

برآورد دامنه رطوبتی خاک با حداقل محدودیت (LLWR) با استفاده از شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک

ریحانه سلیمانی^۱، الهام چاوشی^{۱*}، حسین شیرانی^۲ و عیسی اسفندیارپور بروجنی^۲

(تاریخ دریافت: ۱۴۰۰/۶/۲۸؛ تاریخ پذیرش: ۱۴۰۰/۹/۲)

چکیده

برآورد سریع و صحیح آب فراهم خاک به عنوان یکی از مهم‌ترین شاخص‌های کیفیت خاک نقش اساسی در مدیریت منابع آب کشاورزی دارد. در پژوهش حاضر با استفاده از روش هوش مصنوعی (ترکیب شبکه عصبی و الگوریتم ژنتیک) و بهره‌گیری از ویژگی‌های زودیافت خاک، مقدار دامنه رطوبتی با حداقل محدودیت (LLWR) در ۲۵۰ نمونه خاک برداشت شده از دشت خان‌میرزا در استان چهارمحال و بختیاری برآورد شد. در این مدل‌ها، ۹ متغیر شامل درصد شن، سیلت، رس، درصد کربن آلی، چگالی ظاهری (BD)، چگالی حقیقی (PD)، pH، رسانایی الکتریکی (EC) و کربنات کلسیم معادل (CCE)، به عنوان پارامترهای ورودی و مقدار LLWR به عنوان تابع خروجی در نظر گرفته شده است. از تعداد کل ۲۵۰ داده، ۲۰۰ عدد برای آموزش و ۵۰ داده برای آزمون مدل استفاده شد. بررسی نتایج شاخص‌های آماری نشان داد که شبکه عصبی به خوبی قادر به برآورد LLWR با ضریب تبیین ۰/۹۳ است. در نهایت مشخص شد که مدل تلفیقی شبکه عصبی مصنوعی-الگوریتم ژنتیک با بیش‌ترین ضریب تبیین ($R^2=0/96$) برای برآورد LLWR مناسب‌ترین مدل است. به طور کلی دو مدل شبکه عصبی مصنوعی و الگوریتم ژنتیک نسبت به معادلات رگرسیونی کارایی مناسب‌تری برای برآورد LLWR را نشان دادند.

واژه‌های کلیدی: شبکه عصبی مصنوعی، دامنه رطوبتی با حداقل محدودیت (LLWR)، ویژگی‌های زودیافت خاک، دشت خان‌میرزا

مقدمه

پژوهشگران به‌ویژه دانشمندان علوم آب و خاک قرار گرفته است (۳۸). داسیلوا و همکاران (۱۴) برای اولین بار مفهوم «دامنه رطوبتی با حداقل محدودیت (LLWR)، Least limiting (water range)» را به صورت کمی ارائه کردند. این دامنه در واقع محدوده‌ای از رطوبت خاک است که در آن ریشه گیاه برای جذب آب با در نظر گرفتن پتانسیل آب، تهویه و مقاومت مکانیکی خاک با حداقل محدودیت روبرو است. از

فراهمی آب در خاک علاوه بر تأثیر مستقیم بر رشد گیاه، با تأثیر بر عوامل فیزیکی خاک، رشد گیاهان را به طور غیرمستقیم تحت تأثیر قرار می‌دهد. فعالیت‌های بیولوژیک و عوامل شیمیایی مانند انتقال عناصر غذایی نیز تحت تأثیر مقدار آب در خاک است. از این رو تعیین فراهمی آب خاک برای گیاهان از سال‌ها پیش مورد توجه بسیاری از

۱- گروه علوم خاک، دانشکده کشاورزی، دانشگاه آزاد اسلامی واحد اصفهان (خوراسگان)، اصفهان، ایران

۲- گروه علوم خاک، دانشکده کشاورزی، دانشگاه ولی عصر (ع) رفسنجان، کرمان، ایران


* مسئول مکاتبات، پست الکترونیکی: chavoshie@yahoo.com

آنجایی که این روش تأثیر مکش ماتریک، تهویه و مقاومت مکانیکی خاک را در برمی گیرد، می تواند به عنوان یک شاخص مناسب برای ارزیابی کیفیت فیزیکی و ساختمانی خاک مدنظر قرار گیرد. برای تعیین مقدار آب در دامنه رطوبتی با حداقل محدودیت (LLWR) دو حد بالایی و حد پایینی تعیین می شود. حد بالایی مقدار رطوبت خاک در گنجایش زراعی و یا در تخلخل تهویه ای برابر ۱۰ درصد، هر کدام که کم تر بود، است. همچنین حد پایینی مقدار رطوبت در نقطه پژمردگی دائم یا در مقاومت مکانیکی خاک برابر ۲ مگاپاسکال، هر کدام که بیش تر بود، در نظر گرفته می شود (۱۴).

LLWR جزء ویژگی های پویای (دینامیک) خاک محسوب می شود و به مقدار زیادی تحت تأثیر زمان و مکان تغییر می کند. بنابراین می توان نتیجه گرفت که این ویژگی از ویژگی های پیچیده و دیرپافت خاک محسوب شده و اندازه گیری آن با در نظر داشتن هزینه های زمانی و مالی، کاری دشوار و پرهزینه است. از این رو اگر با استفاده از تکنیک های نوین ارزیابی داده ها بتوان به گونه ای مقادیر این ویژگی را پیش بینی کرد، می توان در وقت و هزینه های پروژه های پژوهشی صرفه جویی کرد.

در دهه های اخیر استفاده از شبکه های عصبی مصنوعی در تعیین برخی ویژگی های خاک در بین پژوهشگران گسترش زیادی داشته است (۸، ۱۹، ۲۳، ۳۲ و ۳۴). شبکه های عصبی مصنوعی یکی از دستاوردهایی است که با الگوبرداری از شبکه مغزی انسان، می تواند پدیده های پیچیده و ناشناخته را به خوبی بررسی کند (۶ و ۲۳). دیدگاه های نوین شبکه عصبی، با افزودن عمل شرط گذاری به عنوان قانون آموزش مطرح شد که با پیدایش شبکه پرسپترون و قانون یادگیری با همین نام توسعه یافت. سپس با طرح الگوریتم پس پراکنش و گسترش ریزپردازنده ها، دگرگونی شگرفی در دنیای شبکه عصبی مصنوعی پدید آمد (۲۳). تاکنون پژوهش های زیادی در زمینه استفاده از شبکه عصبی و الگوریتم های تکاملی در تعیین ویژگی های خاک مانند گنجایش تبادل کاتیونی (۱۹ و ۳۴)،

