

پیش‌بینی بافت خاک با استفاده از شبکه‌های عصبی مصنوعی

الناز خان‌باباخانی^۱، علی محمدی ترکاشوند^{۲*} و محمدعلی محمودی^۳

(۱) دانشجوی کارشناسی ارشد خاکشناسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

(۲*) دانشیار گروه خاکشناسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

(۳) استادیار گروه خاکشناسی، دانشگاه کشاورزی، دانشگاه کردستان، سنندج، ایران

تاریخ دریافت: ۱۳۹۶/۰۹/۲۰ تاریخ پذیرش: ۱۳۹۷/۰۳/۱۱

چکیده:

بافت خاک یکی از مهم‌ترین ویژگی‌های خاک است که بر روی بسیاری از خصوصیات فیزیکی و شیمیایی مانند ظرفیت نگهداری آب، ظرفیت تبادل کاتیونی، حاصلخیزی خاک و تهویه خاک اثر می‌گذارد. امروزه از فناوری هوش مصنوعی مانند شبکه‌های عصبی و عصبی فازی برای حل مسائل مربوط به مدل‌سازی سیستم‌ها و فرایندها استفاده می‌شود. در این پژوهش کارایی شبکه‌های عصبی مصنوعی در پیش‌بینی بافت خاک بررسی شد. بدین منظور ۱۵۰ نمونه خاک از عمق ۱۵-۰ سانتی‌متری از حوزه آبخیز سد گاوشان در استان کردستان جمع‌آوری گردید. موقعیت جغرافیایی، ارتفاع و درصد شیب در هر نقطه ثبت شد. بافت خاک در آزمایشگاه به روش هیدرومتری اندازه‌گیری شد. با استفاده از شبکه‌های عصبی مصنوعی رابطه بین طول و عرض جغرافیایی، ارتفاع و شیب و درصد هر کدام از گروه‌های ذرات خاک با استفاده از نرم‌افزار MATLAB به دست آمد. دقت شبکه ساخته شده با استفاده از شاخص‌های آماری مانند شاخص ریشه میانگین مربعات خطا (RMSE)، شاخص نسبت خطای متوسط هندسی (GMER) و ضریب همبستگی (R) ارزیابی گردید. نتایج به دست آمده نشان داد که کارایی روش استفاده شده برای برآورد مقدار شن و رس خاک نسبتاً یکسان و برای برآورد مقدار سیلت کم‌تر بود؛ با این حال در سطح برآورد بافت خاک روش استفاده شده از کارایی بالایی برخوردار نبود.

کلید واژه‌ها: بافت خاک؛ رس؛ سیلت؛ شبکه عصبی مصنوعی؛ شن

مقدمه

طبقه‌بندی وزارت کشاورزی آمریکا (USDA) ذرات خاک به سه جزء اصلی شن، سیلت و رس تقسیم می‌شوند (علیزاده، ۱۳۸۳). بافت خاک یکی از خصوصیات است که دارای تغییرات مکانی است (Marchetti et al., 2012). آگاهی داشتن از الگوی تغییرات مکانی توزیع اندازه ذرات خاک برای توصیف تغییرات مکانی ذرات و در نهایت تهیه نقشه بافت خاک ضروری است.

خاک به عنوان جزئی از طبیعت، دارای تغییرپذیری ذاتی در نتیجه برهم‌کنش عوامل تشکیل‌دهنده آن و دارای تغییرپذیری غیرذاتی است که حاصل مدیریت کشت‌وکار، استفاده از اراضی و فرسایش است (Moghimi et al., 2014). آگاهی از نحوه تغییرپذیری ویژگی‌های خاک و عملکرد در مزارع برای دستیابی به تولید بیش‌تر، مدیریت بهتر و پایدار، ضروری به نظر می‌رسد. در سیستم

با مغز واقعی انسان، توانایی لازم را در یادگیری داشته و قادر به بکار بردن و استفاده از تجارب به دست آمده در مسائل نو و مشابهی می‌باشند. مهم‌ترین کاربرد شبکه‌های عصبی پیش‌بینی می‌باشد. در مسائلی که ایجاد ارتباط بین اطلاعات موجود مشکل است، این شبکه‌ها بسیار مؤثر هستند. شبکه‌های عصبی مصنوعی، ساختاری (شبکه‌ای) است متشکل از تعدادی واحد (نورن‌های مصنوعی) که در داخل شبکه به هم وصل شدند. هر واحد دارای یک مشخصه ورودی و خروجی می‌باشد که محاسبه یا عمل جزئی را اجرا می‌کند (جورابیان و همکاران، ۱۳۸۴).

