

مدل‌سازی شاخص S و تعیین عوامل مؤثر بر آن با استفاده از الگوریتم هیبرید شبیه‌سازی تبرید - شبکه عصبی مصنوعی در خاک‌های آهکی جنوب شرق ایران

فهیمة امیری میجان^{۱*}، حسین شیرانی^۱، عیسی اسفندیارپور^۱، علی اصغر بسالت‌پور^۲ و حسین شکفته^۳

(تاریخ دریافت: ۱۳۹۷/۱/۱۹؛ تاریخ پذیرش: ۱۳۹۷/۱۱/۲)

چکیده

استفاده از شیب منحنی مشخصه رطوبتی خاک در نقطه عطف (شاخص S)، یکی از شاخص‌های مهم ارزیابی کیفیت خاک در برنامه‌ریزی مدیریت اراضی زراعی و باغی محسوب می‌شود. هدف از این پژوهش، تعیین مؤثرترین ویژگی‌های خاک در منطقه جیرفت بر تخمین شاخص S با استفاده از الگوریتم هیبرید شبیه‌سازی تبرید - شبکه عصبی مصنوعی بود. به این منظور، ۳۵۰ نمونه خاک دست‌خورده و ۳۵۰ نمونه خاک دست‌نخورده از اراضی زراعی و باغی برداشت و سپس برخی از ویژگی‌های فیزیکی و شیمیایی خاک، شامل درصد شن، سیلت، رس، قابلیت هدایت الکتریکی اشباع، چگالی ظاهری، درصد تخلخل کل، درصد مواد آلی و درصد کربنات کلسیم معادل با استفاده از روش‌های استاندارد اندازه‌گیری شدند. همچنین با استفاده از دستگاه صفحات فشاری، مقدار رطوبت خاک در مکش‌های ۰، ۱۰، ۳۰، ۵۰، ۱۰۰، ۳۰۰، ۵۰۰ و ۱۰۰۰ و ۱۵۰۰ کیلوپاسکال تعیین شد. در ادامه با استفاده از الگوریتم هیبریدی شبکه عصبی مصنوعی - شبیه‌سازی تبرید، ویژگی‌های مؤثر بر مدل‌سازی شاخص S استخراج شدند. در نهایت با استفاده از پنج ویژگی استخراج شده (درصد ش و رس، قابلیت هدایت الکتریکی، چگالی ظاهری و ظرفیت زراعی)، مدل‌سازی شاخص S توسط شبکه عصبی مصنوعی انجام شد. نتایج نشان داد که با کاهش متغیرهای ورودی، دقت مدل‌سازی افزایش یافت. به‌علاوه، نتایج آنالیز حساسیت نشان داد چگالی ظاهری با بالاترین ضریب حساسیت (ضریب حساسیت ۰/۵) به‌عنوان مهم‌ترین ویژگی در مدل‌سازی شاخص S محسوب می‌شود. بنابراین، از آنجا که افزایش تعداد ویژگی‌ها لزوماً باعث افزایش دقت مدل‌سازی نمی‌شود، کاهش ویژگی‌های ورودی به‌سبب کاهش هزینه و زمان انجام پژوهش مقرون به‌صرفه است.

واژه‌های کلیدی: کیفیت فیزیکی خاک، انتخاب ویژگی، تحلیل حساسیت، الگوریتم‌های تکاملی

۱. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه ولیعصر (عج) رفسنجان

۲. مؤسسه مدیریت یکپارچه منابع آب، برلین، آلمان

۳. گروه مهندسی علوم خاک، دانشکده کشاورزی، دانشگاه جیرفت

*: مسئول مکاتبات: پست الکترونیکی: fahime.amiri@gmail.com

مقدمه

خواهد بود؛ زیرا مواد آلی به شدت کیفیت فیزیکی خاک را تحت تأثیر قرار می دهند. دکستر اظهار داشت هرچند همواره با افزایش چگالی ظاهری خاک، شاخص S کاهش نمی یابد، لیکن این شاخص به تغییرات چگالی ظاهری خاک حساس است. کالنگو و رسولوم نیز نشان دادند که تناوب زراعی و شخم می توانند منجر به افزایش مقدار شاخص S به میزان ۰/۰۳۵ در خاکی به عمق ۲۰ سانتی متر شوند. در هر حال، تعداد پژوهش های انجام شده در مورد شاخص S، به عنوان یکی از پارامترهای بیان کننده کیفیت فیزیکی خاک، چندان زیاد نیست. هرچند پژوهش های دامنه دار دکستر، جزء موارد جالب توجه این پژوهش ها هستند؛ اما در این پژوهش ها ارتباط شاخص S با ویژگی های مختلف خاک، اغلب از طریق روش رگرسیون خطی بررسی شده است.

امروزه به دلیل گسترش دانش و پیچیده تر شدن تصمیم گیری، استفاده از دانش های نوین از جمله هوش مصنوعی اهمیت بیشتری پیدا کرده است. تاکنون استفاده از ترکیب الگوریتم های تکاملی با روش های مدل سازی غیرخطی (مانند شبکه عصبی مصنوعی، درخت تصمیم و غیره) به منظور مدل سازی شاخص S صورت نگرفته است. لازم به ذکر است که فرایند انتخاب ویژگی برای دو حالت تخمین و طبقه بندی ویژگی ها کاربرد دارد (۴۸). تخمین زیرمجموعه، همیشه نظارت شده است، در حالی که طبقه بندی ویژگی ها را می توان نظارت شده و یا در برخی موارد غیر نظارت شده انجام داد (۱۳ و ۴۸). با به کار بردن تکنیک های انتخاب ویژگی می توان محاسبات ضروری و دقت پیش بینی را بهبود بخشید و زمان اجرای محاسبات را کاهش داد (۱۲). الگوریتم های تکاملی زیرمجموعه ای از محاسبات تکاملی بوده و در شاخه هوش مصنوعی قرار می گیرند. الگوریتم های تکاملی شامل الگوریتم های برای جستجو هستند که در آنها عمل جستجو از چندین نقطه در فضای جواب صورت می گیرد.

یکی از الگوریتم های تکاملی کارآمد شبیه سازی ترید است، که یک الگوریتم فرا ابتکاری ساده و اثربخش در حل مسائل

مفهوم کیفیت خاک در دهه ۱۹۹۰ مورد توجه پژوهشگران قرار گرفته است (۴۶) و یکی از جنبه های مهم مدیریتی در خاک است (۲۶). در واقع، کیفیت خاک ابزاری است که می تواند تصمیم های مدیریتی را که سبب توسعه کشاورزی پایدار می شود، تسهیل کند (۴). در هر حال، حفظ یا بهبود کیفیت خاک می تواند باعث استمرار در باروری خاک و افزایش کارایی عناصر غذایی شود. به دلیل اهمیت کیفیت فیزیکی خاک، ارزیابی کمی آن، با هدف ارائه راهکار به سیستم های دولتی به منظور ایجاد و توسعه کشاورزی پایدار لازم و ضروری است (۱۹). لیکن از آنجا که کیفیت خاک به صورت مستقیم قابل اندازه گیری نیست، بسیاری از پژوهشگران به دنبال پیدا کردن راهی بوده اند تا آن را به صورت غیرمستقیم اندازه گیری کنند (۳۴). در نتیجه شاخص های مختلفی برای این منظور طراحی و استفاده شده اند که از آن جمله می توان به شیب منحنی مشخصه رطوبتی خاک در نقطه عطف یا شاخص S اشاره کرد (۱۵، ۱۶ و ۱۷).

