

حفاظت از محیط زیست، جنگل ها و منابع طبیعی و فراهم کردن فضایی سالم و با طراوت برای زندگی از اساسی ترین وظایف است که مسئولان باید آن را در اولویت کاری خود قرار دهند.  
مقام معظم رهبری (مدظله العالی)

کد احراز اصالت گواهینامه: HN10102090076

تاریخ: ۹۴/۰۳/۲۱



## سومین همایش ملی گیاهان دارویی و کشاورزی پایدار

The third National Conference of Medical Herbs and Stable Agriculture  
Thursday, June 11, 2015

Certificate of Presentation

گواهی نامه پذیرش، ارائه مقاله و حضور در همایش

نخبة فریخته، دانشمند گرانمایه  
سرکار خانم اجتاب آقای

بهزاد باقری شیروان، روزبه شاد، مرجان قائمی

دیپلومایه پاس تلاش های پژوهشی شاد ارائه مقاله ارزشمندتان با عنوان:

ارزیابی روش های آموزش شبکه عصبی MLP به منظور پیش بینی رطوبت خاک به کمک خصوصیات زود یافت خاک

در سومین همایش ملی گیاهان دارویی و کشاورزی پایدار که در همان برگزار گردید، به رسم تعظیم و تکریم این لوح تقدیر تقدیم شامی گردد، از یگانگی یکتادایت و بصیرت بحکام و همراه با ایفاد نقش ممتاز جهت فردایی بهتر و افق روشن تر، آرزومند است، امید است، با تدبیر، تعجب، تعمق و تفحص، افق روشنی در تحقق چشم انداز آینده ی ایران اسلامی پدیدار نماید. هم چنان پذیرای اندیشه های ناب و خلاقانه ی شما، هستیم.

ISBN 978-600-6720-91-3



9 786006 720913

دسیر اجرایی همایش  
مهندس الهام رحبهر خرابانی

دسیر علمی همایش  
دکتر رمضان طوبدی

رئیس همایش  
مهندس سجاد آستانی





## ارزیابی روش‌های آموزش شبکه عصبی MLP به منظور پیش‌بینی رطوبت خاک

### به کمک خصوصیات زودیافت خاک

بهزاد باقری شیروان<sup>۱\*</sup>، روزبه شاد<sup>۲</sup>، مرجان قائمی<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد مهندسی عمران- GIS دانشگاه فردوسی مشهد. پست الکترونیکی: behzad.bagheri.bb@gmail.com

<sup>۲</sup> استادیار گروه عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد. پست الکترونیکی: rouzbeh\_shad@yahoo.com

<sup>۳</sup> استادیار گروه عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد. پست الکترونیکی: mghaemi270@yahoo.com

#### چکیده

با وجود پیشرفت‌های تکنیکی و بهبود ابزار آلات مورد استفاده در اندازه‌گیری مستقیم خصوصیات خاک، فرآیند مذکور همچنان زمان‌بر بوده و همراه با خطا می‌باشد. لذا در این مقاله کارایی شبکه عصبی مصنوعی به عنوان یک روش غیرمستقیم، برای پیش‌بینی رطوبت قابل دسترس خاک با استفاده از خصوصیات زودیافت مورد بررسی قرار گرفت. بدین منظور، ابتدا قطعه زمینی تحت کشت چغندر قند به مساحت ۱۶ هکتار در محدوده مطالعاتی شیروان، استان خراسان شمالی انتخاب شد. سپس خصوصیات رطوبت قابل دسترس (AWC)، کربن آلی (SOC)، توزیع اندازه ذرات خاک، وزن مخصوص ظاهری (BD)، اسیدیته (pH) و هدایت الکتریکی (EC) با استفاده از روش‌های استاندارد، در ۱۰۰ نمونه مشاهداتی به صورت یک شبکه منظم ۴۰ × ۴۰ متر اندازه‌گیری شدند. در ادامه، تست‌های آماری سری داده‌ها از نظر نرمال بودن بررسی شده و همبستگی بین متغیرها محاسبه گردید. سپس شبکه عصبی با اجرای سه الگوریتم Levenberg-Marquardt، Bayesian Regularization و Scaled Conjugate Gradient آموزش داده شد. در مرحله بعد، پارامترهای آماری میانگین مربعات خطا (MSE)، ضریب همبستگی در سطح ۵ درصد (r) و مقدار bias برای اعتبارسنجی هر الگوریتم محاسبه گردید. نتایج حاصل از این پژوهش نشان دادند که الگوریتم Bayesian Regularization با خطای (MSE = ۶/۳۰۲۷E-۵)، ضریب همبستگی (\*r = ۰/۹۱۴۷) و bias = ۰/۰۰۱۳ بهترین عملکرد را در بین الگوریتم‌های آموزش شبکه عصبی پرسپترون چند لایه (MLP) دارد. بنابراین می‌توان نتیجه گرفت که روش‌های شبکه عصبی مصنوعی برای تخمین و پیش‌بینی پدیده‌ها با ماهیت غیرخطی و مبهم مانند رطوبت خاک از کارایی بالایی برخوردار می‌باشند.

