ای منحنی مشخصه‌ی رطوبتی خاک از دقت بالایی برخوردار است (NMSE=054/0، MAE=019/0، R=963/0). همچنین تلفیق شبکه‌ی عصبی با الگوریتم ژنتیک، جهت بهینه‌سازی شرایط اجرایی آن، مثبت ارزیابی گردید و روش تلفیقی در تمامی موارد برتری خود را نسبت به اجرای شبکه‌ی عصبی بدون بهینه‌سازی نشان داد (NMSE=015/0، MAE=01/0، R=985/0).

واژه‌های کلیدی: الگوریتم ژنتیک، شبکه‌های عصبی مصنوعی، منحنی مشخصه‌ی رطوبتی خاک

## Point estimation of soil moisture characteristic curve using artificial neural networks and its optimizing by genetic algorithm in Agro-Industries of Khuzestan

**. N. Jenadeleh**

Graduated student (MSc.), Department of Soil Science, Ramin Agriculture and Natural Resources University of Khuzestan, Ahvaz, Iran

**. H.A. Nadian**

Prof., Department of Soil Science, Ramin Agriculture and Natural Resources University of Khuzestan, Ahvaz, Iran

**. B. Khalilimoghadam**

(Corresponding Author) Associate Prof., Department of Soil Science, Ramin Agriculture and Natural Resources University of Khuzestan, Ahvaz, Iran

**. S. Ghorbani dashtaki**

Prof., Department of Soil Science, Shahrekord University, Shahrekord, Iran

### Abstract

Soil hydraulic properties have key role in sugar cane cultivation management. The purpose of this study is to estimate soil moisture characteristic curve using an artificial neural network and its optimization with genetic algorithm. Therefore, based on the cultivation operations management and soil properties included: organic matter content, soil texture, electrical conductivity, sodium adsorption ratio, 4 land unit tracts in Debel-Khozaii, Amir-Kabir, Karoon and Haft-Tapeh agro-industries were selected. A total of 310 soil samples from both 40-0 and 80-40 cm of soil profiles were collected. In this study, five models were arranged in hierarchy to estimate soil hydraulic properties with ANNs. The performances of the models were evaluated using Spearman's correlation coefficient ( $r$ ) between the observed and the estimated values, normalized mean square error (NMSE), and mean absolute error (MAE). Owing to the fact that the selection of each of the variable parameters of neural network necessitated recurring trails and errors, and consequently teaching a large number of networks with various topologies, genetic algorithm method was utilized for finding the optimization of these parameters and the efficiency of this method was examined in terms of the optimization of neural network. Results showed that the neural network has a high degree of accuracy in modeling and estimating soil moisture characteristic curve ( $R = 0.943$ ,  $MAE = 0.019$ ,  $NMSE = 0.054$ ). Also, combining artificial neural networks with genetic algorithm for optimizing the conditions of the artificial neural networks implementation was positive and combining approach indicated its superiority over non-optimized implementation of artificial neural networks in all cases ( $R = 0.985$ ,  $MAE = 0.01$ ,  $NMSE = 0.0151$ ).

**Keywords:** Genetic algorithms, Artificial neural networks, Soil moisture characteristic curve

یکی از مسائل بسیار مهم در کشت نیشکر، آبیاری، تعیین نیاز آبی آن و زهکشی اراضی زیر کشت می‌باشد؛ که لازمه‌ی آن آگاهی از ویژگی‌های هیدرولیکی خاک در این شرایط است (Torabi Farsani and Ghahramani, 2007). اندازه‌گیری مستقیم خواص

### مقدمه

خوزستان به دلیل موقعیت جغرافیایی خاص خود، دارای اقلیم مناسب جهت کشت نیشکر می‌باشد. در حال حاضر توسعه‌ی نیشکر در این استان از رونق خاصی برخوردار گردیده‌است (Fauconnier, 2004).

بیشینه یا کمینه کند. برای رسیدن به چنین هدفی، الگوریتم ژنتیک از فرآیندهای بیولوژیکی انتخاب طبیعی و کارکرد عملگرهای ژنتیکی، مانند تقاطع ۱ و جهش ۲، تقلید می‌کند (Michalewicz, 1996). پاراشورامان و همکاران (۲۰۰۷) برای به دست آوردن توابع انتقالی خاک جهت تخمین هدایت هیدرولیکی اشباع خاک به عنوان تابعی از میزان شن، سیلت، رس و چگالی ظاهری از الگوریتم ژنتیک استفاده نمودند. مجدلانی و همکاران (۲۰۰۷) پارامترهای معادله‌ی جریان ترجیحی آب ۵ در خاک‌های غیر اشباع را به وسیله‌ی الگوریتم ژنتیک بهینه کردند. پدروزو و ویلیامز (۲۰۱۱)، جهت بهینه‌سازی مدل‌های خود، روش الگوریتم ژنتیک را به کار بردند.

بر اساس تحقیقات ماتیوس (۲۰۰۰)، امروزه یکی از پر کاربردترین کارکردهای الگوریتم ژنتیک، اتصال آن به شبکه‌های عصبی مصنوعی می‌باشد. مونتانا (۲۰۰۱) تحقیقی در مورد نحوه‌ی آموزش شبکه‌های عصبی پیشرو به وسیله‌ی الگوریتم ژنتیک انجام دادند. پرورش‌ریزی و همکاران (۲۰۰۶) تلفیق شبکه‌ی عصبی و الگوریتم ژنتیک را برای بهینه‌سازی شرایط اجرای شبکه‌ی عصبی، در برآورد پارامترهای هیدرولیکی، مثبت ارزیابی کردند. در یک پژوهش که توسط فقیه (۲۰۱۰) انجام شد، داده‌های بارش ماهانه در منطقه‌ی کردستان با استفاده از شبکه‌ی عصبی مصنوعی تخمین و شرایط اجرای آن با الگوریتم ژنتیک بهینه‌سازی گردید. نتایج تحقیقات جوهری و همکاران (۲۰۱۱) نشان‌دهنده‌ی برتری روش تلفیقی الگوریتم ژنتیک و شبکه‌ی عصبی، نسبت به اجرای شبکه‌ی عصبی مصنوعی بدون بهینه‌سازی جهت تبیین رفتار مکانیکی خاک‌های غیر اشباع، می‌باشد. استفاده از توابع انتقالی خاک نقش اساسی در حل مشکلات مدیریتی آب و زهکشی اراضی زیر کشت نیشکر دارد.