یک شبکه عصبی آموزش دیده می‌تواند به‌عنوان مدلی برای کاربردهای خاص به‌کار رود. پیش‌بینی با یک شبکه عصبی آموزش دیده به‌طور معمول سریع‌تر از عملکرد برنامه‌های مدل‌سازی متداول است. به‌علاوه امکان کاهش و یا افزایش متغیرهای ورودی و خروجی در صورت نیاز وجود دارد. تفاوت دیگر شبکه‌ی عصبی مصنوعی با روش‌های متداول این است که شبکه عصبی را می‌توان برای پیش‌بینی بیش از دو متغیر در خروجی شبکه استفاده کرد (Hristev, 1998). مطالعات اخیر نشان داده است که استفاده از تکنیک‌های شبکه عصبی مصنوعی نیز برای پیش‌بینی بسیاری از ویژگی‌های خاک‌ها روشی کاربردی است (Ingleby and Crowe, 2001; Zhao et al., 2010).

Guo و همکاران (۲۰۱۳) برای پیش‌بینی تغییرات مقدار ماده آلی خاک از شاخص‌های توپوگرافی مانند شاخص خیزی، طول شیب، ارتفاع و داده‌های نقشه خاک استفاده کردند. آن‌ها از مدل‌های شبکه‌های عصبی مصنوعی و رگرسیون خطی چندمتغیره برای پیش‌بینی این تغییرات استفاده کردند و میزان کارایی مدل‌ها با استفاده از آماره‌های میانگین خطا (ME)، ریشه میانگین مربعات خطا (RMSE) و ضریب تبیین (R^2) ارزیابی کردند. نتایج نشان داد که کارایی شبکه‌های عصبی مصنوعی در توصیف تغییرات مقدار ماده آلی خاک بیش‌تر از رگرسیون چند متغیره خطی بود. به‌علاوه، درصد رس خاک، شاخص

روش‌های پیش‌بینی مختلفی برای تخمین پارامترهای مختلف در خاک وجود دارد که در میان آنها توابع انتقالی بیشتر استفاده می‌شود. برخی روش‌های رایج برای توسعه توابع انتقالی، رگرسیون چند متغیره و شبکه‌های عصبی مصنوعی (ANN) هستند. روش‌های رگرسیونی گوناگونی برای به‌دست آوردن توابع انتقالی به‌طور گسترده مورد استفاده قرار گرفته‌اند (Sepaskhah et al., 2000; Verecen et al., 1992).

مناسب‌ترین یا مهم‌ترین متغیرهای ورودی مدل‌ها با استفاده از رگرسیون گام به گام خطی یا پلی‌نومیل تعیین می‌شوند (Pachepsky and Rawls, 1999). مهم‌ترین پارامترهای ورودی در بسیاری از توابع انتقالی درصد گروه‌های مختلف ذرات خاک (شن، سیلت و رس) می‌باشند. توابع انتقالی می‌توانند توسط شبکه‌های عصبی مصنوعی با استفاده از نرم‌افزارهای موجود همانند نرم افزار Neurosolution ایجاد می‌شوند. یکی از مزایای توابع انتقالی ANN نسبت به توابع انتقالی حاصل از روش‌های رگرسیونی رایج آن است که آن‌ها نیاز به یک مدل رگرسیونی اولیه که داده‌های ورودی و خروجی را به هم متصل می‌کند، ندارد (Mermoud and Xu, 2006). دقت روش‌های مختلف درون‌یابی، برای متغیرهای مختلف، متفاوت است. از جمله روش‌های مختلف درون‌یابی می‌توان به روش وزن‌دهی عکس فاصله^۱، تابع اسپلاین^۲ و روش‌های زمین‌آماری که شامل روش کریجینگ و روش کوکریجینگ است اشاره کرد. به‌علاوه مطالعات اخیر نشان داده است که استفاده از تکنیک‌های شبکه عصبی مصنوعی نیز برای پیش‌بینی بسیاری از ویژگی‌های خاک‌ها روشی کاربردی است (Xu et al., 2009; Ingleby and Crowe, 2001). امروزه شبکه‌های عصبی مصنوعی به‌عنوان یک روش هوشمند پردازش داده‌ها، در شاخه‌های متفاوت علوم، کاربرد زیادی پیدا کرده‌اند. شبکه‌های عصبی مشابه

1 . Inverse Distance Weighted

2 . Spline

اولین گام در استفاده از روش‌های درونیابی نرمال‌سازی داده‌ها است که برای نرمال‌سازی داده‌ها از تبدیل باکس-کاکس با استفاده از نرم‌افزار MALAB استفاده شد.