**کلمات کلیدی:** رطوبت قابل دسترس خاک، خصوصیات زودیافت، شبکه عصبی مصنوعی، الگوریتم آموزش، ضریب همبستگی



امروزه از توابع انتقالی به عنوان راهی آسان و با صرفه برای برآورد خصوصیات با اندازه‌گیری دشوار و پرهزینه (خصوصیات دیر یافت خاک) از قبیل هدایت هیدرولیکی، ظرفیت تبادل کاتیونی و رطوبت قابل دسترس خاک، از خصوصیات سهل‌الوصول مانند فراوانی نسبی ذرات معدنی، وزن مخصوص ظاهری، هدایت الکتریکی و اسیدیته خاک (خصوصیات زود یافت خاک)، به طور رایج استفاده می‌شود (بوما و ون لانن، ۱۹۷۸). توابع انتقالی بر اساس یکی از مدل‌های طبقه‌بندی سیستماتیک در سه گروه زیر قرار می‌گیرند (کورنلیس و همکاران، ۲۰۰۱). (الف) پیش‌بینی پارامترهای هیدرولیکی بر اساس مدل‌های مفهومی فیزیکی (آریا و پاریس، ۱۹۸۱). (ب) پیش‌بینی پارامترهای هیدرولیکی بر اساس معادلات ریاضی بروکس و کوری (۱۹۶۴) و ون گنختون (۱۹۸۰) به وسیله رگرسیون‌های چند متغیره خطی (وستن و همکاران، ۱۹۹۸) و شبکه‌های عصبی (پاچسکی و همکاران، ۱۹۹۶). (پ) تخمین محتوای رطوبت از مقادیر مشخص مکش به وسیله رگرسیون‌های چند متغیره خطی (گوپتا و لارسن، ۱۹۷۹؛ راول و براکنسیک، ۱۹۸۲) و شبکه‌های عصبی (پاچسکی و همکاران، ۱۹۹۶).

به طور کلی دو روش رایج رگرسیون و شبکه‌های عصبی مصنوعی برای توسعه روش‌های پیش‌بینی مورد استفاده قرار می‌گیرند. در بسیاری از موارد، روابط ورودی-خروجی بین خصوصیات خاک به دلیل پیچیدگی و غیرخطی بودن توسط مدل‌های رگرسیونی، مطابق با واقعیت به خوبی شبیه‌سازی نمی‌شوند. بنابراین در نظر گرفتن اثرات متقابل بین ویژگی‌های مختلف خاک در این مدل‌ها به دلیل عدم درک فیزیکی وضعیت خاک در دنیای واقعی و ساده‌سازی روابط بین خصوصیات مختلف، بسیار دشوار می‌باشد. در نتیجه، بسیاری از مدل‌های ریاضی، موفق به شبیه‌سازی رفتار پیچیده‌ترین مشکلات مهندسی خاک نمی‌شوند. در این میان شبکه عصبی مصنوعی (ANN) برای استخراج الگو و شناسایی روند، جهت آگاهی و درک روابط غیرخطی بین خصوصیات مختلف در سیستم‌های پیچیده و غیردقیق کاربرد زیادی دارد (هابکین، ۱۹۹۹). شبکه‌های عصبی مصنوعی به طور گسترده‌ای برای پیش‌بینی خصوصیات هیدرولیکی خاک (مینانسی و همکاران، ۲۰۰۴)، نقشه‌های دیجیتالی خاک (بهرن و همکاران، ۲۰۰۵) و مدل‌سازی رفتار عناصر کمیاب (آناگو و همکاران، ۲۰۰۹؛ گاندهیماتی و مینامبال، ۲۰۱۲) مورد استفاده قرار گرفته است.

طبری و همکاران (۲۰۱۱) برای تخمین دمای روزانه خاک در شش عمق ۵، ۱۰، ۲۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متری از مدل‌های شبکه عصبی پرسپترون چند لایه ((Multi Layer Perceptron (MLP)) و روش رگرسیون خطی چند متغیره (در یک منطقه خشک از کشور ایران) استفاده نمودند. نتایج آن‌ها نشان داد که مدل شبکه عصبی مصنوعی در مقایسه با روش‌های رگرسیون در پیش‌بینی دمای روزانه خاک در عمق‌های مختلف کارایی بالاتری داشته است. بیلگیلی (۲۰۱۰) دمای ماهانه خاک را