از آن‌جا که در کشت و صنعت‌های نیشکر خوزستان چنین توابعی وجود ندارد، ایجاد چنین توابعی لازم و ضروری به نظر می‌رسد. هدف از این پژوهش ایجاد توابع انتقالی نقطه‌ای جهت برآورد منحنی مشخصه‌ی رطوبتی خاک با استفاده از شبکه‌های عصبی مصنوعی و بهینه‌سازی شرایط اجرای آن‌ها با استفاده از الگوریتم ژنتیک در کشت و صنعت‌های نیشکر خوزستان می‌باشد.


هیدرولیکی خاک، پرهزینه، مشکل و زمان‌بر می‌باشند (Wosten, Pachepsky and Rawls 2001). به همین دلیل تلاش‌های متعددی برای برآورد این خصوصیات به طریقه‌ی غیرمستقیم صورت پذیرفته‌است. یکی از این روش‌ها، استفاده از توابع انتقالی است. توابع انتقالی خاک، روابطی ریاضی هستند که امکان برآورد خصوصیات دیرپافت خاک مانند منحنی نگهداشت رطوبتی و هدایت هیدرولیکی را از متغیرهای زودپافت خاک مانند بافت، چگالی ظاهری و میزان ماده‌ی آلی فراهم می‌کنند (Mermoud and Xu, 2006).

قربانی دشتکی و همکاران (۲۰۱۰)، از توابع انتقالی نقطه‌ای برای پیش‌بینی میزان آب خاک در پتانسیل‌های ماتریک مختلف برای بعضی از خاک‌های ایران استفاده کردند. کشاورزی و همکاران (۲۰۱۱) طرح جستجوی جدول فازی ۳ را جهت تخمین رطوبت خاک در ظرفیت زراعی و نقطه‌ی پژمردگی با استفاده از ویژگی‌های رس، سیلت، کربن آلی درصد رطوبت اشباع، چگالی ظاهری و کربنات کلسیم به کار بردند. چاکرابورتی و همکاران (۲۰۱۱) از توابع انتقالی نقطه‌ای جهت تخمین میزان رطوبت در نقاط مختلف منحنی رطوبتی استفاده کردند. این پژوهشگران در مطالعات خود برتری توابع انتقالی نقطه‌ای را نسبت به توابع انتقالی پارامتریک نشان دادند.

جهت ایجاد توابع انتقالی خواص هیدرولیکی خاک می‌توان از شبکه‌های عصبی مصنوعی استفاده کرد. سرمدیان و همکاران (۲۰۰۹) و شیرانی و رفیعی‌نژاد (۲۰۱۲) برتری شبکه‌های عصبی بر دیگر توابع انتقالی جهت برآورد منحنی رطوبتی خاک را گزارش دادند. پاتیل و همکاران (۲۰۱۲)، با استفاده از الگوریتم نزدیک‌ترین همسایه ۴ و شبکه‌های عصبی، ده تابع انتقالی متفاوت برای پیش‌بینی ظرفیت آب قابل استفاده در خاک‌های ورتی‌سول هندوستان ایجاد کردند. محققان زیاد دیگری نیز قابلیت بالای شبکه‌های عصبی را جهت ایجاد توابع انتقالی خود گزارش کردند (Schaap, Leij, and Van Genuchten, 1998., Zhu, and Julian, 2011., Kianpoor Kalkhajeh, Rezaie Arshad, Amerikhah, and Sami, 2012).

برای بهینه‌سازی پارامترهای مدل‌های به دست آمده می‌توان از الگوریتم‌های ژنتیک استفاده نمود (Deb, 2009). هدف الگوریتم ژنتیک پیدا کردن ترکیبی از مقادیر است که بتواند یک تابع معین را

## مواد و روش‌ها منطقه مورد مطالعه و شیوهی نمونه‌برداری



شکل ۱ موقعیت چهار کشت و صنعت مورد مطالعه در استان خوزستان

کیلوپاسکال توسط ستون آویزان آب و در مکش‌های ماتریک ۱۰۰، ۵۰۰ و ۱۵۰۰ کیلو پاسکال با استفاده از دستگاه صفحات فشاری به دست آمد و با استفاده از چگالی ظاهری خاک‌ها به رطوبت حجمی تبدیل شده و سپس منحنی مشخصه رطوبتی آن‌ها ترسیم شد. مدل‌سازی توابع انتقالی خاک به وسیله‌ی شبکه‌های عصبی مصنوعی برای ایجاد توابع انتقالی از شبکه‌ی عصبی مصنوعی با ساختار پیش‌خور چند لایه‌ی استاندارد (MLP) استفاده گردیده است. این ساختار از مهم‌ترین ساختارهای شبکه‌های عصبی است که در مدل‌سازی اکولوژیکی مورد استفاده قرار می‌گیرد (Schulze, ۲۰۰۰). تعداد نورون، اندازه گام و مقدار ممنتوم به وسیله روش سعی و خطا تعیین شده‌اند. بر این اساس کم‌ترین تعداد نورونی که عملکرد رضایت بخشی حاصل نمایند، انتخاب می‌شوند (قضاوت بر اساس کارایی شبکه). ماکزیمم ۱۰۰۰۰ دور (اپچ) در نظر گرفته شده است و توقف زود هنگام در حین آموزش به وسیله اعتبارسازی انجام گردید. تحلیل حساسیت به روش حساسیت در حدود میانگین ۷ با استفاده از نرم افزار Neurosolution ۵ برای هر یک از مدل‌های داده‌های زود یافت انجام گرفت. برای آزمون شبکه‌های عصبی از روش اعتبار سازی نمونه‌های تقسیم شده استفاده گردید. در این روش داده‌ها به دو بخش آموزش و آزمون تقسیم می‌شوند و از داده‌های آزمون در فرایند آموزش استفاده نمی‌شود. پس از آموزش شبکه عصبی، داده‌های آزمون به وسیله شبکه آموزش دیده، تحلیل می‌شود و خطای داده‌های آزمون به دست می‌آید که در واقع تخمین ناریبی از خطای تعمیم سازی است. در این پژوهش ۶۶ درصد داده‌ها (۱۰ درصد اعتبارسازی) برای آموزش و ۳۴ درصد برای آزمون انتخاب شدند.