برای شبکه عصبی، از پرسپترون چند لایه (MLP) و برای آموزش شبکه از الگوریتم آموزش پس انتشار خطای Levenberg Marquardt استفاده شد. MLP می‌تواند بیش از یک لایه پنهان داشته باشد. مطالعات زیادی نشان داده که یک لایه پنهان برای توابع غیر خطی پیچیده در شبکه عصبی برآورد بهتری نشان می‌دهد (Kisi, 2004). اما در مطالعه کنونی، تعداد متفاوتی از نورون‌ها در لایه پنهان بررسی شد. به علاوه از تابع سیگموئیدی به عنوان تابع انتقالی بین داده‌های ورودی و خروجی استفاده شد. از نرم‌افزار MATLAB برای آنالیز شبکه عصبی استفاده شد. در این پژوهش به طور تصادفی از ۷۰٪ داده‌ها برای آموزش و ۱۵٪ داده‌ها برای اعتبار سنجی و از ۱۵٪ داده‌های باقی‌مانده برای آزمون استفاده شد. متغیرهای ورودی عبارتند از طول جغرافیایی، عرض جغرافیایی، ارتفاع، درصد شیب و خروجی مدل نیز درصد ذرات بافت خاک بود.

برای ارزیابی دقت مدل از شاخص‌های ریشه میانگین مربعات خطا (RMSE)، نسبت خطای متوسط هندسی (GMER) و ضریب همبستگی پیرسون استفاده شد. RMSE نشانگر صحت تخمین است، که هرچه به صفر نزدیک‌تر شود، تخمین قابل قبول‌تر می‌شود (رابطه ۱).

$$RMSE = \sqrt{\frac{1}{N} \sum (K_p - K_m)^2} \quad (1)$$

در این فرمول، N تعداد کل نمونه‌ها، K_m مقادیر اندازه‌گیری شده، K_p مقادیر پیش‌بینی شده متغیر مورد نظر است.


نسبت خطای متوسط هندسی (GMER) بیان‌کننده وجود هماهنگی و تطابق بین مقادیر مشاهده شده و پیش‌بینی شده می‌باشد. چنانچه مقدار (GMER) برابر یک

خیزی توپوگرافیکی از مهم‌ترین شاخص‌های توپوگرافی تأثیرگذار بر تنوع ماده آلی در دو مدل بوده است.


هدف از انجام این تحقیق، ارزیابی روش شبکه‌های عصبی مصنوعی در پیش‌بینی گروه‌های مختلف ذرات خاک (شن، سیلت و رس) و در نهایت بافت خاک می‌باشد. این مطالعه در حوزه آبخیز سد گاوشان در استان کردستان انجام گرفت.

مواد و روش‌ها

منطقه مورد مطالعه حوزه آبخیز سد گاوشان در استان کردستان با مساحتی در حدود ۱۵۳۰۰۰ هکتار و در محدوده جغرافیایی ۴۶/۹۷ تا ۴۷/۹۷ درجه طول شرقی و ۴۷/۳۳ تا ۴۷/۵۴ درجه عرض شمالی قرار دارد (شکل ۱). ۱۵۰ نمونه به حجم ۵ کیلوگرم به صورت تصادفی انتخاب شدند. موقعیت محل نمونه‌برداری نقاط توسط GPS شناسایی شد. سپس در هر نقطه از افق سطحی از عمق ۰-۱۵ سانتی‌متری اقدام به نمونه‌برداری گردید. پس از هواخشک شدن نمونه‌ها و عبور از الک ۲ میلی‌متری برای تعیین بافت خاک نمونه‌ها از روش هیدرومتر استفاده شد (Gee and Bauder, 1986).