هدایت هیدرولیکی اشباع (۳۲) و مقاومت برشی (۸) انجام شده است. اما بررسی عوامل مؤثر بر آب فراهم خاک در مقیاس بزرگ با استفاده از روش های هوش مصنوعی انجام نشده است. از الگوریتم ژنتیک در مدیریت منابع آب نیز استفاده می شود. به عنوان مثال اصغری مقدم و همکاران (۲) کارایی الگوریتم ژنتیک را در تخمین پارامترهای هیدرولیکی سفره های تحت فشار از داده های آزمایش پمپاژ مورد ارزیابی قرار دادند. بدین منظور توسط الگوریتم ژنتیک پارامترهای چهار سفره تحت فشار را برآورد نموده و با نتایج حاصل از روش های گرافیکی مقایسه کردند. نتایج آن ها نشان داد که الگوریتم ژنتیک روشی قابل اعتماد و قوی برای تخمین پارامترهای هیدرولیکی سفره های تحت فشار است. خداوردی لو و همایی (۲۱) نقاط شاخص منحنی مشخصه رطوبتی ۲۷ نمونه خاک منطقه کرج را از روی ویژگی های زودپافت خاک (فراوانی نسبی ذرات، چگالی ظاهری، درصد کرنات کلسیم و ...) تنها با استفاده از روش سنتی رگرسیونی با ضریب همبستگی زیاد تخمین زدند. ثروتی و ممتاز (۳۳) نیز به بررسی کارایی الگوریتم ژنتیک در تخمین گنجایش تبادل کاتیونی خاک در مقایسه با شبکه های عصبی مصنوعی پرداختند. نتایج این پژوهشگران نشان داد که کاربرد الگوریتم بهینه سازی ژنتیک باعث افزایش کارایی مدل سازی تخمین گنجایش تبادل کاتیونی نسبت به مدل شبکه های عصبی مصنوعی می شود. آنها پیشنهاد کردند با توجه به اینکه شبکه های عصبی مصنوعی بدون یک روش استقرایی جامع در انتخاب الگوریتم یادگیری شبکه و توقف الگوریتم در حداقل مکانی است، بنابراین در تخمین های مختلف ویژگی های دیرپافت خاک از یک الگوریتم بهینه سازی استفاده شود. جنادله و همکاران (۱۶) با بهینه سازی شبکه عصبی مصنوعی با الگوریتم ژنتیک به برآورد نقطه ای منحنی مشخصه رطوبتی خاک پرداختند. این پژوهشگران برای بررسی کارایی مدل ها از ضریب همبستگی اسپیرمن بین داده های واقعی و داده های تخمین زده شده (R^1)، میانگین مربعات خطای نرمال شده



شکل ۱. موقعیت کلی منطقه مورد مطالعه (دشت خانمیرزا) روی نقشه.

Fig. 1. Location of study area (The Khanmirza plain).

مساحتی حدود ۲۰۰ کیلومترمربع دارد. ارتفاع آن از سطح دریا ۱۸۸۰ متر و میانگین بارندگی سالیانه ۵۰۰ میلی‌متر است. حداقل دمای منطقه ۵- و حداکثر آن ۳۰ درجه سلسیوس بوده که در عرض ۳۱ درجه شمالی و طول جغرافیایی ۵۱ درجه شرقی قرار گرفته و از لحاظ تقسیمات زمین‌ساختاری جزء منطقه مرتفع زاگرس است. این منطقه در نقشه زمین‌شناسی ۱:۲۵۰۰۰۰ بروجن قابل مشاهده است. شکل (۱) مکان تقریبی قرارگیری دشت خانمیرزا را در نقشه کشور ایران نشان می‌دهد. برای تعیین نقاط نمونه‌برداری ابتدا با استفاده از تصاویر ماهواره‌ای گرفته شده از نرم‌افزار گوگل ارث، شناسایی کلی منطقه و بخش‌های مختلف موجود در منطقه مطالعاتی صورت گرفت. سپس بسته به موقعیت هر منطقه در مجموع ۲۵۰ نقطه به صورت نامنظم و تصادفی برای بررسی ویژگی‌های مورد نظر مشخص و از خاک رویین (عمق صفر تا ۳۰ سانتی‌متری) نمونه‌برداری انجام شد. همچنین از مکان‌های مورد اشاره نمونه‌های دست‌نخورده با استفاده از سلیندرهای نمونه‌گیری برای تعیین شاخص‌های آب فراهم خاک برداشته شد. ویژگی‌های دریافت مورد اندازه‌گیری، LLWR و شاخص‌های زود یافت و مرتبط مورد ارزیابی توزیع اندازه ذرات خاک (درصد شن، سیلت و رس)، مقدار کربن آلی، چگالی ظاهری، چگالی

(NMSE)^۱ و میانگین خطای مطلق (MAE)^۲ استفاده کردند. نتایج آنها نشان داد که شبکه عصبی در مدل‌سازی و برآورد نقطه‌ای منحنی مشخصه رطوبتی خاک از دقت زیادی برخوردار است (NMSE= 0.054, MAE=0.019, R=0.96).

در سال‌های اخیر به واسطه خشکسالی و مدیریت نامناسب، کیفیت و ذخیره آب در بسیاری از مناطق ایران از جمله دشت خانمیرزا رو به تنزل نهاده و تأمین آب به‌ویژه در بخش کشاورزی با مشکل مواجه شده است (۱۵). از این رو لازم است پژوهش‌های تخصصی در این منطقه انجام شود. از آنجایی که کیفیت فیزیکی خاک یکی از مهم‌ترین مباحث مطرح در ارتقای کارایی مصرف آب در بخش کشاورزی محسوب می‌شود، بنابراین بررسی معیارهای آب فراهم خاک که از شاخص‌های کیفیت فیزیکی خاک محسوب می‌شوند (۴) و نسبت به مدیریت کشاورزی حساسیت زیادی دارند، ضروری به نظر می‌رسد. از سوی دیگر با توجه به اهمیت تعیین میزان LLWR به روش‌های ساده‌تر و کاراتر و همچنین صرفه‌جویی در زمان و هزینه‌ها، در این پژوهش با در نظر گرفتن توزیع اندازه ذرات، مقدار ماده آلی خاک، چگالی ظاهری (BD)^۳، چگالی حقیقی (PD)^۴، رسانایی الکتریکی (EC)، کلسیم کربنات معادل (CCE)^۵ و pH به عنوان پارامترهای زود یافت و مرتبط، میزان LLWR با استفاده از مدل‌های هوشمند تعیین شد. هدف از این پژوهش کاربرد ترکیبی از شبکه عصبی مصنوعی و الگوریتم ژنتیک است که بتواند میزان LLWR را با استفاده از ویژگی‌های دیگر خاک در دشت خانمیرزا به درستی برآورد کند.

مواد و روش‌ها

منطقه مورد مطالعه

دشت خانمیرزا یکی از حوضه‌های آبریز بخش لردگان و در جنوب استان چهارمحال و بختیاری واقع شده است. این دشت

1. Normalized mean square error
2. Mean absolute error
3. Bulk density
4. Particle density
5. Calcium carbonate equivalent

مکش‌های ماتریک ۳۰۰، ۵۰۰، ۱۰۰۰، ۳۰۰۰، ۸۰۰۰ و ۱۵۰۰۰ سانتی‌متر پس از ایجاد تعادل با استفاده از دستگاه تک‌محوری با قطر قاعده مخروط ریزفروسنج ۲/۵ میلی‌متر و زاویه مخروط ۳۰ درجه اندازه‌گیری شد (۷). مقادیر مقاومت فروروی در برابر رطوبت و چگالی ظاهری با استفاده از مدل بوسچر (۱۱) تعیین شد (معادله‌های ۳ و ۴):

$$\theta = \exp(\alpha + \beta BD)h^{\delta} \quad (2)$$

$$SR = d\theta^e D^f \quad (3)$$

در این رابطه θ رطوبت حجمی ($\text{cm}^3 \text{cm}^{-3}$)، h مکش ماتریک خاک (cm)، BD چگالی ظاهری (g cm^{-3})، α ، β و δ پارامترهای مدل داسیلو و همکاران (۱۴)، SR مقاومت فروروی خاک (MPa)، d ، e و f ضرایب مدل بوسچر (۱۱) هستند.

