

تعیین ویژگی‌های مؤثر بر پایداری ساختمان خاک‌های مناطق خشک با استفاده از الگوریتم ترکیبی ژنتیک-شبکه عصبی مصنوعی

ایرج کوچمی ساردو^۱، حسین شیرانی^۲، عیسی اسفندیارپور بروجنی^{۳*} و علی اصغر بسالت پور^۴

(تاریخ دریافت: ۱۳۹۸/۷/۱۴ تاریخ پذیرش: ۱۳۹۸/۹/۱۱)

چکیده

پایداری خاکدانه‌ها به‌عنوان یکی از کلیدی‌ترین شاخص‌های کیفیت فیزیکی خاک، بیان‌گر قدرت نسبی خاک در برابر نیروهای فرساینده و تخریب مکانیکی است. در این پژوهش، به‌منظور شناسایی یک زیرمجموعه از مهم‌ترین ویژگی‌های مؤثر بر شاخص میانگین وزنی قطر خاکدانه‌ها (MWD)، از الگوریتم ترکیبی ژنتیک-شبکه عصبی مصنوعی (GA-ANN) استفاده گردید. افزون بر آن، قابلیت شبکه‌های عصبی مصنوعی (ANNs) و رگرسیون چند متغیره خطی (MLR) برای کمی‌سازی رابطه بین شاخص MWD و ویژگی‌های خاک مؤثر بر آن، ارزیابی شد. پس از فرآیند مدل‌سازی، اهمیت هر یک از ویژگی‌های انتخاب شده در ارتباط با تغییرات مکانی پایداری خاکدانه‌ها بررسی گردید. به‌منظور دست‌یابی به یک مجموعه داده مناسب، شاخص MWD و تعدادی از ویژگی‌های خاک در نمونه‌های خاک جمع‌آوری شده از ۹۰ نقطه مشاهداتی اندازه‌گیری شدند. نتایج حاصل از انتخاب ویژگی نشان داد که شش ویژگی خاک شامل رس، شن، ماده آلی، کربنات کلسیم معادل، قابلیت هدایت الکتریکی و نسبت جذب سدیم، بیش‌ترین تأثیر را بر روی شاخص MWD خاک‌های مورد مطالعه داشتند. با توجه به نتایج به‌دست آمده از برآورد شاخص MWD، مقادیر محاسبه‌شده ضریب تبیین (R^2)، میانگین درصد خطای مطلق (MAEP) و مجذور میانگین مربعات خطا (RMSE) برای عملکرد شبکه عصبی مصنوعی، به‌ترتیب برابر با ۰/۹۴، ۲۱/۳۹ و ۰/۰۷۵ درصد بودند. این نتایج بیان‌گر آن بود که مدل ANN توسعه داده شده به‌خوبی توانسته است روابط پیچیده و غیرخطی بین شاخص MWD و ویژگی‌های خاک انتخاب‌شده توسط الگوریتم GA-ANN را پیش‌بینی و کمی‌سازی کند. بر اساس نتایج به‌دست آمده از تحلیل حساسیت، کربنات کلسیم معادل، ذرات شن و ماده آلی به‌عنوان فاکتورهای کلیدی برای تخمین پایداری خاکدانه‌ها معرفی شدند. به‌طور کلی، این پژوهش یک چارچوب قوی برای تخمین پایداری خاکدانه‌ها و شناسایی مهم‌ترین ویژگی‌های مؤثر بر آن در خاک‌های مناطق خشک و نیمه‌خشک فراهم می‌کند که می‌تواند برای سایر مناطق با چالش‌های مشابه، مورد استفاده قرار گیرد.

واژه‌های کلیدی: آنالیز حساسیت، بهینه‌سازی، رگرسیون چند متغیره خطی، میانگین وزنی قطر خاکدانه‌ها

کوچمی ساردو ا.، شیرانی ح.، اسفندیارپور بروجنی ع.، بسالت پور ع.، تعیین ویژگی‌های مؤثر بر پایداری ساختمان خاک‌های مناطق خشک با استفاده از الگوریتم ترکیبی ژنتیک-شبکه عصبی مصنوعی. تحقیقات کاربردی خاک. جلد ۸، شماره ۳. صفحه: ۱۲۹-۱۴۳.

۱- دانشجوی دکتری گروه علوم و مهندسی خاک، دانشکده کشاورزی دانشگاه ولی‌عصر (عج) رفسنجان

۲- استاد گروه علوم و مهندسی خاک، دانشکده کشاورزی دانشگاه ولی‌عصر (عج) رفسنجان

۳- دانشیار گروه علوم و مهندسی خاک، دانشکده کشاورزی دانشگاه ولی‌عصر (عج) رفسنجان (مکاتبه‌کننده)

۴- استادیار گروه علوم و مهندسی خاک، دانشکده کشاورزی دانشگاه ولی‌عصر (عج) رفسنجان

* پست الکترونیک: esfandiarpour@vru.ac.ir

مقدمه

پایداری خاکدانه‌ها یکی از مهم‌ترین عوامل مؤثر در ارزیابی کیفیت فیزیکی خاک است. به گونه‌ای که افزایش هم‌آوری ذرات خاک و تشکیل خاکدانه‌های مقاوم، سبب بهبود ویژگی‌های خاک، هم از دیدگاه کشاورزی و هم از دیدگاه زیست‌محیطی می‌گردد (Obalum et al., 2019). در عرصه کشاورزی، پایداری خاکدانه‌ها با اثر بر تهویه خاک و قابلیت دسترسی آب و عناصر غذایی برای گیاهان، بر روی حاصلخیزی و محصول دهی خاک تأثیر چشمگیری دارد (Whalen et al., 2003). از منظر زیست‌محیطی، پایداری خاکدانه‌ها با اثر بر مقاومت ذرات خاک در برابر نیروهای فرساینده و نفوذپذیری خاک، تا حدود زیادی تعیین‌کننده شدت فرسایش‌پذیری خاک است. تا کنون شاخص‌های متعددی برای بیان پایداری خاکدانه‌ها معرفی شده‌اند که از جمله آن‌ها می‌توان به میانگین وزنی قطر خاکدانه‌ها (MWD)، میانگین هندسی قطر خاکدانه‌ها (GMD)، مقاومت کششی خاکدانه‌ها و رس قابل پراکنش اشاره کرد. ساختمان خاک هم‌چون بسیاری از مسایل دنیای واقعی، معلول برهمکنش مجموعه بزرگی از ویژگی‌ها است که تعدادی از این ویژگی‌ها در ارتباط با مسئله مورد نظر، بی‌ربط و یا کم‌اهمیت می‌باشند. به عبارت دیگر، پارامترهای متعددی از قبیل عوامل مدیریتی و ویژگی‌های خاک (فیزیکی، شیمیایی و بیولوژیکی) بر روی پایداری خاکدانه‌ها تأثیرگذار می‌باشند (Ternan et al., 1996; Besalatpour et al., 2014).

تعداد زیاد پارامترهای مؤثر بر پایداری خاکدانه‌ها و روابط پیچیده بین این پارامترها، یکی از چالش‌های اصلی در جهت مطالعه این ویژگی خاک به‌شمار می‌آید (Etminan et al., 2011). به عبارت دیگر، در فرآیند پردازش داده‌ها، وارد کردن ویژگی‌های غیرضروری و غیرمرتبط با مسئله مورد نظر، می‌تواند منجر به کاهش دقت و پیچیدگی بیش از حد آن گردد (Shirani et al., 2015). در واقع، انتخاب یک زیرمجموعه مناسب از ویژگی‌های مرتبط با هدف مورد نظر، بسیار مهم است. به گونه‌ای که انتخاب زیرمجموعه گفته‌شده، علاوه بر کسب نتایج کارآمدتر، در مواردی باعث افزایش دقت پردازش داده‌ها نیز شده است

(Wu et al., 2013). تا کنون روش‌های متعددی برای انجام فرآیند انتخاب ویژگی^۴، مورد پژوهش و ارزیابی واقع شده‌اند. الگوریتم ژنتیک (GA) یکی از روش‌های مورد استفاده در این ارتباط می‌باشد که از جمله روش‌های توانمند بهینه‌سازی غیرخطی الهام‌گرفته از فرآیندهای زیستی است و در مواردی که تابع هدف، ناپیوسته، غیرخطی، غیرقابل مشتق‌گیری و شامل مقادیر بهینه موضعی باشد، استفاده می‌شود.