(الف)



(ب)

شکل ۱- الف) موقعیت محدوده مطالعاتی در ایران و استان کردستان و ب) پراکنش مکانی نقاط نمونه‌برداری در منطقه مورد مطالعه



شکل ۲- توزیع کلاس بافتی خاک‌های منطقه مورد مطالعه


باشد، نشان‌دهنده برازش دقیق بین داده‌های اندازه‌گیری شده و پیش‌بینی شده است و مقادیر کم‌تر یا بیش‌تر از یک به ترتیب نشان‌دهنده کم برآوردی و بیش‌برآوردی مدل می‌باشد (معادله ۲).

$$GMER = EXP \left(\frac{1}{N} \sum \ln \left(\frac{K_p}{K_m} \right) \right) \quad (2)$$

جدول ۱- برخی شاخص‌های آماری ذرات شن، سیلت و رس خاک در حوزه آبخیز سد گاوشان

پارامتر	تعداد نمونه	حداقل	حداکثر	میانگین	انحراف معیار	واریانس	ضریب تغییرات	کشیدگی	چولگی
شن (%)	150	4	5.78	76.22	12.83	164.87	56.38	1.31	2.22
سیلت (%)	150	14	63	37.90	7.86	61.90	20.75	0.492	1.136
رس (%)	150	7.5	67	39.33	11.81	139.66	30.34	-0.352	-0.149

با توجه به اینکه تعداد نورون‌ها در لایه مخفی تأثیر زیادی روی کارایی شبکه دارد، بنابراین برای حصول بهترین نتیجه از تعداد ۳، ۶ و ۷ نورون در لایه مخفی استفاده شد که بهترین نتیجه از تعداد ۳ نورون به دست آمد و بهترین شبکه براساس کم‌ترین مقدار میانگین مربعات خطا (MSE) بین مقادیر برآورد شده و اندازه‌گیری شده انتخاب شد. از آنجایی که مقادیر اولیه، وزن‌ها و اورب‌ها رو کارایی نهایی شبکه تأثیر می‌گذارد هر شبکه ۲۰ بار با مقادیر اولیه‌ی متفاوت آموزش داده شد. ساختار و توپولوژی شبکه طراحی و اجرا شده در محیط MATLAB انجام شد که در شکل ۴ نشان داده شده است.



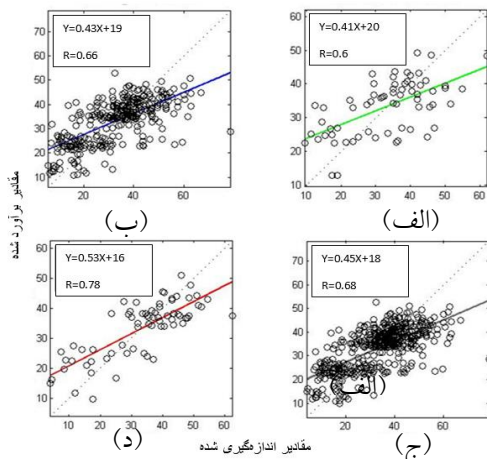
شکل ۳- ساختار و توپولوژی شبکه عصبی مصنوعی ایجاد شده

ضریب همبستگی پیرسون (R) میزان همبستگی خطی بین دو متغیر تصادفی را می‌سنجد (معادله ۳). مقدار این ضریب بین -۱ تا ۱ تغییر می‌کند که «۱» به معنای همبستگی مثبت کامل، «۰» به معنی نبود همبستگی، و «-۱» به معنی همبستگی منفی کامل است.

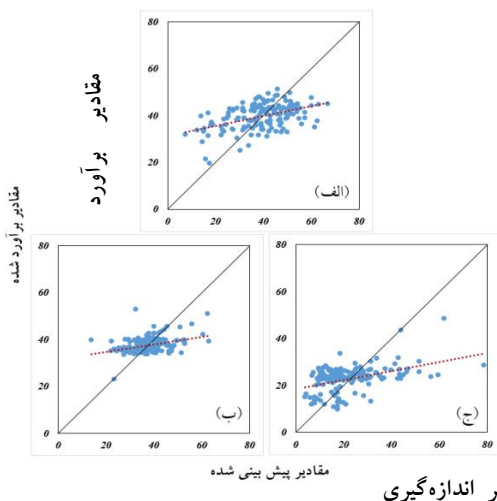
$$R = \sqrt{1 - \frac{\sum (K_m - K_p)^2}{\sum (K_m - \bar{K}_m)^2}} \quad (3)$$