برای تعیین دامنه رطوبتی با حداقل محدودیت (LLWR)، حد بالایی LLWR، رطوبت در نقطه گنجایش مزرعه (θ_{FC}) یا رطوبت نظیر تخلخل تهویه‌ای (θ_{AFP}) ۱۰ درصد، هر کدام که کم‌تر باشد و حد پایینی LLWR، رطوبت در نقطه پژمردگی دائم (θ_{PWP}) یا رطوبت نظیر مقاومت فروروی (θ_{SR}) ۲ مگاپاسکال هر کدام که بیش‌تر باشد، در نظر گرفته شد (۱۴).

مدل‌سازی

انتخاب داده‌های ورودی

در این پژوهش داده‌های ورودی به مدل‌ها شامل ۹ ویژگی فیزیکی و شیمیایی خاک شامل توزیع اندازه ذرات خاک (درصد شن، سیلت و رس)، مقدار ماده آلی، چگالی ظاهری، چگالی حقیقی، رسانایی الکتریکی، pH و کربنات کلسیم معادل بود. ورودی‌های مدل بر اساس همبستگی زیاد آنها با میزان LLWR در خاک و پژوهش‌های گذشته و همچنین زود یافت بودن آنها انتخاب شدند (۶). به‌عنوان مثال میزان شن، رس، pH و EC از ویژگی‌های زود یافت خاک هستند. از سوی دیگر ارتباط مستقیم و غیرمستقیم و همبستگی زیاد بین LLWR با مقدار ماده آلی، چگالی ظاهری، چگالی حقیقی و کربنات کلسیم معادل دلیل انتخاب این آنها به‌عنوان ورودی مدل بود.

حقیقی، رسانایی الکتریکی (EC)، pH و کربنات کلسیم معادل بودند.

تجزیه‌های آزمایشگاهی

درصد ذرات اولیه خاک (شن، سیلت و رس) به روش هیدرومتر و بر اساس قانون استوکز اندازه‌گیری شد (۱۰). چگالی ظاهری خاک با استفاده از نمونه‌های دست‌نخورده و روش سیلندر تعیین شد. سیلندرهایی اندازه‌گیری دارای ارتفاع و قطر ۵ سانتی‌متر بودند. همچنین اندازه‌گیری ماده آلی خاک به روش اکسیداسیون تر (۳۷) و مقدار کربنات کلسیم خاک به روش تیتراسیون برگشتی (۲۷) انجام شد. رسانایی الکتریکی (EC) عصاره اشباع خاک با استفاده از دستگاه رسانایی‌سنج الکتریکی و pH با دستگاه pH متر و در گل اشباع اندازه‌گیری شد. چگالی ظاهری خاک با استفاده از نمونه‌های دست‌نخورده و روش سیلندر تعیین شد. چگالی حقیقی توسط روش پیکنومتر اندازه‌گیری شد.

برای تعیین منحنی مشخصه رطوبتی و مقاومت فروروی خاک، ابتدا با استفاده از سیلندرهایی فلزی، نمونه‌های دست‌نخورده از خاک برداشته شد. پس از اشباع‌شدن خاک سیلندرها، مقدار رطوبت در مکش‌های ماتریک ۱۰، ۲۰، ۴۰ و ۶۰ سانتی‌متر با دستگاه جعبه شن (۱۲) و مقدار رطوبت در مکش‌های ماتریک ۱۰۰، ۳۰۰، ۵۰۰، ۱۰۰۰، ۳۰۰۰ و ۸۰۰۰ سانتی‌متر با استفاده از دستگاه صفحات تحت فشار اندازه‌گیری شد (۲۲). مدل‌سازی منحنی مشخصه رطوبتی خاک با استفاده از معادله ون‌گنوختن-معلم و به کمک ابزار Excel Solver صورت گرفت (۲۹):

$$\theta = \theta_r + (\theta_s + \theta_r) \left[1 + (ah)^n \right]^{\left(\frac{1}{n} - 1 \right)} \quad (1)$$

در این رابطه θ_s و θ_r به‌ترتیب رطوبت اشباع و رطوبت باقی‌مانده (g g^{-1})، a مرتبط با عکس مکش ماتریک در نقطه عطف (cm^{-1})، h مکش ماتریک (cm) و n شاخص توزیع اندازه منافذ خاک (-) است.

مقاومت فروروی خاک در نمونه‌های دست‌نخورده در

مدل رگرسیون چند متغیره

در این مرحله رگرسیون خطی چند متغیره برای آماده‌سازی توابع انتقالی برای تخمین میزان LLWR استفاده شد. متغیر LLWR به عنوان متغیر وابسته و متغیرهای توزیع اندازه ذرات خاک (درصد شن، سیلت و رس)، مقدار ماده آلی، چگالی ظاهری، چگالی حقیقی، رسانایی الکتریکی، pH و کربنات کلسیم معادل به عنوان متغیرهای غیروابسته برای تخمین میزان LLWR استفاده شد. ابتدا مقادیر آماره‌های کلاسیک مانند مقدار حداکثر، حداقل، میانگین، درصد ضریب تغییرات و چولگی محاسبه شد و نرمال بودن داده‌ها مورد بررسی قرار گرفت. سپس از روش رگرسیون چند متغیره برای انجام مدل‌سازی و برقراری ارتباط بین ویژگی‌های زودیافت با LLWR استفاده شد و معادلات رگرسیونی معتبر با استفاده از معیارهای آماری معرفی شد.

مدل‌سازی با شبکه عصبی مصنوعی

برای دستیابی به اهداف مورد نظر از شبکه‌های عصبی با ساختارهای مختلف همانند پرسپترون سعی شد تا بهترین و کاراترین شبکه با تعیین مقدار خطای آن انتخاب شود و مورد استفاده قرار گیرد. با توجه به اینکه وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود، برای اجتناب از چنین شرایطی و همچنین به منظور یکسان کردن ارزش داده‌ها، پیش از آموزش شبکه عصبی، داده‌های ورودی به آن بایستی استاندارد شوند. این کار مانع کوچک شدن بیش از حد وزن‌ها می‌شود (۶) و در عین حال با تنظیم داده‌های ورودی در یک محدوده خاص می‌توان نرون‌ها را در محدوده مطلوب قرار داده و از اشباع زودهنگام نرون‌ها جلوگیری کرد. همچنین این کار بدین علت صورت می‌گیرد که داده‌ها به اعدادی بین صفر تا یک تبدیل شوند، زیرا خروجی اکثر توابع، آستانه اعدادی بین صفر و یک است و شکل داده‌های ورودی به آن نقش مهمی در یادگیری شبکه ایفا می‌کند. برای ورودی‌های نزدیک به صفر یا یک، تغییرات وزن نرون‌ها حداقل خواهد بود، ولی برای مقادیر

ورودی‌های نزدیک به نیم، پاسخ نرون‌ها به سیگنال ورودی سریع‌تر خواهد بود. با در نظر گرفتن این واقعیت، نرمال‌سازی داده‌ها به گونه‌ای صورت گرفت که میانگین سری داده‌ها برابر ۰/۵ شود. در این پژوهش ۸۰ و ۲۰ درصد کل داده‌ها، به ترتیب برای آموزش و آزمون مدل اختصاص یافت (۶). در این مدل توابع Tan Axon, Sigmoid Axon, Tan Sig, Linear Axon برای فرآیند آموزش به کار گرفته شدند. تعداد عناصر پردازش لایه پنهان نیز از ۱ تا $2N + 1$ (N تعداد نرون‌های ورودی است) و تعداد لایه‌های مخفی نیز از ۱ تا ۳ بار در فرآیند آموزش و آزمون مدل تکرار شدند. فرآیند آموزش که شامل تغییر وزن‌ها بین لایه‌های مختلف در طول زمان آموزش است، انجام شد تا جایی که تفاوت بین داده‌های واقعی (برای داده‌های آزمون) و داده‌های پیش‌بینی شده به حداقل برسد.