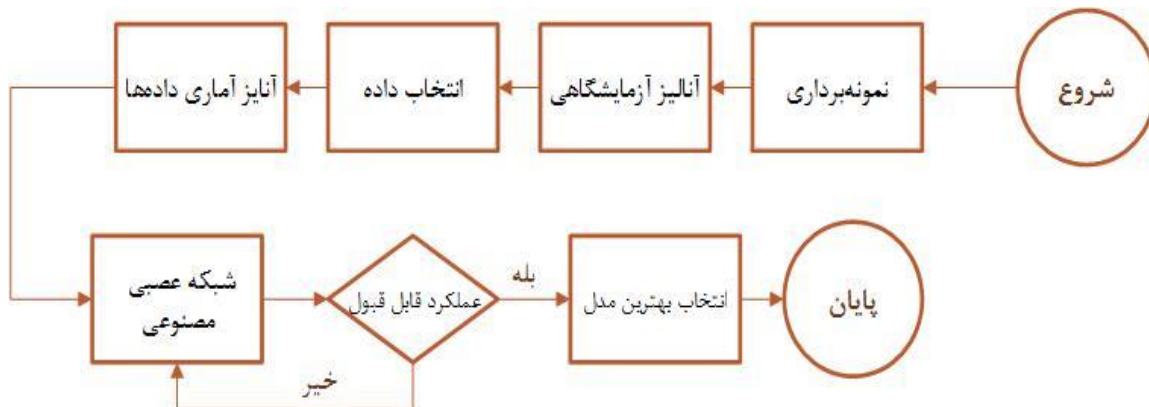


با استفاده از رگرسیون‌های خطی و غیرخطی و روش‌های شبکه عصبی مصنوعی در شهر آدانا ترکیه مدل‌سازی کرد. نتایج مبین آن بود که روش شبکه عصبی عملکرد بهتری نسبت به روش‌های رگرسیونی ارائه نموده است. در مطالعه‌ای دیگر بیلگیلی و همکاران (۲۰۱۳) دماهای خاک یک ایستگاه هدف را با استفاده از دماهای خاک ایستگاه‌های همسایه در ترکیه تخمین زدند و بر این اساس یک مدل شبکه عصبی مصنوعی را برای تخمین دمای خاک ایستگاه هدف پیشنهاد نمودند. نتایج حاصل از اعتبارسنجی نشان داد که مدل شبکه عصبی گسترش یافته، پیش‌بینی واقعی‌تری را برای تخمین دمای خاک ارائه می‌کند. اصغری مقدم و همکاران (۲۰۱۰) برای پیش‌بینی مکانی غلظت فلوراید از دو روش شبکه عصبی مصنوعی و زمین‌آمار در دشت‌های بازرگان و پلدشت در شمال غرب ایران استفاده کردند. نتایج بیانگر دقت بهتر برآوردهای شبکه عصبی مصنوعی در مقایسه با تخمین‌های زمین‌آمار کریجینگ و کوکریجینگ بود. با توجه به مطالب گفته شده در مورد قابلیت‌های شبکه عصبی مصنوعی و اندازه‌گیری سخت و پرهزینه رطوبت قابل دسترس خاک و اهمیت این پارامتر در مدیریت آب و پایش خشکسالی کشاورزی، این پژوهش با هدف بررسی عملکرد شبکه عصبی در پیش‌بینی رطوبت قابل دسترس با استفاده از پارامترهای زودیاقت خاک و ارائه یک الگوریتم بهینه اجرا گردید.

## ۲- مواد و روش‌ها

در تحقیق پیش‌رو با توجه به فلوچارت ارائه شده، بعد از انجام عملیات میدانی، داده‌های مورد نیاز جمع‌آوری می‌گردند. سپس داده‌های لازم برای کاربرد رطوبت خاک انتخاب شده، نرمالیتی داده‌ها بررسی شده و در ادامه از آن‌ها در آموزش و تست شبکه عصبی مصنوعی استفاده می‌گردد. مهم‌ترین موضوع در مدل‌های شبکه عصبی، انتخاب ورودی‌های مناسب به مدل برای رسیدن به خروجی‌های مد نظر می‌باشد. در نتیجه ضمن انتخاب بهترین مدل در هر الگوریتم بهترین الگوریتم جهت پیش‌بینی رطوبت خاک نیز تعیین خواهد شد.






شکل (۱) فلوجارت کار

## ۱-۲ منطقه و داده‌های مورد مطالعه

داده‌های مورد استفاده در سال زراعی ۹۳-۱۳۹۲ در مزرعه‌ای، واقع در ۱۰ کیلومتری شمال شیروان با عرض جغرافیایی ۳۷ درجه و ۲۵ دقیقه شمالی و طول جغرافیایی ۵۹ درجه و ۴۹ دقیقه شرقی و ارتفاع ۱۰۴۵ متری از سطح دریا اجرا می‌گردد (شکل (۲)).