نتایج و بحث

خلاصه آماری داده‌های مربوط به پارامترهای شن، سیلت و رس خاک در جدول ۱ نشان داده شده است. داده‌هایی که چولگی بالایی داشتند غیرنرمال تشخیص داده شده و برای نرمال‌سازی آنها از تبدیل باکس-کاکس استفاده شد. در مثلث بافت خاک (شکل ۳)، نتایج حاصل از توزیع کلاس بافتی خاک‌های منطقه مورد مطالعه نشان داده شده است. همانطور که مشاهده می‌شود اغلب خاک‌های منطقه مورد مطالعه سنگین بوده و بافت غالب منطقه، بافت لوم رسی و رسی می‌باشد.



شکل ۵- مقادیر اندازه‌گیری شده در مقابل برآورد شده ذرات شن، سیلت و رس (الف) داده‌های آموزش، (ب) اعتبارسنجی، (ج) آزمون و (د) کل داده‌ها



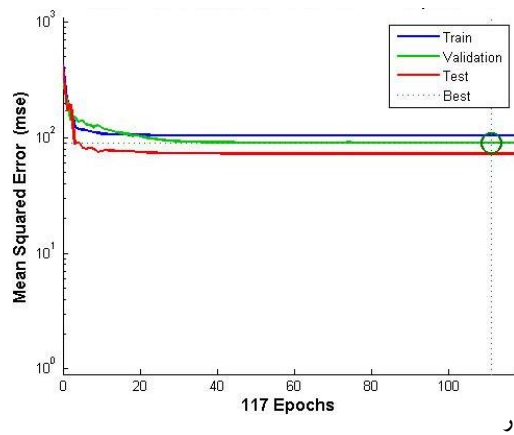
شکل ۶- پراکندگی مقادیر برآوردی در مقابل مشاهده‌ای رس (الف)، سیلت (ب) و شن (ج) منطقه مورد مطالعه را در روش شبکه‌های عصبی مصنوعی

جدول ۲- ارزیابی شبکه‌های عصبی مصنوعی در برآورد شن، سیلت و رس

پارامتر	RMSE	GMER	R
شن (%)	11.4	1.130	0.453
سیلت (%)	7.3	1.010	0.370
رس (%)	10.4	1.052	0.459

در سال‌های اخیر به موازات پیشرفت‌های سخت‌افزاری و نرم‌افزاری کامپیوتر و ارائه سامانه

همچنین در شکل ۵ تغییرات تابع هدف (میانگین مربعات خطا) برای هرکدام از داده‌های آموزش، اعتبارسنجی و آزمون در حین آموزش شبکه عصبی نشان داده شده است. بطوریکه ملاحظه می‌شود پس از ۱۱۵ تکرار فرآیند یادگیری مدل شبکه عصبی ایجاد شده کامل شده است. همچنین برای شبکه عصبی آموزش یافته مجموع مربعات خطای داده‌های اعتبارسنجی و آزمون کم‌تر از داده‌های آموزش است که خود بیانگر قدرت بالای تعمیم‌پذیری شبکه عصبی ایجاد شده است.



شکل ۴- تغییرات تابع هدف (میانگین مربعات خطا) برای داده‌های آموزش، اعتبارسنجی و آزمون

در شکل ۶ مقادیر اندازه‌گیری شده در برابر برآورد شده ذرات شن، سیلت و رس برای داده‌های آموزش، اعتبارسنجی، آزمون و کل داده‌ها در شبکه عصبی مصنوعی نشان داده شده است. شکل ۷ پراکندگی مقادیر برآوردی در مقابل مشاهده‌ای شن، سیلت و رس منطقه مورد مطالعه را در روش شبکه‌های عصبی مصنوعی نشان می‌دهد. بدیهی است هرچه خط حاصل از برازش داده‌های مشاهده‌ای و پیش‌بینی شده به خط یک به یک نزدیک‌تر باشد، دقت مدل ایجاد شده بیشتر است. جدول ۲، ارزیابی روش شبکه‌های عصبی مصنوعی را در تعیین پراکندگی شن، سیلت و رس خاک را براساس شاخص‌های ارزیابی نشان می‌دهد.