مدل‌سازی با مدل تلفیقی شبکه‌های عصبی مصنوعی -

الگوریتم ژنتیک و ارزیابی مدل‌ها

در این روش الگوریتم ژنتیک به تنظیم اوزان اتصالات شبکه می‌پردازد. شایان ذکر است که در شبکه‌های عصبی مصنوعی بایستی تعداد و نوع ورودی‌ها، لایه‌های میانی، نرون‌ها و الگوریتم مناسب آموزش شبکه درست انتخاب شوند تا شبکه کارآمد و دقیق طراحی شود. پس از فرآیند پیش-پردازش، مجموعه داده‌ها به عنوان ورودی شبکه عصبی مورد استفاده قرار گرفت. وزن‌های اولیه متناظر با ورودی‌های شبکه عصبی (کروموزم‌های الگوریتم ژنتیک) در تکرار اول به صورت تصادفی انتخاب شدند. همچنین، رابطه میانگین خطا به عنوان تابع برازش هر کروموزم از الگوریتم ژنتیک انتخاب شد و از این رو به کارگیری عملگر تقاطع امکان‌پذیر شد. در پایان هر تکرار، ۱۰ درصد از بهترین کروموزم‌ها به همراه ۹۰ درصد کروموزم تولید شده تصادفی جدید، به نسل بعد منتقل شد. فرآیند مذکور تا رسیدن به شرایط توقف الگوریتم ادامه یافت. در پایان بهترین کروموزم به عنوان وزن‌های اولیه به شبکه عصبی مصنوعی اعمال شد. تعداد کل تکرار الگوریتم ژنتیک برابر با

جدول ۱. معادلات رگرسیون خطی چند متغیره برای تخمین دامنه رطوبتی با حداقل محدودیت (LLWR).

Table 1. Multiple linear regression equations for estimating least limiting water range (LLWR).

| Linear Regression Equation | MAE | RMSE | R ² |
|--|-------|-------|----------------|
| LLWR (cm ³ cm ⁻³) = 0.033 + 0.002 clay (%) | 0.824 | 0.725 | 0.306 |
| LLWR (cm ³ cm ⁻³) = 0.002 clay (%) + 0.022 OC (%) | 0.38 | 0.62 | 0.409 |
| LLWR (cm ³ cm ⁻³) = 0.002 clay (%) + 0.022 OC (%) - 0.02 sand (%) | 0.35 | 0.41 | 0.419 |

LLWR: دامنه رطوبتی با حداقل محدودیت، Clay: رس، OC: کربن آلی، Sand: شن، R²: ضریب تبیین (Coefficient of determination)، RMSE: ریشه میانگین مربعات خطا (Root mean square error)، MAE: میانگین خطای مطلق (Mean absolute error).

همکاران (۱) و بیات و همکاران (۳) نتایج مشابهی را در زمینه اثر ماده آلی بر آب قابل دسترس و LLWR گزارش کردند. در پژوهش کاظمی و همکاران (۲۰) نیز اثر بافت و ماده آلی بر برآورد مستقیم LLWR مثبت بود. مصدقی و محبوبی (۲۴) نیز در پژوهشی توابع رگرسیونی برای نگهداشت آب در خاک را در مکش‌های ماتریک مختلف ایجاد کرده و گزارش کردند که مقدار سیلت و رس، تأثیر معنی‌دار مثبتی بر نگهداشت رطوبت توسط خاک دارد. شیرانی (۳۵) نیز اثر مثبت رس بر میزان رطوبت خاک در وضعیت FC و PWP را گزارش کرد. نکته مهم اینکه مدل‌های رگرسیونی به‌دست آمده نتوانستند به‌خوبی تغییرپذیری ویژگی‌های مورد بررسی را به‌وسیله ویژگی‌های اولیه خاک به‌کار گرفته شده، توجیه کنند. این موضوع به‌دلیل وجود روابط غیرخطی بین پدیده‌ها است که در مدل رگرسیونی در نظر گرفته نمی‌شود.

مدل‌سازی LLWR با استفاده از شبکه عصبی مصنوعی

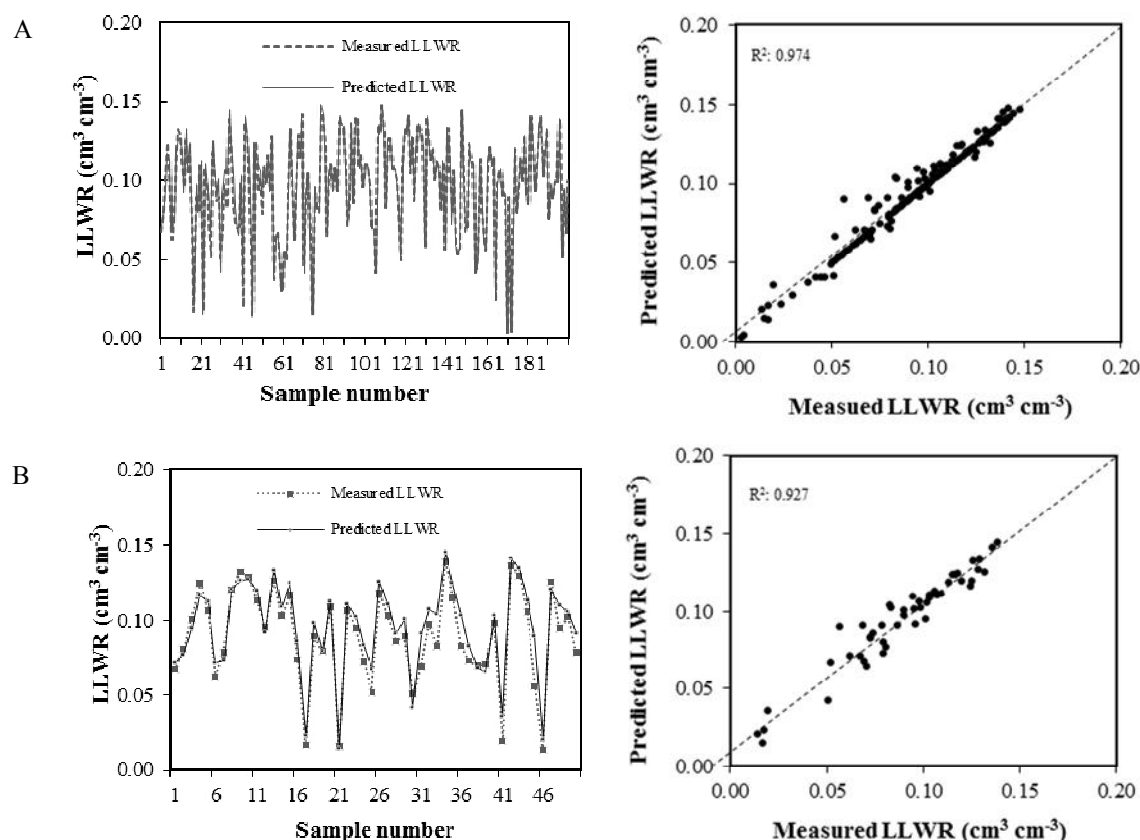
برای تخمین میزان LLWR با استفاده از شبکه عصبی از تعداد کل ۲۵۰ داده، به‌صورت تصادفی ۲۰۰ داده برای آموزش و ۵۰ داده برای آزمون مدل به‌کار گرفته شد. بر اساس شکل (۲) بررسی نتایج شاخص‌های آماری برای LLWR با استفاده از شبکه عصبی مصنوعی نشان داد که شبکه عصبی به‌خوبی قادر به برآورد LLWR است. ضریب تبیین حاصل از برازش به‌دست آمده بین مشاهدات و خروجی برای داده‌های آموزش برابر ۰/۹۷ و برای داده‌های آزمون برابر ۰/۹۳ به‌دست آمد. همچنین مقادیر RMSE نزدیک صفر بود. این نتایج نشان می‌دهد که مدل