محدوده مورد مطالعه این پژوهش، چهار کشت و صنعت امیر کبیر، هفت تپه، دعبل خزاعی و کارون در استان خوزستان واقع در جنوب غربی ایران می‌باشد (شکل ۱). خاک‌های مورد مطالعه در گروه بزرگ Typic Haploustepts قرار دارند و نوع کاربری اراضی نیز، نیشکر می‌باشد (Nasari, Jafari and Alimohammadi, ۲۰۰۷). در این کشت و صنعت‌ها براساس تعداد سال‌های کشت، مواد آلی، بافت و هدایت الکتریکی مزارعی جهت نمونه برداری به طور تصادفی نظارت شده انتخاب گردید و تعداد ۳۱۰ نمونه خاک از دو عمق ۰-۴۰ و ۴۰-۸۰ سانتی‌متری پروفیل، جمع‌آوری شد.

### ویژگی‌های اندازه‌گیری شده

نمونه‌های جمع‌آوری شده پس از انتقال به آزمایشگاه، هوا خشک شده، سپس کوبیده و از الک دو میلی‌متری عبور داده شدند. اندازه‌گیری چگالی ظاهری (BD) به روش سیلندری، بافت خاک به روش هیدرومتری، میانگین وزنی قطر خاکدانه‌ها (MWD) به روش الک تر و مقاومت نفوذی خاک با استفاده از پنترومتر (دستگاه نفودسنج الکترونیکی) انجام شد.

درصد کربن آلی (OC) به روش والکی-بلاک، درصد کربنات کلسیم معادل (CaCO<sub>3</sub>) به روش کلسیمتری، نسبت سدیم جذب سطحی شده (SAR) به کمک روش‌های معمول آزمایشگاهی و هدایت الکتریکی (EC) در عصاره اشباعی خاک و واکنش خاک (pH) در گل اشباع به ترتیب توسط دستگاه‌های EC متر و pH متر اندازه‌گیری شدند. درصد رطوبت اشباع به روش وزن سنجی، مقادیر رطوبت وزنی خاک‌های دست نخورده در مکش‌های ماتریک ۱۰ و ۳۳

ورودی‌های زودیاقت جهت ایجاد پنج مدل از توابع انتقالی نقطه‌ای منحنی مشخصه‌ی رطوبتی خاک نشان داده شده است.

مجموعاً حدود ۳۰۰۰ داده برای ایجاد پنج مدل از داده‌های زودیاقت برای برآورد نقطه‌ای منحنی مشخصه رطوبتی خاک توسط شبکه عصبی مصنوعی به کار رفته است. در جدول ۱ متغیرهای مطلوب و

جدول ۱- متغیرهای مطلوب و ورودی جهت مدل‌های به کار رفته برای ایجاد توابع انتقالی نقطه‌ای

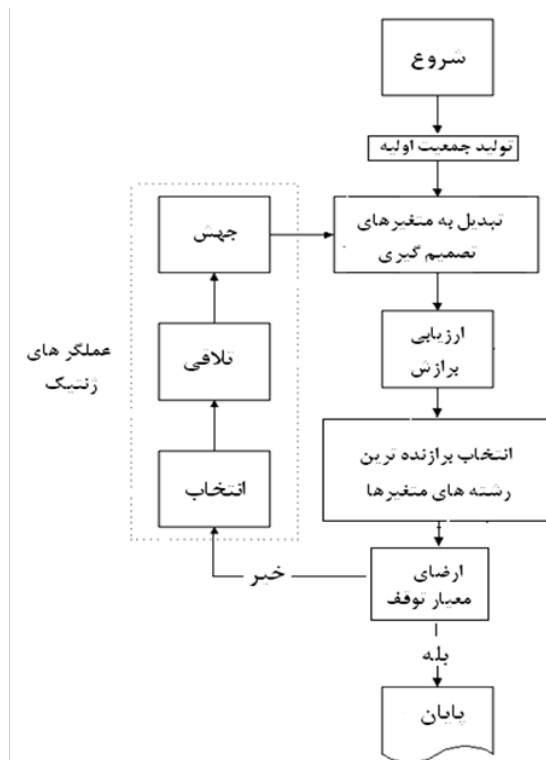
مدل	متغیرهای مطلوب	متغیرهای لایه‌ی ورودی
مدل ۱	$\theta_{\psi}$	SSC
مدل ۲	$\theta_{\psi}$	SSC+ CaCO <sub>3</sub>
مدل ۳	$\theta_{\psi}$	SSC+ BD +OC
مدل ۴	$\theta_{\psi}$	SSC+BD
مدل ۵	$\theta_{\psi}$	SSC+BD+ CaCO <sub>3</sub>

$\theta$ : درصد رطوبت خاک در پتانسیل ماتریک  $\psi$ ، SSC: بافت خاک (درصد شن، سیلت و رس)، BD: چگالی ظاهری، OC: درصد کربن آلی خاک، CaCO<sub>3</sub>: درصد آهک خاک

برای اجرای این بهینه‌سازی، در الگوریتم ژنتیک از تلاقی دو نقطه‌ای با احتمال ۰/۹ و جهش یک‌نواخت با احتمال ۰/۱ استفاده گردید و تعداد تکرار ۱۰۰۰، تعداد جمعیت ۴۰ و حداکثر نسل تولید شده ۱۰۰ در نظر گرفته شد. روند اجرایی الگوریتم ژنتیک به صورت شماتیک در شکل (۲) نشان داده شده است.

### الگوریتم ژنتیک

در این پژوهش پارامترهای شبکه‌های عصبی، شامل ورودی و تعداد نورون‌ها در لایه‌ی پنهان، با الگوریتم ژنتیک به نحوی بهینه‌یابی شدند که در مرحله‌ی آزمون شبکه‌ی عصبی، نتایج برآورد شده توسط مدل، یا داده‌های خروجی، بهترین برازش را با داده‌های مطلوب، داشته باشند.