منحنی مشخصه رطوبتی خاک، یکی از مهم ترین ویژگی های هیدرولیکی مورد نیاز برای مدل کردن جریان آب در محیط غیراشباع خاک است که در مسائل مربوط به کیفیت فیزیکی خاک، از اهمیت ویژه ای برخوردار است. به طور معمول، تغییر جهت این منحنی در نقطه ای اتفاق می افتد که به نام نقطه عطف منحنی شناخته می شود. شاخص S که بر مبنای شیب منحنی مشخصه رطوبتی خاک در نقطه عطف برای اولین بار توسط دکستر مورد توجه قرار گرفت، تحت تأثیر ویژگی های فیزیکی و شیمیایی خاک از جمله توزیع اندازه ذرات، ماده آلی خاک، چگالی ظاهری و غیره است (۱۵). وی بیان کرد با افزایش درصد رس، شاخص S در یک دامنه معینی افزایش پیدا می کند و در بیش از آن مقدار، افزایش رس منجر به کاهش شاخص S می شود. به علاوه، وی نشان داد که مقدار شاخص S با افزایش مقدار ماده آلی، به صورت خطی افزایش می یابد و هر چه مقدار رس در خاک کمتر باشد، اثر ماده آلی بر شاخص S بیشتر

مورد مطالعه در یک دوره آماری ۲۸ ساله، به ترتیب، ۱۵۹ میلی‌متر و ۳۲/۹ درجه سلسیوس هستند. این منطقه یکی از مناطق مهم کشاورزی در ایران بوده و از اهمیت ویژه‌ای برخوردار است. بر این اساس، منطقه مورد مطالعه شامل کاربری‌های مختلف از جمله کاربری مرکبات، نخیلات، زراعی، ترکیبی (خرما- یونجه) و جنگل (گونه انارشیطان) با نام علمی *Tecomella Undulata* است.

روش نمونه‌برداری

در ابتدا نقشه توپوگرافی منطقه با مقیاس ۱:۲۵۰۰۰ تهیه شد. پس از پیاده کردن محدوده مطالعاتی روی این نقشه و اسکن کردن آن، با استفاده از نرم‌افزار ایلویس (نسخه ۳/۴)، منطقه مزبور زمین مرجع شد. سپس ۳۵۰ نقطه، به عنوان نقاط مطالعاتی انتخاب شدند (شکل ۱). در ادامه، موقعیت هریک از نقاط مشاهداتی با استفاده از سامانه موقعیت‌یاب جهانی در صحرا مشخص شد و از عمق صفر تا ۲۰ سانتی‌متری هر نقطه مشاهداتی، ۳۵۰ نمونه دست‌خورده با استفاده از بیلچه و ۳۵۰ نمونه دست‌نخورده با استفاده از سیلندرهایی به ارتفاع ۵/۵ و قطر ۴/۵ سانتی‌متر برداشت و به آزمایشگاه منتقل شدند. لازم به ذکر است فواصل نمونه‌برداری در کاربری مرکبات و نخیلات ۱۰۰ متر، در کاربری زراعی ۲۵۰ متر، در کاربری ترکیبی (خرما- یونجه) متغیر و در کاربری جنگل (گونه انارشیطان) ۷۰ متر بود.

اندازه‌گیری ویژگی‌های فیزیکی و شیمیایی خاک

نمونه‌های دست‌خورده بعد از هوا خشک شدن، از ال‌ک دو میلی‌متری عبور داده شدند. سپس بافت خاک به روش هیدرومتری (۸)، مواد آلی خاک به روش والکی و بلک (۴۵)، کربنات کلسیم معادل به روش خشتی‌سازی با اسید کلریدریک (۱)، قابلیت هدایت الکتریکی عصاره اشباع توسط دستگاه EC متر (۳۹) و pH گل اشباع توسط دستگاه pH متر (۳۹) اندازه‌گیری شدند. چگالی ظاهری به روش سیلندر (۶) و منحنی مشخصه رطوبتی خاک با استفاده از دستگاه صفحات فشاری، روی نمونه‌های دست‌نخورده اندازه‌گیری شدند. تخلخل خاک

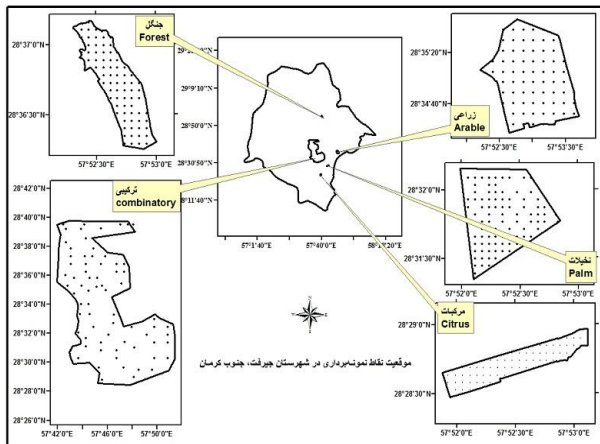
بهینه‌سازی است. این تکنیک شامل قرار دادن ماده در دمای بالا و سپس کم کردن تدریجی این دماست. انتخاب دمای مناسب برای شروع اجرای الگوریتم بسیار مهم و حیاتی است. چنانچه اگر مقادیر بسیار بزرگ دما همراه با نرخ کاهش دما آهسته انتخاب شود، موجب طولانی شدن مدت اجرای الگوریتم و گسترش فضای جستجو می‌شود. درحالی که مقادیر بسیار کوچک دما ممکن است موجب همگرایی زود هنگام الگوریتم شده و الگوریتم در بهینه محلی متوقف شود.

با توجه به اهمیت منطقه جیرفت از لحاظ تنوع ژنتیکی و محصولات کشاورزی، بررسی وضعیت کیفیت فیزیکی خاک ضروری به نظر می‌رسد. همچنین به نظر می‌رسد تاکنون پژوهشی درخصوص تعیین ویژگی‌های فیزیکی و شیمیایی مهم و مؤثر بر شاخص S و مدل‌سازی آن به‌ویژه در خاک‌های آهکی این منطقه به‌وسیله الگوریتم‌های قوی مانند SA-ANN انجام نشده است. بنابراین پژوهش حاضر با هدف انتخاب مهم‌ترین و مؤثرترین ویژگی‌های فیزیکی و شیمیایی خاک بر شاخص S در خاک‌های آهکی با استفاده از الگوریتم شبیه‌سازی تبرید - شبکه عصبی مصنوعی، کاربرد شبکه عصبی مصنوعی برای مدل‌سازی شاخص S با استفاده از ویژگی‌های انتخاب شده و تعیین اهمیت متغیرهای ورودی در مدل‌سازی شاخص S به‌روش تحلیل حساسیت انجام شد.

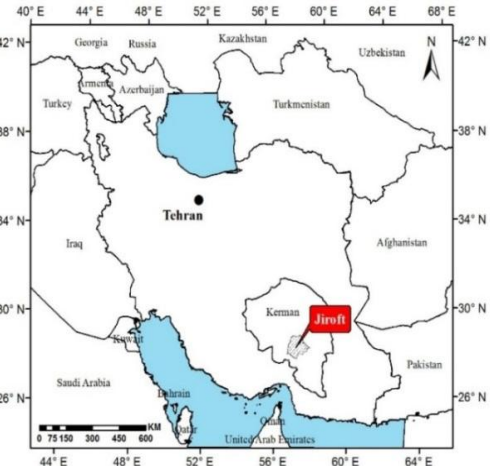
مواد و روش‌ها

منطقه مورد مطالعه

منطقه مطالعاتی شامل بخش‌هایی از اراضی زراعی و باغی شهرستان جیرفت، واقع در جنوب‌شرقی ایران است که در حد فاصل عرض‌های جغرافیایی ۵۵°۱۴۴ تا ۳۲°۳۹۶۹۷ شمالی و طول‌های جغرافیایی ۳۱°۲۴۵۳ تا ۵۰°۰۸۰۱ شرقی واقع شده است (شکل ۱). میانگین ارتفاع منطقه از سطح دریا‌های آزاد، ۶۸۱ متر است. خاک‌های دشت جیرفت عموماً جز خاک‌های رده‌های اریدی‌سول و انتی‌سول هستند. آب‌وهوای منطقه از نوع گرم و خشک است. میانگین بارندگی و دمای سالانه منطقه



ب.