۱۰۰۰ در نظر گرفته شد. به‌منظور انتخاب پارامترهای الگوریتم ژنتیک شامل تعداد جمعیت اولیه، احتمال تقاطع و احتمال جهش، الگوریتم از روش سعی و خطا استفاده شد. فرآیند آموزش و آزمون شبکه عصبی پیشنهادی و همچنین الگوریتم ژنتیک در نرم‌افزار Matlab نسخه ۲۰۱۱ کدنویسی شده و نتایج محاسباتی آن‌ها توسط سیستم یکسان با مشخصات پردازنده ۲ گیگاهرتزی و ۴ گیگابایتی به‌دست آمد. در این پژوهش، از نرم‌افزار Excel برای ذخیره و بررسی اولیه داده‌ها در منطقه استفاده شد. به‌منظور بررسی‌های آماری لازم مانند آزمون‌های معنی‌داری و تعیین رگرسیون چندمتغیره خطی بین داده‌های زودیافت و دیریافت از نرم‌افزارهای آماری SPSS و Minitab استفاده شد. همچنین اجرای شبکه‌های عصبی مصنوعی و الگوریتم‌های تکاملی در نرم‌افزار Matlab انجام شد. در نهایت بهترین ساختارهای شبکه برای مؤلفه‌های مورد بررسی بر اساس ضریب تبیین (R²)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) تعیین شد.

نتایج و بحث

معادلات رگرسیونی خطی برای برآورد میزان LLWR

همانگونه که در جدول (۱) مشاهده می‌شود، بهترین معادله رگرسیون خطی برای تخمین میزان LLWR با استفاده از درصد رس، کربن آلی و شن به‌دست آمد. نمس و همکاران (۲۵) بیان داشتند که ماده آلی با بهبود ساختمان خاک و افزایش منافذ متوسط که مسئول نگهداری آب در مکش‌های ماتریک بین FC و PWP هستند، موجب افزایش LLWR می‌شود. آنابی و



شکل ۲. مقایسه مقادیر اندازه‌گیری و پیش‌بینی شده LLWR با مدل شبکه عصبی مصنوعی در مراحل آموزش (A) و آزمون (B).


Fig. 2. Comparison of measured and estimated LLWR values using artificial neural network model in training (A) and testing steps (B).

برآورد LLWR را به میزان چشم‌گیری بهبود بخشیده است. این نتایج همچنین با یافته‌های بیات و همکاران (۵) و اسکولو و همکاران (۳۶) که گزارش کردند توابع تبدیلی توسعه یافته برای تخمین پارامترهای منحنی مشخصه رطوبتی خاک بر مبنای ANNs در مقایسه با توابع رگرسیونی عملکرد بهتری دارند، هماهنگ است.

مدل‌سازی LLWR با استفاده از مدل تلفیقی شبکه عصبی مصنوعی-الگوریتم ژنتیک

نتایج مدل‌سازی LLWR با استفاده از شبکه عصبی مصنوعی-الگوریتم ژنتیک در شکل (۳) ارائه شده است. نتایج مدل‌سازی نشان‌دهنده ضریب تبیین ۹۹٪ در هر دو مرحله آموزش و ۹۶٪ در مرحله آزمون است. وجود ضریب تبیین زیاد و مقادیر کم RMSE نشان می‌دهد که شبکه عصبی مصنوعی و الگوریتم

شبیه‌ساز با ۲ لایه پنهان و ۵ نرون به‌عنوان بهترین پیشگو دارای حداکثر دقت برآوردی است. همچنین مشاهده شد که افزایش تعداد لایه ورودی تأثیر چندانی در افزایش دقت شبیه‌سازی LLWR نداشت. داسیلوا و کی (۱۳) درصد رس، BD و OC را برای ایجاد توابع تبدیلی مناسب برای رسم منحنی مشخصه رطوبتی خاک به‌کار گرفتند و مقدار R^2 را برابر ۰/۹۵ گزارش کردند. نصرتی و همکاران (۲۶) نیز LLWR را به‌طور غیرمستقیم از روی توابع تبدیلی ایجاد شده برای چهار ثابت رطوبتی θ_{FC} و θ_{PWP} و θ_{AFP} و θ_{SMR} (با به‌کارگیری درصد رس، کربن آلی، آهک و چگالی ظاهری) برآورد کردند. مقادیر R^2 برای ثابت‌های مذکور به‌ترتیب برابر ۰/۵۷۸، ۰/۵۷۸، ۰/۶۰ و ۰/۹۹۸ بود. در همین زمینه کاظمی و همکاران (۲۰) کارایی مدل‌های برآورد LLWR در خاک را بررسی کرده و نشان دادند که کاربرد شبکه عصبی به‌جای رگرسیون چند متغیره خطی



شکل ۳. مقایسه مقادیر اندازه‌گیری و پیش‌بینی شده LLWR با مدل شبکه عصبی مصنوعی- الگوریتم ژنتیک در مراحل آموزش (A) و آزمون (B).

Fig. 2. Comparison of measured and estimated LLWR values using artificial neural network - genetic algorithm model in training (A) and testing steps (B).