شکل ۲- نمای روند اجرای الگوریتم ژنتیک


## تحلیل‌های آماری

برای ایجاد مدل‌های شبکه عصبی جهت برآورد نقطه‌ای منحنی مشخصه رطوبتی خاک و انجام محاسبات از نرم افزارهای آماری SAS Institute Inc. 1999 (SAS) و Neurosolutions5 استفاده گردید. جهت ارزیابی دقت مدل‌های تدوین شده با شبکه‌های عصبی و نیز مقایسه‌ی این مدل‌ها با مدل‌های بهینه‌سازی شده با الگوریتم ژنتیک از معیارهای آماری ضریب همبستگی (R)، میانگین خطای مطلق (MAE) و میانگین مربعات خطای نرمال شده (NMSE) استفاده شده است (Wosten et al, 2001).

## نتایج

### ویژگی‌های خاک‌های منطقه مورد مطالعه

ویژگی‌های خاک‌های منطقه مورد بررسی که برای ایجاد توابع انتقالی خاک به کار رفته است، در جدول ۲ آمده است. خاک‌های مورد مطالعه در کلاس‌های بافتی رسی، لوم رسی، رسی سیلتی، لوم رسی سیلتی، لوم رسی شنی، لوم، لوم سیلتی و لوم شنی قرار دارند (شکل ۳).



شکل ۳- توزیع فراوانی نسبی ذرات خاک‌های مورد مطالعه

خاک‌های مورد نظر، از چگالی ظاهری زیادتری نسبت به آن محدوده برخوردارند. میانگین مقاومت نفوذی (PR) نسبتاً بالاست. اما با توجه به یافته‌های اتو و همکاران (۲۰۱۱) این مقدار مقاومت نفوذی مانع رشد ریشه‌ی گیاه نیشکر نمی‌شود.

مقدار کربن آلی در حد متوسط می‌باشد. با توجه به میانگین آهک و با در نظر گرفتن میانگین pH که در محدوده ۸/۱۱ تا ۸/۳۵ قرار دارد، این خاک‌ها در گروه خاک‌های آهکی جای می‌گیرند. با توجه به این که چگالی ظاهری در خاک‌های رسی بین ۱ تا ۱/۵ گرم بر سانتی‌متر مکعب نوسان می‌کند (Musy and Soutter, ۱۹۹۱)،

جدول ۲- ویژگی‌های خاک‌های چهار کشت و صنعت مورد مطالعه

هفت تپه	کارون		امیر کبیر		دعبل خزاعی		کشت و صنعت ویژگی	
	انحراف میانگین	انحراف معیار	انحراف میانگین	انحراف معیار	انحراف میانگین	انحراف معیار		
۳/۱۳	۳۹/۴۰	۳/۸۲	۳۵/۰۰	۱۳/۳۰	۳۸/۸۰	۸/۶۳	۳۷/۶۰	رس (/)
۲/۵۴	۳۸/۱۰	۲/۶۰	۴۵/۱۰	۸/۵۲	۳۰/۸۰	۷/۴۷	۳۸/۵۰	سیلت (/)
۳/۱۸	۲۲/۴۰	۴/۰۴	۱۹/۸۰	۱۸/۹۸	۳۰/۴۰	۹/۵۰	۲۳/۹۰	شن (/)
۰/۳۵	۱/۳	۰/۳۶	۰/۹	۰/۳۶	۰/۸۵	۰/۵۳	۰/۹۲	کربن آلی (/)
۱/۸۵	۳۸/۰۲	۱/۴۲	۳۶/۷۴	۱/۵۸	۳۹/۹۶	۱/۱۱	۴۰/۶۱	آهک (/)
۱۰/۰۰	۱/۷۶	۰/۲۸	۱/۶۱	۰/۱۶	۱/۶۰	۰/۱۴	۱/۵۷	چگالی ظاهری (grcm <sup>-3</sup> )
۰/۱۵	۸/۳۵	۰/۱۶	۸/۲۷	۰/۱۶	۸/۲۳	۰/۳۰	۸/۱۱	اسیدیته
۰/۱۴	۰/۶۸	۰/۷۸	۱/۹۹	۱/۱۹	۲/۹۱	۳/۵۰	۵/۴۷	هدایت الکتریکی (dSm <sup>-1</sup> )
۰/۸۲	۱/۰۰	۱/۸۷	۴/۰۱	۲/۲۵	۸/۳۵	۲/۶۷	۸/۳۰	نسبت جذب سطحی سدیم (meq/l) <sup>1/2</sup>
۱/۱۸	۰/۲۰	۲/۳۷	۴/۳۸	۲/۶۴	۹/۸۸	۳/۰۰	۹/۸۰	سدیم قابل تبادل (/)
۰/۵۰	۱/۲۶	۰/۶۵	۱/۲۸	۰/۶۳	۱/۰۷	۰/۳۶	۰/۹۸	میانگین وزنی قطر خاکدانه‌ها (/)
۰/۴۷	۱/۶۵	۰/۶۳	۱/۶	۰/۴۱	۱/۳	۰/۴۰	۱/۱۲	مقاومت نفوذی (MPa)

به وسیله‌ی شبکه‌ی عصبی در خاک رویین و خاک زیرین در جدول ۳ نشان داده شده‌است. مشاهده می‌شود که وارد شدن میزان آهک به مدل ۱ (با متغیرهای میزان شن، سیلت و رس) موجب افزایش ضریب همبستگی در مدل ۲ شده‌است. همچنین نتایج نشان می‌دهد که وارد شدن کربن آلی در مدل ۴ (با متغیرهای میزان شن، سیلت و رس و چگالی ظاهری) باعث کاهش ضریب همبستگی در مدل ۳ گشته است. به علاوه، ملاحظه می‌گردد که وارد کردن چگالی ظاهری در مدل ۱ (با متغیرهای میزان شن، سیلت و رس) و مدل ۲ (با متغیرهای میزان شن، سیلت و رس و درصد آهک) ضریب همبستگی را به ترتیب در مدل‌های ۴ و ۵ افزایش داده‌است.