الف.

شکل ۱. الف) موقعیت شهرستان جیرفت در جنوب کرمان، ایران و ب) موقعیت نقاط نمونه برداری در شهرستان جیرفت

مشتق‌گیری از معادله ۴، معادله شاخص S (معادله ۵) به‌دست آمد. باید خاطر نشان کرد که نقطه عطف در منحنی مشخصه رطوبتی، نقطه‌ای است که منحنی تغییر جهت می‌دهد و انحنا در آن صفر است. شیب در نقطه عطف منحنی مشخصه رطوبتی که شاخص S نامیده می‌شود، منفی است، اما برای سهولت کار به‌صورت مثبت بیان می‌شود (۱۵).

$$S = -n(\theta_{sat} - \theta_{res}) \left(1 + \frac{1}{m}\right)^{-(1+m)} \quad (3)$$

تعاریف پارامترهای معادله ۳ مشابه تعریف پارامترها در معادله ۲ است.

مدل‌سازی شاخص S

الگوریتم شبیه‌سازی تبرید (Anneling Algorithm Simulated) شبیه‌سازی تبرید یا دمایی، یکی از الگوریتم‌های فرا ابتکاری شناخته شده در زمینه الگوریتم‌های هوش مصنوعی است و به‌طور گسترده‌ای در مسائل بهینه‌سازی استفاده می‌شود. طبیعت تصمیم‌گیری در این الگوریتم به این‌صورت است که یک پاسخ جدید به‌صورت تصادفی ایجاد و برای حرکت ارزیابی می‌شود. اساساً بیشتر الگوریتم‌های فرا ابتکاری با مدل‌سازی و شبیه‌سازی یکی از قوانین یا روابط موجود در طبیعت وضع شده‌اند. این الگوریتم که بر اساس فرایند سردسازی یا تبرید فلزات طراحی شده است، اهمیت بالایی دارد (۱۱ و ۲۷).

(F) نیز با استفاده از معادله ۱ محاسبه شد (BD چگالی ظاهری و PD چگالی حقیقی خاک):

$$F = 1 - \frac{BD}{PD} \quad (1)$$

محاسبه شاخص S

با استفاده از دستگاه صفحات فشاری، رطوبت خاک در مکش‌های ۰، ۱۰، ۳۰، ۵۰، ۱۰۰، ۳۰۰، ۵۰۰، ۱۰۰۰ و ۱۵۰۰ کیلوپاسکال تعیین شد. یکی از مهم‌ترین و پرکاربردترین مدل‌های برازش منحنی مشخصه رطوبتی خاک، معادله ون‌گونوختن (معادله ۲) است که تا کنون توسط بسیاری از پژوهشگران مورد توجه قرار گرفته است. این معادله به‌شکل زیر است:

$$\theta = (\theta_{sat} - \theta_{res}) \left[1 + (\alpha h)^n\right]^{-m} + \theta_{res} \quad (2)$$

که θ مقدار آب در مکش θ_{res} (kg/kg) h مقدار رطوبت باقی‌مانده θ_{sat} (kg/kg) مقدار رطوبت در حالت اشباع (kg/kg) و α فاکتور مقیاس است که عکس مکش در نقطه ورود هوا است. m و n فاکتورهای شکل منحنی مشخصه رطوبتی خاک هستند که شیب این منحنی را کنترل می‌کنند. با برازش نقاط مختلف در منحنی مشخصه رطوبتی خاک توسط نرم‌افزار RETC بر اساس مدل ون‌گونوختن و با محدودیت معلم $(m = 1 - \frac{1}{n})$ ، پارامترهای مدل به‌دست آمدند. آنگاه با

توپولوژی شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یکی از تلاش‌های صورت گرفته برای توسعه مدلی است که مشابه با مغز انسان کار کند (۱۴).

روش ANN از مدل‌های غیرخطی بوده و در برابر تغییرات ناگهانی پایدار است. از طرفی توانایی آموزش و تعمیم را در محیط‌هایی که از نظر داده غنی هستند، دارا است (۳۶). این نوع مدل شامل یک یا چند لایه به صورت مخفی و یک لایه خروجی است. معمولاً داده‌ها به داده‌های آموزشی و آزمونی تقسیم می‌شوند. شایان ذکر است که هر کدام از لایه‌ها در شبکه عصبی مصنوعی دارای یک و یا چند نرون هستند. (۳۲). از ویژگی‌های مهم ANN، توانایی برقراری ارتباط بین ورودی و خروجی یک فرایند، بدون در نظر گرفتن فیزیک آن مسئله است (۳۷). ویژگی‌های مدل شبکه عصبی مصنوعی مورد استفاده در پژوهش حاضر در جدول ۱ ارائه شده‌اند.

الگوریتم شبکه عصبی مصنوعی - شبیه‌سازی تبرید

انتخاب ویژگی، تکنیکی است که برای انتخاب زیرمجموعه‌ای از ویژگی‌های مرتبط با یک هدف خاص به کار می‌رود و مهم‌ترین اصل در این فرایند، انتخاب ویژگی‌های پایدار و حذف داده‌های مازاد است (۲۹). یکی از روش‌های کارآمد در انتخاب ویژگی، استفاده از الگوریتم‌های تکاملی است. بر این اساس، فرایند انتخاب ویژگی با توجه به حداقل خطای ممکن، مؤثرترین زیرمجموعه ویژگی‌ها را از مجموعه کل ویژگی‌های ورودی بیرون می‌کشد و ویژگی‌های اضافی که اثری روی مدل‌سازی ندارند و یا اثر ناچیزی دارند، حذف می‌کند. در این روش، یک الگوریتم تکاملی با یک روش مدل‌سازی غیرخطی مانند شبکه عصبی مصنوعی ترکیب شده و یک الگوریتم هیبرید به دست می‌آید که می‌تواند روابط پیچیده و غیرخطی را به خوبی شبیه‌سازی کند و ویژگی‌های مؤثر بر متغیر هدف را با دقت مناسبی استخراج کند. در پژوهش حاضر، ابتدا شاخص S با استفاده از معادله ون‌گونختن (۴۴) محاسبه شد. برنامه‌نویسی الگوریتم SA-ANN در محیط متلب ۲۰۱۴ انجام شد، در ادامه به منظور اجرای مدل، ویژگی‌های فیزیکی و شیمیایی خاک

به عنوان متغیر ورودی و شاخص S به عنوان متغیر هدف در محیط نرم‌افزار متلب وارد شدند. با اجرای الگوریتم SA-ANN، مؤثرترین ویژگی‌ها در مدل‌سازی شاخص S استخراج شدند (۱۳). به منظور انتخاب ویژگی در الگوریتم هیبرید SA-ANN، به طور کلی داده‌ها به دو دسته آموزشی و آزمون تقسیم شدند و برای محاسبه خطای مدل، از میانگین وزنی خطاهای آموزشی و آزمون به صورت زیر استفاده شد:

$$\text{Error}_{\text{ff}} = 0.8 \text{ error}_{\text{tr}} + 0.2 \text{ error}_{\text{tt}}$$

در رابطه بالا، Error_{ff} ، error_{tr} و error_{tt} به ترتیب خطای نهایی مدل به ازای هر دسته d تایی از ویژگی‌ها، خطای داده‌های آموزشی و تست هستند. RMSE نیز شاخص خطا است که در قسمت بعدی توضیح داده شده است. با توجه به اینکه در فرایند انتخاب ویژگی، هدف تشخیص ویژگی‌های مهم و مؤثر بر متغیر هدف است و نه برآورد آن، لذا خطای داده‌های آموزشی اهمیت خیلی بیشتری دارد، زیرا رابطه بین متغیرهای ورودی و هدف با استفاده از داده‌های آموزشی به دست می‌آید.