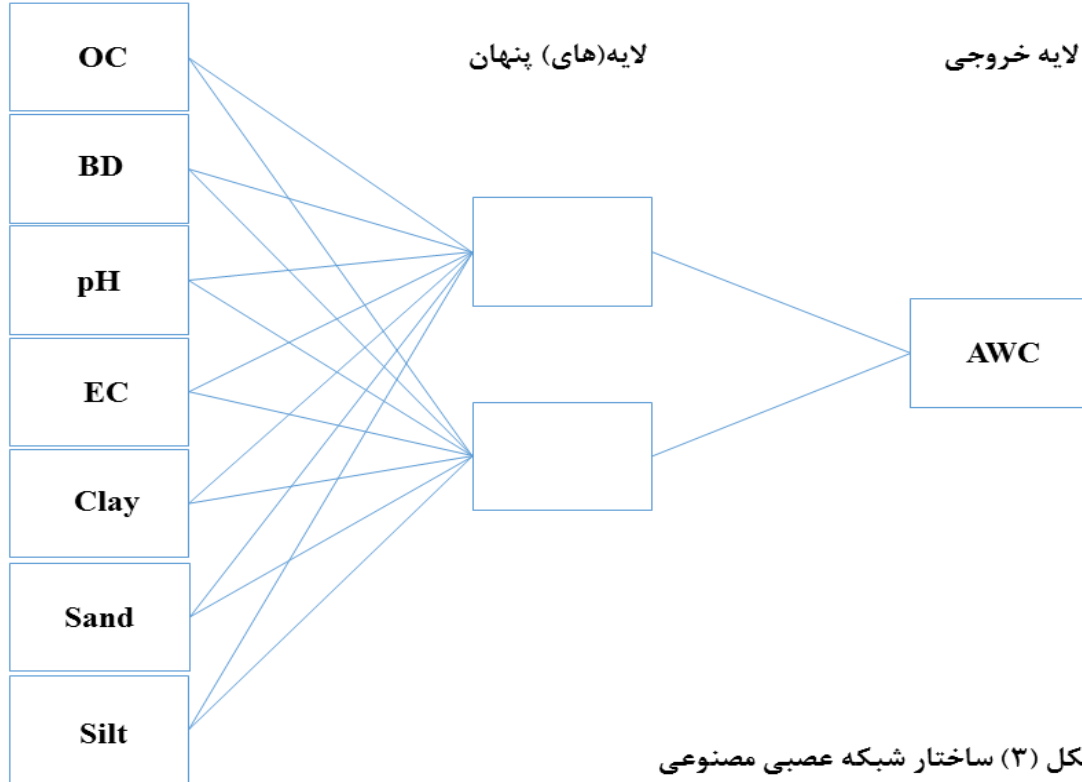
شکل (۲) موقعیت منطقه مورد مطالعه



عملیات نمونه برداری در محدوده مورد مطالعه مزرعه با مساحت ۱۶ هکتار انجام شده است. بر این اساس ۱۰۰ نمونه مرکب خاک به روش نمونه برداری سیستماتیک در یک شبکه منظم (۵ زیر نمونه درون شبکه‌های  $1600 \text{ m}^2$ ) از عمق سطحی ۳۰-۰ سانتی متر جمع آوری گردیدند (شکل (۲)). برای انجام تجزیه‌های آزمایشگاهی، ابتدا نمونه‌های خاک تهیه شده، هوا خشک گردیده و از الک ۲ میلی متری عبور داده شدند. سپس هفت ویژگی فیزیکی و شیمیایی موثر بر رطوبت خاک، بر اساس روش‌های استاندارد اندازه گیری شدند. بر این اساس ویژگی‌های شیمیایی شامل: الف- هدایت الکتریکی ( $EC_e$ ) نمونه‌ها (که پس از اشباع کردن خاک به مدت ۲۴ ساعت در عصاره گل اشباع، با استفاده از هدایت سنج الکتریکی تعیین گردید (مدل JENWAY 4310)) (ریچاردز، ۱۹۵۴) و ب- کربن آلی (که به روش والکلی و بلک (۱۹۳۴) قابل تعیین است) اندازه‌گیری شدند. سپس ویژگی‌های فیزیکی شامل: الف- فراوانی نسبی ذرات معدنی خاک (که به روش استاندارد هیدرومتری (جی و باودر، ۱۹۸۶) محاسبه می‌گردد)، ب- رطوبت قابل استفاده گیاه (که از تفاضل رطوبت در مکش‌های ۳۳ و ۱۵۰۰ کیلوپاسکال با استفاده از دستگاه صفحات فشاری (کلوت و دیرکسون، ۱۹۸۶) مشخص می‌شود) و ج- جرم مخصوص ظاهری (که به روش کلوخه و پوشش دادن با پارافین (Core method) (بلیک و هارتگ، ۱۹۸۶) قابل محاسبه می‌باشد) تعیین گردیدند.

## ۲-۲ شبکه عصبی مصنوعی

شبکه عصبی مصنوعی ابزاری محاسباتی می‌باشد که از طریق تعداد زیادی عنصر به هم پیوسته ساده به نام نورون با قابلیت‌های منحصر به فرد که تحت رابطه با ورودی‌ها و خروجی‌ها شناخته می‌شود. ساختار و بهره‌برداری از شبکه عصبی توسط تعدادی از نویسندگان مورد بحث قرار گرفته است (روگزر و دولا، ۱۹۹۴). شبکه عصبی مصنوعی به لایه‌های گسسته شامل ورودی، پنهان و خروجی مرتب شده است. مجموعه‌ای از سلول‌های عصبی به راحتی در یک آرایه چند بعدی به نام لایه مرتب شده‌اند. هر کدام از لایه‌ها شامل یک یا چند نود مخصوص یا عناصر پردازش می‌شود. تعداد متغیرهای ضروری ورودی برای پیش‌بینی متغیرهای خروجی مورد نظر تعداد نودهای ورودی را نشان می‌دهد. تعداد بهینه نودهای مخفی و لایه‌های مخفی به پیچیدگی مشکل مدل‌سازی و هدف محقق مانند خطای یادگیری قابل قبول بستگی دارد (گریمز، ۲۰۰۳) هر چه تعداد لایه‌های مخفی موجود در شبکه عصبی بیشتر باشد پیچیدگی مدل بزرگتر است. در طی آموزش شبکه عصبی مصنوعی با الگوهای ورودی و متناظر جفت نقطه خروجی آشنا می‌شود. الگوریتم یادگیری مقادیر وزن‌های اتصال‌ها را در ساختار شبکه عصبی مصنوعی تنظیم می‌کند. در کل برای رسیدن به دقت مناسب با یک ساختار شبکه عصبی مصنوعی ساده مطلوب‌تر است. همچنین این باعث کاهش زمان آموزش، بهبود فعال‌سازی شبکه و جلوگیری از اتصال بیشتر می‌شود (هاگن و همکاران، ۱۹۹۶).



شکل (۳) ساختار شبکه عصبی مصنوعی

## ۳-۲ توپولوژی آموزش

در این مطالعه توپولوژی فقط از یک لایه ورودی (با چند نورون)، یک لایه مخفی (با چند نورون) و نورون خروجی تشکیل شده است. نورون یک واحد مستقل می‌باشد که یک نقشه استاتیک بین ورودی و خروجی از طریق یک تابع فعال‌سازی که می‌تواند خطی یا غیرخطی باشد، انجام می‌دهد. هر نورون دو جزء دارد: (۱) مجموعه‌ای وزن‌دار شده  $s = \sum w_i x_i + b$  که جمع وزن‌دار از ورودی‌ها  $(x_1, x_2, \dots, x_n)$  می‌باشد در حالی که  $b$  عرض از مبدأ شبکه می‌باشد و (۲) خطی یا غیرخطی یا تابع انتقال منطقی که یک خروجی مربوط به  $s$  را می‌دهد. شبکه عصبی مصنوعی یک سیستم تطبیقی است که ساختار آن بر اساس اطلاعات خارجی و یا داخلی که در طول جریان فاز یادگیری از طریق شبکه تغییر می‌کند.