جدول ۳- ضریب همبستگی (R) بین مقادیر رطوبتی اندازه‌گیری و

نظر به میانگین مقادیر EC، ESP و pH، خاک کشت و صنعت دعبل خزاعی در رده‌ی خاک‌های شور قرار می‌گیرد. خاک‌های سه کشت و صنعت دیگر نیز شور بوده‌اند ولی بر اثر آبشویی شدید میزان شورى آن‌ها کاهش پیدا کرده‌است؛ به طوری که در حال حاضر در رده‌ی خاک‌های معمولی (نه شور - نه سدیمی) طبقه‌بندی می‌شوند. با در نظر گرفتن میانگین درصد خاکدانه‌های پایدار در آب (MWD) و با توجه به دسته بندی دیلکوا و همکاران (۱۹۹۸) این خاک‌ها در دسته‌ی خاک‌های با پایداری خیلی خوب قرار می‌گیرند.

### مدل‌سازی نقطه‌ای ضرایب رطوبتی خاک به وسیله‌ی شبکه‌ی عصبی مصنوعی

ضرایب همبستگی بین میزان رطوبت اندازه‌گیری شده و برآورد شده

جدول ۳- ضریب همبستگی (R) بین مقادیر رطوبتی اندازه‌گیری و برآورد شده به وسیله‌ی شبکه‌ی عصبی در خاک رویین و زیرین

مدل	R خاک رویین					R خاک زیرین				
	$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$
مدل ۱	۰/۶۷۴	۰/۷۷۰	۰/۶۳۵	۰/۶۴۵	۰/۶۵۳	۰/۶۴۳	۰/۷۲۶	۰/۵۹۲	۰/۶۵۰	۰/۶۷۷
مدل ۲	۰/۷۶۱	۰/۸۲۷	۰/۷۲۲	۰/۷۲۳	۰/۷۳۱	۰/۷۰۹	۰/۷۷۷	۰/۶۹۱	۰/۷۲۶	۰/۷۴۹
مدل ۳	۰/۷۲۶	۰/۸۰	۰/۶۶۵	۰/۶۹۴	۰/۷۰۳	۰/۶۹۱	۰/۷۵۸	۰/۶۳۳	۰/۷۰۷	۰/۷۲۸
مدل ۴	۰/۸۰۷	۰/۸۸۹	۰/۷۷۲	۰/۷۸۱	۰/۷۹۰	۰/۷۶۷	۰/۸۴۱	۰/۷۴۱	۰/۷۹۵	۰/۷۹۴
مدل ۵	۰/۸۸۴	۰/۹۴۳	۰/۸۶۱	۰/۸۵۹	۰/۸۷۶	۰/۸۶۷	۰/۹۲۰	۰/۸۲۲	۰/۸۸۲	۰/۹۰۷

جداول ۴ و ۵ میانگین خطای مطلق (MAE) و میانگین مربعات خطای نرمال شده (NMSE) در خاک رویین و زیرین را نشان می‌دهند. با توجه به این جداول، MAE و NMSE، همان روند ضریب همبستگی را نشان می‌دهند، به طوری که کمترین NMSE و MAE با بیش‌ترین ضریب همبستگی به دست آمده است.

این نتایج نشان می‌دهد که از بین همه‌ی مدل‌ها، مدل ۵ (با متغیرهای میزان شن، سیلت و رس، چگالی ظاهری و میزان آهک) دارای بیش‌ترین ضریب همبستگی می‌باشد و مدل‌های ۴، ۲ و ۳ در رتبه‌ی بعدی قرار دارند؛ در حالی که مدل ۱ (با متغیرهای میزان شن، سیلت و رس) کم‌ترین ضریب همبستگی را دارا می‌باشد.

جدول ۴- ضرایب خطا MAE و NMSE بین مقادیر رطوبتی اندازه‌گیری و برآورد شده به وسیله‌ی شبکه‌ی عصبی در خاک رویین

مدل	MAE					NMSE				
	$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$
مدل ۱	۰/۰۴	۰/۰۳۱	۰/۰۴۳	۰/۰۴۲	۰/۰۴۲	۰/۱	۰/۰۹۶	۰/۱۱۲	۰/۱۱۲	۰/۱۰۴
مدل ۲	۰/۰۳۲	۰/۰۲۴	۰/۰۳۵	۰/۰۳۵	۰/۰۳۴	۰/۰۸۶	۰/۰۷۶	۰/۰۸۸	۰/۰۹۰	۰/۰۹۲
مدل ۳	۰/۰۳۵	۰/۰۲۶	۰/۰۴	۰/۰۳۸	۰/۰۳۷	۰/۰۹۲	۰/۰۷۸	۰/۱۰۳	۰/۱۰۱	۰/۰۹۶
مدل ۴	۰/۰۲۶	۰/۰۱۹	۰/۰۳۱	۰/۰۳	۰/۰۲۸	۰/۰۷۹	۰/۰۶۶	۰/۰۹	۰/۰۹۲	۰/۰۸۱
مدل ۵	۰/۰۱۲	۰/۰۱۲	۰/۰۱۵	۰/۰۱۴	۰/۰۱۵	۰/۰۵۹	۰/۰۵۴	۰/۰۶۷	۰/۰۷	۰/۰۶۳

جدول ۵- ضرایب خطا MAE و NMSE بین مقادیر رطوبتی اندازه‌گیری برآورد شده به وسیله‌ی شبکه‌ی عصبی در خاک زیرین

NMSE					MAE					مدل
$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	
۰/۱۰۷	۰/۰۹۴	۰/۱۱۵	۰/۱۰۵	۰/۱۰۱	۰/۰۴۳	۰/۰۳۵	۰/۰۴۸	۰/۰۴۲	۰/۰۴	مدل ۱
۰/۰۹۳	۰/۰۸۴	۰/۰۹۹	۰/۰۹۳	۰/۰۹	۰/۰۳۷	۰/۰۳۱	۰/۰۳۹	۰/۰۳۴	۰/۰۳۲	مدل ۲
۰/۱۰۳	۰/۰۸۸	۰/۰۱۱	۰/۰۹۶	۰/۰۹۳	۰/۰۳۹	۰/۰۳۲	۰/۰۴۴	۰/۰۳۷	۰/۰۳۵	مدل ۳
۰/۰۹۱	۰/۰۷۵	۰/۰۹۱	۰/۰۸۲	۰/۰۸۳	۰/۰۳۲	۰/۰۲۴	۰/۰۳۴	۰/۰۲۹	۰/۰۲۹	مدل ۴
۰/۰۷	۰/۰۶۳	۰/۰۷۶	۰/۰۶۸	۰/۰۶۵	۰/۰۲۳	۰/۰۱۹	۰/۰۲۶	۰/۰۲۲	۰/۰۲	مدل ۵

خاک رویین و خاک زیرین در جداول ۶ و ۷ ارائه شده‌است. با مقایسه‌ی این جدول‌ها ملاحظه می‌شود که بهینه‌سازی شبکه‌ی عصبی با الگوریتم ژنتیک، موجب افزایش دقت مدل‌ها و کاهش خطا شده‌است.