ارزیابی مدل

مجموعه داده‌ها به دو دسته آموزشی و تست تقسیم شدند. ۷۰ درصد از کل مجموعه داده‌ها به عنوان مجموعه آموزشی و ۱۵ درصد به عنوان مجموعه تست انتخاب شدند. مابقی داده‌ها به عنوان داده‌های اعتبارسنجی به کار رفتند. به منظور اعتبارسنجی مدل‌سازی، RMSE استفاده شد (۳۵):

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_p - X_o)^2} \quad (4)$$

به علاوه، به منظور تعیین بیش‌برآورد و یا کم‌برآورد مدل، از شاخص GMER مطابق معادله ۵ استفاده شد:

$$\text{GMER} = \exp \left[\frac{1}{N} \sum_{i=1}^N \ln \left(\frac{X_p}{X_o} \right) \right] \quad (5)$$

که X_o مقادیر مشاهده شده، X_p مقادیر پیش‌بینی شده و N تعداد کل مشاهدات است.

آنالیز حساسیت

آنالیز حساسیت به منظور کمی‌سازی همبستگی بین متغیرهای ورودی و خروجی انجام می‌شود و همچنین تعیین می‌کند که

جدول ۱. پارامترهای شبکه عصبی مصنوعی مورد استفاده

MLP*	Kind of ANN
۱	No. of hidden layers
۲۵	No. of neuron in hidden layer
**LM	Training algorithm
Linear	Transfer function in output layer
Tansig	Transfer function in hidden layer
۱۰۰	No of epochs
۷۰	Percentage of training data
۱۵	Percentage of testing data
۱۵	Percentage of validating data

*Multilayer Perceptron, **Levenberge Marquardt

هستند که در مسیر سیلاب‌های کوهستانی جیرفت تشکیل شده‌اند. به دلیل بالا بودن دما، تجزیه ترکیبات آلی به سرعت صورت می‌گیرد و بنابراین مواد آلی به خاک اضافه نمی‌کنند. به همین دلیل مقدار مواد آلی خاک‌های جنگل انار شیطان کم است. همچنین بالاترین و کمترین مقدار چگالی ظاهری در کاربری مرکبات دیده شد. کاربری مرکبات تحت مدیریت مناسب کشت‌وکار بوده و سالانه کود دامی به آن اضافه می‌شود. ساختمان خاک مطلوب و دارای تخلخل مناسبی است. از طرفی منطقه مورد مطالعه از نظر شوری دارای پراکنندگی زیادی بوده و بالاترین درصد شوری در کاربری نخیلات و کمترین آن در کاربری جنگل دیده شد. شایان ذکر است بالا بودن مقدار حداکثر نقطه پژمردگی دایم، به دلیل وجود چند نمونه با بافت رسی است که در کاربری زراعی وجود داشت. زیرا مقدار رطوبت در نقطه پژمردگی دائم به بافت خاک بستگی دارد. در مجموع اثر کاربری بر ویژگی‌های فیزیکی و شیمیایی خاک مورد توجه بسیاری از پژوهشگران بوده است به طوری که کارپتر و چانگ (۱۰) بیان کردند کاربری اراضی و مدیریت نیز خاکدانه‌سازی خاک و پایداری خاکدانه‌ها را تحت تأثیر قرار می‌دهد.

انتخاب ویژگی با استفاده از الگوریتم هیبریدی شبکه عصبی مصنوعی - شبیه‌سازی تبرید
در فرایند انتخاب ویژگی، ویژگی‌هایی که در مدل‌سازی متغیر

کدام متغیر بیشترین نقش را در برآورد متغیر خروجی یا همان متغیر هدف دارد (۲۳). در پژوهش حاضر، آنالیز حساسیت به روش هیل (۲۴) برای ویژگی‌های انتخاب شده انجام گرفت. در روش هیل، هر یک از متغیرها یا ویژگی‌های ورودی، به یک مقدار معین (مثلاً ۱۰ درصد) تغییر داده می‌شوند و تأثیر آنها بر خروجی مدل محاسبه شده و مقدار حساسیت مدل نسبت به متغیر ورودی مد نظر به دست می‌آید. هرچه مقدار حساسیت برای یک متغیر ورودی بیشتر باشد، اهمیت آن در مدل‌سازی بیشتر بوده و تأثیر بیشتری بر خروجی و یا متغیر هدف دارد. ضریب حساسیت کمتر از ۰/۱ برای ویژگی‌ها، نشان‌دهنده آن است که آن ویژگی اثر معنی‌داری بر دقت پیش‌بینی مدل ندارد و بنابراین می‌توان آن را از متغیرهای ورودی حذف کرد (۲۴).

نتایج و بحث

آمار توصیفی

برخی آمار توصیفی ویژگی‌های اندازه‌گیری شده خاک با استفاده از نرم‌افزار SPSS (نسخه ۲۰) محاسبه و در جدول ۲ آورده شده‌اند. طبق جدول ۲، بیشترین ضریب تغییرات مربوط به مواد آلی و کمترین آن مربوط به چگالی ظاهری است. به طور میانگین بالاترین درصد مواد آلی در کاربری ترکیبی و کمترین آن در کاربری جنگل دیده شد. جنگل‌های انار شیطان، جنگل‌هایی تنک و با تراکم پایین

جدول ۲. خلاصه اطلاعات آماری ویژگی‌های فیزیکی و شیمیایی ۳۵۰ نمونه از اراضی زراعی، باغی و جنگلی شهرستان جیرفت


ویژگی	واحد	پیشینه	کمینه	میانگین	میانه	SD	CV	چولگی
شن	(%)	۹۱	۱۵	۶۰/۲۲	۶۰/۵	۱۷/۷۴	۰/۲۹	-۰/۱۶۵
رس	(%)	۴۴/۵	۴	۱۴/۵۸	۱۳/۵	۵/۴	۰/۳۷	۱/۵
چگالی ظاهری	(Mg m ⁻³)	۱/۷۸	۱/۳۳	۱/۵۲	۱/۵۲	۰/۱۱۵	۰/۰۷۵	۰/۱۵۳
تخلخل	(%)	۰/۴۹	۰/۳۳	۰/۴۲۵	۰/۴۳	۰/۰۴۳	۰/۱	-۰/۱۵۳
مواد آلی	(%)	۱/۹	۰/۰۲۶	۰/۵۳	۰/۴۹	۰/۳	۰/۵۷	۱/۰۷۶
کربنات کلسیم	(%)	۳۰	۹	۱۲/۷۳	۱۱/۵	۳/۵۶	۰/۲۸	۱/۹۴
هدایت الکتریکی اشباع	(dS m ⁻¹)	۱۸/۹۹	۱/۱	۴/۷	۳/۹۵	۲/۶۷	۰/۵۷	۱/۷۹
رطوبت ظرفیت زراعی	(M ³ M ⁻³)	۰/۴۴	۰/۰۶	۰/۲۴	۰/۲۶	۰/۰۶۶	۰/۲۷	-۰/۳۵
رطوبت پژمردگی دائم	(M ³ M ⁻³)	۰/۱۶۴	۰/۰۰۸۹	۰/۰۶	۰/۰۶۵	۰/۰۲۷	۰/۴۵	۰/۲۸
شاخص S	-	۰/۱	۰/۰۰۱۴	۰/۰۴۸	۰/۰۵	۰/۰۲۲	۰/۴۶	۰/۰۲۹

SD انحراف معیار، CV ضریب تغییرات

بیان کردند که در اکثر موارد، افزایش تعداد متغیرهای ورودی در مدل‌سازی نه تنها سبب صرف زمان زیادی می‌شود، بلکه منجر به کاهش دقت مدل‌سازی نیز می‌شود. همچنین، (۲۸) نشان داد که افزایش تعداد متغیرها اثری روی دقت مدل‌سازی و پیش‌بینی تابع هدف ندارد.