میزان تغییر پارامتر هدف (به‌عنوان مثال، پایداری خاکدانه‌ها) به ازای تغییر معین در میزان ویژگی‌های مؤثر بر آن (به‌عنوان مثال، ماده آلی خاک) را تحلیل حساسیت^۵ گویند. به عبارت دیگر، تحلیل حساسیت شامل وارد کردن یک محدوده از مقادیر برای ویژگی‌های مؤثر و مشاهده تغییرات در مقادیر پارامتر هدف است (Veihe and Quinton, 2000). ویژگی‌هایی که تغییرات کم آن‌ها باعث تغییرات زیادی در میزان پارامتر هدف شود، متغیرهای حساس نامیده می‌شوند که به دلیل تأثیر زیاد این نوع از ویژگی‌ها بر پارامتر هدف، باید دقت زیادی در محاسبه و اندازه‌گیری آن‌ها صورت گیرد (Shirani et al., 2015). برای انجام آزمون تحلیل حساسیت، در ابتدا نیاز به توابعی است که بتوانند مسئله مورد نظر را با استفاده از ویژگی‌های مؤثر بر آن پیش‌بینی کنند. در مورد مسایل خاک، توابع مزبور به روش‌های مختلفی استخراج می‌شوند که از جمله این روش‌ها می‌توان به مدل‌های رگرسیونی و هوش مصنوعی اشاره کرد. برخلاف قابلیت بالای رویکردهای هوش مصنوعی در پردازش داده‌ها، در مقایسه با کاربرد گسترده مدل‌های رگرسیونی برای تخمین پایداری خاکدانه‌ها (Khazaei et al., 2008; Karimi et al., 2008; Etminan et al., 2011; Nikpur et al., 2012)، روش‌هایی مانند شبکه‌های عصبی مصنوعی (ANNs)، برای این منظور به ندرت به کار گرفته شده‌اند. شبکه‌های عصبی مصنوعی از جمله رویکردهای نوین برای مدل‌سازی فرآیندهای پیچیده و روابط غیرخطی می‌باشند. به‌طور کلی، شبکه‌های عصبی مصنوعی بیانگر یک مدل ریاضی می‌باشند که قابلیت پیش‌بینی روابط مبهم برای میان‌یابی داده‌ها را دارند (Shirani, 2018). به دلیل توانایی شبکه‌های عصبی مصنوعی (از جمله قدرت

4. Genetic Algorithm
5. Sensitivity analysis
6. Artificial Neural Networks

1. Mean Weight Diameter
2. Geometric Mean Diameter
3. Feature selection

کرمان می‌باشد که در حد فاصل طول‌های جغرافیایی $14^{\circ} 00' 56''$ تا $41^{\circ} 07' 56''$ شرقی و عرض‌های جغرافیایی $30^{\circ} 29' 53''$ تا $30^{\circ} 35' 30''$ شمالی واقع شده است. بر اساس داده‌های هواشناسی ثبت شده در ایستگاه هواشناسی شهرستان رفسنجان طی یک دوره آماری ده ساله (۱۳۸۷-۱۳۹۷)، میانگین بارش سالانه در منطقه مورد مطالعه برابر با ۹۵ میلی‌متر و میانگین دمای سالانه آن برابر با ۱۸ درجه سلسیوس می‌باشد؛ به‌گونه‌ای که بر اساس روش دومارتن، منطقه مورد مطالعه دارای آب و هوای خشک است. بخشی از منطقه به کشت درختان پسته اختصاص داده شده است که تعدادی از این باغ‌ها در اثر هجوم شن‌های روان و خشک‌سالی‌های تقسیم‌بندی واحدهای ژئومورفولوژیکی در واحد دشت سر و تیپ دشت‌سر پوشیده قرار دارد. به‌طور کلی، منطقه مورد مطالعه شامل کاربری‌های باغ پسته، اراضی باغی رهاشده، اراضی تحت کشت تاغ، اراضی مسکونی و اراضی بایر می‌باشد (شکل ۱).

مطالعات صحرایی و آزمایشگاهی

ابتدا منطقه مورد مطالعه بر اساس نوع کاربری به واحدهای کاری گوناگون تقسیم شد. سپس با توجه به مساحت و شرایط خاک (یکنواختی یا عدم یکنواختی) در اراضی مورد مطالعه، موقعیت مکانی ۹۰ نقطه مشاهداتی به روش تصادفی نظارت‌شده آدر محیط نرم‌افزار ایلویس^۳ مشخص گردید. با استفاده از سامانه موقعیت‌یاب جهانی^۴، محل هر یک از نقاط در منطقه مشخص شد و از خاک سطحی (عمق صفر تا پنج سانتی‌متر) آن‌ها نمونه‌برداری خاک انجام گرفت. علاوه بر آن، در هر نقطه مطالعاتی، نمونه خاک جداگانه‌ای به‌منظور ارزیابی پایداری خاکدانه‌ها از عمق صفر تا پنج سانتی‌متر برداشت و به آرامی در ظرف پلاستیکی قرار داده شد؛ به‌گونه‌ای که کم‌ترین آسیب به خاکدانه‌ها وارد گردد.

یادگیری و انعطاف‌پذیری آن‌ها)، این رویکرد می‌تواند به‌عنوان جایگزینی مناسب برای روش‌های سنتی در مدل‌سازی روابط پیچیده و غیرخطی مسایل مختلف مورد استفاده قرار گیرد (Merdun *et al.*, 2006). بسالت‌پور و همکاران (Besalatpour *et al.*, 2014) با انجام پژوهشی به بررسی قابلیت روش‌های مبتنی بر هوش مصنوعی (مانند سیستم‌های استنتاج نروفازی انطباقی (ANFIS)) برای پیش‌بینی پایداری خاکدانه‌ها (به روش الگوترا) پرداختند. نتایج حاصل از این پژوهش نشان داد که رویکردهای هوش مصنوعی، یک تکنیک رضایت‌بخش برای کمی‌سازی روابط پیچیده بین پایداری خاکدانه‌ها و فاکتورهای مؤثر بر آن می‌باشند.

وسعت قابل توجهی از کشور ایران را مناطق خشک و نیمه‌خشک شامل می‌شوند. با توجه به مقادیر اندک ماده آلی و سایر عوامل پیوند دهنده ذرات در خاک‌های مناطق خشک و نیمه‌خشک، خاکدانه‌ها از پایداری بسیار پایینی برخوردار هستند (Bouajila & Gallali, 2008). ارزیابی پایداری خاکدانه‌ها به روش الگوترا، یکی از مناسب‌ترین شاخص‌ها برای بیان وضعیت خاک‌ها (به‌عنوان مثال، از دیدگاه کیفیت فیزیکی و فرسایش بادی) در مناطق خشک و نیمه‌خشک است. با توجه به محدود شدن درک مسایل خاک (از جمله شاخص MWD) در نتیجه تعداد زیاد متغیرهای مؤثر بر فرآیندهای مرتبط با خاک و پیچیدگی زیاد روابط بین این متغیرها، بررسی قابلیت الگوریتم ترکیبی ژنتیک-شبکه عصبی مصنوعی (GA-ANN) به‌منظور شناسایی یک زیرمجموعه مناسب از ویژگی‌های مؤثر بر شاخص MWD، هدف اصلی این پژوهش می‌باشد. به‌علاوه، تعیین درجه اهمیت هر یک از ویژگی‌های مؤثر بر پایداری خاکدانه‌ها (آنالیز حساسیت) از دیگر اهداف پژوهش حاضر می‌باشد.