مدل‌سازی نقطه‌ای ضرایب رطوبتی خاک به وسیله‌ی شبکه‌ی عصبی مصنوعی بهینه‌سازی شده با الگوریتم ژنتیک نتایج آماری اجرای شبکه‌های عصبی و شبکه‌ی عصبی بهینه‌سازی شده برای دو مدل برگزیده جهت برآورد ضرایب رطوبتی در

جدول ۶- مقایسه‌ی ضریب همبستگی (R) بین مقادیر رطوبتی اندازه‌گیری و برآورد شده به وسیله‌ی شبکه‌ی عصبی با مقادیر بهینه‌سازی شده با الگوریتم ژنتیک در خاک رویین و زیرین

R خاک زیرین					R خاک رویین					مدل
$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	
۰/۷۶۷	۰/۸۴۱	۰/۷۴۱	۰/۷۹۵	۰/۷۹۴	۰/۸۰۷	۰/۸۸۹	۰/۷۷۲	۰/۷۸۱	۰/۷۹	مدل ۴
۰/۸۸۶	۰/۹۰۲	۰/۷۹۵	۰/۸۵۳	۰/۸۵۲	۰/۸۹	۰/۹۶۳	۰/۸۳۶	۰/۸۴۷	۰/۸۵۶	
۰/۸۶۷	۰/۹۲	۰/۸۲۲	۰/۸۸۲	۰/۹۰۷	۰/۸۸۴	۰/۹۴۳	۰/۸۶۱	۰/۸۵۹	۰/۸۷۶	مدل ۵
۰/۹۷۳	۰/۹۸۶	۰/۸۸۱	۰/۹۴۵	۰/۹۷۳	۰/۹۶۴	۰/۹۸۵	۰/۹۴۷	۰/۹۴۴	۰/۹۶۴	

جدول ۷- مقایسه‌ی ضرایب خطا MAE و NMSE بین مقادیر رطوبتی اندازه‌گیری و برآورد شده به وسیله‌ی شبکه‌ی عصبی با مقادیر بهینه‌سازی شده با الگوریتم ژنتیک در خاک رویین

NMSE					MAE					مدل
$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	
۰/۰۸	۰/۰۶۶	۰/۰۹	۰/۰۹۲	۰/۰۸۱	۰/۰۲۶	۰/۰۱۹	۰/۰۳۱	۰/۰۳	۰/۰۲۸	مدل ۴
۰/۰۷	۰/۰۶	۰/۰۸۱	۰/۰۸۴	۰/۰۷۳	۰/۰۲۴	۰/۰۱۷	۰/۰۲۸	۰/۰۲۶	۰/۰۲۶	
۰/۰۵۹	۰/۰۵۴	۰/۰۶۷	۰/۰۶۳	۰/۰۷	۰/۰۱۲	۰/۰۱۹	۰/۰۱۵	۰/۰۱۵	۰/۰۱۴	مدل ۵
۰/۰۱۹	۰/۰۱۵	۰/۰۲	۰/۰۱۹	۰/۰۲	۰/۰۰۷	۰/۰۱	۰/۰۰۸	۰/۰۰۸	۰/۰۰۸	



جدول ۸- مقایسه‌ی ضرایب خطا MAE و NMSE بین مقادیر رطوبتی اندازه‌گیری و برآورد شده به وسیله‌ی شبکه‌ی عصبی با مقادیر بهینه‌سازی شده با الگوریتم ژنتیک در خاک زیرین

NMSE					MAE					مدل	
$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$	$\theta_{1500}$	$\theta_{500}$	$\theta_{100}$	$\theta_{33}$	$\theta_{10}$		
۰/۰۹۱	۰/۰۷۵	۰/۰۹۱	۰/۰۸۲	۰/۰۸۳	۰/۰۳۲	۰/۰۲۴	۰/۰۳۴	۰/۰۲۹	۰/۰۲۹	MLP MLP+GA	مدل ۴
۰/۰۷۳	۰/۰۰۷	۰/۰۸۴	۰/۰۷۶	۰/۰۷۷	۰/۰۲۵	۰/۰۲۳	۰/۰۳۱	۰/۰۲۶	۰/۰۲۶		
۰/۰۰۷	۰/۰۶۳	۰/۰۷۶	۰/۰۶۸	۰/۰۶۵	۰/۰۲۳	۰/۰۱۹	۰/۰۲۶	۰/۰۲۲	۰/۰۰۲	MLP MLP+GA	مدل ۵
۰/۰۰۶	۰/۰۵۸	۰/۰۰۷	۰/۰۶۳	۰/۰۰۶	۰/۰۱۸	۰/۰۱۷	۰/۰۲۴	۰/۰۰۲	۰/۰۱۸		

بوده‌اند (Faghhi, 2010., Kianpoor Kalkhajeh et al., 2012., Schaap et al, 1998., Shirani and Rafienejad, 2012., Zhu and Julian, 2011).

با توجه به یافته‌های این پژوهش می‌توان نتیجه گرفت که الگوریتم ژنتیک روش مناسبی برای بهینه‌سازی شبکه‌ی عصبی برای برآورد ضرایب رطوبتی خاک می‌باشد و در این خصوص از توانایی بالایی برخوردار است. محققان زیادی مانند پاراشورامان و همکاران (۲۰۰۷)، مجدلانی و همکاران (۲۰۰۷)، پرورش‌ریزی و همکاران (۲۰۰۶)، فقیه (۲۰۱۰)، جوهری و همکاران (۲۰۱۱) و پدروزو و ویلیامز (۲۰۱۱) جهت بهینه‌سازی پارامترهای مدل‌های خود از الگوریتم ژنتیک استفاده کرده‌اند. نتایج تحقیقات آن‌ها نیز نشان‌دهنده‌ی کارایی الگوریتم ژنتیک جهت بهینه‌سازی پارامترها یا شرایط اجرای مدل‌ها بوده‌است.