بنابراین، به منظور افزایش دقت پیش‌بینی متغیر هدف، بایستی تعداد متغیرهای ورودی را از طریق حذف متغیرهای مازاد کاهش داد. سانگ و همکاران (۴۲) نیز نشان دادند که با حذف داده‌های مازاد، هم دقت مدل شبکه عصبی مصنوعی بالاتر رفت و هم هزینه جمع‌آوری داده‌ها کاهش پیدا کرد. بنابراین می‌توان نتیجه گرفت که استفاده از الگوریتم هیبرید SA-ANN منجر به کسب نتایج با دقت بالا می‌شود که با نتایج برخی از پژوهشگران مطابقت دارد. (۴۱) برای پیش‌بینی برخی از شاخص‌های کیفیت خاک از جمله ظرفیت آب قابل دسترس گیاه، ظرفیت زراعی نسبی و ظرفیت هوا از الگوریتم هیبرید PSO-DT استفاده کردند. نتایج آنها نشان داد که با این الگوریتم ترکیبی، پیش‌بینی پارامترهای دیرپافت خاک (همچون شاخص‌های کیفیت فیزیکی خاک) با استفاده از داده‌های زودپافت از جمله توزیع اندازه ذرات، چگالی ظاهری و ...

هدف مهم و مؤثر هستند، استخراج می‌شوند. نتایج استفاده از الگوریتم SA-ANN، نشان داد که از بین ۹ ویژگی اندازه‌گیری شده (جدول ۲)، پنج ویژگی شامل درصد شن، درصد رس، چگالی ظاهری، قابلیت هدایت الکتریکی عصاره اشباع خاک و رطوبت ظرفیت زراعی، بیشترین تأثیر را در مدل‌سازی شاخص S داراست. زیرا براساس نتایج ارائه شده در شکل ۲، این زیرمجموعه پنج‌تایی، کمترین خطا را در مدل‌سازی پارامتر هدف (شاخص S) دارد (۴-۱۰×۵۴/۶= RMSE). براساس نتایج شکل ۲، مقدار RMSE با تغییر تعداد ورودی‌ها تغییر می‌کند. نتایج نشان داد که با افزایش تعداد ویژگی‌ها از یک تا پنج ویژگی تا حدودی مقدار RMSE کاهش پیدا کرده است و حداکثر دقت (حداقل RMSE) در شرایطی که پنج ویژگی انتخاب شدند، به دست آمد. با افزایش تعداد ویژگی‌ها از ۵ تا ۹ عدد، مقدار RMSE افزایش یافت و در نتیجه دقت مدل کاهش پیدا کرد. ویژگی‌های منتخب و مقدار RMSE آن در جدول ۲ نشان داده شده است. حذف ویژگی‌های غیرضروری و انتخاب پارامترهای مؤثر در مدل‌سازی متغیر هدف، به وسیله پژوهشگران زیادی بررسی و تأیید شده است. (۲) و (۳۰)



شکل ۲. مقادیر RMSE ویژگی‌ها در روش انتخاب ویژگی

و در نتیجه کیفیت فیزیکی خاک کاهش می‌یابد. یکی دیگر از شاخص‌های بیان کیفیت فیزیکی خاک، پایداری خاکدانه‌ها است که تحت تأثیر مقدار رس مواد آلی، چگالی ظاهری و درصد کربنات کلسیم است. به طوری که (۳۸) دریافتند با افزایش درصد رس پایداری خاکدانه‌ها افزایش می‌یابد. آنها بیان کردند که یکی از عوامل مهم در پیوند دادن ذرات اولیه خاک و تشکیل خاکدانه‌ها، میزان رس است. این نتایج توسط (۴۳) نیز تأیید شده است. همچنین در این پژوهش، یکی دیگر از پارامترهای مؤثر در مدل‌سازی متغیر هدف، چگالی ظاهری خاک معرفی شد. (۱۵) ضمن اشاره به حساس بودن شاخص S به تغییرات چگالی ظاهری خاک، اظهار داشت در خاک با تخلخل پایین و تراکم بالا، کیفیت فیزیکی پایین خواهد بود. بنابراین به دلیل اثری که چگالی ظاهری بر ساختمان خاک و وضعیت خاکدانه‌سازی دارد، می‌تواند روی رشد گیاه، تهویه خاک، انتقال آب و املاح و نگهداشت رطوبت اثرگذار باشد. با توجه به اینکه چگالی ظاهری خاک به بافت نیز بستگی دارد و با افزایش مقدار شن در خاک، چگالی ظاهری افزایش می‌یابد، لذا نمی‌توان گفت که با افزایش چگالی ظاهری، شاخص S کاهش می‌یابد. زیرا افزایش شن در خاک تا حدی به دلیل افزایش منافذ درشت و بهبود تهویه و نفوذپذیری، موجب افزایش شاخص S می‌شود. بر اساس مطالعات (۱۸)، با

امکان پذیر است. بر اساس نتایج حاصل از این پژوهش، از جمله متغیرهای مؤثر در مدل‌سازی شاخص S که در فرایند انتخاب ویژگی استخراج شدند، درصد شن و رس هستند. این نتیجه احتمالاً به دلیل نقش مؤثر مقدار شن در تشکیل و افزایش تعداد ماکروپورها و در نتیجه ایجاد و افزایش منافذ تهویه‌ای است که به بهبود کیفیت فیزیکی خاک کمک می‌کند. همچنین چنانچه خاکی در معرض انبساط و انقباض و تر و خشک شدن متوالی باشد، با افزایش درصد رس، پراکندگی و تخریب خاکدانه‌ها بیشتر شده و این وضعیت روی ساختمان خاک اثر نامطلوب گذاشته و کیفیت فیزیکی خاک را کاهش می‌دهد. اهمیت نقش مقدار شن و رس در کیفیت فیزیکی خاک توسط برخی پژوهشگران تأیید شده است که با نتایج حاصل از این پژوهش همخوانی دارد. برای نمونه، (۳) نشان دادند که بافت و چگالی ظاهری خاک روی کیفیت فیزیکی خاک اثر مستقیم دارند. همچنین (۳۳) و (۷) گزارش دادند که ذرات رس در خاک، حتی در مقادیر جزئی، روی تشکیل ساختمان خاک و بنابراین کیفیت فیزیکی آن اثر چشمگیری دارند. بر اساس (۱۵) حداکثر شاخص S بین مقدار رس ۳۰ تا ۵۰ درصد دیده شد که دلیل آن می‌تواند به علت افزایش تعداد ریزساختمان‌ها در خاک باشد. در هر حال، افزایش مقدار رس از یک حد مشخص، موجب افزایش سخت‌شدگی خاک شده

ویژگی‌های گیاه بستگی دارد. بنابراین از آنجا که ظرفیت زراعی به ویژگی‌های ساختمانی خاک بستگی دارد، منطقی است که به‌عنوان یکی از پارامترهای مهم در برآورد غیرمستقیم کیفیت فیزیکی خاک معرفی شود. بر اساس نتایج حاصل از روش انتخاب ویژگی در این پژوهش، متغیرهای نقطه پژمردگی دائم و کربنات کلسیم معادل، جزء پارامترهای ضروری در مدلسازی شاخص S معرفی نشدند. این موضوع احتمالاً به این دلیل است که نقطه پژمردگی دائم بیشتر تحت تأثیر سطح ویژه ذرات است و متأثر از ساختمان خاک نیست. بنابراین عدم استخراج آن به‌عنوان یکی از ویژگی‌های مؤثر بر شاخص S منطقی به نظر می‌رسد. هرچند با افزایش میزان کربنات کلسیم در خاک، پایداری خاکدانه‌ها افزایش می‌یابد (۵) و در نتیجه از پراکندگی خاکدانه‌ها کاسته می‌شود، اما آهکی بودن همه خاک‌های مورد مطالعه (جدول ۲)، می‌تواند دلیلی بر عدم انتخاب متغیر کربنات کلسیم در مدلسازی باشد؛ زیرا خاک‌های منطقه جیرفت از نوع خاک‌های آهکی هستند و میزان آهک در آنها بالا است.