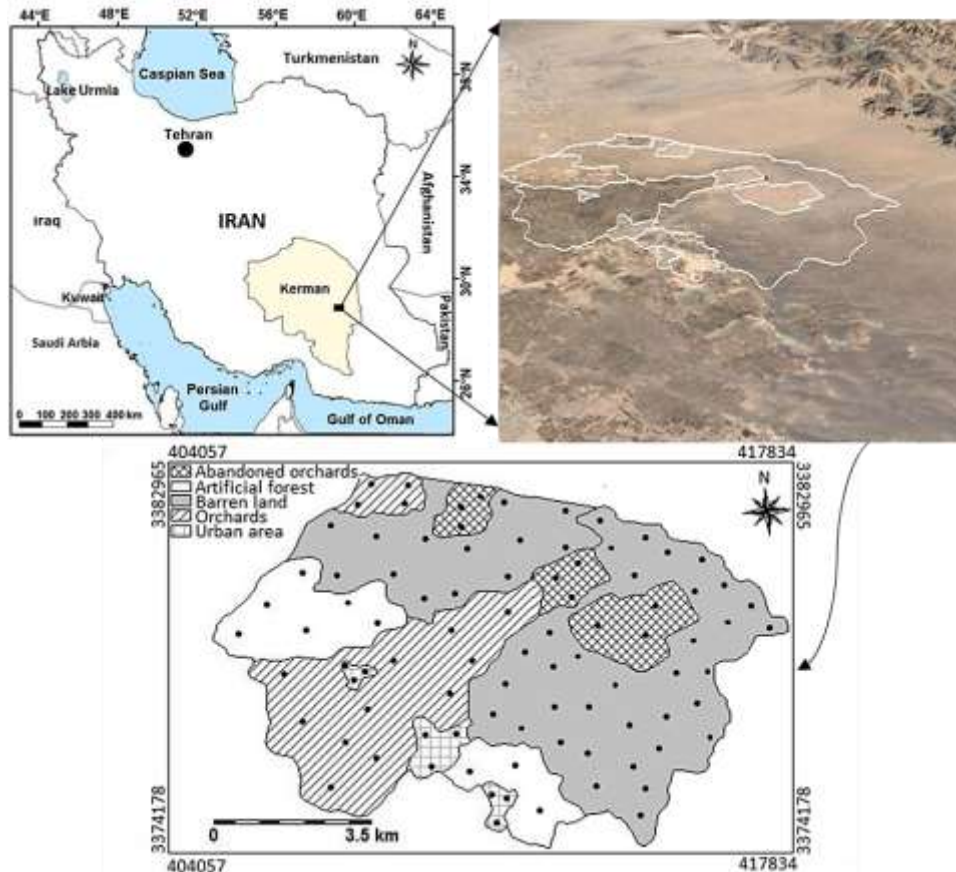
مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه شامل بخشی از اراضی شهرستان رفسنجان (دشت داوران)، واقع در شمال غرب استان

3. ILWIS
4. Global Positioning System, GPS

1. Adaptive Neuro-Fuzzy Inference Systems
2. Supervised random soil sampling



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه به همراه ۹۰ نقطه نمونه برداری

Figure 1. Geographical location of the study area along with 90 sampling points

خاک به روش سیلندر تعیین شدند. برای اندازه‌گیری رطوبت، نمونه‌های خاک بلافاصله پس از برداشت در بسته‌های پلاستیکی ریخته شدند و در آزمایشگاه میزان رطوبت آن‌ها با استفاده از روش وزنی تعیین گردید. به‌منظور تعیین پایداری خاکدانه‌ها به روش خشک، نمونه‌های خاک بدون کوبیدن از الک چهار میلی‌متر عبور داده شدند. سپس ۵۰ گرم از خاک الک شده روی یک سری الک شامل ۰/۱، ۰/۲۵، ۰/۵ و دو میلی‌متر (بر اساس استاندارد ASTM) به‌طور یکنواخت ریخته شد. سپس نمونه‌های خاکدانه به مدت سه دقیقه توسط دستگاه شیکر الک تکان داده شدند. پس از پایان فرآیند الک کردن، خاکدانه‌های باقی‌مانده بر روی هر الک توزین گردیدند. سپس خاکدانه‌های مربوط به هر الک، خرد شدند و ذرات شن و سنگریزه آن‌ها جدا گردیدند و بدین ترتیب، وزن واقعی خاکدانه‌های باقی‌مانده بر روی هر الک محاسبه شد. در نهایت، شاخص MWD به‌عنوان

پس از هوا خشک شدن نمونه‌های خاک جمع‌آوری شده و عبور آن‌ها از الک دو میلی‌متری (به‌جز نمونه‌های خاک برداشت شده برای سنجش پایداری خاکدانه‌ها)، به‌منظور حذف بقایای گیاهی و سنگریزه‌ها، این نمونه‌ها مورد آنالیز قرار گرفتند. اجزای بافت خاک شامل درصد شن، سیلت و رس به روش هیدرومتری (Gee & Bauder, 1986) و پ‌هاش خاک (pH) در گل اشباع با استفاده از دستگاه پی‌اچ‌متر اندازه‌گیری گردیدند. قابلیت هدایت الکتریکی (EC) عصاره اشباع خاک با استفاده از دستگاه هدایت‌سنج و درصد ماده آلی (OM) به روش واکلی و بلاک (Walkley & Black, 1934) تعیین شدند. اندازه‌گیری کلسیم و منیزیم در عصاره اشباع خاک به روش کمپلکسومتری و سدیم به روش شعله‌سنجی صورت پذیرفت. علاوه بر آن، مقادیر کربنات کلسیم معادل (CCE) به روش خنثی‌سازی با اسید کلریدریک، گچ به روش استون (Nelson, 1982) و چگالی ظاهری

3. Calcium carbonate equivalent
4. American Society for Testing and Materials

1. Electrical conductivity
2. Organic matter

جنبه‌های مختلف، از جمله اهمیت و چگونگی تأثیر بر پایداری خاکدانه‌ها مورد بررسی قرار گرفتند؛ به گونه‌ای که پس از مرور منابع مختلف (به‌عنوان مثال، Besaltpour et al., 2014; Obalum et al., 2019)، ۱۱ ویژگی خاک شامل ماده آلی، کربنات کلسیم معادل، رطوبت، رس، شن، سیلت، گچ، نسبت جذب سدیم، قابلیت هدایت الکتریکی، چگالی ظاهری و پهاش به‌عنوان ورودی‌های الگوریتم گفته شده، در نظر گرفته شدند.

الگوریتم ژنتیک (GA)

در این الگوریتم، برای تولید نسل جدید از کروموزوم‌های نسل جاری، از سه عملگر ژنتیکی انتخاب، تقاطع و جهش استفاده شد. ویژگی‌های استفاده شده برای الگوریتم ژنتیک توسعه داده شده در پژوهش حاضر، در جدول ۱ نشان داده شده‌اند.

جدول ۱- پارامترهای الگوریتم ژنتیک مورد استفاده در پژوهش حاضر
Table 1. Parameters of the genetic algorithm used in this research

Population no.	Iteration no.	Crossover rate	Mutation rare	Compound crossover operator		
				Two-point probability	One-point probability	Uniform probability
50	100	0.8	0.02	0.1	0.2	0.8

داده‌های آزمون مد نظر قرار گرفتند. به‌منظور تعیین بهترین توپولوژی برای شبکه عصبی مصنوعی، آزمون‌های متعدد سعی و خطا صورت گرفت و در نهایت، پارامترهای شبکه عصبی مصنوعی مورد استفاده در پژوهش حاضر به شرح جدول ۲ تعیین گردیدند.

جدول ۲- ویژگی‌های شبکه عصبی مصنوعی چند لایه مورد استفاده در پژوهش حاضر

Table 2. Characteristics of the multi-layer perception (MLP) neural network used in this research

Hidden layers no.	Neurons no.	Epoch no.	Training algorithm	Transfer function in hidden layer	Transfer function in output layer
1	10	500	Levenberg-Marquardt	tansig	linear

تولید شده، برای ارزیابی آن‌ها بر اساس تابع شایستگی به شبکه عصبی مصنوعی وارد شدند. در پژوهش حاضر، داده‌ها در شبکه عصبی مصنوعی به دو بخش داده‌های آموزشی و آزمون به نسبت ۷۰ به ۳۰ تقسیم‌بندی شدند و خطای مربوط به هر جایگشت با استفاده از این داده‌ها محاسبه گردید. بر اساس پارامترهای در نظر گرفته شده

شاخصی از پایداری خاکدانه‌ها با استفاده از معادله (۱) تعیین گردید (Kemper & Rosenau, 1986):

$$MWD = \sum_{i=1}^n w_i \bar{X}_i \quad (1)$$

که در این رابطه، w_i نسبت وزن خاکدانه‌های باقی مانده روی الک i به وزن کل خاک مورد استفاده در آزمایش، \bar{X}_i میانگین قطر خاکدانه‌های باقی مانده بر روی الک i و n تعداد کل الک‌ها می‌باشند.