چندگانه استفاده کرده‌اند. پارامترهای ورودی این معادلات درصد هر کدام از اجزاء شن و رس به علاوه مقدار ماده آلی خاک و جرم مخصوص ظاهری می‌باشد.

Schaap و همکاران (۱۹۹۹) نیز برای تخمین منحنی رطوبتی خاک از ترکیب بافتی شامل درصد اجزاء شن، سیلت و رس استفاده کرده‌اند. همچنین برخی از محققین برای تخمین ظرفیت تبادل کاتیونی (CEC) خاک‌ها از توابع انتقالی استفاده کرده‌اند. این توابع نیز عموماً از ترکیب بافتی و مقدار ماده آلی به عنوان پارامترهای ورودی برای برآورد CEC استفاده کرده‌اند (Bayat et al., 2014).

بسیاری از ویژگی‌های خاک از جمله توزیع اندازه ذرات آن دارای تغییرات مکانی است به این معنی که این خصوصیات با مکان تغییر می‌کنند (Marchetti et al., 2012). آگاهی داشتن از الگوی تغییرات مکانی خصوصیات خاک برای توصیف تغییرات مکانی خصوصیات خاک ضروری است. ناهمگونی خصوصیات خاک را می‌توان با نمونه‌برداری ناپیوسته از خاک تخمین زد. سپس با استفاده از تکنیک‌های درون‌یابی مقادیر خصوصیات در هر نقطه تخمین زده شده و نقشه پیوسته‌ای از خصوصیات خاک به دست می‌آید (Peng-Tao et al., 2013).

بسیاری از خصوصیات خاک می‌تواند تحت تأثیر موقعیت یک منطقه، اقلیم و توپوگرافی قرار گیرد که خود این شاخص‌ها با یکدیگر در ارتباطند. به همین منظور در این مطالعه، همبستگی مکانی ذرات خاک و برآورد این ذرات به کمک موقعیت و توپوگرافی منطقه بررسی شد. مطالعه مشابهی نیز توسط (Xu et al., 2009) برای برآورد کربن آلی خاک با استفاده از خصوصیات توپوگرافی انجام شده است. طبق نتایج، دقت و صحت روش پایین بود، طوری که همبستگی برای هر سه ذره شن، سیلت و رس کم‌تر از ۵۰ درصد بود و نشان می‌دهد که شبکه عصبی نتوانسته با داده‌های ورودی تخمین مناسبی از اجزاء بافت

اطلاعات جغرافیایی توجه و علاقه‌مندی به پردازش و مدل‌سازی داده‌های مکانی افزایش یافته است. برای اشتقاق توابع انتقالی از روش‌های رگرسیونی و شبکه‌های عصبی مصنوعی استفاده می‌شود. شبکه‌های عصبی روش‌های هوشمند مدل‌سازی هستند که همانند سیستم عصبی انسان عمل می‌کنند این شبکه‌ها توانایی یادگیری تعمیم و تحلیل اطلاعات را دارند. مزیت اصلی شبکه‌های عصبی در این است که برخلاف روش‌های رگرسیونی نیازی به ارتباط از پیش تعیین شده‌ای میان داده‌های ورودی و داده‌هایی که قرار است پیش‌بینی شوند ندارند. روش‌های رگرسیونی، روش‌های ریاضی هستند که نیاز دارند ارتباط میان داده‌های ورودی و داده‌هایی که قرار است پیش‌بینی شوند از قبل مشخص باشد.

شبکه عصبی مصنوعی که یکی از روش‌های نوظهور در حل مسائل مهندسی است، ابزاری قدرتمند و مؤثر در شبیه‌سازی سیستم‌های غیرخطی است (Kumar et al., 2004) و ساختاری ریاضی‌گونه دارد که عملکرد آن شبیه عملکرد مغز انسان است. شبکه‌های عصبی مصنوعی در واقع مدل ساده‌شده‌ای از مغز انسان بوده که یکی از ابزارهای پیش‌بینی پدیده‌های فیزیکی است و به‌طور کاربردی نخستین بار در دهه ۵۰ قرن بیستم مطرح شد، زمانی که روزنبلات (۱۹۵۸) شبکه پرسپترون را معرفی کرد (منهاج، ۱۳۸۸).