#### نتیجه‌گیری

در این پژوهش سعی بر این بود که کارایی شبکه‌ی عصبی مصنوعی و شبکه‌ی عصبی مصنوعی بهینه‌سازی شده به وسیله‌ی الگوریتم ژنتیک در برآورد نقطه‌ای منحنی مشخصه‌ی رطوبتی خاک بررسی شود. این پژوهش نیز مانند بسیاری از کارهای پژوهشگران دیگر موفقیت شبکه‌ی عصبی مصنوعی را در حل مسائل مختلف به اثبات می‌رساند. همچنین نتایج، برتری شبکه‌ی عصبی مصنوعی بهینه‌سازی شده به وسیله‌ی الگوریتم ژنتیک بر شبکه‌ی عصبی مصنوعی بدون بهینه‌سازی در برآورد نقطه‌ای منحنی مشخصه‌ی رطوبتی خاک را نشان می‌دهد. نتایج نشان داد که در همه‌ی مدل‌ها وارد شدن چگالی ظاهری و درصد آهک به افزایش کارایی مدل‌ها منجر گردیده است که نشان‌دهنده‌ی تأثیر زیاد این ویژگی‌ها بر خواص هیدرولیکی خاک می‌باشد، در حالی که اعمال بعضی از اطلاعات (درصد کربن آلی) کارایی مدل‌ها را کاهش داده است.

#### بحث

نتایج این پژوهش نشان می‌دهد که در همه‌ی مدل‌ها وارد شدن چگالی ظاهری به افزایش ضریب همبستگی منجر گردیده‌است. پژوهشگران بسیاری همانند ژانگ و همکاران (۲۰۰۶) و کشاورزی و همکاران (۲۰۱۱) اثر معنی‌دار چگالی ظاهری بر میزان نگهداشت آب توسط خاک در نقاط مختلف رطوبتی را تأیید کرده‌اند. چاکرابورتی و همکاران (۲۰۱۱) نیز نشان دادند که اعمال چگالی ظاهری باعث افزایش دقت مدل‌های ایجاد شده توسط آنان گردیده‌است. اعمال درصد آهک نیز دقت مدل‌ها را افزایش داده‌است. بررسی‌ها نیز نشان می‌دهد که مقدار آهک مهم‌ترین پارامتر مستقل در توابع انتقالی خاک‌های آهکی می‌باشد (Keshavarzi, Sarmadian, Lab-bafi and Ahmadi, 2011., Matlabi, Homae, Zarei, and Mahmoudi, 2010). در تمام موارد درصد کربن آلی باعث کاهش ضریب همبستگی شده‌است. چاکرابورتی و همکاران (۲۰۱۱) همبستگی معنی‌داری بین میزان مواد آلی و میزان رطوبت خاک در نقاط مختلف رطوبتی پیدا نکردند. این در حالی است که دانشمندان زیادی همچون واتارا و همکاران (۲۰۰۶) و کشاورزی و همکاران (۲۰۱۱) اثر معنی‌دار مواد آلی بر میزان رطوبت خاک در نقاط مختلف رطوبتی را گزارش کردند. کاهش ضریب همبستگی در این بررسی را می‌توان به دامنه‌ی کم تغییرات میزان مواد آلی در خاک‌های مورد مطالعه نسبت داد (Chakraborty et al, 2011). ملاحظه می‌شود که افزایش بعضی از اطلاعات ورودی عملکرد شبکه‌ها را افزایش داده‌است که با یافته‌های اسچاپ و همکاران (۱۹۹۸) همخوانی دارد؛ در صورتی که وارد شدن اطلاعات دیگری باعث کاهش دقت مدل‌ها گردیده‌است؛ بورگسن و همکاران (۲۰۰۸) این مسئله را تأیید می‌کنند. نتایج این تحقیق نشان‌دهنده‌ی توانایی بالای شبکه‌ی عصبی مصنوعی برای تدوین مدل‌های برآورد نقطه‌ای منحنی مشخصه‌ی رطوبتی در منطقه‌ی مورد مطالعه می‌باشد. بیش‌تر مطالعات مربوط به استفاده از شبکه‌های عصبی نیز با نتایج خوبی همراه

using a genetic algorithm-based neural network. *Computer and Geotecnic*. Vol, 38. pp: 2-13.

9. Keshavarzi, A., Sarmadian, F., Labbafi, R., and Ahmadi, A. (2011). Developing Pedotransfer Functions for Estimating Field Capacity and Permanent Wilting Point Using Fuzzy Table Look-up Scheme. *Computer and Information Science*. Vol, 4. pp: 130-141.

10. Kianpoor Kalkhajeh, Y., Rezaie Arshad, R., Amerikhah, H., and Sami, M. (2012). Multiple Linear Regression, Artificial Neural Network (Mlp, Rbf) and ANFIS Models for Modeling the Saturated Hydraulic Conductivity of Tropical Region Soils (A case study: Khuzestan Province: Southwest Iran). *International Journal of Agriculture. Research and Review*. Vol, 2. pp: 255-265.

11. Majdalani, S., Angulo-Jaramillo, R., and Di Pietro, L. (2008). Estimating preferential water flow parameters using a binary genetic algorithm inverse method. *Environmental Modeling & Software*. Vol, 23. pp: 950-956.

12. Matlabi, A., Homae, M., Zarei, Gh., and Mahmoudi, Sh. (2010). Studying effect of Lime on hydraulic properties using pedotransfer functions in Garmsar. *Irrigation and Drainage*. Vol, 3. pp: 426-439.

13. Matthews, J. (2000). Using Genetic Algorithm with Neural Networks. *Generation 5*, May 2000.

14. Menhaj, M. B. (2002). *Fundamentals of Neural Networks*. Amirkabir University Press. pp. 715.

15. Mermoud, A., and Xu, D. (2006). Comparative analysis of three methods to generate soil hydraulic functions. *Soil and Tillage Research*. Vol, 87. pp: 89-100.

16. Michalewicz, Z. (1996). *Genetic Algorithms+Data Structure =evolutionary Program*. Third edition. Springer-Verlag. Berlin.