آموزش می‌بیند و عملکرد بهتری از خود نشان می‌دهد. پرورش‌ریزی و همکاران (۲۸) نیز تلفیق شبکه عصبی و الگوریتم ژنتیک را برای بهینه‌سازی شرایط اجرای شبکه عصبی، در برآورد پارامترهای هیدرولیکی خاک، مثبت ارزیابی کردند. جنادله و همکاران (۱۶) شبکه عصبی و شبکه عصبی بهینه‌سازی شده با الگوریتم ژنتیک را برای برآورد ضرایب رطوبتی خاک در مکش‌های ماتریک مختلف به‌کار بردند. نتایج این پژوهش‌گران نشان داد که بهینه‌سازی شبکه عصبی با الگوریتم ژنتیک موجب افزایش دقت مدل‌ها و کاهش خطا شده است. به‌عنوان مثال برای θ_{FC} ، بهینه‌سازی شبکه عصبی با الگوریتم ژنتیک موجب افزایش ضریب همبستگی از ۰/۷۸ به ۰/۸۴ شده است. همچنین برای θ_{PWP} ، بهینه‌سازی شبکه عصبی با الگوریتم ژنتیک موجب افزایش ضریب همبستگی از ۰/۸۰ به ۰/۸۹ شده

ژنتیک به‌خوبی قادر به برآورد میزان LLWR با استفاده از دیگر ویژگی‌های خاک است. همان‌طور که در شکل (۳) دیده می‌شود پراکنش داده‌ها در اطراف خط ۴۵ درجه حداقل بوده و تمرکز داده‌ها روی خط است که نشان از دقت زیاد مدل در تخمین میزان LLWR با استفاده از سایر ویژگی‌های خاک است. در نمودارهای قرار گرفته در سمت راست شکل، همپوشانی مقادیر تخمین زده شده توسط مدل با مقادیر اندازه‌گیری شده مشخص است. همپوشانی زیاد داده‌های تخمین زده شده با داده‌های اندازه‌گیری شده هم یکی دیگر از دلایل کارایی زیاد مدل در هر دو حالت آموزش و آزمون مدل است. دلیل انطباق بهتر مدل با واقعیت در حالت آموزش نسبت به مرحله آزمون احتمالاً به دلیل تعداد بیش‌تر داده‌ها (۲۰۰ داده) در این مرحله هست چرا که مدل با حالات مختلف و متفاوت‌تری از پراکنش داده‌ها

جدول ۲. ارزیابی عملکرد مدل‌های مختلف مورد استفاده برای برآورد دامنه رطوبتی با حداقل محدودیت (LLWR).

Table 2. Assessing the performance of different models for estimation of least limiting water range (LLWR).

| پارامتر (Parameter) | مدل (Model) | TFs | مرحله (Step) | R ² | RMSE | MSE |
|------------------------|----------------|---------|-----------------|----------------|-------|--------|
| LLWR | SMR | - | 1 | 0.306 | 0.725 | 0.824 |
| | | - | 2 | 0.409 | 0.62 | 0.38 |
| | | - | 3 | 0.419 | 0.41 | 0.35 |
| | ANN | Sigmoid | Train | 0.97 | 0.021 | 0.011 |
| | | | Test | 0.93 | 0.042 | 0.1163 |
| | ANN-GA | Sigmoid | Train | 0.99 | 0.01 | 0.042 |
| | | | Test | 0.96 | 0.037 | 0.071 |

TFs: توابع انتقالی (Transfer functions)، R²: ضریب تبیین (Coefficient of determination)، RMSE: ریشه میانگین مربعات خطا (Root mean square error)، MSE: خطای میانگین مربعات (Mean squared error)، SMR: رگرسیون چند متغیره گام به گام (Stepwise multiple regression)، ANN: شبکه عصبی مصنوعی (Artificial neural network)، ANN-GA: شبکه عصبی مصنوعی-الگوریتم ژنتیک (Artificial neural network-Genetic algorithm)، Train: آموزش، Test: آزمون.

مصنوعی-الگوریتم ژنتیک عملکرد زیادتری دارد. همان‌طور که قبلاً اشاره شد دلیل عملکرد بهتر این مدل آن است که الگوریتم ژنتیک وزن ارتباطات شبکه را تنظیم کرده و میزان خطای مدل را کاهش می‌دهد.

به‌طور کلی دو مدل شبکه عصبی مصنوعی و الگوریتم ژنتیک نسبت به معادلات رگرسیونی کارایی مناسب‌تری نشان دادند. در واقع مدل‌های شبکه عصبی مصنوعی و الگوریتم ژنتیک از نوع ویژه‌ای از معادلات استفاده نکرده و شبکه با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌تواند به نتایج رضایت‌بخشی دست یابد (۳۱). در صورت وجود رابطه غیرخطی بین متغیرهای وابسته و مستقل شبکه عصبی مصنوعی با توجه به بررسی غیرخطی بودن داده‌ها می‌تواند به نتایج بهتری نسبت به روش‌های رگرسیونی که تنها به بررسی وجود رابطه خطی می‌پردازند، دست یابد. شایان ذکر است که در مدل‌های رگرسیونی، همبستگی ضعیف بین دو متغیر وابسته به هم، همیشه نشان‌دهنده عدم ارتباط این دو متغیر با همدیگر نیست و ممکن است همبستگی غیرخطی بین دو متغیر وجود داشته باشد که به‌وسیله ضریب همبستگی خطی قابل بررسی نیست (۱۸).

نتیجه‌گیری

در این پژوهش سه مدل عددی رگرسیون خطی چندگانه، شبکه

است. با اینکه مدل شبکه عصبی توانایی زیادی در مدل‌سازی رفتارهای غیرخطی دارد، ولی این توانایی در حضور غنی داده‌ها و مشاهدات فراوان است، در غیر این صورت این تکنیک‌ها کارایی زیادی نداشته و این نقص، کارایی آن‌ها را به‌شدت محدود می‌کند. از این‌رو در این بررسی به‌منظور غلبه بر مسئله فوق، به‌کمک الگوریتم ژنتیک به بهینه‌سازی ورودی‌ها، اندازه گام‌ها، یادگیری مومنتوم و تعداد گره‌های هر لایه در شبکه عصبی پرداخته شد.

مقایسه کارایی مدل‌های رگرسیون خطی، شبکه عصبی مصنوعی و الگوریتم ژنتیک

در جدول (۲) مقادیر ضریب تبیین (R²) و خطا (RMSE) و (MAE) برای داده‌های ارزیابی بر اساس مدل رگرسیون خطی، شبکه عصبی مصنوعی و مدل تلفیقی شبکه عصبی مصنوعی-الگوریتم ژنتیک ارائه شده است. بر اساس این جدول مدل تلفیقی شبکه عصبی مصنوعی-الگوریتم ژنتیک با بیش‌ترین ضریب تبیین و کم‌ترین میزان خطا برای برآورد LLWR مناسب‌ترین مدل شناخته شد. این نتایج با نتایج جوهری و همکاران (۱۷) هم‌خوانی دارد. این پژوهشگران با استفاده از الگوریتم ژنتیک مقادیر خطای مدل شبکه عصبی مصنوعی را کاهش داده و گزارش کردند که مدل تلفیقی شبکه عصبی

عصبی مصنوعی-الگوریتم ژنتیک را به عنوان مدلی مناسب و دقیق برای استفاده در تخمین LLWR به کار برد. از طرف دیگر مدل رگرسیونی به عنوان ضعیف ترین مدل در برآورد ویژگی مورد بررسی بود که این امر نشان از رفتار غیرخطی متغیر مورد بررسی دارد که موجب برتری شبکه عصبی مصنوعی و الگوریتم ژنتیک بر مدل رگرسیون چند متغیره خطی شد. با توجه به دقت بیش تر پیش بینی الگوریتم ترکیبی شبکه عصبی و ژنتیک در این بررسی، استفاده از این تکنیک در پیش بینی سایر ویژگی های دیرپافت خاک پیشنهاد می گردد.