مدلسازی شاخص S با استفاده از ویژگی‌های انتخاب شده

توسط شبکه عصبی مصنوعی

به‌منظور مدلسازی متغیر هدف (شاخص S) با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه (MLP)، پنج متغیر درصد شن، درصد رس، چگالی ظاهری، قابلیت هدایت الکتریکی اشباع و ظرفیت زراعی حاصل از فرایند انتخاب ویژگی، به‌عنوان متغیرهای ورودی استفاده شدند. از طرفی برای ارزیابی کارایی مدل شبکه عصبی مصنوعی مورد استفاده، نیاز به شاخص‌هایی است که بتوان کارکرد این مدل را در مقایسه با مجموعه داده‌ها قضاوت کرد. از این رو برای افزایش اعتماد به نتایج به دست آمده از ضرایب R^2 ، RMSE و GMER استفاده شد (جدول ۳).

مقدار پایین RMSE نشان‌دهنده این است که مدل به‌خوبی برازش شده است و فرایند مدلسازی از دقت بالایی برخوردار

افزایش چگالی ظاهری، مقدار شاخص S کاهش می‌یابد. همچنین (۱۵) نشان داد اگر مقدار مواد آلی ثابت فرض شود (۱/۵ کیلوگرم بر صد کیلوگرم)، بر اساس یک معادله رگرسیونی بین مقدار چگالی ظاهری و شاخص S، با افزایش چگالی ظاهری، مقدار شاخص S کاهش می‌یابد. همچنین بر اساس برخی پژوهش‌ها اثبات شده است که چگالی ظاهری، خاکدانه‌سازی و پایداری آنها از ویژگی‌های مهم فیزیکی خاک هستند که می‌توانند به شدت تحت عملیات کشاورزی و تغییر کاربری قرار گیرند (۴۷). بنابراین می‌توان نتیجه گرفت که با تغییر درصد رس، چگالی ظاهری، درصد مواد آلی، کیفیت فیزیکی تغییر یابد. همچنین برخی از پژوهشگران نشان دادند که یکی از پارامترهای مهم در تعیین پایداری خاکدانه‌ها در خاک، پوشش گیاهی و کربن آلی خاک هستند (۱۰ و ۲۱). متغیر بعدی استخراج شده از فرایند انتخاب ویژگی که نقش مؤثری در پیش‌بینی شاخص S دارد، قابلیت هدایت الکتریکی است. اهمیت نقش شوری در پایداری ساختمان خاک و کیفیت فیزیکی آن توسط تعدادی از پژوهشگران بررسی و تأیید شده است که با نتایج این پژوهش همخوانی دارد. اثر قابلیت هدایت الکتریکی روی شاخص S احتمالاً به دلیل نقش آن در همآوری ذرات خاک و تشکیل ساختمان خاک است (۴۱). هر چند افزایش بیش از حد شوری خاک می‌تواند سبب تخریب ساختمان خاک شود (۱۳). زیرا هرچه غلظت املاح در محلول خاک کمتر باشد، اثر مقدار سدیم تبدلی در پراکندگی ذرات خاک و تخریب ساختمان بیشتر می‌شود. بر اساس نتایج جدول ۲، متغیر دیگری که بر مدلسازی شاخص S اثر چشمگیری دارد، ظرفیت زراعی است. بدیهی است که ظرفیت زراعی و نقطه پژمردگی دائم از نقاط رطوبتی بسیار مهم خاک هستند که به دلیل قرار گرفتن آب سهل‌الوصول در حد فاصل این دو نقطه، اثر چشمگیری بر رشد گیاه دارند. ظرفیت زراعی به ویژگی‌های خاک از جمله بافت و ساختمان خاک بستگی دارد، درحالی که نقطه پژمردگی دائم تنها به سطح ویژه یا بافت خاک و

جدول ۳. ارزیابی ANN با استفاده از شاخص‌های ارزیابی مختلف

Data	RMSE	GMER	R ²
Testing	$4/54 \times 10^{-4}$	$0/99 \times 10^{-4}$	0/78
Training	$2/52 \times 10^{-4}$	$1/013 \times 10^{-4}$	0/86

RMSE (Root Mean Square Error), GMER (Geometric Mean Error Ratio)

داده شد که الگوریتم هیبرید مذکور در مهندسی علوم خاک و مدیریت آن می‌تواند مفید واقع شود (۴۹).

بررسی اهمیت متغیرها با استفاده از آنالیز حساسیت

به منظور تعیین درجه اهمیت هر کدام از ویژگی‌های استخراج شده از فرایند انتخاب ویژگی، آنالیز حساسیت انجام شد. بر اساس نتایج حاصل، شاخص S بیشترین حساسیت را به چگالی ظاهری خاک دارد. این نتایج با مشاهدات جو و پراسانا (۲۵) همخوانی دارد. دلیل این موضوع می‌تواند ارتباط نزدیک ساختمان و چگالی ظاهری خاک باشد. نتایج شکل ۳ همچنین نشانگر تأثیر بیشتر درصد شن نسبت به درصد رس بر شاخص S است. دلیل این امر احتمالاً مربوط به مقدار خیلی بیشتر شن در خاک‌های منطقه و تأثیر بیشتر آن بر شاخص S است. میزان رس در یک دامنه مشخص سبب افزایش شاخص S شده و اگر از حد آستانه (۵۰ درصد) بیشتر شود، شاخص S کاهش پیدا می‌کند (۱۵). یکی از دلایلی که در اثبات تأثیر یک ویژگی بر مدل‌سازی متغیر هدف می‌توان ذکر کرد، تغییرپذیری آن ویژگی است. هرچه تغییرپذیری ویژگی بیشتر باشد، اثر آن روی مدل‌سازی متغیر هدف بیشتر خواهد بود. از آنجا که تغییرپذیری درصد شن در خاک بالا است (جدول ۲)، بنابراین نقش مؤثری در مدل‌سازی متغیر هدف دارد. ظرفیت زراعی به عنوان پنجمین متغیر بود که روی مدل‌سازی شاخص S اثر چشمگیری داشت. بنابراین از آنجا که ظرفیت زراعی به خواص ساختمانی خاک بستگی دارد، می‌تواند به عنوان یکی از پارامترهای مهم در برآورد غیرمستقیم کیفیت فیزیکی خاک معرفی شود. از بین پنج ویژگی انتخاب شده، طبق نتایج آنالیز حساسیت (شکل ۳)، کمترین اثر را شوری خاک بر شاخص S داشت. اگرچه شوری بر ساختمان خاک