17. Montana. D. J. (2001). *Training Feed Forward Neural Network using Genetic Algorithm*. Cambridge. Ma. 02138.

18. Musy, A., and Soutter, M. (1991). *Physique du sol*. In: *Collection gerer lenvironnement*. Presses Polytechniques et Universitaires Romandes. Lausanne. p. 335.

19. Naseri, A. A., Jafari, S., and Alimohammadi, M. (2007). Soil compaction due to sugarcane (*Saccharum officinarum*) mechanical harvesting and the effects of sub soiling on the improvement of soil physical properties. *Applied Scientific Information*, ISSN

## پاورقی‌ها

1. Crossover
2. Mutation
3. fuzzy table look-up scheme
4. Nearest Neighbor
5. preferential water flow
6. Multilayer Perceptron
7. Sensitivity about mean
8. Coefficient of Correlation
9. Mean Absolute Error
10. Normalized Mean Square of Error

## منابع

1. Borgesen, C. D., Iversen, B. V., Jacobsen, O. H., and Schaap, M. G. (2008). Pedotransfer functions estimating soil hydraulic properties using different soil parameters. *Hydrological Processes*. Vol, 22. pp: 1630-1639.
2. Chakraborty, D., Mazundar, S. P., Garg, R. N., Banerjee, S., Santra, P., Singh, R., and Tomar, R. K. (2011). Pedotransfer functions for predicting points on the moisture retention curve of Indian soils. *Indian Journal of Agricultural Sciences*. Vol, 81. pp: 1030-1036.
3. Deb, K. 2009. Genetic algorithm approach to multi-objective optimization issue. *Translator: Rezaei, J. Vali-Asr University. Rafsanjan*. pp. 624.
4. Dilkova, R., Jokova, M., Kerchev, G., and Kercheva, M. (1998). Aggregate stability as a soil quality criterion. *Soil science, agrochemistry and ecology*. pp: 305-312.
5. Faghih, H. 2010. Assess the application of artificial neural networks and optimization it with the genetic algorithm approach to estimate the monthly precipitation (The Case of study: the Kurdistan region). *Science and Technology of Agriculture and Natural Resources. Soil and Water Science*. Vol, 51. pp: 27-42.
6. Fauconnier, R. 2004. Sugarcane cultivation and production principles. *Translators: Hamid Madani and Ghoaban Noormohammadi. Islamic Azad University. Arak*. pp. 150.
7. Ghorbani Dashtaki, S., Homae, M., and Khodaverdilo, H. (2010). Derivation and validation of pedotransfer functions for estimating soil water retention curve using a variety of soil data. *Soil Use and Management*. Vol, 26. pp: 68-74.
8. Johari, A., Javadi, A. A., and habibagahi, G. (2011). modeling the mechanical behavior of unsaturated soils

- Sciences. Vol, 3. pp: 323-329.
- 27.SAS Institute Inc. (1999). SAS/STAT User's Guide. Ver. 8.0. SAS Institute Inc., Cary, NC.
- 28.Schaap, M. G., Leij, F. J., and Van Genuchten, M. Th. (1998). Neural network analysis for hierachical prediction of soil water retention saturated hydraulic conductivity. Soil Science Society of American Journal. Vol, 62. pp: 847-855.
- 29.Schulze, R. (2000). Transcending scales of space and time in impact studies of climate and climate change on agro-hydrological responses. Agric. Ecosyst. Environ. Vol, 82. pp: 185-212.
- 30.Shirani, H. and Rafienjad, N. (2012). Prediction of Some Difficult-to-measure Soil Characteristics Using Regression Pedotransfer Functions and Artificial Neural Network in Kerman Province. Iranian Journal of Soil Research (Soil and Water Science). Vol. 25, No. 4.
- 31.Torabi Farsani, N., and Ghahramani, B. (2007). Comparing some conventional transfer functions for estimating soil water retention curve in some soil in Iran. Irrigation and Drainage of Iran. Vol, 1. pp: 45- 55.
- 32.Wosten, J. H. M., Pachepsky, Y. A., and Rawls, W. J. (2001). Pedotransfer functions bridging the gap between available basic soil data and missing soil hydraulic characteristics. Hydrology. Vol, 251. pp: 123-150.
- 33.Zhang, S., Grip, H., and Lovdahl, L. (2006). Effect of soil compaction on hydraulic properties of two loess soils in China. Soil and Tillage Research. Vol, 90. pp: 117-125.
- 34.Zhu, A. X., and Julian, J. (2011). Unsaturated Hydraulic Properties of Anisotropic Soils. State Water Resources Research Institute Program. 1812-5654.
- 20.Otto, R., Silva, A. P., Franco, H. C. J., Oliveira, E. C. A. and Trivelin, P. C. O. (2011). High soil penetration resistance reduces sugarcane root system development. Soil and Tillage Research. Vol, 117. pp: 201-210.
- 21.Ouattara, K., Ouattara, B., Assa, A., and Sedogo, P. M. (2006). Long-term effect of ploughing and organic matter input on soil moisture characteristics of a Ferric Lixisol in Burkina Faso. Soil and Tillage Research. Vol, 88. pp: 217-224.
- 22.Parasuraman, K., Elshorbagy, A., and Cheng Si, B. (2007). Estimating Saturated Hydraulic Conductivity Using Genetic Programming. Soil Science Society of American Journal. Vol, 71. pp: 1676-1684.
- 23.Parvareshrizi, A., Koochakzade, S., and Omid, M. H. (2006). Estimating moving hydraulic jump profile using artificial neural networks and integrated neural networks - genetic algorithm. Agricultural Sciences. Vol, 37. pp: 187- 196.
- 24.Patil, N. G., Pal, D. K., Mandal, C., and Mandal, D. K. (2012). Soil Water Retention Characteristics of Vertisols and Pedotransfer Functions Based on Nearest Neighbor and Neural Networks Approaches to Estimate available water capacity. Irrigation and Drainage Engineering. Vol, 138. pp: 138-177.
- 25.Pedroso, D. M., and Williams, D. J. (2011). Automatic calibration of soil- water characteristic curve using genetic algorithms. Computers and Geotechnics. Vol, 38. pp: 330-340.
- 26.Sarmadian, F., Taghizadeh Mehrjui, R. A., and Akbarzadeh, A. (2009). Optimization of Pedotransfer Functions Using an Artificial Neural Network. Australian Journal of Basic and Applied