## ۳-۳ معیار ارزیابی



به منظور ارزیابی نتایج مدل شبکه عصبی مصنوعی از معیارهای میانگین مربعات خطا (MSE) و ضریب همبستگی (r) استفاده گردید. معادلات شاخص‌های مذکور به صورت زیر است.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad \text{رابطه (۱)}$$

$$corr(X, Y) = \frac{Cov(X, Y)}{\sigma_X \sigma_Y} \quad \text{رابطه (۲)}$$

### ۳- نتایج و بحث

در این پژوهش، به منظور مدل‌سازی رطوبت خاک از ۱۰۰ نمونه اندازه‌گیری شده شامل هشت پارامتر در مزرعه‌ای استفاده شد. مهم‌ترین موضوع در مدل‌های شبکه عصبی، انتخاب ورودی‌های مناسب به مدل برای رسیدن به خروجی مورد نظر می‌باشد (لیج و همکاران، ۲۰۰۲). با توجه به این موضوع ضرایب همبستگی بین خصوصیات مختلف خاک و رطوبت قابل دسترس مورد بررسی قرار گرفت و هفت پارامتر با همبستگی بالا به عنوان ورودی‌های منتخب به مدل شبکه عصبی جهت تخمین رطوبت خاک مورد استفاده قرار گرفتند (جدول ۲). ۸۰ درصد داده‌ها در فاز آموزش و مابقی داده‌ها برای صحت‌سنجی شبکه‌ها مورد استفاده قرار گرفت. ساختار شبکه‌های عصبی مصنوعی و چگونگی انتخاب ارتباط بین نرون‌ها و وزنی که هر نرون به خود اختصاص خواهد داد، نیز از اهمیت بالایی برخوردار است. بر این اساس در این پژوهش ابتدا ورودی‌های مدل استاندارد شده و سپس ساختار شبکه به برآورد رطوبت خاک تعیین گردید. برای تعیین تعداد گره‌های لایه مخفی از آزمون سعی و خطا استفاده شد که این روابط، محدوده مقادیر گره‌های لایه پنهان را بین  $2n^{1/2} + m$  و  $2n + 1$  تخمین می‌زنند (گانگ-مینگ، ۲۰۰۵). در این معادلات m تعداد گره‌های خروجی و n تعداد گره‌های ورودی می‌باشد.





خلاصه آماره‌های توصیفی خصوصیات خاک برای آموزش و آزمون مدل‌ها در جدول (۱) ارائه شده است. براساس طبقه‌بندی وایلدینگ (وایلدینگ، ۱۹۸۵) خصوصیات خاک با CV بیش از ۳۵٪ دارای تغییر پذیری زیاد می‌باشد. از این رو مقدار ضریب تغییرات نشان دهنده آن است که اغلب خصوصیات مورد مطالعه از تغییر پذیری خوبی برخوردار می‌باشد.

جدول (۱) آنالیز آماری داده‌ها

متغیرها	N	Mean	Std Dev	Std Err Mean	Variance	Skewness	Kurtosis	CV
Sand	۱۰۰	۳۵/۷	۲/۵۷۸۷	۰/۲۵۷۸	۶/۶۵۰۱	۰/۲۰۳۷	-۰/۴۶۱۸	۷/۲۲۳۴
Clay	۱۰۰	۱۵/۲۲	۵/۲۵۲۲	۰/۵۲۵۲	۲۷/۵۸۵۸	-۰/۳۱۲۲	-۱/۲۱۴۵	۳۴/۵۰۸۷
Silt	۱۰۰	۴۹/۰۸	۳/۸۷۰۸	۰/۳۸۷	۱۴/۹۸۳۴	۰/۲۶۶۵	-۰/۷۶۳۵	۷/۸۸۶۸
AWC	۱۰۰	۰/۱۵۸	۰/۰۲۰۴۹	۰/۰۰۲۰۴۹	۰/۰۰۰۴۲۰۱	۰/۳۹۹۲	-۱/۰۱۵۸	۱۲/۹۶۴۴
pH	۱۰۰	۷/۵۵۹۶	۰/۲۳۵۲	۰/۰۲۳۵۲	۰/۰۵۵۳۵	۰/۰۶۷۵	-۱/۴۳۲۲	۳/۱۱۲۱
EC	۱۰۰	۲/۲۸۱۶	۰/۹۵۸۵	۰/۰۹۵۸۵	۰/۹۱۸۷	۰/۲۸۶۹	-۱/۶۲۲۱	۴۲/۰۱۰۳۷
BD	۱۰۰	۱/۴۲۸۴	۰/۰۶۷۵۵	۰/۰۰۶۷۵۵	۰/۰۰۴۵۶۳	۰/۱۲۱۳	-۱/۴۰۵۵	۴/۷۲۹۱
OC	۱۰۰	۰/۸۷۳۲	۰/۲۹۹۷	۰/۰۲۹۹۷	۰/۰۸۹۸	۰/۲۶۸۶	-۰/۳۰۳۳	۳۴/۳۳۱۹

با توجه به نتایج به دست آمده در جدول (۲) پارامترهای خاک انتخاب شده بالاترین همبستگی را با رطوبت قابل دسترس خاک داشتند. کربن آلی با تأثیر بر ساختمان خاک موجب ایجاد خلل و فرج مناسب در خاک شده و در نتیجه به افزایش مقدار رطوبت خاک می‌گردد. هم‌چنین مقدار رس به علت افزایش خلل و فرج ریز در خاک موجب افزایش نگهداشت آب در خاک شده و میزان رطوبت قابل استفاده در خاک را به مقدار قابل ملاحظه‌ای افزایش می‌دهد (قائم‌ی و همکاران، ۲۰۱۴). این ضرایب همبستگی بالا بیانگر روند تغییرات مشابه بین خصوصیات مذکور است به طوری که نتایج اجرای راهکارهای مدیریتی می‌تواند بر وضعیت هر یک از این خصوصیات تأثیر مشابهی داشته باشد. (یائو و همکاران، ۲۰۱۳).