از آنجایی که خاک یک سیستم طبیعی و ناهمگن است، ایجاد ارتباط میان خصوصیات آن تا حدی دشوار می‌باشد از این رو در این سیستم‌ها، شبکه‌های عصبی مصنوعی کارآتر از روش‌های رگرسیونی عمل می‌کند به عنوان مثال Schaap و همکاران (۱۹۹۹) و Tamari و همکاران (۱۹۹۶) نشان داده‌اند که شبکه‌های عصبی مصنوعی در تخمین ویژگی‌های هیدرولیکی خاک از عملکرد بهتری نسبت به روش‌های رگرسیونی برخوردار می‌باشند. Vereecen و همکاران (۱۹۹۲) برای تخمین منحنی رطوبتی خاک از یک معادله رگرسیونی خطی

نتیجه‌گیری

در این پژوهش کارایی روش شبکه‌های عصبی مصنوعی در پیش‌بینی بافت خاک بررسی شد همچنین با استفاده از شاخص‌های آماری مانند شاخص ریشه میانگین مربعات خطا (RMSE)، شاخص نسبت خطای متوسط هندسی (GMER) و ضریب همبستگی (R) دقت این روش ارزیابی گردید و در نهایت نتایج نهایی براساس شاخص‌های آماری نشان داد که کارایی و دقت روش شبکه عصبی مصنوعی در برآورد پراکنش مکانی ذرات شن، سیلت و رس خاک منطقه مورد مطالعه از دقت بالایی برخوردار نبود.

خاک (درصد شن، سیلت و رس) داشته باشد. شاید مهم‌ترین دلیلی که برای این موضوع بتوان بیان نمود، سری داده‌های ورودی است. اگر چه موقعیت جغرافیایی مناطق مختلف جهان می‌تواند بر نوع خاک و حتی بافت خاک اثرگذار باشد، مثل خاک‌های تکامل‌یافته رسی در مناطق استوایی حاره، اما نتایج تحقیق نشان داد که ارتباط دقیقی بین موقعیت جغرافیایی نقاط و بافت خاک وجود ندارد. همچنین شاخص ارتفاع و شیب نیز به همراه موقعیت جغرافیایی نقاط نمونه‌برداری نتوانسته دقت مدل شبکه عصبی در برآورد درصد ذرات خاک را افزایش دهد.

منابع مورد استفاده

- جورابیان، م.، زارع، ط. و استوار، ا. ۱۳۸۴. شبکه‌های عصبی مصنوعی. (ترجمه). انتشارات دانشگاه شهید چمران اهواز. ۷۱۶ صفحه.
- علیزاده، ا. ۱۳۸۳. فیزیک خاک. انتشارات دانشگاه فردوسی. شماره نشر ۳۵، ۴۵۳ صفحه.
- منهاج، م.ب. ۱۳۸۸. هوش مصنوعی (جلد اول): مبانی شبکه‌های عصبی. انتشارات دانشگاه صنعتی امیر کبیر، ۷۱۵ صفحه.
- Bayat, H., Davatgarand, N., and Jalali, M. 2014. Prediction of CEC using fractal parameters by artificial neural networks. *International Agrophysics*, 28: 143-152
- Gee, G.W. and Bauder, J.W. 1986. Particle-size analysis. In Klute, A. (ed.) *Methods of Soil Analysis. Part 1. Physical and Mineralogical Methods*. 2nd Edition. Agronomy No. 9. ASA and SSSA, Madison, WI. pp. 383-411
- Guo, P.T., Wu, W., Sheng, Q.K., Li, M.F., Liu, H.B. and Wang, Z.Y. 2013. Prediction of soil organic matter using artificial neural network and topographic indicators in hilly areas. *Nutrient Cycling in Agroecosystems*, 95, 333-344.
- Hristev, R.M. 1998. *The ANN Book*. GNU Public License. USA 169 pp.
- Ingleby, H.R., and Crowe T.G. 2001. Neural network models for predicting organic matter content in Saskatchewan soils. *Canadian Biosystems Engineering*. 43:71-75.
- Kisi, Ö. 2004. Multi-layer perceptrons with Levenberg-Marquardt training algorithm for suspended sediment concentration prediction and estimation. *Hydrology Science Journal*, 49(6):1025-1040.
- Kumar, D.N., Raju, K.S. and Sathish, T. 2004. River flow forecasting using recurrent neural networks. *Water Research Management*. 18: 143-161.
- Marchetti, A., Piccini, C., Francaviglia, R. and Mabit, L. 2012. Spatial Distribution of Soil Organic Matter Using Geostatistics: A Key Indicator to Assess Soil Degradation Status in Central Italy. *Pedosphere*, 22(2): 230-242.
- Mermoud, A. and Xu, D., 2006. Comparative analysis of three methods to generate soil hydraulic functions. *Soil and Tillage Research*, 87:89-100.
- Moghimi, S., Mahdian, M.H., Parvizi, Y and Masihabadi, M.H. 2014. Estimating effects of terrain attributes on local soil organic carbon content in a semi-arid pastureland. *Journal of Biodiversity and Environmental Sciences*. 5(2): 67-106.