است. این نتایج با نتایج برخی پژوهش‌ها همخوانی دارد. از جمله (۲۲) به منظور پیش‌بینی مقدار رطوبت خاک، با مقایسه سه مدل، گزارش داد که ANN به دلیل RMSE کمتر نسبت به دو مدل دیگر از دقت بالاتری برخوردار است. شاخص دیگری که برای ارزیابی کارایی شبکه عصبی استفاده شد، GMER بود (جدول ۳). هرچه GMER به عدد یک نزدیک‌تر باشد، نشان‌دهنده این است که مدل بهتر برآزش یافته است و دقت بالاتری دارد. دلیل استفاده از شاخص GMER در این پژوهش ارجحیت آن نسبت به برخی دیگر از شاخص‌ها است. اگر مقدار GMER کمتر یا بیشتر از یک باشد به ترتیب نشان دهنده کم‌برآورد یا بیش‌برآورد مدل است. همان‌طور که از جدول ۳ استنباط می‌شود، در داده‌های آموزشی، بیش‌برآورد جزئی و در داده‌های آزمایشی، کم‌برآورد جزئی رخ داده است. این نتایج با نتایج پژوهش‌های برخی از پژوهشگران مطابقت دارد. به طوری که براساس نتایج (۲۵) در پیش‌بینی مقدار رطوبت خاک و نقاط مختلف منحنی مشخصه رطوبتی خاک با استفاده از شبکه عصبی مصنوعی، مقدار GMER کمتر از یک به دست آمده بود که نشان‌دهنده مقدار جزئی کم‌برآورد در مقادیر پیش‌بینی است. همچنین نتایج نشان داد که مدل‌سازی شاخص S، به عنوان یکی از شاخص‌های کیفیت فیزیکی خاک، با استفاده از متغیرهای زودیافت خاک دارای R² بالایی است که می‌تواند نشان‌دهنده دقت بالای مدل‌سازی باشد (جدول ۳). دقت بالای شبکه عصبی مصنوعی توسط بسیاری از پژوهشگران به اثبات رسیده است. به عنوان مثال، (۲) و (۴۰) نشان دادند که تخمین پارامتر خروجی با استفاده از ANN دقت بیشتری نسبت به رگرسیون خطی دارد. از طرفی، با ارائه یک روش جدید حاصل از ترکیب شبکه عصبی مصنوعی و آنالیز موجک برای شبیه‌سازی مقدار آب خاک نشان



شکل ۳. آنالیز حساسیت ویژگی‌های ورودی با استفاده از انتخاب ویژگی

طرفی با بررسی ویژگی‌های مؤثر بر شاخص S مشخص شد که مؤثرترین ویژگی اثرگذار بر شاخص S، چگالی ظاهری است که متأثر از بافت و ساختمان خاک است. مشاهده شد که بافت خاک از عوامل اثرگذار بر شاخص S است. نتایج نیز نشان داد که درصد شن و رس به‌عنوان ویژگی‌های اصلی در مدل‌سازی شاخص S انتخاب شدند. در نتیجه به‌عنوان یک ویژگی برای بررسی ساختمان و همچنین کیفیت خاک مناسب است. همچنین ECEc کمترین اثر را بر مدل‌سازی شاخص S دارد که احتمالاً به‌دلیل نوع تأثیری است که بر ساختمان خاک دارد. بنابراین با وجود بیش‌برآورد جزئی در داده‌های آموزشی و کم‌برآورد جزئی در داده‌های آزمایشی، روش مورد استفاده در مدل‌سازی شاخص S مناسب است. زیرا بین مقادیر اندازه‌گیری شده و پیش‌بینی شده شاخص S، همبستگی بالایی وجود دارد.

تأثیرگذار است، اما نتایج نشان داد که در مقایسه با ویژگی‌های مانند بافت و چگالی ظاهری خاک، از اهمیت کمتری از نظر تأثیر بر شاخص S برخوردار است.

نتیجه‌گیری

منحنی مشخصه رطوبتی خاک از ویژگی‌های مهم هیدرولیکی خاک است که نقاط مختلف آن از جمله شیب در نقطه عطف در مسائل مربوط به کیفیت فیزیکی خاک از اهمیت ویژه‌ای برخوردارند. به‌طوری که ویژگی‌هایی که از الگوریتم SA-ANN به‌عنوان ویژگی‌های مؤثر بر شاخص S استخراج شدند، قابل تفسیر و منطقی هستند. نتایج این پژوهش نشان داد که با افزایش تعداد ویژگی‌ها، دقت مدل‌سازی و سرعت یادگیری الگوریتم ابتدا افزایش و سپس کاهش می‌یابد. بنابراین افزایش تعداد ویژگی‌ها لزوماً باعث افزایش دقت مدل‌سازی نمی‌شود. از

منابع مورد استفاده

1. Alison, L. E. and C. D. Modie. 1965. Carbonate. Pp: 1379-1396. In: Black, C.A., A. L. Page., D. E. Baker, R. Ellis, D. R. Keeney, R. H. Miller and J. D. Rhoades.(Ed.), Methods of Soil Analysis. Part II, Am. Soc. Agron., Madison, WI.
2. Amini, M., K. C. Abbaspour, H. Khademi, N. Fathianpour, M. Afyuni and R. Schulin. 2005. Neural network models to predict cation exchange capacity in arid regions of Iran. *European Journal of Soil Science* 53: 748-757.
3. Anlauf, R. and P. Rehrmann. 2012. Effect of compaction on soil hydraulic parameters of vegetative landfill covers. *Geomaterials* 2: 29-36.

4. Andrews, S. S., D. L. Karlen and C. A. Cambardella. 2004. The soil management assessment framework, a quantitative soil quality evaluation method. *Soil Science Society of American Journal* 68: 1945–1962.
5. BenHur, M., I. Shainberg, D. Bakker and R. Keren. 1985. Effect of soil texture and CaCO₃ content on water infiltration in crusted soil as related to water salinity. *Irrigation Science* 6(4): 281-294.
6. Blake, G. R. and K. H. Hartge. 1986. Bulk density, pp. 363-381. In: Klute, A. (Eds.), *Methods of Soil Analysis, Part 1(Physical and Mineralogical Methods)*, Second Edition, Madison, Wisconsin USA.
7. Botula, Y. D., A. Nemes, P. Mafuka, E. Van Ranst and W. M. Cornelis. 2013. Prediction of water retention of soils from the humid tropics by the nonparametric k-nearest neighbor approach. *Vadose Zone Journal* <http://doi.org/10.2136/vzj2012.0123>.
8. Bouyoucos, G. J. 1951. A recalibration of hydrometer method for making mechanical analysis of soil. *Agronomy Journal* 43: 434-438.
9. Calonego, J. C. and C. A. Rosolem. 2011. Soil water retention and s index after crop rotation and chiseling. *Revista Brasileira de Ciencia do Solo* 35: 1927-1937.
10. Carpenter, D. R. and G.W. Chong. 2010. Patterns in the aggregate stability of Mancos Shale derived soils. *Catena* 80: 65-73.
11. Cerny, V. A. 1985. Thermodynamical approach to the traveling salesman problem, an efficient simulation algorithm, *Journal of Optimization Theory and Applications* 45: 41-51.
12. Chandrashekar, G. and F. Sahin. 2014. A survey on feature selection methods. *Computers and Electrical Engineering* 40: 16–28.
13. Cucci, G., G. Lacolla, M. Pagliai and N. Vignozzi. 2015. Effect of reclamation on the structure of silty-clay soils irrigated with saline-sodic waters. *International Agrophysics Journal* 29: 23-30.
14. De Melo, T. M. and O. C. Pedrollo. 2015. Artificial neural networks for estimating soil water retention curve using fitted and measured data. *Applied and Environmental Soil Science* <http://doi.org/10.1155/2015/535216>.
15. Dexter, A. R. 2004a. Soil physical quality, part i, theory, effects of soil texture, density, and organic matter, and effects on root growth. *Geoderma* 120: 201-214.
16. Dexter, A. R. 2004b. Soil physical quality, part II, friability, tillage, tilth and hard-setting, *Geoderma* 120: 215-225.
17. Dexter, A. R. 2004c. Soil physical quality, part III, unsaturated hydraulic conductivity and general conclusions about S-theory. *Geoderma* 120: 227-239.
18. Dexter, A. R. and E. A. Czyz. 2007. Applications of S-theory in the study of soil physical degradation and its consequences. *Land Degredation and Development* 18(4): 369–381.
19. Doran, J. W. and T. B. Parkin. 1994. Defining and assessing soil quality. in J. W. Doran et al., *Defining soil quality for a sustainable environment. Soil Science Society of American Journal* 35: 1-21.
20. Emadodin, I., S. Reiss and R. Bork. 2009. A study of the relationship between land management and soil aggregate stability (case study near Albersdorf, Northern-Germany). *ARPN Journal of Agricultural and Biological Science* 4: 48-53.
21. Fattet, M., Y. Fu, M. Ghestem, W. Ma, M. Foulonneau, J. Nespoulous, Y. L. Bissonnais and A. Stokes. 2011. Effects of vegetation type on soil resistance to erosion, Relationship between aggregate stability and shear strength. *Catena* 87: 60-69.
22. Gorthi, S. 2011. Prediction models for estimation of soil moisture content. A thesis submitted in partial fulfillment of the requirements for the degree of Master of Science in Electrical Engineering. Utah State University Logan, Utah.
23. Harrington, P. B. and Ch.Wan. 2002. Sensitivity analysis applied to artificial neural networks, what has my neural network actually learned?. *International Journal of Interdisciplinary and Multidisciplinary Studies* 2: 1-18.
24. Hill, M. C. 1998. *Methods and Guidelines for Effective Model Calibration*. U.S. Geological Survey Water-Resources Investigations Report, 98-4005. pp. 1-98.
25. Joe, A. M. and P. R. Prasanna. 2016. Simulation of soil water retention curve using artificial neural networks with pseudocontinuous pedotransfer functions. *International Journal of Applied Engineering Research* 11(7): 4700-4706.
26. Karlen, D. L., M. J. Mausbach, J. W. Doran, R. G. Cline, R. F. Harris and G. E. Chuman. 1997. Soil quality, a concept, definition, and framework for evaluation. *Soil Science Society of America Journal* 61: 4-10.
27. Kirkpatrick, S., C. D. Gelatt and M. P. Vecchi. 1983. Optimization by simulated annealing. *Science* 220: 671-680.
28. Kotsiantis, S. B. 2011. Feature selection for machine learning classification problems: arecent overview. *Springer* 1-20.
29. Kumar, V. and S. Minz. 2014. Feature selection, a literature review. *Smart Computing Review* 4(3): 211-229.
30. Lake, H. R., A. Akbarzadeh and R. Taghizadeh Mehrjardi. 2009. Development of pedotransfer functions (PTFs) to predict soil physico-chemical and hydrological characteristics in southern coastal zones of the Caspian Sea. *Journal of Ecology and the Natural Environment* 1(7): 160-172.
31. Liu, H. and H. Motoda. 2008. *Computational Methods of Feature Selection*. Chapman and Hall/CRC, New York.
32. Manyame, C., C. L. Morgan, J. L. Heilman, D. Fatondji, B. Gerard and W. A. Payne. 2007. Modeling hydraulic