جدول (۲) همبستگی داده‌های مورد استفاده



OC	BD	EC	pH	Silt	Clay	Sand	
۰/۸۷۰۶*	-۰/۶۵۹۱*	-۰/۸۴۹*	-۰/۸۵۰۷*	-۰/۶۵۳۶*	۰/۶۸۰۶*	۰/۴۰۵۰*	AWC

### ۲-۳ اعتبارسنجی

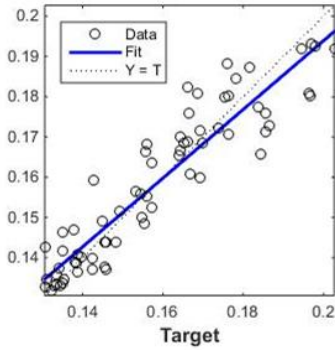
بر اساس آزمون سعی و خطا در مدل شبکه عصبی، دو لایه به عنوان لایه مخفی انتخاب شد. برای آموزش شبکه عصبی مصنوعی MLP از سه الگوریتم آموزش Levenberg-Marquardt، Bayesian Regularization و Scaled Conjugate Gradient استفاده گردید که روش Levenberg-Marquardt با کمترین مقدار خطا ( $MSE = ۴/۲۷۵۸E-۵$ ) و  $bias = ۰/۰۲۱$  و همچنین بالاترین همبستگی ( $r = ۰/۹۷۴۳^*$ ) به عنوان الگوریتم مناسب در داده‌های آموزشی گزینش شد (جدول ۳). در حقیقت اختلاف بین میزان پارامتر خروجی اندازه‌گیری شده با میزان پیش‌بینی را نشان می‌دهد که هر چه به صفر نزدیک‌تر باشد، کارایی مدل بالاتر است. در نهایت از روش آزمون و خطا برای تعیین معماری این شبکه استفاده شد. معماری بهینه انتخاب شده برای این شبکه دارای هفت نرون در لایه ورودی، دو نرون در لایه پنهان و یک نرون در لایه خروجی با تابع هدف خطی با تعداد ۱۰۰۰ تکرار بود. بر طبق نظر اسپاچ (۱۹۹۸) در طراحی شبکه‌های عصبی استفاده از یک نوع معادله مشخص چندان حائز اهمیت نبوده و با ایجاد یک رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مطلوب‌تری دست یافت.

جدول (۳) نتایج آموزش شبکه عصبی مصنوعی

Training			Algorithm
Bias	r	MSE	
۰/۰۲۱	۰/۹۷۴۳*	۴/۲۷۵۸E-۵	Levenberg-Marquardt
۰/۰۲۳	۰/۹۲۶۳*	۵/۶۹۷۱E-۵	Bayesian Regularization
۰/۰۲۲	۰/۹۳۱۱*	۵/۱۹۴۴E-۵	Scaled Conjugate Gradient