- Pachepsky, Y. and Rawls, W.J., 1999. Accuracy and reliability of pedotransfer functions as affected by grouping soils. *Soil Science Society American Journal*, 63:1748-1757.
- Peng-Tao G., Wei W., Qing-Kai S., Mao-Fen L., Hong-Bin L. and Zheng-Yin W. 2013. Prediction of soil organic matter using artificial neural network and topographic indicators in hilly area. *Springer Science Business Media Dordrecht*, 95:333-344.
- Schaap, M.G. and F.J. Leij. 1999. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil and Tillage Research*, 47: 37-42.
- Sepaskhah, A.R. and Moosavi, S.A.A. and Boersma, L., 2000. Evaluation of fractal dimension for analysis of aggregate stability. *Iran Agriculture Research*, 19: 99-114.
- Tamari, S., Wosten J.H.M. and Ruiz-Suarez, J.C. 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Science Society American Journal*, 60: 1732-1741.
- Verecen H., Dielst, J., van Orshoven, J., Feyen, J. and Bouma, J., 1992. Functional evaluation of pedotransfer functions for the estimation of soil hydraulic properties. *Soil Science Society American Journal*, 56:1371-1378.
- Xu, Z.X., Pang, J.P., Liu, C.M., and Li, J.Y. 2009. Assessment of runoff and sediment yield in the Miyun Reservoir catchment by using SWAT model. *Hydrology Processes*. 23(25): 3619-3630.
- Zhao, Z., Yang, Q., Benoy, G., Chow, T.L., Xing, Z., Rees, H.W. and Meng, F.R. 2010. Using artificial neural network models to produce soil organic carbon content distribution maps across landscapes. *Canadian Journal of Soil Science*. 90(1) 75-87.



ISSN 2251-7480

Prediction of soil texture using artificial neural networks

Lnaz khanbabakhani¹, Ali Mohammadi Torkashvand^{2*} and Mohammad Ali mohmoodi³

1) M.Sc. Student, Department of Soil Science, Science and Research Branch, Islamic Azad University, Tehran, Iran.

2*) Associate Professor, Department of Soil Science, Science and Research Branch, Islamic Azad University, Tehran, Iran.

* Corresponding author: m.torkashvan54@yahoo.com.

3) Assistant Professor, Department of Soil Science, Agriculture Faculty, University of Kordestan, Sannandaj, Iran.

Received: 11-12-2017

Accepted: 01-06-2018

Abstract

Soil texture is one of the most important soil properties that affect many physico-chemical properties such as water storage, cation exchange capacity (CEC), soil fertility and soil ventilation. Today, artificial intelligence technology such as neural and neuro-fuzzy networks is used to solve problems in modeling systems and processes. For this purpose, 150 soil samples from a depth of 0 - 15 cm of Gavshan Dam watershed in the Kurdistan province were collected. The geographic locations, height and slope percent of every sampling point were recorded. The particle size distribution of samples was measured in the laboratory using hydrometer method. The longitude and latitude, height, slope percent and soil texture particles of training points were introduced to artificial neural networks to estimate soil texture particles by MATLAB software. The accuracy of model was evaluated by scoring, using statistical indicators such as root mean square error (RMSE), the ratio of geometric mean error (GMER) and correlation coefficient (R^2). According to the results, the values for estimating sand and clay are approximately the same and for predicting the silt, less than sand and clay, and 37.0, although less error. The accuracy and accuracy of the model show that the neural network does not have any accuracy and accuracy in estimating the percentage of soil texture components and the soil texture mapping.

Keywords: Artificial neural networks, Clay, Sand, Silt, Soil texture