عصبی مصنوعی و مدل تلفیقی شبکه عصبی مصنوعی-الگوریتم ژنتیک به منظور تخمین دامنه رطوبتی با حداقل محدودیت (LLWR) مورد مقایسه قرار گرفتند. نتایج نشان داد که بر اساس مقدار آماره های ارزیابی، روش شبکه عصبی مصنوعی-الگوریتم ژنتیک دارای دقت بیش تری در برآورد مقادیر LLWR بود. نتایج روش شبکه عصبی مصنوعی-الگوریتم ژنتیک برای تخمین ویژگی مورد بررسی خاک رضایت بخش بود به گونه ای که این مدل توانست ۹۶ درصد تغییرپذیری LLWR را نشان دهد. بنابراین با توجه به نتایج به دست آمده می توان مدل شبکه

منابع مورد استفاده

1. Annabi, M., Houot, S., Francou, C., Poitrenaud, M., Bissonnais, Y., 2007. Soil aggregate stability improvement with urban composts of different maturities. *Soil Science Society of America Journal* 71(2): 413–423.
2. Asghari Moghaddam, A., Norani, V., Kord, M., 2008. Estimation of hydraulic parameters of confined aquifers using genetic algorithm optimization technique. *Iran- Water Resources Research* 3(3): 30–41. (in Persian with English abstract)
3. Bayat, H., Ebrahimi, E., Fallah, M., 2017. Estimation of soil moisture using confined compression curve parameters. *Geoderma* 318: 64–77.
4. Bayat, H., Heydari, L., Ebrahimzadeh, G., 2017. Evaluation of the regression pedotransfer functions using physical, mechanical, and chemical soil properties in the estimation of the least limiting water range (LLWR). *Journal of Soil Research (Soil and Water Sciences)* 31(4): 545–559. (in Persian with English abstract)
5. Bayat, H., Neyshaburi, M.R., Hajabbasi, M.A., Mahboubi, A.A., Mosaddeghi, M.R., 2008. Comparing neural networks, linear and nonlinear regression techniques to model penetration resistance. *Turkish Journal of Agriculture and Forestry* 32(5): 425–433.
6. Bazoobandi, A., Emamgholizadeh, S., Ghorbani, H., 2019. Estimating the amount of cadmium and lead in polluted soil using artificial intelligence models. *European Journal of Environmental and Civil Engineering* 8: 1–9.
7. Bengough, A.G., Campbell, D.J., O'Sullivan, M.F., 2001. Penetrometer techniques in relation to soil compaction and root growth. In: Smith, K.A., Mullins, C.E. (Eds.), *Soil and Environmental Analysis: Physical Methods*. Marcel Dekker Inc, New York, pp. 377–405.
8. Besalatpour, A., Hajabbasi, M.A., Ayoubi, S., Afyuni, M., Jalalian, A., Schulin, R., 2012. Soil shear strength prediction using intelligent systems: artificial neural networks and an adaptive neuro-fuzzy inference system. *Soil Science and Plant Nutrition* 58(2): 149–160.
9. Beutler, A.N., Centurion, J.F., Da Silva A.P., Da Cruz Centurion, M.A.P., Leonel, C.L., Freddi, O.S., 2008. Soil compaction by machine traffic and least limiting water range related to soybean yield. *Pesquisa Agropecuária Brasília* 43(11): 1591–1600.
10. Bouyoucos, G.J., 1962. Hydrometer method improved for making particle size analyses of soils. *Agronomy Journal* 54(5): 464–465.
11. Busscher, W., 1990. Adjustment of flat-tipped penetrometer resistance data to a common water content. *Transactions of the American Society of Agricultural Engineers* 33: 519–524.
12. Clement, C., 1966. A simple and reliable tension table. *Journal of Soil Science* 17(1): 133–135.
13. da Silva, A.P., Kay, B.D., 1997. Estimating the least limiting water range of soils from properties and management. *Soil Science Society of America Journal* 61(3): 877–883.
14. da Silva, A.P., Kay, B.D., Perfect, E., 1994. Characterization of the least limiting water range of soils. *Soil Science Society of America Journal* 58(6): 1775–1781.

15. Hasani, Z., Mirabbasi Najafabadi, R., Ghasemi, A.R., 2018. Prediction of groundwater quality of Khanmirza plain using decision tree method. *Hydrogeology* 3(1): 99–110. (in Persian with English abstract)
16. Jenadeleh, N., Nadian, H.A., Khalilimoghadam, B., Ghorbani dashtaki, S., 2016. Point estimation of soil moisture characteristic curve using artificial neural networks and its optimizing by genetic algorithm in agro-industries of Khouzestan. *Watershed Management Research* 29 (113): 40–50. (in Persian with English abstract)
17. Johari, A., Javadi, A.A., Habibagahi, G., 2011. Computers and geotechnics modelling the mechanical behaviour of unsaturated soils using a genetic algorithm-based neural network. *Computers and Geotechnics* 38(1): 2–13.
18. Karamouz, M., Araghinejad, S., 2005. Advanced Hydrology. Second ed., Amirkabir University of Technology Press, Tehran. (in Persian)
19. Kashi, H., Emamgholizadeh, S., Ghorbani, H., 2014. Estimation of soil infiltration and cation exchange capacity based on multiple regression, ANN (RBF, MLP), and ANFIS models. *Communications in Soil Science and Plant Analysis* 45(9): 1195–1213.
20. Kazemi, Z., Neyshabouri, M.R., Bayat, H., Oustan, S., Moghaddam, M., 2015. Performance of three models in predicting least limiting water range in soil. *Iranian Journal of Soil Research* 28(4): 659–699. (in Persian with English abstract)
21. Khodaverdiloo, H., Homaei, M., Van Genuchten, M.T., Dashtaki, S.G., 2011. Deriving and validating pedotransfer functions for some calcareous soils. *Journal of Hydrology* 399(1–2): 93–99.
22. Klute, A., 1986. Water retention: laboratory methods. In: Klute, A. (Ed.), *Methods of Soil Analysis, Part 1. Physical and Mineralogical Methods*, Agronomy Monograph, ASA, Wisconsin, pp. 635–662.
23. Menhaj, M.B., 1998. *Fundamental of Artificial Neural Networks*. Second ed., Amirkabir University of Technology Press, Tehran. (in Persian)
24. Mosaddeghi, M.R., Mahboubi, A.A., 2011. Point pedotransfer functions for prediction of water retention of selected soil series in a semi-arid region of western Iran. *Archives of Agronomy and Soil Science* 57(4): 327–342.
25. Nemes, A., Rawls, W.J., Pachepsky, Y.A., 2005. Influence of organic matter on the estimation of saturated hydraulic conductivity. *Soil Science Society of America Journal* 69 (4): 1330–1337.
26. Nosrati, A., Mahboubi, A., Mosaddeghi, M.R., 2007. Determining the least limiting water range (LLWR) and comparing it with the plant available water in some soils of Hamadan province. In: *Proceedings of 10th Soil Science Congress of Iran*, Karaj, Iran, August 26–29, pp. 117–120.
27. Pansu, M., Gautheyrou, J., 2006. *Handbook of Soil Analysis: Mineralogical, Organic and Inorganic Methods*. Second ed., Springer-Verlag Berlin Heidelberg, Berlin.
28. Parvareshrizi, A., Kouchakzadeh, S., Omid, M.H., 2006. Estimating moving hydraulic jump parameters by means of ann and the integration of ANN and GA. *Iranian Journal of Agriculture Science* 37(1): 187–196.
29. Pierson, F.B., Mulla, D.J., 1989. An improved method for measuring aggregate stability of a weakly aggregated loessial soil. *Soil Science Society of America Journal* 53: 1825–1831.
30. Reynolds, W.D., Drury, C.F., Yang, X.M., Fox, C.A., Tan, C.S., Zhang, T.Q., 2007. Land management effects on the near-surface physical quality of a clay loam soil. *Soil & Tillage Research* 96: 316–330.
31. Schaap, M.G., Leij, F.J., van Genuchten, M.T., 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Science Society of America Journal* 62(4): 847–855.
32. Sedaghat, A., Bayat, H., Sinigani, A.A.S., 2016. Estimation of soil saturated hydraulic conductivity by artificial neural networks ensemble in smectitic soils. *Eurasian Soil Science* 49(3): 347–357.
33. Servati, M., Momtaz, H., 2017. Firefly algorithm and genetic algorithm performance in cation exchange capacity prediction by artificial neural networks. *Journal of Water and Soil* 31(5): 1456–1466. (in Persian with English abstract)
34. Shekofteh, H., Ramazani, F., 2017. Prediction of soil cation exchange capacity using support vector regression optimized by genetic algorithm and adaptive network-based fuzzy inference system. *Desert* 22(2): 187–196.
35. Shirani, H., 2012. Prediction of FC and PWP using neural network and statistical regression in Bardsir-Kerman area. *Journal of Water and Soil Science (Journal of Science and Technology of Agriculture and Natural Resources)* 16(59): 141–151. (in Persian with English abstract)
36. Skalová, J., Čistý, M., Bezák, J., 2011. Comparison of three regression models for determining water retention curves. *Journal of Hydrology and Hydromechanics* 59(4): 275–284.
37. Walkley, A., 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(1): 29–38.