**Bayesian Regularization**




Output = 0.85Target + 0.023  
R = 0.93

**Levenberg-Marquardt**



Output = 0.86Target + 0.021  
R = 0.95

**Scaled Conjugate Gradient**



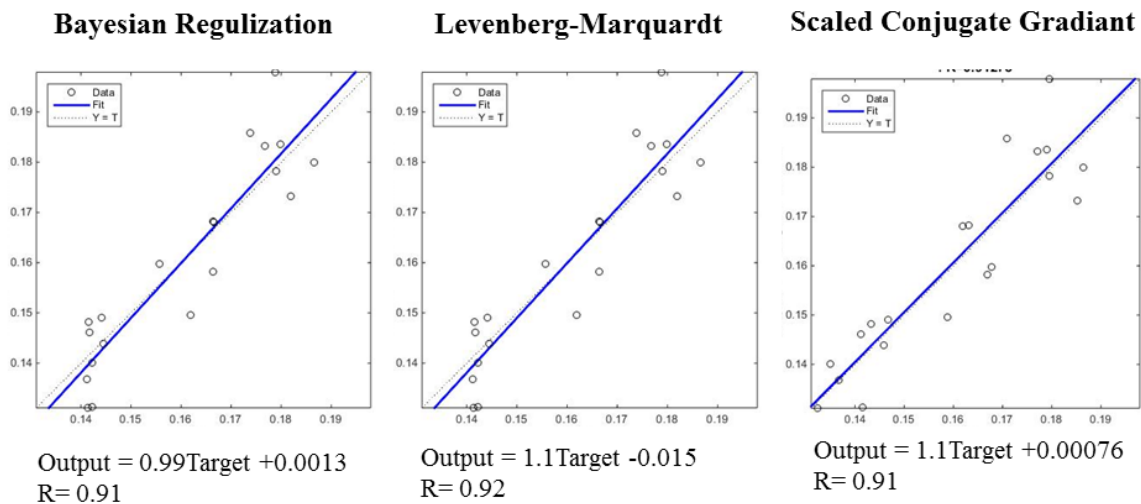
Output = 0.86Target + 0.022  
R = 0.93

شکل (۴) نتایج ارزیابی الگوریتم‌های مختلف آموزش شبکه عصبی مصنوعی

تحلیل رگرسیونی بین خروجی‌های پیش‌بینی شده و داده‌های اندازه‌گیری شده جهت اعتبارسنجی نتایج حاصل از مدل‌های شبکه عصبی انجام شد و مقادیر همبستگی، خطا (MSE) و bias برای تطابق تخمین حاصل از مدل با واقعیت زمینی محاسبه گردید. وجود مقادیر همبستگی بالا، bias و MSE کم در مراحل آموزش و آزمون شبکه بیانگر عملکرد مطلوب مدل شبکه عصبی در تخمین رطوبت قابل دسترس خاک با استفاده از ویژگی‌های درصد توزیع اندازه ذرات، چگالی ظاهری، کربن آلی، اسیدیته و هدایت الکتریکی می‌باشد. پاچسکی و همکاران (۱۹۹۶)، با استفاده از آماره‌های ضریب همبستگی و ریشه میانگین مربعات خطا به بررسی شبکه عصبی مصنوعی و آنالیز رگرسیون پرداختند. آن‌ها نتیجه گرفتند که شبکه عصبی در مقایسه با روش رگرسیون برآورد بهتر و با خطای کمتری را بر اساس داده‌های زود یافت خاک ارائه می‌دهد. تاماری و همکاران (۱۹۹۶) نیز نتایج مشابهی را در کارایی مدل شبکه عصبی نسبت به سایر روش‌های مورد آزمون گزارش نمودند. نتایج آن‌ها نشان داد که برآورد خصوصیات خاک با شبکه عصبی مصنوعی در مقایسه با روش رگرسیون خطی چندمتغیره، مقدار RMSE کمتری داشته و نتایج مطلوب‌تری را ارائه می‌دهد. در مرحله آزمون، الگوریتم آموزشی Bayesian Regularization با همبستگی ۰/۹۱۴۷، و خطای ۵-۶/۳۰۲VE عملکرد بهتری در بین سایر روش‌ها نشان داد (جدول ۴) که با نتایج رضایی و همکاران (۱۳۹۱) نیز مطابقت دارد. نتایج این پژوهشگران نشان داد که شبکه عصبی MLP با الگوریتم آموزشی Bayesian Regularization و تابع آستانه تانژانت سیگموئید با سه نرون در لایه پنهان و تابع آستانه خطی با یک نرون در لایه خروجی و شش نرون در لایه ورودی، می‌تواند نتایج با دقت بالاتری را برای پیش‌بینی هدایت هیدرولیکی اشباع خاک در استان خوزستان ارائه نماید (رضایی و همکاران، ۱۳۹۱).



Testing			الگوریتم
bias	R	MSE	
-۰/۰۱۵	۰/۹۱۶۳*	۶/۳۶۳	Levenberg-Marquardt
۰/۰۰۱۳	۰/۹۱۴۷*	-۵ ۶/۳۰۲۷e	Bayesian Regularization
-۰/۰۰۰۷۶	۰/۹۱۲۷*	۶/۴۴۳۰	Scaled Conjugate Gradient



شکل (۵) نتایج ارزیابی شبکه عصبی مصنوعی

#### ۴- نتیجه گیری

وجود روابط غیرخطی در پدیده‌های دنیای واقعی علاقه و انگیزه مهندسين را به استفاده از مدل‌های شبکه عصبی مصنوعی در سال‌های اخیر افزایش داده است. از طرف دیگر استفاده از روش‌های شبکه عصبی مصنوعی به عنوان یک ابزار قدرتمند در تجزیه و تحلیل داده‌ها و همچنین مدل‌سازی روابط، در پدیده‌های مبهم و با ماهیت غیرخطی نظیر خصوصیات خاک رو به گسترش است. در مطالعه حاضر، نتایج نشان داد که روش شبکه عصبی مصنوعی از دقت بالایی در برآورد رطوبت خاک برخوردار می‌باشد. با توجه





به آنچه در این تحقیق صورت گرفت، می توان گفت شبکه عصبی MLP با الگوریتم آموزشی Bayesian Regularization و تابع آستانه تانژانت سیگموئید با دو نرون در لایه پنهان و تابع آستانه خطی با یک نرون در لایه خروجی و هفت نرون در لایه ورودی، می تواند رطوبت قابل دسترس خاک را در منطقه مورد مطالعه با دقت بیشتری نسبت به سایر الگوریتم های آموزش پیش بینی نماید.

## منابع

- رضایی، ارشد...، صیاد، روح اله غلامعباس، مظلوم، مسعود، شرفا، مهدی. و جعفرزادگی، علیرضا. (۱۳۹۱). مقایسه روش های شبکه عصبی مصنوعی و رگرسیونی برای پیش بینی هدایت هیدرولیکی اشباع خاک های استان خوزستان، مجله علم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک/ سال شانزدهم/ شماره شصتم/ ۱۰۷-۱۱۸
- Leij, F., M.G. Schaap and L.M. Arya. 2002. Water retention and storage: Indirect methods. PP. 1009–1045. In: J.H. Dane and G.C. Topp (Ed.), Methods of Soil Analysis. Part 4. SSSA Book Ser. No. 5. SSSA, Madison, W
- Pachepsky., Y.A., Timlin, D. and G. Varallyay. (1996). Artificial neural networks to estimate soil water retention from easily measurable data. Soil Science Society of America Journal, 60:727–733.
- Schaap, M.G., Leij F.J. and van Genuchten M.Th. (1998). Neural network analysis for hierarchical prediction of soil hydraulic properties. Soil Science Society of America Journal, 62: 847–855.
- Tamari, S., J.H.M. Wosten and J.C. Ruiz-Suarez. 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. Soil Science Society of America Journal, 60: 1732–1741.
- Anagu, I., Ingwersen, J., Utermann, J. and Streck, T. (2009). Estimation of heavy metal sorption in German soils using artificial neural networks. Geoderma, 152: 104–112.
- Arya L.M. and Paris J.F. (1981). A physico-empirical model to predict the soil moisture characteristic from particle size distribution and bulk density data. Soil Science Society of America Journal, 45: 1023-1030.
- Behrens, T., Förster, H., Scholten, T., Steinrücken, U., Spies, E. and Goldschmitt, M. (2005). Digital soil mapping using artificial neural networks. Journal of Plant Nutrition and Soil Science, 168: 21–33.
- Bilgili, M. (2010). Prediction of soil temperature using regression and artificial neural network models. Meteor Atmospheric Physics, 110:59–70
- Bilgili, M., Sahin, B. and Sangun, L. (2013). Estimating soil temperature using neighboring station data via mult-nonlinear regression and artificial neural network models. Environ Monitoring Assess, 185: 347–358