انتخاب ویژگی

در این پژوهش، از مدل ترکیبی الگوریتم ژنتیک-شبکه عصبی مصنوعی (GA-ANN) به‌منظور انتخاب یک زیرمجموعه مناسب از ویژگی‌های مؤثر بر پایداری خاکدانه‌ها استفاده شد. برای در نظر گرفتن پارامترهای ورودی به مدل GA-ANN، پارامترهای پیشنهادی از

شبکه عصبی مصنوعی (ANN)

برای توسعه یک شبکه MLP، نیاز به تقسیم‌بندی داده‌ها به سه گروه آموزشی، اعتبارسنجی و آزمون است. در این پژوهش، ۶۰ درصد داده‌ها به‌عنوان داده‌های آموزشی، ۲۰ درصد به‌عنوان داده‌های اعتبارسنجی و ۲۰ درصد به‌عنوان

مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی مصنوعی (GA-ANN)

در این پژوهش، ۱۱ ویژگی خاک به‌عنوان ورودی به مدل معرفی شدند. بنابراین، مدل به صورت تصادفی تعداد ۵۰ جایگشت (برابر با اندازه جمعیت) از هر ترکیب n -تایی ویژگی‌ها (از ۱ تا ۱۱) تولید کرد. سپس جایگشت‌های

در این پژوهش، به منظور بررسی میزان حساسیت شاخص MWD نسبت به تغییرات مکانی ویژگی‌های خاک انتخاب شده توسط مدل ترکیبی GA-ANN، از روش هیل^۳ استفاده شد که خلاصه کارهای انجام شده به صورت زیر می‌باشد:

در ابتدا همه متغیرهای انتخاب شده توسط مدل ترکیبی GA-ANN بدون تغییر، به شبکه عصبی مصنوعی توسعه داده شده وارد شدند و خروجی مدل (y)، به ازای هر رکورد از داده‌ها محاسبه شد. سپس، یکی از ورودی‌های مدل (p)، انتخاب شد و مقدار عددی آن به میزان ۱۰ درصد تغییر داده شد (p*) و خروجی جدید مدل (y*) به ازای هر رکورد از داده‌ها محاسبه گردید. تفاوت مقداری بین y و y* به ازای هر رکورد از داده‌ها (Δy) بر اساس معادله (۴) به دست آمد:

$$\Delta y = y^* - y \quad (4)$$

مقدار عددی به دست آمده Δy برای هر رکورد از داده‌ها بر مقدار عددی p* متناظر خود تقسیم شد (معادله ۵):

$$m = \frac{y^* - y}{p^*} = \frac{\Delta y}{p^*} \quad (5)$$

مقدار عددی به دست آمده m به ازای هر رکورد، در مقدار عددی p متناظر خود ضرب گردید (معادله ۶):

$$n = m \times p \quad (6)$$

مقدار به دست آمده n به ازای هر رکورد از داده‌ها در مقدار متناظر خود ضرب شد (معادله ۷):

$$S = n \times n = n^2 \quad (7)$$

میانگین مقادیر Sهای به دست آمده بر اساس معادله (۸) محاسبه گردید (N برابر با تعداد رکوردها است):

$$\bar{S} = \text{mean}(S) = \frac{S_1 + S_2 + \dots + S_N}{N} \quad (8)$$

در نهایت، ضریب حساسیت ویژگی تغییر داده شده با استفاده از معادله (۹) تعیین شد:

$$\text{Sensitivity} = \sqrt{\bar{S}} \quad (9)$$

ارزیابی عملکرد مدل‌ها

به منظور بررسی کارایی و صحت‌سنجی نتایج مدل‌های مورد استفاده، از برخی شاخص‌های آماری نظیر ضریب تبیین (R²)، مجذور میانگین مربعات خطا (RMSE) و میانگین درصد خطای مطلق (MAEP) استفاده شد:

برای مدل، شبکه عصبی مصنوعی برای هر جایگشت از ویژگی‌ها به تعداد ۱۰ بار اجرا شد و مقدار نهایی خطا با استفاده از شاخص مجذور میانگین مربعات خطا (RMSE) بر اساس معادله (۲) به دست آمد:

$$RMSE = 0.7E_{train} + 0.3E_{test} \quad (2)$$

که در آن، E_{train}، خطای داده‌های آموزشی و E_{test}، خطای داده‌های آزمون است. شاخص مجذور میانگین مربعات خطا (RMSE) خود بر اساس معادله (۳) محاسبه گردید:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [M(x_i) - P(x_i)]^2} \quad (3)$$

که در آن، n تعداد رکوردها، M(x_i) داده‌های مشاهده‌ای و P(x_i) داده‌های برآورد شده (تخمینی) می‌باشند. بعد از محاسبه شاخص خطا، جایگشت شایسته‌تر از میان سایر جایگشت‌های مربوط به هر ترکیب n-تایی از ویژگی‌ها، انتخاب شد. پس از پایان هر چرخه، معیارهای توقف الگوریتم از قبیل شاخص خطا و تعداد رکوردها به منظور تعیین توقف الگوریتم یا از سرگیری چرخه بررسی گردیدند. لازم به ذکر است که برنامه‌نویسی‌های مربوط به شبکه MLP و مدل GA-ANN در نرم‌افزار متلب^۴ (نسخه ۲۰۱۵) انجام شد.

مدل‌سازی پایداری خاکدانه‌ها

پیش‌بینی تغییرات پایداری خاکدانه‌ها در پاسخ به تغییرات مکانی ویژگی‌های خاک با استفاده از شبکه عصبی مصنوعی و رگرسیون چند متغیره خطی انجام شد.

رگرسیون چند متغیره خطی (MLR)

در پژوهش حاضر، با توسعه یک مدل رگرسیون چند متغیره خطی (MLR) در محیط نرم‌افزار SPSS 16.0، قابلیت این رویکرد مدل‌سازی در جهت پیش‌بینی رابطه بین شاخص پایداری خاکدانه‌ها (MWD) و ویژگی‌های خاک انتخاب شده به وسیله الگوریتم ترکیبی GA-ANN ارزیابی گردید.

آنالیز حساسیت

3. Hill

4. Mean absolute Error Percentage

1. Root Mean Square Error

2. MATLAB

ویژگی در بین ترکیب‌های تولیدشده، کم‌ترین میزان خطا ($RMSE = 1/23$) را دارا بود (شکل ۲). شش ویژگی انتخاب‌شده شامل ماده آلی، رس، شن، کربنات کلسیم معادل، نسبت جذب سدیم و قابلیت هدایت الکتریکی بودند. پژوهش‌های متعددی در ارتباط با نقش ماده آلی بر روی پایداری خاکدانه‌ها وجود دارند. کورتین و مولن (Curtin & Mullen, 2002) نشان دادند که کربن آلی، مهم‌ترین عامل تأثیرگذار بر میانگین هندسی قطر خاکدانه‌ها می‌باشد. بر اساس نتایج پژوهش شیرانی و همکاران (Shirani et al., 2015)، ماده آلی با پیوند ذرات معدنی خاک باعث شکل‌گیری خاکدانه‌ها و افزایش پایداری آنها می‌شود و از این طریق، بهبود کیفیت فیزیکی خاک را موجب می‌گردد.

توزیع اندازه ذرات خاک، یکی از مهم‌ترین عوامل مؤثر بر پایداری خاکدانه‌ها است، به طوری که تأثیر نسبت‌های مختلف ذرات معدنی (درصد شن، سیلت و رس) بر پایداری خاکدانه‌ها همواره مورد پژوهش قرار گرفته است. بر اساس نتایج حاصل از پژوهش عسگری و سرپرست (Asgari & Sarparast, 2013)، ذرات رس با پایداری خاکدانه و تشکیل ساختمان خاک، رابطه مستقیم و معنی‌داری دارند. ترنان و همکاران (Ternan et al., 1996) از رس به‌عنوان ملات بین ذرات خاک نام بردند و دریافتند که افزایش میزان رس، بهبود پایداری خاکدانه‌ها را به دنبال دارد.

ذرات شن بر خلاف ذرات رس، دارای بار الکتریکی و سطح ویژه قابل ملاحظه نمی‌باشند. بنابراین، می‌توان دلیل احتمالی انتخاب درصد ذرات شن به‌عنوان یک ویژگی مهم در ارتباط با پایداری خاکدانه‌ها را به اثرات منفی این ذرات بر روی پایداری خاکدانه‌ها مربوط دانست. محمودآبادی و احمدبیگی (Mahmoodabadi & Ahmadbeygi, 2013) با بررسی اثر توزیع اندازه ذرات خاک بر روی پایداری خاکدانه‌ها دریافتند که درصد ذرات شن با خاکدانه‌های پایدار (بزرگتر از ۰/۲۵ میلی‌متر) در آب، همبستگی معنی‌دار و منفی دارد. در مناطق خشک و نیمه‌خشک که مقدار ماده آلی خاک‌ها پایین است، عامل سیمانی‌کننده‌ای مانند کربنات‌ها می‌تواند مشابه ماده آلی عمل کرده و هم‌آوری ذرات و شکل‌گیری ساختمان خاک را باعث شود.

(۱۰)

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^n \frac{|M(x_i) - P(x_i)|}{P(x_i)} \right) \times 100$$

در این رابطه، $M(x_i)$ و $P(x_i)$ به ترتیب، مقادیر مشاهده‌ای و برآوردشده و n تعداد کل مشاهدات می‌باشند.

تجزیه و تحلیل آماری داده‌ها

در پژوهش حاضر، از نرم‌افزار آماری SPSS 16.0 به‌منظور محاسبه پارامترهای آماری داده‌های اندازه‌گیری شده از قبیل میانگین، میانگین، بیشینه، کمینه، ضریب تغییرات و ضریب چولگی استفاده گردید.

نتایج و بحث

توصیف آماری داده‌ها

خلاصه آماری ویژگی‌های اندازه‌گیری شده خاک‌های مورد مطالعه در جدول ۳ ارائه شده است. در بین ذرات معدنی خاک، بالاترین درصد مربوط به ذرات شن (میانگین ۸۳/۵۸ درصد) و پایین‌ترین درصد مربوط به ذرات رس (میانگین ۷/۰۲ درصد) بود. به‌گونه‌ای که لوم شنی، کلاس بافتی غالب در خاک‌های مورد مطالعه بود. در بین خصوصیات خاک اندازه‌گیری شده، کم‌ترین درصد ضریب تغییرات مربوط به پهاش خاک (۴/۱۶ درصد) بود. آهکی بودن خاک‌های منطقه و خاصیت بافری بالای این خاک‌ها را می‌توان دلیلی بر پایین بودن ضریب تغییرپذیری واکنش آن‌ها عنوان کرد. بر خلاف پهاش خاک، ماده آلی بالاترین ضریب تغییرپذیری (۱۳۴/۱ درصد) را شامل شد. تغییرپذیری و عدم یکنواختی بالای ماده آلی در خاک‌های مورد مطالعه، احتمالاً به دلیل اضافه کردن کودهای آلی به خاک‌های اراضی باغی نسبت به سایر کاربری‌ها بوده است. به‌طور کلی، ضریب تغییرات به‌دست آمده برای اغلب ویژگی‌های خاک بالا می‌باشد. در واقع، نقاط نمونه‌برداری به‌گونه‌ای انتخاب شدند که اثر احتمالی هر کدام از ویژگی‌های خاک بر روی شاخص پایداری خاکدانه‌ها قابل بررسی و ارزیابی باشد.

انتخاب ویژگی با استفاده از الگوریتم ترکیبی GA-ANN


نتایج اجرای الگوریتم GA-ANN برای انتخاب پارامترهای مؤثر بر شاخص MWD نشان داد که ترکیبی با شش

جدول ۳- توصیف آماری ویژگی‌های خاک اندازه‌گیری شده در خاک‌های مورد مطالعه
Table 3. Statistics summary of the soil properties measured in the studied soils

Parameter	Mean	Median	Max.	Min.	Skewness	Coefficient of Variation (%)
MWD (mm)	0.18	0.07	0.89	0.00	1.41	122.7
Organic matter (%)	1.00	0.85	3.65	0.08	2.26	134.1
Sand (%)	83.58	88.50	99.00	45.00	-1.20	17.77
Clay (%)	7.02	5.75	27.50	0.00	1.23	87.25
Silt (%)	9.36	5.50	36.00	0.50	1.29	98.83
Bulk density (g (cm ³) ⁻¹)	1.49	1.51	1.81	1.30	0.20	6.70
Moisture (%)	1.84	1.11	9.33	0.31	3.01	85.91
Gypsum (meq 100g ⁻¹ soil)	0.07	0.01	0.27	0.00	1.29	92.80
Calcium carbonate equivalent (%)	16.89	14.28	34.02	1.50	1.24	33.12
Sodium adsorption ratio (mmol l ⁻¹) ^{0.5}	19.45	18.82	77.12	1.91	3.07	28.19
Electrical conductivity (dS m ⁻¹)	17.30	16.13	48.26	1.15	0.51	64.72
pH	7.92	7.35	8.15	7.68	0.18	4.16

جهت تأثیر املاح محلول بر ساختمان خاک می‌باشند. سدیم، عنصری با شعاع یونی کم و شعاع هیدراته زیاد است که در صورت قرار گرفتن در فازهای تبادل خاک، می‌تواند تخریب ساختمان خاک را سبب شود (Tedeschi & Dell'Aquila, 2005; Zaker *et al.*, 2017). تجادا و همکاران (Tejada *et al.*, 2006) دریافتند که یون‌های سدیم در محلول خاک با انبساط و پراکنش ذرات خاک، سبب کاهش پایداری ساختمان خاک می‌گردند. در اغلب پژوهش‌های انجام‌شده در ارتباط با نقش قابلیت هدایت الکتریکی بر پایداری خاکدانه‌ها، رابطه بین این دو ویژگی خاک، معنی‌دار و مثبت گزارش شده است. ساین و همکاران (Singh *et al.*, 2014) مشاهده نمودند که افزایش املاح محلول از طریق کاهش ضخامت لایه پخشیده دوگانه^۱ می‌تواند منجر به هم‌آورد شدن ذرات خاک و تشکیل ساختمان خاک گردد.


بر اساس نتایج حاصل از پژوهش‌های بسالت‌پور و همکاران (Besalatpour *et al.*, 2014) و بوجیلا و گالالی (Bouajila & Gallali, 2008)، کربنات کلسیم معادل، یکی از مهم‌ترین ویژگی‌های خاک در ارتباط با پایداری خاکدانه‌ها و ساختمان خاک است. امرسون و گرین‌لند (Emerson & Greenland, 1990) ضمن مطالعه نقش کربنات‌ها در شکل‌گیری ساختمان خاک، دریافتند که کربنات‌ها می‌توانند به‌عنوان منبع یون کلسیم به ورود کلسیم به محلول خاک کمک کرده و در نتیجه عمل هم‌آوری ذرات خاک را تسهیل و تسریع کنند. بر اساس نتایج مدل مورد استفاده، نسبت جذب سدیم و قابلیت هدایت الکتریکی از دیگر ویژگی‌های مؤثر بر پایداری خاکدانه‌ها بودند. تا کنون پژوهش‌های متعددی در ارتباط با نقش املاح محلول بر شکل‌گیری یا تخریب خاکدانه‌ها و ساختمان خاک انجام شده‌اند. به‌طور کلی، شعاع یونی و شعاع هیدراته یون‌ها تعیین‌کننده میزان و



شکل ۲- نتایج الگوریتم GA-ANN برای ۱۱ متغیر ورودی
Figure 2. GA-ANN model results for the 11 input variables

مقادیر اندازه‌گیری شده و مقادیر برآورد شده شاخص MWD با استفاده از مدل MLP وجود دارد. در طول فرآیند مدل‌سازی شاخص پایداری خاکدانه‌ها با استفاده از مدل MLP، پدیده بیش‌برازش با استفاده از داده‌های اعتبارسنجی کنترل گردید. به‌گونه‌ای که برخلاف ضریب تبیین بالای به‌دست آمده برای داده‌های آموزش، مقدار ضریب مذکور برای داده‌های آزمون نیز بالا و قابل پذیرش بود.

برآورد پایداری خاکدانه‌ها با استفاده از مدل MLP شش ویژگی خاک انتخاب‌شده توسط الگوریتم، به‌عنوان پارامترهای ورودی شبکه MLP برای مدل‌سازی شاخص MWD در نظر گرفته شدند و نتایج حاصل در شکل ۳ نشان داده شده‌اند. با توجه به نتایج، مقادیر ضریب تبیین (R^2) به‌دست آمده برای داده‌های آموزشی، برابر با ۰/۹۸ و برای داده‌های اعتبارسنجی، برابر با ۰/۹۴ بود. این یافته‌ها نشان می‌دهند که همبستگی قابل قبولی بین



شکل ۳- مقایسه مقادیر مشاهده‌ای و برآوردشده شاخص MWD توسط مدل MLP برای داده‌های آموزشی (الف) و داده‌های آزمون (ب)

Figure 3. The comparison of the actual MWD values against the predicted MWD values by the MLP model for training data (a) and test data (b)

داده شده می‌باشد و هنگامی که مقادیر این شاخص‌ها برابر با صفر است، بهترین حالت عملکرد مدل اتفاق افتاده است (Singh *et al.*, 2005). مقادیر به‌دست آمده معیارهای ارزیابی خطا نیز بیان‌گر آن است که مدل MLP توسعه داده شده قادر بوده با دقت قابل قبولی رابطه بین شاخص MWD و ویژگی‌های ورودی را پیش‌بینی کند.

برآورد پایداری خاکدانه‌ها با استفاده از مدل MLP مقادیر محاسبه‌شده شاخص‌های آماری RMSE و MAPE برای داده‌های آموزشی، به‌ترتیب برابر با ۰/۰۲۵ و ۱۱/۶۱ درصد و برای داده‌های آزمون، به‌ترتیب برابر با ۰/۰۷۵ و ۲۱/۳۹ درصد بودند (جدول ۴). به‌طور کلی، هر چه مقادیر عددی شاخص‌های آماری گفته‌شده به صفر نزدیک‌تر باشند، نشان‌دهنده عملکرد بهتر مدل توسعه

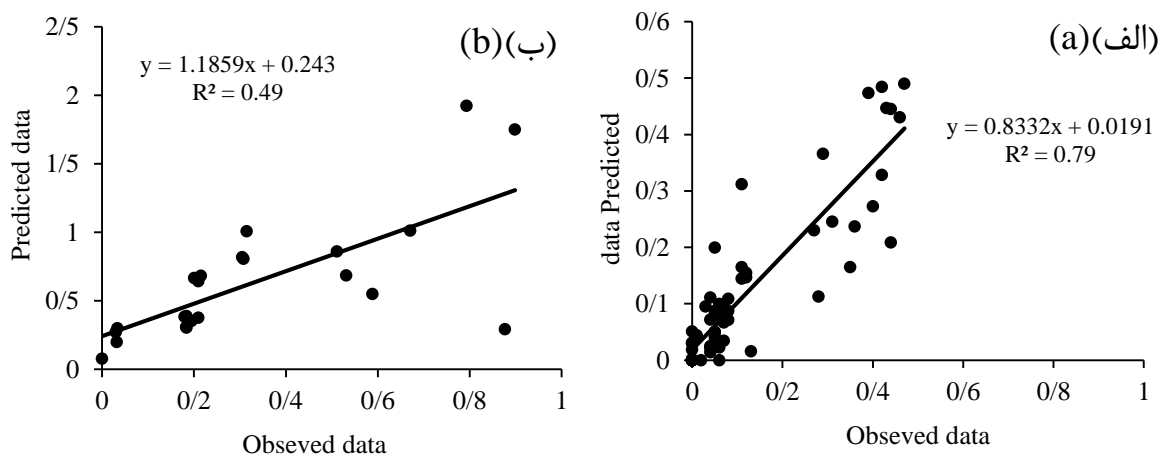
جدول ۴- معیارهای آماری مورد استفاده برای ارزیابی کارایی مدل MLP
Table 4. The validation statistics used to evaluate the performance of the MLP model

Data	Evaluation criteria		
	MAPE (%)	RMSE (%)	R ²
Training data	11.61	0.025	0.98
Testing data	21.39	0.075	0.94

درصد ماده آلی و کربنات کلسیم معادل وجود دارد، در حالی که این رابطه در مورد درصد ذرات شن و نسبت جذب سدیم، یک رابطه منفی است. نتایج حاصل از عملکرد مدل رگرسیون چند متغیره خطی استفاده شده به منظور پیش‌بینی شاخص MWD در پاسخ به تغییرات مکانی ویژگی‌های خاک در شکل ۴ نشان داده شده است.

$$MWD = 1.205 - 0.009(Sand) + 0.43(OM) - 0.007(SAR) + 0.189(CCE) \quad (11)$$

برآورد پایداری خاکدانه‌ها با استفاده از مدل MLR به منظور مدل‌سازی پایداری خاکدانه‌ها با استفاده از رگرسیون چند متغیره خطی، مشابه مدل MLP از ویژگی‌های انتخاب‌شده به وسیله الگوریتم ترکیبی به عنوان ورودی استفاده شد. مدل رگرسیونی به دست آمده برای برآورد شاخص MWD (معادله ۱۱) نشان می‌دهد که یک رابطه مثبت بین پایداری خاکدانه‌ها و



شکل ۴- مقایسه مقادیر مشاهده‌ای و برآوردشده شاخص MWD توسط مدل MLR برای داده‌های آموزشی (الف) و داده‌های آزمون (ب)

Figure 4. The comparison of the actual MWD values against the predicted MWD values by the MLR model for training data (a) and test data (b)

است که عمومیت مدل MLR نیز بسیار پایین بوده است. توانایی ضعیف مدل MLR در پیش‌بینی رابطه بین پایداری خاکدانه‌ها و ویژگی‌های خاک انتخاب‌شده را می‌توان در مقادیر محاسبه‌شده برای شاخص‌های آماری RMSE و MAPE نیز مشاهده نمود. به گونه‌ای که این شاخص‌ها برای داده‌های آموزشی، به ترتیب برابر با ۰/۰۵ و ۳۷/۲۳ درصد و برای داده‌های آزمون، به ترتیب برابر با ۰/۴۴ و ۱۲۷ درصد می‌باشند (جدول ۵).

با توجه به نتایج به دست آمده، مقادیر مشاهده‌ای و برآوردشده شاخص MWD، پراکندگی زیادی در اطراف خط رگرسیون دارند. به گونه‌ای که مقادیر ضریب تبیین به دست آمده برای داده‌های آموزشی، برابر با ۰/۷۹ و برای داده‌های اعتبارسنجی، برابر با ۰/۴۹ می‌باشد. این نتایج نشان می‌دهند که تفاوت در مقادیر مشاهده‌ای و برآوردشده شاخص پایداری خاکدانه‌ها با استفاده از مدل MLR، نسبتاً زیاد بوده است. علاوه بر آن، مقدار ضریب تبیین به دست آمده برای داده‌های آموزشی بیانگر آن

جدول ۵- معیارهای آماری استفاده شده برای ارزیابی کارایی مدل MLR

Table 5. The validation statistics used to evaluate the performance of the MLR model

Data	Evaluation criteria		
	MAPE (%)	RMSE (%)	R ²
Training data	37.23	0.05	0.79
Testing data	127	0.44	0.49


بررسی درجه اهمیت ویژگی‌های ورودی بر شاخص MWD

در این پژوهش، به منظور بررسی میزان حساسیت شاخص MWD نسبت به ویژگی‌های خاک انتخاب شده توسط مدل ترکیبی GA-ANN، از روش هیل استفاده شد و نتایج به دست آمده در شکل ۵ نشان داده شده‌اند. بر اساس نتایج، شاخص پایداری خاکدانه‌ها حساسیت قابل توجهی به تغییرات مکانی کربنات کلسیم معادل (ضریب حساسیت برابر با ۰/۰۴) در مقایسه با سایر ویژگی‌های ورودی به مدل دارد. با توجه به مقادیر بالای اندازه‌گیری شده کربنات کلسیم معادل در خاک‌های مورد مطالعه به دلیل عدم آبشویی کربنات‌ها (جدول ۳)، این ویژگی سیمانی‌کننده به عنوان یکی از تأثیرگذارترین عوامل می‌تواند سبب هم‌آورد شدن ذرات اولیه خاک، شکل‌گیری خاکدانه‌ها و بهبود شرایط ساختمان خاک گردد. نتایج حاصل از پژوهش تاتارکو و همکاران (Tatarko *et al.*, 2001) نشان دادند که کربنات کلسیم معادل با فراهم‌آوردن شرایط برای هم‌آوری ذرات خاک، باعث شکل‌گیری خاکدانه‌ها و افزایش پایداری ساختمان خاک در خاک‌های درشت بافت می‌شود.

علاوه بر کربنات کلسیم معادل، دو ویژگی درصد شن و ماده آلی با ضرایب حساسیت به ترتیب ۰/۰۲ و ۰/۰۱ به عنوان متغیرهای حساس در ارتباط با تخمین شاخص MWD تعیین گردیدند. ذرات شن به واسطه نداشتن بار الکتریکی و سطح ویژه قابل توجه، سبب کاهش معنی‌دار پایداری خاکدانه‌ها و ساختمان خاک می‌گردند. اصغری و نجفیان (Asghari & Najafian, 2015) و شکفته و همکاران (Shekofteh *et al.*, 2017) گزارش کردند که ماده آلی یکی از مهم‌ترین عوامل پیونددهنده ذرات اولیه خاک است که از این طریق می‌تواند شکل‌گیری خاکدانه‌ها و پایداری آن‌ها را به شدت تحت تأثیر قرار دهد.

مقایسه عملکرد مدل‌های MLP و MLR در برآورد پایداری خاکدانه‌ها

مقادیر محاسبه شده معیارهای ارزیابی خطا (جدول‌های ۴ و ۵) نشان می‌دهند که نتایج حاصل از مدل MLP نسبت به مدل MLR از دقت و عمومیت بالاتری برخوردار می‌باشند. اینگل بای و کوروو (Ingleby & Crowe, 2001) با مقایسه عملکرد مدل‌های رگرسیونی و شبکه عصبی مصنوعی در برآورد کربن آلی خاک، عملکرد بهتر مدل شبکه عصبی مصنوعی را نسبت به مدل رگرسیونی گزارش کردند. این پژوهشگران بیان نمودند که مقادیر محاسبه شده شاخص میانگین مربعات خطا (MSE) برای عملکرد مدل شبکه عصبی مصنوعی و مدل رگرسیونی چند متغیره، به ترتیب ۵/۴۳ و ۶/۲۳ بودند. وجود روابط غیرخطی میان متغیرهای وابسته و پیش‌بینی‌کننده، می‌تواند از دلایل عملکرد ضعیف مدل‌های رگرسیونی نسبت به شبکه عصبی مصنوعی باشد (Schaap *et al.*, 1998). اسفندیارپور بروجنی و همکاران (Esfandiarpour-Borujeni *et al.*, 2018) از شبکه‌های عصبی مصنوعی و رگرسیون چند متغیره خطی برای برآورد عملکرد درختان پسته استفاده کردند و دریافتند که شبکه‌های عصبی مصنوعی به دلیل توانایی قدرت یادگیری و پردازش اطلاعات، پیش‌بینی خود را با خطای خیلی کمتری نسبت به روش‌های رگرسیونی چند متغیره خطی انجام می‌دهند. مدل‌های رگرسیونی تنها قادر به تشخیص روابط خطی و ساده بین متغیرهای مستقل و وابسته هستند و چنانچه روابط غیرخطی و مبهم بین متغیرها وجود داشته باشد، کارایی این رویکرد به حد قابل ملاحظه‌ای کاهش می‌یابد. در حالی که شبکه‌های عصبی مصنوعی قادر به استخراج روابط پیچیده غیرخطی، حتی در صورت مبهم بودن ماهیت مسئله می‌باشند (Shirani *et al.*, 2018).



شکل ۵- تعیین اهمیت ویژگی‌های ورودی در برآورد شاخص MWD

Figure 5. Determining the importance of the input features in predicting the MWD index

می‌باشد. با این وجود، با توجه به وقت‌گیر بودن و هزینه‌بر بودن اندازه‌گیری ویژگی‌های مؤثر بر پایداری خاکدانه‌ها، مدل‌سازی این پارامتر خاک به تنهایی، اهمیت و ضرورتی ندارد. در واقع، در رویکرد تخمین (به‌عنوان مثال برآورد پایداری خاکدانه‌ها با استفاده از ویژگی‌های مؤثر بر روی آن)، عمومیت داشتن مدل (امکان کاربرد مدل برای سایر مناطق با چالش‌های مشابه) ضروری می‌باشد. در حالی که در آزمون تحلیل حساسیت، عمومیت و اعتبار مدل برای تخمین مسئله مورد نظر در سایر مناطق مورد توجه نیست؛ بلکه هدف اصلی بررسی روابط بین متغیرها در منطقه مورد مطالعه می‌باشد که ممکن است با استفاده از آزمون همبستگی خطی امکان‌پذیر نباشد. با این وجود، استفاده از سایر الگوریتم‌های فرابتکاری مانند الگوریتم کلونی مورچگان^۱ و الگوریتم کرم شب‌تاب^۲ و سایر روش‌های تحلیل حساسیت مانند روش تغییر در ضریب تبیین و روش استات‌سافت‌آدر راستای دستیابی به اهداف پژوهش حاضر و مقایسه عملکرد و نتایج آن‌ها، برای مطالعات آتی نیز می‌تواند مد نظر پژوهشگران قرار گیرد.

References

- Asgari H.R., and Sarparast M. 2013. The impact of Haloxylonplantation on some soil erodibility indices on the sandy lands of Taybad. *Environmental Erosion Research Journal*, 3 (10): 1-12. (In Persian)
- Ashgari S., and Najafian M. 2015. Interactive effects of organic matters and earthworm on some physical and chemical properties of two soils under different compaction conditions. *Applied Soil Research*, 3(1): 89-102. (In Persian)

3. Statsoft

1. Ant Colony Optimization
2. Firefly Algorithm

- Besalatpour A.A., Ayoubi S., Hajabbasi M.A., Jazi A.Y., and Gharipour A. 2014. Feature selection using parallel genetic algorithm for the prediction of geometric mean diameter of soil aggregates by machine learning methods. *Arid Land Research and Management*, 28(4): 383-394.
- Bouajila A., and Gallali T. 2008. Soil organic carbon fractions and aggregate stability in carbonated and no carbonated soils in Tunisia. *Journal of Agron*, 7(2): 127-137.
- Curtin J.S., and Mullen G.J. 2002. Spent mushroom compost effect on aggregate stability and percent organic carbon on low organic matter tilled soils. Life Science Department, University of Limerick, Limerick.
- Emerson W.W., and Greenland D.J. 1990. Soil aggregates-formation and stability. In: De Boodt, M., Hayes, M., Herbillon, A. (Ed.), *Soil colloids and their associations in aggregates*. Plenum Press, New York, pp. 485-511.
- Esfandiarpour-Borujeni I., Hosseinifard S.J., Shirani H., Zeinadini M., and Besalatpour A.A. 2018. Identifying Soil and Plant Nutrition Factors Affecting Yield in Irrigated Mature Pistachio Orchards. *Communications in soil science and plant analysis*, 49(12): 1474-1490.
- Etminan S., Kiani F., Khormali F., and Habashi H. 2011. Effect of soil properties with different parent materials on aggregate stability: in Shastkola watershed, Golestan province. *Journal of Soil Management and Sustainable Production*, 1(2): 39-60. (In Persian)
- Gee G.W., and Bauder J.W. 1986. Particle size analysis. In: Klute, A. (Ed.), *Methods of Soil Analysis: Part 1. American Society of Agronomy and Soil Science Society of America*, Madison, pp. 383-411.
- Ingleby H.R., and Crowe T.G. 2001. Neural network models for predicting organic matter content in Saskatchewan soils. *Canadian Biosystems Engineering*, 43 (7): 1-5.
- Karimi H., Soufi M., Haghnia G., and Khorasani R. 2008. Investigation of aggregate stability and soil erosion potential in some loamy and sandy clay loam soils: case study in Lamerd watershed (south of Fars province). *Journal of Agricultural Sciences and Natural Resources*, 14(6): 348-356. (In Persian)
- Kemper W.D., and Rosenau R.C. 1986. Aggregate stability and size distribution. In: *Methods of Soil Analysis, Part 1. Physical and Mineralogical Methods*. Agronomy Monograph No. 9. *Society of Agronomy/Soil Science Society of America*, Madison, pp. 425-442.
- Khazaei A., Mosaddeghi M.R., and Mahboubi A.A. 2008. Test conditions, and soil organic matter, clay and calcium carbonate contents' impacts on mean weight diameter and tensile strength of aggregates from some Hamadan soils. *Journal of Agricultural and Natural Resource Sciences and Technology*, 44(4): 123-135. (In Persian)
- Mahmoodabadi M., and Ahmadbeygi B. 2013. Effect of primary particle size distribution on aggregate stability at different size classes. *Water Soil Science*, 23(3): 207-219. (In Persian)
- Merdun H., Çınar Ö., Meral R., and Apan M. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research*, 90(2): 108-116.
- Nelson R.E. 1982. Carbonate and gypsum. In: Page, A.L. (Ed.), *Methods of Soil Analysis: Part 1. Agronomy Handbook 9. American Society of Agronomy and Soil Science Society of America*, Madison, pp. 181-197.
- Nikpur M., Mahboubi A.A., Mosaddeghi M.R., and Safadoust A. 2012. Assessment of soil intrinsic properties effects on soil structural stability of some soils in Hamadan province. *Journal of Agricultural and Natural Resource Sciences and Technology*, 15(58): 85-96. (In Persian)
- Obalum S.E., Uteau-Puschmann D., and Peth S. 2019. Reduced tillage and compost effects on soil aggregate stability of a silt-loam Luvisol using different aggregate stability tests. *Soil and Tillage Research*, 189: 217-228.
- Schaap M.G., Leij F.J., and 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.
- Shekofteh H., Ramazani F., and Shirani H. 2017. Optimal feature selection for predicting soil CEC: Comparing the hybrid of ant colony organization algorithm and adaptive network-based fuzzy system with multiple linear regression. *Geoderma*, 298: 27-34.

- Shirani H., 2018. Artificial Neural Networks with an Application in Agricultural and Natural Resource Sciences, 2nd Ed. Vali-E-Asr University of Rafsanjan, 189p. (In Persian)
- Shirani H., Habibi M., Besalatpour A.A., and Esfandiarpour I. 2015. Determining the features influencing physical quality of calcareous soils in a semiarid region of Iran using a hybrid PSO-DT algorithm. *Geoderma*, 259: 1-11.
- Shirani H., Hosseinifard S.J., and Hashemipour H. 2018. Factors affecting cadmium absorbed by pistachio kernel in calcareous soils, southeast of Iran. *Science of the Total Environment*, 616: 881-888.
- Singh A.K., Bordoloi L.J., Kumar M., Hazarika S., and Parmar B. 2014. Land use impact on soil quality in eastern Himalayan region of India. *Environmental monitoring and assessment*, 186(4): 2013-2024.
- Singh J., Knapp H.V., Arnold J.G., and Demissie M. 2005. Hydrological modeling of the Iroquois river watershed using HSPF and SWAT 1. *JAWRA Journal of the American Water Resources Association*, 41(2): 343-360.
- Tatarko J., 2001. Soil aggregation and wind erosion: processes and measurements. *Annals of Arid Zone*, 40(3): 251-264.
- Tedeschi A., and Dell'Aquila R. 2005. Effects of irrigation with saline waters, at different concentrations, on soil physical and chemical characteristics. *Agricultural Water Management*, 77(1-3): 308-322.
- Tejada M., Garcia C., Gonzalez J.L., and Hernandez M.T. 2006. Use of organic amendment as a strategy for saline soil remediation: influence on the physical, chemical and biological properties of soil. *Soil Biology and Biochemistry*, 38(6): 1413-1421.
- Ternan J.L., Elmes A., Williams A.G., and Hartley R. 1996. Aggregate stability of soils in central Spain and the role of land management. *Earth Surface Processes and Landforms*, 21(2): 181-193.
- Veihe A., and Quinton J. 2000. Sensitivity analysis of EUROSEM using Monte Carlo simulation I: hydrological, soil and vegetation parameters. *Hydrological Processes*, 14(5): 915-926.
- Walkley 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(1): 29-38.
- Whalen J.K., Hu Q., and Liu A. 2003. Compost applications increase water-stable aggregates in conventional and no-tillage systems. *Soil Science Society of America Journal*, 67(6): 1842-1847.
- Wu B., Zhang L., and Zhao Y. 2013. Feature selection via Cramer's V-test discretization for remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 52(5): 2593-2606.
- Zaker M., Emami H., Astarai A., and Fotovat A. 2017. Soil physical properties as affected by potassium and salinity of irrigation water. *Applied Soil Research*, 6(1): 51-61. (In Persian)

Determining the Features Influencing the Structural Stability of Soils of Arid Regions Using a Hybrid GA-ANN Algorithm

Iraj Kouchami-Sardoo¹, Hosein Shirani², Isa Esfandiarpour-Boroujeni^{3*}, Ali Asghar Besalatpour⁴

(Received: October 2019 Accepted: December 2019)

Abstract

Aggregate stability of soils informs about their relative strengths against erosive forces and mechanical disruption. In this research, a hybrid Genetic Algorithm-Artificial Neural Network method was used to select the best subset of features affecting the mean weight diameter (MWD). In addition, the ability of ANNs and multiple linear regression (MLR) for quantifying the relationship between the MWD index and some soil properties was assessed. After the modeling process, the importance of the selected features in relation to spatial variability of aggregate stability was investigated. In order to prepare a suitable data set; MWD index and some soil features were measured in collected soils from 90 sampling points. Feature selection results showed that six soil features including clay, sand, organic matter, calcium carbonate, electrical conductivity, and sodium adsorption ratio had the greatest effect on the aggregates stability of the studied soils. According to the MWD modeling results, the obtained values of coefficient of determination (R^2), mean absolute error percentage (MAEP), and root mean square error (RMSE) for the ANN model performance were 0.94, 21.39, and 0.07% respectively. These findings indicated that the developed ANN model was able to predict the complex and nonlinear relationships between the MWD index and the soil properties selected by the algorithm. Based on the sensitivity analysis results, calcium carbonate equivalent, sand particles, and organic matter were identified as key factors in estimating aggregate stability. Overall, this study provides a robust framework for the prediction of aggregate stability and identifying the most determinant parameters influencing it in arid and semi-arid soils that could be applied to other regions with similar challenges.

Keywords: Optimization, mean weight diameter, multiple linear regression, sensitivity analysis

Kouchami-Sardoo I., Shirani H., Esfandiarpour-Boroujeni I. and Besalatpour A.A. 2020. Determining the features influencing the structural stability of soils of arid regions using a hybrid GA-ANN algorithm. *Applied Soil Research*. 8(3): 129-143.

1. PhD Student, Department of Soil Science, College of Agriculture, Vali-e-Asr University of Rafsanjan

2. Professor, Department of Soil Science, Faculty of Agriculture, Vali-e-Asr University of Rafsanjan

3. Associate Professor, Department of Soil Science, Faculty of Agriculture, Vali-e-Asr University of Rafsanjan

4. Assistance Professor, Department of Soil Science, Faculty of Agriculture, Vali-e-Asr University of Rafsanjan

* Corresponding Author Email: esfandiarpour@vru.ac.ir