- properties of sandy soils of Niger using pedotransfer functions. *Geoderma* 141: 407–415.
33. Moncada, M. P., D. Gabriels and W. M. Cornelis. 2014. Data-driven analysis of soil quality indicators using limited data. *Geoderma* 235–236: 271–278.
 34. Matula, S., M. Mojrova and K. Spongrova. 2007. Estimation of the soil water retention curve (SWRC) using pedotransfer functions (PTFs). *Soil and Water Research* 2(4): 113–122.
 35. Obe, O. O. and D. K. Shangodoyin. 2010. Artificial neural network based model for forecasting sugar cane production. *Journal of Computer Science* 6(4): 439-445.
 36. Oscar, C. and P. Melin. 2002. Hybrid intelligent systems for time series prediction using neural networks, fuzzy logic, and fractal theory. *IEEE Transactions on Neural Networks* 13(6): 1395-1408.
 37. Parekh, F. P. and T. M. V. Suryanarayana. 2012. Impact of climatological parameters on yield of wheat using neural network fitting. *International Journal of Modern Engineering Research* 2: 3534-3537.
 38. Rasiah, V. and B. D. Kay. 1994. Characterizing changes in aggregate stability subsequent to introduction of forages. *Soil Science Society of American Journal* 58: 935-942.
 39. Richards, L. A. 1954. Diagnosis and improvement of saline and alkali soils. *Soil Science* 78(2): 8-19.
 40. Sarmadian, F. and A. Keshavarzi. 2010. Developing pedotransfer functions for estimating some soil properties using artificial neural network and multivariate regression approaches. *International Journal of Environmental and Earth Sciences* 1(1): 31-37.
 41. Shirani, H., M. Habibi, A. A. Besalatpour and I. Esfandiarpour. 2015. Determining the features influencing physical quality of calcareous soils in a semiarid region of Iran using a hybrid PSO-DT algorithm. *Geoderma* 259–260: 1–11.
 42. Song, J., D. Wang, N. Liu, L. Cheng, L. Du and K. Zhang. 2008. Soil moisture prediction with feature selection using a neural network. *Digital Image Computing, Techniques and Applications* 35: 130-136.
 43. Ternan, J. L., A. G. Williams, A. Elmes and R. Hartley. 1996. Aggregate stability of soils in central Spain and the role of land management. *Earth Surface Processes and Landforms* 21: 181-193.
 44. Van Genuchten, M. T. 1980. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils, *Soil Science Society of American Journal* 44: 892-898.
 45. Walkley, A. and I. A. Black. 1934. An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Science Society of American Journal* 37: 29–38.
 46. Wienhold, B. J., J. L. Pikul, M. A. Liebig, M. M. Mikha, G. E. Varvel, J. W. Doran and S. S. Rews. 2006. Cropping system effects on soil quality in the Great Plains, Synthesis from a regional project. *Renewable Agriculture and Food Systems* 21: 49-59.
 47. Wu, R. and H. Tiessen. 2002. Effect of land use on soil degradation in Alpine grassland soil, China. *Soil Science Society of American Journal* 66: 1648-1655.
 48. Wu, K., C. Soci, P. P. Shum and N. and I. Zheludev. 2014. Computing matrix inversion with optical networks. *Optics Express* 22(1): 295–304.
 49. Yang, J., Z. B. He, W. J. Zhao, J. Du, L. F. Chen and X. Zhu. 2016. Assessing artificial neural networks coupled with wavelet analysis for multilayer soil moisture dynamics prediction. *Science in Cold and Arid Regions* 8(2): 116-124.

Identifying the Determinant Factors Influencing S Index in Calcareous Soils of South East of Iran Using Simulated Annealing – Artificial Neural Network Hybrid Algorithm

F. AmiriMijan^{1*}, H. Shirani¹, I. Esfandiarpour¹, A. Besalatpour² and H. Shekofteh³

(Received: April 8-2018; Accepted: January 22-2019)

Abstract

Use of the curve gradient of the Soil Water Retention Curves (SWRC) in the inflection point (S Index) is one of the main indices for assessing the soil quality for management objectives in agricultural and garden lands. In this study Simulated Annealing – artificial neural network (SA-ANN) hybrid algorithm was used to identify the most effective soil features on estimation of S Index in Jiroft plain. For this purpose, 350 disturbed and undisturbed soils samples were collected from the agricultural and garden lands and then some physical and chemical soil properties including Sand, Silt, Clay percent, Electrical Conductivity at saturation, Bulk Density, total porosity, Organic Matter, and percent of equal Calcium Carbonate were measured. Moreover, the soil moisture amount was determined within the suctions of 0, 10, 30, 50, 100, 300, 500, 1000, 1500 KP using pressure plate. Then, the determinant features influencing the modeling of S Index were derived using SA-ANN hybrid algorithm. The results indicated that modeling precision increased by reducing the input variables. According to the sensitivity analysis, the Bulk Density had the highest sensitivity coefficient (sensitivity coefficient=0.5) and was identified as the determinant feature for modeling the S Index. So, since increasing the number of features does not necessarily increase the accuracy of modeling, reducing input features is due to cost reduction and time-consuming research.

Keywords: soil physical quality, feature selection, sensitivity analysis, meta-heuristic algorithms

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

2. Inter 3 GmbH - Institut for Resources management, Berlin, Germany.

3. Department of Soil Science, Faculty of Agriculture, University of Jiroft, Jiroft, Kerman, Iran.

*: Corresponding Author, Email: fahime.amiri@gmail.com