- Blake, G.R. and Hartge, K.H. (1986). Bulk Density. In: Klute, A. (Ed.), Methods of Soil Analysis, Part I, ASA Monograph No. 9. Madison, WI, pp 363–376.
- Bouma, J. and Van Lanen, H. A. J. (1995). Transfer functions and threshold values from soil characteristics to land qualities. In: Beek, K., P. A. Barrough and D. D Mc Cormack (Editors), Proc. Workshop by ISSS/SSSA Quantified land evaluation procedures, ITC publication No. 6, Enschede, the Netherlands, pp 106-111.
- Brooks R.H. and Corey A.T. (1964). Hydraulic properties of porous media. Hydrol. Pap., 3, Colorado State University, Fort Collins, Co.
- Cornelis W.M., Ronsyn J., Van Meirvenne M. and Hartmann R. (2001). Evaluation of pedotransfer functions for predicting the soil moisture retention curve. Soil Science Society of America Journal, 65:638-648.
- Gandhimathi, A. and Meenambal, T. (2012). Analysis of heavy metal for soil in Coimbatore by using ANN model. European Journal of Scientific Research, 68(4): 462–474.
- Gee, G.W. and Bauder J.W. (1986). Particle Size Analysis. In: Klute, A. (Ed.), Methods of Soil Analysis. Part 1. Physical and Mineralogical Methods, Agronomy Monogr. 9. 2nd ed. ASA and SSSA, Madison, WI, pp 404–408.
- Ghaemi, M., Astaraei, A.R., Emami, H., Nassiri Mahalati, M. and Sanaeinejad, S.H. (2014). Determining soil indicators for soil sustainability assessment using principal component analysis of Astan Quds-east of Mashhad- Iran. Journal of Soil Science and Plant Nutrition, 14 (4), 987-1004.
- Guang-ming, Z., Hong-wei, L.U., Xiang-can, J.I.N. and Min, X.U. (2005). Assessment of the Water Quality and Nutrition of the Dongting Lake with Wavelet Neural Network. Journal of Hunan University, 2005-01: 3291 -94.
- Gupta S.C. and Larson W.E. (1979). Estimating soil water retention characteristics from particle size distribution, organic matter percent and bulk density. Water Resource Research, 15: 1633-1635.
- Hagan, M., Demuth, H., Beale, M, (1996). Neural Network Design. Electrical Engineering Series. Brooks/Cole.
- Haykin, S.S. (1999). Neural networks: a comprehensive foundation. Prentice Hall. Hassanipak, A.A, (2006). Geostatistics. Tehran University, pp 330. (In Persian).
- Klute, A. and Dirkson, C, (1986). Hydraulic Conductivity and Diffusivity: laboratory methods. In: Klute, A. (Ed.), Methods of Soil Analysis, Part I, ASA Monograph No. 9, Madison, WI, pp 687–734.
- Minasny, B., Hopmans, J.W., Harter, T., Eching, S.O., Tuli, A. and Denton, M.A. (2004). Neural networks prediction of soil hydraulic functions for alluvia l soils using multi step out flow data. Soil Science Society of America Journal, 68: 417– 429.



- Pachepsky Y.A., Timlin D. and Varallyay G. (1996D). Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Science Society of America Journal*, 60:727-733.
- Rawls, W.J. and Brakensiek, D.L. (1982). Estimating soil water retention from soil properties. *J. Irrig. Drain. Div. ASCE*, 108: 166-171.
- Richards, L.A. (1954). Diagnosis and Improvement of Saline and Alkali Soils, L.A. Richards (Eds). *Handbook of U.S. Dept. of Agriculture, Washington*, pp 4-160.
- Rogers, L.L., Dowla, F.U. and Johnson, V.M. (1995). Optimal Field-Scale Groundwater Remediation Using Neural Networks and the Genetic Algorithm. *Environ Science Technology*, 29(5): 1145-1155.
- Tabari, H., Sabziparvar, A.A. and Ahmadi, M. (2011). Comparison of artificial neural network and multivariate linear regression methods for estimation of daily soil temperature in an arid region. *Meteor Atmospheric Physics*, 110:135-142
- Van Genuchten, M.T.H. (1980). A closed form equation for predicting the hydraulic conductivity of unsaturated soils. *Soil Science Society of America Journal*, 44:892-898.
- Walkely, A. and Black, I.A. (1934). An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Science*, 37: 29-38.
- Westen, J.H.M., Lilly, A., Nemes A. and Le Bas C. (1998). Using existing soil data to derive hydraulic parameters for simulation models in environmental studies and in land use planning, Final Rep. Eur. Un., Wageningen.