38. Zarehaghi, D., Neyshabouri, M.R., Gorji, M., Monirifar, H., Shorafa, M., 2012. Determination of non-limiting water range for seedling growth of pistachio at two levels of soil compaction. *Water and Soil Science* 22(3): 59–71. (in Persian with English abstract)



Estimating Least Limiting Water Range (LLWR) of Soil Using Artificial Neural Networks and Genetic Algorithms

R. Soleimani¹, E. Chavoshi^{1*}, H. Shirani² and I. Esfandiarpour Boroujeni²

(Received: 19 September 2021; Accepted: 23 November 2021)

Abstract

Quick and accurate estimation of soil available water as one of the most critical soil quality indices plays an essential role in agricultural water resources management. The present study estimated the least limiting water range (LLWR) for 250 soil samples taken from Khanmirza plain in Chaharmahal and Bakhtiari province. Artificial intelligence method (combining genetic algorithm (GA) with artificial neural network (ANN)) and readily available soil properties were used for this purpose. The LLWR was considered as output variable, and sand, silt and clay percentages, organic carbon content, bulk density (BD), particle density (PD), pH, electrical conductivity (EC) and equivalent calcium carbonate (CCE) were considered as input variables. From 250 data, 200 were allocated to model training and 50 to model testing. The statistical analyses showed that the artificial neural network had a reasonable estimate of LLWR with a coefficient of determination of 0.93. Finally, the combined model of artificial neural network-genetic algorithm (ANN-GA) with the highest coefficient of determination ($R^2 = 0.96$) was identified as the most appropriate model for predicting LLWR. The two models of artificial neural network and genetic algorithm generally showed better performance than the regression equations.

Keywords: Artificial neural network, Least limiting water range (LLWR), Readily available soil properties, Khanmirza plain.

Background and Objective: Soil available water (SAW) is a key attribute, as it quantifies the amount of water available for plants that the soil can hold (4). Various approaches have been proposed to quantify the soil available water for plants. The least limiting water range (LLWR) concept defines a range of soil water content within which root growth is least limited from a soil physical point of view; conversely, the boundaries of the LLWR define critical soil physical limits for root growth (1). In recent decades, numerous models have been developed to estimate soil water retention from conveniently measurable properties, including mathematical models and physical models. In the case of complex systems, mathematical modeling techniques may be more efficient in predicting soil available water, such as ANN. There have been many studies on the use of ANN model, in determining some soil properties such as cation exchange capacity (2), and saturated hydraulic conductivity (3). Considering the importance of LLWR and the difficulties in its direct measurement, this study aimed to use ANN, ANN-GA and stepwise multivariate regression (SMR) to estimate LLWR and compare the performance of these models and pick a better model using statistical parameters.

1- Department of Soil Science, Collage of Agriculture, Isfahan (Khorasgan) Branch, Islamic Azad University, Isfahan, Iran.

2- Department of Soil Science, Collage of Agriculture, Vali-e-Asr University of Rafsanjan, Kerman, Iran.

* Corresponding Author, Email: chavoshie@yahoo.com

Methods: This research was conducted at Khanmirza agricultural plain (southeast of the Shahr-e Kord). General identification of the study area was carried out using satellite imagery taken from Google Earth software and 250 samples were collected. Surface samples were taken from a depth of 0–20 cm. The pH, EC, soil organic carbon, calcium carbonate equivalent, bulk density, particle density, sand, silt, and clay contents were measured for models input. The amount of LLWR was chosen as the output. Three numerical models of SMR, ANN and ANN-GA were compared to estimate the LLWR. Statistical parameters including R^2 , RMSE and MAE were used to compare the methods used.

Results: Based on 200 data for training and 50 data for model testing, it was shown that the ANN-GA model is a better method for estimating LLWR by improving the weaknesses of the ANN model. This provided better performance in terms of accuracy ($R^2 = 0.96$) and error reduction (Root mean square error (RMSE) = 0.037 and mean absolute error (MAE) = 0.071).

Conclusions: In this study, three numerical models of SMR, ANN, and ANN-GA were compared to estimate the LLWR. The results showed that ANN-GA was more accurate in estimating LLWR values. This model was able to explain about 95 to 98% variability of the studied properties. Therefore, according to the obtained results, the ANN-GA can be used as a suitable and accurate model for use in LLWR estimation. On the other hand, the SMR model was the weakest in estimating the studied features, indicating the nonlinear behavior of the studied variable. Due to the more accurate prediction of ANN-GA in this study, it is recommended to use this model in predicting other soil variables.

References:

1. da Silva, A.P., Kay, B.D., Perfect, E., 1994. Characterization of the least limiting water range of soils. *Soil Science Society of American Journal* 58(6): 1775–1781.
2. Kashi, H., Emamgholizadeh, S., Ghorbani, H., 2014. Estimation of soil infiltration and cation exchange capacity based on multiple regression, ANN (RBF, MLP), and ANFIS models. *Communications in soil Science and Plant Analysis* 45(9): 1195–1213.
3. Sedaghat, A., Bayat, H., Sinegani, A.A.S., 2016. Estimation of soil saturated hydraulic conductivity by artificial neural networks ensemble in smectitic soils. *Eurasian Soil Science* 49(3): 347–357.
4. Zarehaghi, D., Neyshabouri, M.R., Gorji, M., Monirifar, H., Shorafa, M., 2012. Determination of non-limiting water range for seedling growth of pistachio at two levels of soil compaction. *Water and Soil Science* 22(3): 59–71. (in Persian with English